

# Statistische Methoden der Datenanalyse

Markus Schumacher

## Übung XI

Matthew Beckingham und Henrik Nilsen

21 .01.2010

### Computerübung

#### Aufgabe 43 *Entdeckung eines neuen Teilchens*

Betrachtet wird folgendes Szenario: Eine Theorie sagt die Existenz eines neuen Teilchens mit einer Masse von  $m_0 = 8 \text{ GeV}$  vorher, welches im Experiment als eine resonante Überhöhung über einem exponentiell verteilten Untergrund ( $\tau = 10 \text{ GeV}$ ) beobachtet werden könnte. Die Wahrscheinlichkeitsdichtefunktion für den Untergrund sei also eine Exponentialverteilung, und die für das Signal eine Gaussfunktion mit Mittelwert  $8 \text{ GeV}$  und Standardabweichung  $0,5 \text{ GeV}$ , da wir weiterhin annehmen, dass die durch die Detektoraufösung beobachtete Breite der Resonanz – sofern sie existiert –  $0,5 \text{ GeV}$  betrage. Des weiteren sagt unsere bisherige Standardtheorie eine Gesamtanzahl von Untergrundeignissen von  $N_{\text{UG}} = 10000$  voraus, sowie unsere neue Theorie  $N_{\text{Sig}} = 175$  Signalereignisse. Im folgenden soll mittels der Neymann-Pearson-Lemma, die in der Vorlesung besprochen wurde, die Sensitivität des Experiments auf eine eventuelle Entdeckung untersucht werden. Die Werte  $Q$  ist definiert über das Verhältnis

$$Q = \frac{L(\vec{x}|H_1)}{L(\vec{x}|H_0)}, \quad (1)$$

wobei  $\vec{x}$  die beobachteten Daten,  $L$  die unter der betreffenden Hypothese Likelihoodfunktion,  $H_0$  die „nur-Untergrund“ Hypothese und  $H_1$  die „Signal und Untergrund“ Hypothese sind. Zumeist wird dann die Größe

$$q = -2 \ln Q \quad (2)$$

betrachtet.

Im folgenden soll die Monte-Carlo-Methode benutzt werden, um das Pseudoexperiment einerseits nur mit Untergrund, andererseits auch mit Signal- und Untergrund durchzuführen. Mittels dieses Pseudoexperimentes können dann die Verteilungen von  $q(\vec{x}_{\text{UG}}) \equiv q_0$  und von  $q(\vec{x}_{\text{Sig.}+\text{UG}}) \equiv q_1$  erzeugt werden, um festzustellen, wie sensitiv das Experiment auf das vorhergesagte neue Teilchen ist.

In dem Makro `SigPlusBg_i.C` finden Sie den Anfang des Skriptes, welches Sie benötigen, um die Verteilungen für  $q_0$  und  $q_1$  zu berechnen. Gehen Sie wie folgt vor, um es zu vervollständigen:

- (i) Erstellen Sie zur Durchführung von 1000 Pseudoexperimenten eine Schleife.
- (ii) Berechnen Sie für jedes Pseudoexperiment eine Anzahl an Signal- und Untergrundeignissen, verteilt nach einer Poisson-Statistik mit Erwartungswerten von  $N_{\text{Sig}} = 175$ , beziehungsweise  $N_{\text{UG}} = 10000$ . Verwenden Sie zum Beispiel die Funktion

```
gRandom->Poisson(nBg);
```

um eine poissonverteilte Variable zu erhalten.

- (iii) Erstellen Sie eine Schleife über alle Signalereignisse, in welcher Sie einen Satz von Variablen der Signal WDF  $\vec{x}_{\text{Sig}}$  erstellen. Füllen Sie diese einerseits in ein Histogramm der Massenverteilung der Signalereignisse und gleichsam in eines für die Massenverteilung der Ereignisse von Signal + Untergrund.

- (iv) Erstellen Sie eine zweite Schleife über die Anzahl der Untergrundereignisse und erstellen Sie ebenfalls einen Satz von Variablen der Untergrund WDF  $\vec{x}_{UG}$ . Diese füllen Sie nun analog in ein Histogramm der Massenverteilung der Untergrundereignisse und in das Histogramm für Signal + Untergrund aus dem letzten Teilabschnitt.
- (v) Berechnen Sie den Wert von  $q$  jeweils für die reine Signal- und Untergrundverteilung. Hierzu müssen Sie eine Schleife über jedes Bin des Histogramms in dem Bereich  $m_0 - 2\sigma < m < m_0 + 2\sigma$  erstellen und

$$q = \sum_{Bin_{min}}^{Bin_{max}} -s_i + n_i \ln \left( 1 + \frac{s_i}{b_i} \right) \quad (3)$$

berechnen, wobei  $n_i$  für die Zahl an Ereignissen in Bin  $i$  des Histogramms des Pseudoexperimentes steht, und  $s_i$  und  $b_i$  die theoretischen Vorhersagen bezeichnen, wie viele Signal- und Untergrundereignisse in Bin  $i$  zu erwarten wären. Die Gesamtzahl an Ereignissen im Bereich  $m_0 - 2\sigma < m < m_0 + 2\sigma$  der theoretischen Annahme ist gegeben durch  $s$ .

Sie können die Nummer des kleinsten Bins des Schleifenbereichs finden mit der Funktion

```
dataSigHist->FindBin(peakPos - 2.0* peakWidth)
```

Die Zahl an Einträgen in Bin  $i$  des Massenhistogramms erhalten Sie durch

```
dataBgHist->GetBinContent(i);
```

Die Zahl an theoretisch erwarteten Einträgen, beispielsweise an Signalereignissen, kann bestimmt werden durch

```
nSig * funkSig->Integral(dataSigHist->GetBinLowEdge(i),
dataSigHist->GetBinLowEdge(i+1))
```

- (vi) Füllen Sie die Werte von  $q_0$  und  $q_1$  für jedes Pseudoexperiment in Histogramme. Den Code um diese Histogramme zeichnen zu lassen finden Sie am Ende des Makros.
- (vii) Welchen Wert würden Sie als kritischen Wert von  $q$  setzen?

#### Aufgabe 44 Vergleich von Messungen einer gaussverteilter Variablen

Betrachten Sie den Fall, Sie hätten einen Satz von  $N$  Messungen einer gaussverteilten Variablen  $\vec{x} = (x_1, x_2, \dots, x_N)$  aufgenommen, wobei  $\vec{x}$  gemäß  $f_G(x; \mu_0, \sigma_0)$  verteilt sei. In dem vorliegenden Beispiel sollen Sie zwei verschiedene Hypothesentests betrachten, um sowohl Mittelwert als auch Varianz Ihrer Messungen mit der erwarteten Verteilung  $f_G(x; \mu_0, \sigma_0)$  zu vergleichen.

Das Makro `HypoTest_i.C` beinhaltet Code, welcher einen Satz von  $M$  Experimenten generiert, jeweils mit  $N$  Messungen einer gaussverteilten Variablen. Jede Messung wird anschließend in ein Histogramm gefüllt, welches am Ende angezeigt wird.

- (i) Vergleichen Sie zuerst den Mittelwert der generierten Messdaten mit der Gaussverteilung, welche Sie dazu verwendeten, die Messungen zu erstellen.
  - a) Nehmen Sie an, Sie kennen Mittelwert  $\mu$  wie auch  $\sigma$  der Gausskurve, welche sie zur Generierung der Daten benutzten. Um zu prüfen, ob Ihre Daten den Mittelwert  $\mu = \mu_0$  besitzen, berechnen Sie für jedes Experiment die Teststatistik

$$t = \frac{\bar{x} - \mu_0}{\sigma/\sqrt{N}} \quad (4)$$

und füllen Sie dies in ein Histogramm. Diese Variable sollte nach der gaussischen WDF  $f_G(t; 0, 1)$  verteilt sein. Überzeugen Sie sich davon, indem Sie die Methode:

```
hist->Fit("gaus");
```

verwenden, um eine Gaussverteilung in Ihr Histogramm von  $t$  zu fitten.

- b) Nehmen Sie nun an, Sie würden lediglich den Mittelwert  $\mu$ , jedoch nicht die Breite der den Messungen zugrunde liegenden Gaussverteilung kennen. Folglich prüfen Sie, ob Ihre Daten den Mittelwert  $\mu = \mu_0$  besitzen, indem Sie für jedes Experiment die Teststatistik

$$t' = \frac{\bar{x} - \mu_0}{s/\sqrt{N}} \quad (5)$$

berechnen, wobei die Standardabweichung  $s$  gegeben ist durch

$$s^2 = \frac{1}{N-1} \sum (x_i - \bar{x})^2 = \frac{1}{N-1} (\overline{x^2} - N\bar{x}^2) \quad (6)$$

Füllen Sie Ihre Werte von  $t'$  in ein Histogramm. Die Variable  $t'$  sollte entsprechend einer Studentischen  $t$ -Verteilung  $f_t(t; N-1)$  mit  $N-1$  Freiheitsgraden verteilt sein. Überzeugen Sie sich analog davon, dass dies der Fall ist, indem Sie eine Studentische  $t$ -Verteilung in Ihr Histogramm fitten. Verwenden Sie

```
TF1* tFit = new TF1("tFit", "[1]*TMath::Student(x, [0])", -50., 50.);
```

um einen Fit in Form einer studentischen  $t$ -Verteilung zu definieren. Der [0]te Parameter steht für die Zahl an Freiheitsgraden. Der Methodenaufruf

```
hist->Fit("tFit");
```

fittet oben genannte Verteilung in das  $t'$ -Histogramm.

- (ii) Als nächstes vergleichen Sie die Breite der generierten Daten mit der der Gaussverteilung, welche Sie verwendet haben, um die Messungen zu erstellen.

- a) Gehen Sie davon aus, Sie würden einzig den Mittelwert  $\mu$ , jedoch nicht die Breite der den Daten zugrundeliegenden Gaussverteilung kennen. Um nun zu prüfen, ob Ihre Daten die Breite  $\sigma = \sigma_0$  aufweisen, berechnen Sie für jedes Experiment die Teststatistik

$$t'' = \frac{(n-1)s^2}{\sigma_0^2} \quad (7)$$

und füllen Sie dies in ein Histogramm. Die Variable  $t''$  sollte nach einer  $\chi^2$  WDF  $f_{\chi^2}(t; N-1)$  mit  $N-1$  Freiheitsgraden verteilt sein. Überzeugen Sie sich davon, dass dies der Fall ist, indem Sie eine  $\chi^2$ -Verteilung in Ihr Histogramm fitten. Verwenden Sie

```
TF1* tChi2Fit = new TF1("tChi2Fit", "[0]*(1.0/(TMath::Power(2, [1]/2.0)
*TMath::Gamma([1]/2.0)))*TMath::Power(x, ([1]/2.0)-1.0)
*TMath::Exp(-x/2.0)", 0., 50.);
```

um die Fitfunktion einer  $\chi^2$ -Verteilung zu definieren. Der [0]te Parameter steht für den Normierungsfaktor und der [1]te für die Anzahl an Freiheitsgraden. Mit

```
hist->Fit("tChi2Fit");
```

fitten Sie anschließend eine  $\chi^2$ -Verteilung in Ihr Histogramm von  $t''$ .

- (iii) Wie verändern sich die Verteilungen von  $t$ ,  $t'$  und  $t''$ , wenn Sie einen systematischen Fehler hinzufügen, welcher alle Messungen um einen Wert von 1 erhöht, in der Art  $\vec{x} \rightarrow \vec{x}' = (x_1 + 1, x_2 + 1, \dots, x_N + 1)$ ?
- (iv) Wie verändern sich die Verteilungen von  $t$ ,  $t'$  und  $t''$ , wenn Sie einen gaussischen Fehler mit Standardabweichung  $\sigma = 0.1$  zu allen Messungen hinzufügen?