



# Moderne Methoden der Datenanalyse

**Ralf Ulrich, Andreas Meyer**

Institut für Kernphysik, Institut für Experimentelle Kernphysik

Master-Kurs SS 2017




# Themen, Volesungsprogramm

- Einführung: Überblick und grundlegende Konzepte (1)
- Einführung: Überblick und grundlegende Konzepte (2)
- Zufallszahlen und Monte-Carlo Methoden
- **Hypothesentests (1)**      ← Heute
- **Parameterschätzung**
- **Parameterschätzung (Goodness-of-fit)**
- **Optimierungs- und Parametrisierungsmethoden**
- Konfidenzintervalle
- Hypothesentests (2)
- Klassifikation
- Klassifikation
- Klassifikation
- Messen und Entfalten
- Systematische Unsicherheiten

# Fällen von Entscheidungen

## ■ Beispiele:

- Ist das beobachtete Teilchen ein Pion?
- Ist die gemessene Zerfallszeitverteilung einer radioaktiven Substanz eine Exponentialverteilung?
- Existiert „*neue Physik*“?



**C. Anderson 1932**

Welche Hypothesen könnten die Beobachtung im Prinzip erklären, und sind diese konsistent mit den Daten.

Science 76 (1932) 238  
<http://inspirehep.net/record/47921>

- Statistische Formulierung in Form von Hypothesen:

$H_i$

**Wahrscheinlichkeitsdichten für Daten:**

$f(x|H_i)$

# Hypothesen

**Einfache Hypothese** spezifiziert Wahrscheinlichkeitsdichte vollständig:

$$f(x | H(\lambda_i)), \text{ alle } \lambda_i \text{ bekannt}$$

z.B. „Daten folgen einer Poisson-Verteilung mit  $\nu=3,5$ “

**Zusammengesetzte Hypothese** spezifiziert WD bis auf einige, aus den Daten zu bestimmende Parameter:

$$f(x | H(\lambda_i; \mu_j)), \lambda_i \text{ bekannt}$$

z.B. „Daten folgen einer Gaussverteilung mit  $\mu=0$ , aber unbekanntem  $\sigma$ “

- Zu testende Hypothese: **Null-Hypothese  $H_0$**  („Alles beim Alten“, „Standardmodell“)
- Andere Hypothesen: **Alternativhypothese(n):  $H_1, H_2, \dots$**  (neuer Effekt, neue Physik)  
für konkreten Test muss diese explizit formuliert werden:
  - „Daten folgen einer Poisson-Verteilung mit  $\nu=3,0$ “ (nicht 3,5)
  - „Meßwerte folgen einer Poisson-Verteilung mit  $\nu < 7,0$ “
  - „Meßwerte folgen einer Gaußverteilung mit  $\mu=1$ “ (nicht 0)
  - „Daten sind nicht Poisson-verteilt“ (schwieriger, da im Prinzip unendlich viele ...)

# Frage: Ist die Hypothese gegenüber einer Alternativen zu Bevorzugen?

Antwort eines statistischen Tests kann JA oder NEIN zu Gunsten von  $H_1$  oder  $H_0$  lauten

- ⇒
- 4 Fälle
  - **2 Fehlermöglichkeiten**
    - I. Verwerfen einer wahren Hypothese („false negative“)
    - II. Akzeptieren einer falschen Hypothese („false positive“)

Wahrscheinlichkeit für I. heißt **Signifikanz,  $\alpha$**  des Tests

Definiere „**Kritische Region**“

für fälschliches Verwerfen von  $H_0$  :

$$\alpha = P(x \in S_c \mid H_0) \quad (\text{Fehler I. Art})$$

bzw. fälschliches Akzeptieren von  $H_0$


$$\beta = P(x \notin S_c \mid H_1) \quad (\text{Fehler II. Art})$$

sehr häufig:  $S_c$  gegeben durch  $\{x \mid x > x_c\}$  : einfacher „Schnitt“ in  $x$

**(1 -  $\beta$ )** heißt **Mächtigkeit** (auch „Power“, Güte, Trennschärfe) des Tests

Wahrscheinlichkeit, keinen Fehler der zweiten Art zu begehen, also eine falsche Null-Hypothese auch als solche zu erkennen

# Entscheidung zwischen zwei Hypothesen



# Mächtigkeit/Güte ist wesentlich wichtiger als Signifikanz

Bsp: Test mit beliebig hoher Signifikanz, aber Mächtigkeit 0

- behaupten Sie irgend etwas
- ziehen Sie eine Zufallszahl  $0 < r < 1$  ;
- akzeptieren Sie Ihre Behauptung als wahr, wenn  $r < \alpha$

da Ihre Teststatistik  $r$  nicht mit Ihrer Behauptung  
zusammenhängt, kann Sie auch nicht falsifiziert werden !

# Signifikanz und Mächtigkeit bei Klassifizierung: Effizienz und Reinheit

Frage: Ausgewähltes Objekt ist vom Typ 0 oder 1  
(z.B. Pion oder Kaon, Positron oder Proton)

Entscheidung durch Vergleich von beobachteter Meßgröße  $t$  („Teststatistik“) mit Verteilungen  $f(t|H_0)$  und  $f(t|H_1)$ .

Auch dies ist also statistisch gesehen ein Hypothesentest.

**Effizienz:** Anteil der richtig ausgewählten Objekte vom Typ 0  
 $\varepsilon = 1 - \alpha$

**Reinheit:** Anteil der Objekte vom Typ 0 unter den ausgewählten

$$p = (1 - \alpha) N_0 / [(1 - \alpha) N_0 + \beta N_1]$$


hängt von den Anzahlen der Objekte von Typ 0 und 1,  $N_0$  und  $N_1$  ab

# „ROC“-Kurve: Effizienz und Reinheit

(Receiver Operating Characteristics)

- Ein statistischer Test ist um so besser je näher er an den Punkt (1,1) kommt
- ... je größer die Fläche unter der ROC-Kurve ist
- Optimale Wahl des Arbeitspunktes | je nach Aufgabe: wie skaliert Gesamtfehler mit  $\epsilon$  und  $p$ ?

Beispiel: inelastische Ereignis-Selektion mit CMS vorwärts-Kalorimeter



(CMS; Measurement of the inelastic cross section in proton-lead collisions at 5.02 TeV; Physics Letters B 759 (2016) 641)

# Hypothesentests in mehreren Dimensionen

Reduktion der Dimensionalität durch sog. **Teststatistik**


- $\mathbf{x} = (x_1, \dots, x_n) \rightarrow t(\mathbf{x}), f(\mathbf{x}|H) \rightarrow g(t|H)$

Beispiele: Mittelwert, Varianz, Likelihood-Fkt., ...

(Fischer-Diskriminante, künstliches neuronales Netz, ...)

→ Definition von Entscheidungskriterien anhand der Teststatistik


Festlegung des Signifikanzniveaus  $\alpha$  und Bestimmung der kritischen Region  $S_c(\alpha)$ , d.h. des Ablehnungsbereichs der Nullhypothese.



Beispiele zur Wahl der kritischen Region

# Vorgehensweise bei Hypothesentests

- Formulierung der Nullhypothese  $H_0$  und der Alternativhypothese  $H_1$
- Wahl einer geeigneten Testgröße oder Teststatistik
- Festlegung des Signifikanzniveaus  $\alpha$
- Bestimmung der kritischen Region  $S_c(\alpha)$ ,  
 d.h. des Ablehnungsbereichs der Nullhypothese  
**Achtung: alles andere als eindeutig:  
 einseitig, zweiseitig symmetrisch, ...**
- **erst dann:** Ziehung der statistischen Stichprobe -  
 d.h. Anschauen der Messdaten!
- Treffen der Testentscheidung und Interpretation:  
 Liegt das Ergebnis der Stichprobe innerhalb  $S_c$   
 wird  $H_0$  verworfen, andernfalls angenommen.



# Test einer Hypothese

- Akzeptieren der Null-Hypothese führt zur Ablehnung der Alternativhypothese
- Akzeptieren der Alternativhypothese führt zur Ablehnung der Null-Hypothese  
**aber: Null - Hypothese kann nicht bewiesen werden !**  
es könnte eine Alternativ-Hypothese existieren, die die Beobachtung noch besser beschreibt als die (gegenwärtige) Null-Hypothese!

Oft statt vorheriger Wahl von  $\alpha$  :

Angabe von beobachtetem **p-Wert** („p-Value“) bzgl.  $H_0$

z.B. bei einfacher einseitiger kritischer Region:  $\alpha_{\text{obs}} = \int_{x_{\text{obs}}}^{\infty} f(x) dx$

als Maß für die Übereinstimmung (oder auch Nicht-Übereinstimmung) einer Beobachtung mit der Null-Hypothese.

Allg. **p-Value**: Geringste Irrtumswahrscheinlichkeit  $\alpha$  , deren Festlegung mit den beobachteten Stichprobenwerten gerade noch zum Verwerfen der Nullhypothese geführt hätte.

# Test einer Hypothese:

## Hauptprobleme:

1. Finden der optimalen Teststatistik – gibt es einen besten Test ?
2. Bestimmen der Verteilungsdichte der Teststatistik,  $f(t)$   
Machmal analytisch möglich, oft mit Hilfe von Monte-Carlo
3. Festlegen der kritischen Region (bzw. der Konfidenzregion)
4. Interpretation des Ergebnisses:
  - **Frequentist**      $p$ -Value bzgl.  $P(\text{Daten} \mid \text{Hypothese})$
  - oder
  - **Bayes`sche**      $P(\text{Hypothese} \mid \text{Daten})$  benötigt Prior-Annahme
  - Sichtweise ?

Beginnen zunächst mit einigen Beispielen

# Binomial Test

$$P(k; n) = \binom{n}{k} p^k (1 - p)^{n-k}, k = 1, \dots, n$$

Beispiel:

- 15 Münzwürfe
- Daten:  $k$  = Anzahl Kopf
- Null-Hypothese:  $p = \frac{1}{2}$  (Münze ok)
- Alternative:  $p > \frac{1}{2}$  (Münze gezinkt)
- Gewählte Signifikanz: 10%

**n=15**

k	p-Value
15	0.003%
14	0.05%
13	0.3%
12	1.4%
11	4.2%
10	9.2%

**Ein Experiment, Anzahl Kopf,  $k$ , als Teststatistik.**

Mit einer Wahrscheinlichkeit von ca. 10% findet man bis zu 10 Mal Kopf. Ab 11 mal Kopf würde man mit einer Signifikanz von 10% die Null-Hypothese verwerfen – die Münze also als gezinkt bezeichnen.

# Effektivität einer med. Behandlung

Ist eine medizinische Behandlung effektiv?

100 Patienten, spontane Heilung 60%

Entscheidung: 5% Signifikanz-Niveau  
 $H_0$  : kein Effekt

Binomial-Verteilung:  $\sigma = \sqrt{Np(1-p)} = \sqrt{100 \cdot 0,6 \cdot 0,4} = 4,90$

$N$  „groß“  $\rightarrow$  Gauß-Näherung

Einseitiger Test mit  $\alpha = 5\%$ :  $1,64 \cdot \sigma$  (Gauß)

$\Rightarrow 60 + 1,64 \cdot 4,90 = 69$  Heilungen mindestens zur  
 Verwerfung von  $H_0$

# Poisson Test

Sehr typisches Problem bei der Suche nach neuen Effekten:

Erwartung: Anzahl von  $\mu_0$  Ereignissen aus bekannten Quellen,

**Hypothese:  $P(k; \mu_0)$**

Zusätzliche Anzahl  $\mu_1$  Ereignisse durch neuen Effekt,

**Alternative:  $P(k; \mu_1 + \mu_0)$**

**Im Experiment beobachtete Zahl von Ereignissen,  $k$ , als Teststatistik.**

Falls  $n$  groß  $\rightarrow$  Gauß'sche Näherung

- $f(k|H_0) = \text{Gauß}(\mu = \mu_0, \sigma = \sqrt{\mu_0})$  bzw.

$$f(k|H_1) = \text{Gauß}(\mu = \mu_0 + \mu_1, \sigma = \sqrt{(\mu_0 + \mu_1)})$$

- Einfaches Maß für die „Signifikanz“ einer Beobachtung:

$$\text{„Signifikanz“ } S = s / \sqrt{b}, \quad s = n - \mu_0, \quad b = \mu_0$$

Beobachteter Signalüberschuss normiert auf den Fehler der Untergrunderwartung

**Häufiges Problem:**

systematischer Fehler,  $\Delta\mu_0$ , auf  $\mu_0$ , erfordert spezielle Maßnahmen


# Angeregte Bs Mesonen

- Grün unterlegte Verteilung modelliert Form des Untergrundes
- Histogramm enthält mögliche Signalereignisse.

**Frage:** wie signifikant sind die einzelnen Signale, wie viele gibt es überhaupt, oder sieht man nur statistische Fluktuationen?

**Typische Vorgehensweise:**

Definition einer „Signalregion“ um einen Peak herum, in der die Zahl der beobachteten Ereignisse und der erwarteten Untergrundereignisse bestimmt werden, dann **Poisson-Test**.



# „Neue Physik“ in 750 GeV Di-Photonen

Gibt es ein Signal?

CMS + ATLAS haben in 2015-Daten je  $> 3\sigma$  Signale bei 750 GeV beobachtet!


ATLAS (3,9- $\sigma$ )

$$N_{\text{signal}} = 15 = N_{\text{obs}} - N_{\text{bg}}$$

$$\sigma = \frac{N_{\text{sig}}}{3,9} = 3,8 = \sqrt{N_{\text{bg}}}$$

$$\Rightarrow N_{\text{bg}} \approx 14$$

$$H_0: N = N_{\text{bg}} \pm \sqrt{N_{\text{bg}}} \quad (\text{Poisson / Gauß})$$



Zum Beispiel:

<https://arxiv.org/pdf/1606.03833.pdf>

<https://inspirehep.net/record/1480039>

(leider verschwand der Effekt in 2016-Daten)

# „Signale“ und ihre Signifikanz

- Signifikanz nur richtig falls schon vor der Messung ein Signal vermutet wurde
  
- Signifikanz viel geringer falls:
  - sie irgendwo in der Verteilung auftreten kann
  - viele Verteilungen betrachtet werden
  - die Selektionskriterien (bewusst oder unbewusst) gewählt wurden um Signal zu erzeugen
  
- Lösung z.B. mit Hilfe von
  - **Blinden Analysen**
    - festlegen aller Kriterien bevor Daten angeschaut werden
  - **Pseudo-Experimente**
    - Künstliches Nachstellen der Daten (sehr oft!) um zu „messen“ wie wahrscheinlich die Beobachtung wirklich ist.

# Student'sche t-Verteilung


- Betrachte Gauß-förmig verteilte Zufallszahlen  $x_i$  mit Erwartungswert  $\mu$  und Varianz  $\sigma^2$
- Mittelwert  $\bar{x}$  als Testgröße
- Varianz aus Daten:  $\hat{\sigma}$   
→  $\chi^2$ -Summe

- $$t = \frac{\bar{x} - \mu}{\hat{\sigma}}$$

- folgt t-Verteilung mit  $n$  Freiheitsgraden

$$f_n(x) = \frac{\Gamma\left(\frac{n+1}{2}\right)}{\sqrt{n\pi}\Gamma\left(\frac{n}{2}\right)} \left(1 + \frac{x^2}{n}\right)^{-\frac{n+1}{2}}$$

( $n \rightarrow$  unendlich: Gauß,  $n=1 \rightarrow$  Breit-Wiegner/Cauchy)



- t-Verteilung hat für kleiner  $n$  deutlich ausgeprägtere Schwänze als Gauß.

# Test auf gleichen Mittelwert bei unbekannter Varianz

Zwei Gauß-verteilte Datensätze mit Mittelwerten  $\mu_1, \mu_2$  und empirischen Varianzen  $\hat{\sigma}_1^2, \hat{\sigma}_2^2$

$$u := \frac{\bar{x}_1 - \bar{x}_2}{\sqrt{\sigma_1^2/N_1 + \sigma_2^2/N_2}} \quad \text{ist standard-normalverteilt}$$

$$\chi^2 := \frac{(N_1 - 1)\hat{\sigma}_1^2}{\sigma_1^2} + \frac{(N_2 - 1)\hat{\sigma}_2^2}{\sigma_2^2} \quad \text{ist } \chi^2\text{-Summe mit } N_1+N_2-2 \text{ Freiheitsgraden}$$

**Verhältnis ist t-verteilt !**

mit  $\sigma_1 = \sigma_2$  und  $\mu_1 = \mu_2$  ergibt sich :

$$t = \frac{\bar{x}_1 - \bar{x}_2}{S\sqrt{1/N_1 + 1/N_2}} \quad \text{mit } S^2 = \frac{(N_1 - 1)\hat{\sigma}_1^2 + (N_2 - 1)\hat{\sigma}_2^2}{N_1 + N_2 - 2}$$

**Diese Teststatistik aus zwei Datensätzen folgt einer t-Verteilung mit  $N_1+N_2-2$  Freiheitsgraden** (für die Nullhypothese: „Mittelwerte sind gleich“)

# Beispiel, Student'sch t-Verteilung

## ■ Punkte bei Klausur in zwei Gruppen

■ Gruppe 1: 39 18 8 22 24 29 22 22 27 28 23 48

■ Gruppe 2: 42 23 36 35 28 42 33

$$\bar{x}_1 = 25,4 \quad \hat{\sigma}_1 = 10,9 \quad N_1 = 12$$

$$\bar{x}_2 = 35,6 \quad \hat{\sigma}_2 = 6,5 \quad N_2 = 7$$

$$H_0: \mu_1 = \mu_2$$

$$S^2 = 91,788$$

$$\frac{\bar{x}_1 - \bar{x}_2}{S \sqrt{\frac{1}{N_1} + \frac{1}{N_2}}} = \frac{10,2}{9,6 \cdot 0,48} = 2,21$$

95% C.L.  $(1-\alpha)$  für t-Verteilung mit 17 Freiheitsgrade  
 ist  $2,110 \Rightarrow$  Gruppen sind unterschiedlich!

# Test auf gleiche Varianz


## ■ Fischer-, F-Verteilung

$$f(F|m, n) = m^{\frac{m}{2}} n^{\frac{n}{2}} \cdot \frac{\Gamma(\frac{m}{2} + \frac{n}{2})}{\Gamma(\frac{m}{2})\Gamma(\frac{n}{2})} \cdot \frac{x^{\frac{m}{2} - 1}}{(mx + n)^{\frac{m+n}{2}}}$$

## ■ Der Größe

$$F_{m,n} = \frac{\chi_m^2/m}{\chi_n^2/n}$$

zweier  $\chi^2$ -verteilter Zufallsvariablen  
mit  $m$  und  $n$  Freiheitsgraden



Verteilungsdichte der F-Verteilung,  $f(x;n,m)$

Quelle: Wikipedia

## ■ Für große $N$ ist $\mathbf{z := 0.5 \log F}$

Gauß-verteilt mit Mittelwert  $0.5(1/n-1/m)$  und Varianz  $0.5(1/m + 1/n)$

# Bester Test, Optimale kritische Region

Bsp: Hypothese: Normalverteilung mit  $\sigma^2$  und  $\lambda = \lambda_0$

Bsp.: Test einer Gauß-Vert. auf Erwartungswert  $\lambda_0 = 0$  für verschiedene kritische Regionen

Alternativ-Hypothese: Erwartungswert ist  $\lambda_1$

Teststatistik: Mittelwert von Gauß-verteilten Zuf.-Zahlen  $x_i$

Erwartungswert  $\lambda$  der Alternativ-Hypothese wird variiert, um Mächtigkeit (=Güte,  $1-\beta$ ) des jeweiligen Tests zu bestimmen.


(a1):  $1-\beta \geq \alpha$  („unverzerrter Test“)

(a2): am besten für  $\lambda_1 \geq \lambda_0$

(a3): am besten für  $\lambda_0 \geq \lambda_1$

(a4): Verwerfungswahrscheinlichkeit maximal, wenn  $H_0$  wahr ist (Unsinn, nur zur Demonstration!)

⇒ Es existiert kein „bester Test“ für alle Alternativhypothesen!



Quelle: Brandt, Datenanalyse

# Beste Test einer einfachen Hypothese

- Was ist der (gleichmäßig) beste Test einer Hypothese  $H_0(x)$  gegen Alternativhypothese  $H_1(x)$

$$M(S_c, \lambda_1) = 1 - \beta = \max \quad (\text{gleichmäßig: für alle Alternativhypothesen } \lambda_i)$$


$$\text{mit} \quad \int_{S_c} f(X|H_0) dX = P(X \in S_c | H_0) = \alpha$$

- **Satz von Neyman und Pearson:**

$$\frac{f(X|H_1)}{f(X|H_0)} \geq c(\alpha) \quad \iff \quad X \in S_c$$

wobei  $c$  eine Konstante ist, die vom Signifikanzniveau abhängt.

# Beweis (siehe Braudt)



$$P(x \in S | H_0) = P(x \in S_C | H_0) \stackrel{!}{=} \alpha$$

$$\begin{aligned} P(x \in A | H_0) &= P(x \in S_C | H_0) - P(x \in C | H_0) \\ &= P(x \in S | H_0) - P(x \in C | H_0) = P(x \in B | H_0) \end{aligned}$$

$$\Rightarrow \begin{cases} \leq c \cdot P(x \in A | H_1) \\ \geq c \cdot P(x \in B | H_1) \end{cases}$$

$$M(S_C, H_1) = P(x \in S_C | H_1) \dots \geq P(x \in S | H_1) = M(S, H_1) \quad \square$$

# Beispiel, Edelsteinabbau (siehe Barlow)

$$s_{\text{Opal}} = 2,2 \text{ g/cm}^3 \quad s_{\text{Quartz}} = 2,6 \text{ g/cm}^3$$

Testen kleiner Proben verschiedener Mienen

$$\Delta s = 0,2 \text{ g/cm}^3 \quad \text{Meßfehler}$$

$H_0$ : Opal Gauß mit  $\mu = 2,2$   $\sigma = 0,2$

$H_1$ : Quartz Gauß mit  $\mu = 2,6$   $\sigma = 0,2$

$$c = \frac{H_1}{H_0} = \frac{e^{-\frac{(s-2,6)^2}{2 \cdot 0,2^2}} / \sqrt{2 \cdot 0,2^2}}{e^{-\frac{(s-2,2)^2}{2 \cdot 0,2^2}} / \sqrt{2 \cdot 0,2^2}} \propto e^{10 \cdot s}$$

$\Rightarrow$  jeder einfache Schnitt  $s > s_c$  definiert ein eindeutiges  $c$  und damit ein optimales  $1-\beta$  für gegebenes  $\alpha$

z. B.:

$$\alpha = 5\%$$

$$s_c = 2,53$$

$$\beta = 36\%$$

$\rightarrow$  gute Mienen verworfen

$\rightarrow$  Quartz abgebaut

$$\alpha = 10\%$$

$$s_c = 2,46$$

$$\beta = 24\%$$

# Gefahr von Verzerrungen, auch bei hoher Signifikanz

Beispiel:

- 20 Physiker führen (unabhängig voneinander) jeweils eine Messung durch
- Einer sieht eine Abweichung von der Erwartung um  $2\sigma$  (Ausschluss der Null-Hypothese mit 5% Signifikanz)
- Der eine publiziert sein Ergebnis, die anderen nicht
- **Bias der veröffentlichten Ergebnisse!**

Publikation sollte nicht vom Ausgang des Tests abhängen

- Auch „negative“ Resultate publizieren

Denn: LHC  $\approx 10000$  Physiker,  $\mathcal{O}(10^4) - \mathcal{O}(10^5)$  Messungen/Verteilungen/Schritte  
 $\Rightarrow$  auch extrem seltene Fluktuationen können signifikant werden!

# Zusammenfassung

- Mit Hilfe von Hypothesen könne Daten verwendet werden um definierte Entscheidungen zu treffen
- Es kann dabei immer zu Fehlern kommen: Fehler 1. und 2. Art.
- Ein Hypothese kann nie „bewiesen“ werden, sondern immer nur Alternativ-Hypothesen verworfen werden (d.h. das Standardmodell kann nie bewiesen werden)
- Die Signifikanz von Tests ist oft schwer zu beurteilen: das Verwenden von blinden Analysen, oder Pseudo-Experimenten ist sehr empfohlen.
- Gleichmäßig beste Tests können mit Hilfe des Neyman-Pearson Lemmas definiert werden.
- Auch nicht-Signifikante Effekte sollten publik gemacht werden.

