

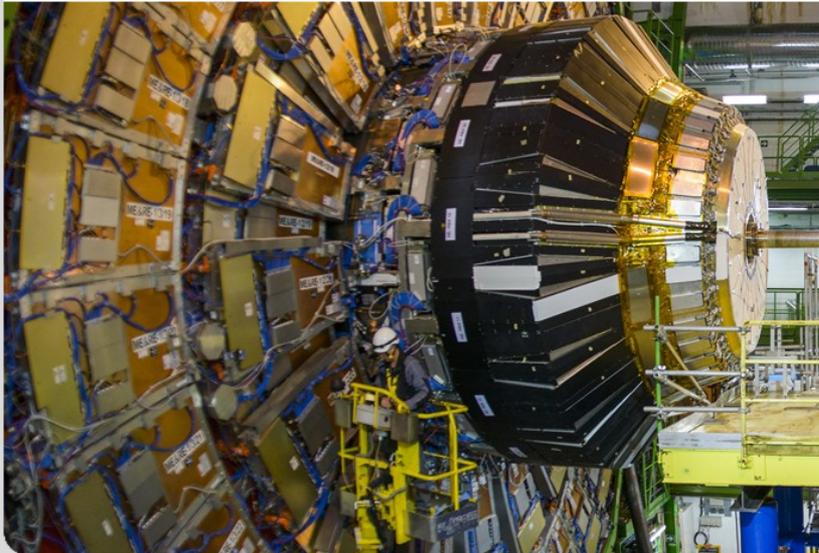
Rechnernutzung in der Physik

Teil 3 – Statistische Methoden in der Datenanalyse

Roger Wolf

19. Januar 2015

INSTITUTE OF EXPERIMENTAL PARTICLE PHYSICS (IEKP) – PHYSICS FACULTY



- Grundlagen der Wahrscheinlichkeitstheorie, Werkzeuge zur statistischen Datenanalyse
- Gängige Wahrscheinlichkeitsverteilungen
- Monte-Carlo Methoden
- **Parameterschätzung**
- **Hypothesentests**

Kapitel 3.6:

Parameterschätzung

- Einführung und Grundlagen der Statistik (→ Stichprobe, Schätzfunktion, Stichprobenverteilung, Verzerrung).
- Charakterisierung von Stichproben (→ Erwartungswert, Varianz, Korrelationskoeffizient).

Kapitel 3.7:


Parameterschätzung mit Hilfe der Maximum Likelihood Methode

- Stochastische Modelle, Hypothesen, Teststatistik, Likelihood Funktion.
- Maximum Likelihood Prinzip.
- Maximum Likelihood Schätzfunktion und Unsicherheit am Beispiel des radioaktiven Zerfalls.
- Abschätzung der Unsicherheit der ML Schätzfunktion, analytisch, durch Monte Carlo Methoden, durch die RCF Ungleichung, graphisch.

Kapitel 3.8:

Parameterschätzung mit Hilfe der Least Square Methode

- Stellen Sie sich vor Sie hätten eine Meßreihe aus 9 **unabhängigen Einzelmessungen** $\{y_i\}$ die **alle nach Gauß verteilt sind**. Es kann sich dabei z.B. um die Zerfallsrate eines radioaktiven Präparats zu bestimmten Zeitpunkten $\{t_i\}$ handeln.⁽¹⁾
- Nehmen Sie weiter an, daß jede Einzelmessung y_i einen anderen unbekanntem Erwartungswert $\mu_i(t_i)$ und eine bekannte Varianz σ_i^2 besitzt. In unserem Beispiel abgeschätzt durch $\sqrt{N_i}$ bei N_i registrierten Zerfällen.
- Die μ_i können außerdem mehreren weiteren Parametern θ_k abhängen. In unserem Beispiel entspricht ein einzelner Parameter θ der Lebensdauer des Isotops.



- Sie können wieder die gesamte Meßreihe aus 9 Einzelmessungen als einzelnes Zufallexperiment betrachten (vgl VL-11). In einer Maximum Likelihood Analyse, mit $\mu_i = \mu(t_i, \theta)$ würden Sie die **Likelihood Funktion wie folgt ansetzen**:

$$\mathcal{L}(\{y_i\}, \{\mu_i(\theta)\}, \{\sigma_i\}) = \prod_{i=1}^9 \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-(y_i - \mu_i(\theta))^2 / 2\sigma_i^2}$$

$$\ln(\mathcal{L}(\theta)) = -\frac{1}{2} \sum_{i=1}^9 \frac{(y_i - \mu_i(\theta))^2}{\sigma_i^2}$$

- Die Likelihood Funktion wird maximal **wenn die Funktion $\chi^2(\theta) = \sum_{i=1}^9 \frac{(y_i - \mu_i(\theta))^2}{\sigma_i^2}$ minimal wird**.
- Für nach Gauß verteilte Zufallsgrößen gilt: $\chi^2(\theta) = -2 \ln(\mathcal{L}(\theta))$

Seien $\{y_i\}$ Einzelmessungen einer Meßreihe, deren Erwartungswerte $\{\mu_i\}$ unbekannt, deren Varianzen $\{\sigma_i^2\}$ jedoch bekannt sind. Diese Einzelmessungen müssen nicht unabhängig sein sondern können über eine bekannte Matrix $\{V_{ij}\}$ korreliert sein. Die Funktion


$$\chi^2(\theta) = \sum_{i,j=1}^n (y_i - \mu_i(\theta))^\top V_{ij}^{-1} (y_j - \mu_j(\theta))$$

heißt **Schätzfunktion der kleinsten Quadrate** (Least Square, LS-Schätzfunktion). Die Parameter $\hat{\theta}_{LS}$, die $\chi^2(\theta)$ minimieren heißen **Schätzwerte der kleinsten Quadrate** (Least Square, LS-Schätzwerte).

- Die Anpassungsmethode der kleinsten Quadrate ist für nach Gauß verteilte Zufallszahlen ein **Spezialfall der Maximum Likelihood Methode**.
- Wie die $\{y_i\}$ nach t verteilt sind kommt in der LS-Schätzfunktion nicht vor. Man sagt die LS-Schätzfunktion ist **verteilungsfrei**.
- Sind die Einzelmessungen $\{y_i\}$ nach Gauß verteilt, dann **folgt die LS-Schätzfunktion Funktion der χ^2 Funktion** aus **VL-09 (slide 41)** für $(n - k)$ Freiheitsgrade.

$$\chi^2(\theta) = \sum_{i=1}^n \frac{(y_i - \mu_i(\theta))^2}{\sigma_i^2}$$

dabei ist n die Anzahl der Messungen und k die Anzahl der freien Parameter des Modells.




9 Meßpunkte minus 1 freier Parameter → 8 Freiheitsgrade.

- Die Anpassungsmethode der kleinsten Quadrate ist für nach Gauß verteilte Zufallszahlen ein **Spezialfall der Maximum Likelihood Methode**.
- Wie die $\{y_i\}$ nach t verteilt sind kommt in der LS-Schätzfunktion nicht vor. Man sagt die LS-Schätzfunktion ist **verteilungsfrei**.
- Sind die Einzelmessungen $\{y_i\}$ nach Gauß verteilt, dann **folgt die LS-Schätzfunktion Funktion der χ^2 Funktion** aus **VL-09 (slide 41)** für $(n - k)$ Freiheitsgrade.

$$\chi^2(\theta) = \sum_{i=1}^n \frac{(y_i - \mu_i(\theta))^2}{\sigma_i^2}$$

dabei ist n die Anzahl der Messungen und k die Anzahl der freien Parameter des Modells.



9 Meßpunkte minus 1 freier Parameter → 8 Freiheitsgrade.

- Die LS-Schätzfunktion **kann numerisch minimiert werden**. Wenn die Schätzfunktion linear von den Parametern θ_k abhängt ist die jedoch auch **analytisch lösbar**.

$$\mu(k_i, \theta_k) = \sum_{k=1}^m a_k(y_i)\theta_k = \sum_{k=1}^m A_{ik}\theta_k$$

in Matrixschreibweise schreibt sich χ^2 als:

$$\chi^2 = (\vec{y} - \vec{\mu})^\top V^{-1} (\vec{y} - \vec{\mu}) = (\vec{y} - A\vec{\theta})^\top V^{-1} (\vec{y} - A\vec{\theta})$$

Um das Minimum zu finden setzen wir:

$$\vec{\partial}_{\theta} \chi^2 = -2 \left(A^\top V^{-1} \vec{y} - A^\top V^{-1} A \vec{\theta} \right) \stackrel{!}{=} 0$$

$$\vec{\theta}_{LS} = \underbrace{(A^\top V^{-1} A)^{-1} A^\top V^{-1} \vec{y}}_{\equiv B}$$

d.h. die LS-Schätzwerte sind **Linearkombinationen der ursprünglichen Messungen**:

$$\hat{\theta}_{LS,k} = \sum_{i=1}^n B_{ki} y_i$$

- Es gibt zwei offensichtliche **Methoden die Varianz der $\hat{\theta}_{LS}$ auszurechnen:**
- **Methode-1:** aus Fehlerfortpflanzung (=Variablentransformation) von V .

$$\text{cov}(\hat{\theta}_i, \hat{\theta}_j) = BV B^T = (A^T V^{-1} A)^{-1}$$

$$\left((A^T V^{-1} A)^{-1} A^T V^{-1} \right) V \left((A^T V^{-1} A)^{-1} A^T V^{-1} \right)^T$$

$$(A^T)^{-1} V A^{-1} \underbrace{A^T V^{-1} V (V^{-1})^T A (A^{-1})^T V^T A^{-1}}_{\equiv 1}$$

$$(A^T)^{-1} V \underbrace{A^{-1} A^T (V^{-1})^T A (A^{-1})^T V^T}_{X^{-1}} A^{-1} = (A^T)^{-1} V A^{-1} = (A^T V^{-1} A)^{-1}$$

$\underbrace{\hspace{10em}}_{\equiv 1}$

Unter Verwendung von:

$$(AB)^T = B^T A^T$$

$$(A^{-1})^T = (A^T)^{-1}$$

- Es gibt zwei offensichtliche **Methoden die Varianz der $\hat{\theta}_{LS}$ auszurechnen:**
- **Methode-1:** aus Fehlerfortpflanzung (=Variablentransformation) von V .

$$\text{cov}(\hat{\theta}_i, \hat{\theta}_j) = BV B^\top = (A^\top V^{-1} A)^{-1}$$

Ein Vergleich mit der RCF-Ungleichung ergibt:

$$\frac{\partial^2}{\partial \theta_i \partial \theta_j} \chi^2(\theta) = 2A^\top V^{-1} A$$

$$\text{cov}[\hat{\theta}_i, \hat{\theta}_j] \geq \left[-\frac{\partial^2}{\partial \theta_i \partial \theta_j} \underbrace{\ln \mathcal{L}(\theta)}_{-\frac{1}{2} \chi^2(\theta)} \right]_{\substack{\theta_i = \hat{\theta}_i \\ \theta_j = \hat{\theta}_j}}^{-1} = (A^\top V^{-1} A)^{-1}$$

↪ Für normalverteilte
Zufallsgrößen

D.h. für nach Gauß verteilte Zufallsgrößen **ist die LS-Schätzfunktion effizient!**⁽²⁾

$$V A^{-1} = (A^\top V^{-1} A)^{-1}$$

Unter Verwendung von:

$$(AB)^\top = B^\top A^\top$$

$$(A^{-1})^\top = (A^\top)^{-1}$$


- Es gibt zwei offensichtliche **Methoden die Varianz der $\hat{\theta}_{LS}$ auszurechnen**:
- **Methode-2:** graphisch aus Abweichung von $\Delta\chi^2$ vom Wert am Minimum χ_{\min}^2 .

Aus der **Taylor-Entwicklung der Likelihood Funktion** im Maximum ergibt sich:

$$\chi^2(\theta_i) \approx \underbrace{\chi^2(\{\hat{\theta}_{LS,i}\})}_{\equiv \chi_{\max}^2} + \underbrace{\frac{1}{2!} \sum \left[\frac{\partial^2}{\partial \theta_i \partial \theta_j} \chi^2 \right]_{\theta=\hat{\theta}_{LS}}}_{\equiv \text{c}\hat{\text{O}}\text{V}_{ij}^{-1}} (\theta_i - \hat{\theta}_{LS,i}) (\theta_j - \hat{\theta}_{LS,j}) + \dots$$

$$\chi^2(\vec{\hat{\theta}}_{LS} \pm \text{c}\hat{\text{O}}\text{V}(\{\hat{\theta}_{LS,i}\}) \cdot \vec{\hat{\theta}}_{LS}) = \chi_{\min}^2 + 1$$

d.h. die Variation aus dem Minimum um $\pm\hat{\sigma}$ bewirkt die **Erhöhung von $\chi^2(\{\theta_i\})$ um den Wert 1!**⁽³⁾



Beispiel: Anpassung eines Polynoms

- Fallbeispiel: Anpassung eines Polynoms n-ten Grades:

$$\mu(y_i, \theta_k) = \sum_{k=1}^m a_k(y_i) \theta_k = \sum_{k=1}^m A_{ik} \theta_k$$

$$A_{ik} = a_k(y_i) = y_i^k$$

Beispiel: Anpassung eines Polynoms

- Fallbeispiel: **Anpassung eines Polynoms n-ten Grades:**


$$\mu(y_i, \theta_k) = \sum_{k=1}^m a_k(y_i) \theta_k = \sum_{k=1}^m A_{ik} \theta_k$$

$$A_{ik} = a_k(y_i) = y_i^k$$

- Fünf unkorrelierte Datenpunkte (gaußisch nach einer unbekanntem linearen Funktion verteilt, $m = 5$):

```
static const int LENGTH = 5;
static float XVALUES[] = { 1.00, 2.00, 3.00, 4.00, 5.00};
static float YVALUES[] = {1.94759, 1.90523, 2.65621, 4.20916, 3.44776};
static float XERRORS[] = { 0.00, 0.00, 0.00, 0.00, 0.00};
static float YERRORS[] = { 0.10, 0.30, 0.25, 0.50, 0.75};
```

- Anpassung einer Geraden ($k = 2$) mit θ_0 (y-Achsenabschnitt) und θ_1 (Steigung).



Beispiel: Anpassung eines Polynoms

$$A^T V^{-1} A = \begin{pmatrix} \sum 1/\sigma_i^2 & \sum x_i/\sigma_i^2 \\ \sum x_i/\sigma_i^2 & \sum x_i^2/\sigma_i^2 \end{pmatrix}$$

$$(A^T V^{-1} A)^{-1} = \frac{1}{\det(A^T V^{-1} A)} \begin{pmatrix} \sum x_i^2/\sigma_i^2 & -\sum x_i/\sigma_i^2 \\ -\sum x_i/\sigma_i^2 & 1/\sigma_i^2 \end{pmatrix}^{(4)}$$

$$A^T V^{-1} \vec{x} = \begin{pmatrix} \sum \mu_i/\sigma_i^2 \\ \sum \mu_i x_i/\sigma_i^2 \end{pmatrix}$$

$$\begin{pmatrix} \hat{\theta}_0 \\ \hat{\theta}_1 \end{pmatrix} = \frac{1}{\det(A^T V^{-1} A)} \begin{pmatrix} (\sum x_i^2/\sigma_i^2)(\sum y_i/\sigma_i^2) - (\sum x_i/\sigma_i^2)(\sum y_i x_i/\sigma_i^2) \\ (\sum 1/\sigma_i^2)(\sum y_i x_i/\sigma_i^2) - (\sum x_i/\sigma_i^2)(\sum y_i/\sigma_i^2) \end{pmatrix}$$

$$\vec{\hat{\theta}}_{LS} = \underbrace{(A^T V^{-1} A)^{-1} A^T V^{-1} \vec{x}}_{\equiv B}$$

$$A = \begin{pmatrix} 1 & x_0 \\ 1 & x_1 \\ \vdots & \vdots \\ 1 & x_5 \end{pmatrix} \quad \vec{x} = \begin{pmatrix} 1 \\ 2 \\ \vdots \\ 5 \end{pmatrix}$$
$$V^{-1} = \begin{pmatrix} 1/\sigma_1^2 & 0 & \dots & 0 \\ 0 & 1/\sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1/\sigma_5^2 \end{pmatrix}$$

Beispiel: Anpassung eines Polynoms

$$A^T V^{-1} A = \begin{pmatrix} \sum 1/\sigma_i^2 & \sum x_i/\sigma_i^2 \\ \sum x_i/\sigma_i^2 & \sum x_i^2/\sigma_i^2 \end{pmatrix}$$

Steigung ($\hat{\theta}_1$) und y-Achsenabschnitt ($\hat{\theta}_0$)
antikorreliert.

$$(A^T V^{-1} A)^{-1} = \frac{1}{\det(A^T V^{-1} A)} \begin{pmatrix} \sum x_i^2/\sigma_i^2 & -\sum x_i/\sigma_i^2 \\ -\sum x_i/\sigma_i^2 & 1/\sigma_i^2 \end{pmatrix}^{(4)}$$

(Korrelationsmatrix)

$$A^T V^{-1} \vec{x} = \begin{pmatrix} \sum \mu_i/\sigma_i^2 \\ \sum \mu_i x_i/\sigma_i^2 \end{pmatrix}$$

$$\begin{pmatrix} \hat{\theta}_0 \\ \hat{\theta}_1 \end{pmatrix} = \frac{1}{\det(A^T V^{-1} A)} \begin{pmatrix} (\sum x_i^2/\sigma_i^2)(\sum y_i/\sigma_i^2) - (\sum x_i/\sigma_i^2)(\sum y_i x_i/\sigma_i^2) \\ (\sum 1/\sigma_i^2)(\sum y_i x_i/\sigma_i^2) - (\sum x_i/\sigma_i^2)(\sum y_i/\sigma_i^2) \end{pmatrix}$$

$$\vec{\hat{\theta}}_{LS} = \underbrace{(A^T V^{-1} A)^{-1} A^T V^{-1} \vec{x}}_{\equiv B}$$

$$A = \begin{pmatrix} 1 & x_0 \\ 1 & x_1 \\ \vdots & \vdots \\ 1 & x_5 \end{pmatrix} \quad \vec{x} = \begin{pmatrix} 1 \\ 2 \\ \vdots \\ 5 \end{pmatrix}$$

$$V^{-1} = \begin{pmatrix} 1/\sigma_1^2 & 0 & \dots & 0 \\ 0 & 1/\sigma_2^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1/\sigma_5^2 \end{pmatrix}$$

Beispiel: Anpassung eines Polynoms

```

std::pair<TMatrixD,TMatrixD> LLS(TMatrixD& A, TMatrixD& V, TMatrixD& X){
    TMatrixD U=TMatrixD(A,TMatrixD::kTransposeMult,TMatrixD(V,TMatrixD::kMult,A)).Invert(); /* (A^t*V*A)^(-1) */
    TMatrixD B=TMatrixD(U,TMatrixD::kMult,TMatrixD(A,TMatrixD::kTransposeMult,V)); /* (A^t*V*A)^(-1)*A^t*v */
    TMatrixD T=TMatrixD(B,TMatrixD::kMult,X); /* fit result */
    return std::make_pair(T,U);
}

/* -----
 * Anpassung einer Geraden (f(x)=a[0]+a[1]*x)
 * ----- */
const int NPARAM=2; /* Koeffizientenmatrix */
TMatrixD A(LENGTH,NPARAM); /*
for(int i=0;i<LENGTH;++i){ /*
    for(int j=0;j<NPARAM;++j){ /*
        A(i,j)=(j==0?1.0:XVALUES[i]); /*
    }
}
// std::cout << "PRINTING A" << std::endl; print(A);
// inverse Korrelationsmatrix
TMatrixD V(LENGTH,LENGTH); /* inverse Korrelationsmatrix */
for(int i=0;i<LENGTH;++i){ /*
    for(int j=0;j<LENGTH;++j){ /*
        V(i,j)=(i==j?1./(YERRORS[i]*YERRORS[i]):0.); /*
    }
}
// std::cout << "PRINTING V" << std::endl; print(V);
TMatrixD Y(LENGTH,1); /* Vektor der Messwerte */
for(int i=0;i<LENGTH;++i){ /*
    Y(i,0)=YVALUES[i]; /*
}
// std::cout << "PRINTING X" << std::endl; print(X);
std::pair<TMatrixD,TMatrixD> fit_result = LLS(A,V,Y);
TMatrixD T = fit_result.first;
TMatrixD U = fit_result.second;

```

LS-Schätzwerte:

$$\hat{\theta}_0 = 1.46 \pm 0.16$$


$$\hat{\theta}_1 = 0.45 \pm 0.09$$

$$\rho(\hat{\theta}_0, \hat{\theta}_1) = -0.85$$

Wahrheit:

$$\theta_0 = 1.0$$

$$\theta_1 = 0.6$$



$$\vec{\hat{\theta}}_{LS} = \underbrace{(A^T V^{-1} A)^{-1} A^T V^{-1}}_{\equiv B} \vec{x}$$

Beispiel: Anpassung eines Polynoms

```
std::pair<TMatrixD,TMatrixD> LLS(TMatrixD& A, TMatrixD& V, TMatrixD& X){
    TMatrixD U=TMatrixD(A,TMatrixD::kTransposeMult,TMatrixD(V,TMatrixD::kMult,A)).Invert(); /* (A^t*V*A)^(-1) */
    TMatrixD B=TMatrixD(U,TMatrixD::kMult,TMatrixD(A,TMatrixD::kTransposeMult,V)); /* (A^t*V*A)^(-1)*A^t*V */
    TMatrixD T=TMatrixD(B,TMatrixD::kMult,X); /* fit result */
    return std::make_pair(T,U);
}

/* -----
 * Anpassung einer Geraden (f(x)=a[0]+a[1]*x)
 * ----- */
const int NPARAM=2; /* Koeffizientenmatrix */
TMatrixD A(LENGTH,NPARAM); /*
for(int i=0;i<LENGTH;++i){ /*
    for(int j=0;j<NPARAM;++j){ /*
        A(i,j)=(j==0?1.0:XVALUES[i]); /*
    }
}
// std::cout << "PRINTING A" <<
// inverse Korrelationsmatrix
TMatrixD V(LENGTH,LENGTH);
for(int i=0;i<LENGTH;++i){
    for(int j=0;j<LENGTH;++j){
        V(i,j)=(i==j?1./(YERRORS[i]*
    }
}
// std::cout << "PRINTING V" <<
TMatrixD Y(LENGTH,1);
for(int i=0;i<LENGTH;++i){
    Y(i,0)=YVALUES[i];
}
// std::cout << "PRINTING X" <<
std::pair<TMatrixD,TMatrixD> fit
TMatrixD T = fit_result.first;
TMatrixD U = fit_result.second;
```

Durch geschickte Wahl können die **Parameter dekorreliert** werden:


$$y(x) = \theta_0 + \theta_1(x - \bar{x})$$

mit $\bar{x} = \frac{\sum x_i / \sigma_i^2}{\sum 1 / \sigma_i^2} = 1.47$

führt auf: $\rho(\hat{\theta}_0, \hat{\theta}_1) = 10^{-8}$

$$\vec{\hat{\theta}}_{LS} = \underbrace{(A^T V^{-1} A)^{-1} A^T V^{-1}}_{\equiv B} \vec{x}$$

LS-Schätzwerte:	Wahrheit:
$\hat{\theta}_0 = 1.46 \pm 0.16$	$\theta_0 = 1.0$
$\hat{\theta}_1 = 0.45 \pm 0.09$	$\theta_1 = 0.6$
$\rho(\hat{\theta}_0, \hat{\theta}_1) = -0.85$	



Kapitel 3.8:

Parameterschätzung mit Hilfe der Least Square Methode

- Least Squares Anpassung als Spezialfall der Maximum Likelihood Methode.
- Varianz des LS-Schätzwertes und Vergleich zur Maximum Likelihood Methode.
- Analytische Lösung der Linear Least Squares Anpassung am Beispiel der Anpassung einer Geraden.

Kapitel 3.9:

Hypothesentests

- **Aufgabenstellung:** Bewertung von Hypothesen H_i im Zusammenhang mit einer **Meßreihe** (Stichprobe). Die Hypothesen entsprechen den Aussagen stochastischer Modelle.
- Oft geht es um die Bewertung einer **ausgezeichneten Hypothese H_0** (z.B. Standardmodell der Teilchenphysik, Existenz oder Nichtexistenz eines neuen Teilchens, ...).
- **Quantitative, objektive Verfahren** zur Beantwortung der Fragen:

Kann/sollte H_0 aufgrund der vorliegenden Meßreihe verworfen werden?


Wie sicher ist es H_0 aufgrund der vorliegenden Meßreihe zu verwerfen?



WWW.PHDCOMICS.COM

Vorgehen beim Hypothesentest


- Meßreihe: $\vec{x} = (x_1, x_2, \dots, x_n)$
- Definition einer **Teststatistik**: $t(\{x_i\})$ ⁽⁵⁾ Die Teststatistik ist **selbst zufallsverteilt** nach der Stichprobenverteilung $g_{H_0}(t(\{x_i\}))$.
- Hier spezifizieren wir die Stichprobenverteilung als bedingte Wahrscheinlichkeitsverteilung unter der Bedingung H_0 .



Vorgehen beim Hypothesentest

- Meßreihe: $\vec{x} = (x_1, x_2, \dots, x_n)$
- Definition einer **Teststatistik**: $t(\{x_i\})$ ⁽⁵⁾ Die Teststatistik ist **selbst zufallsverteilt** nach der Stichprobenverteilung $g_{H_0}(t(\{x_i\}))$.
- Hier spezifizieren wir die Stichprobenverteilung als bedingte Wahrscheinlichkeitsverteilung unter der Bedingung H_0 .
- Festlegen eines **Kriteriums um H_0 zu verwerfen** (vor der Messung!):

$$\alpha = \int_{t_0}^{\infty} g_{H_0}(t) dt \quad (\text{Signifikanzniveau})$$



Angenommen H_0 ist wahr, dann ist in einem Bruchteil von α Fällen $t \geq t_0$.


Vorgehen beim Hypothesentest

- Meßreihe: $\vec{x} = (x_1, x_2, \dots, x_n)$
- Definition einer **Teststatistik**: $t(\{x_i\})$ ⁽⁵⁾ Die Teststatistik ist **selbst zufallsverteilt** nach der Stichprobenverteilung $g_{H_0}(t(\{x_i\}))$.
- Hier spezifizieren wir die Stichprobenverteilung als bedingte Wahrscheinlichkeitsverteilung unter der Bedingung H_0 .
- Festlegen eines **Kriteriums um H_0 zu verwerfen** (vor der Messung!):

$$\alpha = \int_{t_0}^{\infty} g_{H_0}(t) dt \quad (\text{Signifikanzniveau})$$

- **Auswertung des Experiments** (Meßreihe):

$$p = P_{H_0}(t \geq t_{exp}) = \int_{t_{exp}}^{\infty} g_{H_0}(t) dt \quad (\text{p-Wert})$$




$t \leq t_0 \rightarrow H_0$ nicht verwerfen.
 $t > t_0 \rightarrow H_0$ verwerfen.

Fehler erster Art:

(„false positive“)

H_0 mit Wahrscheinlichkeit α **verworfen obwohl sie wahr ist.**

- Patient krank diagnostiziert obwohl er gesund ist.
- Fälschliche entdeckung eines neuen Teilchens.




Fehler erster Art:

(„false positive“)

H_0 mit Wahrscheinlichkeit α **verworfen obwohl sie wahr ist.**

- Patient krank diagnostiziert obwohl er gesund ist.
- Fälschliche entdeckung eines neuen Teilchens.



Fehler zweiter Art:

(„false negative“)

H_0 **nicht verworfen obwohl falsch.**

- Patient gesund diagnostiziert obwohl er krank ist.
- Neues Teilchen nicht entdeckt, obwohl es da ist.
- Von Relevanz beim Vergleich von Hypothesen.




Fehler erster Art:

(„false positive“)

H_0 mit Wahrscheinlichkeit α **verworfen obwohl sie wahr ist.**

- Patient krank diagnostiziert obwohl er gesund ist.
- Fälschliche Entdeckung eines neuen Teilchens.



Fehler zweiter Art:

(„false negative“)

H_0 **nicht verworfen obwohl falsch.**


- Patient gesund diagnostiziert obwohl er krank ist.
- Neues Teilchen nicht entdeckt, obwohl es da ist.
- Von Relevanz beim Vergleich von Hypothesen.



- Wahrscheinlichkeiten für den Ausgang der Messung. Eigenschaft der Messung. Festlegung von α erfolgt (**unbeeinflusst vom Ausgang des Experiments!**) vor der Auswertung der Meßreihe.

- Der p -Wert ist eine **a posteriori Wahrscheinlichkeit** bestimmt nach(!) Auswertung des Experiments:
- Wahrscheinlichkeit für $t > t_{exp}$ wenn H_0 wahr ist **wenn die Meßreihe beliebig oft wiederholt würde.**
- **Achten Sie auf die Interpretation** ihrer Ergebnisse. Die Mathematik versorgt Sie mit nackten Zahlen. Die Deutungshoheit liegt bei Ihnen.

Etwas unlautere Interpretation des p -Wertes:



[xkcd.com]

P-VALUE	INTERPRETATION
0.001	HIGHLY SIGNIFICANT
0.01	
0.02	SIGNIFICANT
0.03	
0.04	OH GRAB REDO CALCULATIONS, ON THE EDGE OF SIGNIFICANCE
0.049	
0.050	HIGHLY SUGGESTIVE, SIGNIFICANT AT THE P<0.10 LEVEL
0.051	
0.06	HEY LOOK AT THIS INTERESTING SUBGROUP ANALYSIS
0.07	
0.08	
0.09	
0.099	
≥ 0.1	

Einfacher Test der H_0 Hypothese

- Oft ist man in der Situation, beurteilen zu müssen, **wie kompatibel ein vorgegebenes Modell** (H_0) mit einer vorliegenden Meßreihe ist.
- Die Kompatibilität kann **mit Hilfe des p -Wertes quantifiziert** werden. Solche Tests bezeichnet man gemeinhin als **goodness-of-fit** Tests.



- Stellen Sie sich vor, Sie haben nach **20-maligem Wurf einer Münze 17 mal Kopf und 3 mal Zahl** erhalten. Wie kompatibel ist die Hypothese $p(\text{Kopf}) = 0.5$ mit diesem Ausgang der Meßreihe?

$$B(p, n, k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

$$\mu = np = 10 \quad \sigma^2 = np(1 - p) = 5 \quad (\text{Abweichung von } 3.13\sigma)$$

Sie berechnen den p -Wert als Summe der Wahrscheinlichkeiten für das **Auftreten einer Abweichung vom Erwartungswert, die größer oder gleich der beobachteten ist**:

$$p = \sum_{k \in \{0, 1, 2, 3, 17, 18, 19, 20\}} B(p = 1/2, n = 20, k) = 0.0026$$

Achtung:

Bei einer Münze ist $H_0 : p(\text{Kopf}) = 0.5$ eine sehr valide Annahme. Überlegen Sie sich genau, wann sie diese Hypothese ins Wanken bringen möchten.

Beispiel: Zählexperiment

- Stellen Sie sich vor, sie haben in einem Zählexperiment (z.B. für den Nachweis eines sterilen Neutrinos) **4 Ereignisse nachgewiesen**. Sie erwarten aus Ihrer **Untergrundhypothese 1 Ereignis**. Sollten Sie das Nobelpreiskomitee informieren?

$$P(\mu, k) = \frac{\mu^k}{k!} e^{-\mu}$$




$$\mu = np = 1 \quad \sigma^2 = np = 1 \quad (\text{Abweichung von } 3.0\sigma)$$

Sie berechnen den p -Wert als Summe der Wahrscheinlichkeiten für das **Auftreten einer Abweichung vom Erwartungswert, die größer oder gleich der beobachteten ist**:

$$p = 1 - \left(\underset{\substack{\text{0 Ereignis(se)}}}{1} + \underset{\substack{\text{1 Ereignis(se)}}}{\mu} + \underset{\substack{\text{2 Ereignis(se)}}}{\mu^2/2} + \underset{\substack{\text{3 Ereignis(se)}}}{\mu^3/6} \right) e^{-1} = 0.019$$

Beispiel: Least Square Teststatistik




- Sie können auch die **Least Square Teststatistik**, $\hat{\theta}_{LS}$ für einen goodness-of-fit Test verwenden. Stellen Sie sich vor, Sie möchten einen Würfel auf seine Unverfälschtheit überprüfen. Dafür werfen Sie den Würfeln 100 mal und histogrammieren wie oft die Zahlen 1 bis 6 auftauchen. Wir geben drei Beispiele von Meßreihen vor:



- Welcher ist der unverfälschte Würfel?

Beispiel: Least Square Teststatistik

- Antwort können sie z.B. nach **1000 maliger Wiederholung der Meßreihe** erhalten, wenn $\hat{\theta}_{LS}$ einer $\chi^2(x, n)$ für 5 Freiheitsgrade folgt. **Warum gerade 5?**






- **Welcher ist der unverfälschte Würfel?**

Beispiel: Least Square Teststatistik

- Antwort können sie z.B. nach **1000 maliger Wiederholung der Meßreihe** erhalten, wenn $\hat{\theta}_{LS}$ einer $\chi^2(x, n)$ für 5 Freiheitsgrade folgt. **Warum gerade 5?**

Sie haben 6 Meßpunkte 1...6 minus 1 Parameter im Modell \rightarrow 5 Freiheitsgrade.




- **Welcher ist der unverfälschte Würfel?**

Test alternativer Hypothesen

- Beim Test alternativer Hypothesen stellt sich die Frage wie gut sich bei vorgegebenem Signifikanzniveau, α , die alternative **Hypothese, H_1** , von der **Nullhypothese H_0** unterscheiden lässt.

$$\beta = \int_{-\infty}^{t_0} g_{H_1}(t) dt \quad (\text{Fehler zweiter Art})$$

- Je geringer der Überlapp der beiden Wahrscheinlichkeitsdichten $g_{H_0}(t)$ und $g_{H_1}(t)$ in t , **desto besser ist das Experiment** dazu in der Lage die beiden Hypothesen zu unterscheiden.
- Man bezeichnet $1 - \beta$ als **Trennschärfe** oder **Mächtigkeit** des Tests. Die Trennschärfe ist eine **Eigenschaft des Experiments** (und der Wahl der Teststatistik).



Je geringer der Überlapp zwischen H_0 und H_1 desto höher die Trennschärfe (Mächtigkeit).

- Zum Glück gibt es bei der Wahl der Teststatistik einen eindeutigen Vorzug: Nach dem **Lemma von Neyman und Pearson** ist die Statistik mit der größten erreichbaren Trennschärfe der **Likelihood Ratio**:

$$Q = \frac{\mathcal{L}(x, \theta, H_1)}{\mathcal{L}(x, \theta, H_0)} \quad (\text{Likelihood Ratio})$$

- Oft auch als Log-Likelihood Ratio (LLR) angegeben:


$$q = -2 \ln \left(\frac{\mathcal{L}(x, \theta, H_1)}{\mathcal{L}(x, \theta, H_0)} \right) \quad (\text{Log-Likelihood Ratio})$$

- **NB:**

Der Faktor -2 wird oft verwendet und ergibt sich wieder aus der Definition von $\chi^2 = -2 \ln \mathcal{L}$. Beachten Sie, sobald Sie annehmen können, daß die Werte der Einzelmessungen nach Gauß verteilt sind, folgt die Likelihood Funktion (und unter bestimmten Bedingungen auch der Likelihood Ratio) einer χ^2 -Funktion. Das Erlaubt den Einsatz asymptotischer Formeln zur Berechnung der Varianz der Schätzwertes statt mühseliger Pseudo-Experimente.


Beispiele aus der Teilchenphysik

$$q_\mu = -2 \ln \left(\frac{\mathcal{L}(n|\mu s+b)}{\mathcal{L}(n|b)} \right), \quad 0 \leq \mu$$





Suche nach dem Higgs Boson bei LEP

Hier ist H_0 die Hypothese:
„kein Higgs Boson entdeckt“.




[arXiv:hep-ex/030633](https://arxiv.org/abs/hep-ex/030633) (im übrigen ein sehr lesenswertes Papier, dessen Anwendung statistischer Methoden zur Signalbestimmung Sie mit Abschluß dieser VL vollständig verstehen können. Dieses Papier hat das mathematische Fundament für alle weiteren Higgs Boson Suchen bis 2012 gelegt!)




Beispiele aus der Teilchenphysik

Spin und CP Hypothesentest für das Higgs Boson bei LHC



PRD 89 (2014) 092007



NB: wie Sie sehen ist die Trennschärfe dieses Tests ist nicht ausgesprochen hoch. Das liegt daran, daß der Test auf ~20 ausgewählten Ereignissen aus unzähligen am LHC aufgezeichneten Ereignissen besteht, die mit hoher Wahrscheinlichkeit Higgs Bosonen enthalten. Basierend auf mehr Ereignissen (wie sie derzeit am LHC weiter aufgezeichnet werden) werden die Stichprobenverteilungen der beiden Hypothesen immer schmaler werden, wodurch sich der Überlapp reduziert, gleichbedeutend mit einer höheren Trennschärfe.

Kapitel 3.9:

Hypothesentests

- Einfache und vergleichende Hypothesentests, χ^2 -Test, Likelihood Ratio.
- Fehler erster und zweiter Art, p -Wert.
- Einige einfache Beispiele und einige Beispiele aus dem täglichen Leben.

Famous Last Words (FLW)

- Das war die letzte Vorlesung aus dem Block Statistik in der Rechnernutzung in der Physik.
- **Was Sie mitnehmen sollten: alles...**, kehren Sie von Zeit zu Zeit zu diesen Folien zurück, sie werden auf dem web-Server verbleiben und können als Referenz dienen.
- Falls Sie Fragen haben, kommen Sie gerne bei mir vorbei: Physikhochhaus 9.20 (roger.wolf@cern.ch).
- Rechnen Sie die Übungen! Davon lernen Sie am nachhaltigsten.
- Und bleiben Sie neugierig...

