



Universität
Zürich^{UZH}

Datenanalyse

(PHY231)

Herbstsemester 2017

Olaf Steinkamp



Vorlesungsprogramm

- **Einführung, Messunsicherheiten, Darstellung von Messdaten**
- **Grundbegriffe der Wahrscheinlichkeitsrechnung und Statistik**
 - Mittelwert, Standardabweichung, Kovarianz und Korrelation
- **Fehlerfortpflanzungsgesetz**
- **Wahrscheinlichkeitsverteilungen**
 - diskrete Verteilungen, kontinuierliche Verteilungen
 - zentraler Grenzwertsatz
- **Monte-Carlo Methode**
- **Wahrscheinlichkeitsverteilungen II**
 - Faltung zweier Verteilungen
 - Verteilungen zweier Variablen
- **Stichproben und Schätzfunktionen**
 - Maximum-Likelihood Methode
 - Methode der kleinsten Quadrate
- **Interpretation von Messergebnissen**
 - Konfidenzintervalle, Testen von Hypothesen

Beispielprogramme im
Verzeichnis

`/disk/puma/da/vorl/ml`



Stichproben und Schätzungen

Zufallsvariable x folgt einer Wahrscheinlichkeitsverteilung $f(x|a)$

- $f(x|a)$ hängt von einem oder mehreren Parametern a ab
 - kenne die funktionale Form von $f(x|a)$, aber nicht die Werte der Parameter a
- **habe eine endliche Anzahl Werte der Zufallsvariable x (“Stichprobe”)**
 - will aus dieser Stichprobe die Werte der Parameter a schätzen

a : wahrer Wert des Parameters

\hat{a} : aus der Stichprobe berechneter Schätzwert

Beispiel: Zerfall eines radioaktiven Isotops

- **Zerfallszeiten folgen einer Exponentialverteilung, $f(t | \lambda) = \lambda \cdot e^{-\lambda t}$**
 - der Wert der Zerfallskonstante λ ist nicht bekannt und soll gemessen werden
- **Experiment ergibt eine endliche Anzahl gemessener Zerfallszeiten**
 - bestimme aus diesen gemessenen Zerfallszeiten einen Schätzwert $\hat{\lambda}$ für λ



Schätzwerte sind Zufallsvariablen


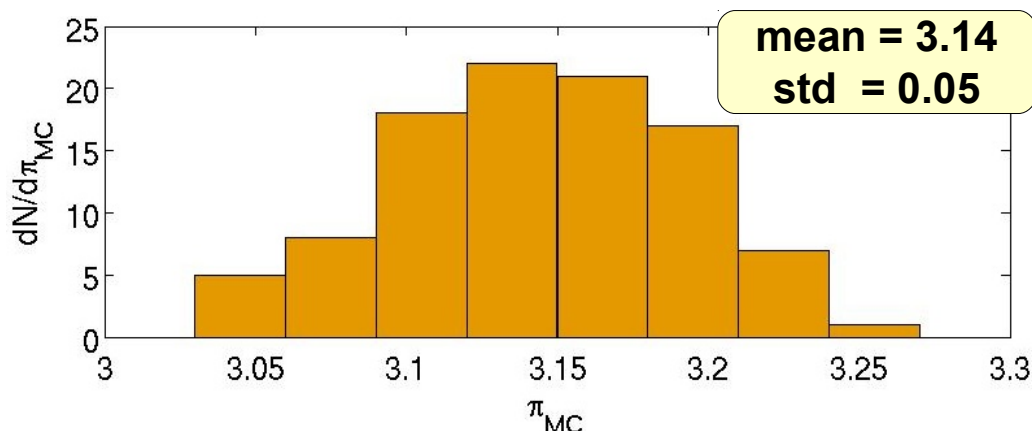
Stichprobe = zufällige Werte aus der Wahrscheinlichkeitsverteilung

- neue Stichprobe \rightarrow andere zufällige Werte \rightarrow anderer Schätzwert \hat{a}
- viele Stichproben \rightarrow Zufallsverteilung für \hat{a}

Schätzwert hat einen Erwartungswert $\langle \hat{a} \rangle$ und eine Varianz $V(\hat{a})$

Beispiel Monte-Carlo Bestimmung von π (s. Vorlesung vor zwei Wochen)

- eine Stichprobe aus 1000 Zufallszahlenpaaren \rightarrow ein Schätzwert für π
- 100 Stichproben \rightarrow 100 Schätzwerte für π





Schätzfunktionen

Schätzfunktion = Algorithmus zur Berechnung von Schätzwerten

- **Ansprüche an “gute” Schätzfunktionen:**
 - **Konsistenz:** Schätzwert soll gegen den wahren Wert des Parameters streben, wenn der Umfang der Stichprobe gegen unendlich strebt
 - **Erwartungstreue:** Schätzwert soll “im Mittel” über viele Stichproben den wahren Wert ergeben, egal wie groß der Umfang der Stichproben ist
 - **Effizienz:** Streuung der Schätzwerte soll für gegebene Größe der Stichproben möglichst klein sein
 - **Robustheit:** Schätzwert soll möglichst unempfindlich gegen “Ausreisser” in der Stichprobe sein
- **verschiedene Ansätze zur Herleitung von Schätzfunktionen**
 - bekannteste: “Maximum Likelihood”, “Methode kleinster Quadrate” (χ^2 -Methode)
- **können verschiedene Schätzfunktionen ergeben**
 - darum: zusammen mit dem Ergebnis immer auch die gewählte Methode angeben



Beispiel: Erwartungswert einer Verteilung

Schätzfunktion für den Erwartungswert μ einer Verteilung

- naheliegender Ansatz: Mittelwert der Stichprobe

$$\hat{\mu} \equiv \bar{\mathbf{x}} = \frac{1}{N} \cdot \sum_{i=1}^N \mathbf{x}_i$$

- $\hat{\mu}$ ist “konsistent”, d.h. $\hat{\mu} \rightarrow \mu$ für $N \rightarrow \infty$

Gesetz großer Zahlen: $\hat{\mu} = \bar{\mathbf{x}} \rightarrow \langle \mathbf{x} \rangle \equiv \mu$ für $N \rightarrow \infty$

- $\hat{\mu}$ ist “erwartungstreu”, d.h. $\langle \hat{\mu} \rangle = \mu$ egal wie groß N ist

$$\langle \hat{\mu} \rangle = \langle \bar{\mathbf{x}} \rangle = \langle \mathbf{x} \rangle = \mu$$



Beispiel: Varianz einer Verteilung

Schätzfunktion für die Varianz $V(x)$ einer Verteilung

- naheliegender Ansatz: Varianz der Stichprobe
- ist konsistent (Gesetz großer Zahlen), aber nicht “erwartungstreu”:

$$\begin{aligned}
 \langle \hat{V} \rangle &= \left\langle \frac{1}{N} \sum (x_i - \bar{x})^2 \right\rangle \\
 &= \underbrace{\left\langle \frac{1}{N} \sum x_i^2 \right\rangle}_{= \langle x^2 \rangle} - 2 \cdot \underbrace{\left\langle \frac{1}{N} \sum x_i \bar{x} \right\rangle}_{= \langle \bar{x}^2 \rangle} + \underbrace{\left\langle \frac{1}{N} \sum \bar{x}^2 \right\rangle}_{= \langle \bar{x}^2 \rangle} \\
 &= \langle x^2 \rangle - \langle \bar{x}^2 \rangle \quad \left| \text{addiere } \langle \bar{x} \rangle^2 - \langle x \rangle^2 = 0 \right. \\
 &= \underbrace{\left(\langle x^2 \rangle - \langle x \rangle^2 \right)}_{= V(x)} - \underbrace{\left(\langle \bar{x}^2 \rangle - \langle \bar{x} \rangle^2 \right)}_{= V(\bar{x}) = V(x)/N} = \boxed{\frac{N-1}{N} \cdot V(x)}
 \end{aligned}$$

- Erwartungstreue Schätzfunktion für die Varianz der wahren Verteilung:

$$\hat{V} \equiv \frac{N}{N-1} \cdot \left\{ \frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^2 \right\} = \frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \bar{x})^2$$



Beispiel: Stichproben einer Gaußverteilung

Erzeuge Stichproben von je 10 Zufallszahlen

- gaußverteilt mit $\mu = 10$, $\sigma = 1$
- berechne Mittelwert, Standardabweichung für jede der Stichproben
- Mittelwert der Mittelwerte $\rightarrow 10$
- Mittelwert der Standardabweichungen $\rightarrow 0.93$

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats

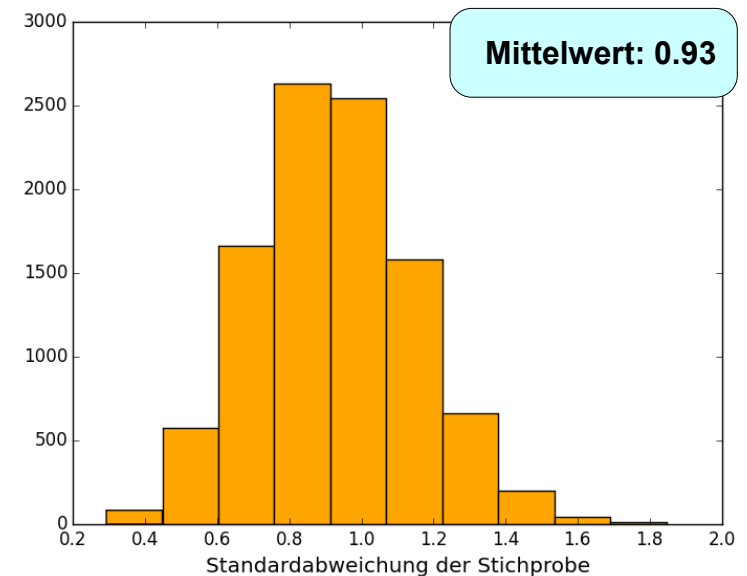

x = stats.norm(10.0,1.0).rvs([10,10000])

meansample = mean(x,0)
sigmasample = std(x,0)

hist(meansample,facecolor='green')
xlabel("Mittelwert der Stichprobe",fontsize='large')
figure()
hist(sigmasample,facecolor='orange')
xlabel("Standardabweichung der Stichprobe",fontsize='large')

print("Mean of means: %5.2f"%mean(meansample))
print("Mean of sigmas: %5.2f"%mean(sigmasample))
```

erwartungstreu.py





Zwei Standardabweichungen

(1) Standardabweichung der x_i selbst

$$\sigma \equiv \sqrt{\frac{1}{N} \cdot \sum_{i=1}^N (x_i - \bar{x})^2}$$

- z.B. messe den Wert eines Widerstandes und bestimme aus der Streuung der Messergebnisse die Genauigkeit meiner Messung

(2) Schätzfunktion für die Standardabweichung der zugrundeliegenden “theoretischen” Verteilung

$$\sigma \equiv \sqrt{\frac{1}{N-1} \cdot \sum_{i=1}^N (x_i - \bar{x})^2}$$

- z.B. überwache eine Produktionslinie für elektrische Widerstände: messe für eine Stichprobe der produzierten Bauteile deren Widerstand und will aus der Streuung der Messergebnisse die Präzision der Produktion abschätzen

**je kleiner der Umfang der Stichprobe,
desto größer der Unterschied zwischen den zwei Definitionen**



Vorlesungsprogramm

- Einführung, Messunsicherheiten, Darstellung von Messdaten
- Grundbegriffe der Wahrscheinlichkeitsrechnung und Statistik
 - Mittelwert, Standardabweichung, Kovarianz und Korrelation
- Fehlerfortpflanzungsgesetz
- Wahrscheinlichkeitsverteilungen
 - diskrete Verteilungen, kontinuierliche Verteilungen
 - zentraler Grenzwertsatz
- Monte-Carlo Methode
- Wahrscheinlichkeitsverteilungen II
 - Faltung zweier Verteilungen
 - Verteilungen zweier Variablen
- Stichproben und Schätzfunktionen
 - Maximum-Likelihood Methode
 - Methode der kleinsten Quadrate
- Interpretation von Messergebnissen
 - Konfidenzintervalle, Testen von Hypothesen

Beispielprogramme im
Verzeichnis

`/disk/puma/da/vorl/ml`



Maximum-Likelihood Methode

Sehr häufig benutzte Methode zur Herleitung von Schätzfunktionen

- habe Wahrscheinlichkeitsverteilung $f(x|a)$
 - habe Stichprobe aus N Werten $x_i (i = 1, \dots, N)$
- } suche Schätzfunktion \hat{a} für die Parameter a
- **Ansatz: bestimme die Likelihood Funktion** (“likelihood” = Wahrscheinlichkeit)

$$L(\mathbf{a}) \equiv f(\mathbf{x}_1 | \mathbf{a}) \cdot f(\mathbf{x}_2 | \mathbf{a}) \cdot \dots \cdot f(\mathbf{x}_N | \mathbf{a}) = \prod_{i=1}^N f(\mathbf{x}_i | \mathbf{a})$$

- $L(a)$ gibt die Wahrscheinlichkeit an, die gegebene Stichprobe zu erhalten
- $L(a)$ ist eine Funktion der Parameter a
- wähle als Schätzwerte \hat{a} diejenigen Werte der Parameter, die $L(a)$ maximieren
 - d.h. wähle als Schätzwerte diejenigen Werte der Parameter, die die größte Wahrscheinlichkeit ergeben, die gegebene Stichprobe zu erhalten
- **rechentechnisch vorteilhaft: suche Maximum der “Log-likelihood” Funktion**

$$\ln L(\mathbf{a}) = \ln f(\mathbf{x}_1 | \mathbf{a}) + \ln f(\mathbf{x}_2 | \mathbf{a}) + \dots + \ln f(\mathbf{x}_N | \mathbf{a}) = \sum_{i=1}^N \ln f(\mathbf{x}_i | \mathbf{a})$$



Einfaches Beispiel

Aus dem Buch “Statistics” von Roger Barlow

- Zufallsvariable x folgt

$$f(x|a) = 1 + a \cdot (x - 0.5)$$

- Stichprobe aus 5 Werten:

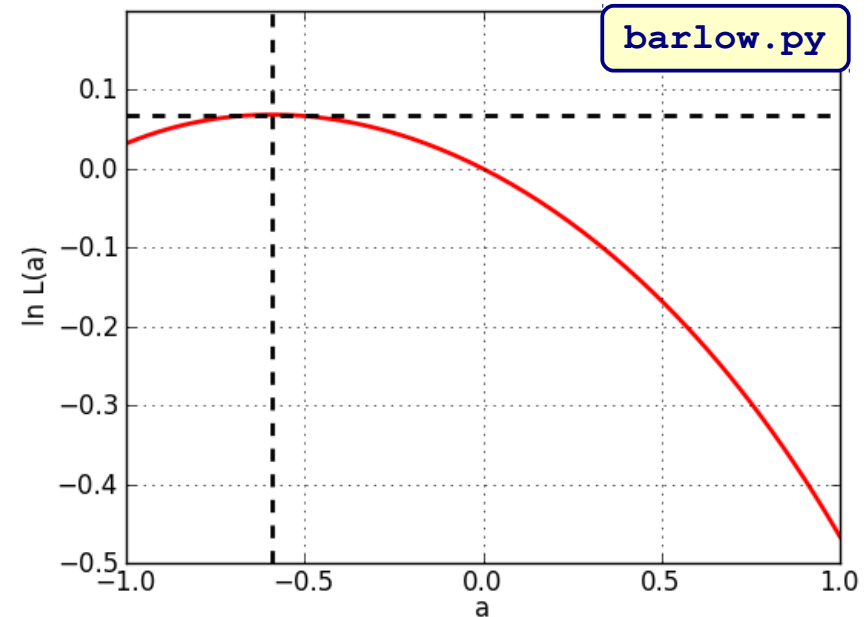
$$x_i = 0.89, 0.03, 0.50, 0.36, 0.49$$

- Log-likelihood Funktion:

$$\ln L(a) = \sum \ln(1 + a \cdot (x_i - 0.5))$$

- Maximum von $\ln L(a)$ bei $a = -0.6$

⇒ Schätzwert $\hat{a} = -0.6$



Finden des Maximums:

- analytisch durch Lösen von $\frac{d(\ln L)}{da} = 0$
- numerisch
- durch Abtasten des Parameterraums

numerische Algorithmen suchen meist Minima einer Funktion
⇒ suche Minimum von $-\ln L$



Beispiel mittlere Lebensdauer

Radioaktive Quelle: exponentialverteilte Zerfallszeiten

- Wahrscheinlichkeitsdichte $f(t | \tau) = 1/\tau \cdot e^{-t/\tau}$
 - Stichprobe aus N gemessenen Zerfallszeiten t_i
 - Log-likelihood Funktion
- } suche Schätzfunktion für mittlere Lebensdauer τ

$$\ln L(\tau) = \sum_{i=1}^N \ln f(t_i | \tau) = \sum_{i=1}^N \ln \left(\frac{1}{\tau} \cdot e^{-t_i/\tau} \right) = \sum_{i=1}^N \left(-\ln \tau - \frac{t_i}{\tau} \right)$$

- Maximum von $\ln L(\tau)$ durch Lösen von $d(\ln L)/d\tau = 0$

$$\frac{d(\ln L)}{d\tau} = \sum_{i=1}^N \left\{ -\frac{1}{\tau} + \frac{t_i}{\tau^2} \right\} = -\frac{N}{\tau} + \frac{1}{\tau^2} \cdot \sum_{i=1}^N t_i = 0 \Rightarrow \hat{\tau} = \frac{1}{N} \cdot \sum_{i=1}^N t_i$$

**Maximum Likelihood Schätzfunktion für mittlere Lebensdauer =
Mittelwert der gemessenen Zerfallszeiten**



Beispiel mittlere Lebensdauer (II)

Aber: messe im Experiment keine beliebig langen Zerfallszeiten

- muss in der Definition der Wahrscheinlichkeitsdichte berücksichtigt werden
 - Erinnerung: Wahrscheinlichkeitsdichten müssen auf 1 normiert sein !
- Zerfallszeiten zwischen $t = 0$ und $t = t_{\max}$

$$\int_0^{t_{\max}} \frac{1}{\tau} \cdot e^{-t/\tau} dt = 1 - e^{-t_{\max}/\tau} \Rightarrow g(t | \tau) = \frac{1}{(1 - e^{-t_{\max}/\tau})} \cdot \frac{1}{\tau} \cdot e^{-t/\tau}$$

- Log-likelihood Funktion

$$\ln L(\tau) = \sum_{i=1}^N \ln g(t_i | \tau) = -N \cdot \ln(1 - e^{-t_{\max}/\tau}) - N \cdot \ln \tau - \frac{1}{\tau} \cdot \sum_{i=1}^N t_i$$

- suche Maximum: $d(\ln L(\tau))/d\tau = 0$

$$\hat{\tau} = t_{\max} \cdot \frac{e^{-t_{\max}/\hat{\tau}}}{1 - e^{-t_{\max}/\hat{\tau}}} + \frac{1}{N} \cdot \sum_{i=1}^N t_i$$

Gleichung für $\hat{\tau}$, kann aber nicht analytisch gelöst werden



Beispiel mittlere Lebensdauer (III)


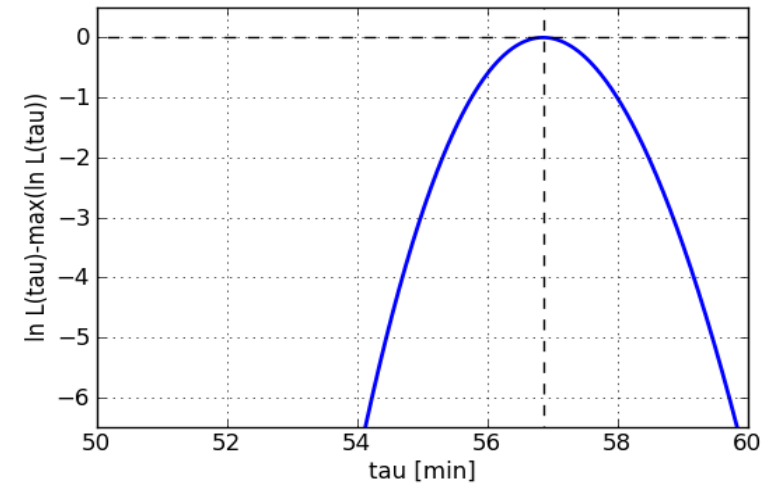
Monte-Carlo Beispiel: finde Maximum durch Abtasten von τ

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge exponentialverteilte Zufallszahlen
#
tautruue = 56.0 ; tmax = 180.0
t = stats.expon(0.0,tautruue).rvs(10000)
#
# verwirfe alle Zufallszahlen > tmax
#
t = t[t<tmax]
#
# einfacher Mittelwert der verbleibenden Zufallszahlen
#
tmean = mean(t)
#
# berechne ln L als Funktion der angenommenen Lebensdauer
# und finde das Maximum
#
nt = len(t)
tau = frange(50.0,60.0,0.02)
logl = nt*(-log(tau)-log(1-exp(-tmax/tau)))-sum(t)/tau
tauml = tau[argmax(logl)]

hold(True)
plot(tau,logl-max(logl))
plot([tauml,tauml],[-7.0,1.0],'k--')

print("ML estimator for tau:    %5.2f min"%tauml)
print("Mean of measured times: %5.2f min"%tmean)
```

mlexpo.py



True mean decay time = 56.00 min
ML estimator for tau = 56.70 min
Mean of measured times = 48.27 min



Beispiel gewichteter Mittelwert

Habe N Messungen x_i einer Größe X mit Messunsicherheiten σ_i

- Annahme 1: die N Messungen sind voneinander unabhängig
- Annahme 2: Messabweichungen sind gaußverteilt

Messergebnis x_i entstammt einer Gaußverteilung mit Erwartungswert X und Standardabweichung σ_i

- Wahrscheinlichkeit für das Messergebnis x_i

$$f(x_i | X, \sigma_i) = \frac{1}{\sqrt{2\pi\sigma_i^2}} \cdot e^{-\frac{(x_i - X)^2}{2\sigma_i^2}}$$

- Log-likelihood als Funktion von X :

$$\ln L(X) = \sum_{i=1}^N \ln(f(x_i | X, \sigma_i)) = -\sum_{i=1}^N (\ln \sqrt{2\pi\sigma_i^2}) - \sum_{i=1}^N \frac{(x_i - X)^2}{2\sigma_i^2}$$

- Maximum-Likelihood Schätzfunktion für X :

$$\frac{d(\ln L)}{dX} = \sum_{i=1}^N \frac{x_i - X}{\sigma_i^2} = \sum_{i=1}^N \frac{x_i}{\sigma_i^2} - X \cdot \sum_{i=1}^N \frac{1}{\sigma_i^2} = 0 \Rightarrow$$

$$\hat{X} = \frac{\sum_{i=1}^N x_i / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2}$$



Unsicherheit auf dem Schätzwert

Taylor-Entwicklung der log-likelihood Funktion um $a = \hat{a}$

$$\ln L(\mathbf{a}) \approx \ln L(\hat{\mathbf{a}}) + \underbrace{\left[\frac{d(\ln L)}{da} \right]_{a=\hat{a}}}_{= 0 \text{ weil } \hat{a} \text{ Maximum}} \cdot (\mathbf{a} - \hat{\mathbf{a}}) + \frac{1}{2} \cdot \left[\frac{d^2(\ln L)}{da^2} \right]_{a=\hat{a}} \cdot (\mathbf{a} - \hat{\mathbf{a}})^2 + \dots$$

- nehme an, Abweichungen des Schätzwerts vom wahren Wert sind nicht zu gross \rightarrow breche Entwicklung nach dem quadratischen Term ab

$$\Rightarrow L(\mathbf{a}) \approx L(\hat{\mathbf{a}}) \cdot e^{\frac{1}{2} \left[\frac{d^2(\ln L)}{da^2} \right]_{a=\hat{a}} (\mathbf{a} - \hat{\mathbf{a}})^2}$$

- für großen Stichprobenumfang ($N \rightarrow \infty$) gilt zentraler Grenzwertsatz: Wahrscheinlichkeitsverteilung für Schätzwert nähert sich Gaußverteilung an

$$p(\hat{\mathbf{a}}) \approx \frac{1}{\sqrt{2\pi\sigma_{\hat{\mathbf{a}}}^2}} \cdot e^{-\frac{(\hat{\mathbf{a}} - \mathbf{a})^2}{2\sigma_{\hat{\mathbf{a}}}^2}}$$

- definiere $\sigma_{\hat{\mathbf{a}}}$ durch Gleichsetzen

$$-\frac{1}{\sigma_{\hat{\mathbf{a}}}^2} = \left[\frac{d^2(\ln L)}{da^2} \right]_{a=\hat{\mathbf{a}}} \Leftrightarrow \sigma_{\hat{\mathbf{a}}}^2 = \left(- \left[\frac{d^2(\ln L)}{da^2} \right]_{a=\hat{\mathbf{a}}} \right)^{-1}$$

Großer Stichprobenumfang ($N \rightarrow \infty$)

- log-likelihood Funktion parabelförmig

$$\ln L(\mathbf{a}) = \ln L(\hat{\mathbf{a}}) - \frac{(\mathbf{a} - \hat{\mathbf{a}})^2}{2\sigma_{\hat{\mathbf{a}}}^2}$$

- Unsicherheit $\sigma_{\hat{\mathbf{a}}}$ aus der Breite der Parabel

$$\ln L(\hat{\mathbf{a}} \pm \sigma_{\hat{\mathbf{a}}}) = \ln L(\hat{\mathbf{a}}) - 0.5$$

$$\ln L(\hat{\mathbf{a}} \pm 2\sigma_{\hat{\mathbf{a}}}) = \ln L(\hat{\mathbf{a}}) - 2.0$$

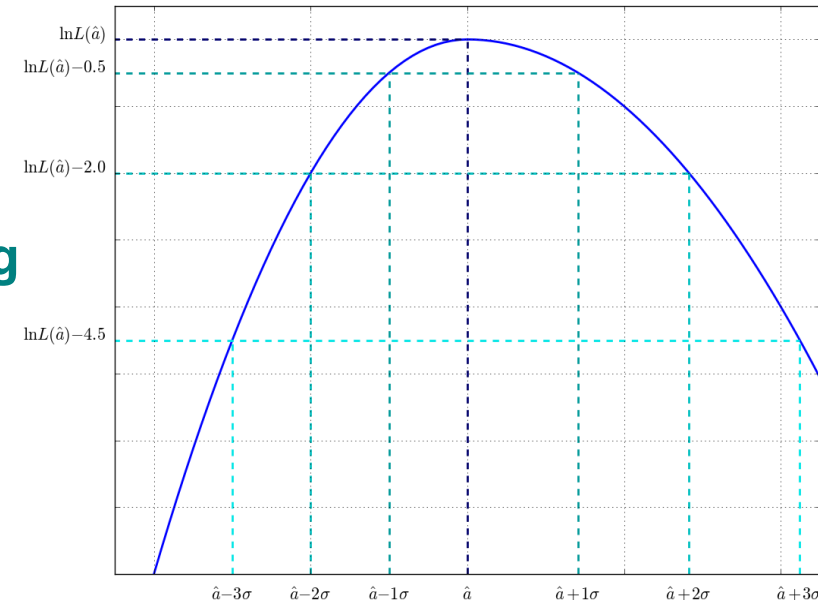

$$\ln L(\hat{\mathbf{a}} \pm 3\sigma_{\hat{\mathbf{a}}}) = \ln L(\hat{\mathbf{a}}) - 4.5$$

Stichprobenumfang N nicht groß genug:

- log-likelihood Funktion i.a. nicht parabelförmig
- definiere Unsicherheit auf $\hat{\mathbf{a}}$ dennoch als

$$\ln L(\hat{\mathbf{a}} \pm n \cdot \sigma_{\hat{\mathbf{a}}}) \equiv \ln L(\hat{\mathbf{a}}) - n^2/2$$

- ergibt u.U. asymmetrische Unsicherheiten




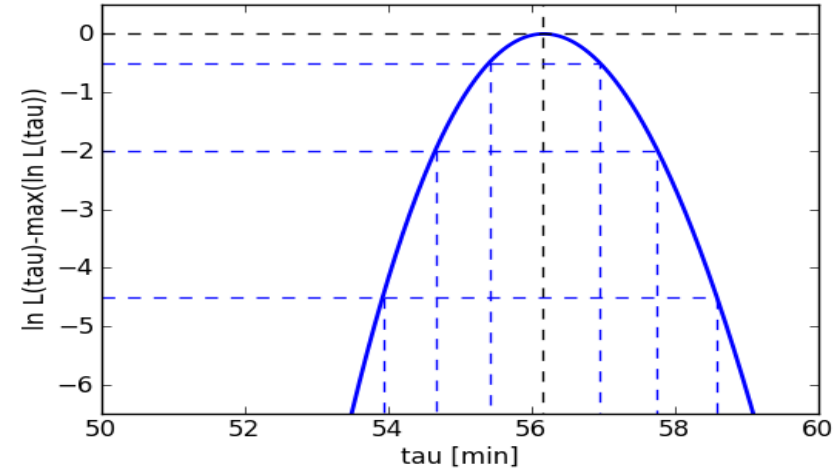


Beispiel mittlere Lebensdauer (IV)

Monte-Carlo Beispiel: Unsicherheit auf $\hat{\tau}$ aus der likelihood-Parabel

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge exponentialverteilte Zufallszahlen
#
tautruue = 56.0 ; tmax = 180.0
t = stats.expon(0.0,tautruue).rvs(10000)
#
# verwirfe alle Zufallszahlen > tmax
#
t = t[t<tmax]
#
# berechne ln L als Funktion der angenommenen Lebensdauer
# und finde das Maximum
#
nt = len(t)
tau = frange(50.0,60.0,0.02)
logl = nt*(-log(tau)-log(1-exp(-tmax/tau)))-sum(t)/tau
tauml = tau[argmax(logl)]
#
# finde Werte von tau, bei denen der Wert von ln L um
# 0.5, 2.0, 4.5 etc vom Wert Maximum abgefallen ist
#
for i in range(1,4):
    c = logl-max(logl)>-i**2/2.0
    tauilo = min(tau[c])
    tauhi = max(tau[c])
#
# weitere Befehle hier nicht gezeigt ...
```

mlexperr.py



ML estimator for lifetime τ = 55.60 min
 -1 sigma = -0.70 min, +1 sigma = 0.70 min
 -2 sigma = -1.40 min, +2 sigma = 1.50 min
 -3 sigma = -2.20 min, +3 sigma = 2.30 min



Verallgemeinerung auf n Parameter

Wahrscheinlichkeitsverteilung hängt von n Parametern a_i ab ($i=1, \dots, n$)

- finde Schätzfunktionen $\hat{a}_1, \dots, \hat{a}_n$ durch Lösen des Gleichungssystems

$$\frac{\partial \ln L(a_1, a_2, \dots, a_n)}{\partial a_i} = 0 \quad \text{für } i=1, \dots, n$$

- Fehlermatrix für die \hat{a}_i durch Invertieren der Matrix

$$\mathbf{V}_{ij}^{-1} = \text{cov}^{-1}(a_i, a_j) = \left[-\frac{\partial^2 \ln L}{\partial a_i \partial a_j} \right]_{a_i=\hat{a}_i, a_j=\hat{a}_j}$$

- definiere n - σ Konfidenzregionen auf den \hat{a}_i durch

$$\ln L(a_i) = \ln L(\hat{a}_i) - n^2 / 2$$

- großer Stichprobenumfang ($N \rightarrow \infty$): $L(a_1, \dots, a_n) \rightarrow n$ -dim Gaußverteilung
- $n=2$: $L(a_1, a_2) \rightarrow 2$ -dim Gaußverteilung; Konfidenzregionen \rightarrow konzentrische Ellipsen
- N nicht groß genug: kompliziertere Konturen, eventuell lokale Maxima



Beispiel Anpassung einer Geraden

Passe Geradengleichung $y = a_0 + a_1 \cdot x$ an N Messpaare (x_i, y_i) an

- Annahme 1: Messunsicherheiten auf den x_i sind vernachlässigbar klein
- Annahme 2: Abweichungen der gemessenen y_i von den erwarteten Werten

$$y = a_0 + a_1 \cdot x_i$$

sind gaußverteilt mit Standardabweichungen σ_i

- **Wahrscheinlichkeit für eines der Wertepaare**

$$p(y_i | a_0, a_1) = \frac{1}{\sqrt{2\pi\sigma_i^2}} e^{-\frac{(y_i - a_0 - a_1 \cdot x_i)^2}{2\sigma_i^2}}$$

- Annahme 3: keine Korrelationen zwischen den Abweichungen auf den y_i
- **log-likelihood Funktion für alle Wertepaare**

$$\ln L(a_0, a_1) = \underbrace{\sum_{i=1}^N \ln \left(\frac{1}{\sqrt{2\pi\sigma_i^2}} \right)}_{= \text{konst}} - \sum_{i=1}^N \frac{(y_i - a_0 - a_1 \cdot x_i)^2}{2\sigma_i^2}$$



Beispiel Anpassung einer Geraden

Vereinfachung: Messunsicherheiten auf allen y_i gleich gross ($\sigma_i = \sigma$)

$$\ln L(\mathbf{a}_0, \mathbf{a}_1) = - \sum_{i=1}^N \frac{(y_i - \mathbf{a}_0 - \mathbf{a}_1 \cdot \mathbf{x}_i)^2}{2\sigma^2} + \text{konst}$$

- zwei gekoppelte Gleichungen für zwei Schätzfunktionen \hat{a}_0 und \hat{a}_1

$$\left[\frac{\partial(\ln L)}{\partial \mathbf{a}_1} \right]_{\substack{\mathbf{a}_0 = \hat{a}_0 \\ \mathbf{a}_1 = \hat{a}_1}} = \sum_{i=1}^N \left\{ \frac{(y_i - \hat{a}_0 - \hat{a}_1 \cdot \mathbf{x}_i) \cdot \mathbf{x}_i}{\sigma^2} \right\} = \mathbf{0} \Rightarrow \sum_{i=1}^N \mathbf{x}_i y_i - \hat{a}_0 \cdot \sum_{i=1}^N \mathbf{x}_i - \hat{a}_1 \cdot \sum_{i=1}^N \mathbf{x}_i^2 = \mathbf{0}$$

$$\left[\frac{\partial(\ln L)}{\partial \mathbf{a}_0} \right]_{\substack{\mathbf{a}_0 = \hat{a}_0 \\ \mathbf{a}_1 = \hat{a}_1}} = \sum_{i=1}^N \left\{ \frac{y_i - \hat{a}_0 - \hat{a}_1 \cdot \mathbf{x}_i}{\sigma^2} \right\} = \mathbf{0} \Rightarrow \sum_{i=1}^N y_i - \hat{a}_0 \cdot \sum_{i=1}^N \mathbf{1} - \hat{a}_1 \cdot \sum_{i=1}^N \mathbf{x}_i = \mathbf{0}$$

- in Matrixschreibweise:

$$\begin{pmatrix} \sum_{i=1}^N \mathbf{x}_i & \sum_{i=1}^N \mathbf{1} \\ \sum_{i=1}^N \mathbf{x}_i^2 & \sum_{i=1}^N \mathbf{x}_i \end{pmatrix} \cdot \begin{pmatrix} \hat{a}_1 \\ \hat{a}_0 \end{pmatrix} = \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N \mathbf{x}_i y_i \end{pmatrix} \quad \underbrace{\Leftrightarrow}_{\times 1/N} \quad \begin{pmatrix} \bar{\mathbf{x}} & \mathbf{1} \\ \overline{\mathbf{x}^2} & \bar{\mathbf{x}} \end{pmatrix} \cdot \begin{pmatrix} \hat{a}_1 \\ \hat{a}_0 \end{pmatrix} = \begin{pmatrix} \bar{y} \\ \overline{\mathbf{x}y} \end{pmatrix}$$



Beispiel Anpassung einer Geraden

- Auflösen nach \hat{a}_0 und \hat{a}_1

$$\hat{a}_0 = \frac{\overline{x^2 y} - \bar{x} \overline{xy}}{\overline{x^2} - \bar{x}^2}$$

$$\hat{a}_1 = \frac{\overline{xy} - \bar{x} \bar{y}}{\overline{x^2} - \bar{x}^2}$$

- Kovarianzmatrix

$$\text{cov}^{-1}(\hat{a}_0, \hat{a}_1) = - \left(\begin{array}{cc} \frac{\partial^2 \ln L}{\partial a_0^2} & \frac{\partial^2 \ln L}{\partial a_0 \partial a_1} \\ \frac{\partial^2 \ln L}{\partial a_0 \partial a_1} & \frac{\partial^2 \ln L}{\partial a_1^2} \end{array} \right)_{\substack{a_0 = \hat{a}_0 \\ a_1 = \hat{a}_1}} = \frac{1}{\sigma^2} \cdot \left(\begin{array}{cc} \sum_{i=1}^N \mathbf{1} & \sum_{i=1}^N \mathbf{x}_i \\ \sum_{i=1}^N \mathbf{x}_i & \sum_{i=1}^N \mathbf{x}_i^2 \end{array} \right) = \frac{N}{\sigma^2} \cdot \left(\begin{array}{cc} \mathbf{1} & \bar{\mathbf{x}} \\ \bar{\mathbf{x}} & \overline{\mathbf{x}^2} \end{array} \right)$$

$$\Rightarrow \text{cov}(\hat{a}_0, \hat{a}_1) = \frac{\sigma^2}{N \cdot (\overline{\mathbf{x}^2} - \bar{\mathbf{x}}^2)} \cdot \left(\begin{array}{cc} \overline{\mathbf{x}^2} & -\bar{\mathbf{x}} \\ -\bar{\mathbf{x}} & \mathbf{1} \end{array} \right)$$





Beispiel in pylab

Analytische Bestimmung der Schätzwerte und ihrer Unsicherheiten

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge Wertepaare gemaess Geradengleichung
# mit gaussverteilten Abweichungen auf den y
#
a = 2.0 ; b = 0.5 ; sig = 0.5
x = frange(1.0,10.0,1.0)
nx = len(x)
y = a*x+b+stats.norm(0.0,sig).rvs(nx)
#
# berechne ML Schaetzwerte und Kovarianzmatrix
#
xmean = mean(x)
ymean = mean(y)
xymean = mean(x*y)
xxmean = mean(x*x)
varx = xxmean-xmean**2
ahat = (xymean-xmean*ymean)/varx
bhat = ymean - ahat*xmean
vara = sig**2/(nx*varx)
varb = vara*xxmean
covab = -xmean*vara
#
# zeichne Wertepaare und angepasste Gerade
#
errorbar(x,y,yerr=sig,fmt='ro')
hold(True)
plot(x,x*ahat+bhat,'b-',linewidth=2)
#
# weitere Befehle hier nicht gezeigt ...
```

mlline.py



```
Estimate for a = 2.012 +/- 0.055
Estimate for b = 0.608 +/- 0.342
Corr coeff      = -0.8864
Cov matrix      = 0.003   -0.017
                  -0.017   0.117
```





Beispiel in pylab

Schätzwerte und Unsicherheiten durch Abtasten in der (a,b)-Ebene

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge Wertepaare gemaess Geradengleichung
# mit gaussverteilten Abweichungen auf den y
#
a = 2.0 ; b = 0.5 ; sig = 0.5
x = frange(1.0,10.0,1.0)
nx = len(x)
y = a*x+b+stats.norm(0.0,sig).rvs(nx)
#
# berechne extended log likelihood auf Raster angenommener
# Werte der zwei Parameter, suche Maximum
#
amin = 1.85 ; amax = 2.15 ; abin = 0.0003
bmin = -0.25 ; bmax = 1.25 ; bbin = 0.0015
am,bm = meshgrid(frange(amin,amax,abin),frange(bmin,bmax,bbin))
ll = zeros(shape(am))
for i in range(0,nx):
    ll -= (y[i]-am*x[i]-bm)**2/(2.0*sig**2)
ahat = am.flatten()[argmax(ll)]
bhat = bm.flatten()[argmax(ll)]
#
# bestimme Unsicherheit auf den Schaetzwerten aus Breite
# der log-likelihood als Funktion jedes der zwei Parameter
#
ll -= ll.max()
ahi = am[ll>-0.5].max()-ahat ; alo = ahat-am[ll>-0.5].min()
bhi = bm[ll>-0.5].max()-bhat ; blo = bhat-bm[ll>-0.5].min()
#
# weitere Befehle hier nicht gezeigt ...
```

mlline2.py



estimate for a = 2.012 +/- 0.055
estimate for b = 0.608 +/- 0.342



“Binned” Maximum-Likelihood

Stichprobe besteht aus Histogramm mit N Intervallen

- Intervall-Zentren: x_i ($i = 1, \dots, N$)
- Intervall-Breiten: Δx_i ($i = 1, \dots, N$)
- Anzahl Einträge pro Intervall: n_i (gesamte Anzahl Einträge: $n = \sum_{i=1}^N n_i$)


Zufallsvariable x folgt Wahrscheinlichkeitsverteilung $f(x|a)$

- erwartete Anzahl Einträge im Intervall i des Histogramms

$$v_i(\mathbf{a}) = n \cdot \int_{x_i - \Delta x_i / 2}^{x_i + \Delta x_i / 2} f(x | \mathbf{a}) dx \approx n \cdot \Delta x_i \cdot f(x_i | \mathbf{a})$$

- Wahrscheinlichkeit, dann n_i Einträge zu beobachten

$$P_i(\mathbf{a}) = \frac{[v_i(\mathbf{a})]^{n_i}}{n_i!} \cdot e^{-v_i(\mathbf{a})}$$



- log-likelihood als Funktion der Parameter \mathbf{a}

$$L(\mathbf{a}) = \prod_{i=1}^N \left\{ \frac{[v_i(\mathbf{a})]^{n_i}}{n_i!} \cdot e^{-v_i(\mathbf{a})} \right\} \Rightarrow \ln L(\mathbf{a}) = \underbrace{\sum_{i=1}^N \frac{1}{n_i!}}_{=\text{konst}} + \sum_{i=1}^N \{ n_i \cdot \ln v_i(\mathbf{a}) - v_i(\mathbf{a}) \}$$



Erweiterte Maximum-Likelihood

Betrachte Zählexperiment, das über eine feste Zeit läuft

- Gesamtzahl n der beobachteten Ereignisse ist dann auch eine Zufallsvariable
- sollte in der likelihood-Funktion berücksichtigt werden
- nehme Poissonverteilung an und nehme deren Erwartungswert ν als zusätzlichen Parameter in die likelihood-Funktion

$$L(\mathbf{a}, \nu(\mathbf{a})) = \frac{\nu^n(\mathbf{a})}{n!} \cdot e^{-\nu(\mathbf{a})} \cdot \prod_{i=1}^n f(\mathbf{x}_i | \mathbf{a})$$

aufgepasst: ν kann von den Parametern \mathbf{a} abhängen !

- erweiterte log-likelihood Funktion:


$$\begin{aligned} \ln L(\mathbf{a}, \nu(\mathbf{a})) &= n \cdot \ln \nu(\mathbf{a}) - \nu(\mathbf{a}) + \sum_{i=1}^n \ln \{ f(\mathbf{x}_i | \mathbf{a}) \} \\ &= -\nu(\mathbf{a}) + \sum_{i=1}^n \ln \{ \nu(\mathbf{a}) \cdot f(\mathbf{x}_i | \mathbf{a}) \} \end{aligned}$$



Beispiel Signal und Untergrund

Verteilung aus n_s Signalereignissen und n_b Untergrundereignissen

- **Form der Signalverteilung $s(x)$ sei bekannt**
 - z.B. Gaußverteilung mit bekanntem μ und σ
- **Form der Untergrundverteilung $b(x)$ sei bekannt**
 - z.B. Exponentialverteilung mit bekanntem λ
- **suche Schätzwerte für n_s und n_b**



- **normale maximum likelihood: Gesamtzahl der Ereignisse $n_{tot} = n_s + n_b$ fest**

$$\ln L(n_s) = \sum_{i=1}^{n_{tot}} \ln \left\{ \frac{n_s}{n_{tot}} \cdot s(x_i) + \frac{n_{tot} - n_s}{n_{tot}} \cdot b(x_i) \right\}$$

ein freier
Parameter

- **erweiterte maximum likelihood: $n_s + n_b$ folgt Poissonverteilung**

$$\ln L(n_s, n_b) = -(n_s + n_b) + \sum_{i=1}^{n_{tot}} \ln \{ n_s \cdot s(x_i) + n_b \cdot b(x_i) \}$$

zwei freie
Parameter





Beispiel Signal und Untergrund

Normale maximum likelihood: $n_s + n_b$ fest, nur ein freier Parameter (n_s)

mlgaussexp.py

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge Zufallszahlen
#
nstrue = 250 ; mu = 6.0 ; sig = 0.7
nbtrue = 500 ; tau = 2.0
x      = concatenate([stats.norm(mu,sig).rvs(nstrue), \
                      stats.expon(0.0,tau).rvs(nbtrue)])
#
# log likelihood als Funktion der angenommenen Anzahl
# Signalereignisse; totale Anzahl Ereignisse fest
#
ntot = nstrue + nbtrue
nsmin = 200 ; nsmax = 300 ; ns = frange(nsmin,nsmax,1.0)
ll     = zeros(len(ns))
for i in range(0,ntot):
    ll += log((ns*stats.norm(mu,sig).pdf(x[i])+\
              (ntot-ns)*stats.expon(0.0,tau).pdf(x[i]))/ntot)
ll     -= ll.max()
nshat  = ns[argmax(ll)]
#
# Unsicherheit auf Schatzwert aus Breite der log likelihood
#
for nsigma in range(1,4):
    c = ll >= -nsigma**2/2.0
    nslo = nshat - min(ns[c])
    nsup = max(ns[c]) - nshat
#
# Ausgabe-Befehle hier nicht gezeigt ...
```



total number of events = 750
ml estimate of signal events = 250
+/- 1 sigma = + 14/- 14 events
+/- 2 sigma = + 29/- 28 events
+/- 3 sigma = + 44/- 42 events





Beispiel Signal und Untergrund

Erweiterte maximum likelihood: $n_s + n_b$ folgt Poissonverteilung

```
#!/usr/bin/env python
from pylab import *
import scipy.stats as stats
#
# erzeuge Zufallszahlen
#
nstrue = 250 ; mu = 6.0 ; sig = 0.7
nbtrue = 500 ; tau = 2.0
x      = concatenate([stats.norm(mu,sig).rvs(nstrue), \
                      stats.expon(0.0,tau).rvs(nbtrue)])
#
# extended log likelihood auf Raster angenommener Anzahlen
# Signal- und Untergrundereignisse
#
nsmin = 200 ; nsmax = 300 ; nstest = frange(nsmin,nsmax,1.0)
nbmin = 450 ; nbmax = 550 ; nbtest = frange(nbmin,nbmax,1.0)
ns,nb = meshgrid(nstest,nbtest)
ll     = zeros(shape(ns))
for i in range(0,ntot):
    ll += log(ns*stats.norm(mu,sig).pdf(x[i])+ \
             nb*stats.expon(0.0,tau).pdf(x[i])) ;
ll     -= (ns+nb)
nshat  = ns.flatten()[argmax(ll)]
nbhat  = nb.flatten()[argmax(ll)]
#
# Unsicherheit auf den Schaeztwerten aus Breite der
# log-likelihood als Funktion jedes der zwei Parameter
#
ll     -= ll.max()
nslo   = ns[ll>-0.5].min() ; nsup = ns[ll>-0.5].max()
nblo   = nb[ll>-0.5].min() ; nbup = nb[ll>-0.5].max()
```

emlgaussexp.py



ns = 255 + 17 /- 18
nb = 495 + 23 /- 24




Beispiel Signal und Untergrund

Zwinge $n_s + n_b$ auf den wahren Wert

emlgaussexp.py

```
#  
# oberer Teil wie auf vorheriger Folie ...  
#  
  
nshat = ns.flatten()[argmax(l1)]  
nbhat = nb.flatten()[argmax(l1)]  
#  
# bestimme Unsicherheit auf den Parametern aus Breite der  
# log-likelihood als Funktion jedes der zwei Parameter  
# fuer Werte auf der Achse ns+nb=nstrue+nbtrue  
#  
l1      -= l1.max()  
nse = ns[l1>-0.5]  
nbe = nb[l1>-0.5]  
ntotfixed = nse+nbe==ntot  
nslo = nse[ntotfixed].min() ; nsup = nse[ntotfixed].max()  
nblo = nbe[ntotfixed].min() ; nbup = nbe[ntotfixed].max()
```



$n_s = 245 + 14 \text{ /- } 14$
 $n_b = 505 + 14 \text{ /- } 14$



Zusammenfassung

Maximum Likelihood Methode zur Herleitung von Schätzfunktionen

- wähle als Schätzwerte der Parameter diejenigen Werte, die die Wahrscheinlichkeit maximieren, die gegebene Stichprobe zu erhalten

Vorteile:

- Schätzfunktionen sind konsistent und für großen Stichprobenumfang ($N \rightarrow \infty$) asymptotisch erwartungstreu
- Schätzwerte sind für $N \rightarrow \infty$ gaußverteilt um den wahren Wert des Parameters
- Daten brauchen nicht histogrammiert zu werden: kein Informationsverlust
- Methode kann leicht auf mehrere Parameter erweitert werden

Nachteile:

- Schätzfunktionen sind nicht immer erwartungstreu
- Resultate lassen keinen Rückschluss auf die Qualität der Anpassung zu