



Universität  
Zürich<sup>UZH</sup>

# **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/ls`



# Methode kleinster Quadrate

## Zweite häufig benutzte Methode zur Herleitung von Schätzfunktionen

- **Stichprobe besteht aus  $N$  Wertepaaren  $(x_i, y_i)$  ( $i = 1, \dots, N$ )**
  - Messunsicherheiten auf den  $x_i$  seien vernachlässigbar klein
  - Messunsicherheiten  $\sigma_i$  auf den  $y_i$
- **Funktion  $f(x|a)$  sagt für jeden  $x$ -Wert den erwarteten  $y$ -Wert vorher**
  - $f(x|a)$  hängt von einem oder mehreren Parametern  $a$  ab
  - aus der Stichprobe sollen Schätzwerte  $\hat{a}$  für diese Parameter abgeleitet werden
- **definiere “Chi-Quadrat” als Funktion der  $a$**

$$\chi^2(\mathbf{a}) = \sum_{i=1}^N \frac{(y_i - f(x_i | \mathbf{a}))^2}{\sigma_i^2}$$

- Maß für Diskrepanz zwischen erwarteten und beobachteten Werten
- **wähle als Schätzwerte  $\hat{a}$  diejenigen Werte der Parameter, die  $\chi^2(\mathbf{a})$  minimieren**



# Beispiel Proportionalität

$f(x) = a \cdot x$ , suche Schätzfunktion  $\hat{a}$  für den Proportionalitätsfaktor  $a$

$$\chi^2(\mathbf{a}) = \sum_{i=1}^N \left( \frac{y_i - \mathbf{a} \cdot \mathbf{x}_i}{\sigma_i} \right)^2$$

- bestimme Minimum von  $\chi^2(\mathbf{a})$  analytisch

$$\left[ \frac{d\chi^2}{d\mathbf{a}} \right]_{\mathbf{a}=\hat{\mathbf{a}}} = 2 \cdot \sum_{i=1}^N \left\{ \frac{y_i - \hat{\mathbf{a}} \cdot \mathbf{x}_i}{\sigma_i^2} \cdot (-\mathbf{x}_i) \right\} = \mathbf{0}$$

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

$$-\frac{2}{\sigma^2} \cdot \sum_{i=1}^N \left\{ \mathbf{x}_i \cdot (y_i - \hat{\mathbf{a}} \cdot \mathbf{x}_i) \right\} = \mathbf{0} \quad \Rightarrow \quad \hat{\mathbf{a}} = \frac{\sum_{i=1}^N \{ \mathbf{x}_i y_i \}}{\sum_{i=1}^N \mathbf{x}_i^2} = \frac{\overline{\mathbf{x}y}}{\overline{\mathbf{x}^2}}$$

- Unsicherheit auf  $\hat{\mathbf{a}}$  durch Fehlerfortpflanzung

$$\frac{\partial \hat{\mathbf{a}}}{\partial y_i} = \frac{\mathbf{x}_i}{\sum_{j=1}^N \mathbf{x}_j^2} = \frac{\mathbf{x}_i}{N \cdot \overline{\mathbf{x}^2}} \quad \Rightarrow \quad \mathbf{V}(\hat{\mathbf{a}}) = \sum_{i=1}^N \left\{ \left( \frac{\partial \hat{\mathbf{a}}}{\partial y_i} \right)^2 \sigma^2 \right\} = \frac{\sigma^2}{(N \cdot \overline{\mathbf{x}^2})^2} \cdot \sum_{i=1}^N \mathbf{x}_i^2 = \frac{\sigma^2}{N \cdot \overline{\mathbf{x}^2}}$$



# Beispiel Anpassung einer Geraden

$f(x) = a_0 + a_1 \cdot x$ , suche Schätzfunktionen für die Parameter  $a_0$  und  $a_1$

$$\chi^2(\mathbf{a}_0, \mathbf{a}_1) = \sum_{i=1}^N \left( \frac{y_i - a_0 - a_1 \cdot x_i}{\sigma_i} \right)^2$$

- Ableiten nach  $a_0, a_1$ : zwei Gleichungen für zwei Schätzfunktionen  $\hat{a}_0$  und  $\hat{a}_1$ 
  - Vereinfachung: nehme an, Unsicherheiten auf allen  $y_i$  gleich groß,  $\sigma_i = \sigma$  für alle  $i$

$$\left[ \frac{\partial \chi^2}{\partial \mathbf{a}_1} \right]_{\substack{a_0 = \hat{a}_0 \\ a_1 = \hat{a}_1}} = -\frac{2}{\sigma^2} \cdot \sum_{i=1}^N \{ (y_i - \hat{a}_0 - \hat{a}_1 \cdot x_i) \cdot x_i \} = 0 \quad \Leftrightarrow \quad \overline{xy} - \hat{a}_0 \bar{x} - \hat{a}_1 \cdot \overline{x^2} = 0$$

$$\left[ \frac{\partial \chi^2}{\partial \mathbf{a}_0} \right]_{\substack{a_0 = \hat{a}_0 \\ a_1 = \hat{a}_1}} = -\frac{2}{\sigma^2} \cdot \sum_{i=1}^N \{ y_i - \hat{a}_0 - \hat{a}_1 \cdot x_i \} = 0 \quad \Leftrightarrow \quad \bar{y} - \hat{a}_0 - \hat{a}_1 \cdot \bar{x} = 0$$

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

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

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



# Beispiel Anpassung einer Geraden

## Fehlermatrix für $\hat{a}_0$ und $\hat{a}_1$ durch Fehlerfortpflanzung

- für Varianz auf  $\hat{a}_1$

$$\begin{aligned} \mathbf{V}(\hat{a}_1) &= \sum_{i=1}^N \left\{ \left( \frac{\partial \hat{a}_1}{\partial y_i} \right)^2 \cdot \sigma_i^2 \right\} & \Bigg| & \hat{a}_1 = \frac{\overline{xy} - \bar{x}\bar{y}}{\overline{x^2} - \bar{x}^2} = \frac{1}{N} \cdot \sum_{i=1}^N \frac{(x_i - \bar{x}) \cdot y_i}{(\overline{x^2} - \bar{x}^2)} \\ &= \frac{\sigma^2}{N^2 \cdot (\overline{x^2} - \bar{x}^2)^2} \cdot \sum_{i=1}^N \left[ \frac{\partial}{\partial y_i} \left\{ (x_i - \bar{x}) \cdot y_i \right\} \right]^2 & \Bigg| & \sum_{i=1}^N (x_i - \bar{x})^2 = N \cdot V(x) = N \cdot (\overline{x^2} - \bar{x}^2) \\ &= \frac{\sigma^2}{N \cdot (\overline{x^2} - \bar{x}^2)} \end{aligned}$$

- entsprechend für Varianz auf  $\hat{a}_0$  und für Kovarianz von  $\hat{a}_0$  und  $\hat{a}_1$  ...

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

**! gleiche Ergebnisse wie mit Maximum Likelihood !**



# Kleinste Quadrate und Maximum Likelihood

Annahme: Abweichungen der  $y_i$  von den wahren Werten gaußverteilt

- Wahrscheinlichkeit für ein Wertepaar  $(x_i, y_i)$

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

- log-likelihood für eine Stichprobe aus  $N$  Wertepaaren  $(x_i, y_i)$

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

- Maximieren von  $\ln L(a)$  = Minimieren von  $\sum_{i=1}^N \left( \frac{y_i - f(x_i | a)}{\sigma_i} \right)^2 = \chi^2(a)$

⇒

die zwei Methoden sind identisch,  
wenn die Messabweichungen auf den  $y_i$  gaußverteilt sind

⇒

Methode kleinster Quadrate nimmt implizit an,  
daß die Messabweichungen auf den  $y_i$  gaußverteilt sind



# Beispiel Anpassung einer Geraden

## Allgemeiner Fall: Messunsicherheiten $\sigma_i$ auf den $y_i$ unterschiedlich groß

- ersetze überall die einfachen Mittelwerte durch gewichtete Mittelwerte

$$\bar{x} = \frac{\sum_{i=1}^N x_i / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2} \quad \bar{y} = \frac{\sum_{i=1}^N y_i / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2}$$
$$\overline{x^2} = \frac{\sum_{i=1}^N x_i^2 / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2} \quad \overline{xy} = \frac{\sum_{i=1}^N x_i y_i / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2}$$

- ersetze in der Kovarianzmatrix  $\sigma^2$  durch den gewichteten Mittelwert der  $\sigma_i^2$

$$\overline{\sigma^2} = \frac{\sum_{i=1}^N \sigma_i^2 / \sigma_i^2}{\sum_{i=1}^N 1 / \sigma_i^2} = \frac{N}{\sum_{i=1}^N 1 / \sigma_i^2}$$

(Herleitungen wie für den Spezialfall gleich großer Messunsicherheiten, nur mehr Schreiarbeit)





# Extrapolation der Geradengleichung


$Y = \hat{a}_0 + \hat{a}_1 \cdot X$  : Unsicherheit auf  $Y$  durch Fehlerfortpflanzung

$$\begin{aligned} V(Y) &= V(\hat{a}_0) + X^2 \cdot V(\hat{a}_1) + 2 X \cdot \text{cov}(\hat{a}_0, \hat{a}_1) \\ &= \frac{\sigma^2}{N(\overline{x^2} - \bar{x}^2)} \cdot (\overline{x^2} + X^2 - 2\bar{x} X) \end{aligned}$$


- Koordinatentransformation  $x_i \rightarrow x'_i = x_i - \bar{x}$

$$\Rightarrow \bar{x}' = 0$$

$\Rightarrow$  Kovarianzterm verschwindet



$\Rightarrow$







# Bedeutung von $\chi^2$

## Geradenanpassung ( unterschiedlich große Messunsicherheiten auf den $y_i$ )

```
#!/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
x      = frange(1.0,15.0,1.0)
n      = len(x)
sig    = 1.0+rand(n)
y      = a*x+b+sig*stats.norm(0.0,1.0).rvs(n)
#
# berechne Schaetzwerte, Kovarianzmatrix
#
w      = sig**-2
sumw   = sum(w)
xmean  = dot(x,w)/sumw
ymean  = dot(y,w)/sumw
xymean = dot(x*y,w)/sumw
xxmean = dot(x*x,w)/sumw
varx   = xxmean-xmean**2
ahat   = (xymean-xmean*ymean)/varx
bhat   = ymean - ahat*xmean
vara   = 1.0/(sumw*varx)
varb   = vara*xxmean
covab  = -xmean*vara
#
# berechne chi2, Freiheitsgrade
#
```

lsline.py

```
chi2 = sum((y-ahat*x-bhat)/sig)**2)
ndf  = n - 2
```



```
estimate for a = 1.942 +/- 0.074
estimate for b = 1.049 +/- 0.708
corr coeff     = -0.880
covariance matrix = 0.005 -0.046
                  -0.046 0.502
```

```
chi2 = 13.95 for ndf = 13
```



# Bedeutung von $\chi^2$


## Quantitatives Maß für die Güte der Anpassung an die Daten

- für  $f(x|a)$  mit den wahren Werte der Parameter  $a$  erwarte im Mittel

$$y_i - f(x_i|a) \approx \sigma_i \Rightarrow \chi^2 \approx N$$

- aber: bestimme Schätzwerte  $\hat{a}$  aus den Wertepaaren

$$y_i - f(x_i|\hat{a}) < y_i - f(x_i|a) \Rightarrow \chi^2 \approx n_f$$



**$n_f = \text{Anzahl der Messpaare} - \text{Anzahl der angepassten Parameter}$**


- $\chi^2 \gg n_f$  ( $\chi^2/n_f \gg 1$ ):
  - Messunsicherheiten unterschätzt ?
  - angenommene Form der Verteilung  $f(x|a)$  falsch ?
- $\chi^2/n_f \ll 1$ : Messunsicherheiten überschätzt ?



# Beispiel: Bedeutung von $\chi^2$




## Beispiel: falsch angenommenes $f(x)$

- erzeuge **15  $(x_i, y_i)$ -Paare** gemäß Polynom 2. Ordnung
  - Abweichungen der  $y_i$  von  $f(x_i)$  gemäß Gaußverteilung
- passe Gerade  $f(x) = a_0 + a_1 \cdot x$  an die Wertepaare an
- Anzahl Freiheitsgrade:  $n_f = 15 - 2 = 13$



## Aber Vorsicht vor Überinterpretation: $\chi^2$ ist Zufallsvariable

- extreme Beispiele aus 50 Iterationen von Isline.py ( $n_f = 13$ ):





# $\chi^2$ -Verteilung

Für gaußverteilte Messabweichungen auf den  $y_j$ :

Beweise z.B. in Barlow, "Statistics"

$$p(\chi^2 | n_f) = \frac{2^{-n_f/2}}{\Gamma(n_f/2)} \cdot \chi^{n_f-2} \cdot e^{-\chi^2/2}$$

- Erwartungswert:

$$\langle \chi^2 \rangle = n_f$$

- Varianz:



$$V(\chi^2) = 2 \cdot n_f$$

- pylab:

```
stats.chi2(ndf).pdf(x)
```

- $\Gamma$ -Funktion = Erweiterung der Fakultät  $n!$  auf reelle Zahlen

$$\Gamma(x+1) \equiv x \cdot \Gamma(x) \text{ mit } \Gamma(1) \equiv 1$$








# Beispiel Anpassung einer Geraden

## 10000 Iterationen von `lsline.py`

- 15  $x_i$ -Werte,  $\sigma_i$ ,  $a_0$  und  $a_1$  immer gleich
- 15  $y_i$ -Werte, für jede Iteration neu
  - Abweichungen von  $a_0 + a_1 \cdot x_i$  gemäß Gaußverteilung mit Standardabweichung  $\sigma_i$
- Histogramme: berechnete Schätzwerte und  $\chi^2$ -Werte aus 10000 Iterationen
- Kurven: erwartete Verteilungen für Schätzwerte und  $\chi^2$ 
  - Gaußverteilung mit  $\mu_{\hat{a}_1} = a_1$ ,  $\sigma_{\hat{a}_1} = \sqrt{V(\hat{a}_1)}$
  - Gaußverteilung mit  $\mu_{\hat{a}_0} = a_0$ ,  $\sigma_{\hat{a}_0} = \sqrt{V(\hat{a}_0)}$
  - $\chi^2$ -Verteilung für  $n_f = 13$





# Histogrammierte Messdaten

Betrachte Zufallsvariable  $x$  mit Wahrscheinlichkeitsverteilung  $p(x|a)$

- Stichprobe besteht aus  $n$  Werten  $x_i$  ( $i = 1, \dots, n$ )
  - Methode kleinster Quadrate funktioniert aber nur für Wertepaare !
- Lösung: histogrammieren die  $x$ -Werte
  - $N$  Intervalle mit Zentren  $x_i$  und  $n_i$  Einträgen  $\Rightarrow N$  Wertepaare  $(x_i, n_i)$
- erwartete Anzahl Einträge im  $i$ -ten Intervall des Histogramms

$$f(x_i|a) = n \cdot \int_{x_i - \Delta x_i/2}^{x_i + \Delta x_i/2} p(x|a) dx \approx n \cdot \Delta x_i \cdot p(x_i|a) \quad (\Delta x_i: \text{Intervallbreiten})$$

- Histogramm = Zählexperiment: Anzahl Einträge poissonverteilt

$$\Rightarrow \sigma_i = \sqrt{n_i}$$

- zu minimierendes  $\chi^2$  :

$$\chi^2(a) = \sum_{i=1}^N \frac{(n_i - f(x_i|a))^2}{\sigma_i^2} = \sum_{i=1}^N \frac{(n_i - f(x_i|a))^2}{n_i}$$

Methode kleinster Quadrate nimmt gaußverteilte Unsicherheiten an:  
gute Näherung, wenn  $n_i$  nicht zu klein



# Korrelierte Messwerte

## Kovarianzmatrix $V(y_i, y_j)$ für die beobachteten $y$ -Werte

$$\chi^2 = \sum_{i=1}^N \sum_{j=1}^N \left\{ \left( \mathbf{y}_i - \mathbf{f}(\mathbf{x}_i | \mathbf{a}) \right) \cdot \left[ \mathbf{V}^{-1}(\mathbf{y}_i, \mathbf{y}_j) \right] \cdot \left( \mathbf{y}_j - \mathbf{f}(\mathbf{x}_j | \mathbf{a}) \right) \right\}$$

- in Matrixschreibweise

$$\chi^2 = (\vec{\mathbf{y}} - \vec{\mathbf{f}})^T \cdot \mathbf{V}_y^{-1} \cdot (\vec{\mathbf{y}} - \vec{\mathbf{f}})$$

- Kontrolle: für Spezialfall unkorrelierter  $y_i$

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

$$\Rightarrow \chi^2 = \sum_{i=1}^N \left\{ \left( \mathbf{y}_i - \mathbf{f}(\mathbf{x}_i | \mathbf{a}) \right) \cdot \frac{1}{\sigma_i^2} \cdot \left( \mathbf{y}_i - \mathbf{f}(\mathbf{x}_i | \mathbf{a}) \right) \right\} = \sum_{i=1}^N \frac{\left( \mathbf{y}_i - \mathbf{f}(\mathbf{x}_i | \mathbf{a}) \right)^2}{\sigma_i^2} \quad \checkmark$$





# Minimieren von $\chi^2(a)$

$n$  Parameter: Minimum von  $\chi^2$  durch Lösen von  $\partial\chi^2 / \partial a_k = 0$  für  $k = 1, \dots, n$

- $n$  Gleichungen für die  $n$  Parameter
- $f(x|a)$  linear in den  $a_k \rightarrow$  lineares Gleichungssystem
- Ansatz: schreibe  $f(x_i|a)$  als Summe linearer Terme in den Parametern

$$f(\mathbf{x}_i | \mathbf{a}) = \sum_{k=1}^n \mathbf{c}_k(\mathbf{x}_i) \cdot \mathbf{a}_k \quad \text{mit} \quad \mathbf{c}_k(\mathbf{x}_i) = \frac{\partial f(\mathbf{x}_i | \mathbf{a})}{\partial \mathbf{a}_k}$$

- in Matrixschreibweise:

$$\vec{\mathbf{f}} = \mathbf{C} \cdot \vec{\mathbf{a}} \quad \text{mit} \quad \mathbf{C} = \begin{pmatrix} \frac{\partial f(\mathbf{x}_1 | \mathbf{a})}{\partial \mathbf{a}_1} & \dots & \frac{\partial f(\mathbf{x}_1 | \mathbf{a})}{\partial \mathbf{a}_n} \\ \vdots & \ddots & \vdots \\ \frac{\partial f(\mathbf{x}_N | \mathbf{a})}{\partial \mathbf{a}_1} & \dots & \frac{\partial f(\mathbf{x}_N | \mathbf{a})}{\partial \mathbf{a}_n} \end{pmatrix}$$

$f(x|a)$  linear  
in den  $a_k$ .  
 $c_k$  hängen  
nicht  
von den  $a_k$  ab

$$\Rightarrow \chi^2 = (\vec{\mathbf{y}} - \vec{\mathbf{f}})^T \cdot \mathbf{V}_y^{-1} \cdot (\vec{\mathbf{y}} - \vec{\mathbf{f}}) = (\vec{\mathbf{y}} - \mathbf{C}\vec{\mathbf{a}})^T \cdot \mathbf{V}_y^{-1} \cdot (\vec{\mathbf{y}} - \mathbf{C}\vec{\mathbf{a}})$$



# Minimieren von $\chi^2(a)$

$$\chi^2 = (\vec{y} - \mathbf{C}\vec{a})^T \cdot \mathbf{V}_y^{-1} \cdot (\vec{y} - \mathbf{C}\vec{a})$$

- nach den  $a$  ableiten und  $= 0$  setzen:

$$-2 \left( \vec{y} - \mathbf{C}\vec{\hat{a}} \right)^T \cdot \mathbf{V}_y^{-1} \cdot \mathbf{C} = 0$$

- nach den  $\hat{a}$  auflösen:

$$\vec{\hat{a}} = \left( \mathbf{C}^T \cdot \mathbf{V}_y^{-1} \cdot \mathbf{C} \right)^{-1} \cdot \mathbf{C}^T \cdot \mathbf{V}_y^{-1} \cdot \vec{y}$$

Funktion  $f(x|a)$  von  $n$  Parametern  
Stichprobe aus  $N$  Wertepaaren

=>

$\vec{y}$ : Spaltenvektor mit  $N$  Elementen

$\mathbf{V}$ : Matrix mit  $N$  Reihen und Spalten

$\vec{a}$ : Spaltenvektor mit  $n$  Elementen

$\mathbf{C}$ : Matrix mit  $N$  Reihen und  $n$  Spalten

## Fehlermatrix für die Schätzwerte durch Fehlerfortpflanzung

- Fehlerfortpflanzung allgemein (siehe Folien vom 11. Oktober)

$$\vec{f}(\vec{y}) = \mathbf{G} \cdot \vec{y} \quad \Rightarrow \quad \mathbf{V}_f = \mathbf{G} \cdot \mathbf{V}_y \cdot \mathbf{G}^T$$

- hier:

$$\vec{f} = \vec{\hat{a}} \quad ; \quad \mathbf{G} = \left( \mathbf{C}^T \cdot \mathbf{V}_y^{-1} \cdot \mathbf{C} \right)^{-1} \cdot \mathbf{C}^T \cdot \mathbf{V}_y^{-1}$$

- einsetzen, kürzen ...

$$\mathbf{V}_{\hat{a}} = \left( \mathbf{C}^T \mathbf{V}_y^{-1} \mathbf{C} \right)^{-1}$$



# Anpassung einer Geraden

## Einfachster Fall: $y_i$ unkorreliert und alle $\sigma_i$ gleich gross

$$\mathbf{V}_y = \begin{pmatrix} \sigma^2 & 0 & \dots & 0 \\ 0 & \sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & \sigma^2 \end{pmatrix} \quad \mathbf{V}_y^{-1} = \begin{pmatrix} 1/\sigma^2 & 0 & \dots & 0 \\ 0 & 1/\sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1/\sigma^2 \end{pmatrix} \quad \left| \quad \mathbf{c}_{ik} = \frac{\partial f(\mathbf{x}_i | \mathbf{a})}{\partial \mathbf{a}_k} = \frac{\partial (\mathbf{a}_0 + \mathbf{a}_1 \cdot \mathbf{x}_i)}{\partial \mathbf{a}_k}$$

$$\mathbf{C} = \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_N \end{pmatrix} \quad \mathbf{C}^T = \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_N \end{pmatrix}$$

- Kovarianzmatrix für die Schätzwerte:

$$\mathbf{V}_{\hat{\mathbf{a}}} = [\mathbf{C}^T \mathbf{V}_y^{-1} \mathbf{C}]^{-1} = \left[ \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_N \end{pmatrix} \cdot \frac{1}{\sigma^2} \cdot \begin{pmatrix} 1 & x_1 \\ 1 & x_2 \\ \vdots & \vdots \\ 1 & x_N \end{pmatrix} \right]^{-1} = \sigma^2 \cdot \begin{pmatrix} N & \sum_{i=1}^N x_i \\ \sum_{i=1}^N x_i & \sum_{i=1}^N x_i^2 \end{pmatrix}^{-1}$$

$$= \frac{\sigma^2}{N \cdot \sum_{i=1}^N x_i^2 - \left(\sum_{i=1}^N x_i\right)^2} \cdot \begin{pmatrix} \sum_{i=1}^N x_i^2 & -\sum_{i=1}^N x_i \\ -\sum_{i=1}^N x_i & N \end{pmatrix} = \frac{\sigma^2}{N \cdot (\overline{x^2} - \bar{x}^2)} \cdot \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}$$



# Anpassung einer Geraden

Einfachster Fall:  $y_i$  unkorreliert und alle  $\sigma_i$  gleich gross

$$\mathbf{C}^T = \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_N \end{pmatrix} ; \quad \mathbf{V}_y^{-1} = \begin{pmatrix} 1/\sigma^2 & 0 & \dots & 0 \\ 0 & 1/\sigma^2 & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ 0 & 0 & \dots & 1/\sigma^2 \end{pmatrix} \Rightarrow \mathbf{V}_{\hat{a}} = \frac{\sigma^2}{N \cdot (\overline{x^2} - \bar{x}^2)} \cdot \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix}$$

- **Schätzwerte**

$$\begin{pmatrix} \hat{a}_0 \\ \hat{a}_1 \end{pmatrix} = \mathbf{V}_{\hat{a}} \cdot \mathbf{C}^T \cdot \mathbf{V}_y^{-1} \cdot \vec{y} = \frac{\sigma^2}{N \cdot (\overline{x^2} - \bar{x}^2)} \cdot \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix} \cdot \begin{pmatrix} 1 & 1 & \dots & 1 \\ x_1 & x_2 & \dots & x_N \end{pmatrix} \cdot \frac{1}{\sigma^2} \cdot \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_N \end{pmatrix}$$

$$= \frac{1}{\overline{x^2} - \bar{x}^2} \cdot \begin{pmatrix} \overline{x^2} & -\bar{x} \\ -\bar{x} & 1 \end{pmatrix} \cdot \frac{1}{N} \cdot \begin{pmatrix} \sum_{i=1}^N y_i \\ \sum_{i=1}^N x_i y_i \end{pmatrix} = \frac{1}{\overline{x^2} - \bar{x}^2} \cdot \begin{pmatrix} \overline{x^2 y} - \bar{x} \bar{xy} \\ \bar{xy} - \bar{x} \bar{y} \end{pmatrix}$$

- **vgl. Rechnung "per Hand" (Folien 5/6)**



# Unsicherheit auf den Parametern aus Breite der $\chi^2$ -Funktion

## Taylorentwicklung von $\chi^2(\mathbf{a})$ um $\mathbf{a} = \hat{\mathbf{a}}$

$$\chi^2(\mathbf{a}) = \chi^2(\hat{\mathbf{a}}) + \underbrace{\sum_{i=1}^n \left\{ \left[ \frac{\partial \chi^2}{\partial \mathbf{a}_i} \right]_{\mathbf{a}_i = \hat{\mathbf{a}}_i} (\mathbf{a}_i - \hat{\mathbf{a}}_i) \right\}}_{=0, \text{ weil } \hat{\mathbf{a}} \text{ Minimum von } \chi^2(\mathbf{a})} + \frac{1}{2} \cdot \sum_{i=1}^n \sum_{j=1}^n \left\{ \left[ \frac{\partial^2 \chi^2}{\partial \mathbf{a}_i \partial \mathbf{a}_j} \right]_{\substack{\mathbf{a}_i = \hat{\mathbf{a}}_i \\ \mathbf{a}_j = \hat{\mathbf{a}}_j}} (\mathbf{a}_i - \hat{\mathbf{a}}_i)(\mathbf{a}_j - \hat{\mathbf{a}}_j) \right\}$$

- Terme höherer Ordnung verschwinden wenn  $f(\mathbf{x} | \mathbf{a})$  linear in den Parametern
- 2. Ableitungen:

$$\chi^2 = (\vec{\mathbf{y}} - \mathbf{C} \vec{\mathbf{a}})^T \cdot \mathbf{V}_y^{-1} \cdot (\vec{\mathbf{y}} - \mathbf{C} \vec{\mathbf{a}}) \quad \Rightarrow \quad \frac{\partial^2 \chi^2}{\partial \mathbf{a}_i \partial \mathbf{a}_j} = 2 \mathbf{C}^T \mathbf{V}_y^{-1} \mathbf{C} = 2 \mathbf{V}_{\hat{\mathbf{a}}}^{-1}$$

- Einsetzen in die Taylor-Entwicklung:

$$\chi^2(\mathbf{a}) = \chi^2(\hat{\mathbf{a}}) + \sum_{i=1}^n \sum_{j=1}^n (\mathbf{a}_i - \hat{\mathbf{a}}_i) \cdot [\mathbf{V}^{-1}(\hat{\mathbf{a}}_i, \hat{\mathbf{a}}_j)] \cdot (\mathbf{a}_j - \hat{\mathbf{a}}_j)$$

- für Funktion von nur einem Parameter  $a$

$$\chi^2(\mathbf{a}) = \chi^2(\hat{\mathbf{a}}) + \frac{1}{\sigma_{\hat{\mathbf{a}}}^2} \cdot (\mathbf{a} - \hat{\mathbf{a}})^2$$



# Unsicherheit auf den Parametern aus Breite der $\chi^2$ -Funktion

## Funktion $f(x|a)$ von einem Parameter $a$

- $\chi^2(a)$  parabelförmig


$$\chi^2(\mathbf{a}) = \chi^2(\hat{\mathbf{a}}) + \frac{1}{\sigma_{\hat{\mathbf{a}}}^2} \cdot (\mathbf{a} - \hat{\mathbf{a}})^2$$

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

$$\chi^2(\hat{\mathbf{a}} \pm \sigma_{\hat{\mathbf{a}}}) = \chi^2(\hat{\mathbf{a}}) + 1$$

$$\chi^2(\hat{\mathbf{a}} \pm 2\sigma_{\hat{\mathbf{a}}}) = \chi^2(\hat{\mathbf{a}}) + 4$$

$$\chi^2(\hat{\mathbf{a}} \pm 3\sigma_{\hat{\mathbf{a}}}) = \chi^2(\hat{\mathbf{a}}) + 9$$



## Vergleich mit Maximum Likelihood

- gaußverteilte Messunsicherheiten auf den  $y_i \Rightarrow$  beide Methoden identisch mit

$$\ln L(\mathbf{a}) = -\chi^2(\mathbf{a}) / 2 + \text{konst}$$

- gaußverteilte Messunsicherheiten auf den  $y_i \Rightarrow \ln L$  parabelförmig mit

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




# Anpassung einer Geraden

lspoly1.py

```
#!/usr/bin/env python
from pylab import *
from scipy import stats
from linearls import *
#
# erzeuge Messpaare mit gaussverteilten Abweichungen von Gerade
#
a = [0.5,2.0]
x = frange(1.0,15.0,1.0)
nx = len(x)
sigy = rand(nx)+1.0
y = a[0] + a[1]*x+stats.norm().rvs(len(x))*sigy
#
# analytisch mit linearls
#
w = sig**-2
sumw = sum(w)
xmean = dot(x,w)/sumw
ymean = dot(y,w)/sumw
xymean = dot(x*y,w)/sumw
xxmean = dot(x*x,w)/sumw
varx = xxmean-xmean**2
alhat = (xymean-xmean*ymean)/varx
a0hat = ymean - alhat*xmean
varal = 1.0/(sumw*varx)
vara0 = varal*xxmean
cova0a1 = -xmean*varal
chi2 = sum(((y-alhat*x-a0hat)/sig)**2)
ndf = n - 2#
# abtasten des chi^2 Profils
#
a0t,alt = meshgrid(frange(-1.5,2.5,0.01),frange(1.5,2.5,0.01))
chi2 = zeros(shape(alt))
for i in range(0,nx):
    chi2 += (y[i]-a0t-alt*x[i])**2/err[i]**2
#
a0hat = a0t.flatten()[argmin(chi2)]
alhat = alt.flatten()[argmin(chi2)]
#
chi2 -= chi2.min()
a0lo = a0t[chi2 <= 1].min() ; a0hi = a0t[chi2 <= 1].max()
allo = alt[chi2 <= 1].min() ; alhi = alt[chi2 <= 1].max()
```

## Zwei Parameter: Fehlerellipsen



Parameters +/- uncertainties:

0.820032+/-0.779911

2.048122+/-0.085428

Covariance matrix:

[[ 0.60826108 -0.05871365]

[-0.05871365 0.0072979 ]]

Chi^2/ndf = 16.89/ 13

a0 = 0.82+ 0.77/- 0.77

a1 = 2.05+ 0.08/- 0.08

analytisch

$\chi^2$ -Profil



# $f(x|a)$ nicht linear in den Parametern $a$

$\partial \chi^2 / \partial a_j$  ergibt kein lineares Gleichungssystem  $\rightarrow$  keine exakte Lösung

• **Ansatz: linearisiere Problemstellung, suche iterativ näherungsweise Lösung**

• “rate” Startwerte  $\vec{a}^0 = (a_1^0, a_2^0, \dots, a_n^0)$  für die  $n$  Parameter

• berechne Korrekturen  $\delta \vec{a}^0$ , sodass  $\vec{a}^1 = \vec{a}^0 + \delta \vec{a}^0$  näher beim Minimum liegt

• **Taylor-Entwicklung von  $\partial \chi^2 / \partial a_j$  um die Startwerte  $a_j^0$**

$$\left[ \frac{\partial \chi^2}{\partial a_j} \right]_{\vec{a}=\vec{a}^0+\delta \vec{a}^0} \approx \left[ \frac{\partial \chi^2}{\partial a_j} \right]_{\vec{a}=\vec{a}^0} + \sum_{k=1}^n \left[ \frac{\partial^2 \chi^2}{\partial a_k \partial a_j} \right]_{\vec{a}=\vec{a}^0} \cdot \delta a_k^0 + \dots \quad \text{für } j=1, \dots, n$$

• nehme an, die  $\delta \vec{a}^0$  sind nicht zu gross: breche nach linearem Term ab und setze

$$\left[ \frac{\partial \chi^2}{\partial a_j} \right]_{\vec{a}=\vec{a}^0} + \sum_{k=1}^n \left[ \frac{\partial^2 \chi^2}{\partial a_k \partial a_j} \right]_{\vec{a}=\vec{a}^0} \cdot \delta a_k^0 = 0 \quad \text{für } j=1, \dots, n$$

• **lineares Gleichungssystem für die  $\delta \vec{a}^0$**

$$\delta \vec{a}^0 = -\mathbf{G}^{-1} \cdot \vec{g}$$

mit  $G_{jk} = \left[ \frac{\partial^2 \chi^2}{\partial a_j \partial a_k} \right]_{\vec{a}=\vec{a}^0}$  und  $g_j = \left[ \frac{\partial \chi^2}{\partial a_j} \right]_{\vec{a}=\vec{a}^0}$





# $f(x|a)$ nicht linear in den Parametern $a$

Iterationen mit  $\vec{a}^1 = \vec{a}^0 + \delta \vec{a}^0$  als neuen “Startwerten”

- $\vec{a}^1$  sollten näher beim Minimum liegen als  $\vec{a}^0$
- Korrekturen  $\delta \vec{a}^1$  sollten kleiner sein als  $\delta \vec{a}^0$

Iterationen solange bis eine Konvergenzbedingung erfüllt ist

- $\delta \vec{a}^i$  ist kleiner als ein vorgegebener Wert
- $\chi^2(a)$  ändert sich um weniger als einen vorgegebenen Wert
- eine vorgegebene maximale Anzahl Iterationen ist erreicht

Gute Startwerte  $\vec{a}^0$  sind sehr wichtig

- Konvergenz ist umso schneller, je näher die  $\vec{a}^0$  beim wahren Minimum liegen
- liegen die  $\vec{a}^0$  zu weit vom Minimum, besteht die Gefahr, dass der Algorithmus nicht konvergiert oder in einem falschen (lokalen) Minimum konvergiert




# pylab Funktion leastsq

## Beispiel: gaußverteiltes Signal über parabolischem Untergrund

```
#!/usr/bin/env python
from pylab import *
from scipy import stats
from scipy.optimize import leastsq
#
# definiere anzupassende Funktion und
# Hilfsfunktion fuer leastsq
#
def func(a,x):
    return a[0]+a[1]*x+a[2]*x**2+\
        a[3]*stats.norm(a[4],a[5]).pdf(x)
def chi(a,x,y,yerr):
    return (func(a,x)-y)/yerr
#
# lese Messpaare von Datei
#
data = loadtxt('lsgausspoly2.dat')
x = data[:,0] ; y = data[:,1] ; yerr = y**0.5
#
# definiere Startwerte und rufe leastsq auf
#
astart = array([200,-10,0.05,500,15,1])
val = leastsq(chi,astart,args=(x,y,yerr),
             maxfev=10000,full_output=1)
#
# extrahiere Resultate der Anpassung
#
ahat = val[0]
cov = val[1]
chi2 = sum(chi(ahat,x,y,yerr)**2)
ndf = len(x)-len(astart)
#
# weitere Befehle hier nicht gezeigt
```

lsgausspoly2.py

- input:  $(f(x_i) - y_i) / \sigma_i$
  - output: Schätzwerte und Kovarianzmatrix für die Fitparameter
- } help(leastsq) in pylab





initial values	fitted values	+/-	uncertainties
200.00	227.652	+/-	42.459
-10.00	-7.881	+/-	0.457
0.05	0.069	+/-	0.000
500.00	526.533	+/-	2511.432
15.00	18.333	+/-	0.027
1.00	1.846	+/-	0.029
chi2/ndf 29.890/33			



# Wichtigkeit der Startwerte

## Beispiele für schlechte Startwerte $\Rightarrow$ Konvergenz in falschem Minimum



initial values	fitted values +/- uncertainties
1.00	621.575 +/- 27837.719
1.00	-31.436 +/- 97.038
1.00	0.417 +/- 0.021
1.00	-7638.539 +/- 28822191.005
1.00	0.234 +/- 6.507
1.00	8.788 +/- 3.871
chi2/ndf 142.843/33	

initial values	fitted values +/- uncertainties
200.00	232.292 +/- 50.121
-10.00	-5.873 +/- 0.405
0.05	0.008 +/- 0.000
500.00	-126.264 +/- 1820.915
10.00	11.303 +/- 0.225
1.00	1.486 +/- 0.252
chi2/ndf 181.038/33	



# Zusammenfassung

## Methode kleinster Quadrate zur Herleitung von Schätzfunktionen

- ergibt als Schätzwerte die Werte der Parameter, die die Diskrepanz zwischen vorhergesagten und beobachteten Messwerten minimieren
- ist für gaußverteilte Abweichungen der  $y_i$  äquivalent zu Maximum-Likelihood

## Vorteil gegenüber Maximum-Likelihood Methode

- Wert von  $\chi^2$  im Minimum gibt quantitatives Mass für die Güte der Anpassung
  - $\chi^2/ndf \gg 1$ : starker Hinweis darauf, dass etwas nicht stimmt (z.B. Messunsicherheiten unterschätzt, Funktion  $f(x|a)$  beschreibt die Daten nicht)

## Nachteile gegenüber Maximum-Likelihood Methode

- kann nur auf Wertepaare  $(x_i, y_i)$  oder Histogramme  $(x_i, n_i)$  angewandt werden
  - Erinnerung: histogrammieren  $\rightarrow$  Informationsverlust
- basiert auf der Annahme, dass die Abweichungen auf den  $y_i$  gaußverteilt sind
  - Messabweichungen nicht gaußverteilt  $\rightarrow$  benutze Maximum-Likelihood Methode