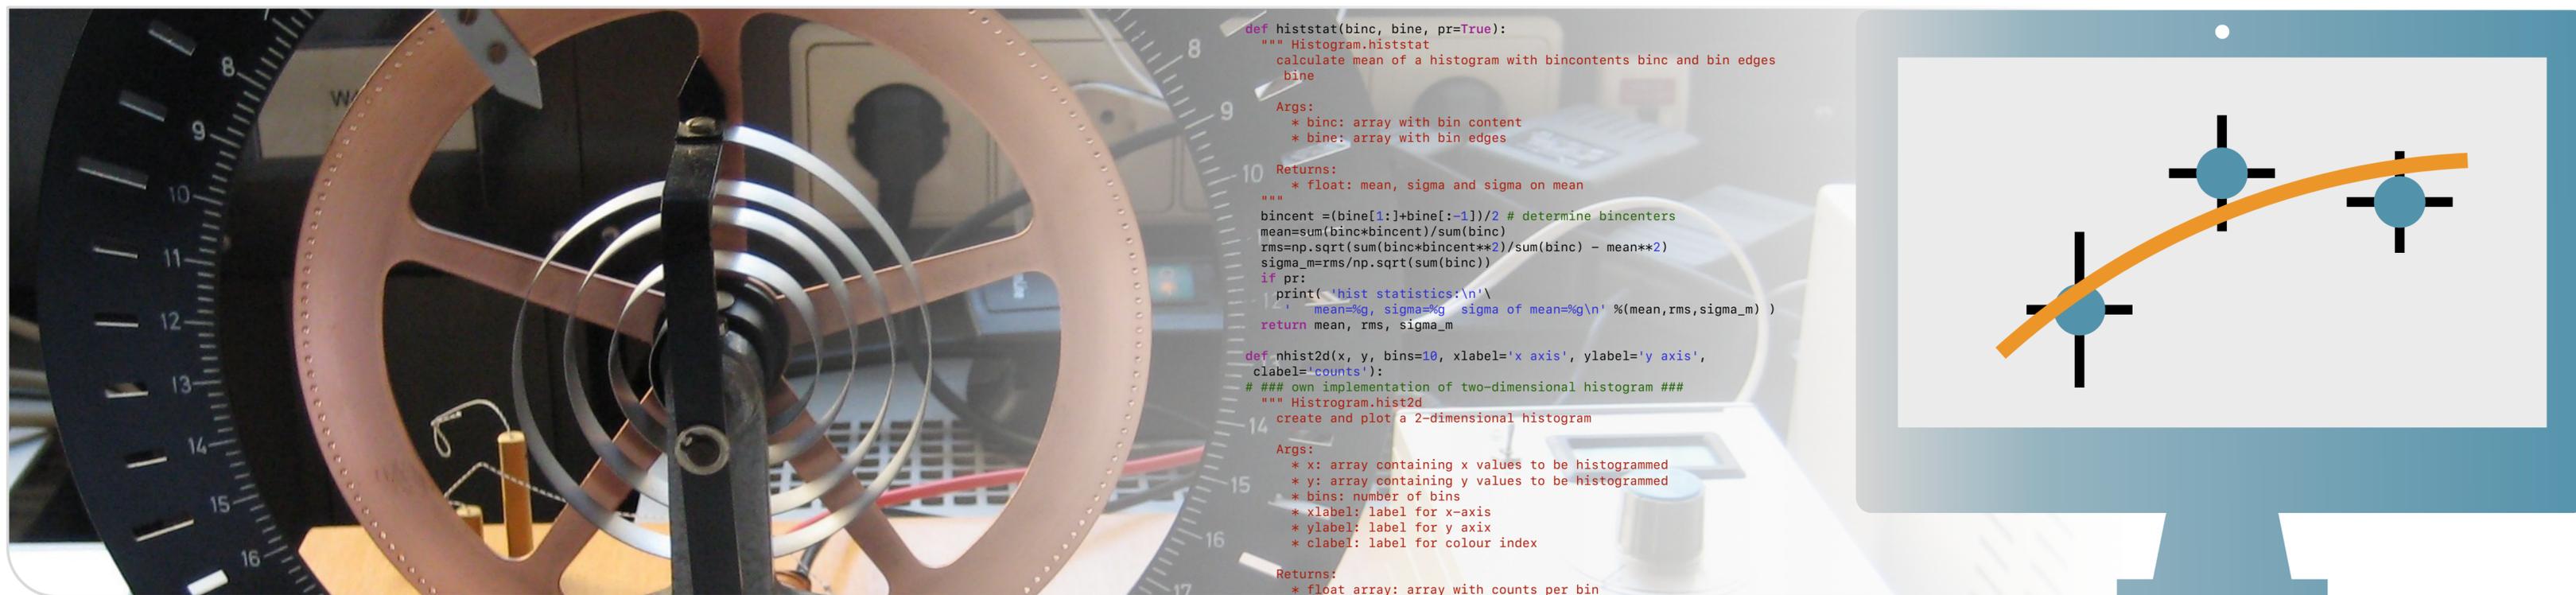


Einführung in die

Computergestützte Datenauswertung

Ulrich Husemann, Karlsruher Institut für Technologie, Institut für Experimentelle Teilchenphysik
Sommersemester 2024 – Kapitel 4



```
def histstat(binc, bine, pr=True):  
    """ Histogram.histstat  
    calculate mean of a histogram with bincontents binc and bin edges  
    bine  
    Args:  
    * binc: array with bin content  
    * bine: array with bin edges  
    Returns:  
    * float: mean, sigma and sigma on mean  
    """  
    bincen = (bine[1:] + bine[:-1]) / 2 # determine bincenters  
    mean = sum(binc * bincen) / sum(binc)  
    rms = np.sqrt(sum(binc * bincen ** 2) / sum(binc) - mean ** 2)  
    sigma_m = rms / np.sqrt(sum(binc))  
    if pr:  
        print('hist statistics:\n'\n              '  mean=%g, sigma=%g sigma of mean=%g\n' % (mean, rms, sigma_m))  
    return mean, rms, sigma_m  
  
def nhist2d(x, y, bins=10, xlabel='x axis', ylabel='y axis',  
           clabel='counts'):  
    """ Histogram.hist2d  
    create and plot a 2-dimensional histogram  
    Args:  
    * x: array containing x values to be histogrammed  
    * y: array containing y values to be histogrammed  
    * bins: number of bins  
    * xlabel: label for x-axis  
    * ylabel: label for y axis  
    * clabel: label for colour index  
    Returns:  
    * float array: array with counts per bin
```

Kapitel 4.5

Ausblick: Moderne Methoden der Datenanalyse

Maximum-Likelihood-Methode

Wiederholung

- Methode der **kleinsten Quadrate** (LS-Methode): systematische Methode zur Schätzung von Parametern und deren Unsicherheit

- Minimierung der **Summe der Residuenquadrate**:

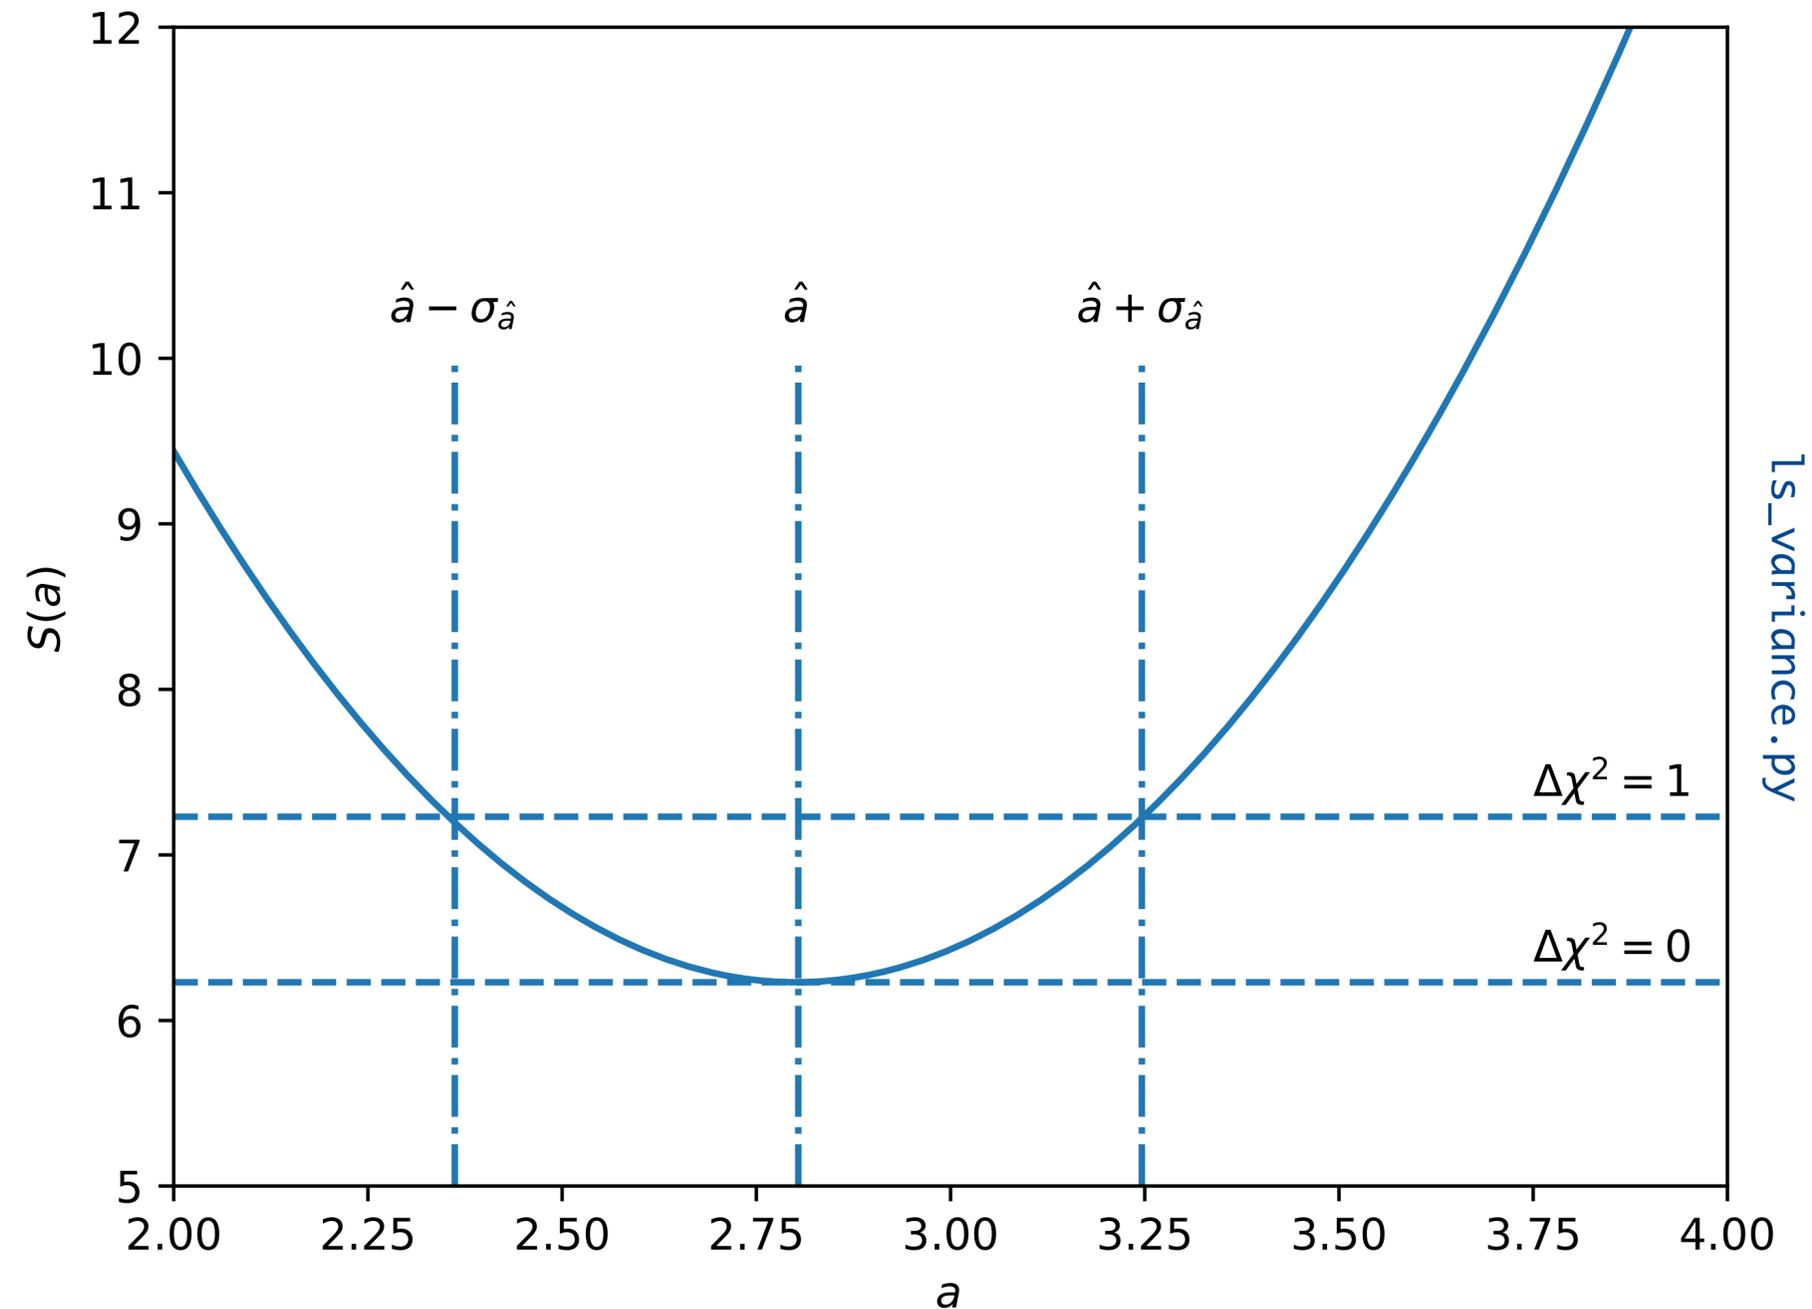
$$S \equiv \chi^2 \equiv \sum_{i=1}^n \frac{(y_i - \lambda_i(x_i; \mathbf{a}))^2}{\sigma_i^2} \stackrel{!}{=} \min \quad S \equiv (\mathbf{y} - \boldsymbol{\lambda}(\mathbf{x}; \mathbf{a}))^T \mathbf{V}^{-1} (\mathbf{y} - \boldsymbol{\lambda}(\mathbf{x}; \mathbf{a})) \stackrel{!}{=} \min$$

(meist numerisch, für lineare Funktionen der Parameter auch analytisch)

- **Güte der Anpassung** über χ^2 -Wahrscheinlichkeit
→ Faustformel: $\chi^2/n_{\text{dof}} \approx 1$

Wiederholung

- Methode der kleinsten Quadrate: **Unsicherheit** der Parameterschätzung
- **Hesse-Matrix**: Varianz des Parameters proportional zu $(2. \text{Ableitung der Summe der Residuenquadrate } S \text{ am Minimum})^{-1}$
- **Grafischer Ansatz**: Unsicherheit der Parameterschätzung = Intervall um Minimalwert mit $\Delta\chi^2 = 1$



Eigenschaften von Schätzwerten

- **Günstige Eigenschaften** von Schätzwerten (nur in Worten):
 - **Erwartungstreue**: keine (oder geringe) **Verzerrung** (engl.: bias)
= Abweichung des erwarteten Schätzwerts von wahren Wert
(Beispiel: Besselkorrektur → erwartungstreue Stichprobenvarianz)
 - **Konsistenz**: im Grenzfall großer Stichproben konvergiert Schätzwert gegen wahren Wert (Beispiel: Stichprobenvarianz, auch ohne Besselkorrektur)
 - **Effizienz**: kleinstmögliche **Varianz** des Schätzwerts
→ Parameter kann mit möglichst geringer Unsicherheit geschätzt werden
 - Große **Genauigkeit**: Kombination aus Varianz und Verzerrung (mittlere quadratische Abweichung, engl.: mean square error, MSE) klein
 - **Robustheit**: geringe Sensitivität auf „Ausreißer“ in Daten oder fehlerhaftes Modell
 - **Einfachheit** der Definition des Schätzwerts

Maximum-Likelihood-Methode

- Maximum-Likelihood-(ML-)Methode (Fisher, ca. 1912):
 - Parameterschätzung durch **Maximierung einer Funktion** („Likelihood-Funktion“), so dass das statistische Modell am **besten zu den Daten passt**
 - **Universell einsetzbar** für fortgeschrittene statistische Methoden (Beispiel später: Hypothesentests)
- Man kann u. a. zeigen:
 - ML-Schätzwerte sind **effizient**, aber im allgemeinen nicht erwartungstreu
 - Für **normalverteilte** Zufallsvariablen sind Methode der kleinsten Quadrate und Maximum-Likelihood-Methode **äquivalent**

LS und ML: erster Vergleich

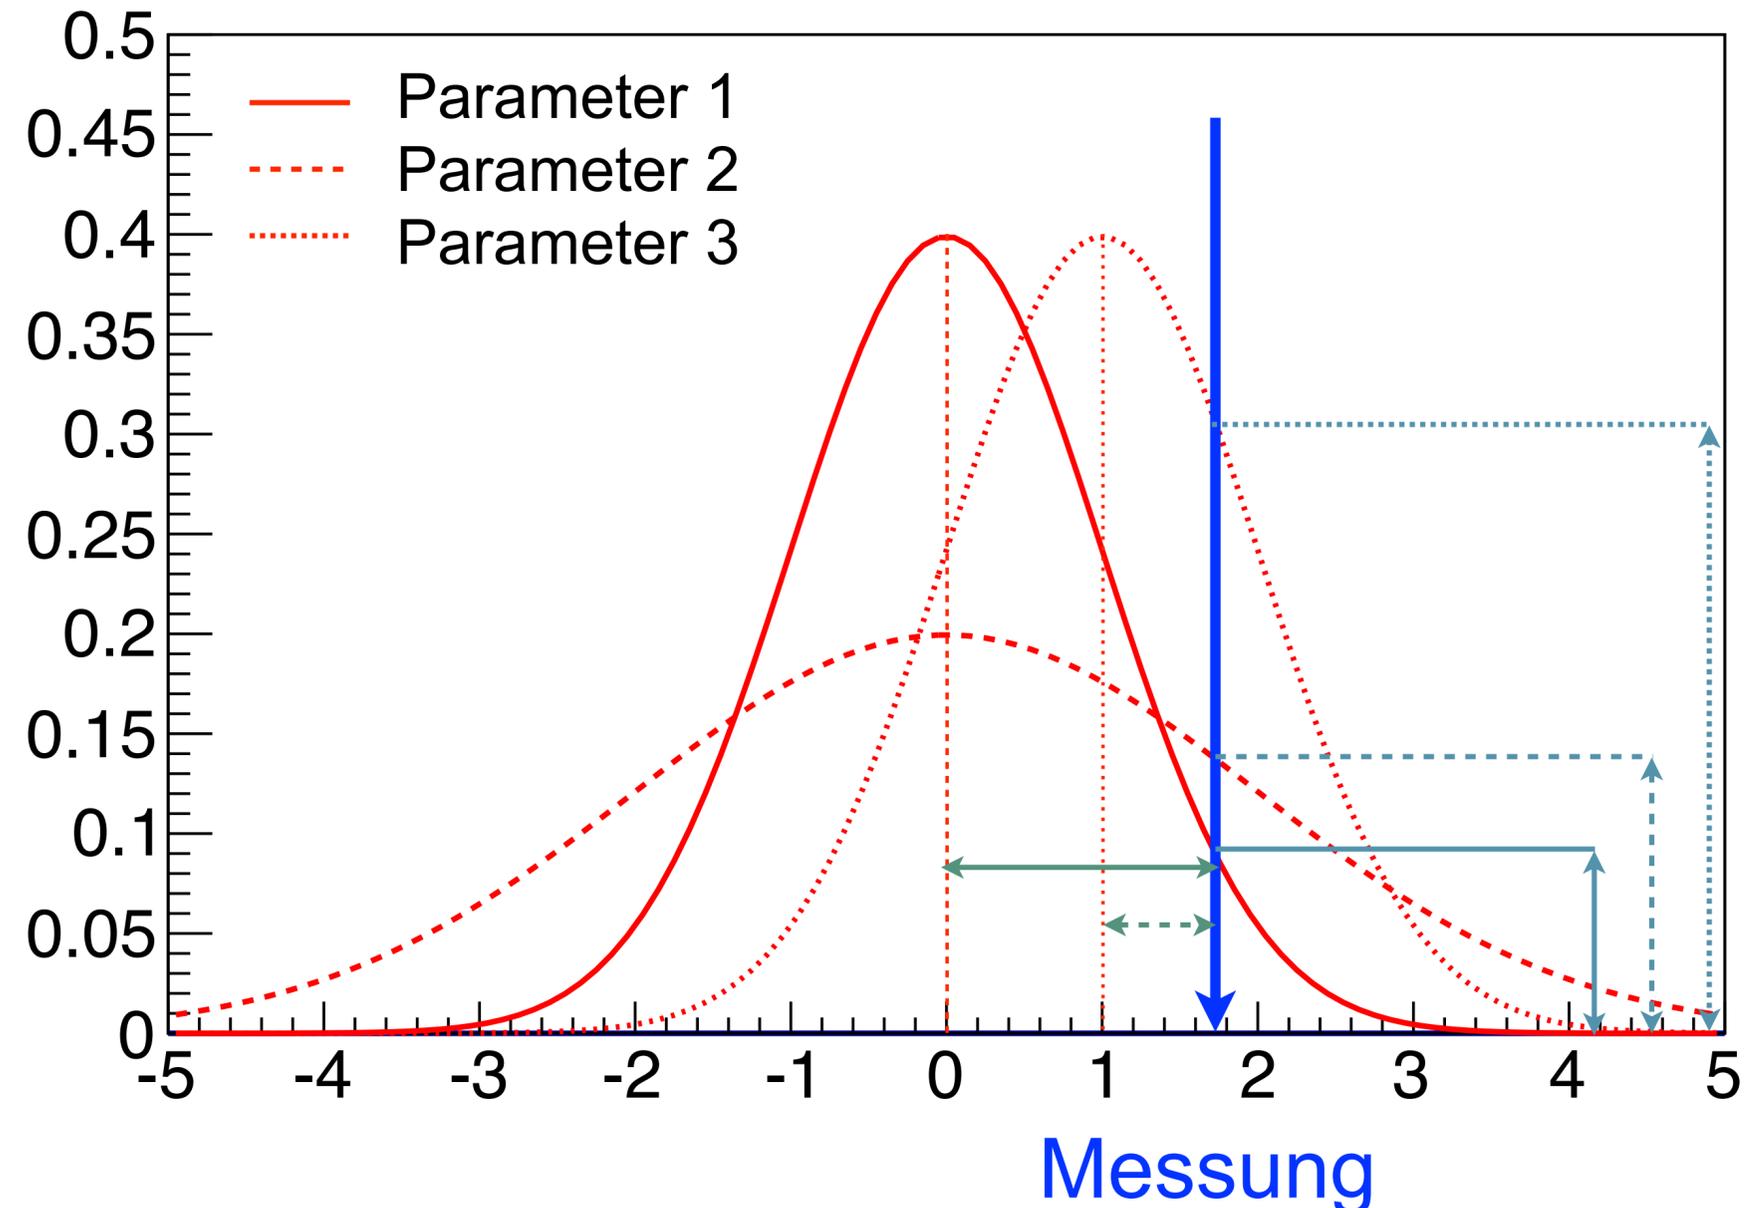
- Frage: welche Modellparameter passen am besten zu den Daten?

Kleinste Quadrate:
 minimiere (normierten)
 Abstand vom
 Erwartungswert

(nur Erwartungswert/Varianz
 müssen bekannt sein)

Maximum Likelihood:
 maximiere Höhe der PDF

(gesamte PDF muss
 bekannt sein)



Likelihood-Funktion

- Messwerte x_i : Stichprobe der Größe n aus **bekannter** Wahrscheinlichkeitsdichte $f(x; \mathbf{a})$ mit **Normierung** bezüglich x :

$$\int f(x; \mathbf{a}) dx = 1$$

- Konstruktion der Likelihood-Funktion: **Produkt** der Wahrscheinlichkeitsdichtefunktionen (PDFs) für alle Messwerte

$$L(\mathbf{a}) \equiv L(\mathbf{a}|\mathbf{x}) \equiv \prod_{i=1}^n f(x_i; \mathbf{a})$$

- Große Werte, wenn \mathbf{a} „passt“ (und PDF korrekt)
- Reinterpretation als **Funktion im Parameterraum** $\{a_1, \dots, a_n\}$ (d. h. **nach** der Messung, x_i fest), dort ist L aber **keine PDF** (nicht normiert)

Maximum-Likelihood-Prinzip

- Der **Maximum-Likelihood-Schätzwert** $\hat{\mathbf{a}}$ für einen Parametervektor \mathbf{a} ist derjenige Wert von \mathbf{a} , für den die Likelihood-Funktion den **größten Wert** annimmt: $L(\hat{\mathbf{a}}) \geq L(\mathbf{a})$ für alle \mathbf{a}

- Praxis: $-\ln L(\mathbf{a})$ wird **minimiert** („negative Log-Likelihood“)

- Logarithmus streng monotone Funktion \rightarrow **dieselben Extrema**

- Aus Produkten werden **Summen**: $-\ln L(\mathbf{a}) = -\sum_{i=1}^n f(x_i; \mathbf{a})$
 \rightarrow konstante Summanden irrelevant für Minimum

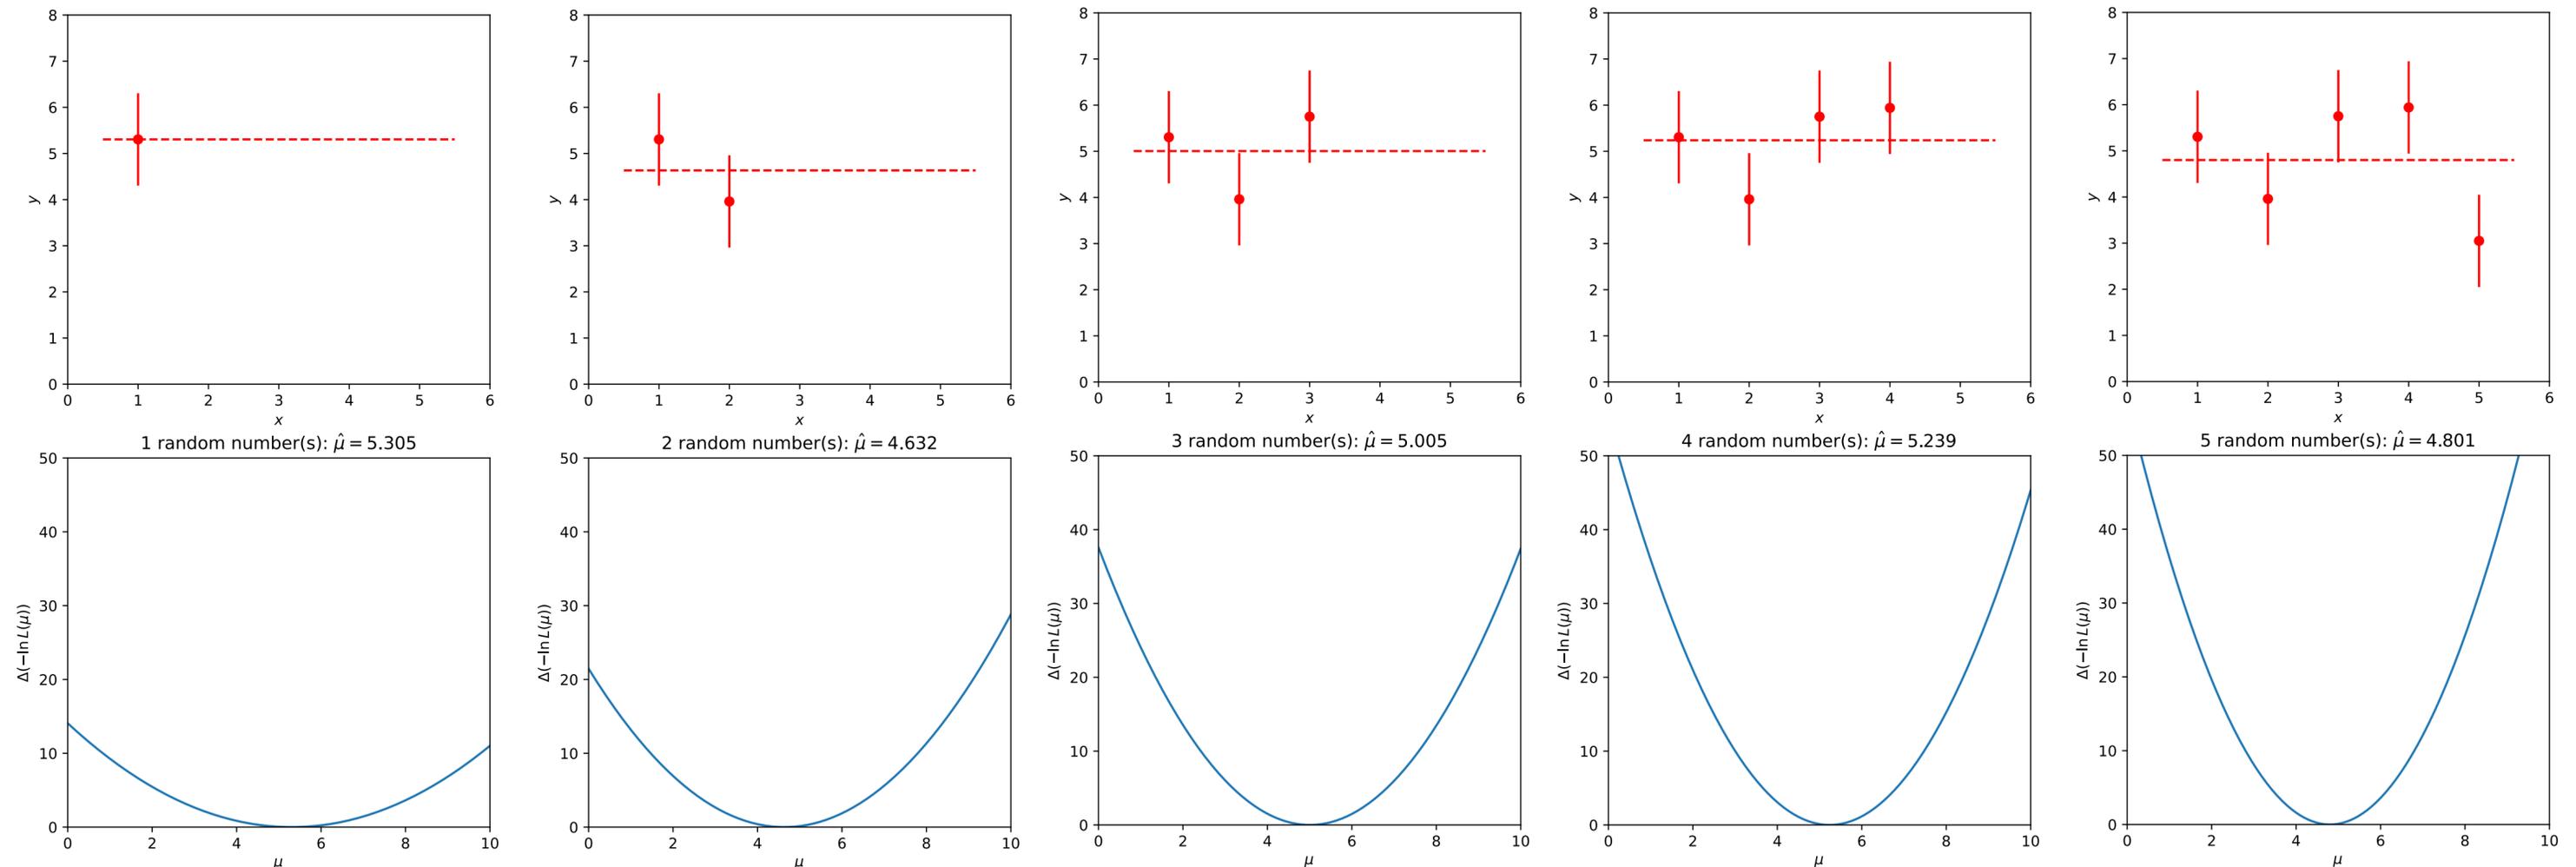
- Schätzwert $\hat{\mathbf{a}}$ aus Bedingungen:

$$\frac{\partial(-\ln L(\mathbf{a}))}{\partial a_j} \stackrel{!}{=} 0 \quad \frac{\partial^2(-\ln L(\mathbf{a}))}{\partial a_i \partial a_j} \bigg|_{\mathbf{a}=\hat{\mathbf{a}}} \text{ negativ definit}$$

- Minimierung: meist **numerisch**, in wenigen Fällen auch analytisch

Beispiel: Normalverteilung

- $n = 1-5$ normalverteilte Zufallszahlen mit $\mu = 5$ und $\sigma^2 = 1$:



$$\Delta(-\ln L(\mu)) \equiv -(\ln L(\mu) - \ln L(\hat{\mu}))$$

→ Parabeln um $\hat{\mu}$, die mit wachsendem n stärker gekrümmt werden

Analytische Lösung: Normalverteilung

- Gegeben: n normalverteilte Messwerte $x_i \rightarrow$ Likelihood-Funktion:

$$L(\mu, \sigma) = \prod_{i=1}^n \frac{1}{\sqrt{2\pi} \sigma} \exp \left[-\frac{(x_i - \mu)^2}{2\sigma^2} \right]$$
$$\rightarrow -\ln L(\mu, \sigma) = \frac{1}{2} \sum_{i=1}^n \left[\ln(2\pi) + \ln(\sigma^2) + \frac{(x_i - \mu)^2}{\sigma^2} \right]$$

- Bemerkungen:

- Gleichung für **Parabel** in μ

- **Äquivalenz** zur Methode der kleinsten Fehlerquadrate für Normalverteilung:

$$-\ln L = \frac{1}{2} S + \text{const}$$

(konstante Terme irrelevant für Minimum von $-\ln L \rightarrow$ **derselbe** Schätzwert)

Varianz von ML-Schätzwerten: grafisch

- Taylorentwicklung von $-\ln L$ um Minimum (analog zu LS-Methode):

$$-\ln L(a) \approx -\ln L(\hat{a}) + \left. \frac{\partial(-\ln L(a))}{\partial a} \right|_{a=\hat{a}} (a - \hat{a}) + \frac{1}{2} \left. \frac{\partial^2(-\ln L(a))}{\partial a^2} \right|_{a=\hat{a}} (a - \hat{a})^2$$

am Minimum: 0

Cramér-Rao-Ungleichung: $\hat{V}[\hat{a}]^{-1}$

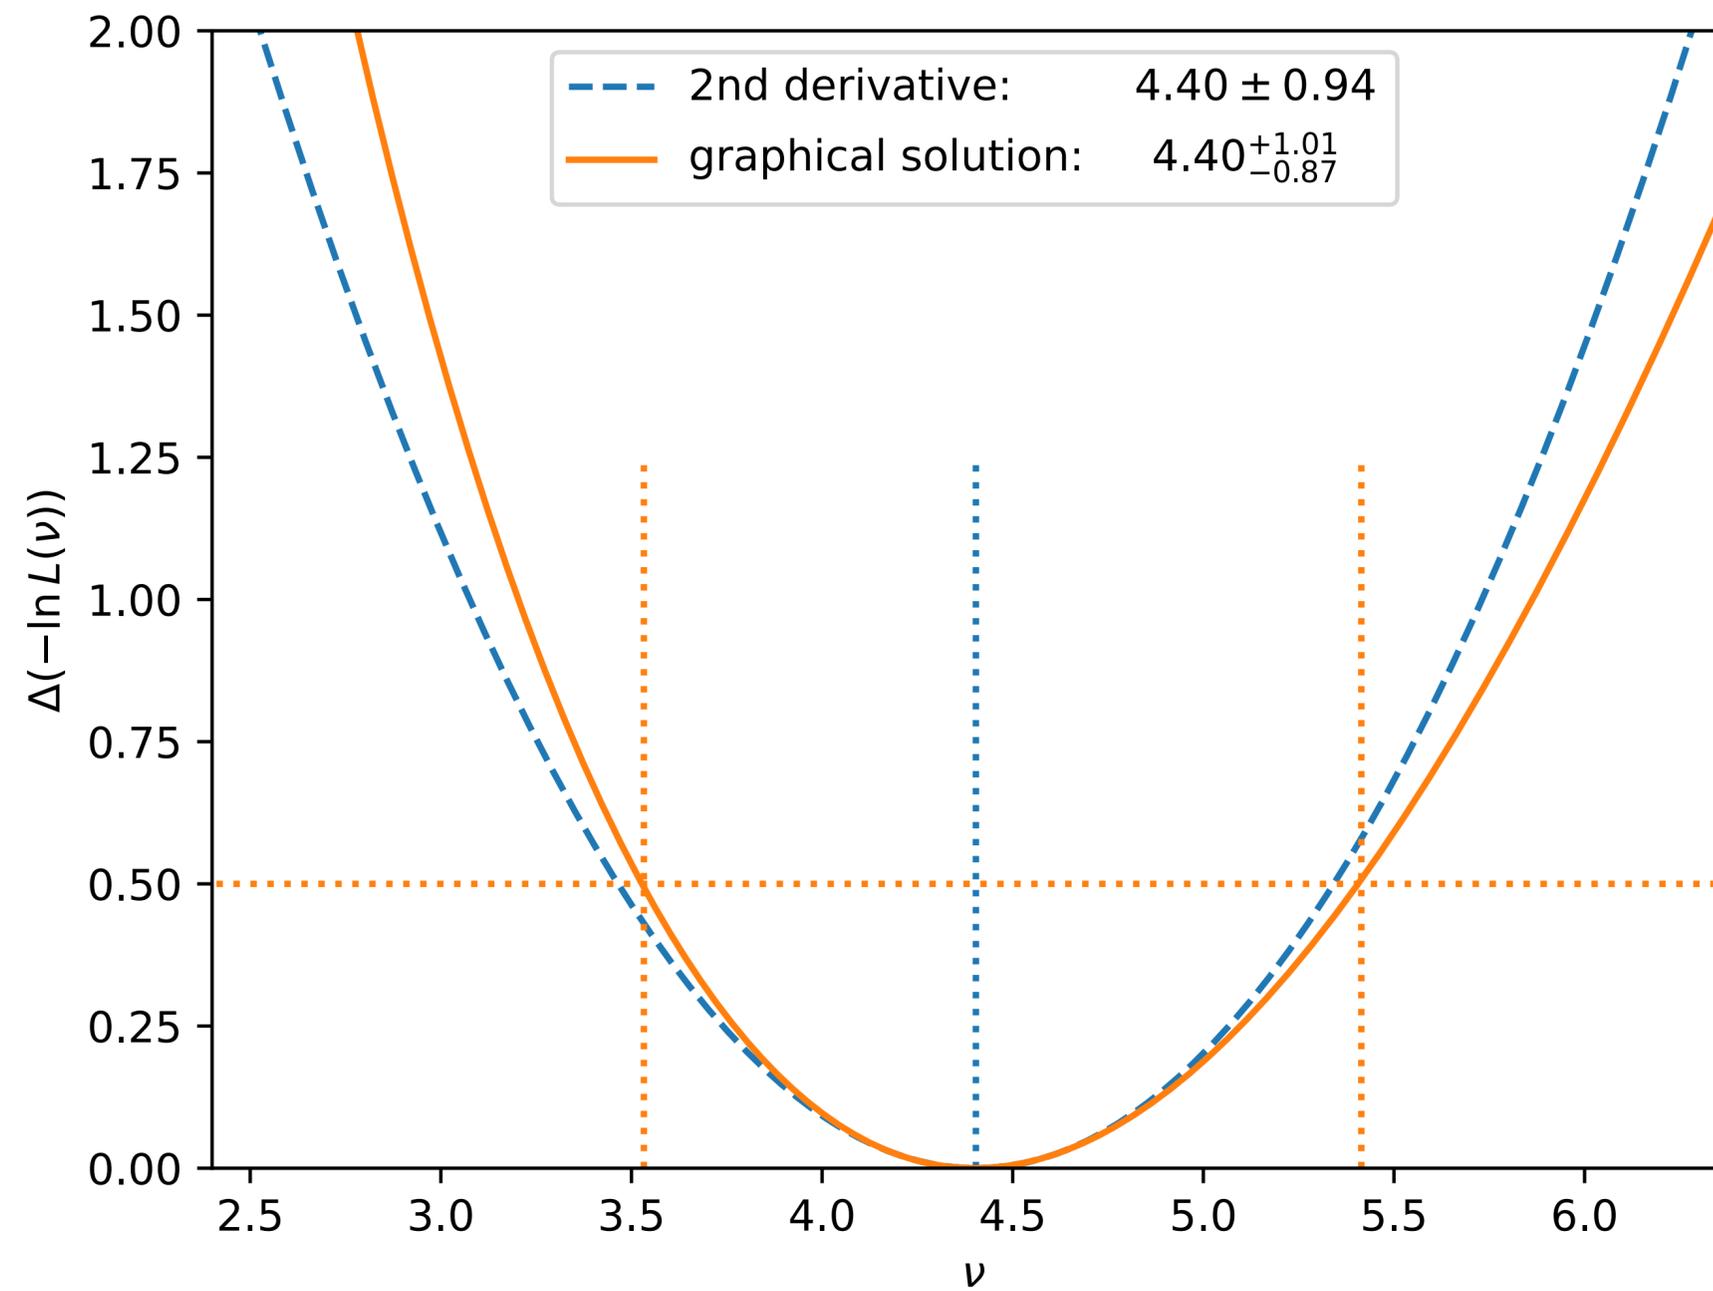
- Damit:

$$\Delta(-\ln L(a)) \equiv -(\ln L(a) - \ln L(\hat{a})) \approx \frac{1}{2} \left. \frac{\partial^2(-\ln L(a))}{\partial a^2} \right|_{\hat{a}} (a - \hat{a})^2 = \frac{1}{2} \frac{(a - \hat{a})^2}{\hat{V}[\hat{a}]}$$

$$\rightarrow \text{für } \Delta(-\ln L(a)) = \frac{1}{2} : a = \hat{a} \pm \sqrt{\hat{V}[\hat{a}]}$$

Unsicherheit der Parameterschätzung: Scan der negativen Log-Likelihood für Funktionswert $-\ln L(\hat{a}) + 1/2$

Varianz von ML-Schätzwerten: grafisch



- **Maximum-Likelihood-Methode:** universelles und mächtiges Werkzeug der mathematischen Statistik
 - **Likelihood-Funktion:** Produkt der (als bekannt vorausgesetzten) Wahrscheinlichkeitsdichten aller Messungen
 - Maximum-Likelihood-Prinzip: Schätzwerte für Parameter durch **Maximierung der Likelihood-Funktion**
 - Praxis: (numerische) **Minimierung** der negativen Log-Likelihood-Funktion
 - Für normalverteilte Zufallsgrößen: dieselben Schätzwerte wie Methode der kleinsten Quadrate