

## 8. Vorlesung, 11. Nov. 2013

Letzte Woche:

- Methode der kleinsten Fehlerquadrate
- graphische Methode zur Bestimmung der Unsicherheiten bei der Parameterabschätzung
- Aufspüren systematischer Fehler durch Untersuchung der Fit-Residuen

### Modellvergleich

Bei der Datenanalyse treffen wir häufig auf folgendes Problem: wir haben in einem Experiment einen Datensatz  $D$  gemessen, die Theorie bietet uns aber zwei (oder mehrere) Modelle  $M_1, M_2$  zur Analyse der Daten an. Jedes Modell hat seinen eigenen Satz von Parametern  $(\theta_1, \theta_2)$ , wobei sich die Modelle auch in der Zahl ihrer Parameter unterscheiden können. Die Abschätzung der Modellparameter nimmt immer die Gültigkeit des entsprechenden Modells als Grundvoraussetzung an. Die Frage lautet nun: Können wir quantitativ angeben, welches Modell die Daten besser beschreibt?

Beispiele:

- ist es besser, die gemessenen Daten  $y_j(x_j)$  mit  $y_j = c$ ,  $y_j = bx_j + c$ , oder mit  $y_j = ax_j^2 + bx_j + c$  zu beschreiben?
- Ist eine Resonanz thermisch verbreitert (beschrieben durch Ableitung der Fermi-Verteilung), Lebensdauerverbreitert (Lorentz-Funktion) oder inhomogen verbreitert (Gaussfunktion)?
- ist der Wert der gemessenen Größe Null, oder von Null verschieden?
- ...

Es wäre wünschenswert, die Wahrscheinlichkeit für die Wahrheit des Modells  $M$  bei gegebenen Daten

$$\text{prob}(M | D, I)$$

angeben zu können. Das Problem ist, dass wir dafür einen vollständigen Satz sich gegenseitig ausschließender Modelle benötigen würden, um diese Wahrscheinlichkeit normieren zu können. Dies ist in der Regel jedoch nicht der Fall. Formal heißt das (Bayessches Theorem)

$$\text{prob}(M_j | D, I) \stackrel{(5)}{=} \frac{\text{prob}(M_j | I) \text{prob}(D | M_j, I)}{\sum_j \text{prob}(M_j | I) \text{prob}(D | M_j, I)}$$

wobei wir den Normierungsnenner nicht kennen! Als Behelf macht es Sinn, Verhältnisse von Modellwahrscheinlichkeiten zu betrachten, denn

$$\ln \left( \frac{\text{prob}(M_1 | D, I)}{\text{prob}(M_2 | D, I)} \right) = \ln \left( \frac{\text{prob}(M_1 | I) \text{prob}(D | M_1, I)}{\text{prob}(M_2 | I) \text{prob}(D | M_2, I)} \right) = \underbrace{\ln \left( \frac{\text{prob}(M_1 | I)}{\text{prob}(M_2 | I)} \right)}_{\text{"welches Modell bevorzugen wir, bevor wir die Daten D kennen?"}} + \underbrace{\ln \left( \frac{\text{prob}(D | M_1, I)}{\text{prob}(D | M_2, I)} \right)}_{\text{"welche Präferenz zu } M_1 \text{ und } M_2 \text{ spricht aus den Daten D?"}} \quad (73)$$

"Bayes Faktor"

Im Folgenden werden wir stets davon ausgehen, dass wir vor der Messung keines der beiden Modelle bevorzugen, so dass der erste Term identisch Null ist. Die Ausdrücke  $\text{prob}(D | M_j, I)$  heißen Evidenz für Modell  $M_j$ . Sie ergeben sich aus

$$\text{prob}(D | M_j, I) \stackrel{(4)}{=} \int \text{prob}(D, \theta_j | M_j, I) d\theta_j \stackrel{(5)}{=} \int d\theta_j \underbrace{\text{pdf}(\theta_j | M_j, I)}_{\text{Prior prob. für Parameter } \theta_j \text{ des Modells } M_j} \underbrace{\text{prob}(D_j | \theta_j, M_j, I)}_{\text{Likelihood}} \quad (74)$$

## Anwendung auf Modelle mit additivem unabhängigem normalverteiltem Rauschen

Diese Modelle haben Priorverteilungen  $\text{pdf}(\theta_j | \sigma, M_j, I)$  und Likelihoodfunktionen der Form

$$\text{pdf}(D | \theta_j, \sigma, M_j, I) = \left( \frac{1}{2\pi\sigma^2} \right)^{N/2} \exp \left[ - \frac{N Q_j(\theta)}{2\sigma^2} \right] \quad (75)$$

Um die Evidenz für  $M_j$  auszurechnen, benötigen wir das Integral (74). Die Integration über  $\sigma$  lässt sich analytisch ausführen, wenn man  $\text{pdf}(\sigma) = C_\sigma = \text{const.}$  annimmt. Das ergibt (bis auf irrelevante Faktoren)

$$\left[ \frac{1}{Q_j(\theta)} \right]^{N/2} = \left( \frac{1}{Q_{\min,j}} \right)^{N/2} \left( \frac{Q_{\min,j}}{Q_j(\theta)} \right)^{N/2}$$

Die Integration über die Parameter  $\theta$  führen wir numerisch aus. Dabei setzen wir für die Priorwahrscheinlichkeiten jeweils Konstanten  $C_{\theta_j}$  an. Das numerisch berechnete Integral definieren wir als

$$\Omega_j := \int \left( \frac{Q_{\min,j}}{Q_j(\theta)} \right)^{N/2} d\theta_j \quad (76)$$

Diese Größe ist ein Maß für das Volumen im Parameterraum, in dem es eine signifikante Wahrscheinlichkeit für die Parameter  $\theta_j$  gibt. Dies bezeichnen wir als relevante Parameterraumvolumen.

Damit ist die Evidenz (74) gegeben durch

$$\text{pdf}(D | M_j, I) \propto \left( \frac{1}{Q_{\min,j}} \right)^{N/2} C_{\theta_j} \Omega_j$$

→ Folie

Die Konstante  $C_{\theta_j}$  stellt das inverse Volumen im Parameterraum dar, in dem die Priorwahrscheinlichkeit einen signifikanten Wert hat. Das Produkt  $C_{\theta_j} \Omega_j$  beschreibt daher, um welchen Faktor sich das relevante Volumen des Parameterraumes durch die Messung der Daten  $D$  verkleinert hat.

Der Modellvergleich ergibt also die relevante Kennzahl

$$\ln \frac{\text{pdf}(D | M_1, I)}{\text{pdf}(D | M_2, I)} = \frac{N-1}{2} \ln \left( \frac{Q_{\min,2}}{Q_{\min,1}} \right) + \ln \frac{C_{\theta_1} \Omega_1}{C_{\theta_2} \Omega_2} \quad (77)$$

Wir bevorzugen das Modell  $M_2$  gegenüber  $M_1$ , wenn dieser Ausdruck kleiner als Null ist, sonst bevorzugen wir  $M_1$  gegenüber  $M_2$ . Der erste Term auf der rechten Seite bevorzugt also das Modell mit dem kleineren  $Q_{\min,j}$ . Der zweite Term bevorzugt dasjenige Modell, das den relevanten Parameterraum weniger verkleinert.

Beispiel Fallversuch:  $N = 31$ ;  $Q_{\min,1} = 2.899 \times 10^{-7} \text{ s}^2$ ;  $Q_{\min,2} = 0.460 \times 10^{-7} \text{ s}^2$ ;  $\Omega_1 = 0.0137 \frac{\text{m}}{\text{s}^2}$ ;  $\Omega_2 = 2.281 \times 10^{-6} \frac{\text{m}^2}{\text{s}^2}$

→ Folien erster Term

$$\frac{N-1}{2} \log \frac{Q_{\min,2}}{Q_{\min,1}} = -27.6$$

zweiter Term

$$\ln \frac{C_{\theta_1} \Omega_1}{C_{\theta_2} \Omega_2} = \ln \frac{\Omega_1}{C_{\theta_2} \Omega_2}$$

Um eine Aussage machen zu können, sind wir gezwungen uns auf einen Wert für  $C_2$  festzulegen. Wir erinnern uns, dass  $z_0$  der Offset in der Längenmessung ist. Nehmen wir zum Beispiel an, wir sind sicher, dass  $-0.5 \text{ m} \leq z_0 \leq 0.5 \text{ m}$  ist, dann wäre

$$C_{z_0} = 1 \text{ m} \quad \text{und} \quad C_{\theta_2} \Omega_2 = 2.281 \times 10^{-6} \frac{\text{m}}{\text{s}^2} \Rightarrow \frac{\Omega_1}{\Omega_2 C_{z_0}} = 5990.75 \Rightarrow \ln \frac{\Omega_1}{\Omega_2 C_{z_0}} = +8.70$$

Der erste Term favorisiert Modell 2 wegen des deutlich besseren Fits. Der zweite Term favorisiert Modell 1, weil das relevante Volumen im Parameterraum weniger stark abnimmt. Das liegt auch daran, dass Modell 2 einen zweidimensionalen Parameterraum besitzt. Der zweite Term 'bestraft' uns daher für den zusätzlichen Parameter  $z_0$ . Dennoch ist insgesamt

$$\ln \frac{\text{prob}(M_1 | D, I)}{\text{prob}(M_2 | D, I)} = -27.6 + 8.70 = -18.9 \Rightarrow \text{prob}(M_2 | D, I) = 1.6 \times 10^8 \text{ pdf}(M_1 | D, I)$$