



# Entfaltungsmethoden in der Datenanalyse

Matthias Bartelt  
Universität Dortmund

[bartelt@physik.uni-dortmund.de](mailto:bartelt@physik.uni-dortmund.de)





# Übersicht

- Motivation
- Mathematisches Problem der Entfaltung
- Regularisierte Entfaltung
- Iterative Methode: Bayes'sche Entfaltung
- Stand der Dinge
- Ausblick



# Motivation

- Vergleich experimenteller Daten mit theoretischen Vorhersagen
- Abweichungen in der Verteilung der Messdaten aufgrund begrenzte Akzeptanz und Messgenauigkeit des Detektors
  - Unzulänglichkeiten des Detektors in die Vorhersage einbeziehen Messdaten „entfalten“
- Vergleich von Messdaten verschiedener Experimente



# Das mathematische Problem

- Gemessene Verteilung  $f_{\text{Messung}}$

$$f_{\text{Messung}}(x) = \int R(x, y) f_{\text{Wahr}}(y) dy$$

- $f_{\text{Wahr}}$  parametrisierbar  $\Rightarrow$  Standard Methoden (z.B. Maximum Likelihood)
- Ansonsten  $\Rightarrow$  Histogramm mit  $n$  Bins:

$$v_i = \sum_{j=1}^n R_{ij} \mu_j \quad i = 1 \dots n$$



# Response-Funktion $R(x, y)$

- $R$  hängt ausschließlich vom der verwendeten Messapparatur ab
- $R$  ist eine bedingte Wahrscheinlichkeit:


$$R_{ij} = P(\text{beobachtet in } i | \text{wahrer Wert in } j)$$

$$\sum_{i=1}^n R_{ij} = P(\text{beobachtet} | \text{wahrer Wert in } j)$$


$$\sum_{i=1}^n R_{ij} = \varepsilon_j$$




# Ein Beispiel



Wahre Daten  $\mu$



Effizienz  $\varepsilon$




$\cdots$  Messwerte  $x$   
 – Erwartung  $\nu$




# Entfaltung

- Entfalten durch Invertierung von  $R$


$$\mu_i = \sum_{j=1}^n R^{-1}_{ij} \nu_j \Rightarrow \hat{\mu}_i = \sum_{j=1}^n R^{-1}_{ij} x_j$$



Wahre Daten  $\mu$



⋯ Messwerte  $x$   
– Erwartung  $\nu$



Erwartungswerte  $\hat{\mu}$   
für  $\mu$



# Entfaltung

- Starke Schwankungen in den Erwartungswerten
- Einfache Korrekturfaktoren  $C_i$  (üblicherweise aus MC) liefern Erwartungswerte mit geringeren Schwankungen

$$C_i = \mu_{i, \text{MC}} / \nu_{i, \text{MC}}$$

$$\hat{\mu}_i = C_i \cdot x_i$$





# Regularisierte Entfaltung

- Wirkungsfunktional  $F(\mu)$  aufstellen, z.B.

$$F(\mu) = \sum_i \frac{\left( v_i - \sum_j R_{ij} \mu_j \right)^2}{\sigma(\mu)}$$

- Minimierung von  $F$  ergibt mathematisch die Lösung
- Auch hier treten starke Oszillationen auf



# Regularisierte Entfaltung

- Unterdrückung der Oszillationen durch Nebenbedingungen: Regularisierungsfunktion  $S(\mu)$  und -Parameter  $\alpha$
- Neues Funktional  $\Phi$  bilden:
$$\Phi(\mu) = \alpha \cdot F(\mu) + S(\mu)$$
- Minimierung von  $\Phi$  führt dann auf die Lösung



# Satz von Bayes

$$P(A|B) = \frac{P(B|A) \cdot P(A)}{P(B)}$$

- $P(A|B)$  = Wahrscheinlichkeit für ein Ereignis  $B$  unter der Bedingung, dass  $A$  auftritt
- Für abzählbar viele Ereignisse gilt

$$P(B) = \sum_j P(B|A_j) \cdot P(A_j)$$

$$\text{d.h. } P(A_i|B) = \frac{P(B|A_i) \cdot P(A_i)}{\sum_j P(B|A_j) \cdot P(A_j)}$$



# Bayes'sche Entfaltung

- Startbedingung  $p_i^0 = 1/N$
- Erwartungswerte  $\hat{\mu}_i$  bestimmen

$$\begin{aligned}\hat{\mu}_i^m &= \frac{1}{\varepsilon_i} \sum_{j=1}^N P(\text{wahrer Wert in } i | \text{beobachtet in } j) x_j \\ &= \frac{1}{\varepsilon_i} \sum_{j=1}^N \frac{R_{ij} p_i^{m-1}}{\sum_k R_{jk} p_k^{m-1}} x_k\end{aligned}$$

- Neue Wahrscheinlichkeiten berechnen

$$p_i^m = \hat{\mu}_i^m / \sum_i \hat{\mu}_i^m$$



# Bisherige Entfaltung: RUN

- Regularisierte Entfaltung
- Begrenzte Anzahl (3) an Parameter
- Fortran-Code, der rechner-spezifische Funktionen verwendet

```
PROGRAM UNFOLDMS
*****
*
* Main program for run-package of v.Blobel
* run only on alphas!!
*
```

- Optimierung läuft halbautomatisch

# Ausblick / Zusammenfassung



- Neues Entfaltungsprogramm in C++
- Beliebige Anzahl an Parametern
- Implementierung verschiedener Methoden der Entfaltung
  - Regularisierte Entfaltung
  - Bayes'sche Entfaltung
  - Kombination aus Regularisierung und Bayes
- Automatische Optimierung