



# Generalized iLUCK-models and prior-data conflict

A contribution to Generalized Bayesian Inference

Gero Walter

Institut für Statistik  
Ludwig-Maximilians-Universität München

4. Juni 2009





## Generalisierte Bayes-Inferenz: Idee

### Warum Intervallwahrscheinlichkeit?

Unsicherheit ist mehrdimensional

Additivität

Modellierung von Nichtwissen

Prior-data conflict

### Generalisierte Bayes-Inferenz mit LUCK-models

LUCK-models

iLUCK-models

generalized iLUCK-models

## Zusammenfassung



# Generalisierte Bayes-Inferenz – Idee


Bayes-Inferenz über einen Parameter  $\theta$ :





# Generalisierte Bayes-Inferenz – Idee

Bayes-Inferenz über einen Parameter  $\theta$ :





# Generalisierte Bayes-Inferenz – Idee

Bayes-Inferenz über einen Parameter  $\theta$ :

Priori-Wissen über  $\theta$  + Daten  $x$  → aufdatiertes Wissen über  $\theta$

Priori-Verteilung  $p(\theta)$  + Likelihood  $f(x | \theta)$  → Posteriori-Verteilung  $p(\theta | x)$

**Menge von** Prioris  $\mathcal{M}_\theta$  + Likelihood  $f(x | \theta)$  → **Menge von** Posterioris  $\mathcal{M}_{\theta|x}$



## Generalisierte Bayes-Inferenz – Idee

→ eindimensionale Größen werden intervallwertig, z.B.

$$\begin{aligned} \mathbb{E}[\theta] &\longrightarrow [\underline{\mathbb{E}}[\theta], \overline{\mathbb{E}}[\theta]] = \left[ \min_{p \in \mathcal{M}_\theta} \mathbb{E}_p[\theta], \max_{p \in \mathcal{M}_\theta} \mathbb{E}_p[\theta] \right] \\ P(\theta \in A) &\longrightarrow [\underline{P}(\theta \in A), \overline{P}(\theta \in A)] \\ &= \left[ \min_{p \in \mathcal{M}_\theta} P_p(X \in A), \max_{p \in \mathcal{M}_\theta} P_p(X \in A) \right] \end{aligned}$$





Generalisierte Bayes-Inferenz: Idee

Warum Intervallwahrscheinlichkeit?

Unsicherheit ist mehrdimensional

Additivität

Modellierung von Nichtwissen

Prior-data conflict

Generalisierte Bayes-Inferenz mit LUCK-models

LUCK-models

iLUCK-models

generalized iLUCK-models

Zusammenfassung



## Unsicherheit ist mehrdimensional

„For three hundred years [...] uncertainty was conceived solely in terms of probability theory. This seemingly unique connection between uncertainty and probability is now challenged [... by several other] theories, which are demonstrably capable of characterizing situations under uncertainty. [...]

[...] it has become clear that there are several distinct types of uncertainty. That is, it was realized that **uncertainty** is a **multidimensional concept**. [...] That] multidimensional nature of uncertainty was obscured when uncertainty was conceived solely in terms of probability theory, in which it is manifested by only one of its dimensions.“

Klir & Wierman: Uncertainty-based Information, Physika, 1998, S.1



## Unsicherheit ist mehrdimensional

- ▶ *risk* / Risiko / ideale stochastische Unsicherheit:  
„Zufalls-Mechanismus“ bekannt/klar
- ▶ *ambiguity* / Ambiguität / Nicht-stochastische Unsicherheit:  
„Zufalls-Mechanismus“ unbekannt/unklar
- ▶ ...

(siehe auch Knight (1921): *risk vs. uncertainty*)



## Unsicherheit ist mehrdimensional

- ▶ *risk* / Risiko / ideale stochastische Unsicherheit:  
„Zufalls-Mechanismus“ bekannt/klar
- ▶ *ambiguity* / Ambiguität / Nicht-stochastische Unsicherheit:  
„Zufalls-Mechanismus“ unbekannt/unklar
- ▶ ...

(siehe auch Knight (1921): *risk* vs. *uncertainty*)

➔ mit Mengen von Verteilungen kann *ambiguity* explizit ins Modell einbezogen werden:

einzelne Verteilung	↔	<i>risk</i>
Größe der Menge	↔	<i>ambiguity</i>



# Additivität $P(A \cup B) = P(A) + P(B)$

(subjektive) Bayesianer: jede Art von Unsicherheit als (subjektive) Wahrscheinlichkeitsverteilung darstellbar

Probleme bei

- ▶ Entwicklung von Expertensystemen



## Additivität $P(A \cup B) = P(A) + P(B)$

(subjektive) Bayesianer: jede Art von Unsicherheit als (subjektive) Wahrscheinlichkeitsverteilung darstellbar

Probleme bei

- ▶ Entwicklung von Expertensystemen
- ▶ bei Experimenten in der Tradition von Ellsberg

Expertenangaben („elicitation“) führen ständig zu nicht-additiven Wahrscheinlichkeiten! (Vermischung von *risk* und *ambiguity*.)

➔ untere/obere Wahrscheinlichkeiten sind nicht-additive Maße



# Modellierung von Nichtwissen

„objektive“ Bayesianer, die keine subjektive Priori verwenden  
möchten, benutzen eine „nichtinformativ“ Priori

Probleme:

- ▶ nicht eindeutig



# Modellierung von Nichtwissen

„objektive“ Bayesianer, die keine subjektive Priori verwenden  
möchten, benutzen eine „nichtinformativ“ Priori

Probleme:

- ▶ nicht eindeutig
- ▶ Nichtwissen über Asymmetrie  $\neq$  Wissen um Symmetrie



# Modellierung von Nichtwissen

„objektive“ Bayesianer, die keine subjektive Priori verwenden  
möchten, benutzen eine „nichtinformativ“ Priori

Probleme:

- ▶ nicht eindeutig
- ▶ Nichtwissen über Asymmetrie  $\neq$  Wissen um Symmetrie
- ▶ *eine* Priori kann kein Nichtwissen über einen Parameter ausdrücken



# Modellierung von Nichtwissen

„objektive“ Bayesianer, die keine subjektive Priori verwenden  
möchten, benutzen eine „nichtinformativ“ Priori

Probleme:

- ▶ nicht eindeutig
  - ▶ Nichtwissen über Asymmetrie  $\neq$  Wissen um Symmetrie
  - ▶ *eine* Priori kann kein Nichtwissen über einen Parameter ausdrücken
- ➔ eine Menge von Verteilungen prinzipiell schon:  
 $P(\theta \in A) = (0, 1)$



## Prior-data conflict

= Situationen, in denen *informatives Priori-Wissen* und *gesicherte Daten* (keine Ausreißer, etc.) in Konflikt stehen

**Beispiel:** (Walley 1991)

Daten:	$X \sim N(\vartheta, 1)$
konjugierte priori:	$\vartheta \sim N(\mu, 1)$
Posteriori:	$\vartheta   x \sim N\left(\frac{\mu + x}{2}, \frac{1}{2}\right)$



## Prior-data conflict

= Situationen, in denen *informatives Priori-Wissen*  
und *gesicherte Daten* (keine Ausreißer, etc.) in Konflikt stehen

**Beispiel:** (Walley 1991)

Daten:	$X$	$\sim$	$N(\vartheta, 1)$
konjugierte priori:	$\vartheta$	$\sim$	$N(\mu, 1)$
Posteriori:	$\vartheta \mid x$	$\sim$	$N\left(\frac{\mu + x}{2}, \frac{1}{2}\right)$

- ▶ Fall (i):  $\mu = 5.5, x = 6.5 \implies \vartheta \sim N(6, \frac{1}{2})$
- ▶ Fall (ii):  $\mu = 3.5, x = 8.5 \implies \vartheta \sim N(6, \frac{1}{2})$



## Prior-data conflict

= Situationen, in denen *informatives Priori-Wissen* und *gesicherte Daten* (keine Ausreißer, etc.) in Konflikt stehen

**Beispiel:** (Walley 1991)

Daten:	$X$	$\sim$	$N(\vartheta, 1)$
konjugierte priori:	$\vartheta$	$\sim$	$N(\mu, 1)$
Posteriori:	$\vartheta \mid x$	$\sim$	$N\left(\frac{\mu + x}{2}, \frac{1}{2}\right)$

▶ Fall (i):  $\mu = 5.5, x = 6.5 \implies \vartheta \sim N(6, \frac{1}{2})$

▶ Fall (ii):  $\mu = 3.5, x = 8.5 \implies \vartheta \sim N(6, \frac{1}{2})$

➔ mit Mengen von Prioris Fall (i) und (ii) unterscheidbar  
(Fall (i): kleine Menge, Fall (ii): große Menge)



# Generalisierte Bayes-Inferenz: Idee Warum Intervallwahrscheinlichkeit?

Unsicherheit ist mehrdimensional

Additivität

Modellierung von Nichtwissen

Prior-data conflict

## Generalisierte Bayes-Inferenz mit LUCK-models

LUCK-models

iLUCK-models

generalized iLUCK-models

## Zusammenfassung



# Generalisierte Bayes-Inferenz mit LUCK-models: Konzept

Wie Mengen von Prioris sinnvoll beschreiben?

- ▶ benutze **konjugierte** Prioris
  - ↳ nur Parameter der Priori aufdatieren



# Generalisierte Bayes-Inferenz mit LUCK-models: Konzept

Wie Mengen von Prioris sinnvoll beschreiben?

- ▶ benutze **konjugierte** Prioris
  - ➡ nur Parameter der Priori aufdatieren
- ▶ statt einem Parameter eine (konvexe) Menge von Priori-Parametern
  - ➡ wenn Aufdatierung linear ist, dann ist die Menge der Posteriori-Parameter einfach ermittelbar!

# Generalisierte Bayes-Inferenz mit LUCK-models: Konzept

Wie Mengen von Prioris sinnvoll beschreiben?

- ▶ benutze **konjugierte** Prioris
  - ➡ nur Parameter der Priori aufdatieren
- ▶ statt einem Parameter eine (konvexe) Menge von Priori-Parametern
  - ➡ wenn Aufdatierung linear ist, dann ist die Menge der Posteriori-Parameter einfach ermittelbar!
- ▶ Idee von Quaeghebeur & de Cooman (2005):  
allgemeine Konstruktion von konjugierten Prioris führt automatisch zu linear aufdatierten Parametern!



## Konstruktion von konjugierten Prioris:

$X \stackrel{iid}{\sim}$  linear, canonical exponential family, d.h.

$$p(x | \theta) \propto \exp \{ \langle \psi, \tau(x) \rangle - n\mathbf{b}(\psi) \} \quad \left[ \psi \text{ Transformation von } \theta \right]$$



# Konstruktion von konjugierten Prioris:

$X \stackrel{iid}{\sim}$  linear, canonical exponential family, d.h.

$$p(x | \theta) \propto \exp \{ \langle \psi, \tau(x) \rangle - n \mathbf{b}(\psi) \} \quad \left[ \psi \text{ Transformation von } \theta \right]$$

→ konjugierte Priori:

$$p(\theta) \propto \exp \{ n^{(0)} [ \langle \psi, y^{(0)} \rangle - \mathbf{b}(\psi) ] \}$$



## Konstruktion von konjugierten Prioris:

$X \stackrel{iid}{\sim}$  linear, canonical exponential family, d.h.

$$p(x | \theta) \propto \exp \{ \langle \psi, \tau(x) \rangle - n \mathbf{b}(\psi) \} \quad \left[ \psi \text{ Transformation von } \theta \right]$$

➔ konjugierte Priori:

$$p(\theta) \propto \exp \{ n^{(0)} [\langle \psi, y^{(0)} \rangle - \mathbf{b}(\psi)] \}$$

➔ (konjugierte) Posteriori:

$$p(\theta | x) \propto \exp \{ n^{(1)} [\langle \psi, y^{(1)} \rangle - \mathbf{b}(\psi)] \}$$

wobei  $y^{(1)} = \frac{n^{(0)} y^{(0)} + \tau(x)}{n^{(0)} + n}$  und  $n^{(1)} = n^{(0)} + n$ .

➔ jedes  $(p(\theta), p(\theta | x))$ , das so aufdatiert wird = LUCK-model



# LUCK-models: Interpretation von $y^{(0)}$ und $n^{(0)}$

$y^{(0)}$ : "main prior parameter"

- ▶ für Stichproben aus  $N(\mu, 1)$  ist  $p(\mu)$  eine  $N(y^{(0)}, \frac{1}{n^{(0)}})$
- ▶ für Stichproben aus  $M(\theta)$  ist  $p(\theta)$  eine  $\text{Dir}(n^{(0)}, y^{(0)})$   
 $(y_j^{(0)} = t_j \hat{=} \text{Priori-W'keit für Kategorie } j, n^{(0)} = s; s \cdot t_j = \alpha_j)$



# LUCK-models: Interpretation von $y^{(0)}$ und $n^{(0)}$

$y^{(0)}$ : "main prior parameter"

- ▶ für Stichproben aus  $N(\mu, 1)$  ist  $p(\mu)$  eine  $N(y^{(0)}, \frac{1}{n^{(0)}})$
- ▶ für Stichproben aus  $M(\theta)$  ist  $p(\theta)$  eine  $\text{Dir}(n^{(0)}, y^{(0)})$   
 $(y_j^{(0)} = t_j \hat{=} \text{Priori-W'keit für Kategorie } j, n^{(0)} = s; s \cdot t_j = \alpha_j)$

$n^{(0)}$ : "prior strength" oder "pseudocounts"

mit  $\tilde{\tau}(x) =: \frac{1}{n} \tau(x)$ :  $[\tau(x) = \sum_{i=1}^n \tau(x_i)]$

$$y^{(1)} = \frac{n^{(0)}}{n^{(0)} + n} \cdot y^{(0)} + \frac{n}{n^{(0)} + n} \cdot \tilde{\tau}(x).$$



## Mengen von LUCK-models – iLUCK-model

iLUCK-model: variiere  $y^{(0)}$  in  $\mathcal{Y}^{(0)}$  [  $\mathcal{Y}^{(0)}$  konvex ]  $\iff$   
erlaubt unscharfes Wissen über den zentralen Parameter  $y^{(0)}$

➔ Priori-„credal set“ enthält *alle finite konvexen Mischungen*  
von  $p(\theta)$ s mit  $y^{(0)} \in \mathcal{Y}^{(0)}$



## Mengen von LUCK-models – iLUCK-model

iLUCK-model: variiere  $y^{(0)}$  in  $\mathcal{Y}^{(0)}$  [  $\mathcal{Y}^{(0)}$  konvex ]  $\iff$   
erlaubt unscharfes Wissen über den zentralen Parameter  $y^{(0)}$

- ➔ Priori-„credal set“ enthält *alle finite konvexen Mischungen* von  $p(\theta)$ s mit  $y^{(0)} \in \mathcal{Y}^{(0)}$
- ➔ Posteriori-„credal set“ einfach berechenbar:  
*alle finite konvexen Mischungen* von  $p(\theta | x)$ s mit

$$y^{(1)} \in \mathcal{Y}^{(1)} = \frac{n^{(0)}}{n^{(0)} + n} \cdot y^{(0)} + \frac{n}{n^{(0)} + n} \cdot \tilde{\tau}(x)$$



## Mengen von LUCK-models – iLUCK-model

iLUCK-model: variiere  $y^{(0)}$  in  $\mathcal{Y}^{(0)}$  [  $\mathcal{Y}^{(0)}$  konvex ]  $\iff$   
erlaubt unscharfes Wissen über den zentralen Parameter  $y^{(0)}$

→ Priori-„credal set“ enthält *alle finite konvexen Mischungen*  
von  $p(\theta)$ s mit  $y^{(0)} \in \mathcal{Y}^{(0)}$

→ Posteriori-„credal set“ einfach berechenbar:  
*alle finite konvexen Mischungen* von  $p(\theta | x)$ s mit

$$y^{(1)} \in \mathcal{Y}^{(1)} = \frac{n^{(0)}}{n^{(0)} + n} \cdot y^{(0)} + \frac{n}{n^{(0)} + n} \cdot \tilde{\tau}(x)$$

Aber:  $\mathcal{Y}^{(0)}$  muss endliche Grenzen haben


→ „perfektes“ Nichtwissen hier nicht darstellbar




# iLUCK-model: Beispiel $X \sim N(\mu, 1)$

→  $\mu \sim N(y^{(0)}, \frac{1}{n^{(0)}})$

Set of priors:  $y^{(0)} \in [3;4]$  and  $n^{(0)} = 5$



Set of posteriors:  $y^{(1)} \in [3.67;4]$  and  $n^{(1)} = 15$







## iLUCK-model: Beispiel $X \sim M(\theta)$

- $\theta \sim \text{Dir}(n^{(0)}, y^{(0)})$  ↔ **Imprecise Dirichlet Model (IDM)**
- Walley (*JRSS*, 1991), Bernard (*IJAR Special Issue*, 2009)



# iLUCK-model: Beispiel $X \sim M(\theta)$


- ➔  $\theta \sim \text{Dir}(n^{(0)}, y^{(0)})$  ↔ **Imprecise Dirichlet Model (IDM)**
- ➔ Walley (*JRSS*, 1991), Bernard (*IJAR Special Issue*, 2009)






# Probleme bei *prior-data conflict*: $X \sim N(\mu, 1)$


Set of priors:  $y^{(0)} \in [3;4]$  and  $n^{(0)} = 5$




Set of posteriors:  $y^{(1)} \in [3.67;4]$  and  $n^{(1)} = 15$



Set of priors:  $y^{(0)} \in [3;4]$  and  $n^{(0)} = 5$




Set of posteriors:  $y^{(1)} \in [6.33;6.67]$  and  $n^{(1)} = 15$





# Probleme bei *prior-data conflict*: $X \sim M(\theta)$ (IDM)





## iLUCK-model — Posteriori-Unschärfe in $y$

$$\begin{aligned}\bar{y}^{(1)} - \underline{y}^{(1)} &= \frac{n^{(0)}\bar{y}^{(0)} + \tau(x)}{n^{(0)} + n} - \frac{n^{(0)}\underline{y}^{(0)} + \tau(x)}{n^{(0)} + n} \\ &= \frac{n^{(0)}(\bar{y}^{(0)} - \underline{y}^{(0)})}{n^{(0)} + n}\end{aligned}$$

... hängt nicht von der suffizienten Statistik  $\tau(x)$  ab!



# iLUCK-model — Posteriori-Unschärfe in $y$

$$\begin{aligned} \bar{y}^{(1)} - \underline{y}^{(1)} &= \frac{n^{(0)}\bar{y}^{(0)} + \tau(x)}{n^{(0)} + n} - \frac{n^{(0)}\underline{y}^{(0)} + \tau(x)}{n^{(0)} + n} \\ &= \frac{n^{(0)}(\bar{y}^{(0)} - \underline{y}^{(0)})}{n^{(0)} + n} \end{aligned}$$

... hängt nicht von der suffizienten Statistik  $\tau(x)$  ab!

Für jede Stichprobe mit Umfang  $n$  reduziert sich die Posteriori-Unschärfe im gleichen Umfang!



## generalized iLUCK-models (Walter & Augustin, 2009):

varyiere  $y^{(0)}$  in  $\mathcal{Y}^{(0)}$  **und**  $n^{(0)}$  in  $\mathcal{N}^{(0)}$   $\iff$   
 flexiblere Gewichtung der Priori-Information  $\mathcal{Y}^{(0)}$  und  
 Stichproben-Information  $\tilde{\tau}(x)$  in

$$y^{(1)} \in \mathcal{Y}^{(1)} = \frac{n^{(0)}}{n^{(0)} + n} \cdot y^{(0)} + \frac{n}{n^{(0)} + n} \cdot \tilde{\tau}(x)$$

$\rightarrow$  Priori-„credal set“ enthält *alle finiten konvexen Mischungen*  
 von  $p(\theta)$ s mit  $y^{(0)} \in \mathcal{Y}^{(0)}$  **und**  $n^{(0)} \in \mathcal{N}^{(0)}$



## generalized iLUCK-models (Walter & Augustin, 2009):

varyiere  $y^{(0)}$  in  $\mathcal{Y}^{(0)}$  **und**  $n^{(0)}$  in  $\mathcal{N}^{(0)}$   $\iff$   
flexiblere Gewichtung der Priori-Information  $y^{(0)}$  und  
Stichproben-Information  $\tilde{\tau}(x)$  in

$$y^{(1)} \in \mathcal{Y}^{(1)} = \frac{n^{(0)}}{n^{(0)} + n} \cdot y^{(0)} + \frac{n}{n^{(0)} + n} \cdot \tilde{\tau}(x)$$


- ➔ Priori-„credal set“ enthält *alle finiten konvexen Mischungen* von  $p(\theta)$ s mit  $y^{(0)} \in \mathcal{Y}^{(0)}$  **und**  $n^{(0)} \in \mathcal{N}^{(0)}$
- ➔ Posteriori-„credal set“ immer noch relativ einfach berechenbar: *alle finiten konvexen Mischungen* von  $p(\theta | x)$ s mit

$$\left\{ \left( n^{(1)}, y^{(1)} \right) \mid n^{(1)} = n^{(0)} + n, y^{(1)} = \frac{n^{(0)} y^{(0)} + \tau(x)}{n^{(0)} + n}, n^{(0)} \in \mathcal{N}^{(0)}, y^{(0)} \in \mathcal{Y}^{(0)} \right\}$$




# generalized iLUCK-model: Beispiel $X \sim N(\mu, 1)$


Set of priors:  $y^{(0)} \in [3;4]$  and  $n^{(0)} \in [1;25]$




Set of posteriors:  $y^{(1)} \in [3.29;4]$  and  $n^{(1)} \in [11;35]$







Set of priors:  $y^{(0)} \in [3;4]$  and  $n^{(0)} \in [1;25]$



Set of posteriors:  $y^{(1)} \in [4.43;7.64]$  and  $n^{(1)} \in [11;35]$



## generalized iLUCK-model: Beispiel $X \sim M(\theta)$





# Zusammenfassung

- ▶ iLUCK-models bieten ein allgemeines (Exponentialfamilie!), handhabbares und leistungsfähiges Kalkül für Bayes-Inferenz mit Mengen von Prioris.
  - ➔ *ambiguity* im Priori-Wissen wird explizit ins Modell einbezogen!



# Zusammenfassung

- ▶ iLUCK-models bieten ein allgemeines (Exponentialfamilie!), handhabbares und leistungsfähiges Kalkül für Bayes-Inferenz mit Mengen von Prioris.
  - ➔ *ambiguity* im Priori-Wissen wird explizit ins Modell einbezogen!
- ▶ mit generalized iLUCK-models werden iLUCK-models so erweitert, dass auch *prior-data conflict* berücksichtigt wird.



# Zusammenfassung

- ▶ iLUCK-models bieten ein allgemeines (Exponentialfamilie!), handhabbares und leistungsfähiges Kalkül für Bayes-Inferenz mit Mengen von Prioris.
  - ➔ *ambiguity* im Priori-Wissen wird explizit ins Modell einbezogen!
- ▶ mit generalized iLUCK-models werden iLUCK-models so erweitert, dass auch *prior-data conflict* berücksichtigt wird.



Walter, G. , Augustin, T.: Imprecision and prior-data conflict in generalized Bayesian inference. *Journal of Statistical Theory and Practice*, 2009.