

4. Bayes-Inferenz

Überblick

Exchangeability

Bayes-Inferenz im Schnelldurchlauf

Wiederholung: Modelle mit einem Parameter

Mehr-Parameter-Modelle

Bayesianisches lineares Modell

Bayesianisches generalisiertes lineares Modell

Bayesianische generalisierte lineare gemischte Modelle

Hierarchische Modelle

Konvergenzdiagnostik

Modellwahl und Modellkritik

4.1 Überblick

„Definition“ bayesianischer Inferenz: Anpassen eines Wahrscheinlichkeitsmodells an eine Menge von Daten.

Ergebnis: Wahrscheinlichkeitsverteilung für die Parameter des Modells (und andere unbeobachtete Größen, zum Beispiel Vorhersagen für neue Beobachtungen).

4.1 Überblick

Idealisierter Prozess bayesianischer Datenanalyse:

1. Stelle ein *volles* Wahrscheinlichkeitsmodell oder eine gemeinsame Wahrscheinlichkeitsverteilung für alle beobachtbaren und unbeobachtbaren Größen auf. Dabei ist Wissen über das zugrundeliegende wissenschaftliche Problem und den datengenerierenden Prozess hilfreich.
2. Berechnung der Posterioriverteilung der unbeobachtbaren Größen (Parameter, missing data, ...): bedingte Wahrscheinlichkeitsverteilung der unbeobachtbaren Größen gegeben die beobachteten Daten.
3. Modelldiagnose: Fit, Sensitivität (bezüglich der Annahmen in 1.).

Ergebnis: „kohärentes System“

4.2 Exchangeability

Exchangeability („Austauschbarkeit“) ist ein wichtiges Konzept für die statistische Modellbildung. Es geht auf de Finetti zurück.

Definition 4.1 (Finite Exchangeability)

Die Zufallsvariablen X_1, \dots, X_n heißen *exchangeable*, wenn

(X_1, \dots, X_n) und $(X_{\pi(1)}, \dots, X_{\pi(n)})$ *identisch verteilt sind*

für alle Permutationen

$$\pi : \{1, \dots, n\} \rightarrow \{1, \dots, n\}.$$

Existiert eine Dichte f der gemeinsamen Verteilung, so gilt:

$$f(x_1, \dots, x_n) = f(x_{\pi(1)}, \dots, x_{\pi(n)}).$$

4.2 Exchangeability

Definition 4.2 (Infinite Exchangeability)

Die unendliche Folge X_1, X_2, \dots ist exchangeable, wenn jede endliche Teilfolge exchangeable ist.

Bemerkung.

Analog zu obigen Definitionen kann auch *bedingte Exchangeability* definiert werden, etwa im Regressionsfall für $Y_1|\mathbf{x}_1, \dots, Y_n|\mathbf{x}_n$.

4.2 Exchangeability

Satz 4.3 (Darstellungssatz für 0-1 Zufallsvariablen)

Sei X_1, X_2, \dots eine unendliche Folge binärer Zufallsvariablen, die exchangeable sind, mit zugrundeliegendem Wahrscheinlichkeitsmaß \mathbb{P} .

Dann existiert eine Verteilungsfunktion Q , so dass die gemeinsame Dichte $f(x_1, \dots, x_n)$ folgende Gestalt hat:

$$f(x_1, \dots, x_n) = \int_0^1 \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i} dQ(\theta)$$

mit

$$Q(\theta) = \lim_{n \rightarrow \infty} \mathbb{P} \left(\frac{Y_n}{n} \leq \theta \right)$$

und

$$Y_n = \sum_{i=1}^n X_i$$

4.2 Exchangeability

Interpretation:

1. Bedingt auf θ sind X_1, X_2, \dots unabhängige, identisch verteilte Bernoulli-Zufallsgrößen.
2. θ wird eine Verteilung zugeordnet.
3. Q ist der „Glaube“ („Belief“) über den Grenzwert der relativen Häufigkeit der Einsen.

Konventionelle Schreibweise:

$$f(x_1, \dots, x_n | \theta) = \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i}.$$

4.2 Exchangeability

Satz 4.4

Ist X_1, X_2, \dots eine (unendliche) Folge reellwertiger Zufallsvariablen, die exchangeable sind und zu denen jeweils die benötigten Dichten existieren, dann gilt

$$f(x_1, \dots, x_n) = \int_{\Theta} \prod_{i=1}^n f(x_i | \theta) dQ(\theta).$$

Wir betrachten nun die *a posteriori prädiktive Verteilung* oder *bedingte prädiktive Verteilung* von zukünftigen (unbeobachteten) Daten x_{m+1}, \dots, x_n gegeben die beobachteten Daten x_1, \dots, x_m :

4.2 Exchangeability

$$\begin{aligned}f(x_{m+1}, \dots, x_n | x_1, \dots, x_m) &= \frac{f(x_1, \dots, x_n)}{f(x_1, \dots, x_m)} && \text{(Satz von Bayes)} \\&= \frac{\int_{\Theta} \prod_{i=1}^n f(x_i | \theta) dQ(\theta)}{\int_{\Theta} \prod_{i=1}^m f(x_i | \theta) dQ(\theta)} && \text{(Darstellungssatz)} \\&= \frac{\int_{\Theta} \prod_{i=1}^m f(x_i | \theta) \prod_{i=m+1}^n f(x_i | \theta) dQ(\theta)}{\int_{\Theta} \prod_{i=1}^m f(x_i | \theta) dQ(\theta)} \\&= \int_{\Theta} \prod_{i=m+1}^n f(x_i | \theta) \cdot \frac{\prod_{i=1}^m f(x_i | \theta) dQ(\theta)}{\int_{\Theta} \prod_{i=1}^m f(x_i | \theta) dQ(\theta)}.\end{aligned}$$

4.2 Exchangeability

Dabei ist

$$\frac{\prod_{i=1}^m f(x_i|\theta) dQ(\theta)}{\int_{\Theta} \prod_{i=1}^m f(x_i|\theta) dQ(\theta)} = dQ(\theta|x_1, \dots, x_m)$$

die Posterioriverteilung für θ gegeben Daten x_1, \dots, x_m .

Hier haben wir aus „vergangenen“, beobachteten Daten für zukünftige Beobachtungen gelernt. Eine Erweiterung auf andere Zufallsgrößen ist möglich:

4.2 Exchangeability

Satz 4.5 (Allgemeiner Darstellungssatz)

Sei X_1, X_2, \dots eine unendliche Folge reellwertiger Zufallsvariablen, die exchangeable sind, mit zugrundeliegendem Wahrscheinlichkeitsmaß \mathbb{P} .

Dann existiert ein Wahrscheinlichkeitsmaß Q über \mathcal{F} , dem Raum aller Verteilungsfunktionen F auf \mathbb{R} , so dass

$$\mathbb{P}(X_1 \leq x_1, \dots, X_n \leq x_n) = \int_{\mathcal{F}} \prod_{i=1}^n F(x_i) dQ(F),$$

wobei

$$Q(F) = \lim_{n \rightarrow \infty} \mathbb{P}(F_n),$$

wobei F_n die zu x_1, \dots, x_n gehörende empirische Verteilungsfunktion bezeichnet.

4.2 Exchangeability

Man beachte, dass obige Aussage sich (auch) auf nichtparametrische Inferenz bezieht. So steht $Q(F)$ für eine Prioriverteilung auf dem Raum aller Verteilungsfunktionen.

4.3 Bayes-Inferenz im Schnelldurchlauf

Notation:

- ▶ \mathbf{X} : beobachtete Daten
- ▶ $\tilde{\mathbf{X}}$: unbeobachtete Daten
- ▶ $\boldsymbol{\theta}$: Parameter

Ziel:

- ▶ Wahrscheinlichkeitsaussagen bedingt auf beobachtete Daten
- ▶ Vorhersage / prädiktive Inferenz

Basiskomponenten in der Bayes-Inferenz:

- ▶ $p(\boldsymbol{\theta})$ Prioriverteilung
- ▶ $f(\mathbf{x}|\boldsymbol{\theta})$ Datenverteilung
- ▶ $f(\boldsymbol{\theta}|\mathbf{x})$ Posterioriverteilung
- ▶ $f(\tilde{\mathbf{x}}|\mathbf{x})$ prädiktive Verteilung

4.3 Bayes-Inferenz im Schnelldurchlauf

Nach dem Satz von Bayes ist die gemeinsame Verteilung von $(\boldsymbol{\theta}, \mathbf{x})$ gleich

$$f(\boldsymbol{\theta}, \mathbf{x}) = f(\mathbf{x}|\boldsymbol{\theta}) \cdot p(\boldsymbol{\theta}),$$

deshalb

$$f(\boldsymbol{\theta}|\mathbf{x}) = \frac{f(\boldsymbol{\theta}, \mathbf{x})}{f(\mathbf{x})} = \frac{f(\mathbf{x}|\boldsymbol{\theta})p(\boldsymbol{\theta})}{f(\mathbf{x})},$$

wobei

$$f(\mathbf{x}) = \sum_{\boldsymbol{\theta} \in \Theta} f(\mathbf{x}|\boldsymbol{\theta})p(\boldsymbol{\theta}), \quad \text{falls } \boldsymbol{\theta} \text{ diskret,}$$

$$f(\mathbf{x}) = \int_{\Theta} f(\mathbf{x}|\boldsymbol{\theta})p(\boldsymbol{\theta}) d\boldsymbol{\theta}, \quad \text{falls } \boldsymbol{\theta} \text{ stetig.}$$

4.3 Bayes-Inferenz im Schnelldurchlauf

Unnormalisierte Posteriori:

$$f(\boldsymbol{\theta}|\mathbf{x}) \propto f(\mathbf{x}|\boldsymbol{\theta})p(\boldsymbol{\theta})$$

A priori prädiktive Verteilung (vor Beobachtung der Daten):

$$f(\mathbf{x}) = \int_{\Theta} f(\boldsymbol{\theta}, \mathbf{x}) d\boldsymbol{\theta} = \int_{\Theta} f(\mathbf{x}|\boldsymbol{\theta}) p(\boldsymbol{\theta}) d\boldsymbol{\theta}$$

A posteriori prädiktive Verteilung (nach Beobachtung der Daten \mathbf{x}):

$$\begin{aligned} f(\tilde{\mathbf{x}}|\mathbf{x}) &= \int_{\Theta} f(\tilde{\mathbf{x}}, \boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} = \int_{\Theta} f(\tilde{\mathbf{x}}|\boldsymbol{\theta}, \mathbf{x}) f(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta} \\ &= \int_{\Theta} f(\tilde{\mathbf{x}}|\boldsymbol{\theta}) f(\boldsymbol{\theta}|\mathbf{x}) d\boldsymbol{\theta}, \end{aligned}$$

da $\tilde{\mathbf{x}}$ bedingt unabhängig von \mathbf{x} gegeben $\boldsymbol{\theta}$ ist.

4.3 Bayes-Inferenz im Schnelldurchlauf

Likelihood und Odds Ratios

Die Likelihoodfunktion ist $f(x|\theta)$ als Funktion von θ nach Beobachtung von \mathbf{x} . Die Daten beeinflussen die Posteriori-Inferenz also nur über die Likelihood.

Die Posteriori-Odds von θ_1 verglichen mit θ_2 sind

$$\frac{f_{\theta|\mathbf{x}}(\theta_1|\mathbf{x})}{f_{\theta|\mathbf{x}}(\theta_2|\mathbf{x})} = \frac{\frac{f(\mathbf{x}|\theta_1)f(\theta_1)}{f(\mathbf{x})}}{\frac{f(\mathbf{x}|\theta_2)f(\theta_2)}{f(\mathbf{x})}} = \frac{f(\mathbf{x}|\theta_1)}{f(\mathbf{x}|\theta_2)} \cdot \frac{f(\theta_1)}{f(\theta_2)},$$

es gilt also

Posteriori-Odds = Priori-Odds \times Likelihoodquotient.

4.4 Wiederholung: Modelle mit einem Parameter

- ▶ Gemeint ist: θ ist skalar.
- ▶ Prioriverteilung kann mehr als einen Parameter haben.
- ▶ Hier funktionieren folgende Konzepte gut:
 - ▶ **Konjugierte Prioriverteilungen**
 - ▶ **Referenzpriors/Referenzanalyse:**

4.4 Wiederholung: Modelle mit einem Parameter

- ▶ **Konjugierte Priorverteilungen**, zum Beispiel bei (einparametrischen) Exponentialfamilien.

Vorteil: Analytische Berechenbarkeit, keine Simulation nötig.

Nachteil: Für komplexe Modelle meist nicht verfügbar, deshalb eher als Baustein in komplizierteren Modellen verwendet.

4.4 Wiederholung: Modelle mit einem Parameter

► Referenzprioris/Referenzanalyse:

- *Idee:* Priori so wählen, dass die Daten auch im Fall geringen Stichprobenumfangs die Posterioriverteilung dominieren („let the data speak for themselves“). Dies benötigt entscheidungs- und informationstheoretische Grundlagen.
Suche nach nicht-informativen Prioriverteilungen: Im skalaren Fall zum Beispiel

$$0 < \theta < 1 \rightarrow \psi = \log \left(\frac{\theta}{1 - \theta} \right).$$

- *Jeffreys' Priori*

$$p(\theta) \propto \sqrt{I(\theta)}$$

ist invariant gegenüber bijektiven Transformationen von θ .

4.4 Wiederholung: Modelle mit einem Parameter

Beispiel 4.1 (Binomial- und Negative Binomialverteilung)

1. *Binomialverteilung*: Die Likelihood lautet

$$f(\mathbf{x}|\theta) = \prod_{i=1}^n \theta^{x_i} (1 - \theta)^{1-x_i}.$$

Als Referenzpriori kann Jeffreys' Priori, Beta $(\frac{1}{2}, \frac{1}{2})$, verwendet werden:

$$p(\theta) \propto \theta^{-1/2} (1 - \theta)^{-1/2}.$$

Sei $y = \sum_{i=1}^n x_i$. Dann ist die Referenzposteriori:

$$\begin{aligned} f(\theta|\mathbf{x}) &\propto f(\mathbf{x}|\theta)p(\theta) \\ &\propto \theta^y (1 - \theta)^{n-y} \theta^{-1/2} (1 - \theta)^{-1/2} \\ &= \theta^{y-1/2} (1 - \theta)^{n-y-1/2}. \end{aligned}$$

4.4 Wiederholung: Modelle mit einem Parameter

1. fortgeführt

Dies entspricht dem Kern der Dichte einer Beta $(\frac{1}{2} + y, \frac{1}{2} + n - y)$ -Verteilung. $f(\theta|\mathbf{x})$ ist auch für die Extremfälle $y = 0$ oder $y = n$ noch „proper“.

Verwendet man dagegen Haldane's Priori

$$p(\theta) \propto \theta^{-1}(1 - \theta)^{-1},$$

die eine uneigentliche Priori 'Beta(0,0)' darstellt, ist die Posteriori Beta($y, n - y$) für die Extreme $y = 0$ oder $y = n$ nicht proper.

4.4 Wiederholung: Modelle mit einem Parameter

2. *Negative Binomialverteilung*: Sei X die Anzahl an Versuchen bis $y \geq 1$ Erfolge eintreten. Dann lautet die Likelihood

$$f(x|\theta) \propto \binom{x-1}{y-1} \theta^y (1-\theta)^{x-y} \quad \text{für } x \geq y.$$

Die Referenzpriori ist durch Jeffreys' Priori für die geometrische Verteilung gegeben (das entspricht $y = 1$):

$$p(\theta) \propto \theta^{-1} (1-\theta)^{-1/2},$$

woraus die Referenzposteriori

$$f(\theta|x) \propto \theta^{y-1} (1-\theta)^{x-y-1/2},$$

also eine $\text{Beta}(y, x - y + 1/2)$ -Verteilung, resultiert.

Da $y \geq 1$ und $x \geq y$, ist auch diese a posteriori stets proper.

4.4 Wiederholung: Modelle mit einem Parameter

Bemerkung.

Konzepte für eindimensionale Modelle sind im mehrdimensionalen Fall im Allgemeinen schwierig umzusetzen bzw. umstritten (zum Beispiel Verwendung von Referenzpriors). Man geht daher oft zu sogenannten hierarchischen Modellen über: Füge zusätzliche Stufen in das Modell ein mit dem Ziel, die Posteriori-Analyse stärker von Priori-Annahmen zu entkoppeln.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Wir betrachten in diesem Abschnitt Daten

$x_1, \dots, x_n | \mu, \sigma^2 \stackrel{\text{i.i.d.}}{\sim} N(\mu, \sigma^2)$ mit μ, σ^2 unbekannt.

(i) *Gemeinsame Posterioriverteilung von $\mu, \sigma^2 | \mathbf{x}$:*

$$f(\mu, \sigma^2 | \mathbf{x}) \propto f(\mathbf{x} | \mu, \sigma^2) \cdot p(\mu, \sigma^2)$$

(ii) *Bedingte Posterioriverteilungen von $\mu | \sigma^2, \mathbf{x}$ bzw. $\sigma^2 | \mu, \mathbf{x}$:*

$$f(\mu | \sigma^2, \mathbf{x}) \quad \text{bzw.} \quad f(\sigma^2 | \mu, \mathbf{x})$$

(iii) *Marginale Posterioriverteilung von $\mu | \mathbf{x}$:*

$$f(\mu | \mathbf{x}) = \int f(\mu, \sigma^2 | \mathbf{x}) d\sigma^2 = \int f(\mu | \sigma^2, \mathbf{x}) f(\sigma^2 | \mathbf{x}) d\sigma^2$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

I. Nichtinformative Prioriverteilung

Ist nur einer der beiden Parameter unbekannt, so wählt man oft folgende **Prioriverteilungen** (Jeffreys' Prioris):

$$\begin{aligned}\sigma^2 \text{ bekannt: } & p(\mu) \propto \text{const}, \\ \mu \text{ bekannt: } & p(\sigma^2) \propto (\sigma^2)^{-1}.\end{aligned}$$

Eine Möglichkeit, daraus eine mehrdimensionale Priori zu konstruieren, ist:

$$p(\mu, \sigma^2) = p(\mu) \cdot p(\sigma^2) \propto (\sigma^2)^{-1},$$

d.h. wir nehmen unabhängige Prioris für μ und σ^2 an.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **gemeinsame Posterioriverteilung** $f(\mu, \sigma^2 | \mathbf{x})$ lautet dann:

$$\begin{aligned} f(\mu, \sigma^2 | \mathbf{x}) &\propto \text{Likelihood} \times \text{Priori} \\ &= \left[\prod_{i=1}^n \frac{1}{\sqrt{2\pi}} \sigma^{-1} \exp\left(-\frac{1}{2\sigma^2} (x_i - \mu)^2\right) \right] \cdot (\sigma^2)^{-1} \\ &\propto \sigma^{-n-2} \exp\left(-\frac{1}{2\sigma^2} \sum_{i=1}^n (x_i - \mu)^2\right) \\ &= \sigma^{-n-2} \exp\left(-\frac{1}{2\sigma^2} ((n-1)s^2 + n(\bar{x} - \mu)^2)\right) \end{aligned}$$

mit $s^2 = \sum_{i=1}^n (x_i - \bar{x})^2 / (n-1)$.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **bedingte Posteriori** von μ , $f(\mu|\sigma^2, \mathbf{x})$, kann auf den Fall mit bekannter Varianz σ^2 zurückgeführt werden. Aus Statistik IV ist bekannt, dass $f(\mu|\sigma^2, \mathbf{x}) \sim N(\bar{x}, \sigma^2/n)$.

Für die **marginale Posteriori** $f(\sigma^2|\mathbf{x})$ hat man

$$\begin{aligned} f(\sigma^2|\mathbf{x}) &= \int f(\mu, \sigma^2|\mathbf{x}) d\mu \\ &\propto \int \sigma^{-n-2} \exp\left(-\frac{1}{2\sigma^2} ((n-1)s^2 + n(\bar{x} - \mu)^2)\right) d\mu \\ &\propto \sigma^{-n-2} \exp\left(-\frac{1}{2\sigma^2} (n-1)s^2\right) \int \exp\left(-\frac{1}{2\sigma^2} n(\bar{x} - \mu)^2\right) d\mu \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Es gilt

$$\int \exp\left(-\frac{1}{2\sigma^2}n(\bar{x} - \mu)^2\right) d\mu = \sqrt{2\pi \frac{\sigma^2}{n}}$$

und damit

$$\begin{aligned} f(\sigma^2|\mathbf{x}) &\propto \sigma^{-n-2} \exp\left(-\frac{1}{2\sigma^2}(n-1)s^2\right) \sqrt{2\pi \frac{\sigma^2}{n}} \\ &\propto (\sigma^2)^{-\frac{n-2}{2}} (\sigma^2)^{\frac{1}{2}} \exp\left(-\frac{1}{2\sigma^2}(n-1)s^2\right) \\ &= (\sigma^2)^{-\frac{n+1}{2}} \exp\left(-\frac{1}{2\sigma^2}(n-1)s^2\right). \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Der Kern dieser Dichte gehört zur inversen Gamma-Verteilung mit den Parametern $(n - 1)/2$ und $(n - 1)s^2/2$.

Wegen

$$f(\mu, \sigma^2 | x_1, \dots, x_n) = f(\mu | \sigma^2, x_1, \dots, x_n) \cdot f(\sigma^2 | x_1, \dots, x_n)$$

kann die gemeinsame Posterioriverteilung von $\mu, \sigma^2 | x_1, \dots, x_n$ nun wie folgt simuliert werden:

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Algorithmus 2 : Direkte Simulation der gemeinsamen Posteriori-
verteilung bei nichtinformativer Priori

Wiederhole für $s = 1, \dots, S$:

Schritt 1: Ziehe $(\sigma^2)^{(s)}$ aus $\text{IG}(\frac{n-1}{2}, \frac{n-1}{2} s^2)$.

Schritt 2: Ziehe $(\mu)^{(s)}$ aus $N(\bar{x}, \frac{1}{n}(\sigma^2)^{(s)})$.

Man erhält Paare $[(\mu^{(1)}, (\sigma^2)^{(1)}), \dots, (\mu^{(S)}, (\sigma^2)^{(S)})]$.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

σ^2 als Nuisance-Parameter

Interessiert nur μ , so gibt es (mindestens) zwei Möglichkeiten zur Simulation:

1. Simuliere die gemeinsame Posteriori $f(\mu, \sigma^2 | \mathbf{x})$ gemäß obigem Algorithmus und betrachte nur die Ziehungen $\mu^{(1)}, \dots, \mu^{(S)}$.
2. Berechne direkt die marginale Posteriori $f(\mu | \mathbf{x})$:

$$f(\mu | \mathbf{x}) = \int_0^{\infty} f(\mu, \sigma^2 | \mathbf{x}) d\sigma^2.$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Zu 2. Führt man die Substitution $z = A/(2\sigma^2)$ mit $A = (n-1)s^2 + n(\mu - \bar{x})^2$ durch, so erhält man wegen

$$\sigma^2 = \frac{1}{2}Az^{-1} \quad \text{und} \quad d\sigma^2 = -2A^{-1}\sigma^4 dz = -\frac{1}{2}Az^{-2} dz$$

für $f(\mu|\mathbf{x})$

$$\begin{aligned} \int_0^\infty f(\mu, \sigma^2|\mathbf{x}) d\sigma^2 &\propto \int_0^\infty A^{-\frac{n+2}{2}} z^{\frac{n+2}{2}} \exp(-z) A z^{-2} dz \\ &= \int_0^\infty A^{-\frac{n}{2}} z^{\frac{n-2}{2}} \exp(-z) dz \\ &= A^{-\frac{n}{2}} \int_0^\infty z^{\frac{n-2}{2}} \exp(-z) dz. \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Zu 2. Allgemein gilt für $a > 0$ und $m > -1$:

$$\int_0^{\infty} z^m \exp(-az) dz = \frac{\Gamma(m+1)}{a^{m+1}}.$$

Daraus folgt, dass das Integral konstant bezüglich μ ist und somit

$$\begin{aligned} f(\mu|\mathbf{x}) &\propto A^{-\frac{n}{2}} \\ &= [(n-1)s^2 + n(\mu - \bar{x})^2]^{-\frac{n}{2}} \\ &= \left[1 + \frac{(\mu - \bar{x})^2}{(n-1)s^2/n} \right]^{-\frac{n}{2}} \\ &= \left[1 + \frac{1}{n-1} \left(\frac{\mu - \bar{x}}{\frac{s}{\sqrt{n}}} \right)^2 \right]^{-\frac{n}{2}} \end{aligned}$$

...

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Zu 2. ...

was der Kern einer skalierten nichtzentralen t-Verteilung mit Skalenparameter $m = s/\sqrt{n}$, Lokationsparameter $l = \bar{x}$ und $\nu = n - 1$ Freiheitsgraden ist.

Allgemein hat der Kern der Dichte einer solchen allgemeinen t-Verteilung die Gestalt

$$f(\theta) \propto \left[1 + \frac{1}{\nu} \left(\frac{\theta - l}{m} \right)^2 \right]^{-\frac{\nu+1}{2}} .$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Bemerkung

1. Statt σ^2 lässt sich auch die sogenannte *Präzision* $\kappa = (\sigma^2)^{-1}$ verwenden. Bei Verwendung von $p(\mu, \kappa) \propto (\kappa)^{-1}$ folgt, dass $\kappa|x \sim \text{Gamma}(\frac{n-1}{2}, \frac{n-1}{2}s^2)$.
2. Statt inverser Gammaverteilung wird häufig der Spezialfall einer sogenannten skalierten inversen χ^2 -Verteilung $\text{inv-}\chi^2$ verwendet (siehe unten).

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

II. Konjugierte Prioriverteilung

Verwende gemäß Bemerkung 2 die skalierte inverse $\chi^2(\nu_0, \sigma_0^2)$ -Verteilung als Priori.

Vorteil: Bessere Interpretation (das werden wir allerdings erst dann verstehen, wenn wir informative Prioriverteilungen in Form von (inversen) Gammaverteilungen betrachten).

Nachteil: Diese Vorgehensweise ist „non-standard“.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Zufallszahlen aus einer skalierten inversen χ^2 -Verteilung kann man wie folgt simulieren:

Algorithmus 3 : Simulation von $\theta \sim \text{inv-}\chi^2(\nu_0, \sigma_0^2)$

1. Ziehe $X^* \sim \chi^2(\nu_0)$.
 2. Setze $\theta = \frac{\nu_0 \sigma_0^2}{X^*}$.
-

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Es gilt:

$$\text{inv-}\chi^2(\nu_0, \sigma_0^2) = \text{IG}\left(\frac{\nu_0}{2}, \frac{\nu_0}{2}\sigma_0^2\right).$$

Dies lässt sich mit dem Transformationssatz für Dichten verifizieren: Definiere $\alpha = \nu_0/2$ und $\beta = 1/2$, so dass $X^* \sim \text{Gamma}(\alpha, \beta)$.

Die Umkehrfunktion der Transformation in Schritt 2 lautet

$$X^* = g^{-1}(\theta) = \frac{\nu_0\sigma_0^2}{\theta}$$

und die zugehörige Ableitung nach θ

$$(g^{-1})'(\theta) = -\frac{\nu_0\sigma_0^2}{\theta^2}.$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Man erhält somit:

$$f(\theta) = f_{X^*}(g^{-1}(\theta)) \cdot |(g^{-1})'(\theta)| = \frac{(\beta\nu_0\sigma_0^2)^\alpha}{\Gamma(\alpha)} \theta^{-\alpha-1} \exp(-\beta\nu_0\sigma_0^2/\theta).$$

Dies ist die Dichte einer inversen Gammaverteilung mit Parametern $(\alpha, \beta\nu_0\sigma_0^2)$, welche gerade der gewünschten inversen χ^2 -Verteilung entspricht. Eine mögliche Parametrisierung ist nun

$$p(\mu, \sigma^2) = p(\mu|\sigma^2) \cdot p(\sigma^2)$$

mit

$$\mu|\sigma^2 \sim N\left(\mu_0, \frac{\sigma^2}{\kappa_0}\right) \quad \text{und} \quad \sigma^2 \sim \text{inv-}\chi^2(\nu_0, \sigma_0^2)$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Man schreibt hierfür kurz: $N\text{-inv-}\chi^2\left(\mu_0, \frac{\sigma_0^2}{\kappa_0}; \nu_0, \sigma_0^2\right)$. Die Priors sind nunmehr voneinander abhängig.

Sei nun also a priori $(\mu, \sigma^2) \sim N\text{-inv-}\chi^2\left(\mu_0, \frac{\sigma_0^2}{\kappa_0}; \nu_0, \sigma_0^2\right)$.

Die **Prioridichte** lautet dann

$$\begin{aligned} p(\mu, \sigma^2) &= \frac{1}{\sqrt{2\pi\sigma^2\kappa_0^{-1}}} \exp\left(-\frac{1}{2\frac{\sigma^2}{\kappa_0}}(\mu - \mu_0)^2\right) \\ &\times \frac{\left(\frac{1}{2}\nu_0\sigma_0^2\right)^{\nu_0/2}}{\Gamma(\nu_0/2)} (\sigma^2)^{-\left(\frac{\nu_0}{2}+1\right)} \exp\left(-\frac{1}{2}\frac{\nu_0\sigma_0^2}{\sigma^2}\right) \\ &\propto (\sigma^2)^{-\frac{1}{2}} (\sigma^2)^{-\left(\frac{\nu_0}{2}+1\right)} \exp\left(-\frac{1}{2\sigma^2} [\nu_0\sigma_0^2 + \kappa_0(\mu - \mu_0)^2]\right). \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **gemeinsame Posteriori** bei gegebenen Daten

$\mathbf{x} = (x_1, \dots, x_n)$ aus $N(\mu, \sigma^2)$ ergibt sich zu:

$$f(\mu, \sigma^2 | \mathbf{x}) \propto (\sigma^2)^{-\frac{1}{2}} (\sigma^2)^{-\left(\frac{\nu_0}{2} + 1\right)} \exp\left(-\frac{1}{2\sigma^2} [\nu_0 \sigma_0^2 + \kappa_0 (\mu - \mu_0)^2]\right) \\ \times (\sigma^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2\sigma^2} ((n-1)s^2 + n(\bar{x} - \mu)^2)\right).$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Man kann zeigen (vgl. Übung), dass die Posteriori wieder N-inv- χ^2 -verteilt ist mit Parametern

$$\begin{aligned}\mu_n &= \left(\frac{\kappa_0}{\kappa_0 + n} \right) \mu_0 + \left(\frac{n}{\kappa_0 + n} \right) \bar{x}, \\ \kappa_n &= \kappa_0 + n, \\ \nu_n &= \nu_0 + n, \\ \nu_n \sigma_n^2 &= \nu_0 \sigma_0^2 + (n - 1) s^2 + \frac{\kappa_0 n}{\kappa_0 + n} (\bar{x} - \mu_0)^2.\end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die Interpretation der Parameter ist wie folgt:

- ▶ μ_n ist gewichteter Mittelwert aus Stichprobenmittel und Priori-Erwartungswert. In den Grenzfällen $\kappa_0 \rightarrow \infty$ ist $\mu_n = \mu_0$ bzw. für $n \rightarrow \infty$ ist $\mu_n = \bar{x}$.
- ▶ ν_n sind die Posteriori-Freiheitsgrade als Summe von Priori-Freiheitsgraden und Stichprobenumfang.
- ▶ Die Posteriori-Quadratsumme $\nu_n \sigma_n^2$ lässt sich partitionieren in die Priori-Quadratsumme $\nu_0 \sigma_0^2$, die Quadratsumme $(n - 1)s^2$ der Stichprobe und einen Term, der die Unsicherheit, die durch die Differenz zwischen Stichprobenmittel und Priori-Erwartungswert entsteht, quantifiziert.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **bedingte Posteriori** von $\mu|\sigma^2, \mathbf{x}$ ist

$$\begin{aligned}\mu|\sigma^2, \mathbf{x} &\sim N\left(\mu_n, \frac{\sigma^2}{\kappa_n}\right) \\ &\stackrel{\wedge}{=} N\left(\frac{\kappa_0}{\kappa_0 + n} \mu_0 + \frac{n}{\kappa_0 + n} \bar{x}, \frac{\sigma^2}{\kappa_0 + n}\right) \\ &\stackrel{\wedge}{=} N\left(\frac{\frac{\kappa_0}{\sigma^2} \mu_0 + \frac{n}{\sigma^2} \bar{x}}{\frac{\kappa_0}{\sigma^2} + \frac{n}{\sigma^2}}, \frac{1}{\frac{\kappa_0}{\sigma^2} + \frac{n}{\sigma^2}}\right).\end{aligned}$$

Die Gewichte κ_0/σ^2 und n/σ^2 entsprechen der Priori- bzw. Datenpräzision. Die **marginale Posteriori** von $\sigma^2|\mathbf{x}$ ist

$$\sigma^2|\mathbf{x} \sim \text{inv-}\chi^2(\nu_n, \sigma_n^2).$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Dies ermöglicht die Simulation der gemeinsamen Posteriori Verteilung:

Algorithmus 4 : Direkte Simulation der gemeinsamen Posteriori-
verteilung bei konjugierter Priori

Schritt 1: Ziehe $(\sigma^2)^*$ aus $\text{inv-}\chi^2(\nu_n, \sigma_n^2)$.

Schritt 2: Ziehe μ^* aus $N\left(\mu_n, \frac{(\sigma^2)^*}{\kappa_n}\right)$.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **marginale Posteriori** von $\mu|x$ lautet

$$f(\mu|x) \propto \left[1 + \frac{\kappa_n(\mu - \mu_n)^2}{\nu_n\sigma_n^2} \right]^{-(\nu_n+1)/2}.$$

Dies entspricht einer t-Verteilung mit ν_n Freiheitsgraden, Lokationsparameter μ_n und Skalenparameter σ_n^2/κ_n .

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

III. Semi-konjugierte Prioriverteilung

Die Parameter μ und σ^2 sollen nun a priori unabhängig sein. Wir wählen deshalb **a priori**

$$\mu|\sigma^2 \sim N(\mu_0, \tau_0^2) \quad \text{und} \quad \sigma^2 \sim \text{inv-}\chi^2(\nu_0, \sigma_0^2).$$

Der einzige Unterschied zum Fall der konjugierten Priori ist also, dass wir τ_0^2 statt σ_0^2/κ_0 verwenden und so die Prioris entkoppeln. Es folgt:

$$p(\mu, \sigma^2) = p(\mu|\sigma^2) \cdot p(\sigma^2) \stackrel{\text{Unabhängigkeit}}{=} p(\mu) \cdot p(\sigma^2).$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die resultierende gemeinsame Posteriori hat allerdings keine Form, die einer bekannten Verteilung zugeordnet werden kann.

Allerdings ist $f(\mu|\sigma^2, \mathbf{x})$ explizit berechenbar und $f(\sigma^2|\mathbf{x})$ einfach zu simulieren.

Die **bedingte Posteriori** ist $\mu|\sigma^2, \mathbf{x} \sim N(\mu_n, \tau_n^2)$ mit

$$\mu_n = \frac{\frac{1}{\tau_0^2}\mu_0 + \frac{n}{\sigma^2}\bar{X}}{\frac{1}{\tau_0^2} + \frac{n}{\sigma^2}} \quad \text{und} \quad \tau_n^2 = \frac{1}{\frac{1}{\tau_0^2} + \frac{n}{\sigma^2}}.$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Zur Herleitung der Posteriori $f(\sigma^2|\mathbf{x})$ benutzt man, dass

$$f(\sigma^2|\mathbf{x}) = \frac{f(\mu, \sigma^2|\mathbf{x})}{f(\mu|\sigma^2, \mathbf{x})}$$

und (salopp), dass

$$f(\mu, \sigma^2|\mathbf{x}) \propto N(\mu|\mu_0, \tau_0^2) \times \text{inv-}\chi^2(\sigma^2|\nu_0, \sigma_0^2) \times \prod_{i=1}^n N(x_i|\mu, \sigma^2).$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Die **marginale Posteriori** hat dann die Struktur

$$f(\sigma^2|\mathbf{x}) \propto \frac{N(\mu|\mu_0, \tau_0^2) \cdot \text{inv-}\chi^2(\sigma^2|\nu_0, \sigma_0^2) \cdot \prod_{i=1}^n N(x_i|\mu, \sigma^2)}{N(\mu|\mu_n, \tau_n^2)}.$$

Da $f(\sigma^2|\mathbf{x})$ nicht von μ abhängen kann, können die entsprechenden Terme ignoriert werden, die nur von μ abhängen. Man beachte jedoch, dass der Nenner über die Parameter μ_n, τ_n^2 noch von σ^2 abhängt. Setzen wir $\mu = \mu_n$, so erhalten wir

$$f(\sigma^2|\mathbf{x}) \propto \tau_n \exp\left(-\frac{1}{2\tau_0^2}(\mu_n - \mu_0)^2\right) \cdot \text{inv-}\chi^2(\sigma^2|\nu_0, \sigma_0^2) \\ \cdot \prod_{i=1}^n \frac{1}{\sqrt{2\pi\sigma^2}} \exp\left(-\frac{1}{2\sigma^2}(x_i - \mu_n)^2\right).$$

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Diese Verteilung lässt sich beispielsweise über einen empirischen CDF-Sampler simulieren. Voraussetzung hierfür ist, dass wir die Dichte einer (univariaten) Zufallsvariable bis auf eine Proportionalitätskonstante c kennen.

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Algorithmus 5 : Empirischer CDF-Sampler

- ▶ Diskretisiere den Träger der zu simulierenden Verteilung in eine Menge von N Punkten $x_1 \leq \dots \leq x_N$.
 - ▶ Evaluiere die bis auf Proportionalität bekannte Dichte an $x_1 \leq \dots \leq x_N$, um Werte f_1, \dots, f_N zu erhalten.
 - ▶ Schätze die Proportionalitätskonstante c über $c = f_1 + \dots + f_N$.
 - ▶ Ziehe Zufallszahlen aus $x_1 \leq \dots \leq x_N$ gemäß den Wahrscheinlichkeiten $f_1/c, \dots, f_N/c$.
-

4.5 Mehr-Parameter-Modelle

4.5.1 Normalverteilung

Dies führt zu folgendem Algorithmus zur Simulation aus $f(\mu, \sigma^2 | \mathbf{x})$:

1. Ziehe $(\sigma^2)^*$ aus der marginalen (approximativen) Posteriori gemäß CDF-Sampler.
2. Ziehe μ aus $f(\mu | (\sigma^2)^*, \mathbf{x})$.

Abschließend betrachten wir noch die **prädiktive Posterioriverteilung** für zukünftige Beobachtungen $\tilde{\mathbf{x}}$ gegeben Daten \mathbf{x} . Diese lautet

$$\begin{aligned} f(\tilde{\mathbf{x}} | \mathbf{x}) &= \int \int f(\tilde{\mathbf{x}} | \mu, \sigma^2, \mathbf{x}) f(\mu, \sigma^2 | \mathbf{x}) d\mu d\sigma^2 \\ &= \int \int f(\tilde{\mathbf{x}} | \mu, \sigma^2) f(\mu, \sigma^2 | \mathbf{x}) d\mu d\sigma^2. \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Im *Dirichlet-Multinomial-Modell* wird für die Daten y_1, \dots, y_n eine *Multinomialverteilung* angenommen, also die Verallgemeinerung der Binomialverteilung auf mehr als zwei mögliche Ereignisse bei festem Stichprobenumfang n . Beispielsweise könnte eine fest vorgegebene Anzahl an Personen nach ihrer Parteipräferenz befragt werden.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Eine multinomialverteilte Zufallsvariable Y kann k mögliche Ausprägungen annehmen (zum Beispiel CDU/CSU, SPD, FDP, Grüne, Linke, andere).

Die Zufallsvariable X_j , $1 \leq j \leq k$, bezeichnet die Anzahl der j -ten Ausprägung in der Stichprobe; es gilt $\sum_{j=1}^k X_j = n$. Der Parameter $\theta_j = \mathbb{P}(Y = j) \in [0, 1]$ für $Y \in \{1, \dots, k\}$ mit $\sum_{j=1}^k \theta_j = 1$ bezeichnet die Wahrscheinlichkeit für die Ausprägung j .

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Die Likelihood von $\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^\top$ bei Beobachtungen $\mathbf{x} = (x_1, \dots, x_k)^\top$ lautet

$$L(\boldsymbol{\theta}) = f(\mathbf{x}|\boldsymbol{\theta}) \propto \prod_{j=1}^k \theta_j^{x_j}.$$

Wegen der Restriktion $\sum_{j=1}^k \theta_j = 1$ liegen faktisch nur $k - 1$ Parameter vor, denn der k -te Parameter lässt sich deterministisch durch $\theta_k = 1 - \theta_1 - \dots - \theta_{k-1}$ berechnen. Die Likelihood lässt sich daher auch in der Form

$$L(\boldsymbol{\theta}) \propto \left(\prod_{j=1}^{k-1} \theta_j^{x_j} \right) (1 - \theta_1 - \dots - \theta_{k-1})^{x_k}$$

schreiben.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Die zur Multinomialverteilung konjugierte Verteilung ist die sogenannte *Dirichletverteilung*, eine Verallgemeinerung der Beta-Verteilung, geschrieben

$$\boldsymbol{\theta} = (\theta_1, \dots, \theta_k)^\top \sim \text{Dirichlet}(\alpha_1, \dots, \alpha_k) = D(\boldsymbol{\alpha}),$$

mit Dichtefunktion

$$p(\boldsymbol{\theta}) = \frac{\Gamma(\alpha_1 + \dots + \alpha_k)}{\Gamma(\alpha_1) \cdot \dots \cdot \Gamma(\alpha_k)} \theta_1^{\alpha_1-1} \cdot \dots \cdot \theta_k^{\alpha_k-1},$$

wobei $\alpha_j > 0$ für alle $j = 1, \dots, k$ und wieder $\theta_j \in [0, 1]$ mit $\sum_{j=1}^k \theta_j = 1$. Die Dirichlet-Verteilung spezifiziert also eine Verteilung auf einem $(k - 1)$ -dimensionalen offenen Simplex.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Eigenschaften der Dirichletverteilung:

Definiere $\alpha_0 = \sum_{j=1}^k \alpha_j$.

► Momente:

$$\mathbb{E}(\theta_j) = \frac{\alpha_j}{\alpha_0},$$

$$\text{Var}(\theta_j) = \frac{\alpha_j(\alpha_0 - \alpha_j)}{\alpha_0^2(\alpha_0 + 1)},$$

$$\text{Cov}(\theta_i, \theta_j) = -\frac{\alpha_i \alpha_j}{\alpha_0^2(\alpha_0 + 1)},$$

wobei die Restriktion $\sum_{j=1}^k \theta_j = 1$ die negative Korrelation impliziert.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

- ▶ Modus:

$$\text{Modus}(\boldsymbol{\theta})_j = \frac{\alpha_j - 1}{\alpha_0 - k}$$

ist die j -te Komponente des k -dimensionalen Modus.

- ▶ Jede Randverteilung ist wieder eine Dirichletverteilung, zum Beispiel

$$(\theta_i, \theta_j, 1 - \theta_i - \theta_j) \sim \text{Dirichlet}(\alpha_i, \alpha_j, \alpha_0 - \alpha_i - \alpha_j).$$

Insbesondere ist

$$\theta_j \sim \text{Beta}(\alpha_j, \alpha_0 - \alpha_j).$$

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

- ▶ Die bedingten Verteilungen sind ebenfalls Dirichletverteilt.
Setzt man

$$\theta'_i = \frac{\theta_m}{1 - \sum_{r=1}^{m-1} \theta_r} \quad , \quad m \leq i \leq k,$$

gegeben die Realisationen $\theta_1, \dots, \theta_{m-1}$, so ist

$$(\theta'_m, \dots, \theta'_k)^\top \sim \text{Dirichlet}(\alpha_m, \dots, \alpha_k).$$

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Algorithmus 6 : Simulation aus der Dirichletverteilung

► Simulation 1:

1. Ziehe Z_1, Z_2, \dots, Z_k aus (unabhängigen) Gammaverteilungen mit Parametern $(\alpha_1, 1), \dots, (\alpha_k, 1)$.
2. Setze

$$\theta_j = \frac{Z_j}{\sum_{i=1}^k Z_i} .$$

► Simulation 2 („Stick Breaking Prior“):

1. Ziehe $\theta_1 \sim \text{Beta}(\alpha_1, \alpha_0 - \alpha_1)$.
 2. Für $j = 2, \dots, k - 1$:
 - (i) Ziehe $Z_j \sim \text{Beta}(\alpha_j, \sum_{i=j+1}^k \alpha_i)$.
 - (ii) Setze $\theta_j = \left(1 - \sum_{i=1}^{j-1} \theta_i\right) Z_j$.
 3. Setze $\theta_k = 1 - \sum_{i=1}^{k-1} \theta_i$.
-

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Für $\mathbf{x}|\boldsymbol{\theta} \sim \text{Multinomial}(n; \theta_1, \dots, \theta_k)$ und $\boldsymbol{\theta}|\boldsymbol{\alpha} \sim \text{Dirichlet}(\alpha_1, \dots, \alpha_k)$ lautet die **Posteriorverteilung** von $\boldsymbol{\theta}$:

$$\begin{aligned} f(\boldsymbol{\theta}|\mathbf{x}) &\propto L(\boldsymbol{\theta}) \cdot p(\boldsymbol{\theta}|\boldsymbol{\alpha}) \\ &\propto \prod_{j=1}^k \theta_j^{x_j} \cdot \prod_{j=1}^k \theta_j^{\alpha_j-1} \\ &= \prod_{j=1}^k \theta_j^{x_j+\alpha_j-1}, \end{aligned}$$

d.h. die Posteriori ist Dirichlet($x_1 + \alpha_1, \dots, x_k + \alpha_k$)-verteilt.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Interpretation der Posteriori

Der Posteriori-Erwartungswert

$$\mathbb{E}[\theta_j | \mathbf{x}] = \frac{x_j + \alpha_j}{\sum_{i=1}^k x_i + \sum_{i=1}^k \alpha_i} = \frac{x_j + \alpha_j}{n + \alpha_0}$$

lässt sich umschreiben zu

$$\mathbb{E}[\theta_j | \mathbf{x}] = \frac{\alpha_0}{\alpha_0 + n} \cdot \underbrace{\frac{\alpha_j}{\alpha_0}}_{\text{Priori-Erwartungswert}} + \frac{n}{\alpha_0 + n} \cdot \underbrace{\frac{x_j}{n}}_{\text{MLE}}$$

Der Parameter α_0 lässt sich als „a priori Anzahl Beobachtungen“ und α_j als „a priori Erfolge“ für Kategorie j interpretieren.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Bemerkung.

1. Die Wahl $\alpha_1 = \dots = \alpha_k = 0$ entspricht einer Gleichverteilung für $\{\log \theta_j\}_{j=1}^k$. In diesem Fall ist die Posteriori nur dann proper, wenn $x_j \geq 1$, $j = 1, \dots, p$.
2. Die Wahl $\alpha_1 = \dots = \alpha_k = 1/2$ entspricht Jeffreys' Priori.
3. Die Wahl $\alpha_1 = \dots = \alpha_k = 1$ entspricht einer Priori-Gleichverteilung auf dem Simplex.

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

Bemerkung.

Die Dirichlet-Verteilung eignet sich auch als Priori bei der Analyse von Kontingenztafeln mit multinomialem Erhebungsschema:

x_1	x_2
x_3	x_4

($n = x_1 + x_2 + x_3 + x_4$). Erweiterungen auf restringierte Multinomialverteilungen sind möglich (loglineare Modelle).

...

4.5 Mehr-Parameter-Modelle

4.5.2 Dirichlet-Multinomial Modell

...

Ad-hoc Prozedur: Addiere $1/2$ zu jedem Eintrag der Kontingenztabelle und berechne dann den Maximum-Likelihood-Schätzer; das entspricht

$\alpha_1 = \dots = \alpha_k = 3/2$ und der Posteriori-Modus Schätzung

$$\begin{aligned}\text{Modus}(\boldsymbol{\theta}|\mathbf{x})_j &= \frac{x_j + \alpha_j - 1}{\sum_{i=1}^k x_i + \sum_{i=1}^k \alpha_i - k} \\ &= \frac{x_j + \frac{1}{2}}{\sum_{i=1}^k x_i + \frac{1}{2}k} .\end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Notation:

- ▶ $\mathbf{X} = (X_1, \dots, X_p)^\top$ ist p -dimensionaler Zufallsvektor.
- ▶ $\boldsymbol{\mu} = (\mu_1, \dots, \mu_p)$ ist p -dimensionaler Erwartungswertvektor.
- ▶ Die symmetrische und positiv definite (Notation: $\boldsymbol{\Sigma} > 0$) Matrix

$$\boldsymbol{\Sigma} = \begin{pmatrix} \sigma_{11} & \sigma_{12} & \dots & \sigma_{1p} \\ \sigma_{21} & \sigma_{22} & \dots & \sigma_{2p} \\ \vdots & \vdots & \ddots & \vdots \\ \sigma_{p1} & \sigma_{p2} & \dots & \sigma_{pp} \end{pmatrix}$$

ist $p \times p$ -dimensionale Kovarianzmatrix.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

- ▶ Eine Beobachtung $\mathbf{x} = (x_1, \dots, x_p)^\top$ ist $\text{MVN}(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ (multivariat normalverteilt), wenn

$$f(\mathbf{x}|\boldsymbol{\mu}, \boldsymbol{\Sigma}) \propto |\boldsymbol{\Sigma}|^{-1/2} \exp\left(-\frac{1}{2}(\mathbf{x} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1}(\mathbf{x} - \boldsymbol{\mu})\right).$$

- ▶ Die Likelihood für n i.i.d. Realisationen $\mathbf{x}_1, \dots, \mathbf{x}_n$ lautet

$$\begin{aligned} L(\boldsymbol{\mu}, \boldsymbol{\Sigma}) &= f(\mathbf{x}_1, \dots, \mathbf{x}_n | \boldsymbol{\mu}, \boldsymbol{\Sigma}) \\ &\propto |\boldsymbol{\Sigma}|^{-n/2} \exp\left(-\frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu})\right) \\ &= |\boldsymbol{\Sigma}|^{-n/2} \exp\left(-\frac{1}{2} \text{tr}(\boldsymbol{\Sigma}^{-1} \mathbf{S}_0)\right) \end{aligned}$$

mit $\mathbf{S}_0 = \sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})(\mathbf{x}_i - \boldsymbol{\mu})^\top$.

...

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

► ...

Die zweite Identität ergibt sich über die Umformungen

$$\begin{aligned}\sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) &= \operatorname{tr} \left(\sum_{i=1}^n (\mathbf{x}_i - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) \right) \\ &= \operatorname{tr} \left(\sum_{i=1}^n \boldsymbol{\Sigma}^{-1} (\mathbf{x}_i - \boldsymbol{\mu}) (\mathbf{x}_i - \boldsymbol{\mu})^\top \right) \\ &= \operatorname{tr}(\boldsymbol{\Sigma}^{-1} \mathbf{S}_0).\end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

I. Konjugierte Prioriverteilung bei unbekanntem μ und bekanntem Σ

Konjugierte **Prioriverteilung** für μ bei bekanntem Σ ist

$$\mu \sim \text{MVN}(\mu_0, \Lambda_0)$$

mit $\Lambda_0 > 0$.

Die **Posteriori** für μ ist

$$f(\mu | \mathbf{x}, \Sigma) \propto \exp \left(-\frac{1}{2}(\mu - \mu_0)^\top \Lambda_0^{-1}(\mu - \mu_0) - \frac{1}{2} \sum_{i=1}^n (\mathbf{x}_i - \mu)^\top \Sigma^{-1}(\mathbf{x}_i - \mu) \right)$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Der Term im Exponenten ist eine quadratische Form in $\boldsymbol{\mu}$, die sich über eine quadratische Ergänzung und Vernachlässigung von Konstanten ergibt. Man erhält

$$f(\boldsymbol{\mu}|\mathbf{x}, \boldsymbol{\Sigma}) \sim \text{MVN}(\boldsymbol{\mu}_n, \boldsymbol{\Lambda}_n)$$

mit

$$\begin{aligned}\boldsymbol{\mu}_n &= (\boldsymbol{\Lambda}_0^{-1} + n\boldsymbol{\Sigma}^{-1})^{-1} (\boldsymbol{\Lambda}_0^{-1}\boldsymbol{\mu}_0 + n\boldsymbol{\Sigma}^{-1}\bar{\mathbf{x}}), \\ \boldsymbol{\Lambda}_n^{-1} &= \boldsymbol{\Lambda}_0^{-1} + n\boldsymbol{\Sigma}^{-1}\end{aligned}$$

und $\bar{\mathbf{x}} = (\sum_{i=1}^n \mathbf{x}_i)/n$ in Analogie zum univariaten Fall.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Die **bedingte** und **marginale Posteriori** für *Subvektoren* von μ folgen aus den Eigenschaften der multivariaten Normalverteilung: Betrachte die Partitionierungen

$$\mu = \begin{pmatrix} \mu^{(1)} \\ \mu^{(2)} \end{pmatrix}, \quad \mu_n = \begin{pmatrix} \mu_n^{(1)} \\ \mu_n^{(2)} \end{pmatrix}, \quad \Lambda_n = \begin{pmatrix} \Lambda_n^{(11)} & \Lambda_n^{(12)} \\ \Lambda_n^{(21)} & \Lambda_n^{(22)} \end{pmatrix}.$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Dann gilt für die bedingten Verteilungen

$$\boldsymbol{\mu}^{(1)} | \boldsymbol{\mu}^{(2)}, \mathbf{x} \sim \text{MVN} \left(\boldsymbol{\mu}_n^{(1)} + \boldsymbol{\beta}^{1|2} \left(\boldsymbol{\mu}^{(2)} - \boldsymbol{\mu}_n^{(2)} \right), \boldsymbol{\Lambda}_n^{1|2} \right)$$

mit

$$\begin{aligned} \boldsymbol{\beta}^{1|2} &= \boldsymbol{\Lambda}_n^{(12)} \left(\boldsymbol{\Lambda}_n^{(22)} \right)^{-1}, \\ \boldsymbol{\Lambda}^{1|2} &= \boldsymbol{\Lambda}_n^{(11)} - \boldsymbol{\Lambda}_n^{(12)} \left(\boldsymbol{\Lambda}_n^{(22)} \right)^{-1} \boldsymbol{\Lambda}_n^{(21)} \end{aligned}$$

und für die marginalen Verteilungen

$$\boldsymbol{\mu}^{(1)} \sim \text{MVN} \left(\boldsymbol{\mu}_n^{(1)}, \boldsymbol{\Lambda}_n^{(11)} \right).$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Die **prädiktive Posterioriverteilung** ist (informell)

$$f(\tilde{\mathbf{x}}, \boldsymbol{\mu} | \mathbf{x}) = \text{MVN}(\tilde{\mathbf{x}} | \boldsymbol{\mu}, \boldsymbol{\Sigma}) \cdot \text{MVN}(\boldsymbol{\mu} | \boldsymbol{\mu}_n, \boldsymbol{\Lambda}_n).$$

Im Exponenten erhält man eine quadratische Form in $(\tilde{\mathbf{x}}, \boldsymbol{\mu})$. $(\tilde{\mathbf{x}}, \boldsymbol{\mu})$ sind gemeinsam multivariat normalverteilt, und daher folgt $\tilde{\mathbf{x}}$ als Randverteilung der beiden Komponenten ebenfalls einer multivariaten Normalverteilung. Die erforderlichen Kenngrößen lassen sich über die iterierte Erwartung und Varianz berechnen:

$$\mathbb{E}[\tilde{\mathbf{x}} | \mathbf{x}] = \mathbb{E}[\mathbb{E}[\tilde{\mathbf{x}} | \boldsymbol{\mu}, \mathbf{x}] | \mathbf{x}] = \mathbb{E}[\boldsymbol{\mu} | \mathbf{x}] = \boldsymbol{\mu}_n$$

und

$$\begin{aligned} \text{Var}(\tilde{\mathbf{x}} | \mathbf{x}) &= \mathbb{E}[\text{Var}(\tilde{\mathbf{x}} | \boldsymbol{\mu}, \mathbf{x}) | \mathbf{x}] + \text{Var}[\mathbb{E}(\tilde{\mathbf{x}} | \boldsymbol{\mu}, \mathbf{x}) | \mathbf{x}] \\ &= \mathbb{E}[\boldsymbol{\Sigma} | \mathbf{x}] + \text{Var}[\boldsymbol{\mu} | \mathbf{x}] \\ &= \boldsymbol{\Sigma} + \boldsymbol{\Lambda}_n. \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

II. Konjugierte Priorverteilung bei unbekanntem μ und unbekanntem Σ

In Abschnitt 4.5.1-II (Folie 409) hatten wir als konjugierte Priorverteilungen für die Parameter μ und σ^2 der univariaten Normalverteilung

$$\mu|\sigma^2 \sim N\left(\mu_0, \frac{\sigma^2}{\kappa_0}\right) \quad \text{und} \quad \sigma^2 \sim \text{inv-}\chi^2(\nu_0, \sigma_0^2),$$

kurz

$$\mu, \sigma^2 \sim \text{N-inv-}\chi^2\left(\mu_0, \frac{\sigma_0^2}{\kappa_0}; \nu_0, \sigma_0^2\right),$$

verwendet.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Hier nun verwenden wir die multivariaten Analoga

$$\boldsymbol{\mu} | \boldsymbol{\Sigma} \sim \text{MVN} \left(\boldsymbol{\mu}_0, \frac{1}{\kappa_0} \boldsymbol{\Sigma} \right) \quad \text{und} \quad \boldsymbol{\Sigma} \sim \text{inv-Wishart}_{\nu_0}(\boldsymbol{\Lambda}_0^{-1}),$$

kurz

$$\boldsymbol{\mu}, \boldsymbol{\Sigma} \sim \text{MVN-inv-Wishart} \left(\boldsymbol{\mu}_0, \frac{1}{\kappa_0} \boldsymbol{\Lambda}_0; \nu_0, \boldsymbol{\Lambda}_0 \right).$$

Die **gemeinsame Prioridichte** ist dann

$$\begin{aligned} p(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \propto & |\boldsymbol{\Sigma}|^{-\left(\frac{\nu_0+p}{2}+1\right)} \\ & \cdot \exp \left(-\frac{1}{2} \left(\text{tr}(\boldsymbol{\Lambda}_0 \boldsymbol{\Sigma}^{-1}) - \kappa_0 (\boldsymbol{\mu} - \boldsymbol{\mu}_0)^\top \boldsymbol{\Sigma}^{-1} (\boldsymbol{\mu} - \boldsymbol{\mu}_0) \right) \right). \end{aligned}$$

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Dabei bezeichnet ν_0 die a priori Anzahl der Freiheitsgrade, κ_0 die a priori Anzahl an Messungen auf der Σ -Skala. Die **gemeinsame Posterioriverteilung** von μ und Σ lautet

$$\mu, \Sigma | \mathbf{x} \sim \text{MVN-inv-Wishart} \left(\mu_n, \frac{1}{\kappa_n} \mathbf{\Lambda}_n; \nu_n, \mathbf{\Lambda}_n \right).$$

mit

$$\begin{aligned} \mu_n &= \frac{\kappa_0}{\kappa_0 + n} \mu_0 + \frac{n}{\kappa_0 + n} \bar{\mathbf{x}}, \\ \kappa_n &= \kappa_0 + n, \\ \nu_n &= \nu_0 + n, \\ \mathbf{\Lambda}_n &= \mathbf{\Lambda}_0 + \mathbf{S} + \frac{\kappa_0 n}{\kappa_0 + n} (\bar{\mathbf{x}} - \mu_0)(\bar{\mathbf{x}} - \mu_0)^\top, \end{aligned}$$

wobei $\mathbf{S} = \sum_{i=1}^n (\mathbf{x}_i - \bar{\mathbf{x}})(\mathbf{x}_i - \bar{\mathbf{x}})^\top$ in Analogie zum univariaten Fall.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Die Interpretation der Parameter von Folie 416 lässt sich direkt übertragen: Der Posteriori-Erwartungswert ist ein gewichtetes Mittel aus Stichprobenmittelwertvektor und Priori-Erwartungswert. Die Gesamtstreuungsmatrix $\mathbf{\Lambda}_n$ lässt sich in Priori-Streuungsmatrix, empirische Streuungsmatrix und Streuung zwischen Priori-Erwartungswert und Stichprobenmittel partitionieren.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Die **marginale Posteriori** für μ folgt einer multivariaten t-Verteilung mit Parametern μ_n und $\mathbf{\Lambda}_n / (\kappa_n \cdot (\nu_n - p + 1))$, die marginale Posteriori für Σ einer inversen Wishart-Verteilung mit Parametern ν_n und $\mathbf{\Lambda}_n^{-1}$. Zur Simulation aus der gemeinsamen Posteriori oder aus der prädiktiven Verteilung ist folgender Algorithmus anwendbar:

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Algorithmus 7 : Simulation aus der gemeinsamen Posteriori und der prädiktiven Verteilung bei konjugierter Priori

Für $s = 1, \dots, S$:

1. Ziehe $\boldsymbol{\Sigma}^{(s)} | \mathbf{x} \sim \text{inv-Wishart}_{\nu_n}(\boldsymbol{\Lambda}_n^{-1})$.
2. Ziehe $\boldsymbol{\mu}^{(s)} | \boldsymbol{\Sigma}^{(s)}, \mathbf{x} \sim \text{MVN}\left(\boldsymbol{\mu}_n, \frac{1}{\kappa_n} \boldsymbol{\Sigma}^{(s)}\right)$.
3. Ziehe $\tilde{\mathbf{x}}^{(s)} | \boldsymbol{\mu}^{(s)}, \boldsymbol{\Sigma}^{(s)}, \mathbf{x} \sim \text{MVN}\left(\boldsymbol{\mu}^{(s)}, \boldsymbol{\Sigma}^{(s)}\right)$.

Dann ist $(\boldsymbol{\mu}^{(s)}, \boldsymbol{\Sigma}^{(s)})$ eine Ziehung aus der gemeinsamen Posterioridichte, $\tilde{\mathbf{x}}$ eine Ziehung aus der prädiktiven Verteilung.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

III. Nichtinformative Prioriverteilung bei unbekanntem μ und unbekanntem Σ

Als nichtinformative Prioriverteilung bei unbekanntem μ und Σ eignet sich die multivariate Jeffreys' Priori

$$p(\mu, \Sigma) \propto |\Sigma|^{-(p+1)/2}.$$

Diese entspricht dem Grenzfall $\kappa_0 \rightarrow 0, \nu_0 \rightarrow 1, |\Lambda_0| \rightarrow 0$ bei der konjugierten Priori. Für die Posteriori-Kenngrößen ergibt sich in diesem Fall für die **bedingte Verteilung** von μ

$$\mu | \Sigma, \mathbf{x} \sim \text{MVN} \left(\bar{\mathbf{x}}, \frac{1}{n} \Sigma \right),$$

...

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

...

und für die **marginalen Verteilungen**

$$\begin{aligned}\boldsymbol{\Sigma}|\mathbf{x} &\sim \text{inv-Wishart}_{n-1}(\mathbf{S}), \\ \boldsymbol{\mu}|\mathbf{x} &\sim \text{mv-t}_{n-p}\left(\bar{\mathbf{x}}, \frac{1}{n(n-p)}\mathbf{S}\right).\end{aligned}$$

Als Beispiel wird im Folgenden die bivariate Normalverteilung betrachtet. Es dient auch dazu, die folgende für die Bayes-Inferenz wichtige Simulationsstrategie, das sogenannte Gibbs-Sampling, zu illustrieren.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Algorithmus 8 : Gibbs-Sampler

Gegeben: Ein mehrdimensionaler stetiger Zufallsvektor \mathbf{X} mit Verteilung π . Der Einfachheit halber seien alle Komponenten von \mathbf{X} stetig.

Wir erzeugen im Folgenden eine Markovkette $\mathbf{X}^{(0)}, \mathbf{X}^{(1)}, \dots$ mit Startwert $\mathbf{X}^{(0)}$ und stationärer Verteilung π . Sei $\mathbf{X}^{(t)}$ der aktuelle Zustand der Markovkette. $\mathbf{X}^{(t)}$ lasse sich in k Subvektoren $\mathbf{X}^{(t)} = (\mathbf{X}_{\bullet 1}^{(t)}, \mathbf{X}_{\bullet 2}^{(t)}, \dots, \mathbf{X}_{\bullet k}^{(t)})$ partitionieren. Definiere

$$\mathbf{X}_{-s}^{(t)} = \left(\mathbf{X}_{\bullet 1}^{(t)}, \mathbf{X}_{\bullet 2}^{(t)}, \dots, \mathbf{X}_{\bullet (s-1)}^{(t)}, \mathbf{X}_{\bullet (s+1)}^{(t-1)}, \dots, \mathbf{X}_{\bullet k}^{(t-1)} \right)$$

für $s = 1, \dots, k$.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Algorithmus 8 : Gibbs-Sampler fortgeführt

Ferner seien die *vollständig bedingten Verteilungen* („full conditionals“)

$$\pi_{\bullet s| -s}^{(t)} = \pi \left(\mathbf{x}_{\bullet s}^{(t)} \mid \mathbf{x}_{-s}^{(t)} \right) = \frac{\pi \left(\mathbf{x}_{\bullet s}^{(t)}, \mathbf{x}_{-s}^{(t)} \right)}{\int \pi \left(\mathbf{x}_{\bullet s}^{(t)}, \mathbf{x}_{-s}^{(t)} \right) d\mathbf{x}_{\bullet s}^{(t)}}$$

gegeben und simulierbar.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Algorithmus 8 : Gibbs-Sampler fortgeführt

Dann wird der nächste Zustand $\mathbf{X}^{(t+1)}$ komponentenweise wie folgt erzeugt:

Schritt 1: Ziehe $\mathbf{X}_{\bullet 1}^{(t+1)} \sim \pi_{\bullet 1|-1}^{(t+1)}$.

Schritt 2: Ziehe $\mathbf{X}_{\bullet 2}^{(t+1)} \sim \pi_{\bullet 2|-2}^{(t+1)}$.

⋮

Schritt k: Ziehe $\mathbf{X}_{\bullet k}^{(t+1)} \sim \pi_{\bullet k|-k}^{(t+1)}$.

Wiederhole diese Schritte ausreichend oft.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Nach einer gewissen Zahl von Wiederholungen kann $\mathbf{X}^{(t)}$ als Ziehung aus π angesehen werden. Im Gegensatz zu obigen „direkten“ Simulationsalgorithmen liegen nun allerdings abhängige Realisationen vor.

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Beispiel 4.2. (Bivariate Normalverteilung)

Sei \mathbf{X} bivariat normalverteilt mit Erwartungswertvektor $(\mu_1, \mu_2)^\top$ und Kovarianzmatrix

$$\begin{pmatrix} \sigma_1^2 & \sigma_{12} \\ \sigma_{12} & \sigma_2^2 \end{pmatrix} = \begin{pmatrix} \sigma_1^2 & \rho \\ \rho & \sigma_2^2 \end{pmatrix} = \begin{pmatrix} 1 & \rho \\ \rho & 1 \end{pmatrix} \text{ und } \rho \text{ bekannt.}$$

Bei einer nichtinformativen Priori $p(\mu_1, \mu_2) \propto \text{const}$ für μ_1, μ_2 reduziert sich die Posteriori auf die Likelihood bei gegebenen Daten $\mathbf{x} = ((x_{11}, x_{12})^\top, \dots, (x_{n1}, x_{n2})^\top)$:

$$L(\mu_1, \mu_2) = \left(\frac{1}{2\pi}\right)^n (1 - \rho^2)^{-\frac{n}{2}} \exp\left(-\frac{1}{2(1 - \rho^2)} A\right),$$

wobei

$$A = \sum_{i=1}^n [(x_{i1} - \mu_1)^2 - 2\rho(x_{i1} - \mu_1)(x_{i2} - \mu_2) + (x_{i2} - \mu_2)^2]$$

...

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

...

Wir möchten nun die vollständig bedingten Verteilungen $\mu_1|\mu_2, \mathbf{x}$ und $\mu_2|\mu_1, \mathbf{x}$ berechnen. Natürlich ist es aus Symmetriegründen ausreichend, nur $\mu_1|\mu_2, \mathbf{x}$ zu ermitteln. Wegen

$$f(\mu_1|\mu_2, \mathbf{x}) = \frac{f(\mu_1, \mu_2|\mathbf{x})}{f(\mu_2|\mathbf{x})} = \frac{f(\mu_1, \mu_2, \mathbf{x})}{f(\mu_2, \mathbf{x})} \propto f(\mu_1, \mu_2|\mathbf{x})$$

genügt es, aus der gemeinsamen Posteriori lediglich die Terme zu betrachten, die von der jeweiligen Variablen in der bedingten Verteilung abhängen. Man erhält dann

$$f(\mu_1|\mu_2, \mathbf{x}) \propto \exp\left(-\frac{1}{2(1-\rho^2)} n [\mu_1^2 - 2\mu_1(\bar{x}_1 + \rho(\mu_2 - \bar{x}_2))]\right)$$

mit $\bar{x}_j = (\sum_{i=1}^n x_{ij})/n$ für $j = 1, 2$.

...

4.5 Mehr-Parameter-Modelle

4.5.3 Multivariate Normalverteilung

Eine quadratische Ergänzung des Terms in eckigen Klammern um $\bar{x}_1 + \rho(\mu_2 - \bar{x}_2)$ liefert schließlich das Endresultat

$$p(\mu_1 | \mu_2, \mathbf{x}) \propto \exp \left(-\frac{1}{2 \frac{1-\rho^2}{n}} \left(\mu_1 - [\bar{x}_1 + \rho(\mu_2 - \bar{x}_2)] \right)^2 \right).$$

Dies entspricht dem Kern einer $N(\bar{x}_1 + \rho(\mu_2 - \bar{x}_2), (1 - \rho^2)/n)$ -Verteilung. Der zugehörige Gibbs-Sampler hat die Gestalt:

1. Wähle einen Startwert $\mu_2^{(0)}$.
2. Für $s = 1, \dots, S$:
 - (a) Ziehe $\mu_1^{(s)} | \mu_2^{(s-1)} \sim N \left(\bar{x}_1 + \rho \left(\mu_2^{(s-1)} - \bar{x}_2 \right), \frac{1-\rho^2}{n} \right)$.
 - (b) Ziehe $\mu_2^{(s)} | \mu_1^{(s)} \sim N \left(\bar{x}_2 + \rho \left(\mu_1^{(s)} - \bar{x}_1 \right), \frac{1-\rho^2}{n} \right)$.