

Seminar in Statistik - FS 2008

# Nonparametric Bayes

*Handout verfasst von*  
**Ivo Francioni und Philippe Muller**

Zürich, 17. März 2008

## 1 Einleitung

Bis jetzt haben wir in der Bayes'schen Statistik immer mit einem endlich-dimensionalen Parameterraum  $\Theta$  gearbeitet. Nun aber betrachten wir nicht-parametrische Probleme, d.h.

$$\Theta = \{\text{Wahrscheinlichkeitsmasse auf dem messbaren Raum } (H, \mathcal{A})\} =: \mathcal{P}.$$

$\Theta$  ist also unendlichdimensional.

Wir wollen nun in einem ersten Teil eine a priori Verteilung auf dem  $\infty$ -dimensionalen Raum  $(\mathcal{P}, \mathcal{C})$  definieren, die sich besonders gut eignet um die a posteriori Verteilung für gegebene Daten zu bestimmen. Hierbei ist  $\mathcal{C}$  die kleinste  $\sigma$ -Algebra, die von den Mengen der Form  $\{P : P(A) < r\}$  erzeugt wird, wobei  $A \in \mathcal{B}$  und  $r \in [0, 1]$ .

In einem zweiten Teil werden wir die Nützlichkeit dieser a priori Verteilung anhand von einigen Beispielen demonstrieren.

## 2 Der Dirichlet-Prozess, hilfreich bei nicht-parametrischen Problemen

### 2.1 Random probability measures (RPM)

Es sei  $(\Omega, \mathcal{F}, \mathbb{P})$  ein Wahrscheinlichkeitsraum. Durch eine  $\mathbb{R}^k$ -wertige ZV auf  $\Omega$  wird ein eindeutiges Wahrscheinlichkeitsmass auf  $(\mathbb{R}^k, \mathcal{B}(\mathbb{R}^k))$  festgelegt. Den gleichen Zusammenhang gibt es auch hier, in unserer Situation, zwischen einem Wahrscheinlichkeitsmass auf  $(\mathcal{P}, \mathcal{C})$  und einer Mass-wertigen ZV'n. Diese masswertigen ZV'n nennen wir „random probability measures“.

Unser Ziel ist es ein passendes RPM zu finden:

$$P : \Omega \rightarrow \mathcal{P}, \omega \mapsto P_\omega$$

mit  $P(A) : \Omega \rightarrow \mathbb{R}, \omega \mapsto P_\omega(A)$   $\mathcal{F}$ - $\mathcal{B}(\mathbb{R})$ -messbar  $\forall A \in \mathcal{A}$ .

### 2.2 Der Dirichlet-Prozess

Das für unsere Zwecke am besten geeignete RPM ist der Dirichlet-Prozess.

**Definition 2.2.1** Sei  $(H, \mathcal{A})$  ein messbarer Raum und  $\alpha$  ein endliches Mass auf  $(H, \mathcal{A})$ , das ungleich Null ist. Dann ist ein Dirichlet-Prozess  $P$  auf  $(H, \mathcal{A})$  mit Parameter  $\alpha$  ein RPM auf  $(H, \mathcal{A})$  s.d. für alle Partitionen  $H = \bigcup_{i=1}^k A_i$

$(A_i \in \mathcal{A})$  von  $H$  gilt: Der Zufallsvektor  $\omega \mapsto (P_\omega(A_1), P_\omega(A_2), \dots, P_\omega(A_k))$  hat Dirichlet-Verteilung mit Parameter  $(\alpha(A_1), \alpha(A_2), \dots, \alpha(A_k))$ .

**Definition 2.2.2** Sei:

- $(\alpha_1, \alpha_2, \dots, \alpha_k)$  ein Vektor mit  $\alpha_j \geq 0 \forall j$  und  $\sum \alpha_j > 0$ .
- $z_{\alpha_j}$ ,  $j = 1, 2, \dots, k$  unabhängige  $\mathcal{G}(\alpha_j, 1)$ -verteilte ZV'n.
- $z = \sum z_{\alpha_j}$  und  $y_j = \frac{z_{\alpha_j}}{z}$  für  $j = 1, 2, \dots, k$ .

Dann ist die  $k$ -dimensionale Dirichlet-Verteilung mit Parametern  $\alpha_1, \alpha_2, \dots, \alpha_k$  (Notation:  $\mathcal{D}(\alpha_1, \alpha_2, \dots, \alpha_k)$ ) definiert als die gemeinsame Verteilung des Zufallsvektors  $(y_1, y_2, \dots, y_k)$ , der Werte im  $k$ -dimensionalen Simplex  $\Delta_k$  annimmt.

**Bemerkung 2.2.3** Falls  $X = (X_1, X_2, \dots, X_k) \sim \mathcal{D}(\alpha_1, \dots, \alpha_k)$ , dann sind die Randverteilungen gegeben durch:  $X_i \sim \text{Beta}(\alpha_i, \sum_{j=1}^k \alpha_j - \alpha_i)$ .

Der Dirichlet-Prozess gibt uns ein Wahrscheinlichkeitsmass auf  $(\mathcal{P}, \mathcal{C})$ . Wir werden nun zwei mögliche Konstruktionen dieses Prozesses kurz erläutern. Sei dafür  $\alpha$  ein endliches Mass auf  $(H, \mathcal{A})$ , das ungleich Null ist.

**Erste Konstruktion:** Axiomatisch (nach Thomas Ferguson)

Lege für jedes  $n \in \mathbb{N}$  und jede Partition  $A_1, A_2, \dots, A_n$  von  $H$  die gemeinsame Verteilung  $(P(A_1), P(A_2), \dots, P(A_n)) \sim \mathcal{D}(\alpha(A_1), \alpha(A_2), \dots, \alpha(A_n))$  fest. Mit dem Konsistenzsatz von Kolmogorov kann man so ein eindeutiges Wahrscheinlichkeitsmass auf  $[0, 1]^{\mathcal{A}}$  bestimmen.

**Zweite Konstruktion:** „Stick-breaking Construction“ (nach Jayaram Sethuraman)

$\forall A \in \mathcal{A}$ , setze  $P(A) = \sum_{i=1}^{\infty} p_i \delta_{Y_i}(A)$ , mit

$$Y_i : \Omega \rightarrow H \text{ iid } \sim \frac{\alpha(\cdot)}{\alpha(H)} \quad \text{und}$$

$$p_i = U_i \cdot \prod_{j=1}^{i-1} (1 - U_j), \quad U_j \text{ iid } \sim \text{Beta}(1, \alpha(H)).$$

Man kann zeigen, dass das so konstruierte RPM ein Dirichlet-Prozess ist.

Jetzt kommen wir zum wichtigsten Resultat dieses Vortrags:

**Satz 2.2.4** *Es sei  $P \sim \mathcal{D}(\alpha)$  ein Dirichlet-Prozess, und  $X_1, \dots, X_n$  eine Folge von Zufallsvariablen, die gegeben  $P$  iid  $P$  verteilt sind. Dann ist die a posteriori Verteilung von  $P$  für gegebene Daten  $(X_1, X_2, \dots, X_n)$  wieder ein Dirichlet-Prozess, und zwar  $\mathcal{D}(\alpha + \sum \delta_{X_i})$ .*

Dieser Satz ist der Grund, warum Dirichlet-Prozesse so wichtig für die nicht-parametrische Bayes-Statistik sind. Näheres dazu werden wir im nächsten Teil, wo wir ein paar Beispiele betrachten, erläutern.

### 3 Beispiele

In diesem Abschnitt werden wir zwei Beispiele von Bayes-Schätzern anschauen. Im Folgenden sei

$$\Theta = \{\text{Menge aller Wahrscheinlichkeitsverteilungen auf } (\mathbb{R}, \mathcal{B})\},$$

wobei  $\mathcal{B}$  die Borel- $\sigma$ -Algebra ist.

Als nützlich wird sich die Eigenschaft erweisen, dass mit einem Dirichlet-prior  $\mathcal{D}(\alpha)$  die a posteriori Verteilung  $\mathcal{D}(\alpha + \sum_i \delta_{X_i})$  ist. Dies erlaubt uns den Bayes-Schätzer für das „no sample“ Problem (also für a posteriori Verteilung = a priori Verteilung  $\mathcal{D}(\alpha)$ ) zu berechnen und dann den Bayesschätzer durch Ersetzen von  $\alpha$  durch  $\alpha + \sum_i \delta_{X_i}$  zu erhalten.

#### 3.1 Verteilungsschätzer

Im ersten Beispiel werden wir die Verteilung selbst schätzen.

Es sei:

$$F(t) = P((-\infty, t]), \quad t \in \mathbb{R}$$

für  $P \in \Theta$ . Wir wollen den Bayesschätzer für die a posteriori Verteilung  $\mathcal{D}(\alpha)$  (no sample) bestimmen unter dem Verlust

$$L(F, \hat{F}) = \int_{\mathbb{R}} (F(t) - \hat{F}(t))^2 dW(t),$$

wobei  $W$  ein endliches Mass auf  $(\mathbb{R}, \mathcal{B})$  ist.

Der Bayesschätzer minimiert den erwarteten Verlust unter der a posteriori

Verteilung und daher ist

$$F_{Bayes} = \arg \min_{\hat{F}} E\left[\int (F(t) - \hat{F}(t))^2 dW(t)\right] \quad (1)$$

$$\stackrel{Tonelli}{=} \int \arg \min_{\hat{F}} \{E[(F(t) - \hat{F}(t))^2]\} dW(t). \quad (2)$$

Für festes  $t$  gilt also:

$$\begin{aligned} F_{Bayes}(t) &= \arg \min_{\hat{F}} E[(F(t) - \hat{F}(t))^2] \\ &= E[F(t)] \\ &= E[P((-\infty, t])]. \end{aligned}$$

Wir wissen das die Randverteilung eines  $k$ -dimensional Dirichlet-verteilten Zufallsvektors Beta-verteilt ist. In diesem Fall ist

$$P(-\infty, t] \sim \text{Beta}(\alpha((-\infty, t]), \alpha((t, \infty)))$$

Also ist im no sample Fall der Bayesschätzer

$$\begin{aligned} F_{Bayes}(t) &= \frac{\alpha((-\infty, t])}{\alpha(\mathbb{R})} \\ &= F_0(t). \end{aligned}$$

Durch ersetzen der a priori Verteilung durch die a posteriori Verteilung  $\mathcal{D}(\alpha + \sum_i \delta_{X_i})$  erhalten wir für die Realisierungen  $X_1, \dots, X_n$  den Bayesschätzer:

$$\begin{aligned} \hat{F}_n(t|X_1, \dots, X_n) &= \frac{\alpha((-\infty, t]) + \frac{1}{n} \sum \delta_{X_i}((-\infty, t])}{\alpha(\mathbb{R}) + n} \\ &= p_n F_0(t) + (1 - p_n) F_n(t|X_1, \dots, X_n), \end{aligned}$$

wobei  $p_n = \frac{\alpha(\mathbb{R})}{\alpha(\mathbb{R}) + n}$  und  $F_n(t|X_1, \dots, X_n)$  die empirische Verteilungsfunktion ist.  $p_n$  ist die Wahrscheinlichkeit, dass die a priori Dichte stimmt und man sieht, dass diese durch  $\alpha(\mathbb{R})$  bestimmt wird.

### 3.2 Mittelwert

Ein weiteres Beispiel wäre ein Schätzer für der Mittelwert  $\mu = \int xP(dx)$  für  $P \in \Theta$ . Für den Verlust

$$L(P, \hat{\mu}) = (\mu - \hat{\mu})^2$$

erhält man den Bayesschätzer

$$\hat{\mu}_n(X_1, \dots, X_n) = p_n \mu_0 + (1 - p_n) \bar{X}_n,$$

wobei  $p_n$  wie oben,  $\bar{X}_n$  der Mittelwert der Beobachtungen und  $\mu_0$  der a priori Erwartungswert ist, d.h.

$$\mu_0 = \int_{\mathbb{R}} x \frac{d\alpha(x)}{\alpha(\mathbb{R})}.$$

## Literatur

- [1] Thomas S. Ferguson. A Bayesian Analysis of some Nonparametric Problems. *The Annals of Statistics*, 1(2):209-230, 1973.
- [2] Mark J. Schervish. *Theory of Statistics*. Springer-Verlag, N. Y., 1995.
- [3] J. Sethuraman. A Constructive Definition of Dirichlet Priors. *Statistica Sinica*, 4:639-650, 1994.