

## Formelsammlung zur Vorlesung Schätzen und Testen II

### 5 Bootstrap

*Einstichproben-Problem:*

$$X = (X_1, \dots, X_n) \rightarrow T(X)$$

mit  $X_i \stackrel{i.i.d.}{\sim} F$ ,  $F$  unbekannt

*Beobachtete Daten:*

$$x = (x_1, x_2, \dots, x_n) \rightarrow T(x)$$

*Bootstrap-Stichprobe:*

$$x^* = (x_1^*, x_2^*, \dots, x_n^*) \rightarrow T(x^*)$$

*Empirische Verteilungsfunktion:*

$$\hat{F}_n(x) = \frac{1}{n} \sum_{i=1}^n I(x_i \leq x)$$

#### Bootstrap-Algorithmus zur Schätzung des Standardfehlers

1. Erzeuge  $B$  Bootstrap-Stichproben  $x^{*1}, \dots, x^{*B}$ .
2. Berechne  $\hat{\theta}^*(b)$ ,  $b = 1, \dots, B$ .
3. Schätze den Standardfehler  $\text{se}_F(\hat{\theta}) = \sqrt{\text{Var}_F(\hat{\theta})}$  durch

$$\widehat{\text{se}}_B = \left\{ \frac{1}{B-1} \sum_{b=1}^B [\hat{\theta}^*(b) - \hat{\theta}^*(\cdot)]^2 \right\}^{\frac{1}{2}} \quad \text{mit} \quad \hat{\theta}^*(\cdot) = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^*(b).$$

#### Standardfehler für die Schätzung des Korrelationskoeffizienten $\theta$

- (i) Vergleich mit der Formel für die bivariate Normalverteilung:

$$\widehat{\text{se}}_{N_2(\mu, \Sigma)}(\hat{\theta}) = \frac{1 - \hat{\theta}^2}{\sqrt{n-3}}$$

- (ii) Vergleich nach Fisher-Transformation:

$$\hat{\xi} = \frac{1}{2} \log \left( \frac{1 + \hat{\theta}}{1 - \hat{\theta}} \right) \underset{\text{approx.}}{\sim} N \left[ \frac{1}{2} \log \left( \frac{1 + \theta}{1 - \theta} \right), \left( \frac{1}{\sqrt{n-3}} \right)^2 \right]$$

## Zweistichproben-Problem für unabhängige Stichproben

$$\left. \begin{array}{l} Y_1, \dots, Y_n \stackrel{\text{i.i.d.}}{\sim} F \\ Z_1, \dots, Z_m \stackrel{\text{i.i.d.}}{\sim} G \end{array} \right\} \text{unabhängig}$$

Schätzung des Standardfehlers der Schätzung für die Differenz  $\theta = \mu_Y - \mu_Z$ :

$$y^{*b} = (y_1^{*b}, \dots, y_n^{*b}) \text{ zufällig mit Zurücklegen aus } \hat{F}_n$$

$$z^{*b} = (z_1^{*b}, \dots, z_m^{*b}) \text{ zufällig mit Zurücklegen aus } \hat{G}_m$$

$$\widehat{\text{se}}_{F,G}(\hat{\theta}) = \text{se}_{\hat{F}_n, \hat{G}_m}(\hat{\theta}^*) \approx \widehat{\text{se}}_B = \left\{ \frac{1}{B-1} \sum_{b=1}^B [\hat{\theta}^*(b) - \hat{\theta}^*(\cdot)]^2 \right\}^{\frac{1}{2}}$$

mit

$$\hat{\theta}^*(b) = \frac{1}{n} \sum_{i=1}^n y_i^{*b} - \frac{1}{m} \sum_{i=1}^m z_i^{*b}$$

und

$$\hat{\theta}^*(\cdot) = \frac{1}{B} \sum_{b=1}^B \hat{\theta}^*(b)$$

## Bootstrap im Linearen Modell

$$y_i = \mathbf{x}_i^\top \boldsymbol{\beta} + \varepsilon_i, \quad \varepsilon_i \stackrel{\text{i.i.d.}}{\sim} F, \quad \mathbb{E}(\varepsilon_i) = 0$$

### Nichtparametrischer Bootstrap

1. *Schritt:* Berechne  $\hat{\boldsymbol{\beta}}$  mit der KQ-Methode:  $\hat{\boldsymbol{\beta}} = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}$ .
2. *Schritt:* Berechne die Residuen  $\hat{\boldsymbol{\varepsilon}} = (\mathbf{I} - \mathbf{X}(\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top) \mathbf{y} = \mathbf{y} - \mathbf{X} \hat{\boldsymbol{\beta}}$ .
3. *Schritt:* Setze für die empirische Verteilung  $\hat{F}_n$  der Residuen eine Wahrscheinlichkeitsmasse  $\frac{1}{n}$  auf  $\hat{\varepsilon}_i, i = 1, \dots, n$  (ohne weitere Einschränkung seien alle Residuen verschieden).
4. *Schritt:*
  - Ziehe eine Stichprobe  $\boldsymbol{\varepsilon}^* = (\varepsilon_1^*, \dots, \varepsilon_n^*)$  mit Zurücklegen aus  $\hat{F}_n$ .
  - Berechne „neue“ Bootstrap-Zielvariablen

$$y_i^* = \mathbf{x}_i^\top \hat{\boldsymbol{\beta}} + \varepsilon_i^*$$

für  $i = 1, \dots, n$ , d.h.

$$\mathbf{y}^* = \mathbf{X} \hat{\boldsymbol{\beta}} + \boldsymbol{\varepsilon}^*.$$

- Berechne den Bootstrap-KQ-Schätzer

$$\hat{\boldsymbol{\beta}}^* = (\mathbf{X}^\top \mathbf{X})^{-1} \mathbf{X}^\top \mathbf{y}^*.$$

### Parametrischer Bootstrap

1. *Schritt:* Berechne  $\hat{\boldsymbol{\beta}}_{KQ}$  und  $\hat{\sigma}_F^2$ .
2. *Schritt:* Setze  $y_i^* = \mathbf{x}_i^\top \hat{\boldsymbol{\beta}}_{KQ} + \varepsilon_i^*$ , wobei  $\varepsilon_i^* \sim N(0, \hat{\sigma}_F^2)$ .

## Bias-Schätzung mittels Bootstrap

$$\text{bias}_F(\hat{\theta}, \theta) = \mathbb{E}_F(\hat{\theta}) - \theta = \mathbb{E}_F(\hat{\theta}) - T(F)$$

$$\widehat{\text{bias}}_F(\hat{\theta}, \theta) = \text{bias}_{\hat{F}_n}(\hat{\theta}^*, \hat{\theta}) = \mathbb{E}_{\hat{F}_n}[\hat{\theta}^*] - T(\hat{F}_n)$$

Bias-Korrektur:

$$\bar{\theta} = 2\hat{\theta} - \hat{\theta}^*(\cdot)$$

## Bootstrap-Konfidenzintervalle

### Bootstrap-t-Intervall

1. Generiere  $B$  Bootstrap-Stichproben  $x^{*1}, \dots, x^{*B}$ .
2. Berechne

$$Z^*(b) = \frac{\hat{\theta}^*(b) - \hat{\theta}}{\widehat{\text{se}}^*(b)}.$$

Ordne die  $Z^*(b)$  aufsteigend der Größe nach.

3. Schätze die Quantile  $\hat{t}^{(\alpha)}$  und  $\hat{t}^{(1-\alpha)}$  als

$$\frac{\#\{Z^*(b) \leq \hat{t}^{(\alpha)}\}}{B} = \alpha.$$

4. Das Bootstrap- $t$ -Intervall zum Vertrauensgrad  $1 - 2\alpha$  lautet dann

$$\left[ \hat{\theta} - \hat{t}^{(1-\alpha)} \cdot \widehat{\text{se}}, \hat{\theta} - \hat{t}^{(\alpha)} \cdot \widehat{\text{se}} \right].$$

### Bootstrap-Perzentil-Intervall

1. Ziehe  $x^{*1}, \dots, x^{*B}$   $B$  Bootstrap-Replikationen

$$\begin{array}{ccc} \downarrow & & \downarrow \\ \hat{\theta}^*(1), & \dots, & \hat{\theta}^*(B) \end{array} \quad \text{mit } \hat{\theta}^*(b) = T(x^{*b}).$$

2. Ordne die  $\hat{\theta}^*(b)$  der Größe nach:  $\hat{\theta}_{(1)}^*, \dots, \hat{\theta}_{(B)}^*$ .

3. Berechne  $B\alpha$  und  $B(1 - \alpha)$  und bezeichne mit  $\hat{\theta}_B^{*(\alpha)}$  bzw.  $\hat{\theta}_B^{*(1-\alpha)}$  die Werte an den jeweiligen Positionen in der sortierten Sequenz der Bootstrap-Schätzungen. Dann ist

$$\left[ \hat{\theta}_{\text{lower}}, \hat{\theta}_{\text{upper}} \right] = \left[ \hat{\theta}_B^{*(\alpha)}, \hat{\theta}_B^{*(1-\alpha)} \right]$$

ein approximatives  $(1 - 2\alpha)$ -Konfidenzintervall.

## Kreuzvalidierung und Vorhersagefehler

*k*-fache Kreuzvalidierung:

$$\text{CV} = \frac{1}{n} \sum_{i=1}^n \left( y_i - \hat{y}_i^{-k(i)} \right)^2$$

Vorhersagefehler:

$$\text{err}(x, F) \equiv \mathbb{E}_{0F}(Q(Y_0, \eta_x(\mathbf{Z}_0)))$$

Apparent error in sample:

$$\text{err}(x, \hat{F}_n) = \mathbb{E}_{0\hat{F}_n}(Q(Y_0, \eta_x(\mathbf{Z}_0))) = \frac{1}{n} \sum_{i=1}^n Q[y_i, \eta_x(\mathbf{z}_i)]$$

Plug-In-Schätzung:

$$\text{err}(x^{*b}, \hat{F}_n) = \frac{1}{n} \sum_{i=1}^n Q[y_i, \eta_{x^{*b}}(\mathbf{z}_i)]$$

Durchschnittlicher Vorhersagefehler:

$$\mathbb{E}_F[\text{err}(x, F)]$$

Approximative Bootstrap-Schätzung:

$$\hat{\mathbb{E}}_{\hat{F}_n}[\text{err}(x^*, \hat{F}_n)] = \frac{1}{B} \sum_{b=1}^B \frac{1}{n} \sum_{i=1}^n Q[y_i, \eta_{x^{*b}}(\mathbf{z}_i)]$$

In bootstrap-sample error:

$$\hat{\mathbb{E}}_{\hat{F}_n}[\text{err}(x^*, \hat{F}_n^*)] = \frac{1}{B} \sum_{b=1}^B \frac{1}{n} \sum_{i=1}^n Q[y_i^{*b}, \eta_{x^{*b}}(\mathbf{z}_i^{*b})]$$

Average optimism:

$$w(F) = \mathbb{E}_F(\text{err}(x, F)) - \mathbb{E}_F(\text{err}(x, \hat{F}_n))$$

Approximative Bootstrap-Schätzung:

$$\hat{w}(\hat{F}_n) = \frac{1}{Bn} \left\{ \sum_{b=1}^B \sum_{i=1}^n Q[y_i, \eta_{x^{*b}}(\mathbf{z}_i)] - \sum_{b=1}^B \sum_{i=1}^n Q[y_i^{*b}, \eta_{x^{*b}}(\mathbf{z}_i^{*b})] \right\}$$

Schätzung des Vorhersagefehlers mit Bias-Korrektur:

$$\text{err}(x, \hat{F}_n) + w(\hat{F}_n) \quad \text{wird geschätzt durch} \quad \frac{1}{n} \sum_{i=1}^n Q[y_i, \eta_x(\mathbf{z}_i)] + \hat{w}(\hat{F}_n)$$

## 6 Fehlspezifikation, Quasi-Likelihood und Schätzgleichungen

### ML-Schätzung bei Fehlspezifikation

Kullback-Leibler-Distanz von  $g$  und  $f_\theta$  für  $X$  stetig:

$$D(g, f_\theta) = \mathbb{E}_g \left( \log \frac{g(X)}{f(X|\theta)} \right)$$

Entropie von  $g$ :

$$-\mathbb{E}_g \log g(X) = - \int g(x) \log(g(x)) dx$$

### Asymptotische Eigenschaften des ML-Schätzers bei Missspezifikation

1. Konsistenz: Sei  $\theta_0$  ein (lokaler) Maximierer von

$$\lambda(\theta) \equiv \mathbb{E}_g \log f_\theta(X|\theta)$$

(bzw. ein Minimierer von  $D(g, f_\theta)$ ). Unter Regularitätsannahmen (ähnlich wie bei Fisher-Regularität) existiert eine Folge  $\hat{\theta}_n$  von („Quasi-“) ML-Schätzern, das heißt lokalen Maximierern von

$$\frac{1}{n} \sum_{i=1}^n \log f(x_i|\theta)$$

mit

$$\hat{\theta}_n \xrightarrow{P} \theta_0.$$

2. Asymptotische Normalität: Es gilt

$$\sqrt{n}(\hat{\theta}_n - \theta_0) \xrightarrow{d} N \left( \mathbf{0}, \mathbf{J}_1^{-1}(\theta_0) \mathbf{I}_1(\theta_0) \mathbf{J}_1^{-1}(\theta_0) \right)$$

mit

$$\mathbf{I}_1(\theta) \equiv \mathbb{E}_g \underbrace{\left( \frac{\partial \log f(X|\theta)}{\partial \theta} \right)}_{\mathbf{s}_1(\theta)} \underbrace{\left( \frac{\partial \log f(X|\theta)}{\partial \theta} \right)^\top}_{\mathbf{s}_1(\theta)^\top}$$

und der (Quasi-)Fisher-Information

$$\mathbf{J}_1(\theta) = \mathbb{E}_g \left( - \frac{\partial^2 \log f(X|\theta)}{\partial \theta \partial \theta^\top} \right).$$

## M-Schätzer in der robusten Statistik

### Asymptotische Eigenschaften von M-Schätzern $\hat{\theta}_M$

Unter Regularitätsvoraussetzungen, insbesondere

$$\mathbb{E}_0 \mathbf{qs}(\theta_0) = \mathbf{0},$$

gilt

$$\hat{\theta}_M \stackrel{a}{\sim} N(\theta_0, \mathbf{V}(\hat{\theta}_M)).$$

Dabei ist  $\mathbf{V}(\hat{\theta}_M)$  definiert als

$$\mathbf{V}(\hat{\theta}_M) = \mathbf{J}^{-1}(\hat{\theta}_M) \mathbf{I}(\hat{\theta}_M) \mathbf{J}^{-1}(\hat{\theta}_M)$$

mit der empirischen (Quasi-) Fisher-Matrix

$$\mathbf{I}(\hat{\theta}_M) = \sum_{i=1}^n \mathbf{qs}_i(\hat{\theta}_M) \mathbf{qs}_i^\top(\hat{\theta}_M)$$

und der (empirischen) beobachteten (Quasi-) Informationsmatrix

$$\mathbf{J}(\hat{\theta}_M) = - \left. \frac{\partial \mathbf{qs}(\theta)}{\partial \theta^\top} \right|_{\theta = \hat{\theta}_M}.$$

## Verallgemeinerte Schätzgleichungen (Generalized Estimating Equations)

$$U(\beta, \alpha) = \sum_{i=1}^N \left( \frac{\partial \mu_i(\beta)}{\partial \beta} \right)^\top V_i(\beta, \alpha, \phi)^{-1} (Y_i - \mu_i(\beta)) = 0$$

Sei  $T_i$  die Anzahl der Beobachtungen an Individuum  $i$  und  $\phi$  der Dispersionsparameter.

- $\left( \frac{\partial \mu_i}{\partial \beta} \right)^\top$  ist eine  $p \times T_i$  Matrix (GLM:  $p \times 1$  Vektor)
- $Y_i$  und  $\mu_i$  sind  $T_i \times 1$  Vektoren (GLM: Skalare)
- $V_i$  ist die  $T_i \times T_i$  Arbeitskovarianzmatrix (GLM: Skalar)

$$V_i(\beta, \alpha, \phi) = \begin{pmatrix} c_{i11}(\beta, \alpha, \phi) & c_{i12}(\beta, \alpha, \phi) & \cdots & c_{i1T_i}(\beta, \alpha, \phi) \\ c_{i21}(\beta, \alpha, \phi) & c_{i22}(\beta, \alpha, \phi) & \cdots & c_{i2T_i}(\beta, \alpha, \phi) \\ \vdots & \vdots & \ddots & \vdots \\ c_{iT_i1}(\beta, \alpha, \phi) & c_{iT_i2}(\beta, \alpha, \phi) & \cdots & c_{iT_iT_i}(\beta, \alpha, \phi) \end{pmatrix}$$

mit

$$c_{itt'}(\beta, \alpha, \phi) = \begin{cases} \text{Cov}(Y_{it}, Y_{it'}; \beta, \alpha, \phi), & \text{falls } t \neq t' \\ \text{Var}(Y_{it}; \beta, \alpha, \phi), & \text{falls } t = t'. \end{cases}$$

- Bei Verwendung einer "Arbeitskorrelation" berechnet sich die "Arbeitskovarianz" als

$$V_i(\beta, \alpha, \phi) = \phi \mathbf{A}_i(\beta)^{\frac{1}{2}} \mathbf{R}_i(\alpha) \mathbf{A}_i(\beta)^{\frac{1}{2}}$$

mit der Diagonalmatrix der Varianzfunktionen

$$\mathbf{A}_i(\beta) = \text{diag}[v(\mu_{i1}(\beta)), v(\mu_{i2}(\beta)), \dots, v(\mu_{iT_i}(\beta))]$$

## Varianzschätzung mittels Sandwich-Schätzer

Sei

$$F = \sum_{i=1}^N \left( \frac{\partial \mu_i}{\partial \beta} \right)^\top V_i^{-1} \left( \frac{\partial \mu_i}{\partial \beta} \right),$$

wobei  $V_i$  die modellbasierte Kovarianzmatrix ist, die sich aus den Annahmen über Varianz und Korrelation ergibt, und

$$G = \sum_{i=1}^N \left( \frac{\partial \mu_i}{\partial \beta} \right)^\top V_i^{-1} \text{Cov}(Y_i) V_i^{-1} \left( \frac{\partial \mu_i}{\partial \beta} \right),$$

wobei  $\text{Cov}(Y_i)$  die wahre Kovarianzmatrix ist. Dann gilt:

$$\widehat{\text{Cov}}(\widehat{\beta}) = \widehat{F}^{-1} \widehat{G} \widehat{F}^{-1}$$

ist die empirische konsistente Schätzung der Kovarianzmatrix von  $\widehat{\beta}$ .  $\widehat{F}$  und  $\widehat{G}$  sind die empirischen Matrizen, die sich durch Einsetzen von  $\widehat{\beta}$ ,  $\widehat{\alpha}$  und  $\widehat{\phi}$  ergeben.  $\text{Cov}(Y_i)$  wird konsistent geschätzt durch die Matrix  $(y_i - \mu_i)(y_i - \mu_i)^\top$ . Im Idealfall gilt:

$$\text{Cov}(Y_i) = V_i.$$

Dann ist GEE effizient und man erhält

$$\text{Cov}(\widehat{\beta}) = F^{-1}$$

bzw. die Schätzung

$$\widehat{\text{Cov}}(\widehat{\beta}) = \widehat{F}^{-1}.$$

### Eigenschaften der GEE Schätzung

- Verwendet man als "Arbeitskorrelation" die Unabhängigkeit, so spricht man vom IEE Schätzer (independence estimating equations). Man erhält

$$V_i(\beta, \alpha, \phi) = V_i(\beta, \phi) = \phi \mathbf{A}_i(\beta)$$

und die Schätzgleichung reduziert sich dann auf

$$U(\beta) = \sum_{i=1}^N \left( \frac{\partial \mu_i(\beta)}{\partial \beta} \right)^\top V_i(\beta, \phi)^{-1} (Y_i - \mu_i(\beta)) = 0.$$

Die IEE Schätzung  $\widehat{\beta}_I$  ist unter schwachen Voraussetzungen konsistent und asymptotisch normalverteilt, wenn  $\phi$  konsistent geschätzt wird und das Modell für den Erwartungswert korrekt spezifiziert ist.

- Wird als "Arbeitskorrelation" nicht die Unabhängigkeit gewählt, so ist die GEE Schätzung  $\widehat{\beta}_G$  unter schwachen Voraussetzungen konsistent und asymptotisch normalverteilt, wenn  $\phi$  und  $\alpha$   $N^{\frac{1}{2}}$ -konsistent geschätzt werden.

### Quantilregression

Bedingte Quantilsfunktion:

$$Q_\tau(y|\mathbf{X} = \mathbf{x}) = F_{Y|\mathbf{X}=\mathbf{x}}^{-1}(\tau|\mathbf{X} = \mathbf{x}) = y_\tau(\mathbf{x})$$

$$Q_\tau(y|\mathbf{X} = \mathbf{x}) = \mathbf{x}^\top \boldsymbol{\beta}_\tau$$

Modellformel:

$$y_i = \mathbf{x}_i^\top \boldsymbol{\beta}_\tau + \varepsilon_{\tau i}$$

mit unabhängigen, aber möglicherweise heteroskedastischen  $\varepsilon_{\tau i}$  und

$$F_{\varepsilon_{\tau i}}(0) = \int_{-\infty}^0 f(\varepsilon_{\tau i}) d\varepsilon_{\tau i} = \tau$$

### Entscheidungstheoretischer Ansatz

Check-Funktion:

$$\rho_\tau(u) = u \cdot (\tau - I(u < 0)), \quad \tau \in (0, 1)$$

Zielfunktion:

$$\underset{\boldsymbol{\beta}_\tau \in \mathbb{R}^p}{\text{argmin}} \sum_{i=1}^n \rho_\tau(y_i - \mathbf{x}_i^\top \boldsymbol{\beta}_\tau)$$

Erwarteter Verlust:

$$\mathbb{E}_{F_Y}[\rho_\tau(y - \hat{y})]$$

**Satz.** Der erwartete Verlust wird minimiert durch  $\hat{y} = F_Y^{-1}(\tau)$ .

**Quasi-ML-Ansatz**

Asymmetrische Laplace-Verteilung (ALD):

$$Y \sim \text{ALD}(\mu, \sigma, \tau)$$

mit  $-\infty < y < \infty$ ,  $\mu \in \mathbb{R}$ ,  $\sigma > 0$  und  $\tau \in (0, 1)$ . Die Dichtefunktion der ALD lautet

$$f_Y(y) = \frac{\tau(1-\tau)}{\sigma} \cdot \exp \left\{ -\rho_\tau \left( \frac{y-\mu}{\sigma} \right) \right\}$$

Quasi-Likelihood:

$$\text{QL}(\beta_\tau) \propto \frac{1}{\sigma} \exp \left\{ -\sum_{i=1}^n \rho_\tau \left( \frac{y_i - \mathbf{x}_i^\top \beta_\tau}{\sigma} \right) \right\}$$

**Eigenschaften der Quantilregression**

- Äquivarianz:

$$\begin{aligned} \hat{\beta}_\tau(a\mathbf{y}, \mathbf{X}) &= a\hat{\beta}_\tau(\mathbf{y}, \mathbf{X}), \\ \hat{\beta}_\tau(\mathbf{y}, \mathbf{XA}) &= \mathbf{A}^{-1}\hat{\beta}_\tau(\mathbf{y}, \mathbf{X}) \end{aligned}$$

- Asymptotische Verteilung:

$$\sqrt{n}(\hat{\beta}_\tau - \beta_\tau) \rightarrow N(0, \tau(1-\tau)\mathbf{H}^{-1}(\tau)\mathbf{J}(\tau)\mathbf{H}^{-1}(\tau))$$

mit

$$\begin{aligned} \mathbf{J}(\tau) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top, \\ \mathbf{H}(\tau) &= \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^\top \cdot f_i(y_{i\tau}) \end{aligned}$$

**7 Non- und Semiparametrische Inferenz****Kerndichteschätzung**

**Definition** (Histogramm). Sei  $x_1, \dots, x_n$  eine i.i.d. Stichprobe einer stetigen Zufallsvariable  $X$  mit Dichte  $f$ . Dann heißt der Schätzer

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n \sum_{j \in \mathbb{Z}} I_{B_j}(x_i) I_{B_j}(x)$$

Histogramm mit Klassenbreite (Bandweite)  $h > 0$  und Ursprung  $x_0$ .

**Definition** (Kerndichteschätzer). Der Schätzer

$$\hat{f}_h(x) = \frac{1}{nh} \sum_{i=1}^n K \left( \frac{x - x_i}{h} \right) = \frac{1}{n} \sum_{i=1}^n K_h(x - x_i)$$

mit

$$K_h(u) := \frac{1}{h} K \left( \frac{u}{h} \right)$$

heißt Kerndichteschätzer mit Kern  $K$  (bzw.  $K_h$ ) und Bandweite  $h > 0$ .

- Dreieckskern:  $K(u) = (1 - |u|)I_{[-1,1]}(u)$ ,
- Epanechnikovkern:  $K(u) = \frac{3}{4}(1 - u^2)I_{[-1,1]}(u)$ ,
- Normalkern:  $K(u) = \frac{1}{\sqrt{2\pi}} \exp(-\frac{1}{2}u^2)$ .

**Erwartungswert, Varianz, Bias, MSE und MISE des Kerndichteschätzers**

$$\begin{aligned}\mathbb{E}(\hat{f}_h(x)) &= \frac{1}{h} \int_{\mathbb{R}} K\left(\frac{x-y}{h}\right) f(y) dy \\ \text{Var}(\hat{f}_h(x)) &= \frac{1}{nh^2} \int_{\mathbb{R}} K^2\left(\frac{x-y}{h}\right) f(y) dy - \frac{1}{n} \mathbb{E}(\hat{f}_h(x))^2 \\ \text{bias}(\hat{f}_h(x)) &= \mathbb{E}(\hat{f}_h(x)) - f(x) = \frac{1}{h} \int_{\mathbb{R}} K\left(\frac{x-y}{h}\right) f(y) dy - f(x) \\ \text{MSE}(\hat{f}_h(x)) &= \frac{1}{nh^2} \int_{\mathbb{R}} K^2\left(\frac{x-y}{h}\right) f(y) dy - \frac{1}{n} \mathbb{E}(\hat{f}_h(x))^2 + \left(\frac{1}{h} \int_{\mathbb{R}} K\left(\frac{x-y}{h}\right) f(y) dy - f(x)\right)^2 \\ \text{MISE}(\hat{f}_h) &= \int_{\mathbb{R}} \text{MSE}(\hat{f}_h(x)) dx.\end{aligned}$$

**Konsistenz des Kerndichteschätzers**

**Satz** (Satz von Parzen). Sei  $R(x)$ ,  $x \in \mathbb{R}$ , eine (messbare) Funktion mit den Eigenschaften

1.  $\sup_{x \in \mathbb{R}} |R(x)| < \infty$  (d.h.  $R(x)$  ist beschränkt),
2.  $\int_{\mathbb{R}} |R(x)| dx < \infty$ ,
3.  $|x|R(x) \rightarrow 0$  für  $|x| \rightarrow \infty$ .

Sei weiterhin  $g(x)$ ,  $x \in \mathbb{R}$ , eine (messbare) Funktion mit  $\int_{\mathbb{R}} |g(x)| dx < \infty$ . Betrachte die Folge

$$g_n(x) = \frac{1}{h_n} \int_{\mathbb{R}} R\left(\frac{x-y}{h_n}\right) g(y) dy,$$

wobei  $h_n$  eine Folge ist mit  $\lim_{n \rightarrow \infty} h_n = 0$ . Dann gilt für jeden Stetigkeitspunkt  $x$  von  $g$

$$g_n(x) \rightarrow g(x) \int_{\mathbb{R}} R(s) ds$$

falls  $n \rightarrow \infty$ .

**Satz** (Konsistenz des Kerndichteschätzers). Sei  $f$  stetig. Dann gilt

$$\mathbb{E}(\hat{f}_{h_n}(x)) \rightarrow f(x),$$

falls die Bandweite  $h_n$  für  $n \rightarrow \infty$  gegen Null konvergiert.  $\hat{f}_{h_n}(x)$  ist also asymptotisch erwartungstreu. Falls  $nh_n \rightarrow \infty$  für  $n \rightarrow \infty$ , dann gilt

$$\text{Var}(\hat{f}_{h_n}(x)) \rightarrow 0.$$

Damit ist  $\hat{f}_{h_n}(x)$  konsistent.

**Konvergenzordnung des MISE**

**Satz.** Sei  $f$  mindestens zweimal stetig differenzierbar,  $f''$  beschränkt,  $f$  und  $f''$  quadratintegrierbar. Sei  $h_n$  eine Folge mit  $h_n \rightarrow 0$  und  $nh_n \rightarrow \infty$  für  $n \rightarrow \infty$ . Unter Verwendung der Abkürzungen  $\int_{\mathbb{R}} g^2(s) ds = \|g\|_2^2$  und

$\mu_2(g) = \int_{\mathbb{R}} g(s)s^2 ds$  für eine Funktion  $g$  gilt:

$$1. \text{Var}(\hat{f}_{h_n}(x)) = \frac{1}{nh_n} \|K\|_2^2 f(x) + o\left(\frac{1}{nh_n}\right) \quad \text{bzw.}$$

$$\int_{\mathbb{R}} \text{Var}(\hat{f}_{h_n}(x)) dx = \frac{1}{nh_n} \|K\|_2^2 + o\left(\frac{1}{nh_n}\right).$$



$$2. \text{bias}(\hat{f}_{h_n}(x)) = \frac{h_n^2}{2} \mu_2(K) f''(x) + o(h_n^2) \quad \text{bzw.}$$

$$\int_{\mathbb{R}} \text{bias}^2(\hat{f}_{h_n}(x)) dx = \frac{h_n^4}{4} \mu_2^2(K) \|f''\|_2^2 + o(h_n^4).$$

$$3. \text{MISE}(\hat{f}_{h_n}) = \frac{1}{nh_n} \|K\|_2^2 + \frac{h_n^4}{4} \mu_2^2(K) \|f''\|_2^2 + o\left(\frac{1}{nh_n} + h_n^4\right).$$

### Asymptotische Verteilung und Konfidenzintervalle

**Satz** (Asymptotische Verteilung).  $f''(x)$  existiere; es gelte  $h_n = cn^{-1/5}$ . Dann ist der Kern-Dichteschätzer  $\hat{f}_{h_n}(x)$  asymptotisch normalverteilt,

$$n^{\frac{2}{5}} \left\{ \hat{f}_{h_n}(x) - f(x) \right\} \xrightarrow{d} N\left( \underbrace{\frac{c^2}{2} f''(x) \mu_2(K)}_{b_x}, \underbrace{c^{-1} f(x) \|K\|_2^2}_{v_x^2} \right)$$

für  $n \rightarrow \infty$ .

### Approximatives $(1-\alpha)$ - Konfidenzintervall

$$\left[ \hat{f}_h(x) - \frac{h^2}{2} f''(x) \mu_2(K) - z_{1-\frac{\alpha}{2}} \sqrt{\frac{f(x) \|K\|_2^2}{nh}}, \hat{f}_h(x) - \frac{h^2}{2} f''(x) \mu_2(K) + z_{1-\frac{\alpha}{2}} \sqrt{\frac{f(x) \|K\|_2^2}{nh}} \right]$$

### Integrated Squared Error (ISE)

$$\text{ISE}(h) = \int_{\mathbb{R}} (\hat{f}_h(x) - f(x))^2 dx = \int_{\mathbb{R}} \hat{f}_h^2(x) dx - 2 \int_{\mathbb{R}} \hat{f}_h(x) f(x) dx + \int_{\mathbb{R}} f^2(x) dx$$

### Kreuzvalidierungsfunktion

$$\text{CV}(h) = \frac{1}{n^2 h} \sum_{i=1}^n \sum_{j=1}^n (K \star K) \left( \frac{x_j - x_i}{h} \right) - \frac{2}{n} \sum_{i=1}^n \hat{f}_{h,i}(x_i)$$

## Bayesianische nichtparametrische Dichteschätzung

### Dirichlet-Verteilung

Dirichlet-Dichte:

$$p(\pi|\alpha) = \frac{\Gamma(\sum_{i=1}^m \alpha_i)}{\prod_{i=1}^m \Gamma(\alpha_i)} \pi_1^{\alpha_1-1} \pi_2^{\alpha_2-1} \dots \pi_m^{\alpha_m-1},$$

wobei  $\pi_m = 1 - \sum_{k=1}^{m-1} \pi_k$ . Kurz:

$$\pi \sim \text{Diri}(\alpha_1, \dots, \alpha_m).$$

Es gilt mit  $\bar{\alpha} := \alpha_1 + \dots + \alpha_m$ :

$$\begin{aligned} \mathbb{E}(\pi_i) &= \frac{\alpha_i}{\bar{\alpha}} \\ \mathbb{E}(\pi_i^2) &= \frac{\alpha_i(\alpha_i + 1)}{\bar{\alpha}(\bar{\alpha} + 1)} \\ \mathbb{E}(\pi_i \pi_j) &= \frac{\alpha_i \alpha_j}{\bar{\alpha}(\bar{\alpha} + 1)} \quad i \neq j. \end{aligned}$$

*Äquivalente Definition:*  $Z_1, Z_2, \dots, Z_m$  seien unabhängige  $\text{Gamma}(\alpha_i, 1)$ -verteilte Zufallsvariablen,  $\alpha_i > 0$ . Dann gilt für  $\pi = (\pi_1, \dots, \pi_m)$  mit

$$\pi_i = \frac{Z_i}{\sum_{j=1}^m Z_j} :$$

$$\pi \sim \text{Diri}(\alpha_1, \alpha_2, \dots, \alpha_m).$$

## Dirichlet-Prozesse

**Definition** (Dirichlet-Prozess). Ein Dirichlet-Prozess (DP) ist ein RPMG auf  $(\Omega, \mathcal{A})$   $\stackrel{\text{def}}{=} \Leftrightarrow$  Für jede finite Partition  $(A_1, \dots, A_m)$  von  $\Omega$  mit  $A_j \in \mathcal{A}$  ist der Zufallsvektor  $(G(A_1), \dots, G(A_m))$  dirichlet-verteilt mit

$$(G(A_1), \dots, G(A_m)) \sim \text{Diri}(\alpha_0 G_0(A_1), \dots, \alpha_0 G_0(A_m)),$$

kurz:

$$G \sim \text{DP}(\alpha_0, G_0).$$

$G_0$  heißt Basis-Verteilung (base measure),  $\alpha_0$  heißt Präzisionsparameter und bestimmt die Varianz um  $\mathbb{E}(G)$ .

## Konjugiertheit des DP

Sei  $G \sim \text{DP}(\alpha_0, G_0)$  und  $\theta_1, \dots, \theta_n \mid G \stackrel{\text{i.i.d.}}{\sim} G$ . Dann ist die Posteriori

$$G \mid \theta_1, \dots, \theta_n \sim \text{DP}\left(\alpha_0 + n, \frac{\alpha_0}{\alpha_0 + n} G_0 + \frac{1}{\alpha_0 + n} \sum_{i=1}^n \delta_{\theta_i}\right).$$

## Polya-Urnen-Repräsentation eines DP

Die a posteriori prädiktive Verteilung lautet

$$\theta_n \mid \theta_1, \dots, \theta_{n-1}, \alpha_0, G_0 \sim \frac{\alpha_0}{n-1+\alpha_0} G_0 + \frac{1}{n-1+\alpha_0} \sum_{j=1}^{n-1} \delta_{\theta_j}.$$

## Steckerlbruch-Repräsentation eines DP

$$G(A) = \sum_{k=1}^{\infty} \pi_k \delta_{\phi_k}(A) \quad \text{mit} \quad \phi_k \stackrel{\text{i.i.d.}}{\sim} G_0$$

für beliebiges  $A \in \mathcal{A}$  und

$$\pi_k = \beta_k \prod_{j=1}^{k-1} (1 - \beta_j) \quad \text{mit} \quad \beta_j \stackrel{\text{i.i.d.}}{\sim} \text{Beta}(1, \alpha_0).$$

Dabei gilt  $\sum_{k=1}^{\infty} \pi_k = 1$  sowie  $\pi_1 = \beta_1$

## Trunkierter Dirichlet-Prozess (TDP)

$$G_T(\cdot) = \sum_{k=1}^T \pi_k \delta_{\phi_k}(\cdot), \quad \pi_T := 1 - \sum_{k=1}^{T-1} \pi_k$$

## DP-Mischungen (DPM)

- $\theta_i$  ist latenter, mit Datenpunkt  $x_i$  assoziierter Parameter.
- Der (trunkierte) DP wird benutzt, um eine Priori für die  $\theta_i$  zu konstruieren

$$f(x_i) = \sum_{k=1}^d \pi_k \phi(x_i \mid \underbrace{\mu_k, \sigma_k^2}_{\theta_k})$$

- Formalisiert:

$$\begin{aligned} x_i \mid \theta_i &\stackrel{\text{i.i.d.}}{\sim} f(x_i \mid \theta_i) && \text{(bzw. } \stackrel{\text{i.i.d.}}{\sim} F(x_i \mid \theta_i)) \\ \theta_i \mid G &\stackrel{\text{i.i.d.}}{\sim} G \\ G &\sim (\text{T})\text{DP}(\alpha_0, G_0) \end{aligned}$$

für  $i = 1, \dots, n$

**Bayes-Inferenz mit DPM-Priori**

- *Allgemeines hierarchisches Modell:*

$$\begin{aligned} x_i | \theta_i, \delta &\stackrel{\text{i.i.d.}}{\sim} f(x_i | \theta_i, \delta), & i = 1, \dots, n \\ \theta_i | G_{(T)} &\stackrel{\text{i.i.d.}}{\sim} G_{(T)} \\ \delta &\sim p(\delta) & \delta \text{ endlich-dimensionaler Parameter} \\ G_{(T)} &\sim (T)\text{DP}(\alpha_0, G_0) \end{aligned}$$

- *Wahl von  $f$ :*

1.  $x_i | \theta_i, \delta \stackrel{\text{i.i.d.}}{\sim} N(\mu_i, \tau)$
2.  $x_i | \theta_i \stackrel{\text{i.i.d.}}{\sim} N(\mu_i, \tau_i), \theta_i = (\mu_i, \tau_i)$
3.  $\mathbf{x}_i | \theta_i \stackrel{\text{i.i.d.}}{\sim} \text{MVN}(\boldsymbol{\mu}_i, \boldsymbol{\Sigma})$
4.  $\mathbf{x}_i | \theta_i \stackrel{\text{i.i.d.}}{\sim} \text{MVN}(\boldsymbol{\mu}_i, \boldsymbol{\Sigma}_i)$

- *Repräsentation von  $(T)\text{DP}$  durch  $(T)\text{SB}$ :*

$$G_T(\cdot) = \sum_{k=1}^T \pi_k \delta_{\phi_k}(\cdot), \quad \phi_k \stackrel{\text{i.i.d.}}{\sim} G_0$$

Dabei ist  $\boldsymbol{\pi} = (\pi_1, \dots, \pi_T)$  ein trunkierter SB-Prozess:

$$\begin{aligned} \pi_1 &= \beta_1 \\ \pi_k &= (1 - \beta_1)(1 - \beta_2) \cdots (1 - \beta_{k-1})\beta_k \quad \text{für } k = 2, \dots, T-1 \\ \pi_T &= 1 - \pi_1 - \cdots - \pi_{T-1} \end{aligned}$$

und

$$\beta_1, \dots, \beta_{T-1} \stackrel{\text{i.i.d.}}{\sim} \text{Beta}(1, \alpha_0).$$

**Glättung und semiparametrische Regression****Glättung für normalverteilte Zeitreihen**

Betrachte die Zeitreihe  $\mathbf{y} = (y_1, \dots, y_t, \dots, y_n)^\top$  mit glattem Trend  $\boldsymbol{\gamma} = (\gamma_1, \dots, \gamma_n)^\top$ .

- **Klassische Glättung**

Modell:

$$y_t = \gamma_t + \varepsilon_t, \quad t = 1, \dots, n$$

Differenzen erster und  $d$ -ter Ordnung:

$$\Delta^1 \gamma_t = \gamma_t - \gamma_{t-1}, \quad \Delta^d \gamma_t = \Delta^{d-1} \gamma_t - \Delta^{d-1} \gamma_{t-1}, \quad d = 2, 3, \dots$$

Differenzenmatrizen:

$$\mathbf{D}_1^{(n)} = \begin{pmatrix} -1 & 1 & & 0 \\ & \ddots & \ddots & \\ 0 & & -1 & 1 \end{pmatrix} \in \mathbb{R}^{(n-1) \times n}, \quad \mathbf{D}_d^{(n)} = \mathbf{D}_{d-1}^{(n-1)} \mathbf{D}_1^{(n)} \in \mathbb{R}^{(n-d) \times n}$$

Strafmatrizen:

$$\mathbf{K}_d = \mathbf{D}_d^{(n)\top} \mathbf{D}_d^{(n)} \in \mathbb{R}^{n \times n}, \quad \text{rg}(\mathbf{K}_d) = n - d$$

Straffunktion:

$$\text{pen}(\boldsymbol{\gamma}) = \sum_{t=d+1}^n (\Delta^d \gamma_t)^2 = \boldsymbol{\gamma}^\top \mathbf{K}_d \boldsymbol{\gamma}$$

Penalisiertes KQ-Kriterium:

$$\text{PKQ}(\boldsymbol{\gamma}) = (\mathbf{y} - \boldsymbol{\gamma})^\top (\mathbf{y} - \boldsymbol{\gamma}) + \lambda \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}$$

Penalisierter KQ-Schätzer:

$$\hat{\boldsymbol{\gamma}}_{\text{PKQ}} = (\mathbf{I} + \lambda \mathbf{K})^{-1} \mathbf{y}$$

- **Bayesianische Glättung**

Likelihood:

$$f(\mathbf{y}|\boldsymbol{\gamma}) \sim N(\boldsymbol{\gamma}, \sigma^2 \mathbf{I})$$

Glattheits-Priori:

$$p(\boldsymbol{\gamma}) \propto (\tau^2)^{-\text{rg}(\mathbf{K})/2} \exp\left(-\frac{1}{2\tau^2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}\right)$$

Posteriori-Erwartungswert:

$$\mathbb{E}(\boldsymbol{\gamma}|\mathbf{y}) = \hat{\boldsymbol{\gamma}}_{\text{PKQ}} \quad \text{mit} \quad \lambda := \frac{\sigma^2}{\tau^2}$$

### Glättung für nicht-normalverteilte Zeitreihen

Sei  $y_t|\gamma_t \sim$  einfache Exponentialfamilie.

- **Klassische Glättung**

Penalisierte log-Likelihood:

$$l_{\text{pen}}(\boldsymbol{\gamma}) = l(\boldsymbol{\gamma}) - \frac{\lambda}{2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}$$

- **Bayesianische Glättung**

Likelihood:

$$f(\mathbf{y}|\boldsymbol{\gamma}) = \prod_{t=1}^n f(y_t|\gamma_t)$$

Glattheits-Priori:

$$p(\boldsymbol{\gamma}) \propto (\tau^2)^{-\text{rg}(\mathbf{K})/2} \exp\left(-\frac{1}{2\tau^2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}\right)$$

Posteriori-Modus:

$$\underset{\boldsymbol{\gamma}}{\text{argmax}} \left( \log f(\mathbf{y}|\boldsymbol{\gamma}) + \log p(\boldsymbol{\gamma}) \right) = \underset{\boldsymbol{\gamma}}{\text{argmax}} \left( l(\boldsymbol{\gamma}) - \frac{1}{2\tau^2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma} \right) = \underset{\boldsymbol{\gamma}}{\text{argmax}} l_{\text{pen}}(\boldsymbol{\gamma}) \quad \text{mit} \quad \lambda := \frac{1}{\tau^2}$$

### P-Splines

**Definition** (Spline-Funktionen, Polynom-Splines). Eine Funktion  $f : [a, b] \rightarrow \mathbb{R}$  heißt (Polynom-) Spline vom Grad  $l \geq 0$  zu den Knoten  $a \leq \kappa_0 < \kappa_1 < \dots < \kappa_{M-1} < \kappa_M \leq b$   $\stackrel{\text{def}}{\Leftrightarrow}$

1.  $f(x)$  ist  $(l-1)$ -mal stetig differenzierbar,
2.  $f(x)$  ist ein Polynom vom Grad  $l$  für  $x \in [\kappa_m, \kappa_{m+1})$ ,  $m = 0, \dots, M-1$ .

**Definition** (Trunkierte-Potenz- (truncated power, TP-) Basis).  $\{B_1^{(l)}(x), \dots, B_K^{(l)}(x)\}$  ist TP-Basis vom Grad  $l$   $\stackrel{\text{def}}{\Leftrightarrow}$

$$B_1^{(l)}(x) = 1, B_2^{(l)}(x) = x, \dots, B_{l+1}^{(l)}(x) = x^l$$

$$B_{l+2}^{(l)}(x) = (x - \kappa_1)_+^l, \dots, B_K^{(l)}(x) = (x - \kappa_{M-1})_+^l$$

mit

$$(x - \kappa_k)_+^l = \begin{cases} (x - \kappa_k)^l & \text{für } x \geq \kappa_k \\ 0 & \text{sonst.} \end{cases}$$

**Definition** (B-Spline-Basis).  $\{B_1^{(l)}(x), \dots, B_K^{(l)}(x)\}$  ist B-Spline-Basis vom Grad  $l \stackrel{\text{def}}{\iff}$

1. Jede Basisfunktion ist stückweises,  $(l-1)$ -mal stetig differenzierbares, nichtnegatives Polynom vom Grad  $l$  über  $l-2$  benachbarten Knotenpunkten, sonst ist  $B_k(x) = 0$ .
2. Die Basisfunktionen sind so normiert, dass

$$\sum_{k=1}^K B_k^{(l)}(x) = 1 \quad \text{für alle } x.$$

### P-Spline-Schätzung bei normalverteilten Zielvariablen

Betrachte  $y_i = f(x_i) + \varepsilon_i$  mit unabhängigen  $\varepsilon_i \sim N(0, \sigma^2)$ ,  $i = 1, \dots, n$ , mit  $f(x)$  approximiert durch

$$f(x) = \sum_{k=1}^K \gamma_k B_k(x), \quad \{B_k(x)\} \text{ eine Spline-Basis.}$$

Dies führt zum linearen Modell

$$\mathbf{y} = \mathbf{Z}\boldsymbol{\gamma} + \boldsymbol{\varepsilon}, \quad \boldsymbol{\varepsilon} \sim N(\mathbf{0}, \sigma^2 \mathbf{I})$$

mit Designmatrix

$$\mathbf{Z} = \begin{pmatrix} B_1(x_1) & \cdots & B_K(x_1) \\ \vdots & \ddots & \vdots \\ B_1(x_n) & \cdots & B_K(x_n) \end{pmatrix}.$$

#### • Klassische Glättung

Wahl der Penalisierung:

– Bei TP-Basis:

$$\text{pen}(\boldsymbol{\gamma}) = \sum_{k=l+2}^K \gamma_k^2 = \boldsymbol{\gamma}^\top \tilde{\mathbf{K}} \boldsymbol{\gamma}$$

$$\tilde{\mathbf{K}} = \text{diag}(\mathbf{0}_{l+1}, \mathbf{1}_{M-l}) = \begin{bmatrix} 0 & & & & 0 \\ & \ddots & & & \\ & & 0 & & \\ & & & 1 & \\ 0 & & & & \ddots & \\ & & & & & 1 \end{bmatrix}$$

$$\hat{\boldsymbol{\gamma}} = \underset{\boldsymbol{\gamma}}{\text{argmin}} \text{PKQ}(\boldsymbol{\gamma}) = (\mathbf{Z}^\top \mathbf{Z} + \lambda \tilde{\mathbf{K}})^{-1} \mathbf{Z}^\top \mathbf{y}$$

– Bei B-Spline-Basis:

$$\text{pen}(\boldsymbol{\gamma}) = \sum_{k=d+1}^K (\Delta^d \gamma_k)^2$$

$$\hat{\boldsymbol{\gamma}} = (\mathbf{Z}^\top \mathbf{Z} + \lambda \mathbf{K})^{-1} \mathbf{Z}^\top \mathbf{y}$$

#### • Bayesianische Glättung

Likelihood:

$$\mathbf{y} | \boldsymbol{\gamma} \sim N(\mathbf{Z}\boldsymbol{\gamma}, \sigma^2 \mathbf{I})$$

Priorverteilungen:

– Bei TP-Basis:

$$p(\gamma_k) \propto \text{const (oder schwach informativ)}, \quad k = 1, \dots, l+1,$$

$$\gamma_k \stackrel{i.i.d.}{\sim} N(0, \tau^2), \quad k = l+2, \dots, K$$

– Bei B-Spline-Basis:

$$p(\boldsymbol{\gamma}) \propto (\tau^2)^{-\text{rg}(\mathbf{K})/2} \exp\left(-\frac{1}{2\tau^2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}\right)$$

Posterioriverteilung:

$$\boldsymbol{\gamma} | \mathbf{y} \sim N(\boldsymbol{\mu}_\boldsymbol{\gamma}, \boldsymbol{\Sigma}_\boldsymbol{\gamma})$$

$$\boldsymbol{\mu}_\boldsymbol{\gamma} = \mathbb{E}(\boldsymbol{\gamma} | \mathbf{y}) = \left(\mathbf{Z}^\top \mathbf{Z} + \frac{\sigma^2}{\tau^2} \mathbf{K}\right)^{-1} \mathbf{Z}^\top \mathbf{y} \quad \text{und} \quad \boldsymbol{\Sigma}_\boldsymbol{\gamma} = \text{Cov}(\boldsymbol{\gamma} | \mathbf{y}) = \sigma^2 \left(\mathbf{Z}^\top \mathbf{Z} + \frac{\sigma^2}{\tau^2} \mathbf{K}\right)^{-1}$$

### P-Spline-Schätzung bei nicht-normalverteilten Zielvariablen

Sei  $y|f \sim$  einfache Exponentialfamilie:

$$\mathbb{E}(y|f(x)) = h(f(x))$$

$$f(x) = \sum \gamma_k B_k(x) \quad \text{bzw.} \quad \mathbf{f} = \mathbf{Z} \boldsymbol{\gamma}$$

- **Klassische Glättung**

$$l_{\text{pen}}(\boldsymbol{\gamma}) = l(\boldsymbol{\gamma}) - \frac{\lambda}{2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}$$

$$\mathbf{s}_{\text{pen}}(\boldsymbol{\gamma}) = \mathbf{s}(\boldsymbol{\gamma}) - \lambda \mathbf{K} \boldsymbol{\gamma}$$

$$\mathbf{F}_{\text{pen}}(\boldsymbol{\gamma}) = \mathbf{F}(\boldsymbol{\gamma}) + \lambda \mathbf{K}$$

- **Bayesianische Glättung**

Das Beobachtungsmodell  $f(y|\boldsymbol{\gamma})$  ist durch den GLM-Typ definiert. Bei voller Bayes-Inferenz wählt man a priori  $\tau^2 \sim \text{IG}(a, b)$  für  $\lambda = \frac{1}{\tau^2}$ . Voll bedingte Dichten:

$$f(\boldsymbol{\gamma} | \tau^2, \mathbf{y}) \propto \prod_{i=1}^n \exp\left(\frac{y_i \theta_i - b(\theta_i)}{\phi}\right) \exp\left(-\frac{1}{2\tau^2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}\right)$$

$$\tau^2 | \boldsymbol{\gamma}, \mathbf{y} \sim \text{IG}\left(a + \frac{\text{rg}(\mathbf{K})}{2}, b + \frac{1}{2} \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}\right)$$

### Glättungs-Splines (Smoothing-Splines)

**Definition** (Natürliche Splines). Eine Funktion  $f$  ist ein natürlicher (kubischer) Spline zu den Knoten  $a < \kappa_1 < \dots < \kappa_m < b \stackrel{\text{def}}{\iff}$

1.  $f(x)$  ist (kubischer) Polynom-Spline zur obigen Knotenmenge.
2.  $f(x)$  genügt  $f''(a) = f''(b) = 0$ , d.h.  $f(x)$  ist linear in den Intervallen  $[a, \kappa_1]$  und  $[\kappa_m, b]$ .

Modell:

$$y_i = f(x_i) + \varepsilon_i \quad \text{mit unabhängigen} \quad \varepsilon_i \sim (0, \sigma^2)$$

bzw.

$$\mathbf{y} = \mathbf{Z} \boldsymbol{\gamma} + \boldsymbol{\varepsilon}$$

Gesucht:

$$\hat{f} = \underset{f \in C^2}{\text{argmin}} \text{PKQ}(f)$$

Penalisiertes KQ-Kriterium:

$$\text{PKQ}(f) = \sum_{i=1}^n (y_i - f(x_i))^2 + \lambda \int (f''(x))^2 dx$$

Straffunktion:

$$\text{pen}(\boldsymbol{\gamma}) = \int (f''(z))^2 dz = \sum_{j=1}^K \sum_{k=1}^K \gamma_j \gamma_k \int B_j''(z) B_k''(z) dz = \boldsymbol{\gamma}^\top \mathbf{K} \boldsymbol{\gamma}$$

mit

$$\mathbf{K} = (K_{jk}) \quad \text{und} \quad K_{jk} = \int B_j''(z) B_k''(z) dz$$

## Strukturiert additive Modelle

### AM und GAM

- Gegeben:
  - Response  $y_i$ ,  $i = 1, \dots, n$  aus Normalverteilung (additives Modell) oder einfacher Exponentialfamilie (generalisiertes additives Modell)
  - Kovariablen  $\mathbf{x}_i = (x_{i1}, \dots, x_{ip})'$  mit linearem Einfluss
  - Kovariablen  $z_{i1}, \dots, z_{iq}$  mit nonparametrisch modelliertem Einfluss
- **Additives Modell:**

$$y_i = \mathbf{x}_i' \boldsymbol{\beta} + f_1(z_{i1}) + \dots + f_q(z_{iq}) + \varepsilon_i = \eta_i + \varepsilon_i, \quad \varepsilon_i \stackrel{\text{iid}}{\sim} N(0, \sigma^2).$$

- **Generalisiertes additives Modell:**

$$\begin{aligned} \mathbb{E}(y_i | \eta_i) &= \mu_i = h(\eta_i), \\ \eta_i &= \mathbf{x}_i' \boldsymbol{\beta} + f_1(z_{i1}) + \dots + f_q(z_{iq}). \end{aligned}$$

### Modelle mit variierenden Koeffizienten

- Gegeben:
  - Response  $y_i$
  - Kovariablen  $\mathbf{x}_i$  mit linearem Effekt
  - Kovariablen  $z_{i1}, \dots, z_{iq}$  mit nonparametrischem Effekt
  - Kovariablen  $u_{i1}, \dots, u_{iq}$ , deren Effekt mit  $z$  variiert
  - ansonsten selbe Struktur wie (G)AM
- **Modell mit variierenden Koeffizienten (VCM):**

$$\eta_i^{VCM} = \mathbf{x}_i' \boldsymbol{\beta} + u_{i1} f_1(z_{i1}) + \dots + u_{iq} f_q(z_{iq}).$$

- ein (G)AM erhält man als Spezialfall mit  $u_1 = u_2 = \dots = u_q = 1$

## 8 Modellwahl

### AIC

- Wahres Modell:

$$f_{\text{wahr}}(\mathbf{y})$$

- Approximierende Modellklasse:

$$f(\mathbf{y} | \boldsymbol{\theta})$$

#### AIC Kriterium:

$$\text{AIC} = -2 \log(f(\mathbf{y} | \hat{\boldsymbol{\theta}}_{ML})) + 2 \dim(\hat{\boldsymbol{\theta}}_{ML}).$$

### BIC

- Gegeben: Daten  $\mathbf{y}$ , Likelihood  $f(\mathbf{y} | \boldsymbol{\theta})$  und Priori  $p(\boldsymbol{\theta})$ .
- Modellwahl mit BIC entspricht Modellwahl basierend auf marginaler Likelihood  $f(\mathbf{y})$ :

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

- Approximation:

$$\log(f(\mathbf{y})) \approx \log(f(\mathbf{y} | \hat{\boldsymbol{\theta}}_{ML})) - \frac{1}{2} \log(n) \cdot \dim(\hat{\boldsymbol{\theta}}_{ML}).$$

#### BIC Kriterium:

$$\text{BIC} = -2 \log(f(\mathbf{y} | \hat{\boldsymbol{\theta}}_{ML})) + \log(n) \cdot \dim(\hat{\boldsymbol{\theta}}_{ML})$$

## DIC

- Gegeben: (burn-in-bereinigtes) MCMC-Sample  $\boldsymbol{\theta}_1, \dots, \boldsymbol{\theta}_L$ .
- unstandardisierte Devianz:  $D(\boldsymbol{\theta}) = -2 \log(f(\mathbf{y}|\boldsymbol{\theta}))$
- Komplexitätsmaß:  $p_D = \overline{D(\boldsymbol{\theta})} - D(\bar{\boldsymbol{\theta}})$

### DIC Kriterium:

$$\text{DIC} = D(\bar{\boldsymbol{\theta}}) + 2p_D = -2 \log(f(\mathbf{y}|\bar{\boldsymbol{\theta}})) + 2p_D,$$

wobei  $D(\bar{\boldsymbol{\theta}})$  die Devianz am geschätzten Posteriori-Erwartungswert bezeichnet und  $\overline{D(\boldsymbol{\theta})}$  die mittlere Devianz über das MCMC-Sample.

## Bayes-Faktoren

- Gegeben: 2 Modelle, bezeichnet mit  $M_k$  und  $M_l$ , mit jeweiligen Parametervektoren  $\boldsymbol{\theta}_k$  und  $\boldsymbol{\theta}_l$ .
- Vergleich zwischen  $M_k$  und  $M_l$  basierend auf marginaler Likelihood:

$$p(\mathbf{y}|M_k) = \int p(\mathbf{y}|\boldsymbol{\theta}_k, M_k)p(\boldsymbol{\theta}_k|M_k)d\boldsymbol{\theta}_k,$$

analog für  $M_l$ .

**Bayes-Faktor** zugunsten von  $M_k$ :

$$B_{kl} = \frac{p(\mathbf{y}|M_k)}{p(\mathbf{y}|M_l)}$$