

**week11b: Kapitel 7: Effizienz von Schätzern, Teil 2**  
**Beweis der Cramer-Rao Abschätzung**

In der letzten Veranstaltung haben wir das folgende Setting betrachtet: Wir haben Zufallszahlen oder zufällige Größen  $x_1, x_2, \dots, x_n$ , die von einer Wahrscheinlichkeitsverteilung

$$p_\theta(x) = p_{\theta_1, \dots, \theta_m}(x_1, \dots, x_n)$$

generiert worden sind. Es gelte also

$$\int_{\mathbb{R}^n} p_\theta(x) d^n x = \int_{\mathbb{R}^n} p_{\theta_1, \dots, \theta_m}(x_1, \dots, x_n) dx_1 dx_2 \dots dx_n = 1$$

Die theta's  $\theta_1, \dots, \theta_m$  sind die Modellparameter. Wenn wir das  $p_\theta(x)$  nur als Funktion von  $\theta$  auffassen, weil wir für die  $x_1, \dots, x_n$  die uns gegebenen realisierten Daten einsetzen, dann ist das genau die Likelihood-Funktion,

$$L(\theta) = L(\theta_1, \dots, \theta_m) = p_{\theta_1, \dots, \theta_m}(x_1, \dots, x_n)$$

Wir hatten das  $p_\theta(x)$  für die 3 Beispiele aus dem Kapitel 5 noch einmal hingeschrieben und in allen 3 Beispielen konnten wir Ableitungen nach den Modellparametern mit den Integralen oder den Summen über die  $x_i$  vertauschen. Das ist nicht immer ganz selbstverständlich, da man etwa bei gleichverteilten Zufallszahlen ja eine Rechteck-Funktion als W'keitsdichte hat, die im klassischen Sinne nicht differenzierbar ist, und solche Fälle hatten wir ausgeschlossen. Die Cramer-Rao Abschätzung war dann:

**Theorem 7.1.2 (Cramer-Rao Lower Bound):** Gegeben sei eine Wahrscheinlichkeitsverteilung  $p_\theta(x) = p_{\theta_1, \dots, \theta_m}(x_1, \dots, x_n)$  mit

$$\int_{\mathbb{R}^n} p_\theta(x) d^n x = \int_{\mathbb{R}^n} p_{\theta_1, \dots, \theta_m}(x_1, \dots, x_n) dx_1 dx_2 \dots dx_n = 1$$

und Ableitungen nach den Modellparametern  $\theta_1, \dots, \theta_m$  seien vertauschbar mit den  $x$ -Integralen. Für  $k = 1, \dots, m$  seien

$$\hat{\theta} = \begin{pmatrix} \hat{\theta}_1 \\ \vdots \\ \hat{\theta}_m \end{pmatrix} : \mathbb{R}^n \rightarrow \mathbb{R}^m$$

erwartungstreue Schätzer, d.h. es gilt

$$E[\hat{\theta}_k] := \int_{\mathbb{R}^n} \hat{\theta}_k(x) p_\theta(x) d^n x = \theta_k$$

Weiter sei

$$\text{Cov}(\hat{\theta}) := \left( \text{Cov}[\hat{\theta}_k, \hat{\theta}_\ell] \right)_{k,\ell=1,\dots,m} \in \mathbb{R}^{m \times m}$$

die Kovarianz-Matrix von  $\hat{\theta}$ , insbesondere also

$$\mathbf{V}[\hat{\theta}_k] = \text{Cov}(\hat{\theta})_{k,k}$$

Wir definieren die sogenannte Fisher-Informationsmatrix  $I(\theta)$  durch

$$I(\theta) := \left( -\mathbb{E} \left[ \frac{\partial^2 \log p_\theta}{\partial \theta_k \partial \theta_\ell} \right] \right)_{k,\ell=1,\dots,m} \in \mathbb{R}^{m \times m}$$

mit

$$\mathbb{E} \left[ \frac{\partial^2 \log p_\theta}{\partial \theta_k \partial \theta_\ell} \right] := \int_{\mathbb{R}^n} \frac{\partial^2 \log p_\theta}{\partial \theta_k \partial \theta_\ell} (x_1, \dots, x_n) p_\theta(x_1, \dots, x_n) d^n x$$

und  $I^{-1}(\theta)$  sei das Inverse von  $I(\theta)$ . Dann gilt:

$$\langle v, \text{Cov}(\hat{\theta}) v \rangle \geq \langle v, I^{-1}(\theta) v \rangle \quad \forall v \in \mathbb{R}^m$$

Insbesondere,

$$\mathbf{V}[\hat{\theta}_k] \geq [I^{-1}(\theta)]_{k,k}$$

für jeden erwartungstreuen Schätzer  $\hat{\theta}_k : \mathbb{R}^n \rightarrow \mathbb{R}$ .

**Beweis:** Für  $1 \leq k, \ell \leq m$  betrachten wir das Integral

$$\begin{aligned} \int_{\mathbb{R}^n} \{ \hat{\theta}_k(x) - \theta_k \} \frac{\partial \log p_\theta}{\partial \theta_\ell} p_\theta(x) d^n x &= \int_{\mathbb{R}^n} \{ \hat{\theta}_k(x) - \theta_k \} \frac{\partial p_\theta}{\partial \theta_\ell} d^n x \\ &= \int_{\mathbb{R}^n} \hat{\theta}_k(x) \frac{\partial p_\theta}{\partial \theta_\ell} d^n x - \int_{\mathbb{R}^n} \theta_k \frac{\partial p_\theta}{\partial \theta_\ell} d^n x \\ &= \frac{\partial}{\partial \theta_\ell} \int_{\mathbb{R}^n} \hat{\theta}_k(x) p_\theta(x) d^n x - \theta_k \frac{\partial}{\partial \theta_\ell} \int_{\mathbb{R}^n} p_\theta(x) d^n x \\ &= \frac{\partial}{\partial \theta_\ell} \theta_k - \theta_k \frac{\partial}{\partial \theta_\ell} 1 = \delta_{k,\ell} \end{aligned} \tag{1}$$

Es seien jetzt

$$v, w \in \mathbb{R}^m$$

beliebige Vektoren und etwa

$$\langle v, \hat{\theta} \rangle = \sum_{k=1}^m v_k \hat{\theta}_k$$

also  $\langle \cdot, \cdot \rangle$  bezeichnet das Standardskalarprodukt im  $\mathbb{R}^m$ . Dann folgt aus (1), wenn wir von links mit  $v$  und von rechts mit  $w$  skalar multiplizieren,

$$\int_{\mathbb{R}^n} \langle v, \hat{\theta}(x) - \theta \rangle \langle \nabla_{\theta} \log p_{\theta}(x), w \rangle p_{\theta}(x) d^n x = \langle v, w \rangle \quad (2)$$

Für beliebige Funktionen  $f, g : \mathbb{R}^n \rightarrow \mathbb{R}$ ,  $f = f(x)$  und  $g = g(x)$ , wird durch

$$(f, g) := \int_{\mathbb{R}^n} f(x) g(x) p_{\theta}(x) d^n x$$

ein Skalarprodukt auf der Menge der bezüglich  $p_{\theta}(x) d^n x$  quadratintegrablen Funktionen definiert und es gilt die Cauchy-Schwarz'sche Ungleichung,

$$\begin{aligned} \left| \int_{\mathbb{R}^n} f(x) g(x) p_{\theta}(x) d^n x \right|^2 &= |(f, g)|^2 \\ &\leq \|f\|^2 \|g\|^2 \\ &= \int_{\mathbb{R}^n} f(x)^2 p_{\theta}(x) d^n x \int_{\mathbb{R}^n} g(x)^2 p_{\theta}(x) d^n x \end{aligned} \quad (3)$$

Wir setzen jetzt

$$\begin{aligned} f(x) &:= \langle v, \hat{\theta}(x) - \theta \rangle \\ g(x) &:= \langle \nabla_{\theta} \log p_{\theta}(x), w \rangle \end{aligned}$$

und bekommen aus Gleichung (2) und der Cauchy-Schwarz'schen Ungleichung (3)

$$\begin{aligned} |\langle v, w \rangle|^2 &= \left| \int_{\mathbb{R}^n} \langle v, \hat{\theta}(x) - \theta \rangle \langle \nabla_{\theta} \log p_{\theta}(x), w \rangle p_{\theta}(x) d^n x \right|^2 \\ &\leq \int_{\mathbb{R}^n} |\langle v, \hat{\theta}(x) - \theta \rangle|^2 p_{\theta}(x) d^n x \\ &\quad \times \int_{\mathbb{R}^n} |\langle \nabla_{\theta} \log p_{\theta}(x), w \rangle|^2 p_{\theta}(x) d^n x \end{aligned} \quad (4)$$

Das erste Integral auf der rechten Seite von (4) können wir auch folgendermassen schreiben:

$$\begin{aligned} \int_{\mathbb{R}^n} |\langle v, \hat{\theta}(x) - \theta \rangle|^2 p_{\theta}(x) d^n x &= \sum_{k, \ell=1}^m v_k v_{\ell} \int_{\mathbb{R}^n} [\hat{\theta}_k(x) - \theta_k] [\hat{\theta}_{\ell}(x) - \theta_{\ell}] p_{\theta}(x) d^n x \\ &= \sum_{k, \ell=1}^m v_k v_{\ell} \text{Cov}[\hat{\theta}_k, \hat{\theta}_{\ell}] \\ &= \langle v, \text{Cov}(\hat{\theta}) v \rangle \end{aligned} \quad (5)$$

Und für das zweite Integral auf der rechten Seite von (4) erhalten wir

$$\int_{\mathbb{R}^n} |\langle \nabla_{\theta} \log p_{\theta}(x), w \rangle|^2 p_{\theta}(x) d^n x = \sum_{k, \ell=1}^m w_k w_{\ell} \int_{\mathbb{R}^n} \frac{\partial \log p_{\theta}}{\partial \theta_k} \frac{\partial \log p_{\theta}}{\partial \theta_{\ell}} p_{\theta}(x) d^n x \quad (6)$$

Das Integral auf der rechten Seite von (6) können wir etwas umformen: Wegen

$$\int_{\mathbb{R}^n} p_\theta(x) d^n x = 1$$

ist

$$\begin{aligned} 0 &= \frac{\partial}{\partial \theta_k} \int_{\mathbb{R}^n} p_\theta(x) d^n x = \int_{\mathbb{R}^n} \frac{\partial p_\theta}{\partial \theta_k}(x) d^n x \\ &= \int_{\mathbb{R}^n} \frac{\frac{\partial p_\theta}{\partial \theta_k}(x)}{p_\theta(x)} p_\theta(x) d^n x \\ &= \int_{\mathbb{R}^n} \frac{\partial \log p_\theta(x)}{\partial \theta_k} p_\theta(x) d^n x \end{aligned} \quad (7)$$

Diese Identität tun wir noch einmal nach  $\theta_\ell$  ableiten und bekommen

$$\begin{aligned} 0 &= \frac{\partial}{\partial \theta_\ell} \int_{\mathbb{R}^n} \frac{\partial \log p_\theta(x)}{\partial \theta_k} p_\theta(x) d^n x \\ &= \int_{\mathbb{R}^n} \frac{\partial^2 \log p_\theta(x)}{\partial \theta_\ell \partial \theta_k} p_\theta(x) d^n x + \int_{\mathbb{R}^n} \frac{\partial \log p_\theta(x)}{\partial \theta_k} \frac{\partial p_\theta}{\partial \theta_\ell}(x) d^n x \\ &= \int_{\mathbb{R}^n} \frac{\partial^2 \log p_\theta(x)}{\partial \theta_\ell \partial \theta_k} p_\theta(x) d^n x + \int_{\mathbb{R}^n} \frac{\partial \log p_\theta(x)}{\partial \theta_k} \frac{\partial \log p_\theta(x)}{\partial \theta_\ell} p_\theta(x) d^n x \end{aligned}$$

Also haben wir

$$\begin{aligned} \int_{\mathbb{R}^n} \frac{\partial \log p_\theta(x)}{\partial \theta_k} \frac{\partial \log p_\theta(x)}{\partial \theta_\ell} p_\theta(x) d^n x &= - \int_{\mathbb{R}^n} \frac{\partial^2 \log p_\theta(x)}{\partial \theta_\ell \partial \theta_k} p_\theta(x) d^n x \\ &= - \mathbb{E} \left[ \frac{\partial^2 \log p_\theta}{\partial \theta_\ell \partial \theta_k} \right] \\ &= + I(\theta)_{\ell,k} = + I(\theta)_{k,\ell} \end{aligned} \quad (8)$$

Das können wir auf der rechten Seite von (6) einsetzen und bekommen

$$\begin{aligned} \int_{\mathbb{R}^n} |\langle \nabla_\theta \log p_\theta(x), w \rangle|^2 p_\theta(x) d^n x &= \sum_{k,\ell=1}^m w_k w_\ell \int_{\mathbb{R}^n} \frac{\partial \log p_\theta}{\partial \theta_k} \frac{\partial \log p_\theta}{\partial \theta_\ell} p_\theta(x) d^n x \\ &= \sum_{k,\ell=1}^m w_k w_\ell I(\theta)_{k,\ell} \\ &= \langle w, I(\theta) w \rangle \end{aligned} \quad (9)$$

Insbesondere ist das  $I(\theta)$  und damit auch  $I^{-1}(\theta)$  eine positiv definite Matrix. Wir setzen (5)

und (9) auf der rechten Seite von (4) ein und bekommen

$$\begin{aligned} |\langle v, w \rangle|^2 &\leq \int_{\mathbb{R}^n} |\langle v, \hat{\theta}(x) - \theta \rangle|^2 p_\theta(x) d^n x \times \int_{\mathbb{R}^n} |\langle \nabla_\theta \log p_\theta(x), w \rangle|^2 p_\theta(x) d^n x \\ &= \langle v, \text{Cov}(\hat{\theta})v \rangle \times \langle w, I(\theta)w \rangle \end{aligned} \quad (10)$$

Wir wählen jetzt

$$w := I^{-1}(\theta)v$$

und erhalten aus (10)

$$|\langle v, I^{-1}(\theta)v \rangle|^2 \leq \langle v, \text{Cov}(\hat{\theta})v \rangle \times \langle I^{-1}(\theta)v, v \rangle \quad (11)$$

oder, mit  $\langle I^{-1}(\theta)v, v \rangle = \langle v, I^{-1}(\theta)v \rangle \geq 0$ ,

$$\langle v, I^{-1}(\theta)v \rangle \leq \langle v, \text{Cov}(\hat{\theta})v \rangle \quad (12)$$

Das aber genau war zu zeigen. ■