

week12a: Kapitel 7: Effizienz von Schätzern, Teil 3
Die Cramer-Rao Abschätzung für das Beispiel 3

Erinnern wir uns an das Beispiel 3, das war der zeitdiskrete Ornstein-Uhlenbeck Prozess oder kurz OU-Prozess:

Beispiel 3: Wir diskretisieren das Zeitintervall $[0, T]$ mit einem Δt gemäss

$$[0, T] \approx \{0, \Delta t, 2\Delta t, \dots, k\Delta t, \dots, N\Delta t\} =: \{t_0, t_1, t_2, \dots, t_k, \dots, t_n = T\}$$

mit $t_k = k\Delta t$ und $t_N = N\Delta t = T$ so dass $N = T/\Delta t$. Ein zeitdiskreter Ornstein-Uhlenbeck oder kurz OU-Prozess $\{x_{t_k}\}_{k=1}^N$ ist dann gegeben durch die Rekursion

$$x_{t_k} = x_{t_{k-1}} + \kappa(\mu - x_{t_{k-1}})\Delta t + \sigma\sqrt{\Delta t}\phi_k \quad (1)$$

mit standard-normalverteilten Zufallszahlen ϕ_k und einem deterministisch vorgegebenen Startwert $x_{t_0} = x_0$, etwa $x_0 = \mu$. Das ist dann äquivalent zu der folgenden stochastischen Rekursionsvorschrift

$$x_{t_k} = \alpha x_{t_{k-1}} + \beta + \eta\phi_k \quad (2)$$

wenn wir die Abkürzungen

$$\begin{aligned} \alpha &:= 1 - \kappa\Delta t \\ \beta &:= \kappa\mu\Delta t \\ \eta &:= \sigma\sqrt{\Delta t} \end{aligned} \quad (3)$$

benutzen. Die Likelihood-Funktion war gegeben durch

$$L(\alpha, \beta, \eta) = \frac{1}{(2\pi\eta^2)^{n/2}} \exp\left\{-\frac{1}{2\eta^2} \sum_{k=1}^n (x_{t_k} - [\alpha x_{t_{k-1}} + \beta])^2\right\} \prod_{k=1}^n dx_{t_k}$$

so dass das $p_\theta(x)$ in diesem Fall also durch (mit $x_k \equiv x_{t_k}$)

$$p_\theta(x) = p_{\alpha, \beta, \eta}(x_1, \dots, x_n) = \prod_{k=1}^n \left\{ \frac{1}{\sqrt{2\pi\eta^2}} e^{-\frac{(x_k - [\alpha x_{k-1} + \beta])^2}{2\eta^2}} \right\} \quad (4)$$

gegeben ist.

Die Maximum-Likelihood-Schätzer waren gegeben durch

$$\hat{\alpha}_{\text{ML}} = \frac{n \sum_{k=1}^n x_{t_{k-1}} x_{t_k} - \sum_{k=1}^n x_{t_{k-1}} \sum_{k=1}^n x_{t_k}}{n \sum_{k=1}^n x_{t_{k-1}}^2 - \left(\sum_{k=1}^n x_{t_{k-1}} \right)^2}$$

$$\hat{\beta}_{\text{ML}} = \frac{\sum_{k=1}^n x_{t_{k-1}}^2 \sum_{k=1}^n x_{t_k} - \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \sum_{k=1}^n x_{t_{k-1}}}{n \sum_{k=1}^n x_{t_{k-1}}^2 - \left(\sum_{k=1}^n x_{t_{k-1}} \right)^2}$$

und

$$\hat{\eta}_{\text{ML}}^2 = \frac{1}{n} \sum_{k=1}^n (x_{t_k} - [\hat{\alpha} x_{t_{k-1}} + \hat{\beta}])^2$$

mit denen dann gemäss

$$\begin{aligned} \kappa &= \frac{1-\alpha}{\Delta t} \\ \mu &= \frac{\beta}{1-\alpha} \\ \sigma^2 &= \frac{\eta^2}{\Delta t} \end{aligned} \tag{5}$$

die ursprünglichen Modell-Parameter (κ, μ, σ) geschätzt werden können.

In dem week9a.pdf hatten wir uns die empirischen, die simulierten Verteilungen von $\hat{\kappa}_{\text{ML}}$, $\hat{\mu}_{\text{ML}}$ und $\hat{\sigma}_{\text{ML}}^2$ angeschaut, das waren die Histogramme, und insbesondere festgestellt, dass die Streuungen der Verteilungen für $\hat{\kappa}_{\text{ML}}$ und $\hat{\mu}_{\text{ML}}$ für $n \rightarrow \infty$ nicht kleiner wurden, sondern das schien so mehr oder weniger gegen eine Grenzverteilung zu konvergieren. Die Schätzer sind nicht konsistent. Dieses Verhalten kann man nun mit Hilfe der Cramer-Rao Abschätzung etwas besser verstehen, und das wollen wir uns jetzt hier anschauen:

Die Cramer-Rao Abschätzung war gegeben durch

$$\mathbf{V}[\hat{\theta}_k] \geq [I^{-1}(\theta)]_{k,k} \tag{6}$$

mit der Fisher-Informationsmatrix

$$I(\theta) = \left(-\mathbf{E} \left[\frac{\partial^2 \log p_{\theta}}{\partial \theta_k \partial \theta_{\ell}} \right] \right)_{k,\ell=1,\dots,m} \in \mathbb{R}^{m \times m} \tag{7}$$

In unserem Fall ist $m = 3$ und

$$\theta = (\theta_1, \theta_2, \theta_3) = (\alpha, \beta, \eta^2) =: (\alpha, \beta, \nu)$$

Wir wollen das $I(\theta)$ berechnen. Anstelle von x_{t_k} schreiben wir für den Moment einfach nur x_k . Dann haben wir

$$\log p_{\theta} = -\frac{n}{2} \log(2\pi\nu) - \frac{1}{2\nu} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta)^2$$

mit den folgenden Ableitungen:

$$\begin{aligned}\frac{\partial \log p_\theta}{\partial \alpha} &= + \frac{1}{\nu} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta) x_{k-1} \\ \frac{\partial \log p_\theta}{\partial \beta} &= + \frac{1}{\nu} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta) \\ \frac{\partial \log p_\theta}{\partial \nu} &= - \frac{n}{2\nu} + \frac{1}{2\nu^2} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta)^2\end{aligned}$$

und

$$\begin{aligned}\frac{\partial^2 \log p_\theta}{\partial \alpha^2} &= - \frac{1}{\nu} \sum_{k=1}^n x_{k-1}^2 \\ \frac{\partial^2 \log p_\theta}{\partial \beta^2} &= - \frac{1}{\nu} \sum_{k=1}^n 1 = - \frac{n}{\nu} \\ \frac{\partial^2 \log p_\theta}{\partial \nu^2} &= + \frac{n}{2\nu^2} - \frac{1}{\nu^3} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta)^2\end{aligned}$$

und den off-diagonalen Termen

$$\begin{aligned}\frac{\partial^2 \log p_\theta}{\partial \beta \partial \alpha} &= - \frac{1}{\nu} \sum_{k=1}^n x_{k-1} \\ \frac{\partial^2 \log p_\theta}{\partial \nu \partial \alpha} &= - \frac{1}{\nu^2} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta) x_{k-1} \\ \frac{\partial^2 \log p_\theta}{\partial \nu \partial \beta} &= - \frac{1}{\nu^2} \sum_{k=1}^n (x_k - \alpha x_{k-1} - \beta)\end{aligned}$$

Wir müssen die Erwartungswerte von den zweiten Ableitungen berechnen. Aus der stochastischen Rekursionsgleichung des OU-Prozesses (2) bekommen wir

$$x_{t_k} - \alpha x_{t_{k-1}} - \beta = \eta \phi_k \quad (8)$$

mit standard-normalverteilten ϕ_k 's. Also

$$\mathbf{E}[x_k - \alpha x_{k-1} - \beta] = \mathbf{E}[\eta \phi_k] = 0$$

und wegen $x_{k-1} = x_{k-1}(\phi_{k-1}, \phi_{k-2}, \dots, \phi_1)$, also in dem x_{k-1} kommt kein ϕ_k drin vor, haben wir auch

$$\begin{aligned}\mathbf{E}[(x_k - \alpha x_{k-1} - \beta) x_{k-1}] &= \mathbf{E}[\eta \phi_k x_{k-1}] \\ &= \eta \mathbf{E}[\phi_k] \mathbf{E}[x_{k-1}] \\ &= \eta \times 0 \times \mathbf{E}[x_{k-1}] = 0\end{aligned}$$

Weiterhin,

$$\mathbb{E}[(x_k - \alpha x_{k-1} - \beta)^2] = \eta^2 \mathbb{E}[\phi_k^2] = \eta^2 = \nu$$

Damit bekommen wir also

$$\begin{aligned} \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \alpha^2}\right] &= -\frac{1}{\nu} \sum_{k=1}^n \mathbb{E}[x_{k-1}^2] \\ \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \beta^2}\right] &= -\frac{n}{\nu} \\ \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \nu^2}\right] &= +\frac{n}{2\nu^2} - \frac{1}{\nu^3} \sum_{k=1}^n \nu = -\frac{n}{2\nu^2} \end{aligned}$$

und die off-diagonalen Terme

$$\begin{aligned} \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \beta \partial \alpha}\right] &= -\frac{1}{\nu} \sum_{k=1}^n \mathbb{E}[x_{k-1}] \\ \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \nu \partial \alpha}\right] &= 0 \\ \mathbb{E}\left[\frac{\partial^2 \log p_\theta}{\partial \nu \partial \beta}\right] &= 0 \end{aligned}$$

Also,

$$\begin{aligned} I(\theta) &= \begin{pmatrix} \frac{1}{\nu} \sum_{k=1}^n \mathbb{E}[x_{k-1}^2] & \frac{1}{\nu} \sum_{k=1}^n \mathbb{E}[x_{k-1}] & 0 \\ \frac{1}{\nu} \sum_{k=1}^n \mathbb{E}[x_{k-1}] & \frac{n}{\nu} & 0 \\ 0 & 0 & \frac{n}{2\nu^2} \end{pmatrix} \\ &= \frac{n}{\nu} \begin{pmatrix} \frac{1}{n} \sum_{k=1}^n \mathbb{E}[x_{k-1}^2] & \frac{1}{n} \sum_{k=1}^n \mathbb{E}[x_{k-1}] & 0 \\ \frac{1}{n} \sum_{k=1}^n \mathbb{E}[x_{k-1}] & 1 & 0 \\ 0 & 0 & \frac{1}{2\nu} \end{pmatrix} \\ &=: \frac{n}{\nu} \begin{pmatrix} \langle x^2 \rangle & \langle x \rangle & 0 \\ \langle x \rangle & 1 & 0 \\ 0 & 0 & \frac{1}{2\nu} \end{pmatrix} \end{aligned} \quad (9)$$

mit den Grössen (es war $T = n\Delta t$)

$$\langle x^2 \rangle \equiv \langle x^2 \rangle_T := \frac{1}{n} \sum_{k=1}^n \mathbb{E}[x_{k-1}^2] = \frac{1}{n\Delta t} \sum_{k=1}^n \mathbb{E}[x_{t_{k-1}}^2] \Delta t \stackrel{\Delta t \rightarrow 0}{\approx} \frac{1}{T} \int_0^T \mathbb{E}[x_t^2] dt \quad (10)$$

und analog

$$\langle x \rangle \equiv \langle x \rangle_T := \frac{1}{n} \sum_{k=1}^n \mathbb{E}[x_{k-1}] = \frac{1}{n\Delta t} \sum_{k=1}^n \mathbb{E}[x_{t_{k-1}}] \Delta t \stackrel{\Delta t \rightarrow 0}{\approx} \frac{1}{T} \int_0^T \mathbb{E}[x_t] dt \quad (11)$$

Das Inverse von $I(\theta)$ ist jetzt kein Problem mehr,

$$I^{-1}(\theta) = \frac{\nu}{n} \begin{pmatrix} \frac{1}{\langle x^2 \rangle - \langle x \rangle^2} & -\frac{\langle x \rangle}{\langle x^2 \rangle - \langle x \rangle^2} & 0 \\ -\frac{\langle x \rangle}{\langle x^2 \rangle - \langle x \rangle^2} & \frac{\langle x^2 \rangle}{\langle x^2 \rangle - \langle x \rangle^2} & 0 \\ 0 & 0 & 2\nu \end{pmatrix} \quad (12)$$

und die Cramer-Rao Abschätzung liefert dann die folgenden unteren Schranken für alle erwartungstreuen Schätzer $\hat{\alpha}$, $\hat{\beta}$ und $\hat{\nu}$:

$$\mathbf{V}[\hat{\alpha}] \geq \frac{\nu}{n} \frac{1}{\langle x^2 \rangle - \langle x \rangle^2} \quad (13)$$

$$\mathbf{V}[\hat{\beta}] \geq \frac{\nu}{n} \frac{\langle x^2 \rangle}{\langle x^2 \rangle - \langle x \rangle^2} \quad (14)$$

$$\mathbf{V}[\hat{\nu}] \geq \frac{2\nu^2}{n} \quad (15)$$

Die Grössen $\langle x^2 \rangle$ und $\langle x \rangle^2$ berechnen wir in dem folgenden Lemma:

Lemma 7.3.1: Die $\{x_{t_k}\}_{k=1}^n$ seien gegeben durch einen zeitdiskreten OU-Prozess (1) oder (2) mit $T = n\Delta t$ und die Grössen $\langle x \rangle_T$ und $\langle x^2 \rangle_T$ seien definiert durch (10) und (11) weiter oben. Der Startwert x_0 des OU-Prozesses sei gegeben durch den Mean Reversion Level μ , also $x_{t_0} := \mu$. Dann gilt im Limes $\Delta t \rightarrow 0$:

$$\langle x \rangle_T = \mu \quad (16)$$

$$\langle x^2 \rangle_T \stackrel{\Delta t \rightarrow 0}{\approx} \mu^2 + \frac{\sigma^2}{2\kappa} \frac{2\kappa T - 1 + e^{-2\kappa T}}{2\kappa T} \quad (17)$$

Insbesondere,

$$\langle x^2 \rangle_T - \langle x \rangle_T^2 \stackrel{\Delta t \rightarrow 0}{\approx} \frac{\sigma^2}{2\kappa} \frac{2\kappa T - 1 + e^{-2\kappa T}}{2\kappa T} \quad (18)$$

Beweis: ..machen wir am Donnerstag. ■

Jetzt schauen wir uns die Schätzer für die ‘ursprünglichen’ Modellparameter (κ, μ, σ) an. Der Zusammenhang zu den ‘abgeleiteten’ Modellparametern $(\alpha, \beta, \nu = \eta^2)$ war gegeben durch (5), das waren die Gleichungen

$$\begin{aligned} \kappa &= \frac{1-\alpha}{\Delta t} \\ \mu &= \frac{\beta}{1-\alpha} \\ \sigma^2 &= \frac{\nu}{\Delta t} \end{aligned}$$

‘Ursprünglich’ meint hier, dass diese Parameter unabhängig von der Zeitdiskretisierung Δt sind und die abgeleiteten Modellparameter hängen dann also von dem Δt ab. Wenn wir also das κ mit

$$\hat{\kappa} = \frac{1}{\Delta t} (1 - \hat{\alpha}) \quad (19)$$

mit einem erwartungstreuen $\hat{\alpha}$ schätzen, dann bekommen wir notwendigerweise

$$\begin{aligned}
\mathbb{V}[\hat{\kappa}] &= \mathbb{V}\left[\frac{1}{\Delta t}(1 - \hat{\alpha})\right] \\
&= \frac{1}{(\Delta t)^2} \times \mathbb{V}[1 - \hat{\alpha}] \\
&= \frac{1}{(\Delta t)^2} \times \mathbb{V}[\hat{\alpha}] \\
&\stackrel{\text{Cramer-Rao (13)}}{\geq} \frac{1}{(\Delta t)^2} \times \frac{\nu}{n} \frac{1}{\langle x^2 \rangle - \langle x \rangle^2} \\
&= \frac{1}{(\Delta t)^2} \times \frac{\sigma^2 \Delta t}{n} \times \frac{1}{\langle x^2 \rangle - \langle x \rangle^2} \\
&= \frac{\sigma^2}{T} \times \frac{1}{\langle x^2 \rangle - \langle x \rangle^2} \\
&\stackrel{\Delta t \rightarrow 0}{=} \frac{\sigma^2}{T} \times \frac{1}{\frac{\sigma^2}{2\kappa} \frac{2\kappa T - 1 + e^{-2\kappa T}}{2\kappa T}} \\
&= \frac{4\kappa^2}{2\kappa T - 1 + e^{-2\kappa T}} \tag{20}
\end{aligned}$$

und dieser Ausdruck geht also nicht nach 0 auch wenn das $\Delta t \rightarrow 0$ geht und das $n = T/\Delta t \rightarrow \infty$ geht. Ein erwartungstreuer Schätzer für das κ kann also erst im Limes $T \rightarrow \infty$ konsistent werden, erst im Limes grosser T kann seine Varianz beliebig klein gemacht werden. Für festes T ist die Varianz immer grösser oder gleich einem festem positiven Wert, gegeben durch die rechte Seite von (20).

Schauen wir uns die Schätzer für das σ^2 an, die sind gegeben durch

$$\hat{\sigma}^2 = \frac{1}{\Delta t} \hat{\nu} \tag{21}$$

und die Cramer-Rao Abschätzung liefert in diesem Fall

$$\begin{aligned}
\mathbb{V}[\hat{\sigma}^2] &= \mathbb{V}\left[\frac{1}{\Delta t} \hat{\nu}\right] \\
&= \frac{1}{(\Delta t)^2} \times \mathbb{V}[\hat{\nu}] \\
&\stackrel{\text{Cramer-Rao (15)}}{\geq} \frac{1}{(\Delta t)^2} \times \frac{2\nu^2}{n} \\
&= \frac{1}{(\Delta t)^2} \times \frac{2(\sigma^2 \Delta t)^2}{n} \\
&= \frac{2\sigma^4}{n} \tag{22}
\end{aligned}$$

und in diesem Fall geht die untere Schranke, die rechte Seite von (22), nach 0 wenn n nach unendlich oder Δt nach 0 geht. Das deckt sich also genau mit dem Verhalten, was wir im week9a.pdf beobachtet haben.