

**week9a: Kapitel 5.3: Die Maximum Likelihood Methode  
 für den Ornstein-Uhlenbeck Prozess**

**Beispiel 3 (OU-Prozess):** Wir diskretisieren das Zeitintervall  $[0, T]$  mit einem  $\Delta t$  gemäss

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

mit  $t_k = k\Delta t$  und Zeithorizont  $T = t_n = n\Delta t$ . Ein zeitdiskreter Ornstein-Uhlenbeck oder kurz OU-Prozess  $\{x_{t_k}\}_{k=0}^n$  war dann gegeben durch die stochastische Rekursion

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

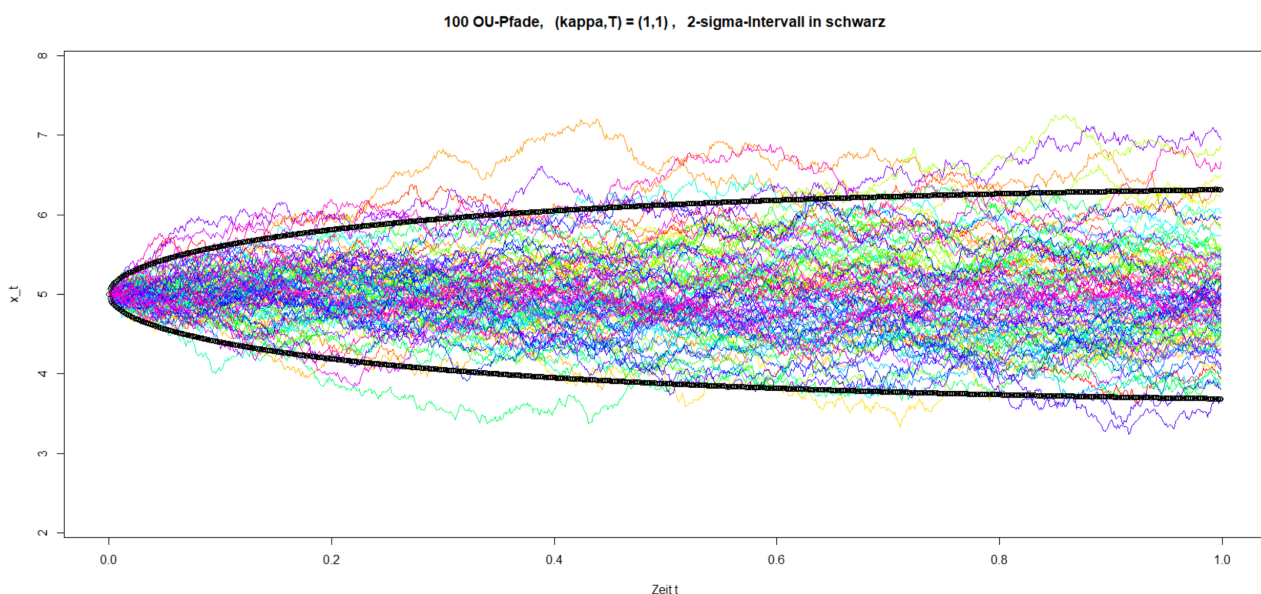
mit standard-normalverteilten Zufallszahlen  $\phi_k$  und einem deterministisch vorgegebenen Startwert  $x_{t_0} = x_0$ , etwa  $x_0 = \mu$ . Mit den Abkürzungen

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

ist das dann äquivalent zu der folgenden Rekursionsvorschrift:


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

Schauen wir uns zunächst mal ein paar Pfade an:




100 OU-Pfade für  $(\kappa, T) = (1, 1)$  und  $\mu = 5$  und  $\sigma = 1$

100 OU-Pfade,  $(\kappa, T) = (1, 10)$ , 2-sigma-Intervall in schwarz



100 OU-Pfade für  $(\kappa, T) = (1, 10)$  und  $\mu = 5$  und  $\sigma = 1$

100 OU-Pfade,  $(\kappa, T) = (10, 1)$ , 2-sigma-Intervall in schwarz



100 OU-Pfade für  $(\kappa, T) = (10, 1)$  und  $\mu = 5$  und  $\sigma = 1$

Auf dem Übungsblatt 7 haben wir in der zweiten Aufgabe gezeigt, dass  $E[x_{t_k}] = \mu$  falls  $x_0 = \mu$  gewählt wird, und dass im Limes  $\Delta t \rightarrow 0$

$$V[x_{t_k}] = \frac{\sigma^2}{2\kappa} (1 - e^{-2\kappa t_k}) \quad (3)$$

gilt. Die schwarzen Kurven in den Bildern sind dann gegeben durch die Ausdrücke

$$\text{2-Sigma-Intervall} := E[x_{t_k}] \pm 2 \sqrt{V[x_{t_k}]} = \mu \pm 2 \sqrt{\frac{\sigma^2}{2\kappa} (1 - e^{-2\kappa t_k})} \quad (4)$$

Das ‘Sigma’ in ‘2-Sigma-Intervall’ bezieht sich also nicht auf den Modellparameter  $\sigma$ , sondern das meint einfach 2 mal Standardabweichung und das Wort ‘Standardabweichung’ wird mitunter auch einfach durch das Wort ‘Sigma’ abgekürzt.

Zurück zum eigentlichen Problem: Wir haben Zeitreihendaten  $\{x_{t_k}\}_{k=1}^n$ , die mit Hilfe eines OU-Prozesses generiert worden sind, wir kennen aber die Parameter  $(\kappa, \mu, \sigma)$  oder  $(\alpha, \beta, \eta)$  nicht und wir möchten sie aus den Zeitreihendaten zurückgewinnen, wie können wir das machen?

**Lösung 3:** Wenn  $x_{t_{k-1}}$  gegeben ist, ist gemäss Gleichung (2) das  $x_{t_k}$  normalverteilt mit Mittelwert  $\alpha x_{t_{k-1}} + \beta$  und Standardabweichung  $\eta$ . Die W'keit, dass sich das  $x_{t_k}$  in einem Intervall  $[\tilde{x}_{t_k}, \tilde{x}_{t_k} + d\tilde{x}_{t_k})$  realisieren tut, bei bekanntem  $x_{t_{k-1}}$ , ist also gegeben durch

$$\text{Prob}\left[x_{t_k} \in [\tilde{x}_{t_k}, \tilde{x}_{t_k} + d\tilde{x}_{t_k}) \mid x_{t_{k-1}}\right] = \frac{1}{\sqrt{2\pi\eta^2}} e^{-\frac{(\tilde{x}_{t_k} - [\alpha x_{t_{k-1}} + \beta])^2}{2\eta^2}} d\tilde{x}_{t_k}$$

Durch wiederholte Anwendung von

$$\text{Prob}[A \cap B] = \text{Prob}[A \mid B] \times \text{Prob}[B]$$

bekommen wir dann

$$\begin{aligned} & \text{Prob}\left[x_{t_n} \in [\tilde{x}_{t_n}, \tilde{x}_{t_n} + d\tilde{x}_{t_n}), x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &= \text{Prob}\left[x_{t_n} \in [\tilde{x}_{t_n}, \tilde{x}_{t_n} + d\tilde{x}_{t_n}) \mid x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &\times \text{Prob}\left[x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &= \text{Prob}\left[x_{t_n} \in [\tilde{x}_{t_n}, \tilde{x}_{t_n} + d\tilde{x}_{t_n}) \mid x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &\times \text{Prob}\left[x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}) \mid x_{t_{n-2}} \in [\tilde{x}_{t_{n-2}}, \tilde{x}_{t_{n-2}} + d\tilde{x}_{t_{n-2}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &\times \text{Prob}\left[x_{t_{n-2}} \in [\tilde{x}_{t_{n-2}}, \tilde{x}_{t_{n-2}} + d\tilde{x}_{t_{n-2}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \end{aligned}$$

und wenn wir das immer so weiter machen

$$\begin{aligned} & \text{Prob}\left[x_{t_n} \in [\tilde{x}_{t_n}, \tilde{x}_{t_n} + d\tilde{x}_{t_n}), x_{t_{n-1}} \in [\tilde{x}_{t_{n-1}}, \tilde{x}_{t_{n-1}} + d\tilde{x}_{t_{n-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &= \prod_{k=1}^n \text{Prob}\left[x_{t_k} \in [\tilde{x}_{t_k}, \tilde{x}_{t_k} + d\tilde{x}_{t_k}) \mid x_{t_{k-1}} \in [\tilde{x}_{t_{k-1}}, \tilde{x}_{t_{k-1}} + d\tilde{x}_{t_{k-1}}), \dots, x_{t_1} \in [\tilde{x}_{t_1}, \tilde{x}_{t_1} + d\tilde{x}_{t_1})\right] \\ &= \prod_{k=1}^n \frac{1}{\sqrt{2\pi\eta^2}} e^{-\frac{(\tilde{x}_{t_k} - [\alpha \tilde{x}_{t_{k-1}} + \beta])^2}{2\eta^2}} d\tilde{x}_{t_k} \end{aligned}$$

Für die  $\tilde{x}_{t_k}$  können wir wieder die realisierten Zeitreihendaten einsetzen und erhalten so wieder eine Funktion, die nur von den Modell-Parametern  $(\alpha, \beta, \eta)$  abhängt, das ist dann also wieder die Likelihood-Funktion:

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

oder

$$\log L = -n \log \eta - \frac{1}{2\eta^2} \sum_{k=1}^n (x_{t_k} - [\alpha x_{t_{k-1}} + \beta])^2 + \text{const} = \log L(\alpha, \beta, \eta)$$

mit der Konstanten

$$\text{const} := -\frac{n}{2} \log(2\pi) + \log \prod_{k=1}^n dx_{t_k}$$

Wir maximieren  $\log L$ . Dazu berechnen wir wieder den Gradienten und setzen den gleich 0. Wir haben

$$\begin{aligned} \frac{\partial}{\partial \alpha} \log L &= + \frac{1}{\eta^2} \sum_{k=1}^n (x_{t_k} - [\alpha x_{t_{k-1}} + \beta]) x_{t_{k-1}} \stackrel{!}{=} 0 \\ \frac{\partial}{\partial \beta} \log L &= + \frac{1}{\eta^2} \sum_{k=1}^n (x_{t_k} - [\alpha x_{t_{k-1}} + \beta]) \stackrel{!}{=} 0 \\ \frac{\partial}{\partial \eta} \log L &= -\frac{n}{\eta} + \frac{1}{\eta^3} \sum_{k=1}^n (x_{t_k} - [\alpha x_{t_{k-1}} + \beta])^2 \stackrel{!}{=} 0 \end{aligned}$$

oder

$$\begin{aligned} \alpha \sum_{k=1}^n x_{t_{k-1}}^2 + \beta \sum_{k=1}^n x_{t_{k-1}} &= \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \\ \alpha \sum_{k=1}^n x_{t_{k-1}} + \beta n &= \sum_{k=1}^n x_{t_k} \end{aligned}$$

und

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

Die ersten beiden Gleichungen sind ein lineares Gleichungssystem der Form

$$A \begin{pmatrix} \alpha \\ \beta \end{pmatrix} = b$$

mit

$$A = \begin{pmatrix} \sum_{k=1}^n x_{t_{k-1}}^2 & \sum_{k=1}^n x_{t_{k-1}} \\ \sum_{k=1}^n x_{t_{k-1}} & n \end{pmatrix}$$

und der rechten Seite

$$b = \begin{pmatrix} \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \\ \sum_{k=1}^n x_{t_k} \end{pmatrix}$$

Wir bekommen dann also

$$\begin{aligned} \begin{pmatrix} \alpha \\ \beta \end{pmatrix} &= \begin{pmatrix} \sum_{k=1}^n x_{t_{k-1}}^2 & \sum_{k=1}^n x_{t_{k-1}} \\ \sum_{k=1}^n x_{t_{k-1}} & n \end{pmatrix}^{-1} \begin{pmatrix} \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \\ \sum_{k=1}^n x_{t_k} \end{pmatrix} \\ &= \frac{1}{n \sum_{k=1}^n x_{t_{k-1}}^2 - (\sum_{k=1}^n x_{t_{k-1}})^2} \begin{pmatrix} n & -\sum_{k=1}^n x_{t_{k-1}} \\ -\sum_{k=1}^n x_{t_{k-1}} & \sum_{k=1}^n x_{t_{k-1}}^2 \end{pmatrix} \begin{pmatrix} \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \\ \sum_{k=1}^n x_{t_k} \end{pmatrix} \end{aligned}$$

oder, wenn wir jetzt wieder Hüte nehmen, da wir Schätzer  $(\hat{\alpha}, \hat{\beta}, \hat{\eta})$  für die Modellparameter  $(\alpha, \beta, \eta)$  haben,

$$\hat{\alpha}_{\text{ML}} = \frac{n \sum_{k=1}^n x_{t_{k-1}} x_{t_k} - \sum_{k=1}^n x_{t_{k-1}} \sum_{k=1}^n x_{t_k}}{n \sum_{k=1}^n x_{t_{k-1}}^2 - \left( \sum_{k=1}^n x_{t_{k-1}} \right)^2} \quad (5)$$

$$\hat{\beta}_{\text{ML}} = \frac{\sum_{k=1}^n x_{t_{k-1}}^2 \sum_{k=1}^n x_{t_k} - \sum_{k=1}^n x_{t_{k-1}} x_{t_k} \sum_{k=1}^n x_{t_{k-1}}}{n \sum_{k=1}^n x_{t_{k-1}}^2 - \left( \sum_{k=1}^n x_{t_{k-1}} \right)^2} \quad (6)$$

und damit dann

$$\hat{\eta}_{\text{ML}}^2 = \frac{1}{n} \sum_{k=1}^n \left( x_{t_k} - [\hat{\alpha}_{\text{ML}} x_{t_{k-1}} + \hat{\beta}_{\text{ML}}] \right)^2 \quad (7)$$

und können dann gemäss

$$\hat{\kappa}_{\text{ML}} = \frac{1 - \hat{\alpha}_{\text{ML}}}{\Delta t} \quad (8)$$

$$\hat{\mu}_{\text{ML}} = \frac{\beta}{\kappa \Delta t} = \frac{\hat{\beta}_{\text{ML}}}{1 - \hat{\alpha}_{\text{ML}}} \quad (9)$$

$$\hat{\sigma}_{\text{ML}}^2 = \frac{\hat{\eta}_{\text{ML}}^2}{\Delta t} \quad (10)$$

die Modell-Parameter  $(\kappa, \mu, \sigma)$  berechnen.

Okay, schauen wir uns mal an, wie gut das so hinkommt. Wir betrachten wieder die 3 Fälle

$$\begin{aligned} (\kappa, T) &= (1, 10) \\ (\kappa, T) &= (10, 1) \\ (\kappa, T) &= (1, 1) \end{aligned} \quad (11)$$

und lassen das  $\mu$  und das  $\sigma$  fest auf den Werten

$$\begin{aligned} \mu &= 5 \\ \sigma &= 1 \end{aligned}$$

Für jeden Fall in (11) simulieren wir jeweils  $N = 10000$  Pfade und für jeden Pfad berechnen wir dann die Modellparameter gemäss der obigen Formeln für  $(\hat{\kappa}, \hat{\mu}, \hat{\sigma})$ . Wir wollen ebenfalls die Abhängigkeit der Resultate von der Anzahl  $n$  der Zeitreihendaten untersuchen. Dazu wählen wir zu gegebenen Zeithorizont  $T$  das  $\Delta t$  so, dass wir einmal  $n = 1000$  Zeitreihendaten bekommen und zum anderen  $n = 10000$  Zeitreihendaten. Also konkret, für  $T = 1$  wählen wir

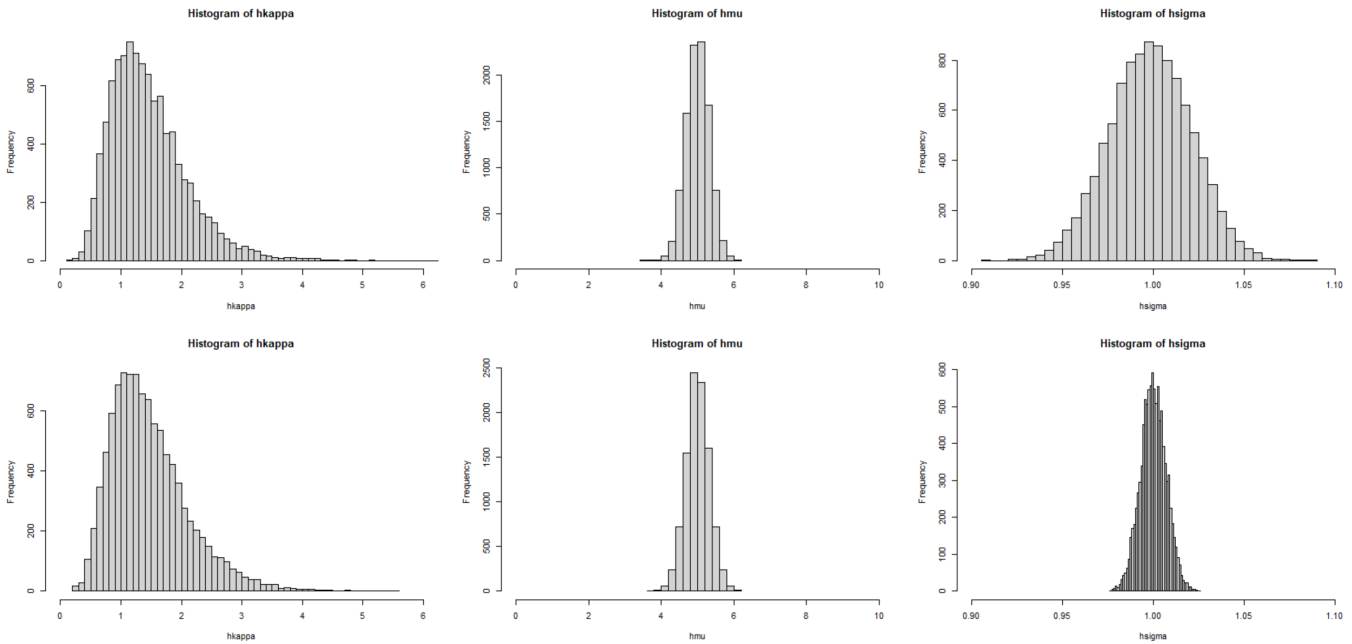
$$\text{Für } T = 1: \quad \Delta t \in \left\{ \frac{1}{1000}, \frac{1}{10000} \right\}$$

und für  $T = 10$  wählen wir

$$\text{Für } T = 10: \quad \Delta t \in \left\{ \frac{1}{100}, \frac{1}{1000} \right\}$$

Wir bekommen dann die folgenden Resultate:

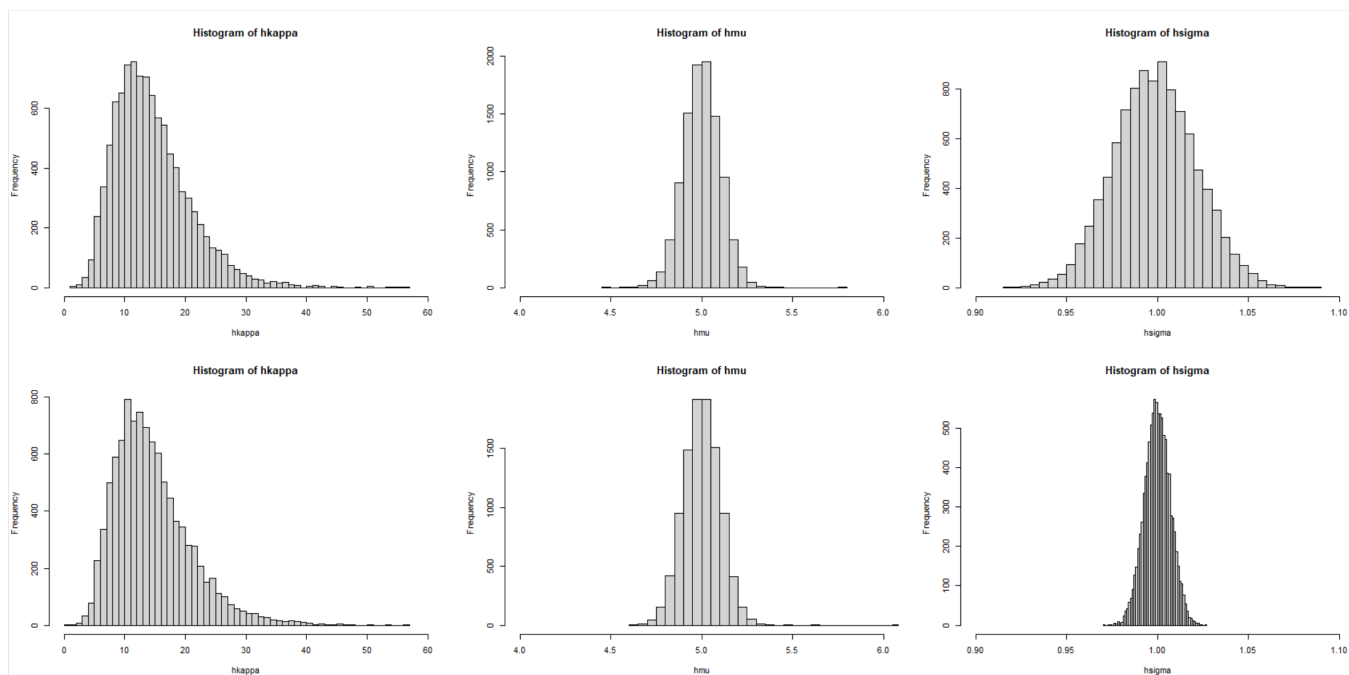
Für  $(\kappa, T) = (1, 10)$ :  $\mu = 5, \sigma = 1$



$(\hat{\kappa}, \hat{\mu}, \hat{\sigma})$  für  $n = 1000$  (obere Zeile) und  $n = 10000$  (untere Zeile) Zeitreihendaten

```
# (kappa,T) = (1,10)
# Mit n=1000 Zeitreihendaten:
> dt = 0.01
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.1400 0.9893  1.3314  1.4410  1.7764  5.6373
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
3.683  4.787  5.005   5.000  5.207   6.583
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.9132 0.9839  0.9988  0.9989  1.0140  1.0891
# Mit n=10000 Zeitreihendaten:
> dt = 0.001
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.1671 1.0061  1.3479  1.4525  1.7827  5.2717
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
3.803  4.783  4.994   4.993  5.206   6.187
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.9692 0.9951  1.0000  0.9999  1.0047  1.0250
```

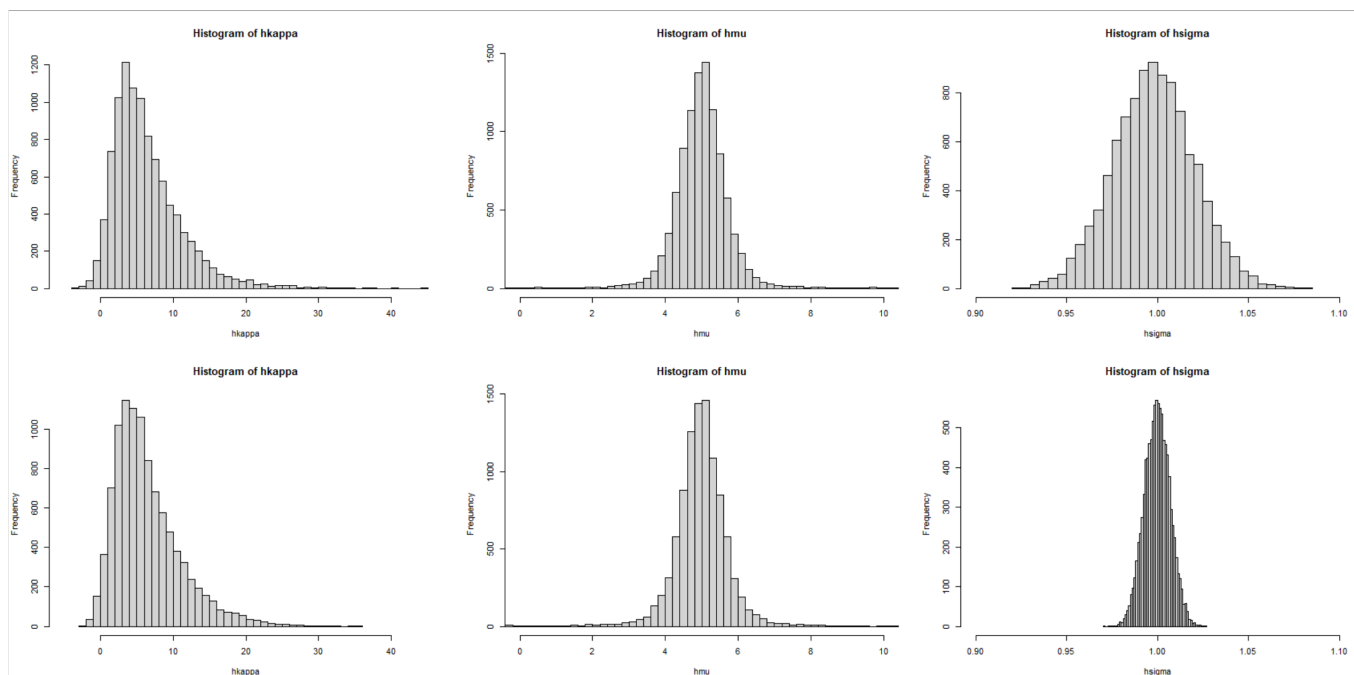
Für  $(\kappa, T) = (10, 1)$ :  $\mu = 5, \sigma = 1$



$(\hat{\kappa}, \hat{\mu}, \hat{\sigma})$  für  $n = 1000$  (obere Zeile) und  $n = 10000$  (untere Zeile) Zeitreihendaten

```
# (kappa,T) = (10,1)
# Mit n=1000 Zeitreihendaten:
> dt = 0.001
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 2.108 10.020 13.548 14.612 18.076 48.466
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 4.570  4.935  5.001  5.000  5.067  5.456
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.9136 0.9833 0.9983 0.9983 1.0137 1.0855
# Mit n=10000 Zeitreihendaten:
> dt = 0.0001
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 1.759 10.013 13.461 14.521 17.887 58.886
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 4.589  4.932  4.999  4.999  5.065  5.371
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
0.9689 0.9951 0.9999 0.9999 1.0046 1.0255
```

Für  $(\kappa, T) = (1, 1)$ :  $\mu = 5, \sigma = 1$



$(\hat{\kappa}, \hat{\mu}, \hat{\sigma})$  für  $n = 1000$  (obere Zeile) und  $n = 10000$  (untere Zeile) Zeitreihendaten

```
# (kappa,T) = (1,1)
# Mit n=1000 Zeitreihendaten:
> dt = 0.001
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
-3.041  3.198   5.528   6.515   8.751   42.654
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
-470.238   4.632   5.005   4.863   5.374  137.887
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 0.9256  0.9825  0.9977  0.9978  1.0126  1.0776

# Mit n=10000 Zeitreihendaten:
> dt = 0.0001
> summary(hkappa)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
-3.041  3.172   5.513   6.509   8.723   42.212
> summary(hmu)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
-425.271   4.633   4.997   4.924   5.378  173.752
> summary(hsigma)
  Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
 0.9736  0.9951  0.9999  0.9999  1.0047  1.0264
```



**Beobachtungen:** Halten wir vielleicht noch die folgenden Beobachtungen fest:

- (i) Für  $(\kappa, T) = (1, 1)$  wird der Schätzer für das  $\kappa$  sehr schlecht. Auch die Summary-Daten für das  $\hat{\mu}$  sehen nicht sehr schön aus. Das wird daran liegen, dass für  $\kappa = 1$  der Zeithorizont  $T = 1$  zu klein ist, als dass die Pfade das ‘Mean-Reversion-Regime’ erreichen können, das wäre der Bereich, in dem das 2-Sigma-Intervall durch horizontale Linien gegeben ist, und nicht durch eine Parabel.
- (ii) In allen 3 Fällen sind die Histogramme für  $\hat{\kappa}$  und  $\hat{\mu}$  im wesentlichen unabhängig von der Anzahl  $n$  der Zeitreihendaten, wohingegen der Schätzer für das  $\sigma$  immer genauer wird mit wachsendem  $n$ . Der Schätzer  $\hat{\sigma}$  ist konsistent, seine Varianz geht nach 0 wenn mehr Daten benutzt werden, aber die Schätzer  $\hat{\kappa}$  und  $\hat{\mu}$  sind nicht konsistent, ihre Varianzen gehen nicht nach 0, wenn die Anzahl  $n$  der Zeitreihendaten nach unendlich geht (sofern der Zeithorizont  $T$  festgehalten wird). Dieses Verhalten werden wir im Kapitel 7.3 genauer verstehen können, wo wir mit der Cramer-Rao Abschätzung eine allgemeine untere Schranke für die Varianzen von erwartungstreuen Schätzern angeben können. Die Schätzer  $\hat{\sigma}$  und  $\hat{\mu}$  scheinen erwartungstreu zu sein, aber das  $\hat{\kappa}$  ist sicherlich nicht erwartungstreu.

Wir wollen uns den Satz “Das wird daran liegen, dass für  $\kappa = 1$  der Zeithorizont  $T = 1$  zu klein ist, als dass die Pfade das ‘Mean-Reversion-Regime’ erreichen können” aus der Beobachtung (i) noch an Hand von 2 Bildern verdeutlichen: Dazu halten wir die Parameter  $(\mu, \sigma) = (5, 1)$  wieder fest und variieren das  $\kappa$  und das  $T$ . Für festes  $T$  generieren wir jeweils 50 Pfade mit  $\kappa = 1$  und 50 Pfade mit  $\kappa = 0$ . Für  $\kappa = 0$  lautet die Rekursionsvorschrift einfach


$$\begin{aligned}
 x_{t_k} &= x_{t_{k-1}} + \kappa(\mu - x_{t_{k-1}})\Delta t + \sigma\sqrt{\Delta t}\phi_k \\
 &\stackrel{\kappa=0, \sigma=1}{=} x_{t_{k-1}} + \sqrt{\Delta t}\phi_k
 \end{aligned}$$

und wird gelöst von

$$x_{t_k} = \sqrt{\Delta t} \sum_{j=1}^k \phi_j \tag{12}$$


Diese Summe von standard-normalverteilten Zufallszahlen mit dem Skalierungsfaktor  $\sqrt{\Delta t}$  wird auch als eine Brownsche Bewegung bezeichnet (in diskreter Zeit). In den folgenden beiden Diagrammen vergleichen wir jeweils 50 Pfade einer Brownschen Bewegung, in schwarz, mit 50 OU-Pfaden, in rot. Dabei wurden jeweils dieselben  $\{\phi_k\}_{k=1}^n$  benutzt:

OU-Prozess vs Brownian Motion (kappa=0) auf dem Zeitintervall [0,1]



50 OU-Pfade mit  $\kappa = 1$  und  $\sigma = 1$  (in rot) und 50 Brownsche Bewegungen (in schwarz) auf  $[0, T] = [0, 1]$

OU-Prozess vs Brownian Motion (kappa=0) auf dem Zeitintervall [0,10]



50 OU-Pfade mit  $\kappa = 1$  und  $\sigma = 1$  (in rot) und 50 Brownsche Bewegungen (in schwarz) auf  $[0, T] = [0, 10]$

Für kleinere  $t_k$ 's sind also OU-Pfade mit  $\kappa = 1$  und OU-Pfade mit  $\kappa = 0$ , das sind dann Brownsche Bewegungen, nicht sehr verschieden und dann ist es natürlich nicht erstaunlich, dass, was immer man für eine statistische Methode auch nimmt, das  $\kappa$  nicht sehr gut identifiziert werden kann, die Daten sind ganz einfach nicht sensitiv genug bezüglich einer Variation von  $\kappa$ .

Die Bilder und Diagramme aus dieser Veranstaltung werden wir dann in der nächsten Veranstaltung konkret in R reproduzieren.