



## 7. Stochastische Prozesse und Zeitreihenmodelle

- Regelmäßigkeiten in der Entwicklung einer Zeitreihe, um auf zukünftige Entwicklung zu schließen
- Verwendung zu Prognosezwecken

### Univariate Zeitreihenanalyse

- für Prognose werden nur endogene Variablen verwendet, d.h. nur Beobachtungswerte derselben statistischen Variablen



grundlegendes Konzept ist der stochastische Prozess:

**Definition:**

Eine zeitlich geordnete Folge von Zufallsvariablen

$$\{Y\} = Y_1, Y_2, Y_3, \dots, Y_t, \dots$$

heißt stochastischer Prozess (Sequenz von endlich vielen oder (abzählbar) unendlich vielen Zufallsvariablen bzw. Wertemenge),  $\{Y \mid \text{für alle ganzen Zahlen } t\}$ .

Zeitreihenmodelle basieren auf der Annahme, dass die zu prognostizierende Zeitreihe durch einen stochastischen Prozess generiert wird. Bei endlich vielen



ZVs kann der stochastische Prozess durch gemeinsame Verteilungsfunktion vollständig angegeben werden.

Realisation der Länge  $T$  des stochastischen Prozess:  $y_1, y_2, y_3, \dots, y_T$ , wobei jeder Beobachtungswert von einer anderen ZV generiert ist, d.h. jeder beobachtete Wert einer Zeitreihe entstammt zufällig einer Wahrscheinlichkeitsverteilung. Ein stochastischer Prozess stellt einen Zufallsprozess  $\{Y\}$  dar, welcher Werte zwischen  $-\infty$  und  $+\infty$  annehmen kann. Der beobachtete Wert  $y_T$  zum Zeitpunkt  $T$  beschreibt eine Realisation dieser stochastischen Prozesse.



## 7.1 Kennzahlen stochastischer Prozesse

I.d.R. genügt die Angabe der ersten und zweiten Momente der ZV, womit der Prozess hinreichend charakterisiert ist. Erwartungswerte, Varianzen und Kovarianzen sind als eine Funktion von  $t$  und  $j$  zu sehen.

### Definition:

1.  $\mu(t) := E(Y_t)$  Mittelwertfunktion
2.  $\sigma^2(t) := V(Y_t)$ , Varianzfunktion
3.  $\gamma_j(t) := Cov(Y_t, Y_{t-j})$ , Autokovarianzfunktion, mit  $\sigma^2(t) =: \gamma_0(t)$
4.  $\rho_j(t) := \frac{\gamma_j(t)}{\sigma(t) \cdot \sigma(t-j)}$  Autokorrelationsfunktion

des stochastischen Prozesses  $\{Y_t\}$



## 7.2 Stationäre stochastische Prozesse

Ann.: zeitliche Stabilität des stochastischen Prozesses (bestimmte mögliche Prozesse werden vorgegeben)

Sind die ersten beiden Momente eines stochastischen Prozesses unabhängig vom Zeitindex, so ist der Prozess stationär.

### Definition: Schwache Stationarität

Ein stochastischer Prozess  $\{Y_t\}$  heißt schwach stationär, wenn für alle  $t$  und  $j$

- gilt:
1.  $\mu(t) = \mu$  oder  $E(Y_t) = \mu = const.$ , für alle  $t$  mittelwertstationär
  2.  $\sigma^2(t) = \sigma^2$  oder  $\sigma_t^2 = \sigma^2 = const.$ , für alle  $t$  varianzstationär
  3.  $\gamma_j(t) = \gamma_j$  oder  $Cov(Y_t, Y_{t-j}) = \sigma_{ij} = \sigma_j = const.$ , für alle  $t$  kovarianzstat.



Kovarianzen hängen lediglich von Entfernung  $j$  ab, aber nicht vom Zeitindex  $t$

Bei stationären Prozessen gilt für jedes  $j$ :

$$\rho_j = \frac{\gamma_j}{\gamma_0}, \text{ mit } -1 \leq \rho_j \leq +1$$

### **Definition: Strenge Stationarität**

Prozess, bei dem gemeinsame Verteilungsfunktion jedes endlichen zusammenhängenden Teiles von ZVs  $Y_1, Y_2, Y_3, \dots, Y_m$  gleich der Verteilungsfunktion des um  $k$  Zeitpunkte verschobenen Teiles  $Y_{1+k}, Y_{2+k}, Y_{3+k}, \dots, Y_{m+k}$  ist, heißt streng stationärer stochastischer Prozess, d.h. gemeinsame Verteilung ist zeitinvariant.  $Y(t+1), \dots, Y(t+m)$  hat die gleiche gemeinsame Verteilung wie  $Y(t+1+k), \dots, Y(t+m+k)$ , wobei  $k$  eine willkürliche positive ganze Zahl ist.



Alle  $Y_t$  sind identisch verteilt, aber nicht notwendigerweise unabhängig.

Strenge Stationarität ist eine stärkere Eigenschaft. Jeder streng stationäre stochastische Prozess ist auch schwach stationär.

Aber:

Eigenschaft der Stationarität ist nicht hinreichend, um konsistente Schätzer zu erhalten.

Voraussetz.: unabhängige Stichproben nicht gegeben (Abhängigkeitsstrukturen)



### Definition eines ergodischen Prozesses:

Ein stationärer stochastischer Prozess  $\{Y_t\}$  mit Mittelwertfunktion  $\mu$  und Kovarianzfunktionen  $\gamma_j$  heißt

1. mittelwertergodisch, wenn  $\lim_{T \rightarrow \infty} E \left( \frac{1}{T} \sum_{t=1}^T Y_t \right) = \mu$

2. kovarianzergodisch, wenn für alle  $j$

$$\lim_{T \rightarrow \infty} E \left( \frac{1}{T} \sum_{t=1}^T (Y_t - \mu)(Y_{t-j} - \mu) \right) = \gamma_j$$

Autokovarianz sollte nicht zu groß sein bzw. sollte mit zunehmender Entfernung  $j$  schnell genug kleiner werden.



## Schätzen der Kennzahlen



empirische Momente eines stationären Prozesses können konsistent geschätzt werden:

Erwartungswert:  $\hat{\mu} = \bar{y}$

Autokovarianzen:  $\hat{\gamma}_j = \frac{1}{T-j-1} \sum_{t=j+1}^T (y_t - \bar{y})(y_{t-j} - \bar{y})$

Autokorrelationsfunktionen:  $\hat{\rho}_j = r_j = \frac{\sum_{t=j+1}^T (y_t - \bar{y})(y_{t-j} - \bar{y})}{\sum_{t=1}^T (y_t - \bar{y})^2}$ , für  $j = 0, 1, 2, \dots$

(empirische Autokorrelationsfunktion)



Signifikanztest:

(Autokorelationskoeffizienten signifikant von Null verschieden?)

$$H_0 : \rho_j = 0$$

ZV  $R_j$  ist unter  $H_0$  annähernd normalverteilt mit der Varianz  $1/T$ . Man verwendet die Faustregel:

$$|r_j| > \frac{2}{\sqrt{T}} \Rightarrow H_0 \text{ verwerfen}$$

≙ zweiseitiger Test auf 5%-Signifikanzniveau ( $\alpha = 0.05$ ).



## White-Noise- und Normalprozess


= einfacher stochastischer Prozess

### Definition:

Ein stochastischer Prozess  $\{\varepsilon_t\} = \varepsilon_1, \varepsilon_2, \dots, \varepsilon_t, \dots$  heißt weißes Rauschen, White-Noise-Prozess, oder reiner Zufallsprozess, wenn

1.  $E(\varepsilon_t) = 0$
2.  $V(\varepsilon_t) = \sigma_\varepsilon^2 = \text{const.}$  für jedes  $t$
3.  $\text{Cov}(\varepsilon_t, \varepsilon_{t-j}) = 0$  für  $j > 0$

White-Noise-Prozesse sind stationär. Sind  $\varepsilon_t$  eines weißen Rauschens normalverteilt, so spricht man von Normalprozess oder Gaussian White Noise.





## 7.3 Moving-Average-Prozesse

Autoregressive Moving Average Modelle = ARMA-Modelle

→ für Kurzfristprognose von guter Qualität

### Drei grundlegende Modelltypen

- Autoregressiver Prozess  $p$ -ter Ordnung, AR( $p$ )
- Moving-Average Prozess  $q$ -ter Ordnung, MA( $q$ )
- ARMA-Prozess  $(p, q)$ -ter Ordnung, ARMA( $p, q$ )

außerdem: ARIMA( $p, d, q$ )-Modell ( $d$  = Anzahl der Differenzenbildung)



## MA(1)-Prozess

Über Bildung gleitender Durchschnitte über eine White-Noise-Prozess erhält man einen neuen stochastischen Prozess

### Definition:

Ein stochastischer Prozess  $\{Y_t\}$  mit

$$Y_t := \alpha_0 + \varepsilon_t + \alpha_1 \varepsilon_{t-1}$$

wobei  $\alpha_0$  und  $\alpha_1$  Parameter sind und die  $\varepsilon_t$  einen White-Noise-Prozess mit  $V(\varepsilon_t) = \sigma_\varepsilon^2$  bilden, heißt Moving-Average Prozess erster Ordnung oder MA(1)-Prozess.

Eigenschaften:

$$1. \mu(t) = E(\alpha_0 + \varepsilon_t + \alpha_1 \varepsilon_{t-1}) = \alpha_0$$

$$2. \gamma_0(t) = V(\alpha_0 + \varepsilon_t + \alpha_1 \varepsilon_{t-1}) = V(\varepsilon_t) + V(\alpha_1 \varepsilon_{t-1}) = (1 + \alpha_1^2) \sigma_\varepsilon^2$$

$$\begin{aligned} \gamma_1(t) &= E[Y_t - \alpha_0)(Y_{t-1} - \alpha_0)] \\ &= E[(\varepsilon_t + \alpha_1 \varepsilon_{t-1})(\varepsilon_{t-1} + \alpha_1 \varepsilon_{t-2})] \end{aligned}$$

$$\begin{aligned} 3. \quad &= E(\varepsilon_t \varepsilon_{t-1}) + \alpha_1 E(\varepsilon_{t-1} \varepsilon_{t-1}) + \alpha_1 E(\varepsilon_t \varepsilon_{t-2}) + \alpha_1^2 E(\varepsilon_{t-1} \varepsilon_{t-2}) \\ &= 0 + \alpha_1 E(\varepsilon_{t-1} \varepsilon_{t-1}) + 0 + 0 \\ &= \alpha_1 \sigma_\varepsilon^2 \end{aligned}$$



Bei MA(1)-Prozess gibt es nur Abhängigkeit der ZV von ihrer jeweils unmittelbaren Vorgängerin. Sämtliche Kovarianzen höherer Ordnung als 1 verschwinden:

$$\gamma_j = \begin{cases} (1 + \alpha_1)\sigma_\varepsilon^2 & \text{für } j = 0 \\ \alpha_1\sigma_\varepsilon^2 & \text{für } j = 1 \\ 0 & \text{für } j > 1 \end{cases}$$

Kovarianzfunktion ist unabhängig von  $t$ ,

MA( $q$ )-Prozess ist immer stationär



Korrelationsfunktion eines MA(1)-Prozesses:

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \begin{cases} 1 & \text{für } j = 0 \\ \frac{\alpha_1}{1 + \alpha_1^2} & \text{für } j = 1 \\ 0 & \text{für } j > 1 \end{cases}$$

d.h. nimmt für Lags größer 1 den Wert Null an

### MA(q)-Prozesse

gleitende Durchschnitte mit mehr als zwei White-Noise-Variablen

$$Y_t := \alpha_0 + \varepsilon_t + \alpha_1 \varepsilon_{t-1} + \dots + \alpha_q \varepsilon_{t-q}$$



Erwartungswert ist konstant und  $\alpha_0$

Merke:

1. Jeder MA( $q$ )-Prozess ist schwach stationär
2. Seine Kovarianzfunktion bricht ab für Lags  $j > q$ , so dass  $\gamma_j = 0$
3. Jeder MA( $q$ )-Prozess ist mittelwertergodisch
4. MA( $q$ )-Prozess ist kovarianzergodisch, wenn das ihn erzeugende weiße Rauschen ein Normalprozess ist.



## 7.4 Autoregressive Prozesse

autoregressiver Prozess erster Ordnung oder AR(1)-Prozess

= einfachster Prozess von AR-Prozessen bei dem aktueller Wert vom vorherigen Wert bestimmt wird:

= stochastischer Prozess  $\{Y_t\}$  mit der Prozessgleichung

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \varepsilon_t$$

wobei  $\beta_0$  und  $\beta_1$  feste Parameter sind und  $\{\varepsilon_t\}$  ein White-Noise-Prozess



Abhängigkeit von allen vorangegangenen Werten:

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \varepsilon_t$$

$$Y_t = \beta_0 + \beta_1(\beta_0 + \beta_1 Y_{t-2} + \varepsilon_{t-1}) + \varepsilon_t = \beta_0(1 + \beta_1) + \beta_1^2 Y_{t-2} + (\varepsilon_t + \beta_1 \varepsilon_{t-1})$$

$$Y_t = \beta_0(1 + \beta_1) + \beta_1^2(\beta_0 + \beta_1 Y_{t-3} + \varepsilon_{t-2}) + (\varepsilon_t + \beta_1 \varepsilon_{t-1})$$

$$= \beta_0(1 + \beta_1 + \beta_1^2) + (\beta_1^3 Y_{t-3} + (\varepsilon_t + \beta_1 \varepsilon_{t-1} + \beta_1^2 \varepsilon_{t-2}))$$

⋮

$$Y_t = \beta_0(1 + \beta_1 + \dots + \beta_1^{t-2}) + \beta_1^{t-1}(\beta_0 + \beta_1 y_0 + \varepsilon_1) + (\varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_1^{t-2} \varepsilon_2)$$

$$= \beta_0(1 + \beta_1 + \dots + \beta_1^{t-1}) + \beta_1^t y_0 + (\varepsilon_t + \beta_1 \varepsilon_{t-1} + \dots + \beta_1^{t-1} \varepsilon_1)$$

Einfluss des Startwertes  $y_0$  nimmt mit wachsende zeitlichen Abstand ab, wenn

$|\beta_1| < 1$  ist.

Satz:

Jeder AR(1)-Prozess, dessen Parameter  $|\beta_1| < 1$ , ist mittelwertstationär, mittelwertergodisch, kovarianzstationär. Ist sein weißes Rauschen ein Normalprozess, dann ist er auch kovarianzergodisch.

## Eigenschaften:

1. Erwartungswert:  $\mu = \frac{\beta_0}{1 - \beta_1}$

2.  $Var(Y_t) = \frac{\sigma_u^2}{1 - \alpha_1^2}$

3. Kovarianzfunktion:  $\gamma_j(t) = E[(Y_t - \mu)(Y_{t-j} - \mu)] = \frac{\beta_1^j}{1 - \beta_1^2} \sigma_\varepsilon^2 = \gamma_j$




Weitere wichtige Eigenschaft des AR(1)-Prozess:

$$\rho_j = \frac{\gamma_j}{\gamma_0} = \beta_1^j$$

d. h. Autokorrelationsfunktion nimmt mit wachsen-dem Lag  $j$  ab, wenn  $\beta_1$  betragsmäßig kleiner eins ist.

- ( $0 < \beta_1 < 1$ ) exponentiell (geometrisch) abnehmendes Verhalten
- ( $-1 < \beta_1 < 0$ ) oszillierendes Verhalten
- „die-out“-Eigenschaft der Autokorrelationsfunktion











Abbildung 3: Autokorrelationsfunktionen für einen theoretischen AR(1)-Prozess.









## AR( $p$ )-Prozesse

### Definition:

Ein stochastischer Prozess  $\{Y_t\}$  mit

$$Y_t = \beta_0 + \beta_1 Y_{t-1} + \dots + \beta_p Y_{t-p} + \varepsilon_t$$

wobei die  $\beta_i$  konstante Parameter sind und  $\{\varepsilon_t\}$  ein White-Noise-Prozess ist, heißt autoregressiver Prozess der Ordnung  $p$  oder AR( $p$ )-Prozess.

$$\beta(L)Y_t = \varepsilon_t \text{ (komplexe Notation)}$$

$$\text{mit } \beta(L) = (1 - \beta_1 L - \beta_2 L^2 - \dots - \beta_p L^p)$$



Folgende Bedingungen müssen für Stationarität erfüllt sein:

- $\beta_1 + \beta_2 < 1$ ,
- $\beta_2 - \beta_1 < 1$  und
- $|\beta_2| < 1$

Partielle Autokorrelationsfunktion:

= Instrument zur Bestimmung der  $p$ -ten Ordnung eines AR( $p$ )-Prozesses.

$$Y_t = \phi_{0,1} + \phi_{1,1} Y_{t-1} + u_{1t}$$

$$Y_t = \phi_{0,2} + \phi_{1,2} Y_{t-1} + \phi_{2,2} Y_{t-2} + u_{2t}$$

$$Y_t = \phi_{0,3} + \phi_{1,3} Y_{t-1} + \phi_{2,3} Y_{t-2} + \phi_{3,3} Y_{t-3} + u_{3t}$$



...

wobei  $\phi_{0,j}$ ,  $\phi_{i,j}$ , und  $\{u_{jt}\}$  Konstante, Koeffizienten von  $Y_{t-j}$  und der Störvariable eines AR( $j$ )-Modells sind.

= multiple lineare Regression (Schätzung durch OLS-Methode)

Der geschätzte Koeffizient  $\hat{\phi}_{2,2}$  in der zweiten Gleichung ist die Stichproben-PACF für Lag 2 von  $Y_t$ . Der geschätzte Koeffizient  $\hat{\phi}_{3,3}$  in der dritten Gleichung ist die Stichproben-PACF für Lag 3 von  $Y_t$  und so weiter.

Nach der Definition erfasst der Partielle Autokorrelationskoeffizient  $\hat{\phi}_{2,2}$  2. Ordnung den zusätzlichen Beitrag von  $Y_{t-2}$  zu  $Y_t$  über das AR(1)-Modell  $Y_t = \phi_0 + \phi_1 Y_{t-1} + u_{1t}$  hinaus. Die PACF für den Lag  $p$  zeigt den zusätzlichen Beitrag



von  $Y_{t-p}$  zu  $Y_t$  über das  $AR(p)$ -Modell hinaus, die Stichproben-PACF  $p$ -ter Ordnung sollte nicht Null sein, aber  $\hat{\phi}_{j,j}$  sollte für alle  $j > p$  nahe Null sein.

Stichproben-PACF eines  $AR(p)$ -Prozesses hat folgende Eigenschaften:

- $\hat{\phi}_{p,p}$  konvergiert gegen  $\phi_p$  wenn Stichprobenumfang  $T$  gegen unendlich geht,
- $\hat{\phi}_{j,j}$  konvergiert gegen Null für alle  $j > p$

= Cut-off-Eigenschaft, d.h. für einen  $AR(p)$ -Prozess, bricht Stichproben-PACF bei Lag  $p$  ab.