

Kapitel 13

Zeitreihen und Zeitreihen-Modelle

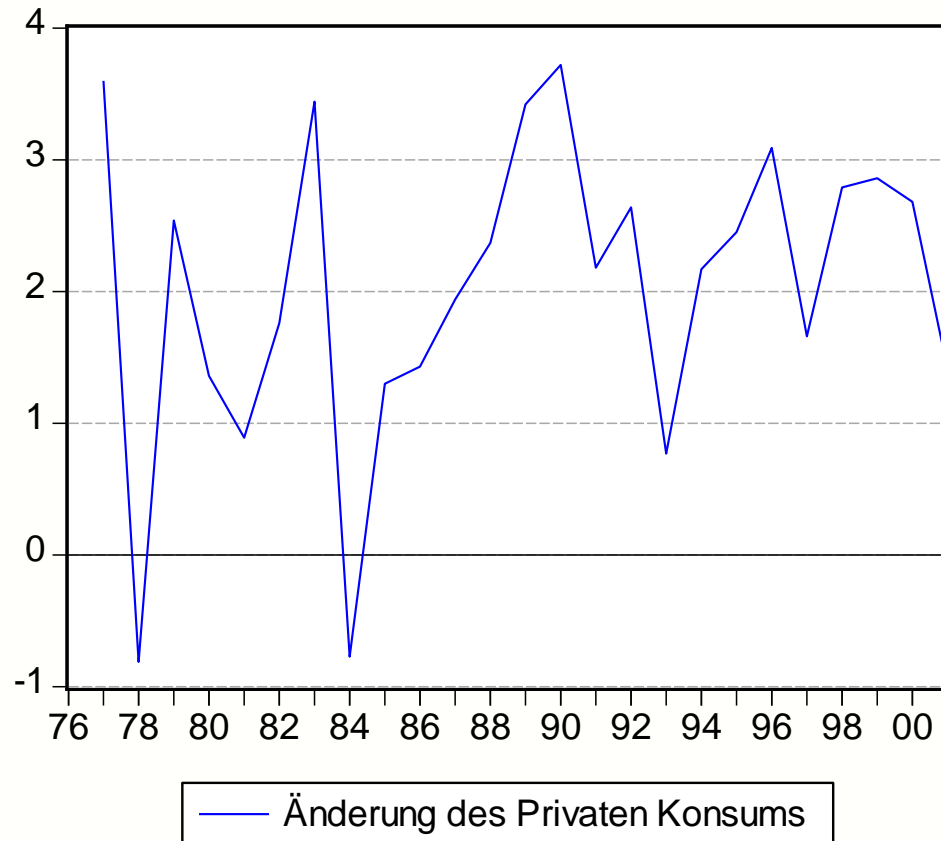
Privater Konsum

Privater Konsum,
Ö, Mrd.EUR,
in Preisen von 1995



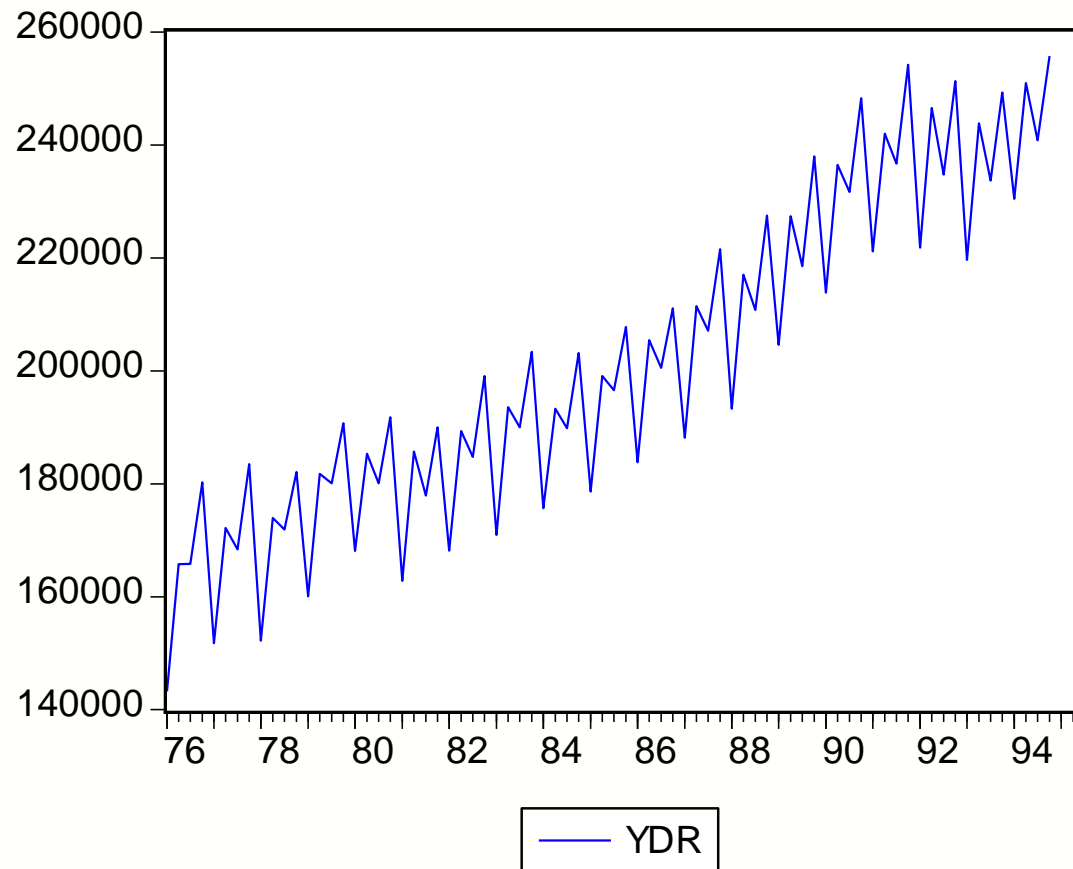
Privater Konsum, Forts.

Änderung des
Privaten Konsums,
Mrd.EUR,
in Preisen von 1995



Persönlich verfügbares Einkommen

Persönlich verfügbares Einkommen, Ö, Quartalsdaten



Zeitreihe

Ist eine zeitlich geordnete Folge von Beobachtungen einer Zufallsvariablen

Beispiele:

- ❑ Jährliche Werte des Privaten Konsums
- ❑ Änderungen der Ausgaben für Privaten Konsum
- ❑ Quartalswerte des persönlich verfügbaren Einkommens
- ❑ Monatliche Werte der Importe

Notation: Zufallsvariable Y

Folge von Beobachtungen: Y_1, Y_2, \dots, Y_n

Zeitreihe wird auch als Realisation eines stochastischen Prozesses aufgefasst

Komponenten einer Zeitreihe

Komponenten oder Charakteristika einer Zeitreihe sind

- Trend
- Saisonalität
- Irreguläre Fluktuationen

Modell einer Zeitreihe soll die Charakteristika möglichst gut repräsentieren

- Darstellung der Zeitreihe
- Prognose (Extrapolation)

Beispiel: $Y_t = \beta t + \sum_i \gamma_i D_{it} + u_t$

mit $D_{it} = 1$ wenn t das i -te Quartal

zum Beschreiben der Entwicklung des persönlichen Einkommens

Stochastischer Prozess

Ist eine Folge von Zufallsvariablen Y_t :

$$\{Y_t, t = 1, \dots, n\}$$

$$\{Y_t, t = -\infty, \dots, \infty\}$$

Gemeinsame Verteilung der Y_1, \dots, Y_n :

$$p(y_1, \dots, y_n)$$

Für viele Fragestellungen: wesentliches Charakteristikum von $p(\cdot)$ ist der Verlauf des Erwartungswertes $\mu_t = E\{Y_t\}$

Beispiel: Extrapolieren einer Zeitreihe zum Zweck der
Prognose

Stationarität

Stationarität eines stochastischen Prozesses: Eigenschaft der gemeinsamen Verteilung, insbesondere

- ▣ der Varianzen $\text{Var}\{Y_t\}$ und
- ▣ der Kovarianzen $\text{Cov}\{Y_t, Y_{t+k}\}$

Kovarianz-Funktion:

$$\gamma_{t,k} = \text{Cov}\{Y_t, Y_{t+k}\}, k = 0, \pm 1, \dots$$

Eigenschaften:

$$\gamma_{t,k} = \gamma_{t,-k}$$

$$\gamma_{t,0} = 1$$

Schwach stationärer Prozess:

$$E\{Y_t\} = \mu \text{ für alle } t$$

$$\text{Cov}\{Y_t, Y_{t+k}\} = \gamma_k, k = 0, \pm 1, \dots \text{ für alle } t \text{ und alle } k$$

auch kovarianz-stationärer Prozess

AC- und PAC-Funktion

Autokorrelations-Funktion (AC-Funktion) ist von Skalierung von Y unabhängig; für stationären Prozess:

$$\rho_k = \gamma_k / \gamma_0, \quad k = \dots, -1, 0, +1, \dots$$

Eigenschaften: $|\rho_k| \leq 1$

$$\rho_k = \rho_{-k}$$

$$\rho_0 = 1$$

Korrelogramm: graphische Darstellung der AC-Funktion

Partielle Autokorrelations-Funktion (PAC-Funktion):

- $\phi_{kk} = \text{Corr}(Y_t, Y_{t-k} | Y_{t-1}, \dots, Y_{t-k+1}), \quad k = \dots, -1, 0, +1, \dots$

ϕ_{kk} ergibt sich aus $Y_t = \phi_{k0} + \phi_{k1} Y_{t-1} + \dots + \phi_{kk} Y_{t-k}$

Partielles Korrelogramm: graphische Darstellung der PACF

AC- und PAC-Funktion, Forts.

Beispiel: Weißes Rauschen

$$\rho_k = \phi_{kk} = 1, \text{ wenn } k = 0,$$

$$\rho_k = \phi_{kk} = 0, \text{ wenn } k \neq 0,$$

Schätzen der AC- und PAC-Funktion:

Schätzer für ρ_k :

$$r_k = \frac{\sum_t (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_t (y_t - \bar{y})^2}$$

Schätzer für ϕ_{kk} ergibt sich als Koeffizient von Y_{t-k} aus Regression von Y_t auf Y_{t-1}, \dots, Y_{t-k}

AR(1)-Prozess

$$Y_t = \varphi Y_{t-1} + \varepsilon_t, \quad \varepsilon_t \text{ Weißes Rauschen}$$

Alternative Darstellung:

$$Y_t = \sum_i \varphi^i \varepsilon_{t-i}$$

Ist $|\varphi| < 1$ ergibt sich

$$\text{Cov}\{Y_t, Y_{t-k}\} = \varphi^k \frac{\sigma^2}{1 - \varphi^2}$$

$|\varphi| < 1$ nennt man die *Stationaritäts-Bedingung*.

AC-Funktion: $\rho_k = \varphi^k, \quad k = 0, 1, \dots$

PAC-Funktion: $\phi_{11} = \varphi, \quad \phi_{kk} = 0 \quad \text{für } k > 1$

AR(p)-Prozess

$$Y_t = \alpha + \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

ε_t Weißes Rauschen

Lag-Operator L : verschiebt den Laufindex um eine Periode

$$L Y_t = Y_{t-1}$$

Es gilt: $L^s Y_t = Y_{t-s}$ und im Speziellen $L^0 Y_t = Y_t$

AR(p)-Prozess:

$$Y_t - \varphi_1 Y_{t-1} - \dots - \varphi_p Y_{t-p} = (1 - \varphi_1 L - \dots - \varphi_p L^p) Y_t = \alpha + \varepsilon_t$$

oder kurz

$$\Phi(L) Y_t = \alpha + \varepsilon_t \quad \text{mit dem Lag-Polynom } \Phi(L)$$

AR(p)-Prozess

Stationaritäts-Bedingung:

Für die p Wurzeln z_i des Charakteristischen Polynoms

$$\Phi(z) = 1 - \varphi_1 z - \dots - \varphi_p z^p$$

muss gelten:

$$|z_i| > 1, \quad i = 1, \dots, p$$

Man sagt die Wurzeln (Nullstellen) liegen außerhalb des Einheitskreises.

AR(p)-Prozess, Forts.

Für stationäre AR(p) Prozesse gilt:

AC-Funktion: fällt geometrisch ab

PAC-Funktion: $\phi_{kk} = 0$ für $k > p$

Sie bricht nach der Ordnung p ab.

Die Kenntnis der Form der AC- und PAC-Funktionen hilft beim Identifizieren der Ordnung des Prozesses.

MA(1)-Prozess

$$Y_t = \alpha + u_t - \theta u_{t-1} = \alpha + \Theta(L)u_t$$

u_t Weißes Rauschen

AR(∞)-Darstellung:

$$Y_t = \alpha/(1-\theta) + u_t + \sum_i \theta^i Y_{t-i}$$

setzt voraus, dass $|\theta| < 1$ (Invertierbarkeits-Bedingung)

Eigenschaften des MA(1)-Prozesses:

- Der Prozess ist für alle α und θ stationär
 - $E\{Y_t\} = \alpha$, $\text{Var}\{Y_t\} = \sigma^2(1+\theta^2)$, $\gamma_1 = \sigma^2\theta$, $\gamma_2 = 0$
- AC-Funktion: $\rho_1 = -\theta/(1-\theta^2)$, $\rho_k = 0$ für $k > 1$
- PAC-Funktion: exponentiell abnehmend, wenn $\theta > 0$, sonst alternierend, exponentiell abnehmend

MA(q)-Prozess

$$Y_t = \alpha + u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} = \alpha + \Theta(L)u_t$$

u_t weißes Rauschen

Eigenschaften des MA(q)-Prozesses:

- MA(q)-Prozess ist stets stationär
- AC-Funktion: $\rho_k = 0$ für $k > q$
- PAC-Funktion:
 - exponentiell abnehmend bei reellen Wurzeln des Charakteristischen Polynoms $\Theta(z) = 0$
 - in Cosinus- oder Sinus-Schwingungen abnehmend bei komplexen Wurzeln des Charakteristischen Polynoms $\Theta(z) = 0$

ARMA(p,q)-Prozess

$$Y_t = \alpha + \varphi_1 Y_{t-1} + \dots + \varphi_p Y_{t-p} + \varepsilon_t$$

$$\varepsilon_t = u_t - \theta_1 u_{t-1} - \dots - \theta_q u_{t-q} = \Theta(L)u_t$$

mit u_t Weißes Rauschen; oder kurz

$$\Phi(L)Y_t = \alpha + \Theta(L)u_t$$

MA(∞)-Darstellung: $Y_t = \psi_0 + \sum_i \psi_i u_{t-i}$ die Koeffizienten ψ_i sind Funktionen der φ_i und θ_i

AR(∞)-Darstellung analog

Stationaritat des ARMA(p,q)-Prozesses: wenn fur alle p Wurzeln z_i des Charakteristischen Polynoms

$$\Phi(z) = 1 - \varphi_1 z - \dots - \varphi_p z^p \quad |z_i| > 1 \text{ gilt.}$$

ARMA(p,q)-Prozess: Übersicht

Bedingung für	AR(p) $\Phi(L)Y_t = u_t$	MA(q) $Y_t = \Theta(L)u_t$	ARMA(p,q) $\Phi(L)Y_t = \Theta(L)u_t$
Stationarität	Wurzeln z_i von $\Phi(z)=0$: $ z_i > 1$	stets stationär	Wurzeln z_i von $\Phi(z)=0$: $ z_i > 1$
Invertibilität	stets invertierbar	Wurzeln z_i von $\Theta(z)=0$: $ z_i > 1$	Wurzeln z_i von $\Theta(z)=0$: $ z_i > 1$
AC-Funktion	gedämpft, unendlich	$\rho_k = 0$ für $k > q$	gedämpft, unendlich
PAC-Funktion	$\phi_{kk} = 0$ für $k > p$	gedämpft, unendlich	gedämpft, unendlich

Identifizieren von ARMA-Modellen

Vergleich der empirischen AC- und PAC-Funktion mit den theoretischen Gegenstücken

Abbruch der

- PAC-Funktion: Hinweis auf Ordnung des AR-Prozesses
- AC-Funktion: Hinweis auf Ordnung des MA-Prozesses

Empirisches Korrelogramm: r_k

Standardfehler aus $\text{Var}\{r_k\} \approx (1+2\sum_i \rho_i^2)/n$ für $k > q$,

wenn $\rho_i = 0$ für alle $i > q$

Analog empirische Partielles Korrelogramm

Anwendung von ARMA Modellen

Mit (univariaten) ARMA Modellen sind kurzfristig i.A. bessere Prognosen zu erzielen, als mit Strukturmodellen.

Vorgansweise: z.B. privater, realer Konsum C_t

Berechnen von $\log(C_t)$ [nicht stationär]

Berechnen von $\Delta \log(C_t)$...

Wachstumsrate von C_t [stationär]

Modellieren von $\Delta \log(C_t)$ als $ARMA(p,q)$

Prognose für die folgenden 4 Perioden