

# Dynamische Modelle: Stabilität und Interpretation

## Kapitel 17

Angewandte Ökonometrie / Ökonometrie III  
Michael Hauser

# Inhalt

- ▶ Kurz- und langfristige Effekte
  - ▶ Einmalige Änderung in  $X$
  - ▶ Permanente Änderung in  $X$
  - ▶ Langfristiges 'Gleichgewicht'
- ▶ Wahl der Lagstruktur
- ▶ Adaptive Erwartungen
- ▶ Anpassungsmodell

## ADL(1,1) rekursiv und explizit

Das ADL(1,1) hat die rekursive Darstellung

$$Y_t = \alpha + \alpha_1 Y_{t-1} + \beta_0 X_t + \beta_1 X_{t-1} + u_t$$

Im Vergleich dazu läßt sich ein AR(1),  $Y_t = \alpha + \alpha_1 Y_{t-1} + v_t$ , darstellen als

$$Y_t - \alpha_1 Y_{t-1} = \alpha + v_t \quad \text{bzw.} \quad (1 - \alpha_1 L) Y_t = \alpha + v_t$$

und durch Division mit  $(1 - \alpha_1 L)$ ,  $|\alpha_1| < 1$  und da  $\alpha/(1 - \alpha_1 L) = \alpha/(1 - \alpha_1)$

$$Y_t = (\alpha + v_t)/(1 - \alpha_1 L) = (\alpha + v_t)(1 + \alpha_1 L + \alpha_1^2 L^2 + \dots)$$

$$Y_t = \alpha/(1 - \alpha_1) + (1 + \alpha_1 L + \alpha_1^2 L^2 + \dots)v_t$$

Angewendet auf das ADL mit  $v_t = \beta_0 X_t + \beta_1 X_{t-1} + u_t$

## Dynamic response: einmalige Änderung in $X$

$$Y_t = \alpha/(1 - \alpha_1) + (1 + \alpha_1 L + \alpha_1^2 L^2 + \dots)(\beta_0 X_t + \beta_1 X_{t-1} + u_t)$$

Wir betrachten den Einfluss einer *einmaligen* Änderung (**impulse**) in  $X_t$  (c.p.) um eine Einheit auf  $Y_{t+i}$ . Das ist die partielle Ableitung von  $Y_{t+i}$  nach  $X_t$  bzw.  $Y_t$  nach  $X_{t-i}$ .

Der *kontemporäre* Effekt,  $i = 0$ :

$$\partial Y_t / \partial X_t = \beta_0$$

## Dynamic response: einmalige Änderung in $X$

Der kurz- bzw. mittelfristige Effekt,  $i > 0$ :

$$\partial Y_{t+1} / \partial X_t = \partial Y_t / \partial X_{t-1} = \beta_1 + \alpha_1 \beta_0$$

$$\partial Y_{t+2} / \partial X_t = \partial Y_t / \partial X_{t-2} = \alpha_1 \beta_1 + \alpha_1^2 \beta_0$$

...

$$\partial Y_{t+i} / \partial X_t = \partial Y_t / \partial X_{t-i} = \alpha_1^{i-1} (\beta_1 + \alpha_1 \beta_0)$$

Eine einmalige Änderung in  $X$  heute bewirkt eine Änderung von  $\alpha_1^{i-1} (\beta_1 + \alpha_1 \beta_0)$  in  $Y$   $i$  Perioden in der Zukunft.

Eine einmalige Änderung in  $X$  vor  $i$  Perioden hat auf das heutige  $Y$  die gleiche Auswirkung.

## Dynamic response: einmalige Änderung in $X$

Der *langfristige* Effekt,  $i \rightarrow \infty$ :

Langfristig geht der Einfluß gegen *null*, da  $|\alpha_1| < 1$ .

Wir nennen

$$\partial Y_t / \partial X_{t-i}$$

**impulse response function, IRF.**

## Dynamic response: permanente Änderung in $X$

Ang wir erhöhen  $X$  in  $t$  um eins und behalten das neue Niveau bei (**step**). Die Auswirkungen in

▶  $t$  sind

$$\partial Y_t / \partial X_t$$

▶  $t + 1$  sind

$$\partial Y_t / \partial X_t + \partial Y_{t+1} / \partial X_t = \partial Y_t / \partial X_t + \partial Y_t / \partial X_{t-1}$$

...

▶  $t + i$  sind

$$\sum_{j=0}^i \partial Y_{t+j} / \partial X_t = \sum_{j=0}^i \partial Y_t / \partial X_{t-j}$$

Wir nennen

$$\sum_{j=0}^i \partial Y_t / \partial X_{t-j}$$

die **cumulative impulse response function**.

## Dynamic response: permanente Änderung in $X$

Langfristig,  $i \rightarrow \infty$ , wirkt

$$\sum_{j=0}^{\infty} \partial Y_{t+j} / \partial X_t = \sum_{j=0}^{\infty} \partial Y_t / \partial X_{t-j}$$

Für den ADL(1,1) gilt

$$\sum_{j=0}^{\infty} \partial Y_t / \partial X_{t-j} = \beta_0 + \sum_{j=1}^{\infty} \alpha_1^{j-1} (\beta_1 + \alpha_1 \beta_0) = \frac{(\beta_0 + \beta_1)}{(1 - \alpha_1)}$$

Die Summe existiert wiederum, solange  $|\alpha_1| < 1$  ist.

## Dynamic response: permanente Änderung in $X$

Der langfristige Effekt einer permanenten Veränderung von  $X$  um eine Einheit ist die Summe aller kurz- bzw. mittelfristigen Effekte aus einmaligen Änderungen.

Den *langfristigen* Effekt einer permanenten Änderung Beziehung in  $X$  erhält man auch aus der langfristigen Beziehung zwischen  $Y$  und  $X$ . Wir setzen

$$Y_t = \bar{Y} = const, \quad X_t = \bar{X} = const, \quad \forall t$$

und erhalten im ADL(1,1) (vgl. das ECM in K16)

$$\bar{Y} = \alpha/(1 - \alpha_1) + (\beta_0 + \beta_1)/(1 - \alpha_1)\bar{X}$$

- ▶ Das ist die **statische Gleichgewichtsbeziehung**.
- ▶ Der Koeffizient vor  $\bar{X}$  ist der **langfristige Multiplikator**.

# Bsp für einmalige und permanente Änderungen

Einige Beispiele für temporäre Änderungen sind:

- ▶ Verschrottungsprämie für PKW in DE 2009
- ▶ 'Autofreier Tag' nach Ölpreisschock 1974
- ▶ Einmalzahlungen bei der Pension
- ▶ einmalige vorzeitige Abschreibungen

Einige Beispiele für permanente Änderungen sind:

- ▶ Zinssatzsteuerung durch die Zentralbank
- ▶ Steuererhöhungen
- ▶ Ölpreis'schocks' (sind i.A. permanent)
- ▶ Technologieschocks, technologische Entwicklungen

# DL(s)

Im DL(s) Modell

$$Y_t = \alpha + \beta_0 X_t + \dots + \beta_s X_{t-s} + u_t$$

ist das statische GGW

$$\bar{Y} = \alpha + (\beta_0 + \dots + \beta_s) \bar{X}$$

Die kurzfristigen Multiplikatoren sind

$$\partial Y_{t+j} / \partial X_t = \partial Y_t / \partial X_{t-j} = \begin{cases} \beta_j & j = 0, \dots, s \\ 0 & j > s \end{cases}$$

## DL(s), durchschnittliche Verzögerung

Die durchschnittliche Verzögerung der Reaktion von  ${}_{t+i}Y$  auf eine einmalige Veränderung in  $X_t$  ist die gewichtetet Summe der Lags.

$$\sum_{i=0}^{\infty} i w_i \quad w_i \geq 0$$

Für das DL(s) sind die Gewichte

$$w_i = \beta_i / (\beta_0 + \dots + \beta_s) \quad \text{und} \quad w_i = 0 \quad i > s$$

sofern alle  $\beta_i \geq 0$ .

Die Partialsumme

$$\sum_{i=0}^k w_i$$

ist die kumulierte Anpassung bis zum Lag  $k$ .

## Koyck-Lag, $0 < \lambda < 1$ , dynamic responses

Der Koyck-Lag hat folgende explizite bzw. rekursive Darstellung

$$Y_t = \alpha + \beta(1 - \lambda) \sum_{i=0}^{\infty} \lambda^i X_{t-i} + u_t$$

$$Y_t = \alpha(1 - \lambda) + \lambda Y_{t-1} + \beta(1 - \lambda) X_t + v_t$$

Die dynamic responses einer einmaligen Veränderung in  $X$ ,  $i \geq 0$

$$\partial Y_{t+i} / \partial X_t = \partial Y_t / \partial X_{t-i} = \beta(1 - \lambda) \lambda^i$$

Sie klingen geometrisch ab.

## Koyck-Lag, $0 < \lambda < 1$ , durchschnittl. Lag

Da  $\sum_0^{\infty} \lambda^i = 1/(1 - \lambda)$ , sind die Gewichte der Lags  $w_i = (1 - \lambda)\lambda^i$ .  
Der durchschnittliche Lag einer einmaligen Veränderung in  $X$  ist in Beobachtungsperioden gemessen:

$$\sum_0^{\infty} i w_i = \lambda/(1 - \lambda)$$

**Tabelle:**  $\lambda$  Werte und die durchschnittliche Anpassungsdauer

$\lambda$	0.1	0.3	0.5	0.7	0.9
$\lambda/(1 - \lambda)$	0.11	0.43	1.00	2.33	9.00

Kleine  $\lambda$  bedeuten eine schnelle Anpassung, große eine langsame.

## Koyck: Beispiel

Die Schätzung einer Konsumfunktion für österreichische Jahresdaten (1977-2001) ergibt

$$\hat{C}_t = -3.477 + 0.766C_{t-1} + 0.260 Y_t^d$$

Ein Vergleich mit der rekursiven Darstellung des Koyck-Modells:

$$\alpha(1 - \lambda) = -3.477, \quad \lambda = 0.766 \quad \text{und} \quad \beta(1 - \lambda) = 0.260$$

Daher ist

$$\alpha = -14.869, \quad \lambda = 0.766, \quad \beta = 1.111(!)$$

Der durchschnittliche Lag,  $\lambda/(1 - \lambda)$ , beträgt daher 3.27 Jahre.

Eine (einmalige) Veränderung im disponiblen Einkommen wirkt mit einer durchschnittlichen Verzögerung von 3 Jahren und 1 Quartal auf den privaten Konsum.

## Wahl der Lagstruktur

## Wahl von Lagstruktur: DL( $s$ )

- ▶ Wählt man in kleinen Stichproben  $s$  zu groß, werden die Freiheitsgrade für die Tests sehr klein.
  - ▶ Damit werden die Tests anfälliger gegenüber Abweichungen von der Annahme der Normalverteilung für die Residuen.
  - ▶ Die Standardfehler werden größer und damit die Macht der Tests geringer.
- ▶ Wenn die  $x$ -Variablen Trend-behaftet oder hoch autokorreliert sind, tritt möglicherweise das Problem der Multikollinearität auf.
- ▶  $s$  ist i.A. nicht bekannt. Üblicherweise geht man so vor, dass die Ordnung  $s$  mit Hilfe eines Informationskriteriums gewählt wird. D.h. man schätzt alle Modelle mit  $s$ -Werten kleiner einem maximalen  $s$ , und wählt dann das Modell mit dem kleinsten AIC oder SBC.

# Einfache Erwartungsbildung

# Adaptive Erwartungen

Ein einfaches Modell für die Erwartungsbildung basierend auf univariater historischer Information sind **adaptive Erwartungen**,  $0 < \lambda < 1$ .

$$X_{t+1}^e = \lambda X_t^e + (1 - \lambda)X_t$$

bzw.

$$(X_{t+1}^e - X_t^e) = (1 - \lambda)(X_t - X_t^e)$$

Die Erwartungen werden proportional zum Fehler aus der Vorperiode angepasst.

Die explizite Darstellung ist

$$X_{t+1}^e = (1 - \lambda)[X_t + \lambda X_{t-1} + \lambda^2 X_{t-2} + \dots]$$

vergleichbar einem  $AR(\infty)$ .

## Verwendung adaptiver Erwartungen

Die Erwartung  $X^e$  wird nicht beobachtet.

- ▶ Sie kann für ein gewähltes  $\lambda$  konstruiert werden, oder
- ▶ es wird die explizite Darstellung in ein Regressionsmodell

$$Y_t = a + bX_{t+1}^e + u_t$$

eingesetzt und die rekursive Darstellung

$$Y_t = a + b(1 - \lambda)[X_t + \lambda X_{t-1} + \lambda^2 X_{t-2} + \dots] + u_t$$

$$Y_t = a(1 - \lambda) + \lambda Y_{t-1} + b(1 - \lambda)X_t + v_t$$

ermittelt. ( $v_t$  ist kein White Noise.) Damit kann das  $\lambda$  aus vorliegenden Daten geschätzt werden.

In der ADL(1,1)-Variante der Konsumfunktion könnte der verzögerte Konsum nicht Ausdruck von habit persistence, sondern von Berücksichtigung zukünftiger Einkommensströme sein.

# Naive Erwartungen

Ist  $\lambda = 0$ , so heißen die Erwartungen **naiv**.

$$X_{t+1}^e = X_t$$

Die Prognose für morgen ist der heutige Wert.

Gehorcht  $X$  einem Random Walk (ohne Drift), ist diese Erwartungsbildung optimal.

$$X_t = X_{t-1} + u_t$$

$u_t$  weißes Rauschen.

# Partielle Anpassung, Anpassungsmodell

## Partielle Anpassung

Das **Anpassungsmodell** hat seine Motivation in geplanten Entscheidungen, die sich nicht sofort zur Gänze realisieren lassen, z.B. gewünschter Lagerbestand, gew. Kapitalstock.

Angenommen der *gewünschte* Lagerbestand,  $K^*$ , hängt vom laufenden Umsatz,  $S_t$ , ab.

$$K_t^* = \alpha + \beta S_t$$

Da der Lagerauf-/abbau eine gewisse Zeit in Anspruch nimmt, kann nur ein Teil,  $(\delta * 100)\%$ , davon realisiert werden. ( $u$  ist WN.)

$$K_t - K_{t-1} = \delta(K_t^* - K_{t-1}) + u_t$$

$\delta$  heißt *Anpassungsparameter*,  $0 < \delta < 1$ .

## Partielle Anpassung

$K^*$  selbst ist nicht beobachtbar. Wir setzen das obige Verhaltensmodell dafür ein.

$$K_t - K_{t-1} = \delta([\alpha + \beta S_t] - K_{t-1}) + u_t,$$

ergibt

$$\Delta K_t = a + bS_t - \delta K_{t-1} + u_t$$

mit  $a = \delta\alpha$  und  $b = \delta\beta$ .

Aus der Schätzung der Gleichung können wir alle Strukturparameter,  $\alpha$ ,  $\beta$  und  $\delta$  bestimmen.

# Übungsbeispiele

- ▶ Hackl 17.A.1: 1.a,b,d
- ▶ Hackl 17.A.2: 1.,4.
- ▶ B17.1: Zeigen sie, dass das adaptive Erwartungsmodell die beste Prognose für einen ARIMA(0,1,1) Prozess gibt.  $\Delta X_t = c + u_t + \beta u_{t-1}$   
*Hinweis:*  $E_{t-1} X_t = X_t^e$ , wenn  $X_t = X_t^e + u_t$  mit  $u_t$  weißes Rauschen.
- ▶ B17.2: Schreiben sie das partielle Anpassungsmodell in Niveaus,  $K_t$ , an. Angenommen sie haben die reduzierte Form geschätzt. Wie lauten die Strukturparameter?