

Kapitel 12:

# Serielle Korrelation in Zeitreihen



Moodle



Lehrbuch

# Das klären wir in diesem Kapitel:

Eigenschaften von OLS mit seriell korrelierten Fehlern

Autoregressive Prozesse erster Ordnung

FGLS bei Autokorrelation

Serielle Korrelation: Robuste Fehler

# Eigenschaften von OLS mit seriell korrelierten Fehlern

# Eigenschaften von OLS mit seriell korrelierten Fehlern

- ▶ OLS ist unverzerrt und konsistent.
- ▶ Das Bestimmtheitsmaß  $R^2$  ist valide.
- ▶ OLS Standardfehler und darauf basierende Tests sind nicht valide.
- ▶ OLS ist nicht effizient.

# Autoregressive Prozesse erster Ordnung

# AR(1) serielle Korrelation

AR(1): Autoregressiver Prozess 1. Ordnung

$$u_t = \rho u_{t-1} + \epsilon_t, t = 1, \dots, n$$

wobei:

- ▶  $u_0$  ein passender Startwert
- ▶  $\rho \in \mathbb{R}$ : unbekannter und fester Parameter
- ▶  $\epsilon_t$  iid Zufallsvariable mit  $E[\epsilon_t|X] = 0$  und  $Var(\epsilon_t|X) = \sigma_\epsilon^2$

# Die Kovarianz zweier Störterme bei AR(1)

Es gilt

$$\text{Cov}(u_t, u_{t-1}) = \text{Cov}(\rho u_{t-1} + \epsilon_t, u_{t-1}) = \rho \text{Var}(u_{t-1}) + \underbrace{\text{Cov}(u_{t-1}, \epsilon_t)}_{=0}$$

und entsprechend:

$$\text{Cov}(u_t, u_{t-s}) = \rho^s \text{Var}(u_{t-s})$$

# Stationäre autoregressive Prozesse

Ein AR(1)-Prozess

$$u_t = \rho u_{t-1} + \epsilon_t$$

ist **stationär**, falls der Erwartungswert  $E[u_t]$  und die Varianz  $Var(u_t)$  für alle Elemente von  $\{u_t\}$  identisch sind:

- ▶  $E[u_t] = \mu \forall t$
- ▶  $Var(u_t) = \sigma^2 \forall t$

## Stationäre autoregressive Prozesse: $|\rho| < 1$

Für  $u_t = \rho u_{t-1} + \epsilon_t$  mit  $\rho \neq 0$  muss also gelten:

$$\underbrace{E[u_t]}_{\mu} = E[\rho u_{t-1} + \epsilon_t] = \rho \underbrace{E[u_{t-1}]}_{\mu} + \underbrace{E[\epsilon_t]}_0,$$

also  $\mu = 0$  oder  $\rho = 1$ .


Ebenso:

$$\underbrace{Var(u_t)}_{\sigma^2} = Var(\rho u_{t-1} + \epsilon_t) = \rho^2 \underbrace{Var(u_{t-1})}_{\sigma^2} + 2\rho \underbrace{Cov(u_{t-1}, \epsilon_t)}_0 + \underbrace{Var(\epsilon_t)}_{\sigma_\epsilon^2}$$

$$\Rightarrow \sigma^2 = \rho^2 \sigma^2 + \sigma_\epsilon^2 \Leftrightarrow \sigma^2 = \frac{\sigma_\epsilon^2}{1 - \rho^2}$$

Damit die Varianz wohldefiniert und positiv ist, muss zusätzlich  $|\rho| < 1$  gelten.

# Drei AR(1) Prozesse



## Varianz-Kovarianz-Matrix von stationären AR(1)

Mit  $\text{Var}(u_t) = \frac{\sigma_\epsilon^2}{1-\rho^2} = \sigma^2$  gilt:

$$\begin{aligned}\Sigma(\mathbf{u}) &= \begin{pmatrix} \text{Var}(u_1) & \text{Cov}(u_1, u_2) & \dots & \text{Cov}(u_1, u_n) \\ \text{Cov}(u_2, u_1) & \text{Var}(u_2) & \dots & \text{Cov}(u_2, u_n) \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(u_n, u_1) & \text{Cov}(u_n, u_2) & \dots & \text{Var}(u_n) \end{pmatrix} \\ &= \sigma^2 \begin{pmatrix} 1 & \rho & \dots & \rho^n \\ \rho & 1 & \dots & \rho^{n-1} \\ \vdots & \vdots & \ddots & \vdots \\ \rho^n & \rho^{n-1} & \dots & 1 \end{pmatrix}\end{aligned}$$

$\Omega$  ist in diesem Fall also nur durch einen Parameter ( $\rho$ ) bestimmt!

## Geeignete Datentransformation: „Quasidifferenzierung“

Betrachte

$$\tilde{u}_t = u_t - \rho u_{t-1} = \rho u_{t-1} + \epsilon_t - \rho u_{t-1} = \epsilon_t, \quad t = 1, \dots, n$$

Der Transformierte Störterm  $\tilde{u}_t = \epsilon_t$  ist iid, erfüllt also  $\Omega = I!$

Definiere mit

$$P = \begin{pmatrix} 1 & 0 & \cdots & 0 & 0 \\ -\rho & 1 & \cdots & 0 & 0 \\ \vdots & \vdots & \ddots & \vdots & \vdots \\ 0 & 0 & \cdots & 1 & 0 \\ 0 & 0 & \cdots & -\rho & 1 \end{pmatrix}$$

die Transformierten Daten:

$$\tilde{\mathbf{y}} = P\mathbf{y} \quad \text{und} \quad \tilde{X} = PX$$

# FGLS bei Autokorrelation

## FGLS bei Autokorrelation

In der Praxis ist  $\rho$  nicht bekannt. Indem wir  $\rho$  durch eine Schätzung  $\hat{\rho}$  ersetzen, erhalten wir FGLS.

Zur Schätzung von  $\hat{\rho}$  können wir die OLS-Residuen  $\hat{u}_t$  des ursprünglichen Modells verwenden. Die OLS-Hilfsregression

$$\hat{u}_t = \rho \hat{u}_{t-1} + \epsilon_t$$

liefert den Schätzwert  $\hat{\rho}$ .


Mit diesem Schätzwert werden die Daten transformiert und die darauf angewandte OLS-Schätzung liefert den FGLS - Schätzer.

Durch die Quasidifferenzierung geht eine Beobachtung verloren. Diese spezielle FGLS - Variante heißt nach ihren Erfindern **Cochrane - Orcutt - Methode**.

# Beispiel: Inflation und Arbeitslosigkeit (Philipps-Kurve)

Benutze die Daten *philipps*.

Regressiere *inf* auf *unem* und erhalte folgende Residuen:



## Beispiel: Inflation und Arbeitslosigkeit (Philipps-Kurve)

Regressiere die Residuen auf ihren ersten Lag ( $\hat{u}_t$  auf  $\hat{u}_{t-1}$ ):

$$\rightarrow \hat{u}_t = 0,572055\hat{u}_{t-1} \\ (0,107465)$$

Der Schätzer für  $\rho$ , also  $\hat{\rho} = 0,572$ , ist signifikant von null verschieden ( $p$ -Wert:  $2 \cdot 10^{-6}$ )

Dies ist ein starker Hinweis auf Autokorrelation der Störterme.

Der  $t$ -Test ist aber nur asymptotische valide (bei großen Stichproben).

## Der Durbin-Watson Test

Die Durbin-Watson (DW) Statistik ist definiert durch:

$$DW = \frac{\sum_{t=2}^n (\hat{u}_t - \hat{u}_{t-1})^2}{\sum_{t=1}^n \hat{u}_t^2}$$

Mit einigen Umformungen können wir zeigen:

$$DW \approx 2(1 - \hat{\rho})$$

Ist  $\hat{\rho} = 0$ , so ist  $DW \approx 2$  und ist  $\hat{\rho} = 1$ , so ist  $DW \approx 0$ .

Für die DW-Statistik gibt es zwei kritische Werte:  $d_U$  und  $d_L$ .

$DW > d_U$  :  $H_0$  kann nicht verworfen werden

$DW \in [d_L, d_U]$  : keine Aussage möglich

$DW < d_L$  :  $H_0$  muss verworfen werden

Der direkte  $t$ -Test auf  $\hat{\rho}$  ist einfacher und sollte bei großen Stichproben vorgezogen werden!

# Breusch-Godfrey Test

1. Schätze  $\mathbf{y} = X\boldsymbol{\beta} + \mathbf{u}$  mit OLS und speichere die Residuen  $\hat{\mathbf{u}}$ .
2. Regressiere  $\hat{u}_t$  auf  $\hat{u}_{t-1}$  **und**  $X$  und berechne das Bestimmtheitsmaß  $R^2$  dieser Regression
3. Teststatistik:  $BG = (n - 1)R^2 \sim_{asy} \chi_1^2$

(In gretl:

Tests  $\rightarrow$  Autokorrelation. Dort wird  $BG = nR^2$  berechnet.)

Der Breusch-Godfrey ist im Gegensatz zum einfachen  $t$ -Test auch dann valide, falls die Regressoren  $X$  nicht strikt exogen sind.

# Serielle Korrelation: Robuste Fehler

## Serielle Korrelation: Robuste Fehler

- ▶ Im Fall seriell korrelierter Störterme überschätzen die OLS-Standardfehler statistische Signifikanz, da weniger unabhängige Variation besteht.
- ▶ Serielle Korrelation-robuste Standardfehler können mit den OLS-Residuen berechnet werden.
- ▶ Das ist nützlich, da FGLS strikt Exogene Regressoren benötigt und eine sehr spezifische Form der Autokorrelation voraussetzt (AR(1) oder allgemeiner AR(q)).

$$\tilde{se}(\hat{\beta}_j) = \left( \frac{se(\hat{\beta}_j)}{\hat{\sigma}} \right)^2 \sqrt{\hat{v}}$$

Die OLS-Standardfehler  $se(\hat{\beta}_j)$  werden normiert und dann mit einem Faktor  $\sqrt{\hat{v}}$  „aufgeblasen“.

## Serielle Korrelation: Robuste Fehler

Der serielle Korrelation-robuste Standardfehler heißt auch **Newey-West Standardfehler**:

$$\tilde{se}(\hat{\beta}_j) = \left( \frac{se(\hat{\beta}_j)}{\hat{\sigma}} \right)^2 \sqrt{\hat{v}}$$

Der Faktor  $\hat{v}$  berechnet sich wie folgt, wobei  $g \in \mathbb{N}$ :

$$\hat{v} = \sum_{t=1}^n \hat{a}_t^2 + 2 \sum_{h=1}^g \left( 1 - \frac{h+1}{g} \right) \sum_{t=h+1}^n \hat{a}_t \hat{a}_{t-1}$$

wobei

- ▶  $\hat{a}_t = \hat{r}_t \hat{u}_t$  ist und  $\hat{r}_t$  das Residuum der Regression von  $x_{tj}$  auf  $x_{t1}, \dots, x_{tk}$
- ▶  $g$  die nächste ganz Zahl an  $\frac{3}{4}n^{\frac{1}{3}}$

... zum Glück brauchen wir uns diese Formel nicht zu merken!

(gretl berechnet diese robusten Standardfehler per Mausklick.)

## Diskussion: robuste Standardfehler

- ▶ Diese Standardfehler sind ebenfalls robust gegenüber Heteroskedastizität und werden demnach **Heteroskedastizitäts und Autokorrelation konsistent (HAC)** genannt.
- ▶ Da gewöhnlich Stichproben von Querschnittsdaten größer sind als von Zeitreihen wurden Heteroskedastizitäts-robuste Standardfehler (aus Kapitel 8) häufiger benutzt.
- ▶ Die Newey-West Standardfehler sind bei starker Autokorrelation und kleinen Stichproben nicht sehr solide.

# Zusammenfassung

- ▶ OLS ist bei Autokorrelation unverzerrt und konsistent, die Standardfehler sind aber falsch und dürfen nicht zur Inferenz benutzt werden.
- ▶ Ein AR(1)-Prozess  $u_t = \rho u_{t-1} + \epsilon_t$  ist stationär, falls  $|\rho| < 1$ .  $\rho$  bezeichnet hier die (Auto-)Korrelation zwischen zwei sukzessiven Störtermen.
- ▶ Durch die Quasidifferenzierung  $\tilde{u}_t = u_t - \hat{\rho}u_{t-1}$  wird die Autokorrelation von AR(1)-Prozessen neutralisiert.
- ▶ Der Durbin-Watson Test oder der Breusch-Godfrey Test können Autokorrelation feststellen.
- ▶ Mit Heteroskedastizitäts- und Autokorrelation konsistenten Standardfehlern (HAC) sind  $t$ - und  $F$ -Tests valide.