

Univ.-Prof. Dr. Robinson Kruse-Becher

# 32681

## Zeitreihenökometrie

### Leseprobe

Einheit 1

Einführung und Stationäre Zeitreihen

Fakultät für  
**Wirtschafts-**  
**wissenschaft**

Das Werk ist urheberrechtlich geschützt. Die dadurch begründeten Rechte, insbesondere das Recht der Vervielfältigung und Verbreitung sowie der Übersetzung und des Nachdrucks, bleiben, auch bei nur auszugsweiser Verwertung, vorbehalten. Kein Teil des Werkes darf in irgendeiner Form (Druck, Fotokopie, Mikrofilm oder ein anderes Verfahren) ohne schriftliche Genehmigung der FernUniversität reproduziert oder unter Verwendung elektronischer Systeme verarbeitet, vervielfältigt oder verbreitet werden. Wir weisen darauf hin, dass die vorgenannten Verwertungsalternativen je nach Ausgestaltung der Nutzungsbedingungen bereits durch Einstellen in Cloud-Systeme verwirklicht sein können. Die FernUniversität bedient sich im Falle der Kenntnis von Urheberrechtsverletzungen sowohl zivil- als auch strafrechtlicher Instrumente, um ihre Rechte geltend zu machen.

Der Inhalt dieses Studienbriefs wird gedruckt auf Recyclingpapier (80 g/m<sup>2</sup>, weiß), hergestellt aus 100 % Altpapier.

# Zeitreihenökometrie - Einführung

Prof. Dr. Robinson Kruse-Becher

FernUniversität in Hagen  
Fakultät für Wirtschaftswissenschaft  
Lehrstuhl für Angewandte Statistik

# Gegenstand des Kurses

- Zeitreihenanalyse für univariate und multivariate Datensätze
- Methoden der angewandten Zeitreihenökometrie
- Anwendungsgebiete in der makroökonomischen Analyse und der Finanzwirtschaft
- Begleitkurs zum neuen Modul 32611 Empirische Makrökonomik

# Anspruch

- Praktische Fragen der empirischen Modellierung stehen im Vordergrund
- Gründliche Methodenkenntnisse werden vermittelt
- Kritische Reflexion der ökonometrischen Verfahren
- Anwendungsbeispiele in R ergänzen die Darstellung unterschiedlicher Methoden
- Direkter Bezug zu Fragestellungen der empirischen Makroökonomik
- Vorkenntnisse in Mathematik und Statistik sind erforderlich

# Thematik

- Behandelte Themen: Univariate Zeitreihenanalyse, Trends, Strukturbrüche und Einheitswurzeln, Multivariate Analyse für stationäre Zeitreihen, Strukturelle Modelle und Kointegration in Einzel- und Mehrgleichungssystemen
- Ausgelassene Themen: Saisonalität und langes Gedächtnis (komplexe Spezialthemen)
- Die Darstellung der Methoden ist so formal wie nötig
- Im Vordergrund steht die empirische Modellierung
- Literaturangaben zu tiefer gehenden Fragestellungen; mögliche Themen für Seminar- und Abschlussarbeiten

## Lehr- und Lernformate

- Lehr- und Lernformat: Lehrtext als Grundlage, Videovorlesungen (asynchron) und synchrone Übungsveranstaltungen
- Grundlage des Kurses ist der Lehrtext von Bernhard Pfaff: Analysis of Integrated and Cointegrated Time Series with R, 2. Auflage 2008, Springer, erschienen in der Reihe "Use R!" bei Springer
- Volltextzugriff (E-Book, online) über die Universitätsbibliothek
- R ist eine führende open-source Statistiksoftware
- Alle R Codes und Daten sind verfügbar zur Replikation der Ergebnisse
- Zu dem verwendeten Lehrtext existieren direkt verknüpfte R Pakete
- Kombinierbar mit RStudio (IDE)

# Inhaltsverzeichnis

- ① Univariate Analyse stationärer Zeitreihen (Kapitel 1)
- ② Univariate Analyse nichtstationärer Zeitreihen (Kapitel 3)
- ③ Bestimmung des Integrationsgrads (Kapitel 5 und 6)
- ④ Multivariate Analyse stationärer Zeitreihen (Kapitel 2)
- ⑤ Kointegration (Kapitel 4, 7 und 8)

Die Kapitelangaben beziehen sich auf Pfaff (2008)



# Univariate Analyse stationärer Zeitreihen

- Lernziele
- Einführung
- Stationarität
- Autoregressive Prozesse
- Moving Average Prozesse
- Autoregressive Moving Average Prozesse
- Zusammenfassung
- Literatur

# Lernziele

- Verständnis fundamentaler Konzepte der Zeitreihenanalyse
- Verständnis für die unterschiedlichen Eigenschaften von Zeitreihen
- Sicherer Umgang mit AR, MA und gemischten ARMA Prozessen
- Fähigkeit zur empirischen Modellierung und Prognose

## Definition diskreter Zeitreihen Prozesse

- Eine (diskrete) Zeitreihe ist definiert als eine zeitlich geordnete Sequenz von Zufallsvariablen
- Diskret meint hier einen fixen zeitlichen Abstand
- Bei zeitstetigen Prozessen wird dieser infinitesimal
- Wir betrachten ausschließlich zeitdiskrete Prozesse
- Ein stochastischer Prozess kann wie folgt formalisiert werden:

$$\{y(s, t), s \in \mathcal{S}, t \in \mathcal{T}\}$$


- Für jedes  $t \in \mathcal{T}$  ist  $y(\cdot, t)$  eine Zufallsvariable auf dem Stichprobenraum  $\mathcal{S}$  und eine Realisation dieses stochastischen Prozesses ist  $y(s, \cdot)$  für jedes  $s \in \mathcal{S}$  mit Bezug auf den Zeitpunkt  $t \in \mathcal{T}$




# Grundidee

- Eine Grundidee der Zeitreihenanalyse (und verwandter Gebiete) ist, den zu Grunde liegenden stochastischen daten-generierenden Prozess (DGP) auf Basis der beobachteten Daten zu modellieren
- Dabei wird also von den empirisch zur Verfügung stehenden Daten auf den zu Grunde liegenden Prozess geschlossen
- Eine der augenscheinlich wichtigsten Eigenschaften von Zeitreihen ist der "Trend"
- Darüber hinaus ist die zeitliche Abhängigkeit von großem Interesse (Autokorrelation)


# Beispiele - Reales BIP in den USA



# Beispiele - Inflationsrate in den USA



# Beispiele - Aktienrenditen in den USA





# Stationarität

- Eines der wichtigsten Charakteristika von Zeitreihen ist die Stationarität bzw. die Nichtstationarität
- Wir unterscheiden die schwache und die starke (bzw. strikte) Form der Stationarität



# Schwache Stationarität

- Ein linearer Trend wäre eine Verletzung dieser Bedingung
- Bedingung (2) betrifft zunächst für  $j = 0$  die (endliche) Varianz von  $y_t$ : Diese muss konstant über die Zeit sein
- Für  $j \neq 0$  beschäftigt sich die zweite Bedingung mit den Autokovarianzen: Diese dürfen nur von dem Zeitabstand  $j$  abhängen, aber nicht von dem Zeitpunkt  $t$
- Die Autokovarianzstruktur muss also überall im Zeitverlauf dieselbe sein
- Autokovarianzen bestimmen die Autokorrelation und somit die (lineare) zeitliche Abhängigkeit in  $y_t$
- Die Verletzung einer der Bedingungen (auch in Teilen) reicht aus, um einen Prozess als nichtstationär zu klassifizieren

# Strikte Stationarität

- Die strikte (oder auch starke) Stationarität verlangt

$$F(y_1, y_2, \dots, y_T) = F(y_{1+j}, y_{2+j}, \dots, y_{T+j}) \quad \forall t, j \in \mathcal{T}$$


wobei  $F(\cdot)$  die gemeinsame Verteilungsfunktion ist

- Diese Definition geht über die ersten beiden Momente hinaus und verlangt dass die gesamte gemeinsame Verteilungsfunktion bei Zeitverschiebung um  $j$  dieselbe ist
- Ein strikt stationärer Prozess (mit endlichen zweiten Momenten) ist somit auch schwach stationär
- Andersherum muss das nicht gelten, da ein Prozess die ersten beiden Bedingungen der schwachen Stationarität erfüllen kann, aber diese Bedingungen nicht für höhere Momente gelten
- In der Praxis beschäftigen wir uns mit der schwachen Stationarität
- (Ergodizität wird im Folgenden nicht benötigt)


# Weißes Rauschen

- Das weiße Rauschen  $\varepsilon_t$  ist der simpelste Zeitreihenprozess
- Eigenschaften:  $E[\varepsilon_t] = 0$ ,  $E[\varepsilon_t^2] = \sigma_\varepsilon^2$  und  $E[\varepsilon_t \varepsilon_{t-j}] = 0$  für alle  $t \neq j$
- Das weiße Rauschen ist (schwach und strikt) stationär
- Unter zusätzlicher Normalverteilung, handelt es sich um Gaußsches weißes Rauschen,  $\varepsilon_t \sim N(0, \sigma_\varepsilon^2)$
- In diesem Fall sind Unkorreliertheit und Unabhängigkeit äquivalent

# Beispiel - Simuliertes Gaußsches weißes Rauschen



# Beispiel - Simuliertes weißes Rauschen, $t(3)$ -Verteilung



## Autoregressive Prozesse erster Ordnung

- Da das weiße Rauschen keinerlei zeitliche Abhängigkeit beinhaltet, wenden wir uns nun dynamischen Prozessen zu
- In autoregressiven Prozessen treiben vergangene Werte die aktuellen und zukünftigen
- Es besteht also eine zeitliche Abhängigkeit
- Der einfachste Fall ist der AutoRegressive (AR) Prozess 1. Ordnung, AR(1):

$$y_t = c + \phi y_{t-1} + \varepsilon_t$$

wobei  $\varepsilon_t$  ein weißes Rauschen ist

- Es handelt sich um eine Differenzgleichung deren Pfad durch den autoregressiven Parameter  $\phi$  bestimmt wird

# Autoregressive Prozesse erster Ordnung

- Für  $\phi = 0$  gibt es keine zeitliche Abhängigkeit und  $y_t$  ist damit eine Konstante  $c$  plus weißes Rauschen  $\varepsilon_t$
- Für  $\phi > 0$  besteht eine positive Abhängigkeit von  $y_t$  zu dem Wert aus der Vorperiode  $y_{t-1}$
- Für den Fall, dass  $\phi = 1$  gilt, akkumulieren sich die Schocks  $\varepsilon_i$  ( $i = 1, 2, \dots, t$ ) und führen zu einem nichtstationären Prozess  $y_t$
- In diesem wichtigen Fall weist  $y_t$  eine sogenannte Einheitswurzel auf
- Dieses Kapitel beschränkt sich auf den kovarianzstationären Fall von  $0 < \phi < 1$
- Der Fall von  $-1 < \phi < 0$  kann analog behandelt werden, ist jedoch kaum von praktischer Relevanz



# Eigenschaften

- Dieser Prozess hat folgende wichtige Eigenschaften
- (1)  $\mu = E[y_t] = \frac{c}{1-\phi}$
- (2)  $\gamma_0 = E[(y_t - \mu)^2] = \frac{\sigma_\varepsilon^2}{1-\phi^2}$
- (3)  $\gamma_j = E[(y_t - \mu)(y_{t-j} - \mu)] = \sigma_\varepsilon^2 \frac{\phi^j}{1-\phi^2}$
- Aus Eigenschaft (1) ergibt sich ein zeitlich konstanter Erwartungswert, der nicht gleich Null sein muss
- Eigenschaft (2) zeigt die zeitlich konstante Varianz und Eigenschaft (3) führt vor, dass die Autokovarianzen  $\gamma_j$  lediglich von  $j$  abhängen, aber nicht von  $t$
- Damit sind alle Bedingungen der schwachen Stationarität erfüllt
- Zudem ist zu erkennen, dass der autoregressive Parameter  $\phi$  alle genannten Größen beeinflusst

# Autokorrelationsfunktion (ACF)

- Aus der Autokovarianzfunktion  $\gamma_j$  folgt die Autokorrelationsfunktion (ACF)


$$\rho_j = \frac{\gamma_j}{\gamma_0}$$

- Im behandelten Fall ergibt sich demnach


$$\rho_j = \phi^j$$

- Damit ist die ACF exponentiell abklingend und strebt gegen 0
- Der autoregressive Parameter  $\phi$  beeinflusst die Stärke der zeitlichen Abhängigkeit


# Beispiel - Simulierter AR(1) Prozess, $c = 0, \phi = 0.5$




# Beispiel - Simulierter AR(1) Prozess, $c = 0, \phi = 0.85$




# Beispiel - Simulierter AR(1) Prozess, $c = 0, \phi = 0.95$




# Beispiel - Simulierter AR(1) Prozess, $c = 0, \phi = 1$




# Beispiel - Simulierte ACF, AR(1) Prozess, $c = 0$ , $\phi = 0.5$




# Beispiel - Simulierte ACF, AR(1) Prozess, $c = 0$ , $\phi = 0.85$



# Beispiel - Simulierte ACF, AR(1) Prozess, $c = 0$ , $\phi = 0.95$



# Beispiel - Simulierte ACF, AR(1) Prozess, $c = 0$ , $\phi = 1$



# Höhere Ordnungen

- Um komplexere Dynamiken zu beschreiben, kann die Ordnung des autoregressiven Prozesses erhöht werden

$$y_t = c + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

Wir sprechen nun von einem  $AR(p)$  Prozess;  $p$  ist die Lagordnung

- Dieser Prozess kann etwas komplexere Abhängigkeitsstrukturen erzeugen als der simple  $AR(1)$  Prozess
- Wir nutzen das Konzept des charakteristischen AR-Polynoms um die Stationarität zu untersuchen
- Dazu benötigen wir den Lag Operator