

# *Zeitreihenanalyse in der Finanzmathematik*

Claudia Michalecz

21. Jänner 2009

# *Inhaltsverzeichnis*

*Grundlagen*

*Modelle*

*Zeitreihenanalyse*


*multivariate Zeitreihen*

# *Der Begriff Zeitreihe*

## *Zeitreihe*

Eine Zeitreihe ist eine (zeitlich) geordnete Folge  $(X_t)_{t \in T}$  von Beobachtungen einer bestimmten Größe, wobei die Reihenfolge der Messungen relevant ist. Im allgemeinen kann von keiner Unabhängigkeit von aufeinanderfolgender Messungen sprechen.

## *Beispiele für Zeitreihen (I)*



Beispiel einer Zeitreihe: täglichen Kursdifferenzen des FTSE100-Indexes zu 1000 Tageswerten zwischen dem 1. Juli 1998 und dem 15. Mai 2002.

## *Beispiele für Zeitreihen (II)*

- Physik
- Marketing
- Finanzmathematik

## *Eigenschaften*

- Zwischen den Werten bestehen (geringe) Abhängigkeiten.
- Serie der Absolutwerte mit greifbaren Abhängigkeiten.
- Bedingte Erwartungswerte nahe null.
- Variierende Schwankungen über die Zeit.
- Leptokurtische Form (spitze Verteilung, starke Wölbung).
- Extreme Werte treten in Gruppen auf.

## *grundlegende Definitionen (I)*

### *streng stationär*

Eine Zeitreihe  $(X_t)_{t \in \mathbb{Z}}$  nennt man streng stationär, wenn die Verteilung jedes endliche Teilsystems mit der Verteilung eines um  $k$  Zeitpunkte verschobenen Teilsystems ident ist.

$$(X_{t_1}, \dots, X_{t_n}) \stackrel{d}{=} (X_{t_1+k}, \dots, X_{t_n+k}), \quad \forall t_1, \dots, t_n, k \in \mathbb{Z}, \forall n \in \mathbb{N}.$$

## *grundlegende Definitionen (II)*

### *schwach stationär*

Die Zeitreihe  $(X_t)_{t \in \mathbb{Z}}$  bezeichnet man als schwach stationär, wenn die ersten zwei Momente existieren, die Erwartungswerte konstant sind und die Kovarianzen nur vom zeitlichen Abstand abhängen:

$$\begin{aligned} \mu(t) &= \mu & t \in \mathbb{Z}, & \text{(mittelwertsstationär)} \\ \gamma(t, s) &= \gamma(t + k, s + k) & t, s, k \in \mathbb{Z} & \text{(schwach stationär)}. \end{aligned}$$

## *grundlegende Definitionen (III)*

### *Autokorrelationsfunktion (ACF)*

Die **Autokorrelationsfunktion (ACF)**  $\rho(h)$  eines schwach stationären Prozesses  $(X_t)_{t \in \mathbb{Z}}$  ist definiert durch:

$$\rho(h) = \rho(X_h, X_0) = \gamma(h)/\gamma(0) \quad \forall h \in \mathbb{Z}$$

# White Noise

## *White Noise Prozess*

Weißes Rauschen oder auch White Noise, ist ein schwach stationärer Prozess  $(X_t)_{t \in \mathbb{Z}}$  mit der Autokorrelationsfunktion:

$$\rho(h) = \begin{cases} 1, & h = 0 \\ 0, & h \neq 0 \end{cases}$$

## *strenger White Noise Prozess*

Eine Serie von unabhängig, identisch verteilten Zufallsvariablen  $(X_t)_{t \in \mathbb{Z}}$  mit endlicher Varianz  $\sigma^2$  wird als strenger White Noise Prozess bezeichnet. Dieser ist das einfachste Beispiel für einen White Noise Prozess.

## *Moving Average Prozess*

### *Moving Average Prozess*

Als ein Moving Average Prozess der Ordnung  $q$  (MA( $q$ )) wird ein Prozess  $(X_t)_{t \in \mathbb{Z}}$  bezeichnet, wenn er sich in folgender Form

$$X_t = \epsilon_t - \beta_1 \epsilon_{t-1} - \dots - \beta_q \epsilon_{t-q} \quad \forall t \in \mathbb{Z}$$

darstellen lässt.

# *Autoregressiver-Prozess*

## *Autoregressiver Prozess*

Als einen Autoregressiven Prozess, auch AR(p)-Prozess, bezeichnet man einen stochastischen Prozess der mit folgender Gleichung darstellbar ist:

$$X_t = \alpha_1 X_{t-1} + \dots + \alpha_p X_{t-p} + \epsilon_t \quad \forall t \in \mathbb{Z}$$

# ARMA-Prozess

## ARMA-Prozess

Sei  $(\epsilon_t)_{t \in \mathbb{Z}}$  ein White Noise Prozess mit Erwartungswert 0 und Varianz  $\sigma^2$ . Ein ARMA(p,q) Prozess mit Erwartungswert 0 ist ein kovariantstetiger Prozess  $(X_t)_{t \in \mathbb{Z}}$ , welcher die Differenzgleichung

$$X_t - \phi_1 X_{t-1} - \dots - \phi_p X_{t-p} = \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q}, \quad \forall t \in \mathbb{Z}$$


erfüllt.

Kombination aus AR(p)- und MA(q)-Prozess.


Definition für einen Prozess mit Erwartungswert  $\mu$  auch anwendbar auf die zentrierte Serie  $(X_t - \mu)$ .

# Darstellung $AR(p)$ , $MA(q)$ und $ARMA(p,q)$


**ARMA**




**MA**




**AR**




**Series arma\_vgl**



**Series ma**



**Series ar**



# ARCH-Prozess



## ARCH-Prozess

$(Z_t)_{t \in \mathbb{Z}}$  sei ein strenger White-Noise-Prozess SWN(0,1). Ein strenger stationärer Prozess  $(X_t)_{t \in \mathbb{Z}}$  wird als ARCH-Prozess bezeichnet, wenn für alle  $t \in \mathbb{Z}$  und einige streng positive Werte  $(\sigma_t)_{t \in \mathbb{Z}}$  folgende Gleichungen erfüllt werden:


$$X_t = \sigma_t Z_t,$$
$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i}^2$$

wobei  $\alpha_0 > 0$  und  $\alpha_i \geq 0$ ,  $i = 1, \dots, p$


# Beispiel ARCH(3)



**Series arch**



**Series arch^2**



## *Eigenschaften ARCH-Prozess*

- Leptokurtische Form.
- $\rho(h)$  nahe null für  $h > 0$ .
- Quadratische Werte weisen Volatitätscluster auf.

## GARCH-Prozess

### GARCH-Prozess



$(Z_t)_{t \in \mathbb{Z}}$  sei ein strenger White-Noise-Prozess  $\text{SWN}(0,1)$ . Ein streng stationärer Prozess  $(X_t)_{t \in \mathbb{Z}}$  wird als GARCH-Prozess bezeichnet, wenn für alle  $t \in \mathbb{Z}$  und einige streng positive Werte  $(\sigma_t)_{t \in \mathbb{Z}}$  folgende Gleichungen erfüllt werden:

$$X_t = \sigma_t Z_t,$$


$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i X_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

für  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$ ,  $i = 1, \dots, p$  und  $\beta_j \geq 0$ ,  $j = 1, \dots, q$ .


# Beispiel GARCH(3,2)



**Series garch**



**Series garch^2**



## *Unterschied von GARCH zu ARCH*

- Varianz abhängig von früheren Varianzen.
- Korrelationen der quadratischen Werte nicht zwingend fallend.

# *Zeitreihenanalyse*

Grundsätzliche Vorgehensweise:

1. Prüfung auf strengen White Noise.
2. Bestimmung eines passenden Modells.
3. Anpassung/Abschätzung der Modellparameter.
4. Prüfung der Gültigkeit des angepassten Modells.
5. Prognose für die Zukunft.

## Analyse mittels ARMA(p,q)-Modell

Bestimmung von p und q mittels Korrelationen und partiellen Korrelationen.

Anpassung der Parameter:

- AR(p)-Prozesse: mittels Yule-Walker-Gleichungen
- ansonsten: mittels Maximum-Likelihood

Gültigkeitsprüfung durch Berechnung der „Zufallswerte“ und Prüfung auf White Noise.

$$\hat{\epsilon}_t = X_t - \hat{\mu}_t,$$
$$\hat{\mu}_t = \hat{\mu} + \sum_{i=1}^p \hat{\phi}_i (X_{t-i} - \hat{m}_u) + \sum_{j=1}^q \hat{\theta}_j \hat{\epsilon}_{t-j}$$

## *ARCH und GARCH*

Schätzung der Ordnung.

Anpassung ebenfalls mittels Maximum-Likelihood:

$$f_{X_0, \dots, X_n}(x_0, \dots, x_n) = f_{X_0}(x_0) \prod_{t=1}^n f_{X_t | X_{t-1}, \dots, X_0}(x_t | x_{t-1}, \dots, x_0)$$

## Beispiel: ARCH(1) (I)

Zu schätzen:  $\alpha_0, \alpha_1$ :

Prozess ist nur abhängig von  $X_{t-1}$ :

$$f_{X_t|X_{t-1}, \dots, X_0}(x_t|x_{t-1}, \dots, x_0) = f_{X_t|X_{t-1}}(x_t|x_{t-1}) = \frac{1}{\sigma_t} g\left(\frac{x_t}{\sigma_t}\right)$$

Die Formel ist zurückführbar auf den Anfangswert  $X_0$ :

$$f_{X_1, \dots, X_n|X_0}(x_1, \dots, x_n|x_0) = \prod_{t=1}^n f_{X_t|X_{t-1}, \dots, X_0}(x_t|x_{t-1}, \dots, x_0)$$

## Beispiel: ARCH(1) (II)

Bildung der bedingten Dichte mit:

$$f_{X_t|X_{t-1}, \dots, X_0}(x_t|x_{t-1}, \dots, x_0) = f_{X_t|X_{t-1}}(x_t|x_{t-1}) = \frac{1}{\sigma_t} g\left(\frac{x_t}{\sigma_t}\right)$$

wobei  $\sigma_t$  sich aus der Vergangenheit direkt berechnen lässt mittels:

$$\sigma_t = \sqrt{\alpha_0 + \alpha_1 x_{t-1}^2}$$

Likelihoodfunktion ergibt sich mit:

$$L(\alpha_0, \alpha_1; X) = f_{X_1, \dots, X_n|X_0}(x_1, \dots, x_n|x_0) = \prod_{t=1}^n \frac{1}{\sigma_t} g\left(\frac{x_t}{\sigma_t}\right)$$

## Beispiel: GARCH(1,1)

Zu schätzen:  $\alpha_0, \alpha_1, \beta$  Funktionsbildung vergleichbar mit ARCH(1)-Prozess.

Wichtiger Unterschied:  $\sigma_0$  ist ebenfalls Startwert.

Likelihoodfunktion:

$$L(\alpha_0, \alpha_1, \beta; X) = f_{X_1, \dots, X_n | X_0, \sigma_0}(x_1, \dots, x_n | x_0, \sigma_0) = \prod_{t=1}^n \frac{1}{\sigma_t} g\left(\frac{X_t}{\sigma_t}\right)$$

mit  $\sigma_t = \sqrt{\alpha_0 + \alpha_1 X_{t-1}^2 + \beta \sigma_{t-1}^2}$ .

## *Benötigte Werte bei ARCH und GARCH*

- $X_1, \dots, X_t$
- $X_{-p+t}, \dots, X_0$
- $\sigma_{-q+1}, \dots, \sigma_0$


Ansatz:

- $X_{-p+t} = \dots = X_0 = \bar{X}$
- $\sigma_{-q+1} = \dots = \sigma_0 = 0$

## *Multivariate Zeitreihen*

- Betrachtung von zwei oder mehr Zeitreihen gemeinsam.
- Zeitwerte werden als Vektoren betrachtet und
- Zeitreihen zusammen als Prozess  $(\mathbf{X}_t)_{t \in \mathbb{Z}}$ .
- Korrelationen nun auch übergreifend.

## *Beispiel: Zusammenhang zweier Zeitreihen*



Gegenüberstellung der Kursdifferenzen von FTSE100 und SMI zwischen dem 1. Juli 1998 und dem 15. Mai 2002.

(a) SMI-Kurs (b) FTSE100-Kurs. (c) Gegenüberstellung mittels QQ-Plot.

## *Grundlegende Definitionen*

- Begriffe vergleichbar mit univariaten Definitionen.
- Korrelations Matrix Funktion ( $P(h)$ ) ersetzt ACF.

### *Multivariater White Noise*

Ein schwach stationärer Prozess  $(X_t)_{t \in \mathbb{Z}}$  ist ein multivariater White Noise Prozess, wenn seine Korrelations Matrix Funktion wie folgt aufgebaut ist:

$$P(h) = \begin{cases} P, & h = 0 \\ 0, & h \neq 0 \end{cases}$$

# VARMA-Prozess

## VARMA-Prozess

Sei  $(\epsilon_t)_{t \in \mathbb{Z}}$  ein multivariater White Noise Prozess  $WN(\mathbf{0}, \Sigma_\epsilon)$ .

Die schwach stationäre Lösung  $(\mathbf{X}_t)_{t \in \mathbb{Z}}$  der Differenzgleichung

$$\mathbf{X}_t - \Phi_1 \mathbf{X}_{t-1} - \dots - \Phi_p \mathbf{X}_{t-p} = \epsilon_t + \Theta_1 \epsilon_{t-1} + \dots + \Theta_q \epsilon_{t-q} \quad \forall t \in \mathbb{Z} \quad (1)$$

wobei die Parameter  $\Phi_i$  und  $\Theta_j$  Matrizen der Form  $\mathbb{R}^{d \times d}$  sind, ist ein VARMA(p,q)-Prozess mit Erwartungswert null.

Ein VARMA(p,q)-Prozess mit Erwartungswert  $\mu$  ergibt sich, wenn der Prozess  $(\mathbf{X}_t - \mu)_{t \in \mathbb{Z}}$  die obige Differenzgleichung erfüllt.

## *multivarianter GARCH-Prozess*

### *multivariater GARCH-Prozess*

$(\mathbf{Z}_t)_{t \in \mathbb{Z}}$  sei ein  $\text{SWN}(\mathbf{0}, I_d)$ . Der Prozess  $(\mathbf{X}_t)_{t \in \mathbb{Z}}$  sei ein multivarianter GARCH-Prozess, wenn er streng stationär und die Gleichung:

$$\mathbf{X}_t = \Sigma_t^{\frac{1}{2}} \mathbf{Z}_t, \quad t \in \mathbb{Z} \quad (2)$$

wobei  $\Sigma_t^{\frac{1}{2}} \in \mathbb{R}^{d \times d}$  der Cholesky-Faktor der positiv-definiten Matrix  $\Sigma_t$  ist.

## *Quellen und weiterführende Informationen*

- Quantitative Risk Management: Concepts, Techniques, and Tools von *Alexander J. McNeil, Rüdiger Frey, & Paul Embrechts, Kapitel 4, Financial Time Series*
- Zeitreihenanalyse von *Rainer Schlittgen und Bernd Streitberg, 6. Auflage, 1995*
- <http://www.luchsinger-mathematics.ch/kap4.pdf>, *Stand: 20.1.2009*
- <http://www.itl.nist.gov/div898/software/dataplot/refman1/auxillar/ljungbox.htm>, *Stand: 20.1.2009*