

Zeitreihe in der Finanzmathematik

Asani Silvia

12. November 2009

Gliederung

1. Einleitung

2. Modelle für Zeitreihen

3. Vorgehensweise von Zeitreihenanalyse

4. Multivariate Zeitreihen

Gliederung

1. Einleitung

- Was sind Zeitreihen?
- Zeitreihenanalyse
- Zusammenhang von Zeitreihen mit der Finanzmathematik

Was sind Zeitreihen?

Definition:

Eine **Zeitreihe** ist eine (endliche) Folge von zeitliche geordneten Beobachtungen/Messwerten.

$$((t_k, y_k) | k = 1, 2, \dots, T)$$

$t_k \in \mathbb{R}$: Zeitpunkt, $t_1 < t_2 < \dots < t_T$.

$y_k \in \mathbb{R}^n$: Messwert(e) zum Zeitpunkt t_k .

Eigenschaften von Zeitreihen

- Geringe Abhängigkeiten zwischen den untersuchten Größen
- Bedingte Erwartungswerte nahe null
- Veränderung der Varianzen über die Zeit

Zeitreihenanalyse

Zeitreihenanalyse

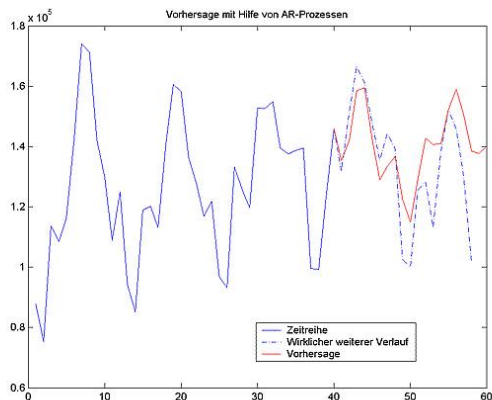
Die Zeitreihenanalyse beschäftigt sich mit der mathematisch - statistischen Analyse von Zeitreihen und der Vorhersage ihrer künftigen Entwicklung.

Anwendung der Zeitreihenanalyse

- besseres Verständnis des zugrunde liegenden Systems
- Prognose
- Erkennen von Veränderungen
- Berechnung von Kennzahlen
- Signalverarbeitung

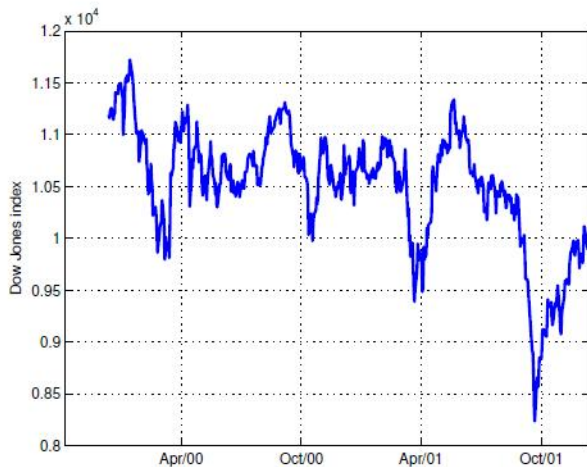
Zusammenhang von Zeitreihen mit der Finanzmathematik

- Vorhersage von Preisen



- Einsatz im Risikomanagement
- Schätzungen von Zinsstrukturen

Dow-Jones-Index



2. Modelle für Zeitreihen

- stationäre Prozesse
- MA(q)-Prozess
- AR(p)-Prozess
- ARMA(p,q)-Prozess
- ARIMA(p,q,d)-Prozess
- Nicht-lineare Zeitreihen

stochastischer Prozess

Definition

Ein **stochastischer Prozess** ist eine Familie von reellen Zufallsvektoren, die auf einem gemeinsamen Wahrscheinlichkeitsraum $(\Omega, \mathcal{F}, \mathbb{P})$ definiert sind:

$$X_t : (\Omega \times \mathbb{T}) \rightarrow \mathbb{R}^n$$
$$(\omega, t) \longmapsto X_t(\omega)$$

stationäre Prozesse (1)

Eine Zeitreihe wird als stationär bezeichnet, wenn ...

- ...sich der Mittelwert nicht mehr ändert,
- ...sich die Varianz nicht mehr ändert,
- ...periodische Variationen nicht mehr vorkommen.

stationäre Prozesse (2)

schwach stationäre Prozesse

Ein stochastische Prozess ist schwach stationär, wenn

- $\mathbb{E}X_t = \mu$ für alle $t \in \mathbb{Z}$
- $\mathbb{V}X_t = \gamma(0) < \infty$, für alle $t \in \mathbb{Z}$
- $\mathbb{C}(X_{t+k}, X_t) = \gamma(k)$, für alle $t, k \in \mathbb{Z}$

strikt stationäre Prozesse

Ein stochastischer Prozess ist strikt stationär, wenn die gemeinsame Verteilung von $(X_{t_1+k}, \dots, X_{t_n+k})$ für alle endlichen Teilmengen $\{t_1, \dots, t_n\} \subset \mathbb{Z}$ und für alle $k \in \mathbb{Z}$ unabhängig von k ist.

stationäre Prozesse (3)

Autokovarianz- und Autokorrelationsfunktion

Die **Autokovarianzfunktion** (*Autokorrelationsfunktion*) eines (*schwach*) stationären Prozesses ist definiert durch

$$\gamma(k) = \mathbb{C}(X_{t+k}, X_t) = \mathbb{E}(X_{t+k} - \mathbb{E}X_t)(X_t - \mathbb{E}X_t)$$

$$\rho(k) = \frac{\gamma(k)}{\gamma(0)}$$

Eigenschaften:

- Symmetrie: $\gamma(k) = \gamma(-k)$
- Positivität: $(\gamma(k)|k \in \mathbb{Z})$ ist positiv semidefinit.
- $-1 \leq \rho(k) \leq 1$, $(\rho(0) = 1)$

White Noise

Definition

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

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

Definition

Eine Serie von unabhängig, identisch verteilten Zufallsvariablen $(X_t)_{t \in \mathbb{Z}}$ mit endlicher Varianz σ^2 wird als **striker White Noise Prozess** $\text{SWN}(\mu, \sigma^2)$ bezeichnet.

Martingal-Differenz

Definition

Erfüllt eine Zeitreihe $(X_t)_{t \in \mathbb{Z}}$ folgende Eigenschaften:

$$\mathbb{E}|X_t| < \infty$$

X_t ist \mathcal{F}_t -messbar

$$\mathbb{E}(X_t | \mathcal{F}_{t-1}) = 0 \quad \forall t \in \mathbb{Z}$$

sagt man sie erfüllt die Eigenschaft der **Martingal-Differenz**.

Moving Average Prozess

Definition

Sei $(\epsilon_t) \sim WN(\sigma^2)$ weißes Rauschen. Einen Prozess

$$X_t = \sum_{k=0}^q b_k \epsilon_{t-k}$$

nennt man **MA-Prozess**. Gilt $b_0 \neq 0, b_q \neq 0$ dann ist (X_t) ein MA-Prozess der Ordnung q (MA(q)).

Eigenschaften:

- MA-Prozesse sind stationär:

$$\mathbb{E}X_t = 0$$

$$\mathbb{V}X_t = \sigma^2 \sum_{i=0}^q b_i^2$$

Autoregressiver Prozess

Definition

Sei $(\epsilon_t) \sim WN(\sigma^2)$ ein White-Noise-Prozess. Dann nennen wir einen Prozess X_t **AR(p)-Prozess** der Ordnung p , wenn er eine Darstellung der Form

$$X_t = a_1 X_{t-1} + \dots + a_p X_{t-p} + \epsilon_t$$

für $a_p \neq 0$ hat.

Eigenschaften:

- $\mathbb{E}X_t = 0$
- $\mathbb{V}X_t = \sigma^2 \sum_{i=0}^{\infty} a^{2i}$.

Autoregressiver Moving Average Prozess


Definition

Ein **ARMA(p, q)-Prozess** mit $p, q \in \mathbb{N}$ und Erwartungswert 0 ist ein schwach stationärer Prozess $(X_t)_{t \in \mathbb{Z}}$, welcher folgende Differenzengleichung erfüllt:


$$X_t - a_1 X_{t-1} - \dots - a_p X_{t-p} = \epsilon_t + b_1 \epsilon_{t-1} + \dots + b_q \epsilon_{t-q}, \quad \forall t \in \mathbb{Z}$$

Darstellungvergleich





ARMA



MA



AR



AR Integrated MA Prozess

Definition

Ein stochastischer Prozess $(X_t)_{t \in \mathbb{Z}}$ wird als **ARIMA**(p, q, d)-**Prozess** mit Schrittweite $d \in \mathbb{N}$ und Ordnungen $p, q \in \mathbb{N}$ bezeichnet, wenn der aus der Differenz gebildete Prozess

$$Y_t = X_t - X_{t-d} \quad \forall t \in \mathbb{Z}$$

die Bedingungen eines ARMA(p, q)-Prozesses erfüllt.

Nicht-lineare Zeitreihen

Autoregressiver Conditionally Heteroskedastic Prozess

Sei $(Z_t)_{t \in \mathbb{Z}}$ ein strikter White Noise Prozess SWN(0,1).

Ein strikt 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:

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

Damit die Varianz immer positiv ist, wird zusätzlich $\alpha_0 > 0$ und $\alpha_i \geq 0$, $i = 1, \dots, p$ gefordert.

Nicht-lineare Zeitreihen

Generalized ARCH Prozess

$(Z_t)_{t \in \mathbb{Z}}$ sei ein strikter White-Noise-Prozess $\text{SWN}(0,1)$. Ein strikt 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(1,1)




Abbildung: Simulation eines GARCH(1,1)-Prozesses

Bemerkungen

ARCH-Prozess

- $\forall X_t$ ist genau dann endlich, wenn $\alpha_1 + \dots + \alpha_p < 1$
- X_t^2 eines ARCH(p)-Prozesses ist ein AR(p)- Prozess

GARCH-Prozess

- $\forall X_t$ ist genau dann endlich, wenn $\alpha_1 + \dots + \alpha_p + \beta_1 + \dots + \beta_q < 1$
- Existiert das vierte Moment von X_t existiert, so ist das Quadrat X_t^2 eines GARCH(p,q)-Prozesses ein ARMA(max(p,q),p)-Prozess

3. Vorgehensweise von Zeitreihenanalyse

- Modellauswahl
- Modellschätzung
- Modelldiagnose
- Einsatzphase des Modelles (Prognose)

Modellauswahl

- graphische Darstellung der empirischen Zeitreihenwerte:
 - ⇒ Existenz von Trends
 - ⇒ Saisonalitäten
 - ⇒ sonstige Auffälligkeiten
- z.B.: lineare Korrelation zwischen Zeitwerten (ARMA-Modell)
- z.B.: nicht-lineare Korrelation zwischen Zeitwerten (ARCH- oder GARCH-Modell)

Informationskriterium

Auswahl der Ordnung p und q eines Modelles!

- Akaikes Informationskriterium

$$\Rightarrow AIC(p, q) := \ln \hat{\sigma}_{p,q}^2 + 2 \frac{(p+q)}{N}$$

- Bayessche Informationskriterium

$$\Rightarrow BIC(p, q) := \ln \hat{\sigma}_{p,q}^2 + \frac{(p+q) \ln N}{N}$$

- Hannan-Quinn Informationskriterium

$$\Rightarrow HQ(p, q) := \ln \hat{\sigma}_{p,q}^2 + \frac{2(p+q) * c * \ln(\ln N)}{N} \quad \text{mit } c > 1$$

Modellschätzung

Die Parameter des ausgewählten Modelles werden geschätzt!

Maximum-Likelihood-Schätzer:

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

Modellschätzung an einem ARCH(p)-Modell

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

$Z_t = \frac{X_t}{\sigma_t}$ N(0,1) - verteilt

Setze für $p = 1$:

Auswahl der zu schätzenden Parameter α_0, α_1 :

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

Modellschätzung an einem ARCH(1)-Modell

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 σ_t sich aus der Vergangenheit berechnen lässt:

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

Likelihoodfunktion:

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

Modellschätzung an einem GARCH(p,q)-Modell

$$X_t = \sigma_t Z_t,$$

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

Setze für $p, q = 1$:

Parameter: $\alpha_0, \alpha_1, \beta$

Startwert: σ_0

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

Modelldiagnose

- 1 Überprüfung ob geschätzte Koeffizienten signifikant von Null verschieden sind (T-Tests)
- 2 Überprüfen inwieweit die empirischen Autokorrelationskoeffizienten mit den vorhergeschätzten Koeffizienten übereinstimmen
- 3 Analyse der Residuen (Differenz zwischen Regressionsgerade & Messwerten)

Einsatzphase

Prognose für die Zukunft

- Modellauswahl
⇒ Verwendung für zukünftige gerichtete Prognosen
- Prognosenfehler
⇒ Analyse von systematischen Abweichungen
- Modell neu auswählen

4. Multivariate Zeitreihen

- Stationäre multivariate Zeitreihen
- Multivariater White Noise Prozess
- multivariate Modelle

Multivariate Zeitreihen

- Betrachtung von zwei oder mehr Zeitreihen gemeinsam
- mehrere Werte pro Zeiteinheit
- Zeitwerte werden als Vektoren betrachtet
- Keine Beschränkung der Korrelation auf einzelne Zeiten, sondern auch zwischen den verschiedenen Zeitreihen

Stationäre multivariate Zeitreihen

schwach stationär

Die multivariate Zeitreihe $(\mathbf{X}_t)_{t \in \mathbb{Z}}$ ist schwach stationär, wenn die ersten zwei Momente existieren, die Erwartungswerte konstant sind und die Kovarianzfunktion nur vom zeitlichen Abstand abhängt:

$$\begin{aligned}\mathbb{E}\mathbf{X}_t &= \mu \quad t \in \mathbb{Z}, \\ \Gamma(t, s) &= \Gamma(t + k, s + k) \quad t, s, k \in \mathbb{Z}\end{aligned}$$

strikt stationär

Eine multivariate Zeitreihe $(\mathbf{X}_t)_{t \in \mathbb{Z}}$ nennt man strikt stationär, wenn jedes endliche Teilsystem in der Verteilung mit einem um s Zeitpunkte verschobenen System ident ist.

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

multivariater White Noise Prozess

multivariater White Noise Prozess

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

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

strikt multivariater White Noise Prozess

Ein Vektor von Serien von identisch, unabhängig verteilten Zufallsvariablen mit endlicher Kovarianz-Matrix ist ein strikt multivariater White Noise Prozess.

multivariate Modelle

Vektor ARMA 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

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

wobei die Parameter Φ_i und Θ_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 μ ergibt sich, wenn der Prozess $(\mathbf{X}_t - \mu)_{t \in \mathbb{Z}}$ die obige Differenzgleichung erfüllt.

multivariate Modelle

multivariater GARCH-Prozess

Der Prozess $(\mathbf{X}_t)_{t \in \mathbb{Z}}$ ist ein **multivariater GARCH-Prozess**, wenn er strikt stationär und die Gleichung:

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

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

Quellenangabe

- Quantitative Risk Management: Concepts, Techniques, and Tools von Alexander J. McNeil, Rüdiger Frey, & Paul Embrechts, Kapitel 4, *Financial Time Series*
- Einführung in die stochastischen Prozesse und Zeitreihenanalyse von Prof. Scherrer, SS09
- http://www.math.uni-hamburg.de/home/drees/VM3_05_06/Kapitel5.pdf

Vielen Dank!