

Zeitreihenanalyse

WS 2005/2006

Gunnar Lischeid

(M. Hauhs, H. Lange)

<http://www.bayceer.uni-bayreuth.de/mod>

- Module M103, *M409*, *M509*
- Vorl.-Nr. 282121

- ergänzend dazu: Blockpraktikum Zeitreihenanalyse
(Februar 2006); *Module M409, M509* (Vorl.-Nr. 28392)

Gliederung

1. Definition und Eigenschaften von Zeitreihen
2. Tests und Trenderkennung für Zeitreihen
3. Fourriertransformation, Powerspektrum
4. Wavelets
5. Zeitreihenmodellierung der ARMA-Klasse (kurzes Gedächtnis)
6. Modellierung von Zeitreihen mit langem Gedächtnis
7. Komplexität und Information von Zeitreihen
8. Wiederkehranalyse
9. Singuläre System-Analyse
10. Skalierung, (Multi-)Fraktale

Literatur zum Thema

Schönwiese, C. (2000): Praktische Statistik für Meteorologen und Geowissenschaftler. Bornträger.

Schlittgen, R. (2001): Angewandte Zeitreihenanalyse. Oldenbourg.

Hipel, K.W., McLeod, A.I. (1994): Time Series Modelling of Water Resources and Environmental Systems. Elsevier.

Tong, H. (1990): Non-linear Time Series. Oxford Science Publ.

Definition: Zeitreihe

Definition: Eine **Zeitreihe** ist eine Menge von Werten, die in einer festgelegten (und bekannten!) **Reihenfolge** vorliegen:

$$X = \{x_i | i = 1, \dots, n\}$$

- Die Zuordnung der Werteposition zum Referenzzeitpunkt ist eine **monotone** Funktion

$$i \rightarrow t_i : i > j \Rightarrow t_i > t_j$$

- Ist der zeitliche Abstand zweier Messungen konstant:

$$t_i - t_{i-1} = \Delta t \neq f(i)$$

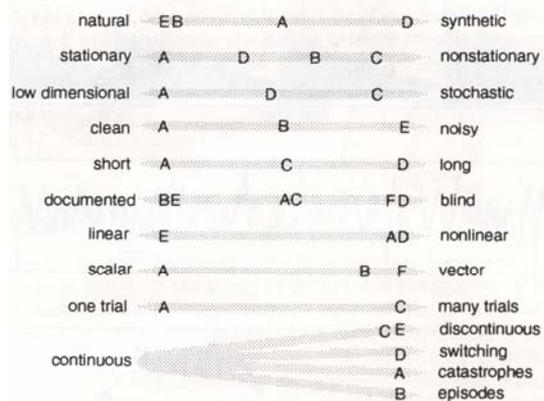
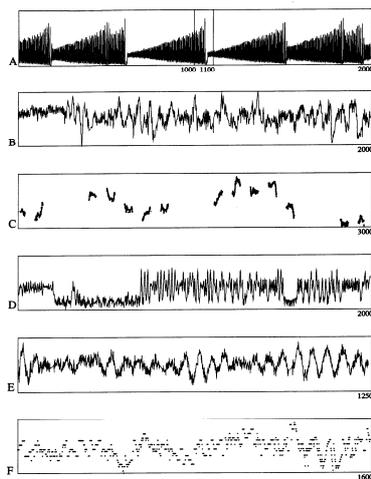
heißt die Zeitreihe **äquidistant**. Es gilt dann $t_i = t_0 + i\Delta t$

- Fehlt ein i in dieser Liste, hat die Zeitreihe eine **Lücke**.

Anwendungsbeispiele

- Börsenkurse
- Wahlverhalten
- Bevölkerungsentwicklung
- Klimatologie
- Hochwassergefährdungsabschätzung
- ...

Zeitreihen: Beispiele



Zugänge

- aus der Physik:
 - Suche nach der Dynamik des erzeugenden Systems (z.B. Geophysik, Meteorologie)
 - der typische Zugang in den **Geowissenschaften**
- aus der Mathematik:
 - als Beispiel für geordnete (oder partiell geordnete) Mengen
- aus den Ingenieurwissenschaften (z.B. Hydrologie):
 - als Ausdruck des empirischen Wissens (Abflüsse)
- aus der Modellbildung:
 - als wichtiges Beispiel zur Demonstration der heutigen technischen Möglichkeiten
 - gibt es einen typischen Zugang für Ökosysteme ?

Ziele

- Frühwarnsystem (Trendanalyse)
- Prozessanalyse (Kausalzusammenhänge)
- Klassifizierung (von Verhalten)
- Vorhersage (Abfluss, Börsenkurs)
- Überprüfung/Optimierung von Modellen

Zeitreihenanalyse in der Geoökologie

- direkteste Verbindung zur experimentellen Beschreibung von Systemen (Datenerhebung)
- kommt (i.d.R.) ohne Annahme von Prozessen aus
- kommt mit gar keinem bis wenigen Parametern aus
- konkrete empirische Beschreibung des zeitlich variablen (dynamischen) Verhaltens
- Vorhersage oft erfolgreicher als bei Prozessmodellen
- Klassifikation von Modellen nach ihrer Erklärungsleistung
- sensibler Test von Modellen ("mehr als r^2 ")

Wichtige Begriffe

- **Univariate** Zeitreihe: Eine (reellwertige) Variable, an einem Ort gemessen
 - **Multivariate** Zeitreihe: mehrere Variablen am selben Ort
 - **Mehrdimensionale** Zeitreihe: eine Variable an verschiedenen Orten zu jeweils gleichen Zeitpunkten
 - **Äquidistante** Zeitreihe
 - **Lückenfreiheit**
 - **Homogenität**: pdf ändert sich nicht mit der Zeit
- > Generelles Problem: viele Eigenschaften beziehen sich auf / sind nur definiert für unendlich lange Zeitreihen

Charakterisierung der Verteilung I

für eine Datenreihe $x(t_i), i = 1, \dots, n$:

- Mittelwert: $\bar{x} = \frac{1}{n} \sum_{i=1}^n x(t_i)$

- Varianz $\sigma^2 = \frac{1}{n-1} \sum_{i=1}^n (x(t_i) - \bar{x})^2$

(Standardabweichung: σ)

- Variationskoeffizient: $cv = \frac{\sigma}{\bar{x}}$

Faustregel:
Zur Berechnung
des q -ten Moments
benötigt man mind.
2q Datenpunkte

- q -tes zentrales Moment: $M_q = \frac{1}{n} \sum_{i=1}^n (x(t_i) - \bar{x})^q$

Charakterisierung der Verteilung II

Häufigkeitsverteilung: Histogramme

- Klassenbreite (Binbreite): $\Delta x = \frac{(x_{\max} - x_{\min})}{n_{\text{bins}}}$

Faustregel: 95% der Klassen (Bins) sollten je mind. 5
Datenpunkte enthalten

Häufigkeitsverteilungen \rightarrow Wahrscheinlichkeitsverteilungen (**pdf's**)

- Median: 50% der Werte sind kleiner
- Modus/Modalwert: Position des Maximums der pdf
- x%-Quantil: x % der Werte sind kleiner

Korrelation

(Produkt-Moment-Korrelation, Pearson r)

$$\text{Varianz: } \sigma^2(x) = \frac{\sum_{i=1}^n (x - \bar{x})^2}{n} = \frac{\sum_{i=1}^n (x - \bar{x}) \cdot (x - \bar{x})}{n}$$

$$\text{Kovarianz: } \text{cov}(x, y) = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{n}$$

$$\text{Korrelation: } r = \frac{\text{cov}(x, y)}{\sqrt{\sigma^2(x)} \cdot \sqrt{\sigma^2(y)}} = \frac{\text{cov}(x, y)}{\sigma_x \cdot \sigma_y}$$

$r^2 = \text{Bestimmtheitsmaß} = \text{erklärte Varianz}$

maximal mögliche Kovarianz

Andere Korrelationsmaße

Spearman-Rangkorrelationskoeffizient:

(D_i : Rangplatzdifferenzen)

$$r_R = 1 - \frac{6 \cdot \sum D_i^2}{n^3 - n}$$

Kendall's τ :

(Ko : Konkordanzen = gleichsinnige Änderungen $x_1 \rightarrow x_2$ und $y_1 \rightarrow y_2$,

Di : Diskordanzen)

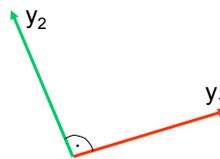
$$r_K = \frac{2 \cdot (Ko - Di)}{n \cdot (n - 1)}$$

Korrelation

= Maß für die Gemeinsamkeiten zweier Funktionen

-> mathematisch bestimmt durch die Multiplikation der jeweils entsprechenden (normierten) Funktionswerte

geometrisches Analog: Skalarprodukt



=> **orthogonale** Funktionen sind nicht korreliert

Faltung (Convolution)

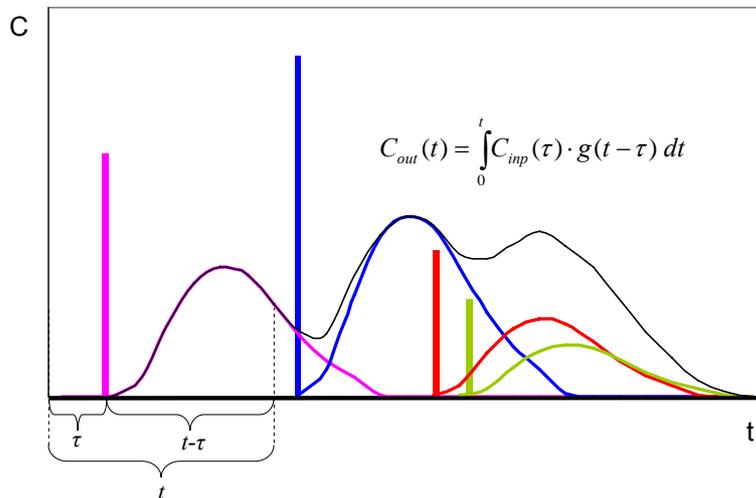
- Verallgemeinerung der Korrelation
- liefert für zwei Funktionen f und g eine dritte Funktion, die die "Überlappung" zwischen f und einer *gespiegelten, verschobenen* Version von g angibt.
- für kontinuierliche Funktionen:

$$(f * g)(t) = \int f(\tau) \cdot g(t - \tau) d\tau$$

- für diskrete Werte:

$$(f * g)(n) = \sum_{k=-\infty}^{\infty} f(k) \cdot g(n - k)$$

Beispiel: Tracer im Vorfluter



Faltung

Anwendungsbeispiele:

- Beschreibung der System*antwort* auf eine *Anregung* durch Faltung der *Anregungsfunktion* mit der *Impulsantwort* des Übertragungsglieds.
- Charakterisierung der Gewichtung einer Funktion mit einer anderen. Der Funktionswert der Gewichtungsfunktion an einer Stelle t gibt an, wie stark der um τ zurückliegende Wert der gewichteten Funktion in den Wert der Ergebnisfunktion eingeht.

Visualisierung der Faltung

Java-Applets:

- <http://www.jhu.edu/~signals/convolve/index.html>
- <http://www.getsoft.net/fouriertrans/animationen/animation04.html>

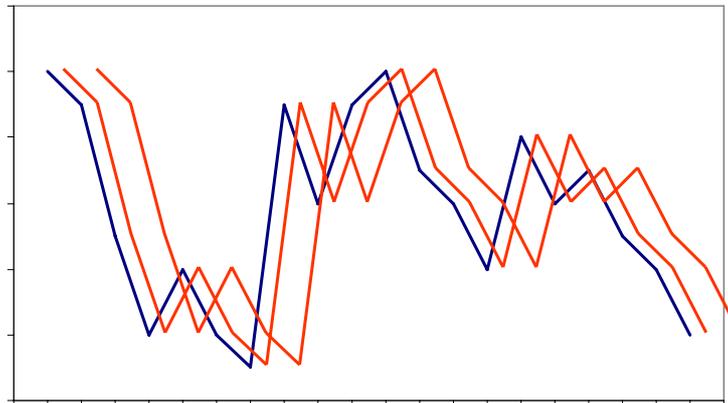
Zeitliche Korrelation

Korrelation:
$$r = \frac{1}{\sigma_x \cdot \sigma_y} \cdot \frac{\sum_{i=1}^n (x - \bar{x}) \cdot (y - \bar{y})}{n}$$
 zeitliche Verschiebung
= time **lag**

Autokorrelation:
$$\rho_{ac,k} = \frac{1}{\sigma_x \cdot \sigma_x} \cdot \frac{\sum_{i=1}^n (x(t_i) - \overline{x(t)}) \cdot ([x(t_i + k)] - \overline{x(t)})}{n}$$

Kreuzkorrelation:
$$\rho_{cc,k} = \frac{1}{\sigma_x \cdot \sigma_x} \cdot \frac{\sum_{i=1}^n (x(t_i) - \overline{x(t)}) \cdot ([y(t_i + k)] - \overline{y(t)})}{n}$$

Autokorrelation



Praktische Hinweise

Faustregeln:

- mindestens 30 Datenpunkte
- nur Lags
 - $k < n/4$ (Puristen) bzw.
 - $k < n/2$ (Pragmatiker) vertrauen
- Daten müssen „im Prinzip“ äquidistant vorliegen;
Lücken sind ein echtes Problem!

Test für (lineare) Unkorreliertheit

Berechnung der Autokorrelation. Für unkorrelierte Daten gilt:

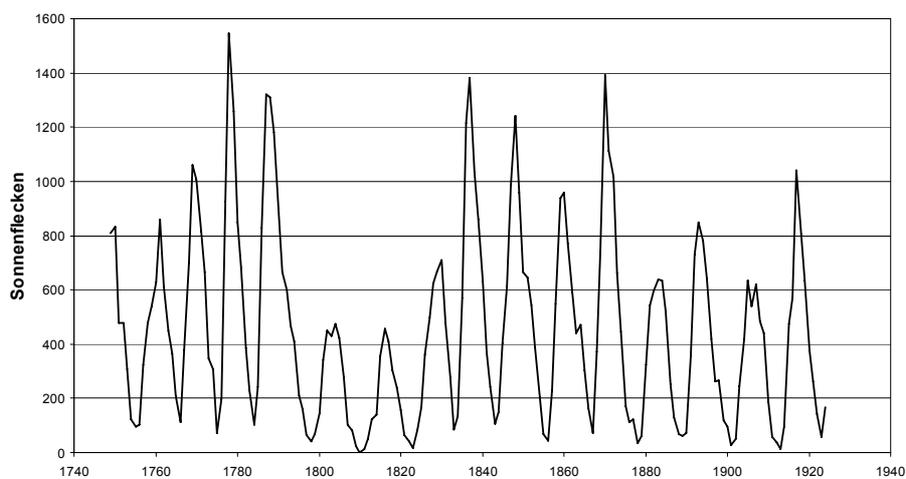
$$\rho_k \sim N\left(0, \frac{1}{n}\right) \quad (\text{normalverteilt})$$

Daher sind die 95%-Signifikanzlinien

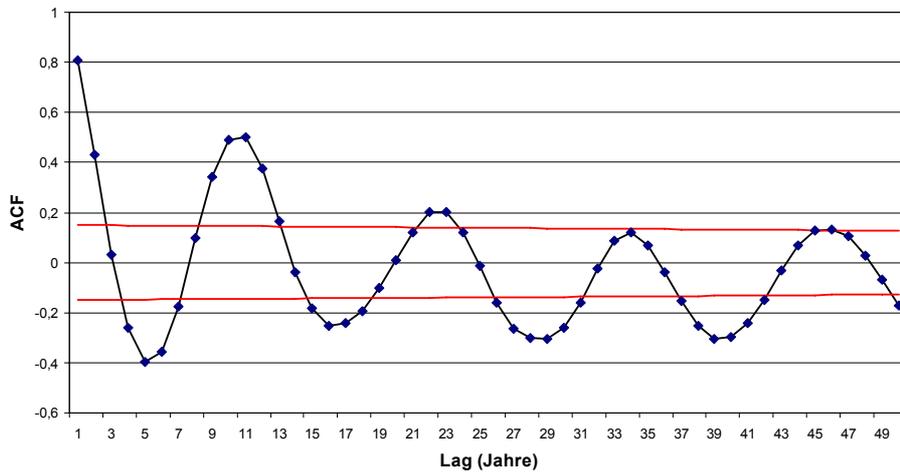
$$SL_{0,95} = \pm \frac{1.96}{\sqrt{n}} \quad (\text{evtl. Verbesserungen für kleine } n)$$

Liegen weniger als 5% der Werte außerhalb des Intervalls, liegen keine signifikanten Korrelationen vor \Rightarrow Autokorrelationslänge

Beispiel: Sonnenfleckenzahlen



Autokorrelation der Sonnenflecken

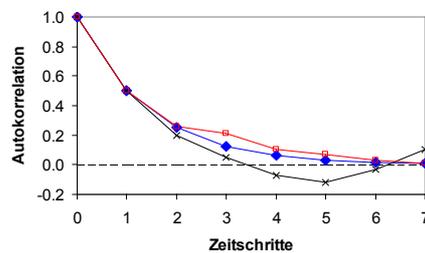


Partielle Autokorrelation

Bsp.: Autokorrelation für 1 Zeitschritt = $\rho_{1,\Delta t}$

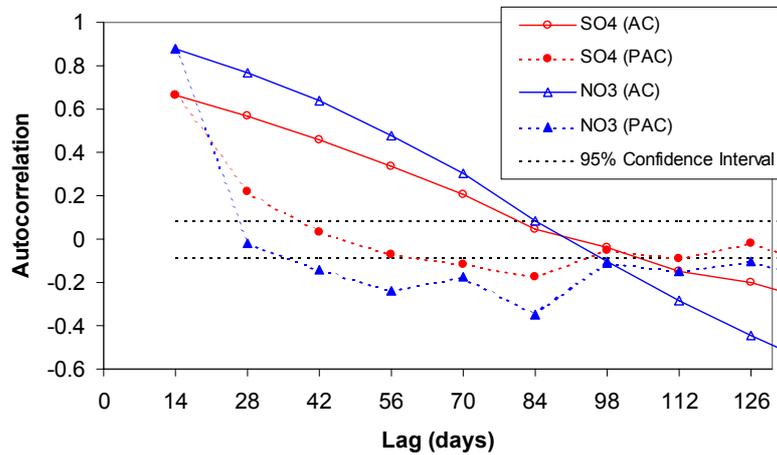
=> Autokorrelation für 2 Zeitschritte = $\rho_{1,\Delta t} \cdot \rho_{1,\Delta t} = \rho_{1,\Delta t}^2$

=> Autokorrelation für n Zeitschritte = $\rho_{1,\Delta t}^n$



=> Die beobachtete Autokorrelation setzt sich aus den Beiträgen der einzelnen Zeitdifferenzen Δt zusammen (**Partielle Autokorrelationen**)

Bsp.: Autokorrelation



Wann ist eine Zeitreihe eine Zeitreihe?

Gibt es signifikante Autokorrelationen, ist die zeitliche Reihenfolge wichtig. Die einzelnen Werte sind dann *nicht* unabhängig.

Unabhängigkeit erreicht man durch

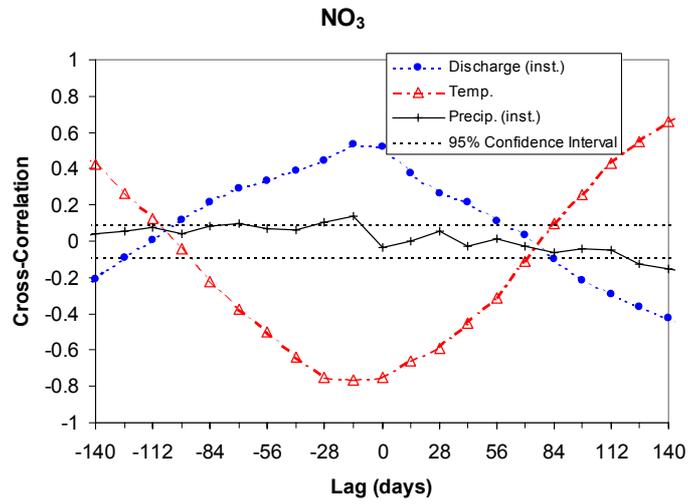
- Aggregation
- Wahl einer gröberen Messauflösung

Falls unabhängig:

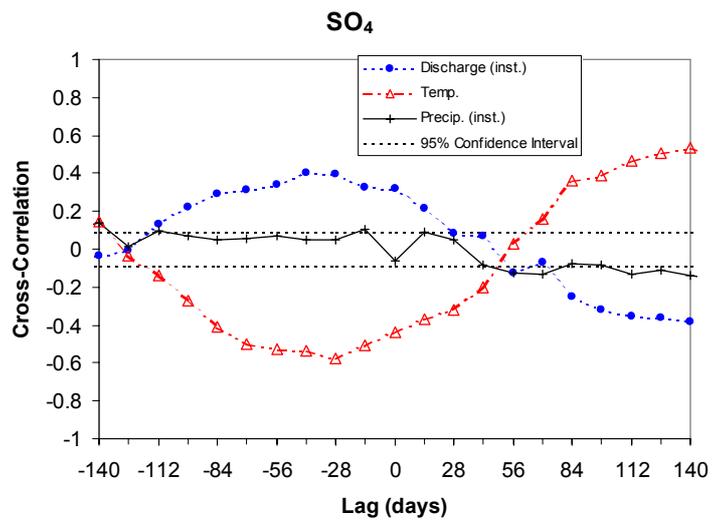
Zeitreihen als *Realisationen eines stochastischen Prozesses*

I.a. liegen Mischtypen vor (z.B. additives Rauschen)

Bsp.: Kreuzkorrelation



Bsp.: Kreuzkorrelation



Eigenschaften der Kreuzkorrelation

$$-1 \leq \rho_{uv}(k) \leq 1$$

$\rho_{uv}(k)$ ist *nicht* symmetrisch: $\rho_{uv}(-k) \neq \rho_{uv}(k), -\rho_{uv}(k)$

95% Signifikanz: $|\rho_{uv}(k)| > 1.96 / (n - |k|)^{1/2}$

Lag-Beschränkung: $-n/4 \leq k \leq n/4$