

## Hinweise

**Seminar** zu aktuellen Themen der ökologischen Modellbildung (M 409):

„Der Klimawandel: wissenschaftliche Erkenntnis,  
gesellschaftliche Diskussion, politische Bedeutung“

Anmeldungen bis 15.11.05

**Seminar:** Forschungswerkstatt „Modellbildung und Simulation“

Wallenfels 20.1. – 22.1.05, Vorbespr. 24.11.05, 14:00 Uhr

**Diplomarbeit:** „Entwicklung multivariater Indikatoren der  
Grundwasserbeschaffenheit in Nordbayern“

in Kooperation mit dem *Bayerischen Landesamt für Umwelt*  
(vorher: *Bayerisches Geologisches Landesamt*)

## Tests und Trenderkennung

(Oft) gewünschte oder geforderte Eigenschaften von Zeitreihen:

Eigenschaft	Anmerkungen	Test
Normalität	gegeben. Transformation der Daten	Kolmogorov-Smirnov, Shapiro-Wilks, $\chi^2$ -Test
Ergodizität	pragmatisch: Sättigung der Statistik	<i>für empirische Daten nicht testbar</i>
Linearität		<i>lineare Modelle</i>
Stationarität = Trendfreiheit	<ul style="list-style-type: none"><li>• Stationarität des Mittelwertes („Trend“ i.e.S.)</li><li>• Stationarität der Varianz (Homoskedastizität)</li><li>• allgemein: Konstanz aller Momente</li></ul>	Mann-Kendall-Test  Bartlett-Test, Levene-Test  Witt-Test

## Mann-Kendall-Test

**Ziel:** Überprüfung auf Trend des Mittelwerts

**Motivation:** viele statistische Verfahren setzen Trendfreiheit voraus

**Prinzip:** Vergleich der Anzahl der Konkordanz ( $x(t_1) > x(t_2)$  für  $t_1 > t_2$ ) und der Diskordanz ( $x(t_1) < x(t_2)$  für  $t_1 > t_2$ )

**Erweiterung:** Seasonal Kendall Test (Trendanalyse getrennt z.B. für einzelne Jahreszeiten)

**Beziehungen zu anderen Verfahren:** Trendfreiheit ist Voraussetzung für viele andere Verfahren

## Kendall-Test

= nicht-parametrischer (verteilungsfreier) Test für bivariate Korrelationen

**Prinzip:** Vergleich der Anzahl der Konkordanz  $n_c$  ( $i < j \Rightarrow x_i < y_j$ ) bzw. der Diskordanz  $n_d$  bzw. der Differenz  $S = n_c - n_d$ :

$$S = n_c - n_d = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x_k - y_j) \quad \text{sgn}(x) = \begin{cases} +1 & x > 0 \\ 0 & x = 0 \\ -1 & x < 0 \end{cases}$$

$$\text{Kendalls } \tau: \quad \tau = \frac{n_c - n_d}{n(n-1)/2} = \frac{S}{n(n-1)/2}$$

mit  $-1 \leq \tau \leq 1$

$n(n-1)/2$  = Anzahl der Vergleiche

## Korrektur für verbundene Ränge

**verbundene Ränge (ties):** identische Werte, die dem gleichen Rang zugeordnet werden

=> erfordern Korrektur für Kendalls  $\tau$  - (statt  $\tau = \frac{n_c - n_d}{n(n-1)/2}$ ):

$$\tau = \frac{n_c - n_d}{\sqrt{\left[ n(n-1)/2 - \sum_{i=1}^{n_{vRx}} n_{vRx i} (n_{vRx i} - 1)/2 \right] \cdot \left[ n(n-1)/2 - \sum_{i=1}^{n_{vRy}} n_{vRy i} (n_{vRy i} - 1)/2 \right]}}$$

mit  $n_{vRx}$ ,  $n_{vRy}$ : Gesamtzahl aller verbundenen Ränge für  $x$  bzw.  $y$   
 und  $n_{vRx i}$ ,  $n_{vRy i}$ : Zahl der  $i$ -ten verbundenen Ränge

## Der Mann-Kendall Test

Anwendung des Kendall-Tests auf Zeitreihen (d.h., sortiert nach Zeit, ohne doppelte Einträge) => Trendtest:

$$S = \sum_{k=1}^{n-1} \sum_{j=k+1}^n \text{sgn}(x(t_k) - x(t_j)) \quad \text{sgn}(y) = \begin{cases} +1 & y > 0 \\ 0 & y = 0 \\ -1 & y < 0 \end{cases}$$

Für die  $H_0$ -Hypothese (= "es gibt keinen Trend") gilt dann:

$$E(S) = \bar{S} = 0$$

$$\text{var}(S) = \sigma^2(S) = \frac{n(n-1) \cdot (2n+5)}{18}$$

=> normalverteilt

=> Ableitung der Testgröße: Abweichung der beobachteten (normierten)  $S$  von den laut  $H_0$  erwarteten

## Der Mann-Kendall Test

beachte: Korrektur für verbundene Ränge (Ranggleichheit) notwendig

=> statt

$$\text{var}(S) = \sigma^2(S) = \frac{n(n-1) \cdot (2n+5)}{18}$$

$$\text{var}(S) = \sigma^2(S) = \frac{n(n-1) \cdot (2n+5) - \sum_{j=1}^p n_{vR_j} (n_{vR_j} - 1) \cdot (2n_{vR_j} + 5)}{18}$$

$n_{vR_j}$  = Anzahl der Werte jeweils gleicher Ränge,

$p$  = Anzahl der Gruppen verbundener Ränge

=> Teststatistik:  $\tau = \frac{S}{D}$  (für große  $n$  annähernd normalverteilt),

wobei  $D$  = maximal mögliche Anzahl der Konkordanzan:

$$D = \sqrt{\frac{1}{2}(n(n-1) - \frac{1}{2} \sum_{j=1}^p n_{vR_j} (n_{vR_j} - 1))} \cdot \sqrt{\frac{1}{2}n(n-1)}$$

## Saisonaler Mann-Kendall Test

$n$  Beobachtungen pro Saisonteil (z.B. fester Tag im Jahr),

$m$  Saisonteile pro Saison (z.B. 365 Tage/Jahr)

$x_{ig}$   $i$ -te Beobachtung im  $g$ -ten Saisonteil

$$S_g = \sum_{i=1}^{n-1} \sum_{j=i+1}^n \text{sgn}(x_{jg} - x_{ig}), \sigma_g = \sqrt{n(n-1)(2n+5)/18}$$

$$S = \sum_{g=1}^m S_g, \sigma_S^2 = \sum_{g=1}^m \sigma_g^2 + \sum_{\substack{g,h \\ g \neq h}} \text{cov}(S_g S_h)$$

- Entmaskierung von Gesamttrends
- Trends in einzelnen Saisonteilen (z.B. Monaten)

## Trendbeseitigung

Linearer Trend des Mittelwertes:

- $\tilde{x}(t) = x(t) - x'(t)$  mit der Regressionsgeraden  $x'(t) = a + b \cdot x(t)$

Saisonaler Trend des Mittelwertes:

- stufenweise:  $\tilde{x}(t) = x(t) - \bar{x}_j$  mit  $j = 1, \dots, p$  Saisons
- $\tilde{x}(t) = x(t) - x'(t)$  mit der Regression  $x'(t) = \sum_{j=1}^{n_f} a_j \cdot \sin(b_j \cdot [x(t) - c_j])$   
für  $n_f$  ausgewählte Frequenzen

## Tests auf Homoskedastizität

Eine Zeitreihe heißt homo-(hetero-)skedastisch, wenn ihre Varianz fensterweise konstant (variabel) ist.

**Übliche Tests:**

- Bartlett-Test
- Levene-Test
- ...

## Bartlett-Test

- Bartlett (1937)
- Voraussetzung:  $x$  ist (annähernd) normalverteilt
- Die Zeitreihe wird in  $p$  Fenster aufgeteilt mit jeweils  $n_i$  Werten

• Bartlett-Testgröße 
$$T = \frac{(n-p) \cdot \ln \sigma_p^2 - \sum_{i=1}^p (n_i - 1) \cdot \ln \sigma_i^2}{1 + \frac{1}{3(p-1)} \cdot \left( \sum_{i=1}^p \frac{1}{n_i - 1} - \frac{1}{n-p} \right)}$$

$$\text{mit } \sigma_p^2 = \frac{1}{n-p} \cdot \sum_{i=1}^p (n_i - 1) \cdot \sigma_i^2$$

- $T$  ist  $\chi^2$ -verteilt mit  $p-1$  Freiheitsgraden

## Levene-Test

- Levene (1960)
- weniger empfindlich gegen Verstoß gegen die Annahme der Normalverteilung
- Die Zeitreihe wird in  $p$  Fenster aufgeteilt mit jeweils  $n_i$  Werten

• Levene-Testgröße 
$$W = \frac{(n-p) \cdot \sum_{i=1}^p n_i (\bar{z}_i - \bar{z}_.)^2}{(p-1) \cdot \sum_{i=1}^p \sum_{j=1}^{n_i} (z_{ij} - \bar{z}_i)^2}$$

$$\text{mit } z_{ij} = |x_{ij} - \bar{x}_i|$$

(robuster: Median statt arithm. Mittel)

- ist  $F$ -verteilt mit  $(p-1, n-p)$  Freiheitsgraden

## Stationaritätstest nach Witt et al. (1998)

**Ziel:** Überprüfung der Konstanz der Momente (Verteilung) innerhalb der Zeitreihe

**Motivation:** Voraussetzung vieler statistischer Verfahren

**Prinzip:** Vergleich der Histogramme für Fenster bestimmter Länge

**Voraussetzungen:** keine

**Beziehungen zu anderen Verfahren:** Stationarität ist Voraussetzung für viele andere Verfahren

## Stationaritätstest nach Witt et al. (1998)

- Aufteilung der Zeitreihe in  $p$  Fenster der jeweils gleichen Länge  $l$

$$x_{\tau}^j = x_{(j-1)l+\tau}, j = 1, \dots, n; \quad \tau = 1, \dots, l$$

- Histogramm der Werte in jedem Fenster mit  $r$  Klassen (*bins*). Werte des  $i$ -ten Fensters in der  $k$ -ten Klasse:

$$\left\{ x_{\rho_1}^i, x_{\rho_2}^i, \dots, x_{\rho_{R_k}^i}^i \right\} \quad R_k^i : \text{Anzahl der Elemente der Klasse}$$

(Bedingung:  $R_k^i > 20$  in allen Bins)

- Teststatistik für  $p$  Fenster

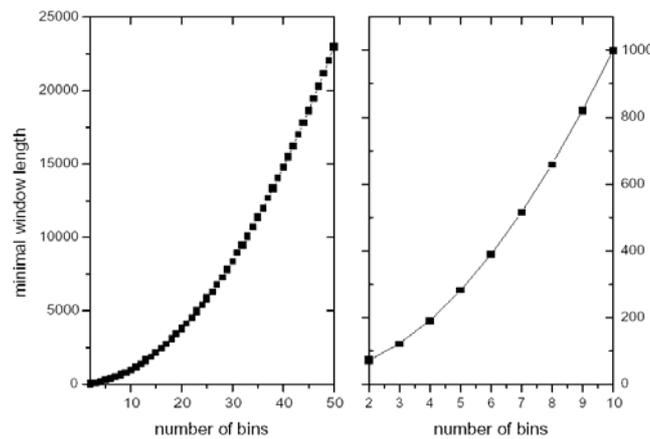
$$t_{A,p} = p^2 l^2 \frac{\sum_{k=1}^r \sum_{i=1}^p (R_k^i - R_k / p)^2}{\sum_{j=1}^p \sigma^2(R_k^j)} \quad (R_k = \sum_{i=1}^p R_k^i)$$

ist asymptotisch  $\chi^2$ -verteilt mit  $(r-1)(p-1)$  Freiheitsgraden

## Erforderliche Datenmenge

Für eine verlässliche Abschätzung der  $\chi^2$ -Verteilung

bei  $p$  Klassen gilt für die minimale Fensterlänge:  $l > \frac{9 \cdot p^3}{p-1}$



## Aufgabe

1. Bestimmen Sie im gegebenen Datensatz die Trends der Mittelwerte jeweils durch Regression der Messwerte mit der Zeitachse.
2. Führen Sie für jeden Parameter eine Trendanalyse mittels des Kendall-Tests durch.
3. Teilen Sie den Datensatz in 5 Fenster gleicher Länge, erstellen für einen Parameter in jedem Fenster ein Histogramm oder die kumulative Häufigkeitsverteilung, und stellen die Ergebnisse in einer Grafik dar.