

Kapitel VIII

Nichtlineare Modelle, Stochastische Prozesse

- 1 Nichtlineares Regressionsmodell
- 2 Verallgemeinertes lineares Modell (GLM)

3 Stochastische Prozesse

Unser Schätz- und Test-theoretischer Ansatz in V.3 und VI.4 ist allgemein genug, um parametrische statistische Analysen in stochastischen Prozessen durchführen zu können. In der Tat, wir haben zugelassen, dass die Zufallsvariablen X_1, \dots, X_n Abhängigkeiten aufweisen. Allerdings beschränken wir uns hier ausschließlich auf den Fall des Likelihoods bzw. des *Quasi*-Likelihoods.

3.1 Likelihood und Scorevektor

Sei $f(x_1, \dots, x_n, \vartheta)$ die gemeinsame Dichte der X_1, \dots, X_n . Dann wird die bedingte Dichte $f_{(i-1)}(x_i, \vartheta)$ von X_i , gegeben X_1, \dots, X_{i-1} gemäß II 5.3 durch

$$f_{(i-1)}(x_i, \vartheta) = \frac{f(x_1, \dots, x_i, \vartheta)}{f(x_1, \dots, x_{i-1}, \vartheta)} \quad [f_{(0)}(x_1, \vartheta) \equiv f(x_1, \vartheta)]$$

definiert. Die Bezeichnungen $\mathbb{E}_{(i-1), \vartheta}$, $\text{Var}_{(i-1), \vartheta}$, $\mathbb{V}_{(i-1), \vartheta}$ beziehen sich dann auf diese Dichten, insbesondere gelten mit der Abkürzung $X^{(i-1)} = (X_1, \dots, X_{i-1})$ die Notationen

$$\mathbb{E}_{(i-1), \vartheta}(\cdot) = \mathbb{E}_{\vartheta}(\cdot | X^{(i-1)}), \quad \text{Var}_{(i-1), \vartheta}(\cdot) = \mathbb{E}_{\vartheta}((\cdot - \mathbb{E}_{(i-1), \vartheta}(\cdot))^2 | X^{(i-1)}).$$

Wir führen Vertauschbarkeitsbedingungen wie in V 1.1 ein, jetzt aber für bedingte Dichten formuliert ($\int \equiv \int_{-\infty}^{\infty}$).

$$\frac{d}{d\vartheta} \int f_{(i-1)}(x, \vartheta) dx = \int \frac{d}{d\vartheta} f_{(i-1)}(x, \vartheta) dx, \quad i = 1, 2, \dots \quad V^{(1)}$$

$V^{(2)}$ möge die gleiche Bedingung mit zweiten anstatt ersten Ableitungen bezeichnen. Die linke Seite von $V^{(1)}$ und von $V^{(2)}$ ist gleich Null. Die log-Likelihoodfunktion $\ell_n(\vartheta)$ einer Beobachtung X_1, \dots, X_n lautet

$$\ell_n(\vartheta) = \sum_{i=1}^n \log f_{(i-1)}(X_i, \vartheta).$$

Mit der Abkürzung

$$u_i(\vartheta) = \frac{d}{d\vartheta} \log f_{(i-1)}(X_i, \vartheta) = \frac{\frac{d}{d\vartheta} f_{(i-1)}(X_i, \vartheta)}{f_{(i-1)}(X_i, \vartheta)} \quad (3.1)$$

läßt sich der Scorevektor $U_n(\vartheta) = \frac{d}{d\vartheta} \ell_n(\vartheta)$ in der Form

$$U_n(\vartheta) = \sum_{i=1}^n u_i(\vartheta) \quad (3.2)$$

schreiben. Unter der stillschweigend gemachten Voraussetzung, dass $\mathbb{E}_\vartheta |u_i(\vartheta)|^2 < \infty$ für alle $i = 1, 2, \dots$ gilt, haben wir auch $\mathbb{E}_\vartheta |U_n(\vartheta)|^2 < \infty$ für alle $n = 1, 2, \dots$. Der Scorevektor U_n erweist sich als ein Martingal, die u_i 's also als Martingaldifferenz-Folge, denn es gilt das

Lemma. *Unter der Bedingung $V^{(1)}$ besitzt die Folge $U_n(\vartheta)$, $n \geq 1$, von Zufallsvektoren die Martingaleigenschaft*

$$\mathbb{E}_{(n-1),\vartheta} U_n(\vartheta) = U_{n-1}(\vartheta) \quad \mathbb{P}_\vartheta - f.s., \quad n = 2, 3, \dots \quad (3.3)$$

Ferner gilt $\mathbb{E}_\vartheta U_n(\vartheta) = 0$.

Beweis. Aufgrund der Darstellung (3.2) ist (3.3) erfüllt, falls

$$\begin{aligned} \mathbb{E}_{(n-1),\vartheta} u_i(\vartheta) &= u_i(\vartheta) \quad \mathbb{P}_\vartheta - f.s. \quad \text{für } i = 1, \dots, n-1 \\ \mathbb{E}_{(n-1),\vartheta} u_n(\vartheta) &= 0 \quad \mathbb{P}_\vartheta - f.s. \quad \text{für } n = 1, 2, \dots \end{aligned}$$

Während die erste Gleichung aus einer Eigenschaft der bedingten Erwartung folgt (für $i = 1, \dots, n-1$ ist $u_i(\vartheta)$ messbare Funktion der X_1, \dots, X_{n-1}), ergibt sich die zweite aus $V^{(1)}$, denn

$$\mathbb{E}_{(n-1),\vartheta} u_n(\vartheta) = \int \left(\frac{d}{d\vartheta} \log f_{(n-1)}(x, \vartheta) \right) \cdot f_{(n-1)}(x, \vartheta) dx = \int \frac{d}{d\vartheta} f_{(n-1)}(x, \vartheta) dx = 0.$$

Ferner $\mathbb{E}_\vartheta u_i(\vartheta) = \mathbb{E}_\vartheta (\mathbb{E}_{(i-1),\vartheta} u_i(\vartheta)) = 0$, $i = 1, 2, \dots$, und deshalb über (3.2) auch $\mathbb{E}_\vartheta U_n(\vartheta) = 0$. \square

Die $d \times d$ -Hessematrix von $\ell_n(\vartheta)$ ist

$$W_n(\vartheta) = \sum_{i=1}^n w_i(\vartheta), \quad w_i(\vartheta) = \frac{d^2}{d\vartheta d\vartheta^\top} \log f_{(i-1)}(X_i, \vartheta).$$

Unter $V^{(1)}$ und $V^{(2)}$ rechnet man ähnlich wie in V 1.1

$$\mathbb{E}_{(i-1),\vartheta} w_i(\vartheta) = -\mathbb{V}_{(i-1),\vartheta} (u_i(\vartheta)). \quad (3.4)$$

3.2 Quasi-Likelihood, Bedingung U^*

Auch ohne explizite Kenntnis der bedingten Dichten $f_{(i-1)}$ lassen sich asymptotische Ergebnisse für stochastische Prozesse gewinnen, wenn wir von einer *estimation function* $U_n(\vartheta)$ der Form (3.2) ausgehen, mit einer Martingaldifferenz-Folge $u_i(\vartheta)$, $i \geq 1$, bez. $\mathcal{F}_i = \sigma(X_1, \dots, X_i)$. Das führt zur

Definition. *Quasi-Likelihood (GEE-Typ):* Für die *estimation function* $U_n(\vartheta)$ gilt

$$U_n(\vartheta) = \sum_{i=1}^n u_i(\vartheta), \quad u_i(\vartheta) \text{ ist } \mathcal{F}_i\text{-messbar, mit } \mathbb{E}_{(i-1),\vartheta} (u_i(\vartheta)) = 0. \quad M^*$$

Nach 3.1 ist M^* im Likelihood-Fall, d. h. wenn (3.1) zusammen mit der Vertauschbarkeitsbedingung $V^{(1)}$ gelten, erfüllt.

Wir stellen einige Bedingungen auf, die in Hinblick auf U^* , das ist die Verteilungskonvergenz von $\Gamma_n \cdot U_n(\vartheta)$ gegen die $N_d(0, \Sigma(\vartheta))$ -Verteilung, von Bedeutung sind. Dazu setzen wir –mit einer Folge Γ_n , $n \geq 1$, von $d \times d$ -Diagonalmatrizen mit positiven Diagonalelementen, die gegen Null konvergieren– zur Abkürzung

$$L_n(\vartheta, \varepsilon) = \sum_{i=1}^n \mathbb{E}_{(i-1), \vartheta} (1(|\Gamma_n u_i(\vartheta)| > \varepsilon) \cdot |\Gamma_n u_i(\vartheta)|^2)$$

$$V_n(\vartheta) = \sum_{i=1}^n v_i(\vartheta), \quad v_i(\vartheta) = \mathbb{V}_{(i-1), \vartheta} (u_i(\vartheta)) \quad [d \times d\text{-Matrizen}].$$

Wir formulieren nun für jedes $\vartheta \in \Theta$ und für den Limes $n \rightarrow \infty$

$$L_n(\vartheta, \varepsilon) \xrightarrow{\mathbb{P}_\vartheta} 0 \quad \text{für jedes } \varepsilon > 0 \quad U_1^*$$

$$\Gamma_n \cdot V_n(\vartheta) \cdot \Gamma_n^\top \xrightarrow{\mathbb{P}_\vartheta} \Sigma(\vartheta) \quad [\text{positiv-definite, symm. } d \times d\text{-Matrix}] \quad U_2^*$$

Bemerkung. U_1^* ist eine bedingte *Lindeberg*-Bedingung, U_2^* stellt eine *ergodische* Bedingung dar, $V_n(\vartheta)$ heißt auch bedingte Fisher-Information(smatrix).

Satz 1. Aus den Bedingungen M^* , U_1^* und U_2^* folgt die Bedingung U^* , das ist $\Gamma_n \cdot U_n(\vartheta) \xrightarrow{\mathcal{D}_\vartheta} N_d(0, \Sigma(\vartheta))$.

Beweis. Mit der Festsetzung $Y_{n,i}(\vartheta) = \Gamma_n \cdot u_i(\vartheta)$ bilden wir das Dreiecksschema

$$Y_{n,1}(\vartheta), \dots, Y_{n,n}(\vartheta), \quad n = 1, 2, \dots$$

Wegen $\mathbb{E}_{(i-1), \vartheta} Y_{n,i}(\vartheta) = 0$ gemäß M^* stellt es ein *Martingaldifferenz*-Schema dar bezüglich $\mathcal{F}_{n,i} \equiv \mathcal{F}_i = \sigma(X_1, \dots, X_i)$. Es gilt dann

$$\Gamma_n \cdot U_n(\vartheta) = \sum_{i=1}^n Y_{n,i}(\vartheta)$$

$$\sum_{i=1}^n \mathbb{V}_{(i-1), \vartheta} (Y_{n,i}(\vartheta)) = \Gamma_n \cdot V_n(\vartheta) \cdot \Gamma_n^\top.$$

Im Fall $d = 1$ sagt U_2^* aus, dass $[\Sigma(\vartheta) \equiv \sigma^2(\vartheta)$ gesetzt]

$$\sum_{i=1}^n \text{Var}_{(i-1), \vartheta} (Y_{n,i}(\vartheta)) \xrightarrow{\mathbb{P}_\vartheta} \sigma^2(\vartheta),$$

das ist (A 3.5), während U_1^* dann (A 3.6) entspricht. Die Voraussetzungen des ZGWS A 3.7 für Martingaldifferenz-Schemata sind also erfüllt, so dass

$$\sum_{i=1}^n Y_{n,i}(\vartheta) \xrightarrow{\mathcal{D}_\vartheta} N(0, \sigma^2(\vartheta)).$$

Im allgemeinen Fall $d \geq 1$ beweist man, dass für alle Vektoren $a \in \mathbb{R}^d$

$$\sum_{i=1}^n a^\top \cdot Y_{n,i}(\vartheta) \xrightarrow{\mathcal{D}_\vartheta} a^\top Z, \quad Z \sim N_d(0, \Sigma(\vartheta)) - \text{verteilt,}$$

so dass Satz 1 aus A 3.4, das ist der Cramér-Wold device, die Behauptung liefert. \square

3.3 Autoregressiver Prozess AR(1)

Als einfaches Beispiel für einen stochastischen Prozess betrachten wir den autoregressiven Prozess der Ordnung 1 (kurz: AR(1)-Prozess) mit Erwartungswert 0. Erst in 3.4 werden wir einen Erwartungswert μ berücksichtigen.

Modell. Unter einem AR(1)-Prozess verstehen wir eine Folge X_0, X_1, \dots von Zufallsvariablen, welche der Gleichung

$$X_n = \vartheta \cdot X_{n-1} + e_n, \quad n = 1, 2, \dots \quad (3.5)$$

genügt. Dabei ist $\vartheta \in (-1, 1)$ und

$$\begin{aligned} e_1, e_2, \dots \text{ ist eine Folge unabh., identisch verteilter Zufallsvariablen mit} \\ \mathbb{E}(e_n) = 0, \quad \text{Var}(e_n) = \sigma_e^2, \\ e_n \text{ unabhängig von } X_0, \dots, X_{n-1}. \end{aligned} \quad (3.6)$$

Ein solcher Prozess ist *stationär* und hat die Darstellung

$$X_n = \sum_{i=0}^{\infty} \vartheta^i e_{n-i}, \quad n = 1, 2, \dots \quad [L_2\text{-Limes}].$$

Es ergeben sich für $n = 1, 2, \dots$ die folgenden unbedingten und bedingten Momente

$$\begin{aligned} \mathbb{E}_\vartheta(X_n) &= 0, & \mathbb{E}_\vartheta(X_n | X_{n-1}) &= \vartheta \cdot X_{n-1} \\ \text{Var}_\vartheta(X_n) &\equiv \sigma_x^2 = \sum_{i=0}^{\infty} \vartheta^{2i} \sigma_e^2 = \frac{1}{1 - \vartheta^2} \sigma_e^2, & \text{Var}_\vartheta(X_n | X_{n-1}) &= \sigma_e^2. \end{aligned}$$

Der Prozess X_n , $n \geq 1$, unterliegt den folgenden ergodischen Gesetzen (Gesetze der großen Zahlen):

$$\frac{1}{n} \sum_{i=1}^n X_i \xrightarrow{\mathbb{P}_\vartheta} \mathbb{E}_\vartheta(X_1) = 0, \quad (3.7)$$

$$\frac{1}{n} \sum_{i=1}^n X_i^2 \xrightarrow{\mathbb{P}_\vartheta} \mathbb{E}_\vartheta(X_1^2) = \text{Var}_\vartheta(X_1) \equiv \sigma_x^2, \quad (3.8)$$

vgl. Schlittgen & Streitberg (1984, sec. 4.1); es gilt sogar die \mathbb{P}_ϑ fast-sichere Konvergenz. In der Extremwerttheorie zeigt man, dass für eine ganze Reihe von Verteilungen der Fehlervariablen e_i , darunter auch die Normalverteilung,

$$\frac{1}{\sqrt{n}} \max(|X_1|, \dots, |X_n|) \xrightarrow{\mathbb{P}_\vartheta} 0, \quad (3.9)$$

gilt, vergleiche dazu Embrechts et al (1997, Ex. 3.5.4, sec. 5.5.2).

Nun setzen wir zusätzlich voraus:

$$\text{Jedes } e_i \text{ ist } N(0, \sigma_e^2)\text{-verteilt.} \quad (3.10)$$

Die bedingte Verteilung von X_i , gegeben X_0, \dots, X_{i-1} , ist dann die $N(\vartheta X_{i-1}, \sigma_e^2)$ -Verteilung; zum Nachweis verwende man die letzte Gleichung in II 5.1, formuliert für bedingte Wahrscheinlichkeiten. Die zugehörige (bedingte) Dichte lautet

$$f_{(i-1)}(x_i, \vartheta) = \frac{1}{\sqrt{2\pi\sigma_e^2}} \exp \left\{ -\frac{1}{2} \left(\frac{x_i - \vartheta X_{i-1}}{\sigma_e} \right)^2 \right\},$$

die gemeinsame Dichte der X_1, \dots, X_n also

$$f(x_1, \dots, x_n, \vartheta) = f(x_1, \vartheta) \cdot f_{(1)}(x_2, \vartheta) \cdot \dots \cdot f_{(n-1)}(x_n, \vartheta).$$

Statistische Analyse. Aus dem Likelihood $f(x_1, \dots, x_n, \vartheta)$ ergeben sich die log Likelihoodfunktion $\ell_n(\vartheta)$, die Scorefunktion $U_n(\vartheta)$ und die zweite Ableitung $W_n(\vartheta)$, mit einem R , das nicht von ϑ abhängt,

$$\ell_n(\vartheta) = -\frac{1}{2\sigma_e^2} \sum_{i=1}^n (X_i - \vartheta X_{i-1})^2 + R, \quad (3.11)$$

$$U_n(\vartheta) = \frac{1}{\sigma_e^2} \sum_{i=1}^n X_{i-1} \cdot (X_i - \vartheta X_{i-1}) \equiv \sum_{i=1}^n u_i(\vartheta)$$

$$W_n(\vartheta) = -\frac{1}{\sigma_e^2} \sum_{i=1}^n X_{i-1}^2.$$

$U_n(\vartheta)$ ist eine 1-dimensionale –in ϑ lineare– *estimation function*, $u_i(\vartheta)$ ist ein Zufallsgewichtetes Martingaldifferenz-Schema im Sinne von (A 3.7), $W_n(\vartheta)$ hängt nicht mehr von ϑ ab. Der ML-Schätzer für ϑ berechnet sich aus $U_n(\vartheta) = 0$ zu

$$\hat{\vartheta}_n = \frac{\sum_{i=1}^n X_{i-1} \cdot X_i}{\sum_{i=1}^n X_{i-1}^2}; \quad (3.12)$$

das ist eine Version $r(1)$ des Koeffizienten der Auto-Korrelation der Ordnung 1 für Prozesse mit Erwartungswert 0.

Wir überprüfen die Bedingungen U^* und W^* . Hier im Fall $d = 1$ setzen wir $\Gamma_n = \gamma_n$.

Satz. Gegeben sei ein autoregressiver Prozess gemäß Gleichung (3.5) bis (3.10), mit $\vartheta \in (-1, 1)$. Dann sind die Bedingungen U^* und W^* erfüllt, und zwar mit

$$\gamma_n = \frac{1}{\sqrt{n}}, \quad \Sigma(\vartheta) = B(\vartheta) = \frac{1}{1 - \vartheta^2} \quad [\equiv \sigma^2(\vartheta)].$$

Beweis. (i) Wir zeigen zunächst mittels Lemma A 3.7, dass die bedingte Lindeberg-Bedingung U_1^* erfüllt ist, wenn wir in (A 3.7)

$$A_{n,i} = \frac{1}{\sqrt{n}} \cdot \frac{X_{i-1}}{\sigma_e^2}, \quad e_i = X_i - \vartheta \cdot X_{i-1},$$

setzen (beachte, dass $\mathbb{E}_\vartheta(e_i|X_{i-1}) = \mathbb{E}_\vartheta(e_i) = 0$). In der Tat, die Momentenbedingungen (A 3.9) reduzieren sich hier auf

$$\text{Var}_\vartheta(e_1) > 0, \quad \mathbb{E}(|e_1|^\kappa) < \infty \quad \text{für ein } \kappa > 2; \quad (3.13)$$

sie sind wegen unserer Annahme (3.10) erfüllt. Auf Grund des ergodischen Gesetzes (3.8) ist (A 3.10) wegen A 3.4, Prop. 1 (i), erfüllt ist. Auf Grund der Extremwert-Eigenschaft (3.9) gilt auch (A 3.11).

(ii) Mit $u_i(\vartheta) = X_{i-1} \cdot e_i / \sigma_e^2$ erhalten wir für $v_i(\vartheta) = \text{Var}_{(i-1), \vartheta}(u_i(\vartheta))$ die Gleichung

$$v_i(\vartheta) = \text{Var}_\vartheta(e_i|X_{i-1}) \frac{X_{i-1}^2}{\sigma_e^4} = \frac{X_{i-1}^2}{\sigma_e^2},$$

so dass U_2^* wegen (3.8) gültig ist, mit

$$\sigma^2(\vartheta) = \frac{\sigma_x^2}{\sigma_e^2} = \frac{1}{1 - \vartheta^2}.$$

Nach Satz aus 4.1 ist damit die Bedingung U^* erfüllt.

(iii) Die Bedingung W^* , mit $B(\vartheta) = \sigma^2(\vartheta)$, ist wegen Aussage (3.8) erfüllt. \square

Der ML-Schätzer (3.12) weist also \sqrt{n} -Konsistenz für ϑ auf; ferner asymptotische Normalität der Form

$$\sqrt{n}(\hat{\vartheta}_n - \vartheta) \xrightarrow{\mathcal{D}_\vartheta} N(0, 1 - \vartheta^2) \quad \text{bzw.} \quad \sqrt{\frac{n}{1 - \hat{\vartheta}_n^2}}(\hat{\vartheta}_n - \vartheta) \xrightarrow{\mathcal{D}_\vartheta} N(0, 1). \quad (3.14)$$

Der obige Satz gilt auch im Quasi-Likelihood Fall, wenn wir also auf die Normalverteilungs-Annahme (3.10) verzichten und gleich mit (3.11) als Kriteriumsfunktion starten (R kann 0 gesetzt werden). Für die Verteilung von e_1 müssen dann nur noch die (schwachen) Annahmen (3.13) und (3.9) getroffen werden. (Tatsächlich ist auch die Gültigkeit von (3.9) durch die Verteilung von e_1 bestimmt). (3.12) ist dann ein Quasi ML-Schätzer (und zwar vom GEE-Typ).

Anwendung. Wir benutzen jetzt die in der Zeitreihenanalyse üblichen Bezeichnungen $\vartheta = \rho(1)$ und $\hat{\vartheta}_n = r(1)$. Der approximative Standardfehler des Schätzers $r(1)$ ist nach (3.14)

$$\text{se}(r(1)) = \sqrt{\frac{1 - (r(1))^2}{n}}.$$

Er ist angenähert gleich $\sqrt{-1/\hat{W}_n(\hat{\vartheta}_n)}$, wobei wir in die Formel für $W_n(\vartheta)$ den Schätzer $\hat{\sigma}_e^2 = (1/n) \sum_{i=1}^n (X_i - \hat{\vartheta}_n X_{i-1})^2$ für σ_e^2 eingesetzt haben. Ein Konfidenzintervall für $\rho(1)$ zum asymptotischen Niveau $1 - \alpha$ lautet

$$r(1) - \text{se}(r(1)) \cdot u_{1-\alpha/2} \leq \rho(1) \leq r(1) + \text{se}(r(1)) \cdot u_{1-\alpha/2}. \quad (3.15)$$

Betrachte jetzt die Hypothese $H_0 : \rho(1) = 0$, das bedeutet die Unkorreliertheit der aufeinanderfolgenden Beobachtungen X_1, X_2, \dots . Ein Test zum Prüfen von H_0 zum asymptotischen Signifikanzniveau α verwendet die Teststatistik

$$Z = \sqrt{n} \frac{r(1)}{\sqrt{1 - r^2(1)}},$$

die gemäß (3.14) unter H_0 asymptotisch $N(0, 1)$ -verteilt ist.

3.4 AR(1)-Prozess mit Mittelwert-Korrektur

Wir gehen jetzt zu dem realistischeren Fall über, dass die Variablen X_n einen Erwartungswert μ besitzt, der nicht notwendig –wie in 3.3– gleich 0 ist.

Modell. Ein AR(1)-Prozess mit *Mittelwert-Korrektur* gehorcht der Gleichung

$$X_n - \mu = \alpha \cdot (X_{n-1} - \mu) + e_n, \quad n = 1, 2, \dots, \quad (3.16)$$

bzw. $X_n = \alpha \cdot X_{n-1} + \mu(1 - \alpha) + e_n$. Hierbei ist $\alpha \in (-1, 1)$ und $\mu \in \mathbb{R}$, und es gelten wieder die Voraussetzungen (3.6) an die Fehlervariablen e_i (keine Normalverteilungsannahme). Es ergibt sich die Darstellung $X_n = \mu + \sum_{i=0}^{\infty} \alpha^i e_{n-i}$ und, mit dem zweidimensionalen Parametervektor $\vartheta = (\mu, \alpha)$,

$$\mathbb{E}_\vartheta(X_n) = \mu, \quad \mathbb{E}_\vartheta(X_n | X_{n-1}) = \alpha \cdot X_{n-1} + \mu(1 - \alpha),$$

während die Varianz-Formeln wie in 3.3 lauten, insbesondere $\sigma_e^2 = (1 - \alpha^2)\sigma_x^2$. Ebenso gelten die ergodischen Gesetze (3.7), mit $\mathbb{E}_\vartheta(X_1) = \mu$, und (3.8), sowie für eine ganze Reihe von Verteilung der e_i die Extremwert-Eigenschaft (3.9).

Statistische Analyse (Quasi-Likelihood.) Ausgehend von der Kriteriumsfunktion

$$\ell_n(\vartheta) = -\frac{1}{2\sigma_e^2} \sum_{i=1}^n (X_i - \alpha X_{i-1} - \mu(1 - \alpha))^2, \quad \vartheta = (\mu, \alpha),$$

gelangen wir zum Gradientenvektor bzw. zur Hessematrix

$$U_n(\vartheta) = \frac{1}{\sigma_e^2} \sum_{i=1}^n \begin{pmatrix} 1 - \alpha \\ X_{i-1} - \mu \end{pmatrix} \cdot (X_i - \alpha \cdot X_{i-1} - \mu(1 - \alpha)),$$

$$W_n(\vartheta) = -\frac{1}{\sigma_e^2} \sum_{i=1}^n \begin{pmatrix} v_{11}(\vartheta) & v_{12}(\vartheta) \\ v_{12}(\vartheta) & v_{22}(\vartheta) \end{pmatrix} + \begin{pmatrix} 0 & R'_n \\ R'_n & 0 \end{pmatrix},$$

($R'_n = c'(X_n - X_0)$ mit Konstante c'). Dabei hat die Matrix die Einträge

$$v_{11}(\vartheta) = (1 - \alpha)^2, \quad v_{12}(\vartheta) = 2(X_{i-1} - \mu)(1 - \alpha), \quad v_{22}(\vartheta) = (X_{i-1} - \mu)^2.$$

Die Lösung $\hat{\vartheta}_n = (\hat{\mu}_n, \hat{\alpha}_n)$ der Schätzgleichung $U_n(\vartheta) = 0$ (vom GEE-Typ) lautet

$$\hat{\mu}_n = \frac{\sum_{i=1}^n (X_i - \alpha X_{i-1})}{n(1 - \alpha)} = \frac{\sum_{i=1}^n X_i}{n} + \frac{1}{n} R''_n \equiv \bar{X}_n + \frac{1}{n} R''_n$$

$$\hat{\alpha} = \frac{\sum_{i=1}^n (X_{i-1} - \hat{\mu}_n) \cdot (X_i - \hat{\mu}_n)}{\sum_{i=1}^n (X_{i-1} - \hat{\mu}_n)^2} = r(1),$$

($R''_n = c''(X_n - X_0)$ mit Konstante c''). Der Quasi ML-Schätzer $\hat{\vartheta}_n = (\hat{\mu}_n, \hat{\alpha}_n)$ für $\vartheta = (\mu, \alpha)$ besteht also (approximativ) aus dem Mittelwert und aus einer Version des Koeffizienten der Autokorrelation (Ordnung 1) der Stichprobe X_1, \dots, X_n .

Proposition. *Gegeben sei ein autoregressiver Prozess mit Mittelwert-Korrektur gemäß Gleichung (3.16), mit $\alpha \in (-1, 1)$. Ferner mögen (3.13) und (3.9) gelten. Dann sind die Bedingungen U^* und W^* erfüllt, und zwar mit*

$$\Gamma_n = \text{Diag}\left(\frac{1}{\sqrt{n}}, \frac{1}{\sqrt{n}}\right), \quad \Sigma(\vartheta) = B(\vartheta) = \begin{pmatrix} (1 - \alpha)^2 / \sigma_e^2 & 0 \\ 0 & 1 / (1 - \alpha^2) \end{pmatrix}.$$

Beweis. Der Beweis verläuft wie der zum Satz 3.3 oben, jedoch mit folgenden Erweiterungen.

ad U_2^* : Es ist

$$U_n(\vartheta) = \sum_{i=1}^n u_i(\vartheta), \quad \text{mit} \quad u_i(\vartheta) = \frac{1}{\sigma_e^2} \begin{pmatrix} 1 - \alpha \\ X_{i-1} - \mu \end{pmatrix} \cdot e_i.$$

Für $v_i(\vartheta) = \mathbb{V}_{(i-1),\vartheta}(u_i(\vartheta))$ erhalten wir wegen $\text{Var}_{(i-1)}(e_i) = \sigma_e^2$

$$v_i(\vartheta) = \frac{1}{\sigma_e^2} \begin{pmatrix} (1-\alpha)^2 & (1-\alpha)(X_{i-1} - \mu) \\ (1-\alpha)(X_{i-1} - \mu) & (X_{i-1} - \mu)^2 \end{pmatrix}.$$

Die ergodischen Gesetze (3.7) und (3.8) liefern dann

$$\frac{1}{n} \sum_{i=1}^n v_i(\vartheta) \xrightarrow{\mathbb{P}_\vartheta} \frac{1}{\sigma_e^2} \begin{pmatrix} (1-\alpha)^2 & 0 \\ 0 & \sigma_x^2 \end{pmatrix} = \Sigma(\vartheta),$$

Letzteres wegen $\sigma_x^2/\sigma_e^2 = 1/(1-\alpha^2)$.

ad W^* : Aufgrund der ergodischen Gesetze (3.7) und (3.8) gilt

$$-\frac{1}{n} W_n(\vartheta) \xrightarrow{\mathbb{P}_\vartheta} \frac{1}{\sigma_e^2} \begin{pmatrix} (1-\alpha)^2 & 0 \\ 0 & \sigma_x^2 \end{pmatrix} = \Sigma(\vartheta).$$

Diese Konvergenzaussage lässt sich auch mit $W_n(\vartheta_n^*)$, $\vartheta_n^* \xrightarrow{\mathbb{P}} \vartheta$, anstelle von $W_n(\vartheta)$ aufstellen. Für das Element (2, 2) etwa verwende man $\sum_{i=1}^n (X_{i-1} - \mu_n^*)^2/n = \sum_{i=1}^n (X_{i-1} - \mu)^2/n + \eta_n$, η_n stochastische Nullfolge. Insbesondere ist damit auch $B(\vartheta) = \Sigma(\vartheta)$ bewiesen. \square

Anwendung. Test der (zusammengesetzten) Hypothese $H_0 : \mu = \mu_0$. Mit $\vartheta = (\mu, \alpha)$ schreiben wir

$$H_0 : r(\vartheta) = 0, \quad r(\vartheta) = \mu - \mu_0.$$

Mit $\hat{\vartheta}_n = (\hat{\mu}_n, \hat{\alpha}_n)$, $\hat{\mu}_n = \bar{X}_n + (\text{const}/n)(X_n - X_0)$, gilt für die Wald-Statistik gemäß VI 4.4

$$T_n^{(W)} = \frac{(\hat{\mu}_n - \mu_0)^2}{\hat{w}_n}, \quad \text{wobei} \quad \hat{w}_n = [-W_n^{-1}(\hat{\vartheta}_n)]_{(1,1)}.$$

W^* und $\sigma_e^2 = (1-\alpha^2)\sigma_x^2$ berücksichtigend, haben wir

$$[-n W_n^{-1}(\hat{\vartheta}_n)]_{(1,1)} \xrightarrow{\mathbb{P}_\vartheta} [\Sigma^{-1}(\vartheta)]_{(1,1)} = \frac{\sigma_e^2}{(1-\alpha)^2} = \frac{1+\alpha}{1-\alpha} \sigma_x^2.$$

Bedeutet $A_n \approx B_n$, dass A_n/B_n stochastisch gegen 1 konvergiert, so lässt sich

$$\hat{w}_n \approx \frac{1}{n} \frac{1+\hat{\alpha}_n}{1-\hat{\alpha}_n} \hat{\sigma}_x^2 \quad [\hat{\sigma}_x^2 \text{ ein konsistenter Schätzer für } \sigma_x^2]$$

schreiben. Wir erhalten

$$T_n^{(W)} \approx n_\alpha \frac{(\bar{X}_n - \mu_0)^2}{\hat{\sigma}_x^2}, \quad \text{mit} \quad n_\alpha = \frac{1-\hat{\alpha}_n}{1+\hat{\alpha}_n} n.$$

$T^{(W)}$ ist unter H_0 asymptotisch χ_1^2 -verteilt. Anders formuliert,

$$Z = \sqrt{n_\alpha} \frac{\bar{X} - \mu_0}{\hat{\sigma}_x} \quad \text{ist unter } H_0 \text{ asymptotisch } N(0, 1)\text{-verteilt.}$$

Dies ist der *asymptotische* t-Test mit *korrigiertem* n : Bei Vorhandensein einer Autokorrelation $\alpha \in (0, 1)$ reduziert sich der „effektive“ Stichprobenumfang um den Faktor $(1-\alpha)/(1+\alpha)$.

3.5 Endliche Markovketten (*)

Modell. Wir betrachten eine Markovkette X_n , $n \geq 0$, mit endlich vielen, nämlich I , Zuständen. Das bedeutet: Mit einem Wahrscheinlichkeitsvektor (*Startverteilung*) $p_0 = (p_{0,1}, \dots, p_{0,I})$ und einer $I \times I$ -Matrix P von *Übergangswahrscheinlichkeiten*,

$$P = (p_{i,j}, i, j = 1, \dots, I), \quad [\text{alle } p_{i,j} \geq 0, \quad \sum_{j=1}^I p_{i,j} = 1]$$

gilt $\mathbb{P}(X_0 = i) = p_{0,i}$, $i = 1, \dots, I$, und

$$\mathbb{P}(X_n = j | X_{n-1} = i) = p_{i,j}, \quad i, j = 1, \dots, I.$$

Einfachhaltshalber setzen wir im Folgenden voraus, dass alle Elemente von P positiv sind, $p_{i,j} > 0$ für alle i, j . Alternativ läßt sich auch fordern, dass –mit einer festen Menge D von Doppelindizes– $p_{i,j} > 0$ genau für $(i, j) \in D$ gilt, wobei D so beschaffen ist, dass die Markovkette *irreduzibel* ist (vgl. Feller 1970, chap. XV). Dann gibt es einen (eindeutig bestimmten) Wahrscheinlichkeitsvektor $\pi = (\pi_1, \dots, \pi_I)$, so dass

$$\pi \cdot P = \pi \quad [\pi \text{ stationäre Verteilung}]$$

gilt. Wählt man π als Startverteilung, so ist π auch die Verteilung für jede der Variablen X_1, X_2, \dots . Unter Verwendung von π können wir ein Gesetz der großen Zahlen (*ergodisches Gesetz*) formulieren, vgl. Billingsley(1961). Für alle Startverteilungen und messbare Funktionen $g : I \times I \rightarrow \mathbb{R}$ gilt

$$\frac{1}{n} \sum_{k=1}^n g(X_{k-1}, X_k) \xrightarrow{\mathbb{P}} \mathbb{E}_\pi(g(X_1, X_2)) = \sum_i \sum_j \pi_i \cdot p_{i,j} \cdot g(i, j), \quad (3.17)$$

$$\text{insbesondere } \frac{1}{n} \sum_{k=1}^n 1(X_{k-1} = i, X_k = j) \xrightarrow{\mathbb{P}} \pi_i \cdot p_{i,j}. \quad (3.18)$$

Statistische Analyse. Wir setzen die Startverteilung p_0 als gegeben voraus und betrachten

$$\vartheta \equiv P^- = (p_{i,j}, i = 1, \dots, I, j = 1, \dots, I-1 : \quad \text{alle } p_{i,j} > 0, \quad \sum_{j=1}^{I-1} p_{i,j} < 1)$$

$[p_{i,I} = 1 - (p_{i,1} + \dots + p_{i,I-1})]$ als (unbekannten) Parameter der Dimension $d = I \cdot (I - 1)$. Die Likelihoodfunktion einer Stichprobe X_0, X_1, \dots, X_n lautet

$$L_n(\vartheta) = p_{0,X_0} \cdot \prod_{k=1}^n p_{X_{k-1}, X_k} = p_{0,X_0} \cdot \prod_{i=1}^I \prod_{j=1}^I p_{i,j}^{n_{i,j}},$$

wobei $n_{i,j}$ die Häufigkeit des Übergangs $i \rightarrow j$ bezeichnet,

$$n_{i,j} = \sum_{k=1}^n 1(X_{k-1} = i, X_k = j).$$

Die log-Likelihoodfunktion heißt dann

$$\ell_n(\vartheta) = \sum_{i=1}^I \sum_{j=1}^I n_{i,j} \log p_{i,j}.$$

Wir erhalten den Scorevektor $U_n(\vartheta)$ und die Hessematrix $W_n(\vartheta)$, Letzteres eine Block-Diagonalmatrix mit Blöcken der Dimension $(I-1) \times (I-1)$, zu

$$U_{n,(i,j)}(\vartheta) = \frac{n_{i,j}}{p_{i,j}} - \frac{n_{i,I}}{p_{i,I}}, \quad i = 1, \dots, I, j = 1, \dots, I-1$$

$$W_n(\vartheta) = \begin{pmatrix} W_{n,1}(\vartheta) & & 0 \\ & \ddots & \\ 0 & & W_{n,I}(\vartheta) \end{pmatrix}, \quad W_{n,i(j,j')}(\vartheta) = - \left(\frac{n_{i,j}}{p_{i,j}^2} \delta_{j,j'} + \frac{n_{i,I}}{p_{i,I}^2} \right).$$

Die ML-Schätzer für die Übergangswahrscheinlichkeiten $p_{i,j}$ sind die relativen Übergangshäufigkeiten

$$\hat{p}_{i,j} = \frac{n_{i,j}}{n_{i,\bullet}}, \quad \text{mit } n_{i,\bullet} = \sum_{j=1}^I n_{i,j}.$$

Wir weisen nun die Voraussetzungen U^* und W^* nach, und zwar mit der Block-Diagonalmatrix

$$\Sigma(\vartheta) = \begin{pmatrix} \Sigma_1(\vartheta) & & 0 \\ & \ddots & \\ 0 & & \Sigma_I(\vartheta) \end{pmatrix}, \quad \Sigma_i(j,j')(\vartheta) = \left(\frac{\pi_i}{p_{i,j}} \delta_{j,j'} + \frac{\pi_i}{p_{i,I}} \right). \quad (3.19)$$

ad U^* : Wir schreiben

$$U_{n,(i,j)}(\vartheta) = \sum_{k=1}^n u_{k,(i,j)}(\vartheta),$$

$$u_{k,(i,j)}(\vartheta) = 1(X_{k-1} = i, X_k = j)/p_{i,j} - 1(X_{k-1} = i, X_k = I)/p_{i,I},$$

und setzen $\mathbb{E}_{(i')} (u_k(\vartheta))$, $\mathbb{V}_{(i')} (u_k(\vartheta))$, für die bedingte Erwartung bzw. bedingte Kovarianzmatrix von $u_k(\vartheta)$, und zwar gegeben $X_{k-1} = i'$. Wir erhalten wegen $\mathbb{E}(1(X_{k-1} = i, X_k = j)) = \mathbb{P}(X_{k-1} = i) \cdot p_{i,j}$

$$\mathbb{E}_{(i')} (u_{k,(i,j)}(\vartheta)) = 0, \quad \text{für alle } i', i, j$$

$$\mathbb{V}_{(i')} (u_{k,(i,\cdot)}(\vartheta)) = \begin{cases} \left(\frac{1}{p_{i,j}} \delta_{j,j'} + \frac{1}{p_{i,I}} \right)_{j,j'=1,\dots,I-1} & \text{falls } i = i' \\ 0 & \text{falls } i \neq i' \end{cases}$$

$$\frac{1}{n} \sum_{k=1}^n \mathbb{V}_{(X_{k-1})} (u_{k,(i,\cdot)}(\vartheta)) \xrightarrow{\mathbb{P}} \Sigma_i(\vartheta),$$

Letzteres mit einer beliebigen Startverteilung. Gemäß A 3.7 ist damit U^* erfüllt [setze $X_{n,k} = A_{n,k} e_k$ mit $A_{n,k} = 1/\sqrt{n}$, $e_k = u_k(\vartheta)$ in (A 3.8) und Lemma A 3.7; die korrekte Behandlung des hier vorliegenden multivariaten Falles mittels Cramér-Wold device unterlassen wir].

ad W^* : Gemäß (3.18) erhalten wir wegen $\mathbb{E}_\pi(n_{i,j}) = n \cdot \pi_i \cdot p_{i,j}$

$$-\frac{1}{n} W_{n,i(j,j')}(\vartheta) \xrightarrow{\mathbb{P}} \left(\frac{\pi_i p_{i,j}}{p_{i,j}^2} \delta_{j,j'} + \frac{\pi_i p_{i,I}}{p_{i,I}^2} \right) = \Sigma_{i(i,j')}(\vartheta),$$

und dasselbe auch mit $W_n(\vartheta_n^*)$, $\vartheta_n^* \xrightarrow{\mathbb{P}} \vartheta$, anstatt $W_n(\vartheta)$. Es gilt insbesondere $B(\vartheta) = \Sigma(\vartheta)$. Wir haben damit die folgende Aussage bewiesen.

Proposition. *Gegeben sei eine irreduzible Markovkette mit Übergangswahrscheinlichkeiten $P = (p_{i,j})$ und stationärer Verteilung $\pi = (\pi_j)$. Dann sind die Bedingungen U^* und W^* erfüllt, mit $\vartheta = P^-$ und mit $\Sigma(\vartheta) = B(\vartheta)$ gemäß (3.19).*

Anwendung. Wir wollen die Hypothese einer Folge unabhängiger X_0, X_1, \dots prüfen. Mit einem Wahrscheinlichkeitsvektor $q = (q_1, \dots, q_I)$ heißt das

$$H_0 : p_{i,j} = q_j, \quad \text{bzw. } p_{i,j} = h_j((q_1, \dots, q_{I-1})), \quad i = 1, \dots, I, \quad j = 1, \dots, I-1,$$

mit $h_j : \mathbb{R}^{I-1} \rightarrow \mathbb{R}$ als Projektion auf die j -te Komponente.

Aus $\ell_n(h(q)) = \sum_{j=1}^I n_{\bullet,j} \log q_j$ erhalten wir den ML-Schätzer $\hat{q}_j = n_{\bullet,j}/n$ für q_j , und daraus die log-LQ Statistik

$$T_n = 2 \sum_{i=1}^I \sum_{j=1}^I n_{i,j} \log \frac{n_{i,j}}{e_{i,j}}, \quad e_{i,j} = \frac{n_{i,\bullet} \cdot n_{\bullet,j}}{n} \quad [\text{erwartete Häufigkeit}].$$

Unter H_0 ist T_n asymptotisch χ_{d-c}^2 -verteilt, mit $d-c = I \cdot (I-1) - (I-1) = (I-1)^2$ Freiheitsgrade. Formal unterscheidet sich dieser Test nicht vom χ^2 -Unabhängigkeitstest VII 4.8 in einer $I \times I$ -Kontingenztafel.