

Ein erweitertes Poisson INAR(1)-Modell



TECHNISCHE
UNIVERSITÄT
DARMSTADT



Fachbereich
Mathematik

Christian H. Weiß

Fachbereich Mathematik

Technische Universität Darmstadt



Populär bei **reellwertigen** stationären Prozessen:

ARMA(p,q)-Modelle. Sei $(\epsilon_t)_{\mathbb{Z}}$ weißes Rauschen, dann

$$X_t = \alpha_1 \cdot X_{t-1} + \dots + \alpha_p \cdot X_{t-p} + \epsilon_t + \beta_1 \cdot \epsilon_{t-1} + \dots + \beta_q \cdot \epsilon_{t-q},$$

wobei $\alpha_1, \dots, \alpha_p, \beta_1, \dots, \beta_q \in \mathbb{R}$ geeignet gewählt.

Beispiel: AR(1)-Modell $X_t = \alpha \cdot X_{t-1} + \epsilon_t$

mit Autokorrelationsfunktion $\rho_X(k) = \alpha^k$.

Nicht auf Zählzeitenprozesse anwendbar: I. A. ist $\alpha \cdot X \notin \mathbb{N}_0$.



Modellierung von Zählzeitenreihen

Poisson-INAR(1)-Modell



INAR(1)-Modell:

Ersetze Multiplikation ‘ \cdot ’ in AR(1)-Rekursion

$$X_t = \alpha \cdot X_{t-1} + \epsilon_t$$

durch **binomial thinning** (‘binomiale Ausdünnung’):

Hat X Wertebereich \mathbb{N}_0 , und ist $\alpha \in (0; 1)$, so

$$\alpha \circ X := \sum_{i=1}^X Y_i,$$

wobei Y_i unabhängige, binäre ZV mit $P(Y_i = 1) = \alpha$,
auch unabhängig von X . (Steutel & van Harn, 1979)

Es gilt: $E[\alpha \circ X] = E[\alpha \cdot X]$, aber stets $\alpha \circ X \in \mathbb{N}_0$.



Beispiel:

INAR(1)-Modell mit Poisson-verteilten Innovationen:

Sei $\alpha \in (0; 1)$, sei $(\epsilon_t)_{\mathbb{N}}$ i.i.d. $Po(\lambda)$ und $X_0 \sim Po(\frac{\lambda}{1-\alpha})$.

Prozess $(X_t)_{\mathbb{N}_0}$, definiert durch Rekursion

$$X_t = \alpha \circ X_{t-1} + \epsilon_t, \quad t \geq 1,$$

sowie durch geeignete Unabhängigkeitsannahmen,

heißt **Poisson-INAR(1)-Prozess**. (McKenzie, 1985)



Grundlegende Eigenschaften:

- $(X_t)_{\mathbb{N}_0}$ stationäre Markovkette, Randverteilung $Po(\frac{\lambda}{1-\alpha})$,
- $E[X_t] = V[X_t] = \frac{\lambda}{1-\alpha}$ (Equidispersion),
- AR(1)-Abhängigkeit: $\rho_X(k) = \alpha^k$,
- $P(k|l) := P(X_t = k \mid X_{t-1} = l)$
 $= \sum_{j=0}^{\min(k,l)} \binom{l}{j} \alpha^j (1-\alpha)^{l-j} \cdot e^{-\lambda} \frac{\lambda^{k-j}}{(k-j)!} > 0.$



Interpretation von $\alpha \circ X := \sum_{i=1}^X Y_i$:

- Population von Größe X zu gewisser Zeit t .
- Später zur Zeit $t + 1$: Population geschrumpft, weil manche Individuen verstorben.
- Sterben alle Individuen unabhängig voneinander mit Wahrscheinlichkeit $1 - \alpha$

\Rightarrow *Zahl der Überlebenden* gegeben durch $\alpha \circ X$.



Interpretation & Beispiele:

$$\underbrace{X_t}_{\text{Population zur Zeit } t} = \underbrace{\alpha \circ X_{t-1}}_{\text{Überlebende der Zeit } t-1} + \underbrace{\epsilon_t}_{\text{Immigration}}$$

- X_t : Zahl der Nutzer, die auf Webserver zugreifen. ϵ_t : Zahl neuer Nutzer, $\alpha \circ X_{t-1}$: Zahl früherer Nutzer, welche noch immer aktiv.
- X_t : Zahl der Kunden. ϵ_t : neue Kunden, $X_{t-1} - \alpha \circ X_{t-1}$: Kunden, welche am Ende der vorigen Periode verloren.




Datenbeispiel aus Jung & Tremayne (2011):

Zeitreihe (Länge 800) zur

Anzahl sog. **iceberg orders** (vgl. Frey & Sandas, 2009)

pro 20 Min. bei 32 Handelstagen im 1. Quartal 2004 bzgl.



Aktien der Deutschen Telekom (XETRA, Deutsche Börse).





Datenbeispiel (iceberg orders):

Autokorrelations- und partielle Autokorrelationsfunktion:



⇒ Klare AR(1)-Abhängigkeit!



Datenbeispiel (iceberg orders):

Mittlere Anzahl: ca. 1.406,

ML-Schätzwerte: $\hat{\lambda}_{ML} \approx 0.638$ (0.038), $\hat{\alpha}_{ML} \approx 0.547$ (0.023).

Denkbare Interpretation:

„Reproduktionswahrscheinlichkeit“ von 55 %

(Händler zeigt nächsten Teil des Auftrags),

mittlere „Innovationsrate“ von 0.64 (neue iceberg orders).

Aber:

Empirische Varianz ca. 2.181, d. h.

etwa 55 % **Überdispersion**.



Modellierung von Zählzeitenreihen

INARCH(1)-Modell



Definition:

Sei $(X_t)_{\mathbb{Z}}$ Prozess mit Wertebereich $\mathbb{N}_0 = \{0, 1, \dots\}$,
sei $b > 0$ und $0 < a < 1$.

$(X_t)_{\mathbb{Z}}$ folgt dem **INARCH(1)-Modell**

wenn X_t , bedingt auf X_{t-1}, X_{t-2}, \dots ,

Poisson-verteilt ist mit zug. Erwartungswert

$$E[X_t \mid X_{t-1}, X_{t-2}, \dots] = b + a \cdot X_{t-1},$$

d. h.

$$X_t \sim Po(b + a \cdot X_{t-1}).$$

(Heinen, 2003)



Grundlegende Eigenschaften:

- $(X_t)_{\mathbb{Z}}$ stationäre, ergodische Markovkette,
(Zhu & Wang, 2009)
- Übergangswahrscheinlichkeiten

$$P(k|l) = \exp(-b - a \cdot l) \cdot \frac{(b+a \cdot l)^k}{k!} > 0,$$

- AR(1)-Abhängigkeit: $\rho_X(k) = a^k$,
- alle Momente existieren (Ferland, 2006).



Weiß (2009):

Rekursionsschema für **Randkumulanten**:

$$\kappa_1 = \frac{b}{1-a}, \quad \kappa_n = -(1-a^n)^{-1} \cdot \sum_{j=1}^{n-1} s_{n,j} \cdot \kappa_j \quad \text{for } n \geq 2,$$

wobei $s_{n,j}$ die Stirlingzahlen erster Art sind:

$$\begin{aligned} s_{n,0} &= 0 \quad \text{und} \quad s_{n,n} = 1 \quad \text{für } n \geq 1, \\ s_{n+1,j} &= s_{n,j-1} - n \cdot s_{n,j} \quad \text{für } j = 1, \dots, n \text{ und } n \geq 1. \end{aligned}$$

Insbesondere liegt Randverteilung mit Überdispersion vor:

$$\kappa_1 = \frac{b}{1-a} = E[X_t], \quad \kappa_2 = \frac{b}{(1-a)(1-a^2)} = V[X_t].$$



Datenbeispiel (iceberg orders):

ML-Schätzwerte: $\hat{b}_{ML} \approx 0.579$ (0.041), $\hat{a}_{ML} \approx 0.589$ (0.032).

Interpretation analog Poisson-INAR(1)-Modell.

Empirische Überdispersion: ca. 55 %,

Modellüberdispersion $1/(1 - \hat{a}_{ML}^2)$: ca. 53 %.

Vergleich der Modelle:

Poisson-INAR(1): $AIC \approx 2229.8$, $BIC \approx 2239.2$;

INARCH(1): $AIC \approx 2219.7$, $BIC \approx 2229.1$.



Ein erweitertes Poisson-INAR(1) -Modell

„Work in progress“



Motivation:

Wie kann man das Poisson-INAR(1)-Modell mit Rekursion

$$X_t = \alpha \circ X_{t-1} + \epsilon_t, \quad (\epsilon_t)_{\mathbb{N}} \text{ i.i.d. gemäß } Po(\lambda),$$

modifizieren, um Überdispersion zuzulassen?

- Ändere Verteilung der Innovationen (vgl. Weiß (2008));
- ändere thinning und Verteilung der Innovationen (vgl. Weiß (2008));
- Idee: Erlaube seriell abhängige Innovationen!



In Anlehnung an Vorschlag von Buckley & Pollett (2010) (dort bezogen auf infinite-patch-Metapopulationsmodelle) nehmen wir an:

Die Innovation ϵ_t hängt funktional von voriger Beobachtung X_{t-1} ab, d. h. $\epsilon_t \sim Po(f(X_{t-1}))$, wobei $f : \mathbb{N}_0 \rightarrow (0; \infty)$.

$\Rightarrow (X_t)_{\mathbb{N}_0}$ ist weiterhin homogene Markovkette, mit

$$\begin{aligned} P(k|l) &:= P(X_t = k \mid X_{t-1} = l) \\ &= \sum_{j=0}^{\min(k,l)} \binom{l}{j} \alpha^j (1 - \alpha)^{l-j} \cdot e^{-f(l)} \frac{f(l)^{k-j}}{(k-j)!} > 0. \end{aligned}$$

Innovationen $(\epsilon_t)_{\mathbb{N}}$ im Allgemeinen nicht mehr i.i.d.!



Analog zu Buckley & Pollett (2010) sei von nun an $f(x) = a \cdot x + b$, mit Achsenabschnitt $b > 0$.

Erweitertes Poisson-INAR(1)-Modell:

Seien $\alpha, a \in (0; 1)$ mit $\alpha + a < 1$, sei $b > 0$.

Der Prozess $(X_t)_{\mathbb{N}_0}$ folgt der Rekursion

$$X_t = \alpha \circ X_{t-1} + \epsilon_t \quad \text{für } t \geq 1,$$

wobei, gegeben X_{t-1} , $\alpha \circ X_{t-1}$ und ϵ_t unabhängig sind,

auch unabhängig von $X_{t-2}, X_{t-3}, \dots, \epsilon_{t-1}, \epsilon_{t-2}, \dots$

und $\alpha \circ X_{t-2}, \alpha \circ X_{t-3}, \dots,$

und ϵ_t verteilt ist gemäß $Po(a \cdot X_{t-1} + b)$.



Interpretation:

$$X_t = \alpha \circ X_{t-1} + \epsilon_t, \quad \epsilon_t \sim Po(a \cdot X_{t-1} + b).$$

analog zu gewöhnlichem Poisson-INAR(1)-Modell,
aber mit folgendem Zusatzmerkmal:

Immigration wird attraktiver,
wenn aktuelle Population groß ist, d. h.

die grundsätzliche, mittlere Immigrationsrate b
wird erhöht um $a \cdot X_{t-1}$.



Beziehung zu anderen Modellen:

Aus der Definition folgt:

$$X_t \stackrel{D}{=} Y_{t,1} + \dots + Y_{t,X_{t-1}} + \nu_t,$$

wobei die $Y_{t,k}$ und ν_s jeweils i.i.d., auch unabhängig voneinander, und wobei $\nu_s \sim Po(b)$ und $Y_{t,k} \sim B(1, \alpha) + Po(a)$.

$\Rightarrow (X_t)_{\mathbb{N}_0}$ verteilt wie „**branching process with immigration**“ (Letzteres wegen $b > 0$).



Beziehung zu anderen Modellen: (Forts.)

Zusammen mit der Eigenschaft, dass

$(X_t)_{\mathbb{N}_0}$ **irreduzibel und aperiodisch** ist

(da $(X_t)_{\mathbb{N}_0}$ echt positive Überg.wahrsch. hat),

folgt unter Anwendung eines Satzes aus Heathcote (1966):

Für $\alpha + a < 1$

besitzt $(X_t)_{\mathbb{N}_0}$ eine **stationäre Randverteilung**,

entsprechend ist $(X_t)_{\mathbb{N}_0}$ sogar **ergodisch**.




Beziehung zu anderen Modellen: (Forts.)

$$X_t = \alpha \circ X_{t-1} + \epsilon_t, \quad \epsilon_t \sim Po(a \cdot X_{t-1} + b).$$

Grenzfall $a \rightarrow 0$:
Poisson-INAR(1)-Modell.

Grenzfall $\alpha \rightarrow 0$:
INARCH(1)-Modell.

„Brücke“





Stochastische Eigenschaften der Beobachtungen X_t :

$$E[X_t | X_{t-1}, \dots] = (\alpha + a) \cdot X_{t-1} + b,$$

$$V[X_t | X_{t-1}, \dots] = (\alpha(1 - \alpha) + a) \cdot X_{t-1} + b;$$

$$E[X_t^n | X_{t-1}, \dots] = \sum_{j=0}^n \binom{n}{j} \cdot \mu_{j,B(X_{t-1}, \alpha)} \cdot \mu_{n-j, Po(a \cdot X_{t-1} + b)};$$

$$\mu_X := E[X_t] = \frac{b}{1 - (\alpha + a)},$$

$$\sigma_X^2 := V[X_t] = \mu_X \cdot \frac{1 - \alpha^2}{1 - (\alpha + a)^2} \quad (\rightarrow \text{Überdispersion});$$

$$E[(X_t - \mu_X)^3] = \mu_X \cdot \frac{(1 - \alpha^3)(1 - \alpha^2 + a\alpha + 2a^2) + 3a\alpha(1 - \alpha)}{(1 - (\alpha + a)^2)(1 - (\alpha + a)^3)};$$

$$\rho_X(k) = (\alpha + a)^k \text{ für } k \geq 1 \quad (\rightarrow \text{AR}(1)\text{-Abhängigkeit}).$$



Stochastische Eigenschaften der Innovationen ϵ_t :

$$\epsilon_t \sim Po(a \cdot X_{t-1} + b);$$

$$\mu_\epsilon := E[\epsilon_t] = (1 - \alpha) \cdot \mu_X,$$

$$\sigma_\epsilon^2 := V[\epsilon_t] = \frac{\sigma_X^2}{1 + \alpha} \cdot (1 - \alpha^2 - \alpha a(2 - a));$$

$$\rho_\epsilon(k) = a \cdot (\alpha + a)^{k-1} \cdot \left(1 + \alpha a \cdot \frac{\sigma_X^2}{\sigma_\epsilon^2}\right) \text{ für } k \geq 1,$$

d. h. seriell abhängige Innovationen.



Parameterschätzung:

Likelihood-Funktion $L(\alpha, a, b) = \prod_{t=1}^T P(X_t|X_{t-1})$,

numerische Maximierung des Log-Likelihood

ergibt **ML-Schätzer** $\hat{\alpha}_{ML}, \hat{a}_{ML}, \hat{b}_{ML}$.

Momentschätzer können basieren auf

$$b = \mu_X \cdot (1 - \rho_X(1)), \quad \alpha = \sqrt{1 - \frac{\sigma_X^2}{\mu_X} \cdot (1 - \rho_X(1))^2},$$
$$a = \rho_X(1) - \alpha.$$



Datenbeispiel (iceberg orders):

ML-Schätzwerte: $\hat{b}_{ML} \approx 0.567$ (0.040),

$\hat{\alpha}_{ML} \approx 0.410$ (0.058), $\hat{a}_{ML} \approx 0.188$ (0.059).

Empirische Überdispersion: ca. 55 %,

Modellüberdispersion $\frac{1-\hat{\alpha}_{ML}^2}{1-(\hat{\alpha}_{ML}+\hat{a}_{ML})^2}$: ca. 29 %.

Vergleich der Modelle:

Poisson-INAR(1): AIC ≈ 2229.8 , BIC ≈ 2239.2 ;

INARCH(1): AIC ≈ 2219.7 , BIC ≈ 2229.1 ;

Erw. Poisson-INAR(1): AIC ≈ 2212.4 , BIC ≈ 2226.4 .



Datenbeispiel (iceberg orders), Interpretation:

Beobachtete Autokorrelation nicht allein durch „Reproduktionsmechanismus“ bestimmt (Händler zeigt nächsten Teil des Auftrags), sondern auch durch Abhängigkeit der Innovation ϵ_t von voriger iceberg-Zahl X_{t-1} (Steigerung des Basismittels 0.567 um ca. $0.188 \cdot X_{t-1}$).
Liegen viele iceberg orders zur Zeit $t - 1$, werden zusätzliche neue iceberg orders angezogen.
(Aufdeckung von iceberg orders: Frey & Sandas (2009).)



Mögliche weitere Schritte:

- Asymptotik von Schätzern,
- Testverfahren zur Abgrenzung der Modelle,
- andere funktionale Abhängigkeit, z. B.
Immigration weniger attraktiv bei großer Population;
- „density dependence“ z. B. bei binomialem AR(1)-Modell,
eng verwandt zu n -patch-Metapopulationsmodellen.

Vielen Dank für Ihr Interesse!



TECHNISCHE
UNIVERSITÄT
DARMSTADT



Fachbereich
Mathematik

Christian H. Weiß

Fachbereich Mathematik

Technische Universität Darmstadt



Literatur



- Buckley & Pollett (2010): *Limit theorems for discrete-time metapopulation models*. Probab. Surveys 7, 53-83.
- Ferland et al. (2006): *Integer-valued GARCH processes*. Jour. Time Series Analysis 27(6), 923-942.
- Frey & Sandas (2009): *The impact of iceberg orders in limit order books*. CFR working paper 09-06.
- Heathcote (1966): *A branching process allowing immigration*. Jour. Roy. Stat. Soc. B 28(1), 213-217.
- Heinen (2003): *Modelling time series count data: an autoregressive conditional Poisson model*. CORE Discussion Paper No. 2003-63.
- Jung & Tremayne (2011): *Useful models for time series of counts or simply wrong ones?* Adv. in Stat. Analysis 95(1), 59-91.
- McKenzie (1985): *Some simple models for discrete variate time series*. Water Resources Bulletin 21(4), 645-650.
- Steutel & van Harn (1979): *Discrete analogues of self-decomposability and stability*. Ann. Prob. 7(5), 893-899.
- Wei (2008): *Thinning operations for modelling time series of counts – a survey*. Adv. in Stat. Analysis 92(3), 319-341.
- Wei (2009): *Modelling time series of counts with overdispersion*. Stat. Meth. Appl. 18(4), 507-519.
- Zhu & Wang (2009): *Estimation and testing for a Poisson autoregressive model*. Metrika 73(2), 211-230.