

# Markov lánc Monte Carlo módszerek és alkalmazásuk

Vasas Krisztina

2007.05.17

Altenburger Gyula Szimpózium

# Markov láncok

- Irreducibilitás : egy osztály van
- Aperiodicitás : minden elem periódusa 1
- Visszatérőség : minden elem az osztályban visszatérő

# Markov-láncok stacionárius eloszlása

- Ha a lánc aperiodikus és irreducibilis, pozitív visszatérő akkor létezik  $\pi(y)$  stacionárius eloszlás

$$\lim_{n \rightarrow \infty} P(X_n = y \mid X_0 = y) = \pi(y) = \frac{1}{m(y)}$$

- Ha egy ergodikus lánc kielégíti a „detailed balance” feltételt azaz:

$$K(x, y)\pi(x) = K(y, x)\pi(y), \quad \forall x, y \in \text{állapotter}$$

- akkor a láncot reverzibilisnek nevezzük

# Egy gyakorlati probléma

- Bayesi módszerek a statisztikában:
- $$\pi(x | y) \propto L(y | x) p(x)$$
- arányossági tényező:  
$$\int L(y | x) p(x) dx$$
  - Ezt nehéz (vagy nem is lehet) analitikus módszerekkel kiszámolni
  - Ugyanígy, ha  $x$  többdimenziós, a marginális posteriorok, vagy az  $E(\theta(X) | y)$  várható érték kiszámítása is bonyolult

# Megoldások

- Numerikus integrálás, approximáció
- A posterior eloszlásból veszünk mintát, majd a kiszámolni kívánt mennyiségeket ennek segítségével becsüljük: ez a Markov lánc Monte Carlo módszer lényege
- Az első alkalmazás: atomok energiaszintjének meghatározása (1953, Metropolis), majd 1970-ben statisztikai problémák megoldása

# Az MCMC-algoritmusok általános elve I.

- Legyen  $\pi(x)$  egy „céleloszlás”, amelyből mintát kívánunk venni (közvetlenül nem tudunk)
- Generáljunk egy Markov-láncot, amely aperiodikus és irreducibilis, és amelynek stacionárius eloszlása éppen  $\pi(x)$
- Ha a generált sor elég hosszú, akkor a tagok tekinthetők egy  $\pi(x)$  eloszlásból való független mintának

# Az MCMC-algoritmusok általános elve II.

- Ebből a mintából becsülhetjük a céleloszláshoz kapcsolódó mennyiségeket, pl. a várható értéket:

$$\frac{1}{n} \sum_{t=1}^n \theta(X^t) \xrightarrow{n \rightarrow \infty} E_{\pi}(\theta(X))$$

- ahol  $X^t$  egy realizáció

# Hogyan generáljunk „jó” láncot?

- Jelölje  $K(x,y)$  az átmenetkernelt, azaz ha most  $x$ -ben van a lánc, akkor a feltételes eloszlását a lánc következő ( $y$ ) állapotának, feltéve a jelenlegi állapotot
- Ahhoz, hogy  $\pi(x)$  stac. eloszlású láncot generáljunk, olyan  $K(x,y)$  kell, amire:  $K\pi = \pi$
- Ha a lánc reverzibilis ( $\pi(x)K(x,y) = \pi(y)K(y,x)$ )
- akkor minden olyan  $K(x,y)$ -nak, ami teljesíti a feltételt,  $\pi(x)$  a stacionárius eloszlása

# Metropolis-Hastings algoritmus

- Legyen  $x = (x_1, \dots, x_k)$  az állapotvektor, amelynek az  $i$ . komponensét újítjuk fel
- $q(x, y)$  tetszőleges eloszlás, amelyből generálunk egy  $y = (x_1, \dots, x_{i-1}, y_i, x_{i+1}, \dots, x_k)$  elemet

- Ezt az elemet

$$\alpha(x, y) = \min\left(1, \frac{\pi(y)q(y, x)}{\pi(x)q(x, y)}\right)$$

- valószínűséggel elfogadjuk, mint a lánc következő elemét, ha nem fogadjuk el, akkor a lánc ugyanabban az állapotban marad

# Átmenetvalószínűségek a M-H által generált láncban

- Legyen  $P(x, A)$  annak valószínűsége, hogy a lánc következő állapota az  $A$  halmazba esik, feltéve, hogy most  $x$ -ben van.

$$P(x, A) = \int_A K(x, y) dy + \chi_A(x) r(x)$$

- Itt  $K(x, y) = q(x, y)\alpha(x, y)$ ,  $r(x) = 1 - \int_{\Omega} q(x, y)\alpha(x, y) dy$
- $P(x, A)$  kielégíti a detailed balance feltételt  $\pi(x)$ -re vonatkozóan
- $\pi(x)$ -et elég konstans szorzó erejéig ismerni
- Ha  $q(x, y)$  szimmetrikus, egyszerű az elfogadási valószínűség

# A Gibbs-sampler

- M-H speciális esete, akkor alkalmazható, ha a lánclemek feltételes sűrűségfüggvényei ismertek

$$\pi(y_i | x_{(i)}) = \pi(y_i | x_j \forall j \neq i)$$

- $q(x, y) := \begin{cases} \pi(y_i | x_{(i)}) & \text{ha } x_{(i)} = y_{(i)}, i = 1 \dots k \\ 0 & \text{egyébként} \end{cases}$
- Ekkor

$$\alpha(x, y) = \frac{\pi(y)\pi(x_i | y_{(i)})}{\pi(x)\pi(x_i | y_{(i)})} = \frac{\pi(y)\pi(y_i | y_{(i)})}{\pi(x)\pi(x_i | x_{(i)})} = \frac{\pi(y_{(i)})}{\pi(x_{(i)})} = 1$$

# Egyéb algoritmusok

- Random-walk
- $q(x, y) = f(y - x)$
- Független sampler
- $q(x, y) = f(y)$
- azaz a lánc pillanatnyi állapotától függetlenül választjuk a következőt
- Kombinált samplerek

# Felmerülő kérdések és problémák

- Hány iterációt hajtsunk végre a felújítások során?
- Mikortól lesz a lánc stationárius?
- Milyenek az egyes algoritmusok keverési tulajdonságai?
- Mi legyen a kezdő állapot?
- Melyik algoritmus a „(leg)jobb”?

# Modellválasztási probléma

- Olyan modellek közül próbálunk választani, amelyekben a paraméterek száma maga is paraméter, azaz dimenziók között „ugrálunk”
- Pl. a lehetséges modellek:  $\{\mathcal{M}_k, k \in \mathcal{K}\}$ , ahol  $\mathcal{M}_k$  paramétervektora  $\theta_k \in \mathfrak{R}^{n_k}$
- Megoldás: „reversible jump” MCMC
- Green, 1995

# RJCMC I.

- Legyen most  $\pi(dx)$  mérték,  $q(x,dy)$  egy magfüggvény, amelyből a jelölt elemet választjuk, illetve definiáljunk mozgástípusokat ( $m=1,2,\dots$ ) amellyel egy dimenzióból a másikba kerülünk
- Ha  $x$ -ben vagyunk éppen, akkor legyen az együttes eloszlása  $q_m(x,dy)$  annak, hogy  $y$  a következő lehetséges jelölt és  $m$  a kiválasztott mozgás típusa

$$\alpha_m(x, y) = \min \left( 1, \frac{\pi(dy)q_m(y, dx)}{\pi(dx)q_m(x, dy)} \right)$$

# A RJMCMC megvalósítása I.

- Tegyük fel, hogy az  $m$  mozgási típus segítségével jutunk el  $\mathbf{x}$ -ből  $\mathbf{y}$ -ba ( $y$  magasabb dimenzióban van)
- Mi lehet az  $m$ ? Válasszunk egy  $\mathbf{x}$ -től független  $\mathbf{u}$  véletlen vektort, és legyen  $y$  ennek és  $\mathbf{x}$ -nek determinisztikus függvénye ( $y(\mathbf{x}, \mathbf{u})$ )
- $\mathbf{y}$ -ból  $\mathbf{x}$ -be az inverz transzformáció segítségével juthatunk

# Példa a mozgástípusok definíciójára

- Két lehetséges alternatíva:

$$C_1 = \{1\} \times \mathcal{X} \text{ és } C_2 = \{2\} \times \mathcal{X}^2$$

- Hogyan jutunk  $\{2, \theta_1, \theta_2\}$ -ből vissza  $C_1$ -be? Például az  $f(\theta_1, \theta_2) = \frac{1}{2}(\theta_1 + \theta_2)$  transzformációval.
- Azaz:  $\{2, \theta_1, \theta_2\} \rightarrow \left\{1, \frac{1}{2}(\theta_1 + \theta_2)\right\}$
- És vissza  $\{1, \theta\}$  -ből? Választunk egy  $u$  véletlen vektort függetlenül  $\theta$ -tól, és  $\theta_1 = \theta + u$  illetve  $\theta_2 = \theta - u$ .

# Az RJMCMC megvalósítása II.

- Ha  $\pi(dx)q_m(x, dy)$  létezik véges sűrűségfüggvénye valamilyen (szimmetrikus) mértékre nézve, akkor az  $(m, y)$  párt előállíthatjuk az együttes sűrűségfüggvényükből
- Ekkor

$$\alpha(x, y) = \min\left(1, \frac{p(y)r_m(y)}{p(x)r_m(x)q(u)} \frac{\partial y}{\partial(x, u)}\right)$$

# Egy térstatisztikai probléma megoldása

## MCMC segítségével

- Cél : épületbiztosítások kárszámadatainak modellezése Poisson-modellel, illetve magyarországi települések veszélyességi kategóriákba sorolása
- 3222 település adatai állnak rendelkezésre
- Ezekből 168 kistérséget képeztünk
- Térbeli összefüggést mutató, „számláló” típusú adatok

# Poisson-modell

- Az alkalmazott modell: 
$$y_i \approx \frac{(\lambda_{z_i} E_i)^{y_i}}{y_i!} e^{-\lambda_{z_i} E_i}$$
- $y_i$ : az  $i$ . kistérséghez tartozó kárszám (Poisson-elo.  $\lambda_{z_i} E_i$  várható kárszámmal)
- $z_i$ : az  $i$ . kistérség milyen veszélykategóriába tartozik, értékei természetes számok 1 és 6 között
- Minden kategóriához tartozik egy (napi) kárintensztás – ez a  $\lambda_j$
- $E_i$  : „módosított tartam”, azaz a kockázatban töltött idő napokban, módosítva az épülettípus, falazat és tető típusának hatásával

# Paraméterbecslés

- Paraméterek: a  $\underline{z}=(z_1, \dots, z_{168})$  és a  $\underline{\lambda}=(\lambda_1, \dots, \lambda_6)$   
intenzitásparaméter-vektor és a  $\psi$   
interakcióparaméter
- Feladat: a paraméterek együttes a posteriori eloszlásából generáljuk a paraméterek becsléseit

# A priori sűrűségfüggvények I.

- Prior a  $\underline{z}$ -re:
$$p(\underline{z} | \psi) = \frac{e^{\psi U(\underline{z})}}{e^{\theta_k(\psi)}}$$
- ahol  $U(\underline{z}) = \sum_{i \sim i'} \mathcal{X}_{\{z_i = z_{i'}\}}$   $i \sim i'$  a szomszédsági relációt jelöli. Szomszédnak nevezünk két települést, ha 30 km-nél közelebb vannak egymáshoz. U tehát azt számolja meg, hogy egy adott szomszédsági struktúrában hány azonos kategóriába tartozó szomszéd van.

- $$\theta_k(\psi) = \log \left( \sum_{z \in \{1, \dots, 6\}^{168}} e^{\psi U(\underline{z})} \right)$$

# A priori sűrűségfüggvények II.

- $\Psi$  nemnegatív paramétert interakció-paraméternek nevezzük, a  $\psi=0$  érték a kockázati osztályokba való független besorolást jelenti ( $\{1, \dots, k\}$ -n egyenletes eloszlás szerint), a térbeli függőség nő, ha  $\psi$  nő, a priori eloszlását egyenletesnek tekintettük a  $\{0, 0.1, \dots, 1\}$  halmazon
- Prior  $\lambda_j$ -re:  $\lambda_j \sim \Gamma(\alpha, \beta)$   $\alpha = 1$  és  $\beta = \frac{\sum y_i}{\sum E_i}$
- Az együttes a priori sűrűségfüggvény

$$p(\underline{\lambda} | \alpha, \beta) = k! \chi_{\{\lambda_1 < \lambda_2 < \dots < \lambda_6\}} \prod_{j=1}^6 \frac{\beta^\alpha \lambda_j^{\alpha-1}}{\Gamma(\alpha)} e^{-\beta \lambda_j}$$

# Az a posteriori együttes sűrűségfüggvény

- $p(\underline{z}, \underline{\lambda}, \underline{\psi} | y) \propto p(\underline{\lambda} | \alpha, \beta) p(\underline{z} | \underline{\psi}) p(y | \underline{z}, \underline{\lambda})$
- A  $\underline{z}$  vektort Gibbs-sampling segítségével becsüljük, ehhez a „full conditional”:

$$P(z_i = j | \underline{\psi}, y) \propto \lambda^{y_i} e^{-\lambda_j E_i} e^{\psi n_{ij}}$$


- $n_{ij}$  :  $i$  azon szomszédainak száma, akik szintén  $j$  osztályba vannak sorolva
- $\Psi$  felújítása random-walk MCMC-vel,  $\pm 0.01$ -os perturbációkkal

# Az intenzitásparaméter felújítása

- Metropolis-Hastings algoritmus
- A „jelölt” eloszlás normális, ebből  $\lambda$  logaritmusát generáljuk, amit exp. függvénybe helyettesítünk
- Az elfogadási valószínűség:

$$\min \left( 1, \prod_{j=1}^6 \left( \frac{\lambda'_j}{\lambda_j} \right)^{\alpha + \sum_{i:z_i=j} y_i} \left\{ (\lambda'_j - \lambda_j) \left( \beta + \sum_{i:z_i=j} E_i \right) \right\} \right)$$

# A log-posterior grafikonja (100000 iteráció)

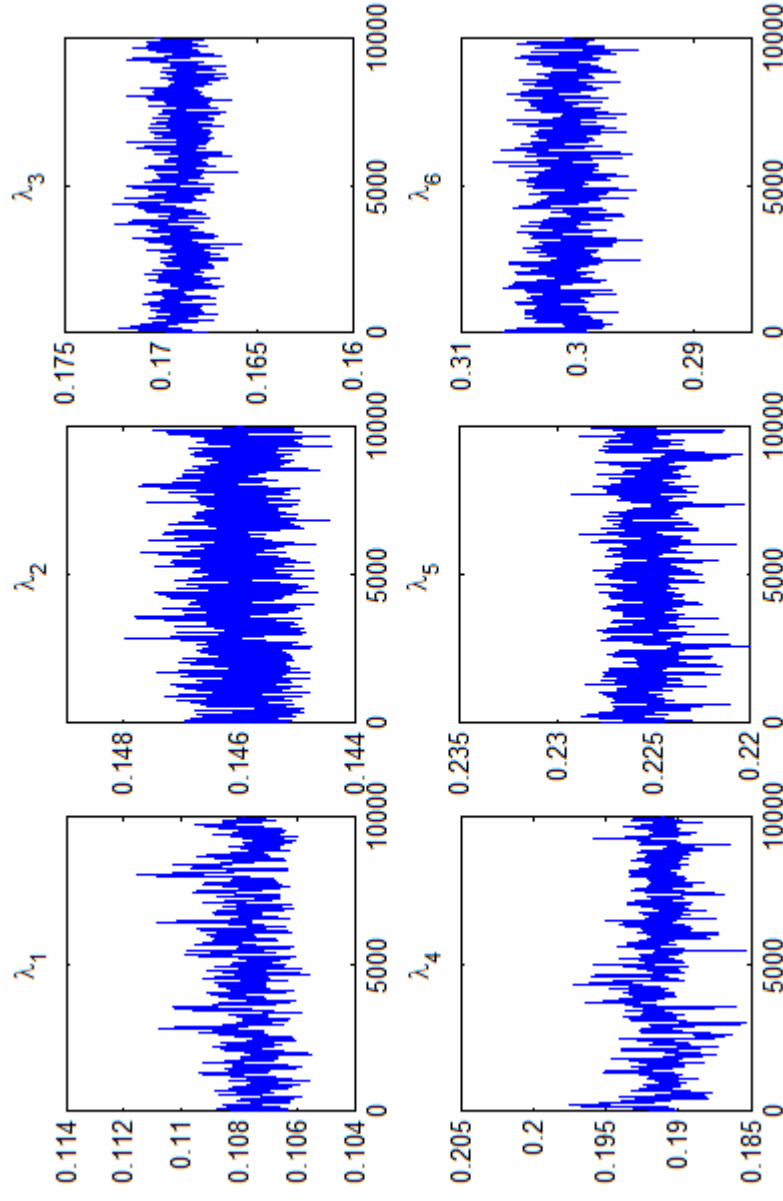


# Az intenzitásparaméterek


- A paraméterek autokorrelációfüggvénye gyorsan lecseng nullához, ez jelzi, hogy a lánc elemei konvergálnak a kívánt eloszláshoz.
- Az utolsó 5000 iterációban már nagyon keveset változnak a paraméterek értékei, ami szintén a jó konvergenciára utal

	Átlagos paraméterérték
$\lambda_1$	0.1079
$\lambda_2$	0.1461
$\lambda_3$	0.1690
$\lambda_4$	0.1910
$\lambda_5$	0.2252
$\lambda_6$	0.3008

# Az intenzitásparaméterek trajektóriái




# Az intenzitásparaméterek trajektóriái az utolsó 5000 iterációban



# A $\lambda$ és $\psi$ paraméterek becslése

- „Veszélyességi” térkép: egy térképen beszínezzük a kistérségek régióközpontjait, minden veszélyosztálynak egy színt megfeleltetve. Az első kockázati osztály a legkevésbé veszélyes(lila), a 6. (fekete) a legveszélyesebb károkozás szempontjából
- A  $\psi$  becslése 1 körül ingadozik
- A legkockázatosabb települések ÉK-en, illetve Pécs környékén találhatóak, Budapest kis mértékben kockázatosnak tekinthető

# Veszélyességi térkép



# A modell lehetséges javítása

- A kockázati osztályok számát nem mondjuk meg előre, hanem azt is paraméterként kezeljük. (RJCMC)

# Egy rezsimváltó autoregresszív modell

$$Y_t = \begin{cases} Y_{t-1} + \varepsilon_{1,t}, & \text{if } I_t = 0 \\ a(Y_{t-1} - c) + c + \varepsilon_{2,t}, & \text{if } I_t = 1 \end{cases}$$

- $I_t$  az aktuális rezsim típusa:
  - 0 ha  $t$  a növekvő rezsimbe tartozik
  - 1 ha  $t$  a csökkenő rezsimbe tartozik.
- $I_t$  Markov-lánc a következő átmenetvalószínűség-mátrixsal:

$$P = \begin{pmatrix} P_{00} & P_{01} \\ P_{10} & P_{11} \end{pmatrix}$$

- A generáló zajok feltételelesen függetlenek:
  - $\varepsilon_{1,t} \sim \Gamma(\alpha, \lambda)$  a növekvő rezsimben (pozitív sokkok)
  - $\varepsilon_{2,t} \sim N(0, \sigma^2)$  a csökkenő rezsimben

# A modell stacionaritása

- A modell a következő sztochasztikus differenciaegyenlet alakjában írható:  $Y_t = a_t Y_{t-1} + b_t$

- ahol  $a_t = 1\mathcal{X}_{\{I_t=0\}} + a\mathcal{X}_{\{I_t=1\}}$

$$b_t = \varepsilon_{1,t}\mathcal{X}_{\{I_t=0\}} + \varepsilon_{2,t}\mathcal{X}_{\{I_t=1\}}$$

- Brandt(1996) tételéből következik, hogy az egyértelmű stacionárius megoldás :

$$Y_t = b_t + \sum_{i=1}^{\infty} a_t a_{t-1} \cdots a_{t-i-1} b_{t-i}$$

- mivel

$$E(\log(|a_0|)) < 0, \text{ and } E(\log(|b_0|^+)) < \infty$$

# A modell becslése

- A modell paraméterei:  $\theta = (p_{00}, p_{11}, \alpha, \lambda, \eta, a, c)$ , ahol  $\eta=1/\sigma^2$ .
- A látens változók ( $I_t$ ) a modell becslését megnehezítik.
- Kézenfekvő lehetőségek:
  - Maximum likelihood  
(A likelihood felírható, de csak rekurzív formában, a látens változók miatt)
  - **Markov Chain Monte Carlo (MCMC)**
  - Efficient Method of Moments (EMM).

# Az a posteriori sűrűségfüggvény

$$f(\underline{\theta} | \{Y_t\}) = \int f(\{I_t\}_{t=1}^T, \underline{\theta} | \{Y_t\}) d\{I_t\}_{t=1}^T$$

$$f(\{I_t\}_{t=1}^T, \underline{\theta} | \{Y_t\}) \propto f(\{Y_t\} | \{I_t\}_{t=1}^T, \underline{\theta}) f(\{I_t\}_{t=1}^T | \underline{\theta}) f(\underline{\theta}) \propto$$

$$\prod_{t=1}^T [f_{\Gamma(\alpha, \lambda)}(Y_t - Y_{t-1})]^{x\{I_t=0\}} [f_{N(0, \sigma^2)}(Y_t - c - a(Y_{t-1} - c))]^{x\{I_t=1\}} p_{00}^{n_{00}} p_{01}^{n_{01}} p_{10}^{n_{10}} p_{11}^{n_{11}} \cdot f(\underline{\theta})$$

Ahol például  $n_{00} = \#(I_{t-1}=0 \text{ and } I_t=0)$ .

# Markov Chain Monte Carlo módszer

- Az együttes posteriorból kell mintát vennünk, hogy megkapjuk a becsléseket
- Erre a megfelelő módszer egy Markov-lánc készítése a következő stacionárius eloszlással:  $f(\{I_t\}_{t=1}^T, \underline{\theta} | \{Y_t\})$ .
- A rejtett állapotokat ( $I_t$ ) a strukturális paraméterekhez hasonlóan „felújítjuk”
- Gibbs-samplinget szeretnénk használni, amikor csak lehet
- Konjugált priorok segítségével 6 paraméternek felírhatóak a megfelelő feltételes eloszlásai
- A Metropolis-Hastings lépés csak a növekvő rezsimben jelenlévő gamma eloszlás alakparaméterének ( $\alpha$ ) becslésekor szükséges

# Gibbs sampling

- Ha felírhatóak a teljes feltétele eloszlások:

$$\pi(\theta_j | \theta_1, \dots, \theta_{j-1}, \theta_{j+1}, \dots, \theta_n) = \frac{\pi(\theta_1, \dots, \theta_{j-1}, \theta_j, \theta_{j+1}, \dots, \theta_n)}{\int \pi(\theta_1, \dots, \theta_{j-1}, \theta_j, \theta_{j+1}, \dots, \theta_n) d\theta_j}$$

- a mintavétel a feltételes eloszlásokból realizálható:

$$\begin{aligned} \theta_1^{(t+1)} &\sim \pi(\theta_1 | \theta_2^{(t)}, \theta_3^{(t)}, \dots, \theta_n^{(t)}) \\ \theta_2^{(t+1)} &\sim \pi(\theta_2 | \theta_1^{(t+1)}, \theta_3^{(t)}, \dots, \theta_n^{(t)}) \\ &\vdots \\ \theta_n^{(t+1)} &\sim \pi(\theta_n | \theta_1^{(t+1)}, \theta_2^{(t+1)}, \dots, \theta_{n-1}^{(t+1)}) \end{aligned}$$

# Metropolis-Hastings

- Válasszuk egy  $Y$  jelöltet  $q(y|\theta^{(t)})$  eloszlásból az iteráció minden lépésében
- A jelölt pontot fogadjuk el az alábbi valószínűséggel

$$\alpha(\theta^{(t)}, y) = \min\left(\frac{\pi(y)q(\theta^{(t)} | y)}{\pi(\theta^{(t)})q(y | \theta^{(t)})}, 1\right)$$

akkor  $\theta^{(t+1)}=y$  és minden egyéb esetben  $\theta^{(t+1)}=\theta^{(t)}$ .

# A priorok megválasztása

Remember the model:

$$Y_t = \begin{cases} Y_{t-1} + \varepsilon_{1,t}, & \text{if } I_t = 0 \\ a(Y_{t-1} - c) + c + \varepsilon_{2,t}, & \text{if } I_t = 1 \end{cases}$$

$$P = \begin{pmatrix} P_{00} & P_{01} \\ P_{10} & P_{11} \end{pmatrix}$$

- $\alpha \sim \Gamma(\alpha_u, \lambda_u)$
- $\lambda \sim \Gamma(r, \beta)$
- $\eta \sim \Gamma(q, \rho)$
- $a \sim N(\mu, \tau)$
- $c \sim N(v, \kappa)$
- $P_{00} \sim \beta(u_1, v_1)$
- $P_{11} \sim \beta(u_2, v_2)$

$$\varepsilon_{1,t} \sim \Gamma(\alpha, \lambda)$$

$$\varepsilon_{2,t} \sim N(0, \sigma^2)$$

# Teljes feltételesek $\lambda$ -ra és $\eta$ -ra

- $\lambda$  eloszlása:

$$\lambda | (\{Y_t\}, \{I_t\}, \alpha) \sim \Gamma(n_0 \alpha + r, \sum_{I_t=0} (Y_t - Y_{t-1}) + \beta)$$

- $\eta$  eloszlása:

$$\eta | (\{Y_t\}, \{I_t\}, a, c) \sim \Gamma\left(\frac{n_1}{2} + q, \sum_{I_t=1} (Y_t - c - a(Y_{t-1} - c))^2 + \rho\right)$$

# Teljes feltételesek $a$ -ra és $c$ -re

- C eloszlása:

$$c | (\{Y_t\}, \{I_t\}, a) \sim N \left( \frac{(1-a) \sum_{I_t=1} (Y_t - aY_{t-1})^2 + v\kappa}{n_1(1-a)^2 + \kappa}, \frac{1}{n_1(1-a)^2 + \kappa} \right)$$

- 

$$a | (\{Y_t\}, \{I_t\}, c) \sim N \left( \frac{\mu\tau + \eta \sum_{I_t=1} (Y_t - c)(Y_{t-1} - c)}{\tau + \eta \sum_{I_t=1} (Y_{t-1} - c)^2}, \frac{1}{\tau + \eta \sum_{I_t=1} (Y_{t-1} - c)^2} \right)$$

# Teljes feltételesek az átmenetvalószínűségekre

- $P_{00}$  eloszlása:

$$P_{00} | (\{I_t\}) \sim \beta(n_{00} + u_1, n_{01} + v_1)$$

- $P_{11}$  eloszlása:

$$P_{11} | (\{I_t\}) \sim \beta(n_{11} + u_1, n_{10} + v_1)$$

# A teljes feltételesek a rejtett állapotokra

e.g.:

$$P(I_t = 0 | I_{t-1} = 0, I_{t+1} = 0, Y_t, Y_{t-1}) = \frac{p_{00}^2 \Gamma(Y_t - Y_{t-1})}{p_{00}^2 \Gamma(Y_t - Y_{t-1}) + (1 - p_{00})(1 - p_{11}) N(Y_t - c - a(Y_{t-1} - c))}$$

$$P(I_t = 1 | I_{t-1} = 1, I_{t+1} = 1, Y_t, Y_{t-1}) = \frac{p_{11}^2 N(Y_t - c - a(Y_{t-1} - c))}{(1 - p_{00})(1 - p_{11}) \Gamma(Y_t - Y_{t-1}) + p_{11}^2 N(Y_t - c - a(Y_{t-1} - c))}$$

# Az $\alpha$ felújítása

- A Metropolis-Hastings lépések során  $\alpha$  felújítására normális eloszlást alkalmaztunk:  $\alpha^* \sim N(\alpha, \delta^2)$

# Mi történik, ha az állapot-folyamat mégsem Markov?

- A Markovitás következménye, hogy az egy rezsimben eltöltött idő geometriai eloszlású
- Egy lehetséges általánosítás:
  - Legyen a növekvő rezsimek hosszának eloszlása:  $\text{NegBin}(\beta, p_1)$
  - A csökkenő rezsimek maradjanak geometriai eloszlásúak:  $\text{Geom}(p_0)$
  - A rezsimhosszak maradjanak függetlenek
- Speciális eset:  $\beta=1$  (az előző modellt nyerjük)

# Az általánosított modell becslése: 1. megközelítés

- A strukturális paraméterek:  $\underline{\theta} = (\alpha, \lambda, \eta, a, c, p_0, \beta, p_1)$
- A posterior a megfelelő módon változtatható
- $\beta$ -ra gamma eloszlású priort feltételezünk
- Minden lépés ugyanaz, mint az előző modellben, kivéve  $\beta$ -t,  $p_{1-t}$   $I_t$ -ket
- $\beta$  Metropolis-Hastings lépésekkel újítjuk fel
- Az  $I_t$ -k eloszlása már nem csak  $Y_{t-1}$ ,  $Y_t$ ,  $I_{t-1}$  és  $I_{t+1}$ -től függ, hanem a  $t$  utáni 0 és 1 futamok hosszától is.

# Az általánosított modell becslése:

## A „reversible jump” megközelítés

- Az  $I_t$ -k helyett vezessük be a rezsimek váltáspontjait, mint látens változókat:
  - A csökkenő periódusok végpontjai:  $\underline{s}=(s_1, \dots, s_k)$
  - A növekvő periódusok végpontjai:  $\underline{t}=(t_1, \dots, t_k)$
- A kezdőértékeket és a váltáspontok számát az előző modellből becsültük meg
- Ha ismerjük a váltáspontokat,  $\{I_t\}$  meghatározható, így az előző algoritmus nagy része alkalmazható
- Az új probléma és feladat: a váltáspontok felújítása

# És ha a váltáspontok száma is paraméter?

- A valóságban a váltáspontok számát nem tudjuk előre meghatározni
- A megoldás: legyen ez is paraméter és a strukturális változókhöz hasonlóan újítsuk fel ezt is
- A standard MCMC technikák itt már nem alkalmazhatóak, itt „reversible jump” MCMC-t kell felépíteni (see Green, 1995)

# A „reversible jump” algoritmus

- 3 lépést definiáltunk:
  - Step 1. : Minden paramétert felújítunk, kivéve a váltáspontok számát
  - Step 2. : „Születési” lépés: egy új váltáspontot szúrunk be két véletlenszerűen kiválasztott már meglévő váltáspont közé
  - Step 3. : „Halál” lépés : egy véletlenszerűen kiválasztott váltáspontot törölünk
- A lépéseket a következő valószínűségekkel választjuk:  $q_1, q_B, q_D$ ,  $q_1 + q_B + q_D = 1$ .

# A váltáspontok felújítása az első lépésben

- Teljes feltételes az  $\underline{s}$ -re:

$$P(s_i = t_{i-1} + x \mid t_{i-1}, t_i, \{Y_t\}) =$$

$$\frac{P(\{Y_t\}_{t_{i-1} \leq t \leq t_i} \mid t_{i-1}, t_i, s_i = t_{i-1} + x) P(s_i = t_{i-1} + x \mid t_{i-1}, t_i)}{\sum_y P(\{Y_t\}_{t_{i-1} \leq t \leq t_i} \mid t_{i-1}, t_i, s_i = t_{i-1} + y) P(s_i = t_{i-1} + y \mid t_{i-1}, t_i)}$$

- Ahol a második tag :  $(N_1$  negatív binomiális,  $N_2$  geometriai eloszlású)

$$P(s_i = t_{i-1} + x \mid t_{i-1}, t_i) = P(N_1 = x) P(N_1 + N_2 = t_i - t_{i-1}) =$$

$$\frac{\text{NegBin}(x, b, 1 - p_{00}) \text{Geom}(t_i - t_{i-1} - x, 1 - p_{11})}{\sum_y \text{NegBin}(y, b, 1 - p_{00}) \text{Geom}(t_i - t_{i-1} - y, 1 - p_{11})}$$

# Elfogadási valószínűségek a második és harmadik lépésben

- A születés lépésében az alábbi mozgási típus elfogadásának valószínűsége:  $(t, s) \rightarrow (t^*, s^*)$

$$\alpha_{birth} = \min \left( 1, \frac{f(\underline{\theta}, k+1, \underline{t}^*, \underline{s}^* | \{Y_t\}) \frac{q_D}{2k+1} \frac{2}{(m-2)(m-1)}}{f(\underline{\theta}, k, \underline{t}, \underline{s} | \{Y_t\}) \frac{q_B}{l}} \right)$$

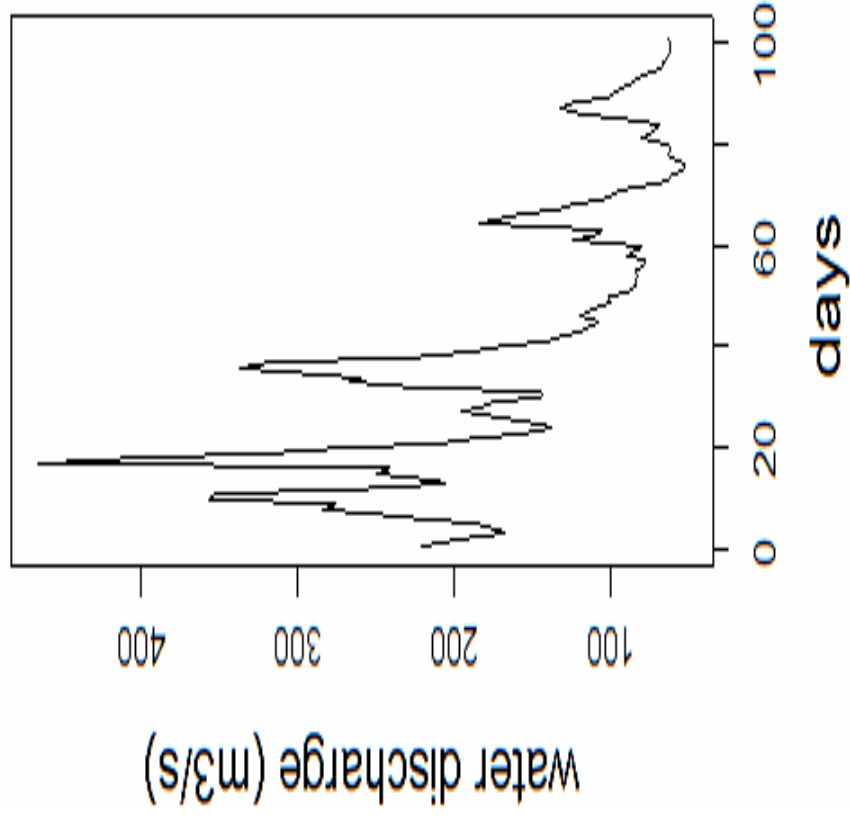
- A „halál” lépésben a fenti valószínűség inverze lesz az elfogadási esély

# Eredmények Tivadar esetében

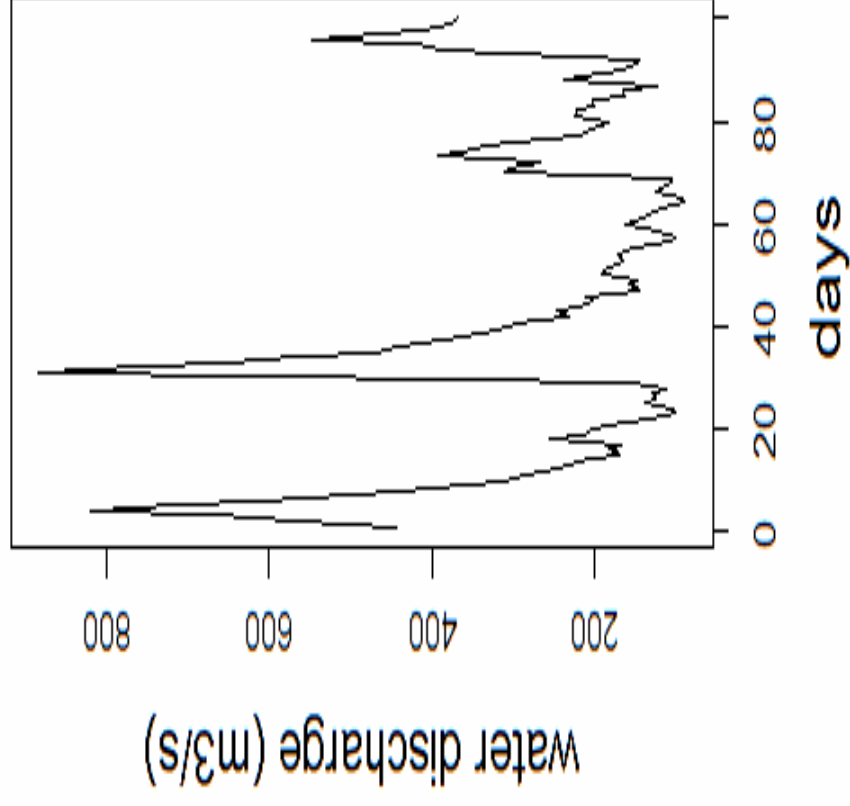
- Mindkét megközelítést kipróbáltuk, a fix dimenziós jobbnak bizonyult
- $\beta = 4.77$  (s.e. 1.38); szignifikánsan különbözik 1-től
- A növekvő rezsimék átlagos hossza 2.5 nap
- A csökkenő rezsimék átlagos hossza 14.4 nap
- $a = 0.815$  (s.e. 0.0023); magas perzisztencia a csökkenő rezsimben
- $\alpha = 0.974$  (s.e. 0.072); a növekvő rezsime majdnem exponenciális

# A modell visszaadja a hidrográf aszimmetrikus alakját


**empirical**



**simulated**



# Az eredeti (red) és a szimulált(kék) idősorok sűrűségfüggvénye



**Köszönöm a figyelmet!**