

# Tolydūs procesai, diskretūs procesai ir burbulų statistika

Aleksejus Kononovicius

Pagal [AK & VG, recenzuojamas (2019)] ir [VG, AK & SR, ACS 15: 1250071 (2012)].

## Paradoksas!

Ilgą atmintį,

$$S(f) \sim f^{-\beta}, \quad C(\tau) \sim \tau^{1-\beta}, \quad \beta \approx 1,$$

gauname naudodami Markovo procesą (netiesinę SDL):

$$dx = \left( \eta - \frac{\lambda}{2} \right) x^{2\eta-1} dt + x^\eta dW. \quad (\star)$$

## Paradokso sprendimas

Būna “tikros” ilgos atminties<sup>1</sup> ir netikros ilgos atminties<sup>2</sup> procesai.

---

<sup>1</sup>pvz., trupmeninis Brauno judėjimas (angl. fractional Brownian motion; trump. fBm)

<sup>2</sup>angl. spurious long-range memory

## Tikslas:

Rasti metodą, kuris atskirtų “tikros” ilgos atminties procesus nuo netikros ilgos atminties procesų.

## Igyvendinimo idėja:

Yra tokia stochastinių procesų savybė vadinama pirmo kirtimo laiku<sup>3</sup>,  $T$ . fBm atveju yra gerai žinoma, kad:


$$p(T) \sim T^{H-2},$$

čia  $H$  yra fBm Hursto rodiklis. Vienmačiams Markovo procesams yra žinoma, kad  $p(T) \sim T^{-3/2}$ .

$$T_{x_0, h} = \text{Inf} \{t > 0 : x(t) = h | x(0) = x_0\}.$$

<sup>3</sup> angl. first passage time

# Idėjos iliustracija



Netiesinės SDL ( $\star$ ) ir fBm spektriniai tankiai ir pirmo kirtimo laikai. Iš [VG & AK, Entropy 19: 387 (2017)].

## Išvystyti metodiką

SDL (★) ir kitų Markovo procesų pirmo kirtimo laikų skirstiniams aproksimuoti.

## Netiesinės SDL ( $\star$ ) pirmo kirtimo laikai

Tiesiogiai spręsti uždavinį sunku,

bet galime netiesinę SDL ( $\star$ ) transformuoti į Besselio procesą:

$$dR = \frac{N-1}{2} \frac{dt}{R} + dW = \left( \nu + \frac{1}{2} \right) \frac{dt}{R} + dW.$$


Čia  $R$  yra  $N$ -mačio Brauno judėjimo padėties vektoriaus modulis (Euklidinė norma), o  $\nu$  vadinamas proceso indeksu.

Perėjimui reikalinga transformacija

yra Lamperti transformacija:

$$R(x) = - \int \frac{1}{x^\eta} dx = \frac{1}{(\eta-1)x^{\eta-1}}.$$

# Transformacija



$$x \in (0, \infty), \quad R \in (0, \infty), \quad R(x) \xrightarrow{x \rightarrow 0} \infty.$$

# Besselio proceso pirmo kirtimo laikai

yra gerai žinomi:

$$p_{R_0, h}^{(\nu)}(T) = \frac{h^{\nu-2}}{R_0^\nu} \sum_{k=1}^{\infty} \frac{j_{\nu, k} J_\nu\left(\frac{R_0}{h} j_{\nu, k}\right)}{J_{\nu+1}(j_{\nu, k})} \exp\left(-\frac{j_{\nu, k}^2 T}{2h^2}\right).$$

Būtų džiugu, bet:


- Suma yra begalinė.
- Joje yra Besselio funkcija  $J_\nu(x)$ .
- Joje yra Besselio funkcijos nuliai  $j_{\nu, k}$  ( $J_\nu(j_{\nu, k}) = 0$ ).
- Ji galioja tik  $R_0 < h$ .

Dalį šių problemų galime apeiti aproksimuodami specifinį atvejį, kai  $R_0 \rightarrow h$ . Šį atvejį vadinsime pikų (kai  $R_0 \downarrow h$ ) ir duobių (kai  $R_0 \uparrow h$ ) statistika.

Pirmą kartą įvesti [Kaulakys and Alaburda, J. Stat. Mech. P02051 (2009)].



## Pikai ir duobės (pavyzdys)



Formalus apibrėžimas,  $\epsilon > 0$ :

$$\tau_h = \text{Inf} \{t > 0 : x(t) \leq h \mid x(0) = h + \epsilon\},$$

$$\theta_h = \text{Inf} \{t > 0 : x(t) \geq h \mid x(0) = h - \epsilon\}.$$

vis dar yra begalinė suma:


$$p_h^{(\nu)}(\theta) \approx C_1 \sum_{k=1}^{\infty} j_{\nu,k}^2 \exp\left(-\frac{j_{\nu,k}^2}{2h^2}\theta\right).$$

Šią begalinę suma galime traktuoti kaip Rymano sumą ir pakeisti sumą integralu:

$$p_h^{(\nu)}(\theta) \approx C_2 \int_{j_{\nu,1}}^{\infty} x^2 \exp\left(-\frac{x^2}{2h_y^2}\theta\right) dx.$$

Toki pakeitimą daryti mums leidžia Besselio nulių savybė, kad jie auga beveik tiesiškai.


# Besselio nuliai



# Besselio proceso duobių trukmių skirstinys

galiausiai užrašomas taip:

$$p_h^{(\nu)}(\theta) \approx C_3 \left[ j_{\nu,1} \frac{\exp\left(-\frac{j_{\nu,1}^2 \theta}{2h^2}\right)}{\theta} + h \sqrt{\frac{\pi}{2}} \frac{\operatorname{erfc}\left(\frac{j_{\nu,1}}{\sqrt{2}h} \sqrt{\theta}\right)}{\theta^{3/2}} \right].$$



Aproksimacija veikia gana gerai,


bet  $C_3$  nustatyti neįmanoma, nes normavimo integralas diverguoja, kai  $\theta \rightarrow 0$ .

Kodėl diverguoja?

Nes procesą startuojame begalo arti ribos  $h$ .

## Gimimo–mirties procesai


- Markovo procesai (grandinės)
- Būseną yra diskreti ir keičiasi tik per vieną žingsnį
- Gali turėti baigtinį būsenų skaičių, gali turėti begalinį
- Pilnai apibrėžti gimimo,  $\lambda_X^+$ , ir mirimo,  $\lambda_X^-$ , spartų



# Radioaktyvaus skilimo gimimo–mirties procesas

$$\lambda_X^+ = 0, \quad \lambda_X^- = \frac{\ln 2}{t_{1/2}} X.$$

Mes žinome, kad  $U^{232}$  izotopo  $t_{1/2} = 2.17 \cdot 10^9$  sekundžių.



## Vieno žingsnių tikimybių metodas:

- 1  $t = 0, X = X_0$  ir pasirenkame  $\Delta t$ .
- 2  $t \rightarrow t + \Delta t$ .
- 3  $X$  pokytis ( $\{-1, 0, 1\}$ ):  $p(X \rightarrow X \pm 1) = \lambda_X^\pm \Delta t$ .
- 4 Jei  $t < t_{max}$  grįžtame į antrą žingsnį.

## Gillespie metodas:

- 1  $t = 0, X = X_0$ .
- 2 Generuojame  $\tau \sim \text{Exp}(\lambda_X^+ + \lambda_X^-)$ .
- 3  $t \rightarrow t + \tau$ .
- 4  $X$  pokytis ( $\{-1, 1\}$ ):  $p(X \rightarrow X \pm 1) = \frac{\lambda_X^\pm}{\lambda_X^+ + \lambda_X^-}$ .
- 5 Jei  $t < t_{max}$  grįžtame į antrą žingsnį.

## Žinant gimimo ir mirties spartas

nesunku išvesti SDL ekvivalenčią gimimo–mirties procesui:

$$dx = \Delta x(\lambda_X^+ - \lambda_X^-)dt + \sqrt{\Delta x^2(\lambda_X^+ + \lambda_X^-)}dW,$$

čia  $x = X/N$  ( $N \rightarrow \infty$ ), atitinkamai  $\Delta x = 1/N$ .

## Atvirkštinis perėjimas,

nuo SDL prie gimimo–mirties proceso, yra įmanomas, bet jis nevisada yra paprastas ir vienareikšmis. Toliau tą darysime du kartus: kursime Besselio proceso ir Ornstein–Uhlenbeck proceso atitikmenis.



Keilsono teorema sako, kad  $X_O < H$  atveju:

$$\mathcal{L} \{p(T_{X_0, H})\} = \langle e^{-sT_{X_0, H}} \rangle = \frac{\prod_{i=1}^H \frac{\lambda_i^{(H)}}{s + \lambda_i^{(H)}}}{\prod_{i=1}^{X_0} \frac{\lambda_i^{(X_0)}}{s + \lambda_i^{(X_0)}}}, \quad s \geq 0.$$

Čia  $\lambda_i^{(H)}$  yra neigiamo  $H$ -tojo rango proceso generatoriaus matricos teigiamos tikrinės vertės. Džiūgu, bet:

- Bendru atveju padaryti atvirkštinę Laplaso transformaciją yra neįmanoma.
- Bet mus domina tik  $X_0 = H - 1$ . Atvirkštinė transformacija yra vis tiek problematiška. Mathematica susidoroja tik su mažais  $H$ .

## Gimimo mirties proceso generatoriaus matrica

yra tri-diagonali matrica, kurios diagonalėse yra mirties spartos, neigiamos suminės spartos ir gimimo spartos:

$$\mathcal{G} = \begin{pmatrix} -\lambda_0^+ & \lambda_0^+ & 0 & 0 & 0 & \dots \\ \lambda_1^- & -\lambda_1^- - \lambda_1^+ & \lambda_1^+ & 0 & 0 & \dots \\ 0 & \lambda_2^- & -\lambda_2^- - \lambda_2^+ & \lambda_2^+ & 0 & \dots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \dots \end{pmatrix}$$

## Skaitmeniškai suskaičiuoti $-\mathcal{G}$

tikrines vertes su fiksuotu  $H$  nėra didesnės problemos. Tačiau bendro analizinio rezultato gauti nepavyksta.

## Kadangi

nemokame tvarkytis su dideliais  $H$ , tai belieka įdėmiau patyrinėti rezultatus su mažais  $H$ :

- Atvirkštinės Laplaso transformacijos rezultatas yra eksponenčių suma.
- Eksponenčių laipsnio rodikliai yra  $-\lambda_i^{(H)}\theta$ .
- Eksponenčių koeficientai yra problematiškesnis klausimas.

## Tegu

mūsų metodika tolydžiam Besselio procesui beveik tinka ir gimimo–mirties procesų atveju.

## Ką tai reiškia?

- Tegu atvirkštinės Laplaso transformacijos rezultatas turi specifinį pavidalą.
- Tegu šaknis iš gimimo–mirties proceso neigiamo generatoriaus teigiamos tikrinės vertės auga tiesiškai tam tikrame (kiek galima platesniame) intervale.
- Tegu pirmoji aproksimacija dažnai nebus gera. Leiskite mums padaryti pataisą, kuri sutapintų pirmus tikrojo skirstinio ir aproksimacijos momentus.

Specifinis pavidalas atvirkštinei transformacijai aproksimuoti:

$$\mathcal{L}^{-1} \left\{ \frac{\prod_{i=1}^H \frac{\lambda_i^{(H)}}{s + \lambda_i^{(H)}}}{\prod_{i=1}^{X_0} \frac{\lambda_i^{(X_0)}}{s + \lambda_i^{(X_0)}}} \right\} \approx \sum_{i=1}^H \lambda_i^{(H)} \exp(-\lambda_i^{(H)} \theta)$$

Jo aproksimavimas:

$$\approx \rho \lambda_1^{(H)} \exp(-\lambda_1^{(H)} \theta) + (1 - \rho) I(\theta, \lambda_2^{(H)}, \lambda_H^{(H)}),$$

$$I(\theta, \lambda_2, \lambda_H) = \frac{1}{\sqrt{\lambda_H} - \sqrt{\lambda_2}} \int_{\sqrt{\lambda_2}}^{\sqrt{\lambda_H}} x^2 \exp(-x^2 \theta) dx,$$

$$\rho = \frac{\lambda_1^{(H)} \left( 1 - \sqrt{\lambda_2^{(H)} \lambda_H^{(H)} \bar{\theta}_{\text{teor}}} \right)}{\lambda_1^{(H)} - \sqrt{\lambda_2^{(H)} \lambda_H^{(H)}}}.$$

Tegu:

$$\lambda_X^+ = \frac{N^2}{2} \left(1 + \frac{\nu'}{X}\right), \quad \lambda_X^- = \frac{N^2}{2} \left(1 - \frac{\nu'}{X}\right).$$





Nesunku įsitikinti, kad:

$$\begin{aligned}\Delta x (\lambda_X^+ - \lambda_X^-) &= \frac{1}{N} \cdot \frac{N^2}{2} \cdot \frac{2\nu'}{X} = \frac{\nu'}{x}, \\ \Delta x^2 (\lambda_X^+ + \lambda_X^-) &= \frac{1}{N^2} \cdot \frac{N^2}{2} \cdot 2 = 1.\end{aligned}$$

Čia  $\nu' = \nu + 1/2$ .

Nepasižymi  $X$  ir  $N - X$  simetrija.

# Besselio gimimo–mirties procesas







Tegu:

$$\lambda_X^+ = \frac{N^2}{2} \left( 1 + \frac{\nu'}{X} - \frac{\nu'}{N-X} \right), \quad \lambda_X^- = \frac{N^2}{2} \left( 1 - \frac{\nu'}{X} + \frac{\nu'}{N-X} \right).$$

Procesas pasižymi  $X$  ir  $N - X$  simetrija.



# Simetrinis Besselio gimimo–mirties procesas



Tegu:

$$\lambda_X^+ = N^2 \left(1 - \frac{X}{N}\right), \quad \lambda_X^- = N^2 \cdot \frac{X}{N}.$$

Nesunku įsitikinti, kad:





$$\begin{aligned}\Delta x (\lambda_X^+ - \lambda_X^-) &= \frac{1}{N} \cdot N^2 \cdot \left(1 - 2\frac{X}{N}\right) = 2N \left(\frac{1}{2} - x\right), \\ \Delta x^2 (\lambda_X^+ + \lambda_X^-) &= \frac{1}{N^2} \cdot N^2 \cdot 1 = 1.\end{aligned}$$

Tolydus O–U procesas:

$$dx = \theta(\mu - x)dt + dW.$$

Procesas pasižymi  $X$  ir  $N - X$  simetrija.

# Ornstein–Uhlenbeck gimimo–mirties procesas







Tegu:

$$\lambda_X^+ = (N - X)(\varepsilon + X), \quad \lambda_X^- = X(\varepsilon + [N - X]).$$

Šis procesas yra analogiškas simetriniam Kirmano modeliui bei Rinkėjo modeliui su išoriniu triukšmu.

Procesas pasižymi  $X$  ir  $N - X$  simetrija.

# Imitacinis gimimo–mirties procesas




# Pritempimas prie duomenų

ir sudėtingesnių modelių

Gautą aproksimaciją galime ir “pritempti” prie duomenų parinkdami parametrus:  $\rho$ ,  $\lambda_1$ ,  $\lambda_2$ ,  $\lambda_n$ . Galime ją taikyti tiek pikams, tiek duobėms.

Pavyzdys su sandorių knygos modelio [AK & JR, recenzuojamas (2019)] pikų ir duobių statistika. Parametrai parinkti derinant pirmus keturis momentus.



## Susiję su tikslu uždaviniai:

- Prielaida apie tikrinių verčių spektrą yra labai stipri. Būtų įdomu pabandyti ją sulaužyti.
- Tikslas platus, uždaviniai yra smulkmeniški. Reikia imti plačiau – sukonstruoti ar surasti lygiavertį “konkurentą”.
- Ar galima atsisakyti burbulų statistikos?

## Nesusiję su tikslu uždaviniai:

- Rinkinys gimimo–mirties procesų, kurių stacionarūs skirstiniai būtų iš pagrindinių naudojamų skirstinių.
- Rinkinys gimimo–mirties procesų analogiškų dažniausiai naudojamiems stochastiniams procesams.

Dėkui už dėmesį!