

## Kapitel 13

# Markovkedjor i Kontinuerlig Tid

### Tidskontinuerliga Markov Kedjor

Nu talar vi lite om Markov kedjor i kontinuerlig tid. En tidskontinuerlig stokastisk process  $\{X_t\}_{t \geq 0}$  med diskret tillståndsrum  $S$  är en Markov kedja om den uppfyller Markov egenskapen:

$$\mathbf{P}(X_{t_{n+1}} = j_{n+1} | X_{t_n} = j_n, X_{t_{n-1}} = j_{n-1}, \dots, X_{t_0} = j_0) = \mathbf{P}(X_{t_{n+1}} = j_{n+1} | X_{t_n} = j_n)$$

för alla  $n \in \mathbb{N}$ ,  $t_{n+1} > t_n > \dots > t_0 \geq 0 \in \mathbb{R}$  och  $j_{n+1}, j_n, \dots, j_0 \in S$ . Det vill säga (precis som i det tidsdiskreta fallet): Fördelningen vid den framtida tiden  $t_{n+1}$  beror bara på processens värde nu ( $t_n$ ) och inte på det förflutna.

Kedjan kallas tidshomogen om  $\mathbf{P}(X_t = j | X_s = i) = \mathbf{P}(X_{t-s} = j | X_0 = i)$ . Liksom tidigare kommer vi endast att diskutera tidshomogena Markov kedjor.

Betänk nu en tidskontinuerlig Markov kedja på rummet  $S = \{0, 1\}$ . Om kedjan börjar i tillstånd 0, finns det en stokastisk variabel som beskriver tiden tills kedjan hoppar till 1 första gången. Vi kallar den tiden  $\xi_0$ .

Antag nu att vi vet att kedjan inte hoppat efter 10 tidsenheter? Vad är sannolikheten att den är kvar efter 15? Det vill säga, vad är

$$\mathbf{P}(\xi_0 > 15 | \xi_0 > 10)?$$

Från Markov egenskapen så vet vi att det som hänt tidigare inte har inverkan på kedjans framtiden givet var den befinner sig nu. Så sannolikheten att den är kvar i 0 i ytterligare 5 minuter utan att hoppa kan inte bero på hur länge vi väntat hittills. Alltså gäller:

$$\mathbf{P}(\xi_0 > 15 | \xi_0 > 10) = \mathbf{P}(\xi_0 > 5).$$

Det följer att  $\xi_0$  måste vara en "minneslös" stokastisk variabel, och den egenskapen har endast exponentialfördelningen. Det följer alltså att  $\xi_0$  är  $\text{Exp}(\lambda_0)$  fördelade för någon intensitet  $\lambda_0$ . Samma sak gäller tiden tills vi hoppar från tillstånd 1 till 0.

En tidskontinuerlig Markov kedja på  $S = \{0, 1\}$  har alltså alltid följande form:

- När den är i tillstånd 0 väntar den en  $\text{Exp}(\lambda_0)$  tid tills den hoppar till tillstånd 1.
- När den är i tillstånd 1 väntar den en  $\text{Exp}(\lambda_1)$  tid tills den hoppar till tillstånd 0.

---

I allmänhet så ser en tidskontinuerlig Markov kedja ut så här:

Befinner vi i tillstånd  $i$ , så finns det en  $\text{Exp}(g_{ij})$  fördelad stokastisk variabel  $\xi_{ij}$  som ger tiden tills vi hoppar till  $j$ . När den första sådana händelse inträffar, hoppar vi till det tillståndet.

Matrisen:

$$G = (g_{ij})_{i,j \in S}$$

med  $g_{ii} = -\sum_{j \in S - \{i\}} g_{ij}$  kallas kedjans *generator*.

- $g_{ij}$  ger takten (intensiteten) med vilken vi går från  $i$  till  $j$ .
- $-g_{ii}$  ger taken med vilken vi lämnar tillstånd  $i$ .

Precis som för tidsdiskret kedjor har vi en övergångsmatris. Skillnaden är att den nu är en matrisvärd funktion av tiden,  $P_t$ :

$$(P_t)_{ij} = \mathbf{P}(X_{s+t} = j | X_s = i)$$

Tidsparametern spelar mycket samma roll som exponenten gjorde för tidsdiskreta Markovkedjor ( $(P^k)_{ij}$  var ju  $\mathbf{P}(X_{n+k} = j | X_n = i)$ ) och beter sig i stort på samma sätt. Till exempel så håller *Chapman-Kolmogorov ekvationen*:

$$P_{s+t} = P_s P_t$$

Att bevisa detta är ren matrisräkning och en applikation av Markov egenskapen. Vi har även att kedjans fördelning i tiden  $t$  ges av:

$$\mu^{(t)} = \mu^{(0)} P_t$$

där  $\mu^{(0)}$

---

Om en kedja är *likformig* så finns kan övergångsmatrisen relateras till generatoren  $G$ :

$$\lim_{h \rightarrow 0} \frac{P_h - P_0}{h} = G$$

dvs

$$g_{ij} = \lim_{h \rightarrow 0} \frac{(P_h)_{ij}}{h}.$$

Detta motiverar (på sätt och vis) att vi tidigare kallade  $g_{ij}$  takten med vilken kedjan går från tillstånd  $i$  till  $j$ .

En fördelning  $\pi$  är stationär om  $\pi P_t = \pi$  för alla tider  $t$ . Detta gäller om och endast om:

$$\pi G = 0.$$

En fördelning är alltså stationär om takten med vilken vi lämnar den är noll.

---

**Exempel: Stationär Telegrafsignal** En tidskontinuerlig Markovkedja med tillståndsrum  $S = \{0, 1\}$  och generator:

$$G = \begin{bmatrix} \lambda & -\lambda \\ -\lambda & \lambda \end{bmatrix}$$

kan liknas vid en telegrafsignal. Det ses direkt att den stationära fördelningen är  $\pi = (\frac{1}{2}, \frac{1}{2})$ . Alltså är det en stationär process om vi utgår från denna fördelningen.

En stationär telegrafsignal studerades tidigare med långa beräkningar i bokens tal 3.9. Genom att se det som en Markov kedja i stället, behövs inga räkningar alls!

---

**Exempel: Poissonprocessen** Poissonprocessen är en tidskontinuerlig Markovkedja  $\{X_t\}_{t \geq 0}$  med tillståndsrum  $S = \mathbb{Z}^+$ , generator:

$$G = \begin{bmatrix} -\lambda & \lambda & 0 & 0 & \dots \\ 0 & -\lambda & \lambda & 0 & \dots \\ 0 & 0 & -\lambda & \lambda & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix}$$

och startfördelning  $\mu^{(0)} = (1, 0, 0, \dots)$ .

Observera att  $G$  är en matris av oändlig storlek, eftersom Poissonprocessens tillståndsrummet är oändligt. (Detta är okej, om man kan vara säker på att alla summer, t ex  $\sum_{j \in S} g_{ij}$ , konvergerar.)

Poissonprocessen har ingen stationär fördelningen: hur den än startas kommer den att växa med tiden.

---

**Exempel: Födelseödsprocess** En födelseödsprocess är en tidskontinuerlig Markovkedja  $\{X_t\}_{t \geq 0}$  med tillståndsrum  $S = \mathbb{Z}^+$ , och generator:

$$G = \begin{bmatrix} -\lambda_0 & \lambda_0 & 0 & 0 & \dots \\ \mu_1 & -(\mu_1 + \lambda_1) & \lambda_1 & 0 & \dots \\ 0 & \mu_2 & -(\mu_2 + \lambda_2) & \lambda_2 & \dots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{bmatrix}$$

**Sats:** En födelseödsprocess  $X_t$  har stationär fördelning  $\pi$  omm.

$$\sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \lambda_2 \dots \lambda_{k-1}}{\mu_1 \mu_2 \mu_3 \dots \mu_k} \leq \infty$$

och i så fall ges  $\pi$  av:

$$\pi_k = \pi_0 \frac{\lambda_0 \lambda_1 \lambda_2 \dots \lambda_{k-1}}{\mu_1 \mu_2 \mu_3 \dots \mu_k}$$

för  $k \geq 1$ , och

$$\pi_0 = 1 / \left( 1 + \sum_{k=1}^{\infty} \frac{\lambda_0 \lambda_1 \lambda_2 \dots \lambda_{k-1}}{\mu_1 \mu_2 \mu_3 \dots \mu_k} \right)$$