

# 1. Folytonos idejű Markov-láncok

## 1. Három ekvivalens definíció

A következőkben definiáljuk a diszkrét állapotterű, folytonos idejű Markov-lánc fogalmát. Az állapotteret  $\mathcal{S}$ -sel fogjuk jelölni.

Legyen adott egy diszkrét idejű Markov-lánc  $Q$  átmenetvalószínűség mátrixszal úgy, hogy a főátlóban lévő elemek 0-k,  $Q_{ii} = 0, i \in \mathcal{S}$ . Ez azt jelenti, hogy ha  $i$ -ben tartózkodik tetszőleges  $i$  állapotra, akkor nem maradhat  $i$ -ben a következő lépés után.

Legyen adott továbbá minden  $i$ -hez egy  $\lambda(i)$  nem negatív valós szám, amit tartási/tartózkodási idő paraméternek hívunk.

Ekkor a folytonos idejű Markov-láncot úgy írhatjuk le, hogy ő egy bolyongás az  $\mathcal{S}$  állapotterén. Ha  $i$ -be ugrott, akkor véletlen hosszú ideig marad  $i$ -ben. Ennek az  $i$ -ben tartózkodásnak a hossza exponenciális eloszlású  $\lambda(i)$  paraméterrel. Amikor letelik ez az idő, akkor elugrik, mégpedig a  $Q$  átmenetvalószínűség mátrixnak megfelelően, tehát  $j$ -be ugrik  $Q_{ij}$  valószínűséggel.

A pontos definíció a következő.

**1. definíció.** Legyen  $\mathcal{S}$  egy diszkrét halmaz. Adott egy  $Q$  átmenetvalószínűség mátrix úgy, hogy minden  $i \in \mathcal{S}$  esetén  $Q_{ii} = 0$ . Adott továbbá egy  $\lambda(i) \geq 0, i \in \mathcal{S}$  sorozat.

Legyen  $X_0, X_1, \dots$  egy  $Q$  átmenetvalószínűség mátrixszal rendelkező Markov-lánc.

Legyen  $T_1 < T_2 < \dots$  egymás utáni ugrási idők sorozata,  $T_0 = 0$ , úgy, hogy az  $(n+1)$ -dik és az  $n$ -dik ugrás között eltelt idő eloszlása  $Exp(\lambda(X_n))$ , azaz

$$T_{n+1} - T_n \sim Exp(\lambda(X_n)).$$

Ekkor az  $X(t), t \geq 0$  folytonos idejű Markov-lánc definíciója:

$$X(t) = X_n \quad \text{ha } T_n \leq t < T_{n+1},$$

azaz két ugrás között konstans, és az értékét a beágyazott Markov-lánc  $X_n$  határozza meg.

Az alkalmazások többségében fontos, hogy a Markov-lánc véges idő alatt ne ugorjon végtelen sokat pozitív valószínűséggel, vagy más szóval ne robbanjon fel. Erre vannak feltételek, amikre most nem térünk ki. Az alkalmazások többségében ez a stabilitás szinte természetesen fenáll.

A következőkben megadjuk a Markov-folyamat második definícióját, amely ekvivalens az elsővel. Ehhez ismételjünk át néhány dolgot exponenciális eloszlásokkal kapcsolatban.

**1. állítás.** Legyen  $Y_1, Y_2, \dots, Y_m$  független exponenciális eloszlások sorozata sorrendben  $\lambda_1, \lambda_2, \dots, \lambda_m$  paraméterrel.

A legkisebb közülük  $\min\{Y_1, Y_2, \dots, Y_m\}$ . Ennek a minimumnak az eloszlása exponenciális  $\lambda_1 + \lambda_2 + \dots + \lambda_m$  paraméterrel:

$$\min\{Y_1, Y_2, \dots, Y_m\} \sim Exp(\lambda_1 + \lambda_2 + \dots + \lambda_m)$$

Annak a valószínűsége, hogy az  $i$ -dik a legkisebb felírható a következőképpen:

$$\mathbf{P}(Y_i = \min\{Y_1, Y_2, \dots, Y_m\}) = \frac{\lambda_i}{\lambda_1 + \lambda_2 + \dots + \lambda_m}.$$

**2. definíció.** Legyen adott egy  $\Lambda = [\lambda_{ij}]_{|\mathcal{S}| \times |\mathcal{S}|}$  mátrix úgy, hogy az elemei nem negatívak és a főátlóban csupa 0 áll. Definiáljuk a folytonos idejű  $X(t), t \geq 0$  Markov-láncot úgy, hogy legyen  $X(0) = i_0$  valamilyen  $i_0 \in \mathcal{S}$  kezdőállapotra. Továbbá, ha  $X(t) = i$  tetszőleges  $i \in \mathcal{S}$  és  $t$  időre, akkor minden olyan  $j$  állapotban, ahol  $\lambda_{ij} \neq 0$  elindítunk egy órát, amelyek egymástól függetlenül csengenek véletlen hosszú idő múlva. Ennek az időnek a hossza exponenciális eloszlású minden állapotra, és a  $j$  állapotban lévő óránál az exponenciális eloszlás paramétere  $\lambda_{ij}$ .

A Markov-folyamat akkor ugrik, amikor az első óra megszólal, és abba az állapotba ugrik, ahol először csengett az óra.

A 1. állítás miatt a két definíció ekvivalens a következő megfeleltetésekkel:

$$\lambda(i) = \sum_{k: \lambda_{ik} \neq 0} \lambda_{ik} = \sum_{k \in \mathcal{S}} \lambda_{ik} \quad \text{és} \quad Q_{ij} = \frac{\lambda_{ij}}{\sum_{k \in \mathcal{S}} \lambda_{ik}}.$$

Ezután leírjuk a folytonos idejű Markov-láncok harmadik definícióját, amely a diszkrét időben leírt Markov-lánc definícióhoz hasonlít, az úgynevezett Markov-tulajdonságot adja meg folytonos időben.

**3. definíció.** Az  $\mathcal{S}$  állapotterén értelmezett  $X(t), t \geq 0$  sztochasztikus folyamatot folytonos idejű Markov-láncnak nevezzük, ha minden  $n$ -re és  $s, t > 0$  számra, és  $t_0 < t_1 < \dots < t_{n-1} < t$  időkre, továbbá  $i, j, i_0, i_1, \dots, i_{n-1} \in \mathcal{S}$  állapotokra igaz a

$$\mathbf{P}(X(t+s) = j \mid X(t) = i, X(t_{n-1}) = i_{n-1}, \dots, X(t_1) = i_1, X(t_0) = i_0) = \mathbf{P}(X(t+s) = j \mid X(t) = i). \quad (1)$$

egyenlőség.

Ha feltesszük, hogy a fenti feltételes valószínűség nem függ  $tt$ -ől, akkor azt mondjuk, hogy a Markov-lánc homogén, azaz

$$\mathbf{P}(X(t+s) = j \mid X(t) = i) = \mathbf{P}(X(s) = j \mid X(0) = i).$$

A (1) egyenlőség azt jelenti, mint diszkrét idő esetén, hogy feltéve a folyamat jelenét  $X(t) = i$ -t a folyamat jövője ( $X(t+s) = j$ ) független a folyamat múltjától ( $X(t_{n-1}) = i_{n-1}, \dots, X(t_1) = i_1, X(t_0) = i_0$ ).

**4. definíció.** Jelöljük  $P(t)$ -vel a  $t$  idejű átmenetvalószínűség mátrixot.  $P(t)$   $ij$  koordinátájú helyén  $P_{ij}(t) = \mathbf{P}(X(t) = j \mid X(0) = i)$  valószínűség áll.

**2. állítás.** A Markov-folyamat három definíciója ekvivalens.

## 2. Tulajdonságok, példák

- Folytonos idejű Markov-lánc állapotteres felbontását érintkezési ekvivalencia osztályokra a beágyazott Markov-lánc állapotteres felbontása határozza meg.
- Hasonlóan a diszkrét esethez, ha megadunk  $n+1$  egymás utáni időpontot  $t_0 < t_1 < \dots < t_n$  és  $i_0, i_1, \dots, i_n \in \mathcal{S}$  állapotot a  $\mathbf{P}(X(t_n) = i_n, \dots, X(t_1) = i_1 \mid X(t_0) = i_0)$  valószínűség felírható

$$\mathbf{P}(X(t_n) = i_n, \dots, X(t_1) = i_1 \mid X(t_0) = i_0) = P_{i_0 i_1}(t_1 - t_0) P_{i_1 i_2}(t_2 - t_1) \dots P_{i_{n-1} i_n}(t_n - t_{n-1})$$

szorzat alakban.

- Hasonlóan a diszkrét idejű esethez itt is kíváncsiak vagyunk az  $X_t$  eloszlására. Ezt úgy tudjuk megadni, hogy megadunk egy kezdeti eloszlást, egy  $\underline{a}$  vektort. Az  $j$ -dik eleme  $a_j = \mathbf{P}(X(0) = j)$ ,  $j \in \mathcal{S}$ . Ekkor teljesen ugyanúgy, mint diszkrét esetben a teljes valószínűség tételt használva azt kapjuk, hogyan

$$\mathbf{P}(X(t) = j) = [\underline{a}P(t)]_j.$$

**1. példa.** *M/M/1 sorbanállási rendszer.* Tegyük fel, hogy egy kiszolgálóhoz érkező csomagok érkezési időpontjai Poisson-folyamatot követnek  $\lambda$  rátával, az két csomag érkezése között  $Exp(\lambda)$  eloszlású időt kell várni. Tegyük fel, hogy a csomagok mérete  $Exp(\mu)$  eloszlású, és egymástól függetlenek. Tegyük még fel, hogy a puffer végtelen, így nincs csomagvesztés, továbbá a szerver egységnyi kapacitású és egyszerre egy csomagot tud kiszolgálni. Legyen  $X(t)$  a rendszerben lévő igények száma, beleszámoljuk az éppen kiszolgálás alatt lévő is, ha van ilyen.  $X(t), t \geq 0$  folytonos idejű Markov-lánc

$$\lambda_{i,i+1} = \lambda, \lambda_{i,i-1} = \mu, \text{ ha } i \geq 1$$

és  $\lambda_{01} = \lambda$  rátákkal.

**2. példa.** *M/M/1 sorbanállási rendszer blokkolással.* Tekintsük az előző feladatban definiált sorbanállási rendszert a következő módosítással. Ha egy csomag beérkezésekor  $i$  másik csomag van a rendszerben, akkor a csomag bekerül a rendszerbe  $\alpha_i$  valószínűséggel,  $1 - \alpha_i$  valószínűséggel pedig eldobódik. Tegyük fel, hogy  $0 \leq \alpha_i \leq 1$  minden  $i$ -re. Legyen  $X(t)$  a rendszerben lévő igények száma, beleszámoljuk az éppen kiszolgálás alatt lévő is, ha van ilyen.  $X(t), t \geq 0$  folytonos idejű Markov-lánc.

A blokkolás azt jelenti, hogy ha  $i$  csomag van a rendszerben, akkor a beérkezéseknek megfelelő Poisson-folyamat ugrásait  $\alpha_i$  valószínűséggel tartjuk meg. Korábban láttuk, hogy az így ritkített Poisson-folyamat is Poisson-folyamat csak  $\alpha_i \lambda$  rátával. Így az  $X(t)$  Markov-lánc rátái a következőképpen alakulnak:

$$\lambda_{i,i+1} = \alpha_i \lambda, \lambda_{i,i-1} = \mu, \text{ ha } i \geq 1$$

és  $\lambda_{01} = \alpha_0 \lambda$  rátákkal.

**3. példa.** *Folytonos idejű elágazófolyamat.* Tegyük fel, hogy egyedek egy populációját vizsgáljuk. Az egyedek egymástól függetlenül fejlődnek, de a fejlődésük ugyanolyan eloszlású. Tekintsünk egy egyedet. Ez az egyed  $Exp(\lambda)$  idő múlva létrehoz egy utódot, vagy  $Exp(\mu)$  idő múlva meghal. Ez a 1. állítás miatt ekvivalens azzal, hogy a megszületése után  $Exp(\lambda + \mu)$  múlva történnie kell valaminek, vagy meghal  $\frac{\mu}{\lambda + \mu}$  valószínűséggel, vagy létrehoz egy utódot  $\frac{\lambda}{\lambda + \mu}$  valószínűséggel. Feltesszük még, hogy ha kihal az elágazó folyamat, akkor  $Exp(\lambda)$  idő múlva megjelenik egy egyed. Belátjuk, hogy ha  $X(t)$  jelöli a  $t$  időben jelenlévő egyedek számát, akkor  $X(t), t \geq 0$  Markov-folyamat.

Számoljuk ki, hogy ha  $i$  egyed van a populációban, akkor mennyi idő telik el az első utód létrehozásáig, illetve az első kihalásig. Ezek lesznek a  $\lambda_{i,i+1}$  és a  $\lambda_{i,i-1}$  ráták. Az első születésig eltelt idő a következőképpen számolható. Legyen  $E_1, E_2, \dots, E_i$  független exponenciális eloszlású valószínűségi változók  $\lambda$  paraméterrel.  $E_1, E_2, \dots, E_i$  jelölő, hogy mennyi idő telne el az egyes egyedeknél az első születésig. A 1. állítás miatt  $\min\{E_1, E_2, \dots, E_i\}$  eloszlása  $Exp(i\lambda)$ . Hasonlóan számolható ki az első halálig eltelt idő, amely  $Exp(i\mu)$  eloszlású. Tehát, az  $X(t), t \geq 0$  Markov-folyamat rátái:

$$\lambda_{i,i+1} = \lambda i, \quad \lambda_{i,i-1} = \mu i, \quad \text{ha } i \geq 1$$

és  $\lambda_{01} = \alpha_0 \lambda$  rátákkal.

**4. példa.** *Folytonos idejű elágazófolyamat bevándorlással.* Módosítsuk úgy az előző modellt, hogy a folyamat fejlődésétől függetlenül van egy bevándorlási folyamat. Egyszerre egy egyed vándorol be, és a bevándorlási idők Poisson-folyamat szerint történnek  $\beta$  paraméterrel. Továbbá, ha a folyamat kihalt, akkor csak bevándorlással jelenhet meg új egyed. Ha  $X(t)$  jelöli a  $t$  időben jelenlévő egyedek számát, akkor  $X(t), t \geq 0$  Markov-folyamat

$$\lambda_{i,i+1} = \lambda i + \beta, \quad \lambda_{i,i-1} = \mu i, \quad \text{ha } i \geq 0$$

rátákkal.

### 3. Markov-lánc időbeli fejlődése

**1. tétel.** Minden Markov-folyamathoz létezik egy  $A, |\mathcal{S}| \times |\mathcal{S}|$  mátrix úgy, hogy a  $P(t)$  mátrix  $t$ -szerinti deriváltjára fennáll a következő két egyenlőség

$$P'(t) = AP(t) \quad \text{és} \quad P'(t) = P(t)A.$$

Az  $A$  mátrixot a Markov-folyamat generátorának nevezzük.

Az  $A$  megadható a beágyazott Markov-lánc  $Q$  átmenetvalószínűség mátrixával, és a  $\lambda(i), i \in \mathcal{S}$  sorozat segítségével a következőképpen:

$$A_{ij} = \lambda(i)Q_{ij} \quad \text{ha } i \neq j \quad A_{ii} = -\lambda(i), \quad i \in \mathcal{S}.$$

A  $P'(t)$  derivált mátrix úgy értendő, hogy az  $ij$ -edik eleme  $P_{ij}(t)'$ .

A Markov-folyamat első két definíciójának ekvivalenciája miatt az  $A$  mátrixot felírhatjuk úgy is, hogy főátlón kívül megegyezik a rátákkal, a főátlóban pedig az egy sorban lévő ráták összegének a  $(-1)$ -szerese áll:

$$A_{ij} = \lambda_{ij} \quad i \neq j, \quad A_{ii} = -\sum_{j \in \mathcal{S}} \lambda_{ij}.$$

### 4. Stacionárius eloszlás

**5. definíció.** Egy  $\underline{\pi}$   $\mathcal{S}$ -en értelmezett valószínűségeloszlást (sorvektor) stacionárius eloszlásnak hívunk, ha teljesül, hogy

$$\underline{\pi}P(t) = \underline{\pi}, \quad \text{minden } t \geq 0 \text{ esetén.}$$

Bebizonyítható a következő állítás.

**3. állítás.** Ha  $\underline{\pi}$  stacionárius eloszlás, akkor a Markov-folyamat stacionárius folyamat, azaz minden  $n$ -re és minden  $t_1, \dots, t_n$  és  $s > 0$  időre igaz az, hogy

$$(X(t_1), \dots, X(t_n)) \text{ eloszlása} = (X(t_1 + s), \dots, X(t_n + s)) \text{ eloszlása.}$$

A fejezet fő állítása a következő.

**2. tétel.** Legyen adott egy  $X_t, t \geq 0$  folytonos idejű Markov-lánc. Tegyük fel, hogy az  $X_n = X(T_n), n = 0, 1, \dots$  beágyazott Markov-lánc irreducibilis és visszatérő – ekkor azt mondjuk, hogy  $X_t, t \geq 0$  irreducibilis és visszatérő.

(A) Ekkor az

$$\underline{y}P(t) = \underline{y}, \text{ minden } t \geq 0$$

sajátvektor egyenletrendszernek létezik pontosan egy megoldása, amely meghatározható az

$$\underline{y}A = \underline{0}$$

egyenlet megoldásával.

(B) Ha  $\sum_{i \in \mathcal{S}} y_i < \infty$ , akkor létezik egyetlen  $\underline{\pi}$  *stacionárius eloszlás* úgy, hogy minden eleme pozitív. Továbbá  $\underline{\pi}$  felírható

$$\pi_j = \frac{y_j}{\sum_{i \in \mathcal{S}} y_i}, j \in \mathcal{S}$$

alakban.

Ha  $\sum_{i \in \mathcal{S}} y_i = \infty$ , akkor *nem létezik* stacionárius eloszlás.

**5. példa.** Legyen adott egy Markov-folyamat az  $\mathcal{S} = \{0, 1, \dots\}$  állapottéren a következő rátákkal

$$\lambda_{i,i+1} = \lambda_i, \lambda_{i,i-1} = \mu_i, \text{ ha } i \geq 1$$

és  $\lambda_{01} = \lambda_0$ .

Ahhoz, hogy meghatározzuk a stacionárius eloszlást először fel kell írunk a generátor mátrixot,  $A$ -t. Az előző fejezet alapján

$$A_{i,i+1} = \lambda_i, A_{i,i-1} = \mu_i, i \neq j, \quad A_{ii} = -(\lambda_i + \mu_i); i \in \mathcal{S}.$$

A ?? példához hasonlóan felírható, hogy

$$\begin{aligned} -\lambda_0 y_0 + \mu_1 y_1 &= 0 \\ \lambda_{i-1} y_{i-2} - (\lambda_i + \mu_i) y_i + \mu_{i+1} y_{i+1} &= 0 \text{ if } i \geq 1 \end{aligned}$$

A megoldás is hasonló, egy rekurziót kapunk az  $y_i$ -kre:

$$y_{i+1} = \frac{\lambda_0 \lambda_1 \dots \lambda_i}{\mu_1 \mu_2 \dots \mu_{i+1}} y_0, i \geq 0.$$

Létezik stacionárius eloszlás pontosan akkor, ha

$$\sum_{i=0}^{\infty} \frac{\lambda_0 \lambda_1 \dots \lambda_i}{\mu_1 \mu_2 \dots \mu_{i+1}} < \infty.$$

Ekkor a  $\underline{\pi}$  stacionárius eloszlás a

$$\pi_{i+1} = \frac{\lambda_0 \lambda_1 \dots \lambda_i}{\mu_1 \mu_2 \dots \mu_{i+1}} \pi_0, i \geq 0.$$

alakban írható.

**6. példa.** Az előző példa alapján az  $M/M/1$  rendszer esetén pontosan akkor létezik stacionárius eloszlás, ha

$$\sum_{i=0}^{\infty} \left(\frac{\lambda}{\mu}\right)^{i+1} < \infty$$

ami akkor teljesül, ha

$$\frac{\lambda}{\mu} < 1.$$

Ekkor a stacionárius eloszlás

$$\pi_i = \left(\frac{\lambda}{\mu}\right)^i \left(1 - \frac{\lambda}{\mu}\right) i = 0, 1, \dots$$

alakú, azaz megegyezik egy  $1 - \frac{\lambda}{\mu}$  paraméterű geometriai eloszlással.

**7. példa.** Feladat: Számoljuk ki a stacionárius eloszlást a korábban megadott további példák esetében.

## 5. Ergod tétel folytonos idejű Markov-lánckra

Legyen  $X(t), t \geq 0$  egy folytonos idejű Markov-lánc  $\mathcal{S}$  állapotterrel. Továbbá, adott egy valós értékű  $f$  költségráta függvény az állapotokon értelmezve:

$$f : \mathcal{S} \rightarrow \mathbb{R}$$

A "ráta" azt jelenti, hogy ha  $t$  ideig marad az  $i$  állapotban a folyamat, akkor ennek költsége  $f(i)t$ . Ez alapján a  $t$  hosszú futás költsége

$$\int_0^t f(X(s)) ds.$$

Ekkor egy időegységer jutó átlagos költség

$$\frac{\int_0^t f(X(s)) ds}{t}.$$

Arra vagyunk kíváncsiak, hogyha a Markov-lánccot végtelen sokáig futtatjuk, akkor mi lesz az egy lépésre jutó költség, vagy másként a *hosszútávú átlagos költség*:

$$\lim_{t \rightarrow \infty} \frac{\int_0^t f(X(s)) ds}{t}.$$

A diszkrét esethez teljesen hasonló tétel mondható ki a kérdés megválaszolására.

**3. tétel.** Legyen  $X(t), t \geq 0$  egy irreducibilis, visszatérő folytonos idejű Markov-lánc, amelynek létezik stacionárius eloszlása,  $\pi$ . Továbbá legyen adott egy  $f : \mathcal{S} \rightarrow \mathbb{R}$  költségráta függvény úgy, hogy a stacionárius eloszlás szerinti átlaga véges,

$$\sum_{i \in \mathcal{S}} f(i)\pi_i < \infty.$$

Ekkor a hosszútávú átlagos költség egyszerűen számolható,

$$\lim_{t \rightarrow \infty} \frac{\int_0^t f(X(s)) ds}{t} = \sum_{i \in \mathcal{S}} f(i)\pi_i.$$

**8. példa.** Tekintsük a 1. példában definiált Markov-lánccot az  $f(i) = ci, i = 0, 1, 2, \dots$  költségráta függvénnyel. Számoljuk ki, hogy hosszú távon mennyi az időegységre jutó átlagos költség. Az előző tétel szerint ehhez meg kell határoznunk a stacionárius eloszlást. Ezt a 6. példában megtettük. Tehát a működés költsége:

$$\sum_{i=0}^{\infty} ci \left(\frac{\lambda}{\mu}\right)^i \left(1 - \frac{\lambda}{\mu}\right) = c \frac{\lambda}{\mu} \sum_{i=0}^{\infty} i \left(\frac{\lambda}{\mu}\right)^{i-1} \left(1 - \frac{\lambda}{\mu}\right) = c \frac{\lambda}{\mu} \frac{1}{1 - \frac{\lambda}{\mu}} = c \frac{\mu}{\mu - \lambda}.$$