

EÖTVÖS LORÁND TUDOMÁNYEGYETEM
TERMÉSZETTUDOMÁNYI KAR

ELÉRÉSI IDŐK TABU MARKOV-LÁNCOK ESETÉN

BSc Szakdolgozat

Készítette: Osváth Tibor Attila
Matematika BSc, Matematikai elemző szakirány

Témavezető: Pröhle Tamás
Eötvös Loránd Tudományegyetem, Természettudományi Kar
Valószínűségelméleti és Statisztika Tanszék



Budapest, 2020.

NYILATKOZAT

Név: Osváth Tibor Attila

ELTE Természettudományi Kar, szak: matematika alapszak

NEPTUN azonosító: JXX096

Szakedolgozat címe:

Elérési idők tabu Markov-láncok esetén

A **szakedolgozat** szerzőjeként fegyelmi felelősségem tudatában kijelentem, hogy a dolgozatom önálló szellemi alkotásom, abban a hivatkozások és idézések standard szabályait következetesen alkalmaztam, mások által írt részeket a megfelelő idézés nélkül nem használtam fel.

Budapest, 2020.05.29



a hallgató aláírása

Köszönetnyilvánítás

Szeretnék köszönetet mondani témavezetőmnek Pröhle Tamásnak, aki mindenben segített, és mindig számíthattam a segítségére. Szeretném még megköszönni családomnak, a töretlen támogatásukat, és a végtelen türelmüket, amivel hozzám viszonyultak.

Tartalomjegyzék

Bevezetés	5
1. A Markov-láncokról általánosságban	6
1.1. Az állapotok osztályozása	7
2. A markovchain csomag	9
2.1. S4 osztály	9
2.2. committorAB	11
2.3. Egyéb módszerek	13
3. Tabu valószínűségek	19
3.1. Elérési valószínűségek	25
3.1.1. Egy állapothalmaz elérésének a valószínűsége	25
3.1.2. Elérési valószínűség kikerülési feltétellel	27
4. Átjáró	29
4.1. Fix nyelőkkel	29
4.2. Aszimptotikus vizsgálat	32
4.2.1. Adott arányú tábla	35
4.2.2. Négyzetes átjáró osztópontokkal	38
4.3. Fix átjáró különböző helyzetű nyelőkkel	41
5. Függelék	44
5.1. Átjáró fix nyelőkkel	44
5.2. Aszimptotikus vizsgálat	47
5.2.1. Adott arányú tábla	48
5.2.2. Négyzetes átjáró osztópontokkal	48
5.3. Fix átjáró különböző helyzetű nyelőkkel	49

Bevezetés

A matematikában a Markov-lánc egy olyan diszkrét sztochasztikus folyamatot jelent, amely Markov-tulajdonságú. Nevét Andrej Markovról kapta, aki hírnevét a sztochasztikus folyamatokban végzett kutatásainak köszönheti. Markov-tulajdonság azt jelenti, hogy a jelen állapot mellett a jövőbeli állapot nem függ a múltbeli állapotoktól. Semmilyen múltban történő esemény, nem hat, nem ad előrejelzést a jövőre nézve.

Egy egyszerű példa erre a következő. Ketten játszanak egy kockával. Mindenki addig dobhat míg 6-ost nem dob. Ha valaki 6-ost dob, akkor át kell adnia a kockát a másiknak. Azt vizsgáljuk, hogy a k . dobás után kinél van a kocka: A-nál vagy B-nél. Ez egy 2 állapotú Markov-lánc. Az, hogy a $k + 1$. lépés után kinél van a kocka, ha tudjuk, hogy a k . lépés után kinél volt, nem függ attól, hogy kinél volt a $(k - 1)$., $(k - 2)$., $(k - 3)$., ... 0. dobás után. Másként mondva, az, hogy kinél lesz a kocka a következő dobás után, csak attól függ, hogy most kinél van, és hogy ő 6-ost dob-e vagy sem.

A matematika ezen ágát számos más tudomány is alkalmazza. A Markovi rendszerek jelentős részei a fizikának, különösképp a statisztikus mechanikának. A gazdaságban a dinamikus makroökonómiának is nélkülözhetetlen része. A Markov-láncokat használhatjuk a statisztika egyes folyamatainak modellezésére is.

Az egyik legismertebb alkalmazása a társasjátékokhoz köthető. Az ismert gyerekjáték, a „Kígyók és létrák” is megközelíthető a Markov-láncok felől. Minden egyes körnél a játékos egy meghatározott mezőn áll (adott állapotban van) és megvannak a rögzített valószínűségek (mit dob a kockával) a következő lehetséges mezőre (állapotba) jutáshoz.

A szakdolgozatom első részében a Markov-lánc fogalmát fogom definiálni és az alapvető definíciókat fogom kimondani ezzel kapcsolatban (elérhetőség, visszatérőség stb.).

A második részben a `markovchain` csomag alapjait fogom bemutatni, továbbá megnézem azokat a függvényeket amik a várható elérési idővel kapcsolatban állnak.

A harmadik részben bevezetem a tabu valószínűségek fogalmát. Az első felében kimondok vele kapcsolatos definíciókat és tételeket, majd a második felében egy másik irányból, rekurzióval közelítem meg az elérési valószínűségeket.

Végül a negyedik részben a tabu Markov-láncok segítségével szimulálok különböző átjárókat és értelmezem a kapott eredményeket.

1. A Markov-láncokról általánosságban

Legyen az $x(t) \equiv x_t$, $t = 0, 1, \dots$ Markov lánc lehetséges állapotainak (az x_t lehetséges értékeinek) a halmaza az $S = \{0, 1, 2, \dots, n\}$ véges vagy $S = \{0, 1, 2, \dots\}$ megszámlálhatóan végtelen diszkrét halmaz.

A fejezethez a [2], [5], [6] forrásokat használtam.

1. Definíció. S értékű véges (vagy megszámlálhatóan végtelen) sok értéket felvevő x_0, x_1, x_2, \dots valószínűségi változók sorozatát **Markov-láncnak** nevezzük, ha a valószínűségi változók között a következő összefüggés fennáll. Minden x_{t+1}, x_t, \dots valószínűségi változó minden lehetséges $i_{t+1}, i_t, \dots \in S$ értékére teljesül, hogy

$$\mathbb{P}(x_{t+1} = i_{t+1} | x_t = i_t, x_{t-1} = i_{t-1}, \dots, x_0 = i_0) = \mathbb{P}(x_{t+1} = i_{t+1} | x_t = i_t)$$

Ez a definíció egyaránt érvényes véges és végtelen állapotterület esetén. Mi a továbbiakban csak véges állapotterű Markov folyamatokkal foglalkozunk. A Markov-tulajdonság értelmezhető folytonos időben is, azaz, ha $t \in \mathbb{R}^+$ vagy \mathbb{R} . Viszont az előző definíció csak a diszkrét idejű Markov-láncokra igaz. Mi a továbbiakban csak véges állapotterű, diszkrét idejű Markov folyamatokkal foglalkozunk, amelyeket röviden Markov-láncoknak nevezünk.

A Markov-lánc időben *homogén*, ha

$$\mathbb{P}(x_{t+1} = i_{t+1} | x_t = i_t) = P(x_1 = i_{t+1} | x_0 = i_t) \quad \forall t \geq 0,$$

és minden lehetséges i_{t+1} és i_t esetén. Azaz, ha az átmenetvalószínűségek a t időponttól függetlenek.

Esetünkben $S = \{1, 2, \dots, n\}$. Jelölje az $n \times n$ méretű \mathbf{P} mátrix a Markov lánc átmenet mátrixát. Azaz ha a \mathbf{P} mátrix i . sor j . eleme p_{ij} akkor tetszőleges $t = 0, 1, \dots$ időpontra legyen

$$p_{i,j} = \mathbb{P}(x_{t+1} = j | x_t = i)$$

A Markov-tulajdonság azt jelenti, hogy ha az x_t eloszlását az n elemű q vektor adja meg, akkor az x_{t+1} eloszlása a $j = 1, 2, \dots, n$ lehetséges értékekre:

$$\mathbb{P}(x_{t+1} = j) = \sum_{i=1}^n \mathbb{P}(x_{t+1} = j | x_t = i) \mathbb{P}(x_t = i) = (q^T \cdot \mathbf{P})_j$$

A \mathbf{P} mátrix neve átmenet-valószínűségmátrix vagy egylépéses átmenet-valószínűségmátrix. Ennek az n -edik hatványa:

$$\mathbf{P}^n = p_{i,j}^{(n)}$$

ahol

$$p_{i,j}^{(n)} = \mathbb{P}(x_{t+n} = j | x_t = i)$$

Ez a kapcsolat teszi lehetővé azt, hogy a Markov-láncok vizsgálatára fel tudjuk használni pl. a mátrix hatványozást.

1.1. Az állapotok osztályozása

Elérhetőség

2. Definíció. Azt mondjuk, hogy az i állapotból a j elérhető ($i \rightarrow j$) ha van olyan $n \geq 0$, amelyre $P_{ij}^{(n)} > 0$. Ez reflexív ($P_{ii}^{(0)} = 0$) és tranzitív (Chapman-Kolmogorov egyenlet)

1. Állítás. Legyenek $p_{ij}^{(n)} = P(X_{n+m} = j | X_m = i)$ az n -edrendű átmenetvalószínűségek. Legyen i egy olyan állapot, amelyre $P(X_m = i) > 0$. Ekkor teljesül a Chapman-Kolmogorov egyenlet:

$$p_{ik}^{(n+m)} = \sum_{j \in S} p_{ij}^{(n)} p_{jk}^{(m)}$$

Bizonyítás.

$$P(X_{n+m} = k | X_0 = i) \stackrel{(1)}{=} \sum_{j \in S} P(X_{n+m} = k, X_n = j | X_0 = i) \stackrel{(2)}{=}$$

$$\stackrel{(2)}{=} \sum_{j \in S} P(X_{n+m} = k | X_n = j, X_0 = i) P(X_n = j | X_0 = i) \stackrel{(3)}{=} \sum_{j \in S} p_{jk}^{(m)} p_{ij}^{(n)}$$

1. Megjegyzés. (1) teljes valószínűség tétele miatt érvényes.

(2) ekvivalens átalakítás.

(3) Markov-tulajdonság miatt teljesül.

□

3. Definíció. Azt mondjuk, hogy i és j közlekednek ha $i \rightarrow j$ és $j \rightarrow i$. Ez ekvivalenciareláció, tehát osztályokra bontja az állapotteret (csak az átmenetmátrixtól függ). A Markov-lánc irreducibilis, ha az állapottere egyetlen osztályból áll.

4. Definíció. Az i állapot lényeges, ha $i \rightarrow j$ esetén $j \rightarrow i$ is teljesül.

Az állapotokra értelmezett valamely tulajdonság osztálytulajdonság, ha egy osztálynak vagy minden eleme ilyen tulajdonságú, vagy egy sem.

5. Definíció. Az $\{n \geq 0, P_{ii}^{(n)} > 0\}$ halmaz legnagyobb közös osztója az i periódusa, jele: $d(i)$. Ha $d(i) = 1$ akkor az állapot aperiodikus.

2. Állítás. Egy osztály minden állapotának ugyanannyi a periódusa.

Bizonyítás. Legyenek $k, l \in C$ azonos osztálybeliek. Ekkor létezik n, m amelyekre teljesül, hogy $P_{kl}^{(n)} > 0$ és $P_{lk}^{(m)} > 0$. Ebből a kettőből következik, hogy $P_{kk}^{(n+m)} > 0$. Ha valamely s -re $P_{kk}^{(s)} > 0$, akkor ezek alapján $P_{kk}^{(n+m+s)} > 0$. Emiatt $d(k)|(n+m)$ és $d(k)|(n+m+s)$ az oszthatóság szabályai miatt, pedig a kettő különbségét $d(k)|s$ is osztja. Tehát $d(k)$ közös osztója az ilyen s számoknak azaz $d(k)|d(l)$. Mivel k és l szerepe felcserélhető, az állítást beláttuk. \square

Visszatérőség

Legyen $f_{ij}^{(0)} = 0$, $f_{ij}^{(n)} = \mathbb{P}(X_n = j, X_k \neq j : k = 1, 2, \dots, n-1 | X_0 = i)$, $n \geq 1$

Ez annak a valószínűsége, hogy az i állapotból indulva a lánc először az n -edik lépésben ér el a j állapotba. Legyen $f_{ij}^* = \sum_{n=1}^{\infty} f_{ij}^{(n)}$ ez azt jelenti, hogy az i állapotból indulva a lánc előbb-utóbb elér a j állapotba.

6. Definíció. Az i állapot visszatérő (vagy rekurrens), ha $f_{ii}^* = 1$, egyébként pedig átmeneti vagy tranziens.

2. A markovchain csomag

A szakdolgozatom elkészítéséhez hozzátartozik egy programozási feladat, amit az R programnyelvben implementáltam. Ahhoz, hogy meg tudjunk ismerkedni a programmal, először nézzük meg a `markovchain` csomagot. A `markovchain` csomagot Giorgio Alfredo Spedicato hozta létre 2016-ban. A célja, hogy a benne található függvények segítségével könnyebben tudjuk kezelni a diszkrét Markov-láncokat.

Forrásként leginkább [3], [4] eredményeire támaszkodtam.

2.1. S4 osztály

Az S4 osztályt a `setClass()` függvény határozza meg. Az objektumok komponenseit slotoknak nevezzük. Az osztály meghatározásakor be kell állítanunk a nevét és a slotokat (a slot osztályával együtt). Egy egyszerű példán bemutatjuk, az S4 osztályok kezelési módját.

```
setClass("tanulo",
slots=list(nev="character", eletkor="numeric", atlag="numeric"))
s <- new("tanulo",nev="Tibor", eletkor=22, atlag=4)
s
An object of class "tanulo"
Slot "nev":
# "Tibor"
Slot "eletkor":
# 22
Slot "atlag":
# 4
isS4(s)
#TRUE
s@nev
# "Tibor"
s@eletkor
```

```
# 22
s@atlag
# 4
```

Itt definiáltunk egy új osztályt annak bemutatására, hogy hogyan működik az objektumorientált környezetben az osztály-metódus pár. Az osztály neve `tanulo`, és 3 slotja van, aminek a nevei a következők: `nev`, `eletkor`, `atlag`. Az S4-es objektumokat a `new()` függvénnyel hozhatunk létre. Azt, hogy egy objektum tényleg S4-es objektum az `isS4()` függvénnyel ellenőrizhetjük. Csakúgy, mint egy lista összetevőjéhez a dollárjel használatával lehet hozzáférni, az objektum egy slotjához a `@` jellel lehet hozzáférni.

```
s@nev<-"Attila"
s
An object of class "tanulo"
Slot "nev":
# "Attila"
Slot "eletkor":
# 22
Slot "atlag":
# 4
```

Egy slot módosítását direkt módon is el lehet végezni. Itt a `nevet` módosítottam Attilára. Ekkor a többi slot értéke változatlan maradt.

```
a<-1
a
# 1
class(a)<-"Tibi"
a
# 1
attr("class")
# "Tibi"
print.Tibi<-function(u){cat("Tibi rendes diák" )}
```

```

print.Tibi
function(u){cat("Tibi rendes diák" )}
a
Tibi rendes diák> class(a)<-NULL
a
# 1

```

Ezen felül saját módszereket is könnyedén írhatunk. Ebben az esetben `print.Tibi` a `print` függvénynek egy módszere lett. Eredetileg `a`-t egynek inicializáljuk az osztályát pedig `"Tibi"`-nek állítjuk be. A `print.Tibi` függvény meghívásakor a `"Tibi rendes diák"` szöveg íratódik ki. Mivel az `a`-nak osztálya `Tibi` ezért a értéke kiíratáskor a `print.Tibi` függvény lesz, de ha `a` osztályát megszüntetjük akkor `a`-nak az eredeti értékét fogja kiírni ami `1`.

2.2. committorAB

Az elérési valószínűségeket `committor` valószínűségeknek nevezik, ebből jön a függvény neve: `committorAB`. A függvény arra jó, hogy ha egy példát már kézzel kiszámoltunk, akkor a segítségével már könnyen tudjuk ellenőrizni az eredmény helyességét. A `committorAB` függvény azt a valószínűséget fogja visszaadni, hogy a folyamat hamarabb ér el egy állapotot az `A` halmazból, mint a `B` halmaz bármely állapotát.

A függvény 4 paraméterrel rendelkezik: `committorAB(Mátrix,A,B,p)`

Paraméterek

Mátrix	egy <code>markovchain</code> osztály objektum
A	állapotok egy halmaza
B	állapotok egy halmaza
p	kezdeti állapot (alapból a program 1-nek veszi)


A függvény megold egy lineáris algebrai egyenletrendszer (az egyenletrendszer formájáról később lesz szó), amivel kiszámolja, hogy a folyamat hamarabb elér egy valamilyen `A`-beli állapotot, mint hogy elérné bármelyik `B`-belit. Ha a kezdeti állapot nincs feltüntetve, akkor egy vektort ad vissza a valószínűségekkel, ha pedig fel van tüntetve akkor egy számot. Egy konkrét példán ez könnyebben szemléltethető.

```

Mátrix <- matrix(c(0,0,0,1,0.5,
                  0.5,0,0,0,0,
                  0.5,0,0,0,0,
                  0,0.2,0.4,0,0,
                  0,0.8,0.6,0,0.5),
                nrow = 5)

MC <- new("markovchain", states=c("a","b","c","d","e"),transitionMatrix=Mátrix)
plot(MC)
committorAB(MC,c(5),c(3))

```



Először feltöltjük a *Mátrix*-ot, amiből a program egy 5x5-ös mátrixot csinál, `nrow=5` parancs segítségével a program soronként tölti fel a beadott adatokkal. Majd létrehozunk egy új *MC* objektumot aminek az osztálya `markovchain`, állapotai az "a", "b", "c", "d", "e" állapotok, továbbá az átmenet-valószínűségmátrix lesz az előbb létrehozott *Mátrix*. A függvény meghívásakor az A halmaz az 5-ös állapotból áll, a B halmaz pedig a 3-as állapotból, kezdeti értéket most nem adtunk meg. A *Mátrix* gráfos reprezentációja a szöveg

fölött található.

```
      a      b      c      d      e
0.4444444 0.8888889 0.0000000 0.4444444 1.0000000
```

Mit is jelent akkor a végeredmény?

A célállapotunk ebben az esetben az "e" állapot, a tabu állapotunk pedig a "c" állapot. Tehát pl. annak a valószínűsége, hogy a "c" állapotból hamarabb elérjük az "e" állapotot, mint a "c"-t nyilvánvalóan 0 lesz, mivel a kezdeti állapotunk a "c" volt. Nézzük meg a másik triviális esetet. A megoldásvektor 5. eleme azt adja meg, hogy az "e" állapotból indulva mennyi a valószínűsége annak, hogy a folyamat hamarabb éri el az "e" állapotot, mint a "c"-t. Ez nyilván 1 lesz mivel, a folyamatot az 5-ös állapotból indítottuk. A többi állapot esetén lesz "érdekes" a kapott valószínűség. Az "a" állapotból $\frac{4}{11}$ a valószínűsége annak, hogy az "e" állapotot hamarabb elérjük, mint a "c"-t. Ezt hasonlóan látjuk a "b" és "d" állapotra is amire rendre $\frac{8}{11}$ és $\frac{4}{11}$ lesz a keresett valószínűség.

2.3. Egyéb módszerek

Ebben az alfejezetben a `markovchain` csomag pár módszerét fogom ismertetni.

- `meanFirstPassageTime(mc, cel)`

A függvény 2 paraméterrel rendelkezik:

Paraméterek

`mc` egy `markovchain` objektum


`cel` célállapotok (alapból üres)

Egy ergodik Markov-lánc esetén a következőt számolja ki:

- Ha a végcél üres akkor egy olyan mátrixot ad ki, ami az összes (i, j) párra kiszámolja a várható elérési időt, ahol i a kezdőállapot és j a végállapot, m állapot esetén a mátrix mérete $m * m$
- Ha a végcél nem üres, akkor a várható elérési időt adja ki a célállapotba többi állapotból. Ha összesen m állapotunk van akkor egy $(m - 1)$ hosszú vektort ad vissza.

Példa: Vegyük a következő Markov-láncot:

$$P_{ij} = \begin{pmatrix} \frac{2}{6} & \frac{3}{6} & \frac{1}{6} \\ \frac{3}{6} & 0 & \frac{3}{6} \\ 0 & \frac{3}{6} & \frac{3}{6} \end{pmatrix}$$



```
mc <- new("markovchain", states = c("1","2","3"),
transitionMatrix = m)
meanFirstPassageTime(mc,"3")
# 1 2
3.6 2.8
```

A program a 3-as állapotba számolja ki az elérési időket az 1-es és 2-es állapotokból. Legyen $\{\phi(i) = i \ (i = 1, 2, 3)$ állapotból a 3-as állapot első elérési ideje}. Ekkor a következő egyenletrendszert kell majd megoldanunk:

$$\begin{aligned}\phi(1) &= 1 + \frac{2}{6}\phi(1) + \frac{3}{6}\phi(2) + \frac{1}{6}\phi(3) \\ \phi(2) &= 1 + \frac{3}{6}\phi(1) + \frac{3}{6}\phi(3) \\ \phi(3) &= 0\end{aligned}$$

Ebból

$$\begin{aligned}\frac{4}{6}\phi(1) &= 1 + \frac{3}{6}\phi(2) \\ \phi(2) &= 1 + \frac{3}{6}\phi(1)\end{aligned}$$

Amiből egyértelműen látszik, hogy a megoldása $\phi(1) = \frac{18}{5}$ és $\phi(2) = \frac{14}{5}$ tehát a kézzel kiszámolt eredmény megegyezik az R által számolt eredménnyel.

- `meanRecurrenceTime(mc)`

Várható visszatérési idő. Bemenetként egy Markov-láncot vár, a kimenete pedig egy vektor lesz, amiben a rekurrens állapotok fognak szerepelni. Ha a Markov-lánc ergodikus (irreducibilis), akkor az összes állapot benne lesz a vektorban az eredeti sorrendben (mivel ugye minden állapot rekurrens). Azt számolja ki, hogy mennyi a várható ideje annak, hogy egy rekurrens állapotból indulva először visszatérünk ugyanabba a rekurrens állapotba. Ez viszonylag közel áll a várható elérési időhöz, ezért az előző példán fogom szemléltetni a kiszámítását.

Jelölje t_j^* az első visszatérési időt a j állapotra.

```
meanFirstPassageTime (mc)
```

```
# 1 2 3
```

```
1 0 2 3.6
```

```
2 4 0 2.8
```

```
3 6 2 0.0
```

```
meanRecurrenceTime(mc)
```

```
# 1 2 3
```

```
4.0 3.0 2.4
```

Az előző példához képest most annyi változtatás történt, hogy a várható elérési idő függvény esetében nincs célpont megadva, ezért outputként egy mátrixot kapunk. A mátrix i . sorának j . eleme azt fogja jelenti, hogy az i állapotból indulva várhatóan a j állapotba hány lépésben jutunk el. A mátrix i . sorának j . elemét jelölje m_{ij} .

Ekkor a következő egyenletrendszer tudjuk felírni:

$$t_1^* = 1 + \sum_{j=1}^3 p_{1j} m_{j1} = 1 + \frac{2}{6} * 0 + \frac{3}{6} * 4 + \frac{1}{6} * 6 = 4$$

$$t_2^* = 1 + \sum_{j=1}^3 p_{2j} m_{j2} = 1 + \frac{3}{6} * 2 + 0 * 0 + \frac{3}{6} * 2 = 3$$

$$t_3^* = 1 + \sum_{j=1}^3 p_{3j} m_{j3} = 1 + 0 * 3.6 + \frac{3}{6} * 2.8 + \frac{3}{6} * 0 = 2.4$$

Az első egyenlet pontosan azt jelenti, hogy egyet lép a folyamat egy valamilyen j majd a j állapotból várhatóan m_{j1} lépésben fog visszatérni az 1-es állapotba. A másik kettő egyenlet ugyanaz csak a 2 és 3 állapotra alkalmazva az előzőt.


Tehát megkaptuk a program által kiszámolt értékeket.

- meanAbsorptionTime(mc)

Várható elnyelési idő. A függvény a Markov-láncot várja bemeneti paraméternek. Megadja, hogy egy tranzien állapotból várhatóan hány lépésben jutunk el valamilyen rekurrens állapotba.

Példa: Vegyük a következő Markov-láncot

$$P_{ij} = \begin{pmatrix} \frac{1}{2} & \frac{1}{2} & 0 \\ \frac{1}{2} & \frac{1}{2} & 0 \\ 0 & \frac{1}{2} & \frac{1}{2} \end{pmatrix}$$



```

recurrentStates(mc)
# "1" "2"

transientStates(mc)
# "3"

meanAbsorptionTime(mc)
# 3
  2

```

Tehát a rekurrens állapotok az 1 és 2 és egy tranzienst is tartalmaz a 3. Könnyedén látszik, hogy a 3 tranzienst is tartalmaz, mivel az 1, 2 állapotból nem vezet irányított él 3-ba. Tehát kevesebb, mint 1 valószínűséggel lesz visszatérő, mivel ha már $3 \rightarrow 2$ -be átmegy, már nem fog tudni visszatérni. $\{\phi(i) = i \ (i = 1, 2, 3)$ állapotból várhatóan hány lépés alatt jut el egy tranzienst is tartalmazó állapotba}.

Ekkor a következő egyenletrendszert kell megoldanunk:

$$\phi(3) = 1 + \frac{1}{2}\phi(3) + \frac{1}{2}\phi(2)$$

$$\phi(2) = 0$$

$$\phi(1) = 0$$

Ennek hasonlóan $\phi(3) = 2$ az eredménye, mint a program esetén, vagyis várhatóan 2 lépés alatt jutunk el egy tranziens állapotból egy rekurrens állapotba.

3. Tabu valószínűségek

Ahhoz, hogy mélyebben megértsük a Markov-láncokat, most bevezetjük az átmenetvalószínűségek fogalmát tabu állapotokkal. Legyen H egy tetszőleges halmaz.

Forrásként az [1]-et fogom használni.

7. Definíció. $HP_{ij}^{(n)} = \mathbb{P}\{X_n(\omega) = j; X_\mu(\omega) \notin H, 0 < \mu < n \mid X_0(\omega) = i\}$, $n \geq 1$.

Ez szavakkal kifejezve azt jelenti, hogy az i állapotból elindulva n lépés múlva eljutunk a j állapotba, úgy, hogy közben a folyamat sohasem volt a H egyik állapotában sem (végpontokat kivéve), vagy máshogy: a folyamat végig az $(I-H)$ halmazon belül marad. H lesz a tabu halmazunk, és a benne levő állapotok a tabu állapotok. H lehet üres, ez esetben a jelölésből kihagyjuk. Ha H egyetlen egy k állapotból áll, akkor jelöljük a valószínűséget $kP_{ij}^{(n)}$ -nel. Ha a taboo halmaz a H halmaz és a k uniójából áll, akkor a következő valószínűséget jelöljük $\{k, H\}P_{ij}^{(n)}$ -nel.

Legyen $HP_{ij}^{(0)} = \delta_{ij}$, ha $i \notin H$; $= 0$, ha $i \in H$.

8. Definíció. $HP_{ij}^* = \sum_{n=1}^{\infty} HP_{ij}^{(n)}$; mely azt adja meg, hogy i -ből indulva, várhatóan hány-szor jár a lánc j -ben, míg H -ba beér (a beérést is beszámítva).

Ha a sorozat divergens akkor az értéke ∞ lesz. Ez persze azon várható alkalmak száma, hogy a Markov-lánc i -ből indulva hamarabb éri el a j állapotot, mint a H valamelyik állapotát. A ∞ -re vonatkozó szokásos konvenciókat ugyanúgy alkalmazhatjuk, így

$$c + \infty = \infty, \quad |c| \cdot \infty = \infty, \quad \frac{c}{\infty} = 0, \quad \frac{\infty}{|c|} = \infty, \quad \frac{\infty}{-\infty} = -\infty$$

ahol $c \neq 0$ véges konstans;

$$\infty \cdot \infty = \infty, \quad 0 \cdot \infty = 0;$$

de a $\infty - \infty$ vagy a $\frac{\infty}{\infty}$ tiltott művelet.

Most meg fogunk adni 2 formulát, ami a kiindulópontja lesz az összes tételnek.

1. Tétel. (Általános dekompozíciós formulák) Ha $n \geq 1$ és $k \notin H$, akkor

$$HP_{ij}^{(n)} = \{k, H\}P_{ij}^{(n)} + \sum_{\nu=1}^{n-1} \{k, H\}P_{ik}^{(\nu)} HP_{kj}^{(n-\nu)}; \quad (1)$$

$$HP_{ij}^{(n)} = \{k, H\}P_{ij}^{(n)} + \sum_{\nu=1}^{n-1} HP_{ik}^{(\nu)} \{k, H\}P_{kj}^{(n-\nu)}. \quad (2)$$

Bizonyítás. Az első tagja az összegnek mindkét esetben azt jelenti, hogy a k állapot sosincs érintve mialatt a folyamat i -ből j -be megy n lépés alatt. Első esetben a szumma pedig azt a valószínűséget jelenti, hogy a k állapot először a ν . lépésben van érintve az átmenet közben, a második esetben pedig azt mutatja hogy a k állapot utoljára a ν . lépésben van érintve az átmenet közben. \square

2. Következmény. Ha $k \notin H$, akkor

$$HP_{ij}^* = \{k, H\}P_{ij}^* + \{k, H\}P_{ik}^* HP_{kj}^*; \quad (3)$$

$$HP_{ij}^* = \{k, H\}P_{ij}^* + HP_{ik}^* \{k, H\}P_{kj}^*; \quad (4)$$

Bizonyítás. Használjuk fel az előző dekompozíciós formulákat és szumázzuk őket $n = 1$ -től $n = N$ -ig

$$\sum_{n=1}^N HP_{ij}^{(n)} = \sum_{n=1}^N \{k, H\}P_{ij}^{(n)} + \sum_{\nu=1}^{N-1} \{k, H\}P_{ik}^{(\nu)} \sum_{n=1}^{N-\nu} HP_{kj}^{(n)} \quad (5)$$

$$\sum_{n=1}^N HP_{ij}^{(n)} = \sum_{n=1}^N \{k, H\}P_{ij}^{(n)} + \sum_{\nu=1}^{N-1} HP_{ik}^{(\nu)} \sum_{n=1}^{N-\nu} \{k, H\}P_{kj}^{(n)} \quad (6)$$

$N \rightarrow \infty$ esetén hozzájutunk a bizonyítandó állításhoz. Konvergens vagy divergens sorozatok esetén is érvényes a bizonyítás a ∞ -re vonatkozó konvenciók alapján. \square

3. Tétel. A 3 mennyiség:

$$HP_{ij}^*, \quad \{j, H\}P_{ij}^*, \quad \{i, H\}P_{ij}^*$$

mindegyike vagy pozitív(esetleg ∞) vagy 0.

Bizonyítás. Ha $j \notin H$ akkor vegyük $k = j$ -t (3)-ban, ez alapján:

$$HP_{ij}^* = \{j, H\}P_{ij}^* + \{j, H\}P_{ij}^* HP_{jj}^* = \{j, H\}P_{ij}^* (1 + HP_{jj}^*). \quad (7)$$

Ha $j \in H$ akkor $HP_{ij}^* = \{j, H\}P_{ij}^*$. Ennélfogva, ha az egyik 0, úgy a másik is 0 lesz. Hasonlóan, ha $i \notin H$, akkor vegyük $k = i$ -t a (4) -ben és így kapjuk:

$$HP_{ij}^* = \{i, H\}P_{ij}^* + HP_{ii}^* \{i, H\}P_{ij}^* = \{i, H\}P_{ij}^* (1 + HP_{ii}^*). \quad (8)$$

A többi hasonlóan következik az előzőekből. \square

9. Definíció. $j \rightsquigarrow H$ ha létezik olyan $k \in H$ amire $j \rightsquigarrow k$

4. Lemma. (Töplitz) Legyen $\{a_n, n \geq 0\}$, egy nemnegatív sorozat, $\{b_n, n \geq 0\}$ egy valós számokból álló sorozat. Ha

$$\lim_{n \rightarrow \infty} \frac{a_n}{\sum_{\nu=0}^n a_\nu} = 0$$

akkor

$$\lim_{n \rightarrow \infty} \frac{\sum_{\nu=0}^n a_\nu b_{n-\nu}}{\sum_{\nu=0}^n a_\nu} = \lim_{n \rightarrow \infty} b_n$$

5. Tétel. Ha $j \in H$ vagy $j \rightsquigarrow H$, akkor $HP_{ij}^* < \infty$.

Bizonyítás. Ha $j \in H$ akkor $HP_{ij}^{(n)} \leq j, P_{ij}^{(n)} = f_{ij}^{(n)}$. Ezért $HP_{ij}^* \leq f_{ij}^* \leq 1$. Legyen $k \in H, k \neq j$, és $j \rightsquigarrow k$ úgy, hogy $kP_{jk}^{(m)} = f_{jk}^{(m)} > 0$ valamilyen $m \geq 1$ -re. Ezek alapján

$$kP_{ij}^{(n)} kP_{jk}^{(m)} \leq kP_{ik}^{(n+m)} = f_{ik}^{(n+m)}$$

Ebből következik, hogy

$$HP_{ij}^* \leq kP_{ij}^* \leq \frac{1}{f_{jk}^{(m)}} \sum_{n=1}^{\infty} f_{ik}^{(n+m)} \leq \frac{1}{f_{jk}^{(m)}}.$$

□

Ezekből elő tudunk állítani 2 általános formulát. Osszuk le az (5)-t és a (6)-t rendre $\sum_{\nu=1}^N HP_{kj}^{(\nu)}$ -nel és $\sum_{\nu=1}^N HP_{ik}^{(\nu)}$ -nel alkalmazzuk a Töplitz-lemmát így hozzájutunk az alábbi 2 formulához.

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{\sum_{n=1}^N HP_{kj}^{(n)}} = \lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N \{k, H\} P_{ij}^{(n)}}{\sum_{n=1}^N HP_{kj}^{(n)}} + \{k, H\} P_{ik}^*; \quad (9)$$

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{\sum_{n=1}^N HP_{ik}^{(n)}} = \lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N \{k, H\} P_{ij}^{(n)}}{\sum_{n=1}^N HP_{ik}^{(n)}} + \{k, H\} P_{kj}^*; \quad (10)$$

feltéve, hogy $k \notin H$ és a limesz a jobb oldalon létezik. Ez a formula általános, de könnyen egyszerűbbé tehetjük néhány feltételezés segítségével.

10. Definíció. Azt mondjuk, hogy $i \overset{H}{\rightsquigarrow} j$, ha $HP_{ij}^* > 0$.

11. Definíció. Azt mondjuk, hogy i és j közlekedhető a H taboo halmaz alatt, ha $i \overset{H}{\rightsquigarrow} j$ és $j \overset{H}{\rightsquigarrow} i$ fennáll. Ezt $i \overset{H}{\leftrightarrow} j$ -val jelöljük.

6. Tétel. Ha $i \notin H, j \notin H$ és $i \overset{H}{\rightsquigarrow} j$, akkor

$$\lim_{N \rightarrow \infty} \frac{1 + \sum_{n=1}^N HP_{jj}^{(n)}}{1 + \sum_{n=1}^N HP_{ii}^{(n)}} = \frac{\{i, H\}P_{ij}^*}{\{j, H\}P_{ij}^*} = \lim_{N \rightarrow \infty} \frac{1 + \sum_{n=1}^N \{i, H\}P_{jj}^{(n)}}{1 + \sum_{n=1}^N \{j, H\}P_{ii}^{(n)}} \quad (11)$$

Bizonyítás. Mivel $HP_{ij}^* > 0$ és a feltevés alapján $0 < \{j, H\}P_{ij}^* < \infty$ és $\{i, H\}P_{ij}^* > 0$ a **4. Tétel** és **5. Tétel** alapján. Írjunk be $k = i$ -t a (10)-be és így a következőt kapjuk

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{\sum_{n=1}^N HP_{ii}^{(n)}} = \frac{\{i, H\}P_{ij}^*}{HP_{ii}^*} + \{i, H\}P_{ij}^* \quad (12)$$

ennek következtében

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{1 + \sum_{n=1}^N HP_{ii}^{(n)}} = \lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ii}^{(n)}}{\sum_{n=0}^N HP_{ii}^{(n)}} \left(\frac{1}{HP_{ii}^*} + 1 \right) \{i, H\}P_{ij}^* = \{i, H\}P_{ij}^* \quad (13)$$

Hasonlóan, ha $k = j$ -t írunk be a (9)-be akkor megkapjuk

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{1 + \sum_{n=1}^N HP_{jj}^{(n)}} = \{j, H\}P_{ij}^* \quad (14)$$

Mert ha $HP_{ii}^* = \infty$, akkor a limesz a jobb oldalon 1 lesz, míg ha $HP_{ii}^* < \infty$, akkor a tényezők kiesnek a zárójelen belül. Ha vesszük a (13) és (14) hányadosát, akkor az első egyenletet kapjuk meg a **6. Tétel** állításában. A tétel második egyenlőségét nem bizonyítom. \square

7. Következmény. Ha $i \notin H, j \notin H$ és $i \overset{H}{\leftrightarrow} j$ akkor

$$\lim_{N \rightarrow \infty} \frac{1 + \sum_{n=1}^N HP_{jj}^{(n)}}{1 + \sum_{n=1}^N HP_{ii}^{(n)}} = \frac{\{i, H\}P_{ij}^*}{\{j, H\}P_{ij}^*} = \frac{\{i, H\}P_{ji}^*}{\{j, H\}P_{ji}^*} = \frac{1 + \{i, H\}P_{jj}^*}{1 + \{j, H\}P_{ii}^*} = \frac{Hf_{ji}^* \{i, H\}f_{ij}^*}{Hf_{ij}^* \{j, H\}f_{ji}^*} \quad (15)$$

ahol a limesz pozitív és véges. Ezen felül ha a következő 4 állapotból i, j, k, l bármelyik kettő közlekedhető a taboo H halmaz alatt és $i \notin H, j \notin H, k \notin H, l \notin H$ vagyis egyik sincs H -ban, akkor

$$\lim_{N \rightarrow \infty} \frac{\sum_{n=1}^N HP_{ij}^{(n)}}{\sum_{n=1}^N HP_{kl}^{(n)}} \quad (16)$$

létezik és véges.

12. Definíció. $m_{ij} = \sum_{n=1}^{\infty} n f_{ij}^{(n)}$

Ez az átlagos első elérés i -ből j -be, feltéve, hogy $f_{ij}^* = 1$ (a lánc előbb-utóbb elér i -ből j -be. Ehhez a definícióhoz fog kapcsolódni a következő tétel.

8. Tétel. Ha $f_{ij}^* = 1$, akkor

$$\sum_k jP_{ik}^* = m_{ij}$$

Bizonyítás. Definíció szerint a következő érvényes:

$$\sum_k jP_{ik}^{(n)} = P\{X_\nu(\omega) \neq j \mid 0 < \nu < n \mid X_0(\omega) = i\} = \sum_{\nu=n}^{\infty} f_{ij}^{(\nu)}$$

Emiatt felírhatjuk a következőt:

$$\sum_k jP_{ik}^* \stackrel{(1)}{=} \sum_k \sum_{n=1}^{\infty} jP_{ik}^{(n)} \stackrel{(2)}{=} \sum_{n=1}^{\infty} \sum_k jP_{ik}^{(n)} \stackrel{(3)}{=} \sum_{n=1}^{\infty} \sum_{\nu=n}^{\infty} f_{ij}^{(\nu)} \stackrel{(4)}{=} \sum_{\nu=1}^{\infty} \nu f_{ij}^{(\nu)} \stackrel{(def)}{=} m_{ij}$$

2. Megjegyzés. (1) a jP_{ik}^* definíciója miatt teljesül.

(2) a nemnegatív sorozatok átrendezhetősége miatt érvényes.

(3) a bizonyítás első lépése miatt igaz.

(4) triviális.

(5) pedig m_{ij} definíciójából következik.

□

Egy másik megközelítés

Legyen az állapotok két diszjunkt részhalmaza A illetve B , az összes többi állapot legyen C . Először azt vizsgáljuk, hogy mennyi annak a valószínűsége, hogy a folyamat állapota az idő teltével úgy válik egy A -beli állapottá, hogy az előző állapotok egyike sem B -beli. Utóbb megvizsgáljuk különböző indulóállapotok mellett, annak várható időtartamát, hogy a lánc állapota A -belivé váljon a B elkerülése mellett. Megvizsgáljuk, hogyan alakulnak a mondott valószínűségek különböző egyszerű strukturájú gráfok esetén.

3.1. Elérési valószínűségek

3.1.1. Egy állapothalmaz elérésének a valószínűsége

Legyen A az S lehetséges állapotok egy tetszőleges részhalmaza. Legyen $\tau(A, k) \equiv \tau_A(k)$ az A állapothalmaz első elérésének időpontja, ha $x(0) = k$, ahol $k \in S$, azaz egy tetszőleges induló állapot. Azaz legyen

$$\tau_A(k) = \inf\{t \geq 0 : x(0) = k \text{ és } x(t) \in A\}$$

A τ lehetséges értékei $1, 2, 3, \dots$, és 0 , ha $k \in A$ és ∞ , ha az A a k -ból nem érhető el.

Alkalmazzuk a következő jelölést:

$$h(A, k) \equiv h_A(k) = \mathbb{P}(\tau_A(k) < \infty)$$

Azaz $h_A(k)$ annak a valószínűségét jelöli, hogy az A állapothalmaz a k állapotból véges idő alatt elérhető. A $h_A(k)$, $k = 1, \dots, n$ valószínűségekből alkotott n dimenziós vektort h_A fogja jelölni. A következő állítást bizonyítjuk:

9. Tétel. Elérési valószínűség

A $h_A(k)$ elérési valószínűség, $k \in S$ -re a következő egyenlet rendszer minimális megoldása:

$$\begin{aligned} \text{ha } k \in A \text{ akkor:} \quad h_A(k) &= 1 \\ \text{ha } k \notin A \text{ akkor:} \quad h_A(k) &= (\mathbf{P} \cdot h_A)(k) = \sum_{j \in S} p_{k,j} h_A(j) \end{aligned}$$

A minimalitás azt jelenti, hogy minden $k \in S$ -re $h_A(k) \leq u(k)$, ha n dimenziós u vektor a fenti egyenlet rendszer egy tetszőleges megoldása.

Bizonyítás.

Előbb belátjuk, hogy az elérési valószínűségek tényleg megoldásai a fenti egyenleteknek. A $k \in A$ eset nyilvánvaló: ha $k \in A$, akkor k -ból 1 valószínűséggel érhető el az A . Ha $k \notin A$ akkor $\tau_A(i) > 0$, emiatt érvényes a következő átalakítás sor első lépése, a következőben az

$x(t)$ Markov tulajdonságát használjuk ki:

$$\begin{aligned}
h_A(k) &= \mathbb{P}(\tau_A(k) < \infty) \\
&= \sum_{j \in S} \mathbb{P}(\tau_A(k) < \infty \text{ és } x(1) = j) \\
&= \sum_{j \in S} \mathbb{P}(\tau_A(k) < \infty \mid x(1) = j) \cdot \mathbb{P}(x(1) = j \mid x(0) = k) \\
&= \sum_{j \in S} p_{k,j} h_A(j)
\end{aligned}$$

Belátjuk, hogy a $h_A(k)$ az egyenletrendszer minimális megoldása.

Legyen $w(k)$, $k \in S$ az egyenletrendszer egy tetszőleges megoldása.

A $k \in A$ eset ismét nyilvánvaló. Ha $k \notin A$ akkor osszuk az egyenlőség szerinti szummát két részre:

$$\begin{aligned}
w(k) &= \sum_{j \in S} p_{k,j} w(j) = \sum_{j \in A} p_{k,j} w(j) + \sum_{j \in S \setminus A} p_{k,j} w(j) \\
&= \sum_{j \in A} p_{k,j} + \sum_{j \in S \setminus A} p_{k,j} w(j) \\
&= \mathbb{P}(x_1 \in A \mid x_0 = k) + \sum_{j \in S \setminus A} p_{k,j} w(j)
\end{aligned}$$

Ugyanis ha $j \in A$ akkor $w(j) = 1$. E felírás szummájában az $w(j)$ -re alkalmazzuk ugyanezt a felbontást, de felhasználva, hogy minden $j \in S$ -re

$\mathbb{P}(x_1 \in A \mid x_0 = j) = \mathbb{P}(x_2 \in A \mid x_1 = j)$:

$$\begin{aligned}
w(k) &= \mathbb{P}(x_1 \in A \mid x_0 = k) + \sum_{j \in S \setminus A} p_{k,j} \left(\mathbb{P}(x_2 \in A \mid x_1 = j) + \sum_{i \in S \setminus A} p_{j,i} w(i) \right) \\
&= \mathbb{P}(x_1 \in A \mid x_0 = k) + \sum_{j \in S \setminus A} p_{k,j} \mathbb{P}(x_2 \in A \mid x_1 = j) + \sum_{j \in S \setminus A} \sum_{i \in S \setminus A} p_{k,j} p_{j,i} w(i) \\
&= \mathbb{P}(x_1 \in A \mid x_0 = k) + \mathbb{P}(x_2 \in A, x_1 \notin A \mid x_0 = k) + \sum_{j \in S \setminus A} \sum_{i \in S \setminus A} p_{k,j} p_{j,i} w(i)
\end{aligned}$$

Mint látható, az első valószínűség annak a valószínűsége, hogy a lánc első lépésre az A -ba jut, a második pedig annak a valószínűsége, hogy a második lépés az első, amikor a lánc egy A -beli állapotba kerül. A dupla szumma pedig, az $w(i)$ tényező nélkül annak a valószínűsége, hogy a lánc állapota sem az első sem a második lépésre nem jut az A állapothalmazba.

Az így nyert kifejezés harmadik tagjában megismételhetjük a helyettesítést. Így az $w(k)$ egy olyan négy tagú felbontását nyerjük, amely a lánc 3 egymás utáni lépésének lehetséges eredményei szerinti. Ha a helyettesítést n -szer megismételjük, akkor egy olyan $n+1$ tagú felbontást kapunk, ahol az első n tag rendre annak a valószínűsége, hogy a lánc $1, 2, \dots, n$ lépés után ér először A -ba. Mivel a helyettesítést akárhányszor megtehetjük, és az utolsó tag mindig nemnegatív, adódik, hogy $w_A(k) \geq h_A(k)$ ami az állást bizonyítja. \square

3.1.2. Elérési valószínűség kikerülési feltétellel

Legyen A és a B az S lehetséges állapotok két diszjunkt részhalmaza. Azt vizsgáljuk, mennyi az A elérésének a valószínűsége a B kikerülése mellett. Alkalmazzuk a következő jelölést:

$$h(A, B, k) \equiv h_{A|\bar{B}}(k) = \mathbb{P}(\tau_A(k) < \tau_B(k))$$

Azaz $h_{A|\bar{B}}(k)$ annak a valószínűségét jelöli, hogy az x_t Markov lánc a k állapotból indulva hamarabb kerül egy A mint egy B -beli állapotba. A $h_{A|\bar{B}}(k)$, $k = 1, \dots, n$ valószínűségekből alkotott n dimenziós vektort $h_{A|\bar{B}}$ fogja jelölni. A következő állítást bizonyítjuk:

10. Tétel. Elérési valószínűség kikerülési feltétel mellett

A $h_{A|\bar{B}}$ elérési valószínűség vektor a következő egyenlet rendszer minimális megoldása:

$$\tilde{\mathbf{P}} \cdot h_{A|\bar{B}} = u$$

Ahol u egy olyan n elemű oszlop vektor, amely minden sorában 0, kivéve az A állapot halmaznak megfelelőket, ahol 1. A $\tilde{\mathbf{P}}$ pedig a \mathbf{P} átmenet valószínűség mátrix úgy módosított változata, hogy előbb a \mathbf{P} mátrixból kivonunk egy identitás mátrixot, majd a mátrix A -nak és B -nek megfelelő sorait 0-val töltjük fel, kivéve az adott sorokbeli diagonális elemeket, amelyek helyére 1-eket írunk.

3. Megjegyzés. Az egyenlet formája, ha az állapotokat olyan sorrendben vesszük, hogy előbb a c darab $S \setminus (A \cup B)$ állapotot, majd a tiltott B állapotokat végül pedig az A állapotokat soroljuk fel:

$$\tilde{\mathbf{P}} \cdot h_{A|\bar{B}} \equiv \begin{pmatrix} p_{1,1} - 1 & \dots & p_{1,c} & p_{1,c+1} & \dots & \dots & \dots & \dots & p_{1,n} \\ \vdots & & \vdots & \vdots & & \vdots & \vdots & & \vdots \\ p_{c,1} & \dots & p_{c,c} - 1 & p_{c,c+1} & \dots & \dots & \dots & \dots & p_{c,n} \\ 0 & \dots & 0 & 1 & \dots & 0 & 0 & \dots & 0 \\ \vdots & & \vdots & \vdots & & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & \dots & 1 & 0 & \dots & 0 \\ 0 & \dots & 0 & 0 & \dots & 0 & 1 & \dots & 0 \\ \vdots & & \vdots & \vdots & & \vdots & \vdots & \ddots & \vdots \\ 0 & \dots & 0 & 0 & \dots & 0 & 0 & \dots & 1 \end{pmatrix} \cdot h_{A|\bar{B}} = \begin{pmatrix} 0 \\ \vdots \\ 0 \\ 0 \\ \vdots \\ 0 \\ 1 \\ \vdots \\ 1 \end{pmatrix}$$

4. Megjegyzés. Nyilvánvaló, hogy az elkerülési feltétel nélküli valószínűségek – az előző tétel szerint – egy ugyanilyen formájú egyenlet megoldásai, kivéve azt, hogy abban az esetben, a B állapothalmaz egy bizonyosan üres halmaz.

Bizonyítás.

Vegyük észre, hogy a $\tilde{\mathbf{P}}$ is egy átmenet-valószínűségmátrix. A \mathbf{P} mátrix szerinti Markov lánc úgy módosított változatának átmenet mátrixa, hogy az A és a B állapotok elnyelő állapotok.

Nyilvánvaló, hogy a módosított mátrix szerinti egyenlet megoldása:

$$\text{ha } k \in A \text{ akkor: } h_{A|\bar{B}}(k) = 1$$

$$\text{ha } k \in B \text{ akkor: } h_{A|\bar{B}}(k) = 0$$

Ami a feladat feltételei szerint szükségszerű. Ha $k \notin (A \cup B)$ akkor a $h_{A|\bar{B}}(k)$ -ra ugyanazok az egyenletek érvényesek mint amelyeket előzőleg a $h_A(k)$ -ra felírtunk. A 2. Megjegyzés szerinti állapot sorrendet és jelölést alkalmazva: $k = 1, \dots, c$ -re:

$$h_{A|\bar{B}}(k) = \sum_{j \in S} p_{k,j} h_{A|\bar{B}}(j)$$

□

4. Átjáró

4.1. Fix nyelőkkel

Vegyünk egy átjárót, más néven egy véges négyzetrácsot. A Markov-lánc az a véletlen sorozat, hogy az idő múlásával melyik állapot az aktuális. Az aktuális lánc állapotainak a halmaza a négyzetrács rácspontjai lesznek. A rácsnak legyen összesen m sora és n oszlopa. Ekkor $m \cdot n$ állapota lesz, vagyis az átmenetmátrixnak $m \cdot n$ sora és $m \cdot n$ oszlopa lesz. Az állapotsorszámokat felülről lefelé és balról jobbra töltjük ki. Későbbiekben a mezőkre állapotsorszámokkal hivatkozom.

Egy konkrét $m = 4$ $n = 5$ esetben ez így néz ki:

sorszám	[, 1]	[,2]	[, 3]	[, 4]	[, 5]
[1,]	1	5	9	13	17
[2,]	2	6	10	14	18
[3,]	3	7	11	15	19
[4,]	4	8	12	16	20

Az átmenet a szomszédokba egyenletes eloszlású lesz. Vagyis ha a jelenben az átjáró csúcspontjában van a folyamat, akkor $\frac{1}{2}$ valószínűséggel lép át egy szomszédos állapotba. Tehát az 1-es sorszámú állapotból $(\frac{1}{2}, \frac{1}{2})$ valószínűséggel lép át az 5-be vagy a 2-be. Hasonlóan, ha a folyamat aktuálisan egy élközép pontban van, akkor $\frac{1}{3}$, ha pedig egy belső pontban van, akkor $\frac{1}{4}$ valószínűséggel lép egy szomszédos pontba, mivel ezeknek rendre 3 illetve 4 szomszédjuk van. Attól Markov, hogy ez az utóbbi valószínűség mindig csak attól függ, hogy melyik állapot az aktuális.

típus	[, 1]	[,2]	[, 3]	[, 4]	[, 5]
[1,]	1	6	6	6	3
[2,]	5	9	9	9	8
[3,]	5	9	9	9	8
[4,]	2	7	7	7	4

9 féle állapottípust különböztetünk meg, az 1, 2, 3, 4 állapotok lesznek a 4 csúcsállapot.

5, 6, 7, 8 jelöljük az élközépi állapotokat attól függően, hogy melyik oldalon vannak és 9 jelöljük a belső pontokat.

A tabu Markov-lánc pedig a következő lesz. A kezdeti állapotok a "felénk" eső állapotok lesznek, $m = 4$ $n = 5$ esetben ezek a 4, 8, 12, 16, 20 állapotok. A célállapotok az átjáró "másik végén" lesznek, vagyis az 1, 5, 9, 13, 17 állapotok. A nyelő állapotaink pedig az átjáró 2 szélén fognak elhelyezkedni, ezek a 2, 3, 18, 19 sorszámmal jelöltek lesznek.

(K: kezdeti, C: cél, NY: nyelő)

sorszám	[, 1]	[, 2]	[, 3]	[, 4]	[, 5]
[1,]	C	C	C	C	C
[2,]	NY	6	10	14	NY
[3,]	NY	7	11	15	NY
[4,]	K	K	K	K	K

Azt fogom megvizsgálni, hogy mennyi a különböző állapotokból a célpontok elérési valószínűsége, azzal a feltétellel, hogy a folyamat nem érinti a nyelő állapotokat. Ekkor egy mátrixban lesznek eltárolva az elérési valószínűségek:

sorszám	[, 1]	[, 2]	[, 3]	[, 4]	[, 5]
[1,]	1	1	1	1	1
[2,]	0	0.447	0.552	0.447	0
[3,]	0	0.237	0.313	0.237	0
[4,]	0.093	0.186	0.229	0.186	0.093

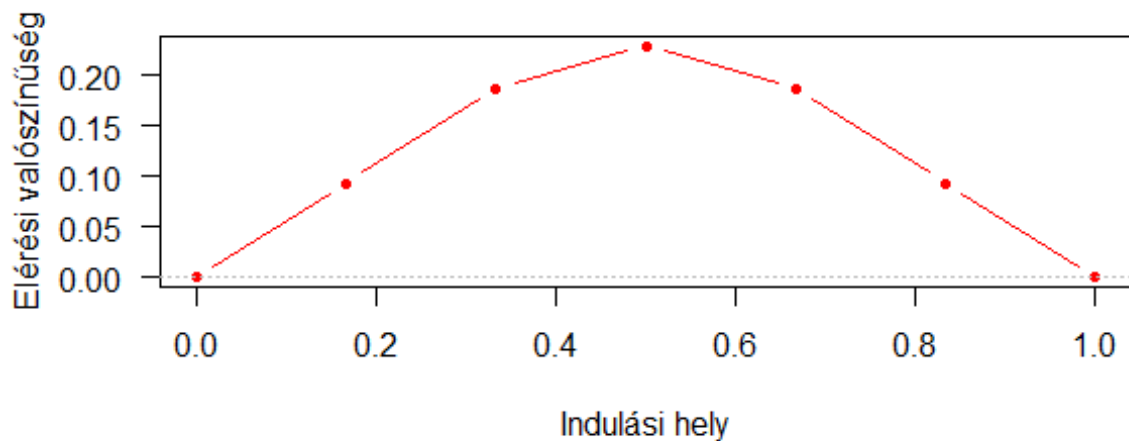
A triviális esetek a nyelő pontok és a célpontok. Annak a valószínűsége, hogy bármelyik nyelő pontból eljutunk a célpontok valamelyikébe azzal a feltétellel, hogy nem érintünk nyelő állapotot, nyilvánvalóan 0 lesz, mivel nyelő állapotból indultunk. Hasonlóan, ha egy célpontból akarunk eljutni egy célpontba úgy, hogy nem érint a folyamat nyelő állapotot 1 valószínűséggel bekövetkezik, mivel a kiinduló állapot egy cél állapot volt. A [4, 1] sorszámú start állapotból ez a valószínűség 0.093, a [3, 3] sorszámú belső pontból 0.313. A belső pontok nem túl érdekesek számunkra, ugyanúgy viselkednek, mint a start állapotok, ezért elég csak a start állapotokkal foglalkozni. **(3.1.2)**

Továbbá meg lehet figyelni, hogy a mátrix a 3. oszlopra szimmetrikus, ami abból

következik, az átjáró és a nyelő pontok is szimmetrikusan helyezkednek el. A valószínűségek kívülről befelé fognak monoton növekedni, ergo a középső elemnél/elemeknél lesz a legnagyobb, mivel a nyelő pontoknak már egyre kisebb hatása lesz a középső elemekre.

Innentől kezdve csak a start pontokból fogjuk megfigyelni a valószínűségeket, az elérési valószínűség mátrix utolsó sorából. Továbbá az ábrázoláskor az átjáró le lesz *normálva*, tehát a $[0, 1]$ intervallumon fogjuk ábrázolni a hozzátartozó valószínűségeket. Az 1. ábra az (5.1) programkóddal készült

Így az előző táblázat utolsó sora ábrázolva az alábbi módon fog kinézni:



1. ábra. 4x5-s átjáró

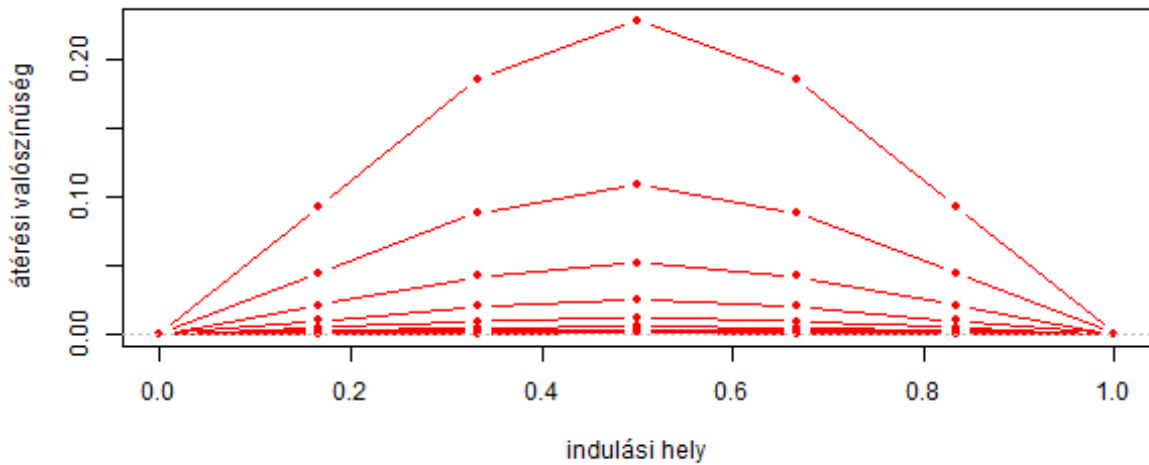
4.2. Aszimptotikus vizsgálat

Most vizsgáljuk meg mi történik aszimptotikusan. Rögzítsük az egyik paramétert miközben a másikat változtatjuk (növeljük). Nyilvánvalóan nem tudjuk azt vizsgálni, hogy a tábla valamelyik paraméterben ∞ nagy legyen, de érdemes megvizsgálni, azokat az eseteket amikor az m/n hányados viszonylag nagy, vagy ha kicsi.

- Legyen $n = 5$ és $m = 4 : 12$, tehát n rögzítve van és m -et növeljük.

Ekkor az értékek táblázatba foglalva az alábbiak:

sorszám	[, 1]	[,2]	[, 3]	[, 4]	[, 5]
$m = 4$	0.093	0.186	0.228	0.186	0.093
$m = 5$	0.044	0.088	0.109	0.088	0.044
$m = 6$	0.0209	0.0418	0.0520	0.0418	0.0209
$m = 7$	0.010	0.198	0.246	0.198	0.010
$m = 8$	0.005	0.009	0.012	0.009	0.005
$m = 9$	0.00222	0.00443	0.00552	0.00443	0.00222
$m = 10$	0.00105	0.00210	0.00261	0.00210	0.00105
$m = 11$	0.00050	0.00099	0.00124	0.00099	0.00050
$m = 12$	0.00023	0.00047	0.00059	0.00047	0.00023

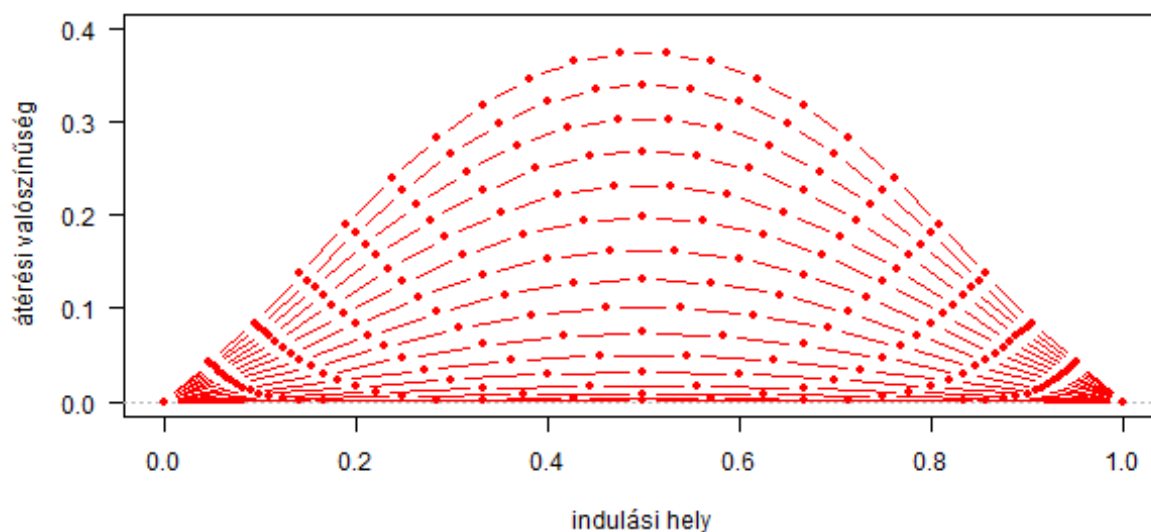


2. ábra. 5 széles átjáró változó hosszúsággal

A táblát *hosszabbítottuk*, vagyis a start és cél pontok egyre messzebb kerültek egymástól. Emellett a nyelő pontok száma is növekedett. Minél hosszabb a tábla, annál nagyobb utat kell bejárni, hogy eljussunk egy célpontba, tehát nagyobb m értékekhez kisebb elérési valószínűségek fognak tartozni.

Ha $m \rightarrow \infty$ -hez, akkor a valószínűségek tartanak 0-hoz. Érdekes megfigyelni, hogy $m = 6$ esetén az elérési valószínűségek, mind kisebbek, mint $\frac{1}{10}$, $m = 9$ esetén már $\frac{1}{100}$ -nál is kisebbek, $m = 12$ esetén pedig már $\frac{1}{1000}$ -t sem érik el. Tehát 3 soronként, nagyjából tizedére csökkennek az egymáshoz tartozó valószínűségek.

Továbbá a második oszlophoz tartozó értékek nagyjából 2-szer akkorák, mint az első oszlopban levők.

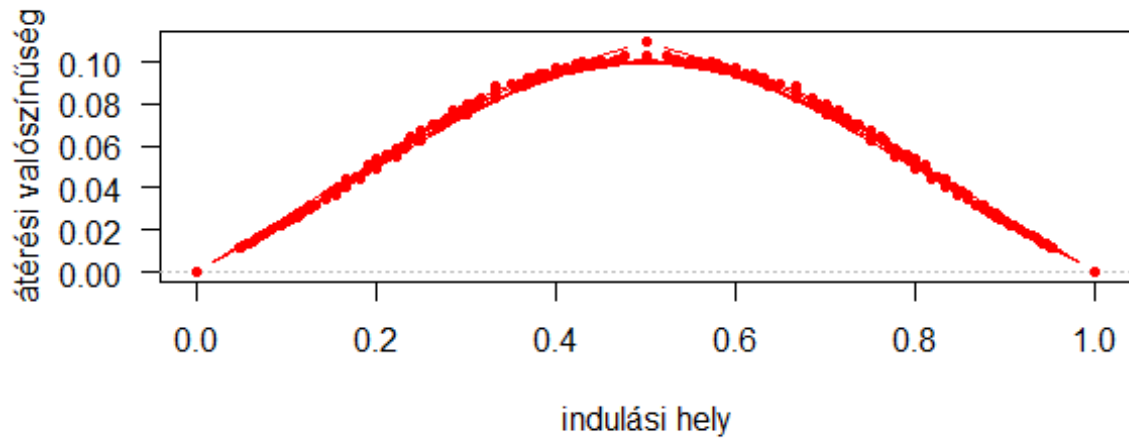


3. ábra. 12 hosszú átjáró változó szélességgel

A táblát ebben az esetben *szélesítettük*, azaz m -et rögzítjük és n -et növeljük egyesével. A 3.ábrán $m = 12$, $n = 5 : 20$ volt. Ilyenkor a nyelő pontok száma változatlan marad, a start és a cél pontok száma pedig növekszik. Várhatóan így az történt amit várni lehetett, kívülről-befelé nőnek a valószínűségek, és a tábla szélesítésével a görbék pontjai egyre közelebb fognak kerülni az 1 valószínűséghez. Az alábbi táblázatban kigyűjtöttem csak a középső 5 darab célpontra az elérési valószínűségeket $\{m = 12; n = 5, 20, 100, 200\}$ esetén. Az alábbi táblázat is mutatja, hogy, ha m rögzített és $n \rightarrow \infty$ akkor 1-hez tartanak a valószínűségek. A 2. és 3. ábra (5.2) programkóddal készültek. Az adatok 5 tizedesjegyre vannak kerekítve.


n	[, 1]	[,2]	[, 3]	[, 4]	[, 5]
$n = 5$	0.00023	0.00047	0.00059	0.00047	0.00023
$n = 20$	0.34588	0.36439	0.37371	0.37371	0.36439
$n = 100$	0.99688	0.99699	0.99705	0.99705	0.99699
$n = 200$	1	1	1	1	1

4.2.1. Adott arányú tábla




4. ábra. Négyzetes átjáró

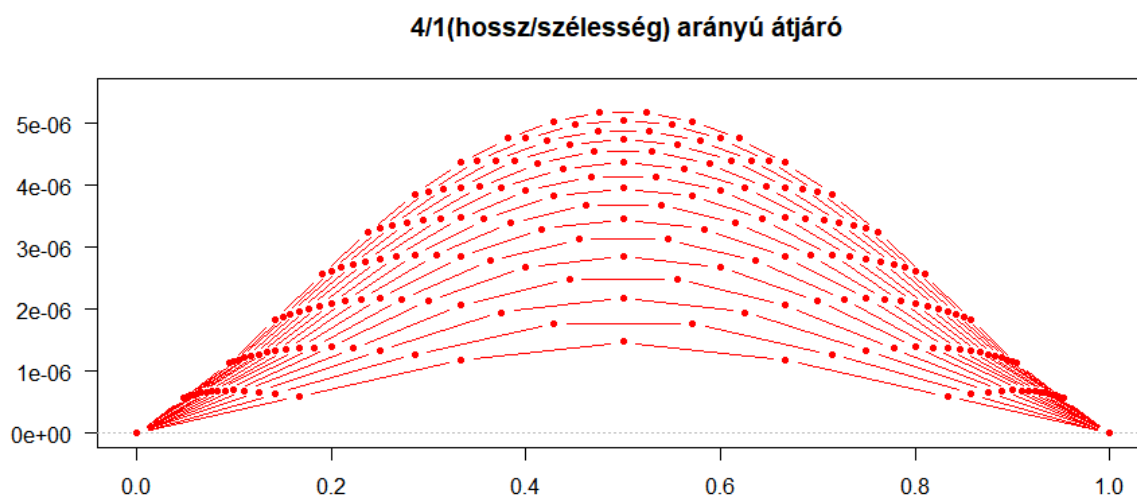
2/1(hossz/szélesség) arányú átjáró



5. ábra. x: Indulási hely, y: Elérési valószínűség



6. ábra. x: Indulási hely, y: Elérési valószínűség



7. ábra. x: Indulási hely, y: Elérési valószínűség

Ebben az esetben azt vizsgáltuk meg, hogy az elérési valószínűség görbék, hogy viselkednek különböző hossz/szélesség arányú átjárók esetén. 4 ilyen táblát vizsgáltunk $1/1$, $2/1$, $3/1$, $4/1$ aránnyal. Miközben a k méretét növeltük 5-től 20-ig.


Ez azt jelenti, hogy első esetben 5×5 , $6 \times 6, \dots, 20 \times 20$ méretű átjárók vannak egy grafikonon ábrázolva. A második esetben, ugyanilyen logika mentén 10×5 , 12×6 , $14 \times 7, \dots 40 \times 20$ -ig vannak a táblák együtt ábrázolva, harmadik, negyedik eset hasonlóan az eddigiekből.

Ha a grafikonokat egymással hasonlítjuk össze, akkor kiderül, hogy minél nagyobb ez az arány annál kisebbek lesznek az elérési valószínűségek. Például egy 5×5 -s táblában nagyságrendekkel nagyobb lesz a valószínűség, mint egy 15×5 -s esetben.

Továbbá, ha külön-külön vizsgáljuk a grafikonokat, akkor megfigyelhető mindegyik esetben, hogy az azonos struktúrájú gráfok esetén a nagyobb tábla esetén az elérési valószínűségek kicsit meg fognak nőni a méret növelésével. Sőt annál jobban fognak változni, minél nagyobb a hossz/szélesség arány. Vagyis, ha például megnézzük, hogy a táblánk 5×5 -ről változik 20×20 -ra, akkor arányaiban nem lesz akkora növekedés, mintha 20×5 -ről 80×20 -ra változtatnánk, habár mindkét esetben a táblák hosszát és szélességét $(4 - 4)$ -szeresére növeltük.


A (4.), (5.), (6.), (7.) ábrák a (5.2.1) programkóddal készültek.

4.2.2. Négyzetes átjáró osztópontokkal




8. ábra. Négyzetes átjáró esetén az osztópontokból az elérési valószínűségek

Elérési valószínűségek a felezőpontokból



9. ábra. x-tengely: Méret, y-tengely: Elérési valószínűség

Elérési valószínűségek a negyedelőpontokból



10. ábra. x-tengely: Méret, y-tengely: Elérési valószínűség

n	3	4	...	31	32
$2n - 1$	5	7	...	61	63

1. táblázat. Felezőpontok

n	2	3	...	20	21
$3n - 1$	5	8	...	59	62

2. táblázat. Harmadolópontok

n	2	3	...	15	16
$4n - 1$	7	11	...	59	63

3. táblázat. Negyedelőpontok

n	2	3	...	12	13
$5n - 1$	9	14	...	59	64


4. táblázat. Ötödölőpontok

Ebben az esetben a különböző osztópontokból (felező, harmadoló, negyedelő, ötödölő) vizsgáltam az elérési valószínűségeket négyzetes átjárók esetén. A fenti 4 táblázat első sora az osztópont sorszámát, a második sora a tábla méretét mutatja. Ez azt jelenti, hogy például a felezőpontok esetén egy 7×7 -s méretű táblánál start sor 4. eleme lesz a középső elem (felezési pont). A hozzárendelési szabály alapján látható, hogy n egyesével van növelve, emellett a tábla mérete 2, 3, 4, 5-tel növekszik, attól függően, hogy melyik osztópont. A felezőpontból indulás minden másodikra, harmadoló csak minden harmadikra van, stb.


Az együttes ábrából látszik, hogy a felezőpontok elérési valószínűsége a legnagyobb, az ötödölőpontoké pedig a legkisebb. Ennek az a magyarázata, hogy fix méretű átjáró esetén a valószínűségek kívülről befelé növekednek. Továbbá, ha a tábla mérete legalább 10×10 , akkor a tábla növelésével mindegyik esetben a valószínűségek növekednek és konvergálnak egy adott számhoz. A felező és a harmadolópontok esetén a tábla kis mérete miatt megfigyelhető egy kezdeti csökkenés, amíg a tábla mérete viszonylag kicsi (5×5 vagy 8×8), de ez nem játszik szerepet az aszimptotikus vizsgálatban.

A (8.), (9.), (10.) ábrák a (5.2.2) programkóddal készültek.

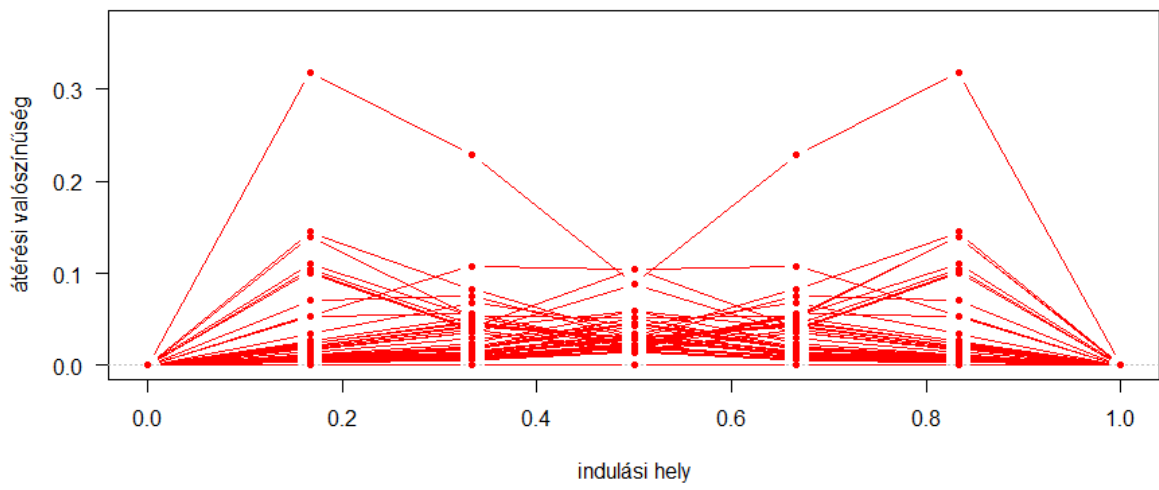
4.3. Fix átjáró különböző helyzetű nyelőkkel




11. ábra. 4×5 átjáró (1-1) nyelővel



12. ábra. 4×5 átjáró (2-2) nyelővel



13. ábra. 4×5 átjáró (3-3) nyelővel



14. ábra. 4×5 átjáró (4-4) nyelővel

Itt egy konkrét táblára (4×5) vizsgáltam meg, mi történik, ha a nyelő pontok számát és helyét változtatom. Mindegyik esetben kirajzolja az összes elérési valószínűség görbét.

A nyelő pontokra egy kikötést tettem, hogy a második és harmadik sorból ugyanannyit választok ki, így hasonló marad a gráf strukturálisan. A fentebbi ábrákon rendre: 1-1, 2-2, 3-3, 4-4 nyelő pontot választottam ki. Az első esetben $\binom{5}{1} \binom{5}{1} = 25$ a második esetben $\binom{5}{2} \binom{5}{2} = 100$ ábra van, és így tovább.

Triviális eset amikor 2×5 nyelő állapotunk van (ezt nem ábrázoltam), ugyanis ez úgy lehet, hogy a 2. és 3.sorban csak nyelő pontok vannak, tehát bármelyik célpont elérési valószínűsége 0 lesz.

Továbbá, ha a 17. ábrát vizsgáljuk a 25 lefutásból csak 5 darab lesz, ahol nem mindegyik elérés 0, ezek pontosan azok az esetek, amikor a nyelő pontok egymás alatt helyezkednek el. Az alábbi táblázat egy ilyen esetet mutat. Itt csak akkor jut el a folyamat egy célpontba, ha végigmegy a 2. oszlopon.

sorszám	[, 1]	[,2]	[, 3]	[, 4]	[, 5]
[1,]	C	C	C	C	C
[2,]	NY	9	NY	NY	NY
[3,]	NY	9	NY	NY	NY
[4,]	K	K	K	K	K

Hasonlóan az eddigiekhez, a görbe akkor lesz szimmetrikus az $x = 0,5$ egyenesre, ha a nyelő pontok is szimmetrikusan helyezkednek el. Nyilvánvalóan mivel fix táblánk van, ha növeljük a nyelő pontok számát az elérési valószínűségek csökkenni fognak.

5. Függelék

5.1. Átjáró fix nyelőkkel

```
%m*n-es átjáró létrehozása
library(markovchain)
folyoso <- function(hossza,szelte,rajz=FALSE)
{
  m <- hossza
  n <- szelte
  allapot_nevek <- apply(cbind("[" ,rep(1:m,n) ,",",rep(1:n,each=m) ,"]" ),1,
                        function(u) paste(u,collapse = ""))
  %állapot sorszám mátrix létrehozása
  allapot_sorszam <- matrix(1:(n*m),m,n)

  %állapot típus mátrix létrehozása
  allapot_tipus <- matrix(9,m,n)
  allapot_tipus[c(1,m),] <- c(6,7)
  allapot_tipus[,c(1,n)] <- rep(c(5,8),each=m)
  allapot_tipus[cbind(c(1,m,1,m),c(1,1,n,n))] <- 1:4

  % valószínűségek a különböző típusú csúcsokból
  p <- c(1/2,1/2,1/2,1/2,1/3,1/3,1/3,1/3,1/4)

  % az [i,j] állapotból melyik sorszámú állapotokba lehet menni
  hova_mehet <- function(tipus,i=2,j=2)
  {
    oda <-
      switch(paste(tipus),
             "1" = c(allapot_sorszam[2,1],
                     allapot_sorszam[1,2]),
```

```

"2"= c(allapot_sorszam[m-1,1],
        allapot_sorszam[m,2]),
"3"= c(allapot_sorszam[1,n-1],
        allapot_sorszam[2,n]),
"4"= c(allapot_sorszam[m,n-1],
        allapot_sorszam[m-1,n]),
"5"= c(allapot_sorszam[i-1,1],
        allapot_sorszam[i+1,1],
        allapot_sorszam[i ,2]),
"6"= c(allapot_sorszam[1,j-1],
        allapot_sorszam[2,j  ],
        allapot_sorszam[1,j+1]),
"7"= c(allapot_sorszam[m  ,j-1],
        allapot_sorszam[m-1,j  ],
        allapot_sorszam[m  ,j+1]),
"8"= c(allapot_sorszam[i  ,n-1],
        allapot_sorszam[i-1,n],
        allapot_sorszam[i+1,n]),
"9"= c(allapot_sorszam[i,j-1],
        allapot_sorszam[i-1,j],
        allapot_sorszam[i+1,j],
        allapot_sorszam[i,j+1]),

NA)

return(oda)
}

% átmenet-valószínűségmátrix feltöltése
P <- matrix(0,m*n,m*n)
for(i in 1:m)for(j in 1:n)
{

```

```

    tipus <- allapot_tipus[i,j]
    sorszam <- allapot_sorszam[i,j]
    P[sorszam,hova_mehet(tipus,i,j)] <- p[tipus]
  }

%a Markov-lánc felépítése
MC <- new("markovchain",transitionMatrix=P)

%a speciális állapotok kijelölése
cel <- ((1:n)-1)*m+1
nyel <- c(2:(m-1),((n-1)*m+2):(n*m-1))
start <- (1:n)*m

hp <- committorAB(MC,cel,nyel) % elérési valószínűség az összes állapotból
hps <- matrix(hp,m,n)[m,] % elérési valószínűség a start állapotokból

% ábra létrehozása
if(rajz)
{
  x <- seq(0,1,length=n+2)
  plot(x,c(0,hps,0),t='b',col="red",pch=20,las=1,
        xlab="Indulási hely",ylab="Elérési valószínűség")
  abline(h=0,col="gray",lty=3)
}

return(hps)
}

% 4 hosszú 5 széles átjáró
folyoso(4,5) %elérési valószínűségek
folyoso(4,5,TRUE) %rajzzal

```

5.2. Aszimptotikus vizsgálat

```
%5 széles 4:12 hosszú átjáró
n <- 5
hpm <- matrix(NA,0,n)
for(m in 4:12) hpm<-rbind(hpm,folyoso(m,n))
round(hpm,5) % az értékek egy táblázatba foglalva

%egy ábrán a különböző hosszúságú átjárók
x <- seq(0,1,length=n+2)
matplot(x,t(cbind(0,hpm,0)),t="b",lty=1,col="red",pch=20,
        xlab="indulási hely",
        ylab="elérési valószínűség")
abline(h=0,col="gray",lty=3)

%12 hosszú 5:20 széles átjáró
m <- 12
hpl <- list(NULL)
for(n in 5:20) hpl <- c(hpl,list(folyoso(m,n)))
hpl <- hpl[-1]

% segédfüggvény a normált valószínűségek ábrázolására
prob.curve <- function(u)
{
  x <- seq(0,1,length=length(u)+2)
  u <- c(0,u,0)
  points(x,u,t="b",lty=1,col="red",pch=20)
}

% egy ábrán a 16 darab átjáró
par(mar=c(4,5,3,1))
```

```

plot(.5,0,xlim=c(0,1),ylim=c(0,.4),t="n",las=1,
      xlab="indulási hely",
      ylab="elérési valószínűség")
abline(h=0,col="gray",lty=3)
w <- sapply(hpl,"prob.curve")

```

5.2.1. Adott arányú tábla

```

%Négyzetes átjáró 5:20 hosszúság esetén
% többi eset folyoso(2*k,k),folyoso(3*k,k),folyoso(4*k,k)
hpl <- list(NULL)
for(k in 5:20) hpl <- c(hpl,list(folyoso(k,k)))
hpl <- hpl[-1]

```

%ábrázolása

```

plot(.5,0,xlim=c(0,1),ylim=c(0,.11),t="n",las=1,
      xlab="indulási hely",
      ylab="elérési valószínűség")
abline(h=0,col="gray",lty=3)
w <- sapply(hpl,"prob.curve")

```

5.2.2. Négyzetes átjáró osztópontokkal

%felezőpontok

%vizsgált hossz

```

h.50 <- 30 %többi eset h.33<-20,h.25<-15,h.20<-12
felezo <- vector("numeric",h.50) %többi eset h.33, h.25,h.20
mn50 <- seq(5,by=2,length=h.50) % méret
pont <- seq(3,by=1,length=h.50) % a felező pontok
rbind(mn50,pont)

```



```

for(k in 1:h.50)
  felezo[k] <- folyoso(mn50[k],mn50[k])[pont[k]]
  %felezőpontok ábrázolása
  plot(mn50,felezo,
        xlab="méret",ylab="valószínűség",
        t="b",col="red",pch=20,las=1)
%együtt az ábrák
plot(.5,0,t="n",las=1,
      xlim=c(1,64),ylim=c(0,0.13),
      xlab="méret",ylab="elérési valószínűség",)
points(mn50,felezo ,col="red" ,t="b",pch=20)
points(mn33,harmadolo,col="blue" ,t="b",pch=20)
points(mn25,negyedelo,col="green4",t="b",pch=20)
points(mn20,otodolo ,col="orange",t="b",pch=20)
legend("bottomleft",c("fél","harmad","negyed","ötöd"),
      text.col=c("red","blue","green4","orange"))

```

5.3. Fix átjáró különböző helyzetű nyelőkkel

Nagyon hasonló a fix nyelős esethez, annyi különbséggel, hogy először a nyelőpontok számát beállítom (1-1), (2-2), (3-3) vagy (4,4) majd az adott esetre megnézem a nyelőpontok összes lehetséges elhelyezkedését és lefutatom a folyoso függvényt.

Ebben az esetben a programkódot nem részletezem.

Hivatkozások

- [1] KAI LAI CHUNG, *Markov Chains with Stationary Transition Probabilities*, Springer-Verlag, New York, 1967, 43-49, (19-23)
- [2] CSISZÁR VILLŐ, *Diszkrét és folytonos paraméterű Markov láncok*
(<https://web.cs.elte.hu/~villo/ml/ML.pdf>)
Elérés időpontja: 2020. április, (7-8)
- [3] <https://cran.r-project.org/web/packages/markovchain/markovchain.pdf>
Elérés időpontja: 2020. április, (11-18)
- [4] <https://www.datamentor.io/r-programming/s4-class/>
Elérés időpontja: 2020. április, (9-11)
- [5] [https://hu.wikipedia.org/wiki/Markov-lánc](https://hu.wikipedia.org/wiki/Markov-l%C3%A1nc)
Elérés időpontja: 2020. április, (5)
- [6] https://math.bme.hu/~szbalazs/oktatas/sztoch_info/het_4_Markov.pdf
Elérés időpontja: 2020. április, (6)