

# Valószínűségszámítás speci I. éves matematika tanárszakos hallgatóknak

## Csiszár Villó

### Ajánlott irodalom:

Székely J. Gábor: Paradoxonok a véletlen matematikájában (Műszaki könyvkiadó, 1982)

Székely J. Gábor: Paradoxonok a véletlen matematikájában, 2. átdolgozott kiadás (Typotex, 2004)

Warren Weaver: Szerencse kisasszony (Kairosz kiadó, 1997)

Denkinger Géza: Valószínűségszámítás (Nemzeti Tankönyvkiadó, 1997)

**Számonkérés:** A félévet írásbeli vizsga zárja.

## 1. A valószínűségszámítás tárgya, véletlen kísérlet matematikai modellje

Véletlen kísérlet: az eredménye nem jósolható meg előre, a véletlentől függ. A véletlent nem filozófiai oldalról közelítjük meg, hanem gyakorlati oldalról. Az életben tapasztaljuk, hogy vannak véletlen jelenségek, sőt, ezeknek bizonyos törvényszerűségei is vannak (pl. nagy számok törvénye).

Pl.: közvéleménykutatás: 2000 embert megkérdezve, az már jól fogja tükrözni a népesség jellemzőit; kaszinó hosszú távon nyereséges, mert ki tudja számítani, hogy az emberek átlagosan mennyit nyernek.

Akkor tanulmányozhatók jól *a véletlen törvényszerűségei*, ha a kísérletet sokszor meg tudjuk ismételni, azonos körülmények között: véletlen tömegjelenségek. Ilyenekre a legjobb példákat a szerencsejátékok szolgáltatják. (Bonyolultabb esetek: tőzsde-árfolyamingadozások, biztosítás-káresemények, biológia-járvány terjedése, stb.)

Célunk, hogy ezekre a véletlen jelenségekre *matematikai modellt* alkossunk, mégpedig úgy, hogy a modellből kiszámolt eredmények jól használhatóak legyenek a gyakorlatban.

1. Bár az eredményt nem tudjuk előre megjósolni, tudjuk, hogy mik a *lehetséges kimenetek*. **Matematikailag** ezek egy (véges vagy végtelen) halmazt alkotnak. (Ennek neve: eseménytér, jel:  $\Omega$ ) Hogy mit tekintünk kimenetelnek, az rajtunk is múlik, hogy mit tartunk érdekesnek, fontosnak (pl. lottóhúzásnál csak az öt számot, vagy a sorrendjüket is).

2. Esemény: **matematikailag** kimenetek egy halmaza (jel. pl. A). Ez vagy bekövetkezik, vagy nem. Az eseményekkel műveletek is végezhetők (A komplementere: pontosan akkor következik be, ha A nem; A és B uniója: akkor következik be, ha A és B legalább egyike bekövetkezik; A és B metszete: akkor következik be, ha A és B is bekövetkezik)

3. Minden kimenetelhez, eseményhez hozzárendelünk egy valószínűséget. Az A esemény valószínűségét jelölje  $P(A)$  (P, mint *probability*). **Matematikailag?**

A hétköznapi életben azt értjük egy esemény valószínűségén, hogy sok független kísérletet elvégezve, hány százalékban következik be:  $P(A) \approx k_A/n$  ha n nagy. Ezért úgy szeretnénk definiálni a valószínűséget, hogy a relatív gyakoriság tulajdonságai érvényesüljenek → a valószínűség axiómái:

i, Bármely esemény valószínűsége egy 0 és 1 közötti szám. ii, A biztos esemény valószínűsége 1.

iii, Egymást kizáró eseményekre (A és B metszete üres) annak valószínűsége, hogy legalább egy bekövetkezik közülük, megegyezik az egyes események valószínűségeinek összegével.

Egy kísérlet **matematikai modelljén** tehát azt értjük, hogy megadjuk a lehetséges kimeneteket (ill. az eseményeket), és ezek valószínűségeit.

Legegyszerűbb eset: minden kimenetelnek ugyanakkora az esélye (ha véges sok kimenetel van). Annak eldöntésénél, hogy egy kísérletben egyformán esélyesek-e a kimenetek, szimmetria okokra lehet hivatkozni (pl. kockadobásnál, lottóhúzásnál).

Ha a lehetséges kimenetek egyformán valószínűek (klasszikus eset), akkor egy esemény valószínűsége = kedvező kimenetek száma / összes kimenetel száma.

Példák: Szabályos dobókockával dobunk: a 6 lehetséges érték egyformán valószínű.

Két kockával dobva 36 egyformán valószínű kimenetel van (fával ábrázolható). Ha csak a két számra vagyunk kíváncsiak (mindegy, hogy milyen sorrendben jöttek ki), akkor 21 kimenetel van, de azok nem egyformán esélyesek (KI LEHET PRÓBÁLNI!). A két kockát a természet mindenképp meg tudja különböztetni, még ha nekünk egyformának tűnnek is! A valóságot tehát az a modell írja le jól, amely a fizikailag különböző objektumokat különbözőnek tekinti, függetlenül attól, hogy mi, mint tökéletlen megfigyelők, meg tudjuk-e különböztetni őket egymástól. (Kivétel:

fizikai kísérletek kimutatták, hogy az elemi részecskék nem mindig így viselkednek, pl. a protonok és a fotonok.)

Események valószínűségének kiszámításához érdemes az egyforma vszgű kimenetelekből kiindulni, így használható a klasszikus képlet (pl. két kockánál melyik esélyesebb: összeg = 9, összeg = 10).

Lottó: 90 számból 5-öt húzunk visszatevés nélkül (sorrend számít-e?) – úgy is lehet venni, hogy számít, úgy is, hogy nem

$$90 \cdot 89 \cdot 88 \cdot 87 \cdot 86 = 5\,273\,912\,160 \qquad 120\text{-val osztva: } 43\,949\,268.$$

(mind egyformán valószínű kimenetelek)

## 2. A valószínűségszámítás születése (röviden)

A szerencsejátékok tanulmányozásából alakult ki a valószínűségszámítás, kezdetben nem volt egyéb, mint a kedvező/összes képlet alkalmazása.

Cardano: Liber de Ludo Aleae (A kockajátékok könyve), 1663-ban jelent meg, de több, mint száz évvel korábban íródott. (arabul *az-zar* = *kocka*, ebből származik a *hazárd* = kockázat szó)

1654: Antoine Gombauld, Méré lovagja (de Méré lovag), művelt, kíváncsi alkat, játékkermeket is látogatott. Ismerte a **Régi Szerencsejátékos-szabályt**, amely arra vonatkozott, hogy egy adott esemény bekövetkezésére nézve mi az a kritikus kísérletszám, amely esetén az esélyek kedvezőtlenről kedvezőre váltanak:

Ha a  $p_1$  valószínűségű eseményre a kritikus szám  $n_1$ , akkor a  $p_2$  valószínűségű eseményre  $n_2 = n_1 \cdot p_1 / p_2$ .

Pl. a szabályt alkalmazva, ha tudjuk, hogy a “hatos dobás” kritikus száma 4, akkor a “dupla hatos”-é 24. (három dobásból 0,42 eséllyel lesz 6-os, négy dobásból 0,52 eséllyel) Igaz-e ez?

NEM! Mekkora az esélye, hogy  $n$  kísérletből legalább egyszer bekövetkezik a  $p = k/m$  valószínűségű A esemény?

$1 - (m - k)^n / m^n = 1 - (1 - p)^n$ . Ez akkor lesz legalább  $\frac{1}{2}$ , ha  $n$  legalább  $-\log_2 / \log(1 - p)$ .  $\log(1 - p)$ -t sorbafejtve,

helyesen:  $n = 0,6931 / (p + p^2/2 + p^3/3 + \dots)$  felső egészrésze, ami elég kis  $p$  esetén megegyezik  $0,6931 / p$  felső egészrészével. Azaz ekkor igaz, hogy  $np$  közel konstans. (A dupla hatos kritikus száma egyébként 25.)

A lovag megkérdezte Blaise Pascalt is, aki megoldotta a feladatot. Később az osztozkodási problémát (mely 1494-ből származott) is megoldotta (Két játékos egy igazságos játékban hat győzelemig játszik, de 5:3-nál abbahagyják: hogyan osztozzanak meg a téten? A helyes válasz: 7:1 arányban kell osztozni.), majd Pierre de Fermat-val kezdett ezekről és más szerencsejátékokról levelezni – megszületett a valószínűségi számítás.

A modern valószínűségi számítás megalapítója A.N. Kolmogorov, aki az 1930-as években dolgozta ki a valószínűségi számítás mai felépítését.

### 3. Körbeverés: kockákra, számhúzásra (Székely I/13f)

- $A$  és  $B$  azt a játékot játssza, hogy  $A$  megszámoz három kockát az 1-18 számokkal,  $B$  választ egyet, majd a maradék kettőből  $A$  egyet. Az nyer, aki nagyobb számot dob. Kinek előnyös a játék?
- Válasz:  $A$ -nak előnyös, mert legyen **I**: 1, 6, 11, 12, 13, 14    **II**: 2, 3, 4, 15, 16, 17    **III**: 5, 7, 8, 9, 10, 18  
 $P(\text{II megveri I-t}) = P(\text{III megveri II-t}) = P(\text{I megveri III-t}) = 21/36$ , azaz a kockák  $21/36$  valószínűséggel körbeverik egymást. Tehát akármelyik kockát választja is  $B$ ,  $A$  tud az övénél jobbat választani. HF: Lehet-e ennél jobb számozást megadni ( $A$  szempontjából)?

**Def:** Egy véletlentől függő mennyiséget *valószínűségi változónak* nevezünk. Az  $X$  (diszkrét) valószínűségi változó megadása: felsoroljuk  $X$  lehetséges értékeit:

$x_1, x_2, x_3, \dots$  és a hozzájuk tartozó valószínűségeket:  $p_1, p_2, p_3, \dots$

**Def:** Az  $X_1, X_2, \dots, X_n$  valószínűségi változók *körbeverik egymást*, ha  $P(X_2 > X_1) = p_1$ ,  $P(X_3 > X_2) = p_2, \dots, P(X_1 > X_n) = p_n$  jelöléssel  $p_i > 1/2$  minden  $i$ -re.

A körbeverési valószínűség a  $p_i$  számok minimuma.

Az előző példában  $X_I, X_{II}, X_{III}$  a három kockával dobott érték, ezek nyilván függetlenek egymástól, nincsenek egymásra hatással, valamelyik ismerete nem mond semmit a többiről (a függetlenséget matematikailag is lehet definiálni, HF: vajon hogyan?).

- Mennyi a körbeverési valószínűség maximuma, ha  $n$  véletlen mennyiség nem feltétlenül független?
- Válasz:  $(n-1)/n$ .

Megvalósítás:  $A$  és  $B$  játékosok játszanak, először  $A$  választ egy számot  $1$  és  $n$  között, majd  $B$  is, de nem választhatja ugyanazt, mint  $A$ . Legyenek a számaik  $k_A$  és  $k_B$ .

Ezután a játékvezető kisorsol  $0$  és  $(n-1)$  között egy  $X$  számot, véletlenszerűen. A játékosok ezt hozzáadják saját számukhoz, és az  $n$ -nel osztva kapott maradékot kapják meg, azaz az  $Y_A = k_A + X \bmod n$  és az  $Y_B = k_B + X \bmod n$  számokat. Itt  $Y_A$  és  $Y_B$  nyilván összefüggnek, hiszen ugyanaz a véletlen  $X$  mennyiség szerepel bennük. Ez a játék is  $B$  számára előnyös, hiszen az  $Y_i = i + X \bmod n$  véletlen mennyiségek körbeverik egymást, amint ez az alábbi táblázatból látszik ( $n = 5$ -re):

$X$	$Y_1$	$Y_2$	$Y_3$	$Y_4$	$Y_5$
0	1	2	3	4	0
1	2	3	4	0	1
2	3	4	0	1	2
3	4	0	1	2	3
4	0	1	2	3	4

$P(Y_{i+1} > Y_i) = (n-1)/n$ . Ez a játék hasonlít az előzőhöz, úgy képzelhetjük, hogy itt  $n$  db. "kocka" van, de ezek egy fonállal össze vannak kötve, úgy, hogy bármelyik kockán a dobott szám meghatározza az összes többi kockán dobott számot is.

Belátjuk, hogy ennél tényleg nem lehet nagyobb a körbeverési valószínűség. Tegyük fel, hogy  $n$  mennyiség körbeveri egymást.  $A_k := \{X_{k+1} > X_k\}$ ,  $P(A_k) := p_k$  jelöléssel ( $k = 1, \dots, n$ ), mivel ennek az  $n$  eseménynek a metszete üres, komplementereik uniója a biztos esemény. Mivel tehát ezek a komplementer események lefedik az összes lehetőséget, valószínűségeik összege legalább egy. Ezért van köztük olyan, amelyik legalább  $1/n$  valószínűségű, azaz olyan  $k$ , hogy  $1 - p_k \geq 1/n$ . Erre a  $k$ -ra  $p_k \leq (n-1)/n$ , azaz  $\min_j p_j \leq (n-1)/n$ .

Megmutatható, hogy független mennyiségek esetén a körbeverési valószínűség maximuma (monoton növekvő módon)  $3/4$ -hez tart. (Usiskin eredménye)

#### 4. Névjegy-probléma (Székely I/6, Weaver 119)

- $n$  ember esetén mekkora az esélye, hogy névjegyüket véletlenszerűen összezacserélve, senki sem a sajátját kapja vissza?
- Válasz: kb.  $1/e$ , azaz 37%. (ha legalább 4 ember játszik). – ez a szita-formulával számítható ki.

Pl.  $n = 4$ :

1-es a helyén van: 1342, 1423, 1243, 1432, 1324, **1234**

2-es a helyén van: 3241, 4213, 1243, 4231, 3214, **1234**

3-as a helyén van: 2431, 4132, 1432, 4231, 2134, **1234**

4-es a helyén van: 3124, 2314, 1324, 3214, 2134, **1234**

Összesen 15 olyan permutáció van, amelyben valamelyik szám a helyén van, tehát  $9/24 = 0,375$  a valószínűsége, hogy egyik sincs a helyén.

Szita-formula:  $n$  darab esemény uniójának valószínűségét – a logikai szitához hasonlóan – úgy számíthatjuk ki, hogy összeadjuk az  $n$  esemény valószínűségeit, majd kivonjuk belőle a kettes metszetek valószínűségeit, hozzáadjuk a hármas metszetek valószínűségeit, és így tovább az  $n$ -es metszetig. Ha most  $A_i$  az az esemény, hogy az  $i$ . ember a saját névjegyet kapja vissza, akkor ezek uniójára, azaz arra az eseményre, hogy legalább egy ember a sajátját kapja vissza, a

$$\sum_{k=1}^n (-1)^{k-1} \frac{1}{k!} = 1 - \sum_{k=0}^n (-1)^k \frac{1}{k!} \text{ valószínűség adódik. Ez pedig } n \text{ növekedésével}$$

gyorsan tart az  $1 - 1/e$  számhoz.

- Átlagosan hány ember kapja a sajátját?
- Válasz: nagyon sokszor, mondjuk  $M$ -szer, kiosztva a névjegyeket, tegyük fel, hogy a  $j$ . kiosztásnál  $n_j$  ember kapta a saját névjegyet. Jelölje még  $k_j$  azt, hogy hány kísérletben kapta  $j$  ember a saját névjegyet. Az átlag tehát  $(n_1 + \dots + n_M)/M = 0 \cdot k_0/M + 1 \cdot k_1/M + \dots + n \cdot k_n/M$ . Mivel a  $k_j/M$  relatív gyakoriság közel van a  $p_j = P(\text{pontosan } j \text{ ember kapja a saját névjegyet})$  valószínűséghez, mondhatjuk, hogy nagy átlagban  $0 \cdot p_0 + 1 \cdot p_1 + \dots + n \cdot p_n$  ember kapja a saját névjegyet.

**Def:** Az  $X$  valószínűségi változó várható értéke  $E(X) = x_1 \cdot p_1 + x_2 \cdot p_2 + x_3 \cdot p_3 + \dots$

Ahhoz, hogy a várható értéket meghatározzuk, ismerni kellene a  $p_j$  valószínűségeket. Ezeket elég bonyolult kiszámolni.

A fenti példában  $n = 4$ -re leszámolhatjuk, hogy  $p_0 = 9/24$ ,  $p_1 = 8/24$ ,  $p_2 = 6/24$ ,  $p_3 = 0/24$ ,  $p_4 = 1/24$ . A várható érték tehát pontosan 1.

Az általános esetben a következő trükkhöz folyamodhatunk: az  $n_1 + \dots + n_M$  összeget úgy is megkaphatjuk, hogy minden emberről megszámloljuk, hogy hányszor kapta a saját névjegyet, és ezeket összeadjuk. Legyen  $u_j$  azon kísérletek száma, amikor a  $j$ . ember a saját névjegyet kapta. Ekkor tehát

$n_1 + \dots + n_M = u_1 + \dots + u_n$ . Így az átlag:  $u_1/M + \dots + u_n/M$ . Viszont az  $u_j/M$  relatív gyakoriság közel van a  $P$ (a  $j$ . ember a saját névjegyet kapta)

valószínűséghez, ami nem más, mint  $1/n$ . Így átlagosan  $n \cdot 1/n = 1$  ember kapja a saját névjegyet, minden  $n$ -re.

A trükk lényege abban áll, hogy egy valószínűségi változót összegre bontunk, és várható értékét tagonként számoljuk ki. Pl.:

permutáció	hány van a helyén ( $X$ )	1-es helyén van-e ( $X_1$ )	2-es helyén van-e ( $X_2$ )	3-as helyén van-e ( $X_3$ )	4-es helyén van-e ( $X_4$ )
1234	4	1	1	1	1
3124	1	0	0	0	1
3214	2	0	1	0	1
4123	0	0	0	0	0
2431	1	0	0	1	0

## 5. A születésnap-paradoxon és az ajándékgyűjtő játék

Születésnap-paradoxon (Egy szimulációs program – angol nyelven – elérhető a következő helyen: <http://www.mste.uiuc.edu/exner/java.f/birthday/default.html>)

- $n$  ember esetén mekkora az esély, hogy van köztük legalább kettő, akik ugyanazon hónap ugyanazon napján születtek, tehát ugyanakkor van a születésnapjuk? Tegyük fel az egyszerűség kedvéért, hogy az év 365 napból áll, és minden ember születésnapja, egymástól függetlenül, véletlenszerűen esik e 365 nap valamelyikére.
- Válasz: Pl. néhány  $n$ -re: 366: 100%, 68: 99,9%, 55: 90%, **23: 50%**.  
Képlettel is megadható:  $1 - 365 \cdot 364 \cdot \dots \cdot (366-n)/365^n$ . Ebben a feladatban nincs semmi nehézség, az eredmény viszont meglepő, ezért nevezik paradoxonnak.
- Átlagosan hányadik embernél következik be az első ismétlődés?

- Válasz: Annak az esélye, hogy a  $k$ . embernél következik be az első ismétlődés,  $p_k = (365 \cdot 364 \cdot \dots \cdot (367-k) \cdot (k-1)) / 365^k$ . A várható érték tehát  $2 \cdot p_2 + 3 \cdot p_3 + 4 \cdot p_4 + \dots + 366 \cdot p_{366} = 24,62$ . HF: Vajon itt lehet-e összegre bontással egyszerűbb képletet kapni? HF:  $n$  ember esetén mekkora az esély, hogy valakinek ugyanakkor van a születésnapja, mint nekem?

Ajándékgyűjtő játék (Egy szimulációs program – angol nyelven – elérhető a következő helyen: <http://www.mste.uiuc.edu/reese/cereal/intro.html>)

- A reggelizőpelyhes dobozokban  $n$  különböző ajándékot lehet találni. Átlagosan hány dobozt kell vásárolni ahhoz, hogy mind az  $n$ -féle ajándékot összegyűjtsük? (vagy: dobókockával hányszor kell dobni, hogy mind a hat szám kijöjjön?)
- Válasz: Kellene annak a valószínűsége, hogy pontosan  $k$  dobozból gyűlik össze mindegyik ajándék. Ezt bonyolult kiszámítani. Összegre bontással egyszerűbb:  $X_1$ : hány doboz kell ahhoz, hogy egyféle ajándékunk már legyen,  $X_2$ : ezután még hány doboz kell ahhoz, hogy már kétféle ajándékunk legyen, stb. Pl. ha négy ajándék van, és az egymás utáni dobozokban a 34413132 ajándékokat találjuk, akkor  $X_1 = 1$ ,  $X_2 = 1$ ,  $X_3 = 2$ ,  $X_4 = 4$ , és  $X = 8$ .

Mennyi  $X_k$  várható értéke? Ekkor  $(k-1)$ -féle ajándékunk már van, tehát minden további dobozban  $(n-k+1)/n$  eséllyel találunk új ajándékot.

- Átlagosan mennyit kell várni egy  $p$  valószínűségű eseményre?
- Válasz: annak az esélye, hogy  $k$  kísérletet kell rá várni,  $p_k = (1-p)^{k-1}p$ . Tehát a várható érték  $1 \cdot p_1 + 2 \cdot p_2 + 3 \cdot p_3 + \dots = 1/p$ . Máshogy: a várakozási időt fel lehet írni végtelen sok valószínűségi változó összegeként, ahol  $Y_k$  akkor 1, ha a  $k$ . kísérlet előtt nem következett be a várt esemény, egyébként pedig nulla.  $Y_k$  várható értéke  $(1-p)^{k-1}$ . Tehát az összegük várható értéke  $1/p$ .
- Az összes ajándék tehát átlagosan  $n/n + n/(n-1) + n/(n-2) + \dots + n/2 + n/1$  dobozból gyűlik össze.

Mekkora az esélye, hogy  $k$  doboz nem elegendő? Ez a szita-formulával írható fel. Pl. ha négyféle ajándékot kell összegyűjtenem, akkor 7 doboz megvásárlása után már 51% az esélyem, hogy mind megvan, és átlagosan 8,3 doboz kell.

HF: tegyük fel, hogy az ajándékok állatos kártyák, méghozzá hatféle állat van: agár, béka, cica, darázs, elefánt, foka. Átlagosan hány dobozt kell vennem, ha csak négyféle



kártyát szeretnék összegyűjteni? Átlagosan hány dobozt kellennem, ha az agarat, békát, cicát, darázst szeretném összegyűjteni?

## 6. Fej-írás sorozatok versenye, a Conway-algoritmus

- Tekintsük a következő játékot: Két (vagy több) játékos mindegyike választ magának egy fej-írás sorozatot, majd egy szabályos érmét elkezdnek dobálni. Az nyer, akinek a sorozata először felbukkan. Milyen sorozatot érdemes választani? (Székely I/13c)
- Pl: Anna sorozata: IFF, Bea sorozata: IIF. A dobássorozat: FFFIFIIIIF – Bea nyert, a játék 10 dobás hosszan tartott.
- Igaz-e, hogy egyenlőek a nyerési esélyek? Hiszen érvelhetünk azzal, hogy minden 3 hosszú sorozat ugyanolyan valószínűséggel jön ki! Mégsem igaz, pl. az IFF és FFI sorozatoknál, FFI csak akkor nyerhet, ha az első két dobás F. Ekkor ugyanis még egy ideig F fog jönni, de előbb-utóbb megjelenik egy I, és ezzel FFI nyert. Ha viszont az első két dobásban volt I is, akkor a játék addig folytatódik, amíg megjelenik egymás után két F, és ezzel IFF nyer. Tehát a két sorozat versenyében  $P(\text{FFI nyer}) = \frac{1}{4}$ ,  $P(\text{IFF nyer}) = \frac{3}{4}$ . Nem minden esetben ilyen egyszerű a valószínűségeket látni.
- A játék menetét *gráffal* lehet ábrázolni, azaz felrajzoljuk a lehetséges állapotokat, és hogy melyikből melyikbe léphetünk. Egy állapot azt fejezi ki, hogy a dobássorozat végén mi az a maximális részsorozat, ami még felhasználható valamelyik célsorozat felépítéséhez. Minden állapotból két nyíl vezet kifelé annak megfelelően, hogy a következő dobás fej-e vagy írás. Azok az állapotok, amikor valamelyik sorozat elkészült, a végállapotok, ekkor befejeződik a játék.
- Az egyes sorozatok nyerési esélyét egyenletrendszer felírásával és megoldásával számíthatjuk ki. Pl. az IFF és IIF versenyében  $\frac{1}{3}$  valószínűséggel nyer IFF ( $\frac{2}{3}$  valószínűséggel pedig IIF): Legyenek az állapotok a következők: 0 – kezdő, 1 – I, 2 – IF, 3 – II, 4 – IFF (végállapot), 5 – IIF (végállapot). Jelölje  $x_k$ , hogy a  $k$ . állapotból indulva, mekkora eséllyel lesz IFF a nyertes. Ekkor nyilván  $x_4 = 1$  (IFF már nyert is), és  $x_5 = 0$  (IIF nyert). Ezt felhasználva a többi állapotra a következő egyenleteket írhatjuk fel:

$$x_0 = \frac{1}{2}x_0 + \frac{1}{2}x_1 \quad x_1 = \frac{1}{2}x_2 + \frac{1}{2}x_3 \quad x_2 = \frac{1}{2} \cdot 1 + \frac{1}{2}x_1 \quad x_3 = \frac{1}{2} \cdot 0 + \frac{1}{2}x_3$$

Ennek megoldása  $x_0 = 1/3$ .

- Könnyen látszik, hogy a játék (dobásszámban mért) hosszának átlagos értéke felülről becsülhető. Ha  $a$  darab  $n$  hosszú sorozat versenyez egymással, akkor a dobássorozatot  $n$  dobásból álló blokkokra felosztva, minden blokkban  $a/2^n$  eséllyel éppen a versenyző sorozatok valamelyike fog megjelenni. Korábban megmutattuk, hogy annak a blokknak az átlagos sorszám, amelyben először megjelenik valamelyik versenyző, éppen  $2^n/a$ . Mivel egy blokk  $n$  dobásból áll, átlagosan  $2^n/a$  dobás kell ahhoz, hogy valamelyik sorozat *egy blokkban* megjelenjen. A játék legkésőbb ekkor véget ér, persze általában ennél hamarabb, hiszen az is elég, ha két blokkon átnyúlva jelenik meg egy sorozat. Tehát pl. egy  $n$  hosszú sorozat megjelenésére átlagosan biztosan kevesebb, mint  $2^n n$  dobást kell várni.
- Pl. az IFF, FFI sorozatoknál, ha az első két dobás F, akkor ezután az első I megjelenésére átlagosan két dobást kell várni. Így ebben az esetben átlagosan  $2+2 = 4$  dobásra van szükség. Ha az első dobás I, akkor F-re átlagosan két dobást kell várni. Ezután vagy F, vagy I jön. Ha F, akkor vége a játéknak, ha I, akkor folytatódik. Tehát átlagosan 3 hosszú blokkjaink vannak, és ezekből átlagosan kettő kell, tehát  $1 + 3 \cdot 2 = 7$  dobás kell. Ha az első két dobás FI, akkor nyilván átlagosan  $1 + 7 = 8$  dobás hosszát tart a játék. Tehát az átlagos játékhossz  $\frac{1}{4} \cdot 4 + \frac{1}{4} \cdot 8 + \frac{1}{2} \cdot 7 = 6.5$ .
- Egyenletrendszerrel számítható ki az is, hogy átlagosan hány dobás (a gráfon lépés) hosszán tart a játék. A korábbi példánál maradva, IFF és IIF versenyében, jelölje  $m_k$ , hogy a  $k$ . állapotból indulva, még átlagosan hány lépés kell a játék befejezéséig. Nyilván  $m_4 = m_5 = 0$ , hiszen ekkor a játék már véget is ért. Ezt felhasználva a többi állapotra a következő egyenleteket írhatjuk fel:

$$m_0 = 1 + \frac{1}{2}m_0 + \frac{1}{2}m_1 \quad m_1 = 1 + \frac{1}{2}m_2 + \frac{1}{2}m_3 \quad m_2 = 1 + \frac{1}{2} \cdot 0 + \frac{1}{2}m_1$$

$$m_3 = 1 + \frac{1}{2} \cdot 0 + \frac{1}{2}m_3$$

Ennek megoldása  $m_0 = 16/3$ .

Ez a módszer nagyon fáradtságos, ha több és hosszabb sorozat van. Egyszerűbb megoldást kínál a **Conway algoritmus** (csak vázlatosan bizonyítjuk).

Ehhez definiáljuk két sorozat átfedési számát:

Azt mondjuk, hogy két sorozat között van  $k$  hosszúságú átfedés, ha az első sorozat utolsó  $k$  tagja megegyezik a második sorozat első  $k$  tagjával. Az A és B sorozat átfedési száma a 2 azon hatványainak összege, melyekre van  $k$  hosszúságú átfedés.

Jelölése:  $A*B$ . Pl.  $IFF*FFI = 2^1 + 2^2 = 6$ .  $FFI*IFF = 2^1 = 2$ .

Belátható, hogy az A sorozat megjelenésére átlagosan  $A*A$  dobást kell végezni, pl. az FIF sorozathoz 10-et.

Ebből következik, hogy az  $n$  hosszú sorozatok közül a legtöbbet azokra a sorozatokra kell várni, amelyekre minden átfedés megvan, azaz a csupa egyformából állókra, mégpedig  $2^1 + 2^2 + \dots + 2^n = 2^{n+1} - 2$  dobást. Legkevesebbet pedig azokra a sorozatokra, amelyekre csak  $n$  hosszúságú átfedés van, pl. a  $FF\dots FI$  sorozatra,  $2^n$  dobást. HF: vajon hány ilyen sorozat van?

Ha több egyforma, mondjuk  $n$ , hosszú sorozat versenyez egymással, akkor az egyes sorozatok nyelési esélyét illetve a játék átlagos időtartamát egyetlen egyenletrendszer megoldásával kaphatjuk meg. Jelöljük a sorozatokat A, B, ..., Z-vel, nyelési esélyüket  $p_A, p_B, \dots, p_Z$ -vel, az átlagos dobásszámot # -vel. Az egyenletek:

$$p_A A*A + p_B B*A + \dots + p_Z Z*A = \#$$

$$p_A A*B + p_B B*B + \dots + p_Z Z*B = \#$$

...

$$p_A A*Z + p_B B*Z + \dots + p_Z Z*Z = \#$$

$$p_A + p_B + \dots + p_Z = 1$$

Speciálisan, ha csak egy sorozat van, akkor kapjuk, hogy  $\# = A*A$ .

Speciálisan, ha két sorozat van, akkor az egyenletrendszer megoldása:

$$p_A = \frac{B*B - B*A}{A*A + B*B - A*B - B*A}, \quad \# = \frac{A*A \cdot B*B - A*B \cdot B*A}{A*A + B*B - A*B - B*A}$$

Az utolsó egyenlet azt fejezi ki, hogy valamelyik sorozat biztosan nyerni fog.

Nézzük az elsőt, mi indokolja az egyenletet? Egy játékvezető egy pénzdarabot dobál addig, amíg az A, B, ..., Z sorozatok valamelyike megjelenik. Képzeld el, hogy valaki a következő fogadásos játékot űzi: mikor beszáll a játékba, feltesz 1 Ft-ot – dupla vagy semmi alapon – arra, hogy a játékvezető következő dobása éppen az A sorozat első eleme lesz. Ha veszít, kiszáll, viszont ha nyer, akkor a most már 2Ft-ját felteszi arra, hogy a következő dobás az A sorozat második elemét adja. És így

tovább, ha nyer, akkor a megduplázott pénzét felteszi a sorozat következő elemére. Ha végül kijön A, akkor mindenképp kiszáll. Ez a játék igazságos, tehát a játékos átlagos nyeresége – minden dobás után – megegyezik a feltett 1Ft-tal. Tegyük most fel, hogy sok játékosunk van, a  $k$ . játékos a  $k$ . dobásnál száll be a játékba, egész addig, amíg a játék véget ér. A játék átlagosan  $n$  dobásig tart, tehát átlagosan ennyi a befizetett összeg. Nézzük, hogy mennyit nyertek a játékosaink, ha végül pl. a B sorozat jött ki? Akik az utolsó  $n$  dobás előtt szálltak be, azok mindenképp vesztek, hiszen az A sorozat nem jött ki. Az pedig, aki csak az utolsó  $k$  dobásra szállt be ( $k \leq n$ ), az akkor nyert  $2^k$  Ft-ot, ha az A sorozat első  $k$  eleme – amikre fogadott – megegyezik a B sorozat utolsó  $k$  elemével – ami kijött. Így éppen  $B^*A$  Ft a teljes nyereség. Ezt az összes sorozatra végiggondolva, és nyerési esélyeikkel súlyozva kapjuk az első egyenletet, amely tehát azt fejezi ki, hogy az átlagos nyereség megegyezik az átlagos befizetéssel. A többi egyenlet hasonlóan adódik, ha a játékosok egy másik sorozatra fogadnak.

Bővebben erről a témáról olvashatunk a [www.math.elte.hu/~mori/fej12\(1\).rtf](http://www.math.elte.hu/~mori/fej12(1).rtf), a [www.math.elte.hu/~mori/fej12\(2\).rtf](http://www.math.elte.hu/~mori/fej12(2).rtf), és a [www.math.elte.hu/~mori/fej12\(3\).rtf](http://www.math.elte.hu/~mori/fej12(3).rtf) írásokban, Móri Tamás tollából.

- Ez a témakör is szolgáltat meglepő jelenségeket. Itt is megfigyelhető a körbeverés. Vegyünk egy végtelen hosszú dobássorozatot, és tetszőleges A sorozatra jelölje  $X_A$ , hogy hányadik dobásra jelenik meg A először. A és B versenyében  $P(X_B > X_A)$  éppen A nyerési esélyét jelenti. Pl. az FFI, FII, IIF, IFF sorozatok ebben az értelemben körbeverik egymást.
- Olyan sorozatok is vannak, melyeknél A átlagosan hamarabb jön ki, mint B, de B mégis 1/2-nél nagyobb valószínűséggel megelőzi A-t: tekintsük az  $A = \text{IFII}$ ,  $B = \text{FIFI}$  sorozatokat. A Conway algoritmus szerint A-ra átlagosan 18 dobást kell várni, míg B-re 20-at. Viszont ha a két sorozat egymással versenyez, akkor 9/14, azaz kb 64% az esélye, hogy B jön ki előbb. (A paradoxon oka: általában egy kicsivel előbb jön ki a B, de néha nagyon sokkal később.)

## 7. Pétervári paradoxon

- Daniel Bernoulli az 1700-as évek elején írt cikket a Pétervári Tudományos Akadémia folyóiratában, innen származik az elnevezés.
- A paradox állítás a következő: annak a játéknak, amelynél  $2^n$  forint a nyereség, ha  $n$ -edikre jön ki először fej, az “ára” végtelen.
- Valóban: a várható nyereség:  $2^1 * (1/2)^1 + 2^2 * (1/2)^2 + \dots = 1 + 1 + \dots$ . Azaz akármennyit is fizetünk a banknak azért, hogy ezt a játékot játszhasuk, a bank hosszú távon rosszul jár. Ez meglepő, hiszen nem nagyon találnánk olyan embert, aki hajlandó volna mondjuk egymillió forintot fizetni, hogy beszállhasson ebbe a játékba! Ennek oka az, hogy ugyan nagyon kicsi valószínűséggel nagyon nagy lesz a nyereségünk, de ha nem nyerünk az első néhány játékban, akkor tönkremegyünk.
- Hogyan lehetne megadni a játék “reális” árát?
- Egy módosítás (Buffon, Cramer): a gyakorlatban nem bízhatunk abban, hogy a bank akármilyen nagy nyereséget ki fog nekünk fizetni. Ésszerű feltenni, hogy a banknak csak  $2^m$  forintja van, így ha többet kellene fizetnie a szabályok szerint, akkor is csak ennyit tud adni. Ekkor már csupán  $m + 1$  Ft a játék méltányos ára, hiszen a várható nyereségünk most  $2^1 * (1/2)^1 + 2^2 * (1/2)^2 + \dots + 2^m * (1/2)^m + 2^m * ((1/2)^{m+1} + \dots) = 1 + 1 + \dots + 1 + 1 = m + 1$ .
- Másik módosítás (Feller): akkor méltányos a játék, ha nagy  $m$  esetén  $m$  játszma után a nyereség és a befizetett részvételi díj hányadosa nagy valószínűséggel közel 1 lesz. Kicsit precízebben, tegyük fel, hogy  $m$  játszmaért  $R_m$  forintot kell befizetni, és  $N_m$  forintot nyerünk. A feltétel az, hogy tetszőleges előírt  $c$  esetén annak a valószínűsége, hogy  $|N_m/R_m - 1| < c$ -nél kisebb, egyhez tartson, ha  $m$  végtelenbe tart. Ezzel a definícióval méltányos a játék, ha  $m$  játszmaért  $m * \log_2 m$  forintot fizetünk (ez összhangban van azzal, hogy egy játszma ára bármilyen  $K$  konstansnál nagyobb lehet, ha sok játszmaért fizetünk be). Így pl. 2048 játszmaért játszmánként 11 forintot méltányos fizetni. (Buffon: 2084 játék alapján azt tapasztalta, hogy 10 forint a méltányos ár játszmánként.)
- Analóg példa: duplázó- (úgynevezett martingál-) stratégia igazságos játékban, pl szabályos érmét dobálva fejnél veszíték, írásnál nyerek. Ez csak végtelen nagy tőkénél (azaz a gyakorlatban nem) működik. A stratégia: az első játszmaiban 1 forint a tétel. Ha veszíték, akkor a következő játszmaiban már 2

forintot kockáztatok, majd minden vesztes után megduplázom a tétemet. Ennél a stratégiánál, mivel előbb-utóbb kijön a fej, egy forint a tiszta nyereségem: ha ugyanis  $n$ -edikre jön az első fej, akkor elvesztettem  $1 + 2 + \dots + 2^{n-2} = 2^{n-1} - 1$  forintot, viszont nyertem  $2^{n-1}$  összeget. Viszont lehet, hogy már azelőtt tönkremegyek, hogy nyernék. (Székely I/7, Weaver 144)

## 8. A lóverseny játék

- Lóverseny-játék egyszerűsített változata: Érmét dobálva fej esetén 1-et, írás esetén 2-t lépünk előre. Tegyük fel, hogy a pálya végtelen hosszú ☺. Mennyi a valószínűsége, hogy egy adott, távoli mezőn elhelyezkedő akadályra rálépünk?
- Megoldás: rekurzióval, zárt alakból adódik a határérték. Azaz: jelölje  $p_n$  annak az esélyét, hogy az  $n$ -edik mezőre rálépünk. Ekkor igaz, hogy  $p_n = p_{n-1} * \frac{1}{2} + (1 - p_{n-1}) * 1$ . Ha ugyanis az  $(n - 1)$ -dik mezőre ráléptünk, akkor onnan  $\frac{1}{2}$  eséllyel lépünk rá az  $n$ -edikre is (ha fejet dobunk), ha viszont az  $(n - 1)$ -dik mezőre nem léptünk rá, akkor az  $n$ -edikre biztosan rálépünk, mert két szomszédos mezőt nem tudunk átugrani. Ebből rekurzióval kapjuk, hogy  $p_n = 1 - \frac{1}{2} + \frac{1}{4} - \dots + (-1)^n (\frac{1}{2})^n * p_0$ . Felhasználva, hogy  $p_0 = 1$ , a mértani sorozat összegképlete alapján  $p_n = \frac{2}{3} * (1 + (-1)^n / 2^{n+1})$ . Ebből látszik, hogy nagy  $n$  esetén a mezőre való rálépés esélye közelítőleg  $\frac{2}{3}$ .
- Ezt a játékot úgy általánosíthatjuk, hogy többféle lehetséges lépéshosszal számolunk, amelyek nem feltétlenül egyformán valószínűek. Ekkor igaz, hogy az adott mezőre lépés valószínűségének határértéke (feltéve hogy  $\ln(\text{lehetséges lépéshosszak}) = 1$ ) éppen  $1/m$ , ahol  $m$  az egyes lépések átlagos hossza. (HF: mi a helyzet, ha  $\ln(\text{lehetséges lépések}) > 1$ ?) Ez heurisztikusan úgy fogadható el, ha arra gondolunk, hogy  $n$  lépés megtétele után közelítőleg az  $nm$ -dik mezőig jutottunk, és az addigi mezők közül éppen  $n$  darabot érintettünk. Így az érintett mezők aránya  $n/nm = 1/m$ , azaz egy-egy mezőre ilyen eséllyel léptünk rá. Az, hogy  $p_n$  egyre inkább stabilizálódik, onnan látszik, hogy mindegyik  $p_n$  néhány előzőnek a (súlyozott) átlaga. Például kockadobásnál  $p_n = (p_{n-6} + p_{n-5} + \dots + p_{n-1})/6$ , hiszen azt az eseményt, hogy  $n$ -re rálépünk, hatfelé bonthatjuk aszerint, hogy melyik előző mezőről léptünk ide. (Itt  $p_0 = 1$ , negatív  $n$ -re pedig  $p_n = 0$ .) Ebben az esetben az első húsz mezőre az eredmények a következők:

0.167	0.194	0.227	0.265	0.309	0.360	0.254	0.268	0.280	0.289
0.293	0.291	0.279	0.284	0.286	0.287	0.287	0.286	0.285	0.286

## 9. A kezdőszámjegy eloszlása

- Feladat: képzeljük el, hogy Magyarország összes települése közül véletlenszerűen kiválasztottunk tizet, és megszámloltuk a lakosságukat. Írjuk le ennek a kísérletnek egy lehetséges végeredményét!
- Játék: képzeljük el, hogy valaki véletlenszerűen választ egy magyarországi települést. Anna arra fogad, hogy lakosság száma 1–4-ig terjedő számmal kezdődik, Bea arra, hogy 5–9-ig terjedő számmal kezdődik. Kinek előnyös a játék?
- 1881-ben Simon Newcomb egy matematikai folyóiratban írt két oldalas cikkben megjegyezte, hogy a gyakorlatban előforduló adathalmazokban a kezdőszámjegyek megoszlása nem egyenletes, azaz nem ugyannyi adat kezdődik 1-gyel, 2-vel, stb. (American Journal of Mathematics)  
Később 1938-ban Frank Benford fizikus ugyanezt a megfigyelést tette, melyet húsz példán mutatott be (a példák egy kicsit túl jók voltak).
- **Benford törvénye:** A gyakorlatban előforduló legtöbb adathalmazban (népszámlálási adatok, tőzsdei árfolyamok, termelési mutatók, bevételek, stb.) a  $k$ -val kezdődő adatok aránya körülbelül  $\log_{10}(1+1/k)$ , illetve a legfeljebb  $k$ -val kezdődő adatok aránya körülbelül  $\log_{10}(1+k)$  ( $k = 1, \dots, 9$ ).
- Illusztráció: Somogy megye 244 településének lakossága az 1991-es népszámlálás szerint.

Kezdőszámjegy	Arány	Benford arány	Kezdőszámjegy	Arány	Benford arány
1	25,0%	30,1%	6	9,0%	6,7%
2	18,9%	17,6%	7	6,1%	5,8%
3	12,7%	12,5%	8	5,7%	5,1%
4	9,8%	9,7%	9	2,0%	4,6%
5	10,7%	7,9%			

- Mi lehet a jelenség magyarázata?
- Magyarázat: A természetben gyakoriak az exponenciálisan növekvő/csökkenő folyamatok, és ezekről megmutatható, hogy ilyen eloszláshoz vezetnek: Tegyük fel, hogy vagyunk minden évben az  $x$ -szeresére nő (vagy csökken). Ha egy forintból indulunk ki, akkor az  $n$ -dik év végén  $x^n$  forintunk lesz. Ez akkor kezdődik 1-gyel (az első értékes számjegyet tekintve), ha van olyan

egész  $s$  szám, hogy

$10^s \leq x^n < 2 \cdot 10^s$ , azaz  $n \cdot \log_{10} x - \log_{10} 2 < s \leq n \cdot \log_{10} x$ . A kérdés tehát az, hogy ebben a  $\log_{10} 2$  hosszúságú intervallumban van-e egész szám. Ha pl.  $\log_{10} x$  elég kicsi, akkor a „jó”  $n$ -ek aránya éppen  $\log_{10} 2$ . (De pl. 10 hatványai mindig 1-gyel kezdődnek!) Ugyanígy számolható ki, hogy az exponenciálisan növekvő folyamat hány százalékban kezdődik legfeljebb  $k$ -val.

- Illusztráció: Legyen  $x = 1,1$  (pl. a pénzem évente 10%-ot kamatozik). Erre  $\log_{10} 1,1 = 0,04$ , és  $\log_{10} 2 = 0,3$ . Tehát azokat az  $n$ -eket keressük, melyekre a  $(0,04n - 0,3 ; 0,04n]$  intervallumban van egész szám.
- Ez a törvényszerűség akkor is érvényben marad, ha a pénzemet átváltom dollárba, hiszen ez csak annyit jelent, hogy az intervallumokat kicsit eltolom: ha a forintban kifejezett összeg  $f$ , akkor a dollárban kifejezett összeg  $d = yf$ , ahol  $y$  az árfolyam. Az  $n$ . év végén tehát  $yx^n$  dollárunk lesz, ez akkor kezdődik 1-gyel, ha van olyan egész  $s$  szám, hogy
$$n \cdot \log_{10} x - \log_{10} 2 + \log_{10} y < s \leq n \cdot \log_{10} x + \log_{10} y$$
- Megmutatható, hogy a kezdőszámjegyeknek ez az egyetlen olyan lehetséges eloszlása, ami a mértékegység megváltoztatása után is érvényben marad.
- Megmutatható, hogy a Benford törvény diktálta egyenletlenség a második számjegy eloszlásában már sokkal kevésbé jelenik meg, és ahogy egyre későbbi jegyek felé haladunk, az eloszlás egyre egyenletesebbé válik.
- Hasonló eredményhez vezető valószínűségszámítási kérdés: Mekkora a valószínűsége, hogy egy véletlenszerűen választott természetes szám 1-gyel kezdődik? A kérdés feltételezi, hogy az összes természetes szám közül lehetséges véletlenszerűen választani, ez azonban nincs így (mivel végtelen sok természetes szám van).
- Kérdezhetjük helyette a következőt: tf. hogy 1 és  $n$  között választunk egy véletlen természetes számot (mindegyiket  $1/n$  eséllyel), jelölje  $p_n$  ezek között az 1-gyel kezdődők arányát. Ha létezik a  $p_n$  sorozat  $p$  határértéke (amint  $n$  végtelenbe tart), akkor természetesnek tűnik azt mondani, hogy „egy véletlen természetes szám első számjegye  $p$  valószínűséggel 1-es”. Ilyen értelemben  $1/2$  az esélye, hogy egy véletlen természetes szám páros, vagy  $6/\pi^2$  az esélye, hogy egy véletlen törtet nem lehet egyszerűsíteni. Azonban a  $p_n$  sorozat nem



konvergál: egyre szélesebb „hullámokat” vet, ahol a hullámhegyek magassága 0,55, a hullámvölgyek mélysége pedig 0,11. Ha azonban ebből „átlagot” számolunk, akkor megint csak kb 30%-ot kapunk.

- Konkrétan: nyilván olyan  $n$ -ekre lesz  $p_n$  a lehető legnagyobb, melyekre  $n = 2 \cdot 10^s - 1$  (pl. 1, 19, 199, stb), ezekre  $p_n = (10^{s+1} - 1) / (9 \cdot (2 \cdot 10^s - 1)) \approx 5/9 = 0,555$ . Ezután  $n$  növekedésével  $p_n$  számlálója változatlan, míg nevezője növekszik, egészen  $n = 10^{s+1} - 1$ -ig (pl. 9, 99, 999), amikor  $p_n = 1/9 = 0,111$ . Innentől  $p_n$  számlálója és nevezője is egyesével növekszik a következő csúcsig.
- Játék: A játékvezető elrejtett két szomszédos, véletlen természetes számot két borítékba. A játékos véletlenszerűen választ egy borítékot. Ha a nagyobb szám van nála, akkor megnyeri a kisebb számot, ha viszont a kisebb szám van nála, akkor ennyit kell fizetnie a játékvezetőnek. A játékos számára nyereséges, veszteséges, vagy igazságos a játék?
- Egyrészt igazságos, hiszen ha a két borítékban az  $n$  és az  $n+1$  számok vannak, akkor  $1/2$  eséllyel nyer  $n$  Ft-ot,  $1/2$  eséllyel pedig veszít  $n$  Ft-ot. Másrészt, tegyük fel, hogy a játékos a borítékban  $n$ -et talált. Ekkor a másik borítékban vagy  $n-1$  van (ha a játékvezető az  $n-1$ ,  $n$  számokat rejtette el), vagy  $n+1$  (ha a játékvezető az  $n$ ,  $n+1$  számokat rejtette el). Mivel véletlenszerűen történt az elrejtés, ennek a két lehetőségnek egyforma az esélye. Tehát a játékos  $1/2$  eséllyel nyer  $n-1$  Ft-ot,  $1/2$  eséllyel veszít  $n$  Ft-ot, azaz veszteséges számára a játék.
- Nyilván egy játék nem lehet egyszerre igazságos és veszteséges is. Az ellentmondás abból adódik, hogy feltettük, hogy lehet az összes természetes szám közül teljesen véletlenszerűen két szomszédosat kiválasztani.

## 10. Adatsorok, illetve valószínűségi változók jellemzése

- Korábban definiáltuk a valószínűségi változót, és megnéztük, hogy hogyan lehet leírni viselkedését a lehetséges értékek, illetve valószínűségeik felsorolásával:  
 $X$  lehetséges értékei:  $x_1, x_2, x_3, \dots$   
a hozzájuk tartozó valószínűségek:  $p_1, p_2, p_3, \dots$

- Ha egy adott valószínűségi változó értékét sokszor megfigyeljük, egymástól függetlenül, akkor egy adatsort kapunk. Pl:  
 $X$ : egy kockadobás eredménye  
 $X$  lehetséges értékei: 1, 2, 3, 4, 5, 6  
a hozzájuk tartozó valószínűségek:  $1/6, 1/6, 1/6, 1/6, 1/6, 1/6$   
12 megfigyelést végzünk, azaz 12-szer feldobunk egy kockát. Az adatsor pl.  
2, 5, 5, 1, 2, 3, 4, 3, 6, 2, 1, 1  
A “nagy számok törvénye” szerint az adatsorban az egyes értékek a valószínűségekhez közeli arányban fordulnak elő.
- Ez alapján a (hosszú) adatsorokat nagy eséllyel helyesen tudjuk összepárosítani a véletlen kísérletekkel. Tekintsük pl. a következő 4 kísérlettel előállított valószínűségi változót:
  - a) Egy szabályos érmét 10-szer feldobunk. Jelölje  $X$  a fejek számát.
  - b) Egy urnában 12 piros és 12 fehér golyó van. 10-et kihúzzunk (visszatevés nélkül). Jelölje  $Y$  a kihúzottak között a pirosak számát.
  - c) Egy urnában 20 piros és 30 fehér golyó van. 10-et kihúzzunk (visszatevés nélkül). Jelölje  $Z$  a kihúzottak között a pirosak számát.
  - d) Egy kalapba 11 cédulát teszünk, 0-tól 10-ig számozva. Véletlenszerűen húzzunk egyet, jelölje ezt  $V$ .
- Tekintsük a következő négy, 30 elemű adatsort (nagyság szerint rendezve)!  
A: 0 0 0 1 1 2 2 2 3 4 4 5 5 5 6 6 6 6 6 6 7 7 8 8 8 8 8 9 10 10  
B: 2 2 3 3 3 3 4 4 4 4 5 5 5 5 5 5 5 5 5 6 6 6 6 7 7 7 7 8 8 9  
C: 2 3 3 3 3 3 3 3 3 3 4 4 4 4 4 4 4 4 4 4 5 5 5 5 5 5 6 6 7  
D: 2 2 3 4 4 4 4 4 4 4 5 5 5 5 5 5 5 6 6 6 6 6 6 6 6 6 6 6 7 7 7 7
- Hogyan tudnánk őket összepárosítani? (A–d, B–a, C–c, D–b)  
Értékkészlet: mindegyik kísérlet eredménye 0 és 10 között lehet.  
Várható érték:  $X, Y$ , és  $V$  várható értéke 5,  $Z$ -é ennél kevesebb.  
Szóródás:  $X, Y$ , és  $V$  közül nyilván  $V$  szóródik legjobban, legkevésbé pedig  $Y$ .

### Adatok jellemző értékei

1. Közéértékek:

- Számítási közép, azaz átlag: Legyen  $y = (y_1, \dots, y_n)$  egy adatsor. Jelölje az átlagát  $\bar{y} = \frac{1}{n} \sum y_i$ . Ha minden adatból kivonjuk az átlagot, akkor az így kapott adatsor átlaga már nulla. Tetszőleges  $a$  és  $b$  számokra jelölje  $ay + b$  azt az adatsort, melynek  $i$ . eleme  $ay_i + b$ . Tetszőleges  $y$  és  $z$  azonos hosszúságú adatsorokra jelölje  $y + z$  azt az adatsort, melynek  $i$ . eleme  $y_i + z_i$ . Ekkor  $\overline{ay + b} = a\bar{y} + b$ ,  $\overline{y + z} = \bar{y} + \bar{z}$
- Medián, azaz a nagyság szerint középső elem (vagy a két középső átlaga), jelölje ezt  $m(y)$ . Erre is igaz, hogy  $m(ay + b) = am(y) + b$ , de  $m(y + z) = m(y) + m(z)$  általában nem teljesül.

A két középérték közül az átlag érzékeny a kiugróan nagy vagy kicsi értékekre, ellenben a medián nem.

## 2. Szóródási mérőszámok:

Az adatok szóródását az méri, hogy átlagosan milyen messze esnek a középértéktől. A használt "távolság" több féle is lehet.

- Hagyományos távolságfogalom, azaz két szám különbségének abszolút értéke. Megmutatható, hogy az adatok egy adott konstanstól vett átlagos távolságát a medián minimalizálja, azaz  $e_c(y) = \frac{1}{n} \sum |y_i - c|$  akkor a legkisebb, ha  $c = m(y)$ . Az  $e(y) = e_{m(y)}(y)$  érték tehát az adatok szóródásának egy fajta mérőszáma lehet. Teljesül, hogy  $e(ay + b) = |a|e(y)$ , azaz ha pl. az adatpontokat vízszintes irányban kétszeresen megnyújtjuk, akkor szóródásuk megduplázódik.
- A fenti állítás bizonyítása: tegyük fel, hogy  $y$  nagyság szerint növekvő sorrendbe van rakva. Válasszuk ki először a legkisebb és a legnagyobb adatot, ezek  $y_1$  és  $y_n$ . Az  $|y_1 - c| + |y_n - c|$  érték akkor minimális, ha  $c$  az  $[y_1, y_n]$  intervallumba esik. Haladjunk ezután az adatsoron „mindkét irányból befelé,” látszik, hogy olyan  $c$  minimalizálja az eltérések összegét, amely mindegyik  $[y_k, y_{n+1-k}]$  intervallumba beleesik.
- A négyzetes távolság kevésbé tűnhet természetesnek, viszont könnyebb vele számolni, és az a jó tulajdonsága is megvan, hogy az átlagos

négyzetes távolságot az átlag minimalizálja:  $d_c^2(y) = \frac{1}{n} \sum (y_i - c)^2$  akkor a legkisebb, ha  $c = \bar{y}$ . A hozzá tartozó  $d^2(y) = d_{\bar{y}}^2(y)$  mennyiséget az adatok szórásnégyzetének, a  $d(y)$  értéket pedig az adatok szórájának nevezzük. Teljesül, hogy  $d(ay + b) = |a|d(y)$ . A szórák kiszámítását gyakran megkönnyíti a következő képlet:  $d^2(y) = d_c^2(y) - (c - \bar{y})^2$ .

- Ezek a mennyiségek analóg módon a valószínűségi változókra is értelmezhetők. Az átlagnak a várható érték felel meg, az adatok szórásnégyzetének a valószínűségi változó szórásnégyzete:  $D^2(X) = E[(X - E(X))^2]$ .

## 11. Néhány nevezetes modell

- Mondjunk minél több, véletlen kísérlethez tartozó valószínűségi változót! Próbáljuk meg valahogy csoportosítani ezeket! Vannak-e közöttük hasonlóak?
- Rögzített számú *független* kísérletből megszámoljuk a sikeres kísérletek számát  $\rightarrow$  binomiális eloszlás. Példák:
  - ✓ 10 kockadobásból hány 6-ost kapunk?
  - ✓ 20 kosárradobásból hány talál be?
  - ✓ 25 hallgató közül hányan születtek áprilisban?
  - ✓ Egy ötgyermekes családban hány fiú van?
- Azt a véletlen mennyiséget, amely a  $0, 1, \dots, n$  értékeket veheti fel, méghozzá a  $k$  értéket  $\binom{n}{k} p^k (1-p)^{n-k}$  eséllyel,  $n$  rendű,  $p$  paraméterű binomiális eloszlásúnak nevezzük. Egy ilyen eloszlású mennyiség várható értéke  $np$ , szórásnégyzete  $np(1-p)$ . Pl. 36 érmédobásból átlagosan 18 fej lesz, a szórák 3.
- A binomiális eloszlást ( $p = 1/2$ -re) jól lehet szemléltetni a Galton-deszka elnevezésű eszközzel (<http://www.stattucino.com/berrie/dsl/Galton.html>). Azt, hogy a Galton-deszka egyes szintjein hogyan oszlanak meg a golyók,

illetve az egyes szögekhez hányféle úton lehet eljutni, a Pascal-háromszög írja le.

- Más eloszlást kapunk, ha a kísérletek nem függetlenek egymástól. Erre tipikus példa, ha urnából *viszatevés nélkül* húzunk golyókat → hipergeometrikus eloszlás.
- Számoljuk ki, hogy ha egy héten 22 millió, egymástól függetlenül és véletlenszerűen kitöltött szelvény játszik a lottón, akkor mennyi az esélye, hogy legalább két öttalálatos lesz? Binomiális eloszlással lehet számolni, de nagyon nagy számok szerepelnek.
- Ilyen esetben a binomiális eloszlást jól közelíti a Poisson eloszlás, amelyet 1837-ben Siméon Denis Poisson fedezett fel. Azt a véletlen mennyiséget, amely a 0, 1, 2, ... értékeket veheti fel, még hozzá a  $k$  értéket  $e^{-s}s^k/k!$  eséllyel,  $s$  paraméterű Poisson eloszlásúnak nevezzük. Ennek alapján a fenti kérdésre a válasz: kb. 9%.
- A Poisson eloszlás átlagos értéke és szórásnégyzete is  $s$ . Legvalószínűbb értéke az  $s$  egészrésze. Ilyen eloszlással modellezhető pl. a sajtóhibák száma egy szövegben, vagy egy ritka betegségben az évi halálozások száma.
- További példa: megnézzük, hogy hányadik kísérletre következett be az első siker → geometriai eloszlás.

## 12. Egyenletes eloszlás egy halmazon

- Feladat: Egy négyzetbe rajzoljunk be 20 “véletlen” pontot.
  - Mit jelent itt a “véletlen”?
1. próbálkozás: minden egyes pontnak ugyanakkora a valószínűsége → igen ám, de mivel végtelen sok pont van, ez a közös valószínűség csak 0 lehet. Például annak a valószínűsége, hogy pont a négyzet középpontját választjuk ki, 0. Ugyanakkor ez nem lehetetlen. Ez paradox, de nem ellentmondás. Ezzel azonban még csak az egyes pontok valószínűségét definiáltuk, hogyan lehet halmazokra kiterjeszteni ezt?

2. próbálkozás: mekkora az esélye, hogy a véletlen pont a négyzet bal alsó negyedébe esik? A bal alsó negyed pontjainak valószínűségét kellene összeadni, de ez kontinuum sok nulla (ez különbözteti meg a természetes számoktól: ott láttuk, hogy nem lehet természetes számot “véletlenszerűen” választani, mert megszámlálhatóan végtelen sok nulla összege nulla. Viszont kontinuum sok nulla összege lehet pozitív)! Viszont nyilvánvaló, hogy ezt a valószínűséget  $\frac{1}{4}$ -nek szeretnénk definiálni. Ebből jön: a valószínűség legyen a területtel arányos!
- Az  $X$  véletlen pont egyenletes eloszlású az  $A$  (valahány dimenziós) halmazban, ha minden  $B$  részhalmaz esetén  $P(X \text{ B-be esik}) = \text{ter}(B)/\text{ter}(A)$ . Ez a definíció teljesíti a valószínűség axiómáit.
  - Példa: 1 méter sugarú céltáblára lövünk messziről, tegyük fel, hogy eltaláljuk.  
Mekkora az esélye, hogy pont a közepét találjuk el?  $\rightarrow 0$   
Mekkora az esélye, hogy a lövedék a középponttól pont fél méterre csapódik be?  $\rightarrow 0$   
Mekkora az esélye, hogy a lövedék a középponthez fél méternél közelebb csapódik be?  $\rightarrow \frac{1}{4}$
  - Ilyen eloszlással modellezhető pl. a buszra való várakozási idő (1 dimenzió), a csillagok elhelyezkedése az égbolton (2 dimenzió), a mazsolák elhelyezkedése a kalácsban (3 dimenzió).
  - Feladat: egy 1 méter hosszú botnak véletlenszerűen kiválasztjuk két pontját, majd ezekben a pontokban eltörjük. Adjuk meg, hogy milyen eloszlású lesz a 25 cm-nél rövidebb darabok száma!
  - Megoldás: Jelölje a két töréspontnak a bot bal végpontjától vett távolságát  $X$  és  $Y$ . Ez két véletlen szám 0 és 1 között. Az  $(X, Y)$  kétdimenziós pontnak tehát mindkét koordinátája véletlenszerű 0 és 1 között, és a két koordináta független. Ez azt jelenti, hogy  $(X, Y)$  egyenletes eloszlású az egységnyezetben. Tehát azt kell megvizsgálni, hogy a négyzet mely pontjai adnak 0, 1, ill. 2 25cm-nél rövidebb darabot. A végeredmény:  $\frac{1}{16}$  eséllyel 0,  $\frac{6}{16}$  eséllyel 1,  $\frac{9}{16}$  eséllyel 2 rövid darab keletkezik.
  - Buffon-féle tűprobléma. (Georges Buffon, 1733). Egy szoba padlóján a padlódeszkák egymással párhuzamosan futnak, szélességük egy egység.

Leejtünk egy szintén egy egység hosszú tűt. Mekkora a valószínűsége, hogy a tű metszi valamelyik két padlódeszka csatlakozási vonalát?

- **Megoldás:** a leesett tű helyzetét két adattal határozhatjuk meg: középpontjának a legközelebbi egyenestől vett  $X$  távolságával, és az egyenesek irányával bezárt  $\Gamma$  szögével. A véletlenszerű leejtés azt jelenti, hogy az  $(X, \Gamma)$  pár egyenletes eloszlású a  $[0, 1/2] \times [0, \pi/2]$  téglalapon. A tű pontosan akkor metszi a hozzá legközelebb eső egyenest, ha  $X \leq (\sin \Gamma)/2$ . Tehát a téglalapon belül az ezen pontok által meghatározott

tartomány területét kell kiszámítani, ami  $\int_0^{\pi/2} \frac{1}{2} \sin x \, dx = \frac{1}{2}$ . Tehát a

valószínűség:  $(1/2)/(\pi/4) = 2/\pi \approx 0,637$ . Ennek alapján, ha  $n$  kísérletből  $k$  esetben volt metszés, akkor  $\pi$  értékét közelíthetjük  $2n/k$ -val.

(<http://www.mste.uiuc.edu/reese/buffon/buffon.html>)

- **A vetület problémája.** Vizsgáljuk meg, hogy átlagosan mekkora lesz a tűnek a deszkák irányára vett vetülete! A tű vetületének hossza  $\cos \Gamma$ , tehát ennek az átlagos értékét kell meghatározni, amint  $\Gamma$  0 és  $\pi/2$  között fut. Az átlagos érték  $2/\pi$ , hiszen a  $[0, \pi/2] \times [0, 2/\pi]$  téglalapnak pont akkora a területe, mint a  $\cos x$  függvény alatti terület, éppen 1.

Ebből általánosítással kaphatjuk, hogy tetszőleges  $K$  kerületű konvex zárt görbét ledobva, vetülete átlagosan  $K/\pi$  hosszú lesz: egy  $a$  illetve  $b$  oldalhosszúságokkal rendelkező téglalapot (pl. radírt) véletlenszerűen leejtve, annak vetülete egyenlő lesz az  $a$  ill.  $b$  oldalak vetületeinek összegével. Az összeg átlagos értéke az átlagos értékek összege, így a vetület átlagosan  $2a/\pi + 2b/\pi = K/\pi$ . Ezt konvex sokszögre is elmondhatjuk: ha az összes oldal vetületét összeadjuk, akkor a sokszög vetületét kétszeresen kapjuk meg. Sokszögről határátmenettel tetszőleges görbére áttérhetünk.

- **Bertrand paradoxon** (Joseph Louis Bertrand, 1889). Egy körnek válasszuk ki véletlenszerűen egy húrját! Mekkora a valószínűsége, hogy a húr hosszabb lesz, mint a körbe írható szabályos háromszög oldala?
- Ez azért paradoxon, mert a “véletlen húrt” többféleképpen is definiálhatjuk, és a különböző definíciók más-más eredményt adnak.

Például:

- a) a körben véletlenszerűen választjuk a húr középpontját  $\rightarrow 1/4$
  - b) a körvonalon véletlenszerűen választjuk a húr két végpontját  $\rightarrow 1/3$
  - c) véletlenszerűen választunk egy irányt, majd az ilyen irányú húrok közül választunk véletlenszerűen  $\rightarrow 1/2$
  - d) a körben véletlenszerűen választunk egy pontot, majd egy arra illeszkedő irányt  $\rightarrow 0.609$
  - e) a körben két véletlen pontot választunk  $\rightarrow 0.745$ .
- A fenti kérdés azzal ekvivalens, hogy a húr metszi-e a fele akkora sugarú kisebb kört. Általánosításként belátható, hogy ha adott egy  $K$  konvex zárt görbe, és annak belsejében egy  $k$  másik konvex zárt görbe, akkor  $K$  egy véletlen húra  $\text{ker}(k)/\text{ker}(K)$  valószínűséggel metszi a belső görbét, ha a véletlenszerű választás azt jelenti, hogy először egy véletlen irányt választunk, majd az adott irányú húrok közül választunk véletlenszerűen.

Előadáson nem hangzott el, csak érdekességképp:

Monte-Carlo módszer:tegyük fel, hogy valamilyen véletlen kísérlettel kapcsolatos valószínűségben vagy várható értékben fellép egy ismeretlen mennyiség. Ekkor az ismeretlen mennyiséget közelíthetjük úgy, hogy a kísérletet sokszor elvégezzük, illetve véletlen számsorozatok segítségével szimuláljuk (ebből ered a kissé félrevezető "Monte-Carlo módszer" elnevezés, hiszen pl. egy játékkaszinó ruletteredményei felhasználhatók lennének ilyen szimulációkhoz). A fenti Buffon probléma is egy Monte-Carlo módszert ír le a  $\pi$  meghatározására (ennek azonban csak elméleti jelentősége van, hiszen a  $\pi$ -t egymillió tizedesjegy pontossággal más módszerekkel is meg lehet határozni).

Más területeken azonban a módszer nagyon hasznosnak bizonyult. Egy egyszerű példa: egy érmét 1000-szer feldobva azt látjuk, hogy 600-szor mutat fejet. Vajon tekinthetjük-e az érmét szabályosnak? Még ha nem is tanultunk semmi valószínűségi számítást, szimulációval meghatározhatjuk, hogy egy szabályos érménél mekkora az esélye, hogy 1000 dobásból vagy a fej vagy az írás legalább 600-szor jön ki. Ha ennek esélye pl. csak 1 ezrelék, akkor ésszerű feltételezni, hogy ez az egyenlőtlenség nem írható a véletlen számlájára, hanem az érme nem szabályos. Fontos alkalmazási terület még a numerikus integrálás (akár sok dimenzióban): kíváncsiak vagyunk pl. a  $(0,1)$  intervallumon az  $f(x)$  nemnegatív függvény alatti területre. Ha tudjuk, hogy ezen az intervallumon az  $f(x)$  maximuma legfeljebb  $C$ , akkor véletlenszerűen választva egy  $(0,1)$ -beli  $X$ -et és egy  $(0,C)$ -beli  $Y$ -t, ellenőrizhetjük, hogy  $Y < f(X)$  teljesül-e. Ha  $n$  kísérletből ez  $k$ -szor teljesül, akkor a területet közelíthetjük a  $kC/n$  képlettel.

Ehhez természetesen kell, hogy a mai számítógépek nagyon jó véletlenszám-generátorokkal rendelkeznek, melyek ugyan csak pszeudovéletlen számokat állítanak elő, de a kapott sorozatok ugyanolyan tulajdonságokkal rendelkeznek, mint a valódi véletlen (pl. Mersenne twister, 1997).



## 13. A szimmetrikus bolyongás

- **Az egyszerű szimmetrikus bolyongás 1 dimenzióban:** Tegyük fel, hogy egy részecske a (függetlenül elhelyezett) valós számegegyenes origójából kiindulva időegységenként lép egy egységnyit úgy, hogy minden alkalommal az előző lépésektől függetlenül, véletlenszerűen választ, hogy felfelé vagy lefelé lépjen.

Jelölje a  $k$ . lépést  $X_k$ , ekkor  $P(X_k = 1) = P(X_k = -1) = 1/2$ .

- $n$  lépés után a részecske az  $S_n = X_1 + X_2 + \dots + X_n$  helyen tartózkodik. Ha egy kétdimenziós koordinátarendszerben ábrázoljuk az  $(n, S_n)$  pontokat, képet kapunk a részecske által megtett útról.

- **Általánosítási lehetőségek:** a bolyongás

- Nem egyszerű, ha a lépéshosszak egytől különböző értékeket is felvehetnek.
- Nem szimmetrikus, ha a pozitív illetve negatív irányú lépések nem egyforma valószínűségűek. (Lásd “Cliff hanger,” <http://www.mste.uiuc.edu/activity/cliff/>)
- Több dimenziós, pl.  $m$  dimenzióban a részecske a  $2m$  darab szomszédos rácspont valamelyikére lép.

- **Alkalmazások (pl):**

1. Modellizhetjük egyszerű szimmetrikus bolyongással egy szavazatszámítás folyamatát (ilyenkor az út végpontja rögzített).
2. Növények magasságának növelésére irányuló kezelésnél, ha a kezelés hatástalan, akkor a kezelt illetve a kezeletlen növénycsoport egyedei véletlenszerűen követik egymást a nagyság szerinti sorrendben (az út végpontja most is rögzített).
3. Egy szabályos érmét dobálva, a dobások folyamatát szimmetrikus bolyongással írhatjuk le.

- **Alapok:**  $n$  hosszúságú útból  $2^n$  darab van, ezek mindegyike egyformán


valószínű. Az  $(n, a)$  pontba vezető utak száma  $N_{n, a} = \binom{n}{p}$ , ahol

$p = (n+a)/2$  a felfelé tett lépések száma. (Vegyük észre, hogy ha  $n$  és  $a$  különböző paritású, akkor  $N_{n, a} = 0$ .)

- **A tükrözési elv:** Legyen  $A = (m, a)$ ,  $B = (n, b)$ ,  $a, b > 0$ ,  $n > m \geq 0$ .  
Legyen  $A$  tükörképe az  $x$ -tengelyre  $A' = (m, -a)$ . Ekkor az  $A$ -ból  $B$ -be vezető,  $x$ -tengelyt érintő utak száma megegyezik az összes  $A'$ -ből  $B$ -be vezető út számával.
- Bizonyítás: A kétféle út között kölcsönösen egyértelmű megfeleltetés létesíthető úgy, hogy az  $x$ -tengely első érintéséig terjedő útszakaszt tükrözzük.
- **Következmény** (szavazási lemma): Tegyük fel, hogy egy választáson két jelölt indult,  $A$  és  $B$ .  $A$  összesen  $p$  szavazatot kapott,  $B$  pedig  $q$  szavazatot, és  $p > q$ . Ekkor annak a valószínűsége, hogy a szavazatszámítás folyamán végig az  $A$  jelölt vezet (szavazategyenlőség sem megengedett),  $(p - q)/(p + q)$ .
- **Origóba való visszatérések:** legyen  $u_{2n} = P(S_{2n} = 0) = N_{2n, 0}/2^n$ . ( $u_0 = 1$ )  
A Stirling formula alapján nagy  $n$ -re  $u_{2n} \sim 1/\sqrt{\pi n}$ . ( $n! \approx \sqrt{2\pi n} n^{n+0.5} e^{-n}$ )  
Pl.  $u_{20} \approx 0,18$ ,  $u_{100} \approx 0,08$ ,  $u_{500} \approx 0,035$ ,  $u_{2000} \approx 0,018$ .

1. Lemma:  $P(S_1 \geq 0, S_2 \geq 0, \dots, S_{2n} \geq 0) = u_{2n}$ .

Bizonyítás: kölcsönösen egyértelmű megfeleltetéssel. Ha van egy olyan utunk, amely  $2n$  lépés alatt az origóba tér vissza, abból az első minimumpontig vezető szakaszt vágjuk le, tükrözzük a függőleges tengelyre, és ragasszuk az út végéhez. Az origót a kapott út kezdőpontjához tolva, egy nemnegatív utat kapunk. Fordítva, ha van egy nemnegatív utunk, amelynek végpontja a  $(2n, 2a)$  pont, akkor keressük meg az  $a$  szint utolsó elérését, az út ezutáni szakaszát vágjuk le, tükrözzük a függőleges tengelyre, és ragasszuk az út elejéhez. Az origót a kapott út kezdőpontjához tolva, egy origóba visszatérő utat kapunk.



2. Lemma:  $P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n} \neq 0) = u_{2n}$ .

Bizonyítás:  $P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n} \neq 0) = 2P(S_1 > 0, S_2 > 0, \dots, S_{2n} > 0)$ .

Viszont  $P(S_1 > 0, S_2 > 0, \dots, S_{2n} > 0) = 0.5 P(S_1 \geq 0, S_2 \geq 0, \dots, S_{2n-1} \geq 0)$ ,

hiszen az első lépés felfelé kell történjen, majd az origót az  $(1,1)$  pontba tolvá,

egy  $2n - 1$  hosszú, nemnegatív útnak kell következnie. De  $P(S_1 \geq 0, S_2 \geq 0, \dots,$

$S_{2n-1} \geq 0) = P(S_1 \geq 0, S_2 \geq 0, \dots, S_{2n} \geq 0) = u_{2n}$ , hiszen  $2n - 1$  lépés alatt

páratlan számhoz érünk, tehát  $S_{2n-1} \geq 1$ , így a következő lépés nem tud

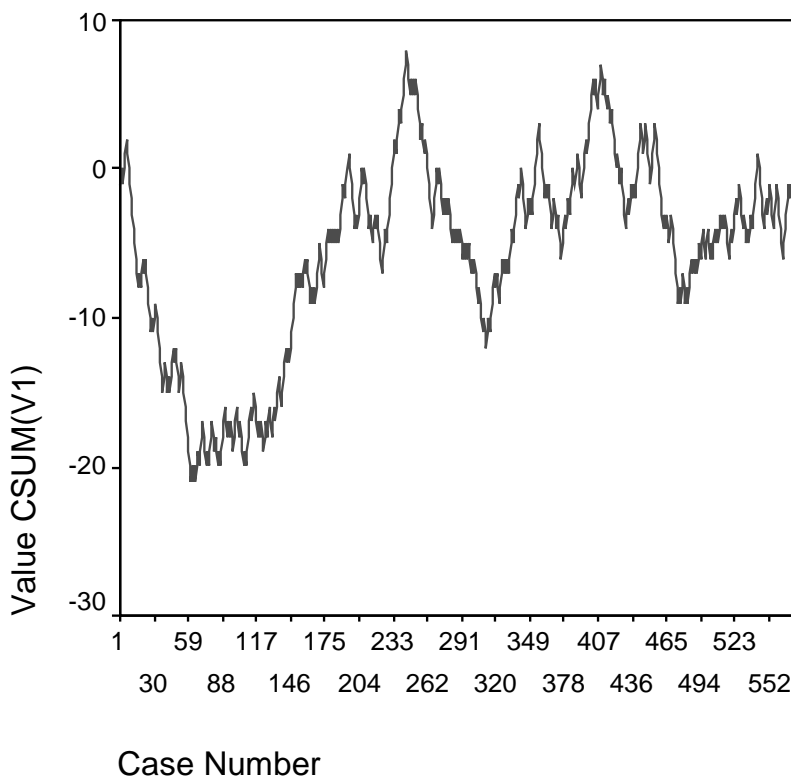
negatívba menni.

- Példa: egy szabályos érmét 100-szor feldobunk. A következő három eseménynek egyaránt kb. 8% a valószínűsége:
  - a 100 dobásból pont 50 fej, 50 írás
  - a dobássorozatban végig legalább annyi fejdobás van, mint írás
  - a dobássorozatban egyszer sem fordul elő, hogy pont ugyanannyi fej legyen, mint írás
- Következmény: jelölje  $f_{2n}$  annak valószínűségét, hogy a bolyongás először a  $2n$ . lépésben tér vissza az origóba, azaz  $f_{2n} = P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n-1} \neq 0, S_{2n} = 0)$ . Ekkor  $f_{2n} = P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n-2} \neq 0) - P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n-1} \neq 0, S_{2n} \neq 0) = u_{2n-2} - u_{2n} = u_{2n}/(2n - 1)$ . ( $f_0 = 0$ )  
Ebből a felírásból látszik, hogy  $f_2 + f_4 + f_6 + \dots = 1$ , azaz a bolyongás

előbb-utóbb visszatér az origóba (1 valószínűséggel).  $u_{2n}$  aszimptotikájából adódik azonban, hogy az első visszatéréshez szükséges lépések számának átlagos értéke minden előírt értéknél nagyobb, azaz végtelen:  $f_{2n} \approx 1/(2n\sqrt{\pi n})$

- Egy (szimulált) példa, a lépések száma 580. A bolyongás 28-szor járt az origóban, 466 lépést töltött a negatív oldalon, és 86-ot a pozitív oldalon.

## Véletlen bolyongás - 1



- Vizsgáljuk most azt a kérdést, hogy egy  $2n$  hosszú bolyongás mikor járt utoljára az origóban!

**Állítás:**  $\alpha_{2k,2n} := P(S_{2k} = 0, S_{2k+1} \neq 0, S_{2k+2} \neq 0, \dots, S_{2n} \neq 0) = u_{2k} u_{2n-2k}$

A bizonyítás az előző alkalom 2. lemmájából adódik, mivel

$$P(S_{2k} = 0, S_{2k+1} \neq 0, S_{2k+2} \neq 0, \dots, S_{2n} \neq 0) = P(S_{2k} = 0) \cdot P(S_1 \neq 0, S_2 \neq 0, \dots, S_{2n-2k} \neq 0)$$

0).  $u_{2n}$  aszimptotikájából kapjuk, hogy  $\alpha_{2k,2n} \sim \frac{1}{\pi \sqrt{k(n-k)}} = f(k/n)/n$ , ahol

$$f(x) = \frac{1}{\pi \sqrt{x(1-x)}} \quad (0 < x < 1).$$

Vegyük észre, hogy  $\alpha_{2k,2n} = \alpha_{2n-2k,2n}$ , azaz pl. egy 1000 hosszú útnál ugyanolyan valószínű, hogy a 100. lépésben járt utoljára az origóban, mint hogy a 900.-ban.

Az  $f(x)$  függvény integrálját ismerve  $(\frac{2}{\pi} \arcsin \sqrt{x})$  felírható, hogy közelítőleg

mekkora a  $p_y$  valószínűsége annak, hogy a bolyongás a teljes idő utolsó  $y$  százalékában nem járt az origóban:

$y\%$	$p_y$
97%	10%
90%	20%
80%	30%
65%	40%
50%	50%

- Következőnek azt vizsgáljuk meg, hogy a  $2n$  lépésből hány történt a pozitív oldalon!

**Állítás:**  $P(\text{a } 2n \text{ lépésből } 2k \text{ történt a pozitív oldalon}) = \alpha_{2k,2n}$

Ezt az eredményt nem bizonyítjuk. Állapítsuk meg összegzésként, hogy a szimmetrikus bolyongás nem az intuíciónknak megfelelően viselkedik: ritkán tér vissza az origóba, és nem közel azonos számú lépést tesz a pozitív illetve a negatív oldalon.

- Összehasonlításként azonban álljon itt az az

**Állítás:** Feltéve, hogy az út végpontját az origóban rögzítjük, azaz feltesszük, hogy  $S_{2n} = 0$ ,  $P(\text{a } 2n \text{ lépésből } 2k \text{ történt a pozitív oldalon}) = 1/(n+1)$  ( $k = 0, \dots, n$ ).

Ehhez kapcsolódik a növények magasságának növelésére irányuló kezelés hatékonyságának vizsgálata. Legyen  $r$  darab kezelt növény  $a_1 > a_2 > \dots > a_r$  magasságokkal, és  $r$  darab kezeletlen növény  $b_1 > b_2 > \dots > b_r$  magasságokkal. Ha a  $2r$  darab növény magasságát csökkenő sorrendbe állítjuk, majd az  $a$ -k és  $b$ -k váltakozását egy úttal ábrázoljuk (minden  $a$ -nál felfelé, minden  $b$ -nél lefelé lépünk), akkor hatástalan kezelés esetén egy egyszerű szimmetrikus bolyongás képét kell kapnunk. Nézzük meg, hogy hány olyan  $k$  index van, melyre  $a_k > b_k$ ! Éppen

feleannyi, mint ahány lépést az út a pozitív oldalon tett. Legutóbbi állításunk szerint tehát minden lehetőség egyformán valószínű.

1876-ban Francis Galton Charles Darwintól kapott adatokat vizsgált, ahol  $r = 15$  volt, és 13-szor voltak az  $a$ -k elől. Galton ez alapján hatásosnak minősítette a kezelést, pedig egy teljesen hatástalan kezelésnél is  $3/16 = 18,75\%$  az esélye, hogy az  $a$ -k legalább 13-szor vezetnek.

- **A tönkremenési probléma.** Van két játékos, az egyiknek 100, a másiknak 200 forintja. Fej vagy írás játékot játszanak, minden menetben a vesztes 1 forintot fizet a nyertesnek. Ezt addig folytatják, míg valamelyiküknek elfogy a pénze. Mik az egyes játékosok tönkremenési valószínűségei?
- A feladatot a szimmetrikus bolyongás segítségével lehet megoldani. Jelölje a két játékos összstőkéjét  $M$ , ez a játék folyamán változatlan. Legyen az első játékosnak  $k$  forintja, és jelölje  $p_k$  annak valószínűségét, hogy ő megy előbb tönkre. Ekkor

$$p_k = (p_{k+1} + p_{k-1})/2 \quad (k = 1, 2, \dots, M-1), \text{ és természetesen } p_0 = 1, p_M = 0.$$

Ennek az egyenletrendszernek a  $p_k = 1 - k/M$  lineáris függvény a megoldása.

- **Alkalmazás:** számítsuk ki, hogy a bolyongás az origóba való két visszatérés között átlagosan hányszor jár az  $a$  pontban!  
Annak valószínűsége, hogy egyáltalán eljut  $a$ -ba (mondjuk  $a > 0$ ): először felfelé kell lépni, majd onnan előbb jutni  $a$ -ba, mint 0-ba, azaz  $\frac{1}{2} * \frac{1}{a} = \frac{1}{2a}$ . Ha már eljutottunk  $a$ -ba, akkor annak valószínűsége, hogy többször már nem járunk ott az origóba való visszatérés előtt:  $\frac{1}{2} * \frac{1}{a} = \frac{1}{2a}$ . Minden  $a$ -ba való visszatérés után tehát  $\frac{1}{2a}$  az esélye, hogy ez az utolsó látogatásunk az adott szinten az origóba való visszatérés előtt.  
Az átlagos érték tehát:  $\frac{1}{2a} + \frac{1}{2a}(1-\frac{1}{2a}) + \frac{1}{2a}(1-\frac{1}{2a})^2 + \frac{1}{2a}(1-\frac{1}{2a})^3 + \dots = 1$ . Meglepő, de ez független attól, hogy melyik szintet vizsgáljuk. Az átlag úgy lehet mindig 1, hogy a távoli szintekre kis valószínűséggel jutunk el, de ha egyszer már eljutottunk, akkor sokáig maradunk ott. Ebből az eredményből is következik, hogy a visszatéréshez szükséges lépések átlagos száma végtelen.

- **Pár szó a többdimenziós bolyongásról:** A kétdimenziós bolyongás két független egydimenziós bolyongással ekvivalens (nézem a bolyongás vetületét a két „átlóra”). Ebből látszik, hogy annak valószínűsége, hogy  $2n$  lépésben visszatér a bolyongás az origóba, az egydimenziós valószínűség négyzetével egyezik meg, azaz  $1/n$  nagyságrendű.

Belátható, hogy a bolyongás akkor és csak akkor tér vissza előbb-utóbb biztosan az origóba, ha a visszatérési valószínűségek összege végtelen. A kétdimenziós bolyongás tehát visszatérő, a három- vagy többdimenziós azonban már nem!

## 14. A Galton-Watson-féle elágazó folyamat

- **Motiváció:** a XIX. században megfigyelték, hogy sok régi, szép családnév fokozatosan eltűnik, kihal. A nevek öröklődését modellező véletlen folyamatról 1874-ben Galton és Watson közölt alapvető cikket.

- **A modell:** Valamilyen egyedek (emberek, sejtek, stb.) egymást követő generációit vizsgáljuk. A 0. generáció egy tagú, ez az ős. Az ős véletlen számú utódot hoz létre, akik az 1. generációt alkotják. Az 1. generáció tagjai, egymástól függetlenül, újabb utódokat hoznak létre, ez lesz a 2. nemzedék. Az  $n$ . nemzedék az  $n - 1$ . nemzedék utódaiból áll.

Feltesszük, hogy az utódok számának eloszlása mindig ugyanaz. Jelölje ezt a véletlen mennyiséget  $X$ , lehetséges értékei a nemnegatív számok:

$k = 0, 1, 2, \dots$  A lehetséges értékekhez tartozó valószínűségeket jelölje

$p_k = P(X = k)$ . Azt, hogy egy egyednek átlagosan hány utódja lesz, jelölje

$m$ , azaz  $m = 0 \cdot p_0 + 1 \cdot p_1 + 2 \cdot p_2 + 3 \cdot p_3 + \dots$

Jelölje még az  $n$ . nemzedék tagjainak számát  $Z_n$ .

- **Kérdések:**

1. Átlagosan hány tagú az  $n$ . nemzedék, azaz mennyi  $E(Z_n)$ ?
2. Mekkora a valószínűsége, hogy  $Z_n = 0$ , azaz az  $n$ . nemzedékre a “család” kihalt?
3. Mekkora a valószínűsége, hogy van olyan  $n$ , melyre  $Z_n = 0$ , azaz a család előbb-utóbb kihalt?

4. Átlagosan hányadik nemzedéknél hal ki a család? (Jelölje a kihalás idejét  $T$ , azaz  $T$  a legkisebb olyan  $n$ , melyre  $Z_n = 0$ .)

- Ezt a folyamatot a legkényelmesebben a **generátorfüggvény** segítségével lehet vizsgálni. A definíció a következő: A fenti  $X$  véletlen mennyiség generátorfüggvénye:  $g(z) = z^0 * p_0 + z^1 * p_1 + z^2 * p_2 + z^3 * p_3 + \dots$ , ahol  $z$  egynél kisebb abszolút értékű szám (ilyenkor a sor biztosan konvergens, és  $|g(z)| < 1$ ). Vegyük észre, hogy ez éppen a  $z^X$  mennyiség átlagos értéke. Könnyű látni, hogy  $g(0) = p_0$ ,  $g(1) = 1$ . A generátorfüggvényt tagonként deriválhatjuk, azaz  $g'(z) = 1 * z^0 * p_1 + 2 * z^1 * p_2 + 3 * z^2 * p_3 + \dots$ , amiből azt kapjuk, hogy  $g'(1) = m$ .

- **Válaszok:**

1. A 0. nemzedék mindig 1 tagú. Az első nemzedék átlagosan  $m$  tagú. Mivel az 1. nemzedék átlagosan  $m$  tagú, és minden tagnak átlagosan  $m$  utóda lesz, a 2. nemzedék átlagosan  $m^2$  tagú (ezt precízen is be lehet bizonyítani). A gondolatmenetet folytatva adódik, hogy az  $n$ . nemzedék átlagosan  $m^n$  tagú.
2. Jelölje az  $n$ . nemzedék tagszámának,  $Z_n$ -nek generátorfüggvényét  $g_n(z)$ . A fentiek szerint  $P(Z_n = 0) = g_n(0) =: q_n$ . Világos, hogy  $g_0(z) = z$ ,  $g_1(z) = g(z)$ . Belátható, hogy általában  $g_n(z) = g(g_{n-1}(z))$ . Azaz  $q_n = g(q_{n-1})$ .  
A bizonyítás vázlatosa: indukcióval,  $n = 1$ -re már tudjuk az állítást. Az  $n$ . nemzedék az 1. nemzedék  $n-1$ -edfokú utódaiból áll. Ha az 1. nemzedék  $k$  tagú, akkor az  $n$ . nemzedék létszáma:  $Z_n = Z_{n-1}^1 + Z_{n-1}^2 + \dots + Z_{n-1}^k$ , ahol az összeadandók függetlenek, és ugyanolyan eloszlásúak, mint  $Z_{n-1}$ . Ezt felemelve a  $z$  alapra, majd várható értéket véve – felhasználjuk, hogy függetlenek szorzatának a várható értéke megegyezik a várható értékek szorzatával – kapjuk, hogy ilyenkor  $E(z^{Z_n}) = g_{n-1}^k(z)$ . Az eddig leírt eseménynek a valószínűsége  $p_k$ . Ezekkel a valószínűségekkel súlyozva és összegezve, megkapjuk, hogy  $g_n(z) = g(g_{n-1}(z))$ .
3. Ha  $Z_n = 0$ , akkor természetesen minden  $l > n$  esetén  $Z_l = 0$  is igaz. Ezek az események tehát egyre bővebbek, és egyesítésük azt az eseményt adja ki, hogy a család előbb–utóbb kihal. Ha tehát a kérdéses valószínűséget  $q$  jelöli, akkor  $q = \lim q_n$ . Ha a  $q_n = g(q_{n-1})$  egyenletben  $n$  végtelenhez tart, akkor azt kapjuk, hogy  $q$  kielégíti a  $q = g(q)$  egyenletet. Láttuk, hogy az 1 mindig megoldás. Ha azonban  $m > 1$ , akkor van 1-nél kisebb pozitív megoldás is, és az adja meg a kihalás



valószínűségét (ábra: a  $g(z)$  függvényt felrajzolhatjuk annak alapján, hogy  $g(0) = p_0$ ,  $g(1) = 1$ ,  $g'(1) = m$ , és a függvény a  $(0,1)$  intervallumon monoton növekvő és konvex).

Ha  $m < 1$ , akkor a folyamat szubkritikus. (1 valószínűséggel kihal)

Ha  $m = 1$ , akkor a folyamat kritikus. (1 valószínűséggel kihal)

Ha  $m > 1$ , akkor a folyamat szuperkritikus. (1-nél kisebb valószínűséggel hal ki)

4. Belátható, hogy a szubkritikus esetben  $E(T) \leq 1/(1-m)$ , a kritikus esetben viszont  $E(T)$  végtelen.

- **Példa:** Ha az utódeloszlás binomiális:  $X \sim \text{Bin}(l, p)$ , akkor  $g(z) = (pz + 1 - p)^l$ , tehát a kihalás valószínűségét egy  $l$ -edfokú egyenlet megoldása adja.