

Pszudovéletlenség

A számítógépes számelmélet tárgya

Neal Koblitznek A Course in Number Theory and Cryptography

című könyvére épülő anyagának kiegészítése

Gyarmati Katalin, Sárközy András

Eötvös Loránd Tudományegyetem

2012

A számelmélet talán legfontosabb alkalmazása a véletlenség szimulációja. Megemlítjük, hogy gyakorlatilag minden számítógépes szoftvernek része egy véletlen szám táblázat. Ezek a táblázatok, számsorozatok rendszerint számelméleti eszközök felhasználásával készülnek. A pszeudovéletlenség legfontosabb alkalmazásai a numerikus analízishez, illetve a kriptográfiához kapcsolódnak. A továbbiakban viszonylag részletesen fogunk foglalkozni ezzel a két területtel.

1. Pszeudovéletlen $[0, 1)$ sorozatok alkalmazásai a numerikus analízisben

A pszeudovéletlenségnek számos megközelítése van (e jegyzetben a függelékben tárgyalunk néhányat). A sok megközelítés közül kiindulópontként az alábbi definíciót tekintjük:

1.1. Definíció. *Ha (x_1, x_2, \dots, x_n) olyan valós számokból álló (véges) sorozat, hogy $i = 1, 2, \dots, n$ esetén $0 \leq x_i < 1$, és az*

$$N(\alpha, \beta) = |\{i : 1 \leq i \leq n, \alpha \leq x_i < \beta\}|$$

jelölést bevezetve, bármely $0 \leq \alpha < \beta \leq 1$ esetén

$$\left| \frac{N(\alpha, \beta)}{n} - (\beta - \alpha) \right|$$

„kicsi” akkor azt mondjuk, hogy a sorozat egyenletes eloszlású $[0, 1)$ -ben.

Alkalmazástól függő, hogy a definícióban a „kicsi” alatt pontosan milyen korlátot értünk. Végtelen sorozat esetén a definíció egyszerűen tehető pontosabbá:

1.2. Definíció. Az (x_1, x_2, \dots) végtelen sorozat egyenletes eloszlású $[0, 1)$ -ben, ha $i = 1, 2, \dots$ esetén $0 \leq x_i < 1$, és az

$$N(\alpha, \beta, n) = |\{i : 1 \leq i \leq n, \alpha \leq x_i < \beta\}|$$

jelölést bevezetve, bármely $0 \leq \alpha < \beta \leq 1$ esetén

$$\lim_{n \rightarrow \infty} \left| \frac{N(\alpha, \beta, n)}{n} - (\beta - \alpha) \right| = 0.$$

A többdimenziós egyenletes eloszlás fontos szerepet játszik a pseudovéletlenség kritériumai között. Ezt ismertetjük most.

1.3. Definíció. Ha $\alpha, \beta \in [0, 1]^s$, $\alpha = (\alpha_1, \alpha_2, \dots, \alpha_s)$ és $\beta = (\beta_1, \beta_2, \dots, \beta_s)$, akkor azt mondjuk, hogy

$$\alpha \leq \beta,$$

ha α és β minden koordinátájára

$$\alpha_i \leq \beta_i \quad (i = 1, 2, \dots, s)$$

teljesül.

Az $(\mathbf{x}_1, \mathbf{x}_2, \dots)$ végtelen sorozat egyenletes eloszlású $[0, 1]^s$ -ben, ha $i = 1, 2, \dots$ esetén $\mathbf{x}_i \in [0, 1]^s$ és $\alpha, \beta \in [0, 1]^s$ vektorokra az

$$N(\alpha, \beta, n) = |\{i : 1 \leq i \leq n, \alpha \leq \mathbf{x}_i < \beta\}|$$

jelölést bevezetve, bármely $\alpha, \beta \in [0, 1]^s$, $(0, \dots, 0) \leq \alpha = (\alpha_1, \dots, \alpha_s) \leq \beta = (\beta_1, \dots, \beta_s) \leq (1, \dots, 1)$ esetén

$$\lim_{n \rightarrow \infty} \left| \frac{N(\alpha, \beta, n)}{n} - \prod_{j=1}^s (\beta_j - \alpha_j) \right| = 0.$$

A $[0, 1)$ sorozatok pszeudovéletlenségének egyik legelfogadottabb kritériuma a többdimenziós egyenletes eloszlást használja. E szerint egy (x_1, x_2, \dots) végtelen $[0, 1)$ sorozat pszeudovéletlen, ha minden $k \geq 1$ természetes számra az $((x_n, x_{n+1}, \dots, x_{n+k-1}) \in [0, 1)^k) : n = 1, 2, \dots$ sorozat egyenletes eloszlású a $[0, 1)^k$ kockában, ez az ún. „**serial teszt**”.

A pszeudovéletlen $[0, 1)$ sorozatokhoz irodalom: I. M. Szobol: A Monte-Carlo módszerek alapjai [18] vagy D. E. Knuth: A Számítógépprogramozás művészete [8].

A pszeudovéletlen $[0, 1)$ sorozatok legfontosabb alkalmazása a **Monte-Carlo módszerhez** kapcsolódik. E fogalomnak nincsen szigorú matematikai definíciója, de nagyjából elfogadható a következő definíció:

1.4. Definíció. *Monte Carlo módszerről akkor beszélünk, ha egy kiszámítandó mennyiség értékét az alábbi úton becsüljük: keresünk olyan ξ va-*

lőszínőségi változót, amelynek várható értéke a : $M(\xi) = a$. Ezután ξ értékeire nagyszámú független megfigyelést végzünk, a kapott értékek legyenek $\xi_1, \xi_2, \dots, \xi_N$. Ekkor a -t $\frac{1}{N} \sum_{i=1}^N \xi_i$ -vel közelítjük:

$$a \approx \frac{1}{N} \sum_{i=1}^N \xi_i.$$

(Ezt a tényt indokolja, hogy a jobb oldal várható értéke a .)

Fontos speciális eset az $[a, b]$ zárt intervallumon Riemann integrálható $f(x)$ függvény integráljának becslése:

$$I = \int_a^b f(x) dx \approx \frac{1}{N} \sum_{i=1}^N f(\xi_i)(b - a).$$

(A függelékben részletesen vizsgáljuk a többváltozós integrálokat is.)

Tegyük fel az egyszerűség kedvéért, hogy $[a, b] = [0, 1]$. Ekkor a gyakorlatban ezt a módszert úgy alkalmazzuk, hogy tekintünk egy pszeudovéletlen (x_1, x_2, \dots, x_n) sorozatot, ahol $0 \leq x_i \leq 1$, kiszámoljuk $f(x_1), f(x_2), \dots, f(x_n)$ -et, és I -t

$$I \approx \frac{1}{N} \sum_{i=1}^N f(x_i)$$

-vel közelítjük.

Mint már említettük a pszeudovéletlen struktúrák általában valamilyen **számelméleti konstrukcióval** készülnek; néhány kivételes esetben előre tudjuk, hogy a megkonstruált sorozat rendelkezik valamilyen véletlen tulajdonsággal vagy tulajdonságokkal (ilyenkor „apriori” vagy „elméleti” tesztről

beszélünk), az esetek többségében azonban az elkészült sorozatot utólag tesztelik valamilyen valószínűségszámítási módszerrel („apozteriori” vagy „empirikus teszt”).

A legfontosabb módszer pszeudovéletlen $[0, 1)$ sorozat készítésére a **lineáris kongruencia módszer**, mely D. H. Lehmertől (1949) és Neumann Jánostól ered.

1.5. Definíció. *Lineáris kongruencia módszer* pszeudovéletlen $[0, 1)$ sorozat készítésére az alábbi: mondjuk N hosszúságú pszeudovéletlen $[0, 1)$ sorozatot akarunk készíteni. Ehhez célszerű először valamely N -nél „kicsit nagyobb” m számot választani, majd még további három $(\in \mathbb{Z})$ paramétert: A , $a(\not\equiv 0 \pmod{m})$, b . Ezután képezzük az y_1, y_2, \dots, y_N sorozatot a következő rekurzióval:

$$y_1 \equiv A \pmod{m} \quad 0 \leq y_1 < m$$

és

$$y_{n+1} \equiv ay_n + b \pmod{m}, \quad 0 \leq y_{n+1} < m \quad (1)$$

$$n = 1, 2, \dots, N - 1 \text{ esetén.}$$

Legyen továbbá $i = 1, 2, \dots, N$ esetén $x_i = \frac{y_i}{m}$. H. Niederreiter [14], [15], [16] igazolta, hogy bizonyos paraméter választások mellett az így konstruált (x_1, x_2, \dots, x_N) sorozat kielégíti a serial tesztet (tehát ez apriori teszt), és így tekinthető pszeudovéletlen $[0, 1)$ sorozatnak.

1.1. Példa. Ha $y_1 = A = m - 1$, $a = -1$, $b = 0$, akkor indukcióval igazolható, hogy


$$y_n \equiv (-1)^n \pmod{m} \quad (n = 1, 2, \dots),$$

ahonnan következik, hogy

$$y_{2k} = 1, \quad y_{2k+1} = m - 1,$$

és így

$$x_{2k} = \frac{y_{2k}}{m} = \frac{1}{m}, \quad x_{2k+1} = \frac{y_{2k+1}}{m} = 1 - \frac{1}{m} :$$



(minden $k \in \mathbb{N}$ -re),
tehát a sorozat nincs egyenletesen eloszolva $[0, 1)$ -ben.

Könnyű belátni a skatulyaelvvel (HF), hogy az (x_1, x_2, \dots) sorozat mindig periodikus; ha a periódus kicsi (mint a példában) a sorozat nem jó, ha a periódus nagy („nem sokkal kisebb” m -nél), akkor a sorozat Niederreiter [14], [15], [16] eredménye szerint jó, abban az értelemben, hogy kielégíti a serial tesztet.

A lineáris kongruencia módszert tovább lehet fejleszteni a következőképpen: annak definíciójában szerepelt az (1), a rekurziót definiáló kongruencia, ami $y_{n+1} \equiv f(y_n) \pmod{m}$ alakban írható, ahol $f(x)$ egy lineáris polinom.

Ez a konstrukció általánosítható úgy, hogy $f(x)$ gyanánt magasabbfokú polinomokat is vehetünk. Ez természetesen némi többletmunkával jár, és nehezebben bizonyítható, hogy a megkonstruált sorozat erős pseudovéletlen tulajdonságokkal rendelkezik, de ezért bőven kárpótol, hogy így „még véletlenszerűbb” sorozatokat konstruálunk.

2. Pseudovéletlen bináris sorozatok, alkalmazásuk a kriptográfiában

Irodalom: A Menezes, P van Oorschot, S. Vanstone: Handbook of Applied Cryptography, (internetről letölthető) [13].

Talán a legfontosabb, ténylegesen használt titkosítási rendszer az un. „**Vernam cipher**”, melyet a XX. század második évtizedében fejlesztett ki Vernam amerikai matematikus.

2.1. Definíció. ((Vernam cipher)) : először a továbbítandó információt kifejezzük („címkézzük”) egy bitsorozat formájában: (a_1, a_2, \dots, a_N) ($a_i \in \{0, 1\}$, $i = 1, 2, \dots, N$ -re). Ezután tekintünk egy (e_1, e_2, \dots, e_N) **véletlen** vagy esetleg **pseudovéletlen** N hosszú bitsorozatot (akkor véletlen, ha $\{0, 1\}^N$ -ből bármely sorozatot $\frac{1}{2^N}$ valószínűséggel választunk: ez az un. „one time pad” (egyszer használatos kulcs)). Ekkor az f titkosítási transzformáció

(e_1, e_2, \dots, e_n) -nek (a_1, a_2, \dots, a_N) -hez való bitenkénti modulo 2 hozzáadása:

$$\begin{aligned} & (a_1, \dots, a_N) \\ & \oplus \underline{(e_1, \dots, e_N)} \\ & = (b_1, \dots, b_N). \end{aligned}$$

2.1. Példa.

$$\begin{aligned} (0111001) & \leftarrow \text{titkosítandó információ} \\ \oplus \underline{(1110010)} & \leftarrow \text{kulcs} \\ = (1001011) & \leftarrow \text{titkosított szöveg ("ciphertext")} \end{aligned}$$

Az elolvasási transzformáció: még egyszer alkalmazni f -et.

Ismeretes, hogy ez a titkosítási rendszer - (e_1, e_2, \dots, e_N) -et valóban véletlenül választva - feltörhetetlen.

Követelmény, hogy az (e_1, e_2, \dots, e_N) kulcs bitsorozat valóban **véletlen** jellegű legyen.

2.2. Definíció. *Egy véletlen bit generátor egy olyan készülék vagy algoritmus, mely statisztikusan független és torzítatlan („unbiased”) biteket állít elő.*

Régen tipikusan hardware bázisú generátorokat (pl. dióda) használtak, de software bázisú generátorok (gépítő, memórianagyság, s í.t.) is lehetségesek;

valamelyik módszerrel előállítanak egy bitsorozatot, és utána ezt tesztelik bizonyos statisztikai tesztekkel (tehát **aposteriori tesztelést** végeznek). Ez igen komplikált, nehézkes és nem kielégítő technika. Ezért ma már a véletlen bit generátorokat **pszeudovéletlen** bit generátorokkal helyettesítik.

2.3. Definíció. *Egy Pszeudovéletlen bit generátor egy olyan determinisztikus algoritmus, mely egy valóban véletlen k hosszú bináris sorozatot megadva, abból egy ℓ (mely k -nál sokkal nagyobb) hosszú „véletlenszerűnek látszó” bináris sorozatot készít. Az „input” k hosszú véletlen bináris sorozatot „magnak” („seed”), a készült ℓ hosszú „output” sorozatot **pszeudovéletlen bit sorozatnak** nevezzük.*

(Természetesen a bit sorozatok, azaz 0, 1-ből álló sorozatok kölcsönösen egyértelműen megfeleltethetők bármely más két szimbólumból álló sorozatnak, ezért pl. vizsgálhatunk bit sorozat helyett $-1, +1$ -ből álló sorozatot; ez sokszor előnyös.)

De mitől „véletlenszerűnek látszó”, azaz, „jó” pszeudovéletlen sorozat egy bizonyos bináris sorozat? Az alkalmazástól (is) függ, milyen véletlen tulajdonságot díjazunk.

Egy kriptográfiában gyakran használt követelmény a megjósolhatatlanság („unpredictability”):

2.4. Definíció. *Azt mondjuk, hogy egy pszeudovéletlen generátor kielégíti*

a **következő bit tesztet**, ha nincs olyan „polinomiális idejű” algoritmus, mellyel az első k jegy ismeretében a $k + 1$ -edik $1/2$ -nél „lényegesen nagyobb” valószínűséggel megjósolható.

Kritikája: lényegében csak rekurzív konstrukciók minősítésére alkalmas, ezért lehet, hogy egy generátort elfogadunk, de pl. az első és utolsó bit ismeretében esetleg az egész sorozat egyértelműen meghatározott; polinomiális idejű algoritmus nem-létezése csak feltételesen igazolható; hogyan definiálható az, hogy $1/2$ -nél „lényegesen nagyobb”?

A legfontosabb, a következő bit tesztet (feltételesen) kielégítő konstrukció:

2.5. Definíció. A **Blum-Blum-Shub** pseudovéletlen generátor:

1. Tekintsünk két „nagy”, véletlen, $4k + 3$ alakú p, q prímet, legyen $n = pq$.

2. Tekintsünk egy véletlen a számot („mag”) $0 < a < n$, $(a, n) = 1$ -gyel.

Legyen x_0 az a^2 -nek modulo n legkisebb nem negatív maradéka.

3. Ha x_0, x_1, \dots, x_k már ismert, legyen x_{k+1} az x_k^2 -nek a modulo n vett maradéka.

4. Legyen z_i az x_i szám utolsó számjegye a 2-es alapú számrendszerben ($i = 1, 2, \dots, t$ esetén).

2.1. Állítás. A (z_0, z_1, \dots, z_t) bit sorozat (ahol t az n függvényében nem túl nagy) kielégíti a következő bit tesztet, feltéve, hogy $n (= pq)$ nagyságú számok faktorizálása számítástechnikailag nem lehetséges. (Nem bizonyítjuk.)

Megjegyezzük, hogy a bizonyítás során van szükség arra a feltételre, hogy p és q két $4k + 3$ alakú prím.)

Láttuk: a pszeudovéletlenség fenti definíciója („következő bit teszt”) a gyakorlatban nem igazán kielégítő. Ezért 1997-től kezdődően kifejlesztésre került bináris sorozatok pszeudovéletlenségének egy új, a korábbinál konstruktívabb, gyakorlati célokra alkalmasabb elmélete. Bevezetésre kerültek bináris sorozatok bizonyos tulajdonságainak véletlen jellegét mérő mértékek (az „eloszlási mérték”, „ k -adrendű korreláció”, ld. függelék); ha e mértékek „kicsik”, akkor a sorozatot „jó” pszeudovéletlen sorozatnak tekintjük. (Ezt azért tehetjük meg, mert majdnem minden sorozatra ezek a mértékek kicsik.) Sikertült megkonstruálni néhány nagy családját olyan bináris sorozatoknak, melyekre e pszeudovéletlen mértékek „kicsik”, vagyis e sorozatok **bizonyítottan** (tehát „apriori tesztelten”) „jó” pszeudovéletlen sorozatok. A következőkben a legfontosabb ilyen konstrukciók közül említék néhányat:

2.1. Konstrukció. (Goubin, Mauduit, Sárközy [3]) *Tegyük fel, hogy N hosszúságú pszeudovéletlen bináris sorozatot szeretnénk konstruálni. Legyen p olyan prím, amelyre $2N < p$ és a 2 primitív gyök modulo p . (ilyen p prím várhatóan nem sokkal $2N$ után, például általában $4N$ -ig van.) Legyen $f(x) \in \mathbb{Z}[x]$ olyan polinom, melynek foka „nem túl nagy” p függvényében (például a fok $< p^{1/10}$), és melynek nincs többszörös gyöke. Ekkor*

$E_N = (e_1, e_2, \dots, e_N)$ sorozat elemeit az

$$e_n = \begin{cases} \left(\frac{f(n)}{p}\right), & \text{ha } p \nmid f(n), \\ 1, & \text{ha } p \mid f(n) \end{cases}$$

képlettel definiáljuk, ahol $\left(\frac{x}{p}\right)$ a Legendre szimbólum. $E_N = (e_1, e_2, \dots, e_N)$ **bizonyítottan „jó”** pszeudovéletlen sorozat. (Annak mély oka van, hogy miért kell 2-nek primitív gyöknek lennie modulo p .)

2.2. Konstrukció. (Mauduit, Sárközy [12]) Legyen p prím, $f(x) \in \mathbb{Z}[x]$ olyan polinom, amelynek a foka „nem túl nagy” p függvényében, és amelynek nincs többszörös gyöke. Jelöljük n legkisebb nemnegatív maradékát modulo p $r_p(n)$ -nel, és legyen $(a, p) = 1$ esetén a multiplikatív inverze modulo p az a^{-1} : $aa^{-1} \equiv 1 \pmod{p}$ (fix p -re). Ekkor e_n -et

$$e_n = \begin{cases} +1, & \text{ha } (f(n), p) = 1 \text{ és } r_p(f(n)^{-1}) \leq p/2, \\ -1, & \text{ha vagy } (f(n), p) = 1 \text{ és } r_p(f(n)^{-1}) > p/2 \text{ vagy } p \mid f(n) \end{cases}$$

képlettel definiálva, $E_p = (e_1, e_2, \dots, e_p)$ **bizonyítottan „jó”** pszeudovéletlen sorozat.

E két konstrukció nagy előnye, hogy egyrészt gyorsan implementálhatók, másrészt a konstruált sorozatok pszeudovéletlen mértékei jól becsülhetők. (A két konstrukció közül talán a Legendre szimbólumra épülő valamivel jobb.) E két konstrukción kívül ma már számos más konstrukció ismert, amelyek

viszonylag jól implementálhatók, és a pszeudovéletlen mértékek is viszonylag jól becsülhetők. Ezek közül ismertetünk két további konstrukciót.

2.3. Konstrukció. (Gyarmati [5]) Legyen p prím, g primitív gyök modulo p . Amennyiben $(n, p) = 1$ definiáljuk $\text{ind } n$ -et azzal a legkisebb pozitív egésszel, amelyre

$$n \equiv g^{\text{ind } n} \pmod{p}.$$

Ekkor $1 \leq \text{ind } n \leq p - 1$. Legyen $f(x) \in \mathbb{Z}[x]$ olyan polinom, amelynek a foka „nem túl nagy” p függvényében, és amelynek nincs többszörös gyöke.

Ekkor $E_p = (e_1, e_2, \dots, e_p)$ sorozat n -edik elemét

$$e_n = \begin{cases} +1 & \text{ha } (f(n), p) = 1 \text{ és } 1 \leq \text{ind } f(n) \leq p/2, \\ -1 & \text{ha vagy } (f(n), p) = 1 \text{ és } p/2 < \text{ind } f(n) < p \text{ vagy } p \mid f(n) \end{cases}$$

képlettel definiálva, azt kapjuk, hogy az $E_p = (e_1, e_2, \dots, e_p)$ sorozat **bizonyítotlan „jó”** pszeudovéletlen sorozat.

Megjegyezzük, hogy ez a konstrukció lassabban implementálható mint az előző kettő, de ezen némi munkával lehet javítani:

2.4. Konstrukció. (Gyarmati [4], [6]) Definiáljuk p -t, g -t, $\text{ind } n$ -et és $f(x) \in \mathbb{Z}[x]$ -et úgy, ahogy a 2.3. Konstrukcióban. Legyen továbbá m páros szám $p - 1$ -nek egy kicsi pozitív osztója. Jelölje ind^*n azt a számot, amelyre

$$\text{ind}^*n \equiv \text{ind } n \pmod{m} \quad \text{és } 1 \leq \text{ind}^*n \leq m.$$

Ekkor $E_p = (e_1, e_2, \dots, e_p)$ sorozat n -edik elemét

$$e_n = \begin{cases} +1 & \text{ha } (f(n), p) = 1 \text{ és } 1 \leq \text{ind}^* f(n) \leq m/2, \\ -1 & \text{ha vagy } (f(n), p) = 1 \text{ és } m/2 < \text{ind}^* f(n) \leq m \text{ vagy } p \mid f(n) \end{cases}$$

képlettel definiálva, azt kapjuk, hogy az E_p sorozat **bizonyítottan „jó”** pszeudovéletlen sorozat.

F. Függelék

Az alábbiakban az elmélyedni kívánóknak ismertetek néhány további részletet. Az F.1. és F.2. fejezetben Niederreiter, *Quasi-Monte Carlo methods and pseudorandom numbers* című cikke alapján [17] adunk rövid ismertetőt a többdimenziós Monte-Carlo módszerekről és a pszeudovéletlen $[0, 1)$ sorozatokról. Az F.3. fejezetben a bináris sorozatok pszeudovéletlenségét tanulmányozzuk.

F.1. Monte Carlo módszerek több dimenzióban

Legyen f egy s változós függvény, amelyet $I^s = [0, 1)^s$ -en szeretnénk integrálni. Tegyük fel, hogy x_1, x_2, \dots, x_N véletlen pontok I^s -ben, amelyeket egymástól függetlenül választunk. Ekkor az

$$\int_{I^s} f(t) dt \tag{2}$$

integrált az

$$\frac{1}{N} \sum_{n=1}^N f(x_n) \quad (3)$$

értékkel közelítjük. Azt várjuk, hogy amint az x_i pontok számát növeljük, a

(3) kifejezés értéke (2)-höz tart, azaz

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N f(x_n) = \int_{I^s} f(t) dt. \quad (4)$$

A következőkben szeretnénk megadni az f függvényeknek és az (x_1, x_2, \dots) sorozatoknak egy olyan nagy családját, amelyre (4) ténylegesen fenn áll. Viszonylag könnyen igazolható, hogy ilyen nagy családot ad például az I^s -en folytonos f függvények halmaza és azon (x_1, x_2, \dots) sorozatok halmaza, amelyek egyenletes eloszlásúak I^s -ben. Valójában azonban több is igaz: ha (x_1, x_2, \dots) egyenletes eloszlású I^s -ben, akkor (4) az összes Riemann integrálható f függvényre fenn áll. (Másképpen (4) nem áll fenn az összes Lebesgue integrálható függvényre, legyen pl. $f(x) = 1$ ha $x \in \{x_1, x_2, \dots\}$ és $f(x) = 0$ különben.)

A Monte-Carlo módszerek tovább általánosíthatóak I^s részhalmazaira. Azaz nagyon általános f -re és $E \subseteq I^s$ -re vonatkozó feltételek mellett teljesül, hogy ha (x_1, x_2, \dots) sorozat egyenletes eloszlású I^s -ben, akkor

$$\lim_{N \rightarrow \infty} \frac{1}{N} \sum_{n=1}^N \chi_E(x_n) f(x_n) = \frac{1}{|E|} \int_E f(t) dt,$$

ahol $\chi_E(x_n) = 1$ ha $x_n \in E$ és $\chi_E(x_n) = 0$ ha $x_n \notin E$, továbbá $|E|$ az E halmaz Lebesgue mértékét jelöli.

Általában - a gyakorlati alkalmazások során - azonban csak véges sok x_i pontunk van. Ezért szükség van egy mértékre amely azt méri, hogy adott véges sok pont „mennyire egyenletes eloszlású” I^s -ben.

F.1. Definíció. Jelölje \mathcal{J} az I^s részintervallumainak halmazát, azaz $\mathcal{J} = \{J : J = [a_1, b_1] \times [a_2, b_2] \times \dots \times [a_s, b_s], \text{ ahol } 0 \leq a_i \leq b_i < 1 \text{ minden } i\text{-re}\}$.

Legyen

$$A(J, N) \stackrel{\text{def}}{=} \sum_{n=1}^N \chi_E(x_n),$$

ahol $\chi_J(x_n) = 1$ ha $x_n \in J$ és $\chi_J(x_n) = 0$ ha $x_n \notin J$. Ekkor a D_N diszkrepancia:

$$D_N = \sup_{J \in \mathcal{J}} \left| \frac{A(J, N)}{N} - |J| \right|,$$

ahol $|J|$ a J halmaz Lebesgue mértékét jelöli, azaz $J = [a_1, b_1] \times \dots \times [a_s, b_s]$ esetén $|J| = \prod_{i=1}^s (b_i - a_i)$.

A diszkrepancia segítségével jól karakterizálható az egyenletes eloszlás véges sok pont esetén. Így a diszkrepancia jól használható a Monte-Carlo módszerekben is, ahol a diszkrepancia segítségével becsülhető a $\int_{I^s} f(t) dt$ és a $\sum_{n=1}^N f(x_n)$ kifejezések eltérése. Minél kisebb az (x_1, x_2, \dots, x_n) sorozat diszkrepanciája, annál élesebb becslés adható a

$$\left| \int_{I^s} f(t) dt - \sum_{n=1}^N f(x_n) \right|$$

abszolút értékre. Ezért fontos, hogy minél több olyan (x_1, x_2, \dots) sorozatot találjunk, melynek a diszkrepanciája minél alacsonyabb. Ezeket a véges - vagy esetleg végtelen - sorozatokat alacsony diszkrepanciájú sorozatoknak nevezzük. Így az alkalmazások kapcsán felmerülő fontos kérdés, hogy mennyire lehet alacsony egy sorozat diszkrepanciája. Chung [2] és Kiefer [7] eredménye szerint majdnem minden (x_1, x_2, \dots, x_N) sorozatra

$$D_N = O(N^{-1/2}(\log \log N)^{1/2}). \quad (5)$$

A következőkben példákat mutatunk I -ben olyan (x_1, x_2, \dots, x_N) sorozatokra, amelyekre

$$D_N = O(N^{-1/2} \log N). \quad (6)$$

Legyen α egy irracionális szám, és legyen $x_i = \{i\alpha\}$. Ekkor (6) valóban fenn áll. A másik példa az úgynevezett van der Corput sorozat [19], amely két ok miatt is nagyon fontos. Egyrészt a diszkrepanciája alacsonyabb mint az előző sorozaté, másrészt ez a sorozat csupán n számjegyeit használja, így a módszer könnyen adaptálható bináris számítógépekre. A van der Corput sorozatot [19] a következőképp definiálják: Legyen $g \geq 2$ egy természetes szám. Ekkor minden pozitív egész n egyértelműen felírható

$$n = \sum_{i=0}^k a_i g^i$$

alakban, ahol $a_i \in \{0, 1, 2, \dots, g-1\}$. Legyen

$$\phi_g(n) = \sum_{i=0}^k a_i g^{-i-1}.$$

(Ekkor $0 \leq \phi_g(n) < 1$.) A van der Corput sorozat: $(\phi_g(0), \phi_g(1), \dots)$. Jelenleg nem ismert olyan sorozat, amelynek a diszkrepanciája alacsonyabb lenne, mint a van der Corput sorozaté. (Erre a sorozatra is bizonyított (6), ahol az ordóban szereplő implicit konstans a lehető legalacsonyabb a jelenleg ismert konstrukciók diszkrepanciájára adott felső becslések között.)

Számos erős konstrukció ismert a többdimenziós esetben is (azaz, amikor (x_1, x_2, \dots) sorozat elemei I^s -ből valók), azonban ezeknek a konstrukcióknak a definíciója komplikáltabb, mint a fenn említett két egydimenziós konstrukcióé. Ezért ezeket a konstrukciókat itt nem ismertetjük.

F.2. Pszeudóvéletlen $[0, 1)$ sorozatok

A Monte-Carlo módszerek során többnyire nem olyan - nagyon specifikus - sorozatot alkalmazunk, amelynek a diszkrepanciája a lehető legalacsonyabb, hanem úgynevezett pszeudóvéletlen sorozatokat. Ezt - többek közt - az is alátámasztja, hogy majdnem minden N hosszú sorozatra fenn áll (5), míg konkrét konstrukciókra bizonyítani csak a jóval gyengébb (6) állítást tudjuk. Ebben a fejezetben a pszeudóvéletlen $[0, 1)$ sorozatokat vizsgáljuk meg közelebbről. Ezeknek a sorozatoknak számos matematikai, fizikai és számí-

tástechnikai alkalmazása van.

Annak, hogy egy $[0, 1)$ sorozat véletlennek tűnjön az alkalmazások szempontjából, két fő kritériuma van:

- (i) A sorozatnak eleget kell tennie bizonyos eloszlási kritériumoknak.
- (ii) Ezeknek az eloszlási tulajdonságoknak invariánsnak kell maradnia akkor is, amikor csak bizonyos részsorozatokat vizsgálunk.

(7)

Knuth: A Számítógépprogramozás művészete című könyvében [8] részletesen tárgyalja ezeket a feltételeket. Minimális elvárás az egyenletes eloszlás I^s -ben, de ez nem feltétlen elegendő. Gondoljunk például a van der Corput sorozatra, ahol az alkalmazott α irracionális szám 0-hoz közeli pozitív szám. Ennél a sorozatnál az egymást követő bitek nagy valószínűséggel a $[0, \frac{1}{2})$ és $[\frac{1}{2}, 1)$ intervallumok közül ugyanabba esnek. Ennek alapján azt mondjuk, hogy egy (x_1, x_2, \dots) végtelen sorozat *teljesen* egyenletes eloszlású $[0, 1)$ -ben, ha az

$$((x_n, x_{n+1}, \dots, x_{n+s-1}) : n = 1, 2, \dots)$$

sorozat egyenletes eloszlású I^s -ben minden $s \geq 1$ egész számra (ld. az 1. fejezetben ismertetett serial teszt). Eddig még nem tárgyaltuk a pszeudovéletlenség (7)-ben említett (ii) elvét. Amennyiben minden részsorozatra megkövetelnénk a teljesen egyenletes eloszlást, úgy egyetlen pszeudovéletlen sorozat sem létezne, hiszen tekinthetjük például azt a részsorozatot, amely

$[0, \frac{1}{2})$ intervallumba eső elemeket tartalmazza; ez a sorozat nyilvánvalóan nem egyenletes eloszlású. Knuth: A Számítógépprogramozás művészete című könyvében [8] részletesen vizsgálja, hogy milyen részsorozatokra érdemes megkövetelni a teljesen egyenletes eloszlást.

Véges sorozatokra vonatkozó pszeudovéletlen vizsgálatok Kolmogorov: Three approaches to the definition of the concept „quality of information” című munkájára [9] épülnek. Ebben a megközelítésben akkor tekintünk egy sorozatot pszeudovéletlennek, ha csak „hosszú” programmal tudjuk leprogramozni egy Turing gépen.

Véges pszeudovéletlen sorozatokat generálnak fizikai módszerekkel is, azonban ezzel kapcsolatban felmerül néhány probléma: ilyen például az adatok tárolása vagy az, hogy szükséges a véletlenség gyakori ellenőrzése, mivel ezeket a sorozatokat nem számítógéppel generálták, hanem egy külső eszközzel.

A pszeudovéletlenség axiomatikusan bevezetett fogalmának a gyakorlati alkalmazások során derül ki egy gyenge pontja: nevezetesen egyetlen egy konkrét sorozat sem ismert, amely eleget tenne a kritériumoknak. Ezért úgy gondolják, hogy valójában elegendő azon sorozatokat vizsgálni, amelyek a gyakorlatban - számítógépek segítségével sem - nem különböztethetőek meg egy valódi véletlen sorozattól. Létezik néhány statisztikus teszt, amely ilyen szempontból vizsgálja a pszeudovéletlenséget. Ezek közül a tesztek közül

alább ismertetünk néhányat (több-kevesebb részletességgel):

Egyenletes eloszlás teszt. Minden N -re tekintjük a sorozat első N elemét: x_1, x_2, \dots, x_N . A sorozat állja a tesztet, ha ezen sorozatok D_N diszkrepanciája minden N -re kicsi. Egy alternatív módszerben I -t részintervallumokra osztjuk, és azt nézzük, hogy hány elem esik a különböző részintervallumokba. Az így kapott adatokra alkalmazunk egy χ^2 próbát. Ez az úgynevezett *gyakoriság teszt*.

Hézag teszt. Legyen J az I intervallumnak egy fix részintervalluma. Ha egy $n \geq 1$ -ra $x_{n-1} \notin J$ (vagy $n = 1$) és $x_n, x_{n+1}, \dots, x_{n+k-1} \notin J$ de $x_{n+k} \in J$, akkor k hosszú hézagról beszélünk. Rögzített h -ra összeszámoljuk a h -nál rövidebb és a h vagy annál hosszabb hézagok számát. Ezekre az eredményekre alkalmazunk egy χ^2 próbát.

A *Futás teszt* a monoton részsorozatokat vizsgálja. Hasonlóan definiálható még a *permutáció teszt*, a „*serial-correlation*” *teszt*, a *spektrál teszt* és az 1. fejezetben ismertetett *serial teszt*.

F.3. Bináris sorozatok

A 0-1 sorozatoknak kiemelt jelentősége van a kriptográfiai alkalmazások során. Például - a már ismertett - Vernam féle titkosító eljárás használ 0-1 sorozatokat. Amennyiben a kulcsként alkalmazott 0-1 sorozat valódi vélet-

lensorozat (azaz a sorozat bitjeit egymástól függetlenül választjuk és minden bit $\frac{1}{2} - \frac{1}{2}$ valószínűséggel 0 vagy 1) úgy az úgynevezett „*one-time pad*” titkosító eljárásról beszélünk. A one-time pad óriási előnye, hogy további feltétel nélküli, teljes biztonságot garantál. Így bizonyos értelemben tökéletes titkosító algoritmus. Az eljárás egyetlen hátránya, hogy a kulcsnak azonos hosszúnak kell lennie a titkosítandó üzenettel, viszont nagyon nehéz hosszú valódi véletlen sorozatot generálni.

Eleinte -a hidegháború idején- fizikai módszerekkel, például diódával generáltak bináris sorozatokat. S bár a tapasztalat azt mutatja, hogy az így módon generált sorozat valóban megfelelhet a matematikai modellnek, ezt nem tudjuk bizonyítani. A fizikai módszerrel történő véletlengenerálás további hátránya, hogy lassú és költséges folyamat. Ezért manapság számítógépekkel generálnak egy valódi véletlen kisebb titkos kulcsból egy hosszú „véletlennek tűnő” kulcsot, amely azonban várhatóan -még számítógépek segítségével sem- különböztethető meg egy valódi véletlen sorozattól. Azonban fontos megfogalmazni, hogy milyen véletlentulajdonságokat várunk egy ilyen módon konstruált pszeudovéletlen sorozattól.

1996-ban Christian Mauduit és Sárközy András [11] új, kvantitatív mértékeket vezetett be bináris sorozatok pszeudovéletlen tulajdonságainak vizsgálatára. A továbbiakban technikai okokból áttérünk a 0-1 sorozatokról a ± 1 sorozatok vizsgálatára. (A 0-1 és ± 1 sorozatok között egy-egy értelmű

megfeleltetés adható.)

F.2. Definíció. Legyen $E_N = (e_1, e_2, \dots, e_N) \in \{-1, +1\}^N$ egy N hosszú ± 1 sorozat. Ekkor az eloszlási mértéket a

$$W(E_N) = \max_{a,b,t} \left| \sum_{j=0}^t e_{a+jb} \right|$$

képlettel definiáljuk, ahol a maximum az összes olyan a, b, t -n fut, ahol $1 \leq a \leq a + tb \leq N$.

Az eloszlási mérték azt vizsgálja, hogy a számtani sorozatokban a $+1$ és -1 -ek száma mennyire közel van. Azonban előfordulhat, hogy a sorozatban több bit között áll fenn összefüggés, például $(+1, +1)$ részsorozat lényegesen többször fordul elő, mint a $(-1, -1)$ részsorozat. A több bit egymás közötti függetlenségének vizsgálatára vezette be Christian Mauduit és Sárközy András a normalitás és a korreláció fogalmát.

F.3. Definíció. Legyen $E_N = (e_1, e_2, \dots, e_N) \in \{-1, +1\}^N$ egy N hosszú ± 1 sorozat. $X = (x_1, x_2, \dots, x_k) \in \{-1, +1\}^k$ és $1 \leq M \leq N - k + 1$ esetén jelölje $T(E_N, M, X)$ a következő mennyiséget:

$$T(E_N, M, X) = |\{n : 1 \leq n \leq M, (e_n, e_{n+1}, \dots, e_{n+k-1}) = (x_1, x_2, \dots, x_k)\}|.$$

Ekkor a k -adrendű normalitás mértéket a

$$N_k(E_N) = \max_{M,x} \left| T(E_N, M, X) - \frac{M}{2^k} \right|$$

kifejezéssel definiáljuk, ahol a maximum az összes olyan pozitív egész M -en és X szám k -ason fut, ahol $1 \leq M \leq N - k + 1$ és $X = (x_1, x_2, \dots, x_k) \in \{-1, +1\}^k$.

Christian Mauduit és Sárközy András [11] igazolta, hogy a normalitás mérték felülről becsülhető a korreláció mértékekkel. Ezeket a mértékeket a következőképpen definiáljuk.

F.4. Definíció. Legyen $E_N = (e_1, e_2, \dots, e_N) \in \{-1, +1\}^N$ egy N hosszú ± 1 sorozat. Ekkor a k -adrendű korreláció mértéket a

$$C_k(E_N) = \max_{M,D} \left| \sum_{n=1}^M e_{n+d_1} e_{n+d_2} \cdots e_{n+d_k} \right|$$

képlettel definiáljuk, ahol a maximum az összes olyan M egész számon és $D = (d_1, d_2, \dots, d_k)$ szám k -ason fut, ahol $0 \leq d_1 < d_2 < \dots < d_k < M + d_k \leq N$.

Ekkor - Christian Mauduit és Sárközy András eredménye szerint -

$$N_k(E_N) \leq \max_{1 \leq t \leq k} C_t(E_N),$$

vagyis a korreláció segítségével a normalitás mérték jól becsülhető. (Ezért a legtöbb cikkben nem kezelik külön a normalitás mértéket.)

A kombinált mérték a k -adrendű korreláció és az eloszlási mérték általánosítása:

F.5. Definíció. Legyen $E_N = (e_1, e_2, \dots, e_N) \in \{-1, +1\}^N$ egy N hosszú

± 1 sorozat. Ekkor a k -adrendű kombinált mértéket a

$$Q_k(E_N) = \max_{a,b,t,D} \left| \sum_{j=1}^t e_{a+bj+d_1} e_{a+bj+d_2} \cdots e_{a+bj+d_k} \right|$$

képlettel definiáljuk, ahol a maximum az összes olyan a, b, t pozitív egész számon és $D = (d_1, d_2, \dots, d_k)$ szám k -ason fut, ahol az összes előforduló $a + bj + d_i$ index az $\{1, 2, \dots, N\}$ halmazba esik.

A fenti mértékeken túl is lehet definiálni pszeudóvéletlen mértékeket, azonban a túl sok mérték egyszerre nehezen kezelhető. Így a legtöbb alkalmazás során az eloszlási és korreláció mértékre szorítkoznak.

Az eloszlási és korreláció mérték maximuma N -hez közeli érték. J. Cassaigne, C. Mauduit és Sárközy A. [1] bebizonyította, hogy majdnem minden N hosszú sorozatra

$$W(E_N) < N^{1/2}(\log N)^c, \quad C_k(E_N) < N^{1/2}(\log N)^{c_k}$$

fenn áll. Ez alapján egy E_N sorozatot erős pszeudóvéletlen tulajdonságokkal rendelkezőnek nevezünk, ha

$$W(E_N) = o(N), \quad C_k(E_N) = o(N).$$

A 2. fejezetben ismertetett konstrukciók erős pszeudóvéletlen tulajdonságokkal rendelkeznek, ezekre az E_N sorozatokra

$$W(E_N) < N^{1/2}(\log N)^{c'}, \quad C_k(E_N) < N^{1/2}(\log N)^{c'_k}$$

valóban fenn áll.

A véges bináris sorozatok elméletéről számos cikk született, rohamosan fejlődik a terület. Számos hazai és külföldi kutató kutat jelenleg is. Mostanában a pszeudovéletlen sorozatok mellett a többdimenziós pszeudovéletlen rácsok is bekerültek a kutatás középpontjába.

Hivatkozások

- [1] J. Cassaigne, C. Mauduit és A. Sárközy, *On finite pseudorandom binary sequences VII: The measures of pseudorandomness*, Acta Arith. 103 (2002), 97-118.
- [2] K. L. Chung, *An estimate concerning the Kolmogoroff limit distribution*, Trans. Amer. Math. Soc. 67 (1949), 36-50.
- [3] L. Goubin, C. Mauduit és A. Sárközy, *Construction of large families of pseudorandom binary sequences*, J. Number Theory 106, (2004), 56-69, 2004.
- [4] K. Gyarmati, *A note to the paper "On a fast version of a pseudorandom generator"*, Ann. Univ. Sci. Budapest. Eötvös Sect. Math. 49 (2006), 143-149.

- [5] K. Gyarmati, *On a family of pseudorandom binary sequences*, Period. Math. Hungar. 49 (2004), 45-63.
- [6] K. Gyarmati, *On a fast version of a pseudorandom generator*, General Theory of Information Transfer and Combinatorics, Lecture Notes in Computer Science, Vol. 4123, Springer Berlin / Heidelberg 2006, 326-342,
- [7] J. Kiefer, *On large deviations of the empiric d.f. of vector chance variables and a law of the iterated logarithm*, Pacific J. Math. 11 (1961), 649-660.
- [8] D. E. Knuth, *A Számítógépprogramozás művészete*, 2. kötet, 2. kiadás, Műszaki Könyvkiadó, Budapest 1994.
- [9] Kolmogorov, *Three approaches to the definition of the concept „quality of information”*, Problemy Peredaci Informacii 1 (1965), 3-11 (oroszul).
- [10] D. H. Lehmer, *Mathematical methods in large-scale computing units*, Proc. 2nd Sympos. on Large-Scale Digital Calculating Machinery (Cambridge, MA, 1949), Harvard Univ. Press, Cambridge, MA, 1951, 141-146.

- [11] C. Mauduit és A. Sárközy, *On finite pseudorandom binary sequence I: Measures of pseudorandomness, the Legendre symbol*, Acta Arith. 82 (1997), 365-377.
- [12] C. Mauduit és A. Sárközy, *Construction of pseudorandom binary sequences by using the multiplicative inverse*, Acta Math. Hungar. 109 (2005), 75-107.
- [13] A Menezes, P van Oorschot, S. Vanstone, *Handbook of Applied Cryptography*, 1997, CRC Press Inc. (internetről letölthető).
- [14] H. Niederreiter, *On the distribution of pseudo-random numbers generated by the linear congruential method.*, Math. Comp. 26 (1972), 793-795.
- [15] H. Niederreiter, *On the distribution of pseudo-random numbers generated by the linear congruential method. II*, Math. Comp. 28 (1974), 1117-1132.
- [16] H. Niederreiter, *On the distribution of pseudo-random numbers generated by the linear congruential method. III*, Math. Comp. 30 (1976), 571-597.
- [17] H. Niederreiter, *Quasi-Monte Carlo methods and pseudorandom numbers*, Bull. Amer. Math. Soc. 84 (1978), 957-1041.

- [18] I. M. Szobol, *A Monte-Carlo módszerek alapjai*, Műszaki Könyvkiadó, Budapest, 1981.
- [19] J. G. van der Corput, *Verteilungsfunktionen, I,II*, Nederl. Akad. Wetensch. Proc. 38 (1935), 813-821, 1058-1066.