


Generatory liczb pseudolosowych

Plan wykładu:

- liniowe generatory o rozkładzie równomiernym
- generatory o dowolnym rozkładzie prawdopodobieństwa
 - metoda odwracania dystrybuanty
 - metoda eliminacji
 - rozkład dyskretny
- generatory o rozkładach wielowymiarowych
 - rozkład równomierny na sferze i kuli w R^M
 - dwuwymiarowy rozkład normalny
- testowanie generatorów
 - testy zgodności z rozkładem: χ^2

Generatory o rozkładzie równomiernym



Najprostsze generatory liczb losowych to generatory fizyczne wykorzystujące

- szумы układów elektronicznych
- promieniotwórczość
- zalety: dostajemy ciągi liczb losowych (niezależne, nieskorelowane)
- wady: wymagana ciągła kalibracja (testowanie parametrów), kłopoty techniczne z obsługą, brak powtarzalności serii

Własności generatorów komputerowych

- łatwość obsługi
- możliwość generowania dowolnego rozkładu
- dowolna liczba wymiarów
- powtarzalność ciągów generowanych liczb

Jak pracują komputerowe generatory liczby?

1) Tworzony jest ciąg liczb nieujemnych (naturalnych)

$$X_0, X_1, X_2, \dots, X_n$$

o **rozkładzie równomiernym** według wybranego algorytmu.

Liczby ograniczone są od góry przez reprezentację,

np. dla k=32 bitowej reprezentacji liczby całkowitej bez znaku, kres górny

$$m = 2^{32}$$

$$\underbrace{X_0, \dots, X_{\nu-1}}_{T_a} \underbrace{X_{\nu}, X_{\nu+1}, \dots, X_{\nu+P-1}}_{T_o}, X_{\nu+P}, \dots$$

T_a - okres aperiodyczności ciągu

T_o - okres ciągu

2) Aby uzyskać liczby „rzeczywiste” dokonujemy przekształcenia

$$U = \frac{X}{m} \Rightarrow U_i \in (0, 1]$$

3) Dokonujemy kolejnej transformacji ciągu aby uzyskać ciąg o zadanym rozkładzie prawdopodobieństwa (normalny, wielomianowy, etc.)

Generatory liniowe

Generatory liniowe tworzą ciąg liczb według schematu:

$$X_{n+1} = (a_1 X_n + a_2 X_{n-1} + \dots + a_k X_{n-k+1} + c) \text{ mod } m$$

gdzie: $a_1, a_2, \dots, a_k, c, m$ - parametry generatora (ustalone liczby)

Operację

$$r = (a \text{ mod } n), \quad a, n, r \in Z$$

nazywamy dzieleniem modulo a jej wynikiem jest reszta z dzielenia liczb całkowitych a i n.

Lub inaczej: r **jest kongruentne do a modulo n jeśli n jest dzielnikiem a-r.**

$$a \equiv r \text{ mod } n \Rightarrow r = a - \left\lfloor \frac{a}{n} \right\rfloor n$$

Generatory wykorzystujące operację dzielenia modulo to generatory **kongruentne** lub **kongruencyjne**.

Przykład

$19 \text{ mod } 6 = \mathbf{1}$

$18 \text{ mod } 6 = 0$

$17 \text{ mod } 6 = 5$

$16 \text{ mod } 6 = 4$

$15 \text{ mod } 6 = 3$

$14 \text{ mod } 6 = 2$

$13 \text{ mod } 6 = \mathbf{1}$

$12 \text{ mod } 6 = 0$

$$X_{n+1} = (a_1 X_n + a_2 X_{n-1} + \dots + a_k X_{n-k+1} + c) \bmod m$$

Aby wygenerować ciąg liczb pseudolosowych należy zdefiniować jego parametry.

- liczby $X_0, X_1, X_2, \dots, X_k$

nazywamy **ziarnem generatora (seed)**

Dla bardziej rozbudowanych generatorów liczby te otrzymujemy z innego generatora lub np. używając zegara systemowego (X_0).

- najprostszy generator liniowy ma dwie odmiany
 - **generator multiplikatywny** $c = 0$
 - **generator mieszany** $c \neq 0$
- maksymalny okres generatora liniowego to $(m-1)$

- najprostszy generator multiplikatywny

$$X_{i+1} = aX_{i-1} \text{ mod } m$$

$$k_i = \left\lfloor \frac{aX_{i-1}}{m} \right\rfloor, \quad i \geq 1$$

$$X_1 = aX_0 - mk_1$$

$$X_2 = a^2X_0 - mk_2 - mk_1a$$

$$X_3 = a^3X_0 - mk_3 - mk_2a - mk_1a^2$$

.....

$$X_n = a^n X_0 - m(k_n + k_{n-1}a + \dots + k_1a^{n-1})$$

ostatnie równanie można zapisać w postaci

$$X_n = a^n X_0 \text{ mod } m$$

- wybór X_0 determinuje wszystkie liczby w generowanym ciągu (a i m są ustalone)
- działa w sposób całkowicie **deterministyczny** !!!
- całkowity brak losowości
- taki generator jest **NIEPRZYDATNY**

przykład: Wpływ parametrów generatora na wyznaczone ciągi liczb

$$X_i = aX_{i-1} \text{ mod } 11, \quad X_0 = 1$$

					X_i					
	a=1	2	3	4	5	6	7	8	9	10
i=0	1	1	1	1	1	1	1	1	1	1
1	1	2	3	4	5	6	7	8	9	10
2		4	9	5	3	3	5	9	4	1
3		8	5	9	4	7	2	6	3	
4		5	4	3	9	9	3	4	5	
5		10	1	1	1	10	10	10	1	
6		9				5	4	3		
7		7				8	6	2		
8		3				4	9	5		
9		6				2	8	7		
10		1				1	1	1		

- okres generatora zależy od jego parametrów
- źle dobrane parametry ograniczają okres generatora

- okres generatora multiplikatywnego

$$T = \min\{i : X_i = X_0, i > 0\}$$

- maksymalny okres generatora multiplikatywnego uzyskujemy dla

$$a^{(m-1)/p} \neq 1 \pmod{m}$$

Gdy m jest liczbą pierwszą a p jest czynnikiem pierwszym liczby $(m-1)$.

przykład: wykorzystujemy **liczby Mersenne'a**
(które dość często są liczbami pierwszymi)

$$m = 2^p - 1 \quad \longrightarrow \quad p = 31 \Rightarrow m = 2^{31} - 1, \quad a = 7^5$$

- okres generatora

$$T = 2^{31} - 2$$

- liczby

$$U = \{U_i, 1 \leq i \leq T\}$$

występują dokładnie 1 raz w pojedynczym okresie generatora

- średnia odległość pomiędzy najbliższymi sąsiadami

$$\frac{1}{2^{31} - 1} = 4.657 \times 10^{-10}$$

Rozkład przestrzenny ciągu

- wadą generatorów multiplikatywnych jest nierównomierne pokrycie d-wymiarowej kostki (I^d)
- generowane liczby lokalizują się na hiperpłaszczyznach, których położenie uzależnione jest od parametrów generatora
- jak badamy pojawienie się zależności między kolejnymi elementami ciągu?
tworzymy ciągi wektorów d-wymiarowych z wylosowanych liczb
 - wektory utworzone z częściowo przekrywających się ciągów liczb

$$(U_1, U_2, \dots, U_d), (U_2, U_3, \dots, U_{d+1}), \dots$$


- wektory utworzone z ciągów rozdzielnych

$$(U_1, U_2, \dots, U_d), (U_{d+1}, U_{d+2}, \dots, U_{2d}), \dots$$


przykład: generator multiplikatywny - korelacja elementów ciągu - test graficzny

$$X_i = aX_{i-1} \text{ mod } 11$$

$$X_0 = 1, \quad a = 2$$



$$X_0 = 1, \quad a = 8$$




wnioski:

- część przestrzeni nie jest pokryta punktami - zostaje wyłączona z obliczeń
- ewidentny brak losowości
- zmiana parametrów nie eliminuje wady

Podstawowe parametry statystyczne generatora o rozkładzie równomiernym $U(0,1)$

- zakładamy, że generator dostarcza liczb losowych o rozkładzie jednorodnym w zakresie $x=(0,1)$, rozkład definiuje **funkcja gęstości prawdopodobieństwa $f(x)$**



- jeśli generowany ciąg liczb jest niezależny to **wartość oczekiwana zmiennej losowej** powinna wynosić

$$\mu = \int_0^1 \underbrace{f(x)}_{=1} x dx = \frac{x^2}{2} \Big|_0^1 = \frac{1}{2}$$

jej estymatorem jest średnia arytmetyczna

$$\bar{\mu} = \frac{1}{N} \sum_{i=1}^N x_i$$

- **wariancja rozkładu** zdefiniowana jest jako drugi moment centralny

$$\sigma^2 = \int_0^1 (x - \mu)^2 dx = \frac{1}{12}$$

$$\bar{\sigma} = \frac{1}{N} \sum_{i=1}^N (x_i - \bar{\mu})^2$$

- jeśli parametry statystyczne generatora (ciągu generowanych przez niego liczb) odbiegają od powyższych wartości to jest on nieprzydatny (lub warunkowo przydatny)
- ponadto **współczynniki autokorelacji** elementów ciągu powinny wynosić 0

Funkcja autokorelacji

- opisuje zależność elementów ciągu od wyrazów poprzednich
- definicja

$$R_r = \frac{E[(X_t - \mu)(X_s - \mu)]}{\sigma^2}$$

oraz wzór dla ciągu skończonego ($r=s-t$ to przesunięcie elementów)

$$\bar{R}_r = \frac{1}{(N-r)\sigma^2} \sum_{i=1}^{N-r} (X_i - \mu)(X_{i+r} - \mu)$$

- inaczej: opisuje związek pomiędzy elementami dwóch szeregów
- danego i przesuniętego o r
- dla rozkładu jednorodnego $R \sim 0$ oznacza brak korelacji pomiędzy elementami ciągu, czyli rozkład liczb pseudolosowych jest stochastyczny (brak korelacji)
- w praktyce najsilniejsza jest korelacja między kilkoma kolejnymi liczbami pseudolosowymi, wyznacza się funkcję autokorelacji dla

$$r = 1, 2, 3, 4, 5, 6$$

przykład: generatory multiplikatywne o dobrych własnościach statystycznych

$$X_i = (1176X_{i-1} + 1476X_{i-2} + 1776X_{i-3}) \bmod (2^{32} - 5)$$

$$X_i = 2^{13}(X_{i-1} + X_{i-2} + X_{i-3}) \bmod (2^{32} - 5)$$

$$X_i = (1995X_{i-1} + 1998X_{i-2} + 2001X_{i-3}) \bmod (2^{35} - 849)$$

$$X_i = 2^{19}(X_{i-1} + X_{i-2} + X_{i-3}) \bmod (2^{32} - 1629)$$

- generatory te posiadają maksymalny okres

$$T = m - 1$$

Generatory (bitowe) na rejestrach przesuwnych

- tworzymy ciąg bitów b_i otrzymywanych rekurencyjnie

$$b_i = (a_1 b_{i-1} + \dots + a_k b_{i-k}) \text{ mod } 2 \quad i = k + 1, k + 2, \dots$$

$a_1, a_2, \dots, a_k \in \{0, 1\}$ - parametry generatora są bitami

$b_1, b_2, \dots, b_k \in \{0, 1\}$ - ciąg inicjujący

- do tworzenia ciągu bitów możemy wykorzystać operację **XOR**

a	b	a xor b
0	0	0
0	1	1
1	0	1
1	1	0

$$a \text{ xor } b = (a + b) \text{ mod } 2$$

- jeśli założymy, że parametry generatora są jedynkami

$$a_{j1} = a_{j2} = \dots = a_{jk} = 1$$

kolejny element ciągu tworzymy stosując operację XOR sekwencyjnie

$$b_i = b_{i-j_1} \text{ xor } b_{i-j_2} \text{ xor } \dots \text{ xor } b_{i-j_k}$$

- okres generatora w tej postaci to $T = 2^k - 1$
- w praktyce używa się tylko bitów do generacji kolejnego (większa wydajność)

$$b_i = b_{i-p} \text{ xor } b_{i-q}, \quad p > q, \quad p, q \in N$$

Generator bitowy Tauswortha

- wykorzystujemy ciąg bitów do obliczenia liczby pseudolosowej z przedziału (0,1]

$$U_i = \sum_{j=1}^L 2^{-j} b_{i_s+j} = 0.b_{i_s+1} \dots b_{i_s+L}, \quad i = 0, 1, 2, \dots$$

gdzie: s jest ustaloną całkowitą liczbą nieujemną

- jeśli $s < L$ to do utworzenia U_i oraz U_{i+1} wykorzystywane są elementy tego samego podciągu
- jeśli $s = L$ to U_i oraz U_{i+1} są tworzone z rozłącznych fragmentów ciągu globalnego
- ciąg bitów łatwo generuje się przy użyciu rejestrów przesuwanych oraz bramek logicznych (**XOR**) - łatwa implementacja w języku C
- modyfikacja tego typu generatora to generator **Mersenne Twister** (1998)
 - okres generatora jest ogromny $T = 2^{19937} - 1$
 - generator potrafi wypełnić liczbami pseudolosowymi w sposób jednorodny 623-wymiarową kostkę

$$U^d(0, 1), \quad d = 623$$

Generatory o dowolnym rozkładzie prawdopodobieństwa

- generator o rozkładzie jednorodnym $U(0,1)$ to podstawowy typ generatora, który wykorzystywany jest do konstrukcji generatorów o innych rozkładach
- do konstruowania generatorów o dowolnym rozkładzie stosujemy
 - metodę **odwracania dystrybucyj** (najszybsza, ale nie zawsze stosowalna)
 - metodę **łańcuchów Markowa** (szybka i skuteczna, ale występują korelacje w ciągu)
 - metodę **eliminacji von Neumanna** (najwolniejsza, ale zawsze działa)


Metoda odwracania dystrybuanty

- rozkład prawdopodobieństwa w sposób jednoznaczny określają dwie funkcje **dystrybuanta rozkładu** i **funkcja gęstości prawdopodobieństwa**
- dystrybuanta jest funkcją niemalejącą i prawostronnie ciągłą

$$F : R \rightarrow R$$

$$\lim_{x \rightarrow -\infty} F(x) = 0$$

$$\lim_{x \rightarrow \infty} F(x) = 1$$



- funkcja gęstości prawdopodobieństwa jest nieujemna i unormowana

$$f(x) \geq 0, \quad \int_{-\infty}^{\infty} f(x)dx = 1$$

- dystrybuanta i fgp rozkładu są ze sobą ściśle związane (są miarą prawdopodobieństwa)

$$F(x) = \int_{-\infty}^x f(y)dy$$

- znajdźmy funkcję odwrotną dystrybuanty, co wówczas uzyskamy?

$$U = F(x) \rightarrow x = F^{-1}(U), \quad U \in [0, 1], \quad x \in (-\infty, \infty)$$

- wstawiając jako argument do funkcji odwrotnej liczbę losową o rozkładzie jednorodnym $U(0,1)$ dokonujemy jej transformacji uzyskując liczbę losową o rozkładzie zdefiniowanym przez dystrybuantę

przykład: metoda odwracania dystrybuanty - **rozkład jednomianowy**

- funkcja gęstości prawdopodobieństwa to

$$f(x) = (n + 1)x^n$$

a pozostałe parametry rozkładu przyjmijmy w postaci

$$x \in [0, 1], \quad n = 1, 2, 3, \dots$$

- określamy funkcję opisującą dystrybuantę

$$F(x) = (n + 1) \int_0^x (x')^n dx' = (n + 1) \frac{x^{n+1}}{n + 1} = U$$

i uzależniamy x od U

$$x = U^{\frac{1}{n+1}}, \quad x \in (0, 1)$$

- generator o rozkładzie jednomianowym

przykład: metoda odwracania dystrybuanty - **rozkład eksponencjalny**

- funkcja gęstości prawdopodobieństwa rozkładu eksponencjalnego

$$f(x) = e^{-x}, \quad x \in [0, \infty)$$

- dystrybuanta

$$F(x) = \int_0^x e^{-x'} dx'$$

$$F(x) = 1 - e^{-x} = U, \quad U \in (0, 1)$$

$$e^{-x} = 1 - U$$

$$F^{-1}(x) = x = -\ln(1 - U)$$

$x = -\ln(1 - U)$

- generator o rozkładzie eksponencjalnym

przykład: metoda odwracania dystrybuanty - **rozkład normalny N(0,1)**


- fgp to funkcja Gaussa

$$f(x) = e^{-x^2}$$

- dystrybuanta jest funkcją błędu

$$F(x) = \int_{-\infty}^x e^{-x'^2} dx' = \text{erf}(x)$$

- szukanie funkcji odwrotnej erf(x) jest kosztowne, dlatego stosuje się **metodę Boxa-Mullera**.



Metoda Boxa-Mullera dla rozkładu normalnego

- definiujemy fgp w **2D** jako złożenie dwóch funkcji gaussowskich

$$f(x, y) = f(x) \cdot f(y) = e^{-\frac{x^2+y^2}{2}}, \quad x, y \in (-\infty, \infty)$$

- docelowo chcemy policzyć prawdopodobieństwo

$$p(x, y) = f(x, y) dx dy$$

(czyli że wylosowana liczba znajdzie się w obszarze $dx dy$)

- dokonujemy transformacji: współrzędne kartezjańskie \rightarrow współrzędne biegunowe

$$\begin{array}{ll} x = r \cos(\theta) & r \in [0, \infty) \\ y = r \sin(\theta) & \theta \in [0, 2\pi] \end{array} \quad \longrightarrow \quad r^2 = x^2 + y^2$$

- prawdopodobieństwo określimy przy użyciu nowych zmiennych
- stosujemy prawo przenoszenia prawdopodobieństwa

$$p = f(x, y) dx dy = f(r, \theta) r dr d\theta$$

$$p(r, \theta) = r \cdot e^{-r^2/2} dr d\theta$$

- dokonaliśmy **separacji zmiennych** (r, θ)

- wprowadzamy jeszcze raz nową zmienną (ułatwi nam to całkowanie)

$$z = \frac{r^2}{2} \rightarrow dz = r dr, \quad z \in [0, \infty)$$

$$p(z, \theta) = e^{-z} dz d\theta = f(z) dz \cdot 1 \cdot d\theta$$

- dostaliśmy **rozkład wykładniczy**, który wiemy jak wygenerować

$$f(z) = e^{-z} \rightarrow z = -\ln(1 - U_1), \quad U_1 \in (0, 1)$$

następnie podstawiamy:

$$r = \sqrt{2z} = \sqrt{-2\ln(1 - U)}$$

- kąt θ ma **rozkład jednorodny**, więc używamy generatora o rozkładzie jednorodnym

$$\theta = U_2 \cdot 2\pi, \quad U_2 \in (0, 1)$$

- dla pary (U_1, U_2) dostajemy parę liczb losowych (x, y) z rozkładu $N(0, 1)$

$$X = r \cos(\theta) = \sqrt{-2 \ln(1 - U_1)} \cos(2\pi U_2)$$

$$Y = r \sin(\theta) = \sqrt{-2 \ln(1 - U_1)} \sin(2\pi U_2)$$

- jeśli chcemy zmienić parametry rozkładu normalnego, to dokonujemy transformacji liniowej

$$X = x \cdot \sigma + \mu \quad x \in N(0, 1) \rightarrow X \in N(\mu, \sigma)$$

Metoda eliminacji von Neumann'a

- chcemy wygenerować ciąg zmiennych losowych o gęstości prawdopodobieństwa f w przedziale $[a,b]$
- wartość f jest w przedziale $[a,b]$ ograniczona od góry przez stałą d

Sposób otrzymania ciągu zmiennych losowych o rozkładzie $f(x)$ jest następujący:

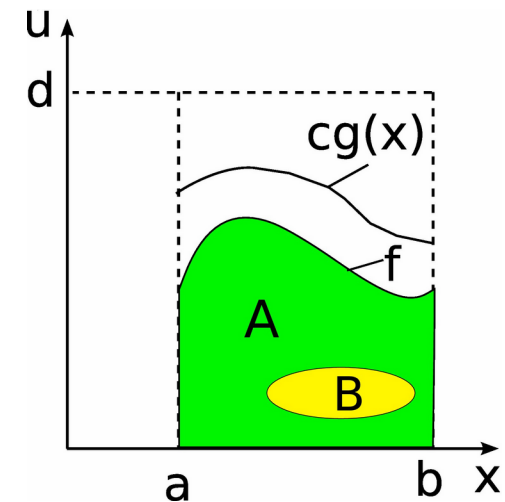
- losujemy dwie zmienne o rozkładzie równomiernym

$$U_1 \in [a, b] \quad U_2 \in [0, d]$$

- sprawdzamy warunek

$$U_2 \leq f(U_1) \Rightarrow X = U_1$$

- gdy powyższy warunek nie jest spełniony wówczas odrzucamy parę U_1, U_2 , jeśli warunek jest spełniony to zachowujemy nowy element $X_i=U_1$
- losowanie wg tego schematu wykonujemy, aż do uzyskania odpowiednio licznego ciągu tj. zaakceptowanych liczb $X_i=U_1$
- wygenerowany ciąg liczb $\{X_1, X_2, X_3, \dots\}$ ma rozkład zdefiniowany przez funkcję gęstości prawdopodobieństwa f



Generowanie ciągu liczb pseudolosowych o zadanym rozkładzie algorytmem Metropolisia

- modyfikujemy metodę eliminacji: w standardowej postaci jest ona mało wydajna, bo nierzadko odrzucamy większość wyników, dzięki **algorytmowi Metropolisia** nie odrzucamy żadnego wyniku
- akceptację nowego położenia (nowej liczby w ciągu) dokonujemy zgodnie z formułą

$$h(x_{i-1}, x_i) = \min \left(1, \frac{f(x_i)}{f(x_{i-1})} \right)$$

- jeśli $f(x_i) > f(x_{i-1})$ to nowe położenie akceptujemy zawsze
- w przeciwnym wypadku akceptacja następuje z prawdopodobieństwem $f(x_i)/f(x_{i-1})$
- jeśli nie akceptujemy nowego punktu to zatwierdzamy stary
(**każdy krok generuje nowy element ciągu**)
- nowe, proponowane położenie losujemy w taki sposób, aby zachowana była symetria prawdopodobieństwa przejścia między dwoma stanami losowymi
(tzw. **warunek detailed balance**)

$$p(x_i \rightarrow x_{i+1}) = p(x_{i+1} \rightarrow x_i)$$

przykład: zastosowanie algorytmu Metropolisa do generowania liczb pseudolosowych

- szukamy ciągu liczb pseudolosowych dla fgp

$$f(x) = \frac{1}{2}x^2e^{-x}$$

- nowego proponowanego stanu losowego (liczby) szukamy w symetrycznym względem punktu x_i przedziale o szerokości 2

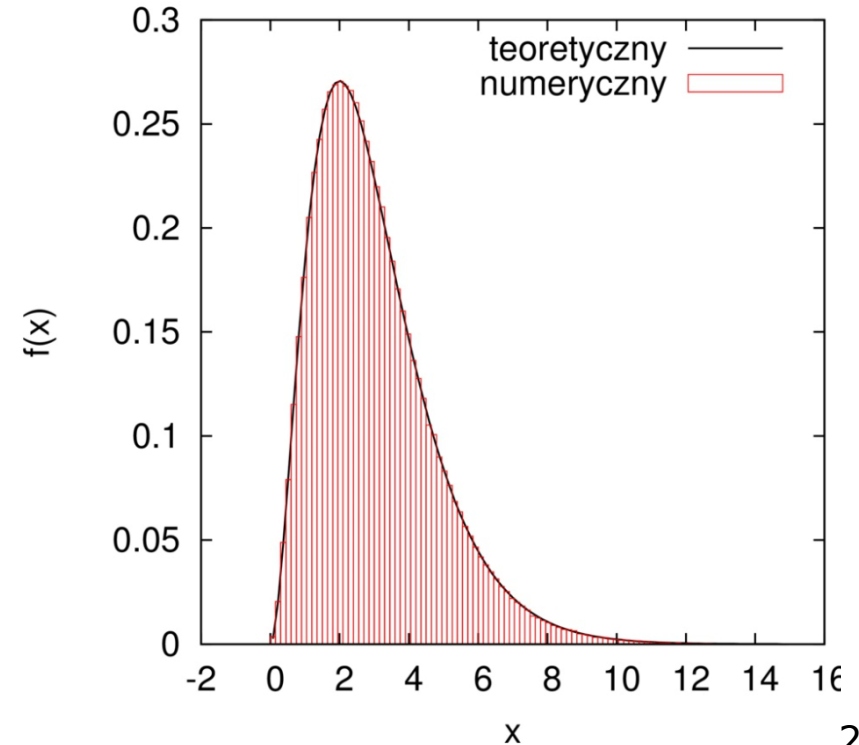
$$x_{new} = x_i + (2 \cdot U(0, 1) - 1)$$

- następnie sprawdzamy warunki akceptacji nowego stanu

$$h(x_{i-1}, x_i) = \min \left(1, \frac{f(x_i)}{f(x_{i-1})} \right)$$

$$x_{i+1} = \begin{cases} x_i & \iff x_{new} < 0 \\ x_i & \iff x_{new} > 0 \wedge u \in U(0, 1) > h \\ x_{new} & \iff x_{new} > 0 \wedge u \in U(0, 1) < h \end{cases}$$

histogram generatora (Metropolis)
dla $f(x)=x^2 \cdot \exp(-x)/2$



Metoda odwracania dystrybuanty dla rozkładu dyskretnego

- w rozkładzie dyskretnym mamy określone prawdopodobieństwo wylosowania danej liczby (rozkład może nie być równomierny)

$$P\{K = k\} = p_k, \quad k = 0, 1, 2, \dots, M$$

$$\sum_{k=0}^M p_k = 1$$

- algorytm generowania ciągu zmiennych o rozkładzie dyskretnym:

1) przyjmujemy wartości początkowe zmiennych: $K=0, S=p_0$

2) losujemy zmienną U o rozkładzie równomiernym z przedziału $[0,1]$

3) sprawdzamy warunek: $U < S$

- jeśli jest prawdziwy to zachowujemy $X=k$ i dokonujemy kolejnego losowania (pkt. 1)
- jeśli nie jest spełniony to iteracyjnie obliczamy (zwiększamy S)

$$K = K + 1, \quad S = S + p_k$$

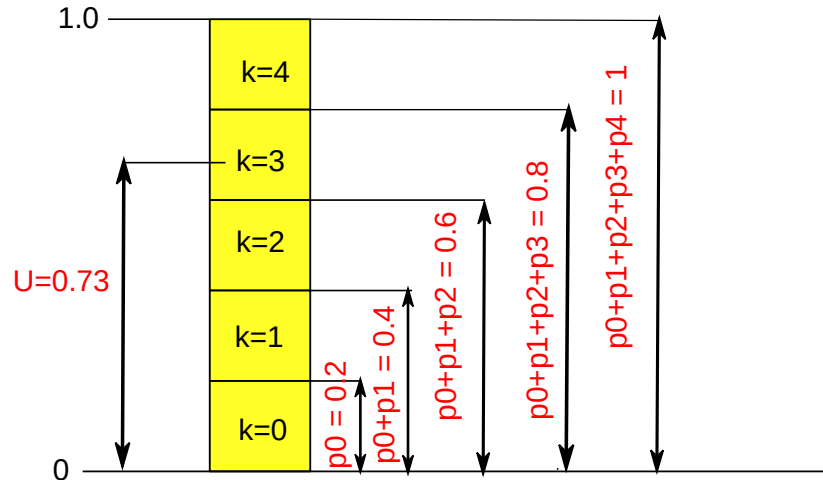
dopóki warunek jest spełniony, gdy przestanie być prawdziwy zachowujemy ostatnią wartość K dołączając ją do ciągu liczb

4) Kroki 1-3 wykonujemy aż do uzyskania odpowiednio licznego ciągu

$$\{K_1, K_2, K_3, \dots\}$$

przykład: odwracanie dystrybuanty dla rozkładu dyskretnego

$$k = 0, 1, 2, 3, 4 \quad \rightarrow \quad p_0 = p_1 = p_2 = p_3 = p_4 = 0.2$$



$$U = 0.73$$

$$K = 0, \quad S = p_0, \quad U > S (?) \quad \text{TAK}$$

$$K = 1, \quad S = p_0 + p_1, \quad U > S (?) \quad \text{TAK}$$

$$K = 2, \quad S = p_0 + p_1 + p_2, \quad U > S (?) \quad \text{TAK}$$

$$K = 3, \quad S = p_0 + p_1 + p_2 + p_3, \quad U > S (?) \quad \text{NIE}$$

$$(0.73 < 0.8)$$

Generatory o rozkładach wielowymiarowych

- zadanie można sformułować następująco:

należy wygenerować ciąg wielowymiarowych zmiennych (**wektorów**) losowych

$$\mathbf{X} = (X_1, X_2, \dots, X_k)$$

których rozkład prawdopodobieństwa ma gęstość

$$f(x_1, x_2, \dots, x_k)$$

- do generacji takiego ciągu można stosować metodę eliminacji, ale w jej najprostszej postaci pojawiają się problemy z wydajnością (duża liczba odrzuconych wyników)

Przykład: Określić prawdopodobieństwo akceptacji wielowymiarowej zmiennej losowej o rozkładzie równomiernym na kuli jednostkowej ($K_k(0,1)$).

- zastosujemy prosty **algorytm eliminacji**
 - losujemy m zmiennych niezależnych o rozkładzie równomiernym w $(-1,1)$ i konstruujemy zmienną wielowymiarową

$$\mathbf{U} = (U_1, U_2, \dots, U_k)$$

- zmienną akceptujemy jeśli

$$\|\mathbf{U}\|_2 \leq 1$$

w przeciwnym wypadku, odrzucamy ją bo leży poza kulą.

- gdzie leży problem w wydajności metody eliminacji?
- prawdopodobieństwo akceptacji zmiennej jest równe ilorazowi objętości kuli i opisanej na niej kostki $[-1,1]^k$

$$V_{kula}(r) = \frac{\pi^{\frac{m}{2}}}{\Gamma\left(\frac{m}{2} + 1\right)} r^m \quad V_{kostka}(r) = 2^m \quad \Rightarrow \quad p_m = \frac{\pi^{\frac{m}{2}}}{2^m \Gamma\left(\frac{m}{2} + 1\right)}$$

- średnia liczba wylosowanych punktów N_m potrzebnych do realizacji jednej zmiennej wynosi

$$N_m = \frac{1}{p_m}$$

m	p_k	N_k
2	7.854×10^{-1}	1.27
5	1.645×10^{-1}	6.08
10	2.490×10^{-3}	4.015×10^2
20	2.461×10^{-8}	4.063×10^7
50	1.537×10^{-28}	6.507×10^{27}

← 1 akceptacja na 400 prób !!!

- modyfikacją usprawniającą powyższy algorytm jest podział kostki na rozłączne podobszary i przeprowadzenia losowania w każdym z nich z osobna
- generalnie dla większej liczby wymiarów, metoda eliminacji jest nieprzydatna

Jednorodny rozkład gęstości prawdopodobieństwa w kole $K^2(0,1)$

- w pewnych (**nielicznych**) przypadkach do generowania ciągu liczb o zadanym rozkładzie wielowymiarowym możemy użyć **metodę odwracania dystrybuanty**
- zastosujemy ją do znalezienia rozkładu jednorodnego w kole o promieniu $R=1$
 - ogólny wzór na powierzchnię
 - element powierzchni we wsp. radialnych

$$S = \int_S dS$$

$$dS = r d\varphi \cdot dr$$

- potraktujemy funkcję podcałkową jako fgp

$$S = \int_0^{2\pi} d\varphi \int_0^1 r dr = S \cdot \int_0^{2\pi} f_\varphi(\varphi) d\varphi \cdot \int_0^1 f_r(r) dr \quad \Rightarrow$$

$$f_\varphi(\varphi) = \frac{1}{2\pi}$$

$$f_r(r) = 2r$$

ogólnie dla k -wymiarów:

$$f_r^{(k)}(r) = k \cdot r^{k-1}$$

- losując dwie liczby losowe z rozkładów f_φ i f_r mamy gwarancję, że znajdują się one wewnątrz koła o promieniu 1

Rozkład równomierny na k-wymiarowej sferze $S^k(0,1)$ i w kuli $K^k(0,1)$

- jeżeli k-wymiarowa zmienna losowa

$$\mathbf{X} = (X_1, X_2, \dots, X_k)$$

położona jest na sferze o promieniu $R=1$ to spełniony jest warunek

$$S_k = \left\{ (x_1, \dots, x_k) : \sum_{i=1}^k x_i^2 = 1 \right\}$$

- k-wymiarowa zmienna X ma rozkład **sferycznie konturowany** jeżeli jej funkcja gęstości prawdopodobieństwa od długości wektora będącego jej argumentem

$$f(x_1, x_2, \dots, x_k) = f(\vec{x}) = f(\|\vec{x}\|) = f\left(\sum_{i=1}^k x_i^2\right)$$

- dysponując zmienną o rozkładzie sferycznie konturowanym wygenerujemy zmienną o rozkładzie równomiernym:
 - na sferze poprzez znormalizowanie długości wektora x do promienia R
 - wewnątrz kuli poprzez przeskalowanie długości wektora wg rozkładu f_r

Rozkład sferycznie konturowany - rozkład normalny (Gaussa)

- k-wymiarowy rozkład normalny opisuje gęstość

$$f_X(x_1, \dots, x_k) = \frac{1}{(2\pi)^{k/2}} \exp\left(-\frac{1}{2}\|\vec{x}\|^2\right)$$

- algorytm generowania rozkładu równomiernego na sferze w k-wymiarach:
 - generujemy m-wymiarową zmienną losową \mathbf{X} o rozkładzie normalnym (**generator Boxa-Mullera**)
 - dokonujemy skalowania, umieszczając punkty (k-wymiarów) na sferze

$$\vec{X} = \frac{\vec{x}}{\|\vec{x}\|}$$

- rozkład jednorodny w kuli k-wymiarowej
 - losujemy długość wektora leżącego wewnątrz kuli z rozkładu

$$R \leftarrow f_r(r) = k \cdot r^{k-1}, \quad 0 \leq r \leq 1$$

- dokonujemy ponownego skalowania długości wektora

$$\mathbf{Z} = (RX_1, RX_2, \dots, RX_k)$$

Testowanie generatorów liczb pseudolosowych

- wszystkie generatory o dowolnym rozkładzie bazują na wykorzystaniu ciągów liczb pseudolosowych o rozkładzie równomiernym więc istotne jest badanie generatorów liczb o takim właśnie rozkładzie
- badanie generatorów o dowolnym rozkładzie można ograniczyć do sprawdzenia czy generowany rozkład jest zgodny z rozkładem docelowym
- testowanie generatora jest procesem złożonym:
 - dla ustalonej liczby n , generujemy n kolejnych liczb startując od losowo wybranej liczby początkowej
 - obliczamy wartość statystyki testowej (T) (np. test χ^2)
 - obliczamy $F(T)$ czyli dystrybuantę statystyki T , gdy weryfikowana hipoteza jest prawdziwa

kroki 1-3 powtarzamy N -krotnie obliczając statystyki: T_1, T_2, \dots, T_N .

- jeśli weryfikowana hipoteza jest prawdziwa to

$$F(T_1), F(T_2), F(T_3), \dots, F(T_N)$$

jest ciągiem zmiennych niezależnych o rozkładzie równomiernym, testowanie generatora kończy się sprawdzeniem tej hipotezy

Testy zgodności z zadaniem rozkładem - test chi-kwadrat

- badamy w nim hipotezę że generowana zmienna losowa X ma rozkład prawdopodobieństwa o dystrybuancie F

jeżeli

$$F(a) = 0 \quad F(b) = 1$$

to możemy dokonać następującego podziału zbioru wartości zmiennej X

$$a < a_1 < a_2 < \dots < a_k = b \quad \longrightarrow \quad p_i = P\{a_{i-1} < X \leq a_i\}, \quad i = 1, 2, \dots$$

Generujemy ciąg n liczb

$$X_1, X_2, \dots, X_n$$

Sprawdzamy ile z nich spełnia warunek

$$a_{i-1} < X \leq a_i$$

ich liczbę oznaczamy n_i . Statystyką testu jest

$$\chi_{k-1}^2 = \sum_{i=1}^k \frac{(n_i - np_i)^2}{np_i}$$

dla dużego n statystyka ta ma rozkład χ^2 o $(k-1)$ stopniach swobody.


- uzyskaną wartość porównujemy z wartością graniczną dla rozkładu chi-kwadrat (np. korzystając z tabel statystycznych), jeśli jest mniejsza od wartości granicznej to **hipotezy nie odrzucamy**

przykład: test generatora o trójkątnym rozkładzie fgp

$$f(x; \mu, \Delta) = -\frac{|x - \mu|}{\Delta^2} + \frac{1}{\Delta}$$

mamy 2 parametry
więc 2 stopnie swobody
mniej:

$$(k-1-2)$$



$$F(a) = P(x < a) = \int_{\mu-\Delta}^a f(x; \mu, \Delta) dx = \begin{cases} -\frac{1}{\Delta^2} \left(-\frac{x^2}{2} + \mu x \right) + \frac{x}{\Delta}, & x \leq \mu \\ -\frac{1}{\Delta^2} \left(\frac{x^2}{2} - \mu x + \mu^2 \right) + \frac{x}{\Delta}, & x > \mu \end{cases}$$

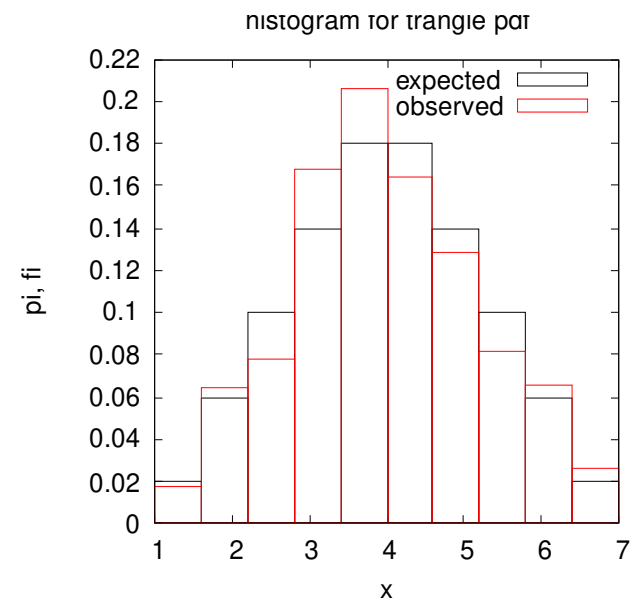
generowanie zmiennej o rozkładzie trójkątnym

$$x = \mu + (\xi_1 + \xi_2 - 1) \cdot \Delta, \quad \xi_1, \xi_2 \in U(0, 1)$$

Test - procedura:

1. Generujemy serię N liczb z rozkładu
2. Grupujemy liczby w k przedziałach
3. Liczymy wartość statystyki testowej χ^2
4. Dla zadanego poziomu istotności α sprawdzamy czy

$$\chi^2 < \text{wartości granicznej}$$



$$\chi_{k-2-1}^2 = 4.52 < 14.06 (\alpha = 0.05) - \text{nie odrzucamy } H_0$$