

1 Wprowadzenie

Często stoimy przed koniecznością generacji liczb losowych o zadanym rozkładzie prawdopodobieństwa. Jeśli dysponujemy liczbami losowymi o rozkładzie równomiernym, to problem sprowadza się do przekształcenia rozkładu równomiernego w rozkład pożądanym. Ponieważ w generatorach liczb o rozkładzie równomiernym wyposażone są ogólnie dostępne kompilatory popularnych języków programowania np. C++, jako punkt wyjścia przyjmujemy zatem, że dysponujemy takowym.

Jako przykład takiego generatora liczb na odcinku $(0, 1)$ może służyć procedura rekurencyjna:

$$x_{n+1} = (ax_n + b) \pmod{c},$$

w której a , b , c są odpowiednio ustalonymi liczbami całkowitymi, natomiast x_1 jest liczbą początkową, przy czym $\alpha \pmod{\beta}$ jest resztą z dzielenia α przez β . Jest oczywiste, że kolejne liczby mają w istocie charakter deterministyczny i jedynie symulują losowość. Z tego też względu nazywane są pseudolosowymi. Generator taki uznawany jest jako dobry, gdy pomyślnie przejdzie testy dotyczące rozkładu, niezależności itp.


Przedstawimy metody, przy pomocy których, wychodząc ze zmiennych losowych o rozkładzie równomiernym, można otrzymywać dowolne rozkłady. Sporo uwagi poświęcimy rozkładowi normalnemu. Dla każdej przedstawionej metody podamy uzasadnienie teoretyczne, a następnie konkretne generatory podamy w czytelnej postaci algorytmicznej.

Pisząc o rozkładzie równomiernym, mamy zawsze na myśli rozkład równomierny na odcinku $(0, 1)$.

2 Metoda inwersyjna

2.1 Omówienie metody

W metodzie inwersyjnej pożądanym rozkład o dystrybuancie F otrzymuje się przez odpowiednie nieliniowe przekształcenie zmiennej losowej o rozkładzie równomiernym. Przekształceniem tym jest F^{-1} , patrz rys. 2.1. Uzasadnieniem metody jest poniższe twierdzenie:



Rys. 2.1: Ilustracja metody inwersyjnej.

Twierdzenie 2.1 *Jeśli zmienna losowa U ma rozkład równomierny na odcinku $(0, 1)$, to $F^{-1}(U)$ ma dystrybuantę F . I na odwrót. Jeżeli X ma dystrybuantę F , to $F(X)$ ma rozkład równomierny.*

Dowód. Zauważmy, że

$$P\{F^{-1}(U) < x\} = P\{U < F(x)\} = F(x),$$

skąd wynika pierwsza część twierdzenia. Druga jest konsekwencją tego, że

$$\begin{aligned} P\{F(X) < u\} &= P\{X < F^{-1}(u)\} \\ &= F(F^{-1}(u)) = u \end{aligned}$$

dla każdego $u \in (0, 1)$. \square

Twierdzenie 2.1 pozwala skonstruować następujący algorytm generacji zmiennej losowej o dystrybuancie F :

Zmienna losowa o dystrybuancie F Metoda inwersyjna	
►	Generuj U o rozkładzie równomiernym na odcinku $(0, 1)$
►	RETURN $X \leftarrow F^{-1}(U)$

2.2 Wybrane rozkłady

Zasadniczą sprawą dla metody jest to czy można, a jeżeli tak, to czy można łatwo wykonać operację F^{-1} . Nadaje się ona zatem do generacji zmiennych losowych, których dystrybuanta znana jest w postaci jawnej, i którą można łatwo odwrócić. Są to rozkłady takie jak np.: wykładniczy, Laplace'a, Cauchy'ego. Nie można tej metody wykorzystać jednak do generacji rozkładu normalnego, gdyż jego dystrybuanta nie ma jawnej postaci.

Dla niektórych ważniejszych rozkładów odwrotności F^{-1} podane są w tabeli 1. Dla pewnych rozkładów, wzory określające F^{-1} podano także w prostszych postaciach alternatywnych. Wynikają one ze spostrzeżenia, że $V = 1 - U$ oraz U mają jednakowe rozkłady. Dzięki tabeli tej możemy podać generatory rozkładu wykładniczego, Cauchy'ego, Laplace'a, Pareto oraz logistycznego.

Tabela 1: Gęstości, dystrybuanty i ich odwrotności

Rozkład	trójkątny $0 \leq x \leq 1$	wykładniczy $0 \leq x < \infty$
$f(x)$	$2(1-x)$	e^{-x}
$F(x)$	$1 - (x-1)^2$	$1 - e^{-x}$
$F^{-1}(u)$	$1 - \sqrt{1-u}$	$-\ln(1-u)$
$F^{-1}(v) _{v=1-u}$	$1 - \sqrt{v}$	$-\ln v$

Rozkład	Pareto $0 < b \leq x$	logistyczny
$f(x)$	$\frac{ab^a}{x^{a+1}}$	$\frac{1}{2 + e^x + e^{-x}}$
$F(x)$	$1 - \left(\frac{b}{x}\right)^a$	$\frac{1}{1 + e^{-x}}$
$F^{-1}(u)$	$\frac{b}{(1-u)^{1/a}}$	$\ln \frac{u}{1-u}$
$F^{-1}(v) _{v=1-u}$	$\frac{b}{v^{1/a}}$	

Rozkład	Cauchy'ego
$f(x)$	$\frac{1}{\pi(x^2 + 1)}$
$F(x)$	$\frac{1}{2} + \frac{1}{\pi} \arctan x$
$F^{-1}(u)$	$\tan \left[\pi \left(u - \frac{1}{2} \right) \right]$

2.2.1 Rozkład trójkątny

Rozkład trójkątny Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► RETURN $X \leftarrow 1 - \sqrt{U}$

2.2.2 Rozkład wykładniczy

Rozkład wykładniczy Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► RETURN $X \leftarrow -\ln U$

2.2.3 Rozkład Laplace'a

Rozkład Laplace'a Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► $X = -\ln U$ X ma rozkład wykładniczy
► Generuj V o rozkładzie równomiernym
► IF $V < 1/2$ THEN $X \leftarrow -X$

2.2.4 Rozkład Cauchy'ego

Rozkład Cauchy'ego Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► RETURN $X \leftarrow \tan \left(\pi \left(U - \frac{1}{2} \right) \right)$

2.2.5 Rozkład Pareto

Rozkład Pareto (a, b) Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► RETURN $X \leftarrow \frac{b}{U^{1/a}}$

2.2.6 Rozkład logistyczny

Rozkład logistyczny Metoda inwersyjna
► Generuj U o rozkładzie równomiernym
► RETURN $X \leftarrow \ln \frac{U}{1-U}$

3 Metoda odrzucania

3.1 Omówienie metody

Istota metody odrzucania polega na tym, że generuje się realizację zmiennej losowej o pewnym, łatwym do uzyskania

rozkładzie, a następnie – według zasady wynikającej z Twierdzenia 3.1 – odrzuca się niektóre z nich. Pozostałe posiadają pożądany rozkład.

Szczególną uwagę zwrócimy na rozkład normalny. Otrzytać go można wychodząc np. z rozkładów Laplace'a, wykładniczego i Cauchy'ego. Wygenerowanie zmiennych losowych o tych rozkładach nie jest trudne, jeśli korzysta się z metody inwersyjnej.

Podstawą metody odrzucania jest poniższe twierdzenie:

Twierdzenie 3.1 Dla funkcji f , niech

$$A = \{(x, y) : -\infty < x < \infty, 0 \leq y \leq cf(x)\},$$

gdzie $c > 0$. Jeśli f jest gęstością prawdopodobieństwa zmiennej losowej X i U ma rozkład równomierny na odcinku $(0, 1)$, to para (X, Y) , gdzie $Y = cUf(X)$, ma rozkład równomierny na zbiorze A . Na odwrót, jeśli (X, Y) ma rozkład równomierny na zbiorze A , to X ma gęstość f .


Dowód. Ilustracją dowodu jest rys 3.1. Załóżmy, że X ma gęstość $f(x)$, natomiast U ma rozkład równomierny na odcinku $[0, 1]$. Zatem

$$f(y|x) = \begin{cases} \frac{1}{cf(x)} & \text{dla } (x, y) \in A \\ 0, & \text{dla } (x, y) \notin A, \end{cases}$$

skąd wynika, że

$$f(x, y) = f(y|x)f(x) = \begin{cases} \frac{1}{c}, & \text{dla } (x, y) \in A \\ 0, & \text{dla } (x, y) \notin A \end{cases}$$

co oznacza, że para (X, Y) ma rozkład równomierny na zbiorze A .



Rys. 3.1: Para (X, Y) , gdzie $Y = cUf(X)$, ma rozkład równomierny na zakresowanym zbiorze A .

Teraz zakładamy że, para (X, Y) ma rozkład równomierny na zbiorze A , tzn. że


$$f(x, y) = \begin{cases} \frac{1}{c}, & \text{dla } (x, y) \in A \\ 0, & \text{dla } (x, y) \notin A, \end{cases}$$

bowiem $\int \int f(x, y) dx dy = c$. Zatem gęstością zmiennej X jest

$$\int f(x, y) dy = \int_0^{cf(x)} \frac{1}{c} dy = f(x),$$

co kończy dowód. \square

Idea algorytmu jest następująca. Gęstość f jest oczywiście zadana. Załóżmy, że istnieje łatwa do generacji gęstość g oraz stała c takie, że $f(x) \leq cg(x)$ dla wszystkich $x \in (-\infty, \infty)$. Schemat postępowania jest następujący, patrz rys. 3.2:



Rys. 3.2: Ilustracja generacji rozkładu f przy pomocy odrzucania z rozkładu g .

- ▶ Najpierw generuje się zmienną losową o rozkładzie równomiernym na zbiorze zawartym pomiędzy osią x a krzywą $y = cg(x)$. Korzystając z Twierdzenia 3.1 można zrobić to zgodnie z poniższym algorytmem:

- ▷ Generuj zmienną losową X o gęstości g
- ▷ Generuj zmienną losową U o rozkładzie równomiernym na odcinku $(0, 1)$
- ▷ $Y \leftarrow cUg(X)$
- ▷ RETURN (X, Y)

- ▶ Następnie odrzuca się wszystkie pary (X, Y) , które leżą ponad krzywą $y = f(x)$. Pozostałe pary, zgodnie z podanym twierdzeniem, mają rozkład równomierny na zbiorze zawartym pomiędzy osią x i krzywą $y = f(x)$. Zatem, zgodnie z Twierdzeniem 3.1, X w pozostałych parach ma pożądaną gęstość f . Schemat postępowania na tym etapie jest jak poniżej:

- ▷ IF $Y \leq f(X)$ THEN $X \leftarrow X$
 ELSE powtórz wszystkie operacje od początku
- ▷ RETURN X

Łącząc to w całość i dokonując oczywistych uproszczeń otrzymujemy gotową procedurę.

Zmienna losowa o gęstości f Metoda odrzucania	
◆	REPEAT
◇	Generuj X o gęstości g
◇	Generuj U o rozkładzie równomiernym
◆	UNTIL $Uc \frac{g(X)}{f(X)} \leq 1$
◆	RETURN X

Aby metoda była efektywna musi posiadać trzy podstawowe cechy:

- 1) musi istnieć gęstość g i stała c takie, że $f(x) \leq cg(x)$ dla wszystkich $x \in (-\infty, \infty)$,
- 2) rozkład o gęstości g powinien być łatwy do generacji,
- 3) liczba iteracji procedury powinna być możliwie mała, tzn. prawdopodobieństwo przyjęcia pary $(X, cUg(X))$ powinno być duże.

Odnosnie do punktu 3), oznaczając przez p prawdopodobieństwo przyjęcia wylosowanej pary (X, Y) , zauważamy, że

$$p = P\{f(X) \geq cUg(X)\} = \frac{1}{c}.$$

Pożądane jest zatem, aby c było możliwie małe. Oznaczając przez N liczbę iteracji algorytmu, która zapewnia przyjęcie pary, zauważmy ponadto, że $P\{N = i\} = p(1-p)^{i-1}$. Zatem N ma rozkład geometryczny i $E\{N\} = 1/p = c$. Zatem wyprowadzony przed chwilą wniosek odnoszący się do c potwierdza się.


Jest więc oczywiste, że stała c powinna być mała, gdyż zarówno prawdopodobieństwo odrzucenia wylosowanej pary jak i średnia liczba iteracji algorytmu są wtedy małe.

3.2 Rozkład trójkątny

Zauważmy, że dla gęstości $f(x)$ rozkładu trójkątnego i gęstości $g(x)$ rozkładu równomiernego, $f(x) \leq cg(x)$, gdzie $c = 2$, bowiem

$$\frac{g(x)}{f(x)} = \frac{1}{2(1-x)} \geq \frac{1}{2},$$

dla $0 \leq x \leq 1$, patrz rys. 3.3.



Rys. 3.3: Generacja rozkładu trójkątnego $f(x)$ (linia ciągła) przez odrzucanie z rozkładu równomiernego (linia przerywana) $g(x)$; $c = 2$.

Pozwala to zbudować algorytm generacji rozkładu trójkątnego jak poniżej:

Rozkład trójkątny Odrzucanie z rozkładu równomiernego	
◆	REPEAT
◇	Generuj X o rozkładzie równomiernym
◇	Generuj U o rozkładzie równomiernym
◆	UNTIL $U \leq 1 - X$
◆	RETURN X

Nie wykonuje on operacji pierwiastkowania, patrz § 2.2.1, ale odrzuca połowę wygenerowanych liczb.

3.3 Rozkład logistyczny

Gęstość rozkładu logistycznego

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


spełnia nierówność $f(x) \leq cg(x)$, gdzie $c = 2$ oraz

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

jest gęstością rozkładu Laplace'a. Zauważmy bowiem, że

$$\begin{aligned}\frac{g(x)}{f(x)} &= \frac{1}{2}(2 + e^{|x|} + e^{-|x|})e^{-|x|} \\ &= \frac{1}{2}(1 + e^{|x|})^2 \geq \frac{1}{2},\end{aligned}$$

patrz rys. 3.4. Krzywa $cg(x)$ leży ponad $f(x)$ na całej prostej $x \in (-\infty, \infty)$.



Rys. 3.4: Generacja rozkładu logistycznego $f(x)$ z rozkładu Laplace'a $g(x)$, $c = 2$.

Wynika stąd podany poniżej algorytm, który zapewnia prawdopodobieństwo przyjęcia na poziomie $1/c = 1/2$:

Rozkład logistyczny Odrzucanie z rozkładu Laplace'a	
◆	REPEAT
◇	Generuj X o rozkładzie Laplace'a
◇	Generuj U o rozkładzie równomiernym
◆	UNTIL $U(1 + e^{- X })^2 \leq 1$
◆	RETURN X

Ćwiczenie 3.1 Zauważając, że $f(x) \leq 1/(4 + x^2)$, zbudować generator rozkładu logistycznego, w którym $c = \pi/2 \approx 1,57$.

3.4 Rozkład normalny

Podamy teraz generatory rozkładu normalnego $N(0, 1)$, czyli o gęstości


$$f(x) = \frac{1}{\sqrt{2\pi}}e^{-x^2/2}.$$

3.4.1 Odrzucane z rozkładu Laplace'a

Jeśli odrzuca się z rozkładu Laplace'a o gęstości $g(x) = (1/2)e^{-|x|}$, to $c = \sqrt{2e/\pi} \approx 1,315$, bowiem

$$\frac{g(x)}{f(x)} = \sqrt{\frac{\pi}{2e}}e^{(|x|-1)^2/2} \geq \sqrt{\frac{\pi}{2e}}.$$

Dla wyznaczonego c , $cg(x) = f(x)$ dla $|x| = 1$. Wzajemne położenie funkcji $f(x)$ i $cg(x)$ pokazuje rys. 3.5. Są one styczne w punktach $x = \pm 1$. Prawdopodobieństwo przyjęcia X jest równe $1/c = 1/\sqrt{2e/\pi} \approx 0,760$.



Rys. 3.5: Generacja rozkładu normalnego $f(x)$ przez odrzucanie z rozkładu Laplace'a $g(x)$, $c = \sqrt{2e/\pi}$.

Rozkład normalny Odrzucanie z rozkładu Laplace'a	
■	REPEAT
□	Generuj X o Laplace'a
□	Generuj U o rozkładzie równomiernym
■	UNTIL $Ue^{(x -1)^2/2} \leq 1$
■	RETURN X

3.4.2 Odrzucanie z rozkładu Cauchy'ego

W podanym teraz generatorze odrzuca się z rozkładu Cauchy'ego o gęstości

$$g(x) = \frac{1}{\pi(x^2 + 1)}.$$


Jak można sprawdzić

$$\begin{aligned}\frac{g(x)}{f(x)} &= \frac{\sqrt{2\pi}e^{x^2/2}}{\pi(x^2 + 1)} = \sqrt{\frac{2}{\pi}} \frac{e^{x^2/2}}{(x^2 + 1)} \\ &\geq \sqrt{\frac{e}{2\pi}},\end{aligned}$$

ponieważ

$$\frac{e^{x^2/2}}{x^2 + 1} \geq \frac{e^{x^2/2}}{x^2 + 1} \Big|_{x=\pm 1} = \frac{\sqrt{e}}{2}.$$

Zatem $c = \sqrt{2\pi/e} \approx 1,520$. Krzywe $f(x)$ i $cg(x)$ pokazane



Rys. 3.6: Generacja rozkładu normalnego $f(x)$ przez odrzucanie z rozkładu Cauchy'ego $g(x)$, $c = \sqrt{2\pi/e}$.

na rys. 3.6 są styczne w punktach $x = \pm 1$. W procedurze przedstawionej poniżej prawdopodobieństwo przyjęcia X jest równe $1/c = 1/\sqrt{2\pi/e} \approx 0,657$:

Rozkład normalny Odrzucanie z rozkładu Cauchy'ego	
▼	REPEAT
▽	Generuj X o rozkładzie Cauchy'ego
▽	Generuj U o rozkładzie równomiernym
▽	$S = X^2$
▼	UNTIL $U \leq \frac{\sqrt{e}}{2}(1 + S)e^{\frac{1}{2}S}$