

Generatory liczb losowych dla podstawowych rozkładów prawdopodobieństwa

- **Rozkłady ciągłe.**
 - ▷ Rozkład wykładniczy.
 - ▷ Rozkład normalny (Gaussa).
 - ▷ Rozkład Cauchy'ego (Breita–Wignera).
 - ▷ Rozkład potęgowy.
 - ▷ Rozkłady α -stabilne.
- **Rozkłady wielowymiarowe.**
 - ▷ Metody ogólne.
 - ▷ Rozkład równomierny na sferze i kuli w \mathbb{R}^m .
 - ▷ Rozkład równomierny na sympleksie i na powierzchni sympleksu.
- **Rozkłady dyskretne.**
 - ▷ Rozkład dwumianowy.
 - ▷ Rozkład Poissona.
 - ▷ Rozkład geometryczny.
 - ▷ Pewna metoda ogólna.

Rozkład wykładniczy $E(\theta, \lambda)$:

► Gęstość prawdopodobieństwa:

$$\rho_{\theta, \lambda}(x) = \frac{1}{\lambda} e^{-\frac{x-\theta}{\lambda}}, \quad x \geq \theta.$$

→ Transformacja liniowa:

$$x \rightarrow x' = \frac{x - \theta}{\lambda} \Rightarrow E(\theta, \lambda) \rightarrow E(0, 1): \rho_{0,1}(x') = e^{-x'}, \quad x' \geq 0.$$

A. Metoda odwracania dystrybuanty:

$$X' = -\ln R, \quad R \in \mathcal{U}(0, 1), \quad \Rightarrow \quad X = \lambda X' + \theta.$$

B. Metoda serii monotonicznych (J. von Neumann, 1951) – rozkład $E(0, 1)$:

1. Generujemy ciąg $U_1, U_2, \dots \in \mathcal{U}(0, 1)$.
2. Obserwujemy serie postaci: $U_1 \geq U_2 \geq \dots \geq U_n < U_{n+1}$ i numerujemy je kolejnymi liczbami $0, 1, 2, \dots$
3. Numer pierwszej serii, której długość n jest liczbą **nieparzystą** przyjmujemy za **część całkowitą** generowanej liczby losowej X , natomiast wartość R_1 pierwszej liczby w tej serii – za jej **część ułamkową**.

⇒ **Ćw. N9.1:** Używając metody serii monotonicznych wygenerować rozkład $E(0, 1)$. Wykonać histogram i porównać z wykresami funkcji gęstości prawdopodobieństwa oraz dystrybuanty.

Rozkład normalny (Gaussa) $N(\mu, \sigma)$:

► Gęstość prawdopodobieństwa:

$$\phi_{\mu, \sigma}(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{(x-\mu)^2}{2\sigma^2}}, \quad -\infty < x < +\infty.$$

→ Zamiana zmiennych (transformacja liniowa):

$$x \rightarrow x' = (x - \mu)/\sigma \Rightarrow N(\mu, \sigma) \rightarrow N(0, 1): \phi_{0,1}(x') = (1/\sqrt{2\pi}) e^{-x'^2/2}.$$

A. Metoda oparta o centralne twierdzenie graniczne → patrz wykład 1.

▷ Dobra dla obszaru centralnego, zła dla „ogonów” rozkładu!

B. Metoda odwracania dystrybuanty – w jednym wymiarze:

▷ W jednym wymiarze dystrybuanta nie jest odwracalna analitycznie – czasem stosuje się pewne przybliżenia dla funkcji odwrotnej do dystrybuanty, np. (Odeh i Evans, 1974):

$$\Phi^{-1}(u) = \begin{cases} g(u), & 10^{-20} < u < 0.5, \\ -g(1-u), & 0.5 < u < 1 - 10^{-20}, \end{cases} \quad \left| \begin{array}{l} g(u) = t - \frac{L(t)}{M(t)}, \\ t = \sqrt{-2 \ln u}, \end{array} \right.$$

$$L(t) = 0.322232431088 + t + 0.342242088547t^2 + 0.0204231210245t^3 + 0.0000453642210148t^4,$$

$$M(t) = 0.099348462606 + 0.588581570495t + 0.531103462366t^2 + 0.10353775285t^3 + 0.0038560700634t^4.$$

C. Metoda odwracania dystrybuanty – w dwóch wymiarach:

▶ Gęstość prawdopodobieństwa:

$$\rho(x, y) = \frac{1}{2\pi} e^{-\frac{x^2+y^2}{2}}, \quad -\infty < x, y < +\infty.$$

▷ Przechodzimy do współrzędnych biegunowych:

$$(x, y) = (r \cos \phi, r \sin \phi), \quad 0 \leq \phi < 2\pi, \quad 0 \leq r < +\infty,$$

$$\Rightarrow \text{faktoryzacja: } \tilde{\rho}(\phi, r) = f(\phi) g(r), \quad \text{gdzie: } f(\phi) = \frac{1}{2\pi}, \quad g(r) = r e^{-\frac{r^2}{2}}.$$

→ Zmienną kątową generujemy z rozkładu równomiernego, a zmienną radialną przez odwrócenie dystrybuanty.

▷ Niech $U_1, U_2 \in \mathcal{U}(0, 1)$:

$$\left. \begin{aligned} x &= \sqrt{-2 \ln U_1} \cos(2\pi U_2) \\ y &= \sqrt{-2 \ln U_1} \sin(2\pi U_2) \end{aligned} \right\} \text{niezależne zmienne losowe o rozkładach } N(0, 1).$$

▶ Zalety: Dokładna i prosta w użyciu!

▶ Wada: Czasochłonne obliczanie funkcji logarytmicznych i trygonometrycznych!

D. Metoda Marsaglii i Braya (1964):

TWIERDZENIE:

Jeżeli: $U_1, U_2 \in \mathcal{U}(-1, 1)$ – niezależne zmienne losowe,
to przy warunku: $U_1^2 + U_2^2 \leq 1$, zmienne losowe:

$$X_1 = U_1 \sqrt{\frac{-2 \ln(U_1^2 + U_2^2)}{U_1^2 + U_2^2}}, \quad Y_1 = X_1 \frac{U_2}{U_1}$$

są niezależne i mają rozkład normalny $N(0, 1)$.

▷ Schemat:

1. Wygenerować: $R_1, R_2 \in \mathcal{U}(0, 1)$ i wyliczyć: $U_1 = 2R_1 - 1$, $U_2 = 2R_2 - 1$.
2. Wyliczyć: $W = U_1^2 + U_2^2$.
3. Jeżeli: $W > 1$, to wrócić do kroku 1. (→ eliminacja ok. 21% przypadków).
4. Wyznaczyć: $X = U_1 Z$ oraz $Y = U_2 Z$, gdzie: $Z = \sqrt{\frac{-2 \ln W}{W}}$.

E. Metoda eliminacji względem rozkładu wykładniczego → patrz wykład 6.

F. Metoda kombinacji superpozycji rozkładów i eliminacji → patrz wykład 6.

⇒ **Ćw. N9.2:** Wygenerować rozkład normalny metodami odwracania dystrybuanty oraz Marsaglii i Braya.

Rozkład Cauchy'ego (Breita–Wignera) $C(\theta, \lambda)$:

► Gęstość prawdopodobieństwa:

$$f_{\theta, \lambda}(x) = \frac{\lambda}{\pi} \frac{1}{\lambda^2 + (x - \theta)^2}, \quad -\infty < x < +\infty.$$

→ Zamiana zmiennych (transformacja liniowa):

$$x \rightarrow x' = \frac{x - \theta}{\lambda} \Rightarrow C(\theta, \lambda) \rightarrow C(0, 1): \quad f_{0,1}(x') = \frac{1}{\pi} \frac{1}{1 + x'^2}.$$

▷ Uwaga: Wartość oczekiwana nie istnieje, a wariancja jest nieskończona!

A. Metoda odwracania dystrybuanty:

► Dystrybuanta:

$$F(x) = \frac{1}{\pi} \arctan x + \frac{1}{2}$$

$$\Rightarrow X = \operatorname{tg} \left(\pi \left[U - \frac{1}{2} \right] \right), \quad U \in \mathcal{U}(0, 1)$$

B. Z uciętego rozkładu Cauchy'ego (kombinacja metody superpozycji rozkładów i eliminacji):

► Ucięty rozkład Cauchy'ego $C_u(0, 1)$:

$$f_u(x) = \begin{cases} \frac{2}{\pi} \frac{1}{1+x^2}, & |x| \leq 1, \\ 0, & |x| > 1. \end{cases}$$

LEMAT:

Jeżeli zmienna losowa X ma ucięty rozkład Cauchy'ego $C_u(0, 1)$, to zmienna losowa Y , która z prawdopodobieństwem $\frac{1}{2}$ jest identyczna ze zmienną losową X oraz z prawdopodobieństwem $\frac{1}{2}$ jest identyczna ze zmienną losową $1/X$, ma rozkład Cauchy'ego $C(0, 1)$.

Dowód: Niech $y \leq -1$:

$$\begin{aligned} \mathcal{P}\{Y \leq y\} &= \frac{1}{2} \mathcal{P}\{X \leq y\} + \frac{1}{2} \mathcal{P}\left\{\frac{1}{X} \leq y\right\} = 0 + \frac{1}{2} \mathcal{P}\left\{\frac{1}{y} \leq X < 0\right\} = \frac{1}{2} \frac{2}{\pi} \int_{1/y}^0 \frac{dt}{1+t^2} \\ &= \frac{1}{\pi} \arctg y + \frac{1}{2} \quad \text{– dystrybuanta rozkładu Cauchy'ego } C(0, 1). \end{aligned}$$

Podobnie dowodzimy dla $y \in (-1, 1)$ oraz $y \geq 1$. ☒

► Ucięty rozkład Cauchy'ego generujemy np. metodą eliminacji względem rozkładu $\mathcal{U}(-1, 1)$ lub metodą AC z: $g(x) = 0.5$, $f_1(x) = f_u(x) - f_u(0) + 0.5$, $f_2(x) = f_u(0) - 0.5$.

⇒ **Ćw. N9.3:** Wygenerować rozkład Cauchy'ego powyższymi metodami.

Rozkład potęgowy:

► Gęstość prawdopodobieństwa:

$$f_1(x) = n x^{n-1},$$

$$f_2(x) = n (1 - x)^{n-1}$$

gdzie: $0 \leq x \leq 1$, $n \in \mathbb{N}$.

A. Metoda odwracania dystrybuanty:

$$X = U^{1/n} \quad \rightarrow f_1, \quad U \in \mathcal{U}(0, 1).$$

$$Y = 1 - U^{1/n} \quad \rightarrow f_2, \quad U \in \mathcal{U}(0, 1).$$

▷ Wada: Czasochłonna operacja $U^{1/n}$.

B. Niech $U_1, U_2, \dots, U_n \in \mathcal{U}(0, 1)$ – niezależne zmienne losowe:

$$X = \max\{U_1, U_2, \dots, U_n\} \text{ ma rozkład o gęstości } f_1,$$

$$Y = \min\{U_1, U_2, \dots, U_n\} \text{ ma rozkład o gęstości } f_2.$$

⇒ **Ćw. N9.4:** Wygenerować rozkład potęgowy powyższymi metodami dla kilku wartości n .

Rozkłady α -stabilne $S_\alpha(\sigma, \beta, \mu)$:

Zmienna losowa X ma rozkład α -stabilny, $0 < \alpha \leq 2$, z parametrem skali $\sigma > 0$, z parametrem asymetrii $\beta \in [-1, 1]$ i z parametrem położenia $\mu \in \mathbb{R}$, jeżeli jej funkcja charakterystyczna $\phi(t)$ jest dana wzorem:

$$\ln \phi(t) = \begin{cases} -\sigma^\alpha |t|^\alpha \left(1 - i\beta \operatorname{sign} t \operatorname{tg} \frac{\pi\alpha}{2}\right) + i\mu t, & \alpha \neq 1, \\ -\sigma |t| \left(1 - i\beta \operatorname{sign} t \frac{2}{\pi} \ln |t|\right) + i\mu t, & \alpha = 1. \end{cases}$$

- ▷ Dla $\alpha = 2$ – rozkład normalny.
 - ▷ Dla $\alpha = 1$ – rozkład Cauchy'ego.
 - ▶ W pozostałych przypadkach nie jest znany wzór analityczny dla gęstości prawdopodobieństwa lub dystrybuanty tego rozkładu!
 - ▷ Dla $0 < \alpha < 2$ – rozkład Levy'ego, który ma zachowanie asymptotyczne w postaci tzw. ogonów Pareto: $\sim \sigma^\alpha / |x|^{1+\alpha}$.
- ¶ **Dygresja:** Rozkład jest stabilny jeżeli suma niezależnych zmiennych losowych z tego rozkładu jest też zmienną losową z tego rozkładu (choć z innymi parametrami).

Jeżeli zmienna losowa X ma rozkład $S_\alpha(1, \beta, 0)$, to zmienna losowa Y dana wzorem:

$$Y = \begin{cases} \sigma X + \mu & \alpha \neq 1, \\ \sigma X + \frac{2}{\pi} \beta \sigma \ln \sigma + \mu & \alpha = 1, \end{cases}$$

ma rozkład $S_\alpha(\sigma, \beta, \mu)$.

► Algorytm generowania zmiennej losowej X (Chambers, Mallows, Stuck, 1976):

1. Wygenerować zmienną losową: $U \in \mathcal{U}(-\pi/2, \pi/2)$.
2. Wygenerować zmienną losową W o rozkładzie wykładniczym $E(0, 1)$.

A) Dla $\alpha = 1$ obliczyć:

$$X = \frac{2}{\pi} \left[\left(\frac{\pi}{2} + \beta U \right) \operatorname{tg} U - \beta \ln \frac{\frac{\pi}{2} W \cos U}{\frac{\pi}{2} + \beta U} \right],$$

B) Dla $\alpha \neq 1$ obliczyć:

$$X = S_{\alpha, \beta} \frac{\sin(\alpha[U + B_{\alpha, \beta}])}{(\cos U)^{1/\alpha}} \left\{ \frac{\cos(U - \alpha[U + B_{\alpha, \beta}])}{W} \right\}^{(1-\alpha)/\alpha},$$

gdzie:

$$B_{\alpha, \beta} = \alpha^{-1} \operatorname{arc} \operatorname{tg} \left(\beta \operatorname{tg} \frac{\pi \alpha}{2} \right), \quad S_{\alpha, \beta} = \left(1 + \beta^2 \operatorname{tg}^2 \frac{\pi \alpha}{2} \right)^{1/(2\alpha)}.$$

Rozkład dwumianowy (Bernoulliego) $b(n, p)$:

► Gęstość prawdopodobieństwa:

$$\mathcal{P}\{X = m\} = \binom{n}{m} p^m (1 - p)^{n-m}, \quad m = 0, 1, 2, \dots, n.$$

→ Liczba sukcesów w schemacie Bernoulliego z prawdopodobieństwem sukcesu p .

► **Algorytm 1:** (typu „Igła Buffona”)

```
m = 0;
for (i = 0; i < n; i++) {
    U = GenU(0,1);           // tzn. U z rozkładu U(0,1)
    if (U <= p) m++;
}
return m;
```

▷ **Wada:** Wymaga wielu liczb losowych.

Jeżeli n nie jest bardzo duże, to może opłacać się stabilizowanie dystrybuanty, tzn. obliczenie:

$$p_k = \sum_{i=0}^k \mathcal{P}\{X = i\}$$

i skorzystanie z następującego algorytmu, który wymaga tylko jednej liczby losowej:

► **Algorytm 2:**

```
m = 0;  
U = GenU(0,1);           // tzn. U z rozkładu U(0,1)  
while (U > p[m]) m++;  
return m;
```

Jeżeli n jest duże, ale może być przedstawione w postaci $n = kl$, gdzie l nie jest bardzo duże, to może opłacać się generowanie k liczb losowych o rozkładach dwumianowych $b(l, p)$ za pomocą powyższego algorytmu i obliczenie m jako sumy tak wygenerowanych liczb.

LEMAT:

Jeżeli zmienna losowa $U \in \mathcal{U}(0, 1)$, to zmienne losowe:

$$Y = \Theta(p - U) \quad \text{oraz} \quad V = \min \left\{ \frac{U}{p}, \frac{1 - U}{1 - p} \right\}$$

są niezależne i $V \in \mathcal{U}(0, 1)$.

Dowód: np. [Wieczorkowski i Zieliński \(1997\)](#).

▷ Zmienną losową Y możemy traktować jako wskaźnik pojawienia się sukcesu, a zmienną losową V jako zmienną losową o rozkładzie $\mathcal{U}(0, 1)$ w niezależnym powtórzeniu doświadczenia w schemacie Bernoulliego.

► **Algorytm 3:** (potrzebna tylko jedna liczba losowa!)

```

m = 0;
U = GenU(0,1);           // tzn. U z rozkładu U(0,1)
for (i = 0; i < n; i++)
    if (U <= p) { m++; U /= p; }
    else U = (1 - U)/(1 - p);
return m;

```

⇒ **Ćw. N9.5:** Zaimplementować generatory rozkładu dwumianowego według powyższych algorytmów.

Rozkład Poissona $P(\lambda)$:

► Gęstość prawdopodobieństwa:

$$\mathcal{P}\{X = n\} = \frac{\lambda^n}{n!} e^{-\lambda}, \quad n = 0, 1, 2, \dots$$

A) LEMAT:

Jeżeli $\xi_0, \xi_1, \xi_2, \dots$ – niezależne zmienne losowe o rozkładzie wykładniczym $E(0, 1)$, to zmienna losowa:

$$X = \min \left\{ k : \sum_{i=0}^k \xi_i > \lambda \right\}$$

ma rozkład Poissona $P(\lambda)$.

Dowód: Zdarzenia losowe: $\{X \leq k\}$ oraz $\{\sum_{i=0}^k \xi_i > \lambda\}$ są równoważne.

Zmienna losowa $\sum_{i=0}^k \xi_i$ ma rozkład $\Gamma(k+1, 1)$, gdzie $\Gamma(\alpha, \theta)$ – rozkład gamma o gęstości:

$$f_{\alpha, \theta}(x) = \frac{1}{\Gamma(\alpha) \theta^\alpha} x^{\alpha-1} e^{-x/\theta}.$$

Zatem $\mathcal{P}\{X \leq k\} = \int_{\lambda}^{+\infty} f_{k+1, 1}(x) dx$ i wystarczy pokazać, że

$\mathcal{P}\{X = k\} = \mathcal{P}\{X \leq k\} - \mathcal{P}\{X \leq k-1\}$ jest równe prawdopodobieństwu Poissona. \square

▶ **Algorytm 1:**

```
X = -1; S = 0;
while (S <= lambda) {
    Y = GenE(0,1);           // tzn. Y z rozkładu E(0,1)
    S += Y; X++;
}
return X;
```

→ **Oczywista odmiana tego algorytmu:**

▶ **Algorytm 2:**

```
X = -1; S = 1; q = exp(-lambda);
while (S > q) {
    U = GenU(0,1);         // tzn. U z rozkładu U(0,1)
    S *= U; X++;
}
return X;
```

▷ **Wada: Wymagają wielu liczb losowych.**

B) Metoda odwracania dystrybuanty (ogólna):**► Algorytm 3:**

```
X = 0;
q = exp(-lambda);
S = P = q;
U = GenU(0,1);           // tzn. U z rozkładu U(0,1)
while (U > S) {
    X++;
    P *= lambda/X;
    S += P;
}
return X;
```

▷ **Wada:** Dla dużych wartości λ kumulacja błędów zaokrążeń przy obliczaniu prawdopodobieństw P może prowadzić do niedokładności numerycznych.

⇒ **Ćw. N9.6:** Zaimplementować generatory rozkładu Poissona według powyższych algorytmów i wygenerować rozkłady dla kilku wartości λ .

Rozkład geometryczny $G(p)$:

► Gęstość prawdopodobieństwa:

$$\mathcal{P}\{X = n\} = (1 - p) p^n, \quad n = 0, 1, 2, \dots$$

LEMAT:

Jeżeli zmienna losowa X ma rozkład wykładniczy o gęstości:

$$f_\alpha(x) = \alpha e^{-\alpha x},$$

to zmienna losowa $\lfloor X \rfloor$ (tzn. część całkowita X) ma rozkład geometryczny:

$$G(e^{-\alpha}).$$

► Algorytm:

1. Generujemy zmienną losową: $U \in \mathcal{U}(0, 1)$.
2. Obliczamy: $X = \lfloor \ln U / \ln p \rfloor$.

⇒ Ćw. N9.7: Zaimplementować generator rozkładu geometrycznego i wygenerować rozkłady dla kilku wartości p .

Metoda równomiernego rozbicia przedziału $(0, 1)$:

► Ogólny rozkład dyskretny:

$$\mathcal{P}\{X = k\} = p_k, \quad k = 0, 1, \dots, K.$$

▷ Czasami metoda odwracania dystrybuanty (patrz wykład 6) może być bardzo wolna (duża wartość K)!

► Bardziej wydajna metoda:

- Przedział $(0, 1)$ dzielimy na $K + 1$ podprzedziałów (binów) $\left(\frac{i-1}{K+1}, \frac{i}{K+1}\right)$ o jednakowej długości i numerujemy je kolejnymi liczbami $1, 2, \dots, K + 1$.
→ Zmienna $U \in \mathcal{U}(0, 1)$ wpada do binu o numerze $\lfloor (K + 1)U + 1 \rfloor$.
- Tworzymy ciąg: $q_j = \sum_{k=0}^j p_k, \quad j = 0, 1, \dots, K$.
- Tworzymy pomocniczy ciąg liczb: $g_i = \max \left\{ j : q_j < \frac{i}{K+1} \right\}, \quad i = 1, 2, \dots, K + 1$.

► Algorytm:

```
U = GenU(0, 1); // tzn. U z rozkładu U(0, 1)
X = g[(int) (K + 1)U + 1] + 1;
while (q[X-1] > U) X--; // oczekiwana liczba porównan <= 2
return X;
```

Metody ogólne:

Niech \vec{X} – m -wymiarowa zmienna losowa o gęstości prawdopodobieństwa $f(x_1, x_2, \dots, x_m)$.

► Do generowania gęstości wielowymiarowej zmiennej losowej można stosować metody eliminacji oraz superpozycji rozkładów.

▷ Mogą się pojawić większe trudności techniczne, np. problem obszaru zmiennej losowej \vec{X} !

PRZYKŁAD:

Generowanie rozkładu równomiernego w kuli jednostkowej $K_m(0, 1)$ metodą eliminacji względem rozkładu równomiernego na kostce $[-1, 1]^m$.

→ Prawdopodobieństwo akceptacji: $p_m = \pi^{m/2} / [2^m \Gamma(m/2 + 1)]$.

m	p_m	$N_m = 1/p_m$
2	$7.854 \cdot 10^{-1}$	1.27
5	$1.645 \cdot 10^{-1}$	6.08
10	$2.490 \cdot 10^{-3}$	$4.015 \cdot 10^2$
20	$2.461 \cdot 10^{-8}$	$4.063 \cdot 10^7$
50	$1.537 \cdot 10^{-28}$	$6.507 \cdot 10^{28}$

Metody ogólne – c.d.

- Metoda eliminacji względem rozkładu równomiernego na wielowymiarowym hiperprostokącie $\prod_{j=1}^m [a_j, b_j]$ jest najbardziej ogólną metodą generowania rozkładu równomiernego na dowolnym obszarze: $\Omega \subset \mathbb{R}^m$.
- Niektóre obszary Ω można otrzymać przez nieosobliwe liniowe przekształcenie prostszych obszarów:
 - ▷ kula $K_m(0, 1) \rightarrow$ elipsoidy w \mathbb{R}^m ;
 - ▷ sfera $S_m(0, 1) \rightarrow$ powierzchnia elipsoidy w \mathbb{R}^m ;
 - ▷ sympleks \rightarrow niektóre wielościany wypukłe;
 - ▷ powierzchnia sympleksu \rightarrow powierzchnie takich wielościanów.
 Jeżeli $\vec{X} \in \mathcal{U}(\Omega)$ oraz F – nieosobliwe przekształcenie liniowe \mathbb{R}^m , to $F(\vec{X}) \in U(F(\Omega))$.
- Gęstość wielowymiarowego rozkładu możemy przedstawić w postaci iloczynu gęstości rozkładów brzegowych i warunkowych:

$$f(x_1, \dots, x_m) = f(x_1)f(x_2|x_1)f(x_3|x_1, x_2) \dots f(x_n|x_1, x_2, \dots, x_{n-1}).$$
 \rightarrow Zmienną losową $\vec{X} = (X_1, \dots, X_m)$ generujemy „współrzędna po współrzędnej”, tzn. X_i wg. rozkładu $f(x_i|x_1, x_2, \dots, x_{i-1})$ po wygenerowaniu: X_1, \dots, X_{i-1} .

- **Rozkład równomierny na sferze** $S_m(0, 1)$:

$$S_m(0, 1) = \left\{ (x_1, \dots, x_m) : \sum_{j=1}^m x_j^2 = 1 \right\}.$$

► **Algorytm:**

- 1) Generuj zmienne losowe Z_1, \dots, Z_m o rozkładzie normalnym $N(0, 1)$.
- 2) Oblicz: $X_j = Z_j / \sqrt{\sum_{i=1}^m Z_i^2}$, $j = 1, 2, \dots, m$.
- 3) Return $X = (X_1, \dots, X_m)$.

- **Rozkład równomierny na kuli** $K_m(0, 1)$:

$$K_m(0, 1) = \left\{ (y_1, \dots, y_m) : \sum_{j=1}^m y_j^2 \leq 1 \right\}.$$

Jeżeli zmienna losowa Y ma rozkład równomierny na kuli $K_m(0, 1)$, to długość promienia wodzącego punktu Y jest zmienną losową o rozkładzie potęgowym z gęstością:

$$h(r) = mr^{m-1}, \quad 0 \leq r \leq 1.$$

► **Algorytm:**

- 1) Generuj zmienną losową X o rozkładzie równomiernym na sferze $S_m(0, 1)$.
- 2) Generuj R według rozkładu o dystrybuancie $H(r) = r^m$, $0 \leq r \leq 1$.
- 3) Return $Y = (RX_1, \dots, RX_m)$.

- **Rozkład równomierny na sympleksie** $W_m \rightarrow$ LEMAT:

Jeżeli $U_1, \dots, U_m \in \mathcal{U}(0, 1)$ oraz $U_{1:m}, \dots, U_{m:m}$ jest ciągiem odpowiednich statystyk pozycyjnych, to zmienna losowa $\vec{X} = (X_1, \dots, X_m)$ dana wzorami:

$$X_1 = U_{1:m}, \quad X_2 = U_{2:m} - U_{1:m}, \quad \dots, \quad X_m = U_{m:m} - U_{m-1:m}$$

ma rozkład równomierny na sympleksie:

$$W_m = \left\{ (x_1, \dots, x_m) : \sum_{j=1}^m x_j \leq 1, \quad x_j \geq 0, \quad j = 1, 2, \dots, m \right\}.$$

- **Rozkład równomierny na powierzchni sympleksu** $V_m \rightarrow$ LEMAT:

Jeżeli $U_1, \dots, U_{m-1} \in \mathcal{U}(0, 1)$ oraz $U_{1:m-1}, \dots, U_{m-1:m-1}$ jest ciągiem odpowiednich statystyk pozycyjnych, to zmienna losowa $\vec{X} = (X_1, \dots, X_m)$ dana wzorami:

$$X_1 = U_{1:m-1}, \quad \dots, \quad X_{m-1} = U_{m-1:m-1} - U_{m-2:m-1}, \quad X_m = 1 - U_{m-1:m-1}$$

ma rozkład równomierny na powierzchni sympleksu:

$$V_m = \left\{ (x_1, \dots, x_m) : \sum_{j=1}^m x_j = 1, \quad x_j \geq 0, \quad j = 1, 2, \dots, m \right\}.$$

\Rightarrow **Ćw. N9.8:** Zaimplementować generatory dla rozkładów na sferze, kuli, sympleksie i jego powierzchni.