

### Poprzednim razem

Wielowymiarowe zmienne losowe

- Łączny rozkład prawdopodobieństwa  $P_{X,Y}(x, y_j)$
- Brzegowy rozkład prawdopodobieństwa  $P_X(x) = \sum_j P_{X,Y}(x, y_j)$
- Łączna dystrybuanta  $F_{X,Y}(x, y) = \sum_{x_i \leq x} \sum_{y_j \leq y} P_{X,Y}(x_i, y_j)$
- Łączna funkcja gęstości prawdopodobieństwa  $f_{X,Y}(x, y) = \frac{\partial^2 F_{X,Y}(x, y)}{\partial x \partial y}$   $F_{X,Y}(x, y) = \int_{-\infty}^x \int_{-\infty}^y f_{X,Y}(u, v) du dv$
- Brzegowa funkcja gęstości prawdopodobieństwa  $f_X(x) = \int_{-\infty}^{+\infty} f_{X,Y}(x, v) dv$

### Poprzedni razem cd

$$cov(X, Y) = E[(X - E(X))(Y - E(Y))] = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} (x - E(X))(y - E(Y)) f_{X,Y}(x, y) dx dy$$

$$\rho_{X,Y} \equiv \rho(X, Y) \equiv corr(X, Y) = \frac{cov(X, Y)}{\sqrt{var(X)var(Y)}}$$

$$-1 \leq \rho_{X,Y} \leq 1$$

$$\rho_{X,Y} = 1 \quad \text{dla } Y = aX + b \quad a > 0$$

$$\rho_{X,Y} = -1 \quad \text{dla } Y = aX + b \quad a < 0$$

### Współczynnik korelacji zmiennych losowych

#### 4. Współczynnik korelacji jest miarą zależności liniowej

$$\rho_{X,Y} = 1 \quad \text{dla } Y = aX + b \quad a > 0$$

$$\rho_{X,Y} = -1 \quad \text{dla } Y = aX + b \quad a < 0$$

Dowód:  
 $Y = aX + b$   
 $\rightarrow E(Y) = E(aX + b) = aE(X) + b$   
 $var(Y) = var(aX + b) = a^2 var(X)$   
 $cov(X, Y) = E[(X - E(X))(Y - E(Y))] = E[(X - E(X))(aX + b - aE(X) - b)] =$   
 $= E[(X - E(X))(aX - aE(X))] = aE[(X - E(X))(X - E(X))] =$   
 $= aE[(X - E(X))^2] = a var(X)$

$$\rightarrow \rho_{X,Y} = \frac{cov(X, Y)}{\sqrt{var(X)var(Y)}} = \frac{a var(X)}{\sqrt{var(X) \cdot a^2 var(X)}} = \frac{a var(X)}{\sqrt{a^2 (var(X))^2}} = \frac{a var(X)}{|a| var(X)} = \frac{a}{|a|}$$

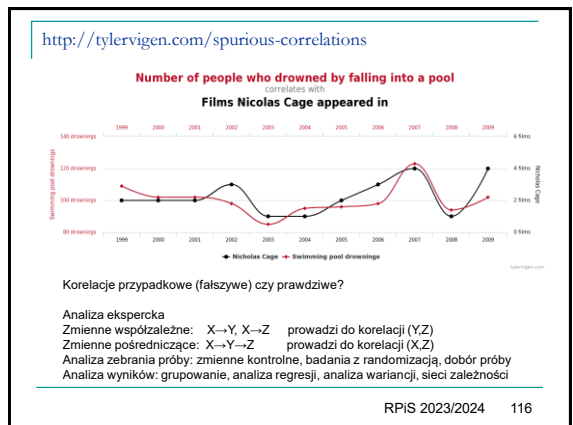
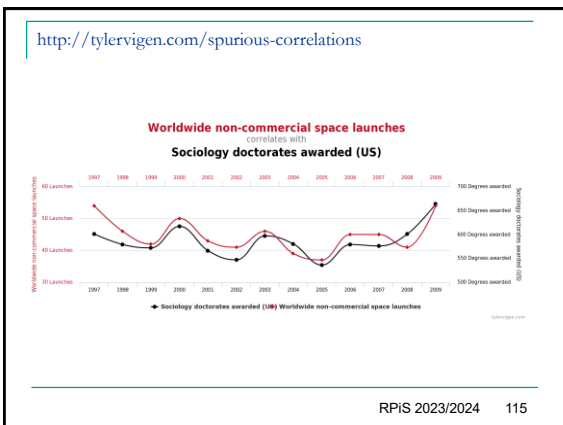
RPIS 2023/2024 3

### Współczynnik korelacji zmiennych losowych

- Jeżeli  $\rho_{X,Y} = 0$  to zmienne X i Y nie muszą być niezależne; nazywamy je wtedy **niekorelowanymi**.  
 Ważny wyjątek: jeżeli X i Y mają rozkłady normalne i  $\rho_{X,Y} = 0$  to zmienne X i Y są niezależne.
- Jeżeli  $\rho_{X,Y} \neq 0$  to zmienne X i Y nie są niezależne.
- Macierz kowariancji**  

$$K_{X_1, \dots, X_n} = \begin{pmatrix} var(X_1) & cov(X_1, X_2) & \dots & cov(X_1, X_n) \\ cov(X_1, X_2) & var(X_2) & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ cov(X_1, X_n) & \dots & \dots & var(X_n) \end{pmatrix} \xrightarrow{\text{2-dim}} K_{X,Y} = \begin{pmatrix} var(X) & cov(X, Y) \\ cov(Y, X) & var(Y) \end{pmatrix}$$
 Jest symetryczna, bo  $cov(X_i, X_j) = cov(X_j, X_i)$ .  
 $V_N = \frac{2}{N} \frac{\pi^{N/2}}{\Gamma(N/2)}$
- Korelacja jako narzędzie testowania generatorów liczb pseudolosowych ( $\rho_{X,Y} = 0$ ), zadania kontrolne, np. N-wymiarowa kula o R=1.

RPIS 2023/2024 4



### Wektor losowy – przypadek n>2

- Syt.: dany jest n-wymiarowy wektor losowy  $\vec{X}$ , z którego tworzymy wielowymiarową zmienną losową  $\vec{Y}$ :  
 $\vec{Y} = \vec{Y}(\vec{X})$

rozwijamy wokół  $Y=E(X)$ , zostawiając czony liniowe

$$Y_i = \underbrace{Y_i(E(\vec{X}))}_{E(Y_i)} + \sum_j \left( \frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} (X_j - E(X_j)) + \dots$$

$$Y_i - E(Y_i) = \sum_j \left( \frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} (X_j - E(X_j))$$

RPiS 2023/2024 7

### Prawo przenoszenia błędów

$$\begin{aligned} \text{cov}(Y_i, Y_q) &= E[(Y_i - E(Y_i))(Y_q - E(Y_q))] = \\ &= E \left[ \sum_j \left( \frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} (X_j - E(X_j)) \sum_m \left( \frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} (X_m - E(X_m)) \right] = \\ &= \sum_{l,m} \left( \frac{\partial Y_i}{\partial X_l} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} E[(X_l - E(X_l))(X_m - E(X_m))] = \\ &= \sum_{l,m} \left( \frac{\partial Y_i}{\partial X_l} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} \text{cov}(X_l, X_m) \\ [C(Y)]_{i,m} &\equiv \text{cov}(X_i, X_m); \quad [C(Y)]_{k,q} \equiv \text{cov}(Y_k, Y_q); \quad T_{i,j} \equiv \left( \frac{\partial Y_i}{\partial X_j} \right)_{\vec{X}=E(\vec{X})} \\ [C(Y)]_{k,q} &= \sum_{l,m} T_{k,l} T_{q,m} [C(X)]_{l,m} = \sum_{l,m} T_{k,l} [C(X)]_{l,m} T_{m,q}^T \\ [C(Y)] &= T C(X) T^T \quad \leftarrow \text{macierzowo} \end{aligned}$$

RPiS 2023/2024 8

### Prawo przenoszenia błędów - przykład

$$\text{cov}(Y_k, Y_q) = \sum_{l,m} \left( \frac{\partial Y_k}{\partial X_l} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial Y_q}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} \text{cov}(X_l, X_m)$$

- Pomiar średniej prędkości polega na pomiarze dystansu i czasu w jakim ten dystans jest pokonywany

$$\begin{aligned} \text{var}(v) &= \text{cov}(v, v) = \sum_{l,m} \left( \frac{\partial v}{\partial X_l} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial X_m} \right)_{\vec{X}=E(\vec{X})} \text{cov}(X_l, X_m) = \\ &= \left( \frac{\partial v}{\partial s} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial s} \right)_{\vec{X}=E(\vec{X})} \text{cov}(s, s) + \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \text{cov}(t, t) + \\ &+ \left( \frac{\partial v}{\partial s} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \text{cov}(t, s) + 2 \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial s} \right)_{\vec{X}=E(\vec{X})} \text{cov}(s, t) + \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \left( \frac{\partial v}{\partial t} \right)_{\vec{X}=E(\vec{X})} \text{var}(t) = \\ &= \frac{1}{t^2} (\sigma(s))^2 + \frac{2s}{t^2} \text{cov}(s, t) + \frac{s^2}{t^2} (\sigma(t))^2 \end{aligned}$$

- Zał: zmienne (s,t) są niezależne  $\rightarrow \text{cov}(s,t)=0$

$$\text{var}(v) = \frac{1}{t^2} (\sigma(s))^2 + \frac{s^2}{t^2} (\sigma(t))^2 \rightarrow \sigma(v) = \sqrt{\frac{1}{t^2} (\sigma(s))^2 + \frac{s^2}{t^2} (\sigma(t))^2}$$

RPiS 2023/2024 9

### Transformacje wektorów losowych

- Syt.  $\vec{Z} = g(\vec{X})$
- Przypadek dyskretny: grupujemy te wartości  $\vec{X}$ , które dają te same wartości  $\vec{Z}$  i dodajemy prawdopodobieństwa. Otrzymujemy rozkład prawdopodobieństwa wektora losowego  $\vec{Z}$ .
- Przypadek ciągły:
  - I sposób: (zał. Z jest jednowymiarowe czyli  $Z = g(X_1, X_2, \dots, X_n)$ )

$$F_Z(z) = \int \dots \int_{\substack{\text{po wszystkich zdarzeniach} \\ \text{dla których } Z(A) \leq z}} f_{\vec{X}}(x_1, x_2, \dots, x_n) dx_1 \dots dx_n$$

Znając dystrybuantę obliczamy (łącznie) funkcję gęstości prawdopodobieństwa.

Dla Z n-wymiarowej całkujemy po wszystkich zdarzeniach dla których  $Z_1(A) \leq z_1 \wedge Z_2(A) \leq z_2 \wedge \dots \wedge Z_n(A) \leq z_n$ .

RPiS 2023/2024 10

### Transformacje wektorów losowych

- Przypadek ciągły:
  - II sposób:
    - zał.:
    - 1. n=2 czyli  $(X,Y) \rightarrow (V,W)$  czyli  $V=g_1(X,Y)$ ,  $W=g_2(X,Y)$
    - 2. istnieją jednoznaczne funkcje  $h_1: X=h_1(V,W)$  i  $h_2: Y=h_2(V,W)$
    - 3. dla każdego x,y funkcje  $g_1$  i  $g_2$  mają ciągłe pochodne cząstkowe
    - 4. Jacobian

$$J_{(X,Y)} \equiv \begin{vmatrix} \frac{\partial g_1}{\partial X} & \frac{\partial g_1}{\partial Y} \\ \frac{\partial g_2}{\partial X} & \frac{\partial g_2}{\partial Y} \end{vmatrix} \neq 0$$

Wtedy

$$f_{V,W}(v,w) = f_{X,Y}(x(v,w), y(v,w)) |J_{(X,Y)}|^{-1}$$

RPiS 2023/2024 11

### Transformacje wektorów losowych - przykład

- Niezależne zmienne losowe X,Y mają rozkłady jednorodne na (0,1). Znaleźć łączną funkcję gęstości prawdopodobieństwa zmiennych  $V = \sqrt{-2 \ln(X)} \cos(2\pi Y)$  oraz  $W = \sqrt{-2 \ln(X)} \sin(2\pi Y)$
- Rozwiązanie:
  - Z treści zadania:  $f_{X,Y}(x,y) = f_X(x) \cdot f_Y(y) = 1 \cdot 1 = 1$
  - Potrzebujemy:  $f_{V,W}(v,w) = f_{X,Y}(x(v,w), y(v,w)) |J_{(X,Y)}|^{-1}$
  - Liczmy

$$\begin{aligned} \frac{\partial v}{\partial x} &= \frac{\partial}{\partial x} (\sqrt{-2 \ln(X)} \cos(2\pi Y)) = \cos(2\pi Y) \frac{\partial}{\partial x} (\sqrt{-2 \ln(X)}) = \frac{\cos(2\pi Y)}{2\sqrt{-2 \ln(X)}} \cdot \left( \frac{-2}{x} \right) \\ \frac{\partial v}{\partial y} &= \frac{\partial}{\partial y} (\sqrt{-2 \ln(X)} \cos(2\pi Y)) = \sqrt{-2 \ln(X)} \frac{\partial}{\partial y} (\cos(2\pi Y)) = \sqrt{-2 \ln(X)} \cdot (-1) \sin(2\pi Y) \cdot 2\pi \\ \frac{\partial w}{\partial x} &= \frac{\partial}{\partial x} (\sqrt{-2 \ln(X)} \sin(2\pi Y)) = \sin(2\pi Y) \frac{\partial}{\partial x} (\sqrt{-2 \ln(X)}) = \frac{\sin(2\pi Y)}{2\sqrt{-2 \ln(X)}} \cdot \left( \frac{-2}{x} \right) \\ \frac{\partial w}{\partial y} &= \frac{\partial}{\partial y} (\sqrt{-2 \ln(X)} \sin(2\pi Y)) = \sqrt{-2 \ln(X)} \frac{\partial}{\partial y} (\sin(2\pi Y)) = \sqrt{-2 \ln(X)} \cdot \cos(2\pi Y) \cdot 2\pi \end{aligned}$$

RPiS 2023/2024 12

### Transformacje wektorów losowych - przykład

$V = \sqrt{-2\ln(X)} \cos(2\pi Y)$   
 $W = \sqrt{-2\ln(X)} \sin(2\pi Y)$

$$J_{(X,Y)} = \det \begin{pmatrix} \frac{\partial V}{\partial X} & \frac{\partial V}{\partial Y} \\ \frac{\partial W}{\partial X} & \frac{\partial W}{\partial Y} \end{pmatrix} = \frac{\partial V}{\partial X} \frac{\partial W}{\partial Y} - \frac{\partial V}{\partial Y} \frac{\partial W}{\partial X} = (\cos(2\pi Y))^2 \cdot \frac{(-2\pi)}{X} - (\sin(2\pi Y))^2 \cdot \frac{(-2\pi)}{X} = \frac{(-2\pi)}{X} \left( (\cos(2\pi Y))^2 + (\sin(2\pi Y))^2 \right) = \frac{(-2\pi)}{X}$$

$$|J_{(X,Y)}|^{-1} = \left| \frac{(-2\pi)}{X} \right|^{-1} = \left( \frac{X}{2\pi} \right)^{-1} = \frac{X}{2\pi}$$

$$V^2 + W^2 = \left( \sqrt{-2\ln(X)} \cos(2\pi Y) \right)^2 + \left( \sqrt{-2\ln(X)} \sin(2\pi Y) \right)^2 = \left( \sqrt{-2\ln(X)} \right)^2 = -2\ln(X)$$

$\rightarrow X = e^{-(V^2+W^2)/2} \rightarrow |J_{(X,Y)}|^{-1} = \frac{X}{2\pi} e^{-(V^2+W^2)/2}$   
 $\rightarrow f_{X,W}(v,w) = f_{X,Y}(x(v,w), y(v,w)) |J_{(X,Y)}|^{-1} = \frac{1}{2\pi} e^{-(v^2+w^2)/2}$   
 $\rightarrow f_{X,W}(v,w) = \frac{1}{2\pi} e^{-v^2/2} \cdot \frac{1}{\sqrt{2\pi}} e^{-w^2/2} = N_v(0,1) \cdot N_w(0,1) = f_v \cdot f_w(w)$

**Dwa niezależne rozkłady N(0,1)**

RPIS 2023/2024 13

### Transformacja Box-Mullera

$X_1, X_2$  mają rozkłady jednorodne na przedziale (0,1); wtedy  
 $Y_1 = \sqrt{-2\ln(X_1)} \cos(2\pi X_2)$      $Y_2 = \sqrt{-2\ln(X_1)} \sin(2\pi X_2)$

mają rozkłady N(0,1).

RPIS 2023/2024 14

### Wielowymiarowy rozkład normalny

**Łączna gęstość prawdopodobieństwa**  
 $f_{\vec{X}}(\vec{x}) = \left( \frac{\det(K^{-1})}{(2\pi)^n} \right)^{1/2} e^{-\frac{1}{2}(\vec{x}-\vec{a})^T K^{-1}(\vec{x}-\vec{a})}$

$\vec{X}$  - wektor n zmiennych losowych  
 $K$  - macierz kowariancji n×n  
 $\vec{a}$  - stały wektor n liczb  
 $(E(\vec{X})=\vec{a})$

**dla n=2**  
 $K^{-1} = \frac{1}{\text{var}(X_1)\text{var}(X_2) - (\text{cov}(X_1, X_2))^2} \begin{pmatrix} \text{var}(X_2) & -\text{cov}(X_1, X_2) \\ -\text{cov}(X_1, X_2) & \text{var}(X_1) \end{pmatrix}$

**Standaryzacja**  $U_i = \frac{X_i - a_i}{\sigma(X_i)}$  dla n=2 prowadzi do  $\rho$  to współczynnik korelacji  $u_1$  i  $u_2$

$$f_{\vec{U}}(u_1, u_2) = \left( \frac{\det(K^{-1})}{(2\pi)^2} \right)^{1/2} e^{-\frac{1}{2}u^T K^{-1}u}$$

$$K^{-1} = \frac{1}{1-\rho^2} \begin{pmatrix} 1 & -\rho \\ -\rho & 1 \end{pmatrix}$$

RPIS 2023/2024 15

### Wielowymiarowy rozkład normalny - elipsa kowariancji

**Łączna gęstość prawdopodobieństwa**  
 $f_{\vec{U}}(u_1, u_2) = \text{const} \rightarrow \vec{u}^T K^{-1} \vec{u} = \text{const} \rightarrow$

$$\frac{1}{1-\rho^2} (u_1^2 + u_2^2 - 2u_1 u_2 \rho) = \text{const} \rightarrow$$

$$\frac{1}{1-\rho^2} \left( \frac{(x_1 - a_1)^2}{(\sigma(X_1))^2} + \frac{(x_2 - a_2)^2}{(\sigma(X_2))^2} - 2\rho \frac{(x_1 - a_1)(x_2 - a_2)}{\sigma(X_1)\sigma(X_2)} \right) = \text{const}$$

**Jest to równanie elipsy zwanej dla const=1 elipsą kowariancji.**  
 Prawdopodobieństwo wystąpienia zmiennych losowych wewnątrz elipsy kowariancji jest niezależne od  $\sigma(X_1), \sigma(X_2)$  i  $\rho$ .

RPIS 2023/2024 16

### Dystrybuanta warunkowa

**Syt.** Szukamy **dystrybuanty warunkowej zmiennej X** czyli dystrybuanty zmiennej X pod warunkiem, że zmienna losowa Y=y. Ale dla zmiennej ciągłej P(Y=y)=0 dlatego rozpatrujemy  $y < Y < y+dy$  i przejdziemy do granicy  $dy \rightarrow 0$ .

$$\int_{-\infty}^x \int_y^{y+dy} f_{X,Y}(u,v) du dv = F_{X|Y}(x|Y \in (y, y+dy)) \cdot \int_y^{y+dy} f_Y(v) dv$$

$$\int_{-\infty}^x f_{X,Y}(u,y) du dy = F_{X|Y}(x|Y \in (y, y+dy)) \cdot f_Y(y) dy \quad /: dy \quad / dy \rightarrow 0$$

$$\int_{-\infty}^x f_{X,Y}(u,y) du = F_{X|Y}(x|Y=y) \cdot f_Y(y)$$

$$F_{X|Y}(x|y) = \frac{\int_{-\infty}^x f_{X,Y}(u,y) du}{f_Y(y)}$$

RPIS 2023/2024 17

### Warunkowa funkcja gęstości prawdopodobieństwa

$$f_{X|Y}(x|y) = \frac{d}{dx} F_{X|Y}(x|y) = \frac{f_{X,Y}(x,y)}{f_Y(y)}$$

**Definicja** ta prowadzi do równoważnej definicji niezależności dwóch zmiennych losowych poprzez warunek:

$$f_{X|Y}(x|y) = \frac{f_{X,Y}(x,y)}{f_Y(y)}$$

$$f_{X|Y}(x|y) \cdot f_Y(y) = f_{X,Y}(x,y)$$

$$f_{X|Y}(x|y) \cdot f_Y(y) = f_X(x) \cdot f_Y(y)$$

$$f_{X|Y}(x|y) = f_X(x) \quad /: \int_{-\infty}^y dx$$

$$F_{X|Y}(v|y) = F_X(v)$$

RPIS 2023/2024 18

### Warunkowa wartość oczekiwana

$$E(X | Y = y) = \int_{-\infty}^{+\infty} x f_{X|Y}(x | y) dx$$

- Jest to funkcja zmiennej losowej Y, zatem E(X|Y) też jest zmienną losową

$$E[E(X | Y)] = \int_{-\infty}^{+\infty} E(X | Y = y) f_Y(y) dy =$$

$$= \int_{-\infty}^{+\infty} \left[ \int_{-\infty}^{+\infty} x f_{X|Y}(x | y) dx \right] f_Y(y) dy = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x \frac{f_{X,Y}(x,y)}{f_Y(y)} dx f_Y(y) dy =$$

$$= \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} x f_{X,Y}(x,y) dx dy = \int_{-\infty}^{+\infty} x f_X(x) dx = E(X)$$

ogólnie dla dowolnej funkcji h(X)  $E[h(X)] = E[E(h(X) | Y)]$

RPIS 2023/2024 19

Blank slide.

### Twierdzenia graniczne

Związki pomiędzy różnymi charakterystykami rozkładów najczęściej badane w jakiejś granicy.

Przykład:

- Nierówność Czebyszewa-Bienayme**  
Zał. Dla zmiennej losowej X istnieje E(X)=μ i var(X)=σ²<+∞

$$\forall a > 0: P(|X - \mu| \geq a) \leq \frac{\sigma^2}{a^2}$$

Powyższe twierdzenie nie zależy od rozkładu → ograniczenia nie są silne

RPIS 2023/2024 21

### Twierdzenia graniczne

- Prawo wielkich liczb Bernoulliego (słabe)**  
Zał. S<sub>n</sub> – liczba sukcesów (o prawdopodobieństwie p) w n próbach

$$\forall \varepsilon > 0: \lim_{n \rightarrow \infty} P\left(\left|\frac{S_n}{n} - p\right| \leq \varepsilon\right) = 1$$

- Słabe prawo „Jest bardzo prawdopodobne, że częstotliwość będzie równa p dla ustalonego, dużego n”.
- Jest to „zbieżność według prawdopodobieństwa”
- Mocne prawo wielkich liczb Bernoulliego**  
Zał. S<sub>n</sub> – liczba sukcesów (o prawdopodobieństwie p) w n próbach

$$\forall \varepsilon > 0: P\left(\lim_{n \rightarrow \infty} \left|\frac{S_n}{n} - p\right| \leq \varepsilon\right) = 1 \quad P\left(\lim_{n \rightarrow \infty} \frac{S_n}{n} = p\right) = 1$$

- Mocne prawo „Częstotliwość musi być w pobliżu p gdy n rośnie”.
- Jest to „zbieżność prawie na pewno”

RPIS 2023/2024 22

### Całkowanie metodą Monte Carlo

- Mocne prawo wielkich liczb Kołmogorowa**
- X<sub>n</sub> – ciąg niezależnych zmiennych losowych o jednakowym rozkładzie, E(|X<sub>i</sub>|) jest skończona, S<sub>n</sub>=X<sub>1</sub>+X<sub>2</sub>+...+X<sub>n</sub>

$$P\left(\lim_{n \rightarrow \infty} \frac{S_n}{n} = E(X_1)\right) = 1$$

- Uzasadnia to definicję częstotliwościową prawdopodobieństwa
- Problem: całkowanie numeryczne f(x) w przedziale (a,b)

$$I = \int_a^b f(x) dx = \int_a^b f(x) \frac{g(x)}{g(x)} dx = E\left(\frac{f(x)}{g(x)}\right) = \frac{1}{n} \sum_{i=1}^n \frac{f(x_i)}{g(x_i)}$$

$$g(x) > 0 \quad \int_a^b g(x) dx = 1 \quad \text{MPWL}$$

RPIS 2023/2024 23

### Całkowanie metodą Monte Carlo

- Zatem  $I = \int_a^b f(x) dx = \frac{1}{n} \sum_{i=1}^n \frac{f(x_i)}{g(x_i)}$
- Niech g(x) – jednostajna na przedziale (a,b).  
 $\int_a^b f(x) dx = \frac{(b-a)}{n} \sum_{i=1}^n f(x_i)$
- Zał. Znamy var(f(x<sub>i</sub>)). Wtedy var(I) = var(f(x<sub>i</sub>))/n
- Poprawę jakości można uzyskać min przez:
  - dobierając g(x) jako podobną do f(x)
  - losowanie warstwowe (rozbijamy całkę na przedziały, gdzie f(x) jest w przybliżeniu stała)
  - metodą zmiennych kontrolnych – h(x) podobne do f(x) ale o znanej calce.  
 $\int_a^b f(x) dx = \int_a^b (f(x) - h(x)) dx + \int_a^b h(x) dx$

RPIS 2023/2024 24

## Całkowanie metodą Monte Carlo

- Całkowanie metodą Monte Carlo stosujemy do całek wielokrotnych.
- Np. całka dziesięciokrotna z  $f(x_1, x_2, \dots, x_{10})$ , przy czym jednokrotne wyliczenie  $f(x_1, x_2, \dots, x_{10})$  zajmuje 0.0001 sekundy.
- Metoda prostokątów wymaga  $N^{10}$  wyliczeń funkcji  
Dla  $N=10$  czas wykonania programu  $10^{10}/10^4=10^6$  sekund (około 12 dób)
- Metoda Monte Carlo  
Niepewność  $\sigma(f(x_i)) n^{-0.5}$   
Dla  $\sigma(f(x_i))=0.01f(x_i)$  (1%) i  $n=10^6$  mamy  
dokładność rzędu 0.00001 (0.001%)  
czas wykonania programu  $10^9/10^4=100$  sekund

RPiS 2023/2024 25

## Twierdzenia graniczne

### Centralne twierdzenie graniczne

Zał. Zmienne losowe  $X_1, X_2, \dots, X_n$  są niezależnymi zmiennymi o tej samej funkcji gęstości prawdopodobieństwa z  $E(X_i)=\mu$  i  $\text{var}(X_i)=\sigma^2>0$

$$\lim_{n \rightarrow \infty} P\left(\left|\frac{x_1 + \dots + x_n - n\mu}{\sigma\sqrt{n}}\right| \leq a\right) = F_{N(0,1)}(a) - F_{N(0,1)}(-a)$$

gdzie  $F_{N(0,1)}(a)$  oznacza dystrybuantę rozkładu  $N(0,1)$ .

- Wniosek: zmienna będąca sumą innych zmiennych losowych dąży do rozkładu  $N(n\mu, n\sigma^2)$ .
- Ogólniejsza wersja twierdzenia mówi, że suma zmiennych o dowolnych funkcjach gęstości o dodatnich wariancjach, w której żaden ze składników nie dominuje, ma rozkład normalny.

RPiS 2023/2024 26