

21.04.2024

W poprzednim odcinku:

$$\mathbb{E} X = \int_{\mathbb{R}} x d\mu(x), \quad X \sim \mu$$

$$\text{Var} X = \mathbb{E} [X - \mathbb{E} X]^2 = \mathbb{E} X^2 - (\mathbb{E} X)^2$$

Jeżeli X, Y wzl., to $\mathbb{E} X \cdot Y = \mathbb{E} X \cdot \mathbb{E} Y$,

$$\text{Var} (X + Y) = \text{Var} (X) + \text{Var} (Y)$$

$$\text{Cov} (X, Y) = \mathbb{E} [(X - \mathbb{E} X)(Y - \mathbb{E} Y)]$$

$$= \mathbb{E} X Y - \mathbb{E} X \mathbb{E} Y$$

$$\text{Var} X = \text{Cov} (X, X)$$

Definicja 5.15 Niech $X = (X_1, \dots, X_n)$ będzie

n -wymiarową zmienną losową taką, że

$\mathbb{E} X_i < \infty$. Macierz

$$Q = \begin{bmatrix} \text{Cov}(X_1, X_1) & \text{Cov}(X_1, X_2) & \dots & \text{Cov}(X_1, X_n) \\ \text{Cov}(X_2, X_1) & \dots & \dots & \vdots \\ \vdots & \vdots & \ddots & \vdots \\ \text{Cov}(X_n, X_1) & \dots & \dots & \text{Cov}(X_n, X_n) \end{bmatrix}$$

nazywamy macierz kowariancji
zmiennej losowej X . Jest to wielowymiarowe
ogólnie wariancji.

Uwaga Jeżeli X_i są parami nie-
skorelowane, to Σ diagonalne.

Tw. 5.16 Macierz kowariancji Σ

zm. los. X jest symetryczna oraz
odwrotnie określona (tzn. dla każdego
 $t_1, \dots, t_n, \sum t_i t_j \sigma_{ij} \geq 0$).

Dz Ustalmy $t_1, \dots, t_n \in \mathbb{R}$. Definiujemy

$$Y = \sum_{i=1}^n t_i X_i.$$

$$0 \leq \text{Var } Y = \mathbb{E}[(Y - \mathbb{E}Y)^2] =$$

$$= \mathbb{E}\left[\left(\sum t_j X_j - \sum t_j \mathbb{E}X_j\right)^2\right] =$$

$$= \mathbb{E}\left[\left(\sum t_j (X_j - \mathbb{E}X_j)\right)^2\right] =$$

$$\begin{aligned}
& \mathbb{E} \left[\sum_{i,j} t_i (X_i - \mathbb{E}X_i) t_j (X_j - \mathbb{E}X_j) \right] = \\
& = \sum_{i,j} t_i t_j \mathbb{E} \left[(X_i - \mathbb{E}X_i)(X_j - \mathbb{E}X_j) \right] = \\
& = \sum_{i,j} t_i t_j \text{Cov}(X_i, X_j) = \sum_{i,j} t_i t_j \sigma_{ij}
\end{aligned}$$

Zadanie X - wielowym. zm. los. $\sim \mathcal{N}(m, A^{-1})$,

gdzie $m \in \mathbb{R}^d$, A jest macierzą sym.

i niejemnie określona, tzn. gęstość


X jest dana wzorem

$$f(x) = \frac{\sqrt{\det A}}{(2\pi)^{\frac{d}{2}}} e^{-\frac{1}{2} \langle x-m, x-m \rangle}$$

• Pokaż, że $\mathbb{E}X = m$, a macierz kov. jest równa A^{-1}

• Pokaż, że jeżeli X ma rozkład normalny, to X_1, \dots, X_d są niezależne iff są nieskorelowane.

Przykład Regresja liniowa. Dane są
zm. los. X i Y , są skorelowane.



$$f(x) = y = \frac{\text{Cov}(X, Y)}{\text{Var } X} (x - \mathbb{E}X) + \mathbb{E}Y$$

Zał., że tutaj jest obserwowane jedną z tych zm. los., np. X (tutaj jest mierzyc przebieg samochodu, trudno liczyć koszty eksploatacji). Szukamy funkcji f , które dobrze aproksymuje Y , to możemy przyjąć $Y = f(x)$.

Jak wyznaczyć ten wzór na f ?

Chcemy zminimalizować $\mathbb{E}[(Y - (aX + b))^2]$.

Szukamy a i b .
" $g(a, b)$

$$\left. \begin{array}{l} \frac{\partial g}{\partial a} = 2a\mathbb{E}X^2 - 2\mathbb{E}XY + 2b\mathbb{E}X = 0 \\ \frac{\partial g}{\partial b} = 2b - 2\mathbb{E}Y + 2a\mathbb{E}X = 0 \end{array} \right\}$$

$$\text{Stąd } \left. \begin{array}{l} a = \frac{\mathbb{E}XY - b\mathbb{E}X}{\mathbb{E}X^2} \\ b = \mathbb{E}Y - a\mathbb{E}X \end{array} \right\}$$

$$a\mathbb{E}X^2 - \mathbb{E}XY + \mathbb{E}Y\mathbb{E}X - a(\mathbb{E}X)^2 = 0$$

$$a\text{Var} X - \text{Cov}(X, Y) = 0$$

$$a = \frac{\text{Cov}(X, Y)}{\text{Var} X}$$

TW. 6.1 Jeżeli $\mathbb{E}X^2 < \infty$, $\mathbb{E}Y^2 < \infty$,

to

$$\mathbb{E}|XY| \leq (\mathbb{E}X^2)^{\frac{1}{2}} (\mathbb{E}Y^2)^{\frac{1}{2}}$$

TW. 6.2 Nierówność Höldera: Jeżeli

$\mathbb{E}|X|^p < \infty$ i $\mathbb{E}|Y|^q < \infty$, dla $p, q > 1$

t. że $\frac{1}{p} + \frac{1}{q} = 1$, to

$$\mathbb{E}|XY| \leq (\mathbb{E}|X|^p)^{\frac{1}{p}} (\mathbb{E}|Y|^q)^{\frac{1}{q}}$$

TW. 6.3 Nierówność Czebyszewa: Niech

X będzie zm. los. i niech $f: [0, \infty) \rightarrow [0, \infty)$

będzie niemalejąca funkcja taka, że

$f(x) > 0$ dla każdego $x > 0$. Wtedy

dla każdego $\lambda > 0$ zachodzi:

$$\mathbb{P}[|X| \geq \lambda] \leq \frac{\mathbb{E}f(|X|)}{f(\lambda)}$$

$$\text{D-o. } P[|X| \geq \lambda] = E \mathbb{1}_{\{|X| \geq \lambda\}} \leq$$

$$\leq E \left[\frac{f(|X|)}{f(\lambda)} \cdot \mathbb{1}_{\{|X| \geq \lambda\}} \right] \leq \frac{1}{f(\lambda)} E[f(|X|)]$$

Wniosek 8.4

- Nierówność Markowa ($f(x) = x^p$ dla $p > 0$):

$$P[|X| > \lambda] \leq \frac{E|X|^p}{\lambda^p}, \quad \forall \lambda > 0$$

- Nierówność Czebyszewa ($f(x) = x^2$,
zamiast X bierzemy $X - EX$):

$$P[|X - EX| \geq \lambda] \leq \frac{\text{Var } X}{\lambda^2}, \quad \forall \lambda > 0$$

- Wykładnicza nierówność Czebyszewa
($f(x) = e^{px}$): Jeżeli $E e^{px} < \infty$, $p > 0$, to

$$P[X \geq \lambda] \leq \frac{E e^{pX}}{e^{p\lambda}}, \quad \forall \lambda > 0$$

Rodzaje zbieżności zmiennych losowych.

Definicja 6.5 Załóżmy, że X_n jest ciągiem zmi. losowych. Mówimy, że

1. X_n zbiega do X prawie na pewno,

jeżeli $P(\{\omega: X_n(\omega) \rightarrow X(\omega)\}) = 1$.

Piszemy wówczas $X_n \rightarrow X$ (lub $X_n \xrightarrow{p.n.} X$)

2. X_n zbiega do X według prawdopodobieństwa,

jeżeli dla każdego $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P[\{\omega: |X_n(\omega) - X(\omega)| \geq \epsilon\}] =$$

$$\lim_{n \rightarrow \infty} P[|X_n - X| \geq \epsilon] = 0$$

Piszemy wówczas $X_n \xrightarrow{P} X$

3. X_n zbiega do X w L^p , jeżeli $X_n \in L^p$

(tzn. $\|X_n\|_p = (E|X_n|^p)^{1/p} < \infty$) oraz

$$\lim_{n \rightarrow \infty} \|X_n - X\|_p = \lim_{n \rightarrow \infty} (E|X_n - X|^p)^{1/p} = 0$$

Piszemy wówczas $X_n \xrightarrow{L^p} X$.

TW.6.6 Jeżeli $X_n \xrightarrow{P} X$, $Y_n \xrightarrow{P} Y$, to

1. $aX_n + bY_n \xrightarrow{P} aX + bY$

2. $X_n Y_n \xrightarrow{P} XY$

TW.6.7 Jeżeli $X_n \rightarrow X$, to $X_n \xrightarrow{P} X$. Impli-

kacja odwrotna nie jest prawdziwa.

\Rightarrow byto na teorii miary

$\Leftarrow (\Omega, \mathcal{F}, P) = ([0,1], \text{Bor}([0,1]), \lambda)$.

$X_1 = \mathbb{1}_{[0,1]}$, $X_2 = \mathbb{1}_{[0,1/2]}$, $X_3 = \mathbb{1}_{[1/2,1]}$,

$X_n = \mathbb{1}_{[0,1/n]}$, ..., $X_7 = \mathbb{1}_{[3/4,1]}$, ...

Wtedy $X_n \xrightarrow{P} 0$, ale nie $X \rightarrow 0$.

TW.6.8 Jeżeli $X_n \xrightarrow{L^p} X$, to $X_n \xrightarrow{P} X$. Implikacja

odwrotna nie jest prawdziwa.

D-d. Z nierówności Czebyszewa

\Rightarrow

$$P[|X_n - X| < \varepsilon] \leq \frac{E|X_n - X|^p}{\varepsilon^p} \rightarrow 0$$

$\Leftarrow X_n = n^{1/p} \cdot \mathbb{1}_{[0,1/n]}$, $X_n \xrightarrow{P} 0$, $X_n \not\xrightarrow{L^p} 0$

Tw. 6.9 Jeżeli $X_n \xrightarrow{P} X$, to istnieje podciąg
 $\{X_{n_k}\}_{k \in \mathbb{N}}$ taki, że $X_{n_k} \xrightarrow{P.n.} X$.

D-2 Ustalmy $\varepsilon = 2^{-k}$.

$$P[|X_n - X| \geq 2^{-k}] \leq 2^{-k} \quad (\text{dla dużych } n).$$

$n \geq n_k$

Możemy założyć, że $\{n_k\}$ jest rosnący.

$$\text{Mamy } \sum_{k=1}^{\infty} P[|X_{n_k} - X| \geq 2^{-k}] \leq \sum_{k=1}^{\infty} 2^{-k} < \infty$$

* lematu Borela - Cantalliego wynika,

$$\text{że } P[|X_{n_k} - X| \geq 2^{-k} \text{ i.o.}] = 0.$$

Stąd wynika, że $|X_{n_k} - X| \geq 2^{-k}$ tylko

dla skończonej liczby indeksów. Tzn. że

$$\text{od pewnego miejsca } |X_{n_k} - X| < 2^{-k}$$

$$\Rightarrow X_{n_k} \rightarrow X.$$

Stabe Prawo Wielkich Liczb (SPWL)

Tw. Dany jest ciąg niezależnych zmiennych losowych $\{X_n\}$ o takiej samej wartości oczekiwanej i wariancji.

$$\text{Wówczas } \frac{X_1 + \dots + X_n}{n} \xrightarrow{\mathbb{P}} \mathbb{E}X_1.$$

Naszym celem będzie pokazanie Mocnego PWL, które mówi o zbieżności p.w.

Tw. 7.1 Jeżeli ciąg X_1, X_2, \dots spełnia $\mathbb{E}X_i^2 < \infty$, zmiennie losowe są niezależne oraz mają wspólnie ograniczoną wariancję, to

$$\frac{X_1 + \dots + X_n - \mathbb{E}[X_1 + \dots + X_n]}{n} \xrightarrow{\mathbb{P}} 0$$

W szczególności, jeżeli wszystkie zmiennie losowe X_i mają tę samą wartość oczekiwaną, to

$$\frac{X_1 + \dots + X_n}{n} \xrightarrow{\mathbb{P}} \mathbb{E}X_1.$$

D-ś. Z nierówności Czebyszewa, dla $\varepsilon > 0$

$$\mathbb{P} \left[\frac{X_1 + \dots + X_n - \mathbb{E}[X_1 + \dots + X_n]}{n} \geq \varepsilon \right] \leq$$

$$\frac{1}{\varepsilon^2} \cdot \text{Var} \left(\frac{X_1 + \dots + X_n}{n} \right) =$$

$$\frac{1}{(n\varepsilon)^2} \text{Var} (X_1 + \dots + X_n) \stackrel{\text{niezależność}}{=} =$$

$$\frac{1}{(n\varepsilon)^2} (\text{Var} X_1 + \dots + \text{Var} X_n) \leq$$

$$\frac{M \cdot n}{(n\varepsilon)^2} \xrightarrow{n \rightarrow \infty} 0$$

Przykład. Weźmy $\{X_k\}$ ciąg n.zl. zm. los.

oraz że $X_k \sim U([-1, 1])$. Wtedy

X_1^2, X_2^2, \dots są niezależne. Ponadto

$$\mathbb{E}X_1^2 = \int_{-1}^1 x^2 \frac{dx}{2} = \frac{1}{2} \cdot \frac{1}{3} x^3 \Big|_{-1}^1 = \frac{1}{3}.$$

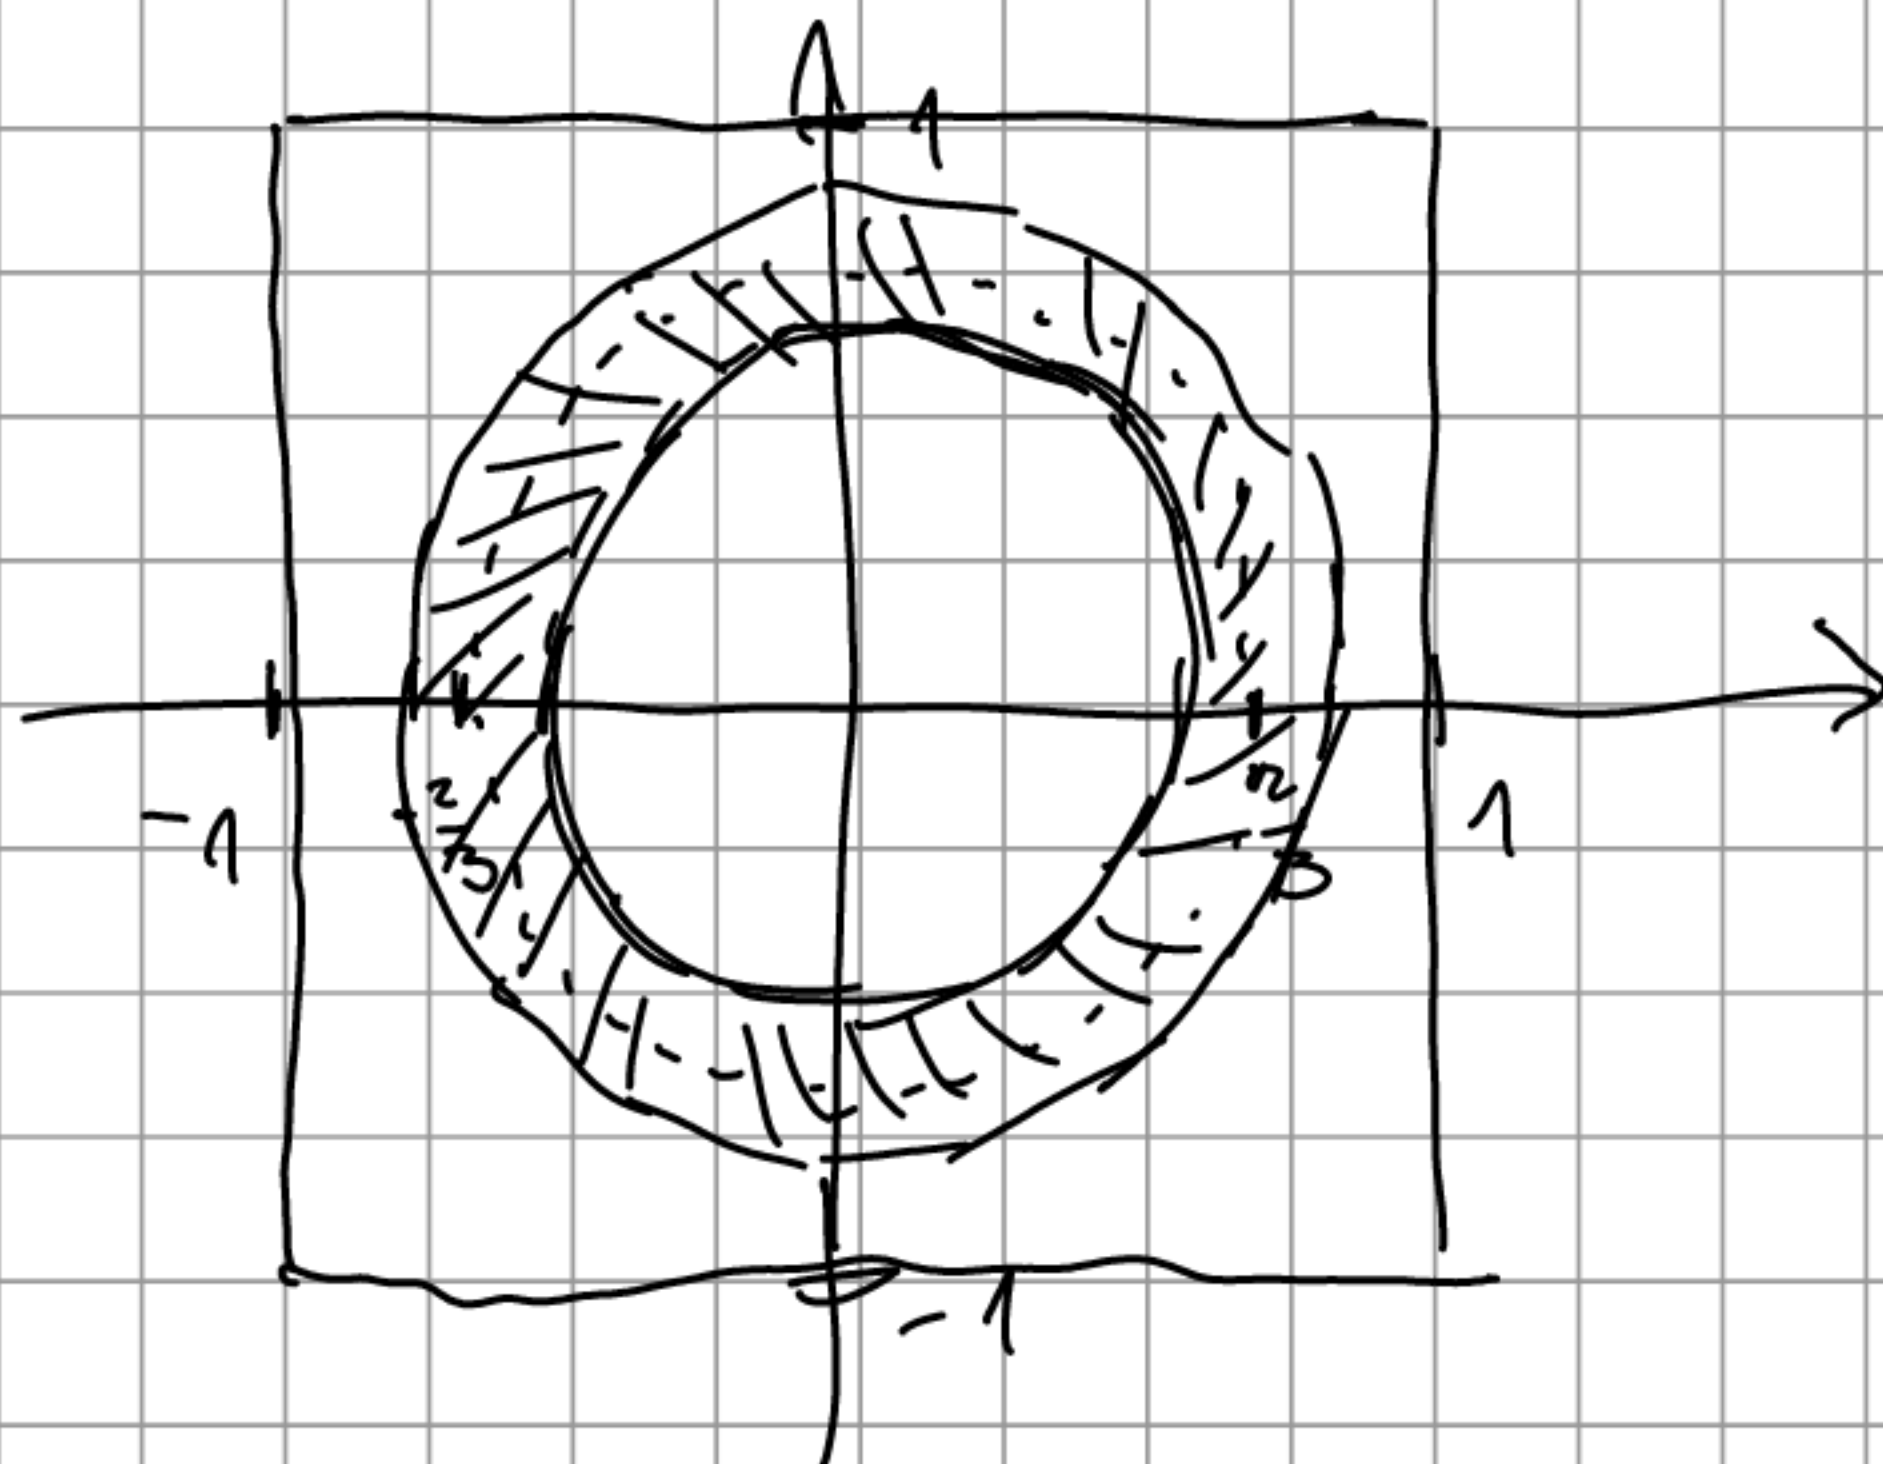
$$\text{Var} X_1^2 \leq \mathbb{E}X_1^4 \leq 1.$$

Ze SPWL mamy

$$\frac{X_1^2 + \dots + X_n^2}{n} \xrightarrow{P} \frac{1}{3}$$

Ustalamy $\varepsilon \in (0, \frac{1}{2})$. Zdefiniujmy

$$A_{n,\varepsilon} = \left\{ x \in \mathbb{R}^n : (1-\varepsilon)\sqrt{\frac{n}{3}} \leq \|x\| \leq (1+\varepsilon)\sqrt{\frac{n}{3}} \right\}$$



Dla $n \geq 4$ będzie tak, że ten pierścień będzie trochę wychodził poza kostkę, a trochę jeszcze w nim będzie.

Teraz

$$\begin{aligned} & \frac{1}{2^n} \cdot \lambda(A_{n,\varepsilon} \cap [-1,1]^n) = \\ & = \mathbb{P}[(X_1, \dots, X_n) \in A_{n,\varepsilon}] = \\ & = \mathbb{P}\left[(1-\varepsilon)\sqrt{\frac{n}{3}} \leq \sqrt{X_1^2 + \dots + X_n^2} \leq (1+\varepsilon)\sqrt{\frac{n}{3}}\right] = \\ & = \mathbb{P}\left[\frac{1}{3}(1-\varepsilon)^2 \leq \frac{X_1^2 + \dots + X_n^2}{n} \leq \frac{1}{3}(1+\varepsilon)^2\right] \geq \\ & \geq \mathbb{P}\left[\left|\frac{1}{n} \sum_{i=1}^n X_i^2 - \frac{1}{3}\right| \leq \frac{1}{3}(2\varepsilon - \varepsilon^2)\right] \xrightarrow{\text{SPWL}} 1 \end{aligned}$$

