

# 1. Pojęcie normy, normy wektora [Kiełbasiński, Schwetlick]

wektor  $\mathbf{x} \in R^d$

$\mathbf{x} = (x_1, x_2, \dots, x_d)^T$  – wektor, punkt w przestrzeni  $d$ -wymiarowej

**norma wektora – własności**


(1)  $\|\mathbf{x}\| \geq 0$ ,  $\|\mathbf{x}\| = 0$  tylko wtedy, gdy  $\mathbf{x} = 0$

(2)  $\|a\mathbf{x}\| = |a| \|\mathbf{x}\|$

(3)  $\|\mathbf{x} + \mathbf{y}\| \leq \|\mathbf{x}\| + \|\mathbf{y}\|$


**norma typu "suma"**

$$\|\mathbf{x}\|_1 = |x_1| + |x_2| + \dots + |x_d| = \sum_{i=1}^d |x_i| \text{ – nieujemna liczba rzeczywista (skalar)}$$




## norma typu "maksimum"

$$\|\mathbf{x}\|_{\infty} = \max_{i=1,\dots,d} |x_i| \text{ - nieujemna liczba rzeczywista (skalar)}$$



## norma euklidesowa

$$\|\mathbf{x}\|_2 = \sqrt{\mathbf{x}^T \mathbf{x}} = (x_1^2 + x_2^2 + \dots + x_d^2)^{1/2} = \sqrt{\sum_{i=1}^d x_i^2} \text{ - nieujemna liczba rzeczywista (skalar)}$$



## 2. Normy macierzy

norma macierzy  $\mathbf{A} \in R^{m,d}$  indukowana przez normę wektora typu  $p$

$$\|\mathbf{A}\|_p = \max \left\{ \frac{\|\mathbf{Ax}\|_p}{\|\mathbf{x}\|_p} : \mathbf{x} \neq 0 \right\} = \max \left\{ \|\mathbf{Ax}\|_p : \|\mathbf{x}\|_p \leq 1 \right\}$$

dla  $p = 1$

$$\|\mathbf{A}\|_1 = \max_{j=1,\dots,d} \sum_{i=1}^m |a_{i,j}|$$

dla  $p = 2$  – tzw. norma spektralna macierzy

$$\|\mathbf{A}\|_2 = \sqrt{\lambda_{\max}(\mathbf{A}^T \mathbf{A})}$$

dla  $p = \infty$

$$\|\mathbf{A}\|_\infty = \max_{i=1,\dots,m} \sum_{j=1}^d |a_{i,j}|$$

### 3. Statystyki opisowe zmiennych losowych [Klonecki]

$\omega$  – zdarzenie losowe,  $\omega \in \Omega$  ( $\Omega$  – tzw. zbiór zdarzeń elementarnych)

funkcja  $X(\omega) \in R$  – zmienna losowa (tu skalar, może być wektorem)

**dyskretne zmienne losowe** – gdy zbiór wartości przyjmowanych przez  $X(\omega)$  jest przeliczalny

wartość oczekiwana :  $EX = \sum_{\omega \in \Omega} X(\omega)P(\omega)$  – średnie  $X$  ważone prawdopodobieństwami (wielkość nie losowa!)

wariancja  $varX = E\{(X - EX)^2\}$  – średni kwadrat odchylenia  $X$  od  $EX$  ważony prawdopodobieństwami

**ciągłe zmienne losowe**

$f(x)$  – funkcja gęstości prawdopodobieństwa

$$P(X \in (a, b)) = \int_a^b f(x)dx$$

$$EX = \int_{-\infty}^{\infty} xf(x)dx \quad varX = \int_{-\infty}^{\infty} (x - EX)^2 f(x)dx$$

### 4. Popularne rozkłady

rozkład jednostajny (*ang. uniform distribution*)  $\sim U[a, b]$

$$f(x) = \begin{cases} \frac{1}{b-a}, & \text{gdy } x \in (a, b) \\ 0, & \text{w przeciwnym przypadku} \end{cases}$$

$$EX = \int_a^b x \frac{1}{b-a} dx = \frac{1}{b-a} \frac{b^2 - a^2}{2} = \frac{a+b}{2} \text{ – \u015brodek przedzia\u0142u}$$

$$\text{var} X = \int_a^b \left(x - \frac{a+b}{2}\right)^2 \frac{1}{b-a} dx = \dots = \frac{(b-a)^2}{12}$$

**rozk\u0142ad normalny** (*ang. normal distribution*)  $\sim N(m, \sigma^2)$

$$f(x) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(x-m)^2}{2\sigma^2}} \quad EX = m \quad \text{var} X = \sigma^2$$

**rozk\u0142ad wy\u0142adniczy**

$$f(x) = \begin{cases} \alpha e^{-\alpha x}, & \text{gdy } x \geq 0 \\ 0, & \text{w przeciwnym przypadku} \end{cases} \quad EX = \frac{1}{\alpha} \quad \text{var} X = ? \text{ – zadanie domowe}$$

pakiet **STATISTICA** – has\u0142o ”dystrybuanty” w indeksie pomocy

## 5. Eksperyment

$x_1, x_2, \dots, x_N$  – ci\u0105g liczb losowych (np. realizacje pewnej zmiennej losowej  $X$ )

## 6. Typy zbieżności probabilistycznych

Fakt zbieżności ciągów deterministycznych (nie losowych)

$$\lim_{k \rightarrow \infty} a_k = g \Leftrightarrow \bigwedge_{\varepsilon > 0} \bigvee_{k_0} \bigwedge_{k > k_0} |a_k - g| < \varepsilon$$

Szybkość zbieżności ciągów deterministycznych

symbol  $o()$  – ”rząd niższy”

$$a_k = o(b_k) \Leftrightarrow \lim_{k \rightarrow \infty} \frac{a_k}{b_k} = 0 \quad (\text{i oba ciągi dążą do zera})$$

symbol  $O()$  – ”ta sama szybkość”

$$a_k = O(b_k) \Leftrightarrow \bigvee_{c < \infty} |a_k| \leq c |b_k|$$

Ciągi zmiennych losowych  $\{\varkappa_k\}$

tutaj operator  $\lim_{k \rightarrow \infty}$  nie wystarcza, gdyż warunek  $|a_k - g| < \varepsilon$  określa pewne zdarzenie **losowe**

**Definicja 1** Ciąg zmiennych losowych  $\{\varkappa_k\}$  jest przy  $k \rightarrow \infty$  zbieżny **według prawdopodobieństwa (słabo)** do  $\varkappa^\#$  jeśli dla każdego  $\varepsilon > 0$  zachodzi

$$\lim_{k \rightarrow \infty} P(|\varkappa_k - \varkappa^\#| > \varepsilon) = 0, \text{ lub równoważnie } \lim_{k \rightarrow \infty} P(|\varkappa_k - \varkappa^\#| < \varepsilon) = 1$$

Wartość  $\varkappa^\#$  nazywamy granicą stochastyczną ciągu  $\{\varkappa_k\}$  i zapisujemy

$$P \lim_{k \rightarrow \infty} \varkappa_k = \varkappa^\# \tag{1}$$

Zapis  $P \lim_{N \rightarrow \infty} \mathbf{X}_N = \mathbf{X}$  dla sekwencji wektorów losowych  $\{\mathbf{X}_N\}$ , oznacza, że  $\mathbf{X}_N \rightarrow \mathbf{X}$  według prawdopodobieństwa, gdy  $N \rightarrow \infty$ .

**Definicja 2** Ciąg zmiennych losowych  $\{\varkappa_k\}$  jest przy  $k \rightarrow \infty$  zbieżny z **prawdopodobieństwem 1** (mocno) do  $\varkappa^*$  jeśli zachodzi

$$P\left(\lim_{k \rightarrow \infty} \varkappa_k = \varkappa^*\right) = 1$$

**Lemat 1** Ze zbieżności z prawdopodobieństwem 1 wynika zbieżność według prawdopodobieństwa.

**Definicja 3** Ciąg zmiennych losowych  $\{\varkappa_k\}$  jest przy  $k \rightarrow \infty$  zbieżny **według średniej z potęgą  $r$**  do  $\varkappa^*$  jeśli zachodzi

$$\lim_{k \rightarrow \infty} \mathbf{E} |\varkappa_k - \varkappa^*|^r = 0$$

w szczególności jest zbieżny **według średniej z kwadratem (średniokwadratowo)**, gdy

$$\lim_{k \rightarrow \infty} \mathbf{E}(\varkappa_k - \varkappa^*)^2 = 0$$

**Definicja 4** Ciąg zmiennych losowych  $\{\varkappa_k\}$  ma **szybkość zbieżności rzędu  $O(e_k)$  według prawdopodobieństwa** przy  $k \rightarrow \infty$  (tj. asymptotycznie), gdzie  $\{e_k\}$  jest ciągiem liczb dodatnich zbieżnym do zera, tzn.

$$\varkappa_k = O(e_k) \text{ według prawdopodobieństwa}$$

wtedy i tylko wtedy, gdy  $\left\{\frac{\varkappa_k}{e_k} \chi_k\right\}$  jest zbieżny według prawdopodobieństwa do zera dla każdego ciągu liczbowego  $\{\chi_k\}$ , takiego że  $\lim_{k \rightarrow \infty} \chi_k = 0$ .

**Definicja 5** Ciąg zmiennych losowych  $\{\varkappa_k\}$  ma **szybkość zbieżności rzędu  $O(e_k)$  według średniej z kwadratem** przy  $k \rightarrow \infty$  jeżeli istnieje stała  $0 \leq c < \infty$ , taka, że


$$\mathbf{E} \varkappa_k^2 \leq c e_k$$

**Lemat 2** Jeżeli  $\varkappa_k = O(e_k)$  według średniej z kwadratem, to  $\varkappa_k = O(\sqrt{e_k})$  według prawdopodobieństwa.

**Definicja 6** Mówimy, że ciąg zmiennych losowych  $X_k$  jest zbieżny **według rozkładu** do zmiennej losowej  $X$ , gdy

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

## 7. Relacje (związki) pomiędzy różnymi typami zbieżności



**Dowód faktu  $P1 \implies P$**

oczywisty, skoro  $P(\lim_{k \rightarrow \infty} \mathcal{X}_k = \mathcal{X}^*) = 1$ , to  $\sum_{k=1}^{\infty} P(|\mathcal{X}_k - \mathcal{X}^*| < \varepsilon) < \infty$  i aby szereg ten był zbieżny, musi zachodzić  $P(|\mathcal{X}_k - \mathcal{X}^*| < \varepsilon) \rightarrow 0$  dla  $k \rightarrow \infty$

**Dowód faktu  $Lr \implies P$**

z definicji

$$\mathbf{E} |\mathcal{X}_k - \mathcal{X}^*|^r = \int_{\Omega} |\mathcal{X}_k - \mathcal{X}^*|^r d\omega \geq \int_{\{|\mathcal{X}_k - \mathcal{X}^*| > \varepsilon\}} |\mathcal{X}_k - \mathcal{X}^*|^r d\omega \geq \varepsilon^r \int_{\{|\mathcal{X}_k - \mathcal{X}^*| > \varepsilon\}} d\omega = \varepsilon^r P(|\mathcal{X}_k - \mathcal{X}^*| > \varepsilon)$$

a zatem

$$P(|\mathcal{X}_k - \mathcal{X}^*| > \varepsilon) \leq \frac{1}{\varepsilon^r} \mathbf{E} |\mathcal{X}_k - \mathcal{X}^*|^r$$

w szczególność dla  $r = 2$  i  $\mathcal{X}^* = \mathbf{E}\mathcal{X}$

$$P(|\mathcal{X} - \mathbf{E}\mathcal{X}| > \varepsilon) \leq \frac{1}{\varepsilon^2} \text{var} \mathcal{X}$$

**Dowód faktu  $\sum_{k=1}^{\infty} P(|\mathcal{X}_k - \mathcal{X}^*| < \varepsilon) < \infty$  i  $\mathcal{X}_k \xrightarrow{p} \mathcal{X}^* \implies \mathcal{X}_k \xrightarrow{p^1} \mathcal{X}^*$**



$$\begin{aligned}
P(\sup_{k \geq k_0} |\varkappa_k - \varkappa^*| > \varepsilon) &= P(|\varkappa_k - \varkappa^*| > \varepsilon \text{ dla pewnego (konkretnego) } k \geq k_0) = P\left(\bigcup_{k=k_0}^{\infty} (|\varkappa_k - \varkappa^*| > \varepsilon)\right) \leq \\
&\leq \sum_{k=k_0}^{\infty} P(|\varkappa_k - \varkappa^*| > \varepsilon) \rightarrow 0, \text{ bo szereg jest zbieżny, zaś } k_0 \rightarrow \infty
\end{aligned}$$

### Przykład

jeśli  $P(|\varkappa_k - \varkappa^*| < \varepsilon) = O(\frac{1}{k})$  wtedy zachodzi  $\varkappa_k \xrightarrow{p} \varkappa^*$ , ale nie zachodzi  $\varkappa_k \xrightarrow{p1} \varkappa^*$

### Problem

jeżeli  $\varkappa_k \xrightarrow{p} \varkappa^*$ , gdy  $k \rightarrow \infty$ , to czy wtedy zachodzi  $g(\varkappa_k) \xrightarrow{p} g(\varkappa^*)$ , gdy  $k \rightarrow \infty$  ???

Tak – pod warunkiem, że  $g(\cdot)$  jest funkcją ciągłą w punkcie  $\varkappa^*$

## 8. Mocne Prawo Wielkich Liczb Kołmogorowa (wersja podstawowa)

### Założenia

- (a)  $X_1, X_2, \dots, X_N$  – jest ciągiem zmiennych losowych typu i.i.d. – niezależnych i o tym samym rozkładzie (*ang independent and identically distributed sequence of random variables*)
- (b) istnieje  $\mathbf{E}X_i = m < \infty$

### Teza

$$\frac{1}{N} \sum_{i=1}^N X_i \xrightarrow{p1} m, \text{ gdy } N \rightarrow \infty$$

inne wersje MPWL – patrz [Feller], [Krzyśko], [Ninness]

## 9. Mocne Prawo Wielkich Liczb Kołmogorowa (wersja bez wymogu i.i.d.)

### Założenia

- (a)  $X_1, X_2, \dots, X_N$  – jest ciągiem niezależnych zmiennych losowych, w ogólności o różnych rozkładach
- (b) istnieją  $\mathbf{E}X_i = m_i < \infty$
- (c) istnieją  $\text{var}X_i = \sigma_i^2 < \infty$
- (d)  $\sum_{i=1}^{\infty} \frac{\sigma_i^2}{i^2} < \infty$

### Teza

$$\frac{1}{N} \sum_{i=1}^N X_i - \frac{1}{N} \sum_{i=1}^N m_i \xrightarrow{p1} 0, \text{ gdy } N \rightarrow \infty$$

## 10. Centralne Twierdzenie Graniczne Lindenberga–Levy’ego

### Założenia

- (a)  $X_1, X_2, \dots, X_N$  – ciąg typu i.i.d. (mają ten sam, ale dowolny rozkład! – niekoniecznie normalny)
- (b) istnieje  $\mathbf{E}X_i = m < \infty$
- (c) istnieje  $\text{var} X_i = \sigma^2 < \infty$

### Teza

$$\frac{\sum_{i=1}^N X_i - Nm}{\sigma\sqrt{N}} \xrightarrow{D} \mathcal{N}(0, 1), \text{ gdy } N \rightarrow \infty$$

### Wnioski – fundamentalne dla zagadnienia estymacji

$$\frac{\frac{1}{N} \sum_{i=1}^N X_i - m}{\frac{\sigma}{\sqrt{N}}} \xrightarrow{D} \mathcal{N}(0, 1) \qquad \frac{1}{N} \sum_{i=1}^N X_i \xrightarrow{D} \mathcal{N}\left(m, \frac{\sigma^2}{N}\right)$$

### Oszacowanie dokładności przybliżenia – nierówność Barry-Essena

oznaczmy  $\varkappa_N = \frac{\sum_{i=1}^N X_i - Nm}{\sigma\sqrt{N}}$

$$\sup_x |F_{\varkappa_N}(x) - \Phi(x)| \leq \frac{33 \mathbf{E}|X_i - m|^3}{4 \sigma^3 \sqrt{N}} = O\left(\frac{1}{\sqrt{N}}\right)$$

## 11. Analiza korelacyjna procesów

**kowariancja** – miara zależności liniowej

$$\text{cov}(X, Y) = \mathbf{E} \{(X - \mathbf{E}X)(Y - \mathbf{E}Y)\} \qquad |\text{cov}(X, Y)| \leq \sqrt{\text{var}X \text{var}Y}$$

**korelacja** (znormalizowana kowariancja)

$$\xi(X, Y) = \frac{\text{cov}(X, Y)}{\sqrt{\text{var}X \text{var}Y}} \qquad |\xi(X, Y)| \leq 1$$

**pojęcie procesu losowego (stochastycznego)**

$X(\omega, t)$  – dla ustalonego momentu czasu  $t = t_0$  otrzymujemy zmienną losową  $X_{t_0}(\omega)$

**funkcja autokowariancji procesu losowego (stacjonarnego)** – miara zależności liniowej pomiędzy  $X_{t_0}$  o przesuniętą o  $\tau$  zmienną  $X_{t_0+\tau}$

$$A_X(\tau) = \text{cov}(X_{t_0}, X_{t_0+\tau}), \qquad A_X(0) = \sigma_X^2$$

**funkcja autokorelacji procesu losowego**

$$r_X(\tau) = \frac{\text{cov}(X_{t_0}, X_{t_0+\tau})}{\sqrt{\text{var}X_{t_0} \text{var}X_{t_0+\tau}}} = \frac{A_X(\tau)}{\sigma_X^2}, \qquad r_X(0) = 1$$

**funkcja kowariancji wzajemnej dwóch procesów** –  $X(\omega, t)$  i  $Y(\omega, t)$

$$W_{X,Y}(\tau) = \text{cov}(X_{t_0}, Y_{t_0+\tau})$$

**funkcja korelacji wzajemnej dwóch procesów** –  $X(\omega, t)$  i  $Y(\omega, t)$

$$r_{X,Y}(\tau) = \frac{W_{X,Y}(\tau)}{\sigma_X \sigma_Y}$$

## 12. Przejście białego szumu przez układ dynamiczny

$$y_k = \sum_{i=0}^{\infty} \gamma_i u_{k-i}$$

### Założenia

- (a)  $\{u_k\}$  – proces typu i.i.d.
- (b) układ jest asymptotycznie stabilny tzn.  $\sum_{i=0}^{\infty} |\gamma_i| < \infty$
- (c) dla uproszczenia prezentacji niech  $\mathbf{E}u_k = 0$  i  $\text{var}u_k = 1$

### Autokowariancja procesu $u_k$

$$A_u(\tau) = \mathbf{E}u_k u_{k+\tau} = \begin{cases} = \text{var}u_k = 1, & \text{dla } \tau = 0 \\ = 0, & \text{dla } \tau \neq 0 \end{cases} \text{ (na podstawie niezależności } u_k \text{ i } u_{k+\tau} \text{ i założenia (c))}$$

$$r_u(\tau) = A_u(\tau) \text{ (patrz założenie (c))}$$

### Własności procesu $y_k$

$$\mathbf{E}y_k = \mathbf{E} \sum_{i=0}^{\infty} \gamma_i u_{k-i} = \sum_{i=0}^{\infty} \mathbf{E} \gamma_i u_{k-i} = \mathbf{E}u_k \sum_{i=0}^{\infty} \gamma_i = 0$$

$$\text{var}y_k = \text{var} \left( \sum_{i=0}^{\infty} \gamma_i u_{k-i} \right) = \sum_{i=0}^{\infty} \text{var} (\gamma_i u_{k-i}) = \text{var}u_k \sum_{i=0}^{\infty} \gamma_i^2$$

$$A_y(\tau) = \mathbf{E}y_k y_{k+\tau} = \mathbf{E} \left( \sum_{i=0}^{\infty} \gamma_i u_{k-i} \sum_{j=0}^{\infty} \gamma_j u_{k+\tau-j} \right) =$$

$$= \mathbf{E} \{ (\gamma_0 u_k + \gamma_1 u_{k-1} + \gamma_2 u_{k-2} + \dots) (\gamma_0 u_{k+\tau} + \gamma_1 u_{k+\tau-1} + \gamma_2 u_{k+\tau-2} + \dots + \gamma_\tau u_k + \gamma_{\tau+1} u_{k-1} + \dots) \} = \text{var}u_k \sum_{i=0}^{\infty} \gamma_i \gamma_{i+\tau}$$

## 13. Popularne nierówności

### Nierówność Czebyszewa

$$P(|\varkappa - \mathbf{E}\varkappa| > \varepsilon) \leq \frac{1}{\varepsilon^2} \text{var } \varkappa$$

### Nierówność Barry-Essena

oznaczmy  $\varkappa_N = \frac{\sum_{i=1}^N X_i - Nm}{\sigma\sqrt{N}}$

$$\sup_x |F_{\varkappa_N}(x) - \Phi(x)| \leq \frac{33 \mathbf{E}|X_i - m|^3}{4 \sigma^3 \sqrt{N}} = O\left(\frac{1}{\sqrt{N}}\right)$$

### Nierówność Jensena

$g()$  – funkcja wypukła

$$\mathbf{E}g(X) \geq g(\mathbf{E}X)$$

### Nierówność Höldera

$\|X\|_p = (\mathbf{E}X^p)^{1/p}$  tzw. p-norma zmiennej losowej

$$\mathbf{E}|XY| \leq \|X\|_p \|Y\|_{p'}, \text{ gdzie } \frac{1}{p} + \frac{1}{p'} = 1$$

Nierówność Schwartza ( $p = 2, p' = 2$ )

$$|\mathbf{E}XY| \leq \mathbf{E}|XY| \leq \sqrt{\mathbf{E}X^2 \mathbf{E}Y^2}$$

### Nierówność Rao-Cramera

$$\mathbf{E}(\theta_N - \theta^*)^2 \geq \frac{1}{N \int_{-\infty}^{\infty} \left(\frac{\partial f(x, \theta^*)}{\partial \theta^*}\right)^2 f(x, \theta^*) dx}$$