

2.

Powtórka z algebry i statystyki

1. Pojęcie normy, normy wektora [Kiełbaśiński, Schwetlick]

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

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

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]

ω – zdarzenie losowe, $\omega \in \Omega$ – 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 $var X = E\{(X - EX)^2\}$ – średni kwadrat odchylenia X od EX ważony prawdopodobieństwami

ciągłe zmienne losowe

$f(x)$ – funkcja gęstości prawdopodobieństwa

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

$$EX = \int_{-\infty}^{\infty} xf(x)dx \qquad var X = \int_{-\infty}^{\infty} (x - EX)^2 f(x)dx$$

4. Popularne rozkłady

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

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

$$EX = \int_a^b x \frac{1}{b-a} dx = \frac{1}{b-a} \frac{b^2 - a^2}{2} = \frac{a+b}{2} - \text{środek przedziału}$$

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

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

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

rozkład wykładniczy

$$f(x) = \begin{cases} \alpha e^{-\alpha x}, & \text{gdy } x \geq 0 \\ 0, & \text{w przeciwnym przypadku} \end{cases} \quad EX = \frac{1}{\alpha} \quad \text{var} X = \frac{1}{\alpha^2}$$

pakiet STATISTICA – hasło ”dystrybuanty” w indeksie pomocy

5. Eksperyment

x_1, x_2, \dots, x_N – ciąg 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 $\{x_k\}$

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

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

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

Wartość $x^\#$ nazywamy granicą stochastyczną ciągu $\{x_k\}$ i zapisujemy

$$P \lim_{k \rightarrow \infty} x_k = x^\# \quad (1)$$

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

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

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

Dowód faktu $Lr \implies P$

z definicji

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

a zatem

$$P(|x_k - x^*| > \varepsilon) \leq \frac{1}{\varepsilon^r} \mathbf{E}|x_k - x^*|^r$$

w szczególności dla $r = 2$ i $x^* = \mathbf{E}x$

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

Dowód faktu $\sum_{k=1}^{\infty} P(|x_k - x^*| < \varepsilon) < \infty$ i $x_k \xrightarrow{p} x^* \implies x_k \xrightarrow{p1} x^*$

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

Przykład

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

Problem

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

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

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], [Krzyszko], [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

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

Wnioski – fundamentalne dla zagadnienia estymacji

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

Oszacowanie dokładności przybliżenia – nierówność Barry-Essena

$$\text{oznaczmy } \mathcal{H}_N = \frac{\sum_{i=1}^N X_i - Nm}{\sigma\sqrt{N}}$$

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

11. Analiza korelacyjna procesów

kowariancja – miara zależności liniowej

$$\text{cov}(X, Y) = \mathbf{E}\{(X - \mathbf{E}X)(Y - \mathbf{E}Y)\}$$

$$|\text{cov}(X, Y)| \leq \sqrt{\text{var}X \text{var}Y}$$

korelacja (znormalizowana kowariancja)

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

$$|\xi(X, Y)| \leq 1$$

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 τ zmienną $X_{t_0+\tau}$

$$A_X(\tau) = \text{cov}(X_{t_0}, X_{t_0+\tau}),$$

$$A_X(0) = \sigma_X^2$$

funkcja autokorelacji procesu losowego

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

$$r_X(0) = 1$$

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

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

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

Właściwości 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

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

Nierówność Barry-Essena

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

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

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

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