

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”

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

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 $\mathcal{X}_k \xrightarrow{p} \mathcal{X}^* \implies \mathcal{X}_k \xrightarrow{p1} \mathcal{X}^*$

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

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 $g()$ 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 τ 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

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

Własości procesu y_k

$$\begin{aligned} \mathbf{E}y_k &= \mathbf{E} \sum_{i=0}^{\infty} \gamma_i u_{k-i} = \sum_{i=0}^{\infty} \mathbf{E}\gamma_i u_{k-i} = \mathbf{E}u_k \sum_{i=0}^{\infty} \gamma_i = 0 \\ \text{var}y_k &= \text{var} \left(\sum_{i=0}^{\infty} \gamma_i u_{k-i} \right) = \sum_{i=0}^{\infty} \text{var}(\gamma_i u_{k-i}) = \text{var}u_k \sum_{i=0}^{\infty} \gamma_i^2 \\ A_y(\tau) &= \mathbf{E}y_k y_{k+\tau} = \mathbf{E} \left(\sum_{i=0}^{\infty} \gamma_i u_{k-i} \sum_{j=0}^{\infty} \gamma_j u_{k+\tau-j} \right) = \\ &= \mathbf{E} \{ (\gamma_0 u_k + \gamma_1 u_{k-1} + \gamma_2 u_{k-2} + \dots) (\gamma_0 u_{k+\tau} + \gamma_1 u_{k+\tau-1} + \gamma_2 u_{k+\tau-2} + \dots + \gamma_\tau u_k + \gamma_{\tau+1} u_{k-1} + \dots) \} = \text{var}u_k \sum_{i=0}^{\infty} \gamma_i \gamma_{i+\tau} \end{aligned}$$

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

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