

Lista 2

11. Niech $\{X_i\}_{i=1}^{\infty}$ będzie ciągiem niezależnych zmiennych losowych (zdefiniowanych na wspólnej przestrzeni probabilistycznej Ω), o zadanym poniżej rozkładzie:

$$X_i \in \{-i; 0; i\} \text{ gdzie } \Pr\{X_i = -i\} = \Pr\{X_i = i\} = \frac{1}{2i \log(i+1)}.$$

Pokaż, że:

- a) $\{X_i\}_{i=1}^{\infty}$ spełnia słabe prawo wielkich liczb
- b) $\{X_i\}_{i=1}^{\infty}$ nie spełnia mocnego prawa wielkich liczb (podpowiedź: użyj drugiego lematu Borela-Cantelli'ego)

12. Indeks Giniego G ciągłej nieujemnej zmiennej losowej X (która m. in. może opisywać rozkład majątku w społeczeństwie) jest zdefiniowana jako podwojone pole pomiędzy linią $y = x$ dla $x \in [0, 1]$ i tak zwanej krzywej Lorenza $L_X(x)$, $x \in [0, 1]$. Krzywa Lorenza zdefiniowana jest jako:

$$L_X(x) = \frac{1}{\mathbb{E}X} \int_0^{F^{-1}(x)} z\varphi(z) \text{ gdzie } \varphi(z) \text{ jest gęstością } X, \text{ zaś } F^{-1} \text{ jest odwrotnością funkcji dystrybuanty } F \text{ zmiennej losowej } X.$$

- a) oblicz indeks Giniego dla zmiennej losowej o ciągłym rozkładzie jednostajnym na odcinku $[0, a]$, $a > 0$
- b) oblicz indeks Giniego dla zmiennej losowej o ciągłym rozkładzie jednostajnym na odcinku $[a, b]$ $b > a > 0$ jako funkcji a i b
- c) oblicz indeks Giniego dla zmiennej losowej o rozkładzie wykładniczym o gęstości $\varphi(z) = \lambda e^{-\lambda z}$ dla $z \geq 0$ i 0 w przeciwnym wypadku.
- d) pokaż że krzywa Lorenza zawsze jest ograniczona linią $y = x$ (dla $x \in [0, 1]$)

13. Niech X_1, \dots, X_n będzie ciągiem niezależnych zmiennych losowych o funkcji gęstości p_θ danej przez $p_\theta(x) = \theta^2 x \exp(-\theta x)$ dla $x \geq 0$, gdzie $\theta > 0$ jest nieznanym parametrem.

- a) Wyznacz estymator maksymalnej wiarygodności dla θ .
- b) Oblicz informację Fishera i_θ dla θ i oblicz plug-in estymator dla i_θ
- c) Wyznacz przybliżony przedział ufności dla θ na poziomie ufności $1 - \alpha$ na podstawie centralnego twierdzenia granicznego dla estymatora maksymalnej wiarygodności parametru θ .

14. Niech X_1, \dots, X_n będzie próbą z rozkładu prawdopodobieństwa z gęstością

$$p_\theta(x) = \theta(1+x)^{-(1+\theta)} \text{ dla } x > 0 \text{ oraz } 0 \text{ w przeciwnym wypadku, gdzie } \theta > 1 \text{ jest nieznanym parametrem.}$$

- a) Wyznacz metodę estymatora momentów dla parametru θ .
- b) Użyj metodę delta i centralne twierdzenie graniczne, by wyznaczyć asymptotyczny przedział ufności na poziomie ufności $1 - \alpha$ dla tego estymatora.

15. Niech $\Omega = \{\omega = \{\omega_i\}_{i=1}^{\infty} : \omega_i \in \{-1, +1\}\}$ będzie zbiorem nieskończonych ciągów o wyrazach $-1, +1$ wyposażonym w miarę produktową, to znaczy że zdarzenia $A_i^\pm = \{\omega : \omega_i = \pm 1\}$ są niezależne dla różnych i . Niech $S_n(\omega) = \sum_{i=1}^n i\omega_i$. Ciąg $\{S_n(\omega)\}_{i \geq 1}$ nazywamy spacerem losowym.

- a) Przy użyciu centralnego twierdzenia granicznego oszacować prawdopodobieństwo dla dużych n , że $|S_n(\omega)| \geq n^\alpha$, $\alpha \in (0, 1)$
- b) Niech B będzie zdarzeniem $\{\text{dla nieskończenie wielu } n : |S_n(\omega)| \geq n^\alpha\}$. Znajdź najmniejszą liczbę α taką że $\Pr\{B\} = 0$. (Podpowiedź: użyj lematu Borela-Cantellego)

16. Niech X_1, \dots, X_n będzie ciągiem niezależnych zmiennych losowych z nieznanego ustalonego rozkładu.
- Użyj nierówności Dvoretzky’ego-Kiefera-Wolfowitza do zaprojektowania testu dla hipotezy $H_0 : X_i \sim \text{Exp}(1)$
 - Niech $n = 6$, a wartości próby równe: $X_1 = 1; X_2 = 4; X_3 = 0.5; X_4 = 2; X_5 = 0,2$ oraz $X_6 = 3$. Czy odrzucisz czy też zaakceptujesz H_0 jeśli błąd pierwszego rodzaju powinien być równy najwyżej 0.05?
17. Rozważ zbiór 9 punktów w \mathbb{R}^2 , gdzie każdy punkt jest realizacją pary zmiennych losowych (X, Y) . Każdy punkt ma przypisaną binarną wartość $Z \in \{0, 1\}$. Wartości próbek razem z odpowiadającymi im wartościami Z , oznaczone przez $(X, Y | Z)$ są następujące:
- $(1, 3 | 0); (2, 1 | 0); (2, 3 | 0); (3, 2 | 0); (4, 4 | 0); (3, 5 | 1); (4, 5 | 1); (5, 4 | 1); (5, 6 | 1)$.
- Dokonaj regresji logistycznej dla zmiennej klasyfikacji Z jako funkcji (X, Y) .
 - Jak dobrze ta regresja opisuje wartości Z pochodzące z rozważanej próby?
18. Niech M_0 będzie wartością portfela w chwili 0 i niech M_i będzie wartością portfela w roku i . W każdym roku wartość portfela wzrasta o 40% z prawdopodobieństwem $\frac{1}{2}$ lub spada o 20% w stosunku do wartości portfela z poprzedniego roku.
- Użyj prawa wielkich liczb, by opisać jak szybko M_n rośnie jako funkcja n dla dużych n .
 - Użyj lewostronnej nierówności Czebyszewa, by wyestymować prawdopodobieństwo że $M_{10} \leq \frac{1}{2}M_0$. (Lewostronna nierówność Czebyszewa oznacza, że dla zmiennej losowej X z wartością oczekiwaną μ i wariancją σ^2 następujące ograniczenie jest spełnione dla każdego $a > 0 : \Pr(X \leq \mu - a) \leq \frac{\sigma^2}{\sigma^2 + a^2}$.)
19. Niech $\{X_i\}_{i=1}^n$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie gdzie $X_i \in \{-1, +1\}$ oraz $\Pr\{X_1 = 1\} = \frac{1}{2}$. Niech $S_n = \sum_{i=1}^n X_i$.
- Użyj centralnego twierdzenia granicznego do oszacowania prawdopodobieństwa, że $S_{1000} < -50$.
 - Jak duże n jest potrzebne, by prawdopodobieństwo tego, że $S_n > 1000$ było równe co najmniej $\frac{1}{4}$? (Ponownie należy użyć centralnego twierdzenia granicznego).
20. Księgowy chce uprościć swoje obliczenia przez zaokrąglenie wszystkich liczb do najbliższej liczby całkowitej. Jest zainteresowany ile wynosi suma pierwszych 100 błędów zaokrągleń wynikających z jego metody. Aby to przeanalizować, zastosuj poniższy model. Oznaczmy błędy zaokrągleń przez X_1, \dots, X_{100} , gdzie X_i są niezależnymi zmiennymi losowymi o rozkładzie jednostajnym na $(-1/2, 1/2)$.
- Oblicz wartość oczekiwaną i wariancję X_1 .
 - Zastosuj centralne twierdzenie graniczne by pokazać, że $\Pr(|\sum_{i=1}^{100} X_i| > 10)$ jest w przybliżeniu równe $2\Pr(N > \sqrt{12})$, gdzie N ma standardowy rozkład normalny.
 - Znajdź przedział $(a, b) \subset \mathbb{R}$ taki że $\Pr\left\{\sum_{i=1}^{100} X_i \in (a, b)\right\}$ to w przybliżeniu 0.9.
21. Niech X będzie zmienną losową o zadanej dystrybucji $F_X(x) = 1 - x^{-a}$ dla $x \geq 1$ i $F_X(x) = 0$ dla $x < 1$ gdzie $a > 2$. Parametr a jest dla nas nieznan. Załóżmy, że zaobserwowaliśmy 4 niezależne realizacje zmiennej losowej X , które mają wartości 2, 6, 3, 12. Użyj metody największej wiarygodności do znalezienia estymatora \tilde{a} prawdziwej wartości parametru a . Oblicz wartość oczekiwaną i wariancję X dla znalezionej wartości \tilde{a} oraz oblicz wartość oczekiwaną i wariancję, gdyby a było znane i równe 3.

22. Automat do kawy akceptuje monety 1\$ i 2\$ dolarowe, pobiera 1\$ dolar za kawę i wydaje resztę gdy ktoś zapłaci monetą dwudolarową pod warunkiem, że w automacie wciąż były monety jednodolarowe. Automat ma dwa pojemniki: jeden na monety jednodolarowe, a drugi na monety dwudolarowe. Całkowita ilość monet które mieszczą się w automacie jest równa $N \gg 1$. Prawdopodobieństwo że osoba płaci za kawę monetą 1\$ wynosi p_1 , a prawdopodobieństwo że osoba płaci monetą 2\$ wynosi p_2 . Osoby przychodzą po kawę niezależnie i po jednej w danej chwili (czyli można przyjąć że czas jest dyskretny i w każdym kroku czasowym inna osoba próbuje zakupić kawę w automacie). Automat przestaje pracować w przypadku gdy jeden z pojemników (pojemnik na monety 1\$ lub pojemnik na monety 2\$) będzie pełny.

a) Zaproponuj dobór wielkości N_1 dla pojemnika na monety 1\$ i N_2 dla pojemnika na monety 2\$ jeśli automat do kawy powinien pracować tak długo, jak to tylko możliwe. Znajdź przybliżoną odpowiedź dla dużego N ($N = N_1 + N_2$) znając wartości p_1 oraz p_2 . (Podpowiedź: użyj mocnego prawa wielkich liczb.)

23. Niech $\{X_i\}_{i=1}^n$ będzie ciągiem niezależnych zmiennych losowych o tym samym rozkładzie gdzie $X_i \in \{-1, +1\}$ oraz $\Pr\{X_1 = 1\} = \frac{1}{2}$. Niech $S_n = \sum_{i=1}^n X_i$.

a) Podaj dokładne górne ograniczenie prawdopodobieństwa, że $S_{2500} > 100$ poprzez połączenie centralnego twierdzenia granicznego i twierdzenia Berry'ego-Esseeny.

(Twierdzenie Berry'ego-Esseeny: Mamy ciąg niezależnych zmiennych losowych o tym samym rozkładzie $\{Y_i\}_{i=1}^n$ spełniających $\mathbb{E}Y_i = 0$, $\text{Var}(Y_i) = \sigma^2$ oraz $\rho = \mathbb{E}(|Y_i|^3)$. Niech dalej F_n będzie

dystrybuantą $\frac{\sum_{i=1}^n Y_i}{\sigma\sqrt{n}}$ oraz niech Φ będzie dystrybuantą standardowego rozkładu normalnego $\mathcal{N}(0, 1)$. Wówczas następujące nierówności są spełnione dla każdego $n \geq 1$:

$$\sup_x |F_n(x) - \Phi(x)| \leq \frac{1}{2} \cdot \frac{\rho}{\sigma^3 \sqrt{n}}.$$

b) Podaj inne górne ograniczenie na $\Pr\{S_{2500} > 100\}$ poprzez użycie prawostronnej nierówności Hoeffdinga.

(Prawostronna nierówność Hoeffdinga:

Mamy ciąg niezależnych zmiennych losowych o tym samym rozkładzie $\{Y_i\}_{i=1}^n$ spełniających $a \leq Y_i \leq b$ dla pewnych liczb a i b i dla wszystkich i . Wówczas następujące nierówności są spełnione dla wszystkich $t > 0$ oraz $n \geq 1$

$$\Pr\left\{\sum_{i=1}^n Y_i - \mathbb{E}\left(\sum_{i=1}^n Y_i\right) \geq t\right\} \leq \exp\left(-\frac{2t^2}{nc^2}\right) \quad (1)$$

gdzie $c := b - a$.)

c) Podaj jeszcze inne górne ograniczenie na $\Pr\{S_{2500} > 100\}$ poprzez użycie tak zwanego ograniczenia Chernoffa.

(Ograniczenie Chernoffa:

Mamy ciąg niezależnych zmiennych losowych o tym samym rozkładzie Bernoulliego $\{Y_i\}_{i=1}^n$, – to jest $Y_i \in \{0; 1\}$ – oraz $\Pr\{Y_i = 1\} = p$. Niech $S_n = \sum_{i=1}^n Y_i$. Wówczas następująca nierówność zachodzi dla wszystkich $n \geq 1$ i dla wszystkich $\delta > 0$:

$$\Pr\{S_n \geq (1 + \delta)np\} \leq \exp\left(-\frac{\delta^2 np}{2 + \delta}\right).$$

d) Które z powyższych trzech ograniczeń jest najlepsze?

e) Które z trzech podejść do otrzymania górnego oszacowania pozwala również obliczyć nietrywialne dolne oszacowanie na $\Pr\{S_{2500} > 100\}$?