

# Rachunek Prawdopodobieństwa 3

Rafał Latała

22 maja 2007

Poniższe notatki powstają na podstawie (wybranych) wykładów z Rachunku Prawdopodobieństwa 3, prowadzonych w semestrze wiosennym 2006/07.

Przepraszam za wszystkie nieścisłości i omyłki mogące pojawić się w tekście i jednocześnie zwracam się z prośbą do czytelników, którzy zauważyli błędy lub mają jakieś inne uwagi na temat notatek o kontakt mailowy na adres [rlatala@mimuw.edu.pl](mailto:rlatala@mimuw.edu.pl) z podaniem wersji notatek (daty) do której chcą się ustosunkować.

Rafał Latała

# 1 Wielkie Odchylenia

W tej części, jeśli nie napiszemy inaczej będziemy zakładać, że  $X, X_1, X_2, \dots$  jest ciągiem niezależnych zmiennych losowym o jednakowym rozkładzie. Definiujemy

$$S_n := X_1 + X_2 + \dots + X_n, \quad \bar{S}_n := \frac{S_n}{n}.$$

Ze słabego prawa wielkich liczb wiemy, że  $\mathbf{P}(|\bar{S}_n - \mathbf{E}X| > \varepsilon) \rightarrow 0$  przy  $n \rightarrow \infty$ . Możemy zapytać jak szybka jest zbieżność. Z nierówności Czebyszewa dostajemy

$$\mathbf{P}(|\bar{S}_n - \mathbf{E}X| > \varepsilon) \leq \frac{\text{Var}(X)}{n\varepsilon^2}.$$

Jednak oszacowanie to jest dalekie od optymalnego dla „porządných” zmiennych  $X$ . Przykładowo, gdy  $X \sim \mathcal{N}(0, 1)$ , to  $\bar{S}_n \sim \mathcal{N}(0, 1/n) \sim X/\sqrt{n}$ , zatem wykorzystując oszacowanie z poniżej sformułowanego Faktu 1.1,

$$\mathbf{P}(|\bar{S}_n| \geq \varepsilon) = 2\mathbf{P}(X \geq \varepsilon\sqrt{n}) \sim \frac{2}{\sqrt{2\pi n\varepsilon}} \exp(-n\varepsilon^2/2).$$

**Fakt 1.1.** Dla dowolnego  $t > 0$ ,

$$(t^{-1} - t^{-3})e^{-t^2/2} \leq \int_t^\infty e^{-s^2/2} ds \leq t^{-1}e^{-t^2/2}.$$

**Dowód.** Mamy  $(s^{-1} \exp(-s^2/2))' = -(1 + s^{-2}) \exp(-s^2/2)$  oraz  $((s^{-1} - s^{-3}) \exp(-s^2/2))' = -(1 - 3s^{-4}) \exp(-s^2/2)$ , stąd

$$\begin{aligned} (t^{-1} - t^{-3})e^{-t^2/2} &= \int_t^\infty (1 - 3s^{-4})e^{-s^2/2} ds \leq \int_t^\infty e^{-s^2/2} ds \\ &\leq \int_t^\infty (1 + s^{-2})e^{-s^2/2} ds = t^{-1}e^{-t^2/2}. \quad \square \end{aligned}$$

Możemy więc postawić pytania:

- 1) Czy oszacowanie  $\mathbf{P}(|\bar{S}_n - \mathbf{E}X| > \varepsilon)$  rzędu  $\exp(-nf(\varepsilon))$  zachodzi dla szerszej klasy zmiennych?
- 2) Czy istnieje granica  $\lim_{n \rightarrow \infty} n^{-1} \log \mathbf{P}(\bar{S}_n \in A)$  dla ogólnej klasy zmiennych  $X$  i zbiorów  $A$ ?

Na te pytania poszukamy odpowiedzi w kolejnych sekcjach.

## 1.1 Podstawowe definicje. Nierówność Chernoffa

**Definicja 1.1.** Funkcję tworzącą momenty (transformatę Laplace’a) zmiennej  $X$  definiujemy wzorem

$$M_X(t) := \mathbf{E}e^{tX}, \quad t \in \mathbb{R}.$$

**Przykłady.**

- a) Dla  $X \sim \mathcal{N}(a, \sigma^2)$ ,  $M_X(t) = \exp(at + \sigma^2 t^2/2)$ .
- b) Dla  $X = g^3$ , gdzie  $g \sim \mathcal{N}(0, 1)$ ,  $M_X(t) = \infty$  dla  $t \neq 0$  i  $M_X(0) = 1$ .

**Fakt 1.2.** *Jeśli  $X$  i  $Y$  są niezależnymi zmiennymi losowymi, to  $M_{X+Y} = M_X M_Y$ . W szczególności,  $M_{S_n} = (M_X)^n$ .*

**Dowód.** Oczywisty. □

Łatwe szacowanie z nierówności Czebyszewa daje dla  $t > 0$ ,

$$\begin{aligned} \mathbf{P}(\bar{S}_n \geq s) &= \mathbf{P}(tS_n \geq stn) \leq e^{-snt} \mathbf{E}e^{tS_n} = e^{-snt} (M_X(t))^n \\ &= \exp(-n(st - \log M_X(t))). \end{aligned}$$

Biorąc infimum lewej strony po wszystkich  $t > 0$  dostajemy

$$\mathbf{P}(\bar{S}_n \geq s) \leq \exp\left(-n \sup_{t \geq 0} (st - \log M_X(t))\right). \quad (1)$$

Motywuje to następującą definicję

**Definicja 1.2.** *Dla zmiennej losowej  $X$  określamy*

$$\Lambda_X(t) := \log M_X(t), \quad D_{\Lambda_X} := \{t \in \mathbb{R} : \Lambda_X(t) < \infty\}$$

oraz

$$\Lambda_X^*(s) := \sup\{st - \Lambda_X(t) : t \in \mathbb{R}\}.$$

**Przykłady**

- a) Dla  $X \sim \mathcal{N}(a, \sigma^2)$ ,  $\Lambda_X(t) = at + \sigma^2 t^2/2$ ,  $D_{\Lambda_X} = \mathbb{R}$  oraz  $\Lambda_X^*(t) = (t - a)^2/(2\sigma^2)$ .  
b) Dla  $X = g^3$ ,  $g \sim \mathcal{N}(0, 1)$ ,  $D_{\Lambda_X} = \{0\}$  oraz  $\Lambda_X^* \equiv 0$ .

**Lemat 1.3.** *Funkcje  $\Lambda_X : \mathbb{R} \rightarrow (-\infty, \infty]$ ,  $\Lambda_X^* : \mathbb{R} \rightarrow [0, \infty)$  są wypukłe.*

**Dowód.** Wypukłość funkcji  $\Lambda$  wynika z nierówności Höldera. Funkcja  $\Lambda_X^*$  jest wypukła jako supremum funkcji wypukłych (liniowych). Ponadto  $\Lambda_X^*(t) \geq 0t - \Lambda_X(0) = 0$ . □

Przed sformułowaniem kolejnego lematu przypomnijmy konwencje, że wartość oczekiwana  $X$  da się określić za pomocą wzoru  $\mathbf{E}X := \mathbf{E}X_+ - \mathbf{E}X_-$ , jeśli tylko  $\mathbf{E}X_+ < \infty$  lub  $\mathbf{E}X_- < \infty$ .

**Lemat 1.4.** *i) Jeśli  $D_{\Lambda_X} = \{0\}$ , to  $\Lambda_X^* \equiv 0$ . Jeśli  $\Lambda_X(t) < \infty$  dla pewnego  $t > 0$ , to  $\mathbf{E}X_+ < \infty$ , a jeśli  $\Lambda_X(t) < \infty$  dla pewnego  $t < 0$ , to  $\mathbf{E}X_- < \infty$ .  
ii) Jeśli  $\mathbf{E}X_+ < \infty$  lub  $\mathbf{E}X_- < \infty$ , to  $st - \Lambda_X(t) \leq 0$  dla  $s \geq \mathbf{E}X$ ,  $t \leq 0$  lub  $s \leq \mathbf{E}X$ ,  $t \geq 0$ . W szczególności,*

$$\Lambda_X^*(s) = \sup\{st - \Lambda_X(t) : t \geq 0\} \text{ dla } s \geq \mathbf{E}X$$

oraz

$$\Lambda_X^*(s) = \sup\{st - \Lambda_X(t) : t \leq 0\} \text{ dla } s \leq \mathbf{E}X.$$

iii) Jeśli  $\mathbf{E}|X| < \infty$ , to  $\Lambda_X^*(\mathbf{E}X) = 0$ . Ponadto, dla dowolnego  $X$ ,  $\inf_t \Lambda_X^*(t) = 0$ .

**Dowód.** i) Dla  $t > 0$  mamy  $e^{tx} \geq tx_+$ , więc skończoność  $\mathbf{E}e^{tX}$  implikuje  $\mathbf{E}X_+ < \infty$ . Podobnie dla  $t < 0$ ,  $e^{tx} > -tx_-$ , a zatem  $\mathbf{E}X_- < \infty$ , jeśli  $\mathbf{E}e^{tX} < \infty$ .

ii) Z nierówności Jensena,

$$\Lambda_X(t) = \log \mathbf{E}e^{tX} \geq \mathbf{E} \log e^{tX} = t\mathbf{E}X,$$

zatem  $st - \Lambda_X(t) \leq (s - \mathbf{E}X)t \leq 0$  dla  $s \geq \mathbf{E}X, t \leq 0$  lub  $s \leq \mathbf{E}X, t \geq 0$ .

iii) Jeśli  $\mathbf{E}|X| < \infty$ , to z udowodnionego wyżej oszacowania  $\Lambda_X(t) \geq t\mathbf{E}X$  i

$$0 \leq \Lambda_X^*(\mathbf{E}X) \leq \sup_t (t\mathbf{E}X - t\mathbf{E}X) = 0.$$

Przypadek  $\mathbf{E}|X| = \infty$  podzielimy na trzy podprzypadki:

a)  $\mathbf{E}X_+ = \mathbf{E}X_- = \infty$ . Wówczas  $D_{\Lambda_X} = \{0\}$  i  $\Lambda_X^* \equiv 0$ .

b)  $\mathbf{E}X_+ < \infty = \mathbf{E}X_-$ . Dla  $s \in \mathbb{R}$  dostajemy

$$\log \mathbf{P}(X \geq s) \leq \inf_{t \geq 0} \log \mathbf{E} \exp(t(X - s)) = \inf_{t \geq 0} (\Lambda_X(t) - ts) = -\Lambda_X^*(s),$$

czyli  $0 \leq \Lambda_X^*(s) \leq -\log \mathbf{P}(X \geq s) \rightarrow 0$  przy  $s \rightarrow \infty$ .

c)  $\mathbf{E}X_+ = \infty > \mathbf{E}X_-$ . Jak w b) dowodzimy, że  $\Lambda_X^*(s) \rightarrow 0$  przy  $s \rightarrow -\infty$ .  $\square$

**Twierdzenie 1.5** (Nierówność Chernoffa). *Jeśli  $\mathbf{E}X_+ < \infty$  lub  $\mathbf{E}X_- < \infty$ , to*

$$\mathbf{P}(\bar{S}_n \geq s) \leq \exp(-n\Lambda_X^*(s)) \text{ dla } s \geq \mathbf{E}X$$

oraz

$$\mathbf{P}(\bar{S}_n \leq s) \leq \exp(-n\Lambda_X^*(s)) \text{ dla } s \leq \mathbf{E}X.$$

**Dowód.** Pierwsza nierówność wynika z (1) i Lematu 1.4 ii). Drugą nierówność dowodzimy analogicznie.  $\square$

**Przykłady.**

a) Dla  $X \sim \mathcal{N}(a, \sigma^2)$  nierówność Chernoffa daje

$$\mathbf{P}(\bar{S}_n \geq t) \leq \exp\left(-\frac{n(t-a)^2}{2\sigma^2}\right) \text{ dla } t \geq a$$

oraz

$$\mathbf{P}(\bar{S}_n \leq t) \leq \exp\left(-\frac{n(t-a)^2}{2\sigma^2}\right) \text{ dla } t \leq a.$$

W rzeczywistości mamy  $\bar{S}_n \sim \mathcal{N}(a, \sigma^2/n) \sim a + \sigma g/\sqrt{n}$ , gdzie  $g \sim \mathcal{N}(0, 1)$ , zatem np dla  $t > a$

$$\mathbf{P}(\bar{S}_n \geq t) = \mathbf{P}\left(g \geq \frac{\sqrt{n}}{\sigma}(t-a)\right) \sim \frac{\sigma}{\sqrt{2\pi n}(t-a)} \exp\left(-\frac{n(t-a)^2}{2\sigma^2}\right).$$

b) Dla  $X = g^3, g \sim \mathcal{N}(0, 1)$ , nierówność Chernoffa daje tylko trywialne oszacowanie  $\mathbf{P}(\bar{S}_n \geq t) \leq 1$ .

## 1.2 Oszacowania z dołu

Widzieliśmy, że bez dodatkowych założeń, nie możemy liczyć na odwrócenie nierówności Chernoffa. Daje się to jednak (w pewnym stopniu) zrobić przy założeniach o skończoności funkcji tworzącej momenty. Dlatego w tej części będziemy zazwyczaj dodatkowo zakładać, że

$$\mathbf{E}e^{tX} < \infty \text{ dla wszystkich } t \in \mathbb{R}. \quad (2)$$

**Lemat 1.6.** *Przy założeniu (2) funkcja  $M_X$  przedłuża się do funkcji analitycznej na całej płaszczyźnie zespolonej. Ponadto  $M_X^{(n)}(t) = \mathbf{E}(X^n e^{tX})$  dla  $n = 1, 2, \dots$*

**Dowód.** Funkcja  $f(z) := \mathbf{E} \exp(zX)$  jest dobrze określona dla  $z \in \mathbb{C}$ , bo  $\mathbf{E}|\exp(zX)| = \mathbf{E} \exp(\operatorname{Re}(z)X) < \infty$ . Oczywiście  $f$  jest przedłużeniem  $M_X$ , nietrudno też wykazać (korzystając z twierdzenia Lebesgue'a o zbieżności zmajoryzowanej), że  $f$  jest różniczkowalna i  $f'(z) = \mathbf{E}(X \exp(zX))$ . Podobnie indukcyjnie dowodzimy, że  $f^{(n)}(z) = \mathbf{E}(X^n \exp(zX))$ .  $\square$

**Definicja 1.3.** *Dla  $t \in \mathbb{R}$  definiujemy miarę probabilistyczną  $\mu_t$  na  $\mathbb{R}$  wzorem  $d\mu_t(x) = M_X(t)^{-1} e^{tx} d\mu_X(x)$ , tzn.*

$$\mu_t(A) = \frac{1}{M_X(t)} \mathbf{E}(e^{tX} \mathbb{1}_{\{X \in A\}}).$$

**Lemat 1.7.** *Miara probabilistyczna  $\mu_t$  spełnia warunki*

$$\mathbf{E}_{\mu_t}(x) = \int_{\mathbb{R}} x d\mu_t(x) = \Lambda'_X(t),$$

$$\operatorname{Var}_{\mu_t}(x) = \int_{\mathbb{R}} x^2 d\mu_t(x) - \left( \int_{\mathbb{R}} x d\mu_t(x) \right)^2 = \Lambda''_X(t).$$

**Dowód.** Zauważmy, że z Lematu 1.6,  $M_X^{(n)}(t) = M_X(t) \mathbf{E}_{\mu_t}(x^n)$ , więc

$$\Lambda'_X(t) = M_X(t)^{-1} M_X'(t) = \mathbf{E}_{\mu_t}(x)$$

oraz

$$\Lambda''_X(t) = M_X(t)^{-1} M_X''(t) - M_X(t)^{-2} (M_X'(t))^2 = \mathbf{E}_{\mu_t}(x^2) - (\mathbf{E}_{\mu_t}(x))^2 = \operatorname{Var}_{\mu_t}(x).$$

$\square$

Określmy

$$\begin{aligned} \alpha &:= \operatorname{ess\,inf} X = \inf\{t: \mathbf{P}(X < t) > 0\}, \\ \beta &:= \operatorname{ess\,sup} X = \sup\{t: \mathbf{P}(X > t) > 0\}. \end{aligned}$$

**Lemat 1.8.** *Dla dowolnej zmiennej losowej  $X$ ,*

$$\begin{aligned} \Lambda_X^*(t) &= \infty \text{ dla } t \notin [\alpha, \beta], \\ \mathbf{P}(X = \alpha) &= \exp(-\Lambda_X^*(\alpha)) \text{ jeśli } \alpha > -\infty, \\ \mathbf{P}(X = \beta) &= \exp(-\Lambda_X^*(\beta)) \text{ jeśli } \beta < \infty. \end{aligned}$$

**Dowód.** Dla  $t \geq 0$  mamy  $\Lambda_X(t) \leq \alpha t$ , stąd dla  $s > \alpha$ ,

$$\Lambda_X^*(s) \geq \sup\{st - \alpha t : t \geq 0\} = \infty.$$

Podobnie  $\Lambda_X(t) \leq \beta t$  dla  $t \leq 0$  i dla  $S < \beta$ ,

$$\Lambda_X^*(s) \geq \sup\{st - \beta t : t \leq 0\} = \infty.$$

Dla dowolnego  $t \in \mathbb{R}$ ,  $\Lambda_X(t) \geq \log(e^{t\beta} \mathbf{P}(X = \beta))$ , czyli

$$\mathbf{P}(X = \beta) \leq \inf_t \exp(-t\beta + \Lambda_X(t)) = \exp(-\sup_t (t\beta - \Lambda_X(t))) = \exp(-\Lambda_X^*(\beta)).$$

Z drugiej strony,

$$\exp(-\Lambda_X^*(\beta)) \leq \exp(\Lambda_X(t) - t\beta) = \mathbf{E} \exp(t(X - \beta)) \rightarrow \mathbf{P}(X = \beta) \text{ dla } t \rightarrow \infty.$$

Zatem  $\mathbf{P}(X = \beta) = \exp(-\Lambda_X^*(\beta))$ . Tożsamość  $\mathbf{P}(X = \alpha) = \exp(-\Lambda_X^*(\alpha))$  dowodzimy analogicznie.  $\square$

**Lemat 1.9.** Załóżmy, że zachodzi warunek (2) oraz  $\alpha < \beta$ . Wówczas  $\Lambda_X'$  jest funkcją ściśle rosnącą z  $\mathbb{R}$  na  $(\alpha, \beta)$ . Przekształcenie  $\Theta := (\Lambda_X')^{-1} : (\alpha, \beta) \rightarrow \mathbb{R}$  spełnia

$$\Lambda_X^*(s) = s\Theta(s) - \Lambda_X(\Theta(s)) \text{ dla } s \in (\alpha, \beta).$$

**Dowód.** Miara  $\mu_X$  jest niezdegenerowana, tzn.  $\mu_X(\{x\}) \neq 1$  dla  $x \in \mathbb{R}$ , więc miary  $\mu_t$  też są niezdegenerowane. Zatem  $\text{Var}_{\mu_t}(x) > 0$  i z Lematu 1.7,  $\Lambda_X''(t) > 0$  czyli  $\Lambda_X'$  jest ściśle rosnąca i funkcja  $\Theta = (\Lambda_X')^{-1}$  jest dobrze określona na  $\Lambda_X'(\mathbb{R})$ . Oczywiście dla dowolnego  $t$ ,

$$\Lambda_X'(t) = \frac{\int_{\alpha}^{\beta} x e^{tx} d\mu_X(x)}{\int_{\alpha}^{\beta} e^{tx} d\mu_X(x)} \in (\alpha, \beta),$$

więc  $\Lambda_X'(\mathbb{R}) \subset (\alpha, \beta)$ . Wykażemy, że zachodzi też odwrotna inkluzja.

Ustalmy  $t \in [\mathbf{E}X, \beta)$  oraz  $u \in (t, \beta)$ . Dla dowolnego  $s \geq 0$ ,

$$\Lambda_X(s) \geq \log(e^{su} \mathbf{P}(X \geq u)) = su + \log \mathbf{P}(X \geq u),$$

zatem

$$st - \Lambda_X(s) \leq s(t - u) - \log \mathbf{P}(X \geq u) < 0 \text{ dla } s > \frac{-\log \mathbf{P}(X \geq u)}{u - t}.$$

Z Lematu 1.4 ii),  $st - \Lambda_X(s) \leq 0$  dla  $s \leq 0$ , zatem supremum funkcji  $f(s) = st - \Lambda_X(s)$  jest osiągnięte w pewnym punkcie  $s_0 \in [0, -(u - t)^{-1} \log \mathbf{P}(X \geq u)]$ . W szczególności  $f'(s_0) = 0$  czyli  $t = \Lambda_X'(s_0)$ . Wykazaliśmy więc, że  $\Lambda_X'(\mathbb{R}) \supset [\mathbf{E}X, \beta)$  oraz  $\Lambda_X^*(t) = t\Theta(t) - \Lambda_X(\Theta(t))$  dla  $t \in [\mathbf{E}X, \beta)$ .

Przypadek  $t \in (\alpha, \mathbf{E}X]$  rozważamy analogicznie.  $\square$

**Twierdzenie 1.10.** Załóżmy, że zachodzi (2). Wówczas dla  $a \in (\alpha, \beta)$  oraz  $\varepsilon > 0$ ,

$$\mathbf{P}(|\bar{S}_n - a| < \varepsilon) \geq \left(1 - \frac{\Lambda_X''(\Theta(a))}{n\varepsilon^2}\right) \exp(-n(\Lambda_X^*(a) + \varepsilon|\Theta(a)|)),$$

gdzie  $\Theta := (\Lambda_X')^{-1}$ .

**Dowód.** Zdefiniujmy  $t := \Theta(a)$ , wówczas z Lematu 1.9,  $\Lambda_X^*(a) = at - \Lambda_X(t)$ . Niech  $Y, Y_1, \dots, Y_n$  będą niezależnymi zmiennymi losowymi o rozkładzie zadanym przez miarę probabilistyczną  $\mu_t$ . Na mocy Lematu 1.7,  $\mathbf{E}Y = \Lambda_X'(t) = a$  i  $\text{Var}(Y) = \Lambda_X''(t)$ . Zauważmy, że dla dowolnej nieujemnej funkcji  $f$  na  $\mathbb{R}^n$ ,

$$\mathbf{E}f(Y_1, \dots, Y_n) = (M_X(t))^{-n} \mathbf{E}e^{tS_n} f(X_1, \dots, X_n).$$

Zatem

$$\begin{aligned} \mathbf{P}\left(\left|\frac{1}{n} \sum_{i=1}^n Y_i - a\right| < \varepsilon\right) &= (M_X(t))^{-n} \mathbf{E}e^{tS_n} \mathbb{1}_{\{|\bar{S}_n - a| < \varepsilon\}} \\ &\leq (M_X(t))^{-n} e^{n(ta + |t|\varepsilon)} \mathbf{P}(|\bar{S}_n - a| < \varepsilon). \end{aligned}$$

Z nierówności Czebyszewa

$$\mathbf{P}\left(\left|\frac{1}{n} \sum_{i=1}^n Y_i - a\right| \geq \varepsilon\right) \leq \frac{\text{Var}(Y)}{n\varepsilon^2} = \frac{\Lambda_X''(t)}{n\varepsilon^2},$$

zatem

$$\begin{aligned} \mathbf{P}(|\bar{S}_n - a| < \varepsilon) &\geq \mathbf{P}\left(\left|\frac{1}{n} \sum_{i=1}^n Y_i - a\right| < \varepsilon\right) \exp(-n(ta - \Lambda_X(t) + |t|\varepsilon)) \\ &\geq \left(1 - \frac{\Lambda_X''(t)}{n\varepsilon^2}\right) \exp(-n(\Lambda_X^*(a) + |t|\varepsilon)). \end{aligned}$$

□

### 1.3 Twierdzenie Cramera na $\mathbb{R}$

Jesteśmy wreszcie gotowi do sformułowania twierdzenia o wielkich odchyłach w przypadku jednowymiarowym. W odróżnieniu od poprzedniego paragrafu nie stawiamy żadnych wstępnych założeń o rozkładzie  $X$ .

**Twierdzenie 1.11** (Prawo Wielkich Odchyłach Cramera).

i) Dla dowolnego zbioru domkniętego  $F \subset \mathbb{R}$ ,

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F) \leq - \inf_{x \in F} \Lambda_X^*(x).$$

ii) Dla dowolnego zbioru otwartego  $G \subset \mathbb{R}$ ,

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in G) \geq - \inf_{x \in G} \Lambda_X^*(x).$$

iii) Dla dowolnego zbioru  $\Gamma \in \mathcal{B}(\mathbb{R})$ ,

$$\begin{aligned} - \inf_{x \in \text{int}(\Gamma)} \Lambda_X^*(x) &\leq \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in \Gamma) \\ &\leq \limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in \Gamma) \leq - \inf_{x \in \text{cl}(\Gamma)} \Lambda_X^*(x). \end{aligned}$$

**Dowód.** i) Niech  $I_F := \inf_{x \in F} \Lambda_X^*(x)$ . Jeśli  $I_F = 0$ , to teza jest oczywista, możemy zatem zakładać, że  $I_F > 0$ . Wtedy  $D_{\Lambda_X} \neq \{0\}$ , czyli  $\mathbf{E}X_+ < \infty$  lub  $\mathbf{E}X_- < \infty$ . Rozważymy trzy przypadki.

a)  $\mathbf{E}|X| < \infty$ . Ponieważ  $\Lambda_X^*(\mathbf{E}X) = 0$  więc  $\mathbf{E}X \notin F$ . Niech  $(a, b)$  będzie składową  $\mathbb{R} \setminus F$  zawierającą  $\mathbf{E}X$ . Jeśli  $a > -\infty$ , to  $a \in F$ ,  $\Lambda_X^*(a) \geq I_F$ , podobnie jeśli  $b < \infty$ , to  $b \in F$ ,  $\Lambda_X^*(b) \geq I_F$ . Mamy zatem z nierówności Chernoffa,

$$\mathbf{P}(\bar{S}_n \in F) \leq \mathbf{P}(\bar{S}_n \leq a) + \mathbf{P}(\bar{S}_n \geq b) \leq e^{-n\Lambda_X^*(a)} + e^{-n\Lambda_X^*(b)} \leq 2e^{-nI_F},$$

skąd  $n^{-1} \log \mathbf{P}(\bar{S}_n \in F) \leq -I_F + n^{-1} \log 2 \rightarrow -I_F$  przy  $n \rightarrow \infty$ .

b)  $\mathbf{E}X = -\infty$ , wówczas  $\Lambda_X^*$  jest niemalejąca,  $\Lambda_X^*(x) \rightarrow 0$  przy  $x \rightarrow -\infty$ , a zatem warunek  $I_F > 0$  implikuje  $b = \inf F > -\infty$ . Z domkniętości  $b \in F$ , czyli  $\Lambda_X^*(b) \geq I_F$  oraz

$$\mathbf{P}(\bar{S}_n \in F) \leq \mathbf{P}(\bar{S}_n \geq b) \leq e^{-n\Lambda_X^*(b)} \leq e^{-nI_F}.$$

c)  $\mathbf{E}X = \infty$ . Rozumujemy analogicznie jak w b).

ii) Musimy, że warunek  $x \in G$  implikuje  $\liminf n^{-1} \log \mathbf{P}(\bar{S}_n \in G) \geq -\Lambda_X^*(x)$ . Zmienna  $Y = X - x$  spełnia  $\Lambda_Y(t) = \Lambda_X(t) - xt$ ,  $\Lambda_Y^*(s) = \Lambda_X^*(s + x)$ . Zatem rozpatrując  $X - x$  i  $G - x$  zamiast  $X$  i  $G$  widzimy, że możemy zakładać, iż  $x = 0$ . Z otwartości  $G$ , mamy  $(-\delta, \delta) \subset G$  dla pewnego  $\delta > 0$ . Wystarczy zatem wykazać

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in (-\delta, \delta)) \geq -\Lambda_X^*(0) = \inf_{t \in \mathbb{R}} \Lambda_X(t). \quad (3)$$

Dowód (3) rozbijemy na kilka przypadków.

Przypadek I.  $X \geq 0$  p.n. Mamy wówczas z twierdzenia Lebesgue'a o zbieżności zmajorzowanej,

$$\inf_t \Lambda_X(t) \leq \lim_{t \rightarrow -\infty} \Lambda_X(t) = \log \lim_{t \rightarrow -\infty} \mathbf{E}e^{tX} = \log \mathbf{P}(X = 0).$$

Ponadto  $\mathbf{P}(\bar{S}_n \in (-\delta, \delta)) \geq \mathbf{P}(\bar{S}_n = 0) = \mathbf{P}(X = 0)^n$  i natychmiast dostajemy (3).

Przypadek II.  $X \leq 0$  p.n. Dowodzimy w taki sam sposób jak w przypadku I.

Przypadek III.  $\text{essinf} X < 0 < \text{esssup} X$  oraz  $D_{\Lambda_X} = \mathbb{R}$ . Z Twierdzenia 1.10 (z  $a = 0$ ) dostajemy dla  $0 < \varepsilon < \delta$ ,

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in (-\delta, \delta)) \geq \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(|\bar{S}_n| \leq \varepsilon) \geq -\Lambda_X^*(0) - \varepsilon.$$

Biorąc  $\varepsilon \rightarrow 0+$  dostajemy (3).



Przypadek IV.  $\text{essinf} X < 0 < \text{esssup} X$  i  $X$  dowolne. Wybierzmy  $M > 0$  na tyle duże by  $\mathbf{P}(X \in [-M, 0))$ ,  $\mathbf{P}(X \in (0, M]) > 0$ . Niech  $Y$  będzie miało taki rozkład jak zmienna  $X$  pod warunkiem  $|X| \leq M$ , tzn.

$$\mathbf{P}(Y \in A) = \mathbf{P}(X \in A, |X| \leq M) / \mathbf{P}(|X| \leq M),$$

zaś  $Y_1, Y_2, \dots$  będą niezależnymi kopiami  $Y$  oraz  $\bar{T}_n = (Y_1 + \dots + Y_n)/n$ . Zauważmy, że dla dowolnej funkcji mierzalnej  $f: \mathbb{R}^n \rightarrow [0, \infty)$  mamy

$$\begin{aligned} \mathbf{E}f(X_1, \dots, X_n) &\geq \mathbf{E}f(X_1, \dots, X_n) \mathbb{1}_{\{|X_1| \leq M, \dots, |X_n| \leq M\}} \\ &= \mathbf{P}(|X| \leq M)^n \mathbf{E}f(Y_1, \dots, Y_n). \end{aligned}$$

W szczególności,

$$\mathbf{P}(\bar{S}_n \in (-\delta, \delta)) \geq \mathbf{P}(|X| \leq M)^n \mathbf{P}(\bar{T}_n \in (-\delta, \delta)).$$

Zmienna  $Y$  jest ograniczona, więc na mocy przypadku III,

$$\begin{aligned} \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in (-\delta, \delta)) &\geq \log \mathbf{P}(|X| \leq M) + \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{T}_n \in (-\delta, \delta)) \\ &\geq \log \mathbf{P}(|X| \leq M) + \inf_t \Lambda_Y(t) = \inf_t \Lambda_M(t), \end{aligned}$$

gdzie  $\Lambda_M(t) := \log \mathbf{E}e^{tX} \mathbb{1}_{\{|X| \leq M\}}$ . Zauważmy, że funkcje  $\Lambda_M$  rośnie po  $M$ , więc  $\inf_t \Lambda_M(t)$  zbiega przy  $M \rightarrow \infty$  do pewnego  $a$ . Wykazaliśmy, że

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in (-\delta, \delta)) \geq a,$$

więc wystarczy wykazać, że  $a \geq \inf_t \Lambda_X(t)$ . Rozpatrzmy zbiory

$$K_M := \{t: \Lambda_M(t) \leq a\}.$$

Funkcja  $\Lambda_M(t)$  zbiega do nieskończoności przy  $t \rightarrow \infty$ , więc zbiory  $K_M$  tworzą zstępującą rodzinę zbiorów zwartych, niepustych. Istnieje więc punkt  $t_0$  należący do ich przecięcia, ale wtedy  $\Lambda_M(t_0) \leq a$  dla wszystkich  $M$  czyli, z twierdzenia Lebesgue'a o zbieżności monotonicznej,  $\Lambda_X(t_0) = \lim_{M \rightarrow \infty} \Lambda_M(t_0) \leq a$ .  $\square$

**Uwaga 1.1** Analiza pierwszej części dowodu pokazuje, że wykazaliśmy

$$\mathbf{P}(\bar{S}_n \in \Gamma) \leq 2 \exp(-n \inf_{x \in \text{cl}(\Gamma)} \Lambda_X^*(x)) \text{ dla dowolnego } \Gamma \in \mathcal{B}(\mathbb{R}).$$

## 1.4 Twierdzenie Cramera na $\mathbb{R}^d$

W tej części będziemy zakładać, że  $X, X_1, \dots$  są niezależnymi  $d$ -wymiarowymi wektorami losowymi o jednakowym rozkładzie.

**Definicja 1.4.** Dla  $d$ -wymiarowego wektora losowego  $X$  określamy dla  $t \in \mathbb{R}^d$ ,

$$M_X(t) := \mathbf{E}e^{\langle t, X \rangle}, \quad \Lambda_X(t) := \log M_X(t)$$

oraz dla  $s \in \mathbb{R}^d$ ,

$$\Lambda_X^*(s) := \sup\{\langle s, t \rangle - \Lambda_X(t) : t \in \mathbb{R}^d\}.$$

Współrzędne wektorów  $X$  (odp.  $X_i$ ) będziemy oznaczać  $X^{(j)}$  (odp.  $X_i^{(j)}$ ) i definiujemy  $\bar{S}_n^{(j)} := n^{-1} \sum_{i=1}^n X_i^{(j)}$ .

Będziemy zakładać, że

$$M_X(t) < \infty \text{ dla wszystkich } t \in \mathbb{R}^d. \quad (4)$$

**Lemat 1.12.** Przy założeniu warunku (4),

i) Funkcja  $\Lambda_X : \mathbb{R}^d \rightarrow \mathbb{R}$  jest wypukła, klasy  $C^\infty$  oraz

$$\frac{\partial}{\partial t_i} \Lambda(t) = \mathbf{E}(X^{(i)} e^{\langle t, X \rangle}).$$

ii) Funkcja  $\Lambda_X^* : \mathbb{R}^d \rightarrow [0, \infty]$  jest wypukła.

iii) Jeśli  $s = \nabla \Lambda_X(t)$  dla pewnych  $s, t \in \mathbb{R}^d$ , to  $\Lambda_X^*(s) = \langle t, s \rangle - \Lambda(t)$ .

**Dowód.** i) Wypukłość  $\Lambda_X$  wynika z nierówności Höldera jak w przypadku jednowymiarowym. By udowodnić gładkość, indukcyjnie po  $|\alpha| = \alpha_1 + \dots + \alpha_d$ , dowodzimy, że dla  $\alpha \in \mathbb{Z}_+^d$ ,

$$\frac{\partial^{\alpha_1}}{\partial t_1^{\alpha_1}} \dots \frac{\partial^{\alpha_d}}{\partial t_d^{\alpha_d}} \Lambda_X(t) = \mathbf{E}((X^{(1)})^{\alpha_1} \dots (X^{(d)})^{\alpha_d} e^{\langle t, X \rangle}).$$

ii) Funkcja  $\Lambda_X^*$  jest wypukła jako supremum funkcji liniowych. Nieujemność  $\Lambda_X^*$  wynika z szacowania  $\Lambda_X^*(t) \geq \langle 0, t \rangle - \Lambda_X(0) = 0$ .

iii) Ustalmy  $u \in \mathbb{R}^d$  i określmy

$$g(\alpha) := \alpha \langle u - t, s \rangle - \Lambda_X(t + \alpha(u - t)) + \langle t, s \rangle, \quad \alpha \in \mathbb{R}.$$

Wypukłość  $\Lambda_X$  implikuje wklęsłość  $g$ , zatem

$$g(1) - g(0) \leq \lim_{\alpha \rightarrow 0^+} \frac{g(\alpha) - g(0)}{\alpha} = \langle u - t, s \rangle - \langle u - t, \nabla \Lambda_X(t) \rangle = 0.$$

Dostaliśmy więc  $g(1) \leq g(0)$ , czyli  $\langle u, s \rangle - \Lambda_X(u) \leq \langle t, s \rangle - \Lambda_X(t)$ , co po wzięciu supremum po  $u \in \mathbb{R}^d$  daje tezę.  $\square$

**Twierdzenie 1.13.** Załóżmy, że  $M_X(t) < \infty$  dla wszystkich  $t \in \mathbb{R}^d$ . Wówczas

i) Dla dowolnego zbioru domkniętego  $F \subset \mathbb{R}^d$ ,

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F) \leq - \inf_{x \in F} \Lambda_X^*(x).$$

ii) Dla dowolnego zbioru otwartego  $G \subset \mathbb{R}^d$ ,

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in G) \geq - \inf_{x \in G} \Lambda_X^*(x).$$

iii) Dla dowolnego zbioru  $\Gamma \in \mathcal{B}(\mathbb{R}^d)$ ,

$$\begin{aligned} - \inf_{x \in \text{int}(\Gamma)} \Lambda_X^*(x) &\leq \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in \Gamma) \\ &\leq \limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in \Gamma) \leq - \inf_{x \in \text{cl}(\Gamma)} \Lambda_X^*(x). \end{aligned}$$

**Dowód.** i) Zauważmy, że  $2\delta - \inf_{s \in F} (\Lambda_X^*(s) \wedge M) \rightarrow - \inf_{s \in F} \Lambda_X^*(s)$  przy  $\delta \rightarrow 0+$ ,  $M \rightarrow \infty$ , więc wystarczy iż wykażemy

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F) \leq 2\delta - \inf_{s \in F} (\Lambda_X^*(s) \wedge M) \text{ dla } \delta > 0, M < \infty. \quad (5)$$

Ustalmy  $\delta > 0$  i  $M < \infty$ , dowód (5) podzielimy na dwa kroki.

Krok I.  $F \subset \mathbb{R}^d$  zwarty. Dla  $s \in F$  niech  $t_s \in \mathbb{R}^d$  będzie takie, że

$$\langle s, t_s \rangle - \Lambda_X(t_s) \geq \Lambda_X^*(s) \wedge M - \delta$$

oraz  $r_s > 0$  takie, że  $r_s |t_s| \leq \delta$ . Przez  $B(s, r)$  będziemy oznaczać kulę otwartą o środku w  $s$  i promieniu  $r$ . Zauważmy, że dla dowolnego zbioru  $G \in \mathcal{B}(\mathbb{R}^d)$ ,

$$\mathbf{P}(\bar{S}_n \in G) = \mathbf{E} \mathbb{1}_{\{\bar{S}_n \in G\}} \leq \mathbf{E} \exp(\langle t, \bar{S}_n \rangle - \inf_{x \in G} \langle t, x \rangle).$$

Zauważmy, że

$$\inf_{x \in B(s, r_s)} \langle t_s, x \rangle = \langle t_s, s \rangle + \inf_{x \in B(s, r_s)} \langle t_s, x - s \rangle = \langle t_s, s \rangle - r_s |t_s| \geq \langle t_s, s \rangle - \delta.$$

Zatem

$$\begin{aligned} \mathbf{P}(\bar{S}_n \in B(s, r_s)) &\leq \mathbf{E} \exp(n \langle t_s, \bar{S}_n \rangle) \exp(- \inf_{x \in B(s, r_s)} n \langle t_s, x \rangle) \\ &\leq \exp(n(\Lambda_X(t_s) - \langle t_s, s \rangle + \delta)) \leq \exp(n(2\delta - \Lambda_X^*(s) \wedge M)). \end{aligned}$$

Zbiór  $F$  jest zwarty więc istnieje skończony podzbiór  $S \subset F$  taki, że  $F \subset \bigcup_{s \in S} B(s, r_s)$  i wówczas

$$\mathbf{P}(\bar{S}_n \in F) \leq \sum_{s \in S} \mathbf{P}(\bar{S}_n \in B(s, r_s)) \leq \sum_{s \in S} \exp(n(2\delta - \Lambda_X^*(s) \wedge M)),$$

zatem

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F) \leq 2\delta - \min_{s \in S} (\Lambda_X^*(s) \wedge M) \leq 2\delta - \inf_{s \in F} (\Lambda_X^*(s) \wedge M).$$

Krok II.  $F$  dowolny zwarty. Dla  $\rho > 0$  niech  $K_\rho := [-\rho, \rho]^d$ . Jeśli  $\rho > \max_j \mathbf{E}|X^{(j)}|$ , to z nierówności Chernoffa,

$$\mathbf{P}(\bar{S}_n \notin K_\rho) \leq \sum_{j=1}^d \mathbf{P}(|\bar{S}_n^{(j)}| > \rho) \leq \sum_{j=1}^d (\exp(-n\Lambda_{X^{(j)}}^*(\rho)) + \exp(-n\Lambda_{X^{(j)}}^*(-\rho))).$$

Ponieważ  $\Lambda_{X^{(j)}}^*(s) \rightarrow \infty$  przy  $|s| \rightarrow \infty$ , więc dla odpowiednio dużego  $\rho$ ,  $\mathbf{P}(\bar{S}_n \notin K_\rho) \leq \exp(-nM)$ , czyli

$$\mathbf{P}(\bar{S}_n \in F) \leq \mathbf{P}(\bar{S}_n \in F \cap K_\rho) + \mathbf{P}(\bar{S}_n \notin K_\rho) \leq \mathbf{P}(\bar{S}_n \in F \cap K_\rho) + \exp(-nM).$$

Zbiór  $F \cap K_\rho$  jest zwarty, więc na mocy Kroku I,

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F \cap K_\rho) \leq 2\delta - \inf_{s \in F \cap K_\rho} (\Lambda_X^*(s) \wedge M),$$

a ponieważ  $2\delta - \inf_{s \in F \cap K_\rho} (\Lambda_X^*(s) \wedge M) > -M$ , więc

$$\limsup_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in F) \leq 2\delta - \inf_{s \in F \cap K_\rho} (\Lambda_X^*(s) \wedge M) \leq 2\delta - \inf_{s \in F} (\Lambda_X^*(s) \wedge M).$$

ii) Wystarczy iż wykażemy, że  $\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in G) \geq -\Lambda_X^*(s)$  dla dowolnego  $s \in G$ . Ponieważ  $B(s, \delta) \subset G$  dla pewnego  $\delta > 0$ , więc musimy jedynie wykazać, że

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in B(s, \delta)) \geq -\Lambda_X^*(s) \text{ dla } \delta > 0.$$

Rozpatrzmy dwa przypadki.

Przypadek I.  $s = \nabla \Lambda_X(t)$  dla pewnego  $t \in \mathbb{R}^d$ .

Określmy miarę probabilistyczną  $\mu_t$  na  $\mathbb{R}^d$  wzorem

$$d\mu_t(x) := \frac{1}{M_X(t)} e^{\langle x, t \rangle} d\mu_X(x),$$

czyli  $d\mu_X(x) = \exp(-\langle x, t \rangle + \Lambda_X(t)) d\mu_t(x)$ . Niech  $Y, Y_1, Y_2, \dots$  będą niezależnymi wektorami losowymi o rozkładzie  $\mu_t$ ,  $T_n := (Y_1 + \dots + Y_n)$  oraz  $\bar{T}_n := T_n/n$ . Dla dowolnej nieujemnej funkcji mierzalnej  $f$  na  $\mathbb{R}^d$  mamy

$$\mathbf{E}f(X_1, \dots, X_n) = \exp(n\Lambda_X(t)) \mathbf{E}f(Y_1, \dots, Y_n) \exp(-\langle t, T_n \rangle),$$

zatem

$$\begin{aligned} \mathbf{P}(\bar{S}_n \in B(s, \delta)) &= \exp(n\Lambda_X(t)) \mathbf{E} \exp(-\langle t, T_n \rangle) \mathbb{1}_{\{\bar{T}_n \in B(s, \delta)\}} \\ &= \exp(-n(\langle t, s \rangle - \Lambda_X(t))) \mathbf{E} \exp(-n\langle t, \bar{T}_n - s \rangle) \mathbb{1}_{\{|\bar{T}_n - s| < \delta\}} \\ &\geq \exp(-n\Lambda_X^*(s) + n\delta) \mathbf{P}(|\bar{T}_n - s| < \delta). \end{aligned}$$

Mamy jednak

$$\mathbf{E}Y = \frac{1}{M_X(t)} \mathbf{E}(X e^{\langle t, X \rangle}) = \frac{\nabla M_X(t)}{M_X(t)} = \nabla \Lambda_X(t) = s,$$

czyli ze słabego prawa wielkich liczb,

$$\begin{aligned} \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in B(s, \delta)) &\geq -\Lambda_X^*(s) + \delta + \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(|\bar{T}_n - s| < \delta) \\ &= -\Lambda_X^*(s) + \delta. \end{aligned}$$

Otrzymujemy więc

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in B(s, \delta)) \geq \lim_{\delta' \rightarrow 0^+} \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in B(s, \delta)) \geq -\Lambda_X^*(s).$$

Przypadek II.  $X$  dowolna zmienna spełniająca (4). Niech  $G, G_1, G_2, \dots$  niezależne kanoniczne  $d$ -wymiarowe wektory gaussowskie (tzn. współrzędne  $G_i$  są niezależnymi zmiennymi  $\mathcal{N}(0, 1)$ ), niezależne od  $X, X_1, X_2, \dots$ . Ustalmy  $M > 0$  i zdefiniujmy

$$Y := X + \frac{1}{\sqrt{M}}G, \quad Y_i := X_i + \frac{1}{\sqrt{M}}G_i, \quad R_n := \frac{G_1 + \dots + G_n}{n\sqrt{M}}$$

Wówczas  $M_Y(t) = M_X(t)M_G(t/\sqrt{M}) = M_X(t) \exp(|t|^2/(2M))$ , czyli  $\Lambda_Y(t) = \Lambda_X(t) + |t|^2/(2M) \geq \Lambda_X(t)$  oraz  $\Lambda_Y^*(s) \leq \Lambda_X^*(s)$  dla wszystkich  $s$ . Z nierówności Jensena,  $\Lambda_X(t) = \log \mathbf{E} \exp(\langle t, X \rangle) \geq \mathbf{E} \langle t, X \rangle$ , czyli  $\Lambda_Y(t) \geq |t|^2/(2M) + \langle t, \mathbf{E}X \rangle$  oraz

$$\langle s, t \rangle - \Lambda_Y(t) \leq -|t|^2/(2M) + \langle t, s - \mathbf{E}X \rangle \rightarrow -\infty \text{ przy } |t| \rightarrow \infty,$$

a więc funkcja  $t \rightarrow \langle s, t \rangle - \Lambda_Y(t)$  osiąga swoje supremum czyli istnieje  $t$  takie, że  $s = \nabla \Lambda_Y(t)$ . Mamy

$$\frac{Y_1 + \dots + Y_n}{n} = \bar{S}_n + R_n,$$

na mocy przypadku I otrzymujemy

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n + R_n \in B(s, \delta/2)) \geq -\Lambda_Y^*(s) \geq -\Lambda_X^*(s).$$

Zmienna  $R_n$  ma ten sam rozkład, co  $G/\sqrt{nM}$ , więc

$$\mathbf{P}(|R_n| \geq \frac{\delta}{2}) = \mathbf{P}(|G| \geq \sqrt{nM} \frac{\delta}{2}) \leq \sum_{j=1}^d \mathbf{P}(|G^{(j)}| \geq \sqrt{nM} \frac{\delta}{2d}) \leq 2d \exp(-\frac{nM\delta^2}{8d^2}),$$

ostatnie szacowanie wynika stąd, że  $G^{(j)} \sim \mathcal{N}(0, 1)$ . Jeśli przyjmiemy  $M := 8\delta^{-2}d^2(\Lambda_X^*(s) + 1)$ , to dostaniemy

$$\mathbf{P}(|R_n| \geq \frac{\delta}{2}) \leq 2d \exp(-n(\Lambda_X^*(s) + 1)) \leq \frac{1}{2} \mathbf{P}(\bar{S}_n + R_n \in B(S, \frac{\delta}{2}))$$

dla dostatecznie dużych  $n$ . Zatem

$$\mathbf{P}(\bar{S}_n \in B(S, \delta)) \geq \mathbf{P}(\bar{S}_n + R_n \in B(S, \frac{\delta}{2})) - \mathbf{P}(|R_n| \geq \frac{\delta}{2}) \geq \frac{1}{2} \mathbf{P}(\bar{S}_n + R_n \in B(s, \frac{\delta}{2}))$$

dla dużych  $n$ , czyli

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n \in B(s, \delta)) \geq \liminf_{n \rightarrow \infty} \frac{1}{n} \log \mathbf{P}(\bar{S}_n + R_n \in B(s, \delta/2)) \geq -\Lambda_X^*(s).$$

□

## 2 Nierówności Wykładnicze.

Nierówność Chernoffa pokazuje, że jeśli  $S = \sum_{i=1}^n X_i$  oraz  $X_i$  są niezależne o jednakowym rozkładzie, to  $\mathbf{P}(S \geq s) \leq \exp(-n\Lambda_X^*(s/n))$ . Jednak stosowanie tej nierówności w praktyce natrafia na pewne ograniczenia:

- i) Nie zawsze da się dokładnie obliczyć  $\Lambda_X$ , a co za tym idzie  $\Lambda_X^*$ ;
- ii) Założenie o jednakowym rozkładzie  $X_i$  bywa często niewygodne.

By te trudności obejść zauważmy, że dowód nierówności Chernoffa pokazuje, że

$$\mathbf{P}(S \geq s) \leq \exp\left(-\sup_{t>0}(st - \Lambda_S(t))\right) \text{ dla } s > 0.$$

Ponadto jeśli będziemy umieli oszacować dla wszystkich  $i$ ,  $\Lambda_{X_i}$  z góry, to da nam to górne ograniczenie  $\Lambda_S = \sum_{i=1}^n \Lambda_{X_i}$  i za pośrednictwem powyższej nierówności ograniczymy też  $\mathbf{P}(S \geq s)$ . Metodę tę będziemy stosować w kolejnych paragrafach.

Szacowania  $\mathbf{P}(S \geq s)$  z dołu są z reguły dużo trudniejsze, co już wcześniej widzieliśmy przy próbie odwrócenia nierówności Chernoffa.

### 2.1 Nierówności dla ograniczonych przyrostów

W tym paragrafie pokażemy jakie szacowania można wyprowadzić, jeśli potrafimy oszacować poszczególne zmienne z góry.

**Lemat 2.1.** *Załóżmy, że  $X$  jest zmienną losową o średniej zero taką, że  $d = \|X\|_\infty < \infty$ . Wówczas*

$$\Lambda_X(t) \leq \exp((dt)^2/2) \text{ dla wszystkich } t.$$

**Dowód.** Ponieważ  $\Lambda_X(t) = \Lambda_{X/d}(dt)$  możemy zakładać, że  $d = 1$ . Dla  $|x| \leq 1$  mamy  $\frac{1-x}{2}t + \frac{1+x}{2}t = tx$ , więc z wypukłości  $\exp(x)$ ,

$$e^{tx} \leq \frac{1-x}{2}e^t + \frac{1+x}{2}e^t = \cosh(t) + x \sinh(t) \text{ dla } |x| \leq 1.$$

Zatem, jeśli  $\|X\|_\infty \leq 1$ , to

$$\mathbf{E} \exp(tX) \leq \cosh(t) + \sinh(t)\mathbf{E}X = \cosh(t) \leq \exp(t^2/2).$$

□

**Twierdzenie 2.2.** *Załóżmy, że  $X_i$  są niezależnymi zmiennymi losowymi o średniej zero oraz  $\|X_i\|_\infty \leq d_i$ . Wówczas*

$$\mathbf{E} \exp\left(t \sum_{i=1}^n X_i\right) \leq \exp\left(\sum_{i=1}^n d_i^2 \frac{t^2}{2}\right)$$

oraz

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \leq \exp\left(-\frac{s^2}{2 \sum_{i=1}^n d_i^2}\right).$$

**Dowód.** Pierwsza nierówność wynika natychmiast z Lematu 2.1. By uzyskać drugą szacujemy dla  $S = \sum_{i=1}^n X_i$ ,

$$\begin{aligned} \mathbf{P}(S \geq s) &\leq \exp\left(-\sup_{t>0}(st - \Lambda_S(t))\right) \leq \exp\left(-\sup_{t>0}\left(st - \sum_{i=1}^n d_i^2 \frac{t^2}{2}\right)\right) \\ &= \exp\left(\frac{s^2}{2\sum_{i=1}^n d_i^2}\right). \end{aligned}$$

□

**Wniosek 2.3.** Załóżmy, że  $(\varepsilon_i)$  jest ciągiem Bernouliego tzn. ciągiem niezależnych zmiennych losowych takim, że  $\mathbf{P}(\varepsilon_i = \pm 1) = 1/2$ . Wówczas dla dowolnego ciągu  $a_i$  spełniającego  $\sum_i a_i^2 < \infty$  zachodzi

$$\mathbf{P}\left(\sum_i a_i \varepsilon_i \geq s\right) \leq \exp\left(-\frac{s^2}{2\sum_i a_i^2}\right).$$

**Dowód.** Prosty argument graniczny pokazuje, że wystarczy rozważać przypadek skończony, który jest natychmiastowym wnioskiem z Twierdzenia 2.2. □

**Uwaga 2.2** Można udowodnić znacznie ogólniejsze twierdzenie - *nierówność Azumy*. Dla dowolnego martyngału  $(M_k, \mathcal{F}_k)_{k=1}^n$  takiego, że  $\|M_k - M_{k-1}\|_\infty \leq d_k$  zachodzi

$$\mathbf{P}(M_n - M_0 \geq s) \leq \exp\left(\frac{s^2}{2\sum_{i=1}^n d_i^2}\right).$$

## 2.2 Nierówności typu Bernsteina

Nierówności z poprzedniego paragrafu są mało precyzyjne, działają dobrze tylko, gdy wariancja zmiennych jest zbliżona do kwadratu ich normy supremum. Jest to związane z tym, że w założeniach występowała tylko norma  $L^\infty$ . W tym paragrafie pokażemy jak można jednocześnie wykorzystywać znajomość wariancji i normy supremum.

**Lemat 2.4.** Załóżmy, że  $X$  jest zmienną losową o średniej zero taką, że istnieją  $\sigma^2, M < \infty$  spełniające

$$\mathbf{E}|X|^k \leq \frac{k!}{2} \sigma^2 M^{k-2} \text{ dla } k = 2, 3, \dots$$

Wówczas

$$\Lambda_X(t) \leq \frac{\sigma^2 t^2}{2(1 - M|t|)} \text{ dla } M|t| < 1.$$

**Dowód.** Liczymy

$$\begin{aligned} M_X(t) &= \sum_{k=0}^{\infty} \frac{t^k}{k!} \mathbf{E}X^k \leq 1 + \sum_{k=2}^{\infty} \frac{t^k}{2} \sigma^2 M^{k-2} = 1 + \frac{t^2 \sigma^2}{2} \sum_{k=2}^{\infty} (tM)^{k-2} \\ &= 1 + \frac{\sigma^2 t^2}{2(1 - M|t|)} \leq \exp\left(\frac{\sigma^2 t^2}{2(1 - M|t|)}\right). \end{aligned}$$

□

**Twierdzenie 2.5** (Nierówność Bernsteina). *Założmy, że  $X_i$  są niezależnymi zmiennymi losowymi o średniej zero, zaś  $\sigma_i^2, M < \infty$  są takie, że*

$$\mathbf{E}|X_i|^k \leq \frac{k!}{2} \sigma_i^2 M^{k-2} \text{ dla } i \geq 1, k \geq 2. \quad (6)$$

Wówczas

$$\mathbf{E} \exp\left(t \sum_{i=1}^n X_i\right) \leq \exp\left(\frac{t^2 \sum_{i=1}^n \sigma_i^2}{2(1 - M|t|)}\right) \text{ dla } M|t| < 1$$

oraz dla  $s > 0$ ,

$$\begin{aligned} \mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) &\leq \exp\left(-\frac{s^2}{2 \sum_{i=1}^n \sigma_i^2 + 2Ms}\right), \\ \mathbf{P}\left(\left|\sum_{i=1}^n X_i\right| \geq s\right) &\leq 2 \exp\left(-\frac{s^2}{2 \sum_{i=1}^n \sigma_i^2 + 2Ms}\right). \end{aligned}$$

**Dowód.** Niech  $S := \sum_{i=1}^n X_i$ ,  $\sigma^2 := \sum_{i=1}^n \sigma_i^2$ , wówczas  $\Lambda_S = \sum_i \Lambda_{X_i}$  i pierwsze oszacowanie wynika z Lematu 2.4. Dalej szacujemy

$$\begin{aligned} \mathbf{P}(S \geq s) &\leq \exp\left(-\sup_{t>0} (st - \Lambda_S(t))\right) \leq \exp\left(-\sup_{0 < t < M^{-1}} \left(st - \frac{t^2 \sigma^2}{2(1 - M|t|)}\right)\right) \\ &\leq \exp\left(-\frac{s^2}{2\sigma^2 + 2Ms}\right), \end{aligned}$$

gdzie ostatnią nierówność dostajemy przyjmując  $t = s(\sigma^2 + Ms)^{-1}$ . Ponieważ zmienne  $-X_i$  spełniają te same założenia co  $X_i$ , więc dostajemy dla  $s < 0$ ,

$$\mathbf{P}(S \leq s) = \mathbf{P}(-S \geq -s) \leq \exp\left(-\frac{s^2}{2\sigma^2 + 2Ms}\right)$$

i z tożsamości  $\mathbf{P}(|S| \geq s) = \mathbf{P}(S \geq s) + \mathbf{P}(S \leq -s)$  wynika ostatnia część tezy. □

**Uwaga 2.3** Na mocy centralnego twierdzenia granicznego oraz Faktu 1.1 nie możemy się spodziewać lepszego oszacowania niż  $\exp(-s^2/(2\sigma^2))$ . Ponadto zmienne  $X_i$  o rozkładzie symetrycznym wykładniczym z parametrem 1 (tzn. zmienne z gęstością  $\exp(-|x|)/2$ ) spełniają  $\mathbf{E}|X_i|^2 = k!$ , czyli dla takich zmiennych zachodzą założenia Twierdzenia 2.5 z  $\sigma_i^2 = 2, M = 1$ . Pokazuje to, że i nie możemy uzyskać szacowania lepszego niż  $\exp(-s/M)$ .



**Wniosek 2.6.** Załóżmy, że  $X_i$  są ograniczonymi niezależnymi zmiennymi losowymi o średniej zero, wówczas dla  $s > 0$ ,

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \leq \exp\left(-\frac{s^2}{2\sigma^2 + 2as/3}\right),$$

gdzie  $\sigma^2 = \text{Var}(\sum_{i=1}^n X_i) = \sum_{i=1}^n \mathbf{E}X_i^2$  oraz  $a = \max_i \|X_i\|_\infty$ .

**Dowód.** Mamy dla  $k \geq 2$ ,

$$\mathbf{E}|X_i|^k \leq a^{k-2} \mathbf{E}X_i^2 \leq \frac{k!}{2} \left(\frac{a}{3}\right)^{k-2} \mathbf{E}X_i^2,$$

zatem warunek (6) jest spełniony z  $M = a/3$  oraz  $\sigma_i = \mathbf{E}X_i^2$ .  $\square$

**Uwaga 2.4** Nierówność Bernsteina pokazuje, iż jeśli  $s \max_i \|X_i\|_\infty \leq 3\varepsilon \sum_i \mathbf{E}X_i^2$ , to

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \leq \exp\left(-\frac{s^2}{2(1+\varepsilon)\sigma^2}\right).$$

Kolejny wynik pokazuje jak odwrócić szacowanie z powyższej uwagi.

**Twierdzenie 2.7** (Odrotna nierówność wykładnicza Kołmogorowa). Dla  $\varepsilon > 0$  istnieją stałe  $K(\varepsilon)$  i  $\delta(\varepsilon)$  takie, że dla ograniczonych niezależnych zmiennych losowych  $X_i$  o średniej zero oraz  $\sigma^2 = \text{Var}(\sum_{i=1}^n X_i)$ ,

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \geq \exp\left(-\frac{s^2}{2\sigma^2}\right),$$

o ile

$$s \max_i \|X_i\|_\infty \leq \delta(\varepsilon)\sigma^2 \text{ oraz } s \geq K(\varepsilon)\sigma.$$

**Dowód.** Ustalmy  $\varepsilon > 0$  i niech  $u = u(\varepsilon)$  będzie taką liczbą dodatnią dla której

$$1 - \Phi(u) \geq 2\exp(-\sqrt{1+\varepsilon}u^2/2).$$

Wybranie  $u$  jest możliwe na podstawie np. oszacowań Faktu 1.1.

Krok I. Istnieje stała  $\gamma = \gamma(\varepsilon)$  taka, że jeśli ograniczone niezależne zmienne losowe  $X_i$  o średniej zero spełniają

$$\max_{i \leq k} \|X_i\|_\infty \leq \gamma(\varepsilon) \left(\sum_{i=1}^k \mathbf{E}X_i^2\right)^{1/2},$$

to

$$\mathbf{P}\left(\sum_{i=1}^k X_i \geq u \left(\sum_{i=1}^k \mathbf{E}X_i^2\right)^{1/2}\right) \geq \frac{1}{2}(1 - \Phi(u)) \geq \exp\left(-\sqrt{1+\varepsilon}\frac{u^2}{2}\right).$$

Oczywiście wystarczy rozpatrywać przypadek  $\sum_{i=1}^k \mathbf{E}X_i^2 = 1$ . Załóżmy, że takie  $\gamma$  nie istnieje. Wówczas dla każdego  $n$  istnieją niezależne zmienne losowe  $X_{n,1}, X_{n,2}, \dots, X_{n,k_n}$  o średniej zero takie, że  $\|X_{n,i}\|_\infty \leq n^{-1}$ ,  $\sum_{i=1}^{k_n} \mathbf{E}X_{n,i}^2 = 1$  oraz

$$\mathbf{P}\left(\sum_{i=1}^{k_n} X_{n,i} \geq u\right) < \frac{1}{2}(1 - \Phi(u)).$$

Łatwo sprawdzić, że układ trójkątny  $(X_{n,i})_{n,i}$  spełnia warunek Lindeberga, więc na mocy centralnego twierdzenia granicznego,

$$\lim_{n \rightarrow \infty} \mathbf{P}\left(\sum_{i=1}^{k_n} X_{n,i} \geq u\right) = 1 - \Phi(u),$$

co daje sprzeczność z poprzednią nierównością. Zatem teza Kroku I została wykazana.

Krok II. Dowód twierdzenia. Bez straty ogólności możemy zakładać, że  $\sum_{i=1}^n \mathbf{E}X_i^2 = 1$ . Zdefiniujmy  $n_0 = 0$  oraz indukcyjnie

$$n_j := \inf \left\{ m : \sum_{i=n_{j-1}+1}^m \mathbf{E}X_i^2 \geq \frac{u^2}{s^2\sqrt{1+\varepsilon}} \right\}.$$

Konstrukcje przerywamy na takim  $n_k$  dla którego

$$\sum_{i=n_k+1}^n \mathbf{E}X_i^2 < \frac{u^2}{s^2\sqrt{1+\varepsilon}},$$

wtedy oczywiście  $k \leq u^{-2}s^2\sqrt{1+\varepsilon}$ . Określmy

$$S_j := \sum_{i=n_{j-1}+1}^{n_j} X_i \text{ dla } j = 1, \dots, k-1$$

oraz

$$S_k := \sum_{i=n_{k-1}+1}^n X_i.$$

Wówczas  $S_1 + \dots + S_k = \sum_{i=1}^n X_i$  oraz  $\text{Var}(S_j) \geq u^2/(s^2\sqrt{1+\varepsilon})$ . Ponadto

$$\max_i \|X_i\|_\infty \leq s^{-1}\delta(\varepsilon) \leq \gamma(\text{Var}(S_j))^{1/2},$$

jeśli  $\delta(\varepsilon) \leq u\gamma(1+\varepsilon)^{-1/4}$ . Zatem na mocy kroku I,

$$\mathbf{P}\left(S_j \geq \frac{u^2}{s^4\sqrt{1+\varepsilon}}\right) \geq \mathbf{P}\left(S_j \geq u(\text{Var}(S_j))^{1/2}\right) \geq \exp\left(-\sqrt{1+\varepsilon}\frac{u^2}{2}\right).$$

oraz

$$\begin{aligned} \mathbf{P}\left(S \geq k \frac{u^2}{t^4\sqrt{1+\varepsilon}}\right) &\geq \prod_{j=1}^k \mathbf{P}\left(S_j \geq \frac{u^2}{s^4\sqrt{1+\varepsilon}}\right) \geq \exp\left(-k\sqrt{1+\varepsilon}\frac{u^2}{2}\right) \\ &\geq \exp(-(1+\varepsilon)s^2/2). \end{aligned}$$

Oszacujmy  $k$  z dołu. Mamy dla  $j = 1, \dots, k$ ,

$$\sum_{i=n_j-1}^{n_j} \mathbf{E}X_i^2 \leq \frac{u^2}{s^2\sqrt{1+\varepsilon}} + \mathbf{E}X_{n_j}^2 \leq \frac{1}{s^2} \left( \frac{u^2}{\sqrt{1+\varepsilon}} + \delta^2(\varepsilon) \right),$$

co daje

$$1 = \sum_{i=1}^n \mathbf{E}X_i^2 \leq \frac{k}{s^2} \left( \frac{u^2}{\sqrt{1+\varepsilon}} + \delta^2(\varepsilon) \right) + \frac{u^2}{s^2\sqrt{1+\varepsilon}},$$

czyli

$$k \geq \frac{s^2\sqrt{1+\varepsilon} - u^2}{u^2 + \sqrt{1+\varepsilon}\delta^2(\varepsilon)} \geq \frac{s^2}{u^2} \sqrt[4]{1+\varepsilon},$$

o ile  $\delta(\varepsilon)$  jest odpowiednio małe, a  $K(\varepsilon)$  odpowiednio duże. I wtedy

$$\mathbf{P}(S \geq s) \geq \mathbf{P}\left(S \geq k \frac{u^2}{t\sqrt[4]{1+\varepsilon}}\right) \geq \exp\left(- (1+\varepsilon) \frac{s^2}{2}\right).$$

□

**Uwaga 2.5** Nierówność z powyższego twierdzenia można też równoważnie sformułować jako

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \geq \frac{1}{K(\varepsilon)} \exp\left(- (1+\varepsilon) \frac{s^2}{2\sigma^2}\right),$$

o ile

$$\max(s, \sigma) \max_i \|X_i\|_\infty \leq \tilde{\delta}(\varepsilon)\sigma^2.$$

### 2.3 Nierówność Bennetta

Szacowanie podane we Wniosku 2.6 jest z uwagi na centralne twierdzenie graniczne bliskie optymalnego dla  $s$  małych. Jednak dla  $s$  dużych można je poprawić o czynnik logarytmiczny.

**Lemat 2.8.** Załóżmy, że  $X$  jest zmienną losową o średniej zero, wariancji  $\sigma^2$  oraz  $\|X_i\|_\infty \leq a$ . Wówczas

$$\Lambda_X(t) \leq \frac{\sigma^2}{a^2} (e^{ta} - ta - 1).$$

**Dowód.** Liczymy

$$\mathbf{E}e^{tX} = 1 + t\mathbf{E}X + \sum_{k=2}^{\infty} \frac{t^k \mathbf{E}X^k}{k!} \leq 1 + \sigma^2 \sum_{k=2}^{\infty} \frac{t^k a^{k-2}}{k!} = 1 + \frac{\sigma^2}{a^2} (e^{ta} - ta - 1)$$

i teza wynika łatwo z nierówności  $\ln(1+x) \leq x$ . □

**Twierdzenie 2.9** (nierówność Bennetta). *Załóżmy, że  $X_i$  są ograniczonymi niezależnymi zmiennymi losowymi o średniej zero,  $\sigma^2 = \text{Var}(\sum_{i=1}^n X_i) = \sum_{i=1}^n \mathbf{E}X_i^2$  oraz  $a \geq \max_i \|X_i\|_\infty$ . Wówczas dla  $t > 0$ ,*

$$\mathbf{E} \exp\left(t \sum_{i=1}^n X_i\right) \leq \exp\left(\frac{\sigma^2}{a^2}(e^{ta} - ta - 1)\right)$$

oraz dla  $s > 0$ ,

$$\mathbf{P}\left(\sum_{i=1}^n X_i \geq s\right) \leq \exp\left(-\frac{\sigma^2}{a^2}h\left(\frac{sa}{\sigma^2}\right)\right) \leq \exp\left(-\frac{s}{2a} \ln\left(1 + \frac{sa}{\sigma^2}\right)\right),$$

gdzie

$$h(x) := (1+x)\ln(1+x) - x.$$

**Dowód.** Pierwsza część wyniku natychmiast z Lematu 2.8. By pokazać drugą zauważamy, że dla  $S = \sum_{i=1}^n X_i$ ,

$$\mathbf{P}(S \geq s) \leq \exp\left(-\sup_{t>0} \Lambda_S(t) - ts\right) \leq \exp\left(-\sup_{t>0} \left(st - \frac{\sigma^2}{a^2}(e^{ta} - ta - 1)\right)\right).$$

Prosty rachunek pokazuje, że powyższe supremum jest osiągnięte w punkcie

$$t = \frac{1}{a} \ln\left(1 + \frac{as}{\sigma^2}\right)$$

i wynosi

$$\frac{\sigma^2}{a^2} \left[ \left(1 + \frac{sa}{\sigma^2}\right) \ln\left(1 + \frac{sa}{\sigma^2}\right) - \frac{sM}{\sigma^2} \right] = \frac{\sigma^2}{a^2} h\left(\frac{sa}{\sigma^2}\right) \geq \frac{s}{2a} \ln\left(1 + \frac{sa}{\sigma^2}\right),$$

gdzie ostatnie oszacowanie wynika z poniższego lematu.  $\square$

**Lemat 2.10.** *Dla dowolnego  $x \geq 0$ ,*

$$(1+x)\ln(1+x) - x \geq \frac{x}{2} \ln(1+x).$$

**Dowód.** Niech  $f(x) = (1+x)\ln(1+x) - x - (x/2)\ln(1+x) = (1+x/2)\ln(1+x) - x$ . Liczymy  $f'(x) = (\ln(1+x) - x(1+x)^{-1})/2$ ,  $f''(x) = x(1+x)^{-2}$ , zatem  $f(0) = f'(0) = 0$  oraz  $f''(x) \geq 0$  dla  $x \geq 0$ .  $\square$

**Uwaga 2.6** Jeśli  $\mathbf{P}(X_{n,i} = 1) = 1 - \mathbf{P}(X_{n,i}) = 1/n$  oraz  $X_{n,i}$  są niezależne, to rozkład  $\sum_{i=1}^n X_{i,n}$  zbiega do rozkładu Poissona z parametrem 1. Oczywiście  $\sum_{i=1}^n \mathbf{E}X_{i,n}^2 = 1 = \max_i \|X_{i,n}\|_\infty$ . To pokazuje, że przy założeniach Twierdzenia 2.9 nie można uzyskać przy  $s \rightarrow \infty$  oszacowania lepszego rzędu niż  $s \ln s$ .

### 3 Nierówności maksymalne

W tym rozdziale będziemy zakładać, że  $(F, \|\cdot\|)$  jest ośrodkową przestrzenią Banacha, a  $X_i$  wektorami losowymi o wartościach w  $F$ . Tradycyjnie definiujemy

$$S_n := \sum_{i=1}^n X_i.$$

Przy dowodzeniu twierdzeń granicznych przydają się nierówności pozwalające szacować  $\max_k \|S_k\|$  przez pojedynczą zmienną  $S_k$ .

#### 3.1 Nierówności Levy'ego i Levy'ego-Octavianiego

**Twierdzenie 3.1** (Nierówność Levy'ego). *Załóżmy, że  $X_i$  są niezależnymi symetrycznymi wektorami losowymi w  $F$ . Wówczas dla  $s > 0$ ,*

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| \geq s\right) \leq 2\mathbf{P}(\|S_n\| \geq s).$$

**Dowód.** Niech

$$A_k := \{\|S_1\| < s, \dots, \|S_{k-1}\| < s, \|S_k\| \geq s\}.$$

Zauważmy, że dla dowolnych  $x, y \in F$ ,

$$\max(\|x + y\|, \|x - y\|) \geq \frac{1}{2}\|x + y\| + \frac{1}{2}\|x - y\| \geq \|x\|,$$

zatem

$$A_k \subset (A_k \cap \{\|S_k + (S_n - S_k)\| \geq s\}) \cup (A_k \cap \{\|S_k - (S_n - S_k)\| \geq s\}).$$

Łączny rozkład zmiennych  $(S_1, S_2, \dots, S_k, S_n - S_k)$  jest taki sam jak łączny rozkład  $(S_1, S_2, \dots, S_k, -(S_n - S_k))$ , więc oba zbiory po prawej stronie powyższej inkluzji mają jednakowe prawdopodobieństwo, zatem

$$\mathbf{P}(A_k) \leq 2\mathbf{P}(A_k \cap \{\|S_n\| \geq s\}),$$

czyli

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| \geq s\right) = \sum_{k=1}^n \mathbf{P}(A_k) \leq 2 \sum_{k=1}^n \mathbf{P}(A_k \cap \{\|S_n\| \geq s\}) \leq 2\mathbf{P}(\|S_n\| \geq s).$$

□

**Wniosek 3.2.** *Załóżmy, że zmienne  $X_i$  są niezależne i symetryczne oraz  $|a_i| \leq 1$ . Wówczas*

$$\mathbf{P}\left(\left\|\sum_{i=1}^n a_i X_i\right\| > t\right) \leq 2\mathbf{P}(\|S_n\| > t).$$

**Dowód.** Możemy zakładać, że  $a_1 \geq a_2 \geq \dots \geq a_n \geq 0$ , wówczas

$$\sum_{i=1}^n a_i X_i = a_n S_n + \sum_{k=1}^{n-1} (a_k - a_{k+1}) S_k,$$

czyli  $\|\sum_{i=1}^n a_i X_i\| \leq \max_{1 \leq k \leq n} \|S_k\|$  i teza wniosku wynika z nierówności Levy'ego.  $\square$

**Uwaga 3.7** Jeśli założenia Wniosku 3.2 są spełnione, to dla dowolnej funkcji wypukłej  $f: F \rightarrow \mathbb{R}_+$ ,

$$\mathbf{E}F\left(\sum_{i=1}^n a_i X_i\right) \leq \mathbf{E}F\left(\sum_{i=1}^n X_i\right),$$

w szczególności  $\|\sum_{i=1}^n a_i X_i\|_p \leq \|\sum_{i=1}^n X_i\|_p$ . Nie jest jednak prawdą, że nierówność z Wniosku 3.2 zachodzi ze stałą 1.

Przejdźmy teraz do przypadku niesymetrycznego.

**Lemat 3.3.** Dla dowolnych niezależnych zmiennych losowych  $X_i$  oraz  $u, t > 0$ ,

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| \geq t + u\right) \leq \frac{\mathbf{P}(\|S_n\| \geq u)}{1 - \max_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| \geq t)}, \quad (7)$$

o ile  $\mathbf{P}(\|S_n - S_k\| \geq t) < 1$  dla  $1 \leq k \leq n$ .

**Dowód.** Zdefiniujmy

$$A_k := \{\|S_1\| < t + u, \dots, \|S_{k-1}\| < t + u, \|S_k\| \geq t + u\}$$

zbiory  $A_k$  są parami rozłączne oraz

$$A := \bigcup_{k=1}^n A_k = \left\{ \max_{1 \leq k \leq n} \|S_k\| \geq t + u \right\}.$$

Zauważmy, że  $\|S_n\| \geq \|S_k\| - \|S_n - S_k\|$ , zatem wykorzystując założenie o niezależności,

$$\mathbf{P}(\|S_n - S_k\| < t) \mathbf{P}(A_k) = \mathbf{P}(A_k \cap \{\|S_n - S_k\| < t\}) \leq \mathbf{P}(A_k \cap \{\|S_n\| \geq u\}).$$

Otrzymujemy

$$\begin{aligned} \min_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| < t) \mathbf{P}(A) &\leq \sum_{k=1}^n \mathbf{P}(\|S_n - S_k\| < t) \mathbf{P}(A_k) \\ &\leq \sum_{k=1}^n \mathbf{P}(A_k \cap \{\|S_n\| \geq u\}) \leq \mathbf{P}(\|S_n\| \geq u), \end{aligned}$$

co po podzieleniu stronami przez  $\min_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| < t) = 1 - \max_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| \geq t)$  daje tezę lematu.  $\square$

**Twierdzenie 3.4** (Nierówność Levy'ego-Octavianiego). . Załóżmy, że  $X_i$  są niezależnymi wektorami losowymi w  $F$ . Wówczas dla  $s > 0$ ,

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| \geq s\right) \leq 3 \max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| \geq s/3). \quad (8)$$

**Dowód.** Szacujemy

$$\mathbf{P}(\|S_n - S_k\| \geq t) \leq \mathbf{P}(\|S_n\| \geq t/2) + \mathbf{P}(\|S_k\| \geq t/2) \leq 2 \max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| \geq t/2),$$

zatem

$$\max_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| < t) \leq 2 \max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| \geq t/2).$$

Oczywiście by udowodnić (8) możemy założyć, że  $\max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| \geq s/3) < 1/3$ . Kładąc  $u = s/3$  oraz  $t = 2s/3$  w (7) dostajemy

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| \geq s\right) \leq \frac{\mathbf{P}(\|S_n\| \geq s/3)}{1 - 2 \max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| \geq s/3)} \leq 3\mathbf{P}(\|S_n\| \geq s/3).$$

□

### 3.2 Nierówności dla sum zmiennych o jednakowym rozkładzie

W tym paragrafie będziemy dodatkowo zakładać, że

$$\text{Niezależne zmienne } X_i \text{ o wartościach w } F \text{ mają jednakowy rozkład.} \quad (9)$$

Dla wektora losowego  $X$  o wartościach w  $F$  i  $s > 0$  okreśmy

$$A(X, s) = \inf_{x \in F} \mathbf{P}(\|X - x\| > s).$$

**Lemat 3.5.** Jeśli  $X$  i  $Y$  są niezależne, to

$$A(X + Y, s) \geq A(X, s) \text{ dla } s > 0.$$

**Dowód.** Dla dowolnego  $x \in F$  dostajemy

$$\mathbf{P}(\|X + Y - x\| > s) = \mathbf{E}_Y \mathbf{P}_X(\|X + Y - x\| > s) \geq \mathbf{E}_Y A(X, s) = A(X, s).$$

□

**Lemat 3.6.** Załóżmy, że zachodzi (9) oraz  $\mathbf{P}(\|S_n\| > s/5) < 1/4$ . Wówczas

$$\max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| > s) \leq \mathbf{P}(\|S_n\| > s/5).$$

**Dowód.** Ustalmy liczbę  $\alpha$  taką, że  $1/4 > \alpha > \mathbf{P}(\|S_n\| > s/5)$ . Wówczas oczywiście  $A(S_n, s/5) < \alpha$ , czyli na mocy Lematu 3.5,  $A(S_k, s/5) < \alpha$  dla  $k = 1, \dots, n$ . Możemy zatem wybrać  $x_1, \dots, x_{n-1} \in F$  dla których

$$\mathbf{P}(\|S_k - x_k\| > s/5) \leq \alpha, \quad k = 1, \dots, n-1.$$

Wybermy  $i \leq n-1$  takie, że  $\|x_i\| = \max_{1 \leq j \leq n-1} \|x_j\|$ . Wiemy, że  $\mathbf{P}(\|S_i - x_i\| > s/5) \leq \alpha$  oraz  $\mathbf{P}(\|S_n\| > s/5) \leq \alpha$ , stąd

$$\mathbf{P}(\|S_{n-i} + x_i\| > 2s/5) = \mathbf{P}(\|S_n - (S_i - x_i)\| > 2s/5) \leq 2\alpha.$$

Rozpatrzmy trzy przypadki.

i)  $i = n - i$ . Mamy

$$\mathbf{P}(\{\|S_i - x_i\| > s/5\} \cup \{\|S_{n-i} + x_i\| > 2s/5\}) < 3\alpha < 1,$$

więc istnieje zdarzenie elementarne  $\omega$  dla którego  $\|S_i(\omega) - x_i\| \leq s/5$  oraz  $\|S_{n-i}(\omega) + x_i\| = \|S_i(\omega) + x_i\| \leq 2s/5$ . Na mocy nierówności trójkąta dostajemy  $\|2x_i\| \leq 3s/5$ .

ii)  $i > n - i$ . Mamy

$$\begin{aligned} \mathbf{P}(\|S_{2i-n} - 2x_i\| > 3s/5) &= \mathbf{P}(\|(S_i - x_i) - (S_i - S_{2i-n} + x_i)\| > 3s/5) \\ &\leq \mathbf{P}(\|S_i - x_i\| > s/5) + \mathbf{P}(\|S_i - S_{2i-n} + x_i\| > 2s/5) \\ &\leq \alpha + \mathbf{P}(\|S_{n-i} + x_i\| > 2s/5) \leq 3\alpha. \end{aligned}$$

Zatem

$$\mathbf{P}(\{\|S_{2i-n} - 2x_i\| > 3s/5\} \cup \{\|S_{2i-n} - x_{2i-n}\| > 2s/5\}) < 4\alpha < 1,$$

czyli istnieje  $\omega$  takie, że  $\|S_{2i-n}(\omega) - 2x_i\| \leq 3s/5$  and  $\|S_{2i-n}(\omega) - x_{2i-n}\| \leq s/5$ . Zatem  $\|x_{2i-n} - 2x_i\| \leq 4s/5$ . Stąd  $\|x_i\| \geq \|x_{2i-n}\| \geq 2\|x_i\| - 4s/5$ , czyli w tym przypadku  $\|x_i\| \leq 4s/5$ .

iii)  $i < n - i$ . Dostajemy

$$\begin{aligned} \mathbf{P}(\|S_{n-2i} + 2x_i\| > 3s/5) &= \mathbf{P}(\|(S_{n-i} + x_i) - (S_{n-i} - S_{n-2i} - x_i)\| > 3s/5) \\ &\leq \mathbf{P}(\|S_{n-i} + x_i\| > 2s/5) + \mathbf{P}(\|S_{n-i} - S_{n-2i} - x_i\| > s/5) \\ &\leq 2\alpha + \mathbf{P}(\|S_i - x_i\| > s/5) \leq 3\alpha. \end{aligned}$$

Tak samo jak w poprzednim przypadku pokazujemy, że  $\|x_{n-2i} + 2x_i\| \leq 4s/5$  oraz  $\|x_i\| \leq 4s/5$ .

Udowodniliśmy zatem, że  $\max_{1 \leq j \leq n-1} \|x_j\| \leq 4s/5$ , stąd

$$\max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| > s) \leq \max_{1 \leq k \leq n} \mathbf{P}(\|S_k - x_k\| > s/5) \leq \alpha,$$

co z dowolności  $\alpha \in (\mathbf{P}(\|S_n\| > s/5), 1/4)$  dowodzi tezy.  $\square$

**Twierdzenie 3.7.** Przy założeniu (9),

$$\mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| > s\right) \leq 4\mathbf{P}(\|S_n\| > s/6).$$



**Dowód.** Oczywiście możemy zakładać, że  $\mathbf{P}(\|S_n\| > s/6) < 1/4$ . Wówczas na mocy Lematu 3.6,  $\max_{1 \leq k \leq n} \mathbf{P}(\|S_k\| > 5s/6) \leq \mathbf{P}(\|S_n\| > s/6) < 1/4$ . Z nierówności (7) (z  $t = 5s/6, u = s/6$ ),

$$\begin{aligned} \mathbf{P}\left(\max_{1 \leq k \leq n} \|S_k\| > s\right) &\leq \frac{\mathbf{P}(\|S_n\| > s/6)}{1 - \max_{1 \leq k \leq n} \mathbf{P}(\|S_n - S_k\| > 5s/6)} \\ &= \frac{\mathbf{P}(\|S_n\| > s/6)}{1 - \max_{1 \leq k \leq n} \mathbf{P}(\|S_{n-k}\| > 5s/6)} \leq \frac{4}{3} \mathbf{P}(\|S_n\| > s/6). \end{aligned}$$

□

**Wniosek 3.8.** Załóżmy, że zachodzi (9) oraz  $0 \leq a_i \leq 1$ . Wówczas

$$\mathbf{P}\left(\left\|\sum_{i=1}^n a_i X_i\right\| > s\right) \leq 4\mathbf{P}(\|S_n\| > s/6).$$

**Dowód.** Możemy zakładać, że  $a_1 \geq a_2 \geq \dots \geq a_n$  i wtedy tak jak we Wniosku 3.2 dostajemy  $\|\sum_{i=1}^n a_i X_i\| \leq \max_{1 \leq k \leq n} \|S_k\|$ . □

## 4 Mocne prawa wielkich liczb

Będziemy zakładali, że  $X, X_1, X_2, \dots$  są niezależnymi zmiennymi losowymi o wartościach w ośrodkowej przestrzeni Banacha  $(F, \|\cdot\|)$ .

### 4.1 Prawo Wielkich Liczb Kołmogorowa

Okazuje się, że przeniesienie tradycyjnego sformułowania mocnego prawa wielkich na przypadek przestrzeni Banacha jest łatwe. Dzieje się tak dzięki następującemu lematowi.

**Lemat 4.1.** *Jeśli  $X$  jest zmienną losową o wartościach w ośrodkowej przestrzeni Banacha taką, że  $\mathbf{E}\|X\| < \infty$ . Wówczas dla dowolnego  $\varepsilon > 0$  istnieje funkcja  $\varphi: F \rightarrow F$  przyjmująca tylko skończenie wiele wartości taka, że  $\mathbf{E}\|X - \varphi(X)\| \leq \varepsilon$ .*

**Dowód.** Proste ćwiczenie. □

**Twierdzenie 4.2.** *Załóżmy, że  $F$  jest dowolną ośrodkową przestrzenią Banacha oraz  $\mathbf{E}\|X\| < \infty$ . Wówczas  $\lim_{n \rightarrow \infty} \frac{S_n}{n} = \mathbf{E}X$  p.n..*

**Dowód.** Zauważmy, że twierdzenie zachodzi dla  $F = \mathbb{R}$ , a więc również dla  $F = \mathbb{R}^k$ . Stąd łatwo pokazujemy tezę dla zmiennych przyjmujących wartości w pewnej skończonej wymiarowej podprzestrzeni  $F$ .

Oczywiście możemy zakładać, że  $\mathbf{E}X = 0$ . Niech  $\varepsilon > 0$ , wówczas na mocy Lematu 4.1 istnieją niezależne zmienne losowe o jednakowym rozkładzie  $Y_i =$

$\varphi(X_i)$  przyjmujące tylko skończenie wiele wartości spełniające  $\mathbf{E}\|X_i - Y_i\| \leq \varepsilon$ . Niech  $T_n := Y_1 + \dots + Y_n$ , wówczas

$$\begin{aligned} \limsup_{n \rightarrow \infty} \frac{\|S_n\|}{n} &\leq \limsup_{n \rightarrow \infty} \frac{\|T_n\|}{n} + \limsup_{n \rightarrow \infty} \frac{\sum_{i=1}^n \|X_i - Y_i\|}{n} = \|\mathbf{E}Y\| + \mathbf{E}\|X - Y\| \\ &\leq \|\mathbf{E}X\| + 2\mathbf{E}\|X - Y\| \leq 2\varepsilon. \end{aligned}$$

Z dowolności  $\varepsilon > 0$  dostajemy tezę.  $\square$

## 4.2 Prawo Wielkich Liczb Marcinkiewicza-Zygmunda

Okazuje się, że dla regularnych przestrzeni Banacha tradycyjne prawo wielkich liczb da się uogólnić. Zaczniemy od dwóch prostych lematów.

**Lemat 4.3.** *Jeśli  $\mathbf{E}\|X\|^p = \infty$ , to  $\limsup_{n \rightarrow \infty} \frac{\|S_n\|}{n^{1/p}} = \infty$  p.n..*

**Dowód.** Niech

$$A := \left\{ \omega : \limsup_{n \rightarrow \infty} \frac{\|S_n(\omega)\|}{n^{1/p}} < \infty \right\}.$$

Dla  $\omega \in A$ , dostajemy  $\|X_n(\omega)\| \leq \|S_n(\omega)\| + \|S_{n-1}(\omega)\| \leq C(\omega)n^{1/p}$  dla pewnego  $C(\omega) < \infty$ . Zatem  $A \subset \bigcup_{k=1}^{\infty} A_k$ , gdzie

$$A_k := \{ \|X_n\| \leq kn^{1/p} \text{ dla } n = 1, 2, \dots \}.$$

Jeśli  $\mathbf{P}(A_k) > 0$ , to  $\mathbf{P}(\limsup\{\|X_n\| > kn^{1/p}\}) < 1$ , czyli na mocy Lematu Borela-Cantelliego,

$$\infty > \sum_{n=1}^{\infty} \mathbf{P}(\|X_n\| > kn^{1/p}) = \sum_{n=1}^{\infty} \mathbf{P}\left(\frac{\|X\|^p}{k^p} > n\right) \geq \mathbf{E}\frac{\|X\|^p}{k^p} - 1.$$

Zatem  $\mathbf{P}(A_k) = 0$  dla wszystkich  $k$ , czyli  $\mathbf{P}(A) = 0$ .  $\square$

**Lemat 4.4.** *Załóżmy, że ciąg normujący  $(\gamma_n)_{n \geq 1}$  liczb dodatnich spełnia warunki*

$$\gamma_{2l} \leq C\gamma_k \text{ dla } l < k \leq 2l.$$

*Wówczas, jeśli*

$$\sum_{n=1}^{\infty} \mathbf{P}(\|S_{2^n}\| \geq \varepsilon\gamma_{2^n}) < \infty \text{ dla wszystkich } \varepsilon > 0,$$

*to  $\lim_{n \rightarrow \infty} \frac{S_n}{\gamma_n} = 0$  p.n..*

**Dowód.** Szacujemy dla  $\varepsilon > 0$ ,

$$\begin{aligned} \mathbf{P}\left(\sup_{m > 2^{k-1}} \frac{\|S_m\|}{\gamma_m} \geq \varepsilon\right) &\leq \sum_{n=k}^{\infty} \mathbf{P}\left(\sup_{2^{n-1} < m \leq 2^n} \|S_m\| \geq C^{-1}\varepsilon\gamma_{2^n}\right) \\ &\leq \sum_{n=k}^{\infty} 4\mathbf{P}(\|S_{2^n}\| \geq C^{-1}\varepsilon\gamma_{2^n}/6) \rightarrow 0 \text{ przy } k \rightarrow \infty, \end{aligned}$$

gdzie ostatnia nierówność wynika z Twierdzenia 3.7.  $\square$

**Twierdzenie 4.5** (Prawo wielkich liczb Marcinkiewicza-Zygmunda). *Załóżmy, że  $F$  jest ośrodkową przestrzenią Hilberta oraz  $0 < p < 2$ . Wówczas następujące warunki są równoważne.*

- i)  $\lim_{n \rightarrow \infty} \frac{S_n}{n^{1/p}} = 0$  p.n.  
ii)  $\mathbf{E}\|X\|^p < \infty$  oraz jeśli  $p \geq 1$ , to  $\mathbf{E}X = 0$ .

**Dowód.** ii)  $\Rightarrow$  i). Wpierw udowodnimy, że warunek ii) implikuje

$$\lim_{n \rightarrow \infty} n^{1-1/p} \mathbf{E}[X I_{\{\|X\| \leq n^{1/p}\}}] = 0. \quad (10)$$

Dla  $p \geq 1$ , wobec  $\mathbf{E}X = 0$  szacujemy

$$\begin{aligned} n^{1-1/p} \|\mathbf{E}[X I_{\{\|X\| \leq n^{1/p}\}}]\| &= n^{1-1/p} \|\mathbf{E}X I_{\{\|X\| > n^{1/p}\}}\| \\ &\leq \mathbf{E}[\|X\| (n^{1/p})^{p-1} I_{\{\|X\| > n^{1/p}\}}] \\ &\leq \mathbf{E}[\|X\|^p I_{\{\|X\| > n^{1/p}\}}] \rightarrow 0 \text{ przy } n \rightarrow \infty, \end{aligned}$$

na mocy skończoności  $\mathbf{E}\|X\|^p$ . Dla  $0 < p < 1$  dostajemy dla dowolnego  $m$ ,

$$\begin{aligned} n^{1-1/p} \|\mathbf{E}[\|X\| I_{\{\|X\| \leq n^{1/p}\}}]\| &\leq n^{1-1/p} \mathbf{E}[\|X\| I_{\{\|X\| \leq m\}}] + \mathbf{E}[\|X\| (n^{1/p})^{p-1} I_{\{m < \|X\| \leq n^{1/p}\}}] \\ &\leq n^{1-1/p} \mathbf{E}[\|X\| I_{\{\|X\| \leq m\}}] + \mathbf{E}[\|X\|^p I_{\{\|X\| > m\}}] =: I + II. \end{aligned}$$

Składnik  $II$  można zrobić dowolnie małym dobierając odpowiednio duże  $m$ , zaś przy ustalonym  $m$ , składnik  $I$  dąży do zera przy  $n$  dążącym do nieskończoności. Czyli (10) zostało wykazane.

Na mocy Lematu 4.4 by wykazać i) wystarczy, iż wykażemy, że dla  $\varepsilon > 0$ ,  $\sum_n \mathbf{P}(\|S_{2^n}\| \geq 2\varepsilon 2^{n/p}) < \infty$ . Z (10) wynika, że  $2^n \mathbf{E}[X I_{\{\|X\| \leq 2^{n/p}\}}] \leq \varepsilon 2^{n/p}$  dla dużych  $n$ , więc wystarczy, iż udowodnimy, że

$$\sum_n \mathbf{P}(\|S_{2^n} - 2^n \mathbf{E}[X I_{\{\|X\| \leq 2^{n/p}\}}]\| \geq \varepsilon 2^{n/p}) < \infty.$$

Określmy

$$\tilde{S}_{2^n} := \sum_{i=1}^{2^n} X_i I_{\{\|X_i\| \leq 2^{n/p}\}},$$

wówczas

$$\begin{aligned} \mathbf{P}(\|S_{2^n} - 2^n \mathbf{E}[X I_{\{\|X\| \leq 2^{n/p}\}}]\| \geq \varepsilon 2^{n/p}) &\leq \mathbf{P}(\tilde{S}_{2^n} \neq S_{2^n}) + \mathbf{P}(\|\tilde{S}_{2^n} - \mathbf{E}\tilde{S}_{2^n}\| \geq \varepsilon 2^{n/p}) \\ &\leq 2^n \mathbf{P}(\|X\| > 2^{n/p}) + \varepsilon^{-2} 2^{-2n/p} \mathbf{E}\|\tilde{S}_{2^n} - \mathbf{E}\tilde{S}_{2^n}\|^2. \end{aligned}$$

Mamy

$$\sum_{n=1}^{\infty} 2^n \mathbf{P}(\|X\| > 2^{n/p}) = \sum_{n=1}^{\infty} 2^n \mathbf{P}(\|X\|^p > 2^n) \leq 2 \mathbf{E}\|X\|^p < \infty$$

oraz

$$\begin{aligned}
\sum_{n=1}^{\infty} 2^{-2n/p} \mathbf{E} \|\tilde{S}_{2^n} - \mathbf{E} \tilde{S}_{2^n}\|^2 &\leq \sum_{n=1}^{\infty} 2^{n(1-2/p)} \mathbf{E} \|X\|^2 I_{\{\|X\| \leq 2^{n/p}\}} \\
&= \mathbf{E} \left[ \|X\|^2 \sum_{n=1}^{\infty} 2^{n(1-2/p)} I_{\{\|X\|^p \leq 2^n\}} \right] \\
&\leq C_p \mathbf{E} [\|X\|^2 (\|X\|^p)^{1-2/p}] = C_p \mathbf{E} \|X\|^p < \infty.
\end{aligned}$$

i)  $\Rightarrow$  ii). Z Lematu 4.3, dostajemy  $\mathbf{E} \|X\|^p < \infty$ . W szczególności, gdy  $p \geq 1$ , to  $\mathbf{E} \|X\| < \infty$  i na mocy zwykłego Mocnego Prawa Wielkich Liczb (albo udowodnionej już implikacji ii)  $\Rightarrow$  i) z  $p = 1$ ),  $\frac{S_n}{n} \rightarrow \mathbf{E} X$ . Stąd  $\mathbf{E} X = 0$ .  $\square$

**Uwaga 4.8** Dla  $p \geq 2$  jeśli  $\mathbf{P}(X \neq 0) > 0$ , to  $\limsup_{n \rightarrow \infty} \frac{S_n}{n^{1/p}} = \infty$  p.n. Istotnie tak jest na mocy Lematu 4.3, jeśli  $\mathbf{E} X^2 = \infty$ . W przypadku zaś gdy  $\mathbf{E} X^2 < \infty$ , to implikacja łatwo wynika z centralnego twierdzenia granicznego.

**Uwaga 4.9** Dokładna analiza dowodu Twierdzenia 4.5 pokazuje, że implikacja i)  $\Rightarrow$  ii) zachodzi dla dowolnych ośrodkowych przestrzeni Banacha  $F$ . Jedyną własnością  $F$ , którą potrzebujemy do dowodu implikacji ii)  $\Rightarrow$  i), jest nierówność

$$\mathbf{E} \left\| \sum_{i=1}^n Z_i \right\|^2 \leq C \sum_{i=1}^n \mathbf{E} \|Z_i\|^2$$

dla niezależnych, ograniczonych zmiennych losowych  $Z_i$  o wartościach w  $F$  i średniej 0. Przestrzenie z taką własnością nazywamy przestrzeniami typu 2 (należą do nich np. przestrzenie  $L^p$ ,  $2 \leq p < \infty$ ).

### 4.3 Przypadek niejednakowych rozkładów.

W poprzednich twierdzeniach zakładaliśmy wspólny rozkład zmiennych  $X_i$ . Jest wiele sformułowań mocnego prawa wielkich liczb, które nie zakładają tego warunku - udowodnimy jedno z nich, sformułowane dla  $p = 2$  przez Kołmogorowa, a dla  $p \geq 2$  przez Brunka.

**Twierdzenie 4.6** (Mocne Prawo Wielkich Liczb Brunka). *Załóżmy, że  $p \geq 2$  oraz  $X_i$  są niezależnymi zmiennymi losowymi o średniej zero takimi, że*

$$\sum_{i=1}^{\infty} \frac{\mathbf{E} |X_i|^p}{i^{p/2+1}} < \infty.$$

*Wówczas zachodzi mocne prawo wielkich liczb, tzn  $S_n/n \rightarrow 0$  p.n..*

**Dowód.** Niech  $(X'_i)$  będzie niezależną kopią ciągu  $(X_i)$  oraz  $Y_i = X_i - X'_i$ . Ponadto przez  $(\varepsilon_i)$  oznaczmy niezależny od  $(Y_i)$  ciąg Bernoulliego, tzn. ciąg

niezależnych zmiennych losowych taki, że  $\mathbf{P}(\varepsilon_i = \pm 1) = 1/2$ . Mamy

$$\begin{aligned} \mathbf{E} \left| \sum_{i=1}^n X_i \right|^p &\leq \mathbf{E} \left| \sum_{i=1}^n X_i - \sum_{i=1}^n X'_i \right|^p = \mathbf{E} \left| \sum_{i=1}^n Y_i \right|^p = \mathbf{E}_Y \mathbf{E}_\varepsilon \left| \sum_{i=1}^n \varepsilon Y_i \right|^p \\ &\leq \mathbf{E}_Y C_p \left( \sum_{i=1}^n |Y_i|^2 \right)^{p/2} \leq C_p \mathbf{E} (n^{p/2-1} \sum_{i=1}^n |Y_i|^p) \\ &\leq 2^p C_p n^{p/2-1} \sum_{i=1}^n \mathbf{E} |Y_i|^p, \end{aligned}$$

gdzie kolejne nierówności wynikają z nierówności Jensena, nierówności Chinczy-  
na, nierówności Höldera oraz oszacowania  $\|Y_i\|_p \leq \|X_i\|_p + \|X'_i\|_p = 2\|X_i\|_p$ .  
Stąd na mocy Twierdzenia 3.4,

$$\begin{aligned} \mathbf{P} \left( \max_{1 \leq k \leq n} |S_k| \geq t \right) &\leq 3 \max_{1 \leq k \leq n} \mathbf{P}(|S_k| \geq t/3) \leq 3 \max_{1 \leq k \leq n} (t/3)^{-p} \mathbf{E} |S_k|^p \\ &\leq C'_p t^{-p} n^{p/2-1} \sum_{i=1}^n \mathbf{E} |X_i|^p, \end{aligned}$$

gdzie  $C'_p = 2^p 3^{p+1} C_p$ . Zatem

$$\begin{aligned} \mathbf{P} \left( \max_{k \geq 2^{l-1}} \frac{|S_k|}{k} \geq \varepsilon \right) &\leq \sum_{j=l}^{\infty} \mathbf{P} \left( \max_{2^{j-1} < k \leq 2^j} \frac{|S_k|}{k} \geq \varepsilon \right) \leq \sum_{j=l}^{\infty} \mathbf{P}(\max_{k \leq 2^j} |S_k| \geq 2^{j-1} \varepsilon) \\ &\leq \sum_{j=l}^{\infty} C'_p (2^{j-1} \varepsilon)^{-p} (2^j)^{p/2-1} \sum_{i=1}^{2^j} \mathbf{E} |X_i|^p \\ &= C'_p (2/\varepsilon)^p \sum_{i=1}^{\infty} \mathbf{E} |X_i|^p \sum_{j \geq l: 2^j \geq i} (2^{-j})^{p/2+1} \\ &\leq C''_p \varepsilon^{-p} \sum_{i=1}^{\infty} \frac{\mathbf{E} |X_i|^p}{\max(i, 2^l)^{p/2+1}} \rightarrow 0 \text{ przy } l \rightarrow \infty. \end{aligned}$$

□

**Uwaga 4.10** Twierdzenie Brunka (z tym samym dowodem) zachodzi też dla przestrzeni Hilberta oraz ogólniej dla przestrzeni  $F$  typu 2.

## 5 Prawo Iterowanego Logarytmu

W tej części, jeśli nie zaznaczymy inaczej, będziemy zakładać, że  $X, X_1, X_2, \dots$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie o średniej zero i wariancji  $\sigma^2$ . Jak zwykle też  $S_k = X_1 + \dots + X_k$ .

**Twierdzenie 5.1** (Prawo Iterowanego Logarytmu Hartmana i Wintnera). *Dla niezależnych zmiennych losowych o jednakowym rozkładzie ze średnią zero i wariancją  $\sigma^2$  zachodzi*

$$\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} = - \liminf_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} = \sigma \text{ p.n..}$$

Dowód twierdzenia podzielimy na szereg prostszych lematów. Dla uproszczenia notacji przyjmiemy  $\gamma(x) := \sqrt{2x \ln \ln(x \vee 10)}$ .

**Lemat 5.2.** *Dla dowolnego  $t > 0$ ,*

$$\mathbf{P}\left(\max_{1 \leq k \leq n} |S_k| \geq t + \sqrt{2}\sigma\sqrt{n}\right) \leq 2\mathbf{P}(|S_n| \geq t).$$

**Dowód.** Z lematu 3.3,

$$\mathbf{P}\left(\max_{1 \leq k \leq n} |S_k| \geq t + \sqrt{2}\sigma\sqrt{n}\right) \leq \frac{\mathbf{P}(|S_n| \geq t)}{1 - \max_{1 \leq k \leq n} \mathbf{P}(|S_n - S_k| \geq \sqrt{2}\sigma\sqrt{n})}.$$

Mamy jednak na mocy nierówności Czebyszewa,

$$\mathbf{P}(|S_n - S_k| \geq \sqrt{2}\sigma\sqrt{n}) \leq \frac{\text{Var}(S_n - S_k)}{2\sigma^2 n} = \frac{(n-k)\sigma^2}{2n\sigma^2} \leq \frac{1}{2}.$$

□

**Lemat 5.3.** *Załóżmy, że dla  $\beta > 1, a > 0$  zachodzi warunek*

$$\sum_{n=1}^{\infty} \mathbf{P}(|S_{\lfloor \beta^n \rfloor}| \geq a\gamma(\beta^n)) < \infty.$$

Wówczas  $\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq a\beta^{1/2}$  p.n..

**Dowód.** Ustalmy  $c > a\beta^{1/2}$  i oszacujmy,

$$\begin{aligned} \mathbf{P}\left(\sup_{n > \beta^{m-1}} \frac{|S_n|}{\sqrt{2n \ln \ln n}} > c\right) &\leq \sum_{k=m}^{\infty} \mathbf{P}\left(\max_{\beta^{k-1} < n \leq \beta^k} \frac{|S_n|}{\sqrt{2n \ln \ln n}} > c\right) \\ &\leq \sum_{k=m}^{\infty} \mathbf{P}\left(\max_{n \leq \beta^k} |S_n| > c\gamma(\beta^{k-1})\right). \end{aligned}$$

Zauważmy, że dla dostatecznie dużych  $k$ ,  $c\gamma(\beta^{k-1}) \geq a\gamma(\beta^k) + \sqrt{2}\sigma\beta^{k/2}$ , czyli na mocy Lematu 5.2,

$$\begin{aligned} \mathbf{P}\left(\max_{n \leq \beta^k} |S_n| > c\gamma(\beta^{k-1})\right) &\leq \mathbf{P}\left(\max_{n \leq \beta^k} |S_n| > a\gamma(\beta^k) + \sqrt{2}\sigma\beta^{k/2}\right) \\ &\leq 2\mathbf{P}(|S_{\lfloor \beta^k \rfloor}| \geq a\gamma(\beta^k)). \end{aligned}$$

Stąd,

$$\lim_{m \rightarrow \infty} \mathbf{P}\left(\sup_{n > \beta^{m-1}} \frac{|S_n|}{\sqrt{2n \ln \ln n}} > c\right) = 0$$

dla dowolnego  $c > a\beta^{1/2}$  i łatwo otrzymujemy tezę. □

**Lemat 5.4.** *Mamy*  $\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq 4\sqrt{2}\sigma$  *p.n.*

**Dowód.** Załóżmy najpierw, że zmienne  $X_i$  są symetryczne i niech  $(\varepsilon_i)$  będzie ciągiem Bernoulliego niezależnym od  $(X_i)$ . Wówczas ciąg  $(X_i)$  ma ten sam rozkład co  $(\varepsilon_i X_i)$ , zatem

$$\mathbf{P}(|S_n| \geq t) = \mathbf{P}\left(\left|\sum_{i=1}^n \varepsilon_i X_i\right| \geq t\right).$$

Z Wniosku 2.3 otrzymujemy dla  $t, \alpha > 0$ ,

$$\mathbf{P}(|S_n| \geq t) \leq \mathbf{P}\left(\sum_{i=1}^n X_i^2 \geq \alpha\right) + 2 \exp\left(-\frac{t^2}{2\alpha}\right).$$

Niech  $T_n = \sum_{i=1}^n X_i^2$ . Na mocy Silnego Prawa Wielkich Liczb  $T_n/n \rightarrow \sigma^2$  p.n., czyli również  $2^{-n}(T_{2^{n+1}} - T_{2^n}) \rightarrow \sigma^2$  p.n.. Zatem na mocy Lematu Borela-Cantelliego,

$$\infty > \sum_{n=1}^{\infty} \mathbf{P}(2^{-n}(T_{2^{n+1}} - T_{2^n}) \geq 2\sigma^2) = \sum_{n=1}^{\infty} \mathbf{P}\left(\sum_{i=1}^{2^n} X_i^2 \geq 2^{n+1}\sigma^2\right).$$

Szacujemy,

$$\begin{aligned} \mathbf{P}(|S_{2^n}| \geq a\gamma(2^n)\sigma) &\leq \mathbf{P}\left(\sum_{i=1}^{2^n} X_i^2 \geq 2^{n+1}\sigma^2\right) + 2 \exp\left(-\frac{a^2\sigma^2 2^{n+1} \ln \ln 2^n}{2^{n+2}\sigma^2}\right) \\ &\leq \mathbf{P}\left(\sum_{i=1}^{2^n} X_i^2 \geq 2^{n+1}\sigma^2\right) + 2(n \ln 2)^{-a^2/2}. \end{aligned}$$

Stąd dla symetrycznych zmiennych losowych,

$$\sum_n \mathbf{P}(|S_{2^n}| \geq 2\gamma(2^n)\sigma) < \infty. \quad (11)$$

W przypadku gdy  $X_i$  są dowolne oznaczmy przez  $(X'_i)$  niezależną kopię  $(X_i)$  oraz niech  $S'_n := \sum_{i=1}^n X'_i$ . Na mocy nierówności Czebyszewa,  $\mathbf{P}(|S'_n| > \sqrt{2n}\sigma) \leq 1/2$ , więc z niezależności,

$$\mathbf{P}(|S_n| \geq t) \leq 2\mathbf{P}(|S_n| \geq t, |S'_n| \leq \sqrt{2n}\sigma) \leq 2\mathbf{P}(|S_n - S'_n| \geq t - \sqrt{2n}\sigma).$$

Zatem dla dużych  $n$ ,

$$\mathbf{P}(|S_n| \geq 4\gamma(n)\sigma) \leq 2\mathbf{P}(|S_n - S'_n| \geq 2\sqrt{2}\gamma(n)\sigma).$$

Zauważmy, że  $S_n - S'_n = \sum_{i=1}^n Y_i$ , gdzie  $Y_i = X_i - X'_i$  są niezależnymi, symetrycznymi zmiennymi losowymi o jednakowym rozkładzie z wariancją  $2\sigma^2$ , czyli na mocy (11),

$$\sum_{n > n_0} \mathbf{P}(|S_{2^n}| \geq 4\gamma(2^n)\sigma) \leq 2 \sum_{n > n_0} \mathbf{P}|S_{2^n} - S'_{2^n}| \geq 2\gamma(2^n)\sigma_Y < \infty.$$

Możemy więc stosować Lemat 5.3 z  $a = 4$  i  $\beta = 2$ . □

**Lemat 5.5.** *Jeśli zmienne  $X_i$  są ograniczone, to  $\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \sigma$  p.n..*

**Dowód.** Załóżmy, że  $\|X\|_\infty \leq a$ , wówczas na mocy nierówności Bernsteina (Wniosek 2.6),

$$\mathbf{P}(|S_n| \geq t) \leq 2 \exp\left(-\frac{t^2}{2n\sigma^2 + 2at/3}\right).$$

Zatem dla  $\beta > 1$  i  $\varepsilon > 0$  oraz dostatecznie dużych  $n$ ,

$$\begin{aligned} \mathbf{P}(|S_{\lfloor \beta^n \rfloor}| \geq \sigma\sqrt{1+2\varepsilon}\gamma(\beta^n)) &\leq 2 \exp\left(-\frac{(1+2\varepsilon)\sigma^2\beta^n \ln \ln \beta^n}{2\lfloor \beta^n \rfloor\sigma^2 + 2a\sqrt{\beta^n \ln \ln \beta^n}/3}\right) \\ &\leq 2 \exp(-(1+\varepsilon) \ln \ln \beta^n) = (n \ln \beta)^{-1+\varepsilon}. \end{aligned}$$

Możemy więc stosować Lemat 5.3 (z  $a = \sigma\sqrt{1+2\varepsilon}$ ) i dostajemy

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \sigma\sqrt{(1+2\varepsilon)\beta} \text{ p.n. .}$$

Z dowolności  $\beta > 1$  i  $\varepsilon > 0$  wynika teza.  $\square$

**Wniosek 5.6.** *Dla dowolnych zmiennych o średniej 0 i wariancji  $\sigma^2$ ,*

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \sigma \text{ p.n.}$$

**Dowód.** Ustalmy  $M > 0$  i rozłóżmy  $X_i = Y_i + Z_i$ , gdzie

$$Y_i := X_i I_{\{|X_i| \leq M\}} - \mathbf{E}X_i I_{\{|X_i| \leq M\}}, \quad Z_i := X_i I_{\{|X_i| > M\}} - \mathbf{E}X_i I_{\{|X_i| > M\}}.$$

Określmy  $T_n := Y_1 + \dots + Y_n$ ,  $R_n := Z_1 + \dots + Z_n$ . Na mocy Lematów 5.4 i 5.5,

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \limsup_{n \rightarrow \infty} \frac{|T_n|}{\sqrt{2n \ln \ln n}} + \limsup_{n \rightarrow \infty} \frac{|R_n|}{\sqrt{2n \ln \ln n}} \leq \sigma_Y + 4\sqrt{2}\sigma_Z \text{ p.n..}$$

Mamy jednak  $\sigma_Y^2 \leq \mathbf{E}X^2 I_{\{|X| \leq M\}} \leq \mathbf{E}X^2 = \sigma^2$  oraz  $\sigma_Z^2 \leq \mathbf{E}X^2 I_{\{|X| > M\}} \rightarrow 0$  przy  $M \rightarrow \infty$ .  $\square$

**Lemat 5.7.** *Założmy, że dla liczby naturalnej  $C > 1$  oraz  $a > 0$  zachodzi*

$$\sum_n \mathbf{P}(S_{C^n - C^{n-1}} \geq a\gamma(C^n - C^{n-1})) = \infty.$$

Wówczas  $\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \geq a(1 - C^{-1})^{1/2} - \sigma C^{-1/2}$  p.n.

**Dowód.** Zmienne  $S_{C^n} - S_{C^{n-1}}$ ,  $n = 1, 2, \dots$  są niezależne oraz

$$\sum_n \mathbf{P}(S_{C^n} - S_{C^{n-1}} \geq a\gamma(C^n - C^{n-1})) = \infty.$$



Zatem na mocy Lematu Borela-Cantelliego,

$$\mathbf{P}\left(\limsup_{n \rightarrow \infty} \frac{S_{C^n} - S_{C^{n-1}}}{\gamma(C^n - C^{n-1})} \geq a\right) \geq \mathbf{P}(\limsup\{S_{C^n} - S_{C^{n-1}} \geq a\gamma(C^n - C^{n-1})\}) = 1.$$

Stąd na podstawie Wniosku 5.6,

$$\begin{aligned} \limsup_{n \rightarrow \infty} \frac{S_{C^n}}{\gamma(C^n)} &\geq \limsup_{n \rightarrow \infty} \frac{S_{C^n} - S_{C^{n-1}}}{\gamma(C^n - C^{n-1})} \lim_{n \rightarrow \infty} \frac{\gamma(C^n - C^{n-1})}{\gamma(C^n)} \\ &\quad - \limsup_{n \rightarrow \infty} \frac{S_{C^{n-1}}}{\gamma(C^{n-1})} \lim_{n \rightarrow \infty} \frac{\gamma(C^n)}{\gamma(C^{n-1})} \\ &\geq a(1 - C^{-1})^{1/2} - \sigma C^{-1/2} \text{ p.n..} \end{aligned}$$

□

**Lemat 5.8.** *Jeśli zmienne  $X_i$  są ograniczone, to  $\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \geq \sigma$  p.n..*

**Dowód.** Oszacujemy  $\mathbf{P}(S_n \geq (1+\varepsilon)^{-2}\gamma(n)\sigma)$  stosując odwrotną nierówność wykładniczą Kołmogorowa (Twierdzenie 2.7) z  $s = (1+\varepsilon)^{-2}\gamma(n)\sigma$  i  $n\sigma^2$  zamiast  $\sigma^2$ . Zauważmy, że dla dużych  $n \geq n(\varepsilon)$  jego założenia są spełnione, bo

$$s \max_i \|X_i\|_\infty \leq \|X\|_\infty \sigma \gamma(n) \leq \delta(\varepsilon) n \sigma^2$$

oraz

$$s = (1 + \varepsilon)^{-2} \gamma(n) \sigma \geq K(\varepsilon) \sqrt{n} \sigma.$$

Zatem dla  $n \geq n(\varepsilon)$ ,

$$\mathbf{P}(S_n \geq (1 + \varepsilon)^{-2} \gamma(n) \sigma) \geq \exp\left(-\frac{(1 + \varepsilon) \gamma^2(n) \sigma^2}{(1 + \varepsilon)^2 n \sigma^2}\right) = (\ln n)^{-1/(1+\varepsilon)}.$$

Zatem

$$\begin{aligned} \sum_n \mathbf{P}(S_{C^n - C^{n-1}} \geq (1 + \varepsilon)^{-2} \sigma \gamma(C^n - C^{n-1})) \\ \geq \sum_{n \geq n(\varepsilon)} (\log((C - 1)C^{n-1}))^{-1/(1+\varepsilon)} = \infty. \end{aligned}$$

Czyli, na mocy Lematu 5.7,

$$\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \geq (1 + \varepsilon)^{-2} \sigma (1 - C^{-1})^{1/2} - \sigma C^{-1/2} \text{ p.n..}$$

Biorąc  $C \rightarrow \infty$  oraz  $\varepsilon \rightarrow 0+$  dostajemy tezę. □

**Wniosek 5.9.** *Dla dowolnych zmiennych o średniej 0 i wariancji  $\sigma^2$ ,*

$$\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \geq \sigma \text{ p.n..}$$

**Dowód.** Jak w dowodzie Wniosku 5.6 dla  $M > 0$  rozkładamy  $X_i = Y_i + Z_i$  oraz  $S_n = R_n + T_n$  i szacujemy używając Lematu 5.8 w Wniosku 5.6,

$$\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \geq \limsup_{n \rightarrow \infty} \frac{T_n}{\sqrt{2n \ln \ln n}} - \limsup_{n \rightarrow \infty} \frac{-R_n}{\sqrt{2n \ln \ln n}} \geq \sigma_Y - \sigma_Z \text{ p.n..}$$

By zakończyć dowód wystarczy zauważyć, że  $\sigma_Y \rightarrow \sigma$  oraz  $\sigma_Z \rightarrow 0$  przy  $M \rightarrow \infty$ .  $\square$

**Dowód Twierdzenia 5.1.** Wnioski 5.6 i 5.9 implikują

$$\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} = \sigma \text{ p.n..}$$

Ponieważ  $-S_n = \sum_{i=1}^n (-X_i)$ , więc

$$\liminf_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} = -\limsup_{n \rightarrow \infty} \frac{-S_n}{\sqrt{2n \ln \ln n}} = -\sigma_{-X} = \sigma \text{ p.n..}$$

$\square$

**Twierdzenie 5.10.** *Załóżmy, że*

$$\mathbf{P}\left(\limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} < \infty\right) > 0,$$

wówczas  $\mathbf{E}X = 0$  oraz  $\mathbf{E}X^2 < \infty$ .

**Dowód.** Na mocy założeń istnieje  $M < \infty$  takie, że

$$\mathbf{P}\left(\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq M\right) > 0,$$

ale na mocy prawa 0-1, powyższe prawdopodobieństwo wynosi 0 lub 1. Stąd

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq M \text{ p.n..}$$

Załóżmy najpierw dodatkowo, że zmienne  $X_i$  są symetryczne. Dla  $t > 0$  zdefiniujmy

$$X_n^t := X_n I_{\{|X_n| \leq t\}} - X_n I_{\{|X_n| > t\}}$$

oraz  $S_n^t := \sum_{i=1}^n X_i^t$ . Zmienne  $(X_n^t)$  mają ten sam rozkład co zmienne  $X_n$ , zatem  $\limsup_{n \rightarrow \infty} \frac{|S_n^t|}{\sqrt{2n \ln \ln n}} \leq M$  p.n., czyli

$$\limsup_{n \rightarrow \infty} \frac{|S_n + S_n^t|}{\sqrt{2n \ln \ln n}} \leq 2M \text{ p.n..}$$

Ale  $S_n + S_n^t = \sum_{i=1}^n 2X_i I_{\{|X_i| \leq t\}}$ . Zmienne  $X_i I_{\{|X_i| \leq t\}}$  mają średnią zero i skończoną wariancję, więc na mocy Twierdzenia 5.1,

$$\limsup_{n \rightarrow \infty} \frac{|S_n + S_n^t|}{\sqrt{2n \ln \ln n}} (\text{Var}(2X I_{\{|X| \leq t\}}))^{1/2} \text{ p.n.}$$

Stąd  $\mathbf{E}X^2 I_{\{|X| \leq t\}} \leq M^2$  i z dowolności  $t > 0$  dostajemy  $\mathbf{E}X^2 < \infty$ .

W przypadku, gdy rozkład  $X_i$  nie jest symetryczny, niech  $(X'_n)$  będzie niezależną kopią  $(X_n)$ ,  $S'_n = \sum_{i=1}^n X'_i$ . Wówczas

$$\limsup_{n \rightarrow \infty} \frac{|S_n - S'_n|}{\sqrt{2n \ln \ln n}} \leq 2M \text{ p.n..}$$

Mamy jednak  $S_n - S'_n = \sum_{i=1}^n (X_i - X'_i)$ , stąd na mocy rozważanego wcześniej przypadku,  $\mathbf{E}(X - X')^2 < \infty$ , a więc również  $\mathbf{E}X^2 < \infty$ .

By zakończyć dowód zauważmy, że na mocy mocnego prawa wielkich liczb

$$\mathbf{E}X = \lim_{n \rightarrow \infty} \frac{S_n}{n} = \limsup_{n \rightarrow \infty} \frac{S_n}{\sqrt{2n \ln \ln n}} \lim_{n \rightarrow \infty} \frac{\sqrt{2n \ln \ln n}}{n} = 0.$$

□

## 5.1 Zbiór graniczny

Okazuje się, że nie tylko jesteśmy w stanie podać granicę górną i dolną ciągu  $\frac{S_n}{\sqrt{2n \ln \ln n}}$ , ale określić zbiór wszystkich możliwych granic jego podciągów. Wprowadźmy najpierw definicję.

**Definicja 5.1.** Dla ciągu liczbowego (lub ogólniej o wartościach w przestrzeni metrycznej)  $a_n$  określamy  $C(a_n)$  zbiór wszystkich punktów skupienia ciągu  $a_n$ , czyli

$$x \in C(a_n) \Leftrightarrow \exists_{n_k} a_{n_k} \rightarrow x.$$

**Twierdzenie 5.11.** Załóżmy, że  $\mathbf{E}X = 0$  oraz  $\mathbf{E}X^2 = \sigma^2 < \infty$ . Wówczas

- i)  $\text{dist}(\frac{S_n}{\sqrt{2n \ln \ln n}}, [-\sigma, \sigma]) \rightarrow 0$  p.n.,
- ii)  $C(\frac{S_n}{\sqrt{2n \ln \ln n}}) = [-\sigma, \sigma]$  p.n..

Dowód opiera się na następującym prostym lemacie.

**Lemat 5.12.** Załóżmy, że  $a_n$  jest ciągiem liczbowym takim, że  $b = \liminf_{n \rightarrow \infty} a_n > -\infty$ ,  $c = \limsup_{n \rightarrow \infty} a_n < \infty$  oraz  $\lim_{n \rightarrow \infty} (a_{n+1} - a_n) = 0$ . Wówczas

- i)  $\text{dist}(a_n, [b, c]) \rightarrow 0$ ,
- ii)  $C(a_n) = [b, c]$ .

**Dowód.** i) Z definicji granicy dolnej i górnej wynika, że dla  $\varepsilon > 0$  dla dostatecznie dużych  $n$ ,  $b - \varepsilon \leq x_n \leq c + \varepsilon$ , co pociąga  $\text{dist}(a_n, [b, c]) < \varepsilon$ .

ii) Oczywiście  $\{b, c\} \subset C(a_n)$ , ustalmy  $d \in (b, c)$ . Możemy skonstruować podciąg  $n_k$  taki, że  $a_{n_{2k-1}} < d < a_{n_{2k}}$ . Zdefiniujmy

$$m_k := \sup\{n \leq n_k : a_n \leq d\},$$

wówczas  $a_{m_k} \leq d < a_{m_k+1}$ , zatem  $|d - a_{m_k}| \leq |a_{m_k+1} - a_{m_k}| \rightarrow 0$ , czyli  $d \in C(a_n)$ . □

**Dowód Twierdzenia 5.11.** Na mocy Lematu 5.12 oraz Twierdzenia 5.1 wystarczy wykazać, że

$$\lim_{n \rightarrow \infty} \left( \frac{S_n}{\gamma(n)} - \frac{S_{n-1}}{\gamma(n-1)} \right) = 0 \text{ p.n.},$$

gdzie  $\gamma(n) := \sqrt{2n \ln \ln n}$ . Zauważmy, że  $\gamma(n)^{-1} - \gamma(n-1)^{-1} = o(\gamma(n-1)^{-1})$  oraz  $\limsup \left| \frac{S_{n-1}}{\gamma(n-1)} \right| = \sigma < \infty$  p.n., więc wystarczy udowodnić, że

$$\lim_{n \rightarrow \infty} \frac{X_n}{\gamma(n)} = 0 \text{ p.n.}$$

Szacujemy,

$$\begin{aligned} \sum_n \mathbf{P}(|X_n| \geq \varepsilon \gamma(n)) &= \mathbf{E} \sum_n I_{\{|X| \geq \varepsilon \gamma(n)\}} \leq \mathbf{E} \sum_n I_{\{|X| \geq \varepsilon \sqrt{2n}\}} \\ &\leq \mathbf{E} \sum_n I_{\{2n \leq |X|^2 \varepsilon^{-2}\}} \leq \mathbf{E} \frac{|X|^2}{2\varepsilon^2} < \infty, \end{aligned}$$

zatem na podstawie Lematu Borela-Cantelliego,  $\limsup \frac{|X_n|}{\gamma(n)} \leq \varepsilon$  p.n.  $\square$

## 5.2 Przypadek wektorowy

Założmy, że  $X, X_1, \dots$  są niezależnymi wektorami losowymi o jednakowym rozkładzie o wartościach w  $\mathbb{R}^d$ .

Dla  $x \in \mathbb{R}^d$  przez  $|x|$  będziemy oznaczać euklidesową długość wektora  $x$ .

**Twierdzenie 5.13.** *Jeśli  $\mathbf{E}X = 0$  oraz  $\mathbf{E}|X|^2 < \infty$ , to*

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} = \sup_{|t| \leq 1} (\mathbf{E}\langle X, t \rangle^2)^{1/2} = \sup_{|t| \leq 1} (\langle Ct, t \rangle)^{1/2} \text{ p.n.},$$

gdzie  $C$  oznacza macierz kowariancji  $X$ .

**Dowód.** Ustalmy  $t \in \mathbb{R}^d$  z  $|t| \leq 1$ , wówczas  $|x| \geq \langle x, t \rangle$  dla dowolnego  $x \in \mathbb{R}^d$  i

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \geq \limsup_{n \rightarrow \infty} \frac{\langle S_n, t \rangle}{\sqrt{2n \ln \ln n}} = (\mathbf{E}\langle X, t \rangle^2)^{1/2} \text{ p.n.},$$

stąd dostajemy

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \geq \sup_{|t| \leq 1} (\mathbf{E}\langle X, t \rangle^2)^{1/2} \text{ p.n.}$$

By udowodnić nierówność w drugą stronę, ustalmy  $\varepsilon > 0$  i wybierzmy skończony podzbiór  $T$  kuli domkniętej  $\overline{B(0, 1)}$  taki, że

$$\overline{B(0, 1)} \subset \bigcup_{t \in T} B(t, \varepsilon).$$

Dla  $x \in \mathbb{R}$ , istnieje  $|s| = 1$  takie, że  $\langle s, x \rangle = |x|$ , wybierając  $t \in T$  takie, że  $|s - t| < \varepsilon$  dostajemy  $\langle t, x \rangle = \langle s, x \rangle - \langle s - t, x \rangle \geq |x| - \varepsilon|x|$ . Zatem

$$\forall x \in \mathbb{R}^n \quad \max_{t \in T} \langle t, x \rangle \geq (1 - \varepsilon)|x|,$$

w szczególności

$$\frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \frac{1}{1 - \varepsilon} \max_{t \in T} \frac{\langle S_n, t \rangle}{\sqrt{2n \ln \ln n}}.$$

Zatem ze skończoności zbioru  $T$  dostajemy

$$\begin{aligned} \limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} &\leq \frac{1}{1 - \varepsilon} \max_{t \in T} \limsup_{n \rightarrow \infty} \frac{\langle S_n, t \rangle}{\sqrt{2n \ln \ln n}} \\ &= \frac{1}{1 - \varepsilon} \max_{t \in T} (\mathbf{E}\langle X, t \rangle^2)^{1/2} \text{ p.n..} \end{aligned}$$

Z dowolności  $\varepsilon > 0$ ,

$$\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} \leq \sup_{|t| \leq 1} (\mathbf{E}\langle X, t \rangle^2)^{1/2} \text{ p.n..}$$

□

**Twierdzenie 5.14.** *Załóżmy, że*

$$\mathbf{P}\left(\limsup_{n \rightarrow \infty} \frac{|S_n|}{\sqrt{2n \ln \ln n}} < \infty\right) > 0,$$

wówczas  $\mathbf{E}X = 0$  oraz  $\mathbf{E}|X|^2 < \infty$ .

**Dowód.** Szacowanie  $\langle x, t \rangle \leq |x||t|$  oraz Twierdzenie 5.10 implikują  $\mathbf{E}\langle X, t \rangle = 0$  oraz  $\mathbf{E}\langle X, t \rangle^2 < \infty$  dla dowolnego  $t \in \mathbb{R}^d$ . □

Dla wektora  $X$  takiego, że  $\mathbf{E}|X|^2 < \infty$  definiujemy

$$K_X := \{\mathbf{E}(\xi X) : \xi \in L^2(\Omega), \mathbf{E}\xi^2 \leq 1\}$$

Jeśli  $\text{Cov}(X) = C = UDU^T$ , gdzie  $U^T = U^{-1}$  oraz  $D$  jest macierzą diagonalną, to kładziemy  $C^{1/2} := UD^{1/2}U^T$ .

**Lemat 5.15.** *Mamy*

$$K_X = \{Ct : \langle Ct, t \rangle \leq 1\} = \{C^{1/2}s : |s| \leq 1\},$$

czyli  $K_X$  jest elipsoidą.

**Dowód.** Weźmy  $\xi \in L^2(\Omega)$  wówczas  $\xi = \sum_{i=1}^d X_i + \eta$ , gdzie  $\mathbf{E}\eta X_i = 0$  dla  $i = 1, \dots, d$ . Mamy

$$\mathbf{E}\xi^2 = \mathbf{E}\left(\sum_{i=1}^d t_i X_i\right)^2 + \mathbf{E}\eta^2 = \langle Ct, t \rangle + \mathbf{E}\eta^2$$

oraz

$$\mathbf{E}(\xi X_j) = \sum_{i=1}^d t_i \mathbf{E} X_i X_j = \sum_{i=1}^d t_i c_{ji} = Ct,$$

skąd wynika pierwsza równość. Druga jest konsekwencją tożsamości  $\langle Ct, t \rangle = |C^{1/2}t|^2$  i  $Ct = C^{1/2}C^{1/2}t$ .  $\square$

**Twierdzenie 5.16.** *Załóżmy, że  $\mathbf{E}X = 0$  oraz  $\mathbf{E}|X|^2 < \infty$ . Wówczas*

a)  $\text{dist}(\frac{S_n}{\sqrt{2n \ln \ln n}}, K_X) \rightarrow 0$  p.n.,

b)  $C(\frac{S_n}{\sqrt{2n \ln \ln n}}) = K_X$  p.n..

**Dowód.** Przyjmijmy  $\gamma(n) := \sqrt{2n \ln \ln n}$  i zacznijmy od rozpatrzenia przypadku  $C = \text{Cov}(X) = Id$ . Wówczas  $K_X = \overline{B(0, 1)}$  i punkt a) wynika stąd, że  $\limsup_{n \rightarrow \infty} \frac{|S_n|}{\gamma(n)} = 1$  p.n. (Twierdzenie 5.13).

By udowodnić b) dla  $C = Id$  weźmy najpierw  $t \in S^{d-1}$ , wówczas  $\mathbf{E}\langle t, X \rangle^2 = 1$  i z Twierdzenia 5.1 z prawdopodobieństwem 1 istnieje podciąg  $n_k$  taki, że  $\frac{\langle S_{n_k}, t \rangle}{\gamma(n_k)} \rightarrow 1$ , ale wtedy

$$\limsup_{k \rightarrow \infty} \left| \frac{S_{n_k}}{\gamma(n_k)} - 1 \right|^2 \limsup_{k \rightarrow \infty} \left( \frac{|S_{n_k}|}{\gamma(n_k)} \right)^2 + |t|^2 - 2 \lim_{k \rightarrow \infty} \frac{\langle S_{n_k}, t \rangle}{\gamma(n_k)} = 0.$$

Zatem dla  $|t| = 1$ ,  $\mathbf{P}(t \in C(\frac{S_n}{\gamma(n)})) = 1$ .

Jeśli  $|t| < 1$ , to rozpatrzmy  $(\varepsilon_i)$  ciąg Bernoulliego niezależny od ciągu  $(X_i)$  i połóżmy  $Y_i = (X_i, \varepsilon_i)$ . Wówczas  $(Y_i)$  jest ciągiem niezależnych wektorów losowych w  $\mathbb{R}^{d+1}$  o średniej zero i macierzy kowariancji  $Id$ . Jeśli położymy  $\tilde{S}_n := \sum_{i \leq n} Y_i$ , to na mocy poprzednich rozważań,

$$t + (1 - |t|^2)^{1/2} e_{d+1} \in C(\frac{\tilde{S}_n}{\gamma(n)}) \text{ p.n.,}$$

co w szczególności implikuje  $t \in C(\frac{S_n}{\gamma(n)})$  p.n.. A zatem dla dowolnego  $t \in \overline{B(0, 1)}$ ,  $\mathbf{P}(t \in C(\frac{S_n}{\gamma(n)})) = 1$ , skąd łatwo wynika (z domkniętości  $C(a_n)$  i ośrodkowości kuli)  $\mathbf{P}(\overline{B(0, 1)} \subset C(\frac{S_n}{\gamma(n)})) = 1$ .

Jeśli  $X$  dowolne takie, że  $C \neq 0$ , to istnieje  $k \leq d$  oraz przekształcenia liniowe  $A: \mathbb{R}^d \rightarrow \mathbb{R}^k$  i  $B: \mathbb{R}^k \rightarrow \mathbb{R}^d$  takie, że  $Y := AX$  jest zmienną o średniej zero i macierzy kowariancji  $Id$  oraz  $X = BY$  p.n. Wówczas  $K_X = BK_Y = B\overline{B_k(0, 1)}$ ,  $S_n = BT_n$  p.n., gdzie  $T_n = \sum_{i \leq n} AX_i$ , czyli

$$\text{dist}(\frac{S_n}{\gamma(n)}, K_X) = \text{dist}(B \frac{T_n}{\gamma(n)}, BK_Y) \leq \|B\| \text{dist}(\frac{T_n}{\gamma(n)}, K_Y) \rightarrow 0 \text{ p.n.}$$

oraz

$$C(\frac{S_n}{\gamma(n)}) = BC(\frac{T_n}{\gamma(n)}) = BK_Y = K_X \text{ p.n..}$$

Dla  $C = 0$ ,  $X = 0$  p.n. oraz  $K_X = \{0\}$  i teza twierdzenia jest oczywista.  $\square$

## 6 Rozkłady nieskończenie podzielne

**Definicja 6.1.** Rozkład probabilistyczny  $\mu$  na  $\mathbb{R}$  nazywamy nieskończenie podzielnym, jeśli dla każdego  $n = 1, 2, \dots$  istnieje rozkład  $\mu_{1/n}$  taki, że  $\mu = \mu_{1/n}^{*n}$ .

Mówimy, że zmienna losowa  $X$  jest nieskończenie podzielna, jeśli rozkład  $X$  jest nieskończenie podzielny, czyli dla każdego  $n = 1, 2, \dots$  istnieją zmienne  $X_{n,1}, \dots, X_{n,n}$  o jednakowym rozkładzie takie, że  $X \sim X_{n,1} + \dots + X_{n,n}$ .

Klasę wszystkich rozkładów nieskończenie podzielnych będziemy oznaczać przez  $ID$ .

**Przykłady.**

- i)  $\mu = \delta_a, \mu_{1/n} = \delta_{a/n}$
- ii)  $\mu = \mathcal{N}(a, \sigma^2), \mu_{1/n} = \mathcal{N}(a/n, \sigma^2/n)$ ,
- iii)  $\mu = \text{Pois}(\lambda), \mu_{1/n} = \text{Pois}(\lambda/n)$ ,
- iv)  $\mu = \Gamma(\alpha), \mu_{1/n} = \Gamma(\alpha/n)$ .

**Definicja 6.2.** Dla  $\lambda \geq 0$  oraz  $\nu$  miary probabilistycznej na  $\mathbb{R}$  definiujemy złożony rozkład Poissona  $\pi_{\lambda\nu}$  wzorem

$$\pi_{\lambda\nu} := e^{-\lambda} \sum_{n=0}^{\infty} \frac{\lambda^n}{n!} \mu^{*n}.$$

Przez  $CP$  będziemy oznaczać klasę wszystkich złożonych rozkładów Poissona, czyli

$$CP := \{\pi_{\lambda\nu} : \lambda \geq 0, \nu \text{ miara probabilistyczna na } \mathbb{R}\}.$$

Domknięcie  $CP$  w topologii zbieżności według rozkładu będziemy oznaczać przez  $\overline{CP}$  czyli

$$\mu \in \overline{CP} \Leftrightarrow \exists \mu_n \in CP \mu_n \Rightarrow \mu.$$

Dla uproszczenia i ujednoczenia notacji wprowadźmy następującą definicję.

**Definicja 6.3.** Dla miar skończonych  $\nu$  na  $\mathbb{R}$  definiujemy transformatę Fouriera  $\nu$  wzorem

$$\widehat{\nu}(t) := \int_{\mathbb{R}} e^{itx} d\nu(x).$$

Podobnie dla funkcji  $f \in L^1(\mathbb{R})$  określamy

$$\widehat{f}(t) := \int_{\mathbb{R}} e^{itx} f(x) dx.$$

Oczywiście gdy  $\nu$  jest miarą probabilistyczną, to  $\widehat{\nu} = \varphi_\nu$  jest funkcją charakterystyczną  $\nu$ .

**Twierdzenie 6.1.** Dowolny rozkład nieskończenie podzielny jest granicą złożonych rozkładów Poissona, czyli  $ID \subset \overline{CP}$ .

**Dowód.** Weźmy  $\mu \in ID$  oraz zdefiniujmy

$$\pi_n := e^{-n} \sum_{k=0}^{\infty} \frac{n^k}{k!} \mu_{1/n}^{*k},$$

pokażemy, że  $\pi_n \Rightarrow \mu$ . W tym celu wystarczy, że wykażemy iż

$$\int \varphi d\pi_n \rightarrow \int \varphi d\mu \text{ dla dowolnej ograniczonej funkcji Lipschitzowskiej } \varphi.$$

Ustalmy więc ograniczoną funkcję Lipschitzowską  $\varphi$  ze stałą Lipschitza  $L$  i dla  $R > 0$  określmy

$$\Delta_n(R) := e^{-n} \sum_{|k-n| \leq \sqrt{n}R} \frac{n^k}{k!} \left| \int \varphi d\mu_{1/n}^{*k} - \int \varphi d\mu \right|.$$

Wówczas,

$$\begin{aligned} \left| \int \varphi d\pi_n - \int \varphi d\mu \right| &\leq e^{-n} \sum_{k \geq 0} \frac{n^k}{k!} \left| \int \varphi d\mu_{1/n}^{*k} - \int \varphi d\mu \right| \\ &\leq \Delta_n(R) + 2\|\varphi\|_{\infty} \varepsilon_n(R), \end{aligned}$$

gdzie

$$\begin{aligned} \varepsilon_n(R) &:= e^{-n} \sum_{|k-n| > \sqrt{n}R} \frac{n^k}{k!} \leq \frac{1}{nR^2} e^{-n} \sum_{k \geq 0} \frac{n^k}{k!} (n-k)^2 \\ &= \frac{1}{nR^2} \text{Var}(\text{Pois}(n)) = \frac{1}{R^2}. \end{aligned}$$

Wykazaliśmy więc, że

$$\left| \int \varphi d\pi_n - \int \varphi d\mu \right| \leq \Delta_n(R) + 2R^{-2} \|\varphi\|_{\infty}$$

i by zakończyć dowód wystarczy pokazać, że

$$\forall R > 0 \quad \lim_{n \rightarrow \infty} \Delta_n(R) = 0. \quad (12)$$

Szacujemy

$$\begin{aligned} \Delta_n(R) &\leq e^{-n} \sum_{|k-n| \leq \sqrt{n}R} \frac{n^k}{k!} \sup_{|k-n| \leq \sqrt{n}R} \left| \int \varphi d\mu_{1/n}^{*k} - \int \varphi d\mu_{1/n}^{*n} \right| \\ &\leq \sup_{0 \leq l \leq \sqrt{n}R, m \geq 0} \left| \int \varphi d\mu_{1/n}^{*(m+l)} - \int \varphi d\mu_{1/n}^{*m} \right|. \end{aligned}$$



Zauważmy, że dla miar probabilistycznych  $\nu_1$  i  $\nu_2$ ,

$$\begin{aligned} \left| \int \varphi d\nu_1 * \nu_2 - \int \varphi d\nu_1 \right| &= \left| \int \int (\varphi(x+y) - \varphi(x)) d\nu_2(y) d\nu_1(x) \right| \\ &\leq \sup_x \int |\varphi(x+y) - \varphi(x)| d\nu_2(y), \end{aligned}$$

ponadto dla dowolnego  $x$  na mocy Lipschitzowskości  $\varphi$ ,

$$\begin{aligned} \int |\varphi(x+y) - \varphi(x)| d\nu_2(y) &= \left( \int_{|y| \leq r} + \int_{|y| > r} \right) |\varphi(x+y) - \varphi(x)| d\nu_2(y) \\ &\leq rL + 2\|\varphi\|_\infty \nu_2(\mathbb{R} \setminus [-r, r]). \end{aligned}$$

Zatem by wykazać (12) pozostaje udowodnić, że

$$\forall R, r > 0 \quad \lim_{n \rightarrow \infty} \sup_{0 \leq l \leq \sqrt{n}R} \mu_{1/n}^{*l}(\mathbb{R} \setminus [-r, r]) = 0. \quad (13)$$

Udowodnijmy wpieryw następujące oszacowanie.

**Lemat 6.2.** *Dla  $|v| \leq 1/2$  oraz  $\alpha \in [0, 1]$ ,  $|e^{\alpha \log(1+v)} - 1| \leq 2\alpha|v|$ , gdzie  $\log(z)$  oznacza kanoniczną gałąź logarytmu w kole  $|z - 1| \leq 1/2$ .*

**Dowód.** Mamy

$$e^{\alpha \log(1+v)} - 1 = \int_0^1 \frac{d}{dt} e^{\alpha \log(1+tv)} dt = \int_0^1 \alpha v (1+tv)^{\alpha-1} dt,$$

zatem

$$|e^{\alpha \log(1+v)} - 1| \leq \alpha|v| \int_0^1 |1+tv|^{\alpha-1} \leq 2\alpha|v|,$$

gdzie ostatnia nierówność wynika stąd, że  $|1+tv| \geq 1-t|v| \geq 1/2$  oraz  $0 \leq \alpha - 1 \leq -1$ .  $\square$

Ustalmy  $\delta > 0$  takie, że  $|\widehat{\mu}(t) - 1| \leq 1/2$  dla  $|t| \leq \delta$ . Ponieważ  $\widehat{\mu_{1/n}^{*l}} = \widehat{\mu}^l$ , więc

$$\widehat{\mu_{1/n}^{*l}}(t) = \widehat{\mu}^{*l/n}(t) = e^{\frac{l}{n} \log \widehat{\mu}(t)} \text{ dla } |t| \leq \delta,$$

gdzie  $\log$  oznacza standardową gałąź logarytmu w kole  $|z - 1| \leq 1/2$ . Na podstawie Lematu 6.2,

$$\forall |t| \leq \delta \quad |\widehat{\mu_{1/n}^{*l}}(t) - 1| \leq 2 \frac{l}{n} |\widehat{\mu}(t) - 1| \leq \frac{l}{n}.$$

Dla miary  $\nu$  liczymy

$$\begin{aligned} \frac{1}{\delta} \int_0^\delta (1 - \operatorname{Re}(\widehat{\nu}(t))) dt &= \frac{1}{\delta} \int_0^\delta \int_{\mathbb{R}} (1 - \cos(tx)) d\nu(x) dt \\ &= \int_{\mathbb{R}} \frac{1}{\delta} \int_0^\delta (1 - \cos(tx)) dt d\nu(x) = \int_{\mathbb{R}} \left(1 - \frac{\sin(x\delta)}{x\delta}\right) d\nu(x) \\ &\geq m(r\delta) \nu(\mathbb{R} \setminus [-r, r]), \end{aligned}$$

gdzie

$$m(s) := \inf\left\{1 - \frac{\sin(y)}{y} : |y| \geq s\right\} > 0 \text{ dla } s > 0.$$

Zatem

$$\mu_{1/n}^{*l}(\mathbb{R} \setminus [-r, r]) \leq \frac{1}{m(r\delta)} \frac{1}{\delta} \int_0^\delta |1 - \widehat{\mu_{1/n}^{*l}}(t)| dt \leq \frac{l}{nm(r\delta)},$$

co łatwo implikuje (13).  $\square$

**Uwaga.** Można udowodnić bezpośrednio, że słaba granica rozkładów nieskończenie podzielnych jest nieskończenie podzielna, skąd łatwo wynika, że  $ID = \overline{CP}$ . My jednak pójdziemy bardziej skomplikowaną drogą, gdyż zależy nam na dobrym opisanu klasy  $ID$ .

**Lemat 6.3.** *Mamy*

$$\widehat{\pi_{\lambda\nu}}(t) = \exp\left(\int (e^{itx} - 1)d\lambda\nu(x)\right) =: f_{\lambda\nu}(t).$$

**Dowód.** Liczymy

$$\widehat{\pi_{\lambda\nu}}(t) = e^{-\lambda} \sum_{n=0}^{\infty} \frac{\lambda^n}{n!} \widehat{\nu}^n(t) = \exp(-\lambda + \lambda\widehat{\nu}(t)) = \exp\left(\int (e^{itx} - 1)d\lambda\nu(x)\right).$$

$\square$

By podać klasyfikację rozkładów nieskończenie podzielnych wprowadzimy następującą definicję.

**Definicja 6.4.** *Niech*

$$\mathcal{M} := \{\text{miary nieujemne } \nu \text{ na } \mathbb{R} \setminus \{0\} : \int 1 \wedge x^2 d\nu(x) < \infty\}.$$

Elementy zbioru  $\mathcal{M}$  nazywamy miarami Levy'ego. Klasę  $\mathcal{L}$  układów Levy'ego określamy jako

$$\mathcal{L} := \mathbb{R} \times [0, \infty) \times \mathcal{M} = \{(a, \sigma, \nu) : a \in \mathbb{R}, \sigma \geq 0, \nu \in \mathcal{M}\}.$$

Dla  $(a, \sigma, \nu) \in \mathcal{L}$  definiujemy  $f_{a, \sigma^2, \nu} := \exp(l_{a, \sigma^2, \nu})$ , gdzie

$$l_{a, \sigma^2, \nu} := ita - \frac{\sigma^2}{2} t^2 + \int_{\mathbb{R} \setminus \{0\}} \left( e^{itx} - 1 - \frac{itx}{1+x^2} \right) d\nu(x).$$

**Twierdzenie 6.4.** *Dla  $(a, \sigma, \nu) \in \mathcal{L}$  istnieje miara probabilistyczna  $\pi_{a, \sigma^2, \nu} \in ID$  taka, że  $\widehat{\pi_{a, \sigma^2, \nu}} = f_{a, \sigma^2, \nu}$ .*

**Dowód.** Przeprowadzimy konstrukcję  $\pi_{a, \sigma^2, \nu}$  w trzech krokach.

**Krok I.** Dla  $a \in \mathbb{R}$  oraz miary skończonej  $\nu$  na  $\mathbb{R}$  istnieje rozkład  $\pi_{a,\nu}$  taki, że

$$\widehat{\pi_{a,\nu}}(t) = f_{a,\nu}(t) = \exp\left(ita + \int (e^{itx} - 1)d\nu(x)\right).$$

Mamy  $f_{a,\nu}(t) = e^{iat}f_\nu(t)$ , więc za  $\pi_{a,\nu}$  wystarczy wziąć przesunięcie  $\pi_\nu$  o  $a$  i skorzystać z Lematu 6.3.

**Krok II.** Dla  $a \in \mathbb{R}$  oraz miary Levy'ego  $\nu \in \mathcal{M}$  istnieje rozkład  $\pi_{a,0,\nu}$  taki, że

$$\widehat{\pi_{a,0,\nu}}(t) = f_{a,0,\nu}(t) = \exp\left(ita + \int (e^{itx} - 1 - \frac{itx}{1+x^2})d\nu(x)\right).$$

Zauważmy, że  $|e^{itx} - 1 - itx| \leq t^2x^2/2$ , więc

$$\left|e^{itx} - 1 - \frac{itx}{1+x^2}\right| \leq \min\left(2+|t|, \frac{1}{2}|t|^2x^2 + \frac{|t||x|^3}{1+x^2}\right) \leq \left(2+|t| + \frac{t^2}{2}\right) \min(1, x^2),$$

skąd wynika, że funkcja  $f_{a,0,\nu}$  jest dobrze określona i ciągła w zerze. Określmy miarę skończoną  $\nu_\varepsilon$  wzorem  $\nu_\varepsilon(A) := \nu(A \setminus (-\varepsilon, \varepsilon))$ , wówczas

$$f_{a,0,\nu_\varepsilon}(t) = \exp\left(it(a - \int_{|x| \geq \varepsilon} \frac{x}{1+x^2}d\nu) + \int (e^{itx} - 1)d\nu_\varepsilon(x)\right) = \widehat{\pi_{a_\varepsilon, \nu_\varepsilon}}$$

dla  $a_\varepsilon := a - \int_{|x| \geq \varepsilon} \frac{x}{1+x^2}d\nu$ . Ponieważ  $f_{a,0,\nu_\varepsilon}$  zbiega punktowo do  $f_{a,0,\nu}$ , więc na mocy twierdzenia Levy'ego  $\pi_{a_\varepsilon, \nu_\varepsilon}$  zbiega słabo do szukanego rozkładu  $\pi_{a,0,\nu}$ .

**Krok III.** Dla  $(a, \sigma, \nu) \in \mathcal{L}$  istnieje miara probabilistyczna  $\pi_{a,\sigma^2,\nu} \in ID$  taka, że  $\widehat{\pi_{a,\sigma^2,\nu}} = f_{a,\sigma^2,\nu}$ .

Za  $\pi_{a,\sigma^2,\nu}$  bierzemy rozkład  $X + Y$ , gdzie  $X$  i  $Y$  są niezależne,  $X \sim \pi_{a,0,\nu}$ , a  $Y \sim \mathcal{N}(0, \sigma^2)$ .

Z postaci funkcji charakterystycznej natychmiast dostajemy, że  $\pi_{a,\sigma^2,\nu} = \pi_{a/n, \sigma^2/n, \nu/n}^{*n}$ , czyli  $\pi_{a,\sigma^2,\nu} \in ID$ .  $\square$

**Fakt 6.5.** Jeśli  $f_{a_1, \sigma_1, \nu_1} = f_{a_2, \sigma_2, \nu_2}$  dla pewnych  $(a_i, \sigma_i, \nu_i) \in \mathcal{L}$ , to  $a_1 = a_2$ ,  $\sigma_1 = \sigma_2$  oraz  $\nu_1 = \nu_2$ .

**Fakt 6.6.** Załóżmy, że  $\pi_{a_n, \sigma_n, \nu_n} \Rightarrow \mu$  dla pewnego ciągu układów Levy'ego  $(a_n, \sigma_n, \nu_n) \in \mathcal{L}$ . Wówczas istnieje  $(a, \sigma, \nu) \in \mathcal{L}$  taki, że  $\mu = \pi_{a,\sigma,\nu}$ .

**Twierdzenie 6.7.** Jeśli  $\mu$  jest rozkładem nieskończenie podzielnym to istnieje dokładnie jeden układ Levy'ego  $(a, \sigma, \nu) \in \mathcal{L}$  taki, że  $\widehat{\mu} = f_{a,\sigma,\nu}$ .

## 6.1 Rozkłady nieskończenie podzielne jako granice sum

Przypomnijmy, że macierz zmiennych losowych  $(X_{n,k})_{k \leq k_n, n=1,2,\dots}$  nazywamy *układem trójkątnym*, jeśli dla każdego  $n$  zmienne  $X_{n,k}$ ,  $1 \leq k \leq k_n$  są niezależne.

Położmy  $S_n := \sum_{k=1}^{k_n} X_{n,k}$ .

Centralne twierdzenie graniczne mówi, że jeśli  $\mathbf{E}S_n \rightarrow a$ ,  $\text{Var}(S_n) \rightarrow \sigma^2$  oraz zachodzi warunek Lindeberga, to  $S_n$  zbiega według rozkładu do zmiennej  $\mathcal{N}(a, \sigma^2)$ .

Twierdzenie Poissona stwierdza, że jeśli  $\mathbf{P}(X_{n,k} = 1) = p_n = 1 - \mathbf{P}(X_{n,k} = 0)$ ,  $k_n \rightarrow \infty$  oraz  $k_n p_n \rightarrow \lambda$ , to  $S_n$  zbiega według rozkładu do zmiennej  $\text{Poiss}(\lambda)$ .

Można się zapytać jakie inne rozkłady można uzyskać jako granice sum układów trójkątnych? Oczywiście trzeba coś założyć, inaczej wystarczy przyjąć  $X_{n,1} \sim X$  oraz wziąć  $X_{n,2} + \dots + X_{n,k_n}$  zbieżne do zera by otrzymać  $X$  jako granicę  $S_n$ . Naturalnym założeniem jest

$$\forall \varepsilon > 0 \quad \lim_{n \rightarrow \infty} \sup_{k \leq k_n} \mathbf{P}(|X_{n,k}| \geq \varepsilon) = 0 \quad (14)$$

mówiące, że wkład pojedynczej zmiennej w sumę  $S_n$  jest granicznie zaniedbywalny.

Celem tego paragrafu jest udowodnienie następującego twierdzenia.

**Twierdzenie 6.8.** *Załóżmy, że  $(X_{n,k})_{k \leq k_n, n \geq 1}$  jest układem trójkątnym spełniającym (14) oraz  $a_n \in \mathbb{R}$ . Wówczas jeśli ciąg zmiennych losowych*

$$S_n := \sum_{k=1}^{k_n} X_{n,k} + a_n$$

*zbiega według rozkładu do zmiennej  $S$ , to  $S$  ma rozkład nieskończenie podzielny.*

**Uwaga.** Na odwrót - jeśli  $S$  ma rozkład nieskończenie podzielny  $\mu$ , to biorąc  $a_n = 0$  oraz  $X_{k,n} \sim \mu_{1/k_n}$  dostajemy  $S_n \sim S$  czyli w szczególności  $S_n$  zbiega według rozkładu do  $S$  oraz jak łatwo sprawdzić warunek (14) jest spełniony, jeśli  $k_n \rightarrow \infty$ .

**Lemat 6.9** (nierówność Paleya-Zygmunda). *Załóżmy, że  $Z$  jest nieujemną całkowalną zmienną losową. Wówczas*

$$\forall \lambda \in (0,1) \quad \mathbf{P}(Z \geq \lambda \mathbf{E}Z) \geq (1 - \lambda)^2 \frac{(\mathbf{E}Z)^2}{\mathbf{E}Z^2}.$$

**Dowód.** Na podstawie nierówności Höldera,

$$\begin{aligned} (\mathbf{E}Z^2)^{1/2} (\mathbf{P}(Z \geq \lambda \mathbf{E}Z))^{1/2} &\geq \mathbf{E}Z I_{\{Z \geq \lambda \mathbf{E}Z\}} = \mathbf{E}Z - \mathbf{E}Z I_{\{Z < \lambda \mathbf{E}Z\}} \\ &\geq (1 - \lambda) \mathbf{E}Z. \end{aligned}$$

Podnosząc obie strony nierówności do kwadratu dostajemy tezę.  $\square$

**Wniosek 6.10.** *Niech  $(\varepsilon_i)$  będzie ciągiem Bernoulliego, wówczas dla dowolnych liczb  $a_i$ ,*

$$\mathbf{P}\left(\left|\sum_{i=1}^n a_i \varepsilon_i\right| \geq \frac{1}{2} \sqrt{\sum_{i=1}^n a_i^2}\right) \geq \frac{3}{16}.$$

**Dowód.** Niech  $S := \sum_{i=1}^n a_i \varepsilon_i$ , łatwo sprawdzić, że

$$\mathbf{E}S^4 = \sum_i a_i^4 + 6 \sum_{i < j} a_i^2 a_j^2 \leq 3 \left(\sum_i a_i^2\right)^2 = 3(\mathbf{E}S^2)^2,$$

stąd na podstawie nierówności Paleya-Zygmunda,

$$\mathbf{P}\left(|S| \geq \frac{1}{2} \left(\sum_{i=1}^n a_i^2\right)^{1/2}\right) = \mathbf{P}\left(|S|^2 \geq \frac{1}{4} \mathbf{E}S^2\right) \geq \left(1 - \frac{1}{4}\right)^2 \frac{(\mathbf{E}S^2)^2}{\mathbf{E}S^4} \geq \frac{3}{16}.$$

□

**Lemat 6.11.** *Załóżmy, że  $X_i$  są nieujemnymi, niezależnymi zmiennymi losowymi. Wówczas*

$$\mathbf{P}\left(\sum_i X_i \geq \frac{1}{4} \sum \mathbf{E}(X_i \wedge 1)\right) \geq \frac{9}{32} \min\left(1, \sum \mathbf{E}(X_i \wedge 1)\right).$$

**Dowód.** Niech  $S := \sum_i X_i \wedge 1$ , wówczas

$$\begin{aligned} \mathbf{E}S^2 &= \mathbf{E} \sum_{i,j} (X_i \wedge 1)(X_j \wedge 1) = \sum_i \mathbf{E}(X_i \wedge 1)^2 + 2 \sum_{i < j} \mathbf{E}(X_i \wedge 1)\mathbf{E}(X_j \wedge 1) \\ &\leq \sum_i \mathbf{E}(X_i \wedge 1) + \left(\sum_i \mathbf{E}(X_i \wedge 1)\right)^2 = \mathbf{E}S + (\mathbf{E}S)^2. \end{aligned}$$

Stąd na mocy nierówności Paleya-Zygmunda,

$$\mathbf{P}\left(\sum_i X_i \geq \frac{1}{4} \sum \mathbf{E}(X_i \wedge 1)\right) \geq \mathbf{P}\left(S \geq \frac{1}{4} \mathbf{E}S\right) \geq \frac{9}{16} \frac{\mathbf{E}S}{\mathbf{E}S + (\mathbf{E}S)^2} \geq \frac{9}{32} \min(1, \mathbf{E}S).$$

□

**Wniosek 6.12.** *Załóżmy, że  $X_i$  są symetrycznymi, niezależnymi zmiennymi losowymi. Wówczas*

$$\mathbf{P}\left(\left|\sum_i X_i\right| \geq \frac{1}{4} \left(\sum \mathbf{E}(X_i^2 \wedge 1)\right)^{1/2}\right) \geq \frac{1}{20} \min\left(1, \sum \mathbf{E}(X_i^2 \wedge 1)\right).$$

**Dowód.** Niech  $(\varepsilon_i)$  będzie ciągiem Bernoulliego niezależnym od  $(X_i)$ , wówczas  $\sum_i X_i$  ma ten sam rozkład co  $\sum_i \varepsilon_i X_i$ . Na mocy Wniosku 6.10 dostajemy  $\mathbf{P}\left(\left|\sum_i \varepsilon_i x_i\right| \geq (\sum_i x_i^2)^{1/2}/2 \geq 3/16\right)$ , zatem przyjmując  $a := \sum_i \mathbf{E}(X_i^2 \wedge 1)$  mamy

$$\begin{aligned} \mathbf{P}\left(\left|\sum_i X_i\right| \geq \frac{1}{4} \sqrt{a}\right) &= \mathbf{P}\left(\left|\sum_i \varepsilon_i X_i\right| \geq \frac{1}{4} \sqrt{a}\right) \geq \frac{3}{16} \mathbf{P}\left(\frac{1}{2} \left(\sum_i X_i^2\right)^{1/2} \geq \frac{1}{4} \sqrt{a}\right) \\ &= \frac{3}{16} \mathbf{P}\left(\sum_i X_i^2 \geq \frac{1}{4} a\right) \geq \frac{3}{16} \cdot \frac{9}{32} \min(1, a), \end{aligned}$$

gdzie ostatnia nierówność wynika z Lematu 6.11. □

## 7 Rozkłady stabilne

**Definicja 7.1.** Mówimy, że niezdegenerowana zmienna losowa  $X$  ma rozkład stabilny, jeśli dla każdego  $n \geq 1$  istnieją liczby  $a_n > 0$  oraz  $b_n \in \mathbb{R}$  takie, że

$$X_1 + \dots + X_n \sim a_n X + b_n,$$

gdzie  $X_1, X_2, \dots$  są niezależnymi kopiami  $X$ .

**Lemat 7.1.** Załóżmy, że  $X_n$  jest ciągiem zmiennych losowych,  $a_n, c_n > 0$ ,  $b_n, d_n \in \mathbb{R}$  są takie, że

$$a_n X_n + b_n \Rightarrow X, \quad c_n X_n + d_n \Rightarrow Y$$

dla pewnych niezdegenerowanych zmiennych losowych  $X$  i  $Y$ . Wówczas istnieją granice

$$\lim_{n \rightarrow \infty} \frac{a_n}{c_n} = A > 0, \quad \lim_{n \rightarrow \infty} \left( d_n - \frac{c_n b_n}{a_n} \right) = B$$

oraz  $Y \sim AX + B$ .

**Twierdzenie 7.2.** Załóżmy, że  $X_1, X_2, \dots$  są niezależnymi zmiennymi losowymi o jednakowym rozkładzie,  $a_n > 0$  oraz  $b_n \in \mathbb{R}$  są takie, że

$$\frac{1}{a_n} \sum_{i=1}^n X_i \Rightarrow Y.$$

Wówczas  $Y$  jest zdegenerowane lub  $Y$  ma rozkład stabilny.

**Lemat 7.3.** Załóżmy, że spełnione są założenia Twierdzenia 7.2 oraz  $Y$  jest niezdegenerowane. Wówczas  $a_n \rightarrow \infty$ ,  $\frac{a_{n+1}}{a_n} \rightarrow 1$ .

**Lemat 7.4.** Załóżmy, że  $g: (0, \infty) \rightarrow [0, \infty)$  niemalejąca oraz

$$\forall x > 0 \forall n \quad g(a_n x) = \lambda_n g(x)$$

dla pewnych ciągów liczb dodatnich  $(a_n)$  i  $(\lambda_n)$  takich, że  $a_n \rightarrow \infty$ ,  $\frac{\lambda_{n+1}}{\lambda_n} \rightarrow 1$ . Wówczas  $g(x) \equiv 0$  lub  $g(x) = Cx^\rho$  dla pewnych  $C > 0$ ,  $\rho \geq 0$ .

**Twierdzenie 7.5.** Załóżmy, że  $X$  ma rozkład stabilny. Wówczas  $X$  ma rozkład nieskończenie podzielny. Ponadto  $a_n = n^{1/\alpha}$  dla pewnego  $0 < \alpha \leq 2$  oraz

i) jeśli  $\alpha = 2$ , to  $X \sim \mathcal{N}(a, \sigma^2)$  dla pewnych  $a \in \mathbb{R}$  oraz  $\sigma > 0$ ,

ii) jeśli  $0 < \alpha < 2$ , to  $X \sim \pi_{a,0,\nu_\alpha,C_1,C_2}$  dla pewnych  $a \in \mathbb{R}$ ,  $C_1, C_2 \geq 0$ ,  $C_1 + C_2 > 0$ , gdzie

$$d\nu_{\alpha,C_1,C_2}(x) = (C_1 x^{-1-\alpha} I_{\{x>0\}} + C_2 (-x)^{-1-\alpha} I_{\{x<0\}}) dx.$$

Na odwrót, zmienne  $\mathcal{N}(a, \sigma^2)$  są stabilne z  $a_n = n^{1/2}$  a zmienne o rozkładzie  $\pi_{a,0,\nu_\alpha,C_1,C_2}$  są stabilne z  $a_n = n^{1/\alpha}$ .

## Literatura

- [1] A. Dembo, O. Zeitouni, *Large deviations techniques and applications*, Springer-Verlag, New York, 1998.
- [2] W. Feller, *Wstęp do rachunku prawdopodobieństwa*, tom II, wyd. III, PWN, Warszawa 1981.
- [3] J. Jakubowski, R. Sztencel, *Wstęp do teorii prawdopodobieństwa*, wyd. II, Script, Warszawa 2001.
- [4] S. Kwapien, W. A. Woyczyński, *Random Series and Stochastic Integrals: Simple and Multiple*, Birkhauser, New York 1992.
- [5] M. Ledoux, M. Talagrand, *Probability in Banach spaces*, Springer-Verlag, Berlin, 1991.
- [6] V. Petrov, *Limit theorems of probability theory. Sequences of independent random variables.*, Oxford University Press, New York, 1995.
- [7] D. W. Stroock, *Probability theory, an analytic view*, Cambridge University Press, Cambridge, 1993.