

Wstęp do Procesów Stochastycznych

Rafał Latała

29 kwietnia 2024

Poniższe notatki powstają na podstawie wykładów ze Wstępu do Procesów Stochastycznych, prowadzonego w semestrze wiosennym 2023/24. Gwiazdkami oznaczono treści, pobieżnie omówione w czasie wykładu, które nie będą wymagane na egzaminie.

U Czytelnika zakłada się znajomość podstawowych faktów z zakresu kursowego wykładu z rachunku prawdopodobieństwa. Wszystkie potrzebne wiadomości można znaleźć w podręcznikach [1] i [2].

Większość materiału wykładu można znaleźć w książkach [3] i [7]. Obszerne notatki do wykładu były też przygotowane przez prof. Talarczyk-Noble [6]. Ambitniejszemu Czytelnikowi polecamy monografię [5].

Autor z góry przeprosza za wszystkie nieścisłości i omyłki mogące się pojawić w tekście i jednocześnie zwraca się z prośbą do Czytelników, którzy zauważyli błędy lub mają jakieś inne uwagi na temat notatek o ich zakomunikowanie osobiste lub wysłanie na adres emailowy rlatala@mimuw.edu.pl z podaniem wersji notatek (daty), której dotyczą.

Spis treści

1	Podstawowe Przykłady Procesów Stochastycznych	3
1.1	Proces Poissona	3
1.1.1	Konstrukcja procesu Poissona	4
1.1.2	Złożony Proces Poissona	7
1.1.3	*Charakteryzacje Procesu Poissona*	7
1.2	Proces Wienera (Ruch Browna)	8
1.2.1	Charakteryzacje procesu Wienera	8
1.2.2	*Proces Wienera jako granica błędzeń losowych*	11
1.2.3	Konstrukcja procesu Wienera przy pomocy układu Haara	11
1.2.4	Nieróżniczkowalność trajektorii	14
2	Rozkłady Procesów Stochastycznych	16
2.1	σ -ciało zbiorów cylindrycznych	16
2.2	Warunki zgodności. Twierdzenie Kołmogorowa o istnieniu procesu	17
2.3	*Dowód twierdzenia o istnieniu procesu*	19
3	Ciągłość trajektorii	21
3.1	Procesy stochastycznie równoważne i nierozróżnialne	21
3.2	Twierdzenie o ciągłej modyfikacji	22
3.3	Inne rodzaje ciągłości procesów	25
4	Procesy gaussowskie	26
4.1	Przypomnienie podstawowych faktów o wektorach gaussowskich	26
4.2	Procesy gaussowskie – definicja i podstawowe własności	27
4.3	Proces Ornsteina-Uhlebecka	28
4.4	Ułamkowy Ruch Browna	28
5	Filtracje z czasem ciągłym, Momenty Zatrzymania	30
5.1	Filtracje	30
5.2	Momenty Zatrzymania	31
6	Martyngały z czasem ciągłym	34
6.1	Definicje i przykłady	34
6.2	Jednostajna całkowalność	35
6.3	Twierdzenia Dooba o stopowaniu	37
6.4	Nierówności maksymalne	38
7	Twierdzenia o zbieżności martyngałów	41
7.1	Przejścia w dół przez przedział	41
7.2	Zbieżność prawie na pewno	42

1 Podstawowe Przykłady Procesów Stochastycznych

Zacniemy od podania podstawowych definicji używanych podczas całego wykładu. Podamy też dwa podstawowe przykłady procesów stochastycznych - proces Poissona i proces Wienera.

Definicja 1.1. Niech $(\Omega, \mathcal{F}, \mathbb{P})$ będzie przestrzenią probabilistyczną, (E, \mathcal{E}) przestrzenią mierzalną, zaś T dowolnym zbiorem. *Procesem stochastycznym* o wartościach w E , określonym na zbiorze T nazywamy rodzinę zmiennych losowych $X = (X_t)_{t \in T}$.

Uwaga 1.2. W zasadzie w czasie całego wykładu T będzie podzbiorem \mathbb{R} (najczęściej przedziałem, niekoniecznie ograniczonym), zaś $E = \mathbb{R}$ lub \mathbb{R}^d . Parametr t można wówczas interpretować jako czas.

Definicja 1.3. *Trajektorią procesu X* nazywamy funkcję (losową!) $t \rightarrow X_t(\omega)$, określoną na zbiorze T o wartościach w E .

Definicja 1.4. Powiemy, że proces $X = (X_t)_{t \in T}$, $T \subset \mathbb{R}$ *ma przyrosty niezależne* jeśli dla dowolnych indeksów $t_0 \leq t_1 \leq \dots \leq t_n$ ze zbioru T , zmienne losowe $X_{t_0}, X_{t_1} - X_{t_0}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}}$ są niezależne.

Definicja 1.5. Mówimy, że proces stochastyczny $(X_t)_{t \geq 0}$ *ma przyrosty stacjonarne*, jeśli rozkład $X_t - X_s$ zależy tylko od $t - s$ czyli

$$\forall t > s \geq 0 \quad X_t - X_s \sim X_{t-s} - X_0.$$

1.1 Proces Poissona

Definicja 1.6. *Procesem Poissona z parametrem (intensywnością) $\lambda > 0$* nazywamy proces stochastyczny $N = (N_t)_{t \geq 0}$ taki, że

$$N_0 = 0; \tag{P0}$$

$$N \text{ ma przyrosty niezależne}; \tag{P1}$$

$$\text{Dla } 0 \leq s \leq t \text{ zmienna } N_t - N_s \text{ ma rozkład Poiss}(\lambda(t - s)); \tag{P2}$$

$$\text{Trajektorie } N \text{ są prawostronnie ciągłe.} \tag{P3}$$

Przypomnijmy, że zmienna X ma rozkład $\text{Poiss}(\lambda)$, jeśli X przyjmuje wartości naturalne oraz $\mathbb{P}(X = k) = e^{-\lambda} \lambda^k / k!$ dla $k = 0, 1, \dots$

Uwaga 1.7. i) Warunek (P3) oznacza, że dla wszystkich $\omega \in \Omega$, $t \rightarrow N_t(\omega)$ jest funkcją prawostronnie ciągłą na $[0, \infty)$.

ii) Czasami wygodniej jest w definicji procesu Poissona zakładać, że $N_0 = 0$ p.n. oraz, że prawie wszystkie trajektorie N są prawostronnie ciągłe. Tak zmodyfikowana definicja jest niezmiennicza z uwagi na zaburzenia procesu na zbiorze miary zero.

Uwaga 1.8. Proces Poissona (oraz zdefiniowany dalej proces Wienera) stanowią dwa podstawowe przykłady tak zwanych *procesów Levy'ego*. Procesy te mają przyrosty niezależne i stacjonarne oraz prawostronnie ciągłe trajektorie z lewostronnymi granicami.

Uwaga 1.9. Warunki (P0)–(P3) implikują, że prawie wszystkie trajektorie N są niemalejącymi, prawostronnie ciągłymi funkcjami o wartościach naturalnych, z nieskończoną liczbą skoków o wartości 1.

1.1.1 Konstrukcja procesu Poissona

Niech X_1, X_2, \dots będą niezależnymi zmiennymi losowymi o rozkładzie wykładniczym z parametrem λ (czyli mają gęstość $\lambda e^{-\lambda t} \mathbb{1}_{[0, \infty)}(t)$). Określmy

$$S_0 = 0, \quad S_n = \sum_{k=1}^n X_k, \quad n = 1, 2, \dots$$

oraz

$$N_t = \sup\{n : S_n \leq t\}. \tag{1}$$

Twierdzenie 1.10. *Proces stochastyczny $(N_t)_{t \geq 0}$ zdefiniowany wzorem (1) jest procesem Poissona z intensywnością λ .*

Warunki (P0) i (P3) są spełnione w oczywisty sposób, wystarczy więc sprawdzić (P1) i (P2). Najpierw udowodnimy pewien techniczny lemat.

Lemat 1.11. *Załóżmy, że $h : \mathbb{R}_+ \rightarrow \mathbb{C}$ jest funkcją taką, że $|h| \leq 1$ oraz $h(u) = 1$ dla $u \geq u_0$. Wówczas zmienna losowa $Y = \prod_{k=1}^{\infty} h(S_k)$ jest dobrze określona, całkowalna oraz*

$$\mathbb{E}Y = \exp\left(\lambda \int_0^{\infty} (h(u) - 1) du\right).$$

Dowód. Na mocy mocnego prawa wielkich liczb, zmienne S_k zbiegają do nieskończoności prawie na pewno, zatem $h(S_k) = 1$ dla dużych k , czyli zmienna Y jest dobrze określona. Ponadto $|Y| \leq 1$, więc Y jest również całkowalna. Stosując twierdzenie Lebesgue'a o zbieżności zmajoryzowanej dostajemy

$$\mathbb{E}Y = \lim_{n \rightarrow \infty} \mathbb{E} \prod_{k=1}^n h(S_k).$$

Liczymy, stosując zamianę zmiennych

$$\begin{aligned}
& \mathbb{E} \prod_{k=1}^n h(S_k) \\
&= \int_0^\infty \dots \int_0^\infty h(x_1) \cdots h(x_1 + \dots + x_n) \lambda^n e^{-\lambda(x_1 + \dots + x_n)} dx_1 \dots dx_n \\
&= \lambda^n \int_0^\infty h(u_n) e^{-\lambda u_n} \left(\int_{0 \leq u_1 \leq u_2 \leq \dots \leq u_{n-1} \leq u_n} h(u_1) \cdots h(u_{n-1}) du_1 \dots du_{n-1} \right) du_n \\
&= \frac{\lambda^n}{(n-1)!} \int_0^\infty h(u_n) e^{-\lambda u_n} \left(\int_0^{u_n} \dots \int_0^{u_n} h(u_1) \cdots h(u_{n-1}) du_1 \dots du_{n-1} \right) du_n \\
&= \frac{\lambda^n}{(n-1)!} \int_0^\infty h(u) e^{-\lambda u} \left(\int_0^u h(s) ds \right)^{n-1} du,
\end{aligned}$$

gdzie w przedostatniej linijce skorzystaliśmy z tego, że funkcja $h(u_1) \cdots h(u_{n-1})$ jest symetryczna względem permutacji zmiennych u_1, \dots, u_{n-1} . Połóżmy $A := \int_0^\infty (h(u) - 1) du$, wtedy wobec założenia iż $h(u) = 1$ dla $u \geq u_0$ dostajemy

$$\int_0^u h(s) ds = u + \int_0^u (h(s) - 1) ds = u + A \text{ dla } u \geq u_0.$$

Stąd $\mathbb{E} \prod_{k=1}^n h(S_k) = \alpha_n + \beta_n$, gdzie

$$\begin{aligned}
\alpha_n &= \frac{\lambda^n}{(n-1)!} \int_0^{u_0} h(u) e^{-\lambda u} \left[\left(\int_0^u h(s) ds \right)^{n-1} - (u + A)^{n-1} \right] du, \\
\beta_n &= \frac{\lambda^n}{(n-1)!} \int_0^\infty e^{-\lambda u} (u + A)^{n-1} du.
\end{aligned}$$

Zauważmy, że $|h(u)| \leq 1$ oraz $|\int_0^u h(s) ds| \leq u$, a zatem

$$\begin{aligned}
|\alpha_n| &\leq \frac{\lambda^n}{(n-1)!} \int_0^{u_0} (u + |A|)^{n-1} e^{-\lambda u} du \leq \frac{\lambda^n (u_0 + |A|)^{n-1}}{(n-1)!} \int_0^\infty e^{-\lambda u} du \\
&= \frac{(\lambda(u_0 + |A|))^{n-1}}{(n-1)!},
\end{aligned}$$

czyli $\lim_{n \rightarrow \infty} \alpha_n = 0$. By policzyć granicę β_n zauważmy, że

$$\begin{aligned}
\beta_n &= \frac{\lambda^n}{(n-1)!} \sum_{k=0}^{n-1} \binom{n-1}{k} A^k \int_0^\infty u^{n-1-k} e^{-\lambda u} du \\
&= \sum_{k=0}^{n-1} \binom{n-1}{k} \frac{\lambda^n}{(n-1)!} A^k \lambda^{-n+k} (n-k-1)! = \sum_{k=0}^{n-1} \frac{\lambda^k A^k}{k!}.
\end{aligned}$$

Stąd

$$\mathbb{E}Y = \lim_{n \rightarrow \infty} (\alpha_n + \beta_n) = e^{\lambda A}.$$

□

Wniosek 1.12. Załóżmy, że B_1, B_2, \dots, B_n są rozłącznymi, ograniczonymi podzbiarami \mathbb{R}_+ oraz określmy

$$N(B_i) = \#\{k : S_k \in B_i\} = \sum_{k=1}^{\infty} \mathbb{1}_{B_i}(S_k).$$

Wówczas $N(B_1), \dots, N(B_n)$ są niezależnymi zmiennymi losowymi o rozkładzie $\text{Pois}(\lambda m(B_k))$, gdzie m oznacza miarę Lebesgue'a.

Dowód. Policzmy wielowymiarową funkcję charakterystyczną

$$\mathbb{E} \exp \left(i \sum_{k=1}^n t_k N(B_k) \right) = \mathbb{E} \prod_{k=1}^{\infty} h(S_k),$$

gdzie

$$h(x) = \begin{cases} e^{it_k} & x \in B_k \\ 1 & x \notin B_1 \cup \dots \cup B_n. \end{cases}$$

Mamy

$$\int_0^{\infty} (h(u) - 1) du = \sum_{k=1}^n \int_{B_k} (e^{it_k} - 1) du = \sum_{k=1}^n m(B_k)(e^{it_k} - 1),$$

czyli na mocy Lematu 1.11,

$$\mathbb{E} \exp \left(i \sum_{k=1}^n t_k N(B_k) \right) = \exp \left(\lambda \sum_{k=1}^n m(B_k)(e^{it_k} - 1) \right).$$

W szczególności

$$\mathbb{E} \exp(itN(B_k)) = \exp(\lambda m(B_k)(e^{it} - 1)) = \mathbb{E} \exp(it \text{Pois}(\lambda m(B_k))),$$

więc $N(B_k)$ ma rozkład $\text{Pois}(\lambda m(B_k))$, ponadto

$$\mathbb{E} \exp \left(i \sum_{k=1}^n t_k N(B_k) \right) = \prod_{k=1}^n \exp(it_k N(B_k)),$$

a zatem $N(B_1), \dots, N(B_n)$ są niezależnymi zmiennymi losowymi. □

Dowód Twierdzenia 1.10. Zauważmy, że przy oznaczeniach z Wniosku mamy $N_t = N([0, t])$ oraz $N_t - N_s = N((s, t])$ dla $s < t$. Stąd warunki (P1) i (P2) w oczywisty sposób wynikają z Wniosku 1.12. □

1.1.2 Złożony Proces Poissona

Trajektorie procesu Poissona są prawostronnie ciągłe, kawałkami stałe, odległości między skokami są zmiennymi niezależnymi o rozkładzie wykładniczym oraz wszystkie skoki są równe 1. Jeśli odrzucimy ten ostatni warunek, a założymy, iż kolejne skoki są zmiennymi niezależnymi o jednakowym rozkładzie to otrzymamy tzw. *złożony proces Poissona*.

Definicja 1.13. Załóżmy, że $\Delta_1, \Delta_2, \dots$ są niezależnymi zmiennymi losowymi o jednakowym rozkładzie, a $(N_t)_{t \geq 0}$ procesem Poissona z intensywnością λ , niezależnym od zmiennych Δ_i . Wówczas proces $N^\Delta = (N_t^\Delta)_{t \geq 0}$ dany wzorem

$$N_t^\Delta = \begin{cases} 0 & N_t = 0 \\ \sum_{n=1}^{N_t} \Delta_n & N_t > 0 \end{cases}$$

nazywamy *złożonym procesem Poissona*.

Zauważmy, że rozkład złożonego procesu Poissona jest wyznaczony przez dwa parametry – intensywność skoków λ i rozkład pojedynczego skoku Δ_1 . Wygodnie jest zakładać, że $\mathbb{P}(\Delta_1 = 0) = 0$, by uniknąć sytuacji „pozornego skoku”. Zwykły proces Poissona odpowiada sytuacji, gdy $\mathbb{P}(\Delta_1 = 1) = 1$.

Używając Lematu 1.11 można bez trudu wykazać, że

Fakt 1.14. Niech N^Δ będzie złożonym procesem Poissona. Wówczas $N_0^\Delta = 0$, N^Δ ma przyrosty niezależne i stacjonarne oraz trajektorie prawostronnie ciągłe, kawałkami stałe. Odległości między poszczególnymi skokami są zmiennymi niezależnymi, o jednakowym rozkładzie wykładniczym.

1.1.3 *Charakteryzacje Procesu Poissona*

Fakt 1.15. Załóżmy, że $X = (X_t)_{t \geq 0}$ jest procesem stochastycznym takim, że $X_0 = 0$, X ma przyrosty niezależne i stacjonarne oraz trajektorie niemalejące, prawostronnie ciągłe, o wartościach całkowitych, skokach równych 1 oraz zbiegające do ∞ w ∞ . Wówczas X jest procesem Poissona.

Idea dowodu polega na tym, że X_t jest sumą przyrostów $X_{kt/n} - X_{(k+1)t/n}$. Przyrosty te mają jednakowe rozkłady, są niezależne i mają wartości całkowite nieujemne. Pokazuje się, że jak n jest duże to z prawdopodobieństwem bliskim 1 wszystkie przyrosty przyjmują tylko wartości 0 lub 1. Zatem X_t aproksymuje się przez rozkład Bernoulliego $\text{Bin}(n, p_n)$. Pokazujemy dalej, że np_n jest ograniczone czyli przechodząc do podciągu $n_k p_{n_k} \rightarrow \lambda(t)$, a stąd X_t ma rozkład Poissona z parametrem $\lambda(t)$. Dalej już łatwo dowodzimy, że $\lambda(t)$ jest funkcją liniową, niemalejącą, czyli jest postaci λt .

Prawdziwe jest znacznie ogólniejsze twierdzenie charakteryzujące złożone procesy Poissona.

Twierdzenie 1.16. *Załóżmy, że dany jest proces stochastyczny $X = (X_t)_{t \geq 0}$ taki, że $X_0 = 0$, X ma przyrosty niezależne i stacjonarne oraz trajektorie prawostronnie ciągle, kawałkami stałe, ze skończoną liczbą skoków w każdym przedziale skończonym. Wówczas X jest złożonym procesem Poissona.*

1.2 Proces Wienera (Ruch Browna)

Definicja 1.17. *Procesem Wienera (Ruchem Browna) nazywamy proces stochastyczny $W = (W_t)_{t \geq 0}$ taki, że*

$$W_0 = 0; \tag{W0}$$

$$W \text{ ma przyrosty niezależne;} \tag{W1}$$

$$\text{Dla } 0 \leq s < t \text{ zmienna } W_t - W_s \text{ ma rozkład normalny } \mathcal{N}(0, t - s); \tag{W2}$$

$$\text{Trajektorie } W \text{ są ciągle} \tag{W3}$$

Uwaga 1.18. i) Warunek (W3) oznacza, że dla wszystkich $\omega \in \Omega$, $t \rightarrow W_t(\omega)$ jest funkcją ciągłą na $[0, \infty)$.

ii) Czasami wygodniej jest zakładać w definicji procesu Wienera, że $W_0 = 0$ p.n. oraz, że trajektorie W są ciągle z prawdopodobieństwem 1.

iii) Proces Wienera na skończonym przedziale $W = (W_t)_{t \in [0, T]}$ definiujemy w podobny sposób – jedyna różnica to, że w warunku (W2) zakładamy, że $0 \leq s < t \leq T$.

1.2.1 Charakteryzacje procesu Wienera

Najpierw podamy twierdzenie, które znacznie ułatwia sprawdzanie, że dany proces jest procesem Wienera. Musimy wpieryw podać ważną definicję.

Definicja 1.19. *Proces $X = (X_t)_{t \in T}$ nazywamy *gaussowskim*, jeśli wszystkie skończenie wymiarowe rozkłady X są gaussowskie, tzn. wektor $(X_{t_1}, \dots, X_{t_n})$ ma rozkład gaussowski dla dowolnych $t_1, \dots, t_n \in T$.*

Przykłady

1. $X_t = f(t)g$, gdzie $f: T \rightarrow \mathbb{R}$ dowolne oraz $g \sim \mathcal{N}(0, 1)$.
2. Proces Wienera $(W_t)_{t \geq 0}$.
3. Most Browna $X_t = W_t - tW_1$, $0 \leq t \leq 1$.
4. Procesy W_t^2 , $\sin(W_t)$, e^{W_t} nie są gaussowskie.

Twierdzenie 1.20. *Proces $(X_t)_{t \geq 0}$ jest procesem Wienera wtedy i tylko wtedy, gdy jest procesem gaussowskim, o ciągłych trajektoriach, startującym z zera, takim, że $\mathbb{E}X_t = 0$ oraz $\text{Cov}(X_t, X_s) = \min\{t, s\}$.*

Dowód. \Rightarrow : Mamy $\mathbb{E}X_t = \mathbb{E}(X_t - X_0) = 0$ oraz $\text{Var}(X_t) = \text{Var}(X_t - X_0) = t$ na mocy (W0) i (W2). Ponadto, z niezależności przyrostów, otrzymujemy dla $t > s$, $\text{Cov}(X_t, X_s) = \text{Cov}(X_t - X_s, X_s) + \text{Var}(X_s) = 0 + s = \min\{t, s\}$.

\Leftarrow : Dla $t > s$, zmienna losowa $W_t - W_s$ ma rozkład normalny ze średnią 0 i wariancją $\text{Var}(X_t - X_s) = \text{Var}(X_t) + \text{Var}(X_s) - 2\text{Cov}(X_t, X_s) = t - s$, więc zachodzi (W2). By sprawdzić niezależność przyrostów ustalmy $0 \leq t_0 \leq t_1 \leq \dots \leq t_n$. Zauważmy, że wektor $(X_{t_0}, X_{t_1} - X_{t_0}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}})$ ma rozkład gaussowski, więc jego współrzędne są niezależne wtedy i tylko wtedy, gdy są nieskorelowane. Mamy jednak dla $s_1 \leq s_2 \leq s_3 \leq s_4$,

$$\text{Cov}(X_{s_1}, X_{s_3} - X_{s_2}) = \text{Cov}(X_{s_1}, X_{s_3}) - \text{Cov}(X_{s_1}, X_{s_2}) = s_1 - s_1 = 0$$

oraz

$$\text{Cov}(X_{s_2} - X_{s_1}, X_{s_4} - X_{s_3}) = \text{Cov}(X_{s_2}, X_{s_4} - X_{s_3}) - \text{Cov}(X_{s_1}, X_{s_4} - X_{s_3}) = 0.$$

□

Uwaga 1.21. Zauważmy, że jeśli $\mathbb{E}X_0 = 0$ oraz $\text{Var}(X_0) = 0$, to $X_0 = 0$ p.n.

Kolejne twierdzenie pokazuje, że (z dokładnością do drobnych technicznych założeń oraz normalizacji) proces Wienera jest jedynym procesem o ciągłych trajektoriach oraz niezależnych i stacjonarnych przyrostach.

Twierdzenie 1.22. *Załóżmy, że proces $(X_t)_{t \geq 0}$ spełnia warunki (W0), (W1), (W3) (z W zastąpionym przez X) oraz*

$$X \text{ ma przyrosty stacjonarne;} \tag{W2a}$$

$$\mathbb{E}X_1 = 0, \text{ Var}(X_1) = 1; \tag{W2b}$$

$$\mathbb{E}X_t^4 < \infty \text{ dla wszystkich } t > 0. \tag{W2c}$$

Wówczas X_t jest procesem Wienera.

Dowód. Określmy dla $t \geq 0$, $a(t) = \mathbb{E}X_t$ oraz $b(t) = \text{Var}(X_t)$. Zauważmy, że na mocy niezależności i stacjonarności przyrostów,

$$\begin{aligned} b(t+s) &= \text{Var}(X_{t+s} - X_t + X_t) = \text{Var}(X_{t+s} - X_t) + \text{Var}(X_t) \\ &= \text{Var}(X_s) + \text{Var}(X_t) = b(t) + b(s). \end{aligned}$$

Ponadto oczywiście $b(t) \geq 0$, zatem funkcja $b(t)$ jest addytywna i niemalejąca na $[0, \infty)$, więc $b(t) = ct$ dla pewnego $c \geq 0$, co wobec (W2b) daje $\text{Var}(X_t) = b(t) = t$. Analogicznie sprawdzamy, że $a(t+s) = a(t) + a(s)$, wiemy też, że $a(0) = 0$, stąd dowodzimy, że $\mathbb{E}X_t = a(t) = 0$ dla t wymiernych. Weźmy $t > 0$ i wybierzmy dążący do t ciąg liczb wymiernych (t_n) . Warunek (W2c) implikuje $\mathbb{E}X_t^2 < \infty$, wiemy też, że $\mathbb{E}X_{t_n}^2 = \text{Var}(X_{t_n}) = t_n$, zatem

$(\mathbb{E}|X_{t_n} - X_t|^2)^{1/2} \leq M$ dla pewnej stałej M . Z ciągłości trajektorii $X_{t_n} \rightarrow X_t$ prawie na pewno, czyli również według prawdopodobieństwa. Zatem dla $\varepsilon > 0$,

$$\begin{aligned} |\mathbb{E}X_t| &= |\mathbb{E}X_t - \mathbb{E}X_{t_n}| \leq \mathbb{E}|X_t - X_{t_n}| \leq \varepsilon + \mathbb{E}|X_t - X_{t_n}| \mathbb{1}_{\{|X_t - X_{t_n}| \geq \varepsilon\}} \\ &\leq \varepsilon + (\mathbb{E}|X_t - X_{t_n}|^2)^{1/2} \mathbb{P}(|X_t - X_{t_n}| \geq \varepsilon)^{1/2} \\ &\leq \varepsilon + M \mathbb{P}(|X_t - X_{t_n}| \geq \varepsilon)^{1/2} \leq 2\varepsilon \end{aligned}$$

dla dostatecznie dużych n . Stąd, wobec dowolności $\varepsilon > 0$, $\mathbb{E}X_t = 0$. Wykazaliśmy zatem, że X_t ma średnią zero i wariancję t .

Ustalmy $t > s \geq 0$, chcemy pokazać, że $X_t - X_s$ ma rozkład normalny $\mathcal{N}(0, t - s)$. Zauważmy, że

$$X_t - X_s = \sum_{k=1}^n Y_{n,k}, \text{ gdzie } Y_{n,k} = X_{s+k(t-s)/n} - X_{s+(k-1)(t-s)/n}.$$

Zmienne $(Y_{n,k})_{1 \leq k \leq n}$ tworzą układ trójkątny, możemy więc skorzystać z Centralnego Twierdzenia Granicznego i wykazać, że $\sum_{k=1}^n Y_{n,k}$ zbiega do $\mathcal{N}(0, t - s)$ według rozkładu. Mamy

$$\sum_{k=1}^n \mathbb{E}Y_{n,k} = 0, \quad \sum_{k=1}^n \text{Var}(Y_{n,k}) = t - s,$$

wystarczy więc sprawdzić warunek Lindeberga. Dla $\varepsilon > 0$,

$$\begin{aligned} L_n(\varepsilon) &= \sum_{k=1}^n \mathbb{E}|Y_{n,k}|^2 \mathbb{1}_{\{|Y_{n,k}| \geq \varepsilon\}} \leq \mathbb{E} \left[\left(\sum_{k=1}^n |Y_{n,k}|^2 \right) \mathbb{1}_{\{\max_{k \leq n} |Y_{n,k}| \geq \varepsilon\}} \right] \\ &\leq \left(\mathbb{E} \left(\sum_{k=1}^n |Y_{n,k}|^2 \right)^2 \right)^{1/2} \mathbb{P} \left(\max_{k \leq n} |Y_{n,k}| \geq \varepsilon \right)^{1/2}. \end{aligned}$$

Zauważmy, że zmienne $(Y_{n,k})$ dla ustalonego n są niezależne i mają średnią zero, zatem

$$\begin{aligned} \mathbb{E}(X_t - X_s)^4 &= \mathbb{E} \left(\sum_{k=1}^n Y_{n,k} \right)^4 = \sum_{1 \leq k_1, k_2, k_3, k_4 \leq n} \mathbb{E}Y_{n,k_1} Y_{n,k_2} Y_{n,k_3} Y_{n,k_4} \\ &= \sum_{k=1}^n \mathbb{E}Y_{n,k}^4 + 6 \sum_{1 \leq k < l \leq n} \mathbb{E}Y_{n,k}^2 \mathbb{E}Y_{n,l}^2 \\ &\geq \sum_{k=1}^n \mathbb{E}Y_{n,k}^4 + 2 \sum_{1 \leq k < l \leq n} \mathbb{E}Y_{n,k}^2 \mathbb{E}Y_{n,l}^2 = \mathbb{E} \left(\sum_{k=1}^n |Y_{n,k}|^2 \right)^2. \end{aligned}$$

Z ciągłości trajektorii X wynika, że $\mathbb{P}(\max_{k \leq n} |Y_{n,k}| \geq \varepsilon) \rightarrow 0$ przy $n \rightarrow \infty$, zatem $\lim_{n \rightarrow \infty} L_n(\varepsilon) = 0$. \square

Uwaga 1.23. Warunek (W2c) nie jest konieczny - zob. Twierdzenie 5 z paragrafu 13.1 podręcznika [2].

Okazuje się, że również nie trzeba zakładać skończoności wariancji ani nawet istnienia wartości średniej W_1 - warunek (W2b) ma charakter czysto normalizacyjny. Dokładniej zachodzi następujące twierdzenie.

Twierdzenie 1.24. *Załóżmy, że proces stochastyczny $X = (X_t)_{t \geq 0}$ spełnia warunki (W0), (W1), (W2a) i (W3). Wówczas istnieją stałe $a, b \in \mathbb{R}$ i proces Wienera W takie, że $X_t = aW_t + bt$ dla wszystkich $t \geq 0$.*

1.2.2 *Proces Wienera jako granica błędzeń losowych*

Załóżmy, że X_1, X_2, \dots są niezależnymi zmiennymi o jednakowym rozkładzie takim, że $\mathbb{E}X_i = 0$ oraz $\text{Var}(X_i) = \sigma^2 \in (0, \infty)$. Zdefiniujemy błędzenie losowe $(S_n)_{n \geq 0}$ wzorami

$$S_0 = 0. \quad S_n = X_1 + \dots + X_n, \quad n = 1, 2, \dots$$

Centralne twierdzenie graniczne łatwo implikuje, że dla $s < t$, zmienne $\frac{S_{[nt]} - S_{[ns]}}{\sigma\sqrt{n}}$ zbiegają według rozkładu do $\mathcal{N}(0, t - s)$. Zasada niezmienniczości Donskera mówi, że ciąg procesów $(\frac{1}{\sigma\sqrt{n}}S_{[nt]})_{t \geq 0}$ zbiega według rozkładu do procesu Wienera. Sformułowanie tego wyniku w pełnej ogólności jest nieco skomplikowane, gdyż trajektorie $t \rightarrow \frac{1}{\sigma\sqrt{n}}S_{[nt]}$ nie są ciągłe. By ominąć trudności techniczne przedłużmy liniowo ciąg $(S_n)_{n \geq 0}$ do procesu $(S_t)_{t \geq 0}$ kładąc

$$S_t := \theta S_n + (1 - \theta)S_{n+1} = X_1 + \dots + X_n + (1 - \theta)X_{n+1} \quad \text{dla } t = \theta n + (1 - \theta)(n + 1) \in [n, n + 1].$$

Twierdzenie 1.25. *Dla każdego $T < \infty$ ciąg procesów $(\frac{1}{\sigma\sqrt{n}}S_{[nt]})_{t \in [0, T]}$ (traktowany jako wektor losowy o wartościach w przestrzeni $C[0, T]$) zbiega według rozkładu do procesu Wienera $(W_t)_{t \in T}$.*

1.2.3 Konstrukcja procesu Wienera przy pomocy układu Haara

Podczas następnych wykładów podamy dość abstrakcyjną konstrukcję procesu Wienera opartą o ogólniejsze twierdzenia dotyczące istnienia i ciągłości trajektorii procesów stochastycznych. W tym paragrafie omówimy konstrukcję Levy'ego-Ciesielskiego procesu Wienera na $[0, 1]$.

Definicja 1.26. Niech $I(0) = \{1\}, I(n) = \{1, \dots, 2^{n-1}\}, n = 1, 2, \dots$. Układem Haara nazywamy rodzinę funkcji $(h_{n,k})_{k \in I(n), n=0,1,\dots}$ określonych na $[0, 1]$ wzorami $h_{0,1}(t) \equiv 1$ oraz dla $k \in I(n), n \geq 1$,

$$h_{n,k}(t) = \begin{cases} 2^{\frac{n-1}{2}} & \text{dla } (2k-2)2^{-n} \leq t < (2k-1)2^{-n} \\ -2^{\frac{n-1}{2}} & \text{dla } (2k-1)2^{-n} \leq t < 2k \cdot 2^{-n} \\ 0 & \text{w pozostałych przypadkach.} \end{cases}$$

Definicja 1.27. Przy oznaczeniach poprzedniej definicji *układem Schaudera* nazywamy rodzinę funkcji $(S_{n,k})_{n=0,1,\dots,k \in I(n)}$ określonych na $[0, 1]$ wzorem $S_{n,k}(t) = \int_0^t h_{n,k}(s) ds$.

Fakt 1.28. a) Układ Haara jest bazą ortonormalną przestrzeni $L_2[0, 1]$.

b) Dla ustalonego $n \geq 1$, funkcje $(S_{n,k})_{k \in I(n)}$ mają nośniki o rozłącznych wnętrzach oraz $\|S_{n,k}\|_\infty = 2^{-(n+1)/2}$.

Część a) powyższego dowodu jest standardowym faktem z analizy funkcjonalnej, a część b) jest bardzo łatwa do sprawdzenia.

Uwaga 1.29. Układ Haara jest bazą Schaudera w przestrzeniach $L_p[0, 1]$, $1 \leq p < \infty$. Po dodaniu funkcji stałe równej 1, układ Schaudera staje się bazą Schaudera przestrzeni $C[0, 1]$.

Fakt 1.30. Dla dowolnych $t, s \in [0, 1]$ mamy

$$\sum_{n=0}^{\infty} \sum_{k \in I(n)} S_{n,k}(t) S_{n,k}(s) = \min\{t, s\}.$$

Dowód. Najprościej skorzystać z tożsamości Parsewala mówiącej, że dla dowolnej bazy ortonormalnej $(u_i)_{i \in I}$ przestrzeni Hilberta \mathcal{H} oraz dowolnych $f, g \in \mathcal{H}$ zachodzi

$$\langle f, g \rangle = \sum_{i \in I} \langle f, u_i \rangle \langle g, u_i \rangle.$$

Teza faktu wynika z powyższej tożsamości zastosowanej do $\mathcal{H} = L_2[0, 1]$, $f = \mathbb{1}_{[0,s]}$, $g = \mathbb{1}_{[0,t]}$ oraz układu Haara.

Alternatywnie można tezę faktu wykazać za pomocą nieco żmudnych, ale elementarnych rachunków. \square

Lemat 1.31. Niech g będzie zmienną losową o standardowym rozkładzie normalnym $\mathcal{N}(0, 1)$. Wówczas

$$\mathbb{P}(|g| \geq t) = \sqrt{\frac{2}{\pi}} \int_t^\infty e^{-x^2/2} dx \leq e^{-t^2/2}, \quad \text{dla } t \geq 0.$$

Dowód. Niech $f(t) = e^{-t^2/2} - \mathbb{P}(|g| \geq t)$. Wówczas $f'(t) = e^{-t^2/2}(\sqrt{2/\pi} - t)$, czyli f jest rosnąca na $[0, \sqrt{2/\pi}]$ i malejąca na $[\sqrt{2/\pi}, \infty)$. Ponieważ $f(0) = f(\infty) = 0$, więc f jest nieujemna na $[0, \infty)$. \square

Niech $(g_{n,k})_{k \in I(n), n=0,1,\dots}$ będzie rodziną niezależnych zmiennych losowych o rozkładzie $\mathcal{N}(0, 1)$ i

$$W_t^{(m)}(\omega) = \sum_{n=0}^m \sum_{k \in I(n)} g_{n,k}(\omega) S_{n,k}(t).$$

Twierdzenie 1.32. Dla prawie wszystkich $\omega \in \Omega$ ciąg funkcji $(W_t^{(m)}(\omega))$ zbiega jednostajnie na $[0, 1]$ do pewnej funkcji ciągłej $W_t(\omega)$. Jeśli określimy np. $W_t(\omega) = 0$ dla pozostałych ω , to tak zdefiniowany proces stochastyczny jest procesem Wienera na $[0, 1]$.

Dowód. Określimy

$$A_n := \left\{ \max_{k \in I(n)} |g_{n,k}| \geq n \right\}, \quad n = 0, 1, \dots$$

Wówczas $\mathbb{P}(A_n) \leq \sum_{k \in I(n)} \mathbb{P}(|g_{n,k}| \geq n) \leq |I(n)|e^{-n^2/2}$. Zatem $\sum_n \mathbb{P}(A_n) < \infty$, czyli na mocy lematu Borella-Cantelliego $\mathbb{P}(\limsup A_n) = 0$. Weźmy $\omega \notin \limsup A_n$, wówczas istnieje n_0 takie, że $\omega \notin A_n$ dla $n \geq n_0$, czyli $|g_{n,k}(\omega)| \leq n$ dla $n \geq n_0$ i $k \in I(n)$. Z uwagi na rozłączność nośników $S_{n,k}$ i oszacowanie $\|S_{n,k}\|_\infty = 2^{-(n+1)/2}$ implikuje to, że $\|\sum_{k \in I(n)} g_{n,k}(\omega) S_{n,k}(t)\|_\infty \leq n 2^{-(n+1)/2}$ dla $n \geq n_0$. Ponieważ $\sum_n n 2^{-(n+1)/2} < \infty$, więc $W_t^{(m)}(\omega)$ zbiega jednostajnie dla $\omega \notin \limsup A_n$ do pewnego $W_t(\omega)$. Określimy $W_t(\omega) = 0$ dla $\omega \in \limsup A_n$.

Proces $W_t^{(m)}$ ma ciągłe trajektorie, jako skończona kombinacja liniowa funkcji ciągłych, zatem proces W_t ma ciągłe trajektorie. Oczywiście $W_0^{(m)} = 0$, więc $W_0 = 0$.

Zauważmy, że dla ustalonych t_1, \dots, t_k , $(W_{t_1}^{(m)}, \dots, W_{t_k}^{(m)}) \rightarrow (W_{t_1}, \dots, W_{t_k})$ p.n., zatem również według rozkładu. Granica rozkładów gaussowskich ma rozkład gaussowski (wystarczy spojrzeć na funkcję charakterystyczną), więc proces W_t jest gaussowski.

Ustalmy $t \in [0, 1]$, zmienne $g_{n,k} S_{n,k}(t)$ są niezależne i mają średnią 0, zatem są ortogonalne w $L_2(\Omega)$. Ponadto, na mocy Faktu 1.30,

$$\sum_{n=0}^{\infty} \sum_{k \in I(n)} \mathbb{E}|g_{n,k} S_{n,k}(t)|^2 = \sum_{n=0}^{\infty} \sum_{k \in I(n)} S_{n,k}(t)^2 = t < \infty,$$

stąd ciąg $W_t^{(m)}$ jest zbieżny w $L_2(\Omega)$. Ponieważ $W_t^{(m)}$ zbiega do W_t p.n., to $W_t^{(m)}$ zbiega do W_t w $L_2(\Omega)$, a zatem i w $L_1(\Omega)$ W szczególności

$$\mathbb{E}W_t = \lim_{m \rightarrow \infty} \mathbb{E}W_t^{(m)} = 0$$

oraz dla $s \leq t$

$$\text{Cov}(W_t, W_s) = \mathbb{E}W_t W_s = \lim_{m \rightarrow \infty} \mathbb{E}W_t^{(m)} W_s^{(m)} = \sum_{n=0}^{\infty} \sum_{k \in I(n)} S_{n,k}(t) S_{n,k}(s) = \min\{t, s\}.$$

□

Uwaga 1.33. Mając dany proces Wienera $(W_t)_{t \in [0,1]}$ nietrudno skonstruować proces Wienera na całej prostej. Można np. sprawdzić, że $((1+t)W_{\frac{1}{1+t}} - W_1)_{t \geq 0}$ jest takim procesem.

1.2.4 Nieróżniczkowalność trajektorii

Trajektorie procesu Wienera mają wiele ciekawych własności, część z nich poznamy później. W tym paragrafie pokażemy, że mimo iż są ciągłe, to z prawdopodobieństwem 1 nie są różniczkowalne w żadnym punkcie.

Twierdzenie 1.34. *Prawie wszystkie trajektorie procesu Wienera $(W_t)_{t \geq 0}$ są funkcjami nieróżniczkowalnymi w żadnym punkcie, tzn.*

$$\mathbb{P}\left(\exists_{t_0 \geq 0} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) = 0.$$

Dowód. Najpierw pokażemy nieróżniczkowalność trajektorii na $[0, 1)$, tzn.

$$\mathbb{P}\left(\exists_{t_0 \in [0, 1)} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) = 0.$$

Zauważmy, że jeśli funkcja $f: [0, 1] \rightarrow \mathbb{R}$ jest różniczkowalna w $t_0 \in [0, 1)$ oraz $|f'(t_0)| < M$, to $|f(t) - f(t_0)| \leq M|t - t_0|$ dla t dostatecznie bliskich t_0 . Zatem, jeśli $j/n \leq t_0 < (j+1)/n$, to dla dostatecznie dużych n ,

$$\left|f\left(\frac{j+1}{n}\right) - f\left(\frac{j}{n}\right)\right| \leq \left|f\left(\frac{j+1}{n}\right) - f(t_0)\right| + \left|f(t_0) - f\left(\frac{j}{n}\right)\right| \leq M\left(\frac{1}{n} + \frac{1}{n}\right),$$

$$\left|f\left(\frac{j+2}{n}\right) - f\left(\frac{j+1}{n}\right)\right| \leq \left|f\left(\frac{j+2}{n}\right) - f(t_0)\right| + \left|f(t_0) - f\left(\frac{j+1}{n}\right)\right| \leq M\left(\frac{2}{n} + \frac{1}{n}\right)$$

oraz

$$\left|f\left(\frac{j+3}{n}\right) - f\left(\frac{j+2}{n}\right)\right| \leq \left|f\left(\frac{j+3}{n}\right) - f(t_0)\right| + \left|f(t_0) - f\left(\frac{j+2}{n}\right)\right| \leq M\left(\frac{3}{n} + \frac{2}{n}\right).$$

Stąd, jeśli funkcja f jest różniczkowalna w jakimś punkcie przedziału $[0, 1)$, to

$$\exists_{M < \infty} \exists_{m < \infty} \forall_{n \geq m} \exists_{0 \leq j \leq n-3} \forall_{k=0,1,2} \left|f\left(\frac{j+k+1}{n}\right) - f\left(\frac{j+k}{n}\right)\right| \leq \frac{5M}{n}.$$

Czyli

$$\begin{aligned} & \mathbb{P}\left(\exists_{t_0 \in [0, 1)} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) \\ & \leq \mathbb{P}\left(\bigcup_{M=1}^{\infty} \bigcup_{m=1}^{\infty} \bigcap_{n=m}^{\infty} \bigcup_{j=0}^{n-3} \bigcap_{k=0}^2 \left\{|W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n}\right\}\right) \\ & \leq \sum_{M=1}^{\infty} \sum_{m=1}^{\infty} \mathbb{P}\left(\bigcap_{n=m}^{\infty} \bigcup_{j=0}^{n-3} \bigcap_{k=0}^2 \left\{|W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n}\right\}\right). \end{aligned}$$

Z niezależności przyrostów dostajemy

$$\begin{aligned} \mathbb{P}\left(\bigcap_{k=0}^2 \left\{ |W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n} \right\}\right) &= \prod_{k=0}^2 \mathbb{P}\left(|W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n}\right) \\ &= \left(\mathbb{P}\left(|W_{\frac{1}{n}}| \leq \frac{5M}{n}\right)\right)^3 = \left(\mathbb{P}\left(\frac{1}{\sqrt{n}}|W_1| \leq \frac{5M}{n}\right)\right)^3 \\ &= \left(\frac{1}{\sqrt{2\pi}} \int_{-5M/\sqrt{n}}^{5M/\sqrt{n}} e^{-x^2/2} dx\right)^3 \leq \left(\frac{1}{\sqrt{2\pi}} \frac{10M}{\sqrt{n}}\right)^3. \end{aligned}$$

Zatem

$$\mathbb{P}\left(\bigcup_{j=0}^{n-3} \bigcap_{k=0}^2 \left\{ |W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n} \right\}\right) \leq \sum_{j=0}^{n-3} \frac{1000M^3}{n^{3/2}} \leq \frac{1000M^3}{\sqrt{n}},$$

czyli

$$\mathbb{P}\left(\bigcap_{n=m}^{\infty} \bigcup_{j=0}^{n-3} \bigcap_{k=0}^2 \left\{ |W_{\frac{j+k+1}{n}} - W_{\frac{j+k}{n}}| \leq \frac{5M}{n} \right\}\right) = 0$$

i

$$\mathbb{P}\left(\exists_{t_0 \in [0,1]} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) = 0.$$

Nieznacznie modyfikując poprzedni dowód (albo używając faktu, że $\widetilde{W}_t = T^{-1/2}W_{tT}$ też jest procesem Wienera oraz w oczywisty sposób nieróżniczkowalność W na $[0,1]$ jest równoważna nieróżniczkowalności \widetilde{W} na $[0,T]$) dostajemy, że dla $T < \infty$,

$$\mathbb{P}\left(\exists_{t_0 \in [0,T]} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) = 0.$$

By zakończyć dowód wystarczy zauważyć, że

$$\begin{aligned} &\mathbb{P}\left(\exists_{t_0 > 0} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) \\ &= \lim_{N \rightarrow \infty} \mathbb{P}\left(\exists_{t_0 \in [0,N]} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\right) = 0. \end{aligned}$$

□

Uwaga 1.35. Dokładna analiza przedstawionego dowodu pokazuje, że nie wykazaliśmy mierzalności zdarzenia $\{\exists_{t_0} t \rightarrow W_t(\omega) \text{ jest różniczkowalne w } t_0\}$, a jedynie to, że jest ono podzbiorem pewnego zdarzenia miary zero. By uniknąć kłopotów technicznych podobnego rodzaju, wygodnie jest przyjąć, że przestrzeń probabilistyczna $(\Omega, \mathcal{F}, \mathbb{P})$ jest zupełna, tzn. dowolny podzbiór zbioru miary zero jest mierzalny (każdą przestrzeń probabilistyczną można rozszerzyć do przestrzeni zupełnej).

2 Rozkłady Procesów Stochastycznych

W tej części zdefiniujemy rozkład procesu stochastycznego, w szczególności powiemy jakie zdarzenia określone przez proces są mierzalne. Udowodnimy, że rozkład procesu jest wyznaczony przez rozkłady skończenie wymiarowe. Sformułujemy też warunki, które muszą być spełnione, by istniał proces stochastyczny o zadanych rozkładach skończenie wymiarowych.

Przypomnijmy, że jeśli X jest zmienną losową o wartościach w przestrzeni (E, \mathcal{E}) , to *rozkładem* X jest miara probabilistyczna na (E, \mathcal{E}) zadana wzorem

$$\mu_X(A) = \mathbb{P}(X \in A), \quad A \in \mathcal{E}.$$

2.1 σ -ciało zbiorów cylindrycznych

Proces $X = (X_t)_{t \in T}$ możemy traktować jako zmienną losową o wartościach w \mathbb{R}^T . Jakie podzbiory \mathbb{R}^T są wówczas na pewno mierzalne?

Definicja 2.1. Zbiory postaci

$$\{x \in \mathbb{R}^T : (x_{t_1}, \dots, x_{t_n}) \in A\}, \quad t_1, \dots, t_n \in T, A \in \mathcal{B}(\mathbb{R}^n)$$

nazywamy *zbiorami cylindrycznymi*. Przez $\mathcal{B}(\mathbb{R}^T)$ będziemy oznaczać najmniejsze σ -ciało zawierające zbiory cylindryczne i będziemy je nazywać *σ -ciałem zbiorów cylindrycznych*.

Uwaga 2.2. Zauważmy, że

$$\mathcal{B}(\mathbb{R}^T) = \sigma(\{x \in \mathbb{R}^T : x_t \in A\}, \quad t \in T, A \in \mathcal{B}(\mathbb{R})).$$

Uwaga 2.3. Nietrudno wykazać, że jeśli zbiór $A \in \mathcal{B}(\mathbb{R}^T)$, to istnieje zbiór przeliczalny $T_0 \subset T$ taki, że jeśli $x, y \in \mathbb{R}^T$ oraz $x(t) = y(t)$ dla $t \in T_0$ to $x \in A \Leftrightarrow y \in A$.

Przykłady

1. Następujące zbiory należą do $\mathcal{B}(\mathbb{R}^{[0, \infty)})$:

- $\{x : x_s > x_t\}, \quad s > t \geq 0,$
- $\{x : x_{t_1} > 0, x_{t_2} - x_{t_1} > 0, \dots, x_{t_n} - x_{t_{n-1}} > 0\}, \quad 0 \leq t_1 < t_2 < \dots < t_n,$
- $\{x : \forall t < s, t, s \in \mathbb{Q}_+ \quad x_t > x_s\}.$

2. Zbiory

- $\{x : \sup_{t \in T} |x_t| \leq 1\},$
- $\{x : t \rightarrow x_t \text{ ciągle}\}$

nie należą do $\mathcal{B}(\mathbb{R}^T)$, gdy T jest niezdegenerowanym przedziałem.

Definicja 2.4. Rozkładem procesu $X = (X_t)_{t \in T}$ nazywamy miarę probabilistyczną μ_X na $\mathcal{B}(\mathbb{R}^T)$ daną wzorem

$$\mu_X(C) = \mathbb{P}((X_t)_{t \in T} \in C), \quad C \in \mathcal{B}(\mathbb{R}^T).$$

Uwaga 2.5. Załóżmy, że T jest przedziałem (skończonym lub nie). Na przestrzeni funkcji ciągłych $C(T)$ rozważmy topologię zbieżności niemal jednostajnej. Wówczas $\mathcal{B}(\mathbb{R}^T) \cap C(T) = \mathcal{B}(C(T))$, co oznacza, że jeśli proces $X = (X_t)_{t \in T}$ ma ciągłe trajektorie, to X wyznacza rozkład probabilistyczny na przestrzeni funkcji ciągłych $(C(T), \mathcal{B}(C(T)))$. W szczególności proces Wienera wyznacza pewien rozkład probabilistyczny na $C[0, \infty)$.

2.2 Warunki zgodności. Twierdzenie Kołmogorowa o istnieniu procesu

Najprostsze zbiory z $\mathcal{B}(\mathbb{R}^T)$, to zbiory cylindryczne. Miary takich zbiorów to rozkłady skończenie wymiarowe procesu.

Definicja 2.6. Dla procesu $(X_t)_{t \in T}$ o wartościach w \mathbb{R} i $t_1, \dots, t_n \in T$ określamy miarę μ_{t_1, \dots, t_n} na \mathbb{R}^n wzorem

$$\mu_{t_1, \dots, t_n}(A) = \mathbb{P}((X_{t_1}, \dots, X_{t_n}) \in A), \quad A \in \mathcal{B}(\mathbb{R}^n).$$

Rodzinę miar $\{\mu_{t_1, \dots, t_n} : t_1, \dots, t_n \in T \text{ parami różne}\}$ nazywamy rodziną *skończenie wymiarowych rozkładów* procesu X .

Fakt 2.7. Załóżmy, że $X = (X_t)_{t \in T}$ i $Y = (Y_t)_{t \in T}$ są procesami o tych samych skończenie wymiarowych rozkładach, czyli

$$\mathbb{P}((X_{t_1}, \dots, X_{t_n}) \in A) = \mathbb{P}((Y_{t_1}, \dots, Y_{t_n}) \in A)$$

dla wszystkich $t_1, \dots, t_n \in T, A \in \mathcal{B}(\mathbb{R}^n)$. Wówczas X i Y mają ten sam rozkład, tzn.

$$\mathbb{P}(X \in C) = \mathbb{P}(Y \in C) \text{ dla wszystkich } C \in \mathcal{B}(\mathbb{R}^T).$$

Dowód. Rodzina zbiorów cylindrycznych \mathcal{A} tworzy π -układ, a rodzina \mathcal{C} zbiorów C takich, że $\mathbb{P}(X \in C) = \mathbb{P}(Y \in C)$, jest λ -układem zawierającym \mathcal{A} . Zatem z twierdzenia o π - i λ -układach, \mathcal{C} zawiera również σ -ciało generowane przez \mathcal{A} , czyli $\mathcal{B}(\mathbb{R}^T)$. \square

Definicja 2.8. Powiemy, że rodzina skończenie wymiarowych rozkładów

$$\{\mu_{t_1, \dots, t_n} : t_1, \dots, t_n \in T \text{ parami różne}\}$$

spełnia warunki zgodności, jeśli zachodzą następujące warunki:

- i) Dla dowolnych $t_1, t_2, \dots, t_n \in T$, dowolnej permutacji (i_1, \dots, i_n) liczb $(1, \dots, n)$ oraz zbiorów $A_1, A_2, \dots, A_n \in \mathcal{B}(\mathbb{R})$,

$$\mu_{t_1, \dots, t_n}(A_{i_1} \times A_{i_2} \times \dots \times A_{i_n}) = \mu_{t_1, \dots, t_n}(A_1 \times A_2 \times \dots \times A_n).$$

ii) Dla dowolnych $t_1, t_2, \dots, t_{n+1} \in T$ oraz $A_1, A_2, \dots, A_n \in \mathcal{B}(\mathbb{R})$,

$$\mu_{t_1, \dots, t_n, t_{n+1}}(A_1 \times A_2 \times \dots \times A_n \times \mathbb{R}) = \mu_{t_1, \dots, t_n}(A_1 \times A_2 \times \dots \times A_n).$$

Oczywiście rodzina rozkładów skończenie wymiarowych dowolnego procesu stochastycznego spełnia warunki zgodności. Okazuje się, że są to jedyne warunki jakie należy nałożyć na taką rodzinę.

Twierdzenie 2.9. *Załóżmy, że rodzina skończenie wymiarowych rozkładów (μ_{t_1, \dots, t_n}) spełniająca warunki zgodności. Wówczas istnieje proces $(X_t)_{t \in T}$ mający skończenie wymiarowe rozkłady równe (μ_{t_1, \dots, t_n}) .*

Dość techniczny dowód powyższego twierdzenia przedstawimy w osobnej sekcji. Teraz omówimy wnioski i przykłady.

Wniosek 2.10. *Załóżmy, że $T \subset \mathbb{R}$ oraz dana jest rodzina rozkładów skończenie wymiarowych $\{\mu_{t_1, \dots, t_n} : t_1 < t_2 < \dots < t_n, t_1, \dots, t_n \in T\}$ spełniająca warunek*

$$\begin{aligned} \mu_{t_1, \dots, t_n}(A_1 \times \dots \times A_{k-1} \times \mathbb{R} \times A_{k+1} \dots \times A_n) \\ = \mu_{t_1, \dots, t_{k-1}, t_{k+1}, \dots, t_n}(A_1 \times \dots \times A_{k-1} \times A_{k+1} \times \dots \times A_n). \end{aligned}$$

dla wszystkich $t_1 < t_2 < \dots < t_n$, $n \geq 2$, $1 \leq k \leq n$ oraz zbiorów borelowskich A_1, \dots, A_n . Wówczas istnieje proces $(X_t)_{t \in T}$ taki, że $(X_{t_1}, \dots, X_{t_n})$ ma rozkład μ_{t_1, \dots, t_n} dla $t_1 < t_2 < \dots < t_n$.

Dowód. Dla $t_1, \dots, t_n \in T$ parami różnych istnieje permutacja (i_1, \dots, i_n) liczb $(1, \dots, n)$ taka, że $t_{i_1} < t_{i_2} < \dots < t_{i_n}$. Możemy więc określić μ_{t_1, \dots, t_n} jako rozkład wektora (Y_1, \dots, Y_n) takiego, że $(Y_{i_1}, \dots, Y_{i_n})$ ma rozkład $\mu_{t_{i_1}, \dots, t_{i_n}}$. Można sprawdzić, że tak określona rodzina miar (μ_{t_1, \dots, t_n}) spełnia warunki zgodności. \square

Przykłady

1. Jeśli $(\mu_t)_{t \in T}$ jest dowolną rodziną rozkładów na \mathbb{R} , to istnieje rodzina niezależnych zmiennych losowych $(X_t)_{t \in T}$ taka, że X_t ma rozkład μ_t . Używamy tu twierdzenia o istnieniu dla $\mu_{t_1, \dots, t_n} = \mu_{t_1} \otimes \dots \otimes \mu_{t_n}$.
2. Istnieje proces spełniający warunki (W0)-(W2) definicji procesu Wienera. Istotnie dla $0 = t_0 \leq t_1 < t_2 < \dots < t_n$ kładziemy

$$\mu_{t_1, \dots, t_n} \sim (X_1, X_1 + X_2, \dots, X_1 + X_2 + \dots + X_n),$$

gdzie X_1, \dots, X_n są niezależnymi zmiennymi losowymi $X_k \sim \mathcal{N}(0, t_k - t_{k-1})$. Warunki zgodności wynikają wówczas stąd, iż jeśli Y_1, Y_2 są niezależne i $Y_i \sim \mathcal{N}(0, \sigma_i^2)$ dla $i = 1, 2$, to $Y_1 + Y_2 \sim \mathcal{N}(0, \sigma_1^2 + \sigma_2^2)$.

Uwaga 2.11. Dla uproszczenia zakładaliśmy podczas tego wykładu, że proces X_t ma wartości rzeczywiste. Nic się zmieni (poza oczywistymi drobnymi zmianami definicji) dla procesów o wartościach w \mathbb{R}^d . Czasem jednak zachodzi potrzeba rozpatrywania procesów o wartościach w ogólniejszej przestrzeni E . warto więc zauważyć, że

- w Fakcie 2.7 nie wykorzystywaliśmy żadnych własności przestrzeni \mathbb{R} ,
- w dowodzie Twierdzenia 2.9 wykorzystuje się regularność miar na \mathbb{R}^n – by zachodził dla procesów o wartościach w E , wystarczy założyć, że E jest przestrzenią polską (tzn. ośrodkową, zupełną przestrzenią metryczną) z sigma-ciałem zbiorów borelowskich lub dodać warunek regularności rozpatrywanych miar.

2.3 *Dowód twierdzenia o istnieniu procesu*

Dowód Twierdzenia 2.9 opiera się na dwóch ważnych faktach z teorii miary, które przytoczymy bez dowodu. Pierwszy z nich podaje warunek kiedy funkcję skończenie addytywną na ciele zbiorów można przedłużyć do miary.

Twierdzenie 2.12 (Caratheodory’ego o przedłużaniu miary). *Załóżmy, że \mathcal{A} jest ciałem podzbiorów X , a μ_0 skończenie addytywną funkcją z \mathcal{A} w \mathbb{R}_+ . Wówczas μ_0 przedłuża się do miary μ na σ -ciele $\sigma(\mathcal{A})$ wtedy i tylko wtedy, gdy μ_0 jest ciągła w \emptyset , tzn*

$$\text{jeśli } (A_n)_{n=1}^{\infty} \subset \mathcal{A}, A_1 \supset A_2 \supset \dots \text{ oraz } \bigcap_{n=1}^{\infty} A_n = \emptyset, \text{ to } \lim_{n \rightarrow \infty} \mu_0(A_n) = 0. \quad (\text{C})$$

Potrzebny nam też będzie fakt o regularności miar borelowskich na \mathbb{R}^n .

Fakt 2.13. *Każda miara skończona na $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ jest regularna, tzn. dla dowolnego zbioru borelowskiego A ,*

$$\mu(A) = \sup\{\mu(K) : K \text{ jest zwartym podzbiorem } A\}.$$

Dowód Twierdzenia 2.9. Niech \mathcal{A} oznacza algebrę zbiorów cylindrycznych. Dla $C = \{x : (x_{t_1}, \dots, x_{t_n}) \in A\}$, $A \in \mathcal{B}(\mathbb{R}^n)$ położmy $\mu_0(C) = \mu_{t_1, \dots, t_n}(A)$. Zauważmy, że

- z warunków zgodności wynika, że μ_0 jest dobrze zdefiniowane, tzn. $\mu_0(C)$ nie zależy od wyboru t_1, \dots, t_n i A reprezentujących C .
- μ_0 jest skończenie addytywna. Istotnie jeśli $C_1, \dots, C_k \in \mathcal{A}$, to można dobrać odpowiednio duży zbiór indeksów $t_1, \dots, t_n \in T$ taki, że zbiory C_1, \dots, C_k zależą tylko od t_1, \dots, t_n , tzn.

$$C_i = \{x : (x_{t_1}, \dots, x_{t_n}) \in A_i\}, A_i \in \mathcal{B}(\mathbb{R}^n).$$

Załóżmy, że zbiory C_1, \dots, C_k są rozłączne. Wówczas zbiory A_1, \dots, A_k są również rozłączne, a zatem

$$\mu_0\left(\bigcup_{i=0}^k C_i\right) = \mu_{t_1, \dots, t_n}\left(\bigcup_{i=0}^k A_i\right) = \sum_{i=0}^k \mu_{t_1, \dots, t_n}(A_i) = \sum_{i=0}^k \mu_0(C_i).$$

By zakończyć dowód musimy wykazać warunek (C) z twierdzenia Caratheodory'ego, czyli

$$\text{jeśli } C_n \in \mathcal{A}, C_1 \supset C_2 \supset \dots, \mu_0(C_n) \geq \varepsilon > 0, \text{ to } \bigcap_{n=1}^{\infty} C_n \neq \emptyset.$$

Każda miara μ na $(\mathbb{R}^n, \mathcal{B}(\mathbb{R}^n))$ jest regularna (zob. Twierdzenie A.?), tzn. dla dowolnego $A \in \mathcal{B}(\mathbb{R}^n)$,

$$\mu(A) = \sup\{\mu(K) : K \subset A, K \text{ zwarte}\}.$$

Zbiory C_n są cylindryczne, czyli zależą tylko od skończonego zbioru indeksów. Możemy założyć, że te zbiory indeksów rosną, co więcej (ewentualnie powtarzając zbiory C_i lub dodając indeksy) możemy zakładać, że istnieje ciąg t_1, t_2, \dots taki, że

$$C_n = \{x : (x_{t_1}, \dots, x_{t_n}) \in A_n\} \text{ dla pewnego } A_n \in \mathcal{B}(\mathbb{R}^n).$$

Na mocy regularności miary μ_{t_1, \dots, t_n} , istnieją zbiory zwarte $K_n \subset A_n$ takie, że

$$\mu_{t_1, \dots, t_n}(A_n \setminus K_n) \leq \frac{\varepsilon}{2^{n+1}}, \quad n = 1, 2, \dots$$

Oznaczając $D_n = \{x : (x_{t_1}, \dots, x_{t_n}) \in K_n\}$, mamy $\mu_0(C_n \setminus D_n) \leq 2^{-n-1}\varepsilon$. Niech

$$\tilde{D}_n = D_1 \cap \dots \cap D_n = \{x : (x_{t_1}, \dots, x_{t_n}) \in \tilde{K}_n\}, \text{ gdzie}$$

$$\tilde{K}_n = (K_1 \times \mathbb{R}^{n-1}) \cap (K_2 \times \mathbb{R}^{n-2}) \cap \dots \cap (K_{n-1} \times \mathbb{R}) \cap K_n.$$

Ponieważ $C_n \setminus \tilde{D}_n = \bigcup_{k=1}^n (C_n \setminus D_k) \subset \bigcup_{k=1}^n (C_k \setminus D_k)$, więc

$$\mu_0(C_n \setminus \tilde{D}_n) \leq \sum_{k=0}^n \mu_0(C_k \setminus D_k) \leq \sum_{k=1}^{\infty} 2^{-k-1}\varepsilon \leq \frac{\varepsilon}{2}.$$

Zatem $\mu_0(\tilde{D}_n) \geq \mu_0(C_n) - \mu_0(C_n \setminus \tilde{D}_n) \geq \varepsilon - \frac{\varepsilon}{2} > 0$ i w szczególności $\tilde{D}_n \neq \emptyset$. Niech $x^{(n)} \in \tilde{D}_n$, wówczas

$$(x_{t_1}^{(n)}, \dots, x_{t_k}^{(n)}) \in K_k, \quad k = 1, \dots, n.$$

Zbiory K_k są zwarte, co implikuje, że dla dowolnego k , ciąg $(x_{t_k}^{(n)})_{n=1}^{\infty}$ jest ograniczony. Za pomocą metody przekątniowej możemy wybrać podciąg (n_i) taki, że $\lim_{i \rightarrow \infty} x_{t_k}^{(n_i)} = x_{t_k}^{\infty}$ dla $k = 1, 2, \dots$. Ale wówczas, z domkniętości K_k ,

$$(x_{t_1}^{\infty}, \dots, x_{t_k}^{\infty}) = \lim_{n_i \rightarrow \infty} (x_{t_1}^{(n_i)}, \dots, x_{t_k}^{(n_i)}) \in K_k.$$

Określmy $y \in \mathbb{R}^T$ wzorem

$$y_t = \begin{cases} x_t^{\infty} & \text{dla } t \in \{t_1, t_2, \dots\}, \\ 0 & \text{dla } t \notin \{t_1, t_2, \dots\}. \end{cases}$$

Wówczas $y \in \bigcap_{n=1}^{\infty} C_n$, czyli $\bigcap_{n=1}^{\infty} C_n \neq \emptyset$, co chcieliśmy dowieść.

Wiemy zatem, że na $\Omega = \mathbb{R}^T$ istnieje miara probabilistyczna μ rozszerzająca μ_0 . Wtedy dla $t_1, \dots, t_n \in T$ oraz $A \in \mathcal{B}(\mathbb{R}^n)$ mamy

$$\mu(\{x: (x_{t_1}, \dots, x_{t_n}) \in A\}) = \mu_{t_1, \dots, t_n}(A).$$

Zatem na przestrzeni probabilistycznej $(\mathbb{R}^T, \mathcal{B}(\mathbb{R}^T), \mu)$ wystarczy zdefiniować proces X wzorem $X_t(x) = x_t$. \square

3 Ciągłość trajektorii

Wiemy już kiedy istnieje proces o zadanych skończone wymiarowych rozkładach. Nasuwa się pytanie – kiedy taki proces ma ciągle trajektorie? Zanim jednak zastanowimy się nad odpowiedzią wprowadzimy dwa ważne sposoby porównywania procesów.

3.1 Procesy stochastycznie równoważne i nierozróżnialne

Definicja 3.1. Niech $X = (X_t)_{t \in T}$ oraz $Y = (Y_t)_{t \in T}$ będą dwoma procesami stochastycznymi, określonymi na tej samej przestrzeni probabilistycznej. Powiemy, że:

a) X jest *modyfikacją* Y (lub X jest *stochastycznie równoważny* Y), jeśli

$$\forall t \in T \quad \mathbb{P}(X_t = Y_t) = 1.$$

b) X i Y są nierozróżnialne, jeśli

$$\mathbb{P}(\forall t \in T \quad X_t = Y_t) = 1.$$

Zauważmy, że procesy nierozróżnialne są oczywiście stochastycznie równoważne. Ponadto dwa procesy stochastycznie równoważne mają ten sam rozkład. Poniższy przykład pokazuje, że z rozkładu procesu nie można wnioskować o własnościach trajektorii.

Przykład

Niech $Z \geq 0$ będzie dowolną zmienną losową o rozkładzie bezzatomowym tzn. $\mathbb{P}(Z = z) = 0$ dla wszystkich $z \in \mathbb{R}$. Zdefiniujmy dwa procesy na $T = [0, \infty)$:

$$X_t \equiv 0 \quad \text{oraz} \quad Y_t(\omega) = \begin{cases} 0 & \text{dla } t \neq Z(\omega), \\ 1 & \text{dla } t = Z(\omega). \end{cases}$$

Wówczas Y jest modyfikacją X , bo $\mathbb{P}(X_t \neq Y_t) = \mathbb{P}(Z = t) = 0$. Zauważmy jednak, że wszystkie trajektorie Y są nieciągłe, czyli w szczególności $\mathbb{P}(\forall t \neq 0 \quad X_t = Y_t) = 0$, a zatem procesy X i Y nie są nierozróżnialne.

Fakt 3.2. Załóżmy, że T jest przedziałem oraz procesy $X = (X_t)_{t \in T}$ i $Y = (Y_t)_{t \in T}$ mają prawostronnie ciągle trajektorie. Wówczas, jeśli X jest modyfikacją Y , to X i Y są nierozróżnialne.

Dowód. Wybierzmy przeliczalny podzbiór $T_0 \subset T$, gęsty w T , zawierający dodatkowo $\sup T$, jeśli T jest przedziałem prawostronnie domkniętym. Niech

$$A = \{\forall t \in T_0 \ X_t = Y_t\},$$

wówczas $\mathbb{P}(A) = 1$, jako przeliczalne przecięcie zbiorów pełnej miary. Ponadto, jeśli $\omega \in A$, to dla dowolnego $t \in T \setminus \{\sup T\}$,

$$X_t(\omega) = \lim_{s \rightarrow t+, s \in T_0} X_s(\omega) = \lim_{s \rightarrow t+, s \in T_0} Y_s(\omega) = Y_t(\omega),$$

czyli

$$\mathbb{P}(\forall t \in T \ X_t = Y_t) \geq \mathbb{P}(A) = 1.$$

□

3.2 Twierdzenie o ciągłej modyfikacji

Najważniejsze twierdzenie tego wykładu podaje kryterium istnienia modyfikacji procesu, która ma ciągle trajektorie. Zanim sformułujemy dokładny wynik przypomnijmy definicję hölderowskości.

Definicja 3.3. Funkcja $f: [a, b] \rightarrow \mathbb{R}$ jest hölderowsko ciągła z wykładnikiem γ , jeśli dla pewnej stałej $C < \infty$,

$$|f(s) - f(t)| \leq C|t - s|^\gamma \text{ dla wszystkich } s, t \in [a, b].$$

Twierdzenie 3.4. Załóżmy, że $X = (X_t)_{t \in [a, b]}$ jest procesem takim, że

$$\forall t, s \in [a, b] \ \mathbb{E}|X_t - X_s|^\alpha \leq C|t - s|^{1+\beta} \tag{2}$$

dla pewnych stałych dodatnich α, β, C . Wówczas istnieje proces $\tilde{X} = (\tilde{X}_t)_{t \in [a, b]}$, będący modyfikacją procesu X , którego wszystkie trajektorie są ciągłe. Co więcej trajektorie każdej modyfikacji X o ciągłych trajektoriach są, z prawdopodobieństwem 1, hölderowsko ciągłe z dowolnym wykładnikiem $\gamma < \frac{\beta}{\alpha}$.

Wniosek 3.5. Twierdzenie 3.4 jest prawdziwe, gdy przedział $[a, b]$ zastąpimy nieskończonym przedziałem, o ile hölderowskość trajektorii zastąpimy lokalną hölderowskością (tzn. hölderowskością na każdym przedziale skończonym). Co więcej, wystarczy, by warunek (2) zachodził dla $|s - t| \leq \delta$, gdzie δ jest ustaloną liczbą dodatnią.

Dowód. Przedział nieskończony T można zapisać jako przeliczalną sumę przedziałów $[a_n, a_{n+1}]$, długości nie większej od δ . Z Twierdzenia 3.4 wynika istnienie modyfikacji $\tilde{X}_t^{(n)}$ procesu X

na przedziale $[a_n, a_{n+1}]$, o ciągłych trajektoriach. Niech $A_n = \{\tilde{X}_{a_{n+1}}^{(n)} \neq \tilde{X}_{a_{n+1}}^{(n+1)}\}$, wówczas $A = \bigcup_n A_n$ ma miarę zero. Możemy więc położyć:

$$\tilde{X}_t(\omega) = \begin{cases} \tilde{X}_t^{(n)}(\omega) & \text{dla } t \in [a_n, a_{n+1}], \omega \notin A \\ 0 & \text{dla } \omega \in A. \end{cases}$$

□

Dowód Twierdzenia 3.4. Ustalmy $\gamma \in (0, \beta/\alpha)$ i niech

$$D := \{t \in [a, b] : t = 2^{-n}k, n = 1, 2, \dots, k \in \mathbb{Z}\}$$

oznacza zbiór liczb dwójkowo wymiernych z $[a, b]$. Wówczas

$$D = \bigcup_{n=0}^{\infty} D_n, \text{ gdzie } D_n := \{t \in [a, b] : t = 2^{-n}k, k \in \mathbb{Z}\}.$$

Na mocy nierówności Czebyszewa,

$$\mathbb{P}(|X_t - X_s| \geq \varepsilon) \leq \varepsilon^{-\alpha} \mathbb{E}|X_t - X_s|^\alpha \leq C\varepsilon^{-\alpha}|t - s|^{1+\beta},$$

w szczególności

$$\mathbb{P}(|X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| \geq 2^{-\gamma n}) \leq C2^{-n(1+\beta-\alpha\gamma)}.$$

Zatem, dla ustalonego n ,

$$\begin{aligned} \mathbb{P}\left(\max_{a \leq \frac{k}{2^n} < \frac{k+1}{2^n} \leq b} |X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| \geq 2^{-\gamma n}\right) &\leq \sum_{a \leq \frac{k}{2^n} < \frac{k+1}{2^n} \leq b} \mathbb{P}(|X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| \geq 2^{-\gamma n}) \\ &\leq 2^n(b-a)C2^{-n(1+\beta-\alpha\gamma)} = C(b-a)2^{-n(\beta-\alpha\gamma)}. \end{aligned}$$

Zdefiniujmy $A := \limsup A_n$, gdzie

$$A_n := \left\{ \max_{a \leq 2^{-n}k < 2^{-n}(k+1) \leq b} |X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| \geq 2^{-\gamma n} \right\}.$$

Nierówność $\gamma\alpha < \beta$ implikuje, że

$$\sum_{n=1}^{\infty} \mathbb{P}(A_n) \leq \sum_{n=1}^{\infty} C(b-a)2^{-n(\beta-\alpha\gamma)} < \infty.$$

zatem, na mocy lematu Borela-Cantelliego, $\mathbb{P}(A) = 0$, czyli $\mathbb{P}(B) = 1$, gdzie

$$B = \Omega \setminus A = \left\{ \omega : \exists_{n_0(\omega)} \forall_{n \geq n_0(\omega)} \forall_{a \leq 2^{-n}k < 2^{-n}(k+1) \leq b} |X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| < 2^{-\gamma n} \right\}.$$

Założmy, że $\omega \in B$, pokażemy w pierw, indukcyjnie po m , że

$$\forall n \geq n_0(\omega) \forall m \geq n \forall s, t \in D_m \quad |s - t| \leq 2^{-n} \Rightarrow |X_s(\omega) - X_t(\omega)| \leq 2 \sum_{j=n}^m 2^{-\gamma j}. \quad (3)$$

Dla $m = n$, jeśli $|s - t| \leq 2^{-n}$, to możemy przyjąć, że $s = \frac{k}{2^n}, t = \frac{k+1}{2^n}$ i $|X_s - X_t| = |X_{\frac{k+1}{2^n}} - X_{\frac{k}{2^n}}| < 2^{-\gamma n}$ na mocy definicji B .

Założmy zatem, że (3) jest udowodnione dla $m = n, n+1, \dots, M-1$, pokażemy, że zachodzi również dla $m = M$. Niech $s, t \in D_M, s < t$, możemy założyć, że $|s - t| > 2^{-M}$, bo inaczej działa argument przedstawiony w pierwszym kroku indukcji. Połóżmy

$$\tilde{s} = \min\{u \in D_{M-1}, u > s\}, \quad \tilde{t} = \max\{u \in D_{M-1}, u < t\},$$

wówczas $s \leq \tilde{s} \leq \tilde{t} \leq t$, czyli $|\tilde{s} - \tilde{t}| \leq |s - t| \leq 2^{-n}$. Stąd, wobec założenia indukcyjnego, $|X_{\tilde{s}}(\omega) - X_{\tilde{t}}(\omega)| \leq 2 \sum_{j=n}^{M-1} 2^{-\gamma j}$. Ponadto, $|s - \tilde{s}| \leq 2^{-M}, |t - \tilde{t}| \leq 2^{-M}$, czyli

$$\begin{aligned} |X_s(\omega) - X_t(\omega)| &\leq |X_{\tilde{s}}(\omega) - X_{\tilde{t}}(\omega)| + |X_{\tilde{s}}(\omega) - X_s(\omega)| + |X_t(\omega) - X_{\tilde{t}}(\omega)| \\ &\leq 2 \sum_{j=n}^{M-1} 2^{-\gamma j} + 2^{-\gamma M} + 2^{-\gamma M} = 2 \sum_{j=n}^M 2^{-\gamma j}, \end{aligned}$$

co kończy dowód (3).

Wiemy zatem, że dla $\omega \in B$,

$$s, t \in D, |s - t| \leq 2^{-n}, n \geq n_0(\omega) \Rightarrow |X_s(\omega) - X_t(\omega)| \leq 2 \sum_{j=n}^{\infty} 2^{-\gamma j} = C_\gamma 2^{-\gamma n},$$

gdzie C_γ jest stałą zależną tylko od γ . Weźmy teraz dowolne $s, t \in D$ takie, że $|s - t| \leq 2^{-n_0(\omega)}$, wówczas istnieje $n \geq n_0(\omega)$ spełniające $2^{-n-1} < |s - t| \leq 2^{-n}$ i

$$|X_s(\omega) - X_t(\omega)| \leq C_\gamma 2^{-\gamma n} \leq 2^\gamma C_\gamma |s - t|^\gamma.$$

W końcu, dla dowolnych $s, t \in D$, możemy dobrać ciąg $s = s_0 < s_1 < \dots < s_k = t$, $k \leq 2^{n_0(\omega)}(b - a)$ taki, że $s_i \in D, |s_{i+1} - s_i| \leq 2^{-n_0(\omega)}$ i otrzymamy

$$\begin{aligned} |X_s(\omega) - X_t(\omega)| &\leq \sum_{i=1}^k |X_{s_i}(\omega) - X_{s_{i+1}}(\omega)| \leq \sum_{i=1}^k 2^\gamma \tilde{C}_\gamma |s_i - s_{i-1}|^\gamma \\ &\leq (b - a) 2^{n_0(\omega)} 2^\gamma \tilde{C}_\gamma |t - s|^\gamma. \end{aligned}$$

Udowodniliśmy zatem, że dla $\omega \in B$, funkcja $t \rightarrow X_t(\omega)$ jest hölderowsko ciągła na D , w szczególności jest jednostajnie ciągła i w każdym punkcie z $[a, b]$ ma granicę. Połóżmy

$$\tilde{X}_t(\omega) = \begin{cases} \lim_{s \rightarrow t, s \in D} X_s(\omega) & \text{dla } \omega \in B, \\ 0 & \text{dla } \omega \notin B. \end{cases}$$

Wówczas wszystkie trajektorie \tilde{X} są ciągłe (a nawet hölderowsko ciągłe z wykładnikiem γ). Z nierówności Czebyszewa łatwo wynika, że dla dowolnego ciągu $(t_n) \subset D$, zbieżnego do $t \in [a, b]$, $X_{t_n} \rightarrow X_t$ według prawdopodobieństwa. Z drugiej strony $X_{t_n} \rightarrow \tilde{X}_t$ p.n., a więc również według prawdopodobieństwa. Z jednoznaczności granicy wynika, że $\tilde{X}_t = X_t$ p.n., czyli proces \tilde{X} jest modyfikacją X .

Na koniec zauważmy, że trajektorie \tilde{X} są hölderowsko ciągłe z wykładnikiem γ , a skoro wiemy, że wszystkie ciągłe modyfikacje X są nierozróżnialne, to wszystkie ciągłe modyfikacje X mają, z prawdopodobieństwem 1, hölderowsko ciągłe trajektorie z dowolnym wykładnikiem $\gamma < \frac{\alpha}{\beta}$. \square

Wniosek 3.6. *Istnieje proces Wienera, tzn. proces spełniający warunki (W0)-(W3).*

Dowód. Mamy $\mathbb{E}|W_s - W_t|^4 = \mathbb{E}|\sqrt{t-s}W_1|^4 = (s-t)^2 \mathbb{E}W_1^4 = 3(s-t)^2$ i możemy zastosować Wniosek 3.5 z $\beta = 1$, $\alpha = 4$ i $C = 3$. \square

Wniosek 3.7. *Prawie wszystkie trajektorie procesu Wienera są lokalnie Hölderowsko ciągłe z dowolnym parametrem $\gamma < 1/2$.*

Dowód. Mamy $\mathbb{E}|W_s - W_t|^p = (s-t)^{p/2} \mathbb{E}W_1^p = C_p (s-t)^{p/2}$ dla dowolnego $p < \infty$. Stosując wniosek 3.5, z $\beta = p/2 - 1$ i $\alpha = p$, otrzymujemy lokalną Hölderowską ciągłość trajektorii z dowolnym $\gamma < \frac{1}{2} - \frac{1}{p}$. Biorąc $p \rightarrow \infty$ dostajemy tezę. \square

Uwaga 3.8. Prawie wszystkie trajektorie procesu Wienera nie są jednostajnie ciągłe na $[0, \infty)$, nie mogą więc być globalnie Hölderowskie z żadnym wykładnikiem.

Uwaga 3.9. Założenia $\beta > 0$ nie można opuścić – wystarczy rozważyć proces Poissona dla którego $\mathbb{E}|N_t - N_s| = \lambda|t - s|$, a oczywiście proces Poissona przyjmuje wartości całkowite, więc nie ma modyfikacji o ciągłych trajektoriach.

3.3 Inne rodzaje ciągłości procesów

W tym wykładzie koncentrowaliśmy uwagę nad procesami o trajektoriach ciągłych. Warto jednak wspomnieć o innych formach ciągłości procesów stochastycznych.

Definicja 3.10. Niech $X = (X_t)_{t \in T}$ będzie procesem stochastycznym. Mówimy, że
a) proces X jest *stochastycznie ciągły*, jeśli

$$t_n \rightarrow t \Rightarrow X_{t_n} \xrightarrow{\mathbb{P}} X_t.$$

b) proces X jest *ciągły wg p -tego momentu (ciągły w L_p)*, jeśli

$$t_n \rightarrow t \Rightarrow \mathbb{E}|X_{t_n} - X_t|^p \rightarrow 0.$$

Uwaga 3.11. Nietrudno wykazać, że zarówno ciągłość trajektorii jak i ciągłość wg p -tego momentu implikują ciągłość stochastyczną procesu. Z pozostałych czterech implikacji między powyższymi pojęciami ciągłości procesu żadna nie jest prawdziwa bez dodatkowych założeń.

4 Procesy gaussowskie

4.1 Przypomnienie podstawowych faktów o wektorach gaussowskich

Definicja 4.1. Wektor losowy $X = (X_1, \dots, X_n)$ w \mathbb{R}^n nazywamy *gaussowskim*, jeśli ma funkcję charakterystyczną postaci

$$\varphi_X(t) = e^{i\langle t, a \rangle - \frac{\langle Ct, t \rangle}{2}}, \quad t \in \mathbb{R}^n$$

dla pewnego $a \in \mathbb{R}^n$ i symetrycznej, nieujemnie określonej macierzy $C \in M_{n \times n}$. Używamy oznaczenia $X \sim \mathcal{N}(a, C)$. W przypadku, gdy $a = 0$ oraz $C = \text{Id}$, X nazywamy kanonicznym wektorem gaussowskim.

Każdy wektor gaussowski ma ten sam rozkład co afiniczny obraz wektora gaussowskiego – jeśli $X \sim \mathcal{N}(a, C)$, to $X \sim a + \sqrt{C}Y$, gdzie $Y \sim \mathcal{N}(0, \text{Id})$. Wektory gaussowskie są zamknięte ze względu na przekształcenia afiniczne.

Jeśli $X \sim \mathcal{N}(a, C)$, to $\mathbb{E}X = a$ oraz $\text{Cov}(X) = C$. W szczególności rozkład wektora gaussowskiego jest jednoznacznie wyznaczony przez wektor wartości średniej i macierz kowariancji.

Uwaga 4.2. Można wykazać, że $X \sim \mathcal{N}(a, C)$ ma gęstość wtedy i tylko wtedy gdy macierz kowariancji C jest odwracalna i wówczas ta gęstość wynosi

$$g_X(x) = \frac{1}{(2\pi)^{\frac{n}{2}} \sqrt{\det C}} \exp\left(-\frac{\langle C^{-1}(x - a), x - a \rangle}{2}\right).$$

Twierdzenie 4.3. *Jeśli wektor losowy $X = (X_1, X_2, \dots, X_n)$ ma rozkład gaussowski to zmienne X_1, \dots, X_n są niezależne wtedy i tylko wtedy, gdy są nieskorelowane, tzn. gdy $\text{Cov}(X_i, X_j) = 0$ dla $i \neq j$.*

Dowód. \Rightarrow : Dowolne zmienne niezależne są nieskorelowane.

\Leftarrow : Macierz $C = \text{Cov}(X)$ jest diagonalna, zatem

$$\varphi_{(X_1, \dots, X_n)}(t) = e^{i\langle t, a \rangle - \frac{\langle Ct, t \rangle}{2}} = \prod_{j=1}^n e^{it_j a_j - \frac{c_{j,j} t_j^2}{2}} = \prod_{j=1}^n \varphi_{X_j}(t_j),$$

co dowodzi niezależności X_j . □

Uwaga 4.4. Kluczowym założeniem w Twierdzeniu 4.3 jest gaussowskość wektora X , a nie tylko jego współrzędnych. Łatwo skonstruować dwie zależne zmienne X_1, X_2 takie, że $X_i \sim \mathcal{N}(0, 1)$ oraz $\text{Cov}(X_1, X_2) = 0$.

4.2 Procesy gaussowskie – definicja i podstawowe własności

Przypomnijmy definicję, która już się pojawiła przy omawianiu procesu Wienera.

Definicja 4.5. Proces $X = (X_t)_{t \in T}$ nazywamy *gaussowskim*, jeśli wszystkie skończone wymiarowe rozkłady X są gaussowskie czyli wektor $(X_{t_1}, \dots, X_{t_n})$ ma rozkład gaussowski dla dowolnych $t_1, \dots, t_n \in T$.

Przykłady

1. $X_t = f(t)g$, gdzie $f: T \rightarrow \mathbb{R}$ dowolne, a $g \sim \mathcal{N}(0, 1)$.
2. Proces Wienera $(W_t)_{t \geq 0}$.
3. Most Browna $X_t = W_t - tW_1$, $0 \leq t \leq 1$.

Wiemy, że wielowymiarowe rozkłady gaussowskie są wyznaczone przez dwa parametry – wektor wartości średniej i macierz kowariancji. Podobnie jest w przypadku procesów, by sformułować odpowiednie twierdzenie, najpierw wprowadzimy stosowne definicje.

Definicja 4.6. Załóżmy, że $X = (X_t)_{t \in T}$ jest procesem stochastycznym całkownym z kwadratem, tzn. $\mathbb{E}X_t^2 < \infty$ dla wszystkich $t \in T$. Funkcję wartości średniej (wartość średnią procesu) X definiujemy wówczas wzorem $m(t) := \mathbb{E}X_t$, $t \in T$, a funkcję kowariancji X wzorem $K(t, s) := \text{Cov}(X_t, X_s)$, $t, s \in T$. Proces X nazywamy *scentrowanym*, jeśli $m \equiv 0$.

Fakt 4.7. Funkcja kowariancji procesu stochastycznego jest nieujemnie określona tzn.

$$\forall_{t_1, \dots, t_n \in T} \forall_{x_1, \dots, x_n \in \mathbb{R}} \sum_{i, j=1}^n K(t_i, t_j) x_i x_j \geq 0.$$

Dowód. Liczymy

$$\begin{aligned} \sum_{i, j=1}^n K(t_i, t_j) x_i x_j &= \sum_{i, j=1}^n \text{Cov}(X_{t_i}, X_{t_j}) x_i x_j = \text{Cov}\left(\sum_{i=1}^n X_{t_i} x_i, \sum_{j=1}^n X_{t_j} x_j\right) \\ &= \text{Var}\left(\sum_{i=1}^n X_{t_i} x_i\right) \geq 0. \square \end{aligned}$$

Wiemy już, że proces Wienera można scharakteryzować jako scentrowany proces gaussowski o ciągłych trajektoriach i funkcji kowariancji $K(t, s) = \min(t, s)$. Poniższe twierdzenie pokazuje, że rozkład procesu gaussowskiego jest jednoznacznie wyznaczony przez dwie funkcje – wartość średnią i kowariancję.

Twierdzenie 4.8. a) Niech $m: T \rightarrow \mathbb{R}$ będzie dowolną funkcją, a $K: T \times T \rightarrow \mathbb{R}$ symetryczną funkcją nieujemnie określoną. Wówczas istnieje proces gaussowski o wartości średniej m i funkcji kowariancji K .

b) Jeśli dwa procesy gaussowskie mają takie same funkcje kowariancji i wartości średniej, to mają ten sam rozkład.

Dowód. a) Dla $\{t_1, \dots, t_n\} \subset T$ określamy μ_{t_1, \dots, t_n} jako rozkład wektora gaussowskiego (X_1, \dots, X_n) takiego, że $\mathbb{E}X_i = m(t_i)$ oraz $\text{Cov}(X_i, X_j) = K(t_i, t_j)$ (wektor taki istnieje bo macierz $(K(t_i, t_j))_{i, j \leq n}$ jest symetryczna nieujemnie określona. Łatwo sprawdzić (wykorzystując to, że n -wymiarowy rozkład gaussowski jest zadany przez dwa parametry), że rodzina miar (μ_{t_1, \dots, t_n}) spełnia warunki zgodności, zatem z Twierdzenia 2.9 wynika istnienie szukanego procesu.

b) Ponieważ n -wymiarowe rozkłady gaussowskie są wyznaczone przez wektor średniej i macierz kowariancji, więc rozważane dwa procesy mają te same rozkłady skończenie wymiarowe, czyli na mocy Faktu 2.7 mają te same rozkłady. \square

Uwaga 4.9. Załóżmy, że X jest ośrodkową przestrzenią Banacha. Powiemy, że zmienna losowa o wartościach w X ma rozkład gaussowski, jeśli dla dowolnego funkcjonału ciągłego $x^* \in X^*$ zmienna rzeczywista $x^*(X)$ ma rozkład gaussowski. Proces Wienera na skończonym przedziale $[0, T]$ można traktować jako gaussowską zmienną losową o wartościach w $C[0, T]$.

4.3 Proces Ornsteina-Uhlebecka

Definicja 4.10. *Proces Ornsteina-Uhlenbecka z parametrem $\beta > 0$ określamy wzorem*

$$X_t = e^{-\beta t} W_{e^{2\beta t}}, \quad t \in \mathbb{R}.$$

Zauważmy, że zbiór indeksów procesu Ornsteina-Uhlebecka to cała prosta rzeczywista.

Proces Ornsteina-Uhlenbecka jest gaussowski, ma ciągłe trajektorie, średnią zero i funkcję kowariancji

$$K(s, t) = \text{Cov}(X_s, X_t) = e^{-\beta s} e^{-\beta t} e^{2\beta(t \wedge s)} = e^{-\beta|t-s|}.$$

Fakt 4.11. *Proces Ornsteina-Uhlenbecka $(X_t)_{t \in \mathbb{R}}$ jest procesem stacjonarnym, tzn. dla dowolnego $h \in \mathbb{R}$ proces $(X_t)_{t \in \mathbb{R}}$ ma ten sam rozkład, co $(X_{t+h})_{t \in \mathbb{R}}$*

Dowód. Proces $Y_t := X_{t+h}$, $t \in \mathbb{R}$, jest gaussowski, ma średnią zero i funkcję kowariancji równą $K_Y(t, s) = K_X(t+h, s+h) = K_X(t, s)$. Zatem, na mocy twierdzenia 4.8, X i Y mają ten sam rozkład. \square

4.4 Ułamkowy Ruch Browna

Definicja 4.12. Niech $H \in (0, 1]$. Proces gaussowski $(X_t)_{t \in \mathbb{R}}$ o średniej zero, funkcji kowariancji

$$K(s, t) = K_H(s, t) = \frac{1}{2} \left(|s|^{2H} + |t|^{2H} - |t-s|^{2H} \right) \quad (4)$$

oraz ciągłych trajektoriach nazywa się *ułamkowym ruchem Browna z parametrem (Hursta) H* .

Uwaga 4.13. W literaturze się często rozważa ułamkowy ruch Browna tylko na $[0, \infty)$.

Zauważmy, że dla $H = 1/2$ oraz $s, t \geq 0$ dostajemy

$$K_{1/2}(s, t) = K_{1/2}(-s, -t) = \frac{1}{2}(s + t - |t - s|) = s \wedge t, \quad K_{1/2}(-s, t) = \frac{1}{2}(s + t - (t + s)) = 0,$$

zatem jeśli $(X_t)_{t \in \mathbb{R}}$ jest ułamkowym ruchem Browna z parametrem $1/2$, to procesy $(X_t)_{t \geq 0}$ i $(X_{-t})_{t \geq 0}$ są niezależnymi procesami Wienera.

Dla $H = 1$, $K_1(s, t) = st = \text{Cov}(sg, tg)$, gdzie g ma rozkład $\mathcal{N}(0, 1)$, zatem 1-ułamkowy proces Wienera można określić wzorem $X_t = tg$, $t \in \mathbb{R}$.

By udowodnić istnienie ułamkowego ruchu Browna dla $H \in (0, 1)$, sprawdzimy najpierw nieujemną określoność funkcji K_H . Jest ona konsekwencją następującego lematu.

Lemat 4.14. *Dla $0 < H < 1$ istnieje stała $c_H > 0$ taka, że*

$$|t|^{2H} = c_H \int_{\mathbb{R}} \frac{1 - \cos(tx)}{|x|^{2H+1}} dx, \quad t \in \mathbb{R}$$

Dowód. Całka jest dobrze określona, bo w otoczeniu zera funkcja podcałkowa jest rzędu $\frac{1}{2}(tx)^2|x|^{-2H-1} = \frac{1}{2}t^2|x|^{1-2H}$, ponadto jest nieujemna i szacuje się z góry przez $|x|^{-1-2H}$. Wykładnik $1 - 2H$ jest większy od -1 a $-1 - 2H$ mniejszy od -1 , więc funkcja podcałkowa jest całkowalna na \mathbb{R} . Podstawienie $y = tx$ pokazuje, że

$$\int_{\mathbb{R}} \frac{1 - \cos(tx)}{|x|^{2H+1}} dx = |t|^{2H} \int_{\mathbb{R}} \frac{1 - \cos(y)}{|y|^{2H+1}} dy.$$

□

Wniosek 4.15. *Funkcja $K_H(s, t) = \frac{1}{2}(|s|^{2H} + |t|^{2H} - |t - s|^{2H})$ jest nieujemnie określona.*

Dowód. Na mocy lematu mamy

$$\begin{aligned} K_H(s, t) &= \frac{c_H}{2} \int_{\mathbb{R}} \frac{1 - \cos(tx) - \cos(sx) + \cos((t - s)x)}{|x|^{2H+1}} dx \\ &= \frac{c_H}{2} \int_{\mathbb{R}} \frac{(1 - \cos(tx))(1 - \cos(sx)) + \sin(tx) \sin(sx)}{|x|^{2H+1}} dx. \end{aligned}$$

Ponadto funkcje $f_1(s, t) = (1 - \cos(tx))(1 - \cos(sx))$ i $f_2(s, t) = \sin(tx) \sin(sx)$ są nieujemnie określone na $\mathbb{R} \times \mathbb{R}$ dla dowolnego $x \in \mathbb{R}$. □

Twierdzenie 4.16. *Dla dowolnego $H \in (0, 1]$ istnieje ułamkowy ruch Browna z parametrem H .*

Dowód. Dla $H = 1$ wystarczy określić $X_t = tg$, dalej będziemy rozpatrywać $H \in (0, 1)$. Twierdzenie 4.8 oraz wnioski 4.15 implikują istnienie scentrowanego procesu gaussowskiego X_t o funkcji kowariancji $K_H(s, t)$. Zauważmy, że

$$\begin{aligned}\text{Var}(X_t - X_s) &= \text{Var}(X_t) + \text{Var}(X_s) - 2\text{Cov}(X_s, X_t) = K_H(s, s) + K_H(t, t) - 2K_H(s, t) \\ &= |s - t|^{2H}.\end{aligned}$$

Zatem zmienna $X_t - X_s$ ma rozkład normalny $\mathcal{N}(0, |t - s|^{2H})$. Stąd

$$\mathbb{E}|X_t - X_s|^\alpha = c_\alpha |t - s|^{\alpha H}.$$

Twierdzenie 3.4 (zastowane z $\alpha > 1/H$ i $\beta = \alpha H - 1$) implikuje, że proces $(X_t)_{t \in \mathbb{R}}$ ma ciągłą modyfikację, ta modyfikacja to ułamkowy ruch Browna. \square

Uwaga 4.17. Twierdzenie 3.4 implikuje, że z prawdopodobieństwem 1 trajektorie ułamkowego ruchu Browna z parametrem H są lokalnie $H - \varepsilon$ hölderowskie dla każdego $\varepsilon > 0$.

Fakt 4.18. *Ułamkowy ruch Browna*

- i) ma stacjonarne przyrosty, tzn. zmienna $X_t - X_s$ ma ten sam rozkład co $X_{t+h} - X_{s+h}$,
- ii) jest samopodobny z wykładnikiem H , tzn. (X_{at}) ma ten sam rozkład co $(|a|^H X_t)$ dla $a \in \mathbb{R}$.

Dowód. i) Dowód twierdzenia 4.16 pokazuje, że $X_t - X_s$ ma rozkład $\mathcal{N}(0, |t - s|^{2H})$.

ii) Procesy (X_{at}) oraz $(|a|^H X_t)$ są gaussowskie, mają średnią zero i funkcję kowariancji równą $|a|^{2H} K_H(s, t)$. \square

Uwaga 4.19. Nietrudno wykazać, że jeśli całkowny z kwadratem proces $(X_t)_{t \in \mathbb{R}}$ ma stacjonarne przyrosty i jest H -samopodobny dla pewnego $H \neq 0$, to $H \in (0, 1]$ oraz X ma funkcję kowariancji równą $C(|t|^{2H} + |s|^{2H} - |s - t|^{2H})$ dla pewnego $C \geq 0$.

5 Filtracje z czasem ciągłym, Momenty Zatrzymania

Celem tej części jest pokazanie jak zmodyfikować definicje omawiane podczas kursowego wykładu z rachunku prawdopodobieństwa z przypadku czasu dyskretnego na czas ciągły.

Będziemy zakładać, że T jest lewostronnie domkniętym przedziałem (typowo $T = [0, \infty)$), choć większość definicji i wyników można uogólnić na szerszą klasę zbiorów.

5.1 Filtracje

Definicja 5.1. *Filtracja* $(\mathcal{F}_t)_{t \in T}$ przestrzeni probabilistycznej $(\Omega, \mathcal{F}, \mathbb{P})$ nazywamy rosnącą rodziną σ -ciał zawartych w \mathcal{F} , tzn. $\mathcal{F}_t \subset \mathcal{F}_s$ dla $t \leq s$, $t, s \in T$.

Zdarzenia z σ -ciała \mathcal{F}_t możemy interpretować jako zdarzenia obserwowalne do chwili t .

Definicja 5.2. Niech $X = (X_t)_{t \in T}$ będzie procesem stochastycznym. *Filtracją generowaną przez X* nazywamy rodzinę $(\mathcal{F}_t^X)_{t \in T}$ daną wzorem $\mathcal{F}_t^X = \sigma(X_s : s \leq t)$.

Fakt 5.3. *Proces X_t ma przyrosty niezależne wtedy i tylko wtedy, gdy dla dowolnych $s < t$, $s, t \in T$ przyrost $X_t - X_s$ jest niezależny od σ -ciała \mathcal{F}_s^X .*

Dowód. \Rightarrow : Rodzina zdarzeń A niezależnych od $X_t - X_s$ tworzy λ -układ, ponadto, z niezależności przyrostów X , zawiera π -układ zdarzeń postaci $\{X_{t_1} \in A_1, \dots, X_{t_n} \in A_n\}$ dla $t_1 < \dots < t_n \leq s$ (bo $\sigma(X_{t_1}, X_{t_2}, \dots, X_{t_n}) = \sigma(X_{t_1}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}})$).

\Leftarrow : Ustalmy $t_1 < \dots < t_n$ oraz zbiory borelowskie A_1, \dots, A_n . Zdarzenie $\{X_{t_1} \in A_1, X_{t_2} - X_{t_1} \in A_2, \dots, X_{t_{n-1}} - X_{t_{n-2}} \in A_{n-1}\}$ należy do σ -ciała $\mathcal{F}_{t_{n-1}}^X$, więc jest niezależne od zmiennej $X_{t_n} - X_{t_{n-1}}$. Stąd

$$\begin{aligned} & \mathbb{P}(X_{t_1} \in A_1, X_{t_2} - X_{t_1} \in A_2, \dots, X_{t_n} - X_{t_{n-1}} \in A_n) \\ &= \mathbb{P}(X_{t_1} \in A_1, \dots, X_{t_{n-1}} - X_{t_{n-2}} \in A_{n-1}) \mathbb{P}(X_{t_n} - X_{t_{n-1}} \in A_n). \end{aligned}$$

Iterując to rozumowanie pokazujemy, że

$$\begin{aligned} & \mathbb{P}(X_{t_1} \in A_1, X_{t_2} - X_{t_1} \in A_2, \dots, X_{t_n} - X_{t_{n-1}} \in A_n) \\ &= \mathbb{P}(X_{t_1} \in A_1) \mathbb{P}(X_{t_2} - X_{t_1} \in A_2, \dots) \cdots \mathbb{P}(X_{t_n} - X_{t_{n-1}} \in A_n). \quad \square \end{aligned}$$

Definicja 5.4. Proces $X = (X_t)$ nazywamy *zgodnym z filtracją $(\mathcal{F}_t)_{t \in T}$* lub *$\mathcal{F}_t$ -adaptowanym*, jeśli dla wszystkich $t \in T$, X_t jest \mathcal{F}_t mierzalne.

Uwaga 5.5. Oczywiście proces X jest zgodny z filtracją $(\mathcal{F}_t)_{t \in T}$ wtedy i tylko wtedy, gdy $\mathcal{F}_t^X \subset \mathcal{F}_t$ dla $t \in T$. W szczególności każdy proces X jest zgodny z filtracją przez siebie generowaną.

5.2 Momenty Zatrzymania

Definicja 5.6. *Momentem zatrzymania (momentem Markowa, czasem zatrzymania) względem filtracji $(\mathcal{F}_t)_{t \in T}$* nazywamy zmienną losową o wartościach w $T \cup \{\infty\}$ taką, że $\{\tau \leq t\} \in \mathcal{F}_t$ dla wszystkich $t \in T$.

Moment zatrzymania to strategia przerywania eksperymentu losowego (np. zakończenia udziału w pewnej grze losowej) taka, że decyzję o przerywaniu do chwili t podejmujemy tylko na podstawie obserwacji dostępnych w tym czasie.

Przykład. Dla zbioru $A \subset \mathbb{R}$ i procesu stochastycznego $(X_t)_{t \in T}$ określmy

$$\tau_A = \inf\{t \in T : X_t \in A\}.$$

Jeśli $(X_t)_{t \in T}$ jest \mathcal{F}_t -adaptowanym procesem o ciągłych trajektoriach, zaś A zbiorem domkniętym, to τ_A jest momentem zatrzymania względem filtracji (\mathcal{F}_t) .

Dowód. Niech $T_0 \subset T$ będzie gęstym podzbiorem T zawierającym lewy koniec. Z domkniętości zbioru A i ciągłości X dostajemy dla $t \in T$

$$\{\tau_A \leq t\} = \{\exists_{s \leq t} X_s \in A\} = \bigcap_{n=1}^{\infty} \bigcup_{s \leq t, s \in T_0} \{X_s \in A_{1/n}\} \in \mathcal{F}_t,$$

gdzie

$$A_\varepsilon := \{x \in \mathbb{R}^n : d(x, A) < \varepsilon\} \quad (\varepsilon\text{-otoczka zbioru } A). \quad \square$$

Uwaga 5.7. Jeśli w powyższym przykładzie A będzie zbiorem otwartym, to τ_A nie musi być momentem zatrzymania względem filtracji $(\mathcal{F}_t)_{t \in T}$, ale musi być momentem zatrzymania względem filtracji $(\mathcal{F}_{t+})_{t \in T}$, gdzie dla $t < \sup T$

$$\mathcal{F}_{t+} := \bigcap_{s > t} \mathcal{F}_s,$$

a jeśli t jest największym elementem T , to kładziemy $\mathcal{F}_{t+} = \mathcal{F}_t$.

Powyższa uwaga motywuje poniższą definicję, która ma nieco techniczny charakter, ale jest powszechnie używana w teorii procesów.

Definicja 5.8. Filtrację $(\mathcal{F}_t)_{t \in T}$ nazywamy *prawostronnie ciągłą*, jeśli $\mathcal{F}_{t+} = \mathcal{F}_t$ dla wszystkich $t \in T$. Mówimy, że filtracja $(\mathcal{F}_t)_{t \in T}$ *spełnia zwykłe warunki*, jeśli

- jest prawostronnie ciągła,
- dla wszystkich t , \mathcal{F}_t zawiera wszystkie zbiory miary zero, tzn. jeśli $A \in \mathcal{F}$, $\mathbb{P}(A) = 0$, to $A \in \mathcal{F}_t$.

Definicja 5.9. Niech τ będzie momentem zatrzymania względem filtracji $(\mathcal{F}_t)_{t \in T}$. Definiujemy σ -ciało *zdarzeń obserwowalnych do chwili τ* wzorem

$$\mathcal{F}_\tau := \left\{ A \in \mathcal{F}_\infty := \sigma\left(\bigcup_{t \in T} \mathcal{F}_t\right) : \forall t \in T \ A \cap \{\tau \leq t\} \in \mathcal{F}_t \right\}.$$

Fakt 5.10. a) Zbiór \mathcal{F}_τ jest σ -ciałem.

b) Jeśli $\tau \leq \sigma$, to $\mathcal{F}_\tau \subset \mathcal{F}_\sigma$.

c) Zmienna losowa τ jest \mathcal{F}_τ mierzalna.

Dowód. a) Zbiór $\Omega \in \mathcal{F}_\tau$, bo $\Omega \cap \{\tau \leq t\} = \{\tau \leq t\} \in \mathcal{F}_t$. Jeśli $A \in \mathcal{F}_\tau$, to $A' \cap \{\tau \leq t\} = \{\tau \leq t\} \setminus (A \cap \{\tau \leq t\}) \in \mathcal{F}_t$, czyli $A' \in \mathcal{F}_\tau$. Jeśli $A_n \in \mathcal{F}_\tau$ dla $n = 1, 2, \dots$, to $(\bigcup_n A_n) \cap \{\tau \leq t\} = \bigcup_n (A_n \cap \{\tau \leq t\}) \in \mathcal{F}_t$, czyli $\bigcup_n A_n \in \mathcal{F}_\tau$.

b) Weźmy $A \in \mathcal{F}_\tau$, wówczas dla $t \in T$, $A \cap \{\sigma \leq t\} = A \cap \{\tau \leq t\} \cap \{\sigma \leq t\} \in \mathcal{F}_t$, czyli $A \in \mathcal{F}_\sigma$.

c) Wystarczy pokazać, że $\{\tau \leq s\} \in \mathcal{F}_\tau$, ale $\{\tau \leq s\} \cap \{\tau \leq t\} = \{\tau \leq s \wedge t\} \in \mathcal{F}_{s \wedge t} \subset \mathcal{F}_t$. □

Kolejny prosty fakt pozostawiamy do udowodnienia na ćwiczeniach.

Fakt 5.11. *Załóżmy, że τ i σ są momentami zatrzymania. Wówczas $\mathcal{F}_{\tau \wedge \sigma} = \mathcal{F}_\tau \cap \mathcal{F}_\sigma$ oraz zdarzenia $\{\tau < \sigma\}, \{\sigma < \tau\}, \{\tau \leq \sigma\}, \{\sigma \leq \tau\}, \{\tau = \sigma\}$ należą do $\mathcal{F}_{\tau \wedge \sigma}$.*

Okazuje się, że (inaczej niż w przypadku czasu dyskretnego) adaptowalność procesu nie gwarantuje np. mierzalności zmiennych X_τ dla wszystkich momentów zatrzymania τ . Dlatego wprowadzimy jeszcze jedną techniczną definicję.

Definicja 5.12. Proces $X = (X_t)_{t \in T}$ nazywamy *progresywnie mierzalnym* względem filtracji $(\mathcal{F}_t)_{t \in T}$, jeśli dla każdego $t \in T$, funkcja $(s, \omega) \rightarrow X_s(\omega)$ traktowana jako funkcja ze zbioru $T \cap (-\infty, t] \times \Omega$ w \mathbb{R} jest mierzalna względem σ -algebry $\mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t$. Równoważnie

$$\forall t \in T \forall A \in \mathcal{B}(\mathbb{R}) \{(s, \omega) \in T \times \Omega : s \leq t, X_s(\omega) \in A\} \in \mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t.$$

Fakt 5.13. *Załóżmy, że T jest przedziałem oraz dany jest proces $X = (X_t)_{t \in T}$ i filtracja $(\mathcal{F}_t)_{t \in T}$.*

- a) *Jeśli proces X jest progresywnie mierzalny względem (\mathcal{F}_t) , to jest \mathcal{F}_t -adaptowalny.*
- b) *Jeśli proces X jest \mathcal{F}_t -adaptowalny oraz ma prawostronnie ciągle trajektorie, to jest progresywnie mierzalny względem (\mathcal{F}_t) .*

Dowód. a) Zbiór $\{\omega : X_t(\omega) \in A\}$ jest przekrojem zbioru $\{(s, \omega) \in T \times \Omega : s \leq t, X_s(\omega) \in A\}$, a zatem należy do \mathcal{F}_t .

b) Ustalmy $t \in T$ i połóżmy dla $s \in T, s \leq t, X_s^{(n)} := X_{t-2^{-n}k}$, gdzie k jest liczbą całkowitą taką, że $t - 2^{-n}(k+1) < s \leq t - 2^{-n}k$. Wówczas

$$\begin{aligned} & \{(s, \omega) \in T \times \Omega : s \leq t, X_s^{(n)}(\omega) \in A\} \\ &= \bigcup_{k=0}^{\infty} \left(T \cap \left(t - \frac{k+1}{2^n}, t - \frac{k}{2^n} \right] \right) \times \{\omega : X_{t-\frac{k}{2^n}}(\omega) \in A\} \\ &\in \mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t. \end{aligned}$$

Zatem funkcja $X_s^{(n)}(\omega), s \in T \cap (-\infty, t], \omega \in \Omega$ jest $\mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t$ mierzalna. Wobec prawostronnej ciągłości X mamy $X_s(\omega) = \lim_{n \rightarrow \infty} X_s^{(n)}(\omega)$, zatem funkcja $X_s(\omega), s \in T \cap (-\infty, t], \omega \in \Omega$ jest $\mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t$ mierzalna jako granica funkcji mierzalnych. \square

Jeśli τ jest momentem zatrzymania, a $X = (X_t)_{t \in T}$ procesem, to zmienna X_τ jest dobrze zdefiniowana tylko na zbiorze $\{\tau < \infty\}$. Musimy zatem określić co mamy na myśli mówiąc, że zmienna X_τ jest mierzalna.

Definicja 5.14. Mówimy, że zmienna losowa Z określona na zbiorze A jest mierzalna względem σ -ciała \mathcal{G} zawierającego A , jeśli $\{\omega \in A : Z(\omega) \in B\} \in \mathcal{G}$ dla dowolnego zbioru borelowskiego B .

Fakt 5.15. Załóżmy, że $X = (X_t)_{t \in T}$ jest procesem progresywnie mierzalnym względem filtracji $(\mathcal{F}_t)_{t \in T}$, a τ jest momentem zatrzymania. Wówczas zmienna losowa X_τ określona na zbiorze $\{\tau < \infty\} \in \mathcal{F}_\tau$ jest \mathcal{F}_τ mierzalna. Ponadto proces zatrzymany w chwili τ , $X^\tau := (X_{t \wedge \tau})_{t \in T}$ jest progresywnie mierzalny.

Dowód. Odwzorowanie

$$(s, \omega) \rightarrow (\tau(\omega) \wedge s, \omega): T \cap (-\infty, t] \times \Omega \rightarrow T \cap (-\infty, t] \times \Omega$$

jest mierzalne względem σ -ciała $\mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t$. Jeśli złożymy je z odwzorowaniem

$$(s, \omega) \rightarrow X_s(\omega) \text{ mierzalnym z } (T \cap (-\infty, t] \times \Omega, \mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t) \text{ w } \mathbb{R},$$

to otrzymamy odwzorowanie

$$(s, \omega) \rightarrow X_{\tau(\omega) \wedge s}(\omega) \text{ mierzalne z } (T \cap (-\infty, t] \times \Omega, \mathcal{B}(T \cap (-\infty, t]) \otimes \mathcal{F}_t) \text{ w } \mathbb{R}.$$

Stąd wynika progresywna mierzalność procesu X^τ . By zakończyć dowód zauważmy, że

$$\{X_\tau \in A\} \cap \{\tau \leq t\} = \{X_{\tau \wedge t} \in A\} \cap \{\tau \leq t\} \in \mathcal{F}_t$$

na mocy progresywnej mierzalności (a właściwie adaptowalności) X^τ . \square

6 Martyngały z czasem ciągłym

6.1 Definicje i przykłady

Definicja 6.1. Mówimy, że $(X_t)_{t \in T}$ jest *martyngałem* (odp. *podmartyngałem*, *nadmartyngałem*) względem filtracji $(\mathcal{F}_t)_{t \in T}$ lub, że $(X_t, \mathcal{F}_t)_{t \in T}$ jest *martyngałem* (odp. *podmartyngałem*, *nadmartyngałem*), jeśli

- a) dla wszystkich $t \in T$, X_t jest \mathcal{F}_t adaptowalny i $\mathbb{E}|X_t| < \infty$,
- b) dla dowolnych $s, t \in T, s < t$, $\mathbb{E}(X_t | \mathcal{F}_s) = X_s$ p.n. (odp. \geq dla podmartyngału i \leq dla nadmartyngału).

Przykład 1. Jeśli X jest całkowalną zmienną losową, a $(\mathcal{F}_t)_{t \in T}$ dowolną filtracją, to $X_t := \mathbb{E}(X | \mathcal{F}_t)$, $t \in T$ jest martyngałem względem $(\mathcal{F}_t)_{t \in T}$.

Istotnie, całkowalność i mierzalność wynikają z definicji wwo. Ponadto dla $t > s$,

$$\mathbb{E}(X_t | \mathcal{F}_s) = \mathbb{E}(\mathbb{E}(X | \mathcal{F}_t) | \mathcal{F}_s) = \mathbb{E}(X | \mathcal{F}_s) = X \text{ p.n..}$$

Przykład 2. $(W_t)_{t \geq 0}$ jest martyngałem względem naturalnej filtracji $\mathcal{F}_t^W = \sigma(W_s : s \leq t)$. Całkowalność i mierzalność są oczywiste. Ponadto, dla $t > s$ mamy z niezależności przyrostów

$$\mathbb{E}(W_t | \mathcal{F}_s) = \mathbb{E}(W_s | \mathcal{F}_s) + \mathbb{E}(W_t - W_s | \mathcal{F}_s) = W_s + \mathbb{E}(W_t - W_s) = W_s \text{ p.n..}$$

Przykład 3. $(W_t^2)_{t \geq 0}$ jest podmartyngealem, a $(W_t^2 - t)_{t \geq 0}$ martyngealem względem naturalnej filtracji $\mathcal{F}_t^W = \sigma(W_s : s \leq t)$.

Całkowalność i mierzalność są jasne. Ponadto, dla $t > s$

$$\begin{aligned} \mathbb{E}(W_t^2 | \mathcal{F}_s) &= \mathbb{E}(W_s^2 | \mathcal{F}_s) + \mathbb{E}(2W_s(W_t - W_s) | \mathcal{F}_s) + \mathbb{E}((W_t - W_s)^2 | \mathcal{F}_s) \\ &= W_s^2 + 2W_s \mathbb{E}(W_t - W_s) + \mathbb{E}(W_t - W_s)^2 = W_s^2 + t - s \text{ p.n.} \end{aligned}$$

Uwaga 6.2. W ostatnich dwu przykładach filtrację (\mathcal{F}_t^W) można zastąpić filtracją (\mathcal{F}_{t+}^W) .

Fakt 6.3. Załóżmy, że (X_t, \mathcal{F}_t) jest martyngealem (odp. podmartyngealem) o wartościach w przedziale I , zaś $f: I \rightarrow \mathbb{R}$ funkcją wypukłą (odp. wypukłą i niemalejącą) taką, że $\mathbb{E}|f(X_t)| < \infty$ dla wszystkich t . Wówczas $(f(X_t), \mathcal{F}_t)$ jest podmartyngealem.

Dowód. Z nierówności Jensena mamy $\mathbb{E}(f(X_t) | \mathcal{F}_s) \geq f(\mathbb{E}(X_t | \mathcal{F}_s))$ p.n., a ostatnia zmienna jest równa $f(X_s)$ w przypadku martyngeалу i nie mniejsza niż $f(X_s)$ dla podmartyngeалу. \square

6.2 Jednostajna całkowalność

By przenieść twierdzenia martyngealowe z przypadku dyskretnego na przypadek ciągły, wykorzystuje się często metodę aproksymacyjną. Dla uzasadnienia przejścia do granicy potrzebne są dodatkowe założenia o procesie (najczęściej wystarczy prawostronna ciągłość) oraz pewne narzędzia analityczne. Jednym z bardzo użytecznych pojęć jest jednostajna całkowalność – przypomnimy teraz jej definicje, omówimy podstawowe przykłady i własności.

Definicja 6.4. Rodzinę zmiennych losowych $(X_i)_{i \in I}$ nazywamy *jednostajnie całkowalną*, jeśli

$$\lim_{C \rightarrow \infty} \sup_{i \in I} \mathbb{E}|X_i| \mathbb{I}_{\{|X_i| > C\}} = 0.$$

Fakt 6.5. Rodzina zmiennych losowych $(X_i)_{i \in I}$ jest jednostajnie całkowalna wtedy i tylko wtedy, gdy spełnione są następujące dwa warunki

- a) $\sup_{i \in I} \mathbb{E}|X_i| < \infty$,
- b) $\forall \varepsilon > 0 \exists \delta > 0 \mathbb{P}(A) \leq \delta \Rightarrow \sup_{i \in I} \mathbb{E}|X_i| \mathbb{I}_A \leq \varepsilon$.

Dowód. \Rightarrow : Ustalmy $\varepsilon > 0$ i dobierzmy C takie, że $\sup_{i \in I} \mathbb{E}|X_i| \mathbb{I}_{\{|X_i| > C\}} \leq \varepsilon/2$. Wówczas

$$\forall_{i \in I} \mathbb{E}|X_i| \leq C + \mathbb{E}|X_i| \mathbb{I}_{\{|X_i| > C\}} \leq C + \varepsilon/2 < \infty$$

oraz, jeśli $\mathbb{P}(A) < \delta := \frac{\varepsilon}{2C}$, to

$$\mathbb{E}|X_i| \mathbb{I}_A \leq C \mathbb{P}(A) + \mathbb{E}|X_i| \mathbb{I}_{\{|X_i| > C\}} \leq C \delta + \frac{\varepsilon}{2} = \varepsilon.$$

\Leftarrow : Niech $M := \sup_{i \in I} \mathbb{E}|X_i|$ oraz $\delta > 0$ będzie takie, że $\sup_{i \in I} \mathbb{E}|X_i| \mathbb{I}_A \leq \varepsilon$ dla $\mathbb{P}(A) \leq \delta$. Wówczas, jeśli $C = M/\delta$, to $\mathbb{P}(|X_i| > C) < M/C = \delta$ dla dowolnego $i \in I$, czyli $\sup_{i \in I} \mathbb{E}|X_i| \mathbb{I}_{\{|X_i| > C\}} \leq \varepsilon$. \square

Przykłady rodzin jednostajnie całkowalnych

1. Rodzina jednoelementowa $\{Y\}$ taka, że $\mathbb{E}|Y| < \infty$.

Istotnie $\lim_{C \rightarrow \infty} \mathbb{E}|Y|I_{\{|Y|>C\}} = 0$.

2. Rodzina wspólnie ograniczona przez zmienną całkowalną tzn. rodzina $(X_i)_{i \in I}$ taka, że $\forall i \in I |X_i| \leq Y$ oraz $\mathbb{E}Y < \infty$.

Wynika to z Faktu 6.5, poprzedniego przykładu i oczywistej obserwacji $\mathbb{E}|X_i|I_A \leq \mathbb{E}|Y|I_A$.

3. Rodzina uśrednień ustalonej całkowalnej zmiennej losowej, tzn. rodzina postaci $(\mathbb{E}(X|\mathcal{F}_i))_{i \in I}$, gdzie $\mathbb{E}|X| < \infty$, zaś $(\mathcal{F}_i)_{i \in I}$ dowolna rodzina σ -podciał \mathcal{F} .

Na podstawie nierówności Jensena $\mathbb{E}|X_i| = \mathbb{E}|\mathbb{E}(X|\mathcal{F}_i)| \leq \mathbb{E}|X|$, a zatem

$$\mathbb{P}(|X_i| \geq C) \leq \frac{\mathbb{E}|X_i|}{C} \leq \frac{\mathbb{E}|X|}{C} \leq \delta \text{ dla } C \geq \frac{\delta}{\mathbb{E}|X|}.$$

Zbiór $\{|X_i| > C\} \in \mathcal{F}_i$, więc z nierówności Jensena

$$\begin{aligned} \mathbb{E}|X_i|I_{\{|X_i|>C\}} &= \mathbb{E}|\mathbb{E}(X I_{\{|X_i|>C\}}|\mathcal{F}_i)| \leq \mathbb{E}\mathbb{E}(|X|I_{\{|X_i|>C\}}|\mathcal{F}_i) \\ &\leq \mathbb{E}(|X|I_{\{|X_i|>C\}}) \leq \varepsilon, \end{aligned}$$

jeśli tylko dobierzemy odpowiednio małe δ korzystając z jednostajnej całkowalności $\{|X|\}$.

Fakt 6.6. Załóżmy, że $1 \leq p < \infty$, a X_n są zmiennymi losowymi takimi, że rodzina $(|X_n|^p)_{n=1}^\infty$ jest jednostajnie całkowalna. Wówczas X_n zbiega do zmiennej X w L_p wtedy i tylko wtedy, gdy X_n zbiega do X według prawdopodobieństwa.

Dowód. Wystarczy udowodnić, że zbieżność X_n według prawdopodobieństwa implikuje zbieżność w L_p , bo przeciwna implikacja jest zawsze prawdziwa. Załóżmy więc, że $X_n \xrightarrow{\mathbb{P}} X$, wówczas dla pewnego podciągu n_k , X_{n_k} zbiega do X p.n., stąd na mocy Lematu Fatou

$$\mathbb{E}|X|^p = \mathbb{E} \lim |X_{n_k}|^p \leq \liminf \mathbb{E}|X_{n_k}|^p \leq \sup_n \mathbb{E}|X_n|^p < \infty.$$

Zatem rodzina $\{|X_n|^p: n = 1, 2, \dots\} \cup \{|X|^p\}$ jest jednostajnie całkowalna. Ustalmy $\varepsilon > 0$ i dobierzmy $\delta > 0$ tak by dla $\mathbb{P}(A) < \delta$ zachodziło $\mathbb{E}|X_n|^p I_A \leq \varepsilon$ oraz $\mathbb{E}|X|^p I_A \leq \varepsilon$. Mamy

$$\begin{aligned} \mathbb{E}|X_n - X|^p &\leq \varepsilon^p + \mathbb{E}|X_n - X|^p I_{\{|X_n - X|>\varepsilon\}} \\ &\leq \varepsilon^p + 2^p \mathbb{E}|X_n|^p I_{\{|X_n - X|>\varepsilon\}} + 2^p \mathbb{E}|X|^p I_{\{|X_n - X|>\varepsilon\}}, \end{aligned}$$

a ponieważ $X_n \xrightarrow{\mathbb{P}} X$, więc $\mathbb{P}(|X_n - X| > \varepsilon) < \delta$ dla dużych n , czyli

$$\mathbb{E}|X_n - X|^p \leq \varepsilon^p + 2^{p+1} \varepsilon \text{ dla dostatecznie dużych } n.$$

□

Wniosek 6.7. *Jeśli rodzina $(X_n)_{n=1}^\infty$ jest jednostajnie całkowalna oraz X_n zbiega prawie na pewno do zmiennej X , to $\lim_{n \rightarrow \infty} \mathbb{E}X_n \mathbb{1}_A = \mathbb{E}X \mathbb{1}_A$ dla wszystkich zdarzeń A .*

Dowód. Stosujemy Fakt 6.6 i oczywiste szacowanie $|\mathbb{E}X_n \mathbb{1}_A - \mathbb{E}X \mathbb{1}_A| \leq \mathbb{E}|X_n - X|$. \square

6.3 Twierdzenia Dooba o stopowaniu

Zacznijmy od przypomnienia lematu Dooba o stopowaniu martyngałów z czasem dyskretnym.

Lemat 6.8. *Załóżmy, że $(X_n, \mathcal{F}_n)_{0 \leq n \leq N}$ jest martyngałem (odp. nad-, pod-), zaś $0 \leq \tau \leq \sigma \leq N$ dwoma momentami zatrzymania. Wówczas*

$$\mathbb{E}(X_\sigma | \mathcal{F}_\tau) = X_\tau \quad \text{p.n. (odp. } \leq, \geq \text{)}.$$

Dowód. Pokażemy dowód dla martyngałów. Musimy pokazać, że dla $A \in \mathcal{F}_\tau$, $\mathbb{E}X_\tau \mathbb{1}_A = \mathbb{E}X_\sigma \mathbb{1}_A$. Połóżmy $A_k := A \cap \{\tau = k\}$ dla $k = 0, 1, \dots, N$. Mamy

$$(X_\sigma - X_\tau) \mathbb{1}_{A_k} = (X_\sigma - X_k) \mathbb{1}_{A_k} = \sum_{i=k}^{\sigma-1} (X_{i+1} - X_i) \mathbb{1}_{A_k} = \sum_{i=k}^N (X_{i+1} - X_i) \mathbb{1}_{A_k \cap \{\sigma > i\}},$$

zatem

$$\mathbb{E}[(X_\sigma - X_\tau) \mathbb{1}_{A_k}] = \sum_{i=k}^N \mathbb{E}[(X_{i+1} - X_i) \mathbb{1}_{A_k \cap \{\sigma > i\}}] = 0,$$

gdyż $A_k \cap \{\sigma > i\} \in \mathcal{F}_i$. Stąd

$$\mathbb{E}[(X_\sigma - X_\tau) \mathbb{1}_A] = \sum_{k=0}^N \mathbb{E}[(X_\sigma - X_\tau) \mathbb{1}_{A_k}] = 0.$$

Dla nadmartyngałów (podmartyngałów) trzeba niektóre równości zastąpić nierównościami, szczegóły pozostawiamy jako proste ćwiczenie. \square

Uwaga 6.9. Lemat 6.8 nie jest prawdziwy, jeśli nie założymy ograniczoności momentów zatrzymania, np. biorąc $X_n = \sum_{k=1}^n \varepsilon_k$, gdzie ε_k niezależne zmienne losowe takie, że $\mathbb{P}(\varepsilon_k = \pm 1) = 1/2$, $\mathcal{F}_n = \sigma(\varepsilon_1, \dots, \varepsilon_n)$, $\tau = 0$, $\sigma = \inf\{n: X_n = 1\}$ widzimy, że $\mathbb{E}X_\tau = 0 \neq 1 = \mathbb{E}X_\sigma$.

Sformułujemy teraz ciągłą wersję Lematu 6.8.

Twierdzenie 6.10. *a) Załóżmy, że T jest przedziałem, $(X_t)_{t \in T}$ jest prawostronnie ciągłym martyngałem, zaś σ i τ są czasami zatrzymania takimi, że $\sigma \leq \tau \leq t_{\max}$ oraz $t_{\max} \in T$. Wówczas $\mathbb{E}(X_\tau | \mathcal{F}_\sigma) = X_\sigma$ p.n..*

b) Jeśli $(X_t)_{0 \leq t \leq \infty}$ jest prawostronnie ciągłym martyngałem z ostatnim elementem X_∞ to dla dowolnych dwu czasów zatrzymania $\sigma \leq \tau$, $\mathbb{E}(X_\tau | \mathcal{F}_\sigma) = X_\sigma$ p.n.

Dowód. Udowodnimy część a) (część b) można za pomocą zmiany czasu sprowadzić do a)). Zdefiniujemy

$$\tau_n(\omega) := \begin{cases} t_{\max} - \frac{k}{n} & \text{dla } \tau(\omega) \in (t_{\max} - \frac{k+1}{n}, t_{\max} - \frac{k}{n}], k = 0, 1, \dots, n^2, \\ t_{\max} - n & \text{dla } \tau(\omega) \leq t_{\max} - n \end{cases}$$

oraz

$$\sigma_n(\omega) := \begin{cases} t_{\max} - \frac{k}{n} & \text{dla } \sigma(\omega) \in (t_{\max} - \frac{k+1}{n}, t_{\max} - \frac{k}{n}], k = 0, 1, \dots, n^2, \\ t_{\max} - n & \text{dla } \sigma(\omega) \leq t_{\max} - n. \end{cases}$$

Wówczas $\sigma_n \leq \tau_n \leq t_{\max}$ są ograniczonymi czasami zatrzymania przyjmującymi jedynie skończenie wiele wartości. Zatem na mocy Lematu 6.8 mamy $\mathbb{E}(X_{\tau_n} | \mathcal{F}_{\sigma_n}) = X_{\sigma_n}$ p.n., $\mathbb{E}(X_{t_{\max}} | \mathcal{F}_{\sigma_n}) = X_{\sigma_n}$ p.n. oraz $\mathbb{E}(X_{t_{\max}} | \mathcal{F}_{\tau_n}) = X_{\tau_n}$ p.n., w szczególności więc rodziny $(X_{\tau_n})_{n=1}^{\infty}$ oraz $(X_{\sigma_n})_{n=1}^{\infty}$ są jednostajnie całkowalne. Ponieważ $\tau_n \rightarrow \tau+$ oraz $\sigma_n \rightarrow \sigma+$, więc z prawostronnej ciągłości X oraz Faktu 6.6 $X_{\tau_n} \rightarrow X_{\tau}$, $X_{\sigma_n} \rightarrow X_{\sigma}$ p.n. i w L_1 . Weźmy $A \in \mathcal{F}_{\sigma} \subset \mathcal{F}_{\sigma_n}$, wówczas

$$\mathbb{E}X_{\tau}I_A = \lim_{n \rightarrow \infty} \mathbb{E}X_{\tau_n}I_A = \lim_{n \rightarrow \infty} \mathbb{E}X_{\sigma_n}I_A = \mathbb{E}X_{\sigma}I_A,$$

co oznacza, że $\mathbb{E}(X_{\tau} | \mathcal{F}_{\sigma}) = X_{\sigma}$ p.n. □

Uwaga 6.11. Powyższy dowód pokazuje też całkowalność zmiennych X_{τ} i X_{σ} .

Uwaga 6.12. Niewielka modyfikacja dowodu pokazuje, że jeśli $(X_t)_{t \in T}$ jest prawostronnie ciągłym nieujemnym podmartyngealem, zaś σ i τ są czasami zatrzymania takimi, że $\sigma \leq \tau \leq t_{\max}$ oraz $t_{\max} \in T$, to $\mathbb{E}(X_{\tau} | \mathcal{F}_{\sigma}) \geq X_{\sigma}$ p.n.. Nieujemność jest tu potrzebna po to, by z warunków $\mathbb{E}(X_{t_{\max}} | \mathcal{F}_{\sigma_n}) \geq X_{\sigma_n}$ p.n. oraz $\mathbb{E}(X_{t_{\max}} | \mathcal{F}_{\tau_n}) \geq X_{\tau_n}$ wywnioskować jednostajną całkowalność $(X_{\tau_n})_{n=1}^{\infty}$ oraz $(X_{\sigma_n})_{n=1}^{\infty}$.

6.4 Nierówności maksymalne

Lemat 6.13. *Niech $(X_n, \mathcal{F}_n)_{0 \leq n \leq N}$ będzie podmartyngealem, wówczas dla wszystkich $\lambda \geq 0$ mamy*

$$a) \lambda \mathbb{P}\left(\max_{0 \leq n \leq N} X_n \geq \lambda\right) \leq \mathbb{E}X_N \mathbb{1}_{\{\max_{0 \leq n \leq N} X_n \geq \lambda\}} \leq \mathbb{E}X_N^+,$$

$$b) \lambda \mathbb{P}\left(\min_{0 \leq n \leq N} X_n \leq -\lambda\right) \leq \mathbb{E}X_N \mathbb{1}_{\{\min_{0 \leq n \leq N} X_n < -\lambda\}} - \mathbb{E}X_0 \leq \mathbb{E}X_N^+ - \mathbb{E}X_0.$$

Dowód. a) Niech $\tau := \inf\{n : X_n \geq \lambda\}$, z lematu 6.8 dostajemy (wobec $\tau \wedge N \leq N$)

$$\begin{aligned} \mathbb{E}X_N &\geq \mathbb{E}X_{\tau \wedge N} = \mathbb{E}X_{\tau} \mathbb{1}_{\{\max_{0 \leq n \leq N} X_n \geq \lambda\}} + \mathbb{E}X_N \mathbb{1}_{\{\max_{0 \leq n \leq N} X_n < \lambda\}} \\ &\geq \lambda \mathbb{P}\left(\max_{0 \leq n \leq N} X_n \geq \lambda\right) + \mathbb{E}X_N \mathbb{1}_{\{\max_{0 \leq n \leq N} X_n < \lambda\}} \end{aligned}$$

i po przeniesieniu wartości oczekiwanych na jedną stronę dostajemy postulowaną nierówność.

b) Definiujemy $\tau := \inf\{n: X_n \leq -\lambda\}$, z lematu 6.8 dostajemy (wobec $\tau \wedge N \geq 0$)

$$\begin{aligned} \mathbb{E}X_0 &\leq \mathbb{E}X_{\tau \wedge N} = \mathbb{E}X_{\tau} \mathbb{1}_{\{\min_{0 \leq n \leq N} X_n \leq -\lambda\}} + \mathbb{E}X_N \mathbb{1}_{\{\min_{0 \leq n \leq N} X_n > -\lambda\}} \\ &\leq -\lambda \mathbb{P}\left(\min_{0 \leq n \leq N} X_n \leq -\lambda\right) + \mathbb{E}X_N \mathbb{1}_{\{\min_{0 \leq n \leq N} X_n > -\lambda\}} \end{aligned}$$

i znów wystarczy pogrupować wartości oczekiwane. \square

Wniosek 6.14. *Jeśli $(X_n, \mathcal{F}_n)_{0 \leq n \leq N}$ jest martyngałem, bądź nieujemnym podmartyngałem, to*

- a) $\forall_{p \geq 1} \forall_{\lambda \geq 0} \lambda^p \mathbb{P}\left(\max_{0 \leq n \leq N} |X_n| \geq \lambda\right) \leq \mathbb{E}|X_N|^p,$
b) $\forall_{p > 1} \mathbb{E}|X_N|^p \leq \mathbb{E} \max_{0 \leq n \leq N} |X_n|^p \leq \left(\frac{p}{p-1}\right)^p \mathbb{E}|X_N|^p.$

Dowód. a) Funkcja $f(t) = |t|^p$ jest wypukła, niemalejąca na \mathbb{R}_+ , stąd na mocy Faktu 6.3 $|X_n|^p$ jest nieujemnym podmartyngałem, zatem z Lematu 6.13 mamy

$$\lambda^p \mathbb{P}\left(\max_{0 \leq n \leq N} |X_n| \geq \lambda\right) \leq \mathbb{E}|X_N|^p \mathbb{1}_{\{\max_{0 \leq n \leq N} |X_n|^p \geq \lambda^p\}} \leq \mathbb{E}|X_N|^p.$$

b) Niech $X^* := \max_{0 \leq n \leq N} |X_n|$, z rachunku przeprowadzonego powyżej (dla $p = 1$) mamy

$$\lambda \mathbb{P}(X^* \geq \lambda) \leq \mathbb{E}|X_N| \mathbb{1}_{\{X^* \geq \lambda\}}.$$

Stosując kolejno wzór na całkowanie przez części, twierdzenie Fubiniego i nierówność Höldera dostajemy

$$\begin{aligned} \mathbb{E} \max_{0 \leq n \leq N} |X_n|^p &= p \int_0^\infty \lambda^{p-1} \mathbb{P}(X^* \geq \lambda) d\lambda \leq p \int_0^\infty \lambda^{p-2} \mathbb{E}|X_N| \mathbb{1}_{\{X^* \geq \lambda\}} d\lambda \\ &= p \mathbb{E}|X_N| \int_0^{X^*} \lambda^{p-2} d\lambda \leq \frac{p}{p-1} \mathbb{E}|X_N| (X^*)^{p-1} \\ &\leq \frac{p}{p-1} (\mathbb{E}|X_N|^p)^{1/p} (\mathbb{E}(X^*)^p)^{(p-1)/p}. \end{aligned}$$

W przypadku $\mathbb{E}|X_N|^p + \infty$ lub $\mathbb{E}(X^*)^p = 0$ dowodzona nierówność jest oczywista. Jeśli $\mathbb{E}|X_N|^p < \infty$, to $\mathbb{E}|X_n|^p \leq \mathbb{E}|X_N|^p < \infty$ dla $0 \leq n \leq N$ oraz $\mathbb{E}(X^*)^p \leq \mathbb{E} \sum_{n=0}^N |X_n|^p < \infty$. Dzieląc więc otrzymaną poprzednio nierówność stronami przez $(\mathbb{E}(X^*)^p)^{(p-1)/p}$ dostajemy

$$(\mathbb{E}(X^*)^p)^{1/p} \leq \frac{p}{p-1} (\mathbb{E}|X_N|^p)^{1/p}.$$

\square

Udowodnimy teraz *nierówność maksymalną Dooba* w przypadku ciągłym.

Twierdzenie 6.15. *Załóżmy, że $(X_t, \mathcal{F}_t)_{t \in T}$ martyngałem lub nieujemnym podmartyngałem, o prawostronnie ciągłych trajektoriach. Wówczas*

- a) $\forall_{p \geq 1} \forall_{\lambda \geq 0} \lambda^p \mathbb{P} \left(\sup_{t \in T} |X_t| \geq \lambda \right) \leq \sup_{t \in T} \mathbb{E} |X_t|^p,$
b) $\forall_{p > 1} \sup_{t \in T} \mathbb{E} |X_t|^p \leq \mathbb{E} \sup_{t \in T} |X_t|^p \leq \left(\frac{p}{p-1} \right)^p \sup_{t \in T} \mathbb{E} |X_t|^p.$

Uwaga 6.16. Oczywiście jeśli T zawiera element maksymalny t_{\max} , to przy założeniach twierdzenia $\sup_{t \in T} \mathbb{E} |X_t|^p = \mathbb{E} |X_{t_{\max}}|^p$.

Dowód. Jeśli D jest skończonym podzbiorem T , to na podstawie Wniosku 6.14 dostajemy

$$\lambda^p \mathbb{P} \left(\sup_{t \in D} |X_t| \geq \lambda \right) \leq \sup_{t \in D} \mathbb{E} |X_t|^p \leq \sup_{t \in T} \mathbb{E} |X_t|^p.$$

Niech T_0 będzie gęstym podzbiorem T zawierającym prawy koniec T (o ile taki istnieje), zaś D_n wstępującym ciągiem skończonych podzbiorów T_0 takim, że $\bigcup_n D_n = T_0$. Wówczas dla dowolnego $\tilde{\lambda} > 0$ dostajemy na mocy prawostronnej ciągłości

$$\begin{aligned} \tilde{\lambda}^p \mathbb{P} \left(\sup_{t \in T} |X_t| > \tilde{\lambda} \right) &= \tilde{\lambda}^p \mathbb{P} \left(\sup_{t \in T_0} |X_t| > \tilde{\lambda} \right) \\ &= \lim_{n \rightarrow \infty} \tilde{\lambda}^p \mathbb{P} \left(\sup_{t \in D_n} |X_t| > \tilde{\lambda} \right) \leq \sup_{t \in T} \mathbb{E} |X_t|^p. \end{aligned}$$

Biorąc ciąg $\tilde{\lambda}_n \nearrow \lambda$ dostajemy postulowaną w a) nierówność. Nierówność z punktu b) wynika z Wniosku 6.14 w podobny sposób. \square

Uwaga 6.17. Punkt b) twierdzenia 6.15 nie zachodzi dla $p = 1$ – można skonstruować martyngał dla którego $\sup_t \mathbb{E} |X_t| < \infty$, ale $\mathbb{E} \sup_t |X_t| = \infty$. Zachodzi jednak (przy założeniach Twierdzenia 6.15) nierówność

$$\mathbb{E} \sup_{t \in T} |X_t| \leq \frac{e}{e-1} \left(1 + \sup_{t \in T} \mathbb{E} |X_t| \ln^+ |X_t| \right).$$

Wniosek 6.18. *Dla dowolnych $u, s > 0$ zachodzi*

$$\mathbb{P} \left(\sup_{0 \leq t \leq s} W_t \geq u \right) \leq e^{-\frac{u^2}{2s}}.$$

Dowód. Ustalmy $\lambda > 0$, wówczas $M_t := \exp(\lambda W_t - \frac{\lambda^2 t}{2})$ jest martyngałem względem filtracji \mathcal{F}_t^W generowanej przez proces Wienera. Stąd na mocy Twierdzenia 6.15 a) i nieujemności M_t dostajemy

$$\begin{aligned} \mathbb{P}\left(\sup_{0 \leq t \leq s} W_t \geq u\right) &\leq \mathbb{P}\left(\sup_{0 \leq t \leq s} M_t \geq e^{\lambda u - \frac{\lambda^2 s}{2}}\right) \\ &\leq e^{-\lambda u + \frac{\lambda^2 s}{2}} \sup_{0 \leq t \leq s} \mathbb{E}|M_t| = e^{-\lambda u + \frac{\lambda^2 s}{2}} \mathbb{E}M_0 = e^{-\lambda u + \frac{\lambda^2 s}{2}}. \end{aligned}$$

Zatem

$$\mathbb{P}\left(\sup_{0 \leq t \leq s} W_t \geq u\right) \leq \inf_{\lambda > 0} e^{-\lambda u + \frac{\lambda^2 s}{2}} = e^{-\frac{u^2}{2s}}.$$

□

7 Twierdzenia o zbieżności martyngałów

7.1 Przejścia w dół przez przedział

Definicja 7.1. Załóżmy, że $I \subset \mathbb{R}$, $f: I \rightarrow \mathbb{R}$ oraz $\alpha < \beta$. Jeśli I jest skończone, to określamy

$$\tau_1 := \inf\{t \in I: f(t) \geq \beta\} \text{ oraz } \sigma_1 := \inf\{t \in I: t > \tau_1, f(t) \leq \alpha\}$$

i dalej indukcyjnie dla $i = 1, 2, \dots$

$$\tau_{i+1} := \inf\{t \in I: t > \sigma_i, f(t) \geq \beta\} \text{ oraz } \sigma_{i+1} := \inf\{t \in I: t > \tau_{i+1}, f(t) \leq \alpha\}.$$

oraz definiujemy

$$D_I(f, [\alpha, \beta]) := \sup\{j: \sigma_j < \infty\} \vee 0$$

W przypadku, gdy I jest nieskończone kładziemy

$$D_I(f, [\alpha, \beta]) := \sup\{D_F(f, [\alpha, \beta]): F \subset I \text{ skończone}\}.$$

Wielkość $D_I(f, [\alpha, \beta])$ nazywamy *liczbą przejść w dół funkcji f przez przedział $[\alpha, \beta]$* .

Przypomnijmy fakt z rachunku prawdopodobieństwa wiążący skończoność liczby przejść ciągu przez przedział z istnieniem granicy

Lemat 7.2. *Ciąg liczbowy x_n jest zbieżny do pewnej, niekoniecznie skończonej granicy wtedy i tylko wtedy, gdy $D_{\mathbb{N}}((x_n), [\alpha, \beta]) < \infty$ dla dowolnych liczb wymiernych $\alpha < \beta$.*

Następny lemat jest niewielką modyfikacją poprzedniego.

Lemat 7.3. *Jeśli $f: [a, b) \rightarrow \mathbb{R}$, $b \leq \infty$ jest prawostronnie ciągłą funkcją taką, że dla dowolnych liczb wymiernych $\alpha < \beta$, $D_{[a,b) \cap \mathbb{Q}}(f, [\alpha, \beta]) < \infty$, to istnieje (niekoniecznie skończona) granica $\lim_{t \rightarrow b} f(t)$.*

Dowód. Załóżmy, że postulowana granica nie istnieje, wtedy można znaleźć liczby wymierne α, β takie, że

$$\liminf_{t \rightarrow b} f(t) < \alpha < \beta < \limsup_{t \rightarrow b} f(t).$$

Stąd wynika, że istnieje rosnący ciąg liczb wymiernych t_n z przedziału $[a, b)$ taki, że $f(t_{2k-1}) \geq \beta$ oraz $f(t_{2k}) \leq \alpha$. Przyjmując $I = \{t_1, t_2, \dots\}$ widzimy, że $D_{[a,b) \cap \mathbb{Q}}(f, [\alpha, \beta]) \geq D_I(f, [\alpha, \beta]) = \infty$. \square

Lemat 7.4. *Założmy, że $X = (X_t)_{t \in T}$ jest podmartyngałem względem pewnej filtracji, a F jest przeliczalnym podzbiorem T , wówczas*

$$\mathbb{E}D_F(X, [\alpha, \beta]) \leq \sup_{t \in F} \frac{\mathbb{E}(X_t - \beta)^+}{\beta - \alpha}.$$

Dowód. Stosując twierdzenie Lebesgue'a o zbieżności monotonicznej widzimy, że wystarczy udowodnić lemat dla skończonych zbiorów F , dla uproszczenia notacji możemy oczywiście przyjąć, że $F = \{1, 2, \dots, N\}$. Zauważmy, że (przy oznaczeniach jak w Definicji 7.1)

$$X_{\tau_i \wedge N} - X_{\sigma_i \wedge N} = \begin{cases} X_{\tau_i} - X_{\sigma_i} \geq \beta - \alpha & \text{gdy } \sigma_i < \infty, \\ X_{\tau_i} - X_N \geq \beta - X_N \geq -(X_N - \beta)^+ & \text{gdy } \tau_i < \sigma_i = \infty, \\ X_N - X_N = 0 & \text{gdy } \tau_i = \infty. \end{cases}$$

Zatem

$$\sum_{i=1}^N (X_{\tau_i \wedge N} - X_{\sigma_i \wedge N}) \geq (\beta - \alpha)D_F(X, [\alpha, \beta]) - (X_N - \beta)^+.$$

Na mocy Lematu 6.8, $\mathbb{E}X_{\tau_i \wedge N} \leq \mathbb{E}X_{\sigma_i \wedge N}$, więc

$$0 \geq \mathbb{E} \sum_{i=1}^N (X_{\tau_i \wedge N} - X_{\sigma_i \wedge N}) \geq \mathbb{E}(\beta - \alpha)D_F(X, [\alpha, \beta]) - \mathbb{E}(X_N - \beta)^+.$$

\square

Tu się zakończył wykład 29 kwietnia

7.2 Zbieżność prawie na pewno

Przypomnijmy twierdzenie dotyczące zbieżności podmartyngałów z czasem dyskretnym:

Twierdzenie 7.5. *Założmy, że $(X_n)_{n \in \mathbb{N}}$ jest podmartyngałem względem pewnej filtracji takim, że $\sup_{n \in \mathbb{N}} \mathbb{E}X_n^+ < \infty$ (lub nadmartyngałem takim, że $\sup_{n \in \mathbb{N}} \mathbb{E}X_n^- < \infty$), wówczas $X = \lim_{n \rightarrow \infty} X_n$ istnieje i jest skończona p.n., ponadto $\mathbb{E}|X| < \infty$.*

Sformułujemy teraz odpowiednik powyższego twierdzenia dla czasu ciągłego.

Twierdzenie 7.6. *Załóżmy, że $(X_t)_{t \in [a,b]}$, $b \leq \infty$ jest podmartyngelem o prawostronnie ciągłych trajektoriach takim, że $\sup_{t \in [a,b]} \mathbb{E}X_t^+ < \infty$. Wówczas $X = \lim_{t \rightarrow b} X_t$ istnieje i jest skończony p.n., ponadto $\mathbb{E}|X| < \infty$.*

Dowód. Dla ustalonego $\alpha < \beta$ na podstawie Lematu 7.4 mamy

$$\mathbb{E}D_{[a,b) \cap \mathbb{Q}}(X_t, [\alpha, \beta]) \leq \frac{1}{\beta - \alpha} \sup_{t \in [a,b)} \mathbb{E}(X_t - \beta)^+ < \infty,$$

zatem $\mathbb{P}(D_{[a,b) \cap \mathbb{Q}}(X_t, [\alpha, \beta]) = \infty) = 0$. Niech

$$A := \bigcap_{\alpha, \beta \in \mathbb{Q}, \alpha < \beta} \{D_{[a,b) \cap \mathbb{Q}}(X_t, [\alpha, \beta]) < \infty\},$$

wówczas $\mathbb{P}(A) = 1$, bo A jest przecięciem przeliczalnej liczby zbiorów pełnej miary. Jeśli $\omega \in A$, to $D_{[a,b) \cap \mathbb{Q}}(X_t(\omega), [\alpha, \beta]) < \infty$ dla dowolnych liczb wymiernych $\alpha < \beta$, czyli na podstawie Lematu 7.3 granica $X(\omega) := \lim_{t \rightarrow b} X_t(\omega)$ istnieje (choć apriori może być nieskończona). Zauważmy, że $\mathbb{E}|X_t| = 2\mathbb{E}X_t^+ - \mathbb{E}X_t \leq 2\mathbb{E}X_t^+ - \mathbb{E}X_0$, zatem $\sup_{t \in [a,b)} \mathbb{E}|X_t| < \infty$. Z Lematu Fatou

$$\mathbb{E}|X| = \mathbb{E} \lim_{t \rightarrow b} |X_t| \leq \liminf_{t \rightarrow \infty} \mathbb{E}|X_t| \leq \sup_t \mathbb{E}|X_t| < \infty,$$

czyli zmienna X jest całkowalna, a więc w szczególności skończona p.n. □

Wniosek 7.7. *Załóżmy, że $(X_t)_{t \geq 0}$ jest niedodatnim podmartyngelem (lub nieujemnym nadmartyngelem) o prawostronnie ciągłych trajektoriach, wówczas $X = \lim_{t \rightarrow \infty} X_t$ istnieje i jest skończony p.n., ponadto $\mathbb{E}|X| < \infty$.*

Literatura

- [1] P. Billingsley *Prawdopodobieństwo i miara*, wyd. II, PWN, Warszawa 2009.
- [2] J. Jakubowski, R. Sztencel, *Wstęp do teorii prawdopodobieństwa*, wyd. IV, Script, Warszawa 2010.
- [3] I. Karatzas, S. Shreve, *Brownian Motion and Stochastic Calculus*, 2nd edition, Springer-Verlag, New York 1997.
- [4] R. Latała, *Wstęp do Analizy Stochastycznej*, Uniwersytet Warszawski, 2011, <https://mst.mimuw.edu.pl/wyklady/was/wyklad.pdf>.
- [5] D. Revuz, M. Yor, *Continuous martingales and Brownian Motion*, 3rd edition, Springer-Verlag, Berlin 1999

- [6] A. Talarczyk-Noble, *Wstęp do Procesów Stochastycznych (2022/23)*.
- [7] A. D. Wentzell, *Wykłady z teorii procesów stochastycznych*, PWN, Warszawa 1980.