

# Wstęp do Procesów Stochastycznych

Rafał Latała

22 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](mailto:rlatala@mimuw.edu.pl) z podaniem wersji notatek (daty), której dotyczą.

# Spis treści

<b>1</b>	<b>Podstawowe Przykłady Procesów Stochastycznych</b>	<b>3</b>
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
<b>2</b>	<b>Rozkłady Procesów Stochastycznych</b>	<b>16</b>
2.1	$\sigma$ -ciało zbiorów cylindrycznych . . . . .	16
2.2	Warunki zgodności. Twierdzenie Kołmogorowa o istnieniu procesu . . . . .	17
2.3	*Dowód twierdzenia o istnieniu procesu* . . . . .	19
<b>3</b>	<b>Ciągłość trajektorii</b>	<b>21</b>
3.1	Procesy stochastycznie równoważne i nierozróżnialne . . . . .	21
3.2	Twierdzenie o ciągłej modyfikacji . . . . .	22
3.3	Inne rodzaje ciągłości procesów . . . . .	25
<b>4</b>	<b>Procesy gaussowskie</b>	<b>26</b>
4.1	Przypomnienie podstawowych faktów o wektorach gaussowskich . . . . .	26
4.2	Procesy gaussowskie – definicja i podstawowe własności . . . . .	27
4.3	Proces Ornsteina-Uhlebeka . . . . .	28
4.4	Ułamkowy Ruch Browna . . . . .	28
<b>5</b>	<b>Filtracje z czasem ciągłym, Momenty Zatrzymania</b>	<b>30</b>
5.1	Filtracje . . . . .	30
5.2	Momenty Zatrzymania . . . . .	31
<b>6</b>	<b>Martyngały z czasem ciągłym</b>	<b>34</b>
6.1	Definicje i przykłady . . . . .	34
6.2	Jednostajna całkowalność . . . . .	35
6.3	Twierdzenia Dooba o stopowaniu . . . . .	37

# 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  $\lambda$  (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

$$N_t = \sup\{n : S_n \leq t\}. \quad (1)$$

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

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  $\beta_n$  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  $\lambda$ , niezależnym od zmiennych  $\Delta_i$ . 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  $\lambda$  i rozkład pojedynczego skoku  $\Delta_1$ . 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  $N^\Delta$  będzie złożonym procesem Poissona. Wówczas  $N_0^\Delta = 0$ ,  $N^\Delta$  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  $\infty$  w  $\infty$ . 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  $\lambda t$ .

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 następných 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  $\omega$ , 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 $\sigma$ -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  $\sigma$ -ciało zawierające zbiory cylindryczne i będziemy je nazywać  *$\sigma$ -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  $\mu_X$  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  $\mu_{t_1, \dots, t_n}$  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  $\pi$ -układ, a rodzina  $\mathcal{C}$  zbiorów  $C$  takich, że  $\mathbb{P}(X \in C) = \mathbb{P}(Y \in C)$ , jest  $\lambda$ -układem zawierającym  $\mathcal{A}$ . Zatem z twierdzenia o  $\pi$ - i  $\lambda$ -układach,  $\mathcal{C}$  zawiera również  $\sigma$ -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  $(\mu_{t_1, \dots, t_n})$  spełniająca warunki zgodności. Wówczas istnieje proces  $(X_t)_{t \in T}$  mający skończenie wymiarowe rozkłady równe  $(\mu_{t_1, \dots, t_n})$ .*

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  $\mu_{t_1, \dots, t_n}$  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  $\mu_{t_1, \dots, t_n}$  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  $(\mu_{t_1, \dots, t_n})$  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  $\mu_t$ . 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  $\mu_0$  skończenie addytywną funkcją z  $\mathcal{A}$  w  $\mathbb{R}_+$ . Wówczas  $\mu_0$  przedłuża się do miary  $\mu$  na  $\sigma$ -ciele  $\sigma(\mathcal{A})$  wtedy i tylko wtedy, gdy  $\mu_0$  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  $\mu_0$  jest dobrze zdefiniowane, tzn.  $\mu_0(C)$  nie zależy od wyboru  $t_1, \dots, t_n$  i  $A$  reprezentujących  $C$ .
- $\mu_0$  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  $\mu$  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  $\mu_{t_1, \dots, t_n}$ , 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  $\mu$  rozszerzająca  $\mu_0$ . 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  $\gamma$ , 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  $\alpha, \beta, C$ . 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  $\delta$  jest ustaloną liczbą dodatnią.

*Dowód.* Przedział nieskończony  $T$  można zapisać jako przeliczalną sumę przedziałów  $[a_n, a_{n+1}]$ , długości nie większej od  $\delta$ . 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 wpieryw, 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  $C_\gamma$  jest stałą zależną tylko od  $\gamma$ . 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  $\gamma$ ). 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  $\gamma$ , 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 całkwalnym 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  $\mu_{t_1, \dots, t_n}$  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  $(\mu_{t_1, \dots, t_n})$  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  $\sigma$ -ciał zawartych w  $\mathcal{F}$ , tzn.  $\mathcal{F}_t \subset \mathcal{F}_s$  dla  $t \leq s$ ,  $t, s \in T$ .

Zdarzenia z  $\sigma$ -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  $\sigma$ -ciała  $\mathcal{F}_s^X$ .*

*Dowód.*  $\Rightarrow$ : Rodzina zdarzeń  $A$  niezależnych od  $X_t - X_s$  tworzy  $\lambda$ -układ, ponadto, z niezależności przyrostów  $X$ , zawiera  $\pi$ -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  $\sigma$ -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  $\tau_A$  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  $\tau_A$  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

- a) jest prawostronnie ciągła,
- b) 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  $\tau$  będzie momentem zatrzymania względem filtracji  $(\mathcal{F}_t)_{t \in T}$ . Definiujemy  $\sigma$ -ciało *zdarzeń obserwowalnych do chwili  $\tau$*  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  $\mathcal{F}_\tau$  jest  $\sigma$ -ciałem.

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

c) Zmienna losowa  $\tau$  jest  $\mathcal{F}_\tau$  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  $\tau$  i  $\sigma$  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  $X_\tau$  dla wszystkich momentów zatrzymania  $\tau$ . 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  $\sigma$ -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  $\tau$  jest momentem zatrzymania, a  $X = (X_t)_{t \in T}$  procesem, to zmienna  $X_\tau$  jest dobrze zdefiniowana tylko na zbiorze  $\{\tau < \infty\}$ . Musimy zatem określić co mamy na myśli mówiąc, że zmienna  $X_\tau$  jest mierzalna.

**Definicja 5.14.** Mówimy, że zmienna losowa  $Z$  określona na zbiorze  $A$  jest mierzalna względem  $\sigma$ -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  $\tau$  jest momentem zatrzymania. Wówczas zmienna losowa  $X_\tau$  określona na zbiorze  $\{\tau < \infty\} \in \mathcal{F}_\tau$  jest  $\mathcal{F}_\tau$  mierzalna. Ponadto proces zatrzymany w chwili  $\tau$ ,  $X^\tau := (X_{t \wedge \tau})_{t \in T}$  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  $\sigma$ -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  $X^\tau$ . 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)  $X^\tau$ . □

## 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 podmartyngałem, a  $(W_t^2 - t)_{t \geq 0}$  martyngałem 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 martyngałem (odp. podmartyngałem), zaś  $f: \mathbb{R} \rightarrow \mathbb{R}$  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 podmartyngałem.

*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 martyngału i nie mniejsza niż  $f(X_s)$  dla podmartyngału.  $\square$

## 6.2 Jednostajna całkowalność

By przenieść twierdzenia martyngałowe 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  $\sigma$ -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  $\delta$  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  $\varepsilon_n$  niezależne zmienne losowe takie, że  $\mathbb{P}(\varepsilon_n = \pm 1) = 1/2$ ,  $\mathcal{F}_n = \sigma(\varepsilon_1, \dots, \varepsilon_n)$ ,  $\tau = 0$ ,  $\sigma = \inf\{n: X_n = 1\}$  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  $\sigma$  i  $\tau$  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  $X_\infty$  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.* Niewielka modyfikacja dowodu pokazuje, że jeśli  $(X_t)_{t \in T}$  jest prawostronnie ciągłym nieujemnym podmartyngeałem, zaś  $\sigma$  i  $\tau$  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  $(X_{\sigma_n})_{n=1}^{\infty}$ .

## 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.