

1. CENTRALNE TWIERDZENIA GRANICZNE

• Intuicja

Suma dużej liczby niezależnych składników o skończonej wariancji, gdzie żaden składnik nie dominuje ma w przybliżeniu rozkład normalny (tłumaczy to też wszechobecność rozkładu \mathcal{N}).

• Schemat serii

Tablica zmiennych losowych postaci (X_{n,r_n}) , gdzie $r_n \rightarrow \infty$, $n = 1, 2, \dots$. Zakładamy, że zmienne losowe w każdym wierszu $X_{n,1}, \dots, X_{n,r_n}$ są niezależne (dla wygodu $k_n = n$).

• Tw. Lindeberga

Zał. że dla każdego n , zmienne $X_{n,1}, X_{n,2}, \dots, X_{n,r_n}$ są niezależnymi zm. los. o średniej 0 takimi że $\sum_{k=1}^{r_n} \mathbb{E}X_{n,k}^2 \rightarrow^{n \rightarrow \infty} 1$. Dodatkowo zał. że jest spełniony war. Lindeberga $\sum_{k=1}^{r_n} \mathbb{E}X_{n,k}^2 \mathbb{1}_{\{|X_{n,k}| > \varepsilon\}} \rightarrow^{n \rightarrow \infty} 0$ dla każdego $\varepsilon > 0$. Wówczas $X_{n,1} + \dots + X_{n,r_n} \Rightarrow \mathcal{N}(0, 1)$.

Dowód:

$$Z_n = \sum_{k=1}^{r_n} X_{n,k}, \varphi_{n,k} = \text{varphi}_{X_{n,k}}, \sigma_{n,k}^2 = \mathbb{E}X_{n,k}^2$$

Pokazujemy, że $\varphi_{Z_n}(t) = \prod_{k=1}^{r_n} \varphi_{n,k}(t) \rightarrow^{n \rightarrow \infty} e^{-t^2/2}$

$$|\varphi_{Z_n}(t) - e^{-t^2/2}| = \left| \prod_{k=1}^{r_n} \varphi_{n,k}(t) - \prod_{k=1}^{r_n} e^{-\sigma_{n,k}^2 t^2/2} \right| \leq$$

Rozbijamy na dwie sumy i szacujemy z góry przez składniki, które zbiegają do 0 przy $n \rightarrow \infty$. (dopisujemy $\mathbb{E}(-itX_{n,k} - 1 + \frac{1}{2}t^2X_{n,k}^2) + 1 - \frac{1}{2}t^2\sigma_{n,k}^2 = 0$.)

Korzystamy z nierówności $a_1, \dots, a_n, b_1, \dots, b_n \in \mathbb{C}$ i $|a_i|, |b_i| \leq 1$ $|a_1 \dots a_n - b_1 \dots b_n| \leq \sum |a_i - b_i|$.

• Uogólnione tw. Lindeberga

– Zał. że dla każdego n zmienne $X_{n,1}, \dots, X_{n,r_n}$ są niezależne i całkowalne z kwadratem. Oznaczmy $m_{n,k} = \mathbb{E}X_{n,k}$ i przypuśćmy że $\sum_{k=1}^{r_n} \mathbb{E}X_{n,k} \rightarrow^{n \rightarrow \infty} m$, $\sum_{k=1}^{r_n} \text{Var}X_{n,k} \rightarrow^{n \rightarrow \infty} \sigma^2$ oraz $\sum_{k=1}^{r_n} \mathbb{E}(X_{n,k} - m_{n,k})^2 \mathbb{1}_{\{|X_{n,k} - m_{n,k}| > \varepsilon\}} \rightarrow 0$. Wówczas $X_{n,1} + \dots + X_{n,r_n} \Rightarrow \mathcal{N}(m, \sigma^2)$.

– Zał. że X_1, X_2, \dots są niezależnymi zm. los. całkowalnymi z kwadratem, $m_n := \mathbb{E}X_n$, $\sigma_n^2 = \text{Var}X_n$, $b_n^2 = \sum_{k=1}^n \sigma_n^2$. Jeśli jest spełniony war. Lindeberga $b_n^{-2} \sum_{k=1}^n \mathbb{E}|X_k - m_k|^2 \mathbb{1}_{\{|X_k - m_k| > \varepsilon b_k\}} \rightarrow^{n \rightarrow \infty} 0$, to $\frac{X_1 + \dots + X_n - m_1 - \dots - m_n}{b_n} \Rightarrow \mathcal{N}(0, 1)$.

• CTG – najprostsza wersja

– Niech X_1, X_2, \dots będą niezależnymi zmiennymi losowymi o tym samym rozkładzie i niech $\mathbb{E}X = 0$, i $D^2X = 1$. Wtedy $\frac{X_1 + \dots + X_n}{\sqrt{n}} \rightarrow_D \mathcal{N}(0, 1)$.

– Zał. że X_1, X_2, \dots są niezależne i mają ten sam rozkład o dodatniej wariancji. Oznaczmy $m = \mathbb{E}X_1$, $\sigma^2 = \text{Var}X_1$. Wówczas war. Lindeberga jest spełniony i $\frac{X_1 + \dots + X_n - nm}{\sqrt{n}\sigma} \Rightarrow \mathcal{N}(0, 1)$.

• Tw. Berry-Esseena

Dokładność przybliżenia w CTG o ile założymy istnienie trzeciego momentu.

• War. Lindeberga nie jest konieczny dla zbieżności rozkładów zmiennych losowych Z_n do $\mathcal{N}(0, 1)$ ($k \rightarrow \infty$, $n = 1, 2, \dots$) np. wszystkie $X_{n,k}$ w schemacie serii mają rozkłady $(0, \sigma_{n,k}^2)$. Zał., że pierwsza zm. los. w kolumnie ma rozkład $\mathcal{N}(0, \frac{1}{2})$ (ten składnik dominuje), a pozostałe mogą mieć równe wariancje, byle ich suma = 1. Wtedy warunek Lindeberga nie jest spełniony, ale $Z_n \sim \mathcal{N}(0, 1)$.

• Warunek Lindeberga spełniony jest gdy

– X_1, X_2, \dots są wspólnie ograniczonymi niezależnymi zm. los. spełniającymi war. $\sum_{k=1}^n \text{Var}X_k \rightarrow \infty$.

– Dla każdego n , $X_{n,1}, \dots, X_{n,r_n}$ są niezależnymi scentrowanymi i zm. los. spełniającymi warunki $\sum_{k=1}^{r_n} \mathbb{E}X_{n,k}^2 \rightarrow^{n \rightarrow \infty} 1$ oraz $\sum_{k=1}^{r_n} \mathbb{E}|X_{n,k}|^{2+\delta} \rightarrow^{n \rightarrow \infty} 0$ dla pewnego $\delta > 0$ (**Stw. Lapunowa**).

• Tw. de Moivre'a-Laplace'a

Zał. że X_n ma rozkład Bernoulliego z parametrami n, p . Wówczas $\frac{X_n - np}{\sqrt{np(1-p)}} \Rightarrow \mathcal{N}(0, 1)$.

• Centralne tw. graniczne pozwala badać zachowanie dystrybuant sum niezależnych zm. los. Istotnie zbieżność $\frac{X_1 + \dots + X_n - (m_1 + \dots + m_n)}{b_n} \rightarrow \mathcal{N}(0, 1)$ jest równoważna zbieżności punktowej dystrybuant:

$$\mathbb{P}\left(\frac{X_1 + \dots + X_n - (m_1 + \dots + m_n)}{b_n} \leq x\right) \rightarrow \phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-y^2/2} dy.$$

2. PROCESY STOCHASTYCZNE. PROCES WIENERA I JEGO WŁASNOŚCI

- **Proces Wienera** (ruch Browna)

Matematyczny model ruchu cząsteczki zawieszonyj w cieczy. Formalnie, rodzina zmiennych losowych W_t , $t \geq 0$, określonych na tej samej p-ni probabilistycznej $(\Omega, \mathcal{F}, \mathbb{P})$.

- **Funkcja losowa**

$X = (X_t)_{t \in T}$, gdzie (Ω, \mathcal{F}, P) – przestrzeń probabilistyczna, (E, B) – przestrzeń mierzalna, E – przestrzeń stanów $T \neq \emptyset$ – dowolny zbiór, X_t – zmienna losowa o wartościach w E .

- **Nierozróżnialność**

Funkcje losowe $X = (X_t)_{t \in T}$, $Y = (Y_t)_{t \in T}$ są nierozróżnialne, jeśli $\mathbb{P}(\exists t \in T X_t \neq Y_t) = 0$.

- **Proces stochastyczny**

Funkcja losowa o wartościach w E (czyli zwykle \mathbb{R} , czas $T = \mathbb{R}_+$, \mathbb{Z}_+ , przedział w \mathbb{R}_+ lub \mathbb{Z}_+ , czasem $T = \mathbb{R}$, \mathbb{Z}) – proces stochastyczny o wartościach w E . Proces X jest: d-wymiarowy, gdy $E = \mathbb{R}^d$; dyskretny, gdy $T \subset \mathbb{Z}_+$; ciągły, gdy $T \subset \mathbb{R}_+$. Oznaczenie: $X_t(\omega) = X(t, \omega)$, $X_t = X(t)$.

Inaczej: Niech $(\Omega, \mathcal{F}, \mathbb{P})$ będzie p-nią probabilistyczną, (E, ε) p-nią mierzalną, zaś T jest dowolnym zbiorem. Procesem stochastycznym o wartościach w E , określonym na zbiorze T , nazywamy rodzinę zm. los. $X = (X_t)_{t \in T}$ przyjmujących wartości w zbiorze E .

- **Trajektoria (ścieżka)**

$\forall \omega \in \Omega$ funkcja $t \mapsto X_t(\omega)$, $T \rightarrow E$.

- **Niezależne przyrosty**

Proces $X = (X_t)_{t \in T}$ (o wartościach w E) ma niezależne przyrosty, jeśli $\forall 0 \leq t_0 < \dots < t_n, t_j \in T X_{t_0}, X_{t_1} - X_{t_0}, \dots, X_{t_n} - X_{t_{n-1}}$ są niezależne, gdzie $E = \mathbb{R}^d$, $T = \mathbb{R}_+$ lub przedział.

- **Stacjonarne przyrosty**

Mówimy, że proces stochastyczny $(X_t)_{t \geq 0}$ ma przyrosty stacjonarne, jeśli rozkład $X_t - X_s$ zależy tylko od $t - s$, czyli $\forall t > s \geq 0 X_t - X_s \sim X_{t-s} - X_0$.

- **Proces Wienera (ruch Browna) [PW]** Proces $W = (W_t)_{t \in \mathbb{R}_+}$ spełniający:

- $W_0 = 0$
- ma niezależne przyrosty
- $\forall s < t, W_t - W_s \sim N(0, t - s)$
- ciągle trajektorie z p-stwem 1 (tzn. \exists taki zbiór A , że $\mathbb{P}(A) = 1$ oraz $\forall \omega \in A, t \rightarrow W_t(\omega)$ jest funkcją ciągłą na $[0, \infty)$).

- **Tw.**

- Proces $W = (W_t)_{t \in \mathbb{R}_+}$ o wartościach w \mathbb{R}^d jest d-wymiarowym [PW] wtedy i tylko wtedy gdy: $W_0 = 0$, ma niezależne przyrosty, $s < t, W_t - W_s$ ma rozkład normalny ze średnią zero i macierzą kowariancji diagonalną z $t - s$ na przekątnej.
- Proces $X_t, t \geq 0$ jest PW wtw. gdy spełnione są warunki 1, 2, 4 oraz $\mathbb{E}X_t = 0, \mathbb{E}X_t^2 = 1$ oraz jeśli $t \geq s$, to $X_t - X_s \sim X_{t-s}$ (przyrosty stacjonarne) i $\mathbb{E}X_t^4 < \infty \forall t > 0$.
- Proces $X = (X_t)_{t \in \mathbb{R}_+}$ jest [PW] wtw. gdy jest ciągły, gaussowski, $\mathbb{E}X_t = 0, Cov(X_t, X_s) = t \wedge s$.

Dowód

\Rightarrow łatwo

\Leftarrow (1) $Var X_0 = 0 = \mathbb{E}X_0$.

(3) Dla $t > s W_t - W_s \sim \mathcal{N}(0, Y), Y = Var(X_t - X_s) = Var X_t + Var X_s - 2Cov(X_t, X_s) = t - s$.

(2) Ustalmy $0 \leq t_0 \leq \dots \leq t_n > \text{Zauważmy, że wektor } (X_{t_0}, X_{t_1} - X_{t_0}, X_{t_2} - X_{t_1}, \dots, X_{t_n} - X_{t_{n-1}})$ ma rozkład gaussowski, więc jego współrzędne są niezależne wtw. gdy są nieskorelowane.

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

- **d-wymiarowy proces Wienera**

Proces $W = (W_t)_{t \in \mathbb{R}_+}$ o wartościach w \mathbb{R}^d , gdy $W = (W^{(1)}, \dots, W^{(d)})$, $W^{(1)}, \dots, W^{(d)}$ są niezależnymi procesami Wienera.

- **Uwaga**

Rozkład $(W_{t_1}, \dots, W_{t_n})$ jest określony przez wartość oczekiwaną 0 oraz macierz kowariancji, taką że $\mathbb{E}(W_t W_s) = s \wedge t$.

Bo: $Cov(X_s, X_t) = Cov(X_s, X_t - X_s) + Var X_s = s$ dla $t \geq s$ oraz t dla $s \geq t$, czyli $= \min\{s, t\}$.

- **Lemat**

Jeśli $X = (X_t)_{t \in T}$ jest ciągłym procesem z własnością $\forall t_1 < \dots < t_n (X_{t_1}, \dots, X_{t_n}) \sim (W_{t_1}, \dots, W_{t_n})$, gdzie W jest [PW], to X jest [PW].

- **Wniosek**
Jeśli W jest [PW], to $\forall_{t_1 < \dots < t_n} (W_{t_1}, \dots, W_{t_n})$ (rozkłady skończenie wymiarowe PW – rozkłady wektorów losowych) ma rozkład normalny.
- **Proces gaussowski**
 $X = (X_t)_{t \in T}$ o wartościach w \mathbb{R} lub \mathbb{R}^d , gdy $\forall_{t_1 < \dots < t_n} (X_{t_1}, \dots, X_{t_n})$ ma rozkład gaussowski (PW, most Browna $X_t = W_t - tW_1$, $t \in [0, 1]$; nie są: W_t^2 , $exp(W_t)$).
- **Fakt**
Niech $W = (W_t)_{t \in \mathbb{R}}$ [PW], ustalmy $0 \leq s < t$. Rozważmy ciąg podziałów $[s, t]$ taki że $s = t_0^n < t_1^n < \dots < t_{m_n}^n = t$, $\max_k (t_{k+1}^n - t_k^n) \rightarrow_{n \rightarrow \infty} 0$. Wówczas $\sum_{k=1}^{m_n} (W_{t_k^n} - W_{t_{k-1}^n}) \rightarrow_{n \rightarrow \infty} t - s$ w $L^2(\Omega, \mathcal{F}, P)$.
- **Rozkład skończenie wymiarowy funkcji losowej X**
Mamy funkcję losową lub $X = (X_t)_{t \in T}$ w E . $\forall_{n \geq 1} \forall_{t_1, \dots, t_n \in T}$. Miara probabilistyczna na $E \times \dots \times E \rightarrow \mu_{t_1, \dots, t_n}(B) = P((X_{t_1}, \dots, X_{t_n}) \in B) \leftarrow$ rozkład skończenie wymiarowy procesu X , $B \in \mathcal{B}^{\otimes n}$.
- **Wniosek**
PW $(W_t, \mathcal{F}_t)_t$ jest martyngałem.
Jeśli zdefiniujemy filtrację $(\mathcal{F}_t)_{t \geq 0}$ zależnością $\mathcal{F}_t = \sigma(W_s : s \leq t)$, to otrzymamy martyngał z czasem ciągłym (W_t, \mathcal{F}_t) . Martyngały: W_t , $W_t^2 - t$.
- **Tw.**
Prawie wszystkie trajektorie PW $(W_t)_{t \in [0, 1]}$ są funkcjami nigdzie nieróżniczkowalnymi (prawie wszystkie trajektorie mają wahanie skończone).

3. ŁAŃCUCHY MARKOWA, WŁASNOŚCI

- Macierz $P = [p_{ij}]_{(i,j) \in E \times E}$ nazywamy **stochastyczną** (przejścia), jeśli $p_{ij} \in [0, 1,]$ dla wszystkich $i, j \in E$ oraz $\sum_{j \in E} p_{ij} = 1$ dla każdego $i \in E$.

• Intuicja

Łańcuch Markowa charakteryzuje się pewną liczbą dopuszczalnych stanów i regułami przechodzenia pomiędzy nimi. Ważne, że szansa znalezienia się w stanie A w chwili n zależy tylko od stanu, w jakim byliśmy w chwili $n - 1$ i od reguł przechodzenia.

- Zał. że $(\Omega, \mathcal{F}, \mathbb{P})$ jest p-nią probabilistyczną, E (zbiór przeliczalny, przestrzeń stanów), P są j.w. ustalone. **Łańcuchem Markowa** o wartościach w E i macierzy przejścia P nazywamy ciąg $(X_n)_{n=0,1,\dots}$ zm. los. (określonych na tej samej przestrzeni probabilistycznej) takich że $\mathbb{P}(X_n = a_n | X_{n-1} = a_{n-1}, X_{n-2} = a_{n-2}, \dots, X_0 = a_0) =$ własność Markowa ciągu zmiennych losowych $\mathbb{P}(X_n = a_n | X_n = a_n)$ jednorodny = $p_{a_n a_{n-1}}$ dla wszystkich a_0, a_1, \dots, a_n t. że zdarzenie warunkujące ma dodatnie p-stwo (gdy istnieje macierz $P = (p_{ij})_{i,j \in E}$ będąca $\forall n$ jego macierza przejścia w każdym kroku). Równoważnie $\mathbb{P}(X_n = j | X_0, X_1, \dots, X_{n-1}) = \mathbb{P}(X_n = j | X_{n-1}) = p_{X_{n-1} j}$. Liczba p_{ij} jest p-stwem przejścia ze stanu i do stanu j w jednym kroku np. błądzenie losowe, model dyfuzji cząstek.

• Błądzenie losowe na prostej

Ciąg niezależnych zmiennych losowych $(U_n)_{n=0}^\infty$, gdzie dla $n \geq 1$ $\mathbb{P}(U_n = 1) = p$, $\mathbb{P}(U_n = -1) = 1 - p$, U_0 – dowolna zmienna losowa o wartościach w E , $X_n = \sum_{k=0}^n U_k$, $n = 1, 2, \dots$. Ciąg (X_n) tworzy łańcuch Markowa. Intuicyjne jasne, bo $X_n = X_{n-1} + U_n$ (z niezależności), $\mathbb{P}(X_n = s_n | X_{n-1} = s_{n-1}, \dots, X_0 = s_0) = \mathbb{P}(U_n = s_n - s_{n-1}) = \frac{\mathbb{P}(U_n = s_n - s_{n-1}, X_{n-1} = s_{n-1})}{\mathbb{P}(X_{n-1} = s_{n-1})} = \mathbb{P}(X_n = s_n | X_{n-1} = s_{n-1})$ (wszystkie stany komunikują się).

• Rozkład skończenie wymiarowe łańcucha Markowa

Rozkłady wektorów $(X_{k_1}, \dots, X_{k_n})$ spełniające zależność $\mathbb{P}(X_0 = s_0, \dots, X_n = s_n) = \mathbb{P}(X_0 = s_0) p_{s_0 s_1} \dots p_{s_{n-1} s_n}$, są więc wyznaczone jednoznacznie przez rozkład początkowy i macierz przejścia.

• Równanie Chapmana-Kołmogorowa

Dla wszystkich $k, n \geq 1$ oraz $i, j \in E$ $p_{ij}^{k+n} = \sum_{i \in E} p_{il}^k p_{lj}^n$.

- Rozkład zmiennej X_0 nazywamy **rozkładem początkowym**. Jest on jednoznacznie wyznaczony przez ciąg $(\pi_i)_{i \in E}$ liczb nieujemnych o sumie 1.

- **Klasyfikacja stanów** Mówimy, że stan j jest **osiągalny** ze stanu i jeśli $p_{ij}^{(n)} > 0$ dla pewnego $n \geq 1$. Mówimy, że stany i oraz j się **komunikują**, jeśli j jest osiągalny z i oraz i jest osiągalny z j (mamy przechodniość!). Stan i jest **nieistotny**, jeśli istnieje taki stan j , że j jest osiągalny z i oraz i nie jest osiągalny z j .

Łańcuch Markowa nazywamy **nieprzywiedlnym**, jeśli wszystkie stany komunikują się ze sobą.

- **Tw.** Stan j jest **chwilowy** (do takiego stanu wraca się skończenie wiele razy) wtw. gdy $P_j < \infty$. Stan j jest **powracający** (nieskończenie) wtw. gdy $P_j = \infty$.

$P_j = \sum_{n=1}^\infty p_{jj}^{(n)} = \mathbb{E}(N_j | X_0 = j)$ – średni czas przebywania łańcucha w stanie j .

- **Tw.** Zał. że łańcuch Markowa jest **nieprzywiedlny**. Wówczas jeśli jeden stan jest chwilowy, to wszystkie są chwilowe; jeśli jeden stan jest powracający, to wszystkie są powracające (inaczej: wszystkie stany są tego samego rodzaju).

• Zamknięty zbiór stanów C

Żaden stan spoza tego zbioru nie da się osiągnąć wychodząc z owolnego stanu w C . Pojedynczy stan s_k tworzący zbiór zamknięty nazywam **stanem pochłaniającym**.

• Tw.

Zbiór stanów łańcucha Markowa można jednoznacznie rozbić na zbiór stanów chwilowych i nieprzywiedlne zamknięte zbiory stanów powracających.

Każdy stan nieistotny jest chwilowy. Jeśli łańcuch Markowa jest skończony, również każdy stan chwilowy jest nieistotny i oba zbiory stanów są równe.

Dowód

Dla stanu powracającego j , $j \in S \setminus T$ niech $\xi_j = \{k : k \leftrightarrow j\}$. S_j jest zamkniętym zbiorem stanów zajmennie komunikujących się. $S_k = S_j$, dla $k \in S_j$ oraz $S_k \cap S_j = \emptyset$ dla $k \notin (S_j \cup T)$. Zatem $S \setminus T$ rozбивa się na rozłączne klasy, które możemy ponumerować S_1, S_2, \dots

- Zał. że P jest macierzą stochastyczną. Rozkład π na e nazywamy **stacjonarnym** (niezmienniczym, granicznym), jeśli $\pi P = \pi$ (tzn. dla wszystkich $j \in E$, $\sum_{i \in E} \pi_i p_{ij} = \pi_j$). Własność $\forall n \geq 1$ $\pi P^n = \pi$ ($\sum_{j \in E} \pi_j = 1$, $\forall_j \pi_j \geq 0$).

- **Wniosek**

Jeżeli łańcuch Markowa jest powracający, to \forall stanu j $\mathbb{P}(\exists n \geq 1 X_n = j) = 1$ niezależnie od rozkładu początkowego X_0 .

- **Tw ergodyczne**

Niech (X_n) będzie nieprzywidylnym, nieokresowym łańcuchem Markowa, dla którego istnieje rozkład stacjonarny π . Wówczas:

- (X_n) jest łańcuchem powracającym (każdy stan jest powracalny)
- dla wszystkich $i, j \in E$, $\lim_{n \rightarrow \infty} p_{ij}^{(n)} = \pi_j > 0$
- rozkład stacjonarny jest jedyny (jednoznaczny) i $\pi_j = \frac{1}{\nu_j}$, gdzie ν_j jest średnim czasem powrotu łańcucha do stanu j .

- **Łańcuch ergodyczny**

Łańcuch Markowa, dla którego istnieją granice z punktu drugiego.

- Jeśli łańcuch Markowa jest nieprzywidylny, powracający, a wartości oczekiwane czasów powrotu są skończone, to istnieje rozkład stacjonarny.

- **Wniosek z tw. ergodycznego**

Niech (X_n) będzie łańcuchem ergodycznym, $A \subset S$ i $\nu_A(n)$ oznacza średni czas przebywania łańcucha Markowa w zbiorze A do momentu n tj. $\nu_A(n) = \frac{1_A(X_0) + \dots + 1_A(X_n)}{n+1}$. Wtedy $\mathbb{E}(\nu_A(n) | X_0 = i) \xrightarrow{n \rightarrow \infty} \sum_{j \in A} \pi_j$.

Dowód

$$\mathbb{E}(\nu_A(n) | X_0 = i) = \frac{1}{n+1} \sum_{m=0}^n \mathbb{E}(1_A | X_m) | X_0 = i = \frac{1}{n+1} \sum_{m=0}^n \sum_{j \in A} p_{ij}(m) = \sum_{j \in A} \frac{1}{n+1} \sum_{m=0}^n p_{ij}(m) \rightarrow \sum_{j \in A} \pi_j$$

ponieważ $\lim_{n \rightarrow \infty} p_{ij}(n) = \pi_j$.

- **Powyższe tw. ogólniej**

Niech (X_n) będzie nieprzywidylnym, nieokresowym łańcuchem Markowa, dla którego istnieje rozkład stacjonarny π . Wtedy $\nu_A(n)$ zdef. powyższym wzorem spełnia zależność $\lim_{n \rightarrow \infty} \nu_A(n) = \pi_j$.

- **Przykład**

$P = \begin{pmatrix} 0 & 1 & 1 & 0 \end{pmatrix}$ – łańcuch okresowy o okresie 2 i $\lim_{n \rightarrow \infty} p_{00}(2n) = 1$ i $\lim_{n \rightarrow \infty} p_{00}(2n+1) = 0$. Granica nie istnieje, natomiast istnieją granice podciągów.

- Rozpatrzmy ł. M. o k stanach, przy czym stany $1, \dots, m$ są pochłaniające. Wtedy macierz przejścia P ma postać $P = (I(m) 0(k-m), RQ)$.

- Macierz $A = (a_{ij})_{i \in \{1, \dots, k-m\}, j \in \{1, \dots, m\}}$, gdzie $a_{ij} = p_{\{j\}}(i+m)$ jest p-stwem, że łańcuch wychodzący ze stanu chwilowego $i+m$ zatrzyma się w stanie pochłaniającym j , spełnia zależność $A = (I - Q)^{-1}R$.

- **Tw.**

Gdy $(X_n)_{n=0}^{\infty}$ jest jednorodnym łańcuchem Markowa to:

- dla dowolnych $m, n \in \mathbb{N}$ i dowolnych $s_0, \dots, s_n \in S$ $\mathbb{P}(X_1 = s_1, X_2 = s_2, \dots, X_n = s_n | X_0 = s_0) = \mathbb{P}(X_{m+1} = s_1, X_2 = s_2, \dots, X_{n+m} = s_n | X_m = s_0) = \mathbb{P}(X_n = s_1 | X_0 = s_0)$
- dla dowolnych $m, n \in \mathbb{N}$ i dowolnych $s_0, s_1 \in S$ $\mathbb{P}(X_{n+m} = s_1 | X_m = s_0) = \mathbb{P}(X_n = s_1 | X_0 = s_0)$
- dla dowolnych $m, n \in \mathbb{N}$ i dowolnych $i_0, \dots, i_m, j_0, \dots, j_n \in S$ $\mathbb{P}(X_1 = i_1, \dots, X_m = i_m, X_{m+1} = j_1, \dots, X_{m+n} = j_n | X_0 = i_0) = \mathbb{P}(X_1 = i_1, \dots, X_m = i_m | X_0 = i_0) \mathbb{P}(X_1 = j_1, \dots, X_n = j_n | X_0 = i_m)$.

- **Okresem stanu j** nazywamy największą taką liczbę n , że powrót do stanu j jest możliwy tylko po liczbie kroków podzielnej przez n : $o(j) = NWD\{n : p_{jj}^{(n)} > 0\}$. Stan nazywamy **okresowym** jeśli $o(j) > 1$ i nieokresowym, jeśli $o(j) = 1$.

- **Stw.**

W nieprzywidylnym ł.M. wszystkie stany mają ten sam okres.

Dowód

Weźmy 2 dowolne stany i, j , $i \leftrightarrow j$, $d_i = o(i)$, $d_j = o(j)$. Istnieją l, m takie że $p_{ij}(l) > 0$, $p_{ji}(m) > 0$. Niech n takie że $p_{ij}(n) > 0$. Wtedy $p_{ii}(l+m+n) \geq p_{ij}(l)p_{jj}(n)p_{ji}(m) > 0$. Zatem d_i dzieli $l+m+n$. Także $p_{ii}(l+m) > 0$, więc d_i dzieli $l+m$, stąd d_i dzieli n . Zatem $d_i \leq d_j = NWD\{n : p_{jj}(n) > 0\}$. Analogicznie $d_i \geq d_j \Rightarrow d_i = d_j$.

- Nieprzywidylny łańcuch Markowa (X_n) nazywamy **okresowym**, jeśli wszystkie jego stany mają okres większy niż 1. W przeciwnym razie łańcuch nazywamy nieokresowym.

4. MODELE POPULACJI I ODDZIAŁYWAŃ MIĘDZY POPULACJAMI (MODEL MALTHUSA, MODEL VERHULSTA - RÓWNIANIE LOGISTYCZNE, MODEL LOTKI-VOLTERRY...)

- Modelowanie pojedynczej populacji – model Malthusa
 - koniec XVIII w. – praca o szybkim przyroście liczebności populacji ludzkiej („liczba ludności wzrasta w tempie geometrycznym, zasoby żywności w tempie arytmetycznym)
 - opis heurystyczny: jednorodna populacja (osobniki są identyczne), osobnik rodzi się zdolny do rozrodu w dowolnym wieku (momenty rozmanżania są rozłożone jednostajnie w dowolnym przedziale czasu), osobnik nie umiera, każdorazowo osobnik ma λ osobników potomnych, wydaje je na świat co τ jednostek czasu.
 - rozrodczość: $N(t + \Delta t) - N(t) = \Delta t / \tau \lambda N(t)$, czyli $\dot{N}(t) = \frac{\lambda}{\tau} N(t) = rN(t)$ (r – współczynnik rozrodczości) – model ciągły ($N(t) = N_0 e^{rt}$, $N(t + \Delta t) = N(t)(\Delta tr + 1) \Rightarrow N_{t+1} = N_t(r + 1)$ – model dyskretny (rozwiązanie $N_t = N_0(1 + r)^t$)
 - rozrodczość i śmiertelność: jak wyżej, tylko r oznacza rozrodczość - śmiertelność, jeśli > 0 to liczebność populacji rośnie, jeśli < 0 , to zbiega do 0
 - model z migracjami $\dot{N}(t) = r_n N(t) + m$ (wprowadzenie nowych osobników do siedliska jeśli $m > 0$, odławienie, gdy $m < 0$).
- Modelowanie pojedynczej populacji – model Verhulsta (logistyczny)
 - heurystycznie: konkurencja wewnątrzgatunkowa o zasoby siedliska
 - $\dot{N}(t) = rN(t) - aN^2(t) = rN(t)(1 - \frac{N(t)}{K})$, gdzie $K = r/a$ – pojemność środowiska, a – współczynnik konkurencji wewnątrzgatunkowej
 - ważne do pokazania – istnienie i jednoznaczność rozwiązań (prawa strona C^1), nieujemność (dla $N_0 \geq 0$, $N(t) \geq 0$ dla $t > 0$), istnienie dla wszystkich $t \geq 0$ ($\dot{N}(t) \leq rN(t) \Rightarrow N(t) \leq N_0 e^{rt}$, wzrost co najwyżej wykładniczy, monotoniczność rozwiązań, krzywa logistyczna
 - dyskretnie równanie logistyczne $N_{t+1} = (1 + r)N_t - \frac{r}{K}N_t^2 = \tilde{r}N_t(1 - \frac{N_t}{K}) \Rightarrow x_{t+1} = ax_t(1 - x_t)$, stany stacjonarne $x_1 = 0$, $x_2 = \frac{a-1}{a}$, gdy $F(x) = x = ax(1 - x)$, pochodna $a(1 - 2x) = dF(x)$ stabilność:
 - * $a \in (0, 1)$ $dF(x_1) = a$ – globalnie stabilny
 - * $a \in (1, 3)$, x_1 niestabilny, x_2 lokalnie stabilne
 - * $a \in (3, 4)$ – oba rozwiązania niestabilne
 - * $a = 2$ trzeba wyróżnić
 - * $a = 4$ – chaos (diagram bifurkacyjny – drzewo Feigenbauma, period dubling
- Modele pojedynczej populacji z uwzględnieniem wieku – macierze Lesliego
 - k grup wiekowych, N_t^i – liczebność grupy wiekowej i w chwili t
 - osobniki są jednorodne w ramach każdej grupy wiekowej
 - procesy rozrodczości i śmiertelności – jednostka czasu == jednostka zmiany wieku
 - $N_{j+1}^{t+1} = s_j N_j^t$, s_j – współczynnik starzenia (przeżywalności), $\gamma_i = 1 - s_i$ – umieralność
 - $N_0^{t+1} = \sum_{j=0}^n r_j N_j^t$, r_j – współczynnik urodzeń
 - $N_{t+1} = MN_t$, gdzie M to macierz Lesliego $[r_0, r_1, \dots, r_k; s_0, \dots, 0; \dots; 0, \dots, 0, s_{k-1}, 0]$
- Modele pojedynczej populacji z uwzględnieniem wieku – równanie logistyczne z opóźnieniem
 - $\dot{N}(t) = rN(t)(1 - \frac{N(t-\tau)}{K})$, $N_0 : [-\tau, 0] \rightarrow \mathbb{R}^+$.
 - można rozwiązywać metodą kroków
 - analiza stabilności – linearyzacja, potem szukamy rozwiązań w postaci wykładniczej ($x(t) = x_0 e^{\lambda t}$)
 - dla równań różnicowych, szukamy rozwiązań w postaci potęgowej $N_t = N_0 \lambda^t$
 - równanie charakterystyczne dla układu równań z pojedynczym opóźnieniem τ $P(\lambda + Q(\lambda)e^{-\beta\tau\lambda})$.
 - funkcja pomocnicza ($F(w) = \|P(iw)\|^2 - \|Q(iw)\|^2$)
 - badamy znak $dRe(\lambda)/d\tau$.
- Modele oddziaływań między dwiema populacjami
 - układ drapieżnik ofiara (model Lotki-Volterra), konkurencja (gatunki rywalizują o zasoby środowiska), symbioza (współżycie ≥ 2 gatunków): mutualizm (obie korzystają), komensalizm (jedna strona korzysta).
 - opis średnich zagęszczeń obu populacji
 - osobniki są rozmieszczone jednorodnie

- prawo zachowania średnich – w naturalnych siedliskach zmiany liczebności populacji w czasie zachodzą tak, że zachowana zostaje liczebność średnia
- w ekosystemie są dwa gatunki drapieżniki i ofiary
- liczba kontaktów jest proporcjonalna do liczebności obu gatunków
- $\dot{V} = rV - aVP$, $\dot{P} = -sP + abVP - r$ (współczynnik rozrodczości), a (współczynnik skuteczności upolowania), s (współczynnik śmiertelności), b (współczynnik upolowanej biomasy, którą gatunek drapieżników przeznacza na reprodukcję)
- gładkość prawej strony i liniowo oszacowanie pochodnej zawsze gwarantuje przedłużalność rozwiązań
- znajdujemy stany stacjonarne $(V, P) = (0, 0)$, $(V, P) = (\frac{s}{ab}, \frac{r}{a})$.
- model drapieżnik-ofiara w oparciu o równanie logistyczne $\dot{V} = rV(1 - \frac{V}{K}) - aVP$, $\dot{P} = -sP + abVP$
- model z kryjówkami dla ofiar $\dot{V} = rV - a(V - K)P$, $\dot{P} = -sP + ab(V - K)P$, K – liczba ofiar, które mogą się schować przed drapieżnikiem
- model Maya – pojemność środowiska zależy od liczby ofiar $\dot{V} = r_1V(1 - \frac{V}{K_1})$, $\dot{P} = r_2P(1 - \frac{P}{K_2}V)$
- konkurencja zewnątrzgatunkowa + wewnątrzgatunkowa $\dot{N}_1 = r_1N_1(1 - \frac{N_1}{K_1} - a_{12}\frac{N_2}{K_2})$, $\dot{N}_2 = r_2N_2(1 - \frac{N_2}{K_2} - a_{21}\frac{N_1}{K_1})$ (z plusem przy a – symbioza)
- model Nicholsona-Baileya (pasożyt – gospodarz)
- **Twierdzenie Poincare-Bendixona**
 $\dot{x}(t) = F(x(t), y(t))$, $\dot{y}(t) = G(x(t), y(t))$. Jeśli dla $t \geq 0$ trajektoria powyższego układu jest ograniczona, wówczas jest ona zamkniętą orbitą okresową/zbiega do zamkniętej orbity okresowej/jest stanem stacjonarnym/zbiega do stanu stacjonarnego.