

## Wykład 8: Tw. ergodyczne. Łańcuchy odwracalne.

Wykładowca: Andrzej Ruciński

Pisarz: Przemysław Rogowski, Tomasz Rzędowski

## 1 Wstęp

W pierwszej części dokończymy zagadnienia z poprzedniego wykładu ukazując zastosowania couplingu na kilku przykładach. Następnie przedstawione będzie twierdzenie ergodyczne. W drugiej części wprowadzimy odwracalne łańcuchy Markowa i podamy kilka prostych przykładów.

## 2 (dokończenie)

**Twierdzenie 1.** (Cam 1960) Niech  $X_1, X_2, \dots, X_n$  będą niezależnymi zmiennymi losowymi o rozkładzie  $0,1$ . Niech  $EX_r = p_r$  oraz  $S = \sum_{r=1}^n X_r$ . Wówczas

$$d_{TV}(S, P) \leq \sum_{r=1}^n p_r^2$$

oraz  $P$  ma rozkład  $Po(\lambda = \sum_{r=1}^n p_r)$

*Dowód.* Wprowadźmy coupling par niezależnych  $(X_r, Y_r)$  takich, że

$$P(X_r = x, Y_r = y) = \begin{cases} 1 - p_r & x = y = 0 \\ e^{-p_r} & x = 1, y = 0 \\ \frac{p_r^y}{y!} e^{-p_r} & x = 1, y \geq 1 \end{cases}$$

Zauważmy, że  $X_r$  ma rozkład  $Ber(p_r)$  oraz  $Y_r$  ma rozkład  $Po(p_r)$ . Postarajmy się ukazać ideę wprowadzenia takiego couplingu tym, którzy nie są w stanie dojrzeć jej już za pierwszym razem. Rozpatrzmy następującą równość

$$P(X_r \neq Y_r) = p_r - p_r e^{-p_r}.$$

W oszacowaniu jej skorzystamy z następującego lematu.

**Lemat 1.** Dla każdego  $x \in \langle 0, 1 \rangle$ , zachodzi

$$e^{-x} \geq 1 - x.$$

*Dowód.* Niech  $\varphi(x) = e^{-x} - 1 + x$ . Każde dziecko widzi, że jest to funkcja różniczkowalna na przedziale  $\langle 0, 1 \rangle$ . Otrzymujemy

$$\varphi(x') = -e^{-x} + 1 \leq 0,$$

gdyż  $\forall x \in \langle 0, 1 \rangle \quad e^{-x} \geq 1$ . Jest to zatem funkcja malejąca na przedziale  $\langle 0, 1 \rangle$ . Czyli  $\varphi(x)$  przyjmuje najmniejszą wartość w dziedzinie w punkcie 1.

$$\forall x \in \langle 0, 1 \rangle \quad \varphi(x) \geq \varphi(1) = e^{-1} \geq 0.$$

Czyli

$$e^{-x} - 1 + x \geq 0$$

□

W oparciu o lemat otrzymujemy

$$\begin{aligned} P(X_r \neq Y_r) &= \\ &= p_r - p_r e^{-p_r} = \\ &= p_r(1 - e^{-p_r}) \leq p_r p_r = \\ &= p_r^2. \end{aligned}$$

Przypomnijmy, że

$$\begin{aligned} S &= \sum_{r=1}^n X_r, \quad P = \sum_{r=1}^n Y_r \\ P &\text{ ma rozkład } Po(\lambda = \sum_{r=1}^n p_r) \\ d_{TV}(S, P) &= \frac{1}{2} \sum_k |\mathbf{P}(S = k) - \mathbf{P}(P = k)| \end{aligned}$$

Zauważmy, że

$$\begin{aligned} |\mathbf{P}(S = k) - \mathbf{P}(P = k)| &= |\mathbf{P}(S = k, P \neq k) - \mathbf{P}(S \neq k, P = k)| \leq \\ &\leq \mathbf{P}(S = k, P \neq k) + \mathbf{P}(S \neq k, P = k) \end{aligned}$$

Ostatnia nierówność wynika z faktu, że prawdopodobieństwo jest nieujemne.

Wróćmy na główny tor.

$$d_{TV}(S, P) \leq \frac{1}{2} 2\mathbf{P}(S \neq P) = \mathbf{P}(S \neq P)$$

Stąd otrzymujemy, w jakże oczywisty sposób, że

$$\mathbf{P}(S \neq P) \leq \mathbf{P}(\exists_r, X_r \neq Y_r) \leq \sum_{r=1}^n \mathbf{P}(X_r \neq Y_r) \leq \sum_{r=1}^n p_r^2$$

□

W ten oto sposób zakończyliśmy podawanie przykładów zastosowań couplingu. Czas powrócić do potężnego Twierdzenia Ergodycznego. Przypomnijmy je.

**Twierdzenie 2.** (*Twierdzenie Ergodyczne*) Dla każdego nieredukowalnego, nieokresowego łańcucha Markowa  $X$  oraz dla każdego rozkładu początkowego  $\mu^{(0)}$  mamy  $\mu^{(n)} \xrightarrow{TV} \pi$ , gdzie  $\pi$  jest rozkładem stacjonarnym.

*Dowód.* Udowodniliśmy już jedyność  $\pi$  na wcześniejszym wykładzie. Pozostaje wykazać zbieżność  $\mu^{(n)} \xrightarrow{TV} \pi$ . Niech  $S = 1, 2, \dots, k$  będzie zbiorem stanów. Musimy pokazać, że

$$\sum_{i=1}^k |\mu_i^{(n)} - \pi_i| \rightarrow 0$$

Niech  $X = (X_n)$  będzie naszym łańcuchem Markowa. Zauważmy drugi łańcuch  $Y = (Y_n)$  mający te same stany ale inne warunki początkowe:  $X$  ma  $\mu^{(0)}$ , natomiast  $Y$  ma  $\pi$ .

Aby nie zagmatwać się w labiryncie trików przedstawmy główną ideę tego dowodu. Jeśli  $X_m = Y_m$  dla pewnego  $m$ , to  $X_n$  i  $Y_n$  mają ten sam rozkład od tego momentu. Wynika to stąd, że opisuje je ta sama macierz.

Wprowadźmy zmienną losową

$$T = \min\{m : X_m = Y_m\}.$$

$$\forall_{i \in S} \forall_n \quad \mu_i^{(n)} = \mathbf{P}(X_n = i) = \mathbf{P}(X_n = i | T \leq n) + \mathbf{P}(X_n = i | T > n)$$

Zauważmy, że w wyrażeniu  $\mathbf{P}(X_n = i | T \leq n)$  możemy wymienić  $X_n$  na  $Y_n$ , gdyż w tej przestrzeni warunkowej są takie same.

$$\begin{aligned} \mu_i^{(n)} &= \mathbf{P}(Y_n = i | T \leq n) \mathbf{P}(T \leq n) + \\ &+ \mathbf{P}(X_n = i | T > n) \mathbf{P}(T > n) \leq \\ &\leq \mathbf{P}(Y_n = i) + \mathbf{P}(T > n) \end{aligned}$$

stąd

$$\mu_i^{(n)} \leq \pi_i + \mathbf{P}(T > n)$$

co implikuje

$$|\mu_i^{(n)} - \pi_i| \leq \mathbf{P}(T > n)$$

Pozostało jedynie pokazać, że  $\mathbf{P}(T > n) \xrightarrow{n \rightarrow \infty} 0$ . □

Uwaga. Gdy

$$\mu^{(0)} = (0, \dots, 0, 1, 0, \dots, 0)$$

gdzie jedynka jest na  $i$ -tym miejscu, wtedy

$$\mu_i^{(0)} \rightarrow \pi_i$$

Innymi słowy, nie istotne jest skąd zaczynamy, ale dokąd zmierzamy. Po pewnej ilości kroków stan początkowy „rozplywa się” i od pewnego momentu nie ważne jest już skąd zaczynaliśmy.

### 3 Odwracalne Łańcuchy Markowa

W tej części wykładu wprowadzone zostaną odwracalne łańcuchy Markowa, proste własności i implikacje oraz przykłady.

**Definicja 1.** Rozkład  $\pi$  nazywamy odwracalnym, gdy

$$\forall_{i,j \in S} \quad \pi_i P_{ij} = \pi_j P_{ji}$$

gdzie  $\pi_i$  jest  $i$ -tą współrzędną wektora prawdopodobieństwa rozkładu  $\pi$ , a  $P_{ij}$  prawdopodobieństwem przejścia ze stanu  $s_i$  do stanu  $s_j$ .

**Definicja 2.** Łańcuch Markowa nazywamy odwracalnym gdy jego rozkład jest douracalny.

**Lemat 2.** Rozkład odwracalny  $\pi$  jest rozkładem stacjonarnym.

*Dowód.*

$$\pi_j = \pi_j \cdot 1 = \pi_j \sum_{i=1}^k P_{ji} = \sum_{i=1}^k \pi_j P_{ji} = \sum_{i=1}^k \pi_i P_{ij}.$$

□

**Lemat 3.** Niech  $X, Y$  będą zmiennymi losowymi takimi, że

$$\forall_{n=0,1,\dots,N} \quad Y_n = X_{N-n},$$

oraz niech  $\mu^{(0)} = \pi$  będzie rozkładem odwracalnym. Wtedy

$$P(Y_{n+1} = j | Y_n = i) = \frac{\pi_j}{\pi_i} P_{ji} \quad (= P_{ij} = P(X_{n+1} = j | X_n = i))$$

*Dowód.* Pokażemy, że  $Y$  jest łańcuchem Markowa.

$$P(Y_{n+1} = i_{n+1} | Y_n = i_n, \dots, Y_0 = i_0) =$$

ze wzoru na prawdopodobieństwo warunkowe mamy

$$= \frac{P(Y_j = i_j, 0 \leq j \leq n+1)}{P(Y_j = i_j, 0 \leq j \leq n)} =$$

podstawiając  $X_{N-n}$  za  $Y_n$

$$= \frac{P(X_{N-n-1} = i_{n-1}, \dots, X_N = i_0)}{P(X_{N-n} = i_n, \dots, X_N = i_0)} =$$


stosując wzór łańcuchowy oraz  $P_{i_{n+1}, i_n} = P_{i_n, i_{n+1}}$  otrzymujemy



Oto konkretny przykład dla  $k = 4$ . Macierz prawdopodobieństwa jest postaci

$$P = \begin{pmatrix} 0 & 1 & 0 & 0 \\ 0.1 & 0 & 0.9 & 0 \\ 0 & 0.1 & 0 & 0.9 \\ 0 & 0 & 1 & 0 \end{pmatrix}$$

co daje graf przejść



Niech teraz  $\pi_1^*$  będzie dowolne, i niech

$$\pi_i^* = \frac{P_{i-1,i}}{P_{i,i-1}} \pi_{i-1}^*.$$

Rozkład  $\pi$  dany wzorem


$$\pi_i = \frac{\pi_i^*}{\sum \pi_i^*}$$

jest rozkładem stacjonarnym. Łatwo sprawdzić, że w naszym przykładzie rozkład przyjmuje następującą postać :

$$\pi = \left( \frac{1}{182}, \frac{10}{182}, \frac{90}{182}, \frac{8}{182} \right)$$

**Przykład 3.** Przykład łańcucha z rozkładem stacjonarnym i nieodwracalnym.

Niech dany będzie łańcuch Markowa



Rozkład  $(\frac{1}{4}, \frac{1}{4}, \frac{1}{4}, \frac{1}{4})$  jest stacjonarny. Nie jest on odwracalny, ponieważ ma „tendencję” do „przemieszczania” się zgodnie z kierunkiem wskazówek zegara. Brak symetryczności.