

# Ograniczenia informacji wzajemnej a estymacja ukrytego rzędu Markowa

Łukasz Dębowski  
ldebowsk@ipipan.waw.pl



Instytut Podstaw Informatyki PAN

Seminarium ZAMS, 23 listopada 2020

- 1 Hipoteza Hilberga i procesy unifilarne
- 2 Pojęcia z teorii MDL
- 3 Uniwersalność rozkładu Ryabki
- 4 Zgodność estymatora rzędu
- 5 Ograniczenia informacji wzajemnej
- 6 Procesy perygraficzne
- 7 Program na przyszłość

# Hipoteza Hilberga

- $H(X)$  – entropia Shannona.
- $I(X; Y) := H(X) + H(Y) - H(X, Y)$  – info. wzajemna.
- $K(w)$  – złożoność Kołmogorowa.
- $J(u; w) := K(u) + K(w) - K(u, w)$  – alg. info. wzajemna.
- **Hipoteza Hilberga:** Dla tekstów w języku naturalnym

$$J(x_1^n; x_{n+1}^{2n}) \propto n^\beta, \quad \beta > 0. \quad (1)$$

- Jeżeli dla procesu stacjonarnego  $(X_i)_{i \in \mathbb{Z}}$  zachodzi

$$I(X_1^n; X_{n+1}^{2n}) \propto n^\beta, \quad \beta > 0, \quad (2)$$

to proces nie może być ukrytym procesem Markowa o skończonej liczbie stanów ukrytych.

Chcemy pokazać, że to samo zachodzi dla (1)  
– również, gdy p-stwa przejścia są nieobliczalne.

# Procesy unifilarne (ogólne)

## Definicja

Proces  $(X_i)_{i \in \mathbb{N}}$  nad przeliczalnym alfabetem  $\mathbb{X}$  nazywa się **unifilarnym** względem  $(Y_i)_{i \in \mathbb{N}}$ , gdy  $(Y_i)_{i \in \mathbb{N}}$  jest procesem nad przeliczalnym alfabetem  $\mathbb{Y}$  takim, że

- 1  $P(X_i | Y_1^i, X_1^{i-1}) = \varepsilon(X_i | Y_i)$  – ukryta markowskość,
- 2  $Y_{i+1} = \tau(Y_i, X_i)$  – determinizm automatowy

dla pewnych  $\varepsilon : \mathbb{X} \times \mathbb{Y} \rightarrow [0, 1]$  oraz  $\tau : \mathbb{Y} \times \mathbb{X} \rightarrow \mathbb{Y}$ .

*Przykład 1:* Procesy Markowa  $n$ -tego bądź zmiennego rzędu.

*Przykład 2:* Ciekawa jest też klasa procesów unifilarnych, gdzie  $\mathbb{X} = \{0, 1\}$ ,  $\mathbb{Y} = \{0, 1\}^*$ , a funkcje  $\varepsilon$  i  $\tau$  są obliczalne. To m.in. procesy symulujące obliczenia maszyny Turinga z szumem.

*Przykład 3:* Położenie  $Y_i := P(X_i^\infty | X_{-\infty}^{i-1})$  spełnia warunki 1. i 2., ale niekoniecznie nad przeliczalnym alfabetem – również dla nieunifilarnych procesów o skończonej liczbie stanów ukrytych.

# Modele unifilarne (skończone, HMM)

Zakładamy, że alfabet  $\mathbb{X}$  jest skończony.

Unifilarne rozkłady o  $k = 1, 2, 3, \dots$  stanach ukrytych:

$$\mathbb{P}(x_1^n, y_1^n | k, \pi, \tau, \varepsilon) := \pi(y_1) \varepsilon(x_1 | y_1) \prod_{i=2}^n \mathbb{1}_{\{y_i = \tau(y_{i-1}, x_{i-1})\}} \varepsilon(x_i | y_i), \quad (3)$$

gdzie

- $\pi : \{1, \dots, k\} \rightarrow [0, 1], \sum_y \pi(y) = 1,$
- $\tau : \{1, \dots, k\} \times \mathbb{X} \rightarrow \{1, \dots, k\},$
- $\varepsilon : \mathbb{X} \times \{1, \dots, k\} \rightarrow [0, 1], \sum_x \varepsilon(x | y) = 1.$

Rozkład brzegowy:

$$\mathbb{P}(x_1^n | k, \pi, \tau, \varepsilon) := \sum_{y_1^n} \mathbb{P}(x_1^n, y_1^n | k, \pi, \tau, \varepsilon). \quad (4)$$

# Trzy pojęcia z teorii MDL

Maksymalna wiarygodność – ML:

$$\hat{\mathbb{P}}(x_1^n | k) := \max_{y, \tau, \epsilon} \mathbb{P}(x_1^n | k, y, \tau, \epsilon). \quad (5)$$

Unormowana maksymalna wiarygodność – NML (Shtarkov):

$$\mathbb{P}(x_1^n | k) := \frac{\hat{\mathbb{P}}(x_1^n | k)}{\sum_{z_1^n \in \mathbb{X}^n} \hat{\mathbb{P}}(z_1^n | k)} \leq \hat{\mathbb{P}}(x_1^n | k). \quad (6)$$

Rozkład uniwersalny (Ryabko):

$$\mathbb{P}(x_1^n) := \sum_{k=1}^{\infty} w_k \mathbb{P}(x_1^n | k), \quad w_k := \frac{1}{k} - \frac{1}{k+1}. \quad (7)$$

# Proste ograniczenia

Rząd maksymalizujący:

$$\mathbb{G}(\mathbf{x}_1^n) := \arg \max_{k \geq 1} \mathbb{P}(\mathbf{x}_1^n | \mathbf{k}). \quad (8)$$

Ograniczenie dwustronne rozkładu Ryabki przez NML:

$$\mathbb{P}(\mathbf{x}_1^n | \mathbb{G}(\mathbf{x}_1^n)) \geq \mathbb{P}(\mathbf{x}_1^n) \geq w_k \mathbb{P}(\mathbf{x}_1^n | \mathbf{k}). \quad (9)$$

„Superaddytywność” pseudorozkładu ML:

$$\hat{\mathbb{P}}(\mathbf{x}_1^n | \mathbf{k}) \hat{\mathbb{P}}(\mathbf{x}_{n+1}^{n+m} | \mathbf{k}) \geq \hat{\mathbb{P}}(\mathbf{x}_1^{n+m} | \mathbf{k}). \quad (10)$$

# Złożoność statystyczna

Używamy logarytmu binarnego  $\log x := \log_2 x$ .

Złożoność statystyczna (klasy rozkładów):

$$\mathbb{C}(n|k) := \log \frac{\hat{\mathbb{P}}(x_1^n|k)}{\mathbb{P}(x_1^n|k)} = \log \sum_{z_1^n \in \mathbb{X}^n} \hat{\mathbb{P}}(z_1^n|k) \leq n \log |\mathbb{X}|. \quad (11)$$

Zbiór różnych parametrów maksymalnej wiarygodności:

$$\mathcal{P}_{kn} := \left\{ (y, \tau, \varepsilon) : \exists_{x_1^n} \mathbb{P}(x_1^n|k, y, \tau, \varepsilon) = \hat{\mathbb{P}}(x_1^n|k) \right\}. \quad (12)$$

Zauważmy, że

$$\mathbb{C}(n|k) = \log \sum_{x_1^n \in \mathbb{X}^n} \hat{\mathbb{P}}(x_1^n|k) \leq \log |\mathcal{P}_{kn}|. \quad (13)$$



# Złożoność ukrytych modeli Markowa

Dla ustalonego  $(\mathbf{y}, \tau)$ ,  $\mathbb{P}(\mathbf{x}_1^n | \mathbf{k}, \mathbf{y}, \tau, \varepsilon)$  jest maksymalizowane dla

$$\varepsilon(\mathbf{b} | \mathbf{a}) = \frac{\sum_{i=1}^n \mathbf{1}\{(y_i, x_i) = (\mathbf{a}, \mathbf{b})\}}{\sum_{i=1}^n \mathbf{1}\{y_i = \mathbf{a}\}}, \quad (14)$$

gdzie  $\mathbf{y}_1 = \mathbf{y}$  oraz  $\mathbf{y}_i = \tau(\mathbf{y}_{i-1}, \mathbf{x}_{i-1})$  dla  $i \geq 2$ .

Różnych rozkładów  $\varepsilon$  jest nie więcej niż  $(n+1)^{k^{|\mathbb{X}|}}$ .

Różnych kombinacji  $(\mathbf{y}, \tau)$  jest nie więcej niż  $k \cdot k^{k^{|\mathbb{X}|}}$ .

Zatem

$$\mathbb{C}(n | k) \leq \log |\mathcal{P}_{kn}| \leq [k^{|\mathbb{X}|} + 1] \log[k(n+1)]. \quad (15)$$

# Uniwersalność rozkładu Ryabki

Zakładamy, że alfabet  $\mathbb{X}$  jest skończony.

Entropie warunkowe:

$$h_k^P := H(X_0 | X_{-k}^{-1}) = \mathbf{E} \left[ -\log P(X_0 | X_{-k}^{-1}) \right].$$

Intensywność entropii:

$$h^P := \lim_{n \rightarrow \infty} \frac{H(X_1^n)}{n} = \inf_k h_k^P = H(X_0 | X_{-\infty}^{-1}).$$

## Twierdzenie

Dla stacjonarnego ergodycznego procesu  $(X_i)_{i \in \mathbb{Z}}$ ,

$$\lim_{n \rightarrow \infty} \frac{1}{n} \left[ -\log \mathbb{P}(X_1^n) \right] = h^P \text{ prawie na pewno,} \quad (16)$$

$$\lim_{n \rightarrow \infty} \frac{1}{n} \mathbf{E} \left[ -\log \mathbb{P}(X_1^n) \right] = h^P. \quad (17)$$

## Dowód

Dla  $\tau(\mathbf{X}_1^k, \mathbf{X}_{k+1}) = \mathbf{X}_2^{k+1}$  i  $\varepsilon(\mathbf{X}_{k+1} | \mathbf{X}_1^k) = P(\mathbf{X}_{k+1} | \mathbf{X}_1^k)$  mamy

$$\hat{\mathbb{P}}(\mathbf{X}_1^n | |\mathbb{X}|^k) \geq \mathbb{P}(\mathbf{X}_1^n | |\mathbb{X}|^k, \mathbf{X}_{-k+1}^0, \tau, \varepsilon) = \prod_{i=1}^n P(\mathbf{X}_i | \mathbf{X}_{i-k}^{i-1}).$$

Zatem z górnego ograniczenia (15) na złożoność statystyczną i z twierdzenia ergodycznego Birkhoffa,

$$\begin{aligned} \limsup_{n \rightarrow \infty} \frac{1}{n} \left[ -\log \mathbb{P}(\mathbf{X}_1^n | |\mathbb{X}|^k) \right] \\ = \limsup_{n \rightarrow \infty} \frac{1}{n} \left[ -\log \hat{\mathbb{P}}(\mathbf{X}_1^n | |\mathbb{X}|^k) + \mathbb{C}(n | |\mathbb{X}|^k) \right] \leq h_k^P \text{ p.n.p.} \end{aligned}$$

Zatem z górnego ograniczenia (9) i lematu Barrona, otrzymujemy (16). Obserwując  $\mathbb{P}(\mathbf{X}_1^n) \geq \mathbf{w}_n \mathbb{P}(\mathbf{X}_1^n | n) = \mathbf{w}_n |\mathbb{X}|^{-n}$ , stąd otrzymujemy (17) ze zbieżności majoryzowanej.

# Zgodność i nieobciążoność estymatora rzędu

Zakładamy, że alfabet  $\mathbb{X}$  jest skończony.

Unifilarny rząd procesu:

$$M^P := \inf \left\{ k : \exists \pi, \tau, \varepsilon \forall n \geq 1, x_1^n P(X_1^n = x_1^n) = \mathbb{P}(x_1^n | k, \pi, \tau, \varepsilon) \right\}.$$

Estymator rzędu:

$$\mathbb{M}(x_1^n) := \min \left\{ k : \hat{P}(x_1^n | k) \geq w_n \mathbb{P}(x_1^n) \right\}, \quad w_n := \frac{1}{n} - \frac{1}{n+1}.$$

Mamy  $\mathbb{M}(x_1^n) \leq n$ , gdyż  $\hat{P}(x_1^n | k) = 1$  dla  $k \geq n$ .

## Twierdzenie

Dla stacjonarnego ergodycznego procesu  $(X_i)_{i \in \mathbb{Z}}$ ,

$$\lim_{n \rightarrow \infty} \mathbb{M}(X_1^n) = M^P \text{ prawie na pewno,} \quad (18)$$

$$\lim_{n \rightarrow \infty} \mathbf{E} \mathbb{M}(X_1^n) = M^P. \quad (19)$$

# Dowód braku przeszacowania

Z nierówności  $\hat{\mathbb{P}}(\mathbf{X}_1^n | M^P) \geq P(\mathbf{X}_1^n | Y_1)$  i lematu Barrona otrzymujemy

$$\begin{aligned} P\left(\mathbb{M}(\mathbf{X}_1^n) > M^P\right) &\leq P\left(\hat{\mathbb{P}}(\mathbf{X}_1^n | M^P) < w_n P(\mathbf{X}_1^n)\right) \\ &\leq P\left(\frac{w_n P(\mathbf{X}_1^n)}{P(\mathbf{X}_1^n | Y_1)} > 1\right) \leq w_n. \end{aligned} \quad (20)$$

Ponieważ  $\sum_{n=1}^{\infty} w_n = 1$ , niemożliwość przeszacowania wynika z lematu Borela-Cantellego.

## Dowód braku niedoszacowania (1/4)

Ponieważ rozkład Ryabki jest uniwersalny w sensie (16), a  $-\log w_n = o(n)$ , wystarczy dowieść

$$\liminf_{n \rightarrow \infty} \frac{1}{n} \left[ -\log \hat{\mathbb{P}}(X_1^n | \mathbf{k}) \right] > h^P \text{ p.n.p. dla } \mathbf{k} < M^P. \quad (21)$$

W dalszej kolejności pokażemy, że lewa strona równa jest pewnej entropii warunkowej  $h_{[\mathbf{k}]}^P$ , która jest większa niż  $h^P$  dla  $\mathbf{k} < M^P$ .

## Dowód braku niedoszacowania (2/4)

Zauważmy, że dla skończonego zbioru  $\mathcal{M}$ ,

$$\liminf_{n \rightarrow \infty} \min_{m \in \mathcal{M}} a_{nm} = \min_{m \in \mathcal{M}} \liminf_{n \rightarrow \infty} a_{nm}. \quad (22)$$

W naszym przypadku, zbiór par  $(y, \tau)$  dla ustalonego  $k$  jest skończony. Zatem

$$\begin{aligned} \liminf_{n \rightarrow \infty} \min_{y, \tau, \varepsilon} \frac{1}{n} \left[ -\log \mathbb{P}(X_1^n | k, y, \tau, \varepsilon) \right] = \\ \min_{y, \tau} \liminf_{n \rightarrow \infty} \min_{\varepsilon} \frac{1}{n} \left[ -\log \mathbb{P}(X_1^n | k, y, \tau, \varepsilon) \right]. \end{aligned} \quad (23)$$

## Dowód braku niedoszacowania (3/4)

Z teorii procesów asymptotycznie średnio stacjonarnych – Kieffer i Rahe (1981) oraz Gray i Kieffer (1980) – istnieją procesy stacjonarne  $(\bar{Y}_{i+1}^{y,\tau})_{i \in \mathbb{Z}}$  takie, że zachodzi rekursja  $\bar{Y}_{i+1}^{y,\tau} = \tau(\bar{Y}_i^{y,\tau}, X_i)$  oraz

$$\begin{aligned} & \min_{y,\tau} \liminf_{n \rightarrow \infty} \min_{\varepsilon} \frac{1}{n} \left[ -\log \mathbb{P}(X_1^n | k, y, \tau, \varepsilon) \right] \\ &= \min_{y,\tau} \liminf_{n \rightarrow \infty} \min_{\varepsilon} \frac{1}{n} \sum_{i=1}^n \left[ -\log \varepsilon(X_i | Y_i^{y,\tau}) \right] \\ &= h_{[k]}^P := \min_{y,\tau} \mathbf{E} \left[ -\log P(X_i | \bar{Y}_i^{y,\tau}) \right] \quad \text{p.n.p.} \quad (24) \end{aligned}$$

Niech  $y$  i  $\tau$  będą minimalizatorami. Oznaczmy  $\bar{Y}_i := \bar{Y}_i^{y,\tau}$ .

Co się dzieje, gdy  $h_{[k]}^P := H(X_i | \bar{Y}_i) = h^P$ ?



## Dowód braku niedoszacowania (4/4)

Ponieważ  $\bar{Y}_{i+1} = \tau(\bar{Y}_i, X_i)$ , mamy

$$H(X_i | \bar{Y}_i) - H(X_i | X_1^{i-1}, \bar{Y}_1) = I(X_i; X_1^{i-1}, \bar{Y}_1^{i-1} | \bar{Y}_i). \quad (25)$$

Zatem ze stacjonarności  $(X_i, \bar{Y}_i^{y, \tau})_{i \in \mathbb{Z}}$ ,

$$\sum_{i=1}^n H(X_i | \bar{Y}_i) = H(X_1^n | \bar{Y}_1) + \sum_{i=0}^{n-1} I(X_i; X_{-i}^{j-1}, \bar{Y}_{-i}^{j-1} | \bar{Y}_i). \quad (26)$$

Dzieląc przez  $n$  i kładąc  $n \rightarrow \infty$  otrzymujemy

$$h_{[k]}^P := H(X_i | \bar{Y}_i) = h^P + I(X_i; X_{-\infty}^{j-1}, \bar{Y}_{-\infty}^{j-1} | \bar{Y}_i). \quad (27)$$

A zatem jeżeli  $h_{[k]}^P = h^P$ , to  $I(X_i; X_{-\infty}^{j-1}, \bar{Y}_{-\infty}^{j-1} | \bar{Y}_i) = 0$ .

Czyli  $(X_i)_{i \in \mathbb{N}}$  jest unifilarnym procesem o  $\leq k$  stanach ukrytych o rozkładzie danym przez  $\bar{Y}_i$ .

# Dowód braku obciążenia

Ponieważ  $\mathbb{M}(x_1^n) \leq n$  oraz  $P(\mathbb{M}(X_1^n) > M^P) \leq w_n$ , mamy

$$\mathbf{E} \mathbb{M}(X_1^n) \leq M^P + nP(\mathbb{M}(x_1^n) > M^P) = M^P + \frac{1}{n+1}. \quad (28)$$

Z drugiej strony ze zgodności i lematu Fatou wynika

$$M^P = \mathbf{E} \liminf_{n \rightarrow \infty} \mathbb{M}(X_1^n) \leq \liminf_{n \rightarrow \infty} \mathbf{E} \mathbb{M}(X_1^n). \quad (29)$$

# Tempo wzrostu potęgowego

Wykładnik Hilberga:

$$\mathbf{hilb}_{n \rightarrow \infty} s(n) := \limsup_{n \rightarrow \infty} \frac{\log \max \{1, s(n)\}}{\log n}. \quad (30)$$

Mamy  $\mathbf{hilb}_{n \rightarrow \infty} n^\beta = \beta$  for  $\beta \geq 0$ .

## Twierdzenie

Dla funkcji  $\mathfrak{S} : \mathbb{N} \rightarrow \mathbb{R}$ , połóżmy  $\mathfrak{J}(n) := 2\mathfrak{S}(n) - \mathfrak{S}(2n)$ .  
Jeżeli  $\lim_{n \rightarrow \infty} \mathfrak{S}(n)/n = \mathfrak{s}$  dla  $\mathfrak{s} \in \mathbb{R}$ , to

$$\mathbf{hilb}_{n \rightarrow \infty} (\mathfrak{S}(n) - n\mathfrak{s}) \leq \mathbf{hilb}_{n \rightarrow \infty} \mathfrak{J}(n) \quad (31)$$

z równością, gdy  $\mathfrak{S}(n) - n\mathfrak{s} \geq 0$ .

# Wykładniki Hilberga dla procesu

$(X_i)_{i \in \mathbb{Z}}$  – proces stacjonarny nad skończonym alfabetem  $\mathbb{X}$ .

Entropia nadwyżkowa:

$$E^P := \lim_{n \rightarrow \infty} [H(X_1^n) - nh^P] = \lim_{n \rightarrow \infty} I(X_1^n; X_{n+1}^{2n}).$$

Z nierówności przetwarzania informacji  $E^P \leq \log M^P$ .

Możemy zdefiniować wykładniki Hilberga  $\beta_1^P \leq \beta_2^P \leq \beta_3^P$ , gdzie

$$\beta_1^P := \text{hilb}_{n \rightarrow \infty} [H(X_1^n) - nh^P] = \text{hilb}_{n \rightarrow \infty} I(X_1^n; X_{n+1}^{2n}) \leq 1,$$

$$\beta_2^P := \text{hilb}_{n \rightarrow \infty} \mathbf{E} [K(X_1^n) - nh^P] = \text{hilb}_{n \rightarrow \infty} \mathbf{E} J(X_1^n; X_{n+1}^{2n}) \leq 1,$$

$$\begin{aligned} \beta_3^P &:= \text{hilb}_{n \rightarrow \infty} \mathbf{E} [-\log \mathbb{P}(X_1^n) - nh^P] \\ &= \text{hilb}_{n \rightarrow \infty} \mathbf{E} [-\log \mathbb{P}(X_1^n) - \log \mathbb{P}(X_{n+1}^{2n}) + \log \mathbb{P}(X_1^{2n})] \leq 1. \end{aligned}$$

# Ograniczenie górne informacji wzajemnej

Zakładamy, że alfabet  $\mathbb{X}$  jest skończony.

## Twierdzenie

Dla procesu stacjonarnego  $(X_i)_{i \in \mathbb{Z}}$ ,

$$\beta_3^P \leq \beta_M^P := \text{hilb}_{n \rightarrow \infty} \mathbf{E} M(X_1^n). \quad (32)$$

## Wniosek

Dla unifilarnych procesów o skończonej liczbie stanów ukrytych zachodzi  $\beta_1^P = \beta_2^P = \beta_3^P = \beta_M^P = 0$ .

## Wniosek

Dla nieunifilarnych procesów o skończonej liczbie stanów ukrytych zachodzi  $\beta_1^P = \beta_2^P = 0$ .

## Dowód

Notacja:  $\lfloor r := -\log r$ .

Kładąc  $k := \mathbb{M}(X_1^{2n}) \leq 2n$ , z nierówności (9) i (10) mamy

$$\begin{aligned}
 & \lfloor \mathbb{P}(X_1^n) + \lfloor \mathbb{P}(X_{n+1}^{2n}) - \lfloor \mathbb{P}(X_1^{2n}) \\
 & \leq \lfloor w_k \mathbb{P}(X_1^n | k) + \lfloor w_k \mathbb{P}(X_{n+1}^{2n} | k) - \lfloor \hat{\mathbb{P}}(X_1^{2n} | k) / w_{2n} \\
 & \leq 2\mathbb{C}(n|k) + \lfloor w_k^2 w_{2n} + \lfloor \hat{\mathbb{P}}(X_1^n | k) + \lfloor \hat{\mathbb{P}}(X_{n+1}^{2n} | k) - \lfloor \hat{\mathbb{P}}(X_1^{2n} | k) \\
 & \leq 2\mathbb{C}(n|k) + \lfloor w_k^2 w_{2n}. \tag{33}
 \end{aligned}$$

Zatem z nierówności (15) otrzymujemy

$$\beta_3^P \leq \mathop{\text{hilb}}_{n \rightarrow \infty} \mathbf{E} \mathbb{C}(n | \mathbb{M}(X_1^{2n})) \leq \mathop{\text{hilb}}_{n \rightarrow \infty} \mathbf{E} \mathbb{M}(X_1^n). \tag{34}$$

# Ograniczenie dolne informacji wzajemnej

Zakładamy, że alfabet  $\mathbb{X}$  jest skończony.

Twierdzenie (Dębowski, 2018)

Niech  $g : \mathbb{N} \times \mathbb{X}^* \rightarrow \{0, 1, 2\}$  – funkcja obliczalna, zaś  $z = (z_k)_{k \in \mathbb{N}}$  – sekwencja algorytmicznie losowa, tzn.  $K(z_1^n) \geq n - c$  dla  $c > 0$ . Połóżmy

$$U_g(x_1^n | z) := \min \{k \geq 1 : g(k, x_1^n) \neq z_k\}. \quad (35)$$

Dla procesu stacjonarnego  $(X_i)_{i \in \mathbb{Z}}$ ,

$$\beta_{g,z}^P := \mathop{\text{hilb}}_{n \rightarrow \infty} \mathbf{E} U_g(X_1^n | z) \leq \beta_2^P. \quad (36)$$

*Przykład:* Wynik nieskończonego rzutu uczciwą monetą jest sekwencją algorytmicznie losową prawie na pewno. (lemat Barrona)

# Procesy perygraficzne

## Definicja (Debowski, 2018)

Proces stacjonary  $(X_i)_{i \in \mathbb{Z}}$  nazywa się **perygraficznym**,  
gdy  $\beta_{g,z}^P > 0$  dla pewnej f-cji obliczalnej  $g : \mathbb{N} \times \mathbb{X} \rightarrow \{0, 1, 2\}$   
i sekwencji algorytmicznie losowej  $z = (z_k)_{k \in \mathbb{N}}$ .

Dla nieskończonego alfabetu  $\mathbb{X}$  prostym przykładem procesu perygraficznego jest **proces Santa Fe**

$$X_i = (K_i, z_{K_i}), \quad (37)$$

gdzie  $K_i$  jest procesem IID o rozkładzie Zipfa  $P(K_i = k) \propto k^{-\alpha}$   
dla  $\alpha > 1$ . Wówczas  $\beta_{g,z}^P = 1/\alpha$ .

*Uwaga: Procesy perygraficzne są nieobliczalne, ale mogą być unifilarne. Obliczalne procesy unifilarne mogą mieć perygraficzne składowe ergodyczne prawie na pewno. (Ciekawe, kiedy tak jest.)*



# Procesy wyroczniowe

W pętli generujemy losowe słowo binarne  $y$ , symbol  $2$ , a potem bit  $z_{\phi(y)}$  sekwencji algorytmicznie losowej i powtarzamy...

## Definicja

Niech  $\psi : \mathbb{N} \rightarrow \{0, 1\}^*$  będzie rozwinięciem binarnym bez początkowej cyfry  $1$ , tzn.  $\psi(1) = \lambda$ ,  $\psi(2) = 0$ ,  $\psi(3) = 1$ ,  $\psi(4) = 00$ , ... Połóżmy  $\phi = \psi^{-1}$ . Niech  $z = (z_k)_{k \in \mathbb{N}}$  będzie sekwencją algorytmicznie losową.

Proces **Oracle**( $\theta$ ) z  $\theta \in [0, 1]$  to następujący proces unifilarny:

- $\mathbb{X} = \{0, 1, 2\}$ ,
- $\mathbb{Y} = \{a, b\} \times \{0, 1\}^*$ ,
- $\varepsilon(x|ay) = \frac{\theta}{2}$ ,  $\tau(ay, x) = ayx$  dla  $x \in \{0, 1\}$ ,  $y \in \{0, 1\}^*$ ,
- $\varepsilon(2|ay) = (1 - \theta)$ ,  $\tau(ay, 2) = by$  dla  $y \in \{0, 1\}^*$ ,
- $\varepsilon(z_{\phi(y)}|by) = 1$ ,  $\tau(by, z_{\phi(y)}) = a$  dla  $y \in \{0, 1\}^*$ .

# Ograniczenia informacji wzajemnej są ścisłe!

Aby wyznaczyć wykładnik Hilberga  $\beta_{g,z}$ , użyjemy predyktora

$$g(k, x_1^n) := \begin{cases} 0 & \text{if } 2_{-\psi(k)20} \sqsubseteq x_1^n \text{ and } 2_{-\psi(k)21} \not\sqsubseteq x_1^n, \\ 1 & \text{if } 2_{-\psi(k)21} \sqsubseteq x_1^n \text{ and } 2_{-\psi(k)20} \not\sqsubseteq x_1^n, \\ 2 & \text{else.} \end{cases} \quad (38)$$

W powyższym symbol ‘\_’ dopasowuje się do dowolnego symbolu.

## Twierdzenie

Dla predyktora (38) i stacjonarnego procesu Oracle( $\theta$ ),

$$\beta_{g,z}^P = \beta_2^P = \beta_3^P = \beta_M^P = \frac{1}{1 - \log \theta}. \quad (39)$$

# Program badawczy na przyszłość

## Procesy BDHM (Binary Denumerable Hidden Markov):

Klasa ukrytych procesów Markowa o  $\mathbb{X} = \{0, 1\}$  i  $\mathbb{Y} = \{0, 1\}^*$ .

Warto zbadać interakcje warunków takich jak:

- 1 unifilarność – determinizm automatowy – minimalność.
- 2 (mocna nie)ergodyczność – perygraficzność – obliczalność.
- 3 stacjonarność rozkładu stanów ukrytych/symboli emitowanych – średnia stacjonarna – asymptotycznie średnia stacjonarność.
- 4 rozstrzygalność i złożoność czasowa w/w charakteryzacji.

Zbliżone podejścia: Computational Mechanics z Santa Fe Institute.