

# Optymalność wnioskowania bayesowskiego dla algorytmicznie losowych parametrów

Łukasz Dębowski  
ldebowsk@ipipan.waw.pl



Instytut Podstaw Informatyki PAN  
Warszawa

# Główne idee

Algorytmiczna teoria informacji sugeruje atrakcyjną interpretację wnioskowania bayesowskiego:

- 1 Jeżeli wierzymy, że parametr jest typowy dla jakiegoś rozkładu a priori, może to oznaczać, że wierzymy, że parametr ów jest algorytmicznie losowy względem rozkładu a priori.
- 2 Można pokazać, że jeżeli parametr jest efektywnie estymowalny, to wnioskowanie bayesowskie jest optymalne wtedy i tylko wtedy, gdy parametr jest algorytmicznie losowy względem rozkładu a priori.

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania
- 7 Podsumowanie

- 1 Wprowadzenie
- 2 **Złożoność Kołmogorowa**
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania
- 7 Podsumowanie

# Bezprzedrostkowa maszyna Turinga (Chaitin 1975)


Rozpatrzmy maszynę, która ma dwie taśmy:

- 1 dwukierunkową taśmę  $(X_i)_{i \in \mathbb{Z}}$  wypełnioną symbolami  $0$ ,  $1$  i  $B$ ,
- 2 jednokierunkową taśmę  $(Y_k)_{k \in \mathbb{N}}$  wypełnioną symbolami  $0$  i  $1$ .

Głowica maszyny przesuwa się w obu kierunkach taśmy  $(X_i)_{i \in \mathbb{Z}}$  i tylko w kierunku rosnących  $k$  wzdłuż taśmy  $(Y_k)_{k \in \mathbb{N}}$ .

Taśma  $(X_i)_{i \in \mathbb{Z}}$  może być czytana i nadpisywana, taśma  $(Y_k)_{k \in \mathbb{N}}$  jest tylko do odczytu.

# Bezprzedrostkowa maszyna Turinga



Początkowy i końcowy stan maszyny  $S$  dla  $S(11010|011) = 01$ .

## Zatrzymywanie się na wejściu

Oznaczmy  $\mathbb{B} = \{0, 1\}^*$ . Mówimy, że maszyna  $\mathbf{S}$  zatrzymuje się na wejściu  $(\mathbf{p}, \mathbf{q}) \in \mathbb{B}^* \times (\mathbb{B}^* \cup \mathbb{B}^{\mathbb{N}})$  i zwraca  $\mathbf{w} \in \mathbb{B}^*$ , jeżeli:

- (A) Głowica w stanie początkowym odczytuje symbole  $\mathbf{Y}_1$  i  $\mathbf{X}_1$ , a początkowy stan taśm to  $\mathbf{Y}_1^{|\mathbf{p}|} = \mathbf{p}$  oraz  $\mathbf{X}_1^{|\mathbf{q}|+1} = \mathbf{q}\mathbf{B}$  lub  $\mathbf{X}_1^\infty = \mathbf{q}$ , jeżeli  $\mathbf{q}$  jest ciągiem nieskończonym. Kładzie się także  $\mathbf{X}_i = \mathbf{0}$  dla  $i < 1$  oraz  $i > |\mathbf{q}| + 1$ , jeżeli  $\mathbf{q}$  jest ciągiem skończonym (napisem).
- (B) Głowica w stanie końcowym odczytuje symbole  $\mathbf{Y}_{|\mathbf{p}|}$  oraz  $\mathbf{X}_j$ , a końcowy stan taśmy  $(\mathbf{X}_i)_{i \in \mathbb{Z}}$  to  $\mathbf{X}_j^{|\mathbf{w}|+j} = \mathbf{w}\mathbf{B}$ .

Zakładając, że (A) jest spełnione, piszemy

$$\mathbf{S}(\mathbf{p}|\mathbf{q}) = \begin{cases} \mathbf{w}, & \text{jeżeli (B) jest spełnione,} \\ \infty, & \text{jeżeli (B) nie jest spełnione dla żadnego } \mathbf{w} \in \mathbb{B}^*. \end{cases}$$

Dla danego  $\mathbf{q}$  zbiór napisów  $\mathbf{p}$  takich, że maszyna  $\mathbf{S}$  zatrzymuje się na wejściu  $(\mathbf{p}, \mathbf{q})$  jest zbiorem bezprzedrostkowym. Takie napisy nazywamy *samoograniczającymi się programami*.

# Złożoność bezprzedrostkowa

## Definicja (złożoność bezprzedrostkowa)

Warunkowa bezprzedrostkowa złożoność Kolmogorowa  $K_S(\mathbf{w}|\mathbf{q})$  napisu  $\mathbf{w} \in \mathbb{B}^*$  względem ciągu  $\mathbf{q} \in (\mathbb{B}^* \cup \mathbb{B}^{\mathbb{N}})$  i maszyny  $\mathbf{S}$  zdefiniowana jest jako

$$K_S(\mathbf{w}|\mathbf{q}) := \min_{\mathbf{p} \in \mathbb{B}^*} \{|\mathbf{p}| : \mathbf{S}(\mathbf{p}|\mathbf{q}) = \mathbf{w}\}. \quad (1)$$

Bezwarunkowa bezprzedrostkowa złożoność Kolmogorowa  $K_S(\mathbf{w})$  napisu  $\mathbf{w} \in \mathbb{B}^*$  względem maszyny  $\mathbf{S}$  zdefiniowana jest jako

$$K_S(\mathbf{w}) := K_S(\mathbf{w}|\lambda), \quad (2)$$

gdzie  $\lambda$  jest napisem pustym.



# Maszyny uniwersalne

## Definicja (maszyna uniwersalna)

Maszynę  $\mathbf{V}$  nazywa się *uniwersalną*, jeżeli dla każdej maszyny  $\mathbf{S}$  istnieje napis  $\mathbf{u} \in \mathbb{B}^*$  taki, że

$$\mathbf{V}(\mathbf{u}\mathbf{p}|\mathbf{q}) = \mathbf{S}(\mathbf{p}|\mathbf{q}) \quad (3)$$

dla wszystkich  $\mathbf{p} \in \mathbb{B}^*$  i  $\mathbf{q} \in (\mathbb{B}^* \cup \mathbb{B}^{\mathbb{N}})$ .

Uniwersalne maszyny istnieją. Przyjmujemy ten fakt bez dowodu.

# Twierdzenie o niezmienniczości

## Twierdzenie

Dla dowolnych dwu maszyn uniwersalnych  $\mathbf{V}$  and  $\mathbf{V}'$  istnieje stała  $c$  taka, że

$$|\mathbf{K}_{\mathbf{V}}(\mathbf{w}|\mathbf{q}) - \mathbf{K}_{\mathbf{V}'}(\mathbf{w}|\mathbf{q})| \leq c \quad (4)$$

dla wszystkich  $\mathbf{w} \in \mathbb{B}^*$  i  $\mathbf{q} \in (\mathbb{B}^* \cup \mathbb{B}^{\mathbb{N}})$ .

## Dowód.

Mamy  $\mathbf{V}(\mathbf{u}\mathbf{p}|\mathbf{q}) = \mathbf{V}'(\mathbf{p}|\mathbf{q})$  i  $\mathbf{V}'(\mathbf{u}'\mathbf{p}|\mathbf{q}) = \mathbf{V}(\mathbf{p})$  dla pewnych napisów  $\mathbf{u}$  i  $\mathbf{u}'$ . Stąd  $\mathbf{K}_{\mathbf{V}}(\mathbf{w}|\mathbf{q}) \leq \mathbf{K}_{\mathbf{V}'}(\mathbf{w}|\mathbf{q}) + |\mathbf{u}|$  oraz  $\mathbf{K}_{\mathbf{V}'}(\mathbf{w}|\mathbf{q}) \leq \mathbf{K}_{\mathbf{V}}(\mathbf{w}|\mathbf{q}) + |\mathbf{u}'|$ . □

# Złożoność bezprzedrostkowa II

## Definicja (złożoność bezprzedrostkowa II)

Niech  $\mathbf{V}$  będzie pewną maszyną uniwersalną. Kładziemy

$$\mathbf{K}(\mathbf{w}|\mathbf{q}) := \mathbf{K}_{\mathbf{V}}(\mathbf{w}|\mathbf{q}), \quad (5)$$

$$\mathbf{K}(\mathbf{w}) := \mathbf{K}_{\mathbf{V}}(\mathbf{w}). \quad (6)$$

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne**
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania
- 7 Podsumowanie

# Obliczalne funkcje dyskretne

Oznaczmy  $\mathbb{A} = \mathbb{B}^* \cup \mathbb{B}^{\mathbb{N}}$ . Złożoność Kołmogorowa dyskretnej funkcji częściowej  $\mathbf{f} : \mathbb{A} \rightarrow \mathbb{B}^* \cup \{\infty\}$  definiujemy jako

$$\mathbf{K}(\mathbf{f}) := \min_{\mathbf{p}} \{|\mathbf{p}| : \forall \mathbf{u} \in \mathbb{A} \mathbf{V}(\mathbf{p}|\mathbf{u}) = \mathbf{f}(\mathbf{u})\}. \quad (7)$$

## Definicja (obliczalna funkcja dyskretna)

Funkcja  $\mathbf{f} : \mathbb{A} \rightarrow \mathbb{B}^* \cup \{\infty\}$  jest *obliczalna*, jeżeli  $\mathbf{K}(\mathbf{f}) < \infty$ .

To uogólnia się na funkcje liczbowe, kodując w ustalony sposób liczby wymierne  $\mathbb{Q}^* \leftrightarrow \mathbb{B}^*$  oraz rzeczywiste  $\mathbb{R}^{\mathbb{N}} \leftrightarrow \mathbb{B}^{\mathbb{N}}$ .

# Semiobliczalne funkcje rzeczywiste

## Definicja (semiobliczalna od dołu funkcja rzeczywista)

Funkcja  $f : \mathbb{A} \rightarrow \mathbb{R}$  nazywa się *semiobliczalną od dołu*, jeżeli istnieje obliczalna funkcja  $\mathbf{A} : \mathbb{A} \times \mathbb{N} \rightarrow \mathbb{Q}$ , która spełnia  $\mathbf{A}(x, k + 1) \geq \mathbf{A}(x, k)$  oraz

$$\forall x \in \mathbb{A} \quad \lim_{k \rightarrow \infty} \mathbf{A}(x, k) = f(x). \quad (8)$$

## Definicja (semiobliczalna od góry funkcja rzeczywista)

Funkcja  $f : \mathbb{A} \rightarrow \mathbb{R}$  nazywa się *semiobliczalną od góry*, jeżeli istnieje obliczalna funkcja  $\mathbf{A} : \mathbb{A} \times \mathbb{N} \rightarrow \mathbb{Q}$ , która spełnia  $\mathbf{A}(x, k + 1) \leq \mathbf{A}(x, k)$  oraz

$$\forall x \in \mathbb{A} \quad \lim_{k \rightarrow \infty} \mathbf{A}(x, k) = f(x). \quad (9)$$

# Obliczalne funkcje rzeczywiste

## Definicja (obliczalna funkcja rzeczywista)

Funkcja  $f : \mathbb{A} \rightarrow \mathbb{R}$  nazywa się *obliczalną*, jeżeli istnieje obliczalna funkcja  $\mathbf{A} : \mathbb{A} \times \mathbb{N} \rightarrow \mathbb{Q}$ , która spełnia

$$\forall_{x \in \mathbb{B}} |f(x) - \mathbf{A}(x, k)| < 1/k. \quad (10)$$

- Funkcja, która jest semiobliczalna od góry i od dołu, jest obliczalna.
- Złożoność Kołmogorowa jest semiobliczalna od góry, ale nie jest obliczalna.

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna**
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania
- 7 Podsumowanie



# Ciągi i miary

Ciągi nieskończone piszmy jako  $\mathbf{x} = (\mathbf{x}_1, \mathbf{x}_2, \mathbf{x}_3, \dots)$ , gdzie  $\mathbf{x}_i \in \mathbb{B}$ .

Ponadto oznaczamy  $\mathbf{x}_1^m = (\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_m)$ .

Symbol  $\mathbf{P}$  oznaczać będzie miarę na nieskończonych ciągach.

Będziemy pisać  $\mathbf{P}(\mathbf{w}) = \mathbf{P}\left(\left\{\mathbf{x} : \mathbf{x}_1^{|\mathbf{w}|} = \mathbf{w}\right\}\right)$ .

Zatem  $\mathbf{P}$  spełnia

$$\mathbf{P}(\lambda) = 1,$$

$$\mathbf{P}(\mathbf{w}) \geq 0,$$

$$\mathbf{P}(\mathbf{w}) = \sum_{\mathbf{a} \in \mathbb{B}} \mathbf{P}(\mathbf{w}\mathbf{a}).$$

Miarą obliczalną nazywać będziemy miarę taką, że funkcja

$\mathbf{P} : \mathbb{B}^* \ni \mathbf{w} \mapsto \mathbf{P}(\mathbf{w}) \in \mathbb{R}$  jest obliczalna.

# Twierdzenie Barrona

Długość dowolnego kodu bezprzedrostkowego jest prawie na pewno asymptotycznie nieskończenie większa niż punktowa entropia.

## Twierdzenie Barrona

Niech  $\mathbf{B} : \mathbb{B}^* \rightarrow \mathbb{B}^*$  będzie kodem bezprzedrostkowym. Wówczas dla dowolnej miary  $\mathbf{P}$  mamy

$$\mathbf{P} \left( \left\{ \mathbf{x} : \lim_{m \rightarrow \infty} [|\mathbf{B}(\mathbf{x}_1^m)| + \log \mathbf{P}(\mathbf{x}_1^m)] = \infty \right\} \right) = \mathbf{1}. \quad (11)$$

Dowód: Nierówność Markowa + nierówność Krafta + lemat Borela-Cantellego.

# Ciągi algorytmicznie losowe

Złożoność Kolmogorowa jest najmniejszą (z dokładnością do stałej) semiobliczalną od góry długością kodu bezprzedrostkowego. Mamy stąd:

$$K(x_1^m) \leq -\log P(x_1^m) + 2 \log m + c.$$

## Definicja (ciąg algorytmicznie losowy)

Mówimy, że  $x$  jest algorytmicznie losowy, jeżeli

$$\lim_{m \rightarrow \infty} [K(x_1^m) + \log P(x_1^m)] = \infty. \quad (12)$$

Z twierdzenia Barrona, zbiór ciągów losowych ma miarę **1**.

# Semimiary

Semimiarą  $\mathbf{U}$  nazywamy funkcję, która spełnia

$$\mathbf{U}(\lambda) \leq 1,$$

$$\mathbf{U}(\mathbf{w}) \geq 0,$$

$$\mathbf{U}(\mathbf{w}) \geq \sum_{a \in \mathbb{B}} \mathbf{U}(\mathbf{w}a).$$

## Twierdzenie

Ciąg  $\mathbf{x}$  jest algorytmicznie losowy wtedy i tylko wtedy, gdy

$$\sup_{n \in \mathbb{N}} \frac{\mathbf{U}(\mathbf{x}_1^n)}{\mathbf{P}(\mathbf{x}_1^n)} < \infty \quad (13)$$

zachodzi dla dowolnej semiobliczalnej od dołu semimiary  $\mathbf{U}$ .

Zatem ciągi losowe to są dokładnie te ciągi, które są optymalnie kompresowane przez miarę  $\mathbf{P}$  w klasie semimiar semiobl. od dołu.

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie**
- 6 Optymalność wnioskowania
- 7 Podsumowanie

# Parametry i jądra

Teraz pokażemy, jak pojęcie losowości algorytmicznej pozwala zrozumieć mocne i słabe strony wnioskowania bayesowskiego.

Niech  $\theta = (\theta_1, \theta_2, \theta_3, \dots)$ , gdzie  $\theta_i \in \mathbb{B}$ , oznacza parametr. Równoważnie ciąg ten będziemy interpretować jako rozwinięcie binarne liczby rzeczywistej, oznaczanej również przez  $\theta$ .

## Definicja (jądro)

Funkcję  $\mathbf{P}(\cdot|\cdot) : \mathbb{B}^* \times \mathbb{B}^{\mathbb{N}} \rightarrow \mathbb{R}$  nazywamy *jądrem*, jeżeli  $\mathbf{P}(\mathbf{w}|\cdot)$  jest mierzalne dla każdego  $\mathbf{w}$ , a  $\mathbf{P}(\cdot|\theta)$  jest miarą prawdopodobieństwa dla każdego  $\theta$ .

# Jądra obliczalne

- Jądro  $\mathbf{P}$  nazywamy obliczalnym, jeżeli funkcja  $\mathbf{P}(\cdot|\cdot) : \mathbb{B}^* \times \mathbb{B}^N \ni (\mathbf{w}, \theta) \mapsto \mathbf{P}(\mathbf{w}|\theta) \in \mathbb{R}$  jest obliczalna. Jest to typowa sytuacja w statystyce.
- Zwróćmy uwagę, że nawet dla obliczalnego jądra, warunkowa miara  $\mathbf{P}(\cdot|\theta)$  nie musi być obliczalna, jeżeli ustalimy określoną wartość parametru  $\theta$ .
- Typowo, mając  $\mathbf{P}(\cdot|\theta)$  możemy obliczyć  $\theta$  z dowolną dokładnością, generując typowe dane i estymując z nich parametr. Wówczas miara  $\mathbf{P}(\cdot|\theta)$  nie jest obliczalna, jeżeli parametr jest algorytmicznie losowy.
- Zatem optymalny obliczalny kompresor danych typowych dla miary warunkowej  $\mathbf{P}(\cdot|\theta)$  jest różny od tej miary.

# Miara bayesowska

- Aby wskazać optymalny kompresor danych typowych dla miary nieobliczalnej, wprowadźmy pewne pojęcia z zakresu wnioskowania bayesowskiego.
- Niech  $\mathbf{Q}$  będzie obliczalną miarą zwaną rozkładem a priori, zaś  $\mathbf{P}$  niech będzie obliczalnym jądrem. Miara

$$\mathbf{Y}(\mathbf{w}) = \int \mathbf{P}(\mathbf{w}|\theta)d\mathbf{Q}(\theta) \quad (14)$$

jest obliczalna i będzie nazywana miarą bayesowską.

- Pokażemy, że miara bayesowska  $\mathbf{Y}$  jest optymalnym obliczalnym kompresorem danych typowych dla miary warunkowej  $\mathbf{P}(\cdot|\theta)$ , jeżeli parametr jest typowy dla rozkładu a priori  $\mathbf{Q}$ .



# Bayes jest optymalny prawie wszędzie

Oznaczmy zbiór ciągów algorytmicznie losowych dla miary  $\mathbf{Y}$  jako

$$\mathcal{R}_{\mathbf{Y}} := \left\{ \mathbf{x} : \lim_{m \rightarrow \infty} [\mathbf{K}(\mathbf{x}_1^m) + \log \mathbf{Y}(\mathbf{x}_1^m)] = \infty \right\}. \quad (15)$$

Następujące twierdzenie orzeka, że dla prawie wszystkich parametrów  $\theta$ , dane typowe dla miar warunkowych  $\mathbf{P}(\cdot|\theta)$  są optymalnie kompresowane przez miarę  $\mathbf{Y}$ .

## Twierdzenie

Mamy

$$\mathbf{Q}(\{\theta : \mathbf{P}(\mathcal{R}_{\mathbf{Y}}|\theta) = 1\}) = 1.$$

Dowód: Prosty wniosek z  $\mathbf{Y}(\mathcal{R}_{\mathbf{Y}}) = 1$ .

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania**
- 7 Podsumowanie

# Bayes jest optymalny tylko dla losowych parametrów

W następnej kolejności, chcielibyśmy pokazać, że dla pewnych jąder poprzednie twierdzenie może zostać wzmocnione jako

$$\mathbf{P}(\mathcal{R}_Y|\theta) = \begin{cases} \mathbf{1} & \text{jeżeli } \theta \in \mathcal{R}_Q, \\ \mathbf{0} & \text{jeżeli } \theta \notin \mathcal{R}_Q. \end{cases} \quad (16)$$

Istnieją jądra, dla których nie jest to prawdą.

Na przykład, jeżeli  $\mathbf{P}(\cdot|\theta)$  nie zależy od  $\theta$ , otrzymujemy  $\mathbf{P}(\mathcal{R}_Y|\theta) = \mathbf{1}$  dla każdego  $\theta$  niezależnie od rozkładu a priori.

Pokażemy, że dychotomia (16) zachodzi, jeżeli jądro dopuszcza istnienie efektywnego estymatora.

# Efektywny estymator

## Definicja (efektywnie ściśle zgodny estymator)

Estymator  $\mathbf{T}(\mathbf{x}_1^n)$  nazywamy *efektywnie ściśle zgodnym*, jeżeli istnieje obliczalna funkcja  $\mathbf{N}(\epsilon, \delta)$  taka, że dla każdego  $\theta$  i dla wszystkich  $\epsilon$  i  $\delta$  mamy

$$\mathbf{P} \left( \left\{ \mathbf{x} : \sup_{n \geq \mathbf{N}(\epsilon, \delta)} |\mathbf{T}(\mathbf{x}_1^n) - \theta| > \epsilon \right\} \middle| \theta \right) \leq \delta.$$

# Ciągi warunkowo losowe

## Definicja (ciąg warunkowo losowy)

Mówimy, że ciąg  $\mathbf{x}$  jest *warunkowo algorytmicznie losowy* dla obliczalnego jądra  $\mathbf{P}$  względem parametru  $\theta$ , jeżeli

$$\lim_{m \rightarrow \infty} [\mathbf{K}(\mathbf{x}_1^m | \theta) + \log \mathbf{P}(\mathbf{x}_1^m | \theta)] = \infty. \quad (17)$$

Zbiór ciągów warunkowo algorytmicznie losowych oznaczamy jako

$$\mathcal{R}_{\mathbf{P}|\theta} := \left\{ \mathbf{x} : \lim_{m \rightarrow \infty} [\mathbf{K}(\mathbf{x}_1^m | \theta) + \log \mathbf{P}(\mathbf{x}_1^m | \theta)] = \infty \right\}. \quad (18)$$

Z twierdzenia Barrona,  $\mathbf{P}(\mathcal{R}_{\mathbf{P}|\theta} | \theta) = 1$ .

# Twierdzenie V'yugina

## Twierdzenie V'yugina

Jeżeli jądro  $\mathbf{P}$  dopuszcza efektywnie ściśle zgodny estymator  $\mathbf{T}(\mathbf{x}_1^n)$ , to

$$\lim_{n \rightarrow \infty} \mathbf{T}(\mathbf{x}_1^n) = \theta \quad (19)$$

dla każdego  $\mathbf{x} \in \mathcal{R}_{\mathbf{P}|\theta}$ .

Wówczas zbiory  $\mathcal{R}_{\mathbf{P}|\theta}$  są rozłączne.

# Twierdzenie Takahashiego

- Kolejny fakt, z którego skorzystamy, to rozkład zbioru ciągów losowych względem miary bayesowskiej.
- Zbiór ten rozkłada się na zbiory ciągów losowych względem miar warunkowych.
- Należy podkreślić, że rozkład ten przebiega wyłącznie po parametrach, które są losowe względem rozkładu a priori.

## Twierdzenie Takahashiego

Dla  $\mathbf{Y} = \int \mathbf{P}(\cdot|\theta)d\mathbf{Q}(\theta)$  zachodzi

$$\mathcal{R}_{\mathbf{Y}} = \bigcup_{\theta \in \mathcal{R}_{\mathbf{Q}}} \mathcal{R}_{\mathbf{P}|\theta}. \quad (20)$$

# Twierdzenie o optymalności

Teraz możemy sformułować twierdzenie o optymalności.

## Twierdzenie

Dla obliczalnego jądra  $\mathbf{P}$  i obliczalnego rozkładu a priori  $\mathbf{Q}$  określmy miarę bayesowską  $\mathbf{Y} = \int \mathbf{P}(\cdot|\theta)d\mathbf{Q}(\theta)$ . Jeżeli jądro dopuszcza efektywnie ściśle zgodny estymator parametru, to mamy dychotomię

$$\mathbf{P}(\mathcal{R}_{\mathbf{Y}}|\theta) = \begin{cases} \mathbf{1} & \text{jeżeli } \theta \in \mathcal{R}_{\mathbf{Q}}, \\ \mathbf{0} & \text{jeżeli } \theta \notin \mathcal{R}_{\mathbf{Q}}. \end{cases} \quad (21)$$

## Dowód.

Z twierdzenia V'yugina zbiory  $\mathcal{R}_{\mathbf{P}|\theta}$  są rozłączne. Mamy także  $\mathbf{P}(\mathcal{R}_{\mathbf{P}|\theta}|\theta) = \mathbf{1}$  dla każdego  $\theta$ . Zatem (21) wynika z twierdzenia Takahashiego. □



# Modele $\tau$ -wyuczalne

## Definicja (modele $\tau$ -wyuczalne)

Niech  $\mathbf{P}$  będzie jądrem, zaś  $\mathbf{Q}$  rozkładem a priori. Zdefiniujmy miarę

$$\mathbf{T}(\mathbf{w}, \mathbf{z}) := \int_{\mathbf{A}(\mathbf{z})} \mathbf{P}_\theta(\mathbf{w}) d\mathbf{Q}(\theta), \quad (22)$$

gdzie  $\mathbf{A}(\mathbf{z}) := \{\theta \in \Theta : \mathbf{z} \text{ jest przedrostkiem } \theta\}$ , oraz miarę

$$\mathbf{Y}(\mathbf{w}) := \mathbf{T}(\mathbf{w}, \lambda) = \int \mathbf{P}_\theta(\mathbf{w}) d\mathbf{Q}(\theta). \quad (23)$$

Parę  $(\mathbf{P}, \mathbf{Q})$  nazywam  $\tau$ -wyuczalną, jeżeli dla funkcji  $\tau : \mathbb{B}^* \rightarrow \mathbb{N}$ , wszystkich  $\theta \in \mathbb{B}^{\mathbb{N}}$ ,  $\mathbf{P}_\theta$ -prawie wszystkich  $\mathbf{x}$  i  $\mathbf{n} = \tau(\theta_1^{\mathbf{n}})$  zachodzi

$$\lim_{m \rightarrow \infty} \mathbf{T}(\mathbf{x}_1^{\mathbf{n}}, \theta_1^{\mathbf{n}}) / \mathbf{Y}(\mathbf{x}_1^{\mathbf{n}}) = 1. \quad (24)$$

# Mój wynik

Wykazałem następujący fakt:

## Twierdzenie

Niech para  $(\mathbf{P}, \mathbf{Q})$  będzie  $\tau$ -wyuczalna z obliczalnym jądrem  $\mathbf{P}$ , obliczalnym rozkładem a priori  $\mathbf{Q}$  i obliczalną funkcją  $\tau$ . Wówczas zachodzi dychotomia

$$\mathbf{P}(\mathcal{R}_Y|\theta) = \begin{cases} 1 & \text{jeżeli } \theta \in \mathcal{R}_Q, \\ 0 & \text{jeżeli } \theta \notin \mathcal{R}_Q. \end{cases} \quad (25)$$

Dowód tego faktu nie odwołuje się do rozłączności zbiorów  $\mathcal{R}_{\mathbf{P}|\theta}$ , której nie udało mi się wykazać.

# Efektywny estymator II

## Definicja (efektywnie ściśle zgodny estymator II)

Estymator  $\mathbf{T}(\mathbf{x}_1^n)$  nazywamy *efektywnie ściśle zgodnym II*, jeżeli dla każdego  $\theta$  istnieje obliczalna funkcja  $\mathbf{N}(\epsilon, \delta)$  taka, że dla wszystkich  $\epsilon$  i  $\delta$  mamy

$$\mathbf{P} \left( \left\{ \mathbf{x} : \sup_{n \geq \mathbf{N}(\epsilon, \delta)} |\mathbf{T}(\mathbf{x}_1^n) - \theta| > \epsilon \right\} \middle| \theta \right) \leq \delta.$$

Czy tw. V'yugina można uogólnić na ten przypadek?

- 1 Wprowadzenie
- 2 Złożoność Kołmogorowa
- 3 Funkcje obliczalne
- 4 Losowość algorytmiczna
- 5 Wnioskowanie bayesowskie
- 6 Optymalność wnioskowania
- 7 Podsumowanie

# Podsumowanie

- Pokazaliśmy, że jeżeli parametr można efektywnie wyestymować, to miara bayesowska zadaje optymalną obliczalną kompresję danych, które są losowe względem miary warunkowej, wtedy i tylko wtedy, gdy parametr jest losowy względem rozkładu a priori.
- Stwierdzenie to jest użyteczne, jeżeli miara warunkowa nie jest obliczalna dla zadanego parametru.
- Ponadto, wiedząc, kiedy kompresja bayesowska jest suboptymalna, powinniśmy dostosowywać rozkład a priori do naszych rzeczywistych przypuszczeń co do złożoności algorytmicznej parametru.
- Czy dla dowolnego parametru istnieje obliczalny rozkład a priori, względem którego parametr jest losowy?