

# Kodowanie, Kompresja, Kryptografia

konspekt II, 8.III.2022

Przesyłamy słowa  $\alpha \in \mathcal{A}^*$ ,  $\mathcal{A} = \{a_1, a_2, \dots, a_k\}$ , i zakładamy, że litery  $a_i$  pojawiają się w nich z prawdopodobieństwami  $p_i = p(a_i)$ .

Szukamy kodu  $c : \mathcal{A} \rightarrow \mathcal{B}^*$ , który minimalizuje *średnią* długość słowa kodowego

$$\hat{l} = \sum_{i=1}^k p(a_i) l(a_i) = \min \quad \text{pod warunkiem, że} \quad \sum_{i=1}^k D^{-l(a_i)} \leq 1.$$

Szukamy więc układu długości  $l_i = l(a_i)$  minimalizujących  $\hat{l}$  przy ograniczeniu

$$g(l_1, \dots, l_k) = \sum_{i=1}^k D^{-l_i} - 1 = 0.$$

Oznaczamy

$$F(l_1, \dots, l_k, \lambda) = \hat{l}(l_1, \dots, l_k) + \lambda g(l_1, \dots, l_k)$$

i szukamy ekstremum  $F$ ,  $\nabla F = 0$ , czyli

$$\begin{aligned} \frac{\partial \hat{l}}{\partial l_i} = -\lambda \frac{\partial g}{\partial l_i} &\Rightarrow p(a_i) = \lambda \ln D D^{-l_i} \\ \frac{\partial F}{\partial \lambda} = 0 &\Rightarrow \sum_{i=1}^k D^{-l_i} = 1. \end{aligned}$$

Sumując stronami po  $i$  otrzymujemy  $\lambda \ln D = 1$ , a stąd  $p_i = D^{-l_i}$ , czyli po zlogarytmowaniu

$$l_i = -\log_D p_i = -\frac{\log p_i}{\log D} \quad \text{a więc} \quad \sum_{i=1}^k p_i l_i = \frac{-\sum_i p_i \log p_i}{\log D} = \frac{H(p)}{\log D}$$

Ponieważ jednak  $l_i = l(a_i)$  muszą mieć całkowite wartości, wybieramy

$$-\log_D p_i \leq l(a_i) = \lceil -\log_D p_i \rceil < 1 - \log_D p_i. \quad (*)$$

Pierwszą nierówność można zapisać jako  $D^{-l(a_i)} \leq p_i$ , co po zsumowaniu względem  $i$  daje  $\sum_i D^{-l(a_i)} \leq 1$ .

Jeśli teraz pomnożymy (\*) stronami przez  $p_i$  i wysumujemy po  $i$ , otrzymamy (po zamianie logarytmu na dwójkowy)

$$\frac{H(A)}{\log_2 D} \leq \hat{l}(c) < 1 + \frac{H(A)}{\log_2 D}.$$

Dzięki warunkowi  $\sum_i D^{-l(a_i)} \leq 1$  nierówność Krafta II gwarantuje, że  $c$  można wybrać jako kod bezprefiksowy. Udowodniliśmy tym samym ważne



**Twierdzenie** Shannona-Fano o kodowaniu bez szumu.

Niech  $A$  będzie zmienną losową o wartościach w zbiorze  $\mathcal{A}$ , (tj. dany jest rozkład  $p(a) = P(A = a)$ ). Istnieje kod bezprefiksowy  $c : \mathcal{A} \rightarrow \mathcal{B}^*$ ,  $|\mathcal{B}| = D$ , dla którego

$$\frac{H(A)}{\log_2 D} \leq \mathbb{E}[c(A)] < 1 + \frac{H(A)}{\log_2 D}.$$

**Przykład**  $\mathcal{A} = \{a, b, c, d\}$  z prawdopodobieństwami  $p_i$  odp. 0.4, 0.3, 0.2, 0.1.  $H(A) = 1.85$ .


$x$	$p(x)$	$-\log p(x)$	$\lceil -\log p(x) \rceil$
$a$	0.4	1.32	2
$b$	0.3	1.74	2
$c$	0.2	2.32	3
$d$	0.1	3.32	4



	$a$	$b$	$c$	$d$
$c(a)$	00	01	100	1010

	$a$	$b$	$c$	$d$
$h(a)$	0	10	110	111

Kod  $c$  Shannona-Fano ma średnią długość  $\mathbb{E}[c(A)] = 2.4$ , drugi kod Huffmana  $h$  jest optymalny,  $\mathbb{E}[h(A)] = 1.9$



Punkt optymalny (czerwony)  $l_i = \log p_i$ ,  $i = 1, 2, \dots, k$  i jego całkowitoliczbowe przybliżenie  $l_i = \lceil \log p_i \rceil$ . Kolor szary wizualizuje rozkład wartości  $\mathbb{E}[c(A)] = \hat{l}(c) = \sum p_i l_i$ . W otoczeniu może się jednak nadal znaleźć lepsze rozwiązanie  $h$  (kod Huffmana) spełniające nierówność Krafta, mimo że  $l_i < \lceil \log p_i \rceil$  dla niektórych długości  $l_i$ .


## Kodowanie Huffmanna

Założmy, że  $\mathcal{A} = \{a, b, c, d, e, f, g, h\}$ . Zwykły kod typu ASCII byłby 3-bitowy,  $c(a) = 000, \dots, c(h) = 111$ . Należy zakodować tekst  $\alpha$  100-znakowy. Wtedy  $|c^*(\alpha)| = 300$ . Litery występują jednak w tym tekście niejednakowo często, np.

$a$	$b$	$c$	$d$	$e$	$f$	$g$	$h$
22	8	12	6	24	15	9	4

a więc  $p(a) = 0.22$ ,  $p(b) = 0.08$ , itd. Ponieważ  $H(A) = 2.79$ , jeśli uda nam się skonstruować kod o *średniej* długości słowa bliskiej  $H(A)$ , cały tekst  $\alpha$  powinien zająć niewiele więcej niż  $100 \cdot H(A) = 279$  bitów. Konstrukcja kodu Huffmanna:

- Budujemy drzewo binarne kodu od dołu, dołączając do niego kolejno litery od najrzadszych do najczęstszych.
- Zaczynamy łącząc w drzewo dwie najrzadsze litery, tu  $h$  i  $d$ , w korzeniu drzewa zapisujemy łączną liczbę wystąpień tych liter (sumę prawdopodobieństw), czyli 10.
- Wybieramy 2 kolejne najrzadsze elementy (litery lub częściowe drzewa ze względu na wagi zapisane w ich korzeniach) i łączymy w jedno drzewo, znowu sumując wagi w korzeniu
- Po wyczerpaniu elementów drzewo reprezentuje optymalny kod prefiksowy.



W naszym przykładzie

litera	$a$	$b$	$c$	$d$	$e$	$f$	$g$	$h$
kod	00	1110	011	0101	10	110	1111	0100
l. wystąpień	22	8	12	6	24	15	9	4
l. bitów	44	32	36	24	48	45	36	16

W sumie 281 bitów. Mamy więc  $\mathbb{E}[h(A)] = 2.81 > 2.79 = H(A)$ .

## Konstrukcja kodu Huffmana

$\mathcal{A} = \{a_1, a_2, \dots, a_k\}$ ,  $h : \mathcal{A} \rightarrow \{0, 1\}^*$ ,  $p_i = p(a_i)$  spełniają  $p_1 \geq p_2 \geq \dots \geq p_k$ .

1. Jeśli  $k = 2$ , weźmy  $h(a_1) = 0$ ,  $h(a_2) = 1$ . Mamy  $\mathbb{E}[h(A)] = 1$ . Jest to oczywiście kod optymalny.
2. Przypuśćmy, że potrafimy zbudować kod Huffmana dla dowolnego alfabetu o  $k - 1$  literach. Wybierzmy w  $\mathcal{A}$  dwie litery o najmniejszych prawdopodobieństwach,  $a_{k-1}$  i  $a_k$ . Tworzymy nowy alfabet  $\hat{\mathcal{A}} = \{a_1, a_2, \dots, a_{k-1} \cup a_k\}$ , w którym obydwie litery  $a_{k-1}$  i  $a_k$  reprezentuje “kolektywny” symbol  $a_{k-1} \cup a_k$  o prawdopodobieństwie  $p_{k-1} + p_k$ . Niech  $\hat{h} : \hat{\mathcal{A}} \rightarrow \{0, 1\}^*$  będzie kodem Huffmana dla nowego alfabetu. Kod Huffmana  $h$  dla  $\mathcal{A}$  powstaje z  $\hat{h}$  następująco:

$$h(a_i) = \begin{cases} \hat{h}(a_i) & \text{dla } i = 1, 2, \dots, k - 2 \\ \hat{h}(a_{k-1} \cup a_k)0 & \text{dla } i = k - 1 \\ \hat{h}(a_{k-1} \cup a_k)1 & \text{dla } i = k \end{cases} \quad (*)$$

Jest to oczywiście kod bezprefiksowy.

**Twierdzenie** Kod Huffmana jest optymalny, tj. jego średnia długość jest *najmniejsza* wśród wszystkich dekodowalnych kodów  $c : \mathcal{A} \rightarrow \{0, 1\}^*$ .

**Lemat** Niech  $\mathcal{A} = \{a_1, a_2, \dots, a_k\}$  oraz  $p_1 \geq p_2 \geq \dots \geq p_k > 0$ ,  $p_i = p(a_i)$ . Istnieje kod optymalny  $c : \mathcal{A} \rightarrow \{0, 1\}^*$ , dla którego  $\mathbb{E}[c(A)]$  jest minimalne oraz

- a) długości  $l_i = |c(a_i)|$  spełniają  $l_1 \leq l_2 \leq \dots \leq l_k$
- b) słowa kodowe  $c(a_{k-1})$  i  $c(a_k)$  mają jednakową długość i różnią się tylko ostatnim bitem.

**DOWÓD.** Weźmy kod bezprefiksowy  $d$  o długościach słów  $d_i = \lceil -\log p_i \rceil$ . Niech  $\mathbb{E}[d(A)] = D$ . Wówczas istnieje jedynie skończenie wiele bezprefiksowych kodów binarnych  $c$ , dla których  $\sum l_i p_i \leq D$  przy zachowaniu nierówności  $\sum 2^{-l_i} \leq 1$ . Jeden z nich osiąga minimalną średnią długość — to jest kod optymalny.

- a) Jeśli  $p_i \geq p_j$ , lecz  $l_i > l_j$ , wówczas można zmniejszyć  $\sum l_i p_i$  przez zamianę słów kodowych  $c(a_i)$  i  $c(a_j)$ . Zatem dla optymalnego kodu mamy  $l_1 \leq l_2 \leq \dots \leq l_k$ .
- b) Niech  $L = l_k$ ,  $c(a_k) = \omega b$ , gdzie  $|\omega| = l_k - 1$ , a  $b$  jest ostatnim bitem  $c(a_k)$ . Utwórzmy nowy kod zamieniając  $c(a_k)$  na  $\omega$ , co oczywiście zmniejsza  $\sum l_i p_i$ . Ponieważ jednak  $c$  jest z założenia optymalny, ten nowy kod nie może być bezprefiksowy. Istnieje zatem inne słowo  $c(a_i)$  długości  $L$ , takie że  $\omega \triangleleft c(a_i)$ . Ale oznacza to, że  $c(a_i)$  i  $c(a_k)$  różnią się tylko ostatnim bitem. Wystarczy teraz przenieść słowa kodowe o długości  $L$  tak, aby  $c(a_i)$  znalazło się na przedostatniej pozycji  $c(a_{k-1})$ .

DOWÓD TWIERDZENIA. Indukcja względem liczby liter  $k$ ,  $\mathcal{A} = \{a_1, a_2, \dots, a_k\}$ .

Niech  $h : \mathcal{A} \rightarrow \{0, 1\}^*$  będzie kodem Huffmana, a  $c : \mathcal{A} \rightarrow \{0, 1\}^*$  kodem optymalnym. Niech  $\hat{h}$  będzie kodem Huffmana na alfabecie  $\{a_1, a_2, \dots, a_{k-1} \cup a_k\}$ , gdzie symbol kolektywny  $a_{k-1} \cup a_k$  ma prawdopodobieństwo  $p_{k-1} + p_k$ . Z (\*) wynika, że

$$\mathbb{E}[h(A)] = \mathbb{E}[\hat{h}(\hat{A})] + (p_{k-1} + p_k).$$

Dla optymalnego kodu  $c$  na podstawie lematu możemy założyć, że  $c(a_{k-1}) = \omega 0$  i  $c(a_k) = \omega 1$ . Zdefiniujmy teraz nowy kod  $\hat{c}$  na  $\hat{\mathcal{A}}$  podstawiając  $\hat{c}(a_{k-1} \cup a_k) = \omega$  oraz  $\hat{c}(a_i) = c(a_i)$  dla  $i = 1, 2, \dots, k - 2$ . Ten kod jest bezprefiksowy i

$$\mathbb{E}[c(A)] = \mathbb{E}[\hat{c}(\hat{A})] + (p_{k-1} + p_k).$$

Na podstawie założenia indukcyjnego  $\hat{h}$  jest optymalny, więc  $\mathbb{E}[\hat{h}(\hat{A})] \leq \mathbb{E}[\hat{c}(\hat{A})]$ , skąd

$$\mathbb{E}[h(A)] \leq \mathbb{E}[c(A)].$$

Ale  $c$  realizuje minimum średniej długości kodu, więc w nierówności powyżej musi zachodzić równość, a zatem  $h$  jest optymalny.

## Kod blokowy

Zamiast pojedynczych liter  $a \in \mathcal{A}$  można kodować ich bloki

$$\alpha = \underbrace{a_1 a_2 \dots a_r}_{\text{blok 1}} \underbrace{a_{r+1} a_{r+2} \dots a_{2r}}_{\text{blok 2}} \dots$$

Kod blokowy  $c_r : \mathcal{A}^r \rightarrow \mathcal{B}^*$ , zgodnie z twierdzeniem Shannona-Fano

$$\frac{H(A_1, A_2, \dots, A_r)}{\log D} \leq \mathbb{E}[c_r(A_1, A_2, \dots, A_r)] < 1 + \frac{H(A_1, A_2, \dots, A_r)}{\log D}$$

czyli na jedną literę  $a \in \mathcal{A}$

$$\frac{H(A_1, A_2, \dots, A_r)}{r \log D} \leq \frac{\mathbb{E}[c_r(A_1, A_2, \dots, A_r)]}{r} < \frac{1}{r} + \frac{H(A_1, A_2, \dots, A_r)}{r \log D}.$$

Oczekiwana długość kodu na 1 literę wynosi więc w przybliżeniu  $\frac{H(A_1, A_2, \dots, A_r)}{r \log D}$ .

$$H(A_1, A_2, \dots, A_r) \leq H(A_1) + H(A_2) + \dots + H(A_r) = rH(A_1),$$

więc jeśli zmienne  $A_i$  są niezależne, średnia długość kodu na literę dąży do  $\frac{H(A_1)}{\log D}$ , gdy długość bloku rośnie do nieskończoności.

W rzeczywistych komunikatach (teksty, obrazy, cyfrowy zapis dźwięku) kolejne "znaki" są silnie zależne, więc  $H(A_1, \dots, A_r) < rH(A_1)$ . Załóżmy np., że rozkład dla kolejnej litery zależy od co najwyżej  $p$  poprzednich liter

$$\begin{aligned} P(A_r = a_r \mid A_{r-1} = a_{r-1}, \dots, A_1 = a_1) \\ = P(A_r = a_r \mid A_{r-1} = a_{r-1}, \dots, A_{r-p} = a_{r-p}), \end{aligned}$$

można tą samą drogą pokazać, że wtedy

$$\frac{H(A_p \mid A_1, A_2, \dots, A_{p-1})}{\log D} \leq \frac{\mathbb{E}[c_r(A_1, \dots, A_r)]}{r} < \frac{1}{r} + \frac{H(A_p \mid A_1, A_2, \dots, A_{p-1})}{\log D}$$

Przypomnienie:  $H(A_r \mid A_1, \dots, A_{r-1}) = H(A_1, \dots, A_r) - H(A_1, \dots, A_{r-1})$ .

Oczywiście w takiej sytuacji kod blokowy długości  $p$  jest właściwym wyborem.