

# Kodowanie, Kompresja, Kryptografia

konspekt I, 7.III.2023

## Literatura

1. T. K. Carne, Codes and Cryptography, skrypt Cambridge University, 2015  
<https://www.dpmms.cam.ac.uk/~tkc/CodesandCryptography/CodesandCryptography.pdf>
2. J.I. Hall, Notes on Coding Theory, Michigan State University, 2015  
<https://users.math.msu.edu/users/halljo/classes/codenotes/coding-notes.html>
3. M. Cover, J.A. Thomas, Elements of information theory, Wiley 2006  
<https://www.wiley.com/en-us/Elements+of+Information+Theory%2C+2nd+Edition-p-9780471241959>
4. D.R. Stinson, M.B. Paterson, Cryptography: Theory and Practice, Taylor & Francis 2019; po polsku: Kryptografia w teorii i praktyce, PWN 2021  
<https://ksiegarnia.pwn.pl/Kryptografia-W-teorii-i-praktyce,897655934,p.html>

Kodowanie, kompresja, kryptografia — pojęcia związane z przechowywaniem i przesyłaniem informacji.

Ocena *ilości* informacji w kodowanej sekwencji

- stratna transmisja kodu, ocena ilości utraconej informacji, niezbędna redundancja dla bezstratnego przesyłu
- kompresja, ocena redundancji, skrócenie zapisu bez utraty informacji
- szyfrowanie, rozpraszanie statystycznych korelacji komunikatu, tak aby proces łamania szyfru był maksymalnie utrudniony

$\mathcal{A}$  — alfabet wejściowy, np.  $\{a, b, \dots, z, A, B, \dots, Z, \dots\}$

$\mathcal{B}$  — alfabet kodu, transmisji, np.  $\{0, 1\}$

$c : \mathcal{A} \rightarrow \mathcal{B}^*$  — funkcja kodująca, np. ASCII,  $c(a) = 01100001$

$\kappa : \mathcal{B}^* \rightarrow \mathcal{F}$  — processing (kompresja, sumy kontrolne...) przed transmisją.

$\kappa^{-1} : \mathcal{F} \dashrightarrow \mathcal{B}^*$  — odwrotny processing (częściowy) po transmisji

$c^{-1} : \mathcal{B}^* \rightarrow \mathcal{A}$  — dekodowanie

## Prawdopodobieństwo

$\mathcal{E}$  — zbiór zdarzeń elementarnych (tu: skończony)

$\Omega$  —  $\sigma$ -algebra zdarzeń,  $A \in \Omega \Leftrightarrow A \subset \mathcal{E}$

1.  $\emptyset \in \Omega$
2. Jeśli  $A \in \Omega$ , to także  $A^c = \mathcal{E} - A \in \Omega$
3. Jeśli  $A_1, A_2, \dots \in \Omega$ , to także  $\bigcup_{i=1}^{\infty} A_i \in \Omega$ .

Ponieważ  $(A^c \cup B^c)^c = A \cap B$ , jeśli  $A, B \in \Omega$ , wtedy także  $A \cap B \in \Omega$ .

Tutaj, ponieważ  $\mathcal{E}$  jest zbiorem skończonym, bierzemy  $\Omega = \mathcal{P}(\mathcal{E})$ .

Rozkład prawdopodobieństwa na  $\Omega$ :  $P : \Omega \rightarrow [0, 1]$

1.  $P(\emptyset) = 0$
2.  $P(\mathcal{E}) = 1$
3.  $P\left(\bigcup_{i=1}^{\infty} A_i\right) = \sum_{i=1}^{\infty} P(A_i)$  jeśli  $A_i \cap A_j = \emptyset \quad \forall i, j$ .

Niektóre własności

1.  $P(A^c) = 1 - P(A)$
2. Jeśli  $A \subset B$ , to  $P(A) \leq P(B)$
3.  $P(A \cup B) = P(A) + P(B) - P(A \cap B)$
4. Dla skończonej przestrzeni  $\mathcal{E} = \{a_1, a_2, \dots, a_n\}$  rozkład  $P$  na  $\Omega$  jest w całości wyznaczony przez liczby  $p_i = P(\{a_i\})$ ,  $i = 1, 2, \dots, n$ .

## Zmienna losowa i jej rozkład

Funkcja mierzalna  $X : \mathcal{E} \rightarrow \mathbb{R}$ , to jest taka że  $\forall (a, b) \quad X^{-1}(a, b) \in \Omega$ .

Rozkład zmiennej losowej  $X$

$$P_X(a < X < b) = P(X^{-1}(a, b)).$$

## Statystyka

Wartość oczekiwana zmiennej losowej:  $\mathbb{E}[X] = \int x P_X(X = x) dx$

Wariancja  $X$ : 
$$\begin{aligned} \text{Var}(X) &= \mathbb{E}[(X - \mathbb{E}[X])^2] = \int (x - \mathbb{E}[X])^2 P_X(X = x) dx \\ &= \mathbb{E}[X^2] - (\mathbb{E}[X])^2, \quad \sigma(X) = \sqrt{\text{Var}(X)} \end{aligned}$$

Kowariancja:  $\text{Cov}(X, Y) = \mathbb{E}[(X - \mathbb{E}[X])(Y - \mathbb{E}[Y])]$

Korelacja:  $r_{XY} = \frac{\text{Cov}(X, Y)}{\sigma(X)\sigma(Y)}$ .

W naszym przypadku, gdy  $\mathcal{E} = \{a_1, a_2, \dots, a_n\}$ ,  $P(a_i) = p_i$ ,  $X(a_i) = x_i$

$$\mathbb{E}[X] = \sum_{i=1}^n p_i x_i, \quad \text{Var}(X) = \sum_{i=1}^n p_i (x_i - \mathbb{E}(X))^2, \quad \text{itd.}$$

## Prawdopodobieństwo warunkowe

Dla  $A, B \in \Omega$ , jeśli  $P(B) \neq 0$ , określamy  $P(A|B) = \frac{P(A \cap B)}{P(B)}$

Przykład: W grupie 100-osobowej jest 55 kobiet i 45 mężczyzn. Ponadto 40 osób to blondyni, a 60 to bruneci. Prawdopodobieństwo wylosowania osoby o jasnych włosach wynosi więc  $P(Bl) = 0.4$ .

a) Załóżmy, że wśród kobiet jest 25 blondynek i 30 brunetek. Jeśli losując 1 osobę dowiemy się najpierw, że to kobieta, zdarzenie  $K$ , wtedy szansa, że jest to blondynka wynosi  $\frac{25}{55} \approx 0.45$ , a więc wiedza o tym, że zaszło zdarzenie  $K$  zmienia niepewność co do zajścia zdarzenia  $Bl$ ,

$$P(Bl|K) = \frac{P(Bl \cap K)}{P(K)} = \frac{25/100}{55/100} = 0.4545... \neq 0.4 = P(Bl)$$

Zdarzenia  $Bl$  i  $K$  są *zależne*.

b) Gdyby wśród kobiet były 22 blondynki i 33 brunetki, wtedy szansa na wylosowanie blondynki wśród pań wynosiłaby  $\frac{22}{55} = 0.4$ , a więc byłaby taka sama jak w ogólnej populacji. Wtedy wiedza o tym że wylosowana osoba jest kobietą nie zmienia niepewności co do tego, czy osoba ta ma jasne włosy. Zdarzenia  $Bl$  i  $K$  są tym razem *niezależne*.

$$P(Bl|K) = \frac{P(Bl \cap K)}{P(K)} = \frac{22/100}{55/100} = 0.4 = P(Bl) = \frac{40}{100}$$

Niezależność  $P(A|B) = P(A)$  oznacza także, że zachodzi  $P(A \cap B) = P(A) \cdot P(B)$ , a więc także  $P(B|A) = P(B)$ .

**UWAGA:** Zdarzenia rozłączne nigdy nie są niezależne! Gdyby były niezależne, to co najmniej jedno z nich musiałoby być niemożliwe

$$P(A \cap B) = 0 \quad \Leftrightarrow \quad P(A) = 0 \vee P(B) = 0.$$

Gdyby wśród mężczyzn nie było ani jednego blondyna,  $M \cap Bl = \emptyset$ , wtedy  $P(M|Bl) = 0 \neq P(M)$ .

## Informacja

Powiedzmy, że w wyniku eksperymentu losowego zachodzi zdarzenie  $A \in \Omega$ . Informacja  $I(A)$  mierzy jak bardzo to zajście zmniejsza naszą początkową niepewność co do wyniku doświadczenia. Jeśli zdarzenie  $A$  jest pewne, t.j. zachodzi z prawdopodobieństwem 1, niepewność nie ulega zmianie, czyli

1. jeśli  $P(A) = 1$ , wtedy  $I(A) = 0$ .

Im mniej prawdopodobne było zdarzenie  $A$ , tym znacznie ubywa niepewności na skutek jego zajścia, a więc

2. Jeśli  $P(A) \leq P(B)$ , wtedy  $I(A) \geq I(B)$ .

Jedoczesne zajście dwóch zdarzeń niezależnych zmniejsza niepewność o sumę informacji niesioną przez każde z tych zdarzeń

3.  $I(A \cap B) = I(A) + I(B)$  jeśli  $A$  i  $B$  są niezależne,  $P(A \cap B) = P(A)P(B)$ .

Z tych postulatów wynika następująca postać informacji

$$I(A) = -\log P(A).$$

Baza logarytmu jest dowolna (określa jednostkę informacji). Konwencjonalnie przyjmujemy bazę 2. Wówczas jednostkowa informacja nazywana jest bitem. Np. wynik rzutu symetryczną monetą niesie ze sobą 1 bit informacji,

$$I(O) = I(R) = -\log_2 0.5 = 1.$$

## Entropia Shannona dyskretnej zmiennej losowej

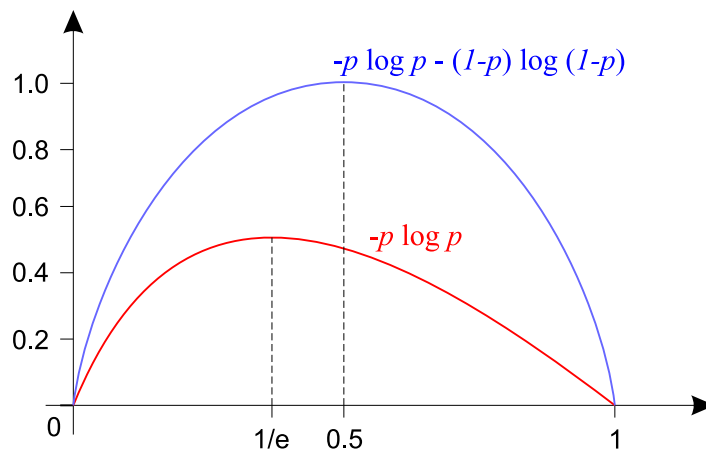
$$H(X) = \mathbb{E}(I(X)) = - \sum_{i=1}^n P(X = x_i) \log P(X = x_i) = - \sum_{i=1}^n p_i \log p_i.$$

Z racji tego, że  $\lim_{x \rightarrow 0} x \log x = 0$ , przyjmujemy, że jeśli  $p_i = 0$ , odpowiadające temu zdarzenie elementarne nie wnosi nic do entropii rozkładu.

**Fakt**  $H(X) \geq 0$ . Ponadto  $H(X) = 0$  wtedy i tylko wtedy gdy zmienna  $X$  jest prawie wszędzie stała.  $H$  przyjmuje maksimum równe  $\log n$  dla zmiennej  $X$  o rozkładzie równomiernym  $p_i = \frac{1}{n}$ ,  $i = 1, 2, \dots, n$ .

Przykład.  $X \in \{0, 1\}$ ,  $p_0 = p$ ,  $p_1 = 1 - p$ . Wówczas

$$H(X) = -p \log p - (1 - p) \log(1 - p) = h(p)$$



## Nierówność Gibbsa

Jeśli  $X$  jest zmienną losową przyjmującą wartości  $x_1, x_2, \dots, x_n$  z prawdopodobieństwami  $p_1, p_2, \dots, p_n$ ,  $\sum p_i = 1$ , oraz jeśli  $q_1, q_2, \dots, q_n \geq 0$  są innym układem liczb takich, że  $\sum q_i = 1$ , wówczas

$$-\sum p_i \log p_i \leq -\sum p_i \log q_i,$$

przy czym równość zachodzi wtedy i tylko wtedy gdy  $p_i = q_i$ ,  $i = 1, 2, \dots, n$ .

DOWÓD: Nierówność jest równoważna  $\sum p_i \log \frac{q_i}{p_i} \leq 0$

Ponieważ  $\log_2 c = \log_2 e \ln c$ , możemy zamienić podstawę logarytmu na  $e$

$$\log_2 e \sum p_i \ln \frac{q_i}{p_i} \leq 0$$

podzielić obie strony przez dodatni czynnik  $\log_2 e$  i stosując nierówność  $\ln t \leq t - 1$  otrzymamy

$$\sum p_i \ln \frac{q_i}{p_i} \leq \sum p_i \left( \frac{q_i}{p_i} - 1 \right) = \sum (q_i - p_i) = 0.$$

Ponieważ  $\ln t = t - 1$  tylko gdy  $t = 1$ , nierówność powyżej przechodzi w równość jedynie gdy  $\frac{q_i}{p_i} = 1$  dla wszystkich  $i$ .

## Entropia łączna

Łączny rozkład wielu zmiennych losowych  $P_{XY}(X = x_i, Y = y_j) = p_{ij}$

Zmienne  $X, Y$  mogą być niezależne lub nie,  $p_{ij} = p_i p_j \Leftrightarrow X \perp Y$ .

Rozkłady brzegowe:  $p_{i\cdot} = \sum_j p_{ij}$ ,  $p_{\cdot j} = \sum_i p_{ij}$

**Definicja** Entropia łączna

$$H(X, Y) = -\sum_{i,j} P(X = x_i, Y = y_j) \log P(X = x_i, Y = y_j)$$

**Twierdzenie**  $H(X, Y) \leq H(X) + H(Y)$ , równość jedynie gdy  $X \perp Y$ .

DOWÓD: Zauważmy, że  $\sum_{i,j} p_{i\cdot} p_{\cdot j} = 1$ .

$$\begin{aligned} H(X, Y) &= -\sum_{i,j} p_{ij} \log p_{ij} \leq -\sum_{i,j} p_{ij} \log(p_{i\cdot} p_{\cdot j}) \\ &= -\sum_{i,j} p_{ij} (\log p_{i\cdot} + \log p_{\cdot j}) \\ &= -\sum_i p_{i\cdot} \log p_{i\cdot} - \sum_j p_{\cdot j} \log p_{\cdot j} = H(X) + H(Y), \end{aligned}$$

przy czym do równości potrzeba by zachodziło  $p_{ij} = p_{i\cdot} p_{\cdot j}$  dla wszystkich  $i, j$ .

## Entropia warunkowa

Prawdopodobieństwa warunkowe z rozkładu łącznego:

$$P(Y = y_j | X = x_i) = \frac{P(X = x_i, Y = y_j)}{P(X = x_i)} = \frac{p_{ij}}{p_i}$$

$$H(X, Y) = - \sum_{i,j} P(X = x_i, Y = y_j) \log P(X = x_i, Y = y_j)$$

$$H(X) = - \sum_{i,j} P(X = x_i, Y = y_j) \log P(X = x_i)$$

$$\begin{aligned} H(X, Y) - H(X) &= - \sum_{i,j} P(X = x_i, Y = y_j) \log \frac{P(X = x_i, Y = y_j)}{P(X = x_i)} \\ &= - \sum_{i,j} P(X = x_i) P(Y = y_j | X = x_i) \log P(Y = y_j | X = x_i) \\ &= \sum_i P(X = x_i) H(Y | X = x_i) \\ &= H(Y | X) \end{aligned}$$

Mamy więc  $0 \leq H(Y | X) = H(X, Y) - H(X)$  z równością jedynie gdy  $H(Y | X = x_i) = 0$  dla wszystkich  $i$ , to znaczy gdy  $Y$  jest dokładnie określone na podstawie wartości  $X$ , czyli  $Y = f(X)$ . Mamy także

$$H(X) \leq H(X, Y) \leq H(X) + H(Y).$$

Przykład 1: Seria niezależnych rzutów symetryczną monetą,  $X_i \in \{O, R\}$

$$P(X_1 = x_1, \dots, X_n = x_n) = P(X_1 = x_1) \cdots P(X_n = x_n) = \left(\frac{1}{2}\right)^n$$

Więc  $H(X_1, \dots, X_n) = n \log_2 2 = n$ . Rzuty kostką  $H(\dots) = n \log_2 6 \approx n 2.59$ .

Przykład 2: Na pasku w TV pojawiają się kolejne litery komunikatu,  $X_i = i$ -ta litera. Duża zależność (kolejne litery są łatwe do przewidzenia)

$$P(X_n = x_n | X_1 = x_1, \dots, X_{n-1} = x_{n-1}) \neq P(X_n = x_n)$$

Wtedy  $H(X_1, \dots, X_n) < nH(X)$ .

## Kody bezprefiksowe

$$c : \mathcal{A} \rightarrow \mathcal{B}^*, \quad c^* : \mathcal{A}^* \rightarrow \mathcal{B}^* \quad c^*(a_1 \dots a_k) = c(a_1) \dots c(a_k)$$

**Definicja**  $c$  jest dekodowalny jeśli  $c^*$  jest funkcją 1-1.

Różnowartościowość  $c$  jest warunkiem koniecznym ale nie dostatecznym dekodowalności. Np.

$$c(0) = 0, \quad c(1) = 00, \quad c(2) = 000, \quad \dots \quad c(9) = 0000000000$$

ale  $(c^*)^{-1}(00000000000000) = ?$

Słowo  $\alpha$  jest prefiksem (przedrostkiem) słowa  $\beta$ ,

$$\alpha \triangleleft \beta \Leftrightarrow \exists \gamma \quad \beta = \alpha\gamma$$

Np.  $abba \triangleleft abbaaabbab$

**Definicja** Kod  $c$  jest bezprefiksowy  $\Leftrightarrow \forall a, b \in \mathcal{A} \quad c(a) \not\triangleleft c(b)$

Przykład:  $c(v) = 0, \quad c(x) = 10, \quad c(y) = 110, \quad c(z) = 111.$


$$1000110111111101001100 \longrightarrow 10 \ 0 \ 0 \ 110 \ 111 \ 111 \ 0 \ 10 \ 0 \ 110 \ 0$$

Kod dekodowalny nie musi być bezprefiksowy:

$$\begin{array}{ll} c(x) = 10 & d(x) = 0 \\ c(y) = 100 & d(y) = 10 \\ c(z) = 1000 & d(z) = 100 \end{array}$$

Zdekodować słowo 100101000.

Kod bezprefiksowy pozwala na dekodowanie "w locie". Można go reprezentować za pomocą drzewa.





**Twierdzenie:** Nierówność Krafta I

Jeśli  $c : \mathcal{A} \rightarrow \mathcal{B}^*$  jest kodem bezprefiksowym, dla którego słowa kodowe  $c(a)$  mają długości  $l(a)$  oraz  $D$  jest liczbą liter w  $\mathcal{B}$ , wówczas

$$\sum_{a \in \mathcal{A}} D^{-l(a)} \leq 1.$$

**Twierdzenie:** Nierówność Krafta II

Niech  $\mathcal{A}$  i  $\mathcal{B}$  będą dwoma alfabetami,  $|\mathcal{B}| = D$ , oraz niech dla układu liczb  $l(a)$ ,  $a \in \mathcal{A}$ , zachodzi nierówność

$$\sum_{a \in \mathcal{A}} D^{-l(a)} \leq 1.$$

Wówczas istnieje kod bezprefiksowy  $c : \mathcal{A} \rightarrow \mathcal{B}^*$  o słowach kodowych  $c(a)$  długości  $l(a)$ ,  $a \in \mathcal{A}$ .

**Twierdzenie McMillana:** Jeśli  $c : \mathcal{A} \rightarrow \mathcal{B}^*$  jest dekodowalny,  $|\mathcal{B}| = D$ , a słowa kodowe  $c(a)$  mają długości  $l(a)$ ,  $a \in \mathcal{A}$ , wówczas

$$\sum_{a \in \mathcal{A}} D^{-l(a)} \leq 1.$$

DOWÓD. Niech  $L = \max_a l(a)$ .

$$\left( \sum_{a \in \mathcal{A}} D^{-l(a)} \right)^R = \sum_{a_1, a_2, \dots, a_R \in \mathcal{A}} D^{-l(a_1) - l(a_2) - \dots - l(a_R)}$$

Oznaczmy

$$\omega = c^*(a_1 a_2 \dots a_R) = c(a_1) c(a_2) \dots c(a_R) \in \mathcal{B}^*, \quad |\omega| = l(a_1) + l(a_2) + \dots + l(a_R) \leq LR.$$

Ponieważ kod  $c$  jest z założenia dekodowalny, dowolnemu  $\omega \in \mathcal{B}^*$  odpowiada co najwyżej jedno słowo  $a_1 a_2 \dots a_R$ , takie, że  $c^*(a_1 a_2 \dots a_R) = \omega$ .

Przez  $N(m)$  oznaczmy liczbę słów  $\omega$  długości  $m$ , które są obrazami pewnych ciągów  $a_1 a_2 \dots a_R$ ,  $c^*(a_1 a_2 \dots a_R) = \omega$

$$\left( \sum_{a \in \mathcal{A}} D^{-l(a)} \right)^R \leq \sum_{m=1}^{LR} N(m) D^{-m} \leq \sum_{m=1}^{LR} D^m D^{-m} = LR,$$

a stąd

$$\sum_{a \in \mathcal{A}} D^{-l(a)} \leq \sqrt[R]{LR} \rightarrow 1 \quad \text{gdy} \quad R \rightarrow \infty.$$