



Elementy teorii informacji i kodowania

Entropia, nierówność Krafta, kodowanie optymalne

Marcin Jenczmyk
m.jenczmyk@knm.katowice.pl

17 kwietnia 2015



Elementy teorii informacji

Niech $S = \{x_1, \dots, x_q\}$ oznacza alfabet, zbiór zdarzeń, a $P = \{p_1, \dots, p_q\}$ będzie stowarzyszonym z nim zbiorem prawdopodobieństw takim, że $P(x_i) = p_i$ oraz $\sum_{i=1}^q p_i = 1$.



Elementy teorii informacji

Niech $S = \{x_1, \dots, x_q\}$ oznacza alfabet, zbiór zdarzeń, a $P = \{p_1, \dots, p_q\}$ będzie stowarzyszonym z nim zbiorem prawdopodobieństw takim, że $P(x_i) = p_i$ oraz $\sum_{i=1}^q p_i = 1$. Ponadto założmy, że źródło S jest *źródłem bez pamięci*, tzn. że kolejne znaki są generowane niezależnie od siebie.



Elementy teorii informacji

Informacja

Ilością informacji stowarzyszonej z zdarzeniem nazywamy funkcję I określoną na zbiorze zdarzeń, zadaną wzorem

$$I(x) = -\log_k P(x)$$

dla pewnego $k > 0$ oraz $k \neq 1$.



Elementy teorii informacji

Informacja

Ilością informacji stowarzyszonej z zdarzeniem nazywamy funkcję I określoną na zbiorze zdarzeń, zadaną wzorem


$$I(x) = -\log_k P(x)$$

dla pewnego $k > 0$ oraz $k \neq 1$.

W zależności od podstawy logarytmu ilość informacji może być mierzona w różnych jednostkach. Dla $k = 2$ jednostką informacji jest bit, dla $k = e$ nat, a dla $k = 10$ Hartley.



Elementy teorii informacji





Elementy teorii informacji

Entropia

Entropią stowarzyszoną z źródłem $S = \{x_1, \dots, x_q\}$ nazywamy funkcję

$$H(S) = H(p_1, \dots, p_q) = \sum_{i=1}^q P(x_i) \log P(x_i) = \sum_{i=1}^q P(x_i) I(x_i).$$

Funkcja ta jest wartością oczekiwaną ilości informacji ujawnianej przez źródło.



Elementy teorii informacji

Przykład

Rozważmy źródło $S = \{x_1, x_2, x_3\}$ takie, że $P(x_1) = \frac{1}{2}$, a $P(x_2) = P(x_3) = \frac{1}{4}$. Wówczas

$$I(x_1) = -\log \frac{1}{2} = \log 2 = 1,$$

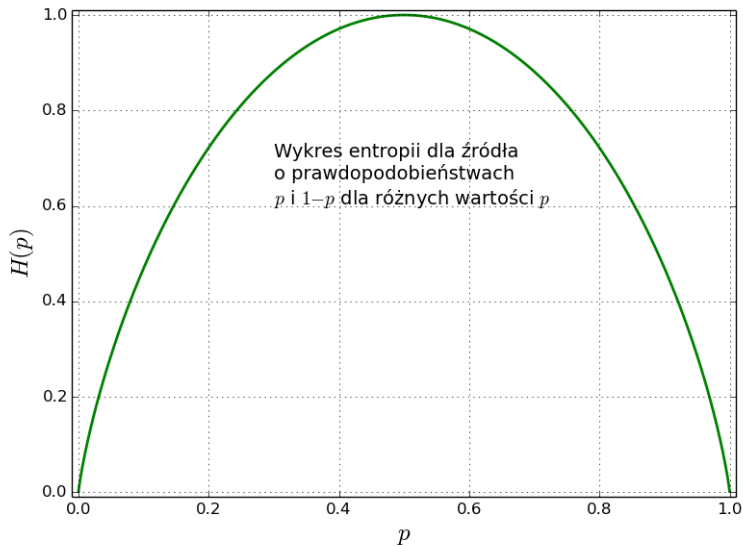
$$I(x_2) = I(x_3) = -\log \frac{1}{4} = \log 4 = 2,$$

a entropia źródła wynosi

$$H(S) = \frac{1}{2}I(x_1) + \frac{1}{4}I(x_2) + \frac{1}{4}I(x_3) = \frac{1}{2} + \frac{1}{2} + \frac{1}{2} = \frac{3}{2}.$$



Elementy teorii informacji





Elementy teorii informacji

Twierdzenie

Dla dowolnego zbioru prawdopodobieństw p_1, \dots, p_q zachodzi oszacowanie

$$0 = H(1, 0, \dots, 0) \leq H(p_1, \dots, p_q) \leq H\left(\frac{1}{q}, \dots, \frac{1}{q}\right) = \log q.$$



Elementy teorii informacji

Dowód.

Ponieważ $\sum_{i=1}^q p_i = 1$, to $p_q = 1 - \sum_{i=1}^{q-1} p_i$ oraz

$$\begin{aligned} H(p_1, \dots, p_q) &= H(p_1, \dots, p_{q-1}) \\ &= - \sum_{i=1}^{q-1} p_i \log p_i - \left(1 - \sum_{i=1}^{q-1} p_i \right) \log \left(1 - \sum_{i=1}^{q-1} p_i \right). \end{aligned}$$



Elementy teorii informacji

Dowód.

Ponieważ $\sum_{i=1}^q p_i = 1$, to $p_q = 1 - \sum_{i=1}^{q-1} p_i$ oraz

$$\begin{aligned} H(p_1, \dots, p_q) &= H(p_1, \dots, p_{q-1}) \\ &= - \sum_{i=1}^{q-1} p_i \log p_i - \left(1 - \sum_{i=1}^{q-1} p_i\right) \log \left(1 - \sum_{i=1}^{q-1} p_i\right). \end{aligned}$$

Funkcja może mieć ekstremum w punkcie, gdy

$$\begin{aligned} \frac{\partial H}{\partial p_i} &= -(\log p_i + \log e) + \log \left(1 - \sum_{i=1}^{q-1} p_i\right) + \log e \\ &= -\log p_i + \log \left(1 - \sum_{i=1}^{q-1} p_i\right) = \log \frac{p_q}{p_i} = 0, \end{aligned}$$



Elementy teorii informacji

Dowód (cd.)

Tak się dzieje gdy

$$\log \frac{p_q}{p_i} = 0 \Leftrightarrow \frac{p_q}{p_i} = 1 \Leftrightarrow p_i = p_q = \frac{1}{q}.$$



Elementy teorii informacji

Dowód (cd.)

Tak się dzieje gdy

$$\log \frac{p_q}{p_i} = 0 \Leftrightarrow \frac{p_q}{p_i} = 1 \Leftrightarrow p_i = p_q = \frac{1}{q}.$$

W badanym punkcie

$$\frac{\partial^2 H}{\partial p_i \partial p_i} = -\frac{\log e (p_i + p_q)}{p_q p_i} = -\log e \left(\frac{1}{p_i} + \frac{1}{p_q} \right) = -2q \log e$$



Elementy teorii informacji

Dowód (cd.)

Tak się dzieje gdy

$$\log \frac{p_q}{p_i} = 0 \Leftrightarrow \frac{p_q}{p_i} = 1 \Leftrightarrow p_i = p_q = \frac{1}{q}.$$

W badanym punkcie

$$\frac{\partial^2 H}{\partial p_i \partial p_i} = -\frac{\log e (p_i + p_q)}{p_q p_i} = -\log e \left(\frac{1}{p_i} + \frac{1}{p_q} \right) = -2q \log e$$

oraz

$$\frac{\partial^2 H}{\partial p_i \partial p_j} = -\frac{\log e}{p_q} = -q \log e.$$



Elementy teorii informacji

Dowód (cd.)

Macierz drugich pochodnych w badanym punkcie jest postaci

$$\begin{bmatrix} -2q \log e & -q \log e & \dots & -q \log e \\ -q \log e & -2q \log e & \dots & -q \log e \\ \vdots & \vdots & \dots & \vdots \\ -q \log e & -q \log e & \dots & -q \log e \end{bmatrix}$$



Elementy teorii informacji

Dowód (cd.)

Macierz drugich pochodnych w badanym punkcie jest postaci

$$\begin{bmatrix} -2q \log e & -q \log e & \dots & -q \log e \\ -q \log e & -2q \log e & \dots & -q \log e \\ \vdots & \vdots & \dots & \vdots \\ -q \log e & -q \log e & \dots & -q \log e \end{bmatrix}$$

Macierz ta jest ujemnie określona, więc punkt jest maksimum entropii.



Elementy kodowania

Kodowanie

Kodowaniem elementów alfabetu $S = \{x_1, \dots, x_q\}$ o prawdopodobieństwach $P = \{p_1, \dots, p_q\}$ przy użyciu alfabetu $C = \{c_1, \dots, c_n\}$ nazywamy proces przyporządkowania elementom S elementów lub ciągów znaków (słów kodowych) alfabetu C .



Elementy kodowania

Kodowanie

Kodowaniem elementów alfabetu $S = \{x_1, \dots, x_q\}$ o prawdopodobieństwach $P = \{p_1, \dots, p_q\}$ przy użyciu alfabetu $C = \{c_1, \dots, c_n\}$ nazywamy proces przyporządkowania elementom S elementów lub ciągów znaków (słów kodowych) alfabetu C .

Przykład (kod binarny)

Elementy alfabetu	Słowa kodowe
s_1	00
s_2	01
s_3	10
s_4	11



Elementy kodowania

Kod jednoznacznie dekodowalny

Kod nazywamy jednoznacznie dekodowalnym, jeśli istnieje tylko jeden sposób podziału ciągu słów kodu $c_{i_1}, c_{i_2}, \dots, c_{i_k}$ na oddzielne słowa kodu, tzn. jeśli

$$c_{i_1}, c_{i_2}, \dots, c_{i_k} = c_{j_1}, c_{j_2}, \dots, c_{j_k}$$

to $l = 1, \dots, k$ zachodzi

$$c_{i_l} = c_{j_l}.$$



Elementy kodowania

Kod jednoznacznie dekodowalny

Kod nazywamy jednoznacznie dekodowalnym, jeśli istnieje tylko jeden sposób podziału ciągu słów kodu $c_{i_1}, c_{i_2}, \dots, c_{i_k}$ na oddzielne słowa kodu, tzn. jeśli

$$c_{i_1}, c_{i_2}, \dots, c_{i_k} = c_{j_1}, c_{j_2}, \dots, c_{j_k}$$

to $l = 1, \dots, k$ zachodzi

$$c_{i_l} = c_{j_l}.$$

Kod prefixowy

Kod nazywamy kodem prefixowym, jeśli żadne słowo kodowe nie jest przedrostkiem innego słowa kodowego.



Elementy kodowania

Przykłady

Znak	K_1	K_2	K_3	K_4
A	0	0	00	00
B	1	11	01	01
C	01	01	10	1



Elementy kodowania

Nierówność Krafta

Binarny kod przedrostkowy złożony ze słów kodu $\{c_1, \dots, c_n\}$ o długościach $\{l_1, \dots, l_n\}$ istnieje \Leftrightarrow

$$\sum_{i=1}^n 2^{-l_i} \leq 1. \quad (1)$$



Elementy kodowania

Nierówność Krafta

Binarny kod przedrostkowy złożony ze słów kodu $\{c_1, \dots, c_n\}$ o długościach $\{l_1, \dots, l_n\}$ istnieje \Leftrightarrow

$$\sum_{i=1}^n 2^{-l_i} \leq 1. \quad (1)$$

Dowód.

(\Rightarrow) Mając binarny kod przedrostkowy umieścimy słowa kodu w drzewie binarnym zgodnie z kodami słów i uzupełnimy je do drzewa pełnego, o $2^{l_{\max}}$ liściach. i -ty wierzchołek "zajmuje" $2^{l_{\max}-l_i}$ liści drzewa. Wobec tego musi zachodzić

$$\sum_{i=1}^n 2^{l_{\max}-l_i} \leq 2^{l_{\max}} \Leftrightarrow \sum_{i=1}^n 2^{-l_i} \leq 1.$$



Elementy kodowania

Dowód.

(\Leftarrow) Przeciwnie, załóżmy, że (1) zachodzi. Wówczas możemy umieścić słowa w wybranych węzłach, tworząc w ten sposób kody słów. Zauważmy, że liści nie może zabraknąć - po umieszczeniu w drzewie j -tego wierzchołka ilość "zablokowanych" to

$$\sum_{i=1}^j 2^{l_{\max} - l_i} \leq 2^{l_{\max}} \sum_{i=1}^j 2^{-l_i} 2^{l_{\max}} \sum_{i=1}^n 2^{-l_i} \leq 2^{l_{\max}}.$$





Elementy kodowania

Twierdzenie

Dla dowolnego binarnego kodu przedrostkowego dla którego średnia długość słowa kodowego $L_{sr} = \sum p_i l_i$ zachodzi nierówność

$$L_{sr} \geq H(S)$$

Ponadto istnieje binarny kod przedrostkowy dla którego

$$L_{sr} < H(S) + 1$$



Elementy kodowania

Dowód.

Na początku udowodnimy część pierwszą tezy.

$$\begin{aligned} H(S) - L_{\text{sr}} &= - \sum p_i \log p_i - \sum p_i l_i \\ &= - \sum p_i (\log p_i + \log 2^{l_i}) = - \sum (p_i \log p_i 2^{l_i}) = \sum p_i \log \frac{1}{p_i 2^{l_i}} \\ &\leq \sum p_i \left(\frac{1}{p_i 2^{l_i}} - 1 \right) \log e = \log e \sum (2^{-l_i} - p_i) \leq 0 \end{aligned}$$

Dowód drugiej części. Niech $l_i = \lceil -\log p_i \rceil$.



$$\sum 2^{-l_i} \leq \sum p_i = 1$$

Ponadto

$$l_i < -\log p_i + 1 \Leftrightarrow p_i l_i < -p_i \log p_i + p_i \Leftrightarrow L_{\text{sr}} < H(S) + 1$$



Bibliografia

-  Adam Drozdek, *Wprowadzenie do kompresji danych*, WNT, Warszawa 1999
-  Norman Abramson, *Teoria informacji i kodowania*, PWN, 1969



Dziękuję za (nie)uwagę!