

Kodowanie, Kompresja, Kryptografia

Konspekt V, 15.V.2023

Kodowanie w obecności szumu — twierdzenie Shannona

Nieformalne oszacowanie efektywności transmisji:

$$\frac{\text{liczba bitów użytkowych}}{\text{długość słowa kodowego}} = \frac{m}{n}$$

Jeśli poziom szumu w kanale wynosi $0 < p < 0.5$, oczekiwana liczba przekłamanych bitów to np . Odległość słów kodowych d musi więc być dostatecznie duża, by zapewnić odpowiednią do warunków zdolność detekcyjną lub korekcyjną kodu,

$$d - 1 > np \quad \text{lub} \quad t = \left\lfloor \frac{d - 1}{2} \right\rfloor > np.$$

Mamy oszacowanie

$$n - m \geq \log_2 V_n(t), \quad V_n(t) = \binom{n}{0} + \binom{n}{1} + \dots + \binom{n}{t}$$

czyli

$$\frac{m}{n} \leq \frac{n - \log V_n(t)}{n} = 1 - \frac{\log V_n(t)}{n}.$$

Korzystając z nierówności

$$\frac{1}{n+1} 2^{nh(q)} \leq \binom{n}{t} \leq 2^{nh(q)},$$

gdzie $q = \frac{t}{n}$, można pokazać, że $\lim_{n \rightarrow \infty} \frac{\log V_n(t)}{n} = h(q)$, stąd jeśli przyjąć, że $t \approx np$, otrzymamy asymptotyczne ograniczenie

$$\frac{m}{n} \leq 1 - h(p).$$

dla kodu z odpowiednią do szumu zdolnością korekcyjną.

Dla $p = 0.01$, $h(p) = 0.08$, a więc $m \simeq 0.92n$,

dla $p = 0.05$, $h(p) = 0.29$, skąd $m \simeq 0.71n$.

STRATEGIE DEKODOWANIA ZNIEKSZTAŁCONEGO KOMUNIKATU

$B = \mathbf{x} \in \mathcal{B}^n$: zmienna losowa odpowiadająca nadanemu komunikatowi,
 $B' = \mathbf{y} \in \mathcal{B}^n$: komunikat otrzymany.

1. Strategia *idealnego obserwatora*: po otrzymaniu \mathbf{y} dekodujemy go jako \mathbf{x} wg. kryterium

$$P(B = \mathbf{x} | B' = \mathbf{y}) = \max$$

2. Strategia *największego prawdopodobieństwa*: szukamy \mathbf{x} , dla którego

$$P(B' = \mathbf{y} | B = \mathbf{x}) = \max$$

3. Strategia *najmniejszej odległości*: wybieramy \mathbf{x} wg. kryterium

$$d_H(\mathbf{x}, \mathbf{y}) = \min .$$

WNIOSEK 1. Jeśli wszystkie słowa kodowe \mathbf{x} są jednakowo prawdopodobne, strategia idealnego obserwatora i strategia maksimum prawdopodobieństwa są równoważne.

$$P(B' = \mathbf{y} | B = \mathbf{x}) = \frac{P(B' = \mathbf{y}, B = \mathbf{x})}{P(B = \mathbf{x})} = P(B = \mathbf{x} | B' = \mathbf{y}) \frac{P(B' = \mathbf{y})}{P(B = \mathbf{x})} .$$

WNIOSEK 2. Jeśli kanał transmisyjny jest binarnym i symetrycznym kanałem bez pamięci z prawdopodobieństwem błędu $p < 0.5$, wówczas strategie maksimum prawdopodobieństwa i minimalnej odległości są równoważne.

$$P(B' = \mathbf{y} | B = \mathbf{x}) = \prod_{i=1}^n P(b'_j = y_j | b_j = x_j) = p^d (1-p)^{n-d} = (1-p)^n \left(\frac{p}{1-p} \right)^d ,$$

gdzie d jest liczbą przekłamanych bitów $y_j \neq x_j$, a więc $d = d_H(\mathbf{x}, \mathbf{y})$. Ponieważ $\frac{p}{1-p} < 1$, maksimum $P(B' = \mathbf{y} | B = \mathbf{x})$ osiągnięte jest wtedy, gdy d jest najmniejsze.

Jak obliczyć $P(B = \mathbf{x} | B' = \mathbf{y})$ itp?

Nasze dane:

- $P(B = x_i)$ rozkład częstości znaków wejściowych $\mathcal{A} = \{x_1, x_2, \dots, x_k\}$
- $P(B' = y_j | B = x_i) = p_{ij}$ charakterystyka kanału

Stąd możemy wyznaczyć:

- $P(B' = y_j, B = x_i) = P(B' = y_j | B = x_i) \cdot P(B = x_i)$
- $P(B' = y_j) = \sum_{x_i \in \mathcal{A}} P(B' = y_j | B = x_i) P(B = x_i),$

a dalej można wyliczyć $H(B)$, $H(B')$, $H(B', B)$, ...

Przypomnienie: $H(Y|X) = H(Y, X) - H(X)$,

X, Y niezależne $\Rightarrow H(Y, X) = H(Y) + H(X)$, $H(Y|X) = H(Y)$.

Gdy $Y = f(X)$, to jest gdy $P(Y = y_i | X = x_i) = \begin{cases} 0 & \text{gdy } f(x_i) \neq y_i \\ 1 & \text{gdy } f(x_i) = y_i \end{cases}$

wtedy $H(Y, X) = H(X)$ i $H(Y|X) = 0$.

Niech teraz $X = B$ (komunikat nadawany) i $Y = B'$ (komunikat odbierany). W tym kontekście

$$\begin{aligned} H(B'|B) &= \text{niepewność co do } B' \text{ gdy znane jest } B \\ &= \text{niepewność wynikająca z przekłamań kanału} \end{aligned}$$

Zatem pozostała część niepewności

$$I(B', B) := H(B') - H(B'|B)$$

wynika wyłącznie z niewiedzy o tym jaka litera została nadana. Innymi słowy, to ta część niepewności $H(B')$, która znika, gdy wiemy wszystko o B . Jest to tzw. *wzajemna informacja między B i B'* .

WŁASNOŚCI

a) $I(B', B) = H(B') - H(B'|B) = H(B') + H(B) - H(B', B) = H(B) - H(B|B') = I(B, B')$

b) $I(B', B) \geq 0$, z równością jedynie gdy B i B' są niezależne

c) $I(B', B) \leq H(B')$, z równością jedynie gdy $B' = f(B)$

d) $I(B', B) \leq H(B)$, z równością jedynie gdy $B = f(B')$.

b) Gdy $B \perp B'$, $I(B', B) = H(B') - H(B'|B) = H(B') - H(B') = 0$

c) Gdy $B' = f(B)$, $I(B', B) = H(B') - H(B'|B) = H(B') - 0 = H(B')$

Definicja: Pojemność informacyjna kanału Φ (information capacity)

$$\mathcal{C}(\Phi) = \sup_{P(B)} I(B', B)$$

PRZYKŁAD: Binarny kanał symetryczny

$$\Phi \longrightarrow \begin{bmatrix} 1-p & p \\ p & 1-p \end{bmatrix}.$$

Niech $\mathcal{A} = \{0, 1\}$, $P(B = 0) = t$, $P(B = 1) = 1 - t$. Stąd

$$H(B) = -t \log t - (1-t) \log(1-t) = h(t)$$

$$\begin{aligned} H(B'|B) &= H(B'|B=0)P(B=0) + H(B'|B=1)P(B=1) \\ &= h(1-p) \cdot t + h(p) \cdot (1-t) \\ &= h(p) \end{aligned}$$

$$\begin{aligned} P(B' = 0) &= P(B' = 0|B = 0)P(B = 0) + P(B' = 0|B = 1)P(B = 1) \\ &= (1-p) \cdot t + p \cdot (1-t) \\ &= t + p - 2tp = q \end{aligned}$$

$$\begin{aligned} P(B' = 1) &= P(B' = 1|B = 0)P(B = 0) + P(B' = 1|B = 1)P(B = 1) \\ &= p \cdot t + (1-p) \cdot (1-t) \\ &= 1 - (t + p - 2tp) = 1 - q \end{aligned}$$

Stąd $H(B') = h(q)$. Dalej

$$I(B', B) = H(B') - H(B'|B) = h(q) - h(p) = h(t + p - 2tp) - h(p).$$

Musimy wybrać t tak, aby $I(B', B) = \max$, a więc aby $h(t + p - 2tp) = \max$.
Zachodzi to gdy

$$t + p - 2tp = \frac{1}{2} \quad \Rightarrow \quad t = \frac{\frac{1}{2} - p}{1 - 2p} = \frac{\frac{1-2p}{2}}{1 - 2p} = \frac{1}{2}.$$

Wtedy $\mathcal{C}(\Phi) = \max I(B', B) = h(1/2) - h(p) = 1 - h(p)$.

Można łatwo pokazać, że jeśli przekazujemy n bitów niezależnie przez równoległe kanały Φ^n , to

$$\mathcal{C}(\Phi^n) = n\mathcal{C}(\Phi).$$

Reguły łańcucha

$$H(X_1, X_2, \dots, X_n) = H(X_1) + H(X_2|X_1) + H(X_3|X_2, X_1) + \dots + H(X_n|X_{n-1}, \dots, X_1)$$

$$I(X_1, X_2, \dots, X_n, Y) = I(X_1, Y) + I(X_2, Y | X_1) + \dots + I(X_n, Y | X_{n-1}, \dots, X_1)$$

przy czym warunkowa wzajemna informacja zdefiniowana jest tak:

$$I(X, Y | Z) = H(X | Z) - H(X | Y, Z).$$

Data processing inequality

Dla sekwencji niezależnych kanałów $X \xrightarrow{\Phi} Y \xrightarrow{\Psi} Z$ zachodzi

$$I(X, Y) \geq I(X, Z).$$

Niezależność kanałów oznacza, że prawdopodobieństwo odbioru $Z = z_k$ gdy nadano $X = x_i$ obliczamy z iloczynu macierzy prawdopodobieństw $P(\Psi) \cdot P(\Phi)$:

$$P(Z = z_k | X = x_i) = \sum_j P(Z = z_k | Y = y_j) P(Y = y_j | X = x_i)$$

Inaczej można to wyrazić następująco:

$$\begin{aligned} P(X = x_i, Y = y_j, Z = z_k) \\ = P(Z = z_k | Y = y_j) \cdot P(Y = y_j | X = x_i) \cdot P(X = x_i). \end{aligned}$$

Oznacza to w szczególności, że rozkłady zmiennych warunkowych $P(X|Y = y)$ i $P(Z|Y = y)$ są niezależne dla wszystkich y , $P(X, Z|Y) = P(X|Y) \cdot P(Z|Y)$, a stąd

$$H(X, Z | Y) = H(X | Y) + H(Z | Y).$$

DOWÓD nierówności $I(X, Z) \leq I(X, Y)$.

Stosując regułę łańcucha na dwa sposoby otrzymamy alternatywne rozwinięcia dla $I(X, Y, Z)$:

$$I(X, Y, Z) = I(X, Z) + I(X, Y | Z) = I(X, Y) + I(X, Z | Y)$$

Na podstawie niezależności $X|Y$ i $Z|Y$, $I(X, Z | Y) = 0$:

$$\begin{aligned} I(X, Z | Y) &= H(X | Y) - H(X | Y, Z) = H(X | Y) - (H(X, Y, Z) - H(Y, Z)) \\ &= H(X | Y) - \left(H(X, Y, Z) - (H(Z | Y) + H(Y)) \right) \\ &= H(X | Y) + H(Z | Y) - H(X, Z | Y) = 0. \end{aligned}$$


Zatem $I(X, Z) + I(X, Y | Z) = I(X, Y)$, a ponieważ $I(X, Y | Z) \geq 0$, otrzymujemy nierówność data processing.

W ogólności mamy także

$$I(X, Y) \geq I(X, f(Y)),$$

gdy drugi kanał jest bezszumowy $Z = f(Y)$ (jednak f nie musi być różnowartościowa i stąd dodatkowa utrata informacji).

Nierówność Fano



$H(A) = H(B)$, bo kodowanie c jest odwracalne. Dla prostoty załóżmy, że $H(A) = \log |\mathcal{A}|$.

$A' = d(B')$ niekoniecznie 1-1, więc $H(B') \geq H(A')$.

Prawdopodobieństwo błędnego odczytania a' gdy wysłano a podlegające minimalizacji

$$P(\text{błąd}) = \sum_{a \in \mathcal{A}} P(\text{błąd} | a \text{ nadane}) \cdot P(A = a).$$

To prawdopodobieństwo jest zależne od sposobu kodowania c , więc minimalizujemy

$$\epsilon(c) = \max\{P(\text{błąd} | a \text{ nadane}) : a \in \mathcal{A}\}$$

Koszt tej minimalizacji jest spadek efektywności transmisji, którą chcielibyśmy — przeciwnie — maksymalizować,

$$\rho(c) = \frac{H(A)}{n} = \frac{\log |\mathcal{A}|}{n}.$$

Nierówność pomocnicza: X przyjmuje wartości w k -elementowym zbiorze \mathcal{A} . Dla ustalonego $a \in \mathcal{A}$ oznaczmy przez $p = P(X \neq a) = 1 - P(X = a)$. Wtedy

$$H(X) \leq p \log(k-1) + h(p). \quad (*)$$

DOWÓD: Określamy pomocniczą zmienną losową (tzw. indykator)

$$J = \begin{cases} 1 & \text{gdy } X \neq a \\ 0 & \text{gdy } X = a \end{cases}$$

Mamy $P(J = 1) = p$, $P(J = 0) = 1 - p$, $H(J) = h(p)$ oraz

$$H(X|J) = H(X, J) - H(J).$$

Ale $J = f(X)$, zatem $H(X, J) = H(X)$, czyli $H(X) = H(X|J) + H(J)$.

$$\begin{aligned} H(X|J) &= H(X|J=0)P(J=0) + H(X|J=1)P(J=1) \\ &= 0 \cdot (1-p) + pH(X|J=1) \leq p \log(k-1), \end{aligned}$$

a stąd

$$H(X) \leq p \log(k-1) + h(p).$$

Nierówność Fano: Niech X i Y przyjmują wartości w k -elementowym zbiorze \mathcal{A} , $p = P(X \neq Y)$. Wówczas

$$H(X|Y) \leq p \log(k-1) + h(p).$$

DOWÓD. Weźmy $(*)$ z warunkiem $Y = y$, przy czym J jest indykatorem relacji $X \neq Y$:

$$H(X|Y=y) \leq P(X \neq Y|Y=y) \log(k-1) + H(J|Y=y).$$

Mnożymy obustronnie przez $P(Y=y)$ i sumujemy po y , otrzymując

$$H(X|Y) \leq P(X \neq Y) \log(k-1) + H(J|Y) \leq p \log(k-1) + h(p).$$

Interpretacja: $H(X|Y)$ mierzy niepewność co do poprawnego odczytania nadanego symbolu X jeśli odebrano Y . Ta niepewność składa się z 2 części: $h(p)$ niepewność tego czy odczyt jest błędny i $p \log(k-1)$ niepewność jakie przekłamanie powstało, gdy wiadomo, że błąd odczytu rzeczywiście powstał.

Cel — określenie relacji między pojemnością kanału a maksymalną możliwą efektywnością transmisji.

$$\begin{array}{ccccccc}
 \boxed{\mathcal{A}} & \xrightarrow{c} & \boxed{\mathcal{B}^n} & \xrightarrow{\Phi} & \boxed{\mathcal{B}^n} & \xrightarrow{d} & \boxed{\mathcal{A}} \\
 H(A) & = & H(B) & \mathcal{C}(\Phi) & H(B') & \geq & H(A')
 \end{array}$$

Jak poprzednio zakładamy, że $P(A = a) = \frac{1}{k}$. Na podstawie nierówności Fano

$$H(A | A') \leq h(p) + p \log(k - 1) < h(p) + p \log k$$

Stąd

$$I(A, A') = H(A) - H(A | A') \geq \log k - (h(p) + p \log k) = (1 - p) \log k - h(p)$$

Ponadto $I(A', A) \leq I(A', B) \leq I(B', B) \leq n\mathcal{C}(\Phi)$, a więc

$$n\mathcal{C}(\Phi) \geq (1 - p) \log k - h(p) \quad \Rightarrow \quad \mathcal{C}(\Phi) + \frac{h(p)}{n} \geq (1 - p)\rho(c).$$

Twierdzenie: Jeśli $|\mathcal{A}| = k$ i słowa kodowe $c : \mathcal{A} \rightarrow \mathcal{B}^n$ są przesyłane przez bezpamięciowy stacjonarny kanał o przepustowości $\mathcal{C}(\Phi)$, przy czym prawdopodobieństwo błędnego dekodowania otrzymanego komunikatu wynosi $p = \epsilon(c)$, wówczas efektywność transmisji spełnia nierówność

$$\rho(c) \leq \frac{\log k}{n} \leq \frac{\mathcal{C}(\Phi)}{1 - p} + \frac{h(p)}{n(1 - p)} \xrightarrow{p \rightarrow 0} \mathcal{C}(\Phi).$$

Twierdzenie Shannona o kodowaniu w obecności szumu

Dla binarnego symetrycznego kanału Φ i dowolnego $\epsilon > 0$ istnieje dostatecznie duże n i kod $c_n : \mathcal{A}_n \rightarrow \{0, 1\}^n$, dla którego efektywność transmisji spełnia nierówność

$$\rho(c_n) = \frac{\log |\mathcal{A}_n|}{n} \geq \mathcal{C}(\Phi) - \epsilon,$$

z gwarancją, że $\epsilon(c_n) < \epsilon$.

PRZYKŁAD. Zamierzamy nadać komunikat $\alpha \in \mathcal{A}^*$, $|\mathcal{A}| = k$, przez binarny kanał symetryczny o poziomie szumu $p = 0.1$. Jaka maksymalna efektywność transmisji możemy osiągnąć przy możliwie małym prawdopodobieństwie przekłamań $\epsilon(c)$?

$\mathcal{C}(\Phi) = 1 - h(0.1) = 0.53$, więc nie można liczyć na większą efektywność transmisji, niezależnie od sposobu kodowania. Ale tw. Shannona gwarantuje istnienie kodów, dla których efektywność może być dowolnie bliska 0.53. Niestety nie mówi nic o tym jak je konstruować.

Powiedzmy, że chcemy osiągnąć efektywność $\rho(c) = 0.5$, gwarantując jakość transmisji na poziomie $\epsilon(c) < 0.01$. Twierdzenie Shannona orzeka o istnieniu kodu $c_n : \mathcal{A}_n \rightarrow \{0, 1\}^n$ o takich parametrach transmisji, za cenę być może dużego n (oznacza to, że należy kodować bloki liter z \mathcal{A}). Powiedzmy, że znamy ten kod i stosowne n . Jak zakodować napis α ?

Wyznaczmy właściwą długość bloków liter

$$r = \left\lceil \frac{0.5n}{\log k} \right\rceil, \quad \text{a więc} \quad |\mathcal{A}^r| = k^r \leq 2^{0.5n}$$

To gwarantuje, że można zakodować odwracalnie bloki liter z \mathcal{A}^r w alfabecie \mathcal{A}_n , bo $|\mathcal{A}_n| \geq 2^{0.5n}$ skoro $\rho(c_n) \geq 0.5$. Efektywność transmisji wynosi wówczas

$$\frac{\log |\mathcal{A}^r|}{n} \simeq 0.5.$$