

Arimoto-Blahut algoritmus csatornkapacitás számítására

Kasza Péter


2009. május 3.

Tartalomjegyzék

1	Egyirányú hírközlési modell	2
1.1	Jelölések és definíciók	3
2	Csatornakapacitás zajos esetben	3
3	Arimoto-Blahut algoritmus	4

1. Egyirányú hírközlési modell

Az alábbi egyirányú hírközlési modellt Shannon és Weaver alkották meg az 1949-es évek környékén. A modell egyirányúsága annyit jelent, hogy a forrás csak adóként, a fogyasztó pedig csak vevőként működhet. Az ilyen egyirányú csatorna a gyakorlatban ritka, de egyszerűsége miatt elméleti jelentősége számottevő.



1. ábra. Shannon-féle egyirányú hírközlés modellje

Legyen $\mathcal{X} = \{x_1, x_2, \dots, x_n\}$ a forrás ábécé, $\mathcal{Y} = \{y_1, y_2, \dots, y_m\}$ a kódszavak halmaza. Ekkor a $g : \mathcal{X} \rightarrow \mathcal{Y}$ leképezést kódolásnak nevezzük. Zajmentes esetben a kódszavak változás nélkül haladnak át a csatornán.

1.1. Definíció (Sztocasztikus és duplán sztocasztikus mátrix). Az $A \in \mathbb{R}^{n \times m}$ mátrixot sztocasztikus mátrixnak nevezzük, ha $\forall(i, j)$ -re $A_{ij} \geq 0$ és az a. vagy b. pontok közül legalább egy teljesül.

a.

$$\sum_{i=1}^n A_{ij} = 1, \quad (1 \leq j \leq m)$$

b.

$$\sum_{j=1}^m A_{ij} = 1, \quad (1 \leq i \leq n)$$

Ha az A illetve A^T mátrixok sztocasztikus mátrixok, akkor az A mátrixot duplán sztocasztikusnak nevezzük.

1.2. Definíció (Csatornamátrix). A csatornamátrix egy olyan duplán sztocasztikus mátrix, amely az egyes szimbólumok átviteli valószínűségeit tartalmazza.

$$T_{ij} = P(\xi = x_i, \eta = y_j)$$

Megjegyzés. Szimmetrikus csatorna esetén a csatornamátrix ortogonális, azaz:

$$T = T^T$$

1.1. Jelölések és definíciók

Jelölés. A P és Q eloszlások együttes eloszlását független esetben a következő képpen jelöljük:

$$(p_1q_1, p_2q_2, \dots, p_nq_n) = (P \times Q)$$

1.3. Definíció (Információmennyiség). A P eloszlás információmennyiségén, más néven entrópiáján az alábbi összefüggést értjük:

$$H(P) = - \sum_{i=1}^n \sum_{j=1}^n p_i \log_2 p_i$$

1.4. Definíció (Kölcsönös információmennyiség). Legyenek ξ, η valószínűségi változók.

$$I(\xi, \eta) = H(\xi) - H(\xi|\eta)$$

1.5. Definíció (I-divergencia). A Q és P eloszlások I-Divergenciáján az alábbi várhatóértéket értjük:

$$D(Q||P) = \sum_{i=1}^n q_i \log_2 \frac{q_i}{p_i}$$

1.6. Definíció (Csatornakapacitás). A csatornakapacitás az a maximális információmennyiség, amelyet még megbízhatóan tudunk továbbítani a csatornán.

2. Csatornakapacitás zajos esetben

Legyen $\xi : Q = \{q_1, \dots, q_n\}$ a bemeneti, $\eta : Q' = \{q'_1, \dots, q'_n\}$ a kimeneti eloszlás. A T csatornamátrix felhasználásával a kimeneti eloszlás az alábbi formában írható fel:

$$Q' = TQ$$

Jelölje $P = (q_1T_1, \dots, q_nT_n)$ az együttes eloszlást. Ekkor a kölcsönös információmennyiség az alábbi formában írható fel:

$$I(\xi, \eta) = D(P||Q \times TQ) = v(Q)$$

A csatornakapacitást zajos esetben a bemeneti és a kimeneti eloszlások kölcsönös információmennyiségének maximumaként definiálhatjuk:

$$\max_Q v(Q) = C$$

3. Arimoto-Blahut algoritmus

Az Arimoto-Blahut algoritmus egy iteratív algoritmus a csatornakapacitás meghatározására. Az algoritmus a kölcsönös információmennyiség maximalizálásával határozza meg az optimális eloszlást és a csatornakapacitást. Az algoritmust elősorban zajos csatorna esetén alkalmazzák, többek közt mivel zajmentes esetben léteznek sokkalta hatékonyabb megoldások, valamint a zajmentes esetet az algoritmus csak abban az esetben adja vissza, ha a bemeneti eloszlás egyenletes. [1]

3.1. Lemma (Log-szumma egyenlőtlenség).

$$\sum_{i=1}^n a_i \log_2 \frac{a_i}{b_i} \geq a \log_2 \frac{a}{b} \quad (1)$$

$$a = \sum_{i=1}^n a_i, \quad b = \sum_{i=1}^n b_i > 0 \quad (2)$$

Állítás (Az I-divergencia nemnegativtása). Az I-divergencia értéke bármely Q, P eloszlásra nemnegatív.

$$D(Q\|P) \geq 0$$

Bizonyítás. Log-szumma egyenlőtlenség felhasználásával:

$$a = \sum_{i=1}^n q_i = 1, \quad b = \sum_{i=1}^n p_i = 1 \quad (3)$$

$$\underbrace{\sum_{i=1}^n q_i \log_2 \frac{q_i}{p_i}}_{D(Q\|P)} \geq 0 \quad (4)$$

□

3.2. Lemma (Adatfeldolgozási lemma).

$$D(TQ\|TQ') \leq D(Q\|Q') \quad (5)$$

Megjegyzés. Az adatfeldolgozási lemma állítása szerint, a bemeneti adatokra bármilyen adatfeldolgozási műveletet alkalmazva, az eredeti adat információmennyiségét csak csökkenteni tudjuk.

3.3. Lemma. Legyenek $\alpha, f_1, \dots, f_m \in \mathbb{R}$, ekkor:

$$H(Q) \leq \alpha \sum_{i=1}^m q_i f_i + \log_2 \left(\sum_{i=1}^m 2^{-\alpha f_i} \right) \quad (6)$$

Jelölés. Vezessük be az alábbi jelöléseket:

$$D_j(R) := D(T_j \| R) \quad (7)$$

$$D(T \| T|Q) := \sum_{j=1}^m q_j D_j(R) \quad (8)$$

$$F(Q, Q') := D(T \| TQ'|Q) - D(Q \| Q') \quad (9)$$

Tekintsük az előbb bevezetett jelölések néhány tulajdonságát:

Állítás.

$$D(T \| R|Q) = v(Q) + D(TQ \| R) \quad (10)$$

Bizonyítás.

$$\sum_{j=1}^m q_j D_j(R) = \sum_{j=1}^m q_j D(T_j \| R) = \quad (11)$$

$$\sum_{j=1}^m q_j \sum_{i=1}^k t_{ij} \log_2 \frac{t_{ij}}{r_i} = \quad (12)$$

$$\sum_{j=1}^m \sum_{i=1}^k \underbrace{q_{ij} t_{ij}}_{p_{ij}} \log_2 \frac{t_{ij}}{r_i} = \quad (13)$$

$$(14)$$

Az $r'_i = \sum_{j=1}^m q_j t_{ij}$ változók bevezetésével:

$$\underbrace{\sum_{j=1}^m \sum_{i=1}^k q_j t_{ij} \log_2 \frac{t_{ij} q_j}{r_i q_j} \frac{r'_i}{r'_i}}_{D(P \| Q \times R)} = \quad (15)$$

$$\underbrace{\sum_{j=1}^m \sum_{i=1}^k q_j t_{ij} \log_2 \frac{t_{ij} q_j}{q_j r'_i}}_{D(P \| Q \times TQ)} + \underbrace{\sum_{j=1}^m \sum_{i=1}^k q_j t_{ij} \log_2 \frac{r'_i}{r_i}}_{\sum_{i=1}^k r'_i \log_2 \frac{r'_i}{r_i}} = \quad (16)$$

$$v(Q) + D(TQ \| R) \quad (17)$$

□

Állítás.

$$F(Q, Q') = v(Q) + D(TQ \| TQ') - D(Q \| Q') \leq v(Q) \quad (18)$$

Bizonyítás. A 10. egyenletet felhasználva:

$$F(Q, Q') = \underbrace{D(T \| TQ' | Q)}_{v(Q) + D(TQ \| TQ')} - D(Q \| Q')$$

Az adatfeldolgozási lemmát, valamint az I-divergencia nemnegativitását felhasználva:

$$v(Q) = D(P \| Q \times TQ) \geq 0, \quad D(Q \| Q') \geq 0, \quad D(TQ \| TQ') \geq 0 \quad (19)$$

$$D(TQ \| TQ') - D(Q \| Q') \leq 0 \quad (20)$$

$$v(Q) + D(TQ \| TQ') - D(Q \| Q') \leq v(Q) \quad (21)$$

□

Ekkor a 18. egyenletből:

$$D(Q \| Q') \leq v(Q) \quad (22)$$

$$v(Q) = F(Q, Q) \geq F(Q, Q') \quad (23)$$

A $v(Q)$ értékét tehát $F(Q, Q')$ maximalizálásával számíthatjuk ki.

$$F(Q, Q') \rightarrow \max$$

Megjegyzés. Az I-divergencia tulajdonságaiból adódóan egyenlőség a 22. egyenletben csak akkor következik be, ha:

$$D(TQ \| TQ') = 0, \quad TQ \equiv TQ'$$

Állítás. A csatornkapacitás értéke:

$$\max_Q F(Q, Q') = \log_2 S'$$

ha az iteráció során a következő eloszlásnak az alábbiakat választjuk:

$$q_j = \frac{q'_j 2^{D_j(TQ')}}{S'}, \quad S = \sum_{j=1}^m q'_j 2^{D_j(TQ')}$$

Bizonyítás. A 6. egyenletbe az alábbiakat helyettesítve:

$$\alpha = -1, \quad f_j = \log_2 q'_j + D_j(TQ')$$

a következők teljesülnek:

$$H(Q) \leq - \sum_{j=1}^m q_j f_j + \log_2 \sum_{j=1}^m 2^{f_j} = \quad (24)$$

$$- \sum_{j=1}^m q_j (\log_2 q'_j + D_j(TQ')) + \log_2 \left(\sum_{j=1}^m 2^{\log_2 q'_j + D_j(TQ')} \right) = \quad (25)$$

$$- \sum_{j=1}^m q_j \log_2 q'_j - \sum_{j=1}^m q_j D_j(TQ') + \log_2 \left(\sum_{j=1}^m q'_j 2^{D_j(TQ')} \right) \quad (26)$$

$$\sum_{j=1}^m q_j \log_2 \frac{q'_j}{q_j} \leq -D(T\|TQ'|Q) + \log_2 S' \quad (27)$$

$$\underbrace{D(T\|TQ'|Q) - D(Q\|Q')}_{F(Q,Q')} \leq \log_2 S' \quad (28)$$

$$\max_Q F(Q, Q') = \log_2 S' \quad (29)$$

□

-
1. **Arimoto-Blahut**($Q^{(0)}, T$)
[$Q^{(0)}$ - bemeneti eloszlás, T - csatornamátrix]
 2. $S^{(0)} \leftarrow 0$
 3. $N \leftarrow 1$
 4. **WHILE True DO**
 5. $S^{(N)} \leftarrow \sum_{j=1}^m q_j^{(N)} 2^{D_j(TQ^{(N)})}$
 6. $q_j^{(N+1)} \leftarrow \frac{q_j^{(N)} 2^{D_j(TQ^{(N)})}}{S^{(N)}}$
 7. **IF** $|\log_2 S^{(N)} - \log_2 S^{(N-1)}| < \varepsilon$ **THEN**
 8. **BREAK**
 9. **ENDIF**
 10. $N \leftarrow N + 1$
 11. **ENDWHILE**
-

2. ábra. Arimoto-Blahut algoritmus

Hivatkozások

- [1] Fegyverneki Sándor. Információelmélet jegyzet. *Miskolci Egyetem*, 2002.