

# B E V E Z E T É S A Z I N F. E L M. - B E

1. előadás (02.12.)

## Bevezetés, alapfogalmak

Legyen  $X$  egy diszkrét valószínűségi változó, amely értékeit az  $X$  halmazból veheti fel! A hozzá tartozó valószínűségi eloszlás:  $p_X = P\{X=x\}$ ,  $x \in X$

Jelölés: Ha a valószínűségi eloszlás változókat ugyanarról a kétiről jelöljük, mint a változókat, akkor az indexet elhagyjuk:  $p(x) = p_X(x)$   
 $p(y) = p_Y(y)$

Def: Egy diszkrét valószínűségi változó entropiáján az alábbi:

$$H(X) = - \sum_{x \in X} p(x) \log p(x).$$

- változó mértékegysége:
- A log alapja 2, ebben a mértékegység bit.
  - Konvencióként  $0 \cdot \log 0 = 0$ . (mert  $\lim_{x \rightarrow 0} x \log x = 0$ )
  - Előző miatt, egy 0 valószínű esemény nem befolyásolja  $H$  értékét.

Egy  $X$ -től függő  $g$  változó várható értéke  $p$  eloszlásna:

$$E_p g(X) = \sum_{x \in X} g(x) p(x). \quad (\text{egyszerűsített jelölés: } E g(X))$$

Vegyük észre, hogy az entropia nem más mint a  $g(X) = \log \frac{1}{p(X)}$  várható értéke!

Ennek jelentősége abban látszik, ha bevezetjük az alábbi megfontolásokat.

Def: Legyen  $h(p)$  az információs mennyiség, amikor egy  $p$  valószínűségi esemény bekövetkezésével jutunk! Ennek 3 tulajdonságát kell teljesítenie:

- $h(p) \geq 0$ , mert minden esemény infót hoz.
- $h(pq) = h(p) + h(q)$ , mert független események információjában külön-külön is hozzáfuthatunk.
- $h(1/2) = 1$ , az csak egy kocka, ami rögzített az állapotát.

Az egyetlen fn, ami ezeket teljesíti:  $h(p) = -\log_2 p$

Mivel  $E h(X) = - \sum_{x \in X} p(x) \log p(x) = H(X)$ , ezért az entropia nem más, mint a változó által közvetített információ várható értéke.

felülírva: • Ha a log alapja nem 2, akkor a entropia:

$$H_b(X) = - \sum_{x \in X} p(x) \log_b p(x)$$

Ha  $b = e$ , akkor a mértékegység a nats

• Ha  $X = \begin{cases} 1 & p \text{ valószínűséggel} \\ 0 & 1-p \text{ valószínűséggel} \end{cases}$  akkor

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

Néhány tulajdonság:

•  $H(X) \geq 0$

•  $H_b(X) = (-\log_b a) H_a(X)$

így pl. 1 nats =  $\ln 2$  bit  $\approx 0,69$  bit

•  $H(p)$  konvex görbe, minimuma  $\frac{1}{2}$ -ra  $\Rightarrow H(p)$  max, ha  $p = \frac{1}{2}$ .

•  $H(X)$  jelentése, hogy változóan egy bináris jellel kódálható egy szószám, vagy hogy hányval tárolható ki.

pl.: szószámok esetében  $(\frac{1}{2}, \frac{1}{4}, \frac{1}{8}, \frac{1}{16}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64}, \frac{1}{64})$

•  $H(X)$  függvény  $X$  értékeitől, csak  $p(x)$  eloszlástól függ.

Def:  $X$  és  $Y$  változók együttes eloszlásának entropiája az együttes entropia:

$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y)$$

Az együttes entropia másik leírása:  $H(X, Y) = - E \log p(X, Y)$

Def: Felkötés entropia  $H(Y|X)$  az  $Y$  változó entropiájának várható értéke, feltéve, hogy  $X$  értéke ismert:

$$H(Y|X) = \sum_{x \in X} p(x) H(Y|X=x) = - \sum_{x \in X} p(x) \sum_{y \in Y} p(y|x) \log p(y|x) =$$

$$= - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) = - E \log p(Y|X)$$



Tétel (láncszabály):  $H(X, Y) = H(X) + H(Y|X)$

Biz: 
$$H(X, Y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) = - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x) p(y|x) =$$

$$= - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x) - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) =$$

$$= - \sum_{x \in X} p(x) \log p(x) - \sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(y|x) =$$

$$= H(X) + H(Y|X) \quad \square$$

Átírás:  $H(X, Y|Z) = H(X|Z) + H(Y|X, Z)$

Vagyis éne, vagy  $H(X|Y) \neq H(Y|X)$ , de  $H(X) - H(X|Y) = H(Y) - H(Y|X)$ !

Def: Egy  $p(x)$  és  $q(x)$  eloszlás Kullback-Leibler-távolsága (vagy a relatív entrópia) az alábbi:

$$D(p||q) = \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)} = E_p \log \frac{p(X)}{q(X)}$$

- ahol konvencionálisan használjuk:
- $0 \log \frac{0}{0} = 0$
  - $0 \log \frac{0}{q} = 0$  ( $q > 0$ -ra)
  - $p \log \frac{p}{0} = \infty$  ( $p > 0$ -ra).

Telát  $D(p||q) \geq 0$  és  $D(p||q) = 0 \Leftrightarrow p = q$ , azaz egybeesik távolsághat értelmezés, de valójában nem igazán metrika (pl  $D(p||q) \neq D(q||p)$ ).

Értelmezés: Ha  $X$  változó eloszlása ismert, akkor az átlagos hosszú biten  $H(p)$ .  
Ha ismert a kódunkban a betűk  $q$  eloszlást követnek, akkor a működés átlagos hosszú  $H(p) + D(p||q)$ .

Def:  $X$  és  $Y$  változó közötti kölcsönös információt az együttes eloszlásból és a marginális eloszlásból meghatározható relatív entrópia:

$$I(X; Y) = D(p(x, y) || p(x)p(y)) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} =$$

$$= E_{p(x, y)} \log \frac{p(x, y)}{p(x)p(y)}$$

Telát: Az  $I$  két változóját; választjuk el, így telát a  $I(X; Y, Z)$  mennyiség az  $X$  és az  $(Y, Z)$  változó közötti kölcsönös információját.

Ígyjén össze, hogy  $I(x; y)$  kifejezhető entropiákkal:

$$\begin{aligned}
 I(x; y) &= \sum_{x, y} p(x, y) \log \frac{p(x, y)}{p(x)p(y)} = \sum_{x, y} p(x, y) \log \frac{p(x, y)}{p(x)} = \\
 &= - \sum_{x, y} p(x, y) \log p(x) + \sum_{x, y} p(x, y) \log p(x, y) = - \sum_x p(x) \log p(x) - \left( - \sum_{x, y} p(x, y) \log p(x, y) \right) = \\
 &= H(x) - H(x|y).
 \end{aligned}$$

Telát  $I(x; y)$  értelmezése:  $x$  bizonytalanságának csökkenése miatt, hogy  $y$  ismert.

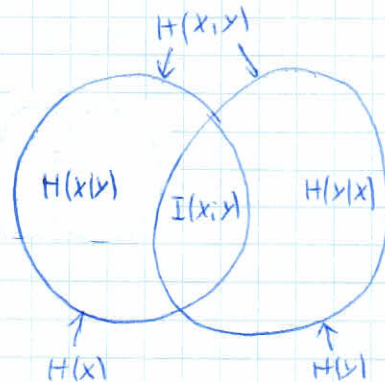
A lévenszabály miatt:  $I(x; y) = H(x) - H(x|y) = H(x) + H(y) - H(x, y)$ .

Telát:  $I(x; x) = H(x) - H(x|x) = H(x)$ .

Telát a fontos összefüggések:

- $I(x; y) = H(x) - H(x|y)$
- $I(x; y) = H(y) - H(y|x)$
- $I(x; y) = H(x) + H(y) - H(x, y)$
- $I(x; y) = I(y; x)$
- $I(x; x) = H(x)$

Gráfikus szemléltetés:





# BEV. INF. ELM.

2. előadás (02.19.)

Eldőlg a lácsmulóllyt a  $H, I, D$  kőríteti kapcsolatokkal 2 változóval  
 írtak fel, de általánosabb tételre is megfogalmazhatóak.

Tétel (általános lácsmulólly): Legyenek  $X_1, X_2, \dots, X_n$  valószínűségi változók, a  
 közös tartomány együttes eloszlás pedig  $p(x_1, x_2, \dots, x_n)$ . Ekkor

$$H(X_1, X_2, \dots, X_n) = \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1)$$

Bizonyítás:

a) teljes indukcióval:

$$n=2\text{-re láttuk: } H(X_1, X_2) = H(X_1) + H(X_2 | X_1)$$

$$n=3\text{-ra: } H(X_1, X_2, X_3) = H(X_1) + H(X_2, X_3 | X_1) = H(X_1) + H(X_2 | X_1) + H(X_3 | X_1, X_2)$$

⋮

$$\begin{aligned} \text{által } n\text{-re: } H(X_1, \dots, X_n) &= H(X_{n-1}, X_n | X_1, \dots, X_{n-2}) + \sum_{i=1}^{n-2} H(X_i | X_{i-1}, \dots, X_1) = \\ &= H(X_{n-1} | X_1, \dots, X_{n-2}) + H(X_n | X_1, \dots, X_{n-1}) + \sum \dots = \\ &= \sum_{i=1}^n H(X_i | X_1, \dots, X_{i-1}) \quad \square \end{aligned}$$

b) algebraileg:

$$\text{Mivel } p(x_1, \dots, x_n) = \prod_{i=1}^n p(x_i | x_{i-1}, \dots, x_1), \text{ ezért}$$

$$\begin{aligned} H(X_1, \dots, X_n) &= - \sum_{x_1, \dots, x_n} p(x_1, \dots, x_n) \log p(x_1, \dots, x_n) = \\ &= - \sum_{x_1, \dots, x_n} p(x_1, \dots, x_n) \log \prod_{i=1}^n p(x_i | x_{i-1}, \dots, x_1) = \\ &= - \sum_{x_1, \dots, x_n} \sum_{i=1}^n p(x_1, \dots, x_n) \log p(x_i | x_{i-1}, \dots, x_1) = - \sum_{i=1}^n \sum_{x_1, \dots, x_i} p(x_1, \dots, x_i) \log p(x_i | x_{i-1}, \dots, x_1) \\ &= \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1) \quad \square \end{aligned}$$

Def: A feltételes közlési információ  $X$  valószínűségi változó között és adott  $Z$  mellett  $Y$  között:

$$\begin{aligned} I(X; Y | Z) &= H(X | Z) - H(X | Y, Z) = \\ &= E_{p(x, y, z)} \log \frac{p(x, y | z)}{p(x | z) p(y | z)} \end{aligned}$$

Ezre másik felületén egy lácsmulólly

Tétel:  $I(X_1, X_2, \dots, X_n; Y) = \sum_{i=1}^n I(X_i; Y | X_{i-1}, \dots, X_1)$

Biz:  $I(X_1, \dots, X_n; Y) = H(X_1, \dots, X_n) - H(X_1, \dots, X_n | Y) =$   
 $= \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1) - \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1, Y) =$   
 $= \sum_{i=1}^n I(X_i; Y | X_1, \dots, X_{i-1})$  □

Def: A  $p(x, y)$  és  $q(x, y)$  eloszlás relatív entrópiája:

$$D(p(y|x) || q(y|x)) = \sum_x p(x) \sum_y p(y|x) \log \frac{p(y|x)}{q(y|x)} =$$

$$= E_{p(x,y)} \log \frac{p(y|x)}{q(y|x)}$$

Tétel:  $D(p(x,y) || q(x,y)) = D(p(x) || q(x)) + D(p(y|x) || q(y|x))$

Biz:  $D(p(x,y) || q(x,y)) = \sum_{x,y} p(x,y) \log \frac{p(x,y)}{q(x,y)} = \sum_{x,y} p(x,y) \log \frac{p(x)p(y|x)}{q(x)q(y|x)} =$   
 $= \sum_{x,y} p(x,y) \log \frac{p(x)}{q(x)} + \sum_{x,y} p(x,y) \log \frac{p(y|x)}{q(y|x)}$  □

Egyszerűsítések

Emeléstétel: Egy  $f$  konvex, az  $(a,b)$  int.-on, és  $\forall x_1, x_2 \in (a,b), \lambda \in [0,1]$ -re

$$f(\lambda x_1 + (1-\lambda)x_2) \leq \lambda f(x_1) + (1-\lambda)f(x_2).$$

Konkáv, ha  $-f$  konvex. Ha egy  $f$  második deriváltja  $\geq 0$ , akkor konvex, ha  $\leq 0$ , akkor konkáv.

Jensen-egyenlőtlenség: Ha  $f$  konvex, akkor  $E f(X) \geq f(E X)$   
 Ha  $f$  konkáv, akkor  $E f(X) \leq f(E X)$ .

Biszimilitás: 2 ponton:  $E f(X) = p_1 f(x_1) + p_2 f(x_2) \geq f(p_1 x_1 + p_2 x_2) = f(E X)$   
 $n$ -re teljes indukcióval.

Tétel: Ha  $p(x)$  és  $q(x)$  két valószínűségi eloszlás, akkor  $D(p || q) \geq 0$ , és  
 egyszerűen akkor  $= 0$  csak akkor, ha  $p = q$ .

Biz: Legyen  $A = \{x : p(x) > 0\}$  a valószínűségi halmaz, akkor:

$$-D(p || q) = - \sum_{x \in A} p(x) \log \frac{p(x)}{q(x)} = \sum_x p(x) \log \frac{q(x)}{p(x)} \leq \log \sum_x p(x) \frac{q(x)}{p(x)} =$$

egyszerűsítés miatt

$$= \log \sum_x q(x) = \log 1 = 0.$$

Egyszerűség akkor áll fenn, ha  $\frac{q(x)}{p(x)} = \text{const} \Leftrightarrow q(x) = p(x)$ . □



- Közvetlenmegadatok:
- $I(X; Y) \geq 0$  ("="  $\Leftrightarrow$   $X$  és  $Y$  független)
  - $D(p(y|x) \| q(y|x)) \geq 0$  ("="  $p(y|x) = q(y|x) \forall x \in \{x | p(x) > 0\}$ )
  - $I(X; Y|Z) \geq 0$  ("="  $\Leftrightarrow$   $X$  és  $Y$  független  $Z$  feltétel esetén)

Tétel: Ha  $|X|$  véges,  $X$  bármely elemeivel  $\sim$  számít, akkor az entrópia maximum  $H(X) \leq \log |X|$ . Egyenlőség akkor és csak akkor, ha  $p(x)$  egyenletes.

Biz: Legyen  $u(x) = \frac{1}{|X|}$ , és legyen  $p(x)$  egy tetszőleges eloszlás!

$$D(p \| u) = \sum_x p(x) \log \frac{p(x)}{u(x)} = \sum_x p(x) \log p(x) - \sum_x p(x) \log u(x) = \\ = \log |X| - H(X).$$

Mivel  $D(p \| u) \geq 0 \Rightarrow H(X) \leq \log |X|$ . Egyenlőség csak ha  $u = p$ .  $\square$

Tétel:  $H(X|Y) \leq H(X)$  „Az információt nem növelhet.”

Egyenlőség akkor és csak akkor, ha  $X$  és  $Y$  függetlenek.

Biz:  $0 \leq I(X; Y) = H(X) - H(X|Y)$ .  $\square$

VIGYAZAT!  $Y$  adott értékeire nem feltétlen működik  $H$ , csak átlagban.

Biz:

$x \setminus X$	1	2	
1	0	$\frac{3}{4}$	$\frac{3}{4}$
2	$\frac{1}{8}$	$\frac{1}{8}$	$\frac{1}{4}$
	$\frac{1}{8}$	$\frac{7}{8}$	

$$H(X) = 0,544$$

$$H(X|Y=1) = 0 < H(X)$$

$$H(X|Y=2) = 1 > H(X)$$

$$H(X|Y) = 0,25 < H(X)$$

Tétel:  $H(X_1, \dots, X_n) \leq \sum_{i=1}^n H(X_i)$ . Egyenlőség akkor és csak akkor, ha  $X_i$ -k függetlenek.

Biz:  $H(X_1, \dots, X_n) = \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1) \leq \sum_{i=1}^n H(X_i)$   $\square$

Tétel: Nemnegatív  $a_1, \dots, a_n, b_1, \dots, b_n$  számokra  $\sum_{i=1}^n a_i \log \frac{a_i}{b_i} \geq \left( \sum_{i=1}^n a_i \right) \log \frac{\sum_{i=1}^n a_i}{\sum_{i=1}^n b_i}$

Egyenlőség akkor és csak akkor, ha  $\frac{a_i}{b_i} = \text{const.}$

Biz: Legyen  $\phi(t) := t \log t$ . Mivel  $\phi''(t) = \frac{1}{t} \log e > 0$ , ezért  $\phi$  konvex pozitív  $t$ -re.

Legyen  $\alpha_i := \frac{b_i}{\sum_j b_j} \rightarrow t_i = \frac{a_i}{b_i}$ ! A Jensen-egyenlőség: Jensen miatt

$$\sum_i a_i \log \frac{a_i}{b_i} = \sum_j b_j \sum_i \alpha_i t_i \log t_i = \sum_j b_j \sum_i \alpha_i \phi(t_i) \geq \sum_j b_j \phi\left(\sum_i \alpha_i t_i\right) = \\ = \sum_i a_i \log \frac{\sum_i a_i}{\sum_i b_i} \quad \square$$

Tétel:  $D(p||q)$  konvex a  $(p, q)$  párra, azaz

$$D(\lambda p_1 + (1-\lambda)p_2 || \lambda q_1 + (1-\lambda)q_2) \leq \lambda D(p_1 || q_1) + (1-\lambda) D(p_2 || q_2) \quad \forall \lambda \in [0, 1]$$

Biz: Alkalmazzuk a log-nem egyenlőtlenséget:

$$(\lambda p_1(x) + (1-\lambda)p_2(x)) \log \frac{\lambda p_1(x) + (1-\lambda)p_2(x)}{\lambda q_1(x) + (1-\lambda)q_2(x)} \leq \lambda p_1(x) \log \frac{\lambda p_1(x)}{\lambda q_1(x)} + (1-\lambda)p_2(x) \log \frac{(1-\lambda)p_2(x)}{(1-\lambda)q_2(x)}$$

$x$ -re numerikus megkezdjük az kívánt egyenlőtlenséget.  $\square$

Tétel:  $H(X)$  konvex  $f(x) = p(x)$ -nek.

Biz: Ha  $u(x) = \frac{1}{|x|}$ , akkor  $H(X) = \log |X| - D(p||u)$   
 $\uparrow$   $\uparrow$   
 konstans konvex  $\Rightarrow H$  konvex  $\square$

Tétel:  $I(X; Y)$  konvex  $f(x) = p(x)$ -nek  $f(y) = p(y|x)$ -re és konvex  $f(x) = p(y|x)$ -nek  $f(y) = p(x)$ -re.

Egyszerűen nem bizonyítható

Def: Az  $X, Y, Z$  változókat egy Markov láncból némszónak hívjuk, és  $X \rightarrow Y \rightarrow Z$ -nek jelöljük, ha  $p(x, y, z) = p(x) p(y|x) p(z|y)$ .

(Ezsel elvárjuk, ha  $p(z|x, y) = p(z|y)$ .)

Tétel (Információ felbontási egyenlőtlenség): Ha  $X \rightarrow Y \rightarrow Z$ , akkor  $I(X; Y) \geq I(X; Z)$ .

Biz: Szorozzalás miatt:  $I(X; Y, Z) = I(X; Z) + I(X; Y|Z) \geq I(X; Z)$   
 $= I(X; Y) + I(X; Z|Y) = I(X; Y)$

Mivel azért  $Y$ -ra  $X$  és  $Z$  független  $I(X; Z|Y) = 0$ , továbbá  $I(X; Y|Z) \geq 0$ .  $\square$

A csatorna általánosan, legyen egy üzenetet kódoljunk, és a kódból visszanyerjük az információt. A kérdés, hogy ezt milyen jól tudjuk megtenni.

Tétel (Fano-egyenlőtlenség): Legyenek a  $X \rightarrow Y \rightarrow \hat{X}$  egy Markov-láncból némszó változó, ahol  $\hat{X}(Y)$  egy ismételt  $f(x)$  (nem feltétlenül determinisztikus).

A hiba valószínűsége:  $P_e = P_r \{ \hat{X} \neq X \}$ . Ennek igaz az alábbi állítás:

$$H(P_e) + P_e \log |X| \geq H(X|\hat{X}) \geq H(X|Y)$$

Biz: Tekintsük az alábbi változót:  $E = \begin{cases} 1 & \text{ha } \hat{X} \neq X \\ 0 & \text{ha } \hat{X} = X \end{cases}$

Ez az entropia:  $H(E, X|\hat{X}) = H(X|\hat{X}) + \overbrace{H(E|X, \hat{X})}^0 = H(X|\hat{X})$   
 $= H(E|\hat{X}) + H(X|E, \hat{X})$



Homályos fel, vagy  $H(E|X) \leq H(E) = H(P_e)$ .

$$\begin{aligned} \text{Tanulási } H(X|E, \hat{X}) &= (1-P_e) \cdot H(X|\hat{X}, E=0) + P_e \cdot H(X|\hat{X}, E=1) = \\ &= (1-P_e) \cdot 0 + P_e H(X|\hat{X}) \leq P_e \log |X|. \end{aligned}$$

Ebből tehát  $H(P_e) + P_e \log |X| \geq H(X, \hat{X})$ .

Az információi feladatoknál egyenlőséggel:  $I(X; \hat{X}) \leq I(X; Y) \Rightarrow H(X|\hat{X}) \geq H(X|Y)$  □

Következő: Mivel  $E$  bináris változó,  $H(P_e)$  maximum 1, így a Fano-egyenlőtlenség alapján csak akkor lehet  $P_e < 1$ :

$$1 + P_e \log |X| \geq H(X|Y) \Rightarrow P_e \geq \frac{H(X|Y) - 1}{\log |X|}$$

Aszimptotikus Entropia-tulajdonság

Valószínűleg láttuk a nagy számok törvénylegét, ami alapján sok kísérletben a gyakoriság az elméleti valószínűségekre tart. Az inf. elméletben ennek analógiája, hogy egy hirtelen megváltozó jelviszonyok között van  $n$  i.i.d. Az alábbiakban ezt is valamilyen következményt vizsgálunk.

jelölés: i.i.d. = független, azonos eloszlású változók.

Tétel (AEP): Legyenek  $X_1, \dots, X_n$  i.i.d. változók! Ekkor az együttes eloszlás:

$$-\frac{1}{n} \log p(X_1, \dots, X_n) \rightarrow H(X)$$

Biz: Mivel  $X_i$ -k függetlenek, az együttes eloszlás nevezetékének számlálói:

$$-\frac{1}{n} \log p(X_1, \dots, X_n) = -\frac{1}{n} \sum_{i=1}^n \log p(X_i) \rightarrow \text{nagy számok törvénye miatt}$$

$$\rightarrow -\mathbb{E} \log p(X) = H(X) \quad \square$$

Def:  $p(x)$  eloszlás esetén az  $X^n$  betűsoroknál tipikus résbetűsoroként azok megjelölésére használhatjuk azt, amikre  $2^{-n(H(X)+\epsilon)} \leq p(X_1, \dots, X_n) \leq 2^{-n(H(X)-\epsilon)}$

Adott  $\epsilon$  esetén a tipikus betűsorok halmaza  $A_\epsilon^{(n)}$ .

Tétel: A tipikus betűsorok az alábbi tulajdonságokkal rendelkeznek:

$$1. \text{ Ha } (X_1, \dots, X_n) \in A_\epsilon^{(n)} \text{ akkor } H(X) - \epsilon \leq -\frac{1}{n} \log p(X_1, \dots, X_n) \leq H(X) + \epsilon.$$

$$2. \Pr\{A_\epsilon^{(n)}\} > 1 - \epsilon \text{ elég nagy } n\text{-re.}$$

$$3. |A_\epsilon^{(n)}| \leq 2^{n(H(X)+\epsilon)}$$

$$4. |A_\epsilon^{(n)}| \geq (1-\epsilon) 2^{n(H(X)-\epsilon)} \text{ elég nagy } n\text{-re.}$$

Biz: 1. definíció átrendezésével triviális.

2. A AEP miatt annak valószínűsége, hogy  $(X_1, \dots, X_n) \in A_\epsilon^{(n)}$  tart 1-hez  $n \rightarrow \infty$  esetén, tehát  $\forall \delta > 0$ -es  $\exists n_0$  úgy, hogy  $\forall n > n_0$ -ra  $\Pr\{A_\epsilon^{(n)}\} > 1 - \delta$ .

$\delta = \epsilon$ -re ez éppen az állítás.

$$3. 1 = \sum_{x \in X^n} p(x) \geq \sum_{x \in A_\epsilon^{(n)}} p(x) \geq \sum_{x \in A_\epsilon^{(n)}} 2^{-n(H(X)+\epsilon)} = 2^{-n(H(X)+\epsilon)} |A_\epsilon^{(n)}|$$

$$4. \text{ elég nagy } n\text{-re a 2.-ből: } 1 - \epsilon < \Pr\{A_\epsilon^{(n)}\} \leq \sum_{x \in A_\epsilon^{(n)}} 2^{-n(H(X)-\epsilon)} = 2^{-n(H(X)-\epsilon)} |A_\epsilon^{(n)}| \quad \square$$



Tétel: Legyen  $X^n$  egy i.i.d.-köl álló sorozat  $p(x)$  valószínűséggel és  $\epsilon > 0$ !

Ekkor létezik olyan  $\epsilon$ -szel, ami az  $X^n$  nemverianális bináris kódolását mondja, vagyis, hogy a sorozat hosszán véletlen értéke:

$$E\left[\frac{1}{n} \ell(X^n)\right] \leq H(X) + \epsilon \quad \text{minden } \epsilon\text{-ra elegendően nagy } n \text{ esetén.}$$

Biz: Bontsuk fel a lehetséges nemverianális kódolást  $A_\epsilon^{(n)}$ -re és  $A_\epsilon^{(n)c}$ -re!

Az  $A_\epsilon^{(n)}$ -beli elemek lévszáma legfeljebb  $n(H+\epsilon)+1$  bit kell. ( $H+1$  oszlop ment  $n(H+\epsilon)$  sor bit, vagy egyérv.) Ezen sorok része még tegyük egy 0-t, hogy jelezzük, ez az  $A_\epsilon^{(n)}$ -beli.

Az  $A_\epsilon^{(n)c}$ -n kívülre nemverianális kódolására  $n \log |X| + 1$  kell. Erre egy 1-t adjunk hozzá. Így a minimális mértékű hossz:  $\ell(x) = \begin{cases} n(H+\epsilon)+2 & x \in A_\epsilon^{(n)} \\ n \log |X| + 2 & x \notin A_\epsilon^{(n)} \end{cases}$

A hossz véletlen értéke:

$$\begin{aligned} E[\ell(X^n)] &= \sum_{x^n} p(x^n) \ell(x^n) = \sum_{x^n \in A_\epsilon^{(n)}} p(x^n) \ell(x^n) + \sum_{x^n \notin A_\epsilon^{(n)}} p(x^n) \ell(x^n) \leq \\ &\leq \sum_{x^n \in A_\epsilon^{(n)}} p(x^n) (n(H+\epsilon)+2) + \sum_{x^n \notin A_\epsilon^{(n)}} p(x^n) (n \log |X| + 2) = \\ &= P_n \{A_\epsilon^{(n)}\} (n(H+\epsilon)+2) + P_n \{A_\epsilon^{(n)c}\} (n \log |X| + 2) \leq \\ &\leq n(H+\epsilon) + \epsilon n \log |X| + 2 = n(H+\epsilon') \end{aligned}$$

ahol  $\epsilon' = \epsilon + \epsilon \log |X| + \frac{2}{n}$ , ami tetszőlegesen kicsi lehet megfelelő  $n$  esetén.  $\square$

Def: Legyen  $B_\delta^{(n)} \subset X^n$  a legkisebb részalgebra a nemverianális analízis valószínűsége:

$$P_n \{B_\delta^{(n)}\} \geq 1 - \delta!$$

Könnyen látható, hogy  $B_\delta^{(n)}$ -be a legnagyobb valószínű elemet kell beáraztatni, vagyis, amíg elem van a  $1-\delta$  tartományban.

megjelölés meggyőzően megfelelő  $\delta$  és  $\epsilon$  esetén.

Belelátó, hogy  $B_\delta^{(n)} \subset A_\epsilon^{(n)}$

Állítás:  $\delta_n \rightarrow 0$  és  $\epsilon_n \rightarrow 0$  monoton módon, ahol  $|B_{\delta_n}^{(n)}| \geq |A_{\epsilon_n}^{(n)}| \geq 2^{nH}$ , ahol

$$a_n \geq b_n \text{ jelentés } \lim_{n \rightarrow \infty} \frac{1}{n} \log \frac{a_n}{b_n} = 0.$$

Szembőltesen:  $A_\epsilon^n \subset B_\delta^n$  elemek közötti viszonyok elvárásai az elemek elvértelmezésére.

## Stochasztikus folyamatok entropiavételezője

A valószínűségi elméletben van idő folyamatainak, egy állapotokból álló és irányított háló. A következőkben látjuk, hogy stacionárius folyamatok entropiájára és tulajdonságaira, ahogy az idő is.

Def: Egy stochasztikus folyamat stacionárius, ha az együttes eloszlás invariáns az indexek eltolására:  $P\{X_1=x_1, \dots, X_n=x_n\} = P\{X_{n+1}=x_1, \dots, X_{2n}=x_n\}$   
 $\forall n \in \mathbb{N}, x_1, x_2, \dots, x_n$ -re.

Def: Egy diszkrét stochasztikus folyamat Markov-láncnak hívünk, ha egy adott elem feltétel nélküli valószínűsége csak az előző elemétől függ:

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

$$\forall x_1, x_2, \dots, x_{n+1} \text{ -re.}$$

Def: Egy Markov-lánc időinvariáns, ha  $P(X_{n+1}|X_n)$  független  $n$ -től.

Egy időinvariáns Markov-lánc az átmeneti mátrixával jellemezhető:  $P \in \mathbb{R}^{(X \times X)}$

$P_{ij} = P\{X_{n+1}=x_j | X_n=x_i\}$ . Ekkor, ha az  $n$ . vektor eloszlása  $P(X_n)$ ,

akkor az  $n+1$ .-é:  $P(X_{n+1}) = \sum_{x_n} P(X_n) P_{x_n X_{n+1}}$ . Ha  $P(X_{n+1}) = P(X_n) \forall x_n$  akkor azt stacionárius eloszlásnak hívjük. Ha a korábbi állapot valószínűsége a stac. eloszlást követi, akkor a folyamat stacionárius.

Ha a Markov-láncunk korlátlan valószínűséggel el lehet jutni bármely állapattal bármelyikbe véges lépésen belül, a folyamat irreducibilis. Ha az állapotokhoz irányultságok vezetés nélkül hozzáférhető minden állapotra 1, a folyamat aperiódikus. Ha egy véges állapattal rendelkező Markov-lánc irreducibilis és aperiódikus, akkor egyértelműen létezik egy stac. eloszlás és bármely kezdeti eloszlás esetén a lánc ehhez tart  $n \rightarrow \infty$  esetén.

Def: Egy  $\{X_i\}$  stochasztikus folyamat entropiavételezője az alábbi képlet, ha létezik:

$$H(X) = \lim_{n \rightarrow \infty} \frac{1}{n} H(X_1, \dots, X_n)$$

Definiálhatjuk az lokális viszonyt is:  $H'(X) = \lim_{n \rightarrow \infty} H(X_n | X_{n-1}, \dots, X_1)$



Tétel: Stac. stoch., folyamatok  $H(X)$  és  $H'(X)$  is létezik és egyenlők.

BG: Feltétel, entropia tulajdonságai miatt:

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

tehát  $H(X_n | X_{n-1}, \dots, X_1)$  egy csökkenő pozitív sorozat, tehát konvergens.

Beleltérési, vagyis  $a_n \rightarrow a$  és  $b_n = \frac{1}{n} \sum_{i=1}^n a_i$ , akkor  $b_n \rightarrow a$  (Cesáro-áttev.)

Láncszabály miatt:

$$\frac{1}{n} H(X_1, \dots, X_n) = \frac{1}{n} \sum_{i=1}^n H(X_i | X_{i-1}, \dots, X_1).$$

A fenti alakú tagokból van kivételünk a stac. miatt a bal oldal mindig  
egyenlő lesz a Cesáro-áttev. miatt  $\Rightarrow H(X) = H'(X)$  □

i.i.d. művevény entropiaértéke:  $H(X) = H(X_1)$

Marks-folyamat entropiaértéke:  $H(X) = H(X_2 | X_1) = - \sum_{i,j} p_{ij} \log p_{ij}$ .

Egyéb nem speciális esetben van köztük, vagy létezik.

Fonduirakmen II. feltétele:  $\exists$  van nárcus  $\ell$ , de a környék k.k. fajátka növekedés  
csúsz.

# B E V I N F E L M

4. előadás (09.05.1)

## Adattömörítés

Def: Egy  $X$  valószínűségi vektoros terev kód egy leképezés  $X$ -ből  $D^*$ -ba, ahol  $X$  az  $X$  írásiértéke,  $D^*$  pedig véges hosszúságú szavak a  $D$ -etűt tartalmazó ábcédék.

jelölések: kód:  $C: X \rightarrow D^*$

$x$ -et kódoló szó:  $C(x)$

$\ell(x)$ : Az  $x$ -hoz tartozó szó hossza.

Def: Egy kód véletlen hosszúsága az  $\ell(x)$  véletlen értéke:

$$L(C) = \sum_{x \in X} p(x) \ell(x)$$

Def: Egy kód nem-singuláris, ha  $X$  tetszőleges írásiérték különböző szóit rendel:

$$x \neq x' \Rightarrow C(x) \neq C(x')$$

Def: Egy  $C$  kód kiterjesztése véges hosszúságú  $X$ -stringekre az alábbi:

$$C(x_1 x_2 \dots x_n) = C(x_1) C(x_2) \dots C(x_n).$$

Def: Egy kód egyértelműen dekódálható, ha a kiterjesztése nem-singuláris.

Def: Egy kód prefix-kód vagy univokális kód, ha egyik kód szó sem előtagja egy másiknak.

Statisztika:



pl.:	$X$	singuláris	nem-singuláris, de nem eg. dekódálható	eg. dekódálható de nem prefix	prefix-kód
1	0	0	0	10	0
2	0	0	010	00	10
3	0	0	01	11	110
4	0	0	10	110	111

Egy kiterjesztés kódolásos az egyértelműen dekódálhatóság a min, hogy az legyen kiterjesztés elválasztó jel, de ha a kód nem prefix-kód, akkor egy kód lehet másik az egyik.

Gél: A leghosszabb szó véletlen hosszúságú szóval kezdődő prefix-kód megtalálása.



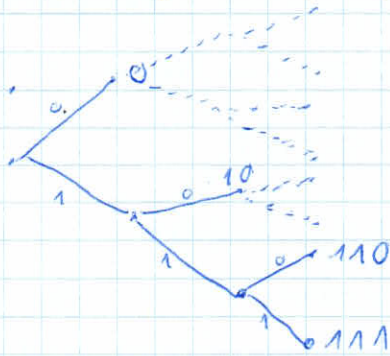
Tétel (Kraft - egyenlőség): Minden prefix-kód egy  $D$  ábrán felett teljesíti az alábbi

$$\sum_i D^{-l_i} \leq 1$$

ahol  $l_i$  az  $i$ -ik kódjának hossza.

Megfordítás: Ha adott a kódzóhosszok egy halmaza, ami teljesíti az egyenlőséget, akkor létezik egy prefix-kód a megadott hosszúságú kódzókkal.

Biz: Képzünk el egy  $D$ -nális fát, ahol az ágak reprezentálják a karaktereket és a csúcsok a kódot: pl.:  $D=2$ -re:



A prefix-kód feltétele, hogy ha egy szó irányos kódja, akkor a szó bármely csúcs leszármazottai nem azok.

Legyen a legrosszabb szó hossza  $l_{max}$ ! Az  $l_{max}$  szinten a  $D$ -nális fában  $D^{l_{max}}$

csúcs van, de csak közül néhány kódja, néhány van. Egy  $l_i$ -ik szinten lévő kódjának  $D^{l_{max}-l_i}$  leszármazottai vannak az  $l_{max}$ -ik szinten, és ezek a legrosszabb színpontok, tehát az összes lehetséges kódja leszármazottai nem lehet többek, mint az összes csúcs:

$$\sum_i D^{l_{max}-l_i} \leq D^{l_{max}}$$

$$\Rightarrow \sum_i D^{-l_i} \leq 1$$

Megfordítás: Ha adott néhány szám, ami teljesíti az egyenlőséget, akkor tudunk konstruálni egy megfelelő  $D$ -nális fát: Az 1. szó legyen az első  $l_i$  hosszú szót. Ez kényszeríti az összes csúcsot és felosztja. Az 2. szó a maradék közül az első  $l_2$ -t, stb...

□

Tétel (kitüntetett kvant - állapotosság): U. a. mita kvant - állapotosság, csak egyarállatósan végtelen sok kódolás:

$$\sum_{i=1}^{\infty} D^{-e_i} \leq 1.$$

Biz: Legyen az ábrék a  $\{0, 1, \dots, D-1\}$  és az  $i$ -ik kódok  $y_1 y_2 \dots y_{e_i}$ !

A  $0, y_1 y_2 \dots y_{e_i}$  egy valós szám a  $D$ -os számrendszerben:

$$0, y_1 y_2 \dots y_{e_i} = \sum_{j=1}^{e_i} y_j D^{-j}.$$

És nyilván össze van a  $[0, y_1 y_2 \dots y_{e_i}, 0, y_1 y_2 \dots y_{e_i} + \frac{1}{D^{e_i}})$  intervallumban,

ahol a  $0, y_1 y_2 \dots y_{e_i}$  -vel kezdődő számok vannak. A prefix-kód feltétele, hogy ezek az intervallumok diszjunktak, tehát az összegük nem lehet nagyobb, mint a  $[0, 1)$  intervallumé:

$$\sum_{i=1}^{\infty} D^{-e_i} \leq 1.$$

Magyarázat: rendezzük át a számokat, hogy  $e_1 \leq e_2 \leq \dots$ , és az adott sorozat minden tagjának hozzá a  $[0, 1)$  intervallum végéhez  $\frac{1}{D^{e_i}}$  hosszúságú intervallumot. pl. ha  $e_1=1, e_2=2, \dots$  akkor  $[0, \frac{1}{D}), [\frac{1}{D}, \frac{1}{D} + \frac{1}{D^2}), \dots$

□

Mert van egy elég erős feltételünk a prefix kódokra, de jó lenne megmutatni a lehető leggyorsabb prefix kódot. Ez egy egyszerű optimizációs probléma:

optimalizálandó kifejezés:  $L = \sum p_i e_i$

feltétel:  $\sum D^{-e_i} \leq 1.$

Lagrange - multiplikatort használva:  $F = \sum p_i e_i + \lambda (\sum D^{-e_i} - 1)$

$$\frac{\partial F}{\partial e_i} = p_i - \lambda D^{-e_i} \ln D \stackrel{!}{=} 0 \Rightarrow D^{-e_i^*} = \frac{p_i}{\lambda \ln D}$$

A feltételbe visszahelyettesítve:  $\lambda \geq (\ln D)^{-1} \Rightarrow D^{-e_i^*} \leq p_i \Rightarrow$

$$\Rightarrow e_i^* \geq -\log_D p_i \Rightarrow L^* = \sum p_i e_i \geq \sum p_i (-\log_D p_i) = H_0(X)$$

Teljesen az entropia egy alsó korlát a végtelen hosszú, és állapotosság, csak akkor lehet, ha a megfelelő  $\log_D p_i$  értékek egy számok.

És precíz is lehetetlen.



Tétel: egy kód  $L$  váratlan hosszú bármely  $D$ -váris prefix-kódba és egy  $X$  random vektorra:

$$L \geq H_D(X).$$

Egyszerűsítés akkor van, ha  $D^{-e_i} = p_i$ .

Biz:

$$L - H_D(X) = \sum_i p_i l_i - \sum_i p_i \log_D \frac{1}{p_i} = -\sum_i p_i \log_D D^{-e_i} + \sum_i p_i \log_D p_i = *$$

bevezetve a  $r_i = \frac{D^{-e_i}}{\sum_j D^{-e_j}}$  és  $c = \sum_j D^{-e_j}$  értékeket:

$$* = \sum_i p_i \log_D \frac{p_i}{r_i} - \log_D c = D_0(p \| r) + \log_D \frac{1}{c} \geq 0$$

Az első tag relatív entrópia tulajdonságai miatt nem negatív, a második pedig a Kraft-egyenletességre miatt  $c \leq 1$ . □

Def: egy eloszlás  $D$ -adikus ha a valószínűségei  $D^{-n}$  alakban írhatóak  $n \in \mathbb{N}$ -ra.

# BEV IVF ELM

5. előadás (03.12.)

Lejtűk: legyen a kvant-egyenletrendszer olyan egyszerű, ha az egyszerű D-nélis, és az általa előírt bocsúság is olyan a minimális. Ez lenne a megfelelően van D-nélis esetében is a legjobbnak írtet.

A minimális kódolásról van definiálva.

Def: Egy  $\{p_1, \dots, p_n\}$  előírtkor tartozó (vagy kód optimális), ha a bocsús tartozó  $\{e_1, \dots, e_n\}$  kódolás bocsúságából képzett  $v_i = \frac{D^{-e_i}}{\sum_j D^{-e_j}}$  előírtkor relatív entropiája minimális a p- előírtkorhoz képest.

Amikor  $H(C)$  előírtkor tartozó r' előírtkorra  $D_f(p||r) \leq D_f(p||r')$ .

Tétel: Legyen a p előírtkor tartozó egy optimális kód valószínűségei valahogy  $\{e_1^*, \dots, e_m^*\}$  a relatív bocsúság pedig  $L^* = \sum p_i e_i^*$ .

Ekkor

$$H_0(x) \leq L^* < H_0(x) + 1.$$

Biz:  $H_0(x) \leq L^*$  előírtkor órák látottak miatt.

Legyen egy néha kód elem, legyen a kódolásnak hossza  $e_i = \lceil \log_2 \frac{1}{p_i} \rceil$  alak

[a] az a felső egész része! Ez kielégíti a kvant-egyenletet, mert

$$\sum_i D^{-\lceil \log_2 \frac{1}{p_i} \rceil} \leq \sum_i D^{-\log_2 \frac{1}{p_i}} = \sum_i p_i = 1 \Rightarrow \text{Létezik prefix kód } \{e_i\} \text{ mondjuk}$$

[b] delfe miatt  $\log_2 \frac{1}{p_i} \leq e_i < \log_2 \frac{1}{p_i} + 1$

Bocsonom  $p_i$ -vel és számomra i-re:  $H_0(x) \leq L < H_0(x) + 1$

Mivel  $L^*$  optimális, miatt  $L^* \leq L < H_0 + 1$ . □

az korábban írtuk?

A hiba továbbra csökkenthető, ha több kvantot mérünk egy helyen, és azokat kódoljuk, mint a  $x^n$ -ből néhány szöveg. Ha  $e(x_1, \dots, x_n)$ -vel jelöljük az  $(x_1, \dots, x_n)$  szekvenciát kódoló szó hosszát, akkor a kvantumcsökkentés relatív bocsús:

$$L_n = \frac{1}{n} \sum_{x \in X^n} p(x_1, \dots, x_n) e(x_1, \dots, x_n).$$

Erre alkalmazva az előbbi tételt:  $H(x_1, \dots, x_n) \leq n L_n < H(x_1, \dots, x_n) + 1$ .

id változók esetén  $H(x_1, \dots, x_n) = \sum H(x_i) = n H(x) \Rightarrow H(x) \leq L_n < H(x) + \frac{1}{n}$

megyis vagy n-re  $L_n \rightarrow H(x)$ . Szokásos esetben mintén  $L_n \rightarrow H(x)$ .



precíz leírás:

Tétel: A minimális kvantizálási kód hossza:

$$\frac{H(x_1, \dots, x_n)}{n} \leq L_n^* \leq \frac{H(x_1, \dots, x_n)}{n} + \frac{1}{n}$$

Ha  $x_1, \dots, x_n$  stochasztikus folyamat, akkor  $L_n^* \rightarrow H(X)$  ahol  $H(X)$  az entrópiaérték.

Tétel (Klász kód): Ha egy  $p$  eloszlású változót egy kódolunk, mint a  $q$  eloszlású lenne, akkor a véletlen hossz

$$H(p) + D(p||q) \leq L < H(p) + D(p||q) + 1.$$

Biz: 
$$L = \sum_{x \in X} p(x) \ell(x) \leq \sum_{x \in X} p(x) \left( \log \frac{1}{q(x)} + 1 \right) = \sum_{x \in X} p(x) \left[ \log \left( \frac{p(x)}{q(x)} \frac{1}{p(x)} \right) + 1 \right] =$$

$$= \sum_{x \in X} p(x) \log \frac{p(x)}{q(x)} + \sum_{x \in X} p(x) \log \frac{1}{p(x)} + 1 = D(p||q) + H(p) + 1$$

alós kodot egyenlő

□

Tétel (McMillen): Minden egyértelműen dekódolható kód hosszai mindig teljesíti a Kraft - egyenlőtlenséget:

$$\sum_i D^{-\ell_i} \leq 1$$

Megfordítás, ha kódolásunknak egy salakra teljesíti a Kraft - egyenlőtlenséget, akkor létezik egy egyértelműen dekódolható kód.

Biz: A megfordítás triviális, hiszen a prefix kódok igen az illatos, ami egyben dekódolható.

Legyen  $C^k$  a  $C$  kód  $k$ -ik hirtérítésére! Ekkor a kód hossza:

$$e(x_1, x_2, \dots, x_n) = \sum_{i=1}^k e(x_i). \text{ Tehát az alábbiakat:}$$

$$\left( \sum_{x \in X} D^{-e(x)} \right)^k = \sum_{x_1 \in X} \dots \sum_{x_k \in X} D^{-e(x_1)} \dots D^{-e(x_k)} = \sum_{x \in X^k} D^{-e(x)} = \sum_{m=1}^{k \cdot \ell_{\max}} a(m) D^{-m}$$

ahol  $a(m)$  az  $m$  hosszú kódok szám  $C^k$ -ben. Mivel egyértelműen dekódolható, ezért  $a(m) \leq D^m$ , tehát

$$\left( \sum_{x \in X} D^{-e(x)} \right)^k \leq \sum_{m=1}^{k \cdot \ell_{\max}} D^m D^{-m} = k \cdot \ell_{\max} \Rightarrow \sum_i D^{-\ell_i} \leq (k \cdot \ell_{\max})^{-1/k}$$

Mivel ez minden  $k$ -ra igaz, hártsa a  $k \rightarrow \infty$  határesetet:  $(k \cdot \ell_{\max})^{-1/k} \rightarrow 1$

$$\Rightarrow \sum_i D^{-\ell_i} \leq 1$$

□

Követelmény: Az egyértelműen dekodálható kódoknál négyteljesen dekodolható és teljesítő a Kraft - egyenlettel.

TV: A probléma az előző tétellel, hogy négyteljes  $|X|$  esetén  $L$  van is lehet, hogy négyteljes is a  $\Sigma$  nem hirtelen, hogy mégis.

DE: A kód minden részében egyértelműen dekodálható, így végig egy egész részlehet, is tudunk a  $\infty$ -ra!

$$\sum_{i=1}^{\infty} D^{-e_i} = \lim_{N \rightarrow \infty} \sum_{i=1}^N D^{-e_i} \leq 1$$

□

## Huffman-kód

Jó lenne tudni egy konkrét konstrukciót, ami magától egy optimális kódok.

A Huffman kód pont ilyen.

Konstrukció: 1) rendszeresen csökkenő sorrendbe a valószínűségeket sorolt a maradék!

2) Adjuk össze a legkisebb két értéket! A hozzájárulást természetesen tehetjük egyet "mentő"

3) Ismétljük a 1-2 lépéseket, amíg csak egy maradt!

4) Egy adott két kódoló kódolási viszonyok alapján, minden előzővel természetesen egy 0-t vagy 1-t!

5) D-úrunk kód esetén a 2. lépésben a legkisebb 0 értéket kell összerakni.

ezt jelenti, hogy minden lépésben 0-1-gyel csökken a maradék száma, tehát lehetetlen  $1+k(D-1)$  db maradék kell lennie valamilyen  $k$ -ra. Ha ez nem teljesül, adjuk hozzá megfelelő számú nullát, amellyel valószínűsége 0!

Példák:

$X$	valószínűsége	előjele
1	0,25	01
2	0,25	10
3	0,2	11
4	0,15	000
5	0,15	001

$$H(X) = 2,29$$

$$L = 2,13$$



2)

X	valószínűség		érdem
1	0,25	0,5	1
2	0,25	0,25	2
3	0,2	0,25	0,0
4	0,15		0,1
5	0,15		0,2

$$H_3(X) = 1,44$$

$$L = 1,75$$

3)

X	valószínűség		érdem
1	0,25	0,25	1
2	0,25	0,25	2
3	0,2	0,2	0,1
4	0,1	0,2	0,2
5	0,1	0,1	0,0
6	0,1		0,0
újra	0		0,2

$$H_3(X) = 1,55$$

$$L = 1,7$$

Vegyük észre, hogy a Huffman-kód nem egyértelmű, még ismerték szintjei nem!

4)

X	valószínűség		érdem
1	1/3	2/3	1
2	1/3	1/3	0,0
3	1/4	1/5	0,1
4	1/12		0,1

1	1/3	1/3	2/3	0,0
2	1/3	1/3	1/3	1,0
3	1/4	1/3		0,1
4	1/12			1,1

$$L_1 = 2$$

$$L_2 = 2$$

$$H(X) = 1,86$$

A két kód még az átlagos hosszúság szintjei nem egyenlő, de a relatív entrópia és a kódhossz igen.

Lemma: Minden előzőleg étent <sup>optimális</sup> egy prefix kód a látszó tulajdonságokkal:

- 1) Ha  $p_j > p_k$  akkor  $e_j < e_k$ .
- 2) A két legrosszabb szó hosszú egyenlő.
- 3) A két legrosszabb szó csak az utolsó bitjében különbözik.

Biz: 1) Legyen  $C_m$  és  $C_n$  két kód, amikben a  $j$  és  $k$  szó fel nem cserélve!  
T.F.H  $L(C_m) \geq L(C_n)$ : Ekkor

$$0 \leq L(C_m) - L(C_n) = \sum_i p_i e_i - \sum_i p_i e_i = p_j e_k + p_k e_j - p_j e_j - p_k e_k = (p_j - p_k)(e_k - e_j).$$

Mivel  $p_j - p_k > 0 \Rightarrow e_k > e_j$ .

- 2) Ha a két legrosszabb szó hosszú nem egyenlő, akkor létezik a legrosszabb szó utolsó karakterét törölve is prefix kód marad.
- 3) Ha egy maximális hosszúságú szóval nem tartozik olyan, ami csak az utolsó karakterében különbözik, akkor létezik az utolsó karaktert törölve is prefix marad. □

Azaz kódot, amik teljesítik a lemma tulajdonságait könnyű kódokká kényszeríteni.

Tétel: A bináris Huffman-kód optimális.

Biz: Legyen  $p = (p_1, \dots, p_m)$  egy előzőleg, ahol  $p_1 \geq \dots \geq p_m$ , a Huffman-redukcióján pedig  $p' = (p_1, p_2, \dots, p_{m-1}, p_{m-1} + p_m)$ . Legyen  $C_{m-1}^*(p')$  egy optimális kód  $p'$ -re,  $C_m^*(p)$  pedig egy kanonikus kód  $p$ -re!

A  $C_{m-1}^*$  kódot kiegészítve  $p$ -re az alábbi módon: A  $p_1, \dots, p_{m-2}$  valószínűségekre tartozó kódoknál egyenlő n.a., a  $p_{m-1} + p_m$ -hoz tartozó szó végén pedig egy 0-t és egy 1-t tételek segítségével hozzá  $p_{m-1}$ -hez és  $p_m$ -hez.

Ekkor a valódi kódossá:  $L(p) = L^*(p') + p_{m-1} + p_m$ .

Mivel  $C_m^*$  kanonikus konstruálható belőle egy kód  $p'$ -re, egyenlően nagy, vagy  $p_{m-1}$  és  $p_m$ -hoz tartozó marad utolsó karakterét elhagyva. Erre a kódossá:

$$L(p') = L^*(p) - p_{m-1} - p_m.$$

A kettőt összeadva:  $L(p') + L(p) = L^*(p') + L^*(p) \Rightarrow (L(p) - L^*(p)) + (L(p') - L^*(p')) = 0.$

Mindkét tag nem negatív  $\Rightarrow L(p) - L^*(p) = 0.$

Ha  $m-1$ -re a Huffman kód optimális, akkor  $m$ -re is, mivel teljes indukcióval.

□



# BEV INF ELM

6. előadás (03.19.)


## Shannon - Fano - Elias - kódolás

Látnuk, hogy a Huffman-kód optimális, de a valószínűségi részt kell mindenkorra a kódolási nyelven. A SFE-kód nem lesz optimális, de a kódolás és az arithmetikai számolás közötti különbség meggyőző.

Legyen a kódolási alfabet:  $X = \{1, 2, \dots, m\}$  adott sorrendben, és a hozzájuk tartozó valószínűségeik:  $p(x) > 0 \forall x$ -re. A kumulatív eloszlás fvk:

$$F(x) = \sum_{a \in X} p(a).$$

A módosított kumulatív eloszlás fvk.:  $\bar{F}(x) = \sum_{a \in X} p(a) + \frac{1}{2} p(x).$



Mivel a valószínűsége pozitívak, ezért  $a \neq b \Leftrightarrow \bar{F}(a) \neq \bar{F}(b)$ ; tehát  $\bar{F}(x)$ -vel lehet kódolni  $x$ -t. A gond, hogy  $\bar{F}(x)$  nem szám, vagyis végtelen bitű.

Ötlet: Látnuk, hogy az  $e(x) = \lceil \log_2 \frac{1}{p(x)} \rceil$  kódolásuk kielégítik a kvant - egyenlőség, ezért válasszuk  $e(x)$ -t  $\bar{F}(x)$ -t  $e(x)$  bitre és kódoljuk az  $x$ -t! Jelöljük ezt  $\lfloor \bar{F}(x) \rfloor_{e(x)}$

Tétel:  $F(x)$  közelése a két lépésű közelítés, vagyis  $F(x-1) < \lfloor \bar{F}(x) \rfloor_{e(x)} < F(x)$

Biz: A második rész triviális, hiszen  $\lfloor \bar{F}(x) \rfloor_{e(x)} \leq \bar{F}(x).$

Az első rész:  $\bar{F}(x) - \lfloor \bar{F}(x) \rfloor_{e(x)} < 2^{-e(x)}$  (bináris nemzérben).

Mivel  $e(x) = \lceil \log_2 \frac{1}{p(x)} \rceil + 1$ , ezért

$$2^{-e(x)} < \frac{p(x)}{2} = F(x) - F(x-1).$$

A kettőt együtt:  $\bar{F}(x) - \lfloor \bar{F}(x) \rfloor_{e(x)} < \bar{F}(x) - F(x-1) \Rightarrow F(x-1) < \lfloor \bar{F}(x) \rfloor_{e(x)}$   $\square$

Tétel: A SFE-kód prefix-kód.

Biz: Ennek bizonyításához rendelkezünk hozzá a  $z_1 z_2 \dots z_n$  kódzóhoz a  $[0, z_1 z_2 \dots z_n, 0, z_1 z_2 \dots z_n + \frac{1}{2^n}]$  intervallumot és látnuk be, hogy vel diszjunktak!

Mivel  $\frac{1}{2^{n+1}} < \frac{p(x)}{2}$  ezért az  $\frac{1}{2^n}$  rövidebb, mint a lépés felé,

tehát  $L\bar{F}(x)|_{e(x)}$ -ben továbbra van éni el a következő lépését, így van még hely a következő intervallumok.  $\square$

Példán:


x	p(x)	F(x)	$\bar{F}(x)$	binárium	e(x)	kódszó
1	0,25	0,25	0,125	0,001	3	001
2	0,25	0,5	0,575	0,011	3	011
3	0,12	0,7	0,6	0,10011	4	1001
4	0,15	0,85	0,775	0,1100011	4	1100
5	0,15	1,0	0,925	0,1110110	4	1110

$$L = 3,5 \quad H(X) = 2,29$$

Abban korábban is láttuk, az átlagos kódhossz nem optimális, de igaz rá, hogy  $L < H(X) + 2$

### Satornakapacitás

Alkommunikáció elja,



hogy üzenetet küldjünk, és a

kapadónál fel úgy vagy valószínűségeket nyújtunk ki. A kommunikációs rendszer működés képe az ábrán, ezt szeretnénk matematikailag leírni.

Def: Egy diszkrét csatornánál vezetett rendszer tartalmaz egy X kimeneti ábrát, egy Y kimeneti ábrát és egy  $p(y|x)$  átviteli valószínűségi függvényt, ami megadja, hogy x elküldött jel esetén mekkora valószínűséggel kapunk y-t.

A csatorna memória mentes, ha  $p(y|x)$  nem függ az előző kimenetektől.

Def: Egy diszkrét memóriamentes csatorna információs satornakapacitása  $C := \max_{p(x)} I(X; Y)$  ahol  $p(x)$  a lehetséges bemeneti eloszlások.

[Példák]



Def: Egy csatorna szimmetrikus, ha az átmeneti mátrix sorai permutációi egymáshoz, és úgy vannak az oszlopok.

$$\text{pl.: } p(y|x) = \begin{pmatrix} 0,5 & 0,2 & 0,3 \\ 0,5 & 0,5 & 0,2 \\ 0,2 & 0,3 & 0,5 \end{pmatrix} \quad (p(y|x) \text{ az } x\text{-ik sor, } y\text{-ik oszlop)}$$

Tétel: Szimmetrikus csatorna információs csatornahatásain  $C = \log |Y| - H(X)$ , ahol  $X$  az átmeneti mátrix egyik sora.

$$\text{Biz: } I(X;Y) = H(Y) - H(Y|X) = \text{mivel a sorokhoz a valószínűségek összege}$$

$$= H(Y) - H(X) \leq \log |Y| - H(X)$$

ahol egyenlőség akkor van, ha  $Y$  egyenletes. Ez teljesül egyenletes  $X$  esetén hiszen

$$p(y) = \sum_{x \in X} p(y|x) p(x) = \frac{1}{|X|} \sum_{x \in X} p(y|x) = c \frac{1}{|X|} = \frac{1}{|Y|}$$

ahol  $c$  az oszlopok összege (ami fix). □

A fenti példa esetén  $C = \log 3 - H(0,5; 0,3; 0,2) = 0,0995$

Def: Egy csatorna egyszerűen szimmetrikus, ha az átmeneti mátrix sorai permutációi egymáshoz, és az oszlopok összege fix.

$$\text{pl.: } p(y|x) = \begin{pmatrix} \frac{1}{3} & \frac{1}{6} & \frac{1}{2} \\ \frac{1}{3} & \frac{1}{2} & \frac{1}{6} \end{pmatrix}$$

Az előző tétel erre is igaz.

Tétel: Az információs csatornahatásról az alábbiakat teljesíti:

(i)  $C \geq 0$  [Mivel  $I(X;Y) \geq 0$ ]

(ii)  $C \leq \log |X|$  [hiszen  $C = \max I(X;Y) \leq \max H(X) = \log |X|$ ]

(iii)  $C \leq \log |Y|$  [szimmetriát]

(iv) Mivel  $I(X;Y)$  folytonos konvex  $\log$ -a  $p(x)$ -nek, ezért a lokális maximum globális maximum is. Tavaszi (ii) és (iii) miatt ez rögzített érték, amit  $I(X;Y)$  felis vesz, tehát  $C$  értéke a valószínűségi optimalizálási eljárásból (pl.: gradiens módszer) meghatározható.

Azt szeretnénk bizonyítani, hogy  $C$  az a szám, amely "külsőleg" a valószínűségi ismeretét kihasználva lehet elérni, előtte azonban ezt formalizálni kell néhány definícióval.

Def: Az  $(X, p(y|x), Y)$  diszkrét csatorna  $n$ -ik iterációjára a  $(X^n, p(y^n|x^n), Y)$  által  

$$p(y_k|x^k, y^{k-1}) = p(y_k|x_k) \quad \forall k=1, 2, \dots, n$$

megjegyzés: Ha a csatorna visszacsatolás és általában illyenket vizsgál,  
 akkor 
$$p(y^n|x^n) = \prod_{i=1}^n p(y_i|x_i)$$

Def: Az  $(X, p(y|x), Y)$  csatorna  $(M, n)$  kódoló az alábbiakból áll:

1. Egy bevetési index-halmaz:  $\{1, 2, \dots, M\}$  (elbővezzük  $\mathcal{W}$ -t)
2. Egy kódolási fu:  $x^n: \{1, 2, \dots, M\} \rightarrow X^n$  "kódoló"
3. Egy dekódolási fu:  $g: Y^n \rightarrow \{1, 2, \dots, M\}$ .

Def: Adott  $i$  indexen tartozó feltételes hiba valószínűség alatt az alábbi értjük:

$$\lambda_i = \Pr(g(Y^n) \neq i \mid X^n = x^n(i))$$

Def: Az  $(M, n)$  kódoló tartozó maximális hiba valószínűség:  $\lambda^{(n)} = \max_i \lambda_i$

Def: Az  $(M, n)$  kódoló tartozó átlagos hiba valószínűség  $P_e^{(n)} = \frac{1}{M} \sum_{i=1}^M \lambda_i$

Def: Az  $(M, n)$  kód ráteje  $R = \frac{\log M}{n}$  bit/sec átvitel.

Def: Az  $R$  rátejt elérhetőnek nevezünk, ha létezik olyan kód  $(2^{nR}, n)$  kóddal,  
 hogy  $\lambda^{(n)} \rightarrow 0$  ha  $n \rightarrow \infty$ .

Def: Egy csatorna kapacitása az elérhető rátej supremuma.

A csatorna kapacitás tételével kelátjuk, hogy az meggyőző az információ kapacitása



# BEVINF ELM

7. előadás (03.26.)

Def: Az  $A_\epsilon^{(n)}$  az együttes típusú nehézségi balhalmaz, elemei olyan  $\{(x^n, y^n)\}$  nehézségi párok, amelyek külön-külön és együttes is tipikusak, azaz

$$A_\epsilon^{(n)} = \left\{ (x^n, y^n) \in X^n \times Y^n : \begin{aligned} & \left| -\frac{1}{n} \log p(x^n) - H(X) \right| < \epsilon \text{ és} \\ & \left| -\frac{1}{n} \log p(y^n) - H(Y) \right| < \epsilon \text{ és} \\ & \left| -\frac{1}{n} \log p(x^n, y^n) - H(X, Y) \right| < \epsilon \end{aligned} \right\}$$

Tétel (együttes AEP): Legyen  $(x^n, y^n)$  n db i.i.d.-lél álló páros nehézségi páros, azaz

$$p(x^n, y^n) = \prod_{i=1}^n p(x_i, y_i). \text{ Ekkor teljesülnek a következők:}$$

1.  $\Pr\{(x^n, y^n) \in A_\epsilon^{(n)}\} \rightarrow 1$  ha  $n \rightarrow \infty$

2.  $|A_\epsilon^{(n)}| \leq 2^{n(H(X, Y) + \epsilon)}$

3. Ha  $(\tilde{x}^n, \tilde{y}^n) \sim p(x^n)p(y^n)$  (azaz, ha  $\tilde{x}^n$  és  $\tilde{y}^n$  függetlenek)

$$\Pr\{(\tilde{x}^n, \tilde{y}^n) \in A_\epsilon^{(n)}\} \leq 2^{-n(I(X; Y) - 3\epsilon)}$$

$$\Pr\{(\tilde{x}^n, \tilde{y}^n) \in A_\epsilon^{(n)}\} \geq (1 - \epsilon) 2^{-n(I(X; Y) + 5\epsilon)} \text{ elég nagy } n\text{-re.}$$

Biz: 1. A nagy számok törvénye miatt elég nagy n-re külön-külön teljesülnek a következők:

$$\Pr\left\{ \left| -\frac{1}{n} \log p(x^n) - H(X) \right| \geq \epsilon \right\} < \frac{\epsilon}{3}$$

$$\Pr\left\{ \left| -\frac{1}{n} \log p(y^n) - H(Y) \right| \geq \epsilon \right\} < \frac{\epsilon}{3}$$

$$\Pr\left\{ \left| -\frac{1}{n} \log p(x^n, y^n) - H(X, Y) \right| \geq \epsilon \right\} < \frac{\epsilon}{3}$$

Válasszuk olyan nagy n-et, hogy mind teljesüljen, illetve a, hogy az unió teljesüljön  $< \epsilon$  valószínűséggel.

2.  $1 = \sum_{(x^n, y^n)} p(x^n, y^n) \geq \sum_{A_\epsilon^{(n)}} p(x^n, y^n) \geq |A_\epsilon^{(n)}| \cdot 2^{-n(H(X, Y) + \epsilon)}$

$$\Rightarrow |A_\epsilon^{(n)}| \leq 2^{n(H(X, Y) + \epsilon)}$$

3.  $\Pr\{(\tilde{x}^n, \tilde{y}^n) \in A_\epsilon^{(n)}\} = \sum_{(x^n, y^n) \in A_\epsilon^{(n)}} p(x^n) p(y^n) \leq 2^{n(H(X, Y) + \epsilon)} \cdot 2^{-n(H(X) - \epsilon)} \cdot 2^{-n(H(Y) - \epsilon)} = 2^{-n(I(X; Y) - 3\epsilon)}$

Mivel egy vagyis  $n$ -re:  $P(A_\epsilon^{(n)}) \geq 1 - \epsilon$ , azaz

$$1 - \epsilon \leq \sum_{(x^n, y^n) \in A_\epsilon^{(n)}} p(x^n, y^n) \leq |A_\epsilon^{(n)}| 2^{-n(H(x, y) - \epsilon)}$$

$$\Rightarrow |A_\epsilon^{(n)}| \geq (1 - \epsilon) 2^{n(H(x, y) - \epsilon)}$$

$$\begin{aligned} \text{Ehhez: } P_n \{(X^n, Y^n) \in A_\epsilon^{(n)}\} &= \sum_{A_\epsilon^{(n)}} p(x^n) p(y^n) \geq \\ &\geq (1 - \epsilon) 2^{n(H(x, y) - \epsilon)} \cdot 2^{-n(H(x) + \epsilon)} \cdot 2^{-n(H(y) + \epsilon)} = \\ &= (1 - \epsilon) \cdot 2^{-n(I(x, y) + 5\epsilon)} \end{aligned}$$

□

Tétel (Crotson kódolás tétele):

Egy díjhat nemorientált, crotsonra minden  $C$ -nél kisebb ráta elérhető. Azaz, minden  $R < C$  esetén létezik egy  $(2^{nR}, n)$  kódskéma, amely függ, hogy a maximális hiba  $d^{(n)} \rightarrow 0$ .

Megfordítás: Minden  $(2^{nR}, n)$  kódskémára, amely  $d^{(n)} \rightarrow 0$  a ráta  $R \leq C$ .

Biz: Adjuk egy konstrukciót, ami  $H$ -re generál egy megfelelő kódot!

Igen van egy adott  $p(x)$  eloszlásuk egyenértékű  $2^{nR}$  darab kódot az előző eloszlással:  $p(x^n) = \prod_{i=1}^n p(x_i)$ . A kódot a  $C$  vektorként reprezentálhatjuk, amelyen a sorok a kódsorok:

$$C = \begin{pmatrix} x_1(1) & x_2(1) & \dots & x_n(1) \\ \vdots & \vdots & \ddots & \vdots \\ x_1(2^{nR}) & x_2(2^{nR}) & \dots & x_n(2^{nR}) \end{pmatrix}$$

Adott  $C$  generálásának a valószínűsége:  $P_n(C) = \prod_{w=1}^{2^{nR}} \prod_{i=1}^n p(x_i(w))$

TFH az üzenet egyenértékű eloszlású, tehát  $P_n(W=w) = 2^{-nR}$  és a kódolás során a  $w$ -ik üzenetben a  $w$ -ik sor tartozik! A dekódolás az

alábbi szerint dolgozik:

- $\hat{W}$ -t ad vissza, ha  $(x^n(\hat{W}), y^n)$  tipikus, és nincs más  $W' \neq \hat{W}$ , amire  $(x^n(W'), y^n)$  tipikus lenne.
- Jeleket dob, ha nincs megfelelő  $\hat{W}$  vagy ha több is van.

Lássuk be, hogy a tévedés valószínűsége  $\rightarrow 0$ !



A tévedéssorozat:  $\mathcal{E} = \{\hat{W}(Y^n) \neq W\}$ . Ennek valószínűsége:

$$\begin{aligned} P_r(\mathcal{E}) &= \sum_c P_r(c) P_2^{(n)}(c) = \sum_c P_r(c) \frac{1}{2^{nr}} \sum_{w=1}^{2^{nr}} \mathbb{1}_w(c) = \\ &= \frac{1}{2^{nr}} \sum_{w=1}^{2^{nr}} \sum_c P_r(c) \mathbb{1}_w(c) = \end{aligned}$$

miel  $c$  konstrukciójai szimmetrikusak  $W=1$ , ezért az eredmény  $w$ -től függően. T.F.H  $w=1$ , és másképp null:  $= \sum_c P_r(c) \mathbb{1}_1(c) = P(\mathcal{E} | W=1)$

Tekintsük az alábbi eseményt:  $E_i = \{(X^n(i), Y^n) \in A_\epsilon^{(n)}\}$   $i \in \{1, \dots, 2^{nr}\}$ !

Tévedés két oldal eset: • a  $(X^n(1), Y^n)$  nem tipikus, azaz  $E_1^c$  teljesül

• más  $(X^n(i), Y^n)$  is tipikus  $i \neq 1$ -re, azaz  $E_2 \cup E_3 \cup \dots \cup E_{2^{nr}}$  teljesül.

Ebből:

$$\begin{aligned} P_r(\mathcal{E} | W=1) &= P(E_1^c \cup E_2 \cup E_3 \cup \dots \cup E_{2^{nr}} | W=1) \leq \\ &\leq P(E_1^c | W=1) + \sum_{i=2}^{2^{nr}} P(E_i | W=1). \end{aligned}$$

AEP miatt  $P(E_1^c | W=1) \leq \epsilon$  és  $P(E_i | W=1) \leq 2^{-n(I(X;Y) - 3\epsilon)}$  elég nagy  $n$ -re.

$$\begin{aligned} P(\mathcal{E} | W=1) &\leq \epsilon + \sum_{i=2}^{2^{nr}} 2^{-n(I(X;Y) - 3\epsilon)} = \text{összevontás hasonlója miatt} \\ &= \epsilon + (2^{nr} - 1) \cdot 2^{-n(I(X;Y) - 3\epsilon)} \leq \\ &\leq \epsilon + 2^{nr} \cdot 2^{-n(I(X;Y) - 2\epsilon)} \quad \text{ha } R < I(X;Y) \text{ akkor} \\ &\quad \text{megfelelő } \epsilon \text{ és } n \text{-re} \\ &\leq 2\epsilon. \end{aligned}$$

Korlát elosztásuk: 1.  $p(x)$  éppen az, amivel a  $I(X;Y)$  maximális, így a bizonyítás minden  $R < C$ -re működik lesz.

2.  $P(\mathcal{E} | W=1) \leq 2\epsilon$  az atlag  $C$  közele íjén, de ha azt választjuk amire a hiba a legkisebb, amél  $2\epsilon$ -nél kisebb lehet, -lehet látni egy konkrét kód.

3. Mivel  $W$  egyenletes, ezért  $P(\mathcal{E} | W=1) = \frac{1}{2^{nr}} \sum_{i=1}^{2^{nr}} \lambda_i(C^*) \leq 2\epsilon$ , tehát a számok legalább felére  $\lambda_i \leq 4\epsilon$ . Eldobva a másik felét, a maximális hiba is korlátotlan  $\rightarrow 0$ -ra. Vagyis a maradék száma így  $2^{nr} - 1$  és a végső  $R \rightarrow R - \frac{1}{n}$  de nagy  $n$ -re az  $n$ -a. □

A megfordítás bizonyításához kell ezt lemma:

Lemma: Egy direkt névleges mátrix csatorna bármely állapotú elvételénél  $W$  iránt esetén teljesül a

$$H(W|\hat{W}) \leq 1 + P_e^{(n)} n R$$

Biz: A Fano-egyenlőtlenség

$$1 + P_e \log |W| \geq H(W|\hat{W}) \quad \text{ha } |W| = 2^{nR} \text{ éppen az kapjuk. } \square$$

Lemma: Legyen  $Y^n$  egy  $X^n$  kanalet eredményező egy  $C$  kapacitású csatorna! Ekkor

$$I(X^n, Y^n) \leq nC \quad \text{minden } P(X^n)\text{-re.}$$

Biz:

$$\begin{aligned} I(X^n, Y^n) &= H(Y^n) - H(Y^n|X^n) = H(Y^n) - \sum_{i=1}^n H(Y_i | Y_1, \dots, Y_{i-1}, X^n) = \text{marginálisok miatt} \\ &= H(Y^n) - \sum_{i=1}^n H(Y_i | X_i) \leq \sum_{i=1}^n H(Y_i) - \sum_{i=1}^n H(X_i | X_i) = \sum_{i=1}^n I(X_i, Y_i) \leq nC \end{aligned}$$

Csatorna kódolási tétel megfordításának bizonyítása:

Van egy  $(2^{nR}, n)$  kódunk  $d^{(n)} \rightarrow 0$ -vel, természetesen, ha  $R \leq C$ !

Adott kódolás és dekódolás fu esetén  $W \rightarrow X^n(W) \rightarrow Y^n \rightarrow \hat{W}$  egy

Markov-lánc, ezért alkalmazható a Fano-egyenlőtlenség. Ha  $W$  elvételű állapotú, akkor

$$nR = H(W) = H(W|\hat{W}) + I(W; \hat{W}) \leq \text{Lemma miatt}$$


$$\leq 1 + P_e^{(n)} nR + I(W; \hat{W}) \leq \text{adatfelbontási egyenlőség miatt}$$

$$\leq 1 + P_e^{(n)} nR + I(X^n, Y^n) \leq \text{Lemma miatt}$$

$$\leq 1 + P_e^{(n)} nR + nC.$$

$$\text{Ezzel } n\text{-vel: } R \leq \frac{1}{n} + P_e^{(n)} R + C \quad n \rightarrow \infty \text{ esetén: } R \leq C. \quad \square$$

Azt gondolhatnánk, hogy ez eléggé egyszerűen értelmezhető a kapacitás:



Itt az  $Y_i$  iránt hiba nélkül ismerjük a kódolást.

és az  $i$ -ik kódolás az összes előbbi  $Y_i$ -től függ.

A valóságban azonban ez nem lesz így, csak a dekódolás egyensúlyát használjuk.



Def: A visszajelzési kapacitás egy diszkrét neuronia mentes csatornában visszajelzéses kódalakkal elérhető maximális átlagos sebesség. Jelölés:  $C_{FB}$ .

Tétel:  $C_{FB} = C = \max_{P(x)} I(X; Y)$

Biz: A csatorna kódalási tétel megfogalmazásából következik, hogy itt nem teljesül, mert  $H(Y_i | Y_1, \dots, Y_{i-1}, X) \neq H(Y_i | X_i)$ , ezért most kell felhasználni.

Mivel a visszajelzés nélküli kód a visszajelzéses kód spec. esete, ezért  $C_{FB} \geq C$ . A másik irányhoz az alábbi kell:

Egyszerűsítés  $W$  esetén  $nR = H(W) = H(W|\hat{W}) + I(W; \hat{W}) \leq$  Fano miatt  
 $\leq 1 + P_e^{(n)} nR + I(W; \hat{W}) \leq$  adatközlési egytl., miatt  
 $\leq 1 + P_e^{(n)} nR + I(W; Y^n)$ .

Ebben az információ:

$$I(W; Y^n) = H(Y^n) - H(Y^n | W) = H(Y^n) - \sum_{i=1}^n H(Y_i | Y_1, \dots, Y_{i-1}, W) =$$

miel  $X_i$  az  $Y_i$ -k  $\hat{W}$  függ, ezért a feltétel nem számít  
 $= H(Y^n) - \sum_{i=1}^n H(Y_i | Y_1, \dots, Y_{i-1}, W, X_i) =$

miel  $Y_i$  csak  $X_i$ -től függ  
 $= H(Y^n) - \sum_{i=1}^n H(Y_i | X_i) \leq \sum_{i=1}^n H(Y_i) - \sum_{i=1}^n H(X_i | X_i) = \sum_{i=1}^n I(X_i; Y_i) \leq$   
 $\leq nC$

Visszatérve:  $nR \leq 1 + P_e^{(n)} nR + nC$  Ezzel  $n$ -vel  $\div$   $n \rightarrow \infty$ -ben  
 $R \leq C \Rightarrow C_{FB} \leq C$  □

## Hamming - kód

A kódek kódolási tétel csak azt mondja ki, hogy minden  $B \subset C$  esetében létezik olyan kód, ami tetszőlegesen kis hibákkal továbbítható, de egy bizonyos hibakorlátot mindig követve továbbítható.

A hiba kioldásának legegyszerűbb módja a redundancia növelése, azaz felesleges bitok beiktatása. Pl.: 0 helyett küldjük a 00000 üzenetet, így ha abból néhány el is romlik, még az üzenet kitalálható.

paritáslít: A kódolás végén egy plusz 1, ha a kódoló paritásos 0, ha a kódoló páros. Errel óvatosabb, ha paritásos de hiba történik.

Még jobb megoldás, ha a kódok több redundancia után is adnak paritáslítet.

A Hamming - kód one egy példa.

Indukció: Írjuk le az összes lehetséges 3 hosszú üzeneteket sorrendben:

$$H = \begin{pmatrix} 0 & 0 & 0 & 1 & 1 & 1 & 1 \\ 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ 1 & 0 & 1 & 0 & 1 & 0 & 1 \end{pmatrix}$$

Ennek a rangja 3, ezért lineárisan mint a magterve  $7-3=4$  dimenz. A kódolás legegyszerűbb módon azaz, amik  $H$ -val megszorozva  $(000)$ -t adnak! Errel:

0000000	0100101	1000011	1100110
0001111	0101010	1001100	1101001
0010110	0110011	1010101	1110000
0011001	0111100	1011010	1111111

Ér  $2^4 = 16$  db kódoló, amit mivel rang  $H=3$  legalább 3 db 1-et tartalmaznak (A 0-n kívül). Mivel csak egy 4 dimenz alternat lehet, ezért bármely kettő legalább 3 bitben különbözik  $\Rightarrow$  ha az egyik bit nem, még mindig kitalálható, hogy melyik kódoló az tartózik. Hogyan?

Legyen  $\underline{c}$  egy kódoló,  $\underline{e}_i$  pedig az a vektor, amelynek az  $i$ -ik bitje 1, a többi 0! Ha  $\underline{c}$ -ben az  $i$ -ik bitje változott, akkor  $\underline{r} = \underline{c} + \underline{e}_i \pmod{2}$  kapjuk. Megszorozva  $H$ -val:

$$H\underline{r} = H(\underline{c} + \underline{e}_i) = H\underline{c} + H\underline{e}_i = H\underline{e}_i \quad \text{ami a } H \text{ } i\text{-ik sorosa.}$$

$\Rightarrow$  Minden lehetséges  $\underline{r}$ -hoz megtalálható a hozzá felelő kódoló.



Gondoljuk át a Hamming kódra az alábbi módon is:

16 kódoló van, ami  $2^4$ , tehát elég lenne 4 bit is, de mi bevettük 3 ellenőrző bitet. Vegyük össze, hogy a kódzóknak első 4 karaktere egyedi, vagyis van az információs bitok, a másik 3 pedig 3 bit-os paritásbitjei.

pl.: 
$$\begin{array}{cccc|cc} 0 & 1 & 1 & 0 & 0 & 1 & 1 \\ \hline & & & & & & \\ \hline & & & & & & \end{array}$$

Általános Hamming kód esetén:

Ha  $H$ -ben  $e$  sor van, a blokkméret  $n = 2^e - 1$ , az információs bitok száma pedig  $k = 2^e - e - 1$ . A minimális túlsúly  $s$  ellenőrző bitjei legyen mindig páratlan számú kódszót felbontalunk.

# BEV. INF. ELM.

8. előadás (04.09.)

## Differenciális entropia

Def: Ha az  $X$  valószínűségi változóhoz tartozó  $F(x) = \Pr(X \leq x)$  kumulatív eloszlásfüggvény folytonos, akkor az  $X$  változót folytonosnak nevezünk.

$f(x) = F'(x)$  függvényt hívjuk a változó valószínűségi sűrűségfüggvénynek, a  $S = \{x \in X \mid f(x) > 0\}$  pedig az átélőterete.

Def: Egy  $f$  sűrűségfüggvényre adott valószínűségi változó differenciális entropiája az alábbi:

$$h(X) = - \int_S f(x) \log f(x) dx$$

(Mivel  $h$  csak  $f$ -től függ, ezért a jelölés néha  $h(f)$ .)

Példák: 1) egyenletes eloszlás.

A  $[c, a]$  intervallumon egyenletes eloszlás sűrűségfüggvénye:  $f(x) = \frac{1}{a}$

$$h(X) = - \int_0^a \frac{1}{a} \log \frac{1}{a} dx = \log a$$

VÉLT  $a < 1 \Rightarrow h(X) < 0$ , tehát a diff. entropia lehet negatív.

2) Normál eloszlás. (itt érdemes nat-log-ra váltani)

$$\text{A sűrűségfüggvény: } \phi = \frac{1}{\sqrt{2\pi}\sigma} e^{-x^2/2\sigma^2}$$

$$\begin{aligned} h(\phi) &= - \int_{-\infty}^{\infty} \phi(x) \left[ -\frac{x^2}{2\sigma^2} - \ln \sqrt{2\pi}\sigma \right] = E_X \left( \frac{x^2}{2\sigma^2} \right) + \frac{1}{2} \ln(2\pi\sigma^2) = \\ &= \frac{1}{2} + \frac{1}{2} \ln(2\pi\sigma^2) = \frac{1}{2} \ln(2\pi e\sigma^2) \end{aligned}$$

A diszkrét esetben hasonlóan itt is bevezethető az AEP tulajdonság.

Tétel: Legyen  $X_1, \dots, X_n$  néhány független i.i.d. változó realizációján azonos  $f$  sűrűséggel! Ekkor

$$-\frac{1}{n} \log f(X_1, \dots, X_n) \rightarrow E(-\log f(X)) = h(X)$$

Biz: Törni a nagy számok törvényével.



Def: Adott  $\epsilon$  és  $n$  értékeire az  $A_\epsilon^{(n)}$  típusú balról az  $f$  számosságára:

$$A_\epsilon^{(n)} = \left\{ (x_1, \dots, x_n) \in S^n : \left| -\frac{1}{n} \log f(x_1, \dots, x_n) - h(X) \right| \leq \epsilon \right\}$$

$$\text{ahol } f(x_1, x_2, \dots, x_n) = \prod_{i=1}^n f(x_i)$$

Def: Egy  $A \subset \mathbb{R}^n$  balról térfogata

$$\text{Vol}(A) = \int_A dx_1 \dots dx_n$$

Tétel: Az  $A_\epsilon^{(n)}$ -re teljesülnek a alábbiak:

1.  $\text{Pr}(A_\epsilon^{(n)}) > 1 - \epsilon$  elég nagy  $n$ -re.
2.  $\text{Vol}(A_\epsilon^{(n)}) \leq 2^{n(h(X) + \epsilon)}$  minden  $n$ -re.
3.  $\text{Vol}(A_\epsilon^{(n)}) \geq (1 - \epsilon) 2^{n(h(X) - \epsilon)}$  elég nagy  $n$ -re.

Biz: 1. Az előző tétellel kiethetjük, hogy a def-ben lévő  $1 \rightarrow 0$ , így a valószínűség  $\rightarrow 1$ .

$$\begin{aligned} 2. \quad 1 &= \int_{S^n} f(x_1, \dots, x_n) dx_1 \dots dx_n \geq \int_{A_\epsilon^{(n)}} f(x_1, \dots, x_n) dx_1 \dots dx_n \geq \\ &\geq \int_{A_\epsilon^{(n)}} 2^{-n(h(X) + \epsilon)} dx_1 \dots dx_n = 2^{-n(h(X) + \epsilon)} \int_{A_\epsilon^{(n)}} dx_1 \dots dx_n = \\ &= 2^{-n(h(X) + \epsilon)} \text{Vol}(A_\epsilon^{(n)}) \Rightarrow \text{Vol}(A_\epsilon^{(n)}) \leq 2^{n(h(X) + \epsilon)} \end{aligned}$$

3. Az 1. teljesül, ahon

$$\begin{aligned} 1 - \epsilon &\leq \int_{A_\epsilon^{(n)}} f(x_1, \dots, x_n) dx_1 \dots dx_n \leq \int_{A_\epsilon^{(n)}} 2^{-n(h(X) - \epsilon)} dx_1 \dots dx_n = \\ &= 2^{-n(h(X) - \epsilon)} \int_{A_\epsilon^{(n)}} dx_1 \dots dx_n = 2^{-n(h(X) - \epsilon)} \text{Vol}(A_\epsilon^{(n)}) \end{aligned}$$

□

Tétel:  $A_\epsilon^{(n)}$  a legkisebb térfogatú balról, amely  $1 - \epsilon$ -nél nagyobb valószínűséggel tartul elő.

Biz: n.a. mint dőhet sebban.

Nézzük milyen viszonyban áll  $n$   $H$ -hoz, ha diszkrétizáljuk a folytonos változót! Jelöljük  $X$  értékmérés-tartományát  $\Delta$  hosszú intervallumra, ahon az átlagérték tétel alapján  $f(x_i) \Delta = \int_{i\Delta}^{(i+1)\Delta} f(x) dx$ .

És alapján definícióit az alábbi diszkrét valószínűségi változó:

$$X^{\Delta} = x_i \quad \text{ha} \quad i\Delta \leq X \leq (i+1)\Delta$$

$$p_i = f(x_i) \Delta \quad \Rightarrow \quad \sum_i p_i = 1$$

Tétel: Ha az  $f$  sűrűségfüggvény Riemann-integrálható, akkor

$$H(X^\Delta) + \log \Delta \rightarrow h(X) \quad \text{amikor } \Delta \rightarrow 0.$$

Biz:

$$H(X^\Delta) = - \sum_{-\infty}^{\infty} p_i \log p_i = - \sum_{-\infty}^{\infty} f(x_i) \Delta \log (f(x_i) \Delta) =$$

$$= - \sum \Delta f(x_i) \log f(x_i) - \sum f(x_i) \Delta \log \Delta =$$

$$= - \underbrace{\sum \Delta f(x_i) \log f(x_i)}_{\Delta \rightarrow 0 \text{ esetén az def miatt}} - \log \Delta$$

$$\Delta \rightarrow 0 \text{ esetén az def miatt } = - \int f(x) \log f(x) dx = h(X) \quad \square$$

Következmény: Egy folytonos változó  $n$ -bit kvantálásának entropiáján

$$H(X^n) \approx h(X) + n.$$

Def: Az  $X_1, \dots, X_n$  változók együttes eloszlásának tartomány entropiája:

$$h(X_1, \dots, X_n) = - \int f(x^n) \log f(x^n) dx^n$$

Def: Ha az  $X, Y$  változók együttes sűrűségfüggvénye  $f(x, y)$ , a feltételes entropiáján:

$$h(X|Y) = - \int f(x, y) \log f(x|y) dx dy.$$

Mivel  $f(x|y) = f(x, y) / f(y)$ , ezért  $h(X|Y) = h(X, Y) - h(Y)$ .

Tétel: Ha  $X_1, \dots, X_n$  eloszlása egy többváltozós normál eloszlás  $\mu$  átlaggal és  $K$  kovarianciamátrixszal, akkor együttes entropiáján:

$$h(X_1, \dots, X_n) = h(W(\mu, K)) = \frac{1}{2} \log [(2\pi e)^n |K|]$$

$$\text{Biz: Mivel az együttes eloszlás sűrűségfüggvénye: } f(x) = \frac{e^{-\frac{1}{2}(x-\mu)^T K^{-1}(x-\mu)}}{(\sqrt{2\pi})^n |K|^{1/2}}$$

ezért

$$h(f) = - \int f(x) \left[ -\frac{1}{2}(x-\mu)^T K^{-1}(x-\mu) - \ln [(\sqrt{2\pi})^n |K|] \right] dx =$$

$$= \frac{1}{2} E_x \left[ \sum_{i,j} (x_i - \mu_i) (K^{-1})_{ij} (x_j - \mu_j) \right] + \ln [(\sqrt{2\pi})^n |K|] =$$

$$= \frac{1}{2} \sum_{i,j} E_x \left[ (x_i - \mu_i) (x_j - \mu_j) \right] (K^{-1})_{ij} + \ln [(\sqrt{2\pi})^n |K|] =$$

$$= \frac{1}{2} \sum_{i,j} K_{ij} \cdot (K^{-1})_{ij} + \ln [(\sqrt{2\pi})^n |K|] = \frac{1}{2} \sum_j I_{jj} + \ln [(\sqrt{2\pi})^n |K|] =$$

$$= \frac{n}{2} + \frac{1}{2} \ln (2\pi |K|) = \frac{1}{2} \ln (2\pi e |K|) \quad \square$$





Tétel: (i)  $h(x+c) = h(x)$  (ii)  $h(ax) = h(x) + \log a$

Biz: (i) trivi

(ii) Ha  $y = ax$ , akkor  $f_y(y) = \frac{1}{|a|} f_x\left(\frac{y}{a}\right)$ .

$$h(ax) = - \int f_y(y) \log f_y(y) dy = - \int \frac{1}{|a|} f_x\left(\frac{y}{a}\right) \log\left(\frac{1}{|a|} f_x\left(\frac{y}{a}\right)\right) dy =$$

$$= - \int f_x(x) \log f_x(x) dx + \log |a| = h(x) + \log |a| \quad \square$$

Következő: Vektormutáció:  $h(AX) = h(X) + \log |\det(A)|$

Tétel: Legyen  $X \in \mathbb{R}^n$ , 0 átlaggal és  $K = \mathbb{E}_X(XX^T)$  kovarianciamátrixmal!

akkor  $h(X) \leq \frac{1}{2} \log(2\pi e)^n |K|$ . Egyenlőség, ha  $X \sim \mathcal{N}(0, K)$ .

Biz: Legyen  $g(x)$  a sűrűségfüggvény! Feltétel miatt  $\int g(x) x_i x_j dx = K_{ij}$ .

Legyen  $\phi_K(x)$  a  $\mathcal{N}(0, K)$  sűrűségfüggvény-e! Ekkor

$$0 \leq D(g \| \phi_K) = \int g \log\left(\frac{g}{\phi_K}\right) = -h(g) - \int g \log \phi_K = \dots$$

$$\text{mivel } g \text{ és } \phi_K \text{ első két momentum megegyezik}$$

$$= -h(g) - \int \phi_K \log \phi_K = -h(g) + h(\phi_K) \quad \square$$

Tétel: Legyen  $X$  egy véletlen vektora  $h(X)$  entropiájával,  $\hat{x}$  pedig egy becslése!

A részletes kiterjedés mértékének értéke:

$$E(X - \hat{x})^2 \geq \frac{1}{2\pi e} e^{2h(X)}, \quad \text{Egyenlőség, ha } X \text{ Gauss-eloszlású.}$$

$$\text{Biz: } E(X - \hat{x})^2 \geq \min_{\hat{x}} E(X - \hat{x})^2 = E(X - E(X))^2 = \text{var}(X) \geq \frac{1}{2\pi e} e^{2h(X)}$$

ahol kihasználjuk, hogy adott varianciájú eloszlásuk közül a Gauss-eloszlás a legnagyobb entropiájú.

Következő: Ha van  $Y$  plusz információ, amivel függ  $X$ , akkor


$$E(X - \hat{x}(Y))^2 \geq \frac{1}{2\pi e} e^{2h(X|Y)}$$



Gauss-i csatorna

Def: Gauss-i csatorna egy olyan folytonos ábrékét továbbítja csatorna, ahol egy Gauss-eloszlású additív zaj adódik hozzá a jelehez.

Az  $i$ . időpillanatra:  $Y_i = X_i + Z_i$   
 ahol  $Z_i \sim \mathcal{N}(0, N)$




Mivel a bemenet és a kimenet végtelen bázisban, a kódközlési kódközlést tetszőlegesen messze választjuk egymástól, így a hiba 0-va valószínűsége, és a kapacitás végtelen.

Mivel  $\rightarrow$  általában valós vektorok modellezésére használjuk, mint például a mi milyen kötés az energiája.  $\rightarrow$  általában az alábbi hatvány-köztérrel kezelik:

$$\frac{1}{n} \sum_{i=1}^n x_i^2 \leq P$$

A leggyakoribb (receptíválás eset), ha egy hívás ábrékét abba továbbítjuk, és a kódközlés  $\pm\sqrt{P}$ . A dekódolásuk egyszerűen el kell dönteni, hogy  $Y_i$  pozitív vagy negatív. A hiba valószínűsége:

$$\begin{aligned} P_e &= \frac{1}{2} P(Y < 0 | X = \sqrt{P}) + \frac{1}{2} P(Y > 0 | X = -\sqrt{P}) = \\ &= \frac{1}{2} P(Z < -\sqrt{P} | X = \sqrt{P}) + \frac{1}{2} P(Z > \sqrt{P} | X = -\sqrt{P}) = P(Z > \sqrt{P}) = \\ &= 1 - \Phi(\sqrt{P/N}) \quad \text{ahol} \quad \Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-\frac{t^2}{2}} dt \end{aligned}$$



A korábban, diszkrét csatornákra adott definíciók és tételek itt is kimondhatók, de a kódközlésrel együtt kell bánni.

Def: Az információ kapacitás egy Gauss-i csatorna a  $P$  hatványfelvitellel:

$$C = \max_{E\{X^2\} \leq P} I(X; Y)$$

A kapacitás analízisán korábban láttuk, hiszen

$$I(X; Y) = h(Y) - h(Y|X) = h(Y) - h(X+Z|X) = h(Y) - h(Z|X) = \text{mivel } X \perp Z \text{ független}$$

$$= h(Y) - h(Z)$$

Mivel  $Z$  Gauss-eloszlású, ezért  $h(Z) = \frac{1}{2} \log(2\pi e N)$ .

$$\text{Továbbá } EY^2 = E(X+Z)^2 = \underbrace{EX^2}_{=P \text{ a csatolás miatt}} + 2 \underbrace{EXEZ}_{=0} + \underbrace{EZ^2}_{=N} = P + N$$

Erőlépcső tétel  $h(Y) \leq \frac{1}{2} \log(2\pi e(P+N))$ .

$$I(X; Y) = h(Y) - h(Z) \leq \frac{1}{2} \log(2\pi e(P+N)) - \frac{1}{2} \log(2\pi e N) = \frac{1}{2} \log\left(1 + \frac{P}{N}\right)$$

$$C = \max I(X; Y) = \frac{1}{2} \log\left(1 + \frac{P}{N}\right).$$

ezt alább látni fogjuk, ha  $X \sim \mathcal{N}(0, P)$

Def: Egy  $(M, n)$  kód egy Gaussi csatornában  $P$ -hatvány korláttal az alábbiakból áll:

1. Index halmaz  $\{1, \dots, M\}$
2. Kódolás  $f$ , amely eljuttatja a kódot:  $x: \{1, \dots, M\} \rightarrow \mathcal{X}^n$   
 egy, leegyházt  $\frac{1}{n} \sum_{i=1}^n x_i^2(w) \leq P \quad \forall w \text{-re.}$
3. Dekódolás függvény:  $g: \mathcal{Y}^n \rightarrow \{1, \dots, M\}$ .

Def: Egy  $P$  határ elvétele egy  $P$ -hatvány korláttal Gaussi csatornában, ha létezik egy  $(2^{nP}, n)$  kód, aminek a kódcsúcsi teljesíti a kódot és a maximális hiba valószínűsége tart a  $C$ -ben.

Def: A csatorna kapacitás az elvétele határ maximuma.

Tétel: Egy  $P$ -hatvány korláttal Gaussi csatornában csatorna kapacitása  $C = \frac{1}{2} \log\left(1 + \frac{P}{N}\right)$ .

Skálázás: Egy  $n$  hosszú kód esetén a hiba valószínűsége  $nN$ , vagyis az  $\mathcal{Y}^n$ -térben a kódotól távolabb körülbelül  $\sqrt{nN}$  sugarú gömbök körül lesz a távolítottak nagy valószínűséggel.

Mivel az  $\mathcal{Y}$  valószínűsége  $n(P+N)$ , ezért az összes nagy valószínűséggel  $\sqrt{n(P+N)}$  sugarú gömbökben lesz.

Mivel egy  $n$ -dimenziós gömb térfogata  $C_n r^n$ , ezért a dekódolható

$$\text{száma körülbelül: } \frac{C_n [n(P+N)]^{n/2}}{C_n (nN)^{n/2}} = \left(1 + \frac{P}{N}\right)^{n/2} = 2^{\frac{n}{2} \log\left(1 + \frac{P}{N}\right)}$$



Tétel első fele: Minden  $R < C = \frac{1}{2} \log \left(1 + \frac{P}{N}\right)$  rate elérhető

Biz: 1. Először generáljunk egy kódhalmazt! Minden szó minden elemét generáljuk egy  $P - \epsilon$  varianciájú normális eloszlásból, ezáltal vagy  $n$ -re  $\frac{1}{n} \sum x_i^2 \rightarrow P - \epsilon < P$ .

2. A kódokat elhelyezik a  $w$  szólarészterű  $X^n(w)$  kódcsúsz.

3. A legutolsó  $n$  bit  $w$  szólarészterű jeladóhalmazok, amivel a  $(X^n(w), Y^n)$  páros benne van a teljes halmazban.

Ha nincs benne egyik  $w$ -re sem, vagy ha  $X^n(w)$  nem teljesíti a feltételt, akkor hibát dob.

4. A hiba valószínűségeit az alábbi módon névelhetjük:

$$\text{Legyen } E_0 = \left\{ \frac{1}{n} \sum_{i=0}^n x_i^2(1) > P \right\}$$

$$E_i = \left\{ (X^n(i), Y^n) \in A_{\epsilon}^{(n)} \right\}$$

Hibát történik, ha  $E_0$  vagy  $E_1^c$  fordul elő, és hibás jeladóhalmaz, ha  $E_2 \cup E_3 \cup \dots \cup E_{2^{nr}}$ .

$$P(\epsilon) = P(E_0 \cup E_1^c \cup E_2 \cup E_3 \cup \dots \cup E_{2^{nr}}) \leq P(E_0) + P(E_1) + \sum_{i=2}^{2^{nr}} P(E_i)$$

$P(E_0) \leq P(E_1)$  a nagy számok törvénye és a AEP miatt  $\leq \epsilon$

Mivel  $X^n(1)$  és  $X^n(i)$  a generálás miatt függetlenek, ezért  $Y^n \sim X^n(i)$  is, ezért a AEP miatt  $P(E_i) \leq 2^{-n(I(X_i; Y) - 3\epsilon)}$

$$\text{Ehhez } P(\epsilon) \leq 2\epsilon + \sum_{i=2}^{2^{nr}} 2^{-n(I(X_i; Y) - 3\epsilon)} = 2\epsilon + (2^{nr} - 1) 2^{-n(I(X_i; Y) - 3\epsilon)} \leq 2\epsilon + 2^{nr} 2^{-n(I(X_i; Y) - 2\epsilon)} \leq 3\epsilon \quad \square$$

Tétel második fele: Az  $R > C = \frac{1}{2} \log \left(1 + \frac{P}{N}\right)$  rate nem elérhető el.

Biz: Azt kell belátni, hogy ha  $(2^{nr}, n)$  kód hányával valószínűsége  $P_e^{(n)} \rightarrow 0$ , akkor  $R \leq C$ .

Vegyünk egy tetszőleges kódot, amire teljesül, hogy  $\frac{1}{n} \sum_{i=1}^n x_i^2(w) \leq P \quad \forall w$ -re, és legyen  $W$  egyjelűs eloszlású!

A diszkrét esetben bizonyított lemma alapján

$$W \rightarrow X^n(W) \rightarrow Y^n \rightarrow \hat{W} \quad \text{lévén esetén}$$

$$H(W | \hat{W}) \leq 1 + n P_e^{(n)} = n \epsilon_n \quad \text{ahol } \epsilon_n \rightarrow 0, P_e^{(n)} \rightarrow 0.$$

Ellát:

$$\begin{aligned} nR &= H(W) = I(W; \hat{W}) + H(W|\hat{W}) \leq I(W; \hat{W}) + n\epsilon_n \leq I(X^n; Y^n) + n\epsilon_n = \\ &= h(Y^n) - h(Y^n|X^n) + n\epsilon_n = h(Y^n) - h(Z^n) + n\epsilon_n \leq \sum_{i=1}^n h(Y_i) - h(Z_i) + n\epsilon_n \\ &= \sum_{i=1}^n h(Y_i) - \sum_{i=1}^n h(Z_i) + n\epsilon_n = \sum_{i=1}^n I(X_i; Y_i) + n\epsilon_n \end{aligned}$$

Legyen  $P_i = \frac{1}{nR} \sum_w x_i^2(w)$ . Mivel a kódolásnál mindig kielégítjük a hatványhatalmát, ezért az átlagunk is:  $\frac{1}{n} \sum_i P_i \leq P$ .

Mivel  $Y_i = X_i + Z_i$  ahol  $X_i$  és  $Z_i$  függetlenek, ezért  $EY_i^2 = P_i + N$ , így

$$h(Y_i) \leq \frac{1}{2} \log(2\pi e(P_i + N)). \quad \text{Ellát:}$$

$$\begin{aligned} nR &\leq \sum_{i=1}^n (h(Y_i) - h(Z_i)) + n\epsilon_n \leq \sum_{i=1}^n \left( \frac{1}{2} \log(2\pi e(P_i + N)) - \frac{1}{2} \log(2\pi eN) \right) + n\epsilon_n = \\ &= \sum_{i=1}^n \frac{1}{2} \log\left(1 + \frac{P_i}{N}\right) + n\epsilon_n \end{aligned}$$

Jensen - egyenlőtlenség miatt

$$R \leq \frac{1}{n} \sum_{i=1}^n \frac{1}{2} \log\left(1 + \frac{P_i}{N}\right) \leq \frac{1}{2} \log\left(1 + \frac{1}{n} \sum_{i=1}^n \frac{P_i}{N}\right) \leq \frac{1}{2} \log\left(1 + \frac{P}{N}\right) \quad \square.$$

### Részbenes Gauss-i csatorna

Ha a feltételezés teljes fúhúvára rajlik, és a raj van bekérve, akkor az új modellbe, mint k. példának, egyáltalán független Gauss-i csatorna:

$$Y_i = X_i + Z_i \quad i = 1, 2, \dots, k \quad \text{ahol } Z_i \sim \mathcal{N}(0, N_i)$$

A hatványhatalmát a példának csatorna közötti közösen értelmezhetjük:  $E \sum_{i=1}^k X_i^2 \leq P$

A csatorna kapacitása:

$$C = \max_{\sum E X_i^2 \leq P} I(X_1, \dots, X_k; Y_1, \dots, Y_k)$$

Mivel  $Z_i$ -k függetlenek  $X_i$ -ktől:

$$\begin{aligned} I(X_1, \dots, X_k; Y_1, \dots, Y_k) &= h(Y_1, \dots, Y_k) - h(Y_1, \dots, Y_k | X_1, \dots, X_k) = \\ &= h(Y_1, \dots, Y_k) - h(Z_1, \dots, Z_k | X_1, \dots, X_k) = \\ &= h(Y_1, \dots, Y_k) - h(Z_1, \dots, Z_k) = h(Y_1, \dots, Y_k) - \sum_i h(Z_i) \leq \\ &\leq \sum_i (h(Y_i) - h(Z_i)) \leq \sum_i \left( \frac{1}{2} \log\left(1 + \frac{P_i}{N_i}\right) \right) \end{aligned}$$

ahol  $P_i = EX_i^2$  és  $\sum_i P_i \leq P$ .

Egyenlőség akkor van, ha  $(X_1, \dots, X_k) \sim \mathcal{N}\left(0, \begin{pmatrix} P_1 & & \\ & P_2 & \\ & & \dots \\ & & & P_k \end{pmatrix}\right)$

a kódot, úgy mindig  $(P_1, P_2, \dots, P_k)$  kördistribúció:



En egy egyszerű optimalizáció, ami Lagrange - multiplikatívval megoldható:

$$F(P_1, \dots, P_k) = \sum_{i=1}^k \frac{1}{2} \log \left( 1 + \frac{P_i}{N_i} \right) + \lambda \left( \sum_{i=1}^k P_i \right)$$

Válassz  $F$ -t, az alábbi koeff. :  $\frac{1}{2} \frac{1}{P_i + N_i} + \lambda = 0 \Rightarrow P_i = \nu - N_i$ .


Bár  $P_i \geq 0$  kell lenne, de az előzőek és most feltétel teljesül.

Előzet: Kuhn-Tucker-feltétel

$$P_i = (\nu - N_i)^+ \quad \text{vagy, hogy teljesüljön a } \sum_{i=1}^k (\nu - N_i)^+ = \nu$$

$$\text{ahol } (x)^+ = \begin{cases} x & \text{ha } x \geq 0 \\ 0 & \text{else} \end{cases}$$

Ábrázolás:



"víz feltöltés" módszer

# BEV INF ELM

10. előadás (04.23.)

## Maximum entropia

Fizikában általában a rendszer adott feltételi mellett megvalósuló valószínűségi állapota közül az valószínű, amelyben történő valószínűségi állapotaik száma a legnagyobb. Ezzel ekvivalens feltétel, ha azt mondjuk, hogy a maximális entropiájú valószínűség az a megvalósulás.

Ezzel az elvvel az analógiáján matematikailag is alkalmazható: gyakran lehet szükségünk arra az elvvel, amely bizonyos feltételek mellett a maximális entropiát rendelkező.

Feladat: Keressük meg azt az  $f$  valószínűségi sűrűség-függvényt, amely  $h(f)$  maximális és teljesíti az alábbi feltételeket:

1.  $f(x) \geq 0$  a teljes  $S$  értelmezési tartományán

2.  $\int_S f(x) dx = 1$

3.  $\int_S f(x) v_i(x) dx = \alpha_i \quad 1 \leq i \leq m$  ahol  $v_i$  korlátos és  $\alpha_i$  köztartó.

1. Megoldási szemlélet (Kalkulus):

Mivel  $h(f)$  konkáv függvény, az optimalizációs módszer alkalmazható:

$$J(f) = - \int f \ln f + \lambda_0 \int f + \sum_{i=1}^m \lambda_i \int f v_i$$

Ezt variálva:  $\frac{\partial J}{\partial f(x)} = -\ln f(x) - 1 + \lambda_0 + \sum_{i=1}^m \lambda_i v_i(x) = 0$

$$\Rightarrow f(x) = e^{\lambda_0 - 1 + \sum_{i=1}^m \lambda_i v_i(x)}$$

ahol  $\lambda_0, \lambda_1, \dots, \lambda_m$  olyanok, hogy  $f$  teljesíti a feltételeket.

Ez azonban csak a fu alakját látjuk meg. A maximum kiszámításához 2. variáns kellene, de egyszerűbb infóval kiszámítani.

2. Megoldási szemlélet (Inkváziós egyenlőtlenség):

Ha  $g$  teljesíti a 1-3 feltételeket, és  $f^*$  az előbbi exp alak, akkor

$$0 \leq D(g \| f^*) = -h(g) + h(f^*)$$

(hiszen egy  $g - f^*$  -gel végtelen sokféleképpen lehet összehasonlítani, mint  $g$ -vel magunkkal.)

$$\text{Ebből } h(g) \leq h(f^*)$$

Funkcionális kiszámítás az alábbi.



Tétel: Az  $f^*(x) = e^{\lambda_0 + \sum_i \lambda_i v_i(x)}$  függvény, ahol  $\lambda_0, \lambda_1, \dots, \lambda_m$  aljarsok, leggy a kibátások teljesülései, egyértelműen maximalizálja az entropiát.

Biz: Legyen  $g$  olyan fn, ami teljesíti a feltételeket! Ekkor

$$\begin{aligned} h(g) &= -\int_S g \ln g = -\int_S g \ln \left( \frac{g}{f^*} f^* \right) = -D(g \| f^*) - \int_S g \ln f^* \leq \\ &\leq -\int_S g \ln f^* = -\int_S g (\lambda_0 + \sum_i \lambda_i v_i) = \text{mivel } g \text{ is } f^* \text{ is teljesíti a feltételeket} \\ &= -\int_S f^* (\lambda_0 + \sum_i \lambda_i v_i) = -\int_S f^* \ln f^* = h(f^*) \end{aligned}$$

Egyenlőség akkor, ha  $D(g \| f^*) = 0 \Leftrightarrow g = f^*$ . □

Példák:

1) 1D-s gép, hőmérséklet kibátással.

A kibátások:  $EX = 0$  és  $EX^2 = \sigma^2$ . Mivel az eloszlás alakja  $e^{\lambda_0 + \lambda_1 x + \lambda_2 x^2}$ , ezért a megoldás normális eloszlás lesz. Ennek paramétereit ismerjük, tehát a megoldás:

$$X \sim \mathcal{N}(0, \sigma^2), \quad f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{x^2}{2\sigma^2}}$$

2) Dobókocka, kibátás nélkül.

Legyen  $S = \{1, 2, 3, 4, 5, 6\}$ . A dobókocka entropia maximalis, ha az eloszlás egyenletes.

$$\Rightarrow p(x) = \frac{1}{6} \quad \forall x \in S$$

3) Dobókocka megadott átlaggal:  $EX = \sum_i i p_i = \alpha$

TFH  $n$  dobásból az  $i$ -t  $n_i$ -szer találjuk! A mikroállapothoz száma

$\binom{n}{n_1, \dots, n_6}$ , és mindegyik valószínűsége  $\frac{1}{6^n}$ . Ha egy kicsit megvár a

egyenlőségűvé, azt kell maximalizálnunk a  $\sum_i i n_i = n\alpha$  feltételre.

A Stirling-formulát alkalmazva:  $n! \approx \left(\frac{n}{e}\right)^n$

$$\binom{n}{n_1, \dots, n_6} \approx \frac{\left(\frac{n}{e}\right)^n}{\prod_i \left(\frac{n_i}{e}\right)^{n_i}} = \prod_i \left(\frac{n}{n_i}\right)^{n_i} = e^{\sum_i n_i \ln \left(\frac{n}{n_i}\right)} = e^{n H\left(\frac{n_1}{n}, \dots, \frac{n_6}{n}\right)}$$

Telát a mikroállapotszám maximalizálásán az entropia maximalizálása elvileg.

Mivel a feltétel az első parametere megadott, ezért

$$p_i = \frac{e^{\lambda_i}}{\sum_i e^{\lambda_i}}$$

és épp a Boltzmann-eloszlás.

4) Véges intervallumon minős kitérés. A tétel alapján a megoldás az egyenletes elvadás

5)  $S = [0, \infty)$ ,  $EX = \mu$ .  $\Rightarrow f(x) = \frac{1}{\mu} e^{-\frac{x}{\mu}}$ .

Fizikai interpretáció: Legyen  $X$  egy adott molekuláris sebesség a légkörben!

Mivel az átlagos sebesség ismeretlen, ezért  $E(\text{mg } X)$  megadott.

Igy kaphatjuk a kanonikus sebességformulát, ami most ez.

Univerzális kódolás

Láttuk, hogy ha ismerjük a kódolási szabály eloszlását, akkor tudhatjuk egy olyan kód, ami közel optimális az átlagos sebesség tekintetében.

Számos esetben van ismerjük előre az eloszlást, hanem folyamatuknál kell kódolni. Egyfel valószínű feladat, hogy így is az ideálishoz közel lévő kódolást kaphatunk.

3 példa:

1) Aritmetikai kódolás

Lemma: Legyen  $Y$  egy véletlen változó, és  $F(y)$  az eloszlásfüggvénye!

Legyen  $U = F(Y)$  egy másik véletlen változó! Ekkor  $U$  egyenletes a  $[0, 1]$ -en.

Biz: Mivel  $F(y) \in [0, 1]$ , ezért  $U$  is itt van definiálva. Adott  $u \in [0, 1]$ -re:

$$F_U(u) = \Pr(U \leq u) = \Pr(F(Y) \leq u) = \Pr(Y \leq F^{-1}(u)) = F(F^{-1}(u)) = u \quad \square$$

Most képzünk el egy  $x_1, x_2, \dots$  végtelen sorozatot a  $X = 0, \dots, m$  abszolút!

Bárna ele egy "0"-t egy valós számot kapunk az  $m+1$  számrendszerben

felírva. Az eredeti sorozat eloszlásfüggvénye:  $F_X(x) = \Pr(X \leq x = 0, x_1, x_2, \dots) =$

$$= \Pr(0, x_1, x_2, \dots \leq 0, x_1, x_2, \dots) =$$

$$= \Pr(x_1 \leq x_1) + \Pr(x_1 = x_1, x_2 < x_2) + \dots$$

Ekkor az  $U = F_X(X) = 0, F_1 F_2 \dots$  változó a lemma értelmében egyenletes


az  $[0, 1]$ -en, tehát a számjegyei független, egyenletes eloszlásúak lesznek.

És a számjegyeket nem tekinthetjük, tehát  $U$  egy ideális tömörítés  $X$ -vel.

Megjegyzés: Legyen  $x_1, \dots, x_n$  egy véges halmaz elemei! Ekkor a  $0, x_1, x_2, \dots, x_n$  sorozatban az  $0, x_1, x_2, \dots, x_n$  számok között van egy valós számot, amely  $0, x_1, x_2, \dots, x_n$  -vel kezdődik. Ez a  $[0, x_1, x_2, \dots, x_n; 0, x_1, x_2, \dots, x_n + \sum_{i=1}^n 10^{-i}]$  intervallumon, ha ezeket



metódus: Válasszuk ki a  $[0,1]$  intervallumból azt, amelyiken az első kerekletés történik a STE-ből alulról! Ezt tovább bontgatjuk fel a második kerekletés alulról és így tovább. Pl.:  $P(A, B, C) = \{0,4; 0,4; 0,2\}$



Azok, legyen minenként két lépés, adhatunk négyet kell alkalmazni, azaz a valószínűségi eloszlást minden lépés után frissíteni kell a keletkezett kerekletéssel.

② Csúszóablakos Sempel-Ziv-kód (LZ77)

Vannak egy  $W$  alfabécéket, és minden "mondat" utam megírásánál, legyen az adott  $W$  kerekletésben van-e olyan szöveg, amelyre valószínű a kerekletés, és legyen mi az ilyen legrosszabb szöveg. Ha van, akkor elhárítjuk a  $P$  mondatot és a  $L$  hosszát. Ha nincs, akkor csak megadjuk a kerekletés kerekletését.

Pl.:  $W = \{A, B\}$ , üresbet:  $ABBAABBA BBBAAB ABBA$

felbontás mondatokra:  $A, B, B, ABBAAB, BA, A, BA, BA$

kódolása:  $(0, A), (0, B), (1, 1, 1), (1, 3, 6), (1, 4, 2), (1, 1, 1), (1, 3, 2), (1, 2, 2)$


③ Fasztruktúrált Sempel-Ziv-kód (LZ78)

Minden mondatot úgy kódolunk, mint az eddig van megadott legújabb mondat. Ezzel, csak a  $n$  korábbi megadott mondatot kell megadni, és azt, hogy milyen kerekletést használunk hozzá. Így egy fa gráffal reprezentálhatjuk a mondatokat

üresbet:  $ABBAABBA BBBAABBA$

felbontás:  $A, B, BA, BB, AB, BBA, ABA, BBA$

fa graf:



kódolása:  $(0, A), (0, B), (2, A), (2, B), (4, A), (5, A), (3, A)$

# BENEFELM

11. előadás (04.30)

## Hálózati információelmélet

A kommunikáció általában több résztvevő között zajlik, akik között valamilyen csatornákon keresztül kommunikálnak. Ez egy hálózatos feladatot eredményez, ami az információelmélet alapvető konceptja. Ennek a legegyszerűbb definícióját a Shannon-Wolf-tételt hívjuk meg.

**feladat:** Legyen  $(X_1, X_2, \dots, X_n)$  véges számú véletlen változó együttese, adott valószínűségi eloszlással:  $p(x_1, x_2, \dots, x_n)$ !

Legyen  $S$  azaz egy részhalomra (pl.:  $S = (x_1, x_2)$ ), és képezzük el belőle  $n$  darabot! Ekkor a valószínűségi eloszlás:

$$Pr(S=s) = \prod_{i=1}^n Pr(S_i=s_i) \quad S \in S^n$$

Nagy  $n$ -re:

$$-\frac{1}{n} \log p(S_1, S_2, \dots, S_n) = -\frac{1}{n} \sum_{i=1}^n \log p(S_i) \rightarrow H(S)$$

**Def:** Legyen  $A_\epsilon^{(n)}$  az  $n$ -redundancia  $\epsilon$ -türes halmaz, azaz

$$A_\epsilon^{(n)} = \left\{ (x_1, \dots, x_n) : \left| -\frac{1}{n} \log p(S) - H(S) \right| < \epsilon \quad \forall S \subseteq \{x_1, \dots, x_n\} \right\}$$

**Def:** Legyen  $A_\epsilon^{(n)}(S)$  annak a maximálisan pozitív  $S$  részhalomra!

Pl., ha  $S = (x_1, x_2)$ , akkor

$$A_\epsilon^{(n)}(x_1, x_2) = \left\{ (x_1, x_2) : \begin{aligned} & \left| -\frac{1}{n} \log p(x_1, x_2) - H(x_1, x_2) \right| < \epsilon, \\ & \left| -\frac{1}{n} \log p(x_1) - H(x_1) \right| < \epsilon, \\ & \left| -\frac{1}{n} \log p(x_2) - H(x_2) \right| < \epsilon \end{aligned} \right\}$$

**Def:** Jelölje  $a_n = 2^{n(b \pm \epsilon)}$  azt, ha  $\left| \frac{1}{n} \log a_n - b \right| < \epsilon$  elég nagy  $n$ -re!

**Tétel:** Bármely  $\epsilon > 0$ -ra, létezik elég nagy  $n$ , amelyre

$$1. P(A_\epsilon^{(n)}(S)) \geq 1 - \epsilon \quad \forall S \subseteq \{x_1, x_2, \dots, x_n\}$$

$$2. \underline{s} \in A_\epsilon^{(n)}(S) \Rightarrow p(\underline{s}) \doteq 2^{n(H(S) \pm \epsilon)}$$

$$3. |A_\epsilon^{(n)}(S)| \doteq 2^{n(H(S) \pm 2\epsilon)}$$

4. Legyenek  $s_1, s_2 \subseteq \{x_1, \dots, x_n\}$ ! Ha  $(s_1, s_2) \in A_\epsilon^{(n)}(s_1, s_2)$ , akkor

$$p(s_1, s_2) \doteq 2^{-n(H(s_1, s_2) \pm 2\epsilon)}$$



Biz: 1. A nagy szám tör-tétel és  $A_\epsilon^{(n)}(S)$  definiálható közvetlenül.

2.  $A_\epsilon^{(n)}(S)$  definiálható átfordítással, azt kaphatjuk.

$$3. 1 \geq \sum_{s \in A_\epsilon^{(n)}(S)} p(s) \geq \sum_{s \in A_\epsilon^{(n)}(S)} 2^{-n(H(s) + \epsilon)} = |A_\epsilon^{(n)}(S)| 2^{-n(H(s) + \epsilon)}$$

$$1 - \epsilon \leq \sum_{s \in A_\epsilon^{(n)}(S)} p(s) \leq \sum_{s \in A_\epsilon^{(n)}(S)} 2^{-n(H(s) - \epsilon)} = |A_\epsilon^{(n)}(S)| 2^{-n(H(s) - \epsilon)}$$

A két oldalra közvetlenül az állítás.

4. Ha  $(s_1, s_2) \in A_\epsilon^{(n)}(s_1, s_2)$ , akkor  $p(s_1) \geq 2^{-n(H(s_1) + \epsilon)}$  és  $p(s_2) = 2^{-n(H(s_2) + \epsilon)}$

Ebből  $p(s_2 | s_1) = \frac{p(s_1, s_2)}{p(s_1)} \geq 2^{-n(H(s_2 | s_1) + 2\epsilon)}$  □

Tétel: Legyen  $s_1, s_2 \in \{x_1, \dots, x_k\}$ , és jelölje  $A_\epsilon^{(n)}(s_1 | s_2)$  azon  $s_1 \in S_1$ -ek szubszétét, amik együttesen tipikusak  $S_2$ -vel!

Ha  $s_2 \in A_\epsilon^{(n)}(s_2)$ , akkor elég nagy  $n$ -re

$$|A_\epsilon^{(n)}(s_1 | s_2)| \leq 2^{n(H(s_1 | s_2) + 2\epsilon)} \quad \text{és} \quad (1 - \epsilon) 2^{n(H(s_1 | s_2) - 2\epsilon)} \leq \sum_{s_1} p(s_1) |A_\epsilon^{(n)}(s_1 | s_2)|$$

Biz:  $1 \geq \sum_{s_1 \in A_\epsilon^{(n)}(s_1 | s_2)} p(s_1 | s_2) \geq \sum_{s_1 \in A_\epsilon^{(n)}(s_1 | s_2)} 2^{-n(H(s_1 | s_2) + 2\epsilon)} =$

$$= |A_\epsilon^{(n)}(s_1 | s_2)| 2^{-n(H(s_1 | s_2) + 2\epsilon)} \quad \text{ebből az első közvetlenül.}$$

$$1 - \epsilon \leq \sum_{s_1} p(s_1) \sum_{s_1 \in A_\epsilon^{(n)}(s_1 | s_2)} p(s_1 | s_2) \leq \sum_{s_1} p(s_1) \sum_{s_1 \in A_\epsilon^{(n)}(s_1 | s_2)} 2^{-n(H(s_1 | s_2) - 2\epsilon)} =$$

$$= \sum_{s_1} p(s_1) |A_\epsilon^{(n)}(s_1 | s_2)| 2^{-n(H(s_1 | s_2) - 2\epsilon)} \quad \text{ebből az második közvetlenül.} \quad \square$$

Tétel: Legyen  $s_1, s_2, s_3 \in \{x_1, \dots, x_k\}$  és tegyük fel, hogy  $s_1$  és  $s_2$  csak  $s_3$ -tal függ, azaz

$$P(s_1 = s_{21}, s_2 = s_{22}, s_3 = s_{23}) = \prod_{i=1}^n p(s_{2i} | s_{3i}) p(s_{2i} | s_{3i}) p(s_{3i})!$$

akkor  $P_n((s_{21}, s_{22}, s_{23}) \in A_\epsilon^{(n)}) \geq 2^{n(I(s_{21}, s_{22} | s_{23}) \pm 6\epsilon)}$


Biz:  $P((s_{21}, s_{22}, s_{23}) \in A_\epsilon^{(n)}) = \sum_{(s_{21}, s_{22}, s_{23}) \in A_\epsilon^{(n)}} p(s_{21}) p(s_{22} | s_{21}) p(s_{23} | s_{21}) =$

$$= |A_\epsilon^{(n)}(s_{21}, s_{22}, s_{23})| 2^{-n(H(s_{21}) \pm \epsilon)} \cdot 2^{-n(H(s_{22} | s_{21}) \pm \epsilon)} \cdot 2^{-n(H(s_{23} | s_{21}) \pm \epsilon)} =$$

$$= 2^{-n(H(s_{21}, s_{22}, s_{23}) \pm 6\epsilon)}$$

$$\geq 2^{-n(H(s_{21}, s_{22}, s_{23}) \pm 6\epsilon)} \quad \square$$

Teljesítmény az alábbi művelet: két helyről ábránd infókat digitális egy-egy csatornába, de ezek nem korelálhatnak. Mivel a kódolás költséges, az ábrándot natúrjait költségekkel  $R_1 > H(X)$ ,  $R_2 > H(Y)$ . Ha viszont az infókat egybe ábrándozzuk, akkor a teljes ráta  $R > H(X, Y)$ . Az ábrándok ezt követik vagy fordítva.



Def: Egy  $(2^{nR_1}, 2^{nR_2}, n)$  elosztott kód egy  $(X, Y)$  együttes ábrándolásból két kódolás fu-kából és egy együttes dekódolás fu-kából áll:

$$f_1: X^n \rightarrow \{1, 2, \dots, 2^{nR_1}\}$$

$$f_2: Y^n \rightarrow \{1, 2, \dots, 2^{nR_2}\}$$

$$g: \{1, 2, \dots, 2^{nR_1}\} \times \{1, 2, \dots, 2^{nR_2}\} \rightarrow X^n \times Y^n$$

$(R_1, R_2)$  a kódolás tartományát

Def: A kód valószínűsége:  $P_e^{(n)} = \Pr(g(f_1(X^n), f_2(Y^n)) \neq (X^n, Y^n))$

Def: Egy  $(R_1, R_2)$  tartomány ábrándtűrő, ha létezik olyan  $(2^{nR_1}, 2^{nR_2}, n)$  kód, amire  $P_e^{(n)} \rightarrow 0$ .

**VIGYÁZAT!!!**  $\Sigma$  az  $R$  nem kompatibilis a csatorna kódolásnál leírt  $R$ -nel! Bár meg lehetett volna látni úgy is, de a könyv nem így fogalmaz.

Tétel (Shannon-Wall): Egy elosztott kódra a  $(X, Y)$  fűzettel és az  $p(x, y)$  valószínűségi eloszlással az ábrándtűrő volték szükséges és elégséges feltételei:

$$R_1 \geq H(X|Y)$$

$$R_2 \geq H(Y|X)$$

$$R_1 + R_2 \geq H(X, Y)$$

A bizonyítás előtt meg kell látni, hogy van egy kód, amely nagyobb  $n$ -re tetszőlegesen  $R > H(X)$  ráta mellett működik.

Minden  $X^n$  vektorhoz rendeljük hozzá véletlenszerűen egy indexet a  $\{1, \dots, 2^{nR}\}$  halmazból, amelyet hívunk címkének! A dekódolásban a kapott index alapján meg kell találni vagy, hogy az adott vektor melyik az egyetlen típusú elem!

Ha nincs ilyen, vagy ha több van, akkor dekódolás hibát!



- Hiba akkor lehet, ha:
  - a küldött rekvizitum nem teljeses vagy
  - hibás teljes rekvizitum is került megvalósításra.

Nagy  $n$  esetén  $g$  első valószínűségi eloszlásjelölté, végül sokkal több rekvizitum van, mint teljes elem, akkor a hiba is. Formalizálva:

$$\begin{aligned}
 \Pr(g(\phi(x)) \neq x) &\leq \Pr(x \notin A_\epsilon^{(n)}) + \sum_x \Pr(\exists x' \neq x: x' \in A_\epsilon^{(n)}, \phi(x') = \phi(x)) p(x) \\
 &\leq \epsilon + \sum_x \sum_{\substack{x' \in A_\epsilon^{(n)} \\ x' \neq x}} \Pr(\phi(x') = \phi(x)) p(x) \\
 &\leq \epsilon + \sum_x \sum_{x' \in A_\epsilon^{(n)}} 2^{-nR} p(x) = \epsilon + \sum_{x' \in A_\epsilon^{(n)}} 2^{-nR} \sum_x p(x) \leq \\
 &\leq \epsilon + 2^{n(H(x) + \epsilon)} 2^{-nR} \leq 2\epsilon \quad \text{ha } R > H(x) + \epsilon.
 \end{aligned}$$

Telát minden  $R > H(x)$  előlétező így módon.

Slepian-Wolf-tétel bizonyítása:

- Előfeltétel:  $A = (R_1, R_2)$  vételező előlétező az alábbi módon:

Minden  $X^n$  rekvizitumán rendeljünk hozzá egy indexet a  $\{1, \dots, 2^{nR_1}\}$  halmazból, és a  $Y^n$  rekvizitumok a  $\{1, \dots, 2^{nR_2}\}$  halmazból!

$A = (R_1, R_2)$  indexpárt delegáljuk  $(x, y)$ -ként, ha ez az egyetlen teljes rekvizitum a lehét megfelelő rekvizitumok! Ha a rekvizitum nincs teljeses van, vagy több ilyen van, akkor delegálunk hibát!

Az alábbi hibahalmazokat definiáljuk:  $E_0 = \{(x, y) \notin A_\epsilon^{(n)}\}$

$$E_1 = \{\exists x' \neq x: \phi_1(x') = \phi_1(x), (x', y) \in A_\epsilon^{(n)}\}$$

$$E_2 = \{\exists y' \neq y: \phi_2(y') = \phi_2(y), (x, y') \in A_\epsilon^{(n)}\}$$

$$E_{12} = \{\exists (x', y'): x' \neq x, y' \neq y, \phi_1(x') = \phi_1(x), \phi_2(y) = \phi_2(y'), (x', y') \in A_\epsilon^{(n)}\}$$

A hiba valószínűsége:  $P_e = \Pr(E_0 \cup E_1 \cup E_2 \cup E_{12}) \leq \Pr(E_0) + \Pr(E_1) + \Pr(E_2) + \Pr(E_{12})$

$\Pr(E_0) < \epsilon$  az AEP miatt.

$$\begin{aligned}
 \Pr(E_1) &= \sum_{(x, y)} p(x, y) \Pr(\exists x' \neq x: \phi_1(x') = \phi_1(x), (x', y) \in A_\epsilon^{(n)}) \leq \\
 &\leq \sum_{(x, y)} p(x, y) \sum_{\substack{x' \neq x \\ (x', y) \in A_\epsilon^{(n)}}} \Pr(\phi_1(x') = \phi_1(x)) = \sum_{(x, y)} p(x, y) 2^{-nR_1} |A_\epsilon(x|y)| \leq \\
 &\leq 2^{-nR_1} 2^{n(H(x|y) + \epsilon)} \rightarrow 0 \quad \text{ha } R_1 > H(x|y).
 \end{aligned}$$

$\Pr(E_2) \rightarrow 0$  ha  $R_2 > H(y|x)$  ugyanígy.

$\Pr(E_{12}) \rightarrow 0$  ha  $R_1 + R_2 > H(x, y)$  ugyanígy.  $\Rightarrow P_e \rightarrow 0$

• szubsztrahciós

Ha  $(R_1, R_2)$  előltek, akkor  $R_1 + R_2 \geq H(X, Y)$  egyenlőség általában nem teljesül.

Ha  $(R_1, R_2)$  előltek, akkor  $(R_1, H(Y))$  is, hiszen csak  $Y$  redundanciáját vettük ki.

$$\text{Ezért } R_1 + H(Y) \geq H(X, Y) \Rightarrow R_1 \geq H(X|Y)$$

$$(H(X), R_2)\text{-re ugyancsak } \Rightarrow R_2 \geq H(Y|X).$$

□

A tétel kitonnyított változatában való változások:

Tétel: Legyen  $(X_1, X_2, \dots, X_m)$  iid-változó  $\alpha$   $P(X_1, \dots, X_m)$  eloszlással!

Ezre a felbontásnak az előltek ráterve a redundancia és elcsúszás feltétel:

$$R(s) \geq H(X(s)|X(s)) \quad \forall s \subseteq \{1, \dots, m\} \text{ -re.}$$

$$\text{ahol } R(s) = \sum_{i \in s} R_i \text{ és } X(s) = \{X_j : j \in s\}.$$

[Lásd a kódolást]




# BEVINFELM

12. előadás (05.14.)

Sok rendszerben találkozhatsz algebrával, legyen töltsz felváltás jellel kell értelmezni, és ezek egyrészt hivatkozik. Pl.: műhold hálózati adás, hálózati telekommunikáció, analóg interakcióval, stb. Ezek általában indultak a többletös kommunikáció rendszerrel.

Def.: Egy diszkrét memóriamentes többletös kommunikációs rendszer 3 alélel. (két bemenő és egy kimenő) és egy átmeneti valószínűségi áll.



Def.: Egy  $(2^{nR_1}, 2^{nR_2}, n)$  kód egy többletös kommunikációs rendszer  $q$  két indexeként:  $W_1 = (1, 2, \dots, 2^{nR_1})$ ,  $W_2 = (1, 2, \dots, 2^{nR_2})$ , két kódalélel:

$X_1: W_1 \rightarrow X_1^n$ ,  $X_2: W_2 \rightarrow X_2^n$  és egy kódalélel:

$g: Y^n \rightarrow W_1 \times W_2$  áll.

Tegyük fel, hogy az üzenetek hálózata a  $W_1 \times W_2$  egyszerű valószínűségi tértérül!

Ekkor a hiba valószínűsége:  $P_e^{(n)} = \frac{1}{2^{n(R_1+R_2)}} \sum_{(w_1, w_2) \in W_1 \times W_2} \Pr(g(Y^n) \neq (w_1, w_2) | (w_1, w_2))$

Def.: A  $(R_1, R_2)$  rátájan elérhető, ha létezik olyan  $(2^{nR_1}, 2^{nR_2}, n)$  kód, amire  $P_e^{(n)} \rightarrow 0$ .

Def.: A kapacitási régió az elérhető  $(R_1, R_2)$  ráta halmazának részlete.

Tétel: Egy többletös kommunikációs rendszer kapacitási régiója azon  $(R_1, R_2)$  ráta halmazában áll, amely teljesíti a

$$R_1 \leq I(X_1; Y | X_2)$$

$$R_2 \leq I(X_2; Y | X_1)$$

$$R_1 + R_2 \leq I(X_1, X_2; Y)$$

feltételeket valamelyik  $p(x_1, x_2) = p(x_1)p(x_2)$  függetlenség mellett.

Példák: • független bináris szimmetrikus rendszer }  
• bináris reverz rendszer }  
• bináris töltő többletös kommunikációs rendszer }

Bizonyítás: két részen bizonyítjuk, először azt, hogy a feltételnek megfelelő  $(R_1, R_2)$ -k elérendőek, aztán, hogy az elérendő  $(R_1, R_2)$ -k minden esetben megfelelnek a rendszernek.

1) Elérendőség.

Az  $X_1(i)$  kódokat generáljuk  $n$  db. i.i.d. változóval  $p_1(x_{1i})$ -ként  
 $\forall i \in \{1, \dots, 2^{nR_1}\}$ -re. Az  $X_2(j)$  kódokat ugyanígy  $p_2(x_{2j})$ -ként.

Legyen  $A_\epsilon^{(n)}$  a tipikus  $(X_1, X_2, Y)$  szekvenciák halmaza! Adott  $(i, j)$  kóppár ~~halmazára a kódok alapján ismerjük azt a  $(i, j)$  indexpárt, amire  $(X_1(i), X_2(j), Y) \in A_\epsilon^{(n)}$ . Ha nincs ilyen vagy több ilyen van, akkor deleyen kívül!~~

TFH az  $(1, 1)$  vált elhírdése (a rendszer generálás miatt mindig)! Legyen

$$E_{ij} = \{(X_1(i), X_2(j), Y) \in A_\epsilon^{(n)}\}. \text{ A hiba valószínűsége:}$$

$$P_0^{(n)} = \Pr \left[ E_n^c \cup \left( \bigcup_{\substack{i \neq 1 \\ j \neq 1}} E_{ij} \right) \right] \leq \Pr(E_n^c) + \sum_{\substack{i \neq 1 \\ j=1}} \Pr(E_{ij}) + \sum_{\substack{i=1 \\ j \neq 1}} \Pr(E_{ij}) + \sum_{\substack{i \neq 1 \\ j \neq 1}} \Pr(E_{ij})$$

AEP miatt  $\Pr(E_n^c) \rightarrow 0$ . Előre már beláttuk általában tétel miatt  $i \neq 1$ -re:

$$\begin{aligned} \Pr(E_{i1}) &= \Pr \left\{ (X_1(i), X_2(1), Y) \in A_\epsilon^{(n)} \right\} = \\ &= \sum_{(x_1, x_2, y) \in A_\epsilon^{(n)}} p(x_1, x_2, y) = \sum_{(x_1, x_2, y) \in A_\epsilon^{(n)}} p(x_1) p(x_2, y) \\ &\leq |A_\epsilon^{(n)}| 2^{-n(H(X_1) - \epsilon)} 2^{-n(H(X_2, Y) - \epsilon)} \leq \\ &\leq 2^{-n(H(X_1) + H(X_2, Y) - H(X_1, X_2, Y) - 3\epsilon)} = 2^{-n(I(X_1; X_2, Y) - 3\epsilon)} = 2^{-n(I(X_1; Y | X_2) - 3\epsilon)} \end{aligned}$$

$$\text{ugyanígy } \Pr(E_{1j}) \leq 2^{-n(I(X_2; Y | X_1) - 3\epsilon)} \quad \text{és} \quad \Pr(E_{ij}) \leq 2^{-n(I(X_1, X_2; Y) - 4\epsilon)}$$


$$\begin{aligned} \text{Ekkor } P_0^{(n)} &\leq \Pr(E_n^c) + 2^{nR_1} 2^{-n(I(X_1; Y | X_2) - 3\epsilon)} + 2^{nR_2} 2^{-n(I(X_2; Y | X_1) - 3\epsilon)} + \\ &\quad + 2^{n(R_1 + R_2)} 2^{-n(I(X_1, X_2; Y) - 4\epsilon)} \end{aligned}$$

Ha  $\epsilon \rightarrow 0$  és a  $(R_1, R_2)$  a feltételnek megfelelőek, akkor  $P_0^{(n)} \rightarrow 0$   $n \rightarrow \infty$ -re.

[A  $\Pr(\cdot)$ -ke mindentől képezünk azt, hogy a feltétel, hogy az  $(1, 1)$  ett elhírdése.]



megjegyzés: ez általában úgy néz ki



A pont alatt  $x_1$  értéke maximális,  
és  $x_2$  nem éri el a határt. Ez nagy  
lejtésű talpata, hiszen

$$\max_{R_1} R_1 = \max_{P(x_1)|P(x_2)} I(x_1, y | x_2)$$

$$\text{ahol } I(x_1, y | x_2) = \sum_{x_2} P_2(x_2) I(x_1, y | x_2 = x_2) \leq \max_{x_2} I(x_1, y | x_2 = x_2)$$

Találjuk a  $x_2$  nem éri el, akkor járunk a legjólabb, ha az optimális  $x_2$ -t  
kialdunk.

B pont az a pont, ahol  $x_1$  értéke a maximális, és a  $x_2$ -t is a  
határhoz legjólabb közeledtünk. Ez olyan, mintha  $x_1$  a nagy része lenne  
és  $x_2$  éri el a határt.

C és D pont ugyanazt a határt mutatja.

2) Megfordított: minden elemtől  $(R_1, R_2)$  után benne van a kérdéses halmazban.

A tétel megfordításának bizonyításához alakítsuk át a hiperiterni egyenlet alagját!

Ehhez szükség van néhány lemmára.

Lemma 1: A C hiperiterni egyenlet konvex, azaz ha  $(R_1, R_2), (R_1', R_2') \in C$   
akkor  $(\lambda R_1 + (1-\lambda)R_1', \lambda R_2 + (1-\lambda)R_2') \in C \quad \forall \lambda \in [0, 1]$ .

Biz: Használjuk a vektor felírást azaz  $\underline{R} = (R_1, R_2)$ . Ha  $\underline{R} \in C$  és  $\underline{R}' \in C$  elemtől,  
akkor  $\lambda \underline{R} + (1-\lambda)\underline{R}'$  is az, ha az első két egyenlet  $\lambda n$  betűjét és a  
háromodik két egyenlet  $(1-\lambda)n$  betűjét használjuk. Akkor a két egyenletet  
összeadva mára az új két egyenlet  $\lambda n R_1 + (1-\lambda)n R_1'$  és  $\lambda n R_2 + (1-\lambda)n R_2'$

A hiba valószínűsége az egyes tagok összege, de az is  $\rightarrow 0$ .  $\square$

Ezután tisztázzuk a konvex kombináció fogalmát! Kétféleképpen ad az alábbi 2 példát:

$$C_1 = \{(x, y) : 0 \leq x \leq 10, 0 \leq y \leq 10, x + y \leq 100\}$$

$$C_2 = \{(x, y) : 0 \leq x \leq 20, 0 \leq y \leq 20, x + y \leq 20\}$$

Azt láthatjuk, hogy az  $(\frac{1}{2}, \frac{1}{2})$  ek. két vekt. kombinációját az alábbi:

$$C = \{(x, y) : 0 \leq x \leq 15, 0 \leq y \leq 15, x + y \leq 60\}$$

de könnyen látható, hogy  $(15, 15) \in C$  amíg  $(15, 15) \notin C_1 \cup C_2$ .

A kérdés az, hogy  $C_1$ -ben a  $x + y \leq 100$  feltétel nem aktív. Ennek elhárítására  
konvexitást használva az ötvonal alakú halmazra!



Legyenek  $I_1 := I(X_1; Y | X_2)$   $I_2 := I(X_2; Y | X_1)$   $I_3 := I(X_1, X_2; Y)$   
 és  $\underline{I} = (I_1, I_2, I_3)$  adott  $p(x_1, x_2) = p(x_1)p(x_2) \Rightarrow p(y | x_1, x_2)$  eloszlása

Az  $\underline{I}$  által definiált régió:

$$C_{\underline{I}} = \left\{ (R_1, R_2) : 0 \leq R_1 \leq I_1, 0 \leq R_2 \leq I_2, R_1 + R_2 \leq I_3 \right\}$$

Miel az  $(x_1, x_2)$  eloszlás normatálakú, ezért

$$I(X_2; Y | X_1) = H(X_2 | X_1) - H(X_2 | Y, X_1) = H(X_2) - H(X_2 | Y, X_1) = I(X_2; Y, X_1) = \\ = I(X_2; Y) + I(X_2; X_1 | Y) \geq I(X_2; Y)$$

$$\text{Ehhez } I(X_1; Y | X_2) + I(X_2; Y | X_1) \geq I(X_1; Y | X_2) + I(X_2; Y) = I(X_1, X_2; Y)$$

azaz  $I_1 + I_2 \geq I_3$  tehát a  $C$  terület valóban átrajg.

Lemma 2: Legyenek  $\underline{I}_1$  és  $\underline{I}_2$  ilyen vektorok és  $C_{\underline{I}_1}$  és  $C_{\underline{I}_2}$  a hozzájuk tartozó régiók! Legyen  $\underline{I}_\lambda = \lambda \underline{I}_1 + (1-\lambda) \underline{I}_2$  és  $C_{\underline{I}_\lambda}$  a hozzá tartozó régió!

$$\text{Ekkor } C_{\underline{I}_\lambda} = \lambda C_{\underline{I}_1} + (1-\lambda) C_{\underline{I}_2}$$

Biz:  $C_{\underline{I}_1}$  minden pontja teljesíti a def. relációt  $\underline{I}_1$ -gyal, és ugyanígy  $C_{\underline{I}_2}$  minden pontja  $\underline{I}_2$ -vel. Ez alapján a  $(\lambda, 1-\lambda)$ -vel kombinált vektor is teljesíti a  $(\lambda, 1-\lambda)$ -vel kombinált relációt, vagyis

$$\lambda C_{\underline{I}_1} + (1-\lambda) C_{\underline{I}_2} \subseteq C_{\underline{I}_\lambda}$$

A  $C_{\underline{I}}$  régiót az alábbi 5 pont keretében definiáljuk:

$$(0, 0), (I_1, 0), (I_1, I_3 - I_1), (I_3 - I_2, I_2), (0, I_2)$$

Ha  $I_3 = I_1 + I_2$ , akkor a 3. és 4. pont azonos, és éppen  $\underline{I}_\lambda$ -ra ugyanígy felírható az az 5 pont,  $\underline{I}_1$  és  $\underline{I}_2$  kombinációjaként. Mivel  $C_{\underline{I}_1}$  minden szarfpontja a  $C_{\underline{I}_1}$  és  $C_{\underline{I}_2}$  szarfpontjainak kombinációja, ezért mindet tartalmazza a kombináció, azaz

$$\lambda C_{\underline{I}_1} + (1-\lambda) C_{\underline{I}_2} \supseteq C_{\underline{I}_\lambda} \quad \square$$

(ha  $I_3 > I_1 + I_2$  lenne, akkor a  $C_{\underline{I}_\lambda}$  valamilyen szarfpontja nem lenne képezve az 5 pont kombinációjából.)

Lemma 3: Tekintsük azon  $(R_1, R_2)$  párokat, amelyekre teljesül a

$$R_1 < I(X_1; Y | X_2, Q)$$

$$R_2 < I(X_2; Y | X_1, Q)$$

$$R_1 + R_2 < I(X_1, X_2; Y | Q)$$

feltételeket valamely  $p(x_1, x_2, y, q) = p(q)p(x_1|q)p(x_2|q)p(y|x_1, x_2)$  eloszlásra, ahol  $|Q| \leq 4$ ! ~~Először is a feltételek teljesülnek.~~

Ekkor minden vektorra elérhető



Biz.: Legyen  $\underline{P}$  egy olyan pár, amely benne van a családban!

$$\begin{aligned} I(x_1, y | x_2, Q) &= \sum_{q=1}^m p(q) I(x_1, y | x_2, Q=q) = \\ &= \sum_{q=1}^m p(q) I(x_1, y | x_2)_{p_{1q}, p_{2q}} \end{aligned}$$

ahol  $m=|Q|$  és  $p_{1q}(x_1) = p_1(x_1|q)$ ,  $p_{2q}(x_2) = p_2(x_2|q)$ .

Ugyanígy  $I(x_2, y | x_1, Q)$ -ra.

Legyen  $\underline{P}_q = (P_{1q}, P_{2q})$  olyan csatolás, amely a  $p_{1q}$  és  $p_{2q}$  eloszlással teljesíti az eredeti tétel feltételeit, azaz  $\underline{P}_q$  elemléte az 54. o. miatt.

Mivel  $\underline{P}$  teljesíti a Lemma 3 feltételét, azt feltüntetve ígyvelük:

$$\underline{P} = \sum_{q=1}^m p(q) \underline{P}_q$$

Lemma 1 miatt, az  $\underline{P}_q$ -k valószínűségi konvexek, így Lemma 2 miatt ezek konvex kombináltján is az információkonvex kombináltján elemléteket várhatunk, tehát ha  $\underline{P}_q$ -k elemlétek, akkor  $\underline{P}$  is.  $\square$

megjegyzés:  $m$  felső határ a Carathéodory-tétel következménye. Erre azt, egy  $d$ -dimenziós Euklidészi térben vett kompakt balról bányászható pontjainak reprezentálhatóságát, mint maximum  $d+1$  pont konvex kombináltján. Mivel a  $\underline{I}$  vektor  $3D$ -s, ezért  $4$ -dből tényleg lehet összerakni bármelyiket. Erre azt fontos, hogy ha a  $Q$  vektor bármilyen nagy alhalmazából választunk fel elemléteket, akkor nem tudunk hozzá egygyel több  $q$  bevetéssel kiválasztani a kapacitásainak régiót.

Most nézzük rá a tétel megfordítottjával bizonyítására. Azt kell belátni, hogy minden elemlétes  $(P_1, P_2)$  párt benne van a Lemma 3-ban definiált baloldalon.

Nézzük tehát  $n$ -re a  $W_1 \times W_2 \times X_1^n \times X_2^n \times Y^n$  balról bányászható eloszlását:

$$p(w_1, w_2, x_1^n, x_2^n, y^n) = 2^{-nR_1} \cdot 2^{-nR_2} p(x_1^n | w_1) p(x_2^n | w_2) \prod_{i=1}^n p(y_i | x_{1i}, x_{2i})$$

ahol természetesen a valószínűségi eloszlás össze kell adnia ki.

Ha  $(P_1, P_2)$  elemlétes, akkor  $Y^n$ -kés jól becsülhető  $(W_1, W_2)$ , így a feltétel, entropiáján

$$\text{úgyis: } H(W_1, W_2 | Y^n) \leq n(R_1 + R_2) P_e^{(n)} + H(P_e^{(n)}) \stackrel{\Delta}{=} n \epsilon_n$$

$$\text{ahol } H(W_1 | Y^n) \leq H(W_1, W_2 | Y^n) \leq n \epsilon_n$$

$$H(W_2 | Y^n) \leq H(W_1, W_2 | Y^n) \leq n \epsilon_n$$

errel a  $R_1$  és  $R_2$  értékek felülbecsülhetők:

$$\begin{aligned}
n R_1 &= H(W_1) = I(W_1; Y^n) + H(W_1 | Y^n) \leq \text{szűrés} \leq I(W_1; Y^n) + n \epsilon_n \leq \\
&\leq I(X_1^n(W_1); Y^n) + n \epsilon_n = H(X_1^n(W_1)) - H(X_1^n(W_1) | Y^n) + n \epsilon_n \leq \\
&\leq H(X_1^n(W_1) | X_2^n(W_2)) - H(X_1^n(W_1) | Y^n, X_2^n(W_2)) + n \epsilon_n = \\
&= I(X_1^n(W_1); Y^n | X_2^n(W_2)) + n \epsilon_n = \\
&= H(Y^n | X_2^n(W_2)) - H(Y^n | X_1^n(W_1), X_2^n(W_2)) + n \epsilon_n = \\
&= H(Y^n | X_2^n(W_2)) - \sum_{i=1}^n H(Y_i | Y^{i-1}, X_1^n(W_1), X_2^n(W_2)) + n \epsilon_n = \\
&= H(Y^n | X_2^n(W_2)) - \sum_{i=1}^n H(Y_i | X_{1i}(W_1), X_{2i}(W_2)) + n \epsilon_n \leq \\
&\leq \sum_{i=1}^n H(Y_i | X_{2i}(W_2)) - \sum_{i=1}^n H(Y_i | X_{1i}(W_1), X_{2i}(W_2)) + n \epsilon_n \leq \\
&\leq \sum_{i=1}^n H(Y_i | X_{2i}(W_2)) - \sum_{i=1}^n H(Y_i | X_{1i}(W_1), X_{2i}(W_2)) + n \epsilon_n = \\
&= \sum_{i=1}^n I(X_{1i}; Y_i | X_{2i}) + n \epsilon_n
\end{aligned}$$

$$\Rightarrow R_1 \leq \frac{1}{n} \sum_{i=1}^n I(X_{1i}; Y_i | X_{2i}) + \epsilon_n$$

symmetria  $R_2 \leq \frac{1}{n} \sum_{i=1}^n I(X_{2i}; Y_i | X_{1i}) + \epsilon_n$

Az összegük pedig:

$$\begin{aligned}
n(R_1 + R_2) &= H(W_1, W_2) = I(W_1, W_2; Y^n) + H(W_1, W_2 | Y^n) \leq I(W_1, W_2; Y^n) + n \epsilon_n \leq \\
&\leq I(X_1^n(W_1), X_2^n(W_2); Y^n) + n \epsilon_n = H(Y^n) - H(Y^n | X_1^n(W_1), X_2^n(W_2)) + n \epsilon_n = \\
&= H(Y^n) - \sum_{i=1}^n H(Y_i | Y^{i-1}, X_1^n(W_1), X_2^n(W_2)) + n \epsilon_n = \\
&= H(Y^n) - \sum_{i=1}^n H(Y_i | X_{1i}, X_{2i}) + n \epsilon_n \leq \\
&\leq \sum_{i=1}^n H(Y_i) - \sum_{i=1}^n H(Y_i | X_{1i}, X_{2i}) + n \epsilon_n = \sum_{i=1}^n I(X_{1i}, X_{2i}; Y_i) + n \epsilon_n \\
\Rightarrow R_1 + R_2 &\leq \frac{1}{n} \sum_{i=1}^n I(X_{1i}, X_{2i}; Y_i) + \epsilon_n
\end{aligned}$$

Az így kapott felső korlátok a kölcsönös információval nem szemléltethetőek.

Bevezetve a  $Q = i \in \{1, \dots, n\}$  változót

$$\begin{aligned}
R_1 &\leq \frac{1}{n} \sum_{i=1}^n I(X_{1i}; Y_i | X_{2i}) + \epsilon_n = \frac{1}{n} \sum_{q=1}^n I(X_{1q}; Y_q | X_{2q}, Q=i) + \epsilon_n = \\
&= I(X_{1Q}; Y_Q | X_{2Q}, Q) + \epsilon_n = I(X_1; Y | X_2, Q) + \epsilon_n \\
&\text{ahol } X_1 \stackrel{\Delta}{=} X_{1Q}, X_2 \stackrel{\Delta}{=} X_{2Q}, Y \stackrel{\Delta}{=} Y_Q
\end{aligned}$$



Miel  $X_{1i}(W_i)$  ja  $X_{2i}(W_i)$  riippottomat

$$\Pr(X_{1i}(W_i) = x_1, X_{2i}(W_i) = x_2) \stackrel{\Delta}{=} \Pr(X_{1i} = x_1 | Q = i) \Pr(X_{2i} = x_2 | Q = i)$$

E2 alajon tult, ka  $n \rightarrow \infty$  -ne  $P_{ii}^{(n)} \rightarrow 0$ , alhen tult aljorn

$$p(q, x_1, x_2, y) = p(q) p(x_1 | q) p(x_2 | q) p(y | x_1, x_2) \text{ absoluuttisesti riippomattomuus, loppu}$$

$$n_1 \in I(x_1, Y | x_2, Q)$$

$$n_2 \in I(x_2, Y | x_1, Q)$$

$$n_1 + n_2 \in I(x_1, x_2, Y | Q) \quad \text{täjösäljös.$$

Ja  $|Q|$  kasvanneen  $n$ -ne, a tultit van valtonit.

□