

AZ IGAZI SHANNON

Halácsy Péter

2006. október

SZIMBÓLUMOKKAL KOMMUNIKÁLUNK

- ▶ Az ember mindig szimbólumokkal kommunikál.
- ▶ Kezdetben: kiáltás, bólintás, kézmozdulat, füstjel, barlangrajz (**dokumentum!**)
- ▶ Jön az írás: ábécé = szimbólumkészlet.
- ▶ Manapság szinte fénysebességgel továbbítunk már szimbólumokat — szöveget, hangot képet, videót digitális kódolásban.

KOMMUNIKÁCIÓ MODELLJE

kommunikációs rendszer elemei

- ▶ a jel forrástól (adó) származik
- ▶ az információs csatornán adott sebességgel tud haladni (sávszélesség, de vajon miért?)
- ▶ nem ugyanaz jön ki a csatornán, zaj van (recseg a telefon)
- ▶ a vevőnek dekódolni kell a jeleket

SHANNON CÉLJA

- ▶ a kommunikáció matematikai formalizmusa,
- ▶ hogy mérnöki problémaként legyen kezelhető az adatátvitel
- ▶ **nem volt célja:** nyelvészeti, bölcsész tudományi, kommunikáció tudományi és PR szakmáknak, khm, metaforát adni

SHANNON CÉLJA

- ▶ a kommunikáció matematikai formalizmusa,
- ▶ hogy mérnöki problémaként legyen kezelhető az adatátvitel
- ▶ **nem volt célja:** nyelvészeti, bölcsész tudományi, kommunikáció tudományi és PR szakmáknak, khm, metaforát adni
- ▶ fogadás: nyelvtantanárok többsége nem érti az információ elmélet alapjait

AZ INFORMÁCIÓ FOGALMA

Speciális jelentés.

- ▶ Telegráf (sms) üzenetekben bizonyos szavakat kihagynak, rövidítenek.
- ▶ Mégis kitalálható, h mi volt az eredeti üzenet. Megjósolhatóak a szimbólumok.
- ▶ Az üzenet kényen dekdolhtó.
- ▶ Megjósolható szimbólumok, elhagyhatóak, redundánsak.

INFORMÁCIÓ BIZONYTALANSÁGOT CSÖKKENT

- ▶ Tfh. egy gép háromféle szimbólum A , B , C és D valamelyikét tudja kiadni
- ▶ Várjuk a következő szimbólumot, **bizonytalanság** van bennünk.
- ▶ Megjelenik egy szimbólum, a bizonytalanság csökkent, **mert** információt kaptunk.
- ▶ Hogyan mérhető az információ?
- ▶ Nevezzük **négy szimbólumos bizonytalanságnak**

KÉT FORRÁS?

- ▶ Most vegyünk egy másik gépet, ez 1 és 2 szimbólumokat ad ki.
- ▶ két szimbólumos bizonytalansága van
- ▶ egymás után nézzük meg a kimenetet: 6 szimbólumos bizonytalanság csökkent

KÉT FORRÁS?

- ▶ Most vegyünk egy másik gépet, ez 1 és 2 szimbólumokat ad ki.
- ▶ két szimbólumos bizonytalansága van
- ▶ egymás után nézzük meg a kimenetet: 6 szimbólumos bizonytalanság csökkent
- ▶ ha a kettőt összekombináljuk 8 lehetséges szimbólum lesz: $A_1, A_2, B_1, B_2, C_1, C_2, D_1, D_2$
- ▶ ennek már nyolc szimbólumos bizonytalansága van

Szeretnénk inkább összeadni az információ mértékét.

LOGARITMUS

- ▶ Megoldható: első gép $\log(4)$ második $\log(2)$ mértékű bizonytalanságot csökkent, akkor
- ▶ egymás után $\log(4) + \log(2) = \log(8)$
- ▶ a kombinált gép szintén $\log(8)$

EMLÉKEZTETŐ

$$\log(ab) = \log(a) + \log(b)$$

KETTES ALAPÚ LOGARITMUS

- ▶ Mindegy, hogy mi a logaritmus alapja.
- ▶ Ha $\log_2()$ -t használunk, **bit**-ben kapjuk a mértéket.
- ▶ Két szimbólum esetén $\log(2) = 1$ bit a bizonytalanság csökkenés.
- ▶ $\log_2(1) = 0$ bit. Ez mit jelent?

A BARKOCHBA JÁTÉKUNK

- ▶ 32 ember közül gondoltam egyre. Hány kérdésből található ki, hogy kire?
- ▶ És ha előre meg kell mondani a kérdéseket?

A BARKOCHBA JÁTÉKUNK

- ▶ 32 ember közül gondoltam egyre. Hány kérdésből található ki, hogy kire?
- ▶ És ha előre meg kell mondani a kérdéseket?
- ▶ Minden embert számozzunk meg és a sorszámát írjuk fel binárisan.
- ▶ 00000, 00001, 00010, 00011, 00100, 00101, 00110, 00111...
- ▶ 5 kérdés az 5 számjegyre vonatkozik.

A BARKOCHBA JÁTÉKUNK

- ▶ 32 ember közül gondoltam egyre. Hány kérdésből található ki, hogy kire?
- ▶ És ha előre meg kell mondani a kérdéseket?
- ▶ Minden embert számozzunk meg és a sorszámát írjuk fel binárisan.
- ▶ 00000, 00001, 00010, 00011, 00100, 00101, 00110, 00111...
- ▶ 5 kérdés az 5 számjegyre vonatkozik.
- ▶ ZH kérdés: 23 binárisan?

INFORMÁCIÓ MÉRTÉKE

- ▶ N elemű (szimbólum) halmazból egy kiválasztása
- ▶ $\log_2(N)$ bit információt jelent
- ▶ Ügyesen kódolva a választás $\log_2(N)$ biten leírható: sorba rendezzük és binárisan megszámozzuk

SZIMBÓLUMOK NEM EGYFORMA VALÓSZÍNŰSÉGGEL

- ▶ Tfh. tudjuk, hogy az első gép D -t soha nem adja ki.
Mennyi bizonytalanságunk csökken? $\log_2(3) < \log_2(4)$

EMLÉKEZTETŐ

$$\log(a) < \log(b) \leftrightarrow a < b$$

SZIMBÓLUMOK NEM EGYFORMA VALÓSZÍNŰSÉGGEL

- ▶ Tfh. tudjuk, hogy az első gép D -t soha nem adja ki. Mennyi bizonytalanságunk csökken? $\log_2(3) < \log_2(4)$
- ▶ Néha kiadja D -t, de csak ritkán. Mit várunk?

$$\log_2(N) = \log_2\left(\frac{1}{\frac{1}{N}}\right) = \log_2\left(\frac{1}{p}\right)$$

EMLÉKEZTETŐ

$$\log(a) < \log(b) \leftrightarrow a < b$$

INFORMÁCIÓ MÉRTÉKE

Egy X szimbólum vételekor kapott információ:

$$I(X) = \log_2\left(\frac{1}{P}\right) = -\log_2(P),$$

ahol P X valószínűsége.

- ▶ $I(\text{fej}) = 1$ bit, mert $P(\text{fej}) = \frac{1}{2}$
- ▶ Ha tudjuk, hogy csak fej lehet, akkor $I(\text{fej}) = 0$ bit.
- ▶ Valami minél ritkább, annál nagyobb az információ tartalma.

EMLÉKEZTETŐ

$P(X) = \frac{k}{N}$, azaz N esetből k -szor az X szimbólumot kapjuk (körülbelül).

NEM MINDEN IGEN/NEM KÉRDÉS 1 BITES

- ▶ Kisasszony, szereti a sajtót?
- ▶ Kisasszony, hozzám jön feleségül?
- ▶ Kisasszony, nyert múlt héten a lottón?

Formálisabban, ha N elemű halmaz minden elemére
 $P = \frac{1}{N} \leftrightarrow \log_2(N)$ bit egy kiválasztása.

BUTA TORPEDÓ

Egy 8x8 táblán, elrejték egy torpedót, bárhova tehettem, nincsen preferált cellám. Ki kell találni, hol van.

	1	2	3	4	5	6	7	8
A								
B								
C								
D								
E								
F								
G								
H								

BUTA TORPEDÓ

- ▶ Mennyi információt jelent, ha megmondom hol van.
- ▶ Hány kérdésből lehet biztos kitalálni?
- ▶ Hány igen/nem kérdésből lehet biztos kitalálni?
- ▶ Mennyi az esélye, hogy elsőre kitalálsz?

MENNYI INFORMÁCIÓ?

Alakítsuk át a feladatot Shannon modelljének megfelelően.

- ▶ Valaki kérdéseket tesz fel, amire én válaszolok.
- ▶ Úgy, hogy előre rögzített szimbólum halmazból választhatok.
- ▶ Csatorna nem fontos, zaj nincs.

FORMÁLIS ÉS GYORS MEGOLDÁS

- ▶ 64 lehetséges helyre tehettem a torpedót
- ▶ Számozzuk meg a cellákat 0, 1, 2, ...63
- ▶ Kódoljuk le binárisan. $\log_2(64) = 6$ bit szükséges
- ▶ Tehát, ha én minden cellát egyenlő valószínűséggel választom, akkor is 6 kérdésből ki lehet találni.
- ▶ (Megj: ha tudod, hogy inkább középre szoktam tenni a torpedót, akkor átlagban könnyebb kitalálnod.)

FORMÁLIS ÉS GYORS MEGOLDÁS

- ▶ 64 lehetséges helyre tehettem a torpedót
- ▶ Számozzuk meg a cellákat 0, 1, 2, ...63
- ▶ Kódoljuk le binárisan. $\log_2(64) = 6$ bit szükséges
- ▶ Tehát, ha én minden cellát egyenlő valószínűséggel választom, akkor is 6 kérdésből ki lehet találni.
- ▶ (Megj: ha tudod, hogy inkább középre szoktam tenni a torpedót, akkor átlagban könnyebb kitalálnod.)

Megmutatom, hogy az információ mértéke ennél univerzálisabb.

MELYIK A JOBB STRATÉGIA?

1. Hol van?
64 szimbólum valamelyike $A1, A2, A3 \dots H8$
2. Melyik oszlopban van? Melyik sorban van?
Mindkét esetben 8 szimbólumom van: $1, 2 \dots 8, A, B \dots H$, de két kérdés csak.
3. $G3$ -n van? $B1$ -n van? $\dots E5$ -n van?
Két szimbólum (igen, nem), de maximum 64 kérdés kell.
4. 1.,2.,3.,4. oszlopban van? A, B, C, D sorban van? Két szimbólum (igen, nem), hány kérdés?

MENNY INFORMÁCIÓ?

1. Hol van? $\log_2\left(\frac{1}{64}\right) = 6\textit{bit}$
2. Melyik oszlopban van? $\log_2\left(\frac{1}{8}\right) = 3\textit{bit}$ + Melyik sorban van? $\log_2\left(\frac{1}{8}\right) = 3\textit{bit} \rightarrow 6\textit{bit}$

MENNY INFORMÁCIÓ?

1, 1-n van? 1, 2-n van? ... 8, 8-n van?

- ▶ Mennyi a valószínűsége, hogy elsőre kitalálod?

$$P(1, \text{igen}) = \frac{1}{64}$$


- ▶ Kicsi eséllyel kitalálható, de mennyire lepődünk ezen meg?

- ▶ Inkább: $P(1, \text{nem}) = \frac{63}{64} \rightarrow 0.0227$ bit

- ▶ Aztán: $P(2, \text{nem}) = \frac{62}{63} \rightarrow 0.0230$ bit






BEUGRÓSZINTŰ ZH KÉRDÉS.

Már 62-t találgattál. Egyszer sem talált. Rákérdezel a 63. cellára. Mi az információ tartalma, hogy „nem, nem ott van” és az „ott van” válaszoknak?








Az n. kérdésre kapott "nem" válasz információ tartalma.

49. kérdésre kitalálsz. Mennyi információt kapsz?



move #	1	2	32	48	49
question	G3	B1	E5	F3	H3
outcome	$x = n$	$x = n$	$x = n$	$x = n$	$x = y$
$P(x)$	$\frac{63}{64}$	$\frac{62}{63}$	$\frac{32}{33}$	$\frac{16}{17}$	$\frac{1}{16}$
$h(x)$	0.0227	0.0230	0.0443	0.0874	4.0
Total info.	0.0227	0.0458	1.0	2.0	6.0

49. kérdésre kitalálsz. Mennyi információt kapsz?



move #	1	2	32	48	49
question	G3	B1	E5	F3	H3
outcome	$x = n$	$x = n$	$x = n$	$x = n$	$x = y$
$P(x)$	$\frac{63}{64}$	$\frac{62}{63}$	$\frac{32}{33}$	$\frac{16}{17}$	$\frac{1}{16}$
$h(x)$	0.0227	0.0230	0.0443	0.0874	4.0
Total info.	0.0227	0.0458	1.0	2.0	6.0

Örület. Ez is 6 bit.

Akárhányadikra találsz ki, mindig 6 bit. Már csak k maradt.

$$\begin{aligned} \log_2 \frac{64}{63} + \log_2 \frac{63}{62} + \dots + \log_2 \frac{k+1}{k} + \log_2 \frac{k}{1} \\ = \log_2 \left(\frac{64}{63} \times \frac{63}{62} \times \dots \times \frac{k+1}{k} \times \frac{k}{1} \right) \\ = \log_2(64) \end{aligned}$$

FELEZGETŐS MÓDSZER

- ▶ Mindig olyan kérdést teszel fel, ami a lehetséges cellák számát pont felezi.
- ▶ Ez igen/nem kérdéssel feltehető.
- ▶ Minden esetben ugyanolyan valószínűséggel várod az igen-t és a nem-et.
- ▶ Minden válasz 1 bit információt ad.
- ▶ Hány kérdés kell?

FELEZGETŐS MÓDSZER

- ▶ Mindig olyan kérdést teszel fel, ami a lehetséges cellák számát pont felezi.
- ▶ Ez igen/nem kérdéssel feltehető.
- ▶ Minden esetben ugyanolyan valószínűséggel várod az igen-t és a nem-et.
- ▶ Minden válasz 1 bit információt ad.
- ▶ Hány kérdés kell? 6 bit

HOL AZ INFORMÁCIÓ?

- ▶ Mindegy, hogy milyen stratégiával kérdezel, összesen mindig 6 bit információt adok, mire kiderül, hol a torpedó.
- ▶ Minden cellára rákérdezés esetén a 32. nem után 1 bitet kapsz összesen. Ugyanannyit, mint a felezgetős módszer első kérdése után.
- ▶ A módszerek különböznek a szükséges kérdésszámban, de az információ nyereség mindig ugyanannyi (az a játék része).
- ▶ Ugyanannyi információt lehet a torpedóval lekódolni, mint a *gondoltam egy számra 1–64 között*

HOL A KOMMUNIKÁCIÓ ?

- ▶ Tüntető 64 lehetséges helyszín valamelyikét a tüntetés előtt választják ki véletlenszerűen, hogy a rendőrség ne tudjon előre felkészülni. Nem beszélhetnek egymással, nem telefonálhatnak.
- ▶ A vezető kiválasztja a helyszínt és szeretne 6 bit információt átküldeni mindenkinek.
- ▶ Előre megállapodtak egy kódrendszerben: egy szabadtéri saktáblán otthagynak egy befejezett sakjátszmát.
- ▶ Mindenki tudja, hogy melyik cella melyik helyszínt jelenti.
- ▶ A fekete király helye mutatja a tüntetés helyét.

MI A KÓDOLÁS?

Mindenkinek ismernie kell a 64 helyszínt és egy kódtáblázatot.

Oktogon	A1
Kossuth tér	A2
...	
Blaha	H8

És, hogy a sakktábla melyik cellája melyik sornak felel meg.

6 BITET ÁTVINNI ZAJOS CSATORNÁN

Néha elkezdenek játszani a gyerekek a téren és arrébb teszik a fekete királyt. Jobb módszer kéne.

6 BITET ÁTVINNI ZAJOS CSATORNÁN

Holnap 12 után minden órában megcsörgetlek egyszer, vagy nem. Ez 6 db. igen/nem (két szimbólumos) döntés.

- ▶ $P = 0.05$ a valószínűsége, hogy nincs téreőrő vagy véletlenül felhívlak.
- ▶ A zaj miatt minden bit csak $P = 0.95$ valószínűséggel megy át. 6 bit 73.5%, hogy hibátlanul átmegy.
- ▶ Ráadásul nem is tudsz arról, hogy hiba történt.
- ▶ Mit tehetünk?

ÁTVITEL ZAJOS CSATORNÁN

Shannon ezzel foglalkozott és nem nyelvészettel.


- ▶ Hibadetektálás: A hetedik alkalommal felhívlak, ha előtte páros esetben akartam telefonálni. Feltehetőleg észreveszed, ha baj volt.

Figyelem: Ha nincs zaj és ezt Te is tudod, akkor a 7 hívás információ tartalma 0 bit lenne. (Ha tudod, hogy mit jelentenek a hívások!)

- ▶ Hibajavítás: minden órában háromszor telefonálok. Ezzel egy hibát tudunk javítani.

KÉPÁTVITEL ZAJOS CSATORNÁN

100x100 bitben kódolok egy fekete–fehér képet. A biteket átküldöm egy csatornán, de az néhány bitet invertál. $f = 0.1$



MILYEN ZAJ LEHET?

Igazából nincs zajmentes csatorna.

- ▶ Átrakják a fekete királyt.
- ▶ A disk néha bitek ront el.
- ▶ Telefonvonalat zavarja, ha bekapcsol valaki egy porszívót.
- ▶ Zajként értelmezhető a DNS átadás közbeni „hiba” is.

A kommunikáció maximális sebességét három dolog határozza meg:

- ▶ A fénysebesség.
- ▶ A csatorna zaja.
- ▶ Az elérni kívánt hibaszázalék.

HIBATŰRŐ KÓDOLÁS

Minden bitet háromszor küldök el. Ha egy hármas blokkban csak egy bit vész el, akkor korrigálni tudom a hibát.

s	0	0	1	0	1	1	0
t	$\underbrace{000}$	$\underbrace{000}$	$\underbrace{111}$	$\underbrace{000}$	$\underbrace{111}$	$\underbrace{111}$	$\underbrace{000}$
n	000	001	000	000	101	000	000
r	$\underbrace{000}$	$\underbrace{001}$	$\underbrace{111}$	$\underbrace{000}$	$\underbrace{010}$	$\underbrace{111}$	$\underbrace{000}$
\hat{s}	0	0	1	0	0	1	0

corrected errors

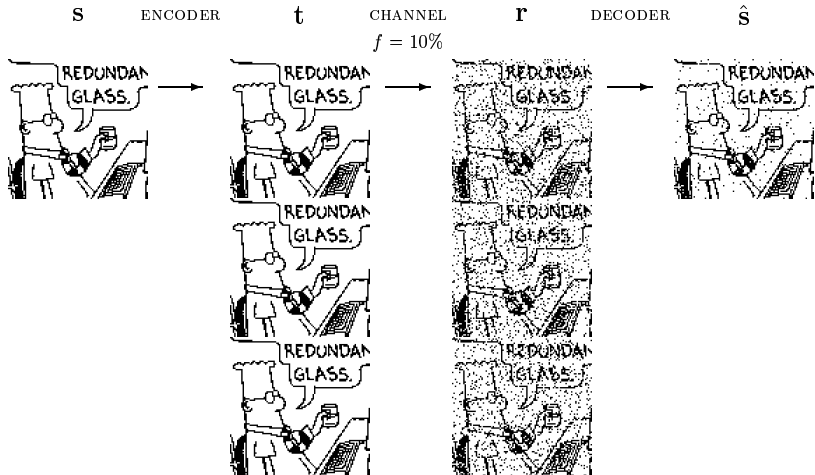
★

undetected errors

★

NEM MINDEN HIBÁT TUDTAM JAVÍTANI

Az eredmény sokkal jobb, de nem 100%-os (elvileg nem is lehet).




REDUNDANCIA

- ▶ A hibatűrő kódolásnak ára van. 30 000 bitet kellett használnom. 3x annyi idő átküldeni.
- ▶ 20 000 bit redundáns, ha nincs zaj.
- ▶ Fordítva gondolkozva: redundancia kiszűrése a tömörítés.

TÖMÖRÍTÜK A KÉPET

Sok fehér folt van egymás mellett.

1. `ww`, `bw`, `wb`, `bb` szimbólumokat használok, és észreveszem, hogy sokkal több a `ww`, mint a `bb`
`ww` - 0 `wb` - 10 `bw` - 110 `bb` - 111
2. Egymás mellett 12 fehér pont legyen 12:0 alakban kódolva. (köv ábra)




```
000000000000 12:0
000000000000 12:0
000001100000 5:0,2:1,5:0
000001100000 5:0,2:1,5:0
000001100000 5:0,2:1,5:0
001111111100 2:0,8:1,2:0
001111111100 2:0,8:1,2:0
000001100000 5:0,2:1,5:0
000001100000 5:0,2:1,5:0
000001100000 5:0,2:1,5:0
000000000000 12:0
000000000000 12:0
```

requires 144 bits

requires 104 bits

30% compression



```
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...  
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...  
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...  
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...  
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...  
010101010101 1:0,1:1,...  
101010101010 1:1,1:0,...
```

requires 144 bits

requires 564 bits

Van, amikor nem jó ez a kódolás.

SZÖVEGTÖMÖRÍTÉS - NINCS ZAJ!

- ▶ Emlékszünk, a gyakori szavakat rövidítjük.
- ▶ Ezzel az össz karakter szám csökken.
- ▶ Vagy másképp: az átlagos karakter/szó igény.

PÉLDA

- ▶ Kocsikat kell számlálni nyári munkában. Pontosabban egy elhaladó kocsiknak le kell írnod egymás után a színét.
 - ▶ Észrevesszük, hogy nem egyenletes a színek eloszlása
- | | |
|-------|-----|
| fehér | 50% |
| kék | 25% |
| piros | 25% |
- ▶ Találjunk olyan kódolást, ami a lehető legrövidebb munkát adja!

EGYENLETES KÓDOLÁS

Minden szín kap egy bináris számot.

fehér	50%	00
kék	25%	01
piros	25%	10

Mennyi a várható bit szükséglet? $N = 100$ kocsi haladt el.

EGYENLETES KÓDOLÁS

Minden szín kap egy bináris számot.

fehér	50%	00
kék	25%	01
piros	25%	10

Mennyi a várható bit szükséglet? $N = 100$ kocsi haladt el.

$$L = 0.5 * 100 * 2 + 0.25 * 100 * 2 + 0.25 * 100 * 2 = 200bit$$

EMLÉKEZTETŐ

p valószínűségű dolog N esetből körülbelül $p * N$ esetben fordul elő. U.n. nagyszámok törvénye.

KICSIT ÁLTALÁNOSABBAN

Van három szimbólum, p_1, p_2, p_3 valószínűséggel fordulnak elő és l_1, l_2, l_3 a hosszúságuk, akkor egy N szimbólumos üzenet várható hossza körülbelül

$$L = p_1 * N * l_1 + p_2 * N * l_2 + p_3 * N * l_3$$

Az átlagos kódolási bit szükséglet

$$\frac{L}{N} = p_1 * l_1 + p_2 * l_2 + p_3 * l_3$$

MENNYI INFORMÁCIÓT KELL LEKÓDOLNOM.

Mennyi információt jelent, ha egy-egy színt látok?

fehér	50%	$\log_2(2)$	1 bit
kék	25%	$\log_2(4)$	2 bit
piros	25%	$\log_2(4)$	2 bit

MENNYI INFORMÁCIÓT KELL LEKÓDOLNOM.

Mennyi információt jelent, ha egy-egy színt látok?

fehér	50%	$\log_2(2)$	1 bit
kék	25%	$\log_2(4)$	2 bit
piros	25%	$\log_2(4)$	2 bit

Mennyi információt fogok kapni $N = 100$ kocsi után?

$$h = 0.5*100*1 + 0.25*100*2 + 0.25*100*2 = 50 + 50 + 50 = 150 \text{ bit}$$

200 biten kódoltam le 150 bit információt! Hol a bibi?

ÜGYES KÓDOLÁS.

Értelemszerűen a gyakoribb fehér színnek rövidebb kódot kéne választani, és fölösleges volt a 11 szimbólum. (emlékszünk? a gép, ami D -t sohasem adott ki, de mi ezt nem tudtuk)

fehér	50%	$\log_2(2)$	1 bit	0
kék	25%	$\log_2(4)$	2 bit	10
piros	25%	$\log_2(4)$	2 bit	11

A kódolás jónak tűnik. Az üzenet hossza:

ÜGYES KÓDOLÁS.

Értelemszerűen a gyakoribb fehér színnek rövidebb kódot kéne választani, és fölösleges volt a 11 szimbólum. (emlékszünk? a gép, ami D -t sohasem adott ki, de mi ezt nem tudtuk)

fehér	50%	$\log_2(2)$	1 bit	0
kék	25%	$\log_2(4)$	2 bit	10
piros	25%	$\log_2(4)$	2 bit	11

A kódolás jónak tűnik. Az üzenet hossza:

$$h = 0.5 * 100 * 1 + 0.25 * 100 * 2 + 0.25 * 100 * 2 = 50 + 50 + 50 = 150 \text{ bit}$$

150 bit információt 150 biten kódoltam (két jelentése van a bit szónak?)

MIT IS CSINÁLTUNK ÁLTALÁNOSABBAN?

Ha van k szimbólumom, amik valószínűsége p_1, p_2, \dots, p_k

- ▶ A k . szimbólum megjelenésének információ tartalma

$$h_k = \log \frac{1}{p_k}$$

- ▶ N hosszú üzenet várható információ tartalma

$$h(M) = p_1 * N * h_1 + p_2 * N * h_2 \dots p_k * N * h_k$$

- ▶ Egy-egy szimbólum észlelésének átlagos információ tartalma

$$H = p_1 * h_1 + p_2 * h_2 \dots p_k * h_k$$

ENTRÓPIA

Ha van k szimbólumom, amik valószínűsége p_1, p_2, \dots, p_k

$$H = \sum_i^k p_k \log \frac{1}{p_k}$$

Az átlagos várható információ minden egyes szimbólum fogadásánál.

ENTRÓPIA

Igazából ez a fontos fogalom.

- ▶ Megadja mennyire nem egyenletesen jönnek egymás után a szimbólumok.
- ▶ Fej vagy írás entrópiája 1 bit.
- ▶ Buta torpedóban a naív kérdés esetén elsőre mit várhatunk?

$$\frac{1}{64} * \log_2 64 + \frac{63}{64} + \log_2 \frac{64}{63} = 0.1160953125$$

Rosszul kérdeztünk, mert a várható információ kicsi.

Letter	Probability of Use in English Text	Code 1	Code 2	Code 3
(Space)	0.1859	00000	00	000
A	0.0642	00001	10100	0100
B	0.0127	00010	0111100	011111
C	0.0218	00011	01101100	11111
D	0.0317	00100	011100	01011
E	0.1031	00101	100	101
F	0.0208	00110	1101100	001100
G	0.0152	00111	0101100	011101
H	0.0467	01000	111100	1110
I	0.0575	01001	1100	1000
J	0.0008	01010	101010100	0111001110
K	0.0049	01011	0110100	01110010
L	0.0321	01110	01100	1001
M	0.0198	01101	010100	001101
N	0.0574	01110	01100	1001
O	0.0632	01111	01010100	0110
P	0.0152	10000	10101100	011110
Q	0.0008	10001	010110100	0111001101
R	0.0484	10010	101100	1101
S	0.0514	10011	11100	1100
T	0.0796	10100	0100	0010
U	0.0228	10101	1100100	11110
V	0.0083	10110	1110100	0111000
W	0.0175	10111	1010100	001110
X	0.0013	11000	01110100	0111001100
Y	0.0164	11001	011010100	00111
Z	0.0005	11010	01011100	0111001111