

La Compression Des Données

Jalal Fadili

Centenaire de la naissance de Claude Shannon



1916-2001

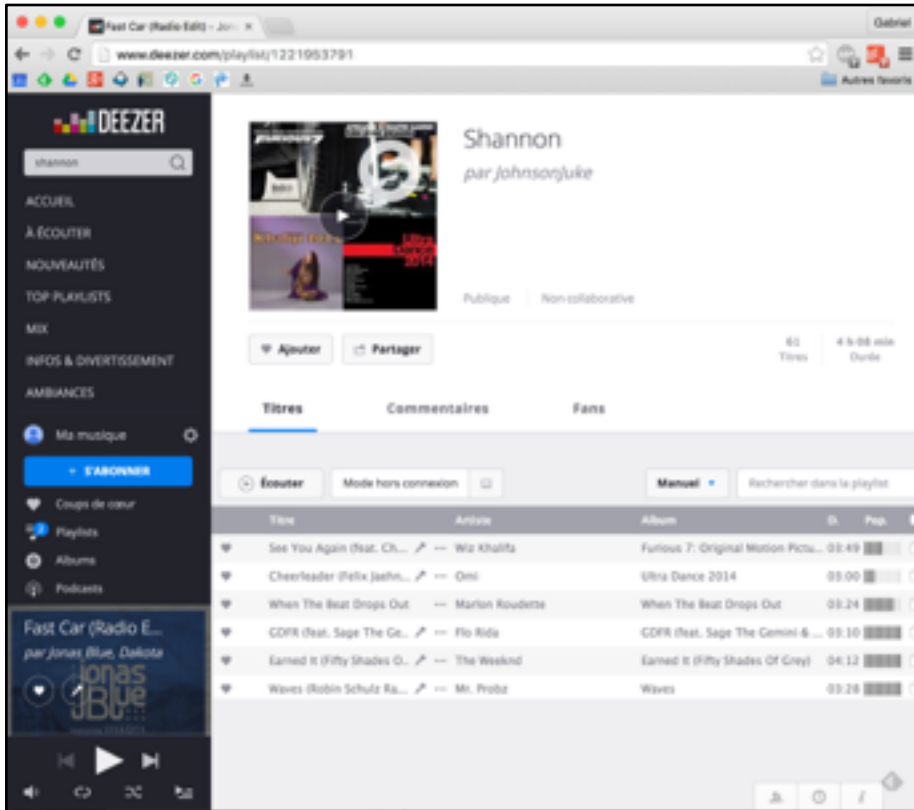


Normandie Université



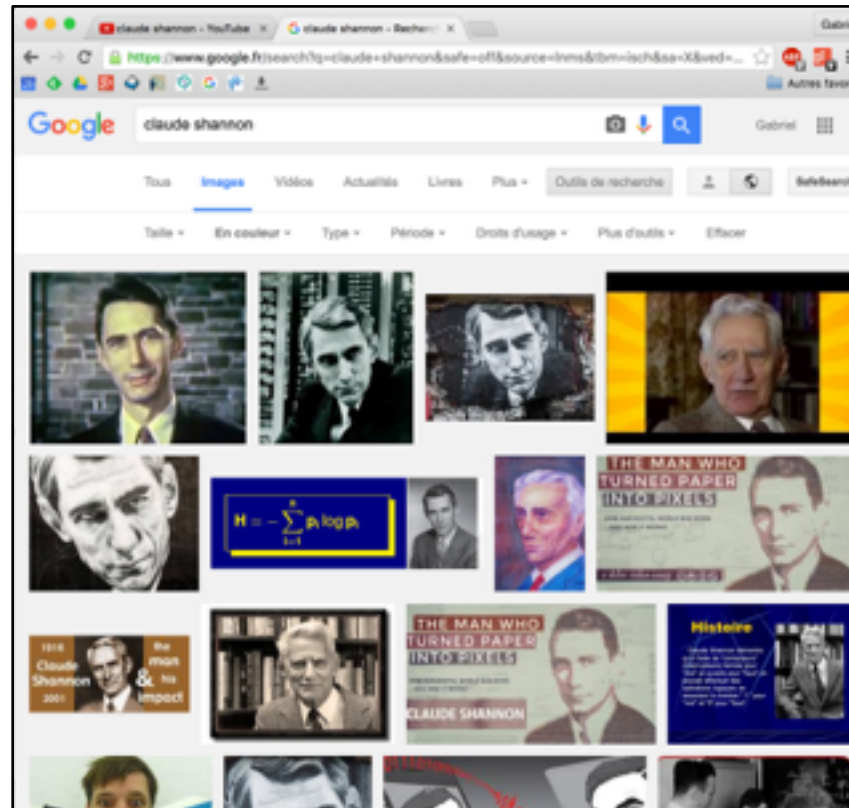
Données, information, communication

www.deezer.com



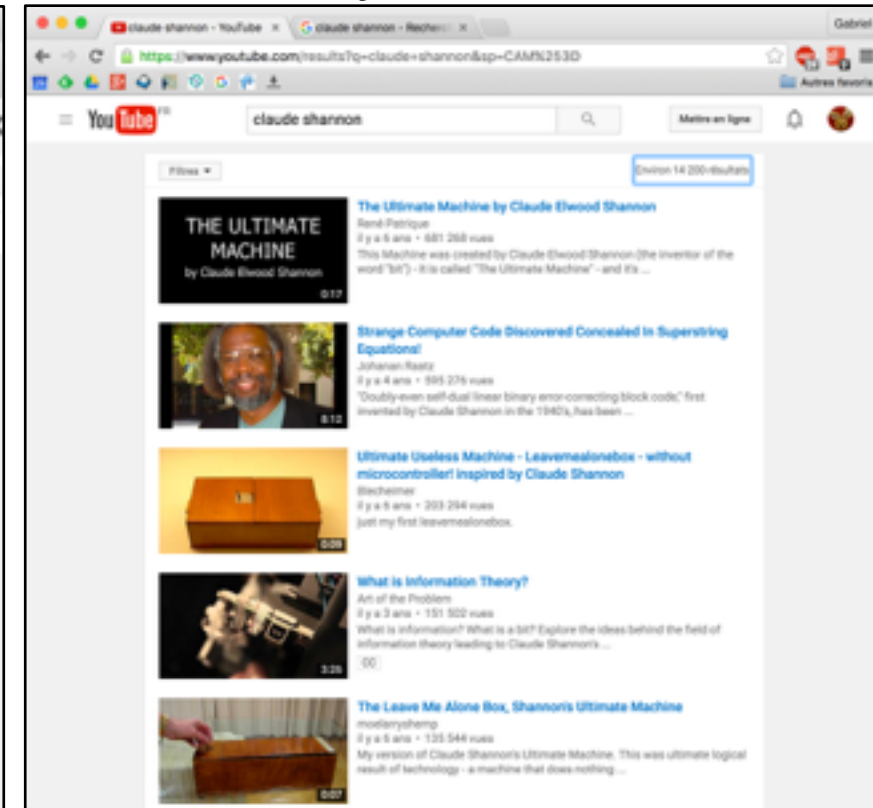
musique

www.google.com/imghp



images

www.youtube.com




vidéos



3D, cinéma, jeux vidéos



réseaux sociaux



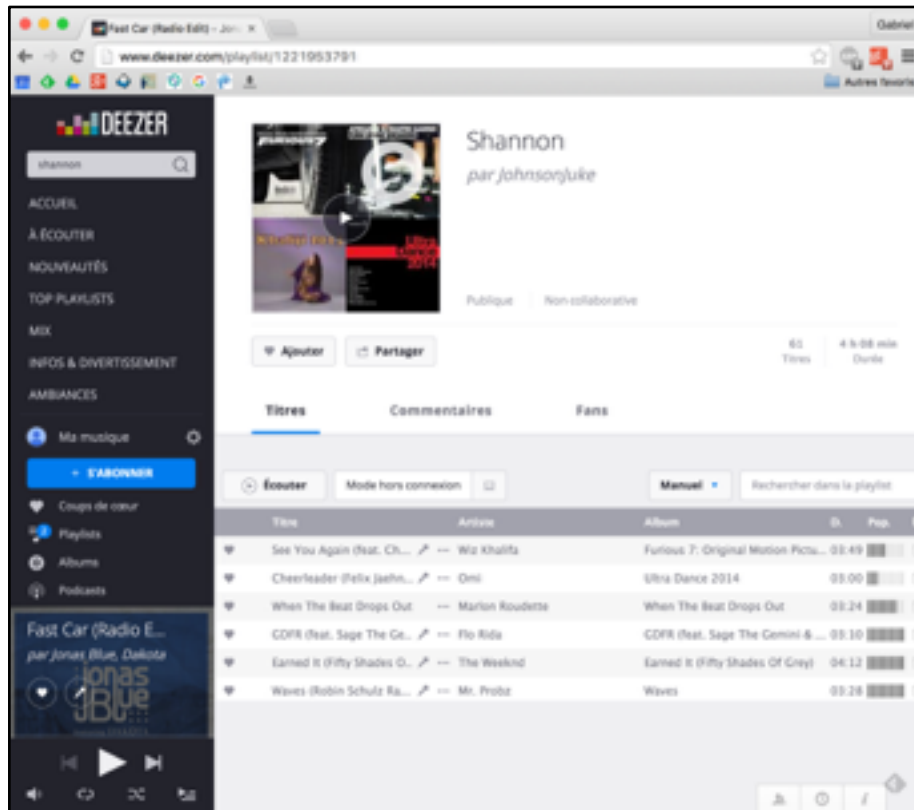
scanner, imagerie

Données, information, communication

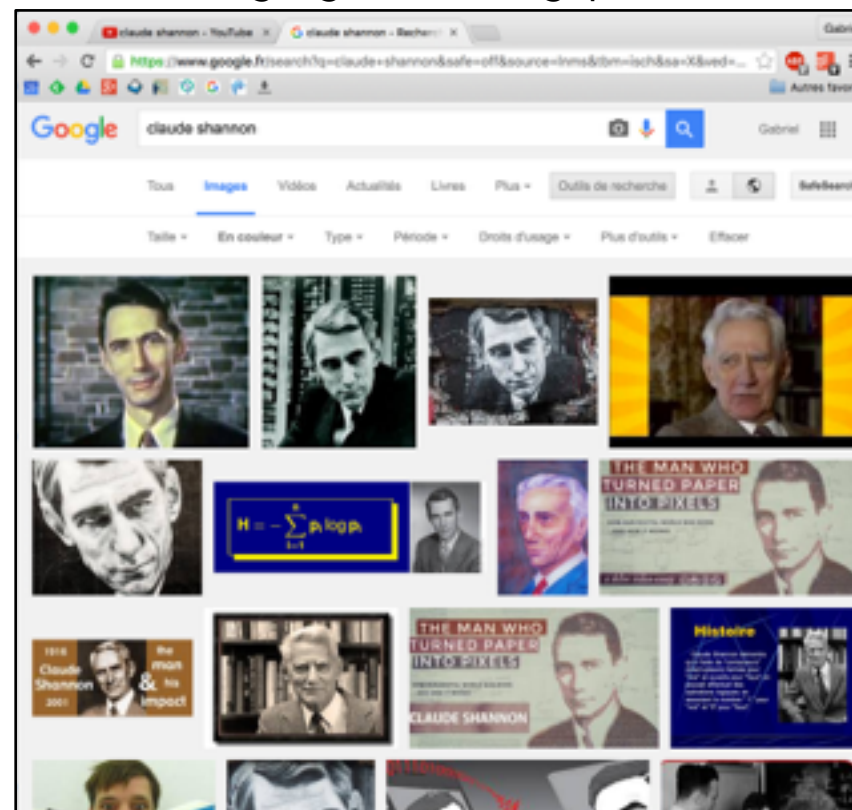
www.deezer.com

www.google.com/imghp

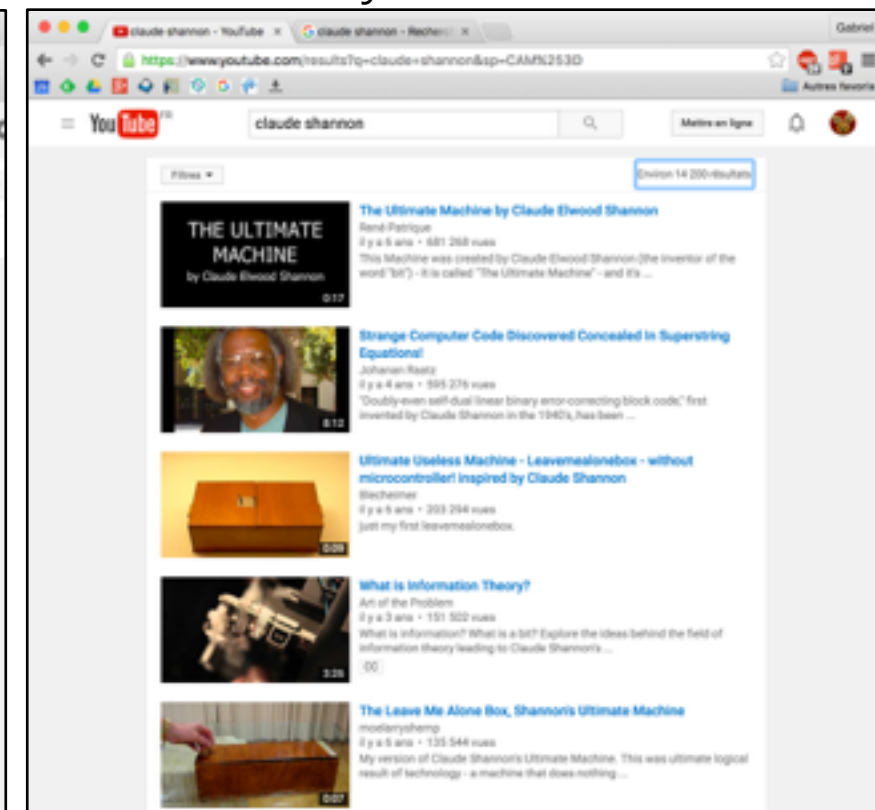
www.youtube.com



musique



images



vidéos



3D, cinéma, jeux vidéos



réseaux sociaux



scanner, imagerie

3 problèmes : acquérir / stocker / transmettre ces données.

Types de compression

- Soit d une donnée à compresser.
- Un algorithme de codage/compression $C : d \mapsto C(d)$.
- Un algorithme de décodage/décompression $D : c \mapsto D(c)$.
- Compression conservative si $D(C(d)) = d$.
- Compression non-conservative si $D(C(d)) \neq d$ mais $D(C(d)) \approx d$.

Types de compression

- Soit d une donnée à compresser.
- Un algorithme de codage/compression $C : d \mapsto C(d)$.
- Un algorithme de décodage/décompression $D : c \mapsto D(c)$.
- Compression conservative si $D(C(d)) = d$.
- Compression non-conservative si $D(C(d)) \neq d$ mais $D(C(d)) \approx d$.



PNG

Types de compression

- Soit d une donnée à compresser.
- Un algorithme de codage/compression $C : d \mapsto C(d)$.
- Un algorithme de décodage/décompression $D : c \mapsto D(c)$.
- Compression conservative si $D(C(d)) = d$.
- Compression non-conservative si $D(C(d)) \neq d$ mais $D(C(d)) \approx d$.



PNG

\approx



JPEG (Q=25%)

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$$[\dots a_3 a_2 a_1 a_0]_2 \text{ représente } a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$[\dots a_3 a_2 a_1 a_0]_2$ représente $a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.

Codage des nombres $\{0, 1, 2, 3\}$:

$$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$$

$$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$$

$$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$$

$$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$$

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$[\dots a_3 a_2 a_1 a_0]_2$ représente $a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.


Codage des nombres $\{0, 1, 2, 3\}$:

$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$

$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$

$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$

$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$



Codage uniforme : représentation binaire

Écriture binaire (base 2):

$[\dots a_3 a_2 a_1 a_0]_2$ représente $a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.

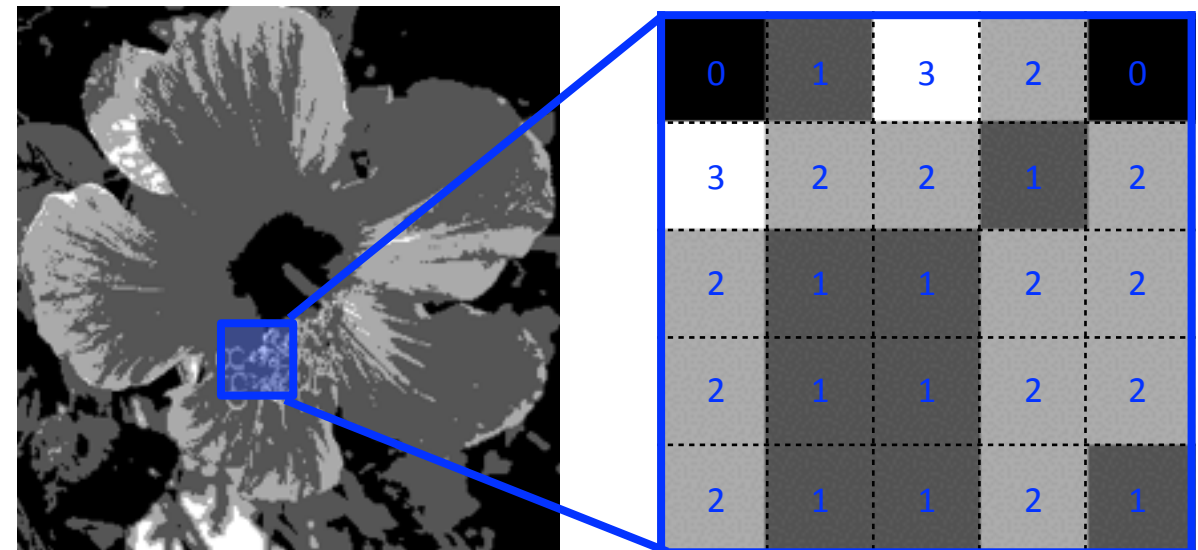
Codage des nombres $\{0, 1, 2, 3\}$:

$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$

$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$

$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$

$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$



Codage uniforme : représentation binaire

Écriture binaire (base 2):

$[\dots a_3 a_2 a_1 a_0]_2$ représente $a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.


Codage des nombres $\{0, 1, 2, 3\}$:

$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$

$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$

$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$

$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$



0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$[\dots a_3 a_2 a_1 a_0]_2$ représente $a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.


Codage des nombres $\{0, 1, 2, 3\}$:

$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$

$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$

$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$

$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$



codage

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
00	01	11	10	00	11	10	10	01	10	10	01	01	10	10	10	01	01	10	10	01	01	10	01

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$$[\dots a_3 a_2 a_1 a_0]_2 \text{ représente } a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.



Codage des nombres $\{0, 1, 2, 3\}$:

$$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$$

$$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$$

$$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$$

$$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$$



Code à envoyer: **000111100011101001101001011010100101101001011001**

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$$[\dots a_3 a_2 a_1 a_0]_2 \text{ représente } a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.



Codage des nombres $\{0, 1, 2, 3\}$:

$$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$$

$$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$$

$$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$$

$$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$$



Code à envoyer: **000111100011101001101001011010100101101001011001**

Chaque symbole 0 ou 1 correspond à 1 **bit**.

Codage uniforme : représentation binaire

Écriture binaire (base 2):

$$[\dots a_3 a_2 a_1 a_0]_2 \text{ représente } a_0 2^0 + a_1 2^1 + a_2 2^2 + a_3 2^3 + \dots$$

Exemple: $[110]_2 = [1 \times 4 + 1 \times 2 + 0 \times 1]_{10} = [6]_{10}$.



Codage des nombres $\{0, 1, 2, 3\}$:

$$[0]_{10} = [0]_2 \rightarrow \text{code} = 00$$

$$[1]_{10} = [1]_2 \rightarrow \text{code} = 01$$

$$[2]_{10} = [10]_2 \rightarrow \text{code} = 10$$

$$[3]_{10} = [11]_2 \rightarrow \text{code} = 11$$



Code à envoyer: **000111100011101001101001011010100101101001011001**

Chaque symbole 0 ou 1 correspond à 1 **bit**.

Décodage: découper en bloc de 2 bits.

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

N symboles $\{0, 1, \dots, N - 1\} \rightarrow$ besoin de $\lceil \log_2(N) \rceil$ bits/symbole.

Exemple: $N = 16 = 2^4 \rightarrow$ besoin de $\log_2(16) = 4$ bits/symbole.

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

N symboles $\{0, 1, \dots, N - 1\} \rightarrow$ besoin de $\lceil \log_2(N) \rceil$ bits/symbole.

Exemple: $N = 16 = 2^4 \rightarrow$ besoin de $\log_2(16) = 4$ bits/symbole.

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111

4 symboles $\{0, 1, 2, 3\} \rightarrow$ besoin de 2 bits par symbole.

0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
00	01	11	10	00	11	10	10	01	10	10	01	01	10	10	10	01	01	10	10	01	01	10	01

Code à envoyer: **000111100011101001101001011010100101101001011001** \rightarrow 50 bits.

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

N symboles $\{0, 1, \dots, N - 1\} \rightarrow$ besoin de $\lceil \log_2(N) \rceil$ bits/symbole.

Exemple: $N = 16 = 2^4 \rightarrow$ besoin de $\log_2(16) = 4$ bits/symbole.

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111

4 symboles $\{0, 1, 2, 3\} \rightarrow$ besoin de 2 bits par symbole.

0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
00	01	11	10	00	11	10	10	01	10	10	01	01	10	10	10	01	01	10	10	01	01	10	01

Code à envoyer: **000111100011101001101001011010100101101001011001** \rightarrow 50 bits.

Peut-on faire mieux?

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

N symboles $\{0, 1, \dots, N - 1\} \rightarrow$ besoin de $\lceil \log_2(N) \rceil$ bits/symbole.

Exemple: $N = 16 = 2^4 \rightarrow$ besoin de $\log_2(16) = 4$ bits/symbole.

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111

4 symboles $\{0, 1, 2, 3\} \rightarrow$ besoin de 2 bits par symbole.

0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
00	01	11	10	00	11	10	10	01	10	10	01	01	10	10	10	01	01	10	10	01	01	10	01

Code à envoyer: **000111100011101001101001011010100101101001011001** \rightarrow 50 bits.

Peut-on faire mieux? $0 \rightarrow 001$, $1 \rightarrow 01$, $2 \rightarrow 1$, $3 \rightarrow 000$

Cas général et codage à longueur variable

CAS GÉNÉRAL

Logarithme en base 2: $\ell = \log_2(N)$ est l'unique réel tel que $2^\ell = N$.

Exemples: $\log_2(2) = 1$, $\log_2(4) = 2$, $\log_2(6) \approx 2.585 \dots$

N symboles $\{0, 1, \dots, N - 1\} \rightarrow$ besoin de $\lceil \log_2(N) \rceil$ bits/symbole.

Exemple: $N = 16 = 2^4 \rightarrow$ besoin de $\log_2(16) = 4$ bits/symbole.

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15
0000	0001	0010	0011	0100	0101	0110	0111	1000	1001	1010	1011	1100	1101	1110	1111

4 symboles $\{0, 1, 2, 3\} \rightarrow$ besoin de 2 bits par symbole.

0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
00	01	11	10	00	11	10	10	01	10	10	01	01	10	10	10	01	01	10	10	01	01	10	01

Code à envoyer: **000111100011101001101001011010100101101001011001** \rightarrow 50 bits.

Peut-on faire mieux? $0 \rightarrow 001$, $1 \rightarrow 01$, $2 \rightarrow 1$, $3 \rightarrow 000$

001	01	000	1	001	000	1	1	01	1	1	01	01	1	1	1	01	01	1	1	01	01	1	01
-----	----	-----	---	-----	-----	---	---	----	---	---	----	----	---	---	---	----	----	---	---	----	----	---	----

Code à envoyer: **00101000100100011011101011110101110101101** \rightarrow 41 bits.

Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101

Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe. → Se représente sous forme d'un arbre binaire.


Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.




Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.



Décodage et arbres binaires



Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.

0 → 001, 1 → 01, 2 → 1, 3 → 000




Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101


Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.



0 → 001, 1 → 01, 2 → 1, 3 → 000



Décodage: parcours de l'arbre.

00101000100100011011101011110101110101101

→ décode 0


Décodage et arbres binaires

Code reçu : 001010001001000110111010111101011101011101


Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.



0 → 001, 1 → 01, 2 → 1, 3 → 000



Décodage: parcours de l'arbre.

001010001001000110111010111101011101011101

→ décode 0

0 010001001000110111010111101011101011101

→ décode 1


Décodage et arbres binaires

Code reçu : 00101000100100011011101011110101110101101


Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.



0 → 001, 1 → 01, 2 → 1, 3 → 000



Décodage: parcours de l'arbre.

00101000100100011011101011110101110101101

→ décode 0

0 01000100100011011101011110101110101101

→ décode 1

0 1 000100100011011101011110101110101101

→ décode 3

Décodage et arbres binaires



Code reçu : 00101000100100011011101011110101110101101

Décodage non-ambiguë : aucun mot du code n'est le début d'un autre.

Code préfixe.

→ Se représente sous forme d'un arbre binaire.

0 → 001, 1 → 01, 2 → 1, 3 → 000



Décodage: parcours de l'arbre.

00101000100100011011101011110101110101101 → décode 0

0 01000100100011011101011110101110101101 → décode 1

0 1 000100100011011101011110101110101101 → décode 3

0 1 3 100100011011101011110101110101101 → décode 2 ...

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$$p_1 \approx 0.53, \quad p_2 \approx 0.19$$

Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$




$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$p_1 \approx 0.53$, $p_2 \approx 0.19$



Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



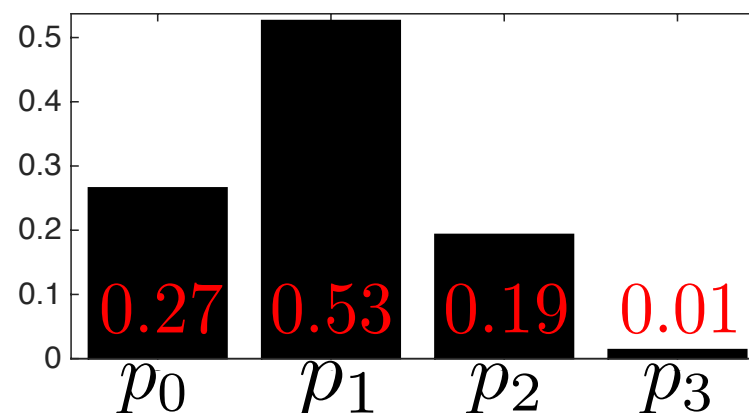

$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$p_1 \approx 0.53$, $p_2 \approx 0.19$

Entropie : $H(p) \stackrel{\text{def.}}{=} \sum_i p_i \log_2 \left(\frac{1}{p_i} \right)$



Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:



17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$$p_1 \approx 0.53, \quad p_2 \approx 0.19$$

Entropie :
$$H(p) \stackrel{\text{def.}}{=} \sum_i p_i \log_2 \left(\frac{1}{p_i} \right)$$

Propriété: $0 \leq H(p) \leq \log_2(N)$.



Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.




923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$p_1 \approx 0.53$, $p_2 \approx 0.19$

Entropie :
$$H(p) \stackrel{\text{def.}}{=} \sum_i p_i \log_2 \left(\frac{1}{p_i} \right)$$

Propriété: $0 \leq H(p) \leq \log_2(N)$.

$$H(p) = 0$$



Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$



$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.



923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.

$p_1 \approx 0.53$, $p_2 \approx 0.19$



Entropie :
$$H(p) \stackrel{\text{def.}}{=} \sum_i p_i \log_2 \left(\frac{1}{p_i} \right)$$

Propriété: $0 \leq H(p) \leq \log_2(N)$.

$$H(p) = 0$$



$$H(p) = \log_2(4) = 2$$



Entropie

Comment quantifier la quantité d'information d'une suite de symboles ?

p_i = fréquence d'apparition du symbole i .

$$p_0 + p_1 + p_2 + p_3 = 1$$




$256 \times 256 = 2^{16}$ pixels:

17432 pixels noirs $\rightarrow p_0 = \frac{17432}{2^{16}} \approx 0.27$.

923 pixels blanc $\rightarrow p_3 = \frac{923}{2^{16}} \approx 0.01$.


$p_1 \approx 0.53, \quad p_2 \approx 0.19$

Entropie :
$$H(p) \stackrel{\text{def.}}{=} \sum_i p_i \log_2 \left(\frac{1}{p_i} \right)$$




Propriété: $0 \leq H(p) \leq \log_2(N)$.


$$H(p) = 0$$



$$H(p) \approx 1.54$$



$$H(p) = \log_2(4) = 2$$



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.


Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Borne de Shannon

Théorème de Shannon:


si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$

Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$



Borne de Shannon

Théorème de Shannon:



si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$

Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$



$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$

Exemple:

$0 \rightarrow 10, \quad 1 \rightarrow 0, \quad 2 \rightarrow 110, \quad 3 \rightarrow 111$

$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$

Exemple:

$0 \rightarrow 10, \quad 1 \rightarrow 0, \quad 2 \rightarrow 110, \quad 3 \rightarrow 111$

$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$

$$\text{Long. moy.} = 0.27 \times 2 + 0.53 \times 1 + 0.19 \times 3 + 0.01 \times 3 = 1.67 \text{ bits/symbole.}$$



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$

Exemple:

$0 \rightarrow 10, \quad 1 \rightarrow 0, \quad 2 \rightarrow 110, \quad 3 \rightarrow 111$

$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$

$$\text{Long. moy.} = 0.27 \times 2 + 0.53 \times 1 + 0.19 \times 3 + 0.01 \times 3 = 1.67 \text{ bits/symbole.}$$

Codage uniforme
2 bits



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$

Exemple:

$0 \rightarrow 10, \quad 1 \rightarrow 0, \quad 2 \rightarrow 110, \quad 3 \rightarrow 111$

$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$

$$\text{Long. moy.} = 0.27 \times 2 + 0.53 \times 1 + 0.19 \times 3 + 0.01 \times 3 = 1.67 \text{ bits/symbole.}$$

Codage uniforme
2 bits

>

Codage variable
1.67 bits



Borne de Shannon

Théorème de Shannon:

si les symboles sont tirés au **hasard** selon la loi $(p_i)_i$
le nombre **moyen** de bits d'un code **préfixe** est supérieur à $H(p)$.

$H(p)$ faible \Leftrightarrow peu d'information \Leftrightarrow facile à coder.

$$H(p) \approx 1.54$$



Codage préfixe:

$0 \rightarrow c_0, \quad 1 \rightarrow c_1, \quad 2 \rightarrow c_2, \quad 3 \rightarrow c_3$

Exemple:

$0 \rightarrow 10, \quad 1 \rightarrow 0, \quad 2 \rightarrow 110, \quad 3 \rightarrow 111$

$$\text{Long. moy.} = p_0 \times \text{Long}(c_0) + p_1 \times \text{Long}(c_1) + p_2 \times \text{Long}(c_2) + p_3 \times \text{Long}(c_3)$$

$$\text{Long. moy.} = 0.27 \times 2 + 0.53 \times 1 + 0.19 \times 3 + 0.01 \times 3 = 1.67 \text{ bits/symbole.}$$

Codage uniforme
2 bits


>

Codage variable
1.67 bits

>


Entropie
1.54 bits

Comment faire mieux?



→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.

Comment faire mieux?




→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---

0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

0	1	3	2	0	3	2	2	1	2	2	1	1	2	2	2	1	1	2	2	1	1	2	1
---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---	---


0																								
---	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--	--

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1

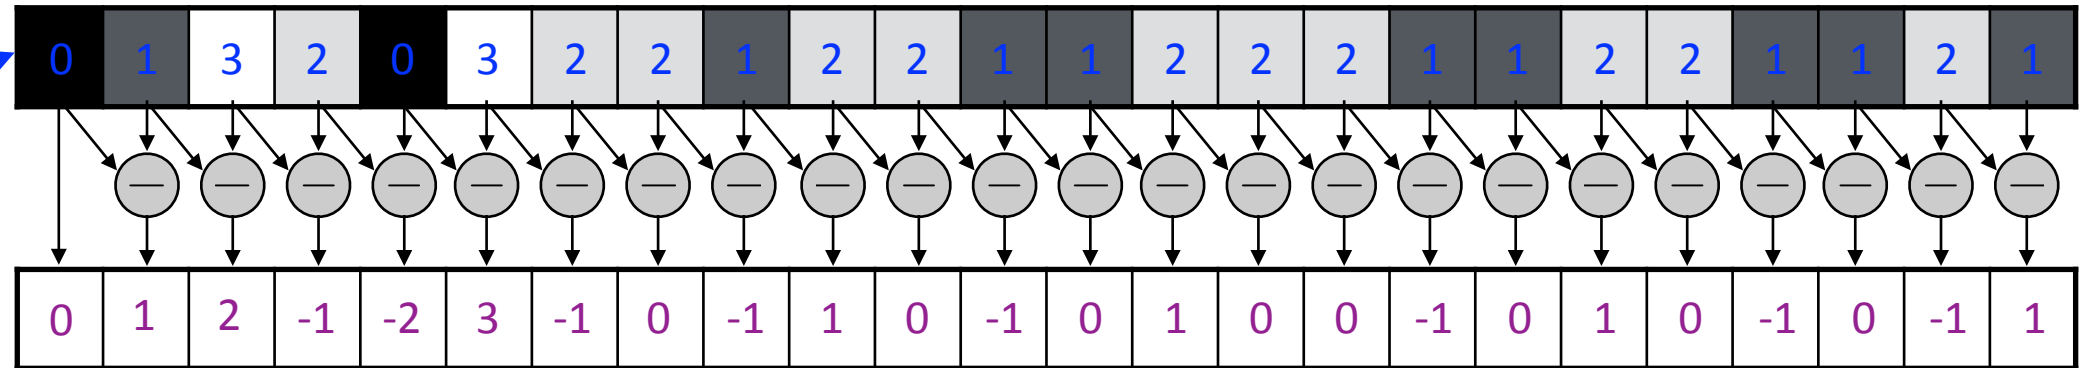


Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	1




bijektivité

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$




Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$




$$H(p) = 0.61$$




Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$




Long. moy. = 1.67 bits.

$$H(p) = 0.61$$




Long. moy. = 1.16 bits.




Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$



Long. moy. = 1.67 bits.

$$H(p) = 0.61$$



Long. moy. = 1.16 bits.





Image 256×256 pixels:


16.3 ko

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$



Long. moy. = 1.67 bits.

$$H(p) = 0.61$$



Long. moy. = 1.16 bits.





Image 256×256 pixels:

16.3 ko


13.7 ko

Comment faire mieux?

→ Les pixels ne sont pas indépendants les uns des autres !
Retransformation des symboles \Leftrightarrow diminuer l'entropie.




0	1	3	2	0
3	2	2	1	2
2	1	1	2	2
2	1	1	2	1




bijektivité

$$H(p) = 1.54$$



Long. moy. = 1.67 bits.

$$H(p) = 0.61$$



Long. moy. = 1.16 bits.




Image 256×256 pixels:

16.3 ko

13.7 ko

9.5 ko

Conclusion

Claude Shannon, père fondateur de la théorie de l'information.



Conclusion

Claude Shannon, père fondateur de la théorie de l'information.

Compression : utilisation de code variables.
symbole fréquent \rightarrow code court



Conclusion

Claude Shannon, père fondateur de la théorie de l'information.

Compression : utilisation de code variables.
symbole fréquent \rightarrow code court

Non abordé: comment calculer ces codes ?
 \rightarrow arbre de Huffman (1952).
 \rightarrow codage arithmétique (1976).



Merci
Questions ?