

---

---

---

---

---



Rappel : on a un alphabet fini  $A = \{a_1, \dots, a_k\}$   
 et une proba  $p_1, \dots, p_k$  proba sur  $A$   
 $\equiv$  fréquence des lettres.

• on veut coder  $X_1 X_2 \dots$  où  $X_i$  indep de  $\text{sup.}$   
 de manière à ce que  $\mathcal{C}(X_1 \dots X_n)$  soit de  
 taille la + petite possible.

$$\prod_{n \geq 0} \{0, 1\}^n$$

• on veut minimiser

$$R_n := E[\|\mathcal{C}(X_1, \dots, X_n)\|]$$

longueur

et  $R = \lim_n R_n$ .

codage bon si  $R$  petit.

• on a introduit  $H = \sum_{k=1}^K -p_k \log_2 p_k$

$$0 \leq H \leq \log_2 K$$

↑ mesure de biais    ↑ mesure uniforme.

• Codage naïf (ne depend pas de  $p$ ) on injecte :  
 $A = \{a_1, \dots, a_k\} \hookrightarrow \{0, 1\}^{\lceil \log_2 K \rceil}$   
 alors  $R_n = n R_1 = n \lceil \log_2 K \rceil$ .  $R \approx \lceil \log_2 K \rceil$

• Codage "entropique" : on a identifié des  
 suites  $x_1, \dots, x_n$  typique au nombre de  $\approx 2^{nH}$   
 celle ci on les code par des suites dans  $\{0, 1\}^{nH}$   
 $\rightsquigarrow R_n \approx n(H + c\varepsilon)$   
 alors  $R \approx H + c\varepsilon$ .  $\triangleright$  meilleur



• Peut on faire mieux ?

on a toujours  $R_n = \sum_{x_1, \dots, x_n} |\mathcal{C}(x_1, \dots, x_n)| p_{x_1, \dots, x_n}$

$$\geq \sum_{\substack{x_1, \dots, x_n \text{ typiques} \\ \in T_\varepsilon^m}} |\mathcal{C}(x_1, \dots, x_n)| p_{x_1, \dots, x_n}$$

$R_n \geq 2^{-n(H+\varepsilon)} \sum_{\substack{x_1, \dots, x_n \\ \text{typique}}} |\mathcal{C}(x_1, \dots, x_n)|$

$\geq 2^{-n(H+\varepsilon)}$  par def de  $T_\varepsilon^m$

$|\mathcal{C}(x_1, \dots, x_n)| \geq 2^{n(H-\varepsilon)}$  (Sinon on ne pourrait pas décoder)

$2^{\frac{1}{m} \sum_{m \geq 0} \{0,1\}^m}$

on  $\geq 2^{n(H-\varepsilon)}$  éléments  $\neq$  dans  $\prod_{m \geq 0} \{0,1\}^m$

de quelle manière minimiser la somme des longueurs ?

mettre  $\emptyset, \{0\}, \{1\}, \dots$  mots de taille 2, mots de taille 3, ...

Si on prend tous les mots de taille  $\leq p$

cela donnera  $1 + 2^1 + \dots + 2^p$  mots

$\frac{2^{p+1} - 1}{2} \geq 2^{n(H-\varepsilon)}$  on veut que cela soit

$p \geq n(H-\varepsilon) - 1$  *contrainte pour coder tous les mots typiques*

$\{ \mathcal{C}(x_1, \dots, x_n) \mid x_1, \dots, x_n \in T_\varepsilon^m \} = \prod_{m \geq 0} \{0,1\}^m$  *par des mots  $\neq$*

La somme des longueurs est alors

$$\sum_{m=0}^p \sum_{\mathcal{C} \in \{0,1\}^m} \text{longueurs} \mathcal{C} = \sum_{m=0}^p 2^m m$$

$$= x \left( \sum_{m=0}^p x^m \right)' \Big|_{x=2}$$

$$= x \left( \frac{x^{p+1} - 1}{x - 1} \right)' \Big|_{x=2}$$

$$= x \frac{(p+1)x^p(x-1) - (x^{p+1}-1)}{x-1} \Big|_{x=2}$$

$$= 2 \left[ (p+1)2^p - 2^{p+1} + 1 \right]$$

$$R_n \geq 2^{-n(H+\epsilon)} 2 \left( (p+1)2^p - 2^{p+1} + 1 \right) \quad p \approx n(H-\epsilon)-1$$

$$R_n \geq 2^{-n(H+\epsilon)} 2 \left( (n(H-\epsilon)-1)2^{n(H-\epsilon)-1} + 1 \right)$$

$$\boxed{R_n} \geq \underbrace{2^{-n\epsilon}}_{\text{mauvaise}} 2^{\boxed{n(H-\epsilon)}}$$

$\rightarrow 0$  lorsque  $n \rightarrow \infty$

On peut raffiner pour voir que  $\forall$  codage  $\forall \epsilon > 0$   
 lorsque  $n$  grand  $R_n \geq n(H-\epsilon) \Rightarrow \boxed{R \geq H-\epsilon}$

Cas particulier : codage lettre à lettre :

cas où  $Q(x_1, \dots, x_n) = Q(x_1) \dots Q(x_n)$ .

• pour éviter les ambiguïtés on doit avoir

si  $i \neq j$  :  $Q(x_i)$  n'est pas un préfixe de  $Q(x_j)$


$\Leftrightarrow$  on peut placer les  $x_i$  sur les feuilles d'un arbre binaire et le chemin de 0 et de 1 qui mène à  $x_i$  est le code de  $x_i$

$$Q(x) = 10$$

$$Q(y) = 11$$

$$Q(z) = 0$$

$\Leftrightarrow$




Codage de Huffman :  $A = \{a_1, \dots, a_k\}$   
 $\{p_1, \dots, p_k\}$

codage lettre à lettre  
 construit récursivement (sur  $K$ ).

Objectif : arbre binaire dont les feuilles sont les  $a_i$

- 1) je sélectionne les 2 éléments  $a_i$  et  $a_j$  tel que  $p_i$  et  $p_j$  sont minimales ( $p_i = \min_{1 \leq b \leq k} p_b$ ,  $p_j = \min_{1 \leq b \leq k, b \neq i} p_b$ )



- 3) Je continue sur les bases  $(\{a_i, a_j\}, a_1, a_2, \dots, a_k)$   
 alphabet  $(p_i + p_j, p_1, p_2, \dots, p_k)$   
 à  $K-1$  lettres

Exo :  $\{T, P, R, U, Y, Z\}$   $K=6$   
 $p: \frac{1}{16} \frac{1}{16} \frac{1}{16} \frac{1}{4} \frac{1}{2} \frac{1}{16}$

1)  $H?$   $H = - (p_T \log_2 p_T + p_P \log_2 p_P + \dots)$   
 $= - (4 \times \frac{1}{16} \log_2 \frac{1}{16} + \frac{1}{4} \log_2 \frac{1}{4} + \frac{1}{2} \log_2 \frac{1}{2})$   
 $(\log_2 \frac{1}{2^k} = -k)$   $= 4 \times \frac{1}{16} \times 4 + \frac{1}{4} \times 2 + \frac{1}{2} \times 1$   
 $= 2$


2) Huffman:

- ①  $T, P, R, U, Y, Z$   
 $\frac{1}{4} \frac{1}{2}$

$p_T$  et  $p_P$  sont minimales.

- ②  $\{T, P\} \frac{1}{8} R, U, Y, Z$   
 $\frac{1}{16} \frac{1}{4} \frac{1}{2} \frac{1}{16}$

$p_R, p_Z$  minimales




③  $\{π, P\} \frac{1}{8} \cup \{R, Z\} \frac{1}{8}$

$\cup \frac{1}{4} \neq \frac{1}{2}$

$\{π, P\}$  et  $\{R, Z\}$   
sont minimaux

④  $\{π, P, R, Z\} \frac{1}{4}$   
 $\cup \frac{1}{4} \neq \frac{1}{2}$

$\{π, P, R, Z\}$  et U  
sont minimaux



Le codage

$\varphi(\pi) = 0000$

$\varphi(P) = 0001$

$\varphi(R) = 0010$

$\varphi(Z) = 0011$

$\varphi(U) = 01$

$\varphi(Y) = 1$

•  $\varphi(Y \cup \pi) = \underbrace{1}_Y \underbrace{01}_U \underbrace{0000}_\pi$

•  $\varphi^{-1}(00100001) = ?$

= RP

on part de la racine et on suit le chemin arriver sur une feuille on la note puis on recommence.

• nombre moyen de bits par message ?

$R_m = n R_s$

et  $R_s = p_n |\varphi(\pi)| + p_P (|\varphi(P)| + \dots)$

$= 4 \underbrace{\frac{1}{16} \times 4}_{\pi, P, R, Z} + \underbrace{\frac{1}{4} \times 2}_U + \underbrace{\frac{1}{2} \times 1}_Y = 2 = H$

En general on ne peut pas espérer  $R_s = H$  pour des problèmes d'arrondis.

Exo: Alphabet:  $\{A, C, F, R\}$ .

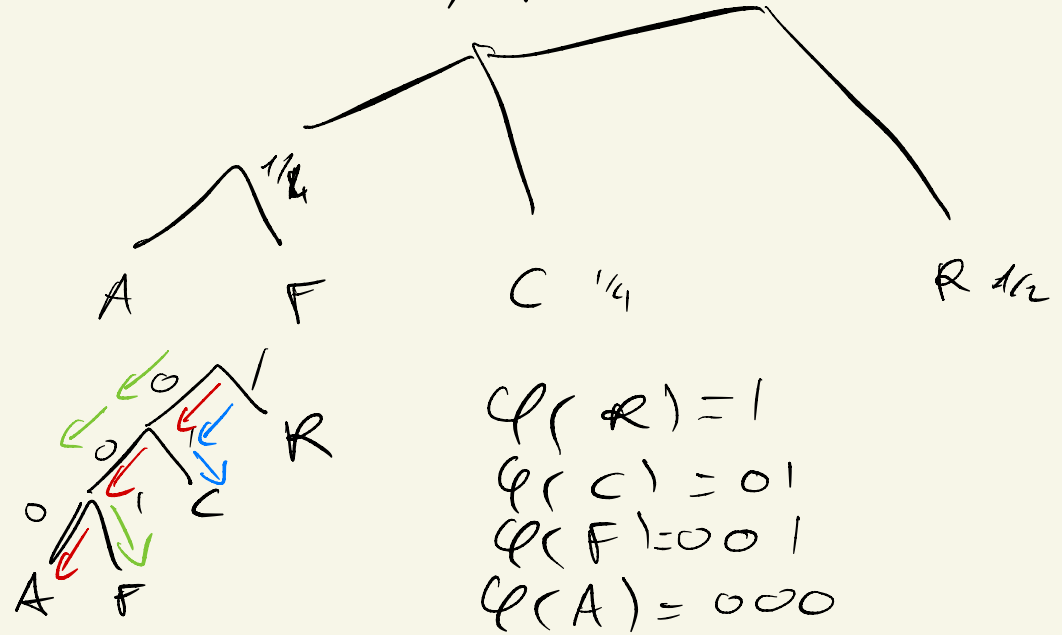
$P: \frac{1}{8}, \frac{1}{4}, \frac{1}{8}, \frac{1}{2}$

- 1) Calculer  $H$
- 2) Le codage de Huffman (et son arbre)
- 3)  $R =$  nombre moyen de bits par lettre
- 4)  $\varphi(ARC)$  ?
- 5)  $\varphi^{-1}(00100001)$  ?

$$1) H = - \left( \frac{1}{8} \ln_2 \frac{1}{8} + \frac{1}{4} \ln_2 \frac{1}{4} + \frac{1}{8} \ln_2 \frac{1}{8} + \frac{1}{2} \ln_2 \frac{1}{2} \right)$$

$$= + \frac{3}{8} + \frac{2}{4} + \frac{3}{8} + \frac{1}{2} = \frac{7}{4}$$

2) A et F min, puis  $\{A, F\}$  etc



$$3) R = \frac{1}{8} (|\varphi(A)| + |\varphi(F)|) + \frac{1}{4} |\varphi(C)| + \frac{1}{2} |\varphi(R)|$$

$$= \frac{1}{8} 2 \times 3 + \frac{2}{4} + \frac{1}{2} = \frac{7}{4}$$

$$4) \varphi(ARC) = \underbrace{000}_A \underbrace{1}_R \underbrace{01}_C$$

$$5) \varphi^{-1}(00100001) = FAC$$

$\xrightarrow{F} \xrightarrow{A} \xrightarrow{C}$   
 $\xrightarrow{F} \xrightarrow{A} \xrightarrow{C}$

Exo: Alphabet:  $\{A, B\}$ .  $\varepsilon < \frac{1}{2}$ .  $\varepsilon$  petit.  
 $p \in \{\varepsilon, 1-\varepsilon\}$ .

- 1) Calculer  $H$
- 2) Calculer le code de Huffman
- 3) Calculer  $R$  et commenter sur l'efficacité.


Exo: Alphabet infini:  $\{1, 2, 3, 4, \dots\} = \mathbb{N}^*$   
 $\mathbb{P}(X_i = i) = \frac{1}{2^i}$  ( $\sum_{\mathbb{N}^*} \frac{1}{2^i} = 1$ ).

- 1) Calculer  $H$
- 2) S'inspirer du code de Huffman pour trouver un codage
- 3) Trouver sur ce codage le  $R_1$  correspondant.

Exo:  $\{A, B\}$ .  $\varepsilon$   $1-\varepsilon$ .  $K=2$ .  $\lfloor \ln_2 K \rfloor = 1$ .

1)  $H = -(\varepsilon \ln \varepsilon + (1-\varepsilon) \ln (1-\varepsilon))$ .

2) Arbre:



3)  $R_1 = 1$

Efficacité: a-t'on  $R_1$  proche de  $H$ ?

Non:  $R_1 = 1$   $H \xrightarrow{\varepsilon \rightarrow 0} 0$

Donc on ne peut pas espérer approcher  $H$  à une constante mult près.

Indication pour l'alphabet  $\omega$ :

S'inspirer des cas  $A = \{1, 2, \dots, n\}$

$$\mathbb{P}(X=i) = \frac{1}{2^i} \text{ si } i=1, 2, \dots, n-1$$

$$\mathbb{P}(X=n) = \frac{1}{2^{n-1}}$$

$$1) H = - \sum_{k \geq 1} p_k \log_2 p_k$$


$$= - \sum_{k \geq 1} \frac{1}{2^{-k}} \log_2 \frac{1}{2^{-k}} = \sum_{k \geq 1} \frac{k}{2^k}$$

$$= z \left( \sum_{k \geq 0} z^k \right)' \Big|_{z=\frac{1}{2}} = z \left( \frac{1}{1-z} \right)' \Big|_{z=\frac{1}{2}}$$

$$= \frac{z}{(1-z)^2} \Big|_{z=\frac{1}{2}} = \frac{\frac{1}{2}}{(1-\frac{1}{2})^2} = 2$$

2) Si  $A = \left\{ \begin{matrix} a_1 & \dots & a_{n-1} & a_n \\ \frac{1}{2} & \frac{1}{4} & \frac{1}{2^{n-1}} & \frac{1}{2^{n-1}} \end{matrix} \right\}$


les 2 minimales:  $a_{n-1}$  et  $a_n$ .



les 2 minimales:  $\{a_{n-1}, a_n\}$  et  $a_{n-2}$

(Après un regroupement on est équivalent à  $A_{n-1}$ )

Bilan:



$$\varphi(i) = \underbrace{000\dots 0}_{i-1} 0 1$$

$$|\varphi(i)| = i$$

$$R_1 = \sum_{i=1}^{\infty} p_i |\varphi(i)|$$

$$= \sum_{i=1}^{\infty} \frac{1}{2^i} i = 2 = H.$$


↑  
comme pour  
H

• Peut on atteindre  $R_1 \approx H$  par les codes  $\varphi(i)$  ?

Lemme (Kraft) si  $y_1, \dots, y_k$  sont des mots  $\in \{0, 1\}^m$

si  $\forall i, y_i$  n'est pas le préfixe de  $y_j \quad \forall j \neq i$   
 si  $l_i = |y_i|$  alors  $\sum_{i=1}^k 2^{-l_i} \leq 1$

Dém:  $\exists$  un arbre binaire dont les  $y_i$  sont les feuilles




$$m = \max_{1 \leq i \leq k} \{l_i\}$$

on complète l'arbre jusqu'à la hauteur  $m$

c'est à dire

arbre binaire complet de hauteur  $l_i - m$




$y_i$  a  $2^{l_i - m}$  descendants à hauteur  $m$ .



les descendants de 2  $y_i \neq$  sont  $\neq$   
 donc  $\sum_i 2^{m-l_i} \leq \# \text{total d'individus \u00e0 la hauteur } m = 2^m$   
 donc  $\boxed{\sum_i 2^{-l_i} \leq 1}$

R\u00e9ciproque: Si  $l_i$  entiers tels que  $\sum_i 2^{-l_i} \leq 1$   
 alors  $\exists$  des mots  $y_1, \dots, y_k$  tel que  $|y_i| = l_i$   
 et  $y_i$  n'est pas pr\u00e9fixe de  $y_j$  si  $i \neq j$ .

Preuve: on veut  $y_1, \dots, y_k$  des feuilles d'un arbre  
 binaire  $y_i$  \u00e0 hauteur  $l_i$ .  
Supposons  $l_1 \leq l_2 \leq \dots \leq l_k$ . *important.* on pose  $m = \max l_i = l_k$ .  
 on regarde l'arbre binaire complet de hauteur  $m$



Ex:  $l_1 = 1$   $m = 3$   
 $l_2 = 2$   $l_3 = 3$   
 $(2^{-1} + 2^{-2} + 2^{-3} \leq 1 \checkmark)$

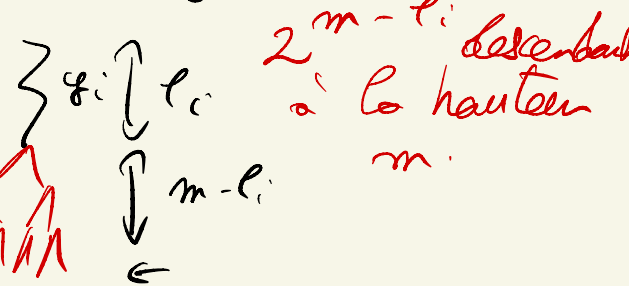
$\leftarrow$  hauteur  $m$  il y a  $2^m$  feuilles.

①  $2^{m-l_1}$  premiers individus ce doit \u00eatre les descendants de  $y_1$ .  
 ( $2^{3-1} = 4$ )

②  $2^{m-l_2}$  suivants ce doit \u00eatre les descendants de  $y_2$


Si  $y_i$  est de longueur  $l_i$  il doit avoir

③  $2^{m-l_3}$  suivants doivent descendre de  $y_3$




Pourquoi \u00e7a marche: pourquoi le premier anc\u00eatre des  $2^{m-l_i}$  individus est \u00e0 hauteur  $l_i$  ?

Problème:



ancêtre de  $2^{2-1}$  indiv n' est pas de longueur 1 mais 0.

Si ça marche pour  $i$  alors comme  $l_{i+1} \geq l_i$   
 $2^{m-l_{i+1}} \leq 2^{m-l_i}$



les  $2^{m-l_{i+1}}$  suivants sont les premiers descendants de  $v_{i+1}$  de droite de  $g_i \Rightarrow$  ils ont un ancêtre commun sans autres descendants

le Problème n'arrive pas

On cherche un codage lettre à lettre optimal.  $\square$

on cherche  $g_1, \dots, g_k$  qui code  $a_1, \dots, a_k$

$l(a_i) = l_i$  et qui minimise.

$$R_1 = \sum_{i=1}^k p_i |g_i| = \sum_{i=1}^k p_i l_i$$

le Lemme de Kraft nous donne une CNS sur  $l_1, \dots, l_k$

pour que il existe des mots  $g_1, \dots, g_k$  ayant ces longueurs.

Donc on cherche  $l_1, \dots, l_k$  tel que  $\sum_{i=1}^k 2^{-l_i} \leq 1$  et qui minimise  $R_1 = \sum_{i=1}^k p_i l_i$ .

Cherchons  $x_1, \dots, x_k \in \mathbb{R}^+$  tels que  $\psi(x) := \sum_{i=1}^k 2^{-x_i} \leq 1$  et  $R_1 = \sum_{i=1}^k p_i x_i$  soit le + petit possible

Pour minimiser  $R_1$  mieux prendre  $x_i$  petit.

si  $\psi(x) = \sum 2^{-x_i} < 1$  on peut sans risque diminuer les  $x_i$

→ optimal atteint en un point  $\varphi(x) = \sum_{i=1}^k 2^{-x_i} = 1$

But: minimiser  $\sum_{i=1}^k p_i x_i$  sous la contrainte  $\sum_{i=1}^k 2^{-x_i} = 1$

Méthode multiplicateur de Lagrange:

on considère  $\varphi(x, \lambda) = \sum_{i=1}^k p_i x_i + \lambda (\varphi(x) - 1)$

Alors l'optimum est atteint en un  $(x, \lambda)$  tel que

$$\partial_{x_i} \varphi = 0 \text{ et } \partial_{\lambda} \varphi = 0$$

En effet,  $\partial_{\lambda} \varphi = \varphi(x) - 1 = 0$

et si  $h$  est une direction selon laquelle

$\nabla \varphi \cdot h = 0$  c'est à dire  $\varphi$  ne varie pas dans la direction  $h$  (donc la contrainte

contenue à être respectée) alors dans cette direction  $\sum_{i=1}^k p_i x_i$  doit être optimal donc  $(\nabla \sum_{i=1}^k p_i x_i) \cdot h = 0$

$$h \in \nabla(\varphi - 1)^\perp \Rightarrow h \in (\nabla \sum_{i=1}^k p_i x_i)^\perp$$

$$\Rightarrow -\lambda \nabla(\varphi - 1) = \nabla \sum_{i=1}^k p_i x_i$$

$$\Rightarrow \nabla \varphi = 0 \Rightarrow \forall i \partial_{x_i} \varphi = 0 \text{ et } \partial_{\lambda} \varphi = 0$$

Normalité on cherche  $x, \lambda$  tq  $\nabla \varphi(x, \lambda) = 0$

$$\text{soit } \varphi(x, \lambda) = \sum_{i=1}^k x_i p_i + \lambda (\sum_{i=1}^k 2^{-x_i} - 1)$$

$$\partial_{x_i} \varphi = 0 \Rightarrow p_i + \lambda (-\ln 2) 2^{-x_i} = 0 \quad (*)$$

$$\sum_i: \sum_{i=1}^k p_i - \ln 2 \lambda \sum_{i=1}^k 2^{-x_i} = 0$$

$$\text{Donc } \lambda = \frac{1}{\ln 2}$$

$$(*) : 2^{-x_i} = p_i \Rightarrow x_i = -\log_2 p_i$$

Donc:

$$\min \left\{ \sum_{i=1}^k x_i p_i : x_i \geq 0 \text{ et } \sum_{i=1}^k 2^{-x_i} = 1 \right\}$$

$$= \sum_{i=1}^k \underbrace{-\log_2 p_i}_{\bar{x}_i} p_i \quad \left( \text{on a } \sum_{i=1}^k 2^{-\log_2 p_i} = 1 \right)$$

Je pose  $l_i = \lceil -\log_2 p_i \rceil = \lceil \bar{x}_i \rceil$ .

et alors  $\sum_{i=1}^k 2^{-l_i} = \sum_{i=1}^k 2^{-\lceil \bar{x}_i \rceil} \leq \sum_{i=1}^k 2^{-\bar{x}_i} = 1$

Donc par le Lemme de Kraft,

$\exists y_1, \dots, y_k$  de longueur  $l_1, \dots, l_k$  avec condition de préfixe.

et pour ce code ( $\mathcal{P}(x_i) = y_i$ )

on a  $R_1 = \sum p_i l_i \leq \sum p_i (\bar{x}_i + 1)$

$$= \sum p_i (-\log_2 p_i) + 1 = H + 1.$$

Et pour tout autre code (on aura  $\sum 2^{-l_i} \leq 1$ )

$$R_1 = \sum p_i l_i \geq \min \left\{ \sum x_i p_i : \sum 2^{-x_i} \leq 1 \right\}$$

$$= \sum \bar{x}_i p_i = H.$$

Lemme : pour tout codage <sup>lettre à lettre</sup>  $(y_1, \dots, y_k)$  avec

condition de préfixe :

$$R_1 \geq H$$

• Il en existe un tel que  $R \leq H + 1$

Exo :  $A = \{ \emptyset, N, S, T, Z \}$

$$\frac{5}{18} \quad \frac{2}{9} \quad \frac{1}{3} \quad \frac{1}{9} \quad \frac{1}{18}$$

1) Calculer  $H$

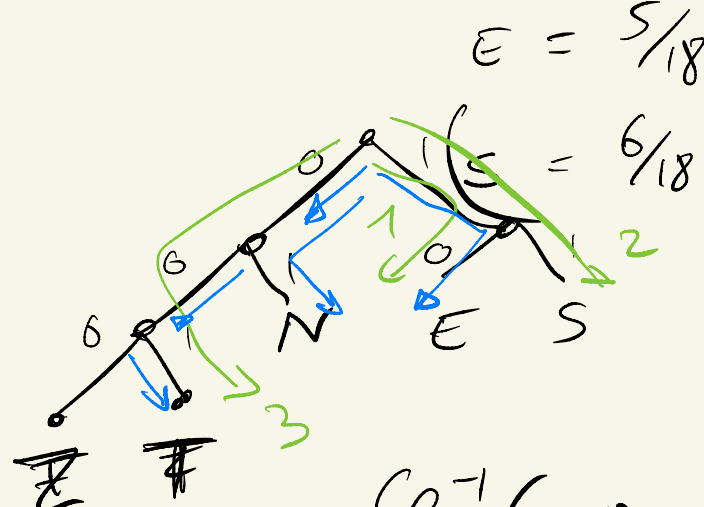
2) Calculer le code

3) Quel est le code de BST

4) on change le premier bit de BST est ce que on obtient le code d'un autre mot?

$$1) H = - \left( \frac{5}{18} \log_2 \frac{5}{18} + \frac{2}{9} \log_2 \frac{2}{9} + \frac{1}{3} \log_2 \frac{1}{3} + \frac{1}{9} \log_2 \frac{1}{9} + \frac{1}{18} \log_2 \frac{1}{18} \right)$$

$$2) \textcircled{1} \quad T, 2 \text{ mm} \quad \frac{3}{18} = \frac{1}{6} \quad \left. \begin{array}{l} \frac{4}{9} \quad \frac{1}{18} \\ N = \frac{4}{18} \end{array} \right\} \rightarrow \frac{7}{18}$$



$$E = \frac{5}{18} \quad \left. \begin{array}{l} \\ S = \frac{6}{18} \end{array} \right\} \rightarrow \frac{11}{18}$$


$$\varphi(\text{BST}) = \frac{10}{8} \quad \frac{11}{5} \quad \frac{001}{T}$$

$$\varphi^{-1}(0011001) \stackrel{?}{=} \text{TEEN} \quad \square$$

Théorème : Il n'y a pas de codage tel que

$$\underbrace{R_1}_{\text{consequence}} \leq \underbrace{R_1}_{\text{Huffman}} \leq H+1$$

Dém : Partons d'un autre codage lettre à lettre sans préfixe. Les  $y_i = (r_i)$  sont les feuilles d'un arbre binaire



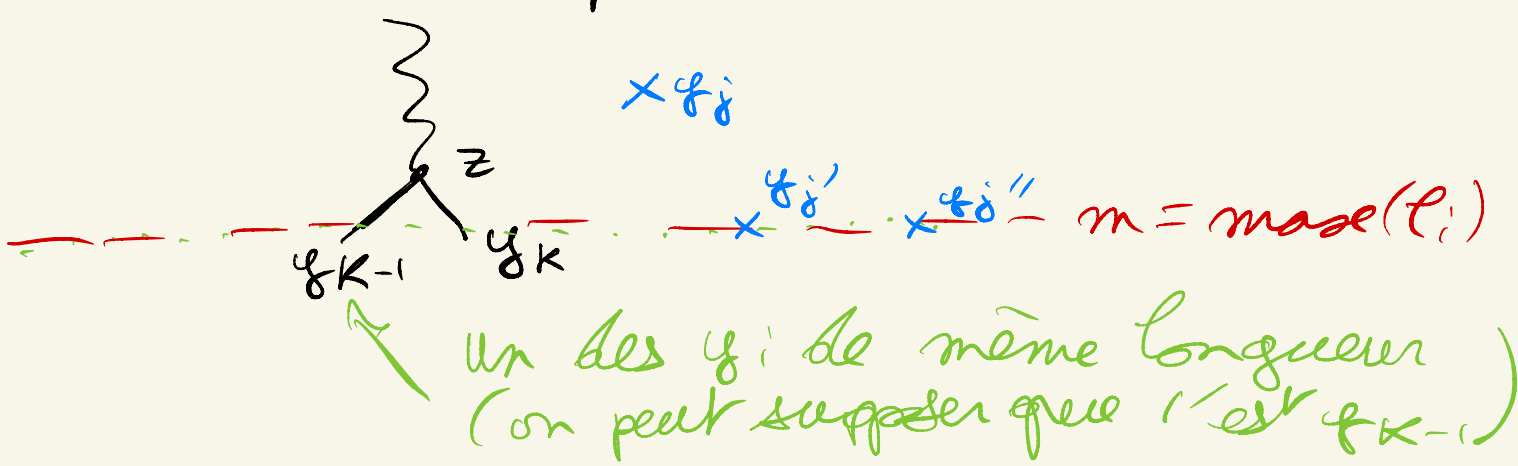
Regardons  $l_1 \dots l_k$  les longueurs de  $y_1 \dots y_k$

et supposons  $l_1 \leq \dots \leq l_k$ .

Supposons :  $\left. \begin{array}{l} \text{ } \\ \text{ } \\ \text{ } \end{array} \right\} z$  que  $z$  le père de  $y_k$  n'ait qu'un fils dans l'arbre (son autre fils possible n'est pas un  $y_i$ ).

on peut améliorer strictement le code en remplaçant  $y_k$  par  $z \rightarrow$  les codes produits seront + courts.

$\Rightarrow$  on améliore le code tant que cette situation se présente  
 $\rightarrow$  ce nous ramène où  $y_k$  (code de longueur max) a son voisin qui est l'un des  $y_i$



Pour ce code  $R = \sum p_i l_i$

$y_{k-1}$  et  $y_k$  de longueur max  $\Rightarrow$  on ne perd rien à leur associer les lettres de poids minimal. Si  $p_i$  est de poids  $< p_k, p_{k-1}$

Je fais un nouveau code  $\tilde{R}$  où la lettre  $a_i$  est codé par  $y_k$ .

et alors 
$$\tilde{R} - R = (p_i m + p_k l_i) - (p_i l_i + p_k m)$$

$$= \underbrace{(p_i - p_k)}_{< 0} \underbrace{(m - l_i)}_{\geq 0} \leq 0$$

→ on se gagne à donner à  $\gamma_k$   $\gamma_{k-1}$  les codes des lettres les moins probables.

→ on ne perd rien à faire la première <sup>étape</sup> de Huffman


→ on recommence sur le reste □

Exo 15: (colage entropique) pas un code lettre à lettre.

on considère  $A = \{1, \dots, K\}$

et une proba  $\{p_1, \dots, p_K\}$

$$\sum p_i = 1$$



$$q_k = p_1 + \dots + p_k$$

$$q_0 = 0 \quad q_K = 1$$

$$q_k - q_{k-1} = p_k$$

Pour coder  $x_1 \dots x_m$   $x_i \in \{1, \dots, K\}$

on définit une suite d'intervalles

$$I_0 \supseteq I_1 \supseteq I_2 \dots \supseteq I_m$$

$$I_k = [a_k; b_k] \quad a_k \uparrow \quad b_k \downarrow$$


$$I_k = \underbrace{a_{k-1}}_{\text{borne gauche de } I_{k-1}} + \underbrace{(b_{k-1} - a_{k-1})}_{\text{longueur de } I_{k-1}} \times [q_{x_{k-1}}; q_{x_k}]$$

Le code de  $x_1 \dots x_m$  est  $z_1 \dots z_{L_m}$  où  $\sum_{i=1}^{L_m} \frac{z_i}{2^i} \in I_m$  (de longueur  $L_m$  la + petite possible)

1)  $A = \{0, 1\}$   
 $\frac{1}{4} \quad \frac{3}{4}$

$$I_0 = [0; 1]$$

coder les 3 messages 0)



0 1  
0 10

$$I_1 = 0 + 1 \underbrace{[\varphi_0; \varphi_1]}_{0 \text{ 1<sup>er</sup> lettre}]} = [0; \frac{1}{4}]$$

$$\begin{aligned} a_1 &= 0 \\ b_1 &= \frac{1}{4} \\ b_1 - a_1 &= \frac{1}{4} \end{aligned}$$

$$I_2 = 0 + \frac{1}{4} \underbrace{[\varphi_1; \varphi_2]}_{1 \text{ 2<sup>emes</sup> lettre}}$$

$$= \frac{1}{4} \left[ \frac{1}{4}; 1 \right]$$

$$= \left[ \frac{1}{16}; \frac{1}{4} \right]$$

$$a_2 = \frac{1}{16} \quad b_2 = \frac{1}{4}$$

$$b_2 - a_2 = .3$$