

THIN - THÉORIE DE L'INFORMATION - TD

Exercice 1 : Quantité d'information et entropie

Dans un disque dur se trouvent deux dossiers : `desktop` et `home`.

Supposons que `desktop` contient 50 fichiers et `home` en contient 150.

- Quelle est la quantité d'information I_1 associée à l'événement e_1 "le fichier appartient au dossier `desktop`" ?

On suppose aussi que `desktop` contient 20 fichiers de type `.jpg` et 30 de type `.txt`, et que `home` contient 110 `.jpg` et 40 `.txt`.

- Quelle est la quantité d'information I_2 associée à l'événement e_2 "le fichier est de type `.jpg`" ?
- Quelle est la quantité d'information I_3 associée à l'événement "le fichier est de type `.jpg` et se trouve dans le dossier `desktop`" ?
- Est-ce que $I_3 = I_1 + I_2$?
- Peut-on en conclure que les deux événements e_1 et e_2 sont dépendants ou indépendants ?
- Calculer l'entropie de la source $A = \{.jpg, .txt\}$ et de la source $B = \{desktop, home\}$.

Exercice 2 : Entropie conditionnelle

Une certaine population a une probabilité de 2% d'attraper une certaine maladie. On appellera donc A la source $A = \{a_1 = \textit{sain}, a_2 = \textit{malade}\}$.

Calculer l'entropie de A .

Supposons qu'il existe un test pour détecter la maladie, qui répond toujours "positif" pour un malade, mais qui répond souvent "positif" pour les sujets sains aussi. En particulier, on considère la source $B = \{b_1 = \textit{positif}, b_2 = \textit{negatif}\}$ et supposons de savoir que:

- la probabilité que le test soit positif est de 51% (i.e. $p(b_1) = 51/100$)
- la probabilité qu'un sujet positif soit vraiment malade est de $2/51$ (i.e. $p(a_2|b_1) = 2/51$).
- Calculer tous les $p(a_i|b_j)$ et $p(a_i, b_j)$.
- Calculer l'entropie conditionnelle $H(A|B)$.
- Est-ce que l'entropie a augmenté ou diminué ?
- En se rappelant que l'entropie est la moyenne d'information est que l'information représente l'incertitude d'un événement...est-ce que l'incertitude augmente ou diminue ?

Exercice 3 : Code de Huffman

On suppose d'avoir une image composée par 10 couleurs, dont on va donner la fréquence dans le tableau ci-dessous :

couleur	fréquence	couleur	fréquence
1=noir	0,05	6 = vert	0,08
2 = blanc	0,02	7 = violet	0,12
3 = bleu	0,03	8 = orange	0,10
4 = jaune	0,15	9 = marron	0,20
5 = rouge	0,20	10 = gris	0,05

(TOURNEZ SVP)

- Calculer le code de Huffman associé à cette source (avec cette loi de probabilité) en dessinant aussi les arbres binaires associés.
- Calculer la longueur moyenne du code de Huffman ci-dessus.
- Calculer l'efficacité du code de Huffman et la comparer avec l'efficacité d'un code à longueur fixe pour cette source.
- Est-ce qu'on peut améliorer encore cette efficacité? Comment?

Exercice 4 : LZ77

- (1) On considère la chaîne de caractères "toto_murmurait" ('_' indique le caractère espace).
On prend une fenêtre de 7 caractères dont 3 pour le tampon de recherche.
Appliquer l'algorithme de codage LZ77 et écrire la suite de triplets de la forme (p, l, c) qu'on obtient à la sortie.
Si on suppose de coder p et l avec 2 bits chacun ($p, l \leq 3$) et chaque caractère avec 8 bits, quelle est le nombre de bits nécessaire pour le message codé? Et pour le message original?
- (2) On prend maintenant une fenêtre de longueur 11 (avec tampon de recherche de longueur 5), décoder le message compressé suivant :
 $(0, 0, i); (0, 0, l); (3, 1, c); (0, 0, a); (4, 1, c); (0, 0, u); (3, 1, e); (0, 0, -); (3, 2, n); (0, 0, t); (3, 1, m); (5, 3, \emptyset)$.
(où \emptyset représente la fin du message).

Exercice 5 : LZ78

- (1) Utiliser la méthode LZ78 pour compresser la chaîne de caractères suivante :
"ababcbcaaabcabbcc".
En supposant que un symbole soit représenté par 8 bits, quelle est la taille originale de la chaîne? Une fois compressée (en supposant qu'on utilise un code de longueur fixe minimale pour les entiers) quelle sera la taille?
- (2) Décompresser le message suivant : $(0, t); (0, r); (0, a); (0, l); (3, l); (5, a); (4, e); (2, e)$.