

THIN - THÉORIE DE L'INFORMATION - TP 1 - 2

Ce TP devra être rendu individuellement: une version temporaire à la fin de chacune des séances de TP, puis une version définitive pour vendredi 4 février.

*Il est conseillé d'utiliser maple (et dans ce cas, de rendre des fichiers source, et **pas** des worksheet).*

Liste de quelques fonctions maple qui peuvent être utiles :

- **length** : donne la taille d'une chaîne de caractères.
- **convert(a,binary)** : convertit *a* en binaire.
- **convert(a,list)** : convertit *a* (de type **set**, **array**, **string** ou autre) en liste.
- **cat** : permet de concatener plusieurs chaînes de caractères.

En outre, au début du TP, vous allez télécharger sur ma page web le fichier **alice** (<http://perso.univ-rennes1.fr/anna.morra/temp.html> puis clic droit et télécharger sous...). À l'intérieur de celui-ci sont définies les fonctions **tri** et **insere** et la chaîne de caractères **texte** (qui contient un long texte à comprimer avec les différentes méthodes qu'on verra, après les avoir testées sur des exemples plus petits).

- **tri(L)** : trie une liste de listes en suivant la deuxième composante (et en ordre croissant).
- **insere(A,L)** : insère dans la bonne position (en respectant l'ordre croissant selon la deuxième composante) la liste *A* dans la liste de listes *L*.

Remarque : le but est de ne pas utiliser les fonctions avancées pour les chaînes de caractères !!!

Exercice 1 : Codage de Huffman

Étant donnée une chaîne de caractères **texte**, écrire un programme qui

- (1) Analyse la source et ses fréquences (i.e. il va construire une liste contenant tous les symboles présents dans **texte**, et une autre liste contenant leur fréquences).
- (2) Calcule l'entropie de la source.
- (3) Crée le code de Huffman associé à la source.
- (4) Calcule la longueur moyenne de ce code et son efficacité (et les compare à celles d'un code à longueur fixe).
- (5) Compresse donc, grâce au codage de Huffman ainsi créé, le fichier original.
- (6) (Facultatif) Construire le code de Huffman pour la source *B* constituée par les paires de caractères consécutifs et compresser à nouveau le fichier.

En particulier, à chaque étape du programme, il faudra imprimer à l'écran les résultats obtenus.

Exercice 2 : LZ77

- Écrire une fonction qui, étant données deux chaînes de caractères **recherche** et **lecture** de longueurs fixées (respectivement *m* et *n*), cherche la plus longue occurrence du début de **lecture** dans **recherche** (si il y en a deux identiques on choisit celle plus à gauche) et retourne le triplet

$$(p, l, c)$$

comme vu en cours.

- Écrire un programme qui utilise la fonction ci-dessus pour compresser un texte avec LZ77.
- Tester son programme sur **texte**.
- Écrire une fonction de décompression pour LZ77.

(TOURNEZ SVP)

Exercice 3 : LZ78

- Écrire un programme qui applique l'algorithme LZ78 pour le compresser une chaîne de caractères (il est conseillé de trier le dictionnaire pour que la recherche soit plus rapide).
- Écrire aussi le programme de décompression.
- Tester son programme sur `texte`.

Exercice 4 (Facultatif)

Modifier les fonctions de compression/décompression des exercices 2 et 3 de manière que les triplets/paires soient codés par des codes binaires à longueur fixe.