

Algorithme de Huffman

Motivation: présenter le codage de Huffman et son optimalité pour une sous-catégorie des encodages.

Il est notamment utilisé pour la compression avec des taux élevés sur des données réelles.

On raisonne ici sur un encodage binaire des caractères: chaque caractère du texte initial est représenté par une chaîne binaire unique, appelée **code**.


Codes de longueur fixe

↳ Simples mais très inefficaces

↳ On utilise des codes de longueur variable.


Définition: On dit qu'un codage est **préfixe** si aucun code n'est préfixe d'un autre code.

Exemples:



est un code non préfixe de longueur variable.

a → 0
b → 00
c → 01
d → 1



est un code préfixe.


a → 00
b → 01
c → 1

Remarque: Dans l'arbre correspondant à un codage préfixe, tous les caractères sont des feuilles.

Définition: On appelle **coût** d'un code C le nombre de bits nécessaires pour encoder un fichier. À partir de l'arbre T correspondant à C , on a:

$$B(T) = \sum_{a \in \Sigma} f_{\Sigma}(a) \times d_T(a) \quad \text{ou} \quad f_{\Sigma}(a) \text{ est le nb d'occurrences}$$

de a dans le texte, et $d_T(a)$ la profondeur de a dans T .



$$\begin{aligned}
 B(T) &= 20 \times 2 + 35 \times 2 + 45 \times 1 \\
 &= 60 + 70 + 45 \\
 &= 175
 \end{aligned}$$

Problème:

Entrée: Σ un alphabet et f_{Σ} une fonction d'occurrences

Sortie: C code de coût optimal

Fonction huffman(c): // c ensemble (caractère, nb d'occurrences)

$n = |c|$

$Q = \text{creer_tas_min}(c)$

Pour i de 1 à n-1

$z = \text{creer_noeud}()$

$x = \text{extraire_min}(Q)$

$y = \text{extraire_min}(Q)$

$z.\text{gauche} = x$

$z.\text{droit} = y$

$z.\text{freq} = x.\text{freq} + y.\text{freq}$



 insérer(Q, z)

Retourner $\text{extraire_min}(Q)$ // racine de l'arbre

Exemple: f:5 e:9 c:12 b:13 d:16 a:45



c:12 b:13 d:16 a:45



Terminaison, on

Complexité : $O(n \log(n))$ avec $n = |\Sigma|$

$O(n \log(\log(n)))$ avec une structure adaptée
(arbres de Van Emde Boas)

Correction :

Lemme : Si x et y sont deux caractères de Σ ayant les
fréquences les plus basses, il existe un codage
préfixe optimal pour C dans lequel les codes de
 x et y ont la même longueur et ne diffèrent
que par le dernier bit.

Lemme : Avec $\Sigma' = (\Sigma \cup \{z\}) \setminus \{x, y\}$ et
 $f_{\Sigma'}(z) = f_{\Sigma}(x) + f_{\Sigma}(y)$, si T' est un arbre
représentant un codage optimal de C' sur Σ' ,
alors le codage ^{préfixe} C de Σ obtenu en remplaçant
la feuille z par $x \rightarrow y$ est optimal.

Théorème : L'algorithme de Huffman produit un code
préfixe optimal.