

Arbres binaires de recherche optimaux

Référence : Cormen, p.357 de la seconde édition

2011-2012

On s'intéresse ici à optimiser les arbres binaires de recherche quand on connaît la probabilité pour chaque clef d'être recherchée.

On se donne n clefs distinctes triées dans l'ordre croissant $k_1 < \dots < k_n$, où pour tout i , k_i a une probabilité p_i d'être recherchée.

On rajoute aussi $n + 1$ clefs factices d_0, \dots, d_n représentant les recherches qui ne sont aucun des k_i .

d_0 représente toutes les valeurs inférieures à k_1 , d_n celle supérieures à k_n , et d_i celles comprises entre k_i et k_{i+1} . On se donne de plus une probabilité q_i que la recherche soit dans d_i .

Les nœuds internes de l'arbre seront les k_i , et les feuilles les d_i .

On a donc

$$\sum_{i=1}^n p_i + \sum_{i=0}^n q_i = 1.$$

Le coût moyen d'une recherche dans notre arbre sera

$$1 + \sum_{i=1}^n \text{Prof}(k_i)p_i + \sum_{i=0}^n \text{Prof}(d_i)q_i.$$

Un arbre binaire de recherche sera dit *optimal* si ce coût moyen est minimal. On abrège en "ABRO".

La recherche d'un ABRO en listant tous les arbres possibles a une complexité bien trop grande, on va donc essayer un algorithme de programmation dynamique.

On remarque pour cela que tout sous-arbre de notre arbre *doit* être optimal : sinon, on le remplace par un optimal, faisant ainsi baisser le coût total.

Le sous-problème à résoudre est donc, étant donnés $i \geq 1$ et $i - 1 \leq j \leq n$ un ABRO contenant les clefs k_i, \dots, k_j .

Soit $e[i, j]$ le coût d'un arbre contenant k_i, \dots, k_j .

Si $j = i - 1$, alors il n'y a que la clef factice d_{i-1} dans l'arbre : le coût moyen est q_{i-1} .

Sinon, $j \geq i$. On choisit un nœud k_r , $i \leq r \leq j$, et on construit l'arbre de racine k_r . Le sous-arbre gauche de k_r contiendra les clefs k_i, \dots, k_{r-1} , et le sous arbre droit les clefs k_{r+1}, \dots, k_j .

Quand on fait "descendre" un sous-arbre, on augmente la profondeur de ce sous-arbre de 1, on donc on augmente le coût de

$$w(i, j) = \sum_{k=i}^j p_k + \sum_{k=i-1}^j q_k.$$

On obtient donc la formule :

$$e[i, j] = p_r + e[i, r - 1] + w(i, r - 1) + e[r + 1, j] + w(r + 1, j).$$

On remarque que

$$w(i, j) = w(i, r - 1) + p_r + w(r + 1, j),$$

et donc

$$e[i, j] = e[i, r - 1] + e[r + 1, j] + w(i, j).$$

Cette formule est valide si on a choisi la bonne racine pour notre sous-arbre. On optimise donc :

$$e[i, j] = \begin{cases} q_{i-1} & \text{si } j = i - 1 \\ \min_{i \leq r \leq j} e[i, r - 1] + e[r + 1, j] + w(i, j) & \text{si } i \leq j \end{cases}$$

Pour garder une trace de notre construction, on définit $racine[i, j]$ comme l'indice de la racine optimale pour le sous-arbre contenant k_i, \dots, k_j .

On va maintenant utiliser la programmation dynamique pour calculer $e[1, n]$.

REMARQUE – Plutôt que de calculer tous les $w(i, j)$ à chaque fois, on crée un tableau défini par

$$\begin{cases} w(i, i - 1) = q_{i-1} \\ w(i, j) = w(i, j - 1) + p_j + q_j \end{cases}$$

On a donc l'algorithme suivant :

Algorithm 1 ABRO

Préconditions: p, q probabilités, n nombre de clefs

```

pour  $i = 1$  à  $n + 1$  faire
     $e[i, i - 1] \leftarrow q_{i-1}$ 
     $w[i, i - 1] \leftarrow q_{i-1}$ 
ruop
pour  $\ell = 1$  à  $n$  faire
    pour  $i = 1$  à  $n - \ell + 1$  faire
         $j \leftarrow i + \ell - 1$ 
         $e[i, j] \leftarrow \infty$ 
         $w[i, j] \leftarrow w[i, j - 1] + p_j + q_j$ 
        pour  $r = i$  à  $j$  faire
             $t \leftarrow e[i, r - 1] + e[r + 1, j] + w[i, j]$ 
            si  $t < e[i, j]$  alors
                 $e[i, j] \leftarrow t$ 
                 $racine[i, j] \leftarrow r$ 
            is
        ruop
    ruop
ruop
retourner  $e$  et  $racine$ 

```

Les trois boucles imbriquées nous donnent une complexité en $\mathcal{O}(n^3)$.