

L'algorithme glouton (Greedy Algorithm)

On suppose un treillis de vues associé à un cube de données, avec un coût de traitement associé à chaque vue (le coût de traitement est égal au coût d'espace occupé). Soient $c(v)$ le coût de traitement de la vue v , k le nombre de vues à sélectionner et S l'ensemble qui va contenir les k vues sélectionnées plus la vue sommet qui doit toujours être matérialisée (initialement $S = \{\text{vue sommet}\}$). Après avoir sélectionné un ensemble S de vues, le bénéfice de la vue v relatif à S noté $B(v,S)$, est défini comme suit :

1. Pour chaque vue $w \leq v$, on définit la quantité B_w par :

a. Soit u la vue qui a le plus petit coût dans S tel que $w \leq u$ (u est l'ancêtre de w qui a le plus petit coût de traitement dans S).

b. Si $c(v) < c(u)$, alors $B_w = c(u) - c(v)$ Sinon $B_w = 0$.

2. On définit le bénéfice de la vue v relatif à S noté $B(v,S)$ par: $B(v,S) = \sum_{w \leq v} B_w$

On calcule le bénéfice d'une vue v en considérant comment cette vue peut améliorer le coût de traitement des vues. Pour chaque vue w que couvre v , on comparons le coût de w en utilisant v et en utilisant l'évaluation la moins chère à partir de S . Si la présence de v améliore, On retient v pour la matérialisation. L'algorithme glouton pour sélectionner k vues à matérialiser est décrit comme suit :

$S = \{\text{vue sommet}\};$

Pour $i = 1$ à k faire

DEBUT

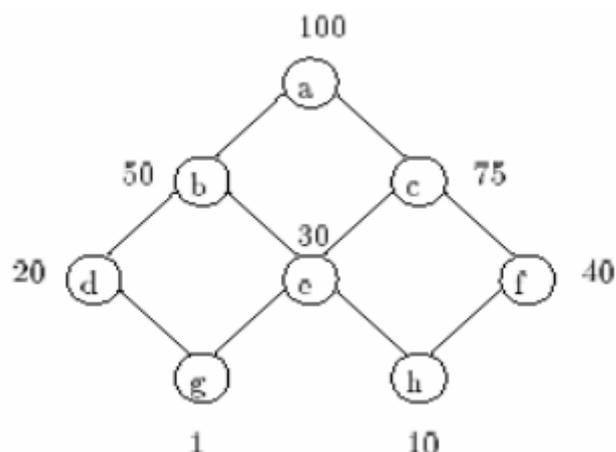
Sélectionner la vue v non dans S qui maximise $B(v,S)$;

$S = S \cup \{v\};$

FIN ;

S est l'ensemble des vues à matérialiser. Nous allons prendre un exemple pour illustrer cet algorithme.

Considérons le treillis de la figure . Ce treillis est constitué de huit vues nommées de a à h , ayant des coûts d'espace (coût de traitement) indiqués sur le treillis



Remarque Lorsqu'on calcule les bénéfices, on commence avec la supposition que chaque vue est évaluée en utilisant la vue sommet a , car initialement $S = \{a\}$. Le tableau suivant

représente les bénéfices des vues dans chaque itération de l'algorithme.

	1 ^{er} choix	2 ^{ème} choix	3 ^{ème} choix
b	50* 5= 250		
c	25* 5 =125	25* 2= 50	25* 1 =25
d	80* 2 =160	30* 2= 60	30* 2= 60
e	70* 3 =210	20* 3= 60	20+ 20+ 10 =50
f	60* 2 =120	60 +10= 70	
g	99* 1 =99	49* 1= 49	49* 1= 49
h	90* 1 =90	40* 1= 40	30* 1= 30

Tab. 4.1 - Le bénéfice des vues à chaque itération.

Premier choix : initialement l'ensemble S ne contient que la vue sommet a donc tous les calculs du bénéfice se font à partir de cette vue. Si on prend la vue b pour être matérialisée, on réduit son coût et celui de ses descendants (d, e, g, h) de 50, donc le bénéfice de B(b, S) = (100-50)*5 = 250. Le même traitement se fait avec toutes les autres vues. Si on prend la vue e pour être matérialisée, on réduit son coût ainsi que le coût de ses descendants (g et h) de 70 donc le bénéfice de e est B(e, S) = (100-30)*3 = 70*3 = 210. Pour le premier choix, on trouve que b a le plus grand bénéfice B(b, S) = 250, b est donc considérée comme la première vue matérialisée après a (la vue sommet). S = {a, b}.

Deuxième choix : Trouver le deuxième choix consiste à refaire la même opération précédente pour toutes les vues, avec S = {a, b}. Par exemple, choisir f réduit son coût de 60 (de 100 qui est le coût de a à 40 qui est le coût de f), la vue f a une seule vue descendante h. h dépend de la vue matérialisée b (b

est la vue qui a le plus petit coût dans S). Donc $B_h = c(u) - c(v) = c(b) - c(f) = 50 - 40 = 10$. Le bénéfice de f est alors $B(f, S) = B_f + B_h = 60 + 10 = 70$. Comme il est indiqué dans le tableau 4.1 f a le plus grand bénéfice, elle est donc considérée comme la deuxième vue à matérialiser. S = {a, b, f}.

Troisième choix : le troisième choix est indiqué dans la troisième colonne du tableau 4.1. Les mêmes calculs que la première et la deuxième étape se font, mais en considérant l'ensemble S = {a, b, f}. Comme exemple d'un calcul un peu compliqué le calcul du bénéfice de e. Le choix de e réduit son coût de 20. $B_e = c(u) - c(v) = c(b) - c(e) = 50 - 30 = 20$ (On a pris b car c'est l'ancêtre matérialisé de e qui a le plus petit coût dans S). La vue e a deux vues descendantes g et h, leurs bénéfices sont calculés comme suit : $B_h = c(u) - c(v) = c(f) - c(e) = 40 - 30 = 10$ (On a pris f car c'est l'ancêtre matérialisé de h qui a le plus petit coût dans S). $B_g = c(u) - c(v) = c(b) - c(e) = 50 - 30$, (b est l'ancêtre matérialisé de g qui a le plus petit coût dans S) $B_g = 20$. Donc le bénéfice de e est : $B(e, S) = \sum_{w \leq e} B_w = B_e + B_h + B_g = 20 + 10 + 20 = 50$. Après avoir calculé tous les bénéfices des vues restantes, d est sélectionné pour la matérialisation avec un bénéfice égal à 60. L'ensemble des vues sélectionnées est donc

S = {a, b, f, d}. Coût total = 100 * 8 = 800. (100 est le coût de la vue a, 8 est le nombre de vues)
 Bénéfice total = B(b, S) + B(f, S) + B(d, S) = 380. Cet ensemble réduit le coût de 800 (le cas où seulement la vue a est matérialisée) à 420. (800 - 380 = 420.)