


IFT2015 hiver 2010 — Notes de cours

Miklós Csűrös


6 janvier 2010

1 Union-Find

Informatique. On va illustrer la branche théorique par l'exemple de connexité.



Connexité



Problème de connexité.

Beaucoup d'objets, avec connexions entre eux. Question : est-ce qu'il existe une connexion entre deux objets p, q ?

Applications :

- ★ connexité dans réseaux (ordinateurs, électronique, interaction moléculaire, société)
- ★ séquençage de génomes (objets = morceau de séquence, connexion = chevauchements de séquences)
- ★ équivalence de variables dans un programme FORTRAN

Opérations abstraites.

- ★ $\text{FIND}(x)$ trouve l'ensemble contenant x («appartenance»)
- ★ $\text{UNION}(x, y)$ remplace les ensembles de x et y par leur union
- ★ $\text{MAKESET}(x)$ crée un ensemble avec le seul élément x

Exemple :

```
UNION(3, 4); UNION(4, 9); UNION(8, 0); UNION(2, 3);  
UNION(7, 4); UNION(6, 4); UNION(5, 0);  
FIND(2); FIND(6)
```

(1)

Connexité : on sait que $\text{FIND}(p) = \text{FIND}(q)$ si et seulement si les deux sont connexes.

Une solution simple. on représente un ensemble par un élément **canonique**.

Structure de données : stocker $\text{id}[x]$ — c'est l'ensemble auquel x appartient

$\text{MAKESET}(x)$
 $\text{id}[x] \leftarrow x$

Pour simplifier la discussion d'une structure de données, on traite souvent les éléments comme des entiers $0, 1, \dots, N-1$. Néanmoins, des implantations équivalentes mais plus générales sont faciles à imaginer.

```
public class MonUF  
{  
    public static class Element  
    {  
        private Element id;  
        private Object contenu;  
    }  
  
    public Element makeset(Object contenu)  
    {  
        Element emt = new Element();  
        emt.id = emt;  
        emt.contenu = contenu;  
        return emt;  
    }  
    ...  
}
```

QuickF — appartenance rapide ... union lente

```


UNION( $x, y$ )
1 si  $\text{id}[x] \neq \text{id}[y]$  alors
2   pour tout  $z$ 
3     si  $\text{id}[z] = \text{id}[x]$  alors  $\text{id}[z] = \text{id}[y]$ 

FIND( $x$ )
1 retourner  $\text{id}[x]$ 

```

QuickU — union rapide. Idée : on utilise id différemment.

1. si $\text{id}[x] = x$ alors x est l'élément canonique de l'ensemble
2. sinon, soit $x \leftarrow \text{id}[x]$ et retourner à 1 (en fait, chaque ensemble forme un arbre)



```

UNION( $x, y$ )
1  $p \leftarrow \text{FIND}(x)$  ;  $q \leftarrow \text{FIND}(y)$ 
2 si  $p \neq q$  alors
3    $\text{id}[p] \leftarrow q$ 

FIND( $x$ )
1 tandis que  $x \neq \text{id}[x]$  faire  $x \leftarrow \text{id}[x]$ 
2 retourner  $x$ 

```

... appartenance lente (appels consécutifs $\text{UNION}(1, 2)$, $\text{UNION}(2, 3)$, $\text{UNION}(3, 4)$, ...) mènent essentiellement à une liste chaînée)

QuickUW — union rapide équilibrée. Idée : au lieu de toujours faire $\text{id}[x] \leftarrow y$, lors d'un appel $\text{UNION}(x, y)$, on examine d'abord la taille des deux arbres. Taille stockée dans $\text{taille}[x]$

```

MAKESET( $x$ )
1  $\text{id}[x] \leftarrow x$ 
2  $\text{taille}[x] \leftarrow 1$ 

```

```

    UNION( $x, y$ )
1   $p \leftarrow \text{FIND}(x); q \leftarrow \text{FIND}(y)$ 
2  si  $p \neq q$  alors
3      si  $\text{taille}[p] < \text{taille}[q]$ 
4          alors  $\text{id}[p] \leftarrow q; \text{taille}[q] \leftarrow \text{taille}[p] + \text{taille}[q]$ 
5          sinon  $\text{id}[q] \leftarrow p; \text{taille}[p] \leftarrow \text{taille}[p] + \text{taille}[q]$ 

    FIND( $x$ )
1  tandis que  $x \neq \text{id}[x]$  faire  $x \leftarrow \text{id}[x]$ 
2  retourner  $x$ 

```

avantage : arbres équilibrés (on arrive à la racine en suivant $\leq \lg k$ liens dans un ensemble de k éléments)

Analyse de QuickUW. Performance de FIND dépend de la **hauteur** de l'arbre : nombre de liens à suivre jusqu'à ce qu'on arrive à la racine. En maintenant la taille, on contrôle la hauteur des arbres ...

Principe esquissé : dans le pire cas, on doit joindre deux arbres de la même taille, et la hauteur augmente par un. Est-ce qu'on peut démontrer que hauteur $\leq \lg(\text{taille})$? (notation : $\lg n = \log_2 n$)

Théorème 1. Dans la structure QuickUW, on a

$$\text{hauteur} \leq \lg(\text{taille}) \quad (2)$$

pour chaque arbre, après n'importe quelle séquence d'opérations UNION et FIND.

Démonstration. La hauteur et la taille ne sont pas affectées par les opérations FIND. On démontre que l'Équation (2) est vraie pour chaque ensemble disjoint après m opérations UNION. La démonstration se fait par induction en $m = 0, 1, \dots$

Cas de base. À $m = 0$, on a des éléments disjoints, avec hauteur = 0 et taille = 1.

Hypothèse d'induction. On suppose que (2) est vraie pour chaque ensemble disjoint après $m \geq 0$ opérations d'UNION.

Cas inductif. Soit UNION(x, y) la $(m+1)$ -ème opération. Si FIND(x) = FIND(y) jusqu'ici, alors rien ne change. Si FIND(x) $\neq$ FIND(y), on considère les arbres associés avec leurs ensembles. Par l'hypothèse d'induction, on a que $h_x \leq \lg t_x$ et

$h_y \leq \lg t_y$, où h et t dénotent les hauteurs et les tailles de deux arbres. Supposons que $t_x \leq t_y$ (sans perdre la généralité). La hauteur du nouvel arbre est alors $h = \max\{h_y, 1 + h_x\}$. Par l'hypothèse d'induction,

$$h \leq \max\{\lg t_y, 1 + \lg t_x\} = \lg \max\{t_y, 2t_x\}.$$

Or, la taille du nouvel arbre est $t_x + t_y \geq \max\{t_y, 2t_x\}$, Donc $h \leq \lg(t_x + t_y)$. En conséquence, le théorème reste valide après $(m + 1)$ opérations. ■

Compression de chemin. Si on a n éléments (n appels de MAKESET) et une série de m appels UNION/FIND

★ QuickF utilise nm opérations

★ QuickU utilise $nm/2$ opérations

★ QuickUW utilise $m \lg n$ opérations

Est-ce qu'on peut faire mieux? Idée : **compression de chemin**. Quand on monte jusqu'à la racine, faire $\text{id}[x] \leftarrow \text{racine}$ pour tous les membres sur le chemin. (On modifie QuickUW pour équilibrer les arbres toujours.)

```

FIND(x)
1 si  $x \neq \text{id}[x]$  alors  $\text{id}[x] \leftarrow \text{FIND}(\text{id}[x])$ 
2 retourner  $\text{id}[x]$ 

```

On a besoin de deux passages ... Autre idée : **compression de chemin par réduction à moitié** (*path halving*). Cela nécessite un seul passage mais les chemins restent deux fois plus longs.

```

FIND(x)
1 tandis que  $\text{id}[\text{id}[x]] \neq \text{id}[x]$  faire  $\text{id}[x] \leftarrow \text{id}[\text{id}[x]]$  ;  $x \leftarrow \text{id}[x]$ 
2 retourner  $\text{id}[x]$ 

```

Logarithme itéré. Composition : $\lg \lg n = \lg(\lg(n))$.

Logarithme itéré

$$\lg^* n = \begin{cases} 0 & \text{si } n \leq 1 \\ 1 + \lg^*(\lg n) & \text{si } n > 1 \end{cases}$$

C'est une fonction à croissance très lente (mais monotone) : $\lg^* n \leq 5$ pour tout $n \leq 2^{65536}$.

Théorème 2. *En utilisant la structure QuickUW avec compression de chemin, une séquence de m opérations sur n éléments prend un nombre d'instructions élémentaires de l'ordre de $m \lg^* n$.*

- ★ Ici, «instruction élémentaire» veut dire des opérations simples comme addition, affectation, etc.
- ★ On verra la définition précise de l'«ordre de» bientôt. (Ce qu'on dénotera par $O(m \lg^* n)$.) Cela veut dire que le nombre d'instructions exécutées est $\leq c \cdot m \lg^* n$ avec une constante quelconque c , indépendante de m, n .
- ★ On a donc un théorème sur le temps d'exécution sur n'importe quel CPU.

Fonction d'Ackermann.

Définition 1 (définition de R. E. Tarjan). *La fonction Ackermann $A(i, j)$ avec $i, j \geq 1$ est définie par*

$$A(i, j) = \begin{cases} 2^j & \text{si } i = 1; \\ A(i-1, 2) & \text{si } j = 1 \text{ et } i \geq 2 \\ A(i-1, A(i, j-1)) & \text{si } i, j \geq 2 \end{cases}$$

Définition 2. *Ackermann inverse ($m \geq n \geq 1$)*

$$\alpha(m, n) = \min\{i : A(i, \lfloor m/n \rfloor) \geq \lg n\}.$$

Ackermann inverse est une fonction à croissance même plus lente que $\lg^*$: $\alpha(m, n) \leq 3$ pour tout $n < 65536$ et $\alpha(m, n) \leq 4$ pour tout $n < 2^{2^{\dots^2}}$ (exponentiation 16 fois).

Théorème 3. *En utilisant la structure QuickUW avec compression de chemin, une séquence de m opérations sur n éléments prend un nombre d'instructions élémentaires de l'ordre de $m\alpha(m, n)$.*