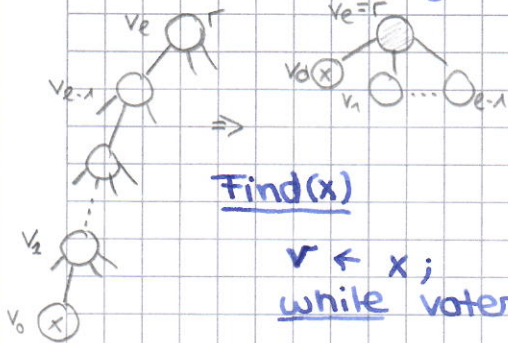


5) Verbesserung 4)

weighted union + Pfad Komprimierung (path. compression)

→ Find(x) durchläuft einen Pfad v_0, \dots, v_e von Knoten wobei $v_0 = x, v_e = \text{Wurzel } r$

Idee: Hänge v_0, \dots, v_{e-2} direkt an die Wurzel r



Find(x)

$v \leftarrow x;$ // r ist Wurzel
while vater[r] $\neq 0$ do

$r \leftarrow$ vater[r];

od

while vater[x] $\neq 0$ do

$p \leftarrow$ vater[x];
vater[x] $\leftarrow r;$
 $x \leftarrow p;$

od

Beobachtung

Pfadkomprimierung

- verteuert aktuelle Find aber nur um konstanten Faktor $\rightarrow O(\log n)$
- macht spätere Finds erheblich billiger

Satz (Tarjan)

Bei Union-Find mit weighted Union und path compression hat eine beliebige Folge von $n-1$ Unions und $m \geq n$ Finds die Gesamtkosten $O(m \cdot \alpha(m, n))$

Eine Variante der Ackermann-Funktion und ihre Inverse

$$\begin{array}{l} A: \mathbb{N}_0 \times \mathbb{N}_0 \rightarrow \mathbb{N}_0 \\ \left. \begin{array}{l} A(i, 0) = 0 \quad \text{für } i \geq 0 \\ A(0, x) = 2x \quad \text{für } x \geq 0 \\ A(i, 1) = 2 \quad \text{für } i \geq 0 \end{array} \right\} \text{Verankerung} \end{array}$$

$$\text{Für } i > 0, x > 1: A(i, x) = A(i-1, A(i, x-1))$$

Wertetabelle für $A(i, x)$

$i \backslash x$	0	1	2	3	4	5	6	7	8	...	"zeilenfunktion"
0	0	2	4	6	8	10	12	14	...		$2x = A(0, x)$
1	0	2	4	8	16	32	64	...			$2^x = A(1, x)$
2	0	2	4	16	2^{16} = 65536	2^{65536}					$2^{2^{\dots^2}} x = A(2, x)$
3	0	2	4								
4	0	2									

$$A(1, 2) = A(0, A(1, 2)) = A(0, 2) = 4$$

$$A(3, 4) = 2^{2^{\dots^2}} 65536 \cdot x$$

Inverse zu A

$$\alpha(m, n) = \min \{ i \mid A(i, \lfloor \frac{m}{n} \rfloor) > \log n \}$$

$$\text{Bsp.: } \alpha(24, 8) = \min \{ i \mid A(i, 3) > 3 \} = 0$$

$$\alpha(3 \cdot 2^{16}, 2^{16}) = \min \{ i \mid A(i, 3) > 16 \} = 3$$

Man sieht leicht, dass $\alpha(m, n) \leq 3$ für alle in der Praxis vorkommenden Werte für m & n (\rightarrow Übung)

Beweis des Satzes

Situation: n Knoten (Elemente)

$m > n$ Folge von $n-1$ Unions + m Finds

$$U F_1 F_2 U_2 U_3 F_3 \dots U F \dots F_m U_{n-1}$$


Am Ende: Einen Baum T'

Können wir auch so erhalten: (konzeptionell)


a) Führe zunächst alle $n-1$ Unions aus \rightarrow Baum T
(\log Tiefe)

b) Führe auf T m partielle Finds (partial finds) aus $P F_1, \dots, P F_m$

$P F_i$ simuliert das echte Find F_i , indem es den selben Pfad wie F_i durchläuft (dh. iA. nicht bis zur Wurzel)



$u_1 \dots u_{n-1}$



$P F_1 \dots P F_m T'$

Wir schätzen nun die Kosten der Folge von Unions und partiellen Finds ab.

Sei F die Multi-Menge (Menge in denen Elemente auch mehrfach vorkommen können) der Kanten, die in allen PFs durchlaufen werden.

zu zeigen: $|F| = O(m \cdot \alpha(m, n))$

Idee

a) Teile F in Gruppen nach Rang der Endpunkt der Kanten ein (Rangdifferenz)

$\text{Rang}(x) = \text{Höhe von } x \text{ im Baum } T$
(nicht T')

$\text{Rang}(x)$ ist konstant (in Folge der PF's)

b) schätze alle Gruppen ab

Definitionen


zunächst "Einteilung" der Knoten (nicht disjunkt)

Sei $z \in \mathbb{N}$ (wird später definiert $\rightarrow \alpha(m, n)$)

Für $0 \leq i \leq z$, $j \geq 0$ definiere

$$G_{ij} = \{ \text{knoten } x \mid A(i, j) \leq \text{Rang}(x) < A(i, j+1) \}$$

Veranschaulichen $\{ [A(i, j) \dots A(i, j+1)] \}$: Menge von Intervallen



Beispiel: $\text{Rang}(x) = 7$, $\text{Rang}(y) = 13$

$$\Rightarrow x \in G_{0,5}, G_{1,2}, G_{2,2}, \dots$$

$$y \in G_{0,6}, G_{1,3}, G_{2,2}, \dots$$

Einteilung der Kanten in F

$$N_k = \{ (x, y) \in F \mid k = \min \{ i \geq 0 \mid \exists j \text{ mit } x, y \in G_{ij} \} \}$$

und für $0 \leq k \leq z$ im Bsp $(x, y) \in N_2$

$$N_{z+1} = F \setminus \bigcup_{k=0}^z N_k \quad (\text{Rest})$$

Intuitiv: $(x,y) \in N_i \Rightarrow \text{Rangdiff}(x,y) \approx A(i,\dots) \stackrel{?}{\Rightarrow} \text{Übung}$

Im Beispiel: $\text{Rang}(X)=7, \text{Rang}(Y)=13$

$(x,y) \in N_2 \rightarrow$ erstes mal in selber Menge

$$G_{2,2} = \begin{matrix} A(1,\dots) & \dots & \dots \\ \vdots & & \vdots \\ A(2,2) & \dots & A(2,3) \\ \vdots & & \vdots \end{matrix}$$

Schließlich definiere:

$$L_k := \{ (x,y) \in N_k \mid (x,y) \text{ ist letzte (oberste) Kante auf PF-Pfad} \}$$

für $0 \leq k \leq z+1$

Lemma

a) $|L_k| \leq m$ für $0 \leq k \leq z+1$

b) $|N_0|, |L_0| \leq n$

c) $|N_k|, |L_k| \leq \frac{5}{8} n$ für $0 \leq k \leq z$

d) $|N_{z+1}|, |L_{z+1}| \leq n \cdot a(z,n)$, wobei $a(z,n) = \min \{ i \mid A(z,i) > \log n \}$

Beweis

zu a) Für jedes PF gibt es höchstens 1 Kante in L_k (eine letzte Kante)
Da m PF's \Rightarrow Teil a

zu b) Sei $(x,y) \in N_0/L_0$, dann gilt:

1) $\exists j$ (Spalte) mit $x,y \in G_{0,j}$

dh $A(0,j) \leq \text{Rang}(x) < \text{Rang}(y) < A(0,j+1)$ (Übung)


$$\begin{aligned} & \Rightarrow \underset{2j}{\text{Rang}(x)} = 2j \text{ und } \underset{2(j+1)}{\text{Rang}(y)} = 2j+1 \\ & \Rightarrow \text{dh. Rangdifferenz} = 1 \end{aligned}$$

2) $(x,y) \notin L_0 \Rightarrow$ war nicht letzte Kante auf PF-Pfad

PF-Pfad:

PF(v)

es kann sein $y=s$



Betrachte PF (des (x,y) nach N_0 brachte

Dann $\exists (s,t) \neq (x,y)$ auf PF-Pfad mit $(s,t) \in N_0$
mit $\text{Rang}(x) = 2j$

$$\begin{aligned} \text{Rang}(y) &= 2j+1 \\ \text{Rang}(s) &\geq \text{Rang}(y) \\ \text{Rang}(t) &> \text{Rang}(s) \\ &= \text{Rang}(s)+1 \end{aligned}$$

$$\Rightarrow \text{Rang}(t) \geq 2j+2$$

Nach PF: x hat neuen Vater u ($u=t$ ist möglich)
 \Rightarrow Rangdifferenz $(x,u) \geq 2$

\Rightarrow spätere PFs können keine Kante (x,u) zu N_0 hinzufügen

\Rightarrow für alle Knoten x gilt es höchstens eine Kante $(x, y) \in N_k \setminus L_k$
 $\Rightarrow |N_k \setminus L_k| \leq r$

zu c)


wie oben: Schätze Beitrag eines Knotens $x \in G_{k,j}$ zu $|N_k \setminus L_k|$ ab
 dh. alle Kanten (x, \dots) mit ...

Sei $k \geq 1$ und $x \in G_{k,j}$ beliebig (Spalte j)
 dh. $A(k, j) \leq \text{Rang}(x) < A(k, j+1)$

und y_1, y_2, \dots, y_q alle Endknoten mit $(x, y_i) \in N_k \setminus L_k$ in der
 Reihenfolge in der sie von PFs benutzt werden

dh. y_{i+1} ist Wurzel des PF von (x, y_i)

$$\Rightarrow \text{Rang}(y_1) \leq \text{Rang}(y_2) \leq \dots \leq \text{Rang}(y_q) < A(k, j+1)$$



Dann gilt:

i) $j \geq 2$ denn sonst wär $k=0$ ^(min)

ii) $(x, y_i) \notin L_k$ für $i=1, \dots, q \Rightarrow \exists (s_i, t_i) \in N_k$ oberhalb von (x, y_i) auf PF

$$\Rightarrow \text{Rang}(x) < \text{Rang}(y_i) \leq \text{Rang}(s_i) < \text{Rang}(t_i) \leq \text{Rang}(y_{i+1})$$

nach Pfadkomprimierung: x hat Vater y_{i+1}

Definition von N_k (k minimal)

$$\Rightarrow (x, x_i), (s_i, t_i) \in N_{k-1}$$

$$\Rightarrow \exists j' \text{ mit } \text{Rang}(s_i) < A(k-1, j') \leq \text{Rang}(t_i)$$

Zeile $n-1$

und daher gilt

$$G_{k-1, j'-1}$$

$$G_{k-1, j}$$

$$\text{Rang}(y_i) < A(k-1, j) \leq \text{Rang}(y_{i+1})$$

Iteriere: q -mal (für y_1, \dots, y_q)


$$\Rightarrow \exists j'' \text{ mit } \text{Rang}(y_i) < A(k-1, j'') \leq A(k-1, j''+q-1) \leq \text{Rang}(y_q)$$

$$\textcircled{I} \exists j \text{ mit } \text{Rang}(y_q) \geq A(k-1, j+q-1)$$

Beobachtung: $j \geq 2$ (siehe oben)

Teile: $1 \leq k \leq z$

$$x \in G_{n,j}, (x, y) \in N^r \Rightarrow y_1, \dots, y_q \in G_{k,j}$$



$$A(k, j) \leq \text{Rang}(y_1) \leq \dots \leq \text{Rang}(y_q) < A(k, j+1)$$

$$\textcircled{\text{I}} \text{Rang}(y_q) < A(k, j+1)$$

$$\textcircled{\text{I+II}} A(k-1, j+q-1) < A(k, j+1) = A(k-1, A(k, j))$$

Monotonie

$$\Rightarrow j+q-1 < A(k, j)$$

$$j \geq 2$$

$$\Rightarrow q < A(k, j)$$

Das bedeutet (Zusammenfassung)

Für jedes $x \in G_{k,j}$, $k \geq 1$, $j \geq 2$ gibt es höchstens $A(k, j)$ Kanten $(x, y) \in N_k \setminus L_k$

$$\Rightarrow |N_k \setminus L_k| \leq \sum_{j=2} |G_{k,j}| \cdot A(k, j)$$

$$* \text{ Behauptung: } |G_{k,j}| \leq \frac{2n}{2^{A(k,j)}}$$

Daraus folgt:

$$|N_k \setminus L_k| \leq \sum_{j=2} \frac{2n \cdot A(k,j)}{2^{A(k,j)}} \leq 2n \cdot \sum_{j=2} \frac{A(k,j)}{2^{A(k,j)}}$$

Es gilt: da $k \geq 1$, $A(k, j) \geq 2^j$

$$= 2n \sum_{j=2} \frac{2^j}{2^{2^j}} = 2n \sum_{j=2} \frac{1}{2^{2^j - j}} = 2n \cdot \left(\frac{1}{4} + \frac{1}{32} + \frac{1}{2^{42}} + \dots \right)$$

$$\leq 2n \cdot \frac{5}{16} = \frac{5}{8} n$$

$$* \text{ Beweis der Behauptung: } |G_{k,j}| \leq \frac{2n}{2^{A(k,j)}} \quad \text{mit } k \geq 1, j \geq 2$$

$G_{k,j}$ = Knoten mit Rang im Intervall $[A(k, j) \dots A(k, j+1)]$

Sei ℓ eine bel. natürliche Zahl mit $A(k, j) \leq \ell < A(k, j+1)$

Wir zählen alle $x \in G_{k,j}$ mit $\text{Rang}(x) = \ell$

$$\text{Sei } G_{k,j,\ell} = \{x \in G_{k,j} \mid \text{Rang}(x) = \ell\}$$

Es gilt:

i) Jeder Knoten x mit Rang ℓ hat $\geq 2^\ell$ Nachkommen (Gewicht von $x \geq 2^\ell$) ← weighted union

ii) Für x, y mit $\text{Rang}(x) = \text{Rang}(y)$ und $x \neq y$ sind die Nachfolgemengen disjunkt

$$i) + ii) \Rightarrow |G_{k,j,\ell}| \leq \sum_{\ell=A(k,j)}^{A(k,j+1)-1} |G_{k,j,\ell}| \leq \sum_{\ell=A(k,j)}^{\infty} \frac{n}{2^\ell} = n \cdot \sum_{\ell=A(k,j)}^{\infty} \frac{1}{2^\ell}$$

$$= \frac{1}{2^{A(k,j)}} + \frac{1}{2} \cdot \frac{1}{2^{A(k,j)}} + \frac{1}{4} \cdot \frac{1}{2^{A(k,j)}} = \frac{n}{2^{A(k,j)}} \cdot \left(1 + \frac{1}{2} + \frac{1}{4} + \dots\right)$$

$$\leq \frac{2n}{2^{A(k,j)}}$$

zu d) $k = z+1$ auch hier Schranke q

weighted union $\Rightarrow \text{Rang}(y_q) \leq \log n$ (da T 's Höhe $\leq \log n$)

Ⓘ für $k = z+1$

$$\exists j: \text{Rang}(y_q) \geq A(k-1, j+q-1) \text{ mit } j \geq 2$$

$$\log n \geq \text{Rang}(y_q) \geq A(z, j+q-1)$$

$$\Rightarrow A(z, j+q-1) \leq \log n$$

$$\Rightarrow j+q-1 < a(z, n), \text{ da } a(z, n) \text{ minimal mit } A(z, a(z, n)) > \log n$$

$$j \geq 2 \Rightarrow q \leq a(z, n)$$

Also gibt es höchstens $a(z, n)$ Kanten (x, y) für jeden Knoten x in $N_{z+1} \setminus L_{z+1}$

$$\Rightarrow |N_{z+1} \setminus L_{z+1}| \leq n \cdot a(z, n)$$

■ a, b, c, d

Zurück zu Satz (Tarjan)

Kosten aller $m \geq n$ Finds

$$|F| = \sum_{k=0}^{z+1} |L_k| + |N_0| |L_0| + \sum_{k=1}^z |N_k| |L_k| + |N_{z+1}| |L_{z+1}|$$

$$|F| \leq \underbrace{(z+2) \cdot m + n}_{\text{A}} + \underbrace{z \cdot \frac{5}{8} n}_{\text{C}} + \underbrace{n \cdot a(z, n)}_{\text{B}}$$

Das gilt für jedes z !

Betrachte $z = \alpha(m, n)$, $m \geq n$

i) $A = O(m \cdot \alpha(m, n))$ Def von α

ii) $a(z, n) = a(\alpha(m, n), n) = \min \{j \mid A(\alpha(m, n), j) > \log n\}$

mit $\alpha(m, n) = \min \{i \mid A(i, \frac{4m}{n}) > \log n\}$

$$\leq \lfloor \frac{4m}{n} \rfloor$$

$$\Rightarrow \text{B} \leq n \cdot \lfloor \frac{4m}{n} \rfloor = O(m)$$

$$\text{A+B} = O(m \cdot \alpha(m, n))$$

Satz: $n-1$ Unions und $m \neq n$ Finds kosten $O(m \cdot \alpha(m, n))$

- i) nicht linear \leftrightarrow praktisch: $O(m)$, da $\alpha(m, n) \leq 3$ für realistische Werte
- ii) praktisch sehr effizient (kleine Konstante)
- iii) leicht implementierbar, Korrektheit einfach
- iv) obere Schranke ist scharf, d.h. es gibt Probleminstanzen mit dieser Laufzeit
- v) die Komplexität des Problems ist tatsächlich

$\Omega(m \cdot \alpha(m, n))$ untere Schranke

Union/Find \leftrightarrow Split/Find (\rightarrow Übung)

\downarrow
Mengen sortiert, Splitten an einer Stelle mit $\leq, >$
 \Rightarrow Menge von Intervallen (disjunkt) von x
in Teile $A \leq x$ und $B > x$

