

# Effiziente Algorithmen und Datenstrukturen I

## Kapitel 6: Verschiedenes

Christian Scheideler  
WS 2008

# Übersicht

- Union-Find Datenstruktur
- DS zur Speicherallokation
- DS für Speicherzugriffe
- DS zur Bandbreitenallokation

# Union-Find Datenstruktur

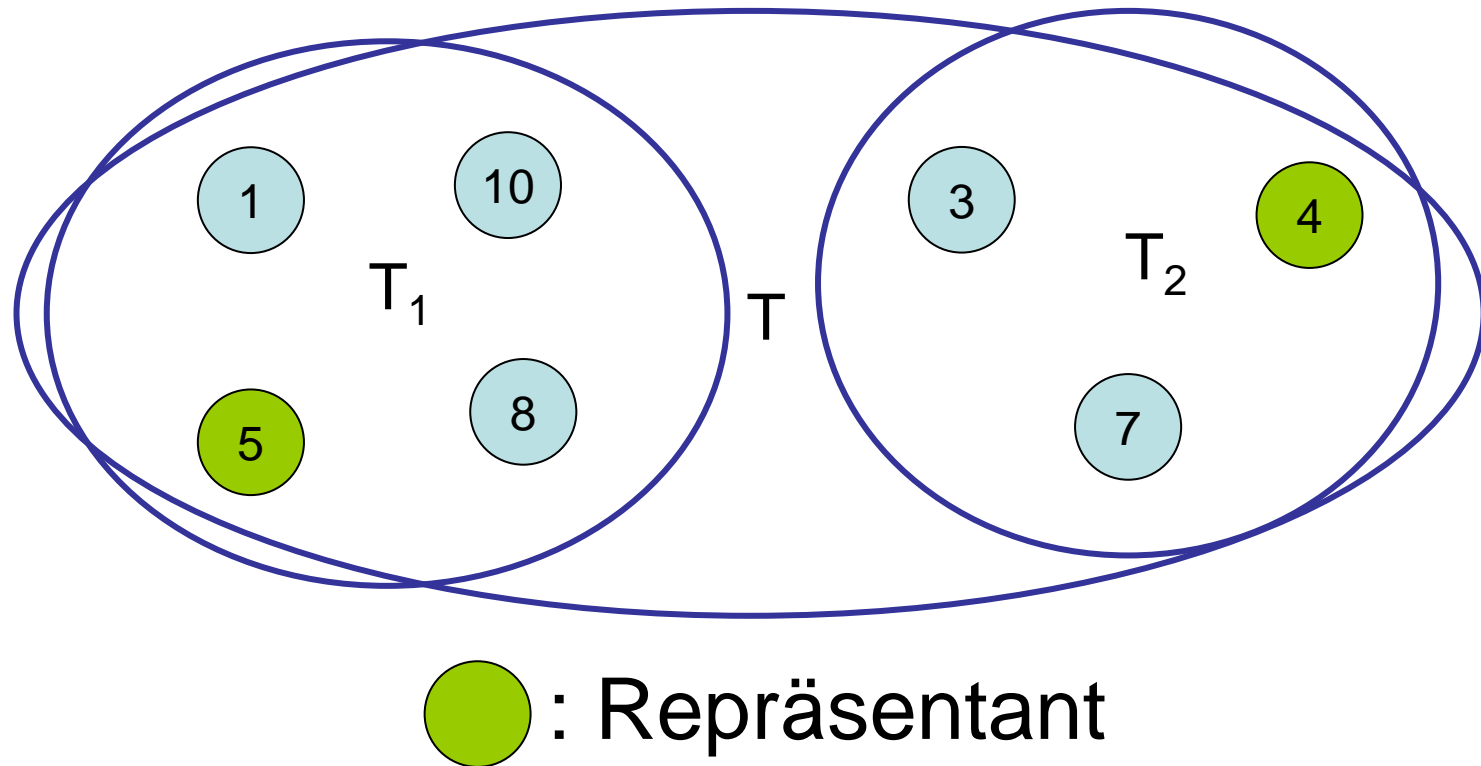
Gegeben: Menge von  $n$  Teilmengen  $T_1, \dots, T_n$  die jeweils ein Element enthalten.

Operationen:

- **Union( $T_1, T_2$ ):** vereinigt Elemente in  $T_1$  und  $T_2$  zu  $T = T_1 \cup T_2$
- **Find( $x$ ):** gibt (eindeutigen) Repräsentanten der Teilmenge aus, zu der  $x$  gehört


# Union-Find Datenstruktur

Union( $T_1, T_2$ ):



# Union-Find Datenstruktur


Find(10) liefert 5



 : Repräsentant

# Union-Find Datenstruktur


**Idee:** repräsentiere jede Menge  $T$  als gerichteten Baum mit Wurzel als Repräsentant



# Union-Find Datenstruktur

## Realisierung der Operationen:

- $\text{Union}(T_1, T_2)$ :



- $\text{Find}(x)$ : Suche Wurzel des Baumes, in dem sich  $x$  befindet

# Union-Find Datenstruktur

## Naïve Implementierung:

- Tiefe des Baums kann bis zu  $n$  (bei  $n$  Elementen) sein
- Zeit für Find:  $\Theta(n)$  im worst case
- Zeit für Union:  $O(1)$



# Union-Find Datenstruktur

**Gewichtete Union-Operation:** Mache die Wurzel des flacheren Baums zum Kind der Wurzel des tieferen Baums.

**Lemma 6.1:** Die Tiefe eines Baums ist höchstens  $O(\log n)$ .

**Beweis:**

- Die Tiefe von  $T = T_1 \cup T_2$  erhöht sich nur dann, wenn  $\text{Tiefe}(T_1) = \text{Tiefe}(T_2)$  ist
- $N(t)$ : min. Anzahl Elemente in Baum der Tiefe  $t$
- Es gilt  $N(t) = 2 \cdot N(t-1)$  und  $N(0) = 1$
- Also ist  $N(\log n) = n$

# Union-Find Datenstruktur

Mit gewichteter Union-Operation:


- Zeit für Find:  $O(\log n)$
- Zeit für Union:  $O(1)$

Es gilt auch: Tiefe eines Baums im worst-case  $\Omega(\log n)$  (verwende Strategie, die Formel im Beweis von Lemma 6.1 folgt)

# Union-Find Datenstruktur

Besser: gewichtetes Union mit Pfadkompression

Pfadkompression bei jedem Find(x): **alle** Knoten von **x** zur Wurzel zeigen direkt auf Wurzel



# Union-Find Datenstruktur

Bemerkung:  $\log^* n$  ist definiert als

$$\log^* n = \min\{ i \geq 0 \mid \underbrace{\log \log \dots \log n}_{i\text{-mal}} \leq 1 \}$$

Beispiele:

- $\log^* 0 = \log^* 1 = 0$
- $\log^* 2 = 1$
- $\log^* 4 = 2$
- $\log^* 16 = 3$
- $\log^* 2^{65536} = 5$

# Union-Find Datenstruktur

**Theorem 6.2:** Bei gewichtetem Union mit Pfadkompression ist die amortisierte Zeit für Union und Find  $O(\log^* n)$ .

**Beweis:**

- $T'$ : endgültiger Baum, der durch die Folge der Unions ohne die Finds entstehen würde (also ohne Pfadkompression).

Ordne jedem Element  $x$  zwei Werte zu:

- $\text{rank}(x)$  = Höhe des Unterbaums mit Wurzel  $x$
- $\text{class}(x) = i$  für das  $i$  mit  $a_{i-1} < \text{rank}(x) \leq a_i$   
wobei  $a_{-1} = -1$ ,  $a_0 = 0$  und  $a_i = 2^{a_i-1}$  für alle  $i > 0$



# Union-Find Datenstruktur

Beweis (Fortsetzung):

- $\text{dist}(x)$ : Distanz von  $x$  zu einem Vorfahr  $y$  im tatsächlichen Union-Find-Baum  $T$  (mit Pfadkompression), so dass  $\text{class}(y) > \text{class}(x)$  ist, bzw. zur Wurzel  $y$

Potenzialfunktion:

$$\Phi := c \sum_x \text{dist}(x)$$

für eine geeignete Konstante  $c > 0$ .

# Union-Find Datenstruktur

## Beobachtungen:

- Für den tatsächlichen Union-Find-Baum  $T$  seien  $x$  und  $y$  Knoten in  $T$ ,  $y$  Vater von  $x$ . Dann ist  $\text{class}(x) \leq \text{class}(y)$ .
- Aufeinander folgende Find-Operationen durchlaufen (bis auf die letzte) verschiedene Kanten. Diese Kanten sind eine Teilfolge der Kanten in  $T'$  auf dem Pfad von  $x$  zur Wurzel.



# Union-Find Datenstruktur


## Amortisierte Kosten von Find:

- $x_0 \rightarrow x_1 \rightarrow x_2 \dots x_k$ : Pfad von  $x_0$  zur Wurzel in  $T'$
- Es gibt höchstens  $\log^* n$  Kanten  $(x_{i-1}, x_i)$  mit  $\text{class}(x_{i-1}) < \text{class}(x_i)$
- Ist  $\text{class}(x_{i-1}) = \text{class}(x_i)$  und  $i < k$ , dann ist  $\text{dist}(x_{i-1})$  vor der Find-Operation  $\geq 2$  und nachher  $= 1$ .
- Damit können die Kosten für alle Kanten  $(x_{i-1}, x_i)$  mit  $\text{class}(x_{i-1}) = \text{class}(x_i)$  aus der Potenzialverringerung bezahlt werden
- Amortisierte Kosten sind also  $O(\log^* n)$

# Union-Find Datenstruktur

Amortisierte Kosten von Union:

- **dist**-Änderungen über alle Unions bzgl.  $T'$  ist gleich  $\Phi(T')$



- Potenzial von Baum  $T'$  mit  $n$  Knoten:

$$\Phi(T') \leq c \sum_{i=0}^{\log^* n} \sum_{x:\text{rank}(x)=a_{i-1}+1}^{a_i} \text{dist}(x)$$

# Union-Find Datenstruktur

$$\begin{aligned}\Phi(T') &\leq c \sum_{i=0}^{\log^* n} \sum_{x:\text{rank}(x)=a_{i-1}+1}^{a_i} \text{dist}(x) \\ &\leq c \sum_{i=0}^{\log^* n} (n/2^j) a_i \quad \text{mit } j=a_{i-1}+1 \\ &\leq c \cdot n \sum_{i=0}^{\log^* n} a_i / 2^{a_i-1} \\ &\leq c \cdot n \sum_{i=0}^{\log^* n} 1 \\ &= O(n \log^* n)\end{aligned}$$

Die zweite Ungleichung gilt, da alle Unterbäume, deren Wurzel  $x$   $\text{rank}(x)=j$  hat, disjunkt sind und jeweils  $\geq 2^j$  Knoten enthalten.

# Union-Find Datenstruktur

Bessere obere Schranke mit  $\alpha(k,n)$ ,  $k \geq n$ .

Betrachte die Ackermannfunktion  $A(m,n)$  mit

- $A(0,n) = 2n$
- $A(m,0) = 2$
- $A(m+1,n+1) = A(m, A(m+1,n))$

Die Ackermannfunktion  $A(n,n)$  steigt asymptotisch schneller als jede primitiv rekursive Funktion (d.h. auch  $\log^* n$ ).

# Union-Find Datenstruktur

Weiter wird gesetzt:

$$\alpha(k,n) = \min\{ i \geq 1 \mid A(i, \lfloor k/n \rfloor) > \log n \}$$

Dann gilt: Der amortisierte Zeitbedarf für eine Folge von  $k$  Find- und  $n-1$  Union-Operationen auf einer Menge von  $n$  Elementen ist  $O(\alpha(k,n))$ .

Es gibt auch eine entsprechende untere Schranke.

# Übersicht

- Union-Find Datenstruktur
- DS zur Speicherallokation
- DS für Speicherzugriffe
- DS zur Bandbreitenallokation

# Das Buddy System

**Problem:** Verwaltung freier Blöcke in einem gegebenen Adressraum  $\{0, \dots, m-1\}$  zur effizienten Allokation und Deallokation.



**Vereinfachung:**

- $m$  ist eine Zweierpotenz
- nur Zweierpotenzen für allokierte Blockgrößen erlaubt

# Das Buddy System

$M \subset \{0, \dots, m-1\}$ : freier Adressraum

Operationen:

- **Allocate( $i$ )**: allokiert Block der Größe  $2^i$ ,  
d.h.  $M := M \setminus B$  für einen Block  $B \subset M$  der  
Größe  $2^i$
- **Deallocate( $B$ )**: gibt Block  $B$  wieder frei,  
d.h.  $M := M \cup B$



# Die Buddy Datenstruktur

## Physikalischer Adressraum:

- **F**: Feld von  $\log m + 1$  Blocklisten  
 $F[i]$ ,  $i \geq 0$ , speichert Anfangsadressen freier Blöcke der Größe  $2^i$
- Verwende das erste Byte von jedem allokierten Block der Größe  $2^i$  zur Speicherung von  $i+1$  (das reicht, da damit Blockgrößen bis zu  $2^{2^8-2} = 2^{254}$  möglich).  
Freie Blöcke haben dieses Byte auf **0** gesetzt.


# Die Buddy Datenstruktur

## Virtueller Adressraum:

- **F**: Feld von  $\log m + 1$  Blocklisten  
 $F[0], \dots, F[\log m]$
- **T**: Hashtabelle mit Einträgen zu freien Blöcken. Jeder Eintrag enthält:
  - Startadresse  $\text{addr}(B)$  des Blocks **B**
  - Größe von Block **B** ( $|B|=2^i$ : speichere  $i$ )


# Das Buddy System

$F[i]$ : Liste von Blockgrößen  $2^i$




# Das Buddy System

Allocate(3):




# Das Buddy System

Allocate(2):



# Das Buddy System

Deallocate(B): (Größe von B ist  $2^2$ )



# Das Buddy System

Problem: zunehmende Fragmentierung

Definition 6.3:

- Block  $B$  der Größe  $2^i$  ist **gültig**: Startadresse von  $B$  ist  $0$  für die ersten  $i$  Bits
- **Buddy** von Block  $B$  der Größe  $2^i$ : Block  $B'$ , für den  $B \cup B'$  einen gültigen Block der Größe  $2^{i+1}$  ergibt

**Invariante**: Für jeden freien Block  $B$  in Feld  $F$  ist der Buddy belegt.

# Das Buddy System

Bewahrung der Invariante bei Deallocate(B):

```
while Buddy(B) frei do
    B:=B  $\cup$  Buddy(B)
    speichere B in F und T ab
```

Schnelle Bestimmung von Buddy(B):


- berechne Startadresse von  $B' = \text{Buddy}(B)$   
(folgt direkt aus Startadresse von B)
- prüfe mittels T, ob  $B'$  existiert (beim physikalischen Adressraum reicht es stattdessen, direkt auf das erste Byte von  $B'$  zuzugreifen)



# Das Buddy System

## Probleme:

1. trotz Buddy-Ansatz keine garantiert niedrigen Obergrenzen für Fragmentierung
2. Allocate und Deallocate können  $\Theta(\log m)$  viele Schritte laufen (wegen split- oder merge-Operationen)  
Beispiel: Allocate(0)




# Das Buddy System

## Probleme:

1. trotz Buddy-Ansatz keine garantiert niedrigen Obergrenzen für Fragmentierung
2. Allocate und Deallocate können  $\Theta(\log m)$  viele Schritte laufen (wegen split- oder merge-Operationen)

Beispiel: Deallocate(0)




# Das Buddy System

## 1. Problem: Fragmentierung

**Theorem 6.4:** Die Anzahl freier Blöcke ist höchstens  $O(\log m \cdot \text{Anzahl allozierter Blöcke})$ .

**Beweis:**

- Freier Block nicht kombinierbar: allozierter Block dafür ein Zeuge



- Allozierter Block wird von höchstens  $\log m$  freien Blöcken als Zeuge verwendet.

# Verbessertes Buddy System

2. Problem: Allocate und Deallocate brauchen Zeit  $\Theta(\log m)$ : kann effizient gelöst werden.

**Idee:** erlaube Blöcke, die freien Speicher der Form  $2^k - 2^i$  ( $i < k$ ) angeben.



Solche Blöcke werden in  $F[k-1]$  gespeichert.

# Verbessertes Buddy System

Allocate( $i$ ): führe **lazy splitting** durch.

- Fall 1:  $2^k$ -Block  $B$  vorhanden,  $k \geq i$ .

Schneide aus  $B$  vorderen  $2^i$ -Block raus, Rest von  $B$  wird  $2^k - 2^i$ -Block.

- Fall 2: nur  $2^k - 2^j$ -Block  $B$  vorhanden,  $k > i$ .

Schneide ersten gültigen  $2^i$ -Block aus  $B$  raus.

Damit teilt sich  $B$  in  $2^i - 2^j$ -Block und  $2^k - 2^{i+1}$ -Block auf.

Laufzeit:  $O(1)$ , falls Suche nach  $2^k$ -Block bzw.  $2^k - 2^j$ -Block in  $O(1)$  Zeit machbar.

# Verbessertes Buddy System

$O(1)$  Suchzeit nach passendem Block:

- **Strategie 1:** Falls Worte der Größe  $\log m + 1$  verfügbar, die mit Einheitskosten bearbeitet werden können, dann setze Bit  $i$  von Indexwort  $W$  auf 1 genau dann, wenn  $F[i]$  ein Element enthält. Suche dann nach dem erstem gesetzten Bit  $k \geq i$  bzw.  $k > i$  (was mit Pentium-Prozessoren in  $O(1)$  Zeit machbar ist).
- **Strategie 2:** Tabelle der Größe  $m^\varepsilon$ , die für jede Zahl  $z \in \{0, \dots, m^\varepsilon - 1\}$  das niedrigste gesetzte Bit in  $z$  enthält. Damit maximal  $1/\varepsilon$  Zeit, bis passender Index  $k \geq i$  bzw.  $k > i$  gefunden.

# Verbessertes Buddy System

Deallocate( $B$ ): führe **lazy merging** durch.

- Wiederhole, bis kein Fall mehr eintritt:
  - Fall 1:  $B$  hat freien Buddy  $B' = \text{Buddy}(B)$  in  $F$ :  
 $B := B \cup B'$
  - Fall 2:  $B$  gehört zu freiem  $2^k - 2^i$ -Block  $B'$  in  $F$ , Größe von  $B$  ist  $2^i$ :  
 $B := B \cup B'$
- Speichere  $B$  in  $F$  (und  $T$ ) ab

Laufzeit: amortisiert  $O(1)$ .

# Verbessertes Buddy System

**Lemma:** Die amortisierte Laufzeit der Deallocate-Operation ist  $O(1)$ .

**Beweis:**

- Ein Merge wird nur dann auf  $B$  und  $B'$  angewandt, wenn  $B \cup B'$  vorher in einem Allocate in  $B$  und  $B'$  geteilt worden ist.
- Gib jedem Block ein Potenzial, das angibt, dass er Ergebnis eines Splittings ist. Damit können Kosten des Mergens verrechnet werden.



# Übersicht

- Union-Find Datenstruktur
- DS zur Speicherallokation
- **DS für Speicherzugriffe**
- DS zur Bandbreitenallokation

# Buddies mit Reallokation



Situation hier:

- Speicherreallokationen erlaubt
- **Allocate(i)** hat ohne Reallokation  $2^i$  Zeitaufwand (Speicher wird überschrieben)
- **Deallocate(i)** hat keinen extra Zeitaufwand (Speicher wird lediglich freigegeben)

# Buddies mit Reallokation

## Allocate(i):

- Annahme: zusammen mit neuem  $2^i$ -Block sind  $(1-\varepsilon)m$  der Speicherzellen belegt.
- Suche gültigen  $2^i$ -Block  $B$  mit Belegung  $<(1-\varepsilon)2^i$  (muss existieren!)
- Für alle Blöcke  $B'$  in  $B$ :  
weise  $B'$  Allocate( $\log|B'|$ ) zu
- Gib  $B$  zurück

Deallocate(B): wie im original Buddy-System

# Buddies mit Reallokation

**Theorem 6.5:** Allocate( $i$ ) hat einen Zeitaufwand von höchstens  $2^i/\epsilon$ .

**Beweis:**

- Allokation von Block  $B$ : Aufwand  $2^i$
- Reallokation der belegten Blöcke  $B'$  in  $B$ : Aufwand  $<(1-\epsilon)2^i$
- Reallokation der dadurch verdrängten Blöcke  $<(1-\epsilon)^2 2^i$
- usw.
- Aufwand insgesamt max.  $2^i \sum_{j \geq 0} (1-\epsilon)^j = 2^i/\epsilon$

# Übersicht

- Union-Find Datenstruktur
- DS zur Speicherallokation
- DS für Speicherzugriffe
- **DS zur Bandbreitenallokation**

# Bandbreitenallokation

**Problem:** Verwaltung freier Frequenzen in einem gegebenen Frequenzraum  $\{0, \dots, m-1\}$  zur effizienten Allokation und Deallokation.



**Vereinfachung (wie bei Buddy-System):**

- $m$  ist eine Zweierpotenz
- nur Zweierpotenzen für allokierte Blockgrößen erlaubt

# Bandbreitenallokation

**Situation hier:** Reallokation von zugewiesenen Bandbreiten ist einfach machbar ( $O(1)$  Zeit pro Block)

**Problem beim Buddy System:** Reallokation teuer bzw. nicht möglich, da Speicherbereiche umkopiert werden müssen.

# Bandbreitenallokation

$M \subset \{0, \dots, m-1\}$ : freier Frequenzraum


Operationen:

- **Allocate( $i$ )**: allokiert Block der Größe  $2^i$ ,  
d.h.  $M := M \setminus B$  für einen Block  $B \subset M$  der  
Größe  $2^i$
- **Deallocate( $B$ )**: gibt Block  $B$  wieder frei,  
d.h.  $M := M \cup B$



# Bandbreitenallokation

**Datenstruktur:** Binärbaum mit freien ( ) und belegten Blättern ( )



# Bandbreitenallokation

**Naiver Ansatz:** Halte die belegten Blöcke sortiert nach Größe.

**Das kann sehr viel Umorganisation verursachen.**

Eine Strategie mit maximal 5 Umplatzierungen pro Allocate und Deallocate ist in “A Constant-Competitive Algorithm for Online OVSF Code Assignment” von F.Y.L. Chin, H.F. Ting und Y. Zhang zu finden.

# Nächstes Kapitel

Wir fangen mit Graphalgorithmen an.