



Informatik II

Van Emde Boas Trees

G. Zachmann
Clausthal University, Germany
zach@tu-clausthal.de



Einleitende Betrachtungen

- Bei vielen Algorithmen / Datenstrukturen (z.B. Sortieren) haben wir nur eine minimale Menge an Basisoperationen vorausgesetzt (z.B. die Vergleichsoperation) ...
- Aber: warum sollen wir nicht ausnutzen, dass wir in allen Fällen eine Maschinenrepräsentation der Daten haben und dass diese in den meisten Fällen
 - einfach ist (z.B. Binärzahlen), und
 - wir darauf noch viel mehr Operationen zur Verfügung haben? (in Zeit $O(1)$, also Basisoperationen)

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 2

- Van-Emde-Boas-Trees haben alles, was ein Klassiker unter den Datenstrukturen braucht ☺ :
 - Ist hinreichend einfach, so dass eine relativ große Zahl von Leuten sie verstehen
 - Ist elegant
 - Hat Anwendungen in vielen sehr verschiedenen Bereichen
 - Hat einen hohen "Impact" (= wird in vielen anderen Algorithmen als Tool verwendet)
 - Löst ein fundamentales Problem optimal
 - Es gibt 101 Varianten davon
 - Und D.E. Knuth war begeistert davon ☺

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 3

- Portrait des Erfinders (von seiner Homepage <http://staff.science.uva.nl/~peter>)



G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 4

Das Ziel

- Betrachte als **Universum** eine Teilmenge der ganzen Zahlen:

$$\mathcal{U} = \{0, \dots, u - 1\} \subset \mathbb{N}$$
- Gesucht: eine Datenstruktur T , die $S \subset \mathcal{U}$ speichern kann, und folgende Operationen für $x \in \mathcal{U}$ bietet:
 - $T.find(x)$: suche x in T
 - $T.insert(x)$: füge x zu T hinzu
 - $T.delete(x)$: lösche x aus T
 - $T.findSucc(x)$: suche das kleinste Element in T , das größer x ist, m.a.W.,
 suche $\min\{y \in S \mid y > x\}$
 - $T.findPred(x)$: analog

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 5

Naive Ansätze

- Lösung mittels **Bit-Array** (a.k.a., **Bit-String**, **Bit-Set**)
- Definition:
 Ein **Bit-Array** $a \in \{0,1\}^u$ repräsentiert $S \subset \mathcal{U}$ folgendermaßen:

$$x \in S \Leftrightarrow a[x] = 1$$
- Beispiel: die Menge $\{1, 9, 17\}$ aus dem Universum $\{0, 31\}$ wird als Bit-String so repräsentiert

$$01000000010000000100000000000000$$
 (LSB first).
- Vorteile: Insert und Delete gehen in Zeit $O(1)$
- Nachteile:
 - Für das Universum der Integer-Zahlen braucht man seehr lange Bitstrings
 - FindSucc geht (im *worst case*) nur in Zeit $O(u)!$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 6

Hilfsfunktionen

- Jedes $x \in \mathcal{U}$ wird als Binärzahl mit $\log(u)$ vielen Bits dargestellt
- Definiere:

$$\text{high}(x) = \lfloor \frac{x}{\sqrt{u}} \rfloor$$

$$\text{low}(x) = x \bmod \sqrt{u}$$
- In Informatikersprache:
 - high(x) := **obere Hälfte** der Bits der Binärdarstellung von x
 - low(x) := **untere Hälfte** der Bits der Binärdarstellung von x
 - Man kann diese Operationen also sehr schnell implementieren
- Annahme im Folgenden: $u = 2^{2^k}$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 9

Die Datenstruktur

- Definition:


Ein vEB-Tree B_u speichert eine Teilmenge $S \subset \mathcal{U}$ mit Hilfe folgender (interner) Daten:

 1. **lo** der Größe \sqrt{u} , wobei **lo**[i] ein vEB-Tree $B_{\sqrt{u}}$ ist;
 2. **hi** = ein vEB-Tree $B_{\sqrt{u}}$
 3. **size** = Anzahl Elemente in B
 4. **max, min** = größtes und kleines Element aus S
- Achtung: $B_{\sqrt{u}}$ ist "nur" noch ein vEB-Tree über ein Universum


$$\mathcal{U}' = \{0, \dots, \sqrt{u} - 1\}$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 10

- Ein Knoten eines vEB-Tree sieht also so aus:



- Repräsentation der Menge S im vEB-Tree B :
 - Min und Max von S werden in `min`, `max` gespeichert
 - Alle übrigen $x \in S \setminus \{\min, \max\}$ werden so gespeichert:
 - Zerlege $x =: a\sqrt{u} + b$
 - `hi` speichert den Wert a , `lo[a]` speichert den Wert b
- Bemerkung: man hat also den zusätzlichen Constraint, daß der vEB-Tree `hi` den Wert a genau dann enthält, wenn der vEB-Tree `lo[a]` nicht leer ist.
- Noch eine Bemerkung:
 - Der vEB-Tree `lo[a]` ist also für alle Werte im Bereich $a\sqrt{u}, \dots, (a+1)\sqrt{u} - 1$ "zuständig"
 - Bei allen diesen Werten sind die oberen $\frac{\log u}{2}$ Bits gleich



Die Insert-Operation

- Der Algorithmus:


```

insert( x ):
  if size == 0:
    size = 1
    min = max = x
  else
    if x < min:
      min, x = x, min           # (1)
    a = high(x); b = low(x)
    if lo[a] == None:
      hi.insert( a )
      lo[a] = vEB_Tree()
    lo[a].insert( b )         # (2)
    update size & max
      
```
- Bemerkungen:
 - Hier wird x in `min` gespeichert (als neues `min`), so daß man im Folgenden nur noch das alte `min` woanders unterbringen muß
 - Falls `lo[a]` vorher leer war, kostet dieser Aufruf nur Zeit $O(1)$!

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 14

Die FindSuccessor-Operation

- Der Algorithmus:


```
findSucc( x ):
  test and deal with special cases
  (size==0, size==1, size==2)
  if x < min:
    return min
  a = high(x); b = low(x)
  if lo[a] != None and b < lo[a].max:
    c = a
    d = lo[a].findSucc( b )      (1)
  else:
    c = hi.findSucc( a )        (2)
    d = lo[c].min
  y = c*sqrt(u) + d
  return y
```
- Bemerkungen:
 - Liefert auf jeden Fall einen gültigen Wert d
 - Aus Gründen der Klarheit fehlt hier der Fall, dass in hi kein Nachfolger zu a existiert

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 15

Ein vEB-Tree ist gleichzeitig eine P-Queue

- Erinnerung: P-Queue = Datenstruktur, die folgende Operationen erlaubt
 - Insert(item, prio)
 - ExtractMin → liefert dasjenige Element mit höchster Prio
- Delete auf vEB-Trees funktioniert analog zur Insert-Operation
- Damit kann man trivial eine ExtractMin-Operation implementieren
- Damit realisiert ein vEB-Tree eine P-Queue und erlaubt
 - Insert in Zeit $O(\log \log n)$
 - ExtractMin in Zeit $O(\log \log n)$
 - Ist also exponentiell besser als Heaps

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 16

Laufzeit

- Rekurrenzgleichung für die Laufzeit lautet:

$$T(n) \leq T(u) = T(\sqrt{u}) + O(1)$$
- Auflösen:

$$\begin{aligned} T(u) &= T(u^{\frac{1}{2}}) + O(1) \\ &= T(u^{\frac{1}{4}}) + 2 \cdot O(1) \\ &= T(u^{\frac{1}{8}}) + 3 \cdot O(1) \\ &= T(u^{\frac{1}{2^k}}) + k \cdot O(1) \end{aligned}$$
- Ergibt:

$$T(n) \in O(\log \log u)$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 17

Platzbedarf


- Rekurrenzgleichung (für worst-case):

$$S(u) = \sqrt{u} \cdot S(\sqrt{u}) + S(\sqrt{u}) + O(\sqrt{u}) + O(1)$$

\uparrow \uparrow \uparrow \uparrow
 Platz für Platz für hi Platz für size, min, max
 ein lo[i] das Array lo
- Auflösen:

$$\begin{aligned} S(u) &\in (1 + \sqrt{u})S(\sqrt{u}) + O(\sqrt{u}) \\ S(u) &\in (1 + \sqrt{u})^k S(u^{\frac{1}{2^k}}) + k \cdot O(\sqrt{u}) \\ S(u) &\in (1 + \sqrt{u})^{\log \log u} + \log \log(u) \cdot O(\sqrt{u}) \end{aligned}$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 18



Beweis, dass $S(u)$ linear ist

- Zunächst die verborgenen Konstanten "angenehm" machen:

$$S(u) = c_1(1 + \sqrt{u})S(\sqrt{u}) + c_2\sqrt{u}$$
- setze $S'(u) = \frac{1}{\max(c_1, c_2)} S(u)$
- Damit wird $S'(u) \leq (1 + \sqrt{u})S'(\sqrt{u}) + \sqrt{u}$
- Ansatz:

$$S'(u) \leq u + b$$

$$S'(4) = 1$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 20

- Beweis per Induktion:
 - Ind.anfang:

$$S'(4) = 1 \leq 4 + b$$

→ ja, falls $b \geq -3$
 - Ind.schritt:

$$\begin{aligned} S'(u) &\leq (1 + \sqrt{u})S'(\sqrt{u}) + \sqrt{u} \\ &\leq (1 + \sqrt{u})(\sqrt{u} + b) + \sqrt{u} \\ &\leq \sqrt{u}(2 + b) + u + b \\ &\stackrel{!}{\leq} u + b \end{aligned}$$

→ ja, falls $b \leq -2$
- Zusammen: $S'(u) \leq u - 2$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 21

Bemerkungen

- In der Praxis implementiert man vEB-Trees als Mix:
 - Baue vEB-Trees rekursiv auf
 - Sobald $|S| <$ Wortbreite (32 / 64 Bit): schalte auf Bit-Array um
 - Viele CPUs bieten als Maschinenbefehle *shift-by-k* und *find-first-zero* mit wenigen Taktzyklen Ausführungszeit
- Selbstverständlich macht man *lazy initialization*:
 - Ein Kind-vEB-Tree wird nur erzeugt, wenn er wirklich Elemente enthält!
 - M.a.W.: ein leerer vEB-Tree besteht nur aus einem (Wurzel-)Knoten, dessen **lo**-Array lauter NULL-Pointer enthält (dito natürlich für den **hi**-Pointer)
 - (In vielen Darstellungen klingt es anders, ist aber Quatsch)

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 22

Eine Variante des vEB-Trees

- Situation: oft ist $n \ll \sqrt{u}$
- Annahmen:
 - $n = u^{\frac{1}{2^k}}$
 - Alle Keys sind völlig gleichmäßig über das Universum \mathcal{U} verteilt
- Der vEB-Tree über der Menge S sieht nun grob so aus:
 - Das h_1 -Array enthält n Keys
 - Pro " \sqrt{u} -Fach" hat man höchstens einen Key (im Mittel)
 - Ein Element des l_0 -Arrays enthält einen NULL-Zeiger, falls in dem zugehörigen vEB-Tree kein Element aus S liegen würde

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 23

- Versucht man damit, die Space-Complexity von "einfachen" vEB-Trees abzuschätzen, kommt folgendes heraus:

$$\begin{aligned}
 S(n, u) &= \sqrt{u} + S(1, \sqrt{u}) \cdot n + S(n, \sqrt{u}) \\
 &= S(n, \sqrt{u}) + \sqrt{u} + n \\
 &\vdots \\
 &= S(n, u^{\frac{1}{2^k}}) + kn + \sum_{i=1}^k u^{\frac{1}{2^i}} \\
 &\in O(n) + k \cdot n + O(u)
 \end{aligned}$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 24

Eine Variante des vEB-Trees

- Ersetze das 1σ -Array durch eine Hash-Tabelle mit m Slots, so daß

$$\frac{n}{m} = \alpha$$
- Damit wird

$$S(n, u) = \frac{n}{\alpha} + S(1, \sqrt{u}) \cdot n + S(n, \sqrt{u})$$

$$\leq c \cdot n + S(n, \sqrt{u})$$


$$\leq k \cdot cn + S(n, u^{\frac{1}{2^k}})$$

$$\in O(\log \log(u) \cdot n)$$

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 25



Anwendung: Akustische Modellierung

- Gegeben:
 - Ein Raum (oder viele) als geometrisches Modell (Menge von Polygonen)
 - Eine Schallquelle (*Source*)
 - Ein Empfänger (*Listener / Receiver*)
- Aufgabe: berechne den Schall, der beim Receiver ankommt
- Problem: der Schall durchläuft sehr viele Wege!

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 26

- Modellierung der Pfade des Schalls mittels Beams:




- Alle Pfade verfolgen dauert zu lange
- Idee: verfolge nur die Pfade, die für das Ohr wichtig sind
 - Kurze Pfade → kommen zuerst am Ohr an; geben wichtige Information über die räumliche Umgebung
 - Pfade mit starkem Schall → übertragen Infos über die Schallquelle, maskieren schwächere Signale
- Lösung: **P-Queue** von Beams, priorisiert nach Lautstärke und potentieller Länge

G. Zachmann Computer-Graphik 2 – SS 11
Van Emde Boas Trees 27

Levels of Detail in der Computer-Graphik


- Fällt Ihnen etwas auf?


- Hoffentlich nicht ☺
- In Wahrheit haben die Modelle sehr verschiedene Auflösungen:


- Diese heißen *Level of Detail (LOD)*

G. Zachmann Computer-Graphik 2 – SS 11
Van Emde Boas Trees 28

- Die fundamentale Operation bei der **Simplifizierung**:


- Führe Bewertungsfunktion für Kanten ein → **Priorität**
 - Wie wichtig ist die Kante für das Erscheinungsbild?
 - Wahrnehmungsbasiert (Krümmung, Viewpoint, Textur, ...)
 - Verwalte alle noch verbleibenden Kanten des Modells in **einer P-Queue**; kollabiere als nächstes immer diejenige mit max. **Priorität**
 - Achtung: die P-Queue muß hier zusätzlich unterstützen, daß die Priority-Keys der Einträge sich *nachträglich* ändern!

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 29

Pathfinding

- Aufgabe: autonome Figuren auf ein Ziel zubewegen






Figure 12.7 Dotted lines represent the portals between convex areas.






Figure 12.8 The portals can be the nodes in a graph representing the map.



- Oder: Routenplanung im Straßennetz


G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 30

- Repräsentation des Geländes mit Hindernissen:
 - Als Graph mit Knoten und Kanten
 - Oder als Gitter mit "verbotenen" Zellen; ist auch ein Graph:
 - Gitterzellen sind die Knoten
 - Jede Zelle ist über 4 Kanten mit den Nachbarn verbunden (falls kein Hindernis)
- Im Folgenden: betrachte nur noch Graphen

G. Zachmann Computer-Graphik 2 – SS 11
Van Emde Boas Trees 31

- Gegeben:
 - Ein Graph mit einer Menge V von Knoten, einer Menge Kanten, und Länge pro Kante
 - Ein Startknoten S
 - Ein Zielknoten E (*goal*)
- Gesucht: ein möglichst kurzer Pfad von S nach E
- Mögliche Lösungen:
 - Exhaustive Search mittels Backtracking bzw. Depth-First Search (zu teuer)
 - Dijkstra's Algorithmus (macht stumpfsinnig breadth-first search)
 - Der A*-Algorithmus



G. Zachmann Computer-Graphik 2 – SS 11
Van Emde Boas Trees 32

Der A*-Algorithmus

- Verwende zusätzliche Informationen (*informed search*)
- Annahme hier:
 - Jeder Knoten V hat eine Position (V_x, V_y) in der Ebene
 - Es gibt eine Heuristic h

$$h : \mathcal{V} \rightarrow \mathbb{R}$$

die zu jedem Knoten V eine **untere Schranke** für den kürzesten Pfad von V nach E liefert
 - Zum Beispiel:

$$h(V) = \|V - E\|$$
- Klar ist: es gibt eine Funktion g , so daß

$$g(V) = \text{Länge des kürzesten Pfades von } S \text{ nach } V$$
 - Diese konstruieren wir im Folgenden peu à peu

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 33

- Definiere damit die "heuristisch geschätzten" Kosten eines Knotens V als

$$f(v) = g(v) + h(v)$$
- Die Idee des A*-Algorithmus:
 - Ausgangssituation:
 - Menge $\mathcal{C} \subset \mathcal{V}$: alle Knoten, für die $g(V)$ schon **bestimmt** wurde, und deren nächste Nachfolger auf dem Weg zu E schon festgelegt wurden;
 - Menge $\mathcal{O} \subset \mathcal{V}$: alle Knoten, für die $g(V)$ schon **geschätzt** wurde, und für die die Nachfolger noch **nicht** bestimmt wurden
 - Die Iteration (ganz grob):
 - Wähle aus \mathcal{O} den Knoten V mit kleinstem Wert $f(V)$ (**P-Queue!**)
 - Füge V zu \mathcal{C} hinzu
 - Bestimme die Nachfolger von $V \rightarrow$ füge diese zu \mathcal{O} hinzu

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 34

- A* ist somit eine Art "gerichteter Breadth-First Search"
- Terminologie:
 - C heißt "*closed set*"
 - O heißt "*open set*" – stellt quasi den "Rand" des bislang explorierten Terrains dar

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 35

A* in Pseudocode

```

C := {} # closed set (as bit-set)
O := {S} # open set (as p-queue)
g(S) := 0; f(S) := h(S)
while O is not empty:
  V := extractMin( O )
  if V == E:
    goal reached; reconstruct path; return
  C.add( V ) # won't find better S→V
  for all neighbors W of V:
    if W ∈ C:
      continue with next W
    if W ∉ O:
      g(W) := g(V) + d(V,W) # d(V,W) = edge length
      f(W) := g(W) + h(W) # first estimate of f(W)
      O.add( W, f(W) ) # add W to "fringe"
    else: # path S→W already known
      if g(V) + d(V,W) < g(W):
        g(W) := g(V) + d(V,W) # better path found
        f(W) := g(W) + h(W) # update f and p-queue!
      else:
        # path to W via V is no better, do nothing
  return "no path from S to E exists"

```

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 36

Informeller Beweise

- Zur Terminierung:
Anzahl Knoten im Graphen ist endlich, jeder Knoten wird nur 1x in die P-Queue (O) aufgenommen
- Zur Korrektheit:
 - Falls es einen Pfad $S \rightarrow E$ gibt (oder mehrere), wird einer davon auch tatsächlich von A^* gefunden
 - Beweis: jeder Knoten wird 1x besucht; einer davon ist E
- Zur Optimalität:
 - Wenn A^* an einem Knoten V steht, dann haben alle Pfade $S \rightarrow V \rightarrow E$ mindestens die Kosten $f(V)$, wegen der Bedingung an h
 - V war aber von allen Knoten an der "Front" derjenige, der den kürzesten Pfad $S \rightarrow V$ hat, wegen der P-Queue

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 37

Ein Beispiel

The diagrams illustrate the search process in eight stages:

- a: Initial state with source (red square) and goal (green square) separated by a barrier (blue vertical line).
- b: Search starts from the source node, expanding to its immediate neighbors.
- c: Search continues, reaching the barrier.
- d: Search reaches the barrier and begins to explore nodes on the other side.
- e: Search expands further on the right side of the barrier.
- f: Search continues to explore more nodes on the right side.
- g: Search reaches the goal node.
- h: Final state showing the complete search tree and the path to the goal.

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 38

Demo

The screenshot shows a Java applet window titled "Applet for Path Finding with A*". The window contains a grid-based environment for pathfinding. A blue obstacle shape is present in the center of the grid. A yellow path is shown starting from a red square at the top left and ending at a green square at the bottom right. The applet interface includes a toolbar with buttons for "A*", "Start", "Clean", and "Szene". The status bar at the bottom of the applet window reads "Applet PathFindingApplet started".

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 39

This slide shows an empty applet window frame, identical in layout to the previous slide, but without the pathfinding content. The status bar at the bottom of the frame reads "Applet PathFindingApplet started".

G. Zachmann Computer-Graphik 2 – SS 11 Van Emde Boas Trees 40

