

5.4.1.4 Taulukosta keeksi

- Nyt voimme ohjelmoida kalvojen 5.4.1.1 tavan muuntaa syötteenä saatu taulukko $A[1 \dots n]$ keeksi.
- Kuljetaan puun solmuja numerointijärjestyksessä *taaksepäin* alkaen ensimmäisestä sisäsolmusta.
- Silloin solmua käsiteltäessä sen lapset täyttävät jo kekoehdon.
- Siis riittää käyttää kalvojen 5.4.1.3 aliohjelmia.

procedure buildHeap($A[1 \dots n]$: taulukkoviite)

```

 $m := n;$ 
for  $i := \lfloor \frac{n}{2} \rfloor$  down to 1 do
  heapify( $A, i$ )
end for.

```

- Tarvitsemme aputuloksen

$$\sum_{h=0}^{\infty} \frac{h}{2^h} = 2. \quad (12)$$

- Yhtälö (12) voidaan osoittaa seuraavasti:

Koulumatematiikasta tunnemme äärettömän *geometrisen sarjan* summan

$$\sum_{h=0}^{\infty} x^h = \frac{1}{1-x}$$

kun $|x| < 1$. Kohdistamme sen molempiin puoliin operaation

$$x \cdot \mathbf{D}_x \left(\sum_{h=0}^{\infty} x^h \right) = x \cdot \mathbf{D}_x \left(\frac{1}{1-x} \right).$$

Vasen puoli saa muodon

$$\begin{aligned} x \cdot \sum_{h=1}^{\infty} \mathbf{D}_x (x^h) &= x \cdot \sum_{h=1}^{\infty} h \cdot x^{h-1} \\ &= \sum_{h=0}^{\infty} h \cdot x^h \end{aligned}$$

joka on mitä etsimme arvolla $x = \frac{1}{2}$.

- Aputilan tarve on kaikkiaan

$$\mathcal{O}(1). \quad (10)$$

- Koska yhtälön (9) mukaan yhden aliohjelmakutsun aikavaatimus riippuu korkeudesta h , niin summataan yli silmukassa läpikäytyjen korkeuksien.

- Koska puu on miltei täydellinen, niin sen korkeus on enintään

$$\lfloor \log(n) \rfloor.$$

- Korkeudella h on enintään

$$\left\lceil \frac{n}{2^{h+1}} \right\rceil$$

solmua.

- Aikavaatimukselle saadaan summa

$$\begin{aligned} \sum_{h=0}^{\lfloor \log(n) \rfloor} \left\lceil \frac{n}{2^{h+1}} \right\rceil \cdot h &= \mathcal{O} \left(n \cdot \frac{1}{2} \cdot \sum_{h=0}^{\infty} \frac{h}{2^h} \right) \\ &= \mathcal{O}(n) \end{aligned} \quad (11)$$

aputuloksen (12) nojalla.

- Yhtälön (12) oikea puoli saa muodon

$$\begin{aligned} x \cdot \mathbf{D}_x \left(\frac{1}{1-x} \right) &= x \cdot \frac{-1}{(1-x)^2} \cdot -1 \\ &= \frac{x}{(1-x)^2} \\ &= 2 \end{aligned}$$

arvolla $x = \frac{1}{2}$.

- Lopuksi pitää vielä tarkistaa että geometrisen sarjan derivointi termeittäin oli sallittua arvollamme $x = \frac{1}{2}$.

Oli, koska geometrinen sarja suppenee peräti *tasaisesti* jokaisella suljetulla välillä

$$[-k, +k] \subsetneq (-1, +1),$$

siis myös pisteemme $x = \frac{1}{2}$ ympäristössä.

5.4.2 Kekojärjestämisalgoritmi

- Kootaan lopuksi kaikki yhteen:

procedure heapsort(A : taulukkoviite)

- 1: buildHeap(A) kalvoilta 5.4.1.4;
- 2: **while** $m > 1$ **do**
- 3: Vaihda taulukkopaikkojen $A[1]$
 ja $A[m]$ sisällöt keskenään;
- 4: $m := m - 1$;
- 5: heapify($A, 1$) kalvoilta 5.4.1.3
- 6: **end while**.

- Kokonaisaika on

$$\mathcal{O}(n \cdot \log(n))$$

yhtälöistä (9) ja (11).

- Aputilan kokonaistarve on

$$\mathcal{O}(1)$$

yhtälöistä (8) ja (10).

- Prioriteettijonon perusoperaatiot:

- heapInsert(S, x) lisää
 - * prioriteettijonoon S alkion x .
 - * jonka prioriteetti on avainkenttänä x .key.
- heapMaximum(S)
 - * palauttaa poistamatta prioriteettijonosta S sellaisen alkion y
 - * jonka prioriteetti y .key on mahdollisimman suuri.
- heapExtractMax(S)
 - * poistaa ja palauttaa
 - * saman alkion y kuin heapMaximum(S).

5.4.3 Prioriteettijono

- Kalvojen 5.4.1 kekotietorakenteesta saadaan helposti *prioriteettijono* (priority queue):

- Tehtävien töiden jono kuten kalvoilla 4.3, mutta seuraavaksi otetaankin aina *kiireellis*in työ.
- Työn kiireellisyys eli *prioriteetti* annetaan silloin, kun työ saapuu jonoon. Seuraavaksi ryhdytään aina korkeimman prioriteetin omaavaan työhön.

- Esimerkiksi seuraavaksi prosessoriaikaa saavan prosessin valinta käyttöjärjestelmän ytimessä.

- Prioriteettijonon toteutus kekona:

- Oletetaan:
 - * osaamme varata prioriteettijonolle S etukäteen tarpeeksi suuren taulukon $A[1 \dots n]$
 - * ettei sen käytössä oleva alkuosa $A[1 \dots m]$ koskaan jää liian pieneksi.
- Myöhemmin palataan siihen, miten tämä oletus voidaan poistaa.
- heapMaximum(A) palauttaa taulukkopaikan $A[1]$ sisällön.
- heapExtractMax(A) saadaan muunnoksena kalvon 5.4.2 algoritmin riveistä 3–5.
- heapInsert(A, x) tehdään lisäämällä seuraava lehti:
 - $m := m + 1$;
 - $A[m] := x$;
 - shiftup(A, m).

- Operaatio $\text{shiftup}(A, i)$ on sukua kalvojen 5.4.1.3 algoritmille:
 - Taulukko A täyttää muuten kekoehdon
 - paitsi että solmu $A[i]$ ja sen *isäsolmu* $A[\text{parent}(i)]$ voivat rikkoa sen.

Silloin rike voidaan siirtää puussa ylöspäin.

```

procedure shiftup( $A$ : taulukkoviite,
                   $i$ : indeksi)
  if  $i > 1$  and  $A[i].\text{key} > A[\text{parent}(i)].\text{key}$ 
  then
    Vaihda näiden taulukkoalkioiden  $A[i]$ 
    ja  $A[\text{parent}(i)]$  sisällöt keskenään;
    shiftup( $A$ , parent( $i$ ))
  end if.

```

- Aliohjelma voidaan tehdä
 - toistorakenteena (kuten kalvoilla 4.6)
 - ilman turhia vaihtoja (samoin kuin kalvojen 5.4.1.3 algoritmikin)
 - ajassa

$$\mathcal{O}(\text{puun korkeus}) = \mathcal{O}(\log(m)).$$

- Mistä prioriteettijonon käyttäjä tietää
 - sen taulukkopaikan i
 - jossa *juuri nyt* on
 - se kekoalkio x jonka prioriteettia halutaan muuttaa?

Alkion x paikka i keossa vaihtelee!
- Usein kekokirjasto tarjoaakin alkioon x *kahvan* (handle) joka tietää sen.
- Yksi toteutustapa on:
 - Kekotaulukossa A onkin kalvojen 4.1 osoittimia kekoalkiotietueisiin t .
 - Tietueessa t on (myös) kenttä $t.\text{handle}$.
 - Keko-operaatiot ylläpitävät jokaiselle tietueelle t invarianttia

" $A[t.\text{handle}]$ osoittaa takaisin tietueeseen t ".
 - Käyttäjä saa muuttaa prioriteettikenttää $t.\text{key}$.

- Usein sallitaan myös prioriteettijonossa olevan alkion prioriteetin
 - nostaminen (tärkeämmäksi)
 - laskeminen (vähemmän tärkeäksi).

- Operaatio $\text{setPriority}(A, i, p)$ asettaa kekotaulukon A paikassa i olevan alkion uudeksi prioriteetiksi p .

```

procedure setPriority( $A$ : taulukkoviite,
                      $i$ : indeksi,
                      $p$ : prioriteetti)

```

```

   $q := A[i].\text{key}$ ;
   $A[i].\text{key} := p$ ;
  if  $p < q$  then
    heapify( $A, i$ )
  else
    shiftup( $A, i$ )
  end if.

```

5.5 Järjestämisalgoritmien työhönnotohaastattelu

- Aikavaatimus?

Lomitusjärjestäminen (kalvoilta 5.1):
 $\Theta(n \cdot \log(n))$.

Pikajärjestäminen (kalvoilta 5.2):
 Tyypillisesti $\mathcal{O}(n \cdot \log(n))$ mutta pahimmillaan $\mathcal{O}(n^2)$.

Kekojärjestäminen (kalvoilta 5.4):
 $\Theta(n \cdot \log(n))$.

- Suosikkietorakenne?

L: Lista jonka osoittimia saa muuttaa.

P: Kumpi vain.

K: Taulukko jota saa muuttaa.

- Rekursiopinon tarve?

L: $\Theta(\log(n))$.

P: Perusversio tyypillisesti $\mathcal{O}(\log(n))$ mutta pahimmillaan $\mathcal{O}(n)$.
Ohjelmoitavissa siten, että $\mathcal{O}(\log(n))$.

K: $\mathcal{O}(1)$.

- Muun aputilan tarve?

L: $\mathcal{O}(1)$ suosikkietorakenteella, muuten $\mathcal{O}(n)$.

P: $\mathcal{O}(1)$.

K: $\mathcal{O}(1)$.

- Erikoistaito?

L: Helppo ohjelmoida *vakaaksi* eli *stabiiliksi* (stable): säilyttämään *yhtä suurten* alkioiden keskinäisen järjestyksen.

P: Käytännössä tehokkain ja suosituin.

K: Inkrementaalinen jo perusversiona.

- Käytetään *päätöspuita* (decision tree): kalvojen 5.1.3.1 binääripuu jonka

sisäsolmussa on kahdesta syötealkiosta esitetty kysymys (13).

haarautuminen on vastauksen mukaan

kyllä vasemmalle

ei oikealle.

lehtisolmussa pysähtyy johtopäätökseen "syötealkioiden (jokin) oikea järjestyks on

$$a_3 \leq a_{57} \leq a_7 \leq \dots \leq a_{14}."$$

- Päätöspuun T kasvatus:

– valitaan järjestämisalgoritmi α

– valitaan syötepituus n

– juureksi *tuntematon* syöte

$$a_1, a_2, a_3, \dots, a_n \quad (14)$$

– solmun lapset lasketaan *simuloimalla* algoritmia α seuraavaan kysymykseen.

5.6 Järjestäminen vertailuin

- Osoitetaan että n alkion järjestäminen vie *ainakin*

$$\Omega(n \cdot \log(n))$$

askelta. . .

- . . . *jos ainoa* syötealkioille a_i sallittu operaatio on niiden *vertailu* toisiinsa kysymyksin

$$\text{"Onko } a_i \leq a_j? \text{"} \quad (13)$$

(Muut vertailut '<', '=', '≥', '≠' ja '>' tehtävissä 2 kysymyksellä.)

- Lehdessä l on tuntemattoman syötteen (14) sellainen uudelleenjärjestely eli *permutaatio*

$$a_{\pi(1)}, a_{\pi(2)}, a_{\pi(3)}, \dots, a_{\pi(n)}$$

joka *sopii yhteen* niiden vastausten kanssa, jotka ovat polulla puun T juuresta tähän lehteen l :

Jos polulla olevista vastauksista seuraa

$$a_i < a_j$$

niin silloin permutaatiossa π pitää olla

$$\pi^{-1}(i) < \pi^{-1}(j)$$

eli "syötearvon a_i pitää olla ennen syötearvoa a_j ".

- Jos puusta T puuttuu jokin permutaatio σ niin käänteinen yhteensopivuusehto

$$\text{jos } \sigma^{-1}(i) < \sigma^{-1}(j) \text{ niin } b_i < b_j$$

antaa vastaesimerkin: syötteen

$$b_{\sigma(1)}, b_{\sigma(2)}, b_{\sigma(3)}, \dots, b_{\sigma(n)}$$

jolla *algoritmi* α *erehtyy* eli joka päättyy väärään lehteen.

- Siis puussa T pitää olla *ainakin* yhtä monta lehteä kuin n alkiolla on permutaatioita.
- Nyt binääripuussa T

$$\begin{aligned} \text{korkeus} &\geq \log_2(\text{lehtien määrä}) \\ &\text{lauseesta 5.1.2} \\ &\geq \log_2(n!) \\ &\text{edellisestä järkeilystä} \\ &= \Omega(n \cdot \log(n)) \\ &\text{yhtälöstä (2).} \end{aligned}$$

- Siis jollakin n alkion syöteaineistolla algoritmi α vie ainakin

$$\Omega(n \cdot \log(n))$$

askelta.

- Koska α oli mielivaltainen
 - oikein toimiva
 - kysymyksiä (13) käyttävä
 - järjestämisalgoritmi
 niin väite seuraa

5.6.2 Järjestäminen vertailuitta

- Jos alkiolle saa tehdä muutakin kuin kysymyksiä (13) niin järjestäminen onnistuu nopeamminkin.
- Oletetaan siis että syöteaineisto

$$a_1, a_2, a_3, \dots, a_n$$
 koostuu *numeroista*.
- Silloin voimme lisäksi
 1. indeksoida taulukkoja
 2. tehdä laskutoimituksia.

5.6.1 Muita alarajoja

- Alarajoja on vaikeampi todistaa kuin ylärajoja:
 - Ylärajaan** riittää kirjoittaa *jokin* algoritmi joka toimii niin nopeasti.
 - Alarajaan** pitää osoittaa että *jokainen* algoritmi — vaikka kuinka nerokas — jää joskus hitaaksi.

- Järjestämisen lisäksi tunnetaan esimerkiksi seuraavat alarajat:

- Alkion haku järjestetystä n -alkioisesta taulukosta:

$$\Omega(\log(n)).$$

Kalvojen 2.4.2 binäärihaku oli optimaalinen.

- Toistuuko jokin alkio tässä n -alkioisessa järjestämättömässä aineistossa?

$$\Omega(n \cdot \log(n)).$$

Teimme tämän kalvoilla 5.3.

5.6.2.1 Laskemisjärjestäminen

- *Laskemisjärjestäminen* (counting sort) soveltuu, kun syötetaulukko

$$A[1 \dots n]$$

sisältää pelkästään niin *pieniä* numeroita $0, 1, 2, \dots, k$

- että voimme käyttää aputaulukkoa

$$C[0 \dots k]$$

jota voimme indeksoida syötealkioilla $A[j]$.

Riveillä 2–4 $C[i]$ on niiden syötealkioiden lukumäärä jotka $= i$.

Riveillä 5–7 $C[i]$ on niiden syötealkioiden lukumäärä jotka $\leq i$.

- Lisäksi käytämme tulostaulukkoa

$$B[1 \dots n]$$

johon kokoamme vastauksen.

Riveillä 8–11 laskureina $C[i]$.

procedure cs(*A*: taulukko, *B*: taulukkoviite)

```

1: Varaa aputaulukko C ja nollaa se;
2: for all j := 1 to n do
3:   C[A[j]] := C[A[j]] + 1
4: end for;
5: for all i := 1 to k do
6:   C[i] := C[i] + C[i - 1]
7: end for;
8: for all j := n down to 1 do
9:   B[C[A[j]]] := A[j];
10:  C[A[j]] := C[A[j]] - 1
11: end for.

```

- Aikaa ja tilaa kuluu

$$\mathcal{O}(n + k)$$

mikä on

$$\mathcal{O}(n)$$

järkevillä *k*.

- Vastaukset kerätään riveillä 8–11 takaperin.
- Algoritmi on vakaa: viimeinen syötealkio kopioidaan viimeiseen mahdolliseen paikkaansa. (Vertaa kalvot 5.5.)

- Siirry yksi sarake vasemmalle ja jatka vaiheesta 3.
- Lopeta kun kaikki sarakkeet on käyty näin läpi.
- Luonteva valinta vaiheessa 3 on kalvojen 5.6.2.1 laskemisjärjestäminen arvolla

$$k = \text{numeromerkkien lukumäärä}$$

$$= 10 \quad \text{kymmen- ja}$$

$$= 2 \quad \text{binäärilukujärjestelmässä}$$
 ja niin edelleen.
- Kantaluvun *k* saamme valita itse!
- Aikaa kuluu

$$\mathcal{O}(\text{rivien määrä} \cdot \text{rivin pituus})$$

=

$$\mathcal{O}(n \cdot \log_k \max \text{syöteluviuista } a_i)$$

askelta kalvojen 3.5 mukaan.

5.6.2.2 Kantalukujärjestäminen

- Kantalukujärjestäminen (radix sort) järjestää *suuretkin etumerkittömät kokonaisluvut*

$$a_1, a_2, a_3, \dots, a_n.$$

seuraavin vaihein:

- Kirjoita luvut ruutupaperille omille riveilleen
 - syötejärjestyksessä a_1, a_2, a_3, \dots alekkain
 - oikea reuna tasaten
 - täyttäen etunollilla vasemmatkin reunat tasan.
- Aloita oikeanpuoleisimmasta sarakkeesta.
- Järjestä rivit paperilla tämän *yhden* sarakkeen perusteella.

Tee se vakaasti: vaihtamatta kahden sellaisen rivin keskinäistä järjestystä, joilla on tässä sarakkeessa sama numeromerkki.

5.6.2.3 Lokerikkojärjestäminen

- Myös syöteaineiston

$$a_1, a_2, a_3, \dots, a_n.$$

todennäköisyysjakauman tunteminen voi nopeuttaa järjestämistä.

- Siihen perustuu *lokerikkojärjestäminen* (bucket sort).
- Oletetaan että syötealkiot
 - ovat *reaalilukuja* $0.0 \leq a_i < 1.0$
 - on poimittu *tasaisesta* jakaumasta. Intuitiivisesti: kun poimitaan a_i , niin todennäköisyys että se osuu väliin $p \leq \dots < q$ on välin *pituus* $q - p$.
- Jaetaan siis arvoalue yhtä suuriin lokeroihin $B[0 \dots n - 1]$ joiden pituus on $\frac{1}{n}$.
- Pudotetaan jokainen syötealkio a_i kokonsa mukaiseen lokeroon.

- Jokainen lokero on lista siihen pudonneista syötealkioista.

- Jokainen lista on todennäköisesti (hyvin) lyhyt.

- Lyhyt lista voidaan lajitella jollakin helpolla

$$\mathcal{O}(\text{listan pituus}^2)$$

askeleen algoritmilla.

(Esimerkiksi kalvojen 3.4 lisäyslajittelun listaversiolla kalvoilta 4.7.)

- Aikavaatimuksen oletusarvoksi saadaan

$$\mathcal{O}(n)$$

(todennäköisyyslaskelmat sivuutetaan).

for all $i := 1$ **to** n **do**

Lisää syötealkio a_i (aluksi tyhjään)

listaan $B[[n \cdot a_i]]$

end for;

for all $i := 0$ **to** $n - 1$ **do**

Lajittele lista $B[i]$

end for;

Liitä listat $B[0], B[1], B[2], \dots, B[n - 1]$ tässä järjestyksessä peräkkäin vastaukseksi siten, että liittämiseen kuuluu kokonaisuudessaan $\mathcal{O}(n)$ askelta.