Záróvizsga tételsor

13. Alapvető algoritmusok és adatszerkezetek

Fekete Dóra

Alapvető algoritmusok és adatszerkezetek

Egyszerű adattípusok ábrázolásai, műveletei és fontosabb alkalmazásai. A hatékony adattárolás és visszakeresés néhány megvalósítása (bináris keresőfa, AVL-fa, 2-3-fa és B-fa, hasítás („hash-elés")). Összehasonlító rendező algoritmusok (buborék és beszúró rendezés, ill. verseny, kupac, gyors és összefésülő rendezés); a műveletigény alsó korlátja.

1 Egyszerű adattípusok ábrázolásai, műveletei és fontosabb alkalmazásai

1.1 Adattípus

Adatszerkezet: $\sim$ struktúra.
Adattípus: adatszerkezet és a hozzá tartozó műveletek.
Adatszerkezetek:

- *Tömb*: azonos típusú elemek sorozata, fix méretű.
- *Verem*: Mindig a verem tetejére rakjuk a következő elemet, csak a legfelsőt kérdezhetjük le, és vehetjük ki.

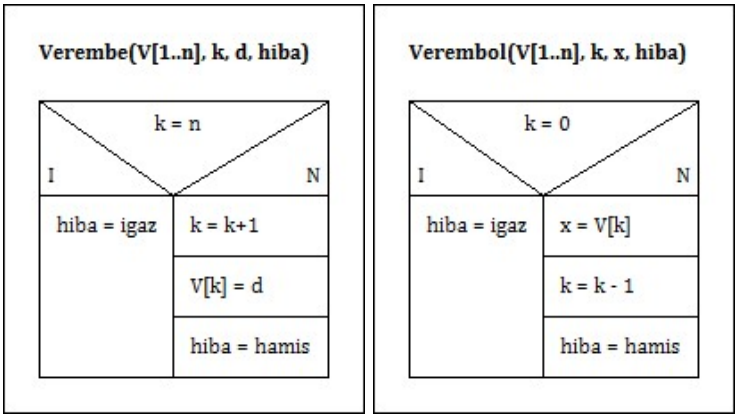

Figure 1: Verem műveletei

- *Sor*: Egyszerű, elsőbbségi és kétvégű. A prioritásos sornál az elemekhez tartozik egy érték, ami alapján rendezhetjük őket.

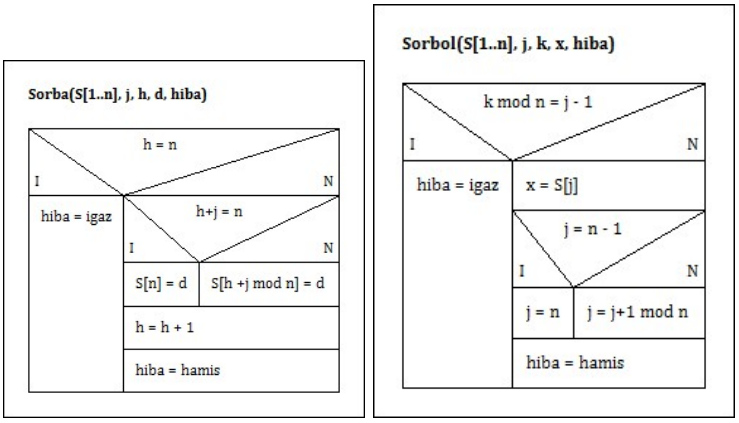

Figure 2: Sor műveletei

- *Lista*: Láncolt ábrázolással reprezentáljuk. 3 szempont szerint különböztethetjük meg a listákat: fejelem van/nincs, láncolás iránya egy/kettő, ciklusosság van/nincs. Ha fejelemes a listánk, akkor a fejelem akkor is létezik, ha üres a lista.
  A lista node-okból áll, minden node-nak van egy, a következőre mutató pointere, illetve lehet az előzőre is, ha kétirányú. Ezen kívül van egy első és egy aktuális node-ra mutató pointer is, és az utolsó elem mutatója NIL. A listát megvalósíthatjuk úgy, hogy tetszőleges helyre lehessen elemet beszúrni, illetve törölni.

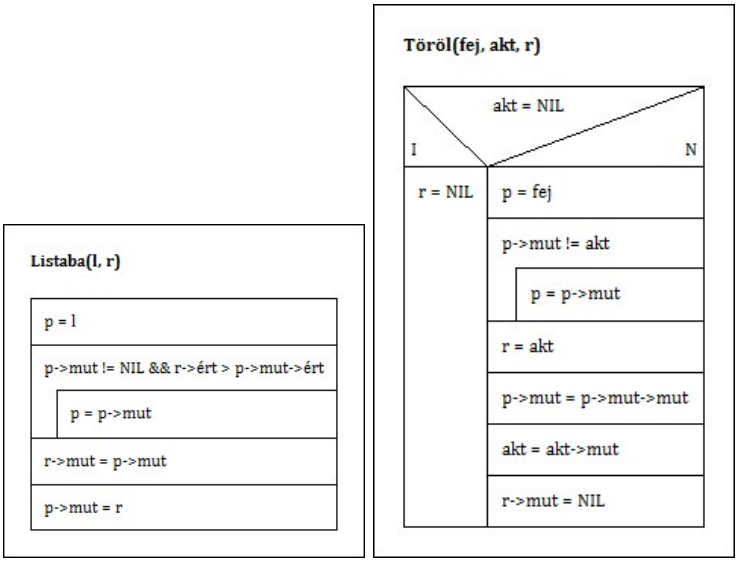

Figure 3: Lista műveletei

- *Fa*: Egyszerű, bináris és speciális (kupac, bináris keresőfa, AVL-fa). A bináris fát rekurzívan definiáljuk: $t \in T(E)$ [bin. fák típusérték halmaza(alaptípus)] $\iff$ t üres fa (jele: Ω), vagy t-nek van gyökéreleme, $bal(t)$, $jobb(t)$ részfája. Láncoltan ábrázoljuk, tömbösen csak teljes fák, illetve kupac esetén.

- *Kupac*: Olyan bináris fa, melynek alakja majdnem teljes és balra rendezett. Tömbösen ábrázoljuk, mert pointeresen a bonyolult lépkedést nem teszi lehetővé, tömbösen indexösszefüggésekkel könnyen megoldható.

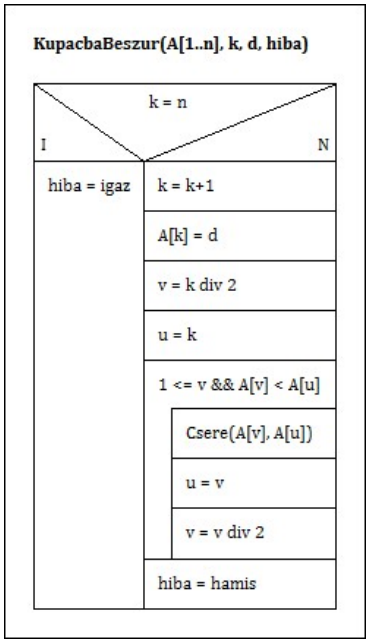

Figure 4: Kupac műveletei

- *Hasítótábla*
- *Gráf* [Nem egyszerű adattípus.]

1.2 Ábrázolásai

Absztrakciós szintek:

1. *absztrakt adattípus (ADT)*: specifikáció szintje, itt nincs szerkezeti összefüggés, csak matematikai fogalmak, műveletek logikai axiómákkal vagy előfeltételekkel.

   - algebrai (axiomatikus) specifikáció, példa: $Verembe : V \times E \to V$. Axióma, példa: $Felso(Verembe(v, e)) = e$
   - funkcionális (elő- és utófeltételes) specifikáció, példa: (elsőbbségi) sor $S(E), s \in S$ egy konkrét sor, $s = \{(e_1, t_1), ..., (e_n, t_n)\}$, $n \geq 0$. Ha $n = 0$, akkor a sor üres.
     $\forall i, j \in [1..n] : i \neq j \to t_i \neq t_j$.
     $Sorbol : S \to S \times E$, $\mathcal{D}_{Sorbol} = S \backslash \{ures\}$. Előfeltétel: $Q = (s = s' \wedge s' \neq \emptyset)$, utófeltétel: $R = (s = s' \backslash \{(e, t)\} \wedge (e, t) \in s' \wedge \forall i (e_i, t_i) \in s' : t \leq t_i)$.

2. *absztrakt adatszerkezet (ADS)*: kognitív pszichológia szintje, ábrák. Az alapvető szerkezeti tulajdonságokat tartalmazza (nem mindet). Ennek a szintnek is része a műveletek halmaza. Példák: az ábra egy irányított gráf, művelet magyarázata, adatszerkezet definiálása.

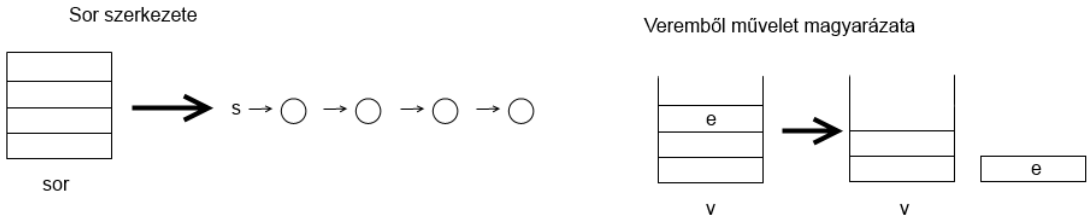

Figure 5: ADS

3. *ábrázolás/reprezentáció*: döntések (tömbös vagy pointeres ábrázolás), a nyitva hagyott szerkezeti kérdések. Egy adatszerkezetet többféle reprezentációval is meg lehet valósítani (pl. prioritásos sor lehet rendezetlen tömb, rendezett tömb, kupac).
    - *tömbös ábrázolás*: takarékos ábrázolás, elhelyezése, tetszőleges rákövetkezések, bejárások, de ezeket meg kell adni.
    - *pointeres ábrázolás*: minden pointer egy összetett rekord elejére mutat.
4. *implementálás*
5. *fizikai szint*

1.3 Műveletei

- Üres adatszerkezet létrehozása
- Annak lekérdezése, hogy üres-e az adatszerkezet
- Elem berakása, itt ellenőrizni kell, hogy nem telt-e még meg
- Elem kivétele vagy törlése, itt ellenőrizni kell, hogy nem üres-e
- Adott tulajdonságú elem (például maximum, veremben a felső) lekérdezése, itt is ellenőrizni kell, hogy üres-e az adatszerkezet
- Bejárások (preorder, inorder, postorder, szintfolytonos), listáknál az első, előző vagy következő elemre lépés
- Elem módosítása bizonyos adatszerkezeteknél (pl. listák)

1.4 Fontosabb alkalmazásai

Prioritásos sor: nagygépes programfuttatásnál az erőforrásokat a prioritás arányában osszuk el, adott pillanatban a maximális prioritásút válasszuk. Sürgősségi ügyeleten, gráfalgoritmusoknál is alkalmazható.
B-fa: ipari méretekben adatbázisokban használják.

2 A hatékony adattárolás és visszakeresés néhány megvalósítása (bináris keresőfa, AVL-fa, 2-3-fa és B-fa, hasítás („hash-elés”))

2.1 Bináris keresőfa

Nincsenek benne azonos kulcsok, a követendő elv: „kisebb balra, nagyobb jobbra". Inorder bejárással növekvő kulcssorozatot kapunk.
Műveletigénye fa magasságú nagyságrendű.
Az a cél, hogy a bináris keresőfa ne nyúljon meg láncszerűen, erre jó az AVL-fa és a 2-3-fa.

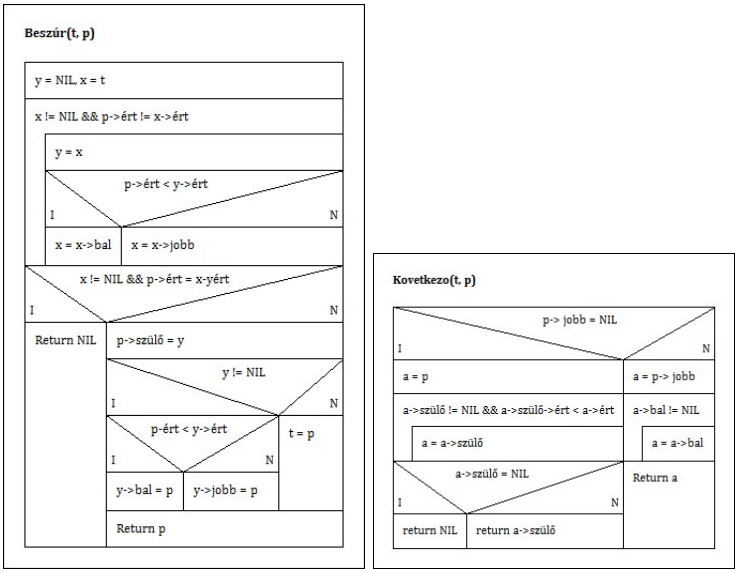

Figure 6: Bináris keresőfa műveletei

2.2 AVL-fa

Cél: a t bináris keresőfa magasságának $\log_2(n)$ közelében tartása, azaz $h(t) \leq c \cdot \log_2(n)$, ahol c elfogadhatóan kicsi. Az ilyen fát kiegyensúlyozottnak nevezzük.
AVL: Adelszon-Velszkij, Landisz 1962-ben alkották meg.
A t bináris keresőfát egyúttal AVL-fának nevezzük $\iff$ t minden x csúcsára $|h(bal(x)) - h(jobb(x))| \leq 1$.
Minden csúcsnak van egy címkéje $+, -, =$ (gyerekek magasságának különbsége). A beszúrás helyétől felfelé ellenőrizzük ezeket, és ha kell, akkor módosítjuk. Ha valahol $++$ vagy $--$ alakul ki, akkor ott elromlik az AVL-tulajdonság, egy vagy több forgatással vagy átkötéssel konstans műveletigénnyel helyre lehet hozni.
Többféle séma is van: $(++, +), (++, -), (++, =)$ és a tükörképeik.

2.3 2-3-fa és B-fa

2-3-fa kis méretben az elmélet számára jó, a B-fa a gyakorlati változat adatbázisban.
t 2-3-fa $\iff$ minden belső csúcsnak 2 vagy 3 gyereke van, a levelek azonos szinten helyezkednek el, adatrekordok csak a levelekben vannak, belső pontokban kulcsok és mutatók, levelekben a kulcsok balról jobbra nőnek.
Ha 4 gyerek lenne a beszúrás után, akkor csúcsot kell vágni. Ha törlésnél 1 gyerek lenne valahol, akkor csúcsösszevonásokat és gyerekátadást alkalmazunk.
B-fa nagyobb méretű, itt két határ között mozog a gyerekszám: $\lceil \frac{r}{2} \rceil$ és r, ahol $50 \leq r \leq 1000$.

2.4 Hasítás

Kulcsos rekordokat tárol.

- *Hasítás láncolással*: a kulcsütközést láncolással oldja fel. Van egy hasítófüggvény: $h : U \to [0..m-1]$, elvárás vele kapcsolatban, hogy gyorsan számolható és egyenletes legyen. m-et úgy választjuk meg n nagyságrendjének ismeretében, hogy $\alpha = \frac{n}{m}$ lesz a várható listahossz, ha egyenletes hasítást feltételezünk.
  Például kétirányú listát használhatunk a hasításhoz. Műveletek: beszúrás, keresés, törlés.
  Gyakorlatban érdemes m-et úgy megválasztani, hogy olyan prímszám legyen, ami nem esik 2-hatvány közelébe.

- *Hasítás nyitott/nyílt címzéssel*: A kulcsokat lehessen egészként értelmezni, ekkor vannak jó hasítófüggvények.
  Próbálkozás általános képlete: $h(k) + h_i(k) \ (mod\ M)$, $0 \leq i \leq M-1$. Egész addig alkalmazza, amíg üres helyet nem talál.

1. *Lineáris próba*: $h_i(k) = -i \ (mod \ M)$, egyesével balra lépegetve keressük az üres helyet. Hátránya az elsődleges csomósodás, ez jelentős lassulást okoz beszúrásnál és keresésnél.
2. *Négyzetes próba*: $h_i(k) = (-1)^i(\lceil \frac{i}{2} \rceil)^2 \ (mod \ M)$, a négyzetszámokkal lépegetünk balra-jobbra, ezek az eltolások kiadják $\{0, 1, ..., M-1\}$-et. Hátrány: másodlagos csomósodás.
3. *Kettős hash-elés*: $h_i(k) = -ih'(k) \ (mod \ M)$, $h'(k)$ a k-hoz tartozó egyedi lépésköz, $(h'(k), M) = 1$ relatív prímek. Ha az M elég nagy, akkor nincs csomósodás.

- *Hasítófüggvények*: Leggyakoribb: k egész, kongruencia reláció. Általánosan: $h(k) = (ak + b \ (mod \ p)) \ (mod \ M)$, az univerzális hasítás családja. Tapasztalat: k egyenletesen hasít.

3 Összehasonlító rendező algoritmusok (buborék és beszúró rendezés, ill. verseny, kupac, gyors és összefésülő rendezés)

Buborék- és beszúró rendezés klasszikusak, n^2-es műveletigényűek, a többi hatékony, $n \log(n)$-es idejűek.

3.1 Buborékrendezés

A legnagyobb értéket cserékkel a végéig felbuborékozza, ezt minden ciklus végén elhagyjuk. A gyakorlatban nem használják.

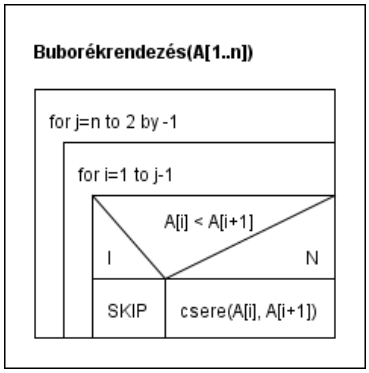

Figure 7: Buborékrendezés

3.2 Beszúró rendezés

Kis n-re (kb 30) ez a rendezés a legjobb.
Itt az elemmozgatás mindig 1 értékadás (buborékrendezésnél a csere 3 értékadás). Listára is implementálni lehet, ez esetben a pointereket állítjuk át, az elemek helyben maradnak.
$A[1..j]$ rendezett, $j = 1..n$.

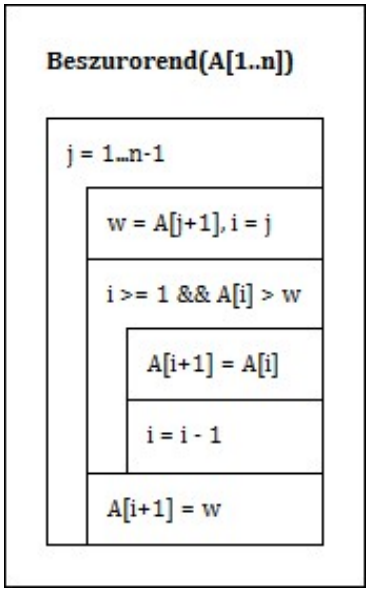

Figure 8: Beszúró rendezés

3.3 Versenyrendezés

Gyakorlatban nem használják.
Teljes bináris fa az alapja, egy versenyfa. Szintfolytonosan ábrázoljuk tömbösen.

1. A versenyfa kitöltése (a verseny lejátszása). Maximum a gyökérben, ennek kiírása az outputra.
2. $(n-1)$-szer
   a) gyökérben szereplő maximális elem helyének megkeresése a levélszinten és $-\infty$ írása a helyére
   b) az egészet újrajátsszuk (azt az ágat, ahol volt) $\rightarrow$ 2. legjobb feljut a gyökérbe

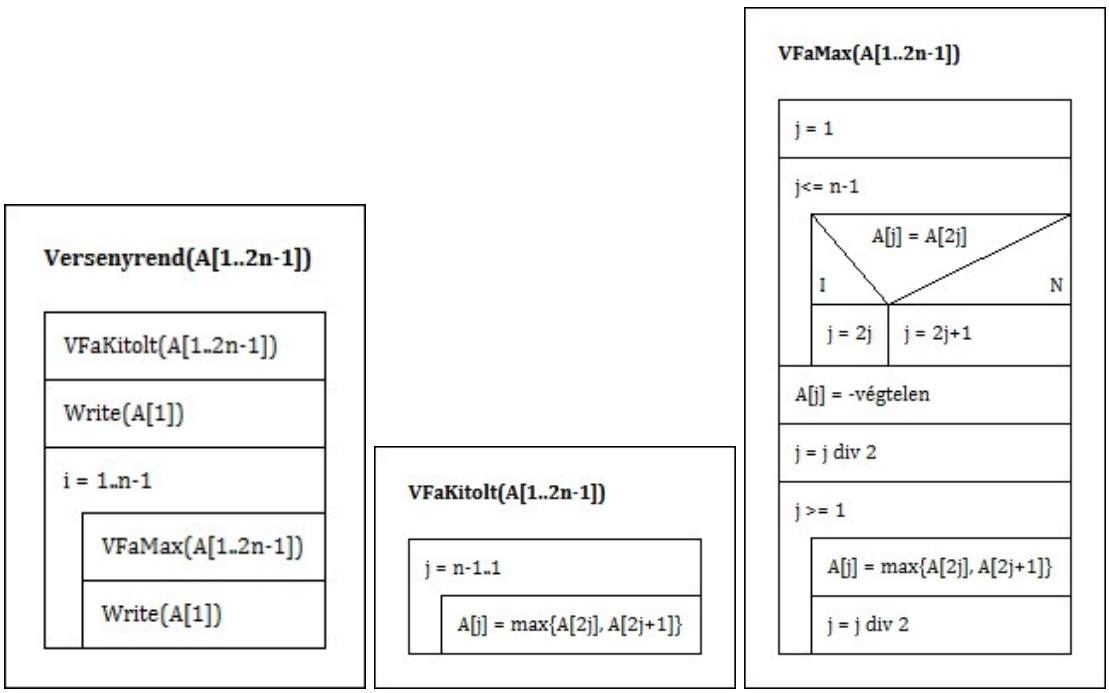

Figure 9: Versenyrendezés

3.4 Kupacrendezés

1. Kezdő kupac kialakítása. Rendezetlen input tömbből tartalmi invariánst készítünk, ami már kupac struktúrájú. Elv: cserékkel lesüllyesztjük az elemet a nagyobb gyerek irányába, ha kisebb a nagyobbik gyereknél. A süllyesztés eljuthat ahhoz a csúcshoz, amelynek nincs jobb gyereke.

2. $(n-1)$-szer

   a) gyökérelem és az alsó szint jobb szélső (=utolsó) aktív elemének cseréje, és a csere után lekerült elem inaktívvá tétele

   b) a gyökérbe került elem süllyesztése az aktív kupacon

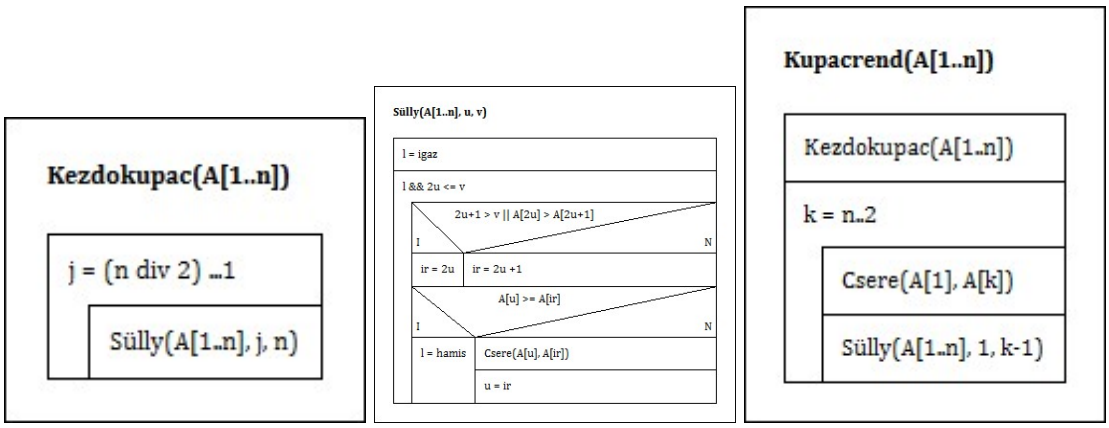

Figure 10: Kupacrendezés

A kezdőkupac kialakításánál, és a ciklus közben a süllyesztés módja kicsit különbözik, hiszen az első esetben a változó elem süllyed le a teljes kupacon, a másodikban a gyökér süllyed az aktív kupacon. A képen látható algoritmus mindkét műveletet teljesíti.

3.5 Gyorsrendezés

Elve: véletlenül választunk egy elemet. A nála kisebb elemeket tőle balra, a nagyobbakat jobbra rakjuk, az elemet berakjuk a két rész közé. Rekurzív algoritmus.

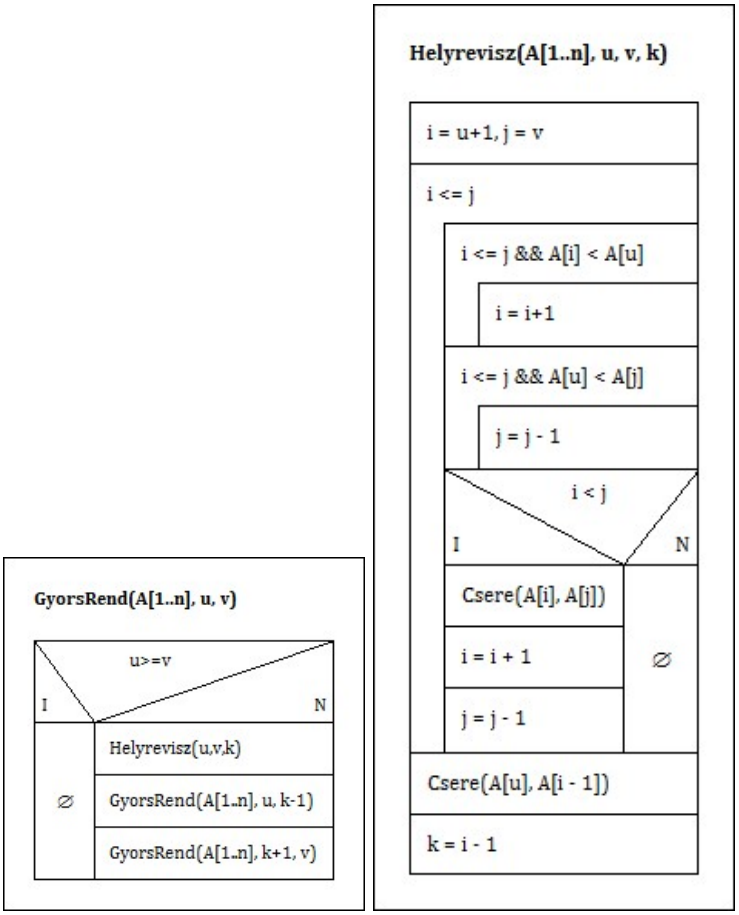

Figure 11: Gyorsrendezés

3.6 Összefésülő rendezés

Alapja: 2 rendezett sorozat összefésülése. Ezt alkalmazhatjuk felülről lefelé (rekurzív) vagy alulról felfelé (iteratív), ez utóbbit szekvenciális fájloknál.

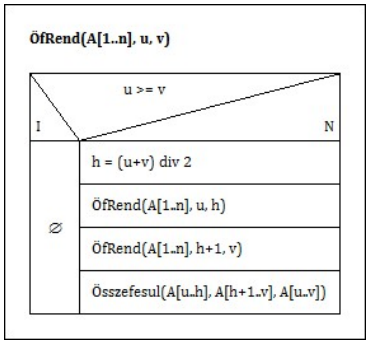

Figure 12: Összefésülő rendezés

4 A műveletigény alsó korlátja összehasonlító rendezésekre

4.1 Műveletigény

Kijelöljük a domináns műveleteket, és az n inputméret függvényében hányszor hajtódnak végre, ezt nézzük. Jelölés általánosan $T(n)$, de lehet konkrétan is, pl $Cs(n)$ [csere]. $mT(n)$ a minimális műveletigény, $MT(n)$ a maximális és $AT(n)$ az átlagos.

Θ : nagyságrendileg azonos, két konstans közé beszorítható

$\mathcal{O}$: nagyságrendi felső becslés, o: nincs megengedve az egyenlőség

Ω : nagyságrendi alsó becslés, ω: nincs megengedve az egyenlőség

4.2 Alsókorlát

Például: n elem maximumkiválasztása legalább $(n-1)$ összehasonlítást igényel. Bizonyítása: Ha ennél kevesebb összehasonlítás lenne, akkor legalább 1 elem kimaradt, és ezzel ellentmondásba kerülhetünk.
Döntési fa: Algoritmus n méretű inputra. Kiegyenesednek a ciklusok véges hosszú lánccá, a végrehajtás nyoma egy fa struktúrát ad. Tökéletes fa: minden belső pontnak 2 gyereke van. Ennél az algoritmusnál nincs jobb, mert $2^{h(t)} \geq n!$, összehasonlító rendezés esetén, $n!$ input.

4.3 Alsókorlát legrosszabb esetben

Tétel: $MO_R(n) = \Omega(n \log n)$ A legkedvezőtlenebb permutációra legalább $n \log n$ összehasonlítás. Bizonyítás: $\log_2 n! \leq n \log_2 n = \Omega(n \log n)$, és $MO_R(n) = h(t) \geq \log_2 n!$ (lemma miatt) $\Rightarrow MO_R(n) = \Omega(n \log n)$.

4.4 Alsókorlát átlagos esetben

Legyen minden input egyformán valószínű ($\frac{1}{n!}$).
$AO_R(n) = \frac{1}{n!} \sum_{p \in Perm(n)} O_R(p)$, és könnyű belátni, hogy $\sum_p O_R(p) = lhsum(h(t_R(n)))$ [levél-magasság-összeg].
Lemma: Az $n!$ levelet tartalmazó tökéletes fák közül azokra a legkisebb az $lhsum(h(t_R(n)))$ érték, amelyek majdnem teljesek.
Tétel: $AO_R(n) = \Omega(n \log n)$.