

# Achtste college Complexiteit

4 april 2025

Shellsort restant  
optimaal sorteren  
 $O(n)$ -sorteren

## ▷ Quicksort

- verdeel-en-heers: partitioneert het array in twee delen en sorteert deze *recursief*
- worst case  $\in \Theta(n^2)$ , average case  $\in \Theta(n \lg n)$

## ▷ Shellsort

- gebruikt een rijtje stapgroottes  $h_t, h_{t-1}, \dots, h_2, h_1 = 1$
- $h_i$ -sorteert deelrijtjes van eltn op afstand  $h_i$  van elkaar
- sorteert de deelrijtjes m.b.v. Insertion sort
- met  $h_i = \lfloor \frac{h_{i+1}}{2} \rfloor$  (Shell): worst case  $\in \Theta(n^2)$
- complexiteit hangt af van de gekozen stapgroottes
- analyse extreem moeilijk en incompleet

**Definitie**

Een rij  $A[1], A[2], \dots, A[n]$  heet  $k$ -gesorteerd als geldt:  
 $A[i] \leq A[i + k]$  voor elke  $i = 1, 2, \dots, n - k$ .

**Voorbeeld:** Het rijtje

5, 8, 24, 13, 7, 18, 31, 19, 44, 63, 82, 29

is 4-gesorteerd (en overigens ook 6-gesorteerd).

Merk op: 1-gesorteerd = gesorteerd.

```
(1)   $h = n \text{ div } 2$ ; //  $h_t = \lfloor \frac{n}{2} \rfloor$  dus
(2)  while  $h > 0$  do
(3)      for  $i := h + 1$  to  $n$  do
(4)           $temp := A[i]$ ;  $j := i$ ;
(5)          while  $j - h > 0$  do
// invoegen op de juiste plek in je eigen deelrijtje
(6)              if  $temp < A[j - h]$  then
(7)                   $A[j] := A[j - h]$ ; // schuif
(8)                   $j := j - h$ ;
(9)              else
(10)                  “exit binnenste while”;
(11)              fi
(12)          od
(13)           $A[j] := temp$ ; // zet neer
(14)      od
// de rij is nu  $h$ -gesorteerd
(15)   $h := h \text{ div } 2$ ; // oorspronkelijke keuze van Shell:  $h_i = \lfloor \frac{h_{i+1}}{2} \rfloor$ 
(16) od
```

Merk op: regel (4) t/m (13) is Insertion sort op deelrijtjes

Stapgroottes:  $h_t = \lfloor \frac{n}{2} \rfloor$ ,  $h_i = \lfloor \frac{h_{i+1}+1}{2} \rfloor$  voor  $i = t-1, \dots, 1$ .  
Het aantal rondes is dan  $t = \lfloor \lg n \rfloor$ .

- **Stelling A**

Het aantal arrayvergelijkingen dat Shellsort met deze serie stapgroottes doet is in de **worst case**  $\Omega(n^2)$ .

Vorige keer aangetoond voor  $n = 2^k$  door een bad case invoer te geven waarvoor het aantal vergelijkingen  $\Omega(n^2)$  is.

- **Stelling B**

Het aantal arrayvergelijkingen dat Shellsort doet met deze serie stapgroottes is in de **worst case**  $O(n^2)$ .

Bewijs: zie college.

Stapgroottes (Hibbard):  $2^k - 1, 2^{k-1} - 1, \dots, 7, 3, 1$ .

Het aantal rondes is hier  $k = \lfloor \lg n \rfloor$ .

Merk op: opeenvolgende stapgroottes zijn hier relatief priem (hebben geen gemeenschappelijke deler). Dit volgt uit:

$$h_{i+1} = 2h_i + 1.$$

- **Stelling**. In de **worst case** doet Shellsort met Hibbard's serie stapgroottes  $O(n\sqrt{n})$  vergelijkingen.

**Voorbeeld.** Na 8-sorteren heeft 3-sorteren i.h.a. veel meer effect dan 4-sorteren.

8-gesorteerd, 36 inversies

5, 2, 11, 7, 15, 3, 16, 6, 12, 9, 14, 8, 19, 13, 20, 10

↓ 4-sorteren

31 inversies

5, 2, 11, 6, 12, 3, 14, 7, 15, 9, 16, 8, 19, 13, 20, 10

8-gesorteerd, 36 inversies

5, 2, 11, 7, 15, 3, 16, 6, 12, 9, 14, 8, 19, 13, 20, 10

↓ 3-sorteren

7 inversies

5, 2, 3, 6, 7, 8, 9, 12, 11, 10, 13, 15, 14, 16, 20, 19

Stapgroottes (Hibbard):  $2^k - 1, 2^{k-1} - 1, \dots, 7, 3, 1$ ,  $k = \lfloor \lg n \rfloor$ .

**Stelling.** In de **worst case** doet Shellsort met Hibbard's reeks stapgroottes  $O(n\sqrt{n})$  arrayvergelijkingen.

**Bewijsschets:** Je kunt inzien dat je bij stapgrootte  $h_i$  voor elk van de  $n - h_i$  getallen maar met hoogstens  $8h_i + 4$  getallen hoeft te vergelijken\*. Met  $h_i = 3$ ,  $h_{i+1} = 7$  en  $h_{i+2} = 15$  weet je bij het  $h_i$ -sorteren bijvoorbeeld al zeker dat  $A[40] \leq A[92]$  omdat  $A[40] \leq A[47] \leq A[62] \leq A[77] \leq A[92]$ . Dat is dus  $O(nh_i)$  werk. We gebruiken dit voor  $h_i < \sqrt{n}$ . Voor  $h_i > \sqrt{n}$  als voorheen (zie bewijs Stelling B):  $O(n^2/h_i)$ . Totaal geeft dat uiteindelijk  $O(n\sqrt{n})$ .

\*dit volgt uit de speciale eigenschappen van de  $h_i$

We gebruiken een **Stelling uit de getaltheorie**

Als  $\text{ggd}(h, \ell) = 1$ , dan is het grootste gehele getal  $m$  dat niet als  $a \cdot h + b \cdot \ell$  ( $a, b \geq 0$ , geheel) geschreven kan worden:  $m = h\ell - h - \ell$

### Gevolg

Alle gehele getallen  $\geq h\ell - h - \ell = (h-1)(\ell-1)$  kunnen als lineaire combinatie van  $h$  en  $\ell$  worden geschreven.

Voorbeeld:  $h = 3, \ell = 7$  dus  $m = 12$ : 1, 2, 3, 4, 5, 6, 7, 8, 9, 10, 11, 12, 13, 14, ...

Als we dit toepassen op  $h_{i+1}$  en  $h_{i+2}$  vinden we: alle integers  $j$  met  $j \geq (h_{i+1} - 1)(h_{i+2} - 1) = 8h_i^2 + 4h_i$  kunnen geschreven worden als  $a \cdot h_{i+1} + b \cdot h_{i+2}$ . Voor deze  $j$  geldt dus bij het  $h_i$ -sorteren dat  $A[p-j] = A[p - a \cdot h_{i+1} - b \cdot h_{i+2}] \leq A[p]$ , want het array is op dat moment al  $h_{i+1}$ - en  $h_{i+2}$ -gesorteerd.

Voor elk van de  $n - h_i$  in te voegen array-elementen hoeven we dus maar met maximaal  $(8h_i^2 + 4h_i)/h_i = 8h_i + 4$  elementen te vergelijken.

\*dit is extra voor de liefhebbers

## Beter stapgrootteseries:

- ▷ Twee (!) doorgangen:  $h_2 \approx 1,72 \cdot \sqrt[3]{n}$ ,  $h_1 = 1$   
Gemiddeld  $O(n^{5/3})$
- ▷ Heel veel doorgangen: increments van de vorm  $2^i \cdot 3^j$ :  
1, 2, 3, 4, 6, 8, 9, 12, 16, 18, 24, 27, 32, 36, 48, 54, 72, 81, ...  
Worst case  $O(n(\lg n)^2)$
- ▷ Increments van de vorm  $4^{j+1} + 3 \cdot 2^j + 1$ :  
1, 8, 23, 77, 281, 1073, 4193, 16577, ...  
Worst case  $O(n^{4/3})$
- ▷ ... (optimale serie stapgroottes is [nog] onbepaald)

Voor sorteeralgoritmen gebaseerd op arrayvergelijkingen is bewezen: het aantal arrayvergelijkingen\* in de worst case is ten minste  $\lceil \lg n! \rceil$

**Vraag:**

hoe dicht kan men in de buurt van deze ondergrens komen?

**Tabel:**

|                        |   |   |   |   |    |    |    |    |    |    |    |     |    |
|------------------------|---|---|---|---|----|----|----|----|----|----|----|-----|----|
| $n$                    | 2 | 3 | 4 | 5 | 6  | 7  | 8  | 9  | 10 | 11 | 12 | ... | 21 |
| $\lceil \lg n! \rceil$ | 1 | 3 | 5 | 7 | 10 | 13 | 16 | 19 | 22 | 26 | 29 | ... | 66 |
| $M(n)$                 | 1 | 3 | 5 | 8 | 11 | 14 | 17 | 21 | 25 | 29 | 33 | ... | 74 |
| $B(n)$                 | 1 | 3 | 5 | 8 | 11 | 14 | 17 | 21 | 25 | 29 | 33 | ... | 74 |

\*voor het vinden van de juiste ordening

$M(n)$  is het aantal arrayvergelijkingen dat Mergesort doet in de worst case voor een rij met  $n$  elementen.

$B(n)$  is het aantal arrayvergelijkingen dat Binary Insertion sort in de worst case doet voor een rij met  $n$  elementen.

Merk op dat  $\lceil \lg 1! \rceil = M(1) = B(1) = 0$ .

Binary Insertion sort werkt als Insertion sort, maar gebruikt voor het zoeken van de plek waar  $A[i]$  moet komen **binair zoeken** in plaats van lineair zoeken. (Zie ook opgave 34.)

Om  $A[i]$  op de juiste plek te kunnen invoegen in het deelarray  $A[1], \dots, A[i-1]$  zijn nu in het slechtste geval  $\lceil \lg i \rceil$  arrayvergelijkingen nodig\*. Dus:

$$B(n) = \sum_{i=2}^n \lceil \lg i \rceil \geq \lceil \sum_{i=2}^n \lg i \rceil = \lceil \lg n! \rceil$$

\*voor het vinden van de juiste positie

Er geldt zelfs:

$$\sum_{i=2}^n \lceil \lg i \rceil = n \lceil \lg n \rceil - 2^{\lceil \lg n \rceil} + 1,$$

en dat is ook precies het aantal vergelijkingen dat Mergesort doet. Dus  $B(n) = M(n)$ .

**Vraag:** Kan het nog beter?

**Antwoord:** Ja !

**Voorbeeld:** 5 elementen kunnen worden gesorteerd met 7 vergelijkingen (Howard Demuth, 1956). Zie ook opgave 25b.

De methode van Demuth kan gegeneraliseerd worden tot het algoritme **Merge Insertion sort** (Ford & Johnson, 1959)\*.

\*Lester Ford, Selmer Johnson

5 elementen kunnen worden gesorteerd met hooguit 7 vergelijkingen

3 vergelijkingen:  $a < b < d$ ;  $c < d$ ;  $e$

2 vergelijkingen:  $e$  invoegen in  $a < b < d$


max 2 vergelijkingen:  $c$  invoegen in  $e < a < b < d$  of

$a < e < b < d$  of

$a < b < e < d$  of

$a < b < d < e$

1. Vergelijk de  $n$  elementen twee aan twee.
2. Sorteer de  $\lfloor \frac{n}{2} \rfloor$  winnaars  $*$  (de grootsten dus) recursief.  
Dit levert iets op als:



Hierin betekent  $*_1 \longrightarrow *_2$  dat  $*_1 < *_2$  en  $\bullet \longrightarrow *$  dat  $\bullet < *$

3. Voeg nu de  $\lfloor \frac{n}{2} \rfloor$  verliezers (en de losse waarde als  $n$  oneven is) in op de juiste plek **in een ingenieuze volgorde**.

Het aantal vergelijkingen dat Merge Insertion sort doet is voor  $n \leq 11$  en  $n = 20, 21$  gelijk aan de theoretische ondergrens  $\lceil \lg n! \rceil$  voor sorteren.

Merge Insertion sort sorteert bijvoorbeeld:

- 10 elementen in 22 vergelijkingen (optimaal)
- 21 elementen in 66 vergelijkingen (optimaal)
- 12 elementen in 30 vergelijkingen: niet gelijk aan de theoretische ondergrens, wel (optimaal)

Voor kleine  $n$  (zoals  $n = 12$ ) is het mogelijk om, via exhaustive search, de echte ondergrens *empirisch* te bepalen: probeer alle mogelijke combinaties van vergelijkingen op alle permutaties van  $n$  getallen en concludeer dat  $\ell$  vergelijkingen niet voldoende zijn. De ondergrens is dan dus  $\geq \ell + 1$ .

Inmiddels is zo ook aangetoond dat Merge Insertion sort optimaal is voor  $n = 13, 14, 15, 22$  (Peczarski, 2004/2006). In 2023 is bewezen dat dit ook geldt voor  $n = 16, 17, 18$  (Stober, Weiss).

**Vraag:** is Merge Insertion sort optimaal?

**Antwoord:** nee, bijvoorbeeld voor  $n = 47$  is een algoritme bekend (Schulte Mönting, 1981) dat één vergelijking minder nodig heeft (200) dan Merge Insertion sort (201).

Als je helemaal niets weet over het array  $A$  is de enige manier om  $A$  correct te ordenen het stellen van vragen van de vorm  $A[i] < A[j]$ . In dat geval geldt de theoretische ondergrens  $\lceil \lg n! \rceil \in \Theta(n \lg n)$ . Soms kun je echter sneller sorteren dan  $\Theta(n \lg n)$  (namelijk in  $O(n)$  tijd) door handig gebruik te maken van voorkennis over de invoer.

Dit is niet in strijd met de theoretische ondergrens: die geldt immers voor sorteeralgoritmen die *alle* mogelijke inputs kunnen sorteren (en gebaseerd zijn op arrayvergelijkingen).

We bekijken ter afsluiting van het gedeelte over sorteren twee methoden die efficiënt sorteren als de invoer aan zekere voorwaarden voldoet: **Counting sort** en **Radix sort**.

**Invoer:** een array  $A = A[1], \dots, A[n]$

**Aanname:** elke  $A[i]$  is een geheel getal tussen 1 en  $k$  (voor zekere  $k$ )

**Uitvoer:** een array  $B$ , voorstellende het array  $A$  oplopend gesorteerd

Het **basisidee** (als alle  $A[j]$ 's verschillen): bepaal voor elke  $X = A[j]$  het aantal array-elementen kleiner dan  $X$ . Deze informatie kan dan gebruikt worden om  $X$  meteen op de juiste positie in het uitvoerarray te zetten: als er  $m$  elementen kleiner zijn komt  $A[j]$  op plek  $m + 1$ . Pas dit idee aan voor de situatie waarin waarden vaker kunnen voorkomen in  $A$ . Onder bovenstaande aanname over de invoer kan dat zonder (array)vergelijkingen in  $O(n)$  stappen.

```
for  $i := 1$  to  $k$  do
     $C[i] := 0$ ;           // initialisatie
od
for  $j := 1$  to  $n$  do
     $C[A[j]] := C[A[j]] + 1$ ;
    // telt hoe vaak de waarde  $A[j]$  in  $A$  voorkomt
od
for  $i := 2$  to  $k$  do
     $C[i] := C[i] + C[i - 1]$ ;
od
//  $C[i]$  bevat nu het aantal getallen  $\leq i$  uit  $A$ 
for  $j := n$  downto 1 do    // !!
     $B[C[A[j]]] := A[j]$ ;
     $C[A[j]] := C[A[j]] - 1$ ;
od
```

$$A = 3 \quad 6 \quad 4 \quad 1 \quad 3 \quad 4 \quad 1 \quad 4 \quad n = 8$$

$$C = 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad 0 \quad k = 6$$

$$C = 2 \quad 0 \quad 2 \quad 3 \quad 0 \quad 1 \quad \leftarrow \text{na tweede for}$$

$C[i]$  = aantal keer dat  $i$  in  $A$  voorkomt

$$C = 2 \quad 2 \quad 4 \quad 7 \quad 7 \quad 8 \quad \leftarrow \text{na derde for}$$

$C[i]$  = aantal array-elementen  $\leq i$

De **complexiteit** van Counting sort wordt bepaald door het aantal **toekenningen** ( $:=$ ) aan array-elementen, en dat zijn er  $\Theta(n + k)$ . Indien  $k \in O(n)$  is de complexiteit dus  $O(n)$ .

Extra geheugenruimte is ook  $\Theta(n + k)$ .

Counting sort werkt voor invoerrijtjes waarvan de waarden begrensd zijn (bijvoorbeeld tussen 1 en  $k$  liggen).

Counting sort is een **stabiele** sorteermethode, dat wil zeggen: gelijke waarden uit het invoerarray  $A$  komen in precies dezelfde volgorde in het uitvoerarray  $B$  te staan als ze in  $A$  stonden.

De sorteermethode **Radix sort** sorteert  $n$  getallen, elk van  $d$  cijfers, waarbij elk cijfer een waarde heeft tussen 0 en  $k - 1$  (bijvoorbeeld  $k = 2$ , of  $k = 10$ ).

De getallen worden gesorteerd door ze achtereenvolgens op het  $i$ -de cijfer te sorteren, te beginnen bij het minst significante cijfer. Het gebruik van een *stabiele* sorteermethode\* voor het sorteren op het  $i$ -de cijfer is essentieel.

**Radixsort**( $A$ ,  $d$ ):

```
for  $i := 1$  to  $d$  do  
  // minst significante cijfer eerst,  
  // dus van rechts naar links  
    sorteer  $A$  op het  $i$ -de cijfer  
    // met een stabiele (!) sorteermethode  
od
```

\*deze behoudt de volgorde van gelijke elementen

|                       |   |                       |   |                       |   |     |
|-----------------------|---|-----------------------|---|-----------------------|---|-----|
| 329                   |   | 720                   |   | 720                   |   | 329 |
| 457                   |   | 455                   |   | 329                   |   | 355 |
| 657                   |   | 355                   |   | 436                   |   | 436 |
| 839                   | → | 436                   | → | 839                   | → | 455 |
| 436                   |   | 457                   |   | 455                   |   | 457 |
| 720                   |   | 657                   |   | 355                   |   | 657 |
| 455                   |   | 329                   |   | 457                   |   | 720 |
| 355                   |   | 839                   |   | 657                   |   | 839 |
| ↑                     |   | ↑                     |   | ↑                     |   |     |
| sorteer op            |   | sorteer op            |   | sorteer op            |   |     |
| 1 <sup>e</sup> cijfer |   | 2 <sup>e</sup> cijfer |   | 3 <sup>e</sup> cijfer |   |     |

Indien de gebruikte sorteermethode voor het sorteren per cijfer niet stabiel is kan het fout gaan:

|     |   |     |   |     |   |     |
|-----|---|-----|---|-----|---|-----|
| 329 |   | 720 |   | 329 |   | 355 |
| 457 |   | 355 |   | 720 |   | 329 |
| 657 |   | 455 |   | 839 |   | 455 |
| 839 | → | 436 | → | 436 | → | 457 |
| 436 |   | 657 |   | 457 |   | 436 |
| 720 |   | 457 |   | 657 |   | 657 |
| 455 |   | 839 |   | 455 |   | 720 |
| 355 |   | 329 |   | 355 |   | 839 |
| ↑   |   | ↑   |   | ↑   |   |     |

Gebruikte sorteermethode per cijfer is hier Mergesort

- Als sorteermethode per cijfer kunnen we **Counting sort** gebruiken, aangezien de cijfers tussen 0 en  $k - 1$  zitten.
- Bovendien is Counting sort *stabiel* (zie eerder).
- Als we Counting sort gebruiken kost elke ronde  $\Theta(k + n)$  stappen. In totaal ( $d$  rondes) dus  $\Theta(dk + dn)$ . En dat is  $O(n)$  als  $d$  een constante is en  $k \in O(n)$ .
- Een nadeel van deze methode is dat er net als bij Counting sort  $\Theta(n + k)$  extra geheugenruimte nodig is.
- Radix sort kun je bijvoorbeeld ook gebruiken om woorden alfabetisch te sorteren (met  $k = 26$  voor het Nederlandse alfabet).

- **Volgende college:** vrijdag 11 april, 11.00 – 12.45,  
Gorlaeusgebouw **zaal BM.1.33**
- **Straks geen werkcollege, wel:** mogelijkheid om te werken  
aan de tweede huiswerkopgave en stellen van vragen  
Gorlaeusgebouw zalen BW.0.29 en BW.0.30
- **Tweede huiswerkopgave:**  
deadline maandag 7 april
- **Derde huiswerkopgave (Shellsort):**  
verschijnt volgende week
- **Website:**  
[liacs.leidenuniv.nl/~graafjmde/COMP/](https://liacs.leidenuniv.nl/~graafjmde/COMP/)