

Vijfde college complexiteit

7 maart 2025

Selectie is $O(n)$

Insertion sort

Recurrente betrekkingen

Probleem

Gegeven een array $A = A[1], A[2], \dots, A[n]$ met n verschillende getallen. Gegeven is verder een geheel getal k met $1 \leq k \leq n$. Gevraagd de $A[i]$ die groter is dan precies $k - 1$ andere $A[j]$'s. M.a.w.: we zoeken de k -de in grootte (in volgorde van klein naar groot).

Complexiteit

Het selectieprobleem is $O(n)$.

We bewijzen dit door een algoritme te geven dat de k -de in grootte vindt in $O(n)$ vergelijkingen in de worst case*.

*Blum, Floyd, Pratt, Rivest & Tarjan, 1973


Algoritme:

1. Verdeel de getallen in $\lfloor \frac{n}{5} \rfloor$ groepjes van 5^* elementen, en één groepje met de resterende $n \bmod 5$.
2. Vind de mediaan van elk van de $\lfloor \frac{n}{5} \rfloor$ groepjes (van maximaal 5), bijvoorbeeld via Bubblesort of opgave 24.
3. Vind de mediaan x van de in stap 2 gevonden $\lfloor \frac{n}{5} \rfloor$ medianen: **recursie[†]**.

*deze 5 is niet zomaar willekeurig gekozen, maar is optimaal

[†]de **mediaan** van ℓ elementen is de $\lceil \frac{\ell}{2} \rceil$ -de in grootte.

4. Partitioneer (ongeveer zoals bij Quicksort) alle elementen rond x . Stel dat m getallen $\leq x$ zijn en $n - m$ getallen $> x$.



5. Vind de k -de in grootte uit m stuks als $k \leq m$, of de $(k - m)$ -de uit $n - m$ als $k > m$: **recursie**.

Na stap 3. van het algoritme geldt:

- ▷ ten minste $3 \cdot (\lceil \frac{1}{2} \lceil \frac{n}{5} \rceil \rceil - 2) \geq \frac{3n}{10} - 6$ elementen zijn groter (resp. kleiner) dan x
- ▷ er zijn dus hooguit $\frac{7n}{10} + 6$ elementen $\leq x$ (resp. $\geq x$) (*).

Gevolg: in stap 5. wordt het algoritme recursief aangeroepen op hooguit $\frac{7n}{10} + 6$ elementen (*).

(*) om preciezer te zijn: $\lceil \frac{7n}{10} \rceil + 6$

Zie opgave 30 voor een voorbeeld.

12	15	11	2	9	5	0	7	3	21	44	40	1	18	20	32	19	35	37	39
13	16	14	8	10	16	6	33	4	27	49	46	52	25	51	34	43	56	72	79
17	23	24	28	29	30	31	36	42	47	50	55	58	60	63	65	66	67	81	83
22	45	38	53	61	41	62	82	54	48	59	57	71	78	64	80	70	76	85	87
96	95	94	86	89	69	68	97	73	92	74	88	99	84	75	90	77	93	98	91

Blauw is de mediaan der medianen (x in stap 3) groen is gegarandeerd lager, evenals het linker oranje gedeelte; rood en het rechter oranje stuk zijn gegarandeerd hoger. In het algemeen zijn gegarandeerd ongeveer $\frac{3n}{10}$ elementen uit het array kleiner dan x en gegarandeerd ongeveer $\frac{3n}{10}$ elementen groter dan x . In het ergste geval ga je de recursie dus in op de resterende $\approx 70\%$ van het array.

Laat $T(n)$ het aantal vergelijkingen zijn dat dit (recursieve) algoritme doet in de worst case.

Onder de aanname dat $T(n)$ stijgend is geldt:

$$T(n) \leq \begin{cases} \text{const} & n \leq \dots \\ T(\lceil \frac{n}{5} \rceil) + T(\lceil \frac{7n}{10} \rceil + 6) + O(n) & n > \dots \end{cases}$$

$< n$ $\leq dn$ $\uparrow$
 als $n > 20$ bijv. 80

De term $O(n)$ komt van stap 1, 2 en 4 samen.

Bewering:

$T(n) \leq cn$ voor geschikte c en $n \geq \dots$

ofwel: $T(n) \in O(n)$

Opgave 26

Elk algoritme voor het selectieprobleem dat is gebaseerd op arrayvergelijkingen doet in de worst case **ten minste** $\lceil \frac{n}{2} \rceil$ van zulke vergelijkingen.

Gevolg

Het selectieprobleem is $\Omega(n)$

Eindconclusie

Het selectieprobleem is $\Theta(n)$


Probleem

Gegeven een rij (array) $A = A[1], \dots, A[n]$. Sorteert A oplopend, dus $A[i] \leq A[i + 1]$ voor alle i ($1 \leq i < n$); $A[i] < A[i + 1]$ als alle elementen verschillend zijn.



We bekijken eerst sorteeralgoritmen die gebaseerd zijn op het doen van arrayvergelijkingen

Insertion sort



Conceptueel idee: itereer over i en voeg $A[i]$ op de juiste plek in het gesorteerde stuk $A[1], \dots, A[i-1]$ in door herhaald te vergelijken met de linkerbuur en te verwisselen indien nodig.



Het algoritme is gebaseerd op het doen van arrayvergelijkingen ($A[i] < A[j]$).

```
(1)  for  $i := 2$  to  $n$  do  
      // nu  $A[i]$  op de juiste plek in  $A[1], \dots, A[i - 1]$  invoegen  
(2)       $x := A[i];$   
(3)       $j := i - 1;$   
(4)      while  $j > 0$  and  $A[j] > x$  do      //  $x = A[i]$   
(5)           $A[j + 1] := A[j];$   
(6)           $j := j - 1;$   
(7)      od  
(8)       $A[j + 1] := x;$   
(9)  od
```

- ▷ het aantal arrayvergelijkingen (&) is een goede maat voor de complexiteit.
- ▷ insertion sort doet eigenlijk steeds **compare-exchange** operaties: vergelijk en verwissel (indien nodig). Deze zijn hier vermomd als verschuivingen, waarna pas in de laatste stap $A[i]$ daadwerkelijk wordt neergezet.
- ▷ de verwisselingen zijn steeds **buurverwisselingen**.

- de for-loop (regel 1) doet precies $n - 1$ iteraties
- de test $(\&)$, dus $A[j] > x$, gebeurt minstens één keer per iteratie van de for-loop, dus totaal *minstens* $n - 1$ keer: $\#(\&) \geq n - 1$
- het vergelijken van array-elementen (want $x = A[i]$) is een kenmerkende operatie voor dit sorteeralgoritme

Dan:

- regels 1, 2, 3 en 8 gebeuren elk precies $n - 1$ keer*
- het eerste deel van regel 4 ($j > 0$) gebeurt per iteratie van de for-loop hooguit één keer vaker dan het tweede deel $(\&)$, dus in totaal hooguit $n - 1$ keer. Dat betekent dat $\#(j > 0) \leq 2 \cdot \#(\&)$
- regels 5 en 6 gebeuren alleen als tweede test in regel 4 waar is, en vinden dus ook in totaal hooguit even vaak plaats als $(\&)$

*eigenlijk gebeurt in regel 1 de test $i \leq n$ precies n keer (vergelijk met een while-loop), en dat is in orde van grootte hooguit even vaak als $(\&)$

We tellen het aantal vergelijkingen $A[j] > x$ (waar $x = A[i]$).

1. **Best case:** $B(n) = \sum_{i=2}^n 1 = n - 1$
2. **Worst case:** $W(n) = \sum_{i=2}^n (i - 1) = \frac{1}{2}n(n - 1)$
3. **Average case*:** $A(n) = \frac{1}{4}n(n - 1) + n - \sum_{i=1}^n \frac{1}{i} \in \Theta(n^2)$

*onder de aanname dat alle $A[i]$'s verschillend zijn en dat alle $n!$ permutaties (ordeningen) van $A[1]$ t/m $A[n]$ even waarschijnlijk zijn. We middelen dan over alle mogelijke permutaties en dat zijn in essentie alle mogelijke invoerrijtjes. We mogen voor het gemak zelfs wel aannemen dat A de getallen 1 t/m n bevat. Zie verder het college.

Het minimale aantal vergelijkingen van Insertion sort is $n - 1$.

- de eerste vergelijking op regel 4 is aanvankelijk altijd waar (want $i > 1$), dus de tweede vergelijking ($A[j] > x$) wordt elke iteratie minstens één keer uitgevoerd. Totaal $n - 1$ iteraties, dus ten minste $n - 1$ keer.
- $n - 1$ kan worden gehaald: daartoe moet voor *elke* i de test (&) precies 1 keer worden gedaan, en dat gebeurt d.e.s.d.a. voor *elke* i ofwel direct $A[i - 1] \leq A[i]$ is, ofwel $j \leq 0$ vóór de tweede vergelijking $A[j] > x$. Dat laatste komt alleen voor als $i = 2$ (en $A[1] > A[2]$).
- twee goede rijtjes: oplopend gesorteerd of alleen de eerste twee elementen staan verkeerd om:
 $A[1] \leq A[2] \leq \dots \leq A[n]$ of $A[2] < A[1] \leq A[3] \leq \dots \leq A[n]$.

Het maximale aantal vergelijkingen van Insertion sort is $\frac{1}{2}n(n-1)$.

- de tweede vergelijking op regel 4 kan alleen gebeuren zolang $j > 0$: dat is hooguit $i-1$ keer per iteratie van de for-loop. Totaal dus hooguit $\sum_{i=2}^n (i-1) = \frac{1}{2}n(n-1)$ keer.
- dit kan worden gehaald: daartoe moet in elke doorgang (voor elke i dus) $A[i]$ met alle voorgaande $A[j]$ vergeleken worden. Dit betekent dat voor alle $j = i-1, \dots, 2$ moet gelden dat $A[j] > A[i]$. Voor $j = 1$ wordt de test (&) nog wel gedaan, maar maakt de uitslag daarvan niet meer uit.
- slechte rijtjes: alle rijtjes waarvoor voor elke $A[i]$ met $i \geq 2$ geldt dat $A[i]$ het kleinste of het op één na kleinste element is van $A[1], \dots, A[i]$.
- Zie verder opgave 7c.

Definitie: een **inversie** van de permutatie $A[1], A[2], \dots, A[n]$ is een paar $(A[i], A[j])$ waarvoor $i < j$ en $A[i] > A[j]$. M.a.w.: een inversie is een paar $(A[i], A[j])$ dat verkeerd om staat.

Merk op: *elk* sorteeralgoritme moet *alle* aanwezige inversies opheffen.

Verder: als een sorteeralgoritme altijd hooguit één inversie opheft per arrayvergelijking, dan is het aantal vergelijkingen dat wordt gedaan om $A[1], \dots, A[n]$ te sorteren *ten minste* het aantal inversies van A .

Ten slotte: een **buurverwisseling** (zoals bij Insertion sort) heft altijd precies één inversie op (aangenomen dat de buurelementen verkeerd om staan).

Stelling

Het maximale aantal inversies dat kan voorkomen in een rijtje van n verschillende waarden is $\binom{n}{2} = \frac{1}{2}n(n-1)$. Dit treedt alleen op bij een omgekeerd (= aflopend) gesorteerd rijtje.

Gevolg

Elk sorteeralgoritme dat sorteert met behulp van arrayvergelijkingen en dat per vergelijking hooguit één inversie opheft, doet **ten minste** $\frac{1}{2}n(n-1)$ vergelijkingen in de **worst case**.

Conclusie: Insertion sort is **optimaal** voor wat betreft de worst case, binnen de klasse van algoritmen gebaseerd op het doen van arrayvergelijkingen, waarbij per vergelijking hooguit één inversie wordt opgeheven (bijvoorbeeld via buurverwisselingen).

Stelling

Het *gemiddeld* aantal inversies in een permutatie van n verschillende waarden (bijvoorbeeld de getallen 1 t/m n) is $\frac{1}{4}n(n-1)$. Dit onder de aanname dat alle $n!$ permutaties even waarschijnlijk zijn.

Gevolg

Elk algoritme dat sorteert met behulp van arrayvergelijkingen en dat per vergelijking ten hoogste één inversie opheft, doet **ten minste** $\frac{1}{4}n(n-1)$ vergelijkingen in de **average case**.

Conclusie: Insertion sort doet gemiddeld $\frac{1}{4}n(n-1) + n - 1 - \sum_{i=2}^n \frac{1}{i} \in \Theta(n^2)$ vergelijkingen, dus Insertion sort is **optimaal in orde van grootte** wat betreft de average case en binnen de beschreven klasse van algoritmen.

Voor sorteeralgoritmen gebaseerd op arrayvergelijkingen, waarbij per arrayvergelijking hooguit één inversie wordt opgeheven*, geldt:

- $\# \text{ arrayvergelijkingen} \geq \# \text{ inversies invoerarray}$
- $\# \text{ arrayvergelijkingen in de worst case} \geq \frac{1}{2}n(n - 1)$

Als je een beter sorteeralgoritme (dat gebaseerd is op arrayvergelijkingen) wilt, moet je elementen verwisselen die verder van elkaar liggen, zoals gebeurt bij Mergesort, Quicksort, Shellsort (en veel meer).

*zoals bij algoritmen die gebruikmaken van buurverwisselingen, zoals Insertion sort en Bubblesort

Extra opgave, zie werkcollege:

Stel dat $A[i]$ en $A[i + k]$ ($k > 0$) verkeerd om staan en dat we die verwisselen. Hoeveel inversies worden dan ten minste respectievelijk ten hoogste opgeheven?

Situatie:



met $A[i] > A[i + k]$. Verwissel nu $A[i]$ en $A[i + k]$.

Complexiteit van recursieve algoritmen:

- in het algemeen is hier het **aantal recursieve aanroepen** een goede maat voor de hoeveelheid werk
- maar je kunt ook hier het aantal keer dat de basisoperatie wordt uitgevoerd tellen
- een en ander leidt tot **recurrente betrekkingen**

Als voorbeeld bekijken we een recursief algoritme voor het bepalen van het maximum van n getallen, opgeslagen in een array A . Basisoperatie: vergelijken van array-elementen.

```
int grootste(int A[ ], n) {  
    if n = 1 then  
        return A[n];  
    else  
        max := grootste(A, n - 1);  
        if A[n] > max then  
            max := A[n];  
        fi  
    fi  
    return max;  
}
```

werk
per
aanroep
($n > 1$)

Laat $C(n)$ = aantal arrayvergelijkingen ($A[n] > max$), dan geldt:

$$C(n) = \begin{cases} 0 & n = 1 \\ C(n-1) + 1 & n > 1 \end{cases} \quad \text{Oplossing: } C(n) = n - 1$$

- ▷ Rij van Fibonacci: 0, 1, 1, 2, 3, 5, 8, 13, 21, ...
- ▷ Vanaf het derde element: som van de voorgaande twee
- ▷ Een **recurrente betrekking** is een voorschrift om een waarde $T(n)$ te berekenen door middel van zijn voorganger(s), dus bijvoorbeeld $T(n - 1)$, of $T(\frac{n}{2})$, of ...

Voor de Fibonacci-getallen geldt:

$$T(n) = \begin{cases} 0 & n = 0 \\ 1 & n = 1 \\ T(n - 1) + T(n - 2) & n > 1 \end{cases}$$

Een ander voorbeeld van een **recurrente betrekking**:

$$T(n) = \begin{cases} 1 & n = 1 \\ 2T(\frac{n}{2}) + n & n = 2^k > 1 \end{cases}$$

- ▷ vorm een vermoeden voor een gesloten formule voor $T(n)$ door middel van:
 - herhaalde substitutie en afleiden algemene vorm, of:
 - probeer wat termen door te rekenen: zie je een patroon?
- ▷ bewijs ten slotte de formule met volledige inductie

Oplossing: $T(n) = n + n \lg n \in \Theta(n \lg n)$

De vorige **recurrente betrekking**, maar nu voor algemene n , dus niet alleen voor tweemachten:

$$T(n) = \begin{cases} 1 & n = 1 \\ 2T(\lfloor \frac{n}{2} \rfloor) + n & n > 1 \end{cases}$$

Dan geldt: $T(n) \in O(n \lg n)^*$ (en overigens ook $T(n) \in \Theta(n \lg n)$).

Dit kan worden bewezen door met behulp van volledige inductie bijvoorbeeld aan te tonen dat $T(n) \leq 2n \lg n$ voor alle $n \geq 2$.

*voor een algemene stelling, zie bijvoorbeeld de Smoothness Rule in The Design & Analysis of Algorithms van A. Levitin

- het kan vaak helpen om termen los te laten staan, waardoor je een sommatie beter kan herkennen, en/of de regelmaat eerder kunt ontdekken
- volledige inductie:
 - (i) *zwak*: neem aan dat het geldt voor $n - 1$ ^{*}
 - (ii) *sterk*: neem aan dat het geldt voor *alle* voorgaande n [†]
- nog een voorbeeld (opgave 14b):

$$T(n) = \begin{cases} 1 & n = 1 \\ 2T(n-1) + 1 & n > 1 \end{cases}$$

^{*}of voor $\frac{n}{2}$ of ...

[†]met $n = 2^k, k \geq 0$ of ...

En ten slotte nog twee voorbeelden om op te lossen.

$$(i) \quad T(n) = \begin{cases} 3 & n = 1 \\ T(n-1) + n - 1 & n > 1 \end{cases}$$

$$\text{Oplossing: } T(n) = 3 + \frac{1}{2}n(n-1)$$

$$(ii) \quad T(n) = \begin{cases} 0 & n = 1 \\ 2T(\frac{n}{4}) + \sqrt{n} & n = 4^k > 1 \end{cases}$$

$$\text{Oplossing: } T(n) = \sqrt{n} \log_4 n = \frac{1}{2} \sqrt{n} \lg n$$

- **Volgende college:** vrijdag 14 maart, 11.00 – 12.45, Gorlaeusgebouw zaal BW.0.40
- **Straks werkcollege:** vrijdag 7 maart, 13.15 – 15.00, Gorlaeusgebouw zalen BW.0.29 en BW.0.30
Opgaven: 7, extra, opgave 2c tentamen juni 2024, 14aeg
- **Eerste huiswerkopgave:**
zie website; deadline maandag 10 maart 2025;
inleveren via Brightspace
- **Website:**
liacs.leidenuniv.nl/~graafjmde/COMP/