

Eerste college complexiteit

4 februari 2008

Introductie

- docent: dr. J.M. (Jeannette) de Graaf
- werkgroep leider: Thijs van Ommen
- website: <http://www.liacs.nl/home/graaf/COMP/>
- college: dinsdag 11.15 – 13.00 in zaal 174
- werkcollege: maandag 11.15 – 13.00 in zaal 174

- eerste college: **maandag** 4 februari 2008
- tweede college: dinsdag 5 februari 2008
- eerste werkcollege: maandag 11 februari 2008
- **tentamen**: donderdag 5 juni, 14.00–17.00
- **hertentamen**: dinsdag 12 augustus, 10.00–13.00

Huiswerk:

- Er komen drie of vier huiswerkopgaven
- Deze dienen individueel ingeleverd te worden
- Samenwerken mag (met mate), overschrijven niet
- Voor elke huiswerkopgave krijg je een cijfer
- Het gemiddelde hiervan wordt opgeteld bij het aantal punten dat je voor het tentamen haalt
- Delen door 10 levert je eindcijfer

- Programmeren en Correctheid: correctheid van algoritmen
- Complexiteit:
 - (tijd)complexiteit: hoeveelheid werk
 - ruimtecomplexiteit: hoeveelheid geheugen
 - optimaliteit: kan het nog beter?

Opmerking: we zullen hier altijd sequentiële algoritmen bekijken.

Vraag: hoe meten we de hoeveelheid werk die een algoritme doet?

Complexiteit = tijdcomplexiteit = hoeveelheid werk

- een maat voor de hoeveelheid werk moet iets vertellen over de **efficiëntie van de methode**
- die maat moet **onafhankelijk** zijn van de gebruikte computer, programmeertaal, implementatiedetails etc.
- de complexiteit hangt gewoonlijk af van de **grootte van de invoer**: hoe groter de invoer, hoe hoger de complexiteit

Gegeven een array A ($A[1], A[2], \dots, A[n]$, ongesorteerd) met $n \geq 1$ gehele getallen. **Gevraagd** het maximum van deze getallen.

Een algoritme dat het maximum vindt:

```
(1)  max :=  $A[1]$ ;  
(2)  index := 2;  
(3)  while  $index \leq n$  do  
(4)      if  $max < A[index]$  then  
(5)           $max := A[index]$ ;  
(6)      fi  
(7)       $index := index + 1$ ;  
(8)  od  
(9)  return max;
```

(1)	$max := A[1];$	1 x
(2)	$index := 2;$	1 x
(3)	while $index \leq n$ do	n x
(4)	if $max < A[index]$ then	$n - 1$ x
(5)	$max := A[index];$	$\leq n - 1$ x
(6)	fi	
(7)	$index := index + 1;$	$n - 1$ x
(8)	od	
(9)	return $max;$	1 x
		<hr/>
		$(\leq) 4n$

aantal vergelijkingen ($max < A[index]$) = $n - 1 \approx n =$

aantal vergelijkingen ($index \leq n$) $\approx 4n$ $\Theta(n)$

Om de complexiteit van een algoritme te bepalen tellen we het aantal keer dat een geschikte **basisoperatie** wordt uitgevoerd.

- identificeer een operatie die **fundamenteel** is voor het algoritme (dus geen boekhoudoperaties zoals tellerophogingen)
- het totale aantal uitgevoerde operaties moet ruwweg evenredig zijn (in orde van grootte) aan het aantal basisoperaties, ofwel:
- alle andere operaties worden (in orde van grootte) **hooguit even vaak** uitgevoerd als de basisoperatie

probleem

X zoeken in een array

twee polynomen vermenigvuldigen

een array sorteren

graafprobleem

basisoperatie

vergelijking van X met een array-element (en vergelijking tussen array-elementen onderling)

vermenigvuldiging van twee getallen (en/of optelling)

vergelijking van twee array-entries

bezoek aan een knoop en/of doorlopen van een tak

De complexiteit van een algoritme hangt af van de **grootte van de invoer**: $f(n)$

- bepaal een basisoperatie
- tel het aantal basisoperaties $\implies f(n)$
- van belang is de orde van grootte van $f(n)$ voor grote $n \implies O, \Theta, \Omega$

De complexiteit hangt af van de grootte van de invoer.
Wat wordt bedoeld met invoergrootte?

probleem

grootte van de invoer

X zoeken in een array

aantal array-elementen

twee polynomen vermenigvuldigen

graad van de polynomen
(=aantal coëfficiënten)

een array sorteren

aantal array-elementen

graafprobleem

aantal knopen en/of takken

De complexiteit van een algoritme hangt af van de **soort invoer**: worst case, average case, best case

- **worst case** complexiteit is $g(n)$: het algoritme doet voor elke mogelijke invoer **hooguit** $g(n)$ stappen
- **best case** complexiteit is $h(n)$: het algoritme doet voor elke mogelijke invoer **minstens** $h(n)$ stappen
- worst case geeft dus een **bovengrens**, best case een **ondergrens**
- **average case** complexiteit is de complexiteit gemiddeld over alle mogelijke invoeren
- verschillende algoritmen voor hetzelfde probleem: vergelijk complexiteiten \implies **optimaliteit**

- bestaat er een efficiënter algoritme voor het probleem?
- heeft te maken met de **complexiteit van het probleem**: soms kan het niet beter
- je bewijst complexiteit van een probleem altijd binnen een bepaalde **klasse van algoritmen**, bijvoorbeeld de klasse van algoritmen gebaseerd op het doen van arrayvergelijkingen
- bewijs stellingen die een **ondergrens** opleveren voor het aantal (basis)operaties dat **nodig** is om het probleem op te lossen, d.w.z.

- laat zien dat **elk algoritme** voor het probleem **minstens** ... elementaire (basis-) stappen moet doen in de ... case (meestal worst case)
- om een ondergrens te bewijzen kunnen we bijvoorbeeld een **beslissingsboomargument** of een **adversary-argument** gebruiken
- de worst case complexiteit van een algoritme dat het probleem oplost levert een **bovengrens** voor de complexiteit van het probleem: het probleem **kan opgelost worden** in **hooguit** ... stappen

Complexiteit van recursieve algoritmen:

- in het algemeen is hier het **aantal recursieve aanroepen** een goede maat voor de hoeveelheid werk
- 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 .


```
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 recursieve aanroepen op n elementen, dan geldt:

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

```
(1)  A[0] := 0; i := 1;
(2)  while i < n do
(3)      while i < n and A[i] < A[i + 1] do
(4)          i := i + 1;
(5)      od
(6)      if i < n then
(7)          wissel(A[i], A[i + 1]);
(8)          i := i - 1;
(9)      fi
(10) od
```

Dit algoritme sorteert A (met $A[i] > 0$ voor $i = 1, \dots, n$ en $n > 1$ en alle $A[i]$ verschillend) oplopend.

- a. Leg uit waarom het vergelijken van array-elementen (regel 3, tweede test) een goede basisoperatie is.
- b. Bekijk worst case en best case.

Tweede college complexiteit

5 februari 2008

Wiskundige achtergrond

- $\lfloor x \rfloor =$ het grootste gehele getal $\leq x$

$$\lceil x \rceil = \text{het kleinste gehele getal } \geq x$$

Er geldt: $x - 1 < \lfloor x \rfloor \leq x \leq \lceil x \rceil < x + 1$ en $\lceil \frac{n}{2} \rceil + \lfloor \frac{n}{2} \rfloor = n$
voor elk geheel getal $n \geq 0$

- $\log_b x = y \iff b^y = x$

Notatie: $\lg x = \log_2 x$ en $\ln x = \log_e x$

$$\text{Er geldt: } \log_b x = \frac{\log_c x}{\log_c b}$$

- $\lceil \lg(n + 1) \rceil = \lfloor \lg n \rfloor + 1$

- $\lceil \frac{n}{2} \rceil = \begin{cases} \frac{n}{2} & \text{als } n \text{ even} \\ \frac{n+1}{2} & \text{als } n \text{ oneven} \end{cases}$

- $\lfloor \frac{n}{2} \rfloor = \begin{cases} \frac{n}{2} & \text{als } n \text{ even} \\ \frac{n-1}{2} & \text{als } n \text{ oneven} \end{cases}$

$$- \sum_{i=1}^n i = \frac{1}{2}n(n+1)$$

$$- \sum_{i=1}^n i^2 = \frac{1}{3}n^3 + \frac{1}{2}n^2 + \frac{1}{6}n$$

$$- \sum_{i=0}^k 2^i = 2^{k+1} - 1$$

$$- \sum_{i=a}^b q^i = \frac{q^a - q^{b+1}}{1-q} \text{ voor } q \neq 1$$

$$- \sum_{i=0}^{k-1} (i+1)2^i = (k-1)2^k + 1$$

$f, g : \mathbb{N} \longrightarrow \mathbb{R}$ (meestal \mathbb{R}^+)

1. $f = O(g)$: er bestaan constanten c en n_0 (beide > 0) zodat $0 \leq f(n) \leq cg(n)$ voor alle $n \geq n_0$: **asymptotische bovengrens**
2. $f = \Omega(g)$: er bestaan constanten c' en n'_0 (beide > 0) zodat $0 \leq c'g(n) \leq f(n)$ voor alle $n \geq n'_0$: **asymptotische ondergrens**
3. $f = \Theta(g)$: er bestaan constanten c_1, c_2 en n''_0 (alle > 0) zodat $0 \leq c_1g(n) \leq f(n) \leq c_2g(n)$ voor alle $n \geq n''_0$: **asymptotisch gedrag**

Voor bijbehorende plaatjes: zie college.

$f = \Theta(g)$: neem uit f de hoogste orde term, negeer alle lagere orde termen en de constante die voor de hoogste orde term staat $\longrightarrow g$.

$\Theta(1)$: constant

$\Theta(\lg n)$: logaritmisch

$\Theta(n)$: lineair

$\Theta(n^k)$ met $k > 0$: polynomiaal

$\Theta(2^n)$, $\Theta(a^n)$ met $a > 1$: exponentieel

$$\frac{1}{2}n^2 - 3n = \Theta(n^2)$$

$$3n^3 + 6n^2 + 9 = \Theta(n^3)$$

$$42n = O(n^2), \text{ maar NIET } 42n = \Omega(n^2)$$

$$\log_7 n = \Theta(\lg n)$$

$$\sum_{i=1}^n i = \Theta(n^2)$$

$$\sum_{i=1}^n \frac{1}{i} = \Theta(\lg n)$$

$$\sum_{i=1}^n \lg i = \Theta(n \lg n)$$

$$2^n = O(3^n), \text{ maar NIET } 2^n = \Omega(3^n)$$

$$n! = 1 * 2 * 3 * \dots * n$$

$$n! = O(n^n); n! = \Omega(2^n)$$

$$\lg(n!) = \sum_{i=1}^n \lg i$$

$$n! \geq \left(\frac{n}{2}\right)^{\frac{n}{2}} \text{ als } n \text{ even is; } n! \geq \left(\frac{n}{2}\right)^{\frac{n+1}{2}} \text{ als } n \text{ oneven is}$$

$$\text{Dus } n! \geq \left(\frac{n}{2}\right)^{\frac{n}{2}} \text{ als } n \geq 2$$

$$\text{En derhalve: } \lg(n!) \geq \frac{n}{2}(\lg n - 1)$$

$$\text{Formule van Stirling: } n! = \sqrt{2\pi n} \left(\frac{n}{e}\right)^n \left(1 + \Theta\left(\frac{1}{n}\right)\right)$$

Stelling

1. $f = \Theta(g) \iff f = O(g)$ en $f = \Omega(g)$
2. $f = O(g) \iff g = \Omega(f)$

Stelling

1. $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = \alpha$ met $0 < \alpha < \infty \implies f = \Theta(g)$
2. $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = 0 \implies f = O(g)$, maar $g \neq O(f)$
(ofwel $f \neq \Omega(g)$)
3. $\lim_{n \rightarrow \infty} \frac{f(n)}{g(n)} = \infty \implies f = \Omega(g)$, maar $f \neq O(g)$

In onderstaande tabel is te zien hoe snel enkele veel voorkomende functies toenemen als functie van n .

N	10	50	100	300	1000
$\log_2 N$	3	5	6	8	9
$5N$	50	250	500	1500	5000
$N \cdot \log_2 N$	33	282	665	2469	9966
N^2	100	2500	10 000	90 000	7 cijfers
N^3	1000	125000	7 cijfers	8 cijfers	10 cijfers
2^N	1024	16 cijfers	31 cijfers	91 cijfers	302 cijfers
$N!$	7 cijfers	65 cijfers	161 cijfers	623 cijfers	onvoorstelbaar
N^N	11 cijfers	85 cijfers	201 cijfers	744 cijfers	onvoorstelbaar

Vergelijk:

het aantal protonen in het heelal is een getal met 79 cijfers

het aantal microseconden sinds de oerknal is een getal met 24 cijfers

Polynomiaal: (meestal) binnen redelijke tijd klaar

Exponentieel: zeker niet in acceptabele tijd klaar

N	10	20	50	100	300
N^2	$\frac{1}{10000}$ sec	$\frac{1}{2500}$ sec	$\frac{1}{400}$ sec	$\frac{1}{100}$ sec	$\frac{9}{100}$ sec
N^5	$\frac{1}{10}$ sec	3,2 sec	5,2 min	2,8 uur	28,1 dag
2^N	$\frac{1}{1000}$ sec	1 sec	35,7 jaar	400 biljoen eeuwen	75 cijfers veel eeuwen
N^N	2,8 uur	3,3 biljoen jaar	70 cijfers veel eeuwen	185 cijfers veel eeuwen	728 cijfers veel eeuwen

executietijd tijd bij miljoen stappen per seconde

Vergelijk: de oerknal was ongeveer 15 miljard jaar geleden

Enige voorbeelden van recurrente betrekkingen.

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

$$\text{Oplossing: } T(n) = n + n \lg n = \Theta(n \lg n)$$

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

$$\text{Dan geldt: } T(n) = O(n \lg n)$$

Enige voorbeelden van recurrente betrekkingen.

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

$$\text{Oplossing: } T(n) = n$$

$$4. T(n) = \begin{cases} 3 & n = 1 \\ T(n-1) + n - 1 & n > 1 \end{cases}$$

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

De volgende stelling geeft een verband aan tussen de hoogte van een binaire boom en het aantal knopen (resp. bladeren).

Stelling

Gegeven een **binaire boom** met n knopen (en b bladeren) en hoogte h . Dan geldt:

$$1. h \geq \lceil \lg b \rceil$$

$$2. h \geq \lceil \lg(n + 1) \rceil - 1 = \lfloor \lg n \rfloor$$

Derde college complexiteit

12 februari 2008

Zoeken en beslissingsbomen

Probleem

Zoek X in een (willekeurig) array A , bestaande uit n elementen $A[1], \dots, A[n]$.

Complexiteit van het probleem (opgave 3.e.)

Elk algoritme dat een waarde X zoekt in een (willekeurig) array A met n elementen, en dat alleen gebruik maakt van sleutelvergelijkingen ($X =, < A[i]$), doet in de **worst case** ten minste n vergelijkingen.

Algoritme en complexiteit

Lineair zoeken (zie opgave 3) doet in de worst case n vergelijkingen, en is dus **optimaal**.

Overigens worden gemiddeld (**average case**) $q * \frac{1}{2} * (n + 1) + (1 - q) * n$ sleutelvergelijkingen gedaan, met q de kans dat X in A voorkomt.

Probleem

Zoek X in een **oplopend gesorteerd** array A , bestaande uit n elementen $A[1], \dots, A[n]$.

Algoritme (zie opgave 4):

```
(1)  index := 1;
(2)  while index ≤ n and  $A[\textit{index}] < X$  do
(3)      index := index + 1;      ↑ basisoperatie
(4)  od
(5)  if index ≤ n and  $X = A[\textit{index}]$  then
(6)      return index;
(7)  else
(8)      return -1;
(9)  fi
```

De complexiteit van **geordend lineair zoeken***.

Worst case:

n sleutelvergelijkingen ($A[index] < X$)

Average case:

$$\frac{n}{2} + \frac{n}{n+1} + q * \left(\frac{1}{2} - \frac{n}{n+1} \right) = \Theta\left(\frac{n}{2}\right),$$

met q de kans dat X in A voorkomt, en:

1. als X in A : alle n posities in A even waarschijnlijk
2. als X niet in A : alle $n + 1$ gaten even waarschijnlijk

*zie ook opgave 4

Neem weer aan dat A oplopend gesorteerd is en kies k met $1 \leq k < n$

```
index := k; // index is altijd een  $k$ -voud
// vergelijk  $X$  met  $A[k], A[2k], A[3k], \dots$ 
while index  $\leq n$  and  $A[\text{index}] < X$  do
    index := index +  $k$ ;
od
if index  $\leq n$ 
    //  $A[\text{index} - k] < X \leq A[\text{index}]$ 
    lineair zoeken van  $X$  in  $A[\text{index} - k + 1] \dots A[\text{index}]$ ;
else
    //  $A[\text{index} - k] < X \leq A[n]$ 
    lineair zoeken van  $X$  in  $A[\text{index} - k + 1] \dots A[n]$ ;
fi
```

Worst case:

$$\lfloor \frac{n}{k} \rfloor + k \text{ sleutelvergelijkingen}$$

Beste keus: $k = \lceil \sqrt{n} \rceil$.

Dan doet Jump sort in het slechtste geval $\Theta(\sqrt{n})$ sleutelvergelijkingen. Dat is beter dan lineair zoeken.

Vraag: kan zoeken in een geordend array nog beter?

Antwoord: Ja, namelijk **binair zoeken**.

```
Links := 1; Rechts := n;
while Links ≤ Rechts do
    Midden := ⌊ $\frac{\text{Links} + \text{Rechts}}{2}$ ⌋;
    if X = A[Midden] then
        return Midden;
    else
        if X < A[Midden] then
            Rechts := Midden - 1;    // linkerstuk
        else
            Links := Midden + 1;    // rechterstuk
        fi
    fi
od
return -1;
```

We tellen de achtereenvolgende tests $X = A[\text{Midden}]$ en $X < A[\text{Midden}]$ als 1 vergelijking.

Worst case: $\lceil \lg(n+1) \rceil = \lfloor \lg n \rfloor + 1$ vergelijkingen

Average case (voor $n = 2^k - 1$): gemiddeld aantal vergelijkingen nodig om X te vinden in A is

- $\frac{1}{n} \sum_{i=0}^{k-1} (i+1)2^i$ als X zeker in A zit*
- k als X niet aanwezig†
- in totaal dus $\frac{q}{n} \sum_{i=0}^{k-1} (i+1)2^i + (1-q)k = \Theta(\lg(n+1))$, met q de kans dat X in A voorkomt.

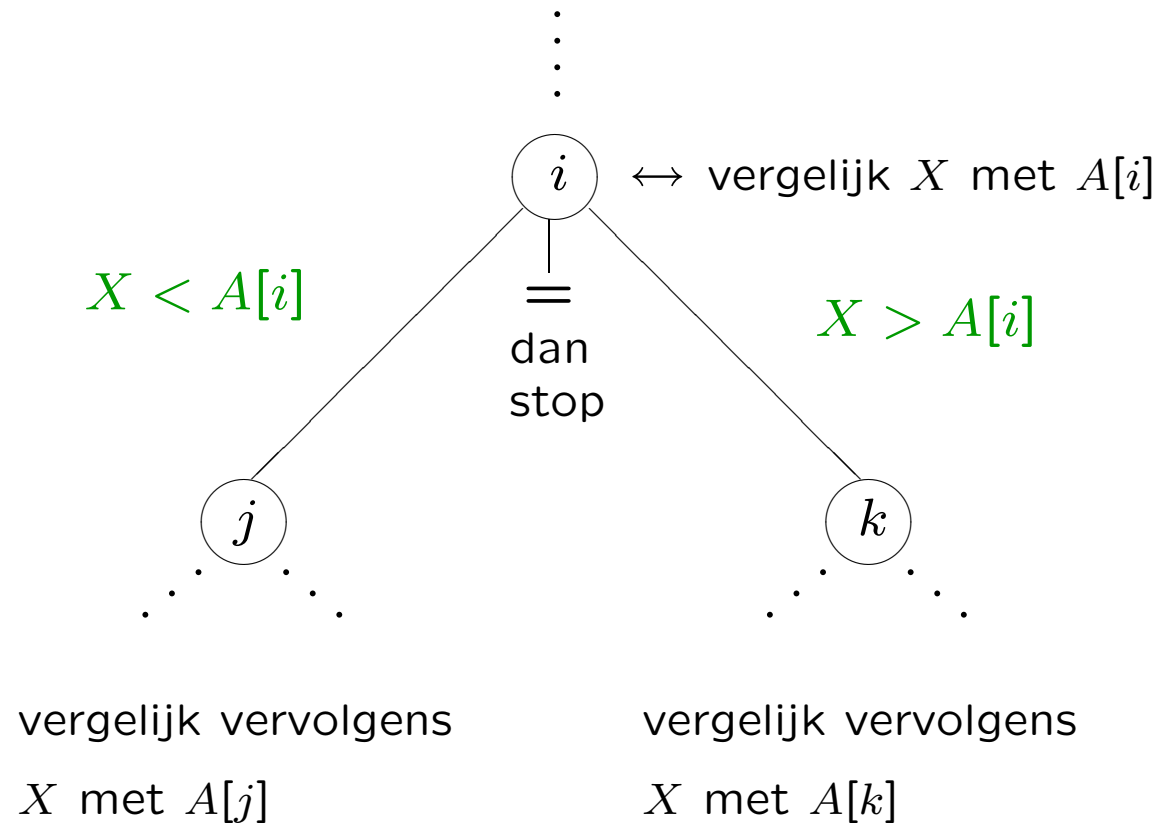
*onder de aanname dat elke positie even waarschijnlijk is

†het kost altijd k vergelijkingen om dat te constateren

algoritme gebaseerd op het doen van sleutelvergelijkingen
 $X =, < A[i]$



beslissingsboom: binaire boom waarin knopen correspon-
deren met sleutelvergelijkingen; een pad vanaf de wortel
naar een willekeurige knoop correspondeert met een exe-
cutie van het algoritme



Beslissingsboom voor algoritmen gebaseerd op sleutelvergelijkingen

Stelling

Elk algoritme dat X opspoot in een array met n elementen, en dat uitsluitend gebaseerd is op het doen van sleutelvergelijkingen*, doet ten minste $\lceil \lg(n+1) \rceil = \lfloor \lg n \rfloor + 1$ vergelijkingen in de **worst case**.

Gevolg

Binair zoeken is optimaal (voor wat betreft de worst case)

*van de vorm $X =, < A[i]$

Vierde college complexiteit

19 februari 2007

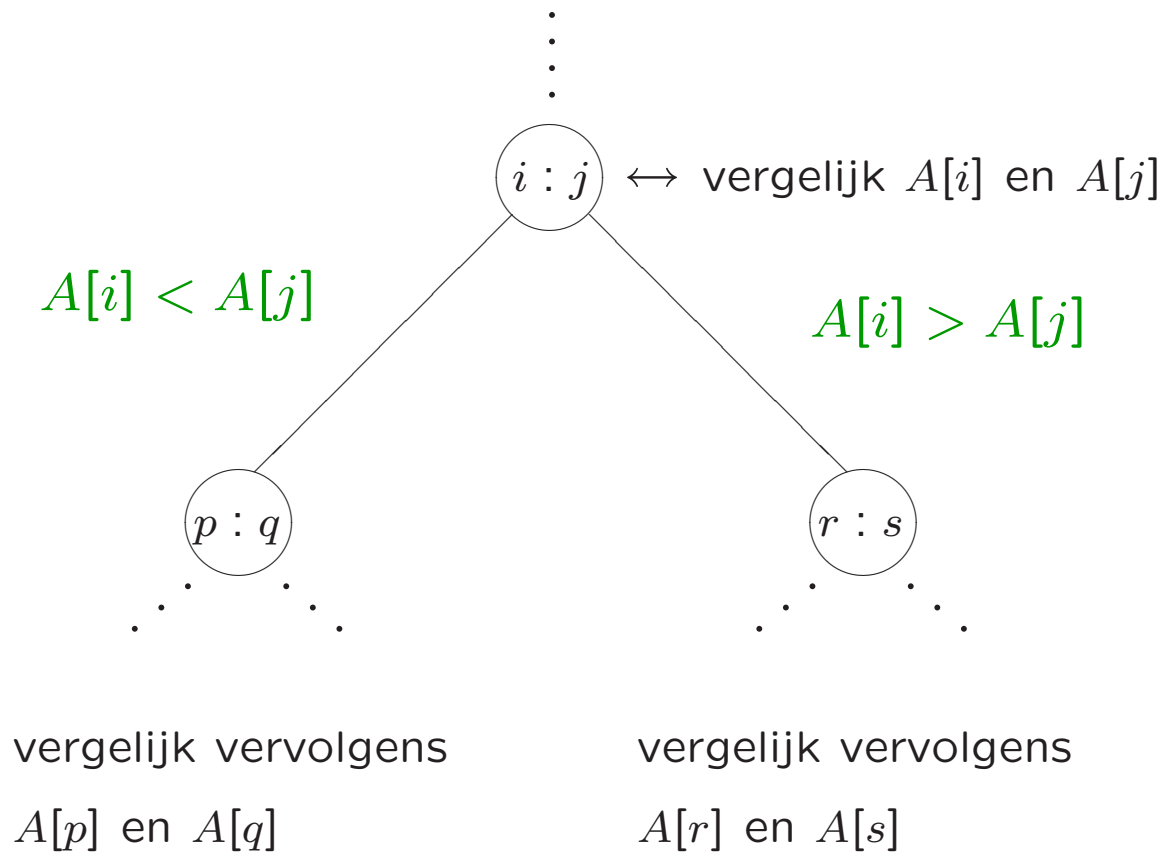
Selectie en adversary argument

algoritme gebaseerd op het doen van arrayvergelijkingen
 $A[i] < A[j]$



beslissingsboom*: binaire boom waarin de interne knopen corresponderen met arrayvergelijkingen en de bladeren/externe knopen met het eindresultaat; een pad vanaf de wortel naar een blad correspondeert met een executie van het algoritme

*alle $A[i]$ zijn verschillend



Beslissingsboom voor algoritmen gebaseerd op arrayvergelijkingen

Stelling

Elk algoritme dat de grootste (resp. kleinste) bepaalt uit een array met n elementen, en dat uitsluitend gebaseerd is op het doen van arrayvergelijkingen, doet **ten minste** $\lceil \lg n \rceil$ vergelijkingen in de **worst case**.

Merk op

We hadden voor het opsporen van het maximum/minimum al een **scherpere ondergrens** gevonden, namelijk $n - 1$.

Probleem

Gegeven n verschillende getallen, opgeslagen in een array $A: A[1], A[2], \dots, A[n]$. Laat verder een geheel getal k met $1 \leq k \leq n$ gegeven zijn. Gevraagd de $A[i]$ die kleiner is dan precies $k - 1$ andere $A[j]$'s.

M.a.w.: we zoeken de k -de in grootte.

Klasse van algoritmen

We bekijken algoritmen die uitsluitend gebaseerd zijn op het doen van **arrayvergelijkingen**.

De **complexiteit** van het **probleem**:

Ondergrens

Elk algoritme gebaseerd op arrayvergelijkingen doet voor het selectieprobleem in de **worst case** altijd **ten minste** $\lceil \lg n \rceil$ vergelijkingen (beslissingsboomargument).

Bovengrens

Het probleem kan worden opgelost door het array eerst aflopend te sorteren. De k -de in grootte is dan $A[k]$. Sorteren kan met $\Theta(n \lg n)$ vergelijkingen (zie later), dus selectie is $O(n \lg n)$.

Opmerkingen

Zowel de bovengrens als de ondergrens kunnen scherper. We bekijken hierna steeds (het precieze aantal vergelijkingen in) de worst case.

1. $k = 1$: het **maximum**, of
 $k = n$: het **minimum**.

Het kan met $n - 1$ vergelijkingen. Dit is optimaal (al gezien)!

2. (Variant) Het **maximum en minimum** beide opsporen.

Voor de hand ligt een algoritme met $2n - 3$ vergelijkingen, maar het kan met $\lceil \frac{3n}{2} \rceil - 2$. Dit is optimaal (**adversary-argument**, zie verderop).

Voor deze variant moet natuurlijk $n \geq 2$ gelden.

3. $k = 2$: de **op een na grootste** (dus $n \geq 2$).

Voor de hand ligt een algoritme met $2n - 3$ vergelijkingen, maar het kan met $n + \lceil \lg n \rceil - 2$ vergelijkingen (**toernooimethode**). Dit is optimaal (ook via een adversary-argument).

4. $k = \lceil \frac{n}{2} \rceil$: de **mediaan** (= de middelste in grootte).

Er zit een gat tussen de best bekende ondergrens (ongeveer $2n$) en het best bekende algoritme. We kunnen dus niets over de optimaliteit van dat algoritme zeggen.

Een **optimaal algoritme**:

```
if A[1] > A[2] then //  $n \geq 2$ 
    grootste := A[1]; kleinste := A[2];
else
    grootste := A[2]; kleinste := A[1];
i := 3; // voor het gemak:  $n$  even
while i < n do // anders kleine aanpassing
    if A[i] > A[i + 1] then *
        gr := A[i]; kl := A[i + 1];
    else
        gr := A[i + 1]; kl := A[i];
    fi
    if gr > grootste then *
        grootste := gr;
    fi
    if kl < kleinste then *
        kleinste := kl;
    fi
    i := i + 2;
od
```

De **toernooimethode** is een optimaal algoritme voor het vinden van de op een na grootste.

Terminologie:

wedstrijd \longleftrightarrow vergelijking;

winnaar \longleftrightarrow grootste van de twee;

speler \longleftrightarrow array-element; etcetera.

Complexiteit:

De toernooimethode doet $n + \lceil \lg n \rceil - 2$ arrayvergelijkingen. Dit is optimaal.

Geschikte implementatie:

met behulp van een soort **heap** (zie opgave 26).

Algoritme (voor het gemak met $n = 2^\ell$):

- Laat de spelers twee aan twee tegen elkaar spelen ($\frac{n}{2}$ wedstrijden).
- Laat de $\frac{n}{2}$ winnaars weer twee aan twee tegen elkaar spelen; de $\frac{n}{4}$ winnaars daarvan weer, etcetera.
- Herhaal dit totdat je één speler overhoudt: dit is de eindwinnaar, dus **de grootste** van allemaal.
- Er zijn nu **$n - 1$ wedstrijden** gespeeld, en er waren **ℓ rondes** nodig ($\ell = \lg n$).

Algoritme (vervolg):

- Nu moet de **op een na grootste** nog gevonden worden.
- Dit moet een van de ℓ spelers zijn die in het toernooi van de grootste verloren heeft, en wel de grootste van die ℓ .
- Het kost nog **$\ell - 1$ vergelijkingen** om deze te bepalen.

Als $n = 2^\ell$ doet de toernooimethode dus **$n + \lg n - 2$** array-vergelijkingen in totaal. Dit is optimaal.

Opmerking: als n geen tweemacht is, is een kleine aanpassing nodig. Het aantal vergelijkingen wordt daarmee: **$n + \lceil \lg n \rceil - 2$** .

Een **algoritme** speelt een vraag-en-antwoord-spel tegen een **adversary (tegenstander)**.

- algoritme: wil zo veel mogelijk informatie krijgen om met **zo weinig mogelijk** vragen het probleem op te lossen
- adversary: wil zo weinig mogelijk informatie prijsgeven om ervoor te zorgen dat het algoritme **zo veel mogelijk** vragen moet stellen om de/een oplossing te vinden
- belangrijkste spelregel: **consistentie**. De adversary geeft alleen antwoorden die consistent zijn met eerder gegeven informatie.

Voorbeelden:

- datum raden (maand + dag)
- galgje: woord raden binnen 10 stappen
- X zoeken in een rij met n verschillende elementen

- de **adversary** beantwoordt de vragen van het algoritme volgens een of andere **adversary-strategie**
- deze strategie wil het algoritme dwingen zo veel mogelijk vragen te stellen
- de adversary bouwt zo tijdens de uitvoering van een algoritme een **bad-case invoer** op
- de adversary(-strategie) zorgt ervoor dat hij op elk moment een invoer kan geven die **consistent** is met de op de gestelde vragen gegeven antwoorden
- het aantal stappen (=vragen) dat elk *willekeurig* algoritme *ten minste* tegen de adversary(-strategie) moet uitvoeren om het juiste antwoord te krijgen geeft een **ondergrens** op de **worst case** complexiteit van het **probleem**.

Stelling

Elk algoritme gebaseerd op arrayvergelijkingen dat het minimum en het maximum van n (verschillende) waarden vindt, doet in het slechtste geval **ten minste** $\lceil \frac{3n}{2} \rceil - 2$ **vergelijkingen**.

Bewijs

De status van een array-element geven we aan met:

1. W: ≥ 1 keer gewonnen, nooit verloren
2. V: ≥ 1 keer verloren, nooit gewonnen
3. WV: ≥ 1 keer gewonnen en ≥ 1 keer verloren
4. N: nog nooit “gespeeld”

wedstrijd $x-y$	uitslag	N	W	V	WV	type
N-N	$x > y$	-2	+1	+1	--	1
V-N	$x < y$	-1	+1	--	--	1
W-N	$x > y$	-1	--	+1	--	1
W-W	consistent	--	-1	--	+1	2
V-V	consistent	--	--	-1	+1	2
W-V	$x > y$	--	--	--	--	
WV-WV	consistent	--	--	--	--	
WV-N	$x > y$	-1	--	+1	--	1
WV-W	$x < y$	--	--	--	--	
WV-V	$x > y$	--	--	--	--	
	begin	n	0	0	0	
	eind	0	1	1	$n - 2$	

Merk op dat de uitslagen altijd kunnen, want de waarde van een V (resp. W) mag altijd omlaag (resp. omhoog).

vergelijking
 $x > y$

actie van de adversary
(constructie bad case)

N-N

kies “frisse” waarden zodat $x > y$

W-N

kies “frisse” waarde voor y ($< x$)

je mag de waarde van x ook ongestraft
verhogen; dat beïnvloedt eerdere
uitslagen namelijk niet

W-V

x mag ongestraft verhoogd worden
(of y verlaagd) zodat $x > y$ wordt

W-W

laat winnen welk van de twee groter is

WV-V

y mag ongestraft verlaagd worden

Vijfde college complexiteit

26 februari 2008

Selectie $O(n)$ en Insertion sort

Een **adversary argument** wordt gebruikt om een **ondergrens** te vinden voor de **worst case** complexiteit van een **probleem**.

De adversary

- “speelt” tegen het algoritme volgens een **adversary strategie**
- probeert het algoritme **zo veel mogelijk** vragen te laten stellen
- antwoordt altijd **consistent** met eerdere antwoorden
- bouwt zo als het ware tegen elk algoritme een **bad case** invoer op

Het doel is een ondergrens $f(n)$ af te leiden voor het aantal stappen dat elk algoritme tegen de adversary nodig heeft. Dat betekent dat er voor *elk algoritme* een invoer bestaat waarop minstens $f(n)$ stappen nodig zijn. In dat geval is het aantal stappen in de worst case voor elk algoritme dus $\geq f(n)$.

Bepaal of een string bestaande uit n bits twee opeenvolgende nullen bevat.

Basisoperatie: het bekijken van één bitpositie

Laat zien:

1. als $n = 2, 3, 5$ moeten in de worst case alle n bits bekeken worden (*)
2. voor $n = 4$ is er een algoritme dat altijd maar 3 bits hoeft te bekijken

(*) met behulp van een **adversary argument**

Probleem

Gegeven n verschillende getallen, opgeslagen in een array $A: A[1], A[2], \dots, A[n]$. Laat verder een geheel getal k met $1 \leq k \leq n$ gegeven zijn. Gevraagd het k -de element in grootte.

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.

Algoritme:

1. Verdeel de getallen in $\lfloor \frac{n}{5} \rfloor$ groepjes van 5 elementen, en 1 groepje met de resterende $n \bmod 5$.
2. Vind de mediaan van elk van de $\lfloor \frac{n}{5} \rfloor$ groepjes van 5 (of minder), bijvoorbeeld met behulp van Bubblesort of opgave 21.
3. Vind de mediaan x van de in stap 2 gevonden $\lfloor \frac{n}{5} \rfloor$ medianen: **recursie**.

4. Partitioneer (ongeveer zoals bij Quicksort) alle elementen rond x . Stel dat m getallen $\geq x$ 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**

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

Na stap 3. van het algoritme geldt:

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


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

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

Probleem

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

Insertion sort



$A[i]$ op de juiste plek in het gesorteerde stuk $A[1] \cdots A[i - 1]$
invoegen.

Het algoritme is gebaseerd op het doen van **arrayvergelijkingen**.

```
(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  
(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 **buursverwisselingen**.

We tellen het aantal vergelijkingen $A[j] > x$.

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

(*) 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.

Zesde college complexiteit

4 maart 2008

Inversies, mergesort en merge

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 .

Bovendien: een **buursverwisseling** (zoals bij Insertion sort) heft altijd precies één inversie op (indien de buurelementen verkeerd om staan).

Stelling. Het maximale aantal inversies dat kan voorkomen in een rijtje van n verschillende waarden is $\binom{n}{2} = \frac{1}{2}n(n-1)$.

Gevolg. Elk sorteeralgoritme (gebaseerd op arrayvergelijkingen) dat hooguit één inversie opheft per vergelijking 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 buursverwisselingen).

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, moet **ten minste** $\frac{1}{4}n(n - 1)$ vergelijkingen doen in de **average case**.

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

Het (recursieve) algoritme:

MergeSort(A, p, r)::

// sorteert $A[p], \dots, A[r]$

if $p < r$ **then**

$q := \lfloor \frac{p+r}{2} \rfloor$;

MergeSort(A, p, q);

MergeSort($A, q + 1, r$);

Merge(A, p, q, r);

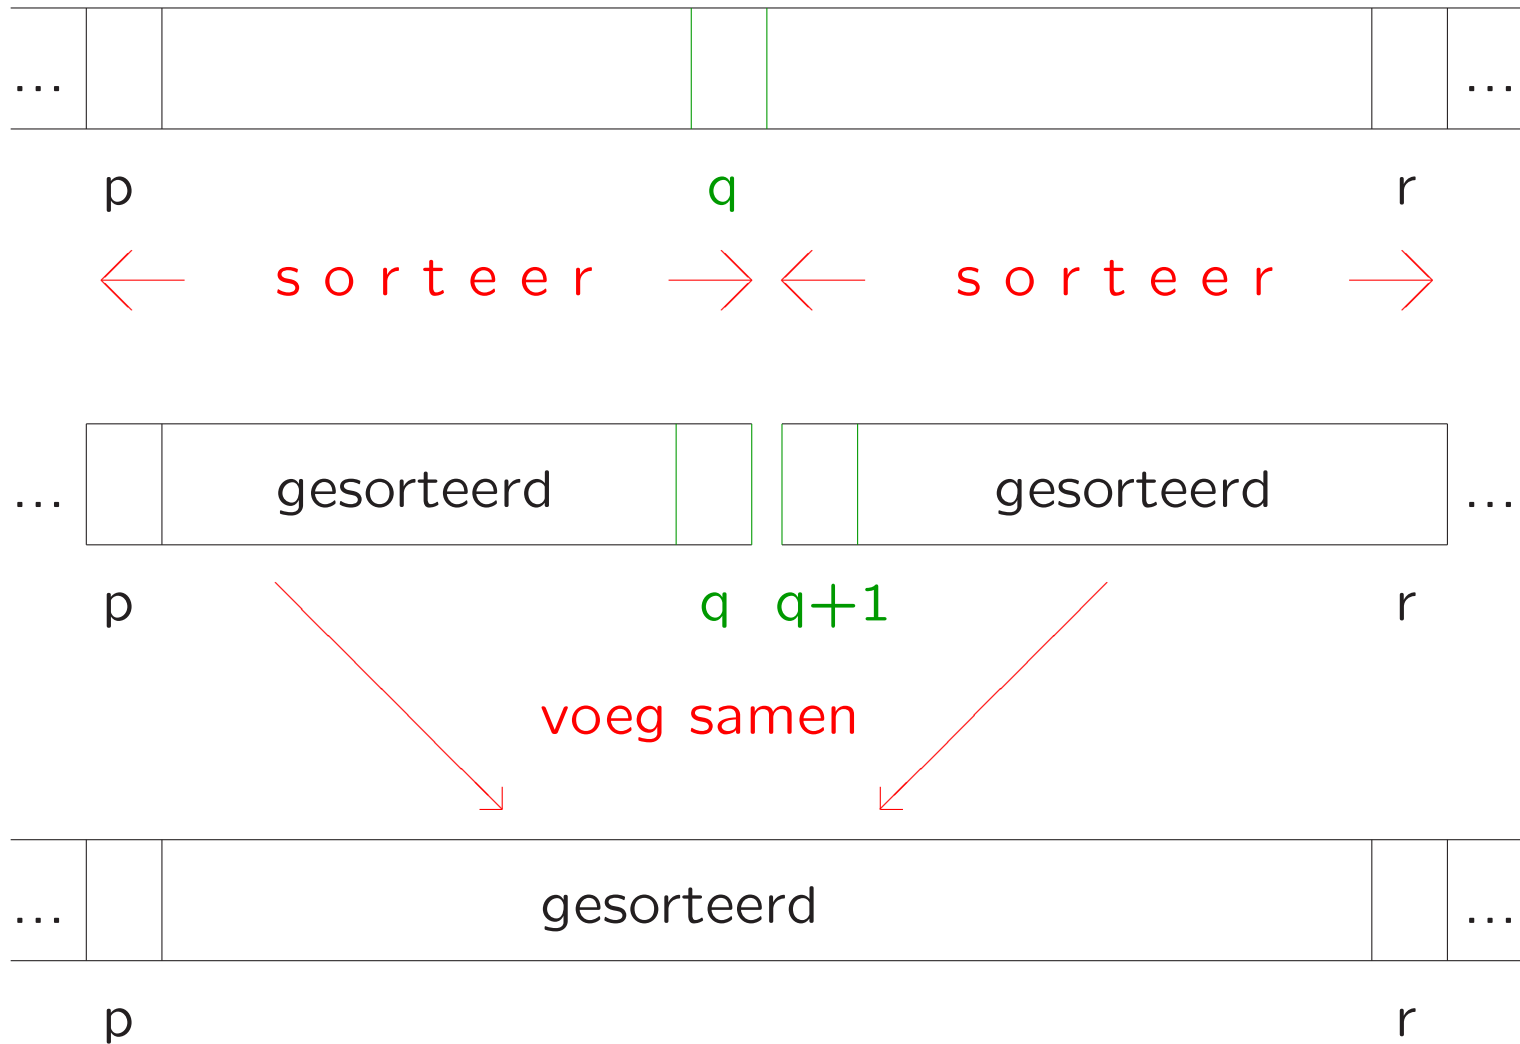
fi

verdeel

en

heers (voeg samen)

Aanroep: MergeSort($A, 1, n$).



Merge(A, p, q, r)::

```
 $i := p; j := q + 1; k := p;$ 
while  $i \leq q$  and  $j \leq r$  do
    if  $A[i] < A[j]$  then
         $hulp[k] := A[i]; i := i + 1; k := k + 1;$ 
    else
         $hulp[k] := A[j]; j := j + 1; k := k + 1;$ 
    fi
od
if  $i > q$  then // eerste helft is op
    kopieer  $A[j], \dots, A[r]$  naar  $hulp$ ;
else // tweede helft is op
    kopieer  $A[i], \dots, A[q]$  naar  $hulp$ ;
fi
kopieer  $hulp[p], \dots, hulp[q]$  terug naar  $A$ ;
```

- $\text{Merge}(A, p, q, r)$ voegt de reeds gesorteerde deelrijtjes $A[p], \dots, A[q]$ en $A[q + 1], \dots, A[r]$ samen tot een gesorteerd stuk $A[p], \dots, A[r]$
- *hulp* is een hulpparray ter grootte n (net als A)
- Voor het bepalen van de complexiteit van Merge tellen we het aantal vergelijkingen van de vorm: $A[i] < A[j]$
- Is het aantal arrayvergelijkingen hier wel een goede maat voor de complexiteit?

Stel dat we met behulp van Merge twee gesorteerde rijtjes van respectievelijk k en m elementen (met $k + m = n$) samenvoegen tot één gesorteerde rij. Dan geldt:

1. Het aantal vergelijkingen in de **worst case** is $n - 1$
2. Het aantal vergelijkingen in de **best case** is $\min\{k, m\}$

Zij $T(n)$ = aantal vergelijkingen in de **worst case** van Mergesort op n elementen, met $n = 2^k$.

Dan geldt:

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

Oplossing: $T(n) = n \lg n - n + 1 = \Theta(n \lg n)$

Als n geen tweemacht is, wordt de recurrente betrekking:

$$T(n) = \begin{cases} 0 & n = 1 \\ T(\lfloor \frac{n}{2} \rfloor) + T(\lceil \frac{n}{2} \rceil) + n - 1 & n > 1 \end{cases}$$

Dan geldt eveneens: $T(n) = \Theta(n \lg n)$. (Zelfs: $T(n) = n \lceil \lg n \rceil - 2^{\lceil \lg n \rceil} + 1$)

Mergesort is in orde van grootte optimaal voor wat betreft de worst case (zie later). Er is echter extra geheugenruimte ter grootte $\Theta(n)$ nodig.

Zij $B(n)$ = aantal vergelijkingen in de **best case**, met $n = 2^k$. Dan geldt:

$$B(n) = \begin{cases} 0 & n = 1 \\ 2B(\frac{n}{2}) + \frac{n}{2} & n = 2^k > 1 \end{cases}$$

Oplossing: $B(n) = \frac{n}{2} \lg n = \Theta(n \lg n)$.

Opmerking: het aantal vergelijkingen in de worst case is $\Theta(n \lg n)$, evenals het aantal vergelijkingen in de best case.

Gevolg: het aantal vergelijkingen in de **average case** is ook $\Theta(n \lg n)$.

Stelling.

1. Elk algoritme, alleen gebaseerd op arrayvergelijkingen, dat twee gesorteerde arrays (rijen) van lengte m samenvoegt tot één gesorteerd array, doet in het **slechtste geval ten minste $2m - 1$** van zulke vergelijkingen.
Voor $m = \frac{n}{2}$ (n even) is dit dus ten minste $n - 1$.
2. Voor het samenvoegen van twee rijtjes ter lengte $m - 1$ respectievelijk m is dat **ten minste $2m - 2$** .
Voor $m = \lceil \frac{n}{2} \rceil$ (n oneven) is dit ten minste $n - 1$.

Gevolg. Binnen de klasse van samenvoegalgoritmen gebaseerd op arrayvergelijkingen is het beschreven Merge-algoritme optimaal.

We geven een klasse van invoerrijtjes waarop *elk* samenvoegalgoritme (gebaseerd op arrayvergelijkingen) *ten minste* $2m - 1$ vergelijkingen doet. Dat bewijst dan de stelling.

Kies de rijtjes $A = (a_1, a_2, \dots, a_m)$ en $B = (b_1, b_2, \dots, b_m)$ zo dat

$$b_1 < a_1 < b_2 < \dots < a_{i-1} < b_i < a_i < b_{i+1} < \dots < b_m < a_m$$

Dan *moet* elk samenvoegalgoritme a_i met b_i vergelijken ($i = 1, 2, \dots, m$) en a_i met b_{i+1} ($i = 1, 2, \dots, m - 1$).

Het bewijs van deze bewering gaat uit het ongerijmde.

We bekijken **sorteeralgoritmen** gebaseerd op het doen van vergelijkingen van de vorm $A[i] < A[j]$.

Aannames:

- A bevat n **verschillende** waarden. (We gaan immers een ondergrens voor de worst case bepalen.)
- het sorteeralgoritme stopt zodra de sortering (onderlinge ordening) gevonden is.

Zo'n algoritme correspondeert (voor elke n) met een **beslissingsboom** die de series vergelijkingen representeert die het algoritme uitvoert voor elke mogelijke invoer.


algoritme gebaseerd op het doen van arrayvergelijkingen
 $A[i] < A[j]$



beslissingsboom*: binaire boom waarin de interne knopen corresponderen met arrayvergelijkingen en de bladeren/externe knopen met het eindresultaat[†]; een pad vanaf de wortel naar een blad correspondeert met een executie van het algoritme

*alle $A[i]$ zijn verschillend

[†]eindresultaat = de gevonden **sorteringen/ordeningen** (in dit geval)



Beslissingsboom voor algoritmen gebaseerd op arrayvergelijkingen

1.
 - alleen de onderlinge volgorde van de array-elementen is van belang; niet de waarde
 - het rijtje 1, 5, 3, 4, 2 wordt bijvoorbeeld precies zo behandeld door het sorteeralgoritme als het rijtje 3, 15, 8, 11, 6
 - ze volgen dan ook precies hetzelfde pad in de beslissingsboom
 - er zijn in essentie $n!$ mogelijke te onderscheiden invoeren

2.
 - sorteren = vind de oplopende ordening
 - er zijn dus $n!$ verschillende eindantwoorden (=ordeningen) mogelijk
 - een sorteeralgoritme moet die allemaal kunnen bereiken
 - de bijbehorende beslissingsboom moet dus minstens $n!$ bladeren hebben

3. conclusie uit het voorgaande: een beslissingsboom corresponderend met een sorteeralgoritme heeft precies $n!$ bladeren (n = aantal array-elementen)

Stelling: Het aantal vergelijkingen in de **worst case** is voor elk algoritme dat sorteert middels arrayvergelijkingen **ten minste $\lceil \lg n! \rceil$** (dus $\Omega(n \lg n)$).

Stelling: Het aantal vergelijkingen in de **average case** is voor elk algoritme dat sorteert middels arrayvergelijkingen $\Omega(n \lg n)$.

Dit onder de aanname dat alle $n!$ mogelijke volgordes als invoerrijtje even waarschijnlijk zijn.

Zevende college complexiteit

17 maart 2008

Ondergrens sorteren, Quicksort

We bekijken **sorteeralgoritmen** gebaseerd op het doen van vergelijkingen van de vorm $A[i] < A[j]$.

Aannames:

- A bevat n **verschillende** waarden.
- het sorteeralgoritme stopt zodra de sortering (onderlinge ordening) gevonden is.

Zo'n algoritme correspondeert (voor elke n) met een **beslissingsboom** die de series vergelijkingen representeert die het algoritme uitvoert voor elke mogelijke invoer.

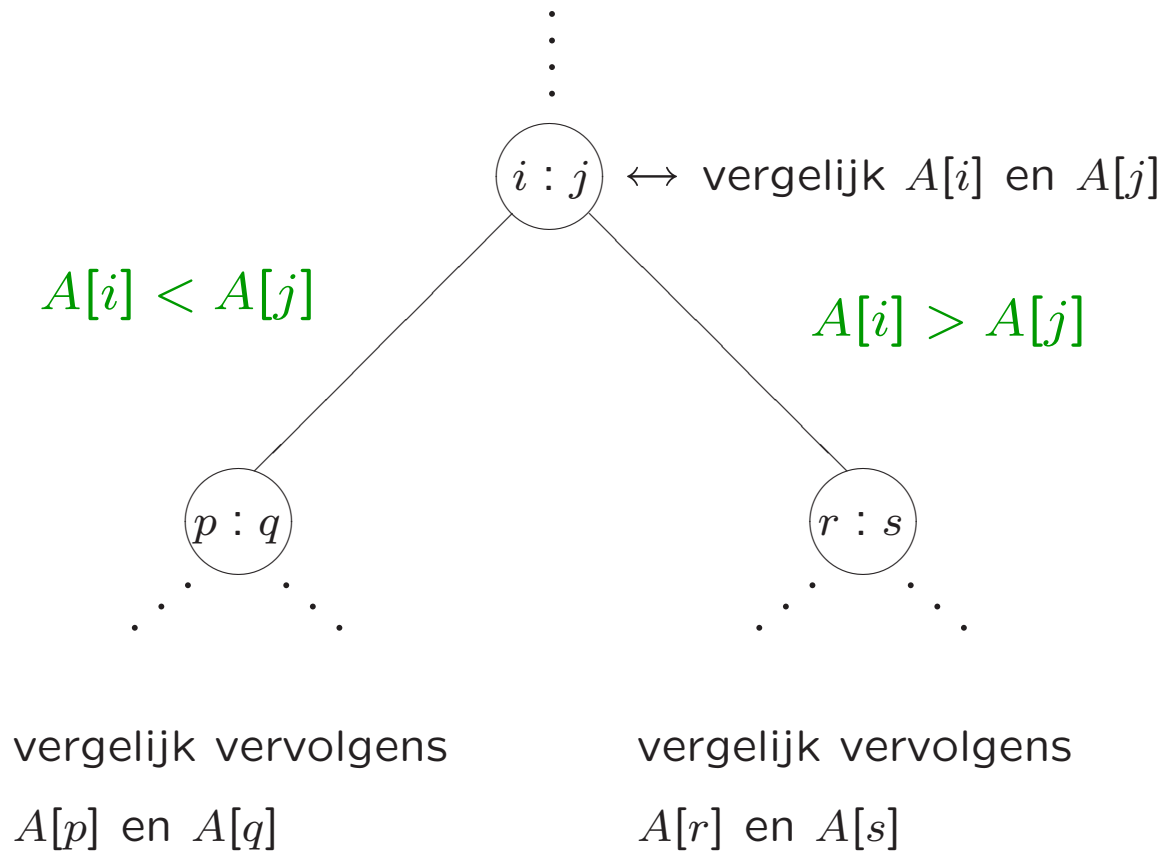
algoritme gebaseerd op het doen van arrayvergelijkingen
 $A[i] < A[j]$




beslissingsboom*: binaire boom waarin de interne knopen corresponderen met arrayvergelijkingen en de bladeren/externe knopen met het eindresultaat[†]; een pad vanaf de wortel naar een blad correspondeert met een executie van het algoritme

*alle $A[i]$ zijn verschillend

[†]eindresultaat = de gevonden **sorteringen/ordeningen** (in dit geval)



Beslissingsboom voor algoritmen gebaseerd op arrayvergelijkingen



Beslissingsboom voor Insertion sort met $n = 3$

1.
 - alleen de onderlinge volgorde van de array-elementen wordt onderscheiden; niet de waarde
 - het rijtje 3, 15, 8, 11, 6 wordt bijvoorbeeld precies zo behandeld door het sorteeralgoritme als het rijtje 1, 5, 3, 4, 2
 - ze volgen dan ook precies hetzelfde pad in de beslissingsboom
 - er zijn in essentie $n!$ mogelijke te onderscheiden invoeren, die elk één pad volgen in de boom \Rightarrow er zijn maximaal $n!$ bladeren
2.
 - sorteren = vind de oplopende ordening
 - er zijn dus $n!$ verschillende eindantwoorden (=ordeningen) mogelijk
 - een sorteeralgoritme moet die allemaal kunnen vinden
 - de bijbehorende beslissingsboom moet dus minstens $n!$ bladeren hebben
3. conclusie: een beslissingsboom corresponderend met een sorteeralgoritme heeft precies $n!$ bladeren (n = aantal array-elementen)

Stelling: Het aantal vergelijkingen in de **worst case** is voor elk algoritme dat sorteert middels arrayvergelijkingen **ten minste** $\lceil \lg n! \rceil$ (dus $\Omega(n \lg n)$).

Stelling: Het aantal vergelijkingen in de **average case** is voor elk algoritme dat sorteert middels arrayvergelijkingen $\Omega(n \lg n)$.

Dit onder de aanname dat alle $n!$ mogelijke volgordes als invoerrijtje even waarschijnlijk zijn.

Gegeven een binaire boom \mathcal{B} met b bladeren.

Definitie. De **externe padlengte** E van \mathcal{B} is de som van de lengtes van alle paden van de wortel naar een blad:

$$E = \sum_{\text{bladeren}} \text{lengte pad wortel naar blad}$$

Lemma. Zij E de externe padlengte van \mathcal{B} . Dan geldt:

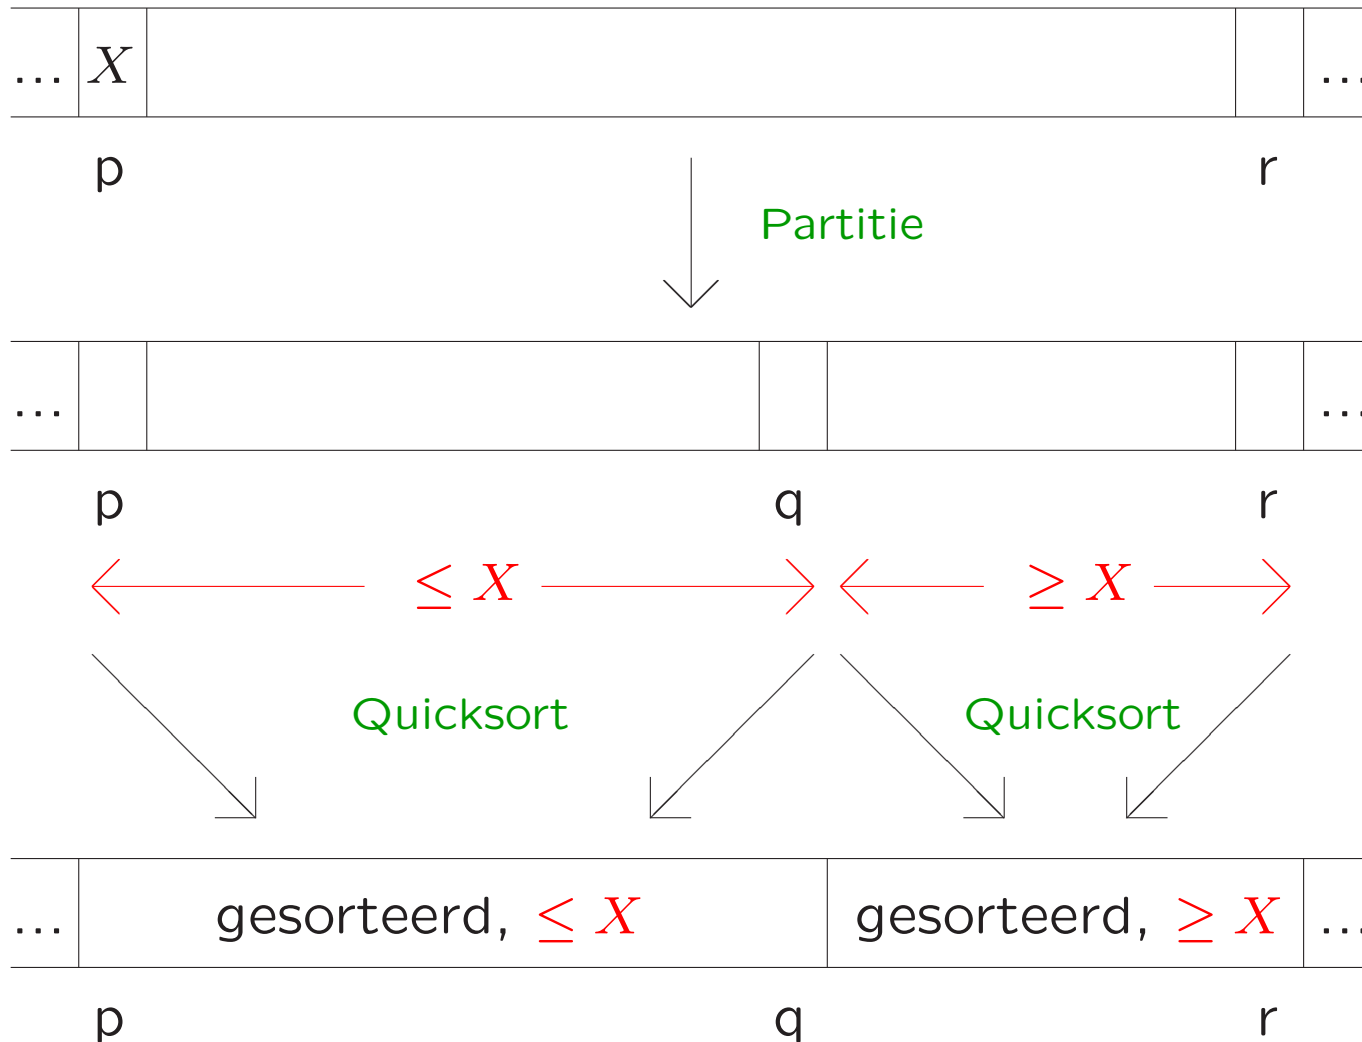
$$E \geq b(\lg b - 1)$$

Gevolg. De gemiddelde lengte van een pad van de wortel naar een blad $= \frac{E}{b} \geq \lg b - 1$.

```
QuickSort( $A, p, r$ )::  
// sorteert  $A[p], \dots, A[r]$  oplopend  
  if  $p < r$  then  
     $q :=$  Partitie( $A, p, r$ );  
    QuickSort( $A, p, q$ );  
    QuickSort( $A, q + 1, r$ );  
  fi
```

Aanroep:
QuickSort($A, 1, n$)

- recursief
- alleen interne verwisselingen
- geen extra geheugenruimte
- in de praktijk een van de snelste



Partitie $(A, p, r)::$
 // reorganiseert het (deel)array $A[p], \dots, A[r]$ als volgt:


//

..	$\leq X$	$\geq X$..
p	q	r	


(*) // hier komt nog wat
 $x = A[p]; i := p - 1; j := r + 1;$
while $i < j$ **do**
 $j := j - 1;$ // loop met j naar links
 while $A[j] > x$ **do**
 $j := j - 1;$
 od // tot je een waarde $A[j] \leq x$ vindt
 $i := i + 1;$ // loop met i naar rechts
 while $A[i] < x$ **do**
 $i := i + 1;$
 od // tot je een waarde $A[i] \geq x$ vindt
 if $i < j$ **then**
 wissel($A[i], A[j]$);
 fi // $A[i]$ en $A[j]$ staan nu weer in het goede stuk
od
 return j; // dit wordt dus q

1. De *basisoperatie* is het vergelijken van array-elementen:
 $A[j] > x$ en $A[i] < x$
2. Partitie stopt met $i = j$ of $i = j + 1$
3. Na afloop is altijd $j \geq p$ en $j \leq r - 1$, dus $p \leq q \leq r - 1$.
Quicksort wordt dus op echt kleinere rijtjes recursief aangeroepen
4. Elk array-element wordt precies één keer met x vergeleken, behalve $A[q]$ (twee keer) en eventueel $A[q + 1]$ (soms twee keer)
5. Partitie doet altijd $\Theta(m)$ vergelijkingen, nl. $m + 1$ of $m + 2$, met m het aantal elementen van het (deel)array $A[p], \dots, A[r]$
6. Er worden elementen verwisseld die ver uit elkaar kunnen liggen. Per vergelijking worden dus wellicht > 1 inversies opgeheven


1. Na een volledige ronde:




2. Na de j -loop:



3. Na de i -loop, vóór de verwisseling:



4. Na de verwisseling:



1. Wat gebeurt er met gelijke array-elementen?
2. Wat gebeurt er met een rijtje met allemaal verschillende elementen?
3. Stel dat we $A[i]$ en $A[i + k]$, die verkeerd om staan, verwisselen. Hoeveel inversies worden dan ten minste resp. ten hoogste opgeheven?

1. **Bad case** voor Quicksort:

Op het reeds gesorteerde rijtje (!), bijvoorbeeld $1, 2, \dots, n$, doet Quicksort $\sum_{k=3}^{n+1} k = \frac{1}{2}n(n+3) - 2 = \Theta(n^2)$ vergelijkingen.

2. **Good case** voor Quicksort (n een tweemacht):

$$\begin{cases} B(n) = 2B(\frac{n}{2}) + \Theta(n) & n > 1, 2; n = 2^k \\ B(1) = 0, B(2) = 3 \end{cases}$$

Het aantal vergelijkingen $B(n)$ is dan $\Theta(n \lg n)$. Dit komt voor als Partitie het array bij elke aanroep precies in tweeën deelt.

Dit is zelfs het beste geval voor Quicksort.

Laat $W(n)$ het aantal vergelijkingen voorstellen dat Quicksort doet in de **worst case**. Dan voldoet W aan*:

$$W(n) = \begin{cases} \max_{1 \leq q \leq n-1} (W(q) + W(n-q)) + \Theta(n) & n > 1 \\ 0 & n = 1 \end{cases}$$

Er geldt dat $W(n) \leq dn^2$ voor zekere $d > 0$, en vanaf zekere n_0 . Dus: $W(n) = O(n^2)$.

Samen met de bad case hebben we dus:

Stelling.

Quicksort doet $\Theta(n^2)$ vergelijkingen in de **worst case**

*I.p.v. $\Theta(n)$ kun je in de recurrenente betrekking ook $\leq n + 2$ zetten

De keuze van de **pivot** (spil; x dus) heeft grote invloed op de complexiteit van Quicksort. Standaard het eerste array-element ($A[p]$) als pivot kiezen is een slechte keuze.

Voeg ter verbetering op plek (*) in Partitie toe:

Kies een *slim* array-element en wissel dat met $A[p]$.

Slim kan zijn: kies een **random*** array-element.

De worst case blijft dan uiteraard $\Theta(n^2)$, maar onder de aanname dat alle $A[i]$ verschillend zijn hebben we nu:

Stelling

Quicksort doet $O(n \lg n)$ vergelijkingen in de **average case**.

*Randomized Quicksort

Partitie $(A, p, r)::$
// reorganiseert het (deel)array $A[p], \dots, A[r]$ als volgt:

```
Kies random array-element en wissel met  $A[p]$ .  
 $x = A[p]; i := p - 1; j := r + 1;$   
while  $i < j$  do  
     $j := j - 1;$  // loop met j naar links  
    while  $A[j] > x$  do  
         $j := j - 1;$   
    od // tot je een waarde  $A[j] \leq x$  vindt  
     $i := i + 1;$  // loop met i naar rechts  
    while  $A[i] < x$  do  
         $i := i + 1;$   
    od // tot je een waarde  $A[i] \geq x$  vindt  
    if  $i < j$  then  
        wissel( $A[i], A[j]$ );  
    fi //  $A[i]$  en  $A[j]$  staan nu weer in het goede stuk  
od  
return j; // dit wordt dus  $q$ 
```

Algorithm	Worst case	Average	Space usage
Insertion sort	$n^2/2$	$\Theta(n^2)$	In place
Quicksort	$n^2/2$	$\Theta(n \lg n)$	Extra space proportional to $\lg n$
Mergesort	$n \lg n$	$\Theta(n \lg n)$	Extra space proportional to n for merging
Heapsort	$2n \lg n$	$\Theta(n \lg n)$	In place
Accel. Heapsort	$n \lg n$	$\Theta(n \lg n)$	In place

Vergelijking van verschillende sorteeralgoritmen

(tijd in seconden)

n	Insertion sort $O(n^2)$	Shellsort $O(n^{7/6})$	Heapsort $O(n \lg n)$	Quicksort $O(n \lg n)$	Quicksort* $O(n \lg n)$
10	0.00044	0.00041	0.00057	0.00052	0.00046
100	0.00675	0.00171	0.00420	0.00284	0.00244
1000	0.59564	0.02927	0.05565	0.03153	0.02587
10000	58.864	0.42998	0.71650	0.36765	0.31532
100000	NA	5.7298	8.8591	4.2298	3.5882
1000000	NA	71.164	104.68	47.065	41.282

Quicksort* = optimized Quicksort

Achtste college complexiteit

18 maart 2008

Opgave 37/38 & Shellsort

- a.** Hoe werkt *Quicksort* op het rijtje 5 5 5 5 5 5 5 5 ?
Hoeveel vergelijkingen en hoeveel verwisselingen worden gedaan?
- b.** Laat $n = 2^k$. Hoeveel vergelijkingen doet Quicksort voor een rijtje van n dezelfde getallen? En hoeveel verwisselingen?
- c.** Is Quicksort stabiel?
- d.** Laat n even zijn. Hoeveel vergelijkingen doet Quicksort op het rijtje $n, n - 1, \dots, 2, 1$? En hoeveel verwisselingen? Hoeveel verwisselingen worden gedaan op het reeds gesorteerde rijtje $1, 2, \dots, n - 1, n$?

- a.** Zoals bekend doet *Quicksort* $\frac{1}{2}n(n+3) - 2 = \Theta(n^2)$ vergelijkingen op reeds gesorteerde rijtjes zoals $1, 2, 3, \dots, n$. Bekijk wat er gebeurt met het gesorteerde rijtje als nu niet steeds het eerste array-element $A[p]$ wordt gekozen als pivot, maar de mediaan van $A[p]$, $A[r]$ en $A[\lceil \frac{p+r}{2} \rceil]$.
- b.** Neem aan dat we een rijtje met n verschillende getallen hebben. Hoe wordt het rijtje opgesplitst door Partitie als de pivot X het i -de element in grootte is (van klein naar groot: het 1-e element in grootte is de kleinste, het n -de in grootte de grootste)? M.a.w. wat is de q die Partitie oplevert?

c. Laat $n = 10$. We bekijken weer de “gewone” versie van Quicksort, dus waarbij als pivot steeds het eerste array-element wordt gekozen. Hoeveel vergelijkingen doet Quicksort als Partitie om en om de slechtste en de beste splitting oplevert? Neem aan dat Partitie in elke stap $m + 1$ vergelijkingen doet voor een (deel)rijtje van m elementen. Vergelijk dit aantal met het aantal vergelijkingen dat gedaan wordt voor het gesorteerde rijtje. Idem met het aantal vergelijkingen dat Quicksort doet voor het rijtje waarbij in elke stap de (deel)rij in twee ongeveer gelijke stukken wordt verdeeld (best case). Ligt het aantal vergelijkingen dichterbij de best case of bij de worst case?

d. Maak aannemelijk dat een invoerrijtje waarbij afwisselend slecht en goed wordt gesplitst (zie **c.**) in orde van grootte evenveel vergelijkingen doet als het rijtje waarbij in elke ronde in twee gelijke delen wordt gesplitst ($\Theta(n \lg n)$ dus). Gebruik hiertoe dat in het eerste geval in twee rondes drie deelrijtjes zijn “ontstaan” van resp. 1, $\frac{m-1}{2}$ en $\frac{m-1}{2}$ (geval m is oneven) elementen, terwijl we in het tweede geval na een ronde een rijtje ter lengte $\frac{m-1}{2}$ en een rijtje ter lengte $\frac{m+1}{2}$ hebben. Hierin is m de lengte van het (deel)rijtje waarop we Quicksort (dus Partitie) loslaten.

Een en ander suggereert dat Quicksort het meestal goed ($= \Theta(n \lg n)$) doet: het gemiddelde zal “dus” rond $\Theta(n \lg n)$ liggen.

Shellsort* was een van de eerste sorteeralgoritmen met worst case complexiteit minder dan kwadratisch.

Shellsort sorteert in elke ronde deelrijtjes. In het begin **veel korte** rijtjes, waarbij de elementen uit een rijtje ver van elkaar liggen. Later **weinig lange** rijtjes, waarbij de elementen uit een rijtje dicht bij elkaar liggen. De rij wordt zo als het ware **voorgesorteerd**. In de laatste ronde wordt de rij dan als geheel gesorteerd. Shellsort sorteert met behulp van **vergelijk-verwissel / compare-exchange** (indien nodig) operaties.

*Donald Shell, 1959

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.

Shellsort gebruikt een rijtje **stapgroottes** (increments) $h_t, h_{t-1}, \dots, h_2, h_1 = 1$. De rij A met n elementen wordt gesorteerd door achtereenvolgens subrijen te sorteren van elementen die telkens op afstand h_i van elkaar liggen. Met andere woorden: A wordt **h_i -gesorteerd** voor $i = t, \dots, 1$. Aangezien $h_1 = 1$ sorteert Shellsort correct.

Merk op: bij het k -sorteren worden k deelrijtjes van elk maximaal $\lceil \frac{n}{k} \rceil$ elementen gesorteerd.

$$h_3 = 6, h_2 = 3, h_1 = 1, n = 13$$

81, 94, 11, 96, 12, 35, 17, 95, 28, 58, 41, 75, 15

↓ 6-sorteren

15, 94, 11, 58, 12, 35, 17, 95, 28, 96, 41, 75, 81

↓ 3-sorteren

15, 12, 11, 17, 41, 28, 58, 94, 35, 81, 95, 75, 96

↓ 1-sorteren

11, 12, 15, 17, 28, 35, 41, 58, 75, 81, 94, 95, 96

$$h_3 = 6, h_2 = 3, h_1 = 1, n = 13$$

81, 94, 11, 96, 12, 35, 17, 95, 28, 58, 41, 75, 15

↓ 6-sorteren

15, 94, 11, 58, 12, 35, 17, 95, 28, 96, 41, 75, 81

↓ 3-sorteren

15, 12, 11, 17, 41, 28, 58, 94, 35, 81, 95, 75, 96

↓ 1-sorteren

11, 12, 15, 17, 28, 35, 41, 58, 75, 81, 94, 95, 96

Insertion sort op het voorbeeldrijtje: 52 vergelijkingen.

Shellsort met Insertion sort: 44 vergelijkingen:

81, 94, 11, 96, 12, 35, 17, 95, 28, 58, 41, 75, 15

inversies = 41 ↓ 6-sorteren: 8 vergelijkingen

15, 94, 11, 58, 12, 35, 17, 95, 28, 96, 41, 75, 81

inversies = 25 ↓ 3-sorteren: 15 vergelijkingen

15, 12, 11, 17, 41, 28, 58, 94, 35, 81, 95, 75, 96

inversies = 11 ↓ 1-sorteren: 21 vergelijkingen

11, 12, 15, 17, 28, 35, 41, 58, 75, 81, 94, 95, 96

```
(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
(6)              // invoegen op de juiste plek
(7)              if  $temp < A[j - h]$  then
(8)                   $A[j] := A[j - h]$ ; // schuif
(9)                   $j := j - h$ ;
(10)             else
(11)                 "exit binnenste while";
(12)             fi
(13)         od
(14)          $A[j] := temp$ ; // zet neer
(15)     od
(16)     // de rij is nu  $h$ -gesorteerd
(17)      $h := h \text{ div } 2$ ; // oorspronkelijke keuze van Shell:  $h_i = \lfloor \frac{h_{i+1}}{2} \rfloor$ 
```

Regel (4) t/m (13) is Insertion sort op deelarrays.

Een zeer belangrijke eigenschap van Shellsort is de volgende (zonder bewijs).

Stelling. Als een ℓ -gesorteerd array h -gesorteerd wordt met behulp van compare-exchanges, dan blijft het ℓ -gesorteerd.

Voorbeeld met $n = 12$ en incrementrijtje 6, 4, 3, 2, 1:

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

↓ 6-sorteren

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

6-gesorteerd

↓ 4-sorteren

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

4-, 6-gesorteerd

↓ 3-sorteren

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

3-, 4-, 6-gesorteerd

↓ 2-sorteren

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

2-, 3-, 4-, 6-gesorteerd

↓ 1-sorteren

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

1-, 2-, 3-, 4-, 6-gesorteerd

De **complexiteit** van Shellsort (= aantal arrayvergelijkingen) hangt in hoge mate af van de gekozen stapgroottes. De analyse is in het algemeen extreem moeilijk en nog zeer incompleet.

1. Stapgroottes: $h_t = \lfloor \frac{n}{2} \rfloor$, $h_i = \lfloor \frac{h_{i+1}+1}{2} \rfloor$ voor $i = t-1, \dots, 1$.
Dan $t = \lfloor \lg n \rfloor$. Voor het gemak nemen we $n = 2^k$, dus $t = k$.

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

Bij het **bewijs**. Het is voldoende om een **bad case** aan te geven waarvoor het aantal vergelijkingen $\Omega(n^2)$ is.

Negende college complexiteit

25 maart 2008

Shellsort, Optimaal sorteren,
 $O(n)$ -sorteren

```
(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
(6)              // invoegen op de juiste plek
(7)              if  $temp < A[j - h]$  then
(8)                   $A[j] := A[j - h]$ ; // schuif
(9)                   $j := j - h$ ;
(10)             else
(11)                 "exit binnenste while";
(12)             fi
(13)         od
(14)          $A[j] := temp$ ; // zet neer
(15)     od
(16)     // de rij is nu  $h$ -gesorteerd
(17)      $h := h \text{ div } 2$ ; // oorspronkelijke keuze van Shell:  $h_i = \lfloor \frac{h_{i+1}}{2} \rfloor$ 
```

Regel (4) t/m (13) is Insertion sort op deelarrays.

$$h_3 = 6, h_2 = 3, h_1 = 1, n = 13$$

81, 94, 11, 96, 12, 35, 17, 95, 28, 58, 41, 75, 15

↓ 6-sorteren

15, 94, 11, 58, 12, 35, 17, 95, 28, 96, 41, 75, 81

↓ 3-sorteren

15, 12, 11, 17, 41, 28, 58, 94, 35, 81, 95, 75, 96

↓ 1-sorteren

11, 12, 15, 17, 28, 35, 41, 58, 75, 81, 94, 95, 96

Insertion sort doet hier **52** vergelijkingen;

Shellsort doet **44** vergelijkingen

De **complexiteit** van Shellsort (= aantal arrayvergelijkingen) hangt in hoge mate af van de gekozen stapgroottes. De analyse is in het algemeen extreem moeilijk en nog zeer incompleet.

1. Stapgroottes: $h_t = \lfloor \frac{n}{2} \rfloor$, $h_i = \lfloor \frac{h_{i+1}+1}{2} \rfloor$ voor $i = t-1, \dots, 1$.
Dan $t = \lfloor \lg n \rfloor$. Voor het gemak nemen we $n = 2^k$, dus $t = k$.

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

Bij het **bewijs**. Het is voldoende om een **bad case** aan te geven waarvoor het aantal vergelijkingen $\Omega(n^2)$ is.

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

Gevolg van **A** en **B**.

In de **worst case** doet Shellsort met Shells increments $\Theta(n^2)$ vergelijkingen.

2. Stapgroottes (Hibbard): $2^k - 1, 2^{k-1} - 1, \dots, 7, 3, 1$ ($k = \lfloor \lg n \rfloor$). Merk op dat opeenvolgende increments hier relatief priem zijn (volgt uit: $h_{i+1} = 2h_i + 1$).

Stelling (zonder bewijs). In de **worst case** doet Shellsort met Hibbards increments $O(n^{\frac{3}{2}})$ vergelijkingen.

3. **Het kan nog beter!**

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

Beter:

- 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 $O(n^{4/3})$.
- ...

Voor sorteeralgoritmen gebaseerd op **arrayvergelijkingen** is bewezen: het aantal vergelijkingen 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

$M(n)$ = aantal vergelijkingen dat Mergesort doet in de worst case voor een rij met n elementen.

$B(n)$ = aantal vergelijkingen 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 31.)

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

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

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 Merge-sort doet. Dus $B(n) = M(n)$.


Vraag: Kan het nog beter?

Antwoord: Ja !

Voorbeeld: 5 elementen kunnen met 7 vergelijkingen gesorteerd worden (Demuth, 1956).

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

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



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

Merge Insertion sort sorteert bijvoorbeeld:

- 21 elementen in 66 vergelijkingen (optimaal)
- 12 elementen in 30 vergelijkingen (optimaal)
- 10 elementen in 22 vergelijkingen (optimaal)

Vraag: is Merge Insertion sort optimaal?

Antwoord: nee, bijvoorbeeld $n = 47$.

Invoer: een array A met n getallen $A[1], \dots, A[n]$.

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. Pas dit idee aan voor de situatie waarin sommige waarden meer dan eens in A voorkomen.

```
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 aantal keer dat  $A[j]$  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
```

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

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

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

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

$$C = 2 \quad 2 \quad 4 \quad 7 \quad 7 \quad 8 \quad \leftarrow \text{na } 3^e \text{ for}$$

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

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

Extra geheugenruimte is ook $O(n + k)$.

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 (!! ) methode
```

```
od
```

329		720		720		329
457		455		329		355
657		355		436		436
839	→	836	→	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 ^e cijfer		2 ^e cijfer		3 ^e cijfer		

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

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

- Als sorteermethode per cijfer kunnen we **Counting sort** gebruiken, aangezien de cijfers tussen 0 en $k - 1$ zitten.
- In dat geval kost elke ronde $O(k + n)$ stappen. In totaal (d rondes) dus $O(dk + dn)$. En dat is $O(n)$ als d een constante is en $k = O(n)$.
- Een nadeel van deze methode is dat er net als bij Counting sort $O(n + k)$ extra geheugenruimte nodig is.

Tiende college complexiteit

1 april 2008

Polynomevaluatie

NP-volledigheid I

Zij $p(x) = a_n x^n + a_{n-1} x^{n-1} + \dots + a_1 x + a_0$ een **polynoom van graad $n \geq 1$** , met alle a_i reële getallen ($a_i \in \mathbb{R}$).

Probleem:

Gegeven: $a_0, a_1, \dots, a_{n-1}, a_n$ en x

Gevraagd: $p(x)$

Van links naar rechts de termen $a_i x^i$ berekenen en optellen levert een $O(n^2)$ -algoritme.

Als we het polynoom daarentegen van rechts naar links evalueren kunnen we eenvoudig een ordeverbetering bereiken.

Algoritme 1: "gewoon"

```
pol := a0 + a1 * x; // n ≥ 1
macht := x;
for i := 2 to n do
    macht := macht * x;
    // berekent x2, x3, ...
    pol := pol + ai * macht;
od
```

Basisoperatie: * en +, -

Complexiteit: aantal * = $2n - 1$
aantal +, - = n

Algoritme 2: methode van Horner

```
pol := an;  
for i := n - 1 downto 0 do  
    pol := pol * x + ai;  
od
```

Gebaseerd op:

$$p(x) = ([\dots ([a_n * x + a_{n-1}] * x + a_{n-2}) * x + \dots a_2] * x + a_1) * x + a_0$$

Complexiteit: aantal * = n
aantal +, - = n

Vraag: kan het met minder * en +, - ?

Antwoord: nee !

Algoritmen gebaseerd op het doen van vergelijkingen konden we beschrijven met **beslissingsbomen**.

Een model om rekenkundige algoritmen (algoritmen die gebaseerd zijn op $+$, $-$, $*$ en $/$) mee te beschrijven: **schema's**.

Een **schema**

- is een eindige serie stappen van de vorm $s_i := q \circ r$;
- hierin is \circ een rekenkundige operatie: $*$, $/$, $+$ of $-$
- q en r zijn **constanten** (bijvoorbeeld $1, -1, \pi^2, \dots$) of **invoerwaarden** (hier a_k 's of x) of **tussenresultaten** van eerdere stappen
- de laatste stap uit het schema berekent het **eindresultaat** (hier dus $p(x)$)

Stelling. Een schema (dat alleen $+$, $-$ en $*$ gebruikt) om $a_0 + a_1x + a_2x^2 + \dots + a_nx^n$ te berekenen moet ten minste n ($+$, $-$) stappen doen en n $*$ stappen. Het bewijs gaat met inductie naar n .

De methode van Horner berekent $p(x)$ met n vermenigvuldigingen en n optellingen ($+/ -$). Er bestaat geen algoritme dat het probleem voor algemene p en x met minder $*$'s en $+/ -$'s kan oplossen. De **methode van Horner** is derhalve **optimaal**.

Maar misschien kan het wel beter voor polynomen die een heel speciale vorm hebben.

Polynomevaluatie met **preprocessing**: bewerk het polynoom tot een polynoom in een speciale vorm waarop een nieuw evaluatie-algoritme sneller werkt.

Het polynoom

Laat $p(x) = x^n + a_{n-1}x^{n-1} + \dots + a_1x + a_0$, met $n = 2^k - 1$. $p(x)$ is dus een **monisch** polynoom, dat wil zeggen dat $a_n = 1$. We kunnen dit zonder beperking der algemeenheid aannemen.

De speciale vorm

$$p(x) = (x^j + b) * q(x) + r(x),$$

waarin q en r ook weer monisch zijn en in de speciale vorm staan, beide van graad $2^{k-1} - 1$ zijn, en $j = 2^{k-1}$.

Voorbeeld (met $n = 7$)

$$p(x) = x^7 + 6x^6 + 5x^5 + 4x^4 + 3x^3 + 2x^2 + x + 1 = \\ (x^4 + 2)[(x^2 + 4)(x + 6) + (x - 20)] + [(x^2 - 10)(x - 10) + (x - 107)]$$

Om dit polynoom in x te evalueren gebruikt Horner 7 *'s en 7 +/-'s, maar het kan met 5 *'s en 10 +/-'s.

Een gegeven monisch polynoom p van graad $n = 2^k - 1$ is eenvoudig om te zetten naar de speciale vorm.

We willen p schrijven als: $p(x) = (x^j + b) * q(x) + r(x)$ met q en r monisch, beide van graad $2^{k-1} - 1$ en $j = 2^{k-1}$. De waarde van b en de coëfficiënten van q en r zijn hieruit simpel af te lezen.

Immers: als $q(x) = x^{j-1} + q_{j-2}x^{j-2} + \dots + q_0$ en $r(x) = x^{j-1} + r_{j-2}x^{j-2} + \dots + r_0$, dan geldt:

$$b + 1 = a_{j-1}, q_l = a_{l+j}, b * q_l + r_l = a_l,$$

voor $l = 0, 1, \dots, j - 2$ en de a_i de coëfficiënten van p .

Vervolgens kunnen q en r op dezelfde manier in de speciale vorm gebracht worden, etcetera. Algoritme: zie opgave 44.

Als het polynoom p in de juiste vorm staat kan $p(x)$ als volgt geëvalueerd worden:

1. Evalueer $q(x)$ en $r(x)$ **recursief**
2. Bereken de x^j 's: nodig hiervoor zijn $x, x^2, x^4, \dots, x^{2^{k-1}}$.
Bereken deze alle van tevoren: **$k - 1$ *'s**
3. Vermenigvuldig $(x^j + b)$ met $q(x)$ en tel er $r(x)$ bij op:
 1 * en 2 $+/-$'s

Zij $M(k)$ = het aantal *'s dat gedaan wordt om een monisch polynoom (in de speciale vorm) van graad $2^k - 1$ te evalueren, zonder de berekening van de x^j mee te tellen.

Dan voldoet $M(k)$ aan de volgende **recurrente betrekking**:

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

Oplossing: $M(k) = 2^{k-1} - 1 \longrightarrow \frac{n-1}{2}$



Zij $A(k)$ = het aantal +/-'s dat gedaan wordt om een monisch polynoom (in de speciale vorm) van graad $2^k - 1$ te evalueren.

Dan voldoet $A(k)$ aan de volgende **recurrente betrekking**:

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

Oplossing: $A(k) = 3 * 2^{k-1} - 2 \longrightarrow \frac{3n-1}{2}$

Koningsberger bruggenprobleem:



Kun je een wandeling door de stad maken waarbij je elke brug precies één keer beloopt en je weer terugkeert in het beginpunt?




Leonard Euler, 1736

Gegeven een samenhangende, ongerichte graaf $\mathcal{G} = (V, E)$.

Definitie: een **kring*** in \mathcal{G} die **alle takken** van \mathcal{G} bevat heet een **Eulerkring**.

* Een kring bestaat per definitie uit allemaal **verschillende takken**.

Voorbeeld:



Voor deze graaf is **1 2 3 4 5 3 7 5 6 7 2 6 1**
een Eulerkring.

Eulerkringprobleem. Gegeven een samenhangende onge-richte graaf $\mathcal{G} = (V, E)$. Heeft \mathcal{G} een Eulerkring?

Dit is een voorbeeld van een **beslissingsprobleem**: het antwoord is ja of nee.

Stelling

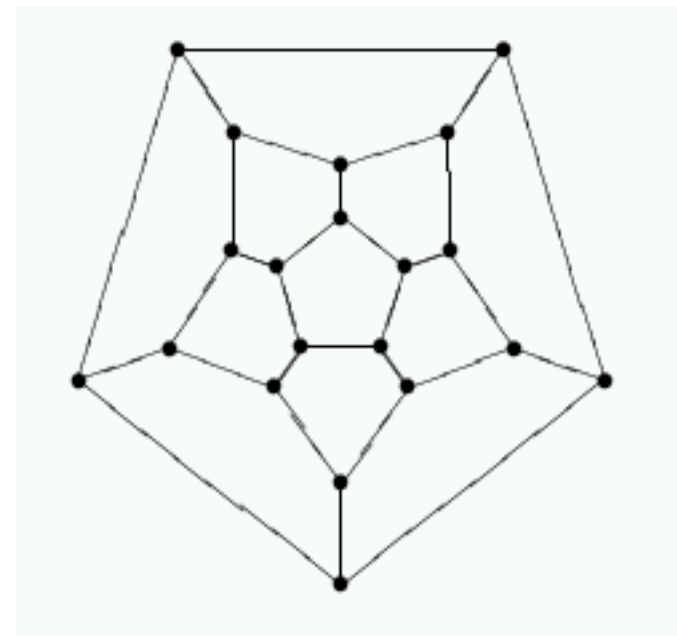

Een samenhangende ongerichte graaf heeft een Eulerkring \iff de graad van iedere knoop is even.

Het is dus heel gemakkelijk (=polynomiaal) na te gaan of een graaf een Eulerkring heeft: $O(|E|)$.

Opmerking

Het bewijs van “ \iff ” is constructief: het geeft je meteen een (overigens $O(|E| + |V|)$) algoritme om een Eulerkring te vinden.

Kun je een wandeling door de graaf rechtsonder maken waarbij elke knoop precies één keer bezocht wordt en je weer in het startpunt eindigt?



Sir William Rowan Hamilton, 1859


Gegeven een ongerichte (of gerichte) graaf $\mathcal{G} = (V, E)$.

Definitie: een **Hamiltonkring** in \mathcal{G} is een **kring** die **elke knoop** precies **één keer** bevat.


Bijbehorend **beslissingsprobleem**: **Hamiltonkringprobleem** (HC) voor ongerichte grafen. Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$. Heeft \mathcal{G} een Hamiltonkring?

Naamgeving: Als een graaf \mathcal{G} een Hamiltonkring heeft spreken we van een ja-instantie van het probleem. Als zo'n kring niet bestaat is \mathcal{G} een nee-instantie.

* analoog voor gerichte grafen

Voorbeeld 1:

Deze graaf heeft een Hamiltonkring, namelijk: 1, 2, 3, 4, 5, 6, 7, 8

Voorbeeld 2:

Deze graaf heeft geen Hamiltonkring, maar wel een Hamiltonpad, namelijk: 1, 2, 3, 4, 5, 6, 7, 8

.

1. Een exponentieel algoritme is snel gevonden.
2. Er is geen polynomiaal algoritme voor dit probleem bekend.
3. Er is ook niet bewezen dat een exponentieel algoritme nodig is.
4. Als \mathcal{G} een Hamiltonkring heeft is er een makkelijke (=polynomiaal) manier om dat aan te tonen (certificaat*).
5. De enige manier om te laten zien dat \mathcal{G} geen Hamiltonkring bevat lijkt te zijn: som alle $n!^\dagger$ kandidaat Hamiltonkringen op en laat zien dat ze geen Hamiltonkring zijn.

* voor dit probleem: certificaat = Hamiltonkring

$^\dagger n = |V| =$ aantal knopen van \mathcal{G}

Complexiteit 2007/10 **Handelbaar/onhandelbaar -1-**

N	10	50	100	300	1000
$\log_2 N$	3	5	6	8	9
$5N$	50	250	500	1500	5000
$N \cdot \log_2 N$	33	282	665	2469	9966
N^2	100	2500	10.000	90.000	7 cijfers
N^3	1000	125.000	7 cijfers	8 cijfers	10 cijfers
2^N	1024	16 cijfers	31 cijfers	91 cijfers	302 cijfers
$N!$	7 cijfers	65 cijfers	161 cijfers	623 cijfers	onvoorstelbaar
N^N	11 cijfers	85 cijfers	201 cijfers	744 cijfers	onvoorstelbaar

Ter vergelijking:

het aantal protonen in het heelal is een getal met 79 cijfers

het aantal microseconden sinds de Oerknal heeft 24 cijfers

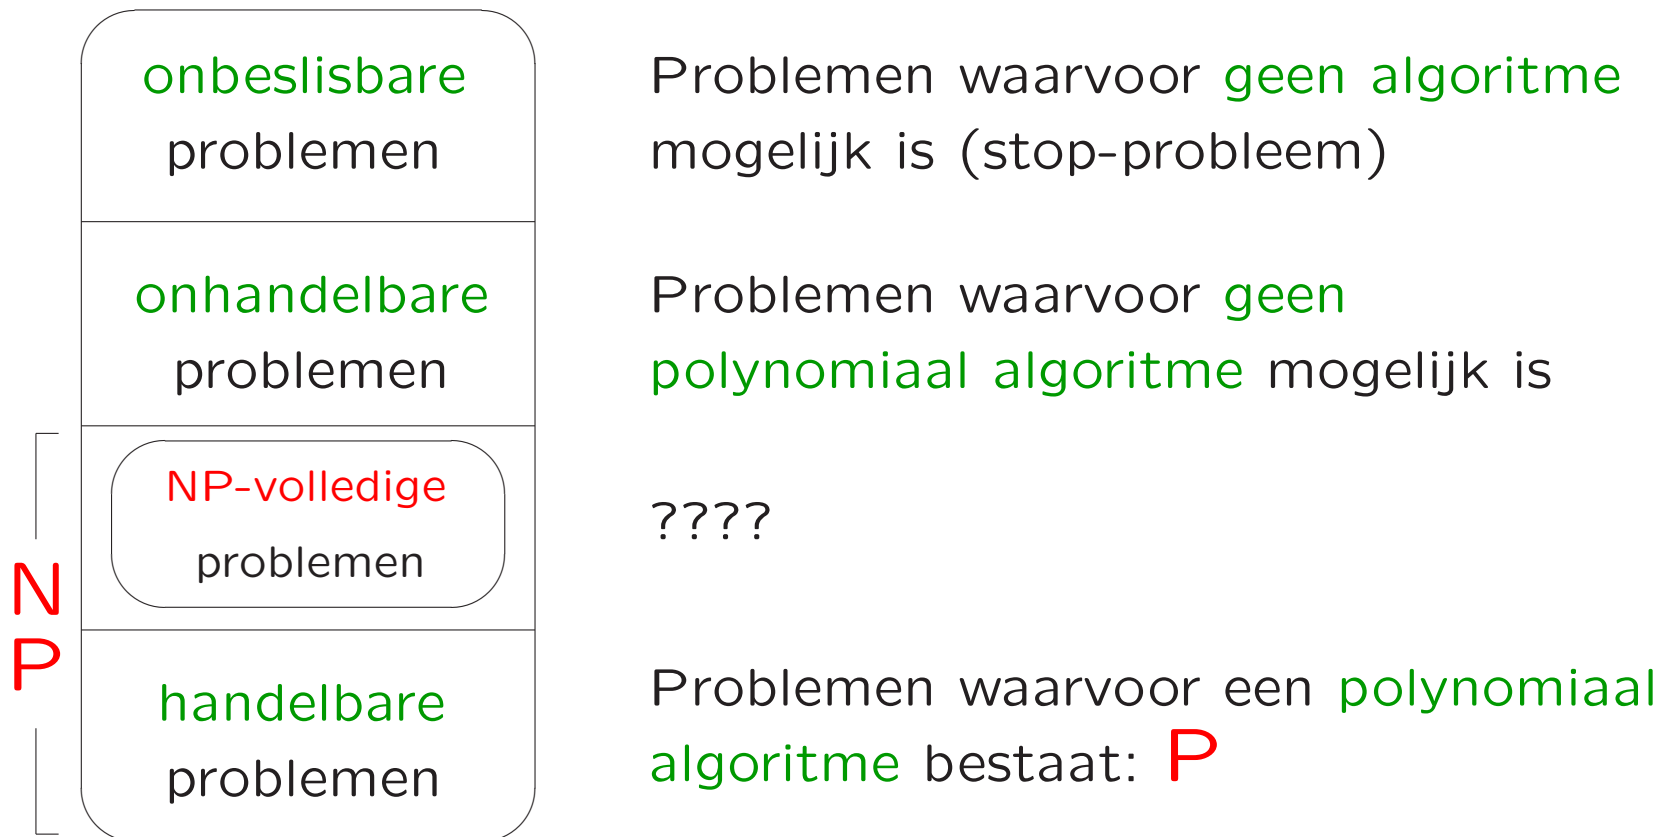
Complexiteit 2007/10 **Handelbaar/onhandelbaar -2-**

Stel dat de computer 1 instructie doet per microseconde (10^{-6} sec).

N	10	20	50	100	300
N^2	$\frac{1}{10000}$ sec	$\frac{1}{2500}$ sec	$\frac{1}{400}$ sec	$\frac{1}{100}$ sec	$\frac{9}{100}$ sec
N^5	$\frac{1}{10}$ sec	3,2 sec	5,2 min	2,8 uur	28,1 dag
2^N	$\frac{1}{1000}$ sec	1 sec	35,7 jaar	400 biljoen eeuwen	75-cijfers veel eeuwen
N^N	2,8 uur	3,3 biljoen jaar	70-cijfers veel eeuwen	185-cijfers veel eeuwen	728-cijfers veel eeuwen

Ter vergelijking: de oerknal was ongeveer 15 miljard jaar geleden.


Problemen kunnen als volgt in klassen worden ingedeeld:



De klasse van **NP-volledige problemen** \mathcal{NPC} (ook wel: NP-complete problemen), heeft enkele interessante eigenschappen, zoals:

1. Voor geen enkel NP-volledig probleem is tot dusver een polynomiaal algoritme gevonden. Men vermoedt dat ze onhandelbaar zijn, maar dat heeft tot dusver ook nog niemand kunnen bewijzen
2. Als er een polynomiaal algoritme bestaat voor willekeurig welk NP-volledig probleem, dan is meteen **elk** NP-volledig probleem in polynomiale tijd oplosbaar. Omgekeerd: als er van één enkel NP-volledig probleem bewezen wordt dat het onhandelbaar is, dan zijn **alle** NP-volledige problemen onhandelbaar.

Uit de theorie van NP-volledigheid:



NP
Nondeterministic
Polynomial

$P = NP ???$

Plaatje

Open vraag

De theorie van NP-volledigheid beperkt zich tot **beslissingsproblemen**. Bij een beslissingsprobleem zijn slechts twee antwoorden mogelijk: **ja** of **nee**.

Probleeminvoer waarop het antwoord *ja* is noemen we **ja-instanties**, als het antwoord *nee* is spreken we van **nee-instanties**.

Optimalisatieproblemen worden omgezet naar beslissingsproblemen, en wel zo dat geldt: als het optimalisatieprobleem handelbaar is, dan is het corresponderende beslissingsprobleem dat ook. En dus ook omgekeerd: **als het beslissingsprobleem onhandelbaar is, dan is het corresponderende optimalisatieprobleem dat ook**.

Handelsreizigersprobleem of Travelling Salesperson Problem

Optimalisatieprobleem

Gegeven een volledige*, ongerichte graaf $\mathcal{G} = (V, E)$ met gewichten op de takken. Geef een Hamiltonkring in \mathcal{G} met minimaal totaalgewicht.

Beslissingsprobleem TSP


Gegeven een volledige*, ongerichte graaf $\mathcal{G} = (V, E)$ met gewichten op de takken, en een geheel getal $k \geq 0$. Bestaat er in \mathcal{G} een Hamiltonkring met totaalgewicht $\leq k$?

* tussen elk tweetal knopen van \mathcal{G} zit een tak.

Voorbeeld.

Een Hamiltonkring in onderstaande graaf is bijvoorbeeld 1, 2, 3, 4. Deze heeft totaalgewicht 14.

De Hamiltonkring met minimaal gewicht is 2, 4, 3, 1. Deze heeft totaalgewicht 7.

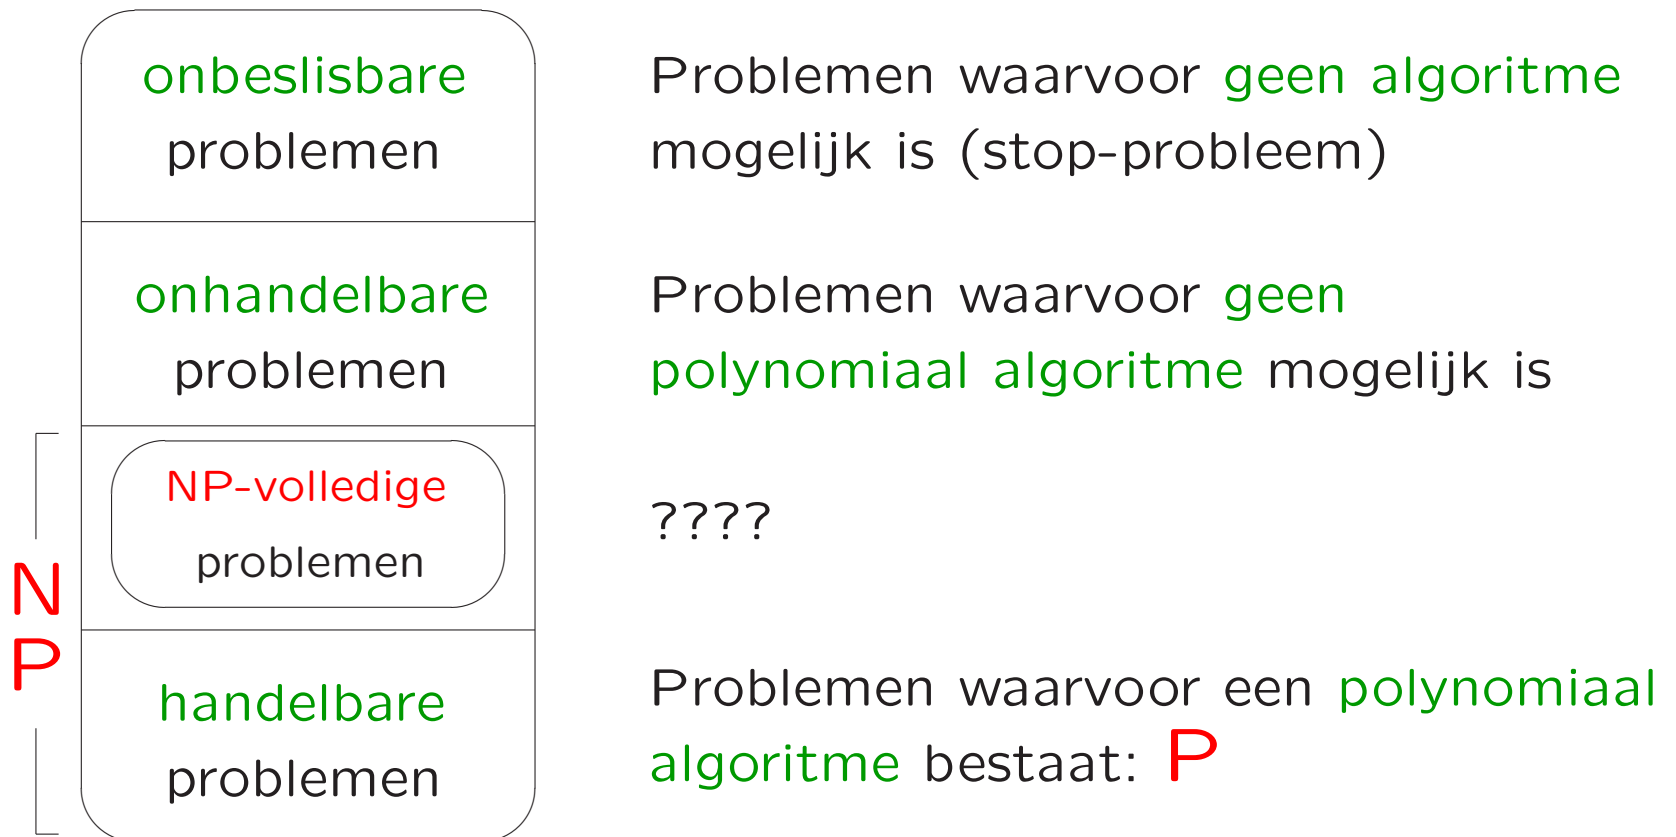


Elfde college complexiteit

8 april 2008

NP-volledigheid II

Problemen kunnen als volgt in klassen worden ingedeeld:



De klasse van **NP-volledige problemen** \mathcal{NPC} (ook wel: NP-complete problemen), heeft enkele interessante eigenschappen, zoals:

1. Voor geen enkel NP-volledig probleem is tot dusver een polynomiaal algoritme gevonden. Men vermoedt dat ze onhandelbaar zijn, maar dat heeft tot dusver ook nog niemand kunnen bewijzen.
2. Als er een polynomiaal algoritme bestaat voor willekeurig welk NP-volledig probleem, dan is meteen **elk** NP-volledig probleem in polynomiale tijd oplosbaar. Omgekeerd: als er van één enkel NP-volledig probleem bewezen wordt dat het onhandelbaar is, dan zijn **alle** NP-volledige problemen onhandelbaar.

De theorie van NP-volledigheid beperkt zich tot **beslissingsproblemen**. Bij een beslissingsprobleem zijn slechts twee antwoorden mogelijk: **ja** of **nee**.

Probleeminvoer waarop het antwoord *ja* is noemen we **ja-instanties**, als het antwoord *nee* is spreken we van **nee-instanties**.

Optimalisatieproblemen worden omgezet naar beslissingsproblemen, en wel zo dat geldt: als het optimalisatieprobleem handelbaar is, dan is het corresponderende beslissingsprobleem dat ook. En dus ook omgekeerd: **als het beslissingsprobleem onhandelbaar is, dan is het corresponderende optimalisatieprobleem dat ook**.

- Een **literal** is een Boolese variabele of de negatie daarvan (dus x of $\neg x$).
- Een **clause (clausule)** is een disjunctie (\vee) van literals. Voorbeeld: $x_1 \vee \neg x_3 \vee x_4 \vee \neg x_6$.
- Een logische formule ϕ staat in **CNF (conjunctieve normaalvorm)** als hij bestaat uit een conjunctie (\wedge) van clauses. Voorbeeld: $\phi = (x_1 \vee x_2) \wedge (x_1 \vee \neg x_2 \vee \neg x_3) \wedge \neg x_1$.
- Een **waardering** (waarheidstoekenning) van een verzameling logische variabelen is een toekenning van de waarde True of False aan elk van de logische variabelen uit die verzameling.

Beslissingsprobleem SAT

Gegeven een logische formule ϕ in CNF. Bestaat er een waardering van de in ϕ voorkomende logische variabelen zodat ϕ de waarde True krijgt (dus een waardering die ϕ waar maakt)?

Voorbeeld.

De waardering w met $w(x_1) = \text{False}$, $w(x_2) = \text{True}$ en $w(x_3) = \text{False}$ maakt de logische formule $\phi = (x_1 \vee x_2) \wedge (x_1 \vee \neg x_2 \vee \neg x_3) \wedge \neg x_1$ waar.

Deze ϕ is dus een ja-instantie voor SAT.

Beslissingsprobleem SUM

Gegeven een getal $t \in \mathbb{N}$ en een eindige verzameling $S \subset \mathbb{N}$.
Bestaat er een deelverzameling $S' \subseteq S$ met $\sum_{s \in S'} s = t$?

Voorbeeld.


Neem $S = \{1, 4, 16, 64, 256, 1040, 1093, 1284, 1344\}$ en $t = 3754$, dan is dit een ja-instantie voor het probleem. Immers $S' = \{1, 16, 64, 256, 1040, 1093, 1344\}$ voldoet.

Een Hamiltonkring in een ongerichte (of gerichte) graaf is een kring die **elke** knoop precies **één** keer bevat.

Beslissingsprobleem HC

Gegeven een graaf $\mathcal{G} = (V, E)$. Heeft \mathcal{G} een Hamiltonkring?

Voorbeeld.



Nevenstaande graaf is een nee-instantie voor HC.

Handelsreizigersprobleem of Travelling Salesperson Problem

Optimalisatieprobleem

Gegeven een volledige*, ongerichte graaf $\mathcal{G} = (V, E)$ met gewichten op de takken. Geef een Hamiltonkring in \mathcal{G} met minimaal totaalgewicht.

Beslissingsprobleem TSP


Gegeven een volledige*, ongerichte graaf $\mathcal{G} = (V, E)$ met gewichten op de takken, en een geheel getal $k \geq 0$. Bestaat er in \mathcal{G} een Hamiltonkring met totaalgewicht $\leq k$?

* tussen elk tweetal knopen van \mathcal{G} zit een tak.

Voorbeeld.

Een Hamiltonkring in onderstaande graaf is bijvoorbeeld 1, 2, 3, 4. Deze heeft totaalgewicht 14.

De Hamiltonkring met minimaal gewicht is 2, 4, 3, 1. Deze heeft totaalgewicht 7.



Een **kliek** in een ongerichte graaf $\mathcal{G} = (V, E)$ is een deelverzameling $V' \subseteq V$ zodanig dat voor elk tweetal knopen $u, v \in V'$ ($u \neq v$) geldt dat $(u, v) \in E$. Met andere woorden: tussen elk tweetal knopen uit V' zit een tak. De grootte van de kliek is het aantal knopen van die kliek.

Optimalisatieprobleem

Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$. Geef een kliek met zo veel mogelijk knopen (een maximale kliek).

Beslissingsprobleem Kliek


Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$ en een geheel getal k ($0 \leq k \leq |V|$). Bestaat er in \mathcal{G} een kliek ter grootte ten minste k ?

Opmerking.

Het is equivalent om te vragen naar een kliek ter grootte gelijk aan k . Immers elke deelverzameling van een kliek is weer een kliek.

Voorbeeld.

In onderstaande graaf is $\{1, 4, 6\}$ een kliek ter grootte 3. Een maximale kliek in deze graaf is er een ter grootte 4: $\{1, 2, 3, 4\}$.



Een **kleuring** van (de knopen van) een ongerichte graaf $\mathcal{G} = (V, E)$ is een afbeelding $c : V \rightarrow S$, waarin S een eindige verzameling (van kleuren) is, en wel zó dat als $(v, w) \in E$ dan $c(v) \neq c(w)$. Met andere woorden: aangrenzende knopen hebben niet dezelfde kleur.

Optimalisatieprobleem

Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$. Vind een kleuring van \mathcal{G} met zo weinig mogelijk kleuren.

Beslissingsprobleem Kleur

Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$ en een geheel getal $k > 0$. Bestaat er een kleuring van \mathcal{G} die hooguit k kleuren gebruikt (ofwel, is \mathcal{G} k -kleurbaar) ?


Opmerking.

Het is equivalent om te vragen naar een kleuring met precies k kleuren.

Voorbeeld.

Onderstaande graaf kan met 4 kleuren gekleurd worden, maar niet met minder dan 4 (waarom niet?).

Kleur bijvoorbeeld 1 en 5 rood, 2 blauw, 3 geel en 4 groen.



1. Voor alle zes voorbeeldproblemen is eenvoudig een **exponentieel algoritme** op te schrijven.
2. In alle gevallen kan in **polynomiale tijd gecontroleerd worden** of een kandidaatoplossing een echte oplossing is.
3. Voor al deze problemen geldt: het lijkt extreem moeilijk (exponentieel) om voor gegeven invoer x te bepalen of het antwoord “ja” of “nee” moet zijn.
4. Echter, *als* x een **ja-instantie** is, dan is er een eenvoudige (polynomiale) manier om iemand daarvan te overtuigen.

5. Voor **ja-instanties** bestaat er een zogenaamd **certificaat** (in de voorbeelden steeds een voorgestelde oplossing, maar dit zou iets anders kunnen zijn) dat gebruikt kan worden om te laten zien dat het antwoord inderdaad “ja” is.
6. Bovendien is dit certificaat **kort** (polynomiaal).
7. Eigenschap 2 t/m 6 betekenen dat de genoemde problemen in **NP** zitten. Later wordt alles wat formeler gemaakt.
8. Ja-instanties zijn eenvoudig te verifiëren met de juiste hint (certificaat). Hoe zit het met nee-instanties?

Definitie.

Een **algoritme** heet **polynomiaal begrensd** als zijn worst case complexiteit van boven begrensd is door een functie die polynomiaal is in de lengte van de invoer.

Dus: worst case is $O(p(n))$ voor een zeker polynoom p , en met n (een maat voor) de lengte van de invoer.

Definitie

Een **probleem** heet **polynomiaal begrensd** als er een polynomiaal begrensd algoritme voor bestaat.

Definitie

De klasse van **beslissingsproblemen** die **polynomiaal begrensd** zijn noteren we als \mathcal{P} .

Vraag: waarom handelbaar = polynomiaal begrensd?

- als een probleem niet in \mathcal{P} zit is het zeker onhandelbaar
- de klasse \mathcal{P} heeft mooie afsluitingseigenschappen: een algoritme dat bestaat uit een eindige opeenvolging van polynomiaal begrensde algoritmen is zelf ook weer polynomiaal begrensd (zie opgaven)
- de klasse \mathcal{P} is onafhankelijk van het berekeningsmodel en van gebruikte coderingen: als een probleem polynomiaal begrensd is in het ene model, dan ook in een ander model

Vraag: wat is eigenlijk de **lengte van de invoer**?

Voorbeeldprobleem

Gegeven een geheel getal $n > 0$. Heeft n echte delers, met andere woorden, is $n = a * b$ voor zekere $a, b > 1$?

Algoritme:

```
// gewoon alle mogelijke delers proberen
gevonden := False;
m := 2;
while not gevonden and m < n do
    if n % m = 0 then
        gevonden := True;
    else
        m := m + 1;
    fi
od
// m is nu de kleinste deler van n
```

De worst case complexiteit van dit algoritme is $O(n)$ (indien we de berekening van $n \% m$ voor 1 stap tellen, anders $O(n^2)$).

De lengte van de invoer is het aantal karakters van de codering, in dit geval van het getal n . Als we de **unaire codering** gebruiken is het algoritme dus **lineair** in de lengte van de invoer. Nemen we de **binaire codering**, of in het algemeen de l -aire codering met $l > 1$, dan is het algoritme **exponentieel** in de lengte van de invoer (voor elke $l > 1$ dus).

Vraag: is het algoritme nu polynomiaal of exponentieel?

Knapzakprobleem

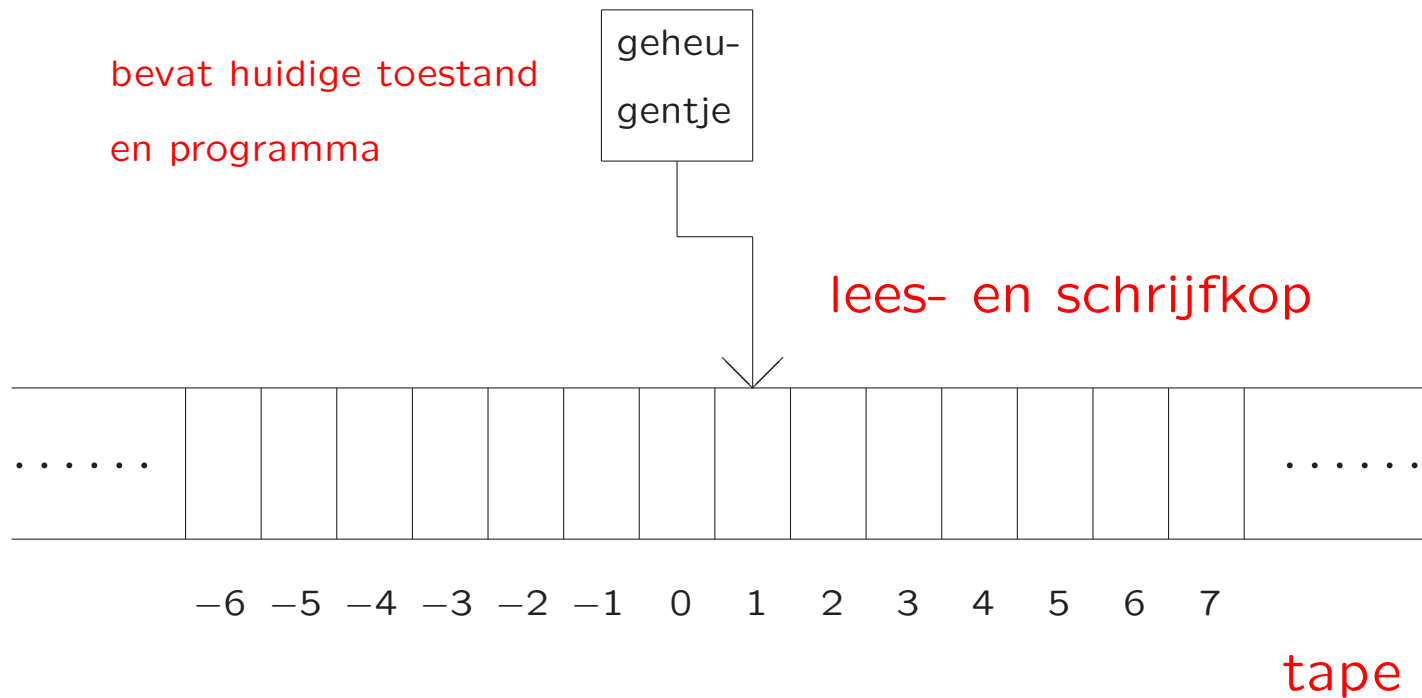
Gegeven een knapzak met capaciteit S (een geheel getal > 0) en n objecten met gewicht s_1, s_2, \dots, s_n en met waarde w_1, w_2, \dots, w_n . (Alle s_i en w_i zijn geheel en > 0 .)

Gevraagd een deelverzameling van de objecten met totaalgewicht $\leq S$ en maximale totaalwaarde.

Het knapzakprobleem kan worden opgelost met een algoritme met complexiteit $O(n * S)$ (dynamisch programmeren, zie Algoritmiek).

Dit is niet polynomiaal, maar **exponentieel** als functie van de lengte van de invoer !

Deterministische one-tape Turing machine (DMT)



Een DTM-programma bevat:

- Γ : een eindige verzameling **tape-symbolen** (inputsymbolen Σ en blanco). Voorbeeld: $\Gamma = \{0, 1, b\}$.
- Q : een eindige verzameling **toestanden**, waaronder een begintoestand q_0 en twee eindtoestanden q_Y en q_N . Voorbeeld: $Q = \{q_0, q_1, q_2, q_3, q_Y, q_N\}$.
- $\delta : Q - \{q_Y, q_N\} \times \Gamma \longrightarrow Q \times \Gamma \times \{-1, 0, 1\}$ een **transitie-functie** die bepaalt wat er gebeurt als in een bepaalde toestand een bepaald karakter wordt gelezen.


In de begintoestand staat de invoerstring x op plek 1 t/m $|x|$ en de rest van de tape is blanco. Het programma start in toestand q_0 met de lees- en schrijfkop op positie 1 en stopt als de toestand q_y (yes) of q_N (no) bereikt wordt.


$$\Gamma = \{0, 1, b\}, \Sigma = \{0, 1\}$$


$$Q = \{q_0, q_1, q_2, q_3, q_Y, q_N\}$$

q	0	1	b
q_0	$(q_0, 0, +1)$	$(q_0, 1, +1)$	$(q_1, b, -1)$
q_1	$(q_2, b, -1)$	$(q_3, b, -1)$	$(q_N, b, -1)$
q_2	$(q_Y, b, -1)$	$(q_N, b, -1)$	$(q_N, b, -1)$
q_3	$(q_N, b, -1)$	$(q_N, b, -1)$	$(q_N, b, -1)$

$$\delta(q, s)$$







Vraag: welk beslissingsprobleem lost dit programma op?

Een **certificaat** kun je gebruiken om aan te tonen dat een ja-instantie van een probleem inderdaad een ja-instantie is.

Veel beslissingsproblemen zijn geformuleerd als “er-is-een”-vragen. In dat geval kun je bij een certificaat denken aan een **kandidaat-oplossing (voorgestelde oplossing)** van het probleem. Daarvan moet dan onder andere geverifieerd worden dat hij aan de criteria van het probleem voldoet, dus een *echte* oplossing is.

Probleem

Certificaat

HC

Hamiltonkring

SAT

waarmakende waardering

Kliek

kliek met k knopen

Kleur

kleuring met $\leq k$ kleuren

Subset Sum

deelverzameling met som = t

TSP

Hamiltonkring met totaalgewicht
 $\leq k$

Een **niet-deterministisch algoritme** bestaat uit 3 fasen:

1. Niet-deterministische **gokfase**

Er wordt een willekeurige string s in het geheugen geschreven. Elke keer dat het algoritme executeert kan dit een andere string zijn.

// deze string is het **certificaat**, het is een soort **gok**

// **van de oplossing** van het probleem;

// s kan echter ook een onzinstring zijn.

2. Deterministische **verificatiefase**

Zowel de invoer van het probleem als de string s mogen hier gebruikt worden. Er wordt True of False geretourneerd of het programma gaat in een oneindige loop en stopt nooit.

```
// hier wordt gecontroleerd of  $s$  een oplossing van het  
// probleem is bij de gegeven invoer, m.a.w. er wordt  
// gecontroleerd of  $s$  een ja-antwoord rechtvaardigt.
```

3. Uitvoerstep

Als fase 2 True retourneert geeft het algoritme antwoord “ja”. Anders is er geen uitvoer.

Het aantal stappen dat een niet-deterministisch algoritme doet is het aantal stappen nodig om s te schrijven (dus het aantal karakters waaruit s bestaat) + het aantal stappen dat gedaan wordt in de verificatiefase (+1 voor fase 3).

Definitie

Het antwoord van een niet-deterministisch algoritme A voor invoer x is “ja” \iff er is een executie* van A die “ja” als uitvoer geeft.

Het antwoord van A is “nee” als er voor geen enkele executie, dus voor geen enkele string s , een uitvoer is.

Er geldt dus: het antwoord van een niet-deterministisch algoritme A voor invoer x is “ja” \iff er bestaat een string s (certificaat) waarmee je kunt aantonen dat x een ja-instantie is.

* dus een string s

Definitie

Een niet-deterministisch algoritme heet **polynomiaal begrensd** als er een polynoom p bestaat zodat voor elke invoer x ter grootte n (dus $n = |x|$) *waarvoor het antwoord "ja" is*, er een executie van het algoritme is die "ja" oplevert in hooguit $p(n)$ stappen.

Dientengevolge mag de string s in dat geval niet te lang zijn (polynomiaal in $|x|$), en het verificatie-algoritme uit fase 2 moet polynomiaal begrensd zijn in $|x|$ (en $|s|$).

Definitie

\mathcal{NP} is de klasse van beslissingsproblemen waarvoor er een polynomiaal begrensd niet-deterministisch algoritme bestaat.

\mathcal{NP} betekent: **Non-deterministic Polynomial time**.

Twaalfde college complexiteit

14/15 april 2008

NP-volledigheid III

Definitie.

Een **algoritme** heet **polynomiaal begrensd** als zijn worst case complexiteit van boven begrensd is door een functie die polynomiaal is in de lengte van de invoer.

Dus: worst case is $O(|x|^k)$ met $k \geq 0$ en met $|x|$ de lengte van de invoer x (of $O(n^k)$ met n een maat voor de lengte van de invoer).

Definitie

Een **probleem** heet **polynomiaal begrensd** als er een polynomiaal begrensd algoritme voor bestaat.

Definitie

De klasse van **beslissingsproblemen** die **polynomiaal begrensd** zijn noteren we als \mathcal{P} .

Een **niet-deterministisch algoritme** bestaat uit 3 fasen:

1. Niet-deterministische **gokfase**

Er wordt een willekeurige string s in het geheugen geschreven. Elke keer dat het algoritme executeert kan dit een andere string zijn.

// deze string is (hopelijk) het **certificaat**, het is een

// soort **gok van de oplossing** van het probleem;

// s kan echter ook een onzinstring zijn.

2. Deterministische **verificatiefase**

Zowel de invoer van het probleem als de string s mogen hier gebruikt worden. Er wordt True of False geretourneerd of het programma gaat in een oneindige loop en stopt nooit.

```
// hier wordt gecontroleerd of  $s$  een oplossing van het  
// probleem is bij de gegeven invoer, m.a.w. er wordt  
// gecontroleerd of  $s$  een ja-antwoord rechtvaardigt.
```

3. Uitvoerstep

Als fase 2 True retourneert geeft het algoritme als antwoord “ja”. Anders is er geen uitvoer.

Het aantal stappen dat een niet-deterministisch algoritme doet is het aantal stappen nodig om s te schrijven (dus het aantal karakters waaruit s bestaat) + het aantal stappen dat gedaan wordt in de verificatiefase (+1 voor fase 3).

Een niet-deterministisch algoritme A antwoordt “ja” op invoer $x \iff$ er bestaat **een executie** (dus een string s) van A op x die “ja” als uitvoer geeft. De invoer x is dan een ja-instantie. Als er geen ja-executie bestaat is het antwoord “nee” (x is dan een nee-instantie).

A is **polynomiaal (begrensd)** als er een ja-executie bestaat* die polynomiaal is in $|x|$. Dit is het geval als voor zo'n ja-executie $|s| = O(|x|^l)$ en Fase 2 polynomiaal is in $|x|$ en $|s|$ (dus $O(|x|^k \cdot |s|^m)$).

\mathcal{NP} is de klasse van beslissingsproblemen waarvoor er een polynomiaal begrensd niet-deterministisch algoritme bestaat. \mathcal{NP} betekent: **Non-deterministic Polynomial time**.

*die kan dus alleen bestaan voor ja-instanties

Stelling. Alle zes voorbeeldproblemen zitten in \mathcal{NP} .

Voorbeeld 1: Kleur

Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$ en een geheel getal $k > 0$. Bestaat er een kleuring van \mathcal{G} die precies k kleuren gebruikt (ofwel, is \mathcal{G} k -kleurbaar)?

Probleeminvoer: $x = \langle \mathcal{G}, k \rangle$.

Voorbeeld 2: HC

Gegeven een (gerichte of ongerichte) graaf \mathcal{G} . Vraag: heeft deze graaf een Hamiltonkring? Probleeminvoer: $x = \mathcal{G}$.

Laat hierna $V = \{1, 2, \dots, n\}$ en dus $|V| = n$.

Voorbeeld 3: SAT

Gegeven een logische formule ϕ in CNF. Bestaat er een waardering van de in ϕ voorkomende logische variabelen die ϕ waar maakt? Probleeminvoer: $x = \phi$.

Een polynomiaal begrensd *niet-deterministisch algoritme* voor HC:

1. **Fase 1 (gokfase)**

Er wordt een string s gegenereerd, hierna te interpreteren als een rij gehele getallen.

2. **Fase 2 (verificatiefase)**

Er wordt gecontroleerd of s een Hamiltonkring voorstelt:

(1) controleer dat er precies n integers staan: $O(|s|)$

(2) controleer dat elke integer tussen 1 en n is: $O(|s|)$

(3) controleer dat alle knopen uit s verschillend zijn:
 $O(|s|^2)$

- (4) controleer dat tussen opeenvolgende knopen uit s een tak zit in de graaf (en tussen de laatste en de eerste): $O(|s| \cdot |E|) = O(|s| \cdot |\mathcal{G}|)$.

Als de vier tests positief zijn wordt True geretourneerd, anders False (of er wordt in een oneindige loop gegaan).

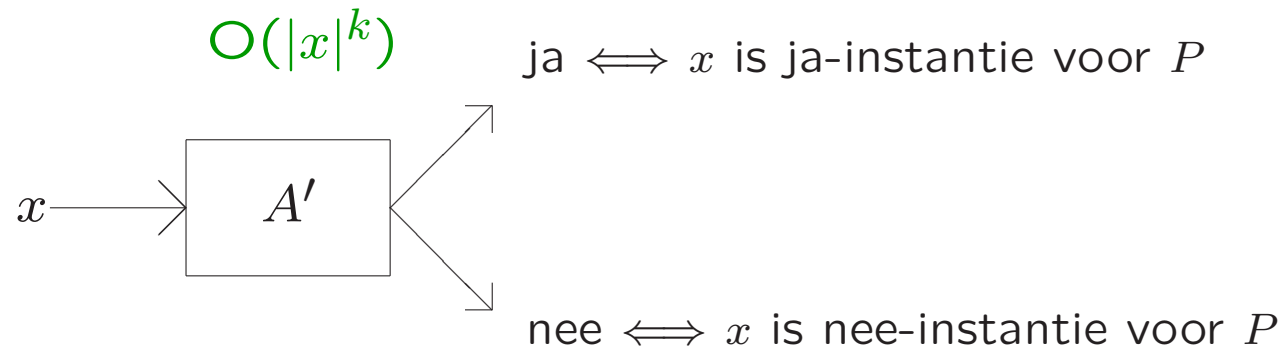
3. Fase 3 (uitvoerfase)

Als fase 2 True oplevert wordt “ja” uitgevoerd, anders geen uitvoer.


Merk op:

Stap (1) t/m (3) controleert dat s een rij van n verschillende knopen van \mathcal{G} voorstelt (soort syntactische controle), stap (4) controleert dat het een Hamiltonkring is.

Neem een willekeurig probleem $P \in \mathcal{P}$. Dan is er een polynomiaal **deterministisch** algoritme A' dat P oplost.



Het volgende **niet-deterministische** algoritme A is dan een **polynomiaal** begrensd algoritme voor P .



fase 1: genereer s ;

fase 2: negeer de string s en voer A' uit op x ;

fase 3:

Laat $V = \{1, 2, \dots, n\}$, en de mogelijke kleuren $1, 2, \dots, k$. Een polynomiaal begrensd *niet-deterministisch algoritme* voor Kleur is:

1. **Fase 1 (gokfase)**

Er wordt een string s gegenereerd, hierna te interpreteren als een rij gehele getallen.

2. **Fase 2 (verificatiefase)**

Er wordt gecontroleerd of s een goede kleuring voorstelt (s_i de kleur van knoop i):

- (1) controleer dat er precies n integers staan (elke knoop een kleur): kan polynomiaal, $O(|s|)$
- (2) controleer dat elke integer tussen 1 en k is (er worden k kleuren gebruikt): kan polynomiaal, $O(|s|)$
- (3) controleer dat aangrenzende knopen verschillend gekleurd zijn. Takken (v, w) aflopen en in s de kleur van v en w opzoeken en vergelijken: $O(|E| \cdot |s|) = O(|\mathcal{G}| \cdot |s|)$.

Als de vier tests positief zijn wordt True geretourneerd, zodra een test negatief uitvalt wordt False teruggegeven (of er wordt in een oneindige loop gegaan).

3. **Fase 3 (uitvoerfase)**

Als fase 2 True oplevert wordt “ja” uitgevoerd, anders geen uitvoer.


Merk op. Stap (1) t/m (2) controleert dat s een kleuring van de knopen voorstelt stap (3) controleert dat het een correcte kleuring is.

Er geldt: $\langle \mathcal{G}, k \rangle$ is een ja-instantie voor Kleur \iff er bestaat een goede kleuring van de knopen \iff er bestaat een goede string s waarop Fase 2 True oplevert \iff het antwoord van A op invoer $x = \langle \mathcal{G}, k \rangle$ is “ja”.

Verder: voor een ja-executie, dus met s een goede kleuring, is $|s| = O(|V|) = O(|x|)$. Ergo: A is polynomiaal begrensd.

Zij T een functie van de invoerverzameling I van een beslissingsprobleem P naar de invoerverzameling I' van een beslissingsprobleem Q .

T beeldt dus elke $x \in I$ af op een $T(x) \in I'$.



Definitie T heet een **polynomiale reductie** (of **polynomiale transformatie**) van P naar Q als de volgende drie punten gelden:

1. T kan berekend worden in polynomiaal begrensde tijd (als functie van $|x|$). D.w.z.: de constructie van $T(x)$ uit x kan in $O(|x|^k)$ stappen ($k \geq 0$).
2. Voor elke x uit I geldt: als x een ja-instantie is voor P dan is $T(x)$ een ja-instantie voor Q .
3. Voor elke x uit I geldt: als x een nee-instantie is voor P dan is $T(x)$ een nee-instantie voor Q .
- 3'. Voor elke x uit I geldt: als $T(x)$ een ja-instantie is voor Q dan is x een ja-instantie voor P . (Dit is equivalent met 3.)

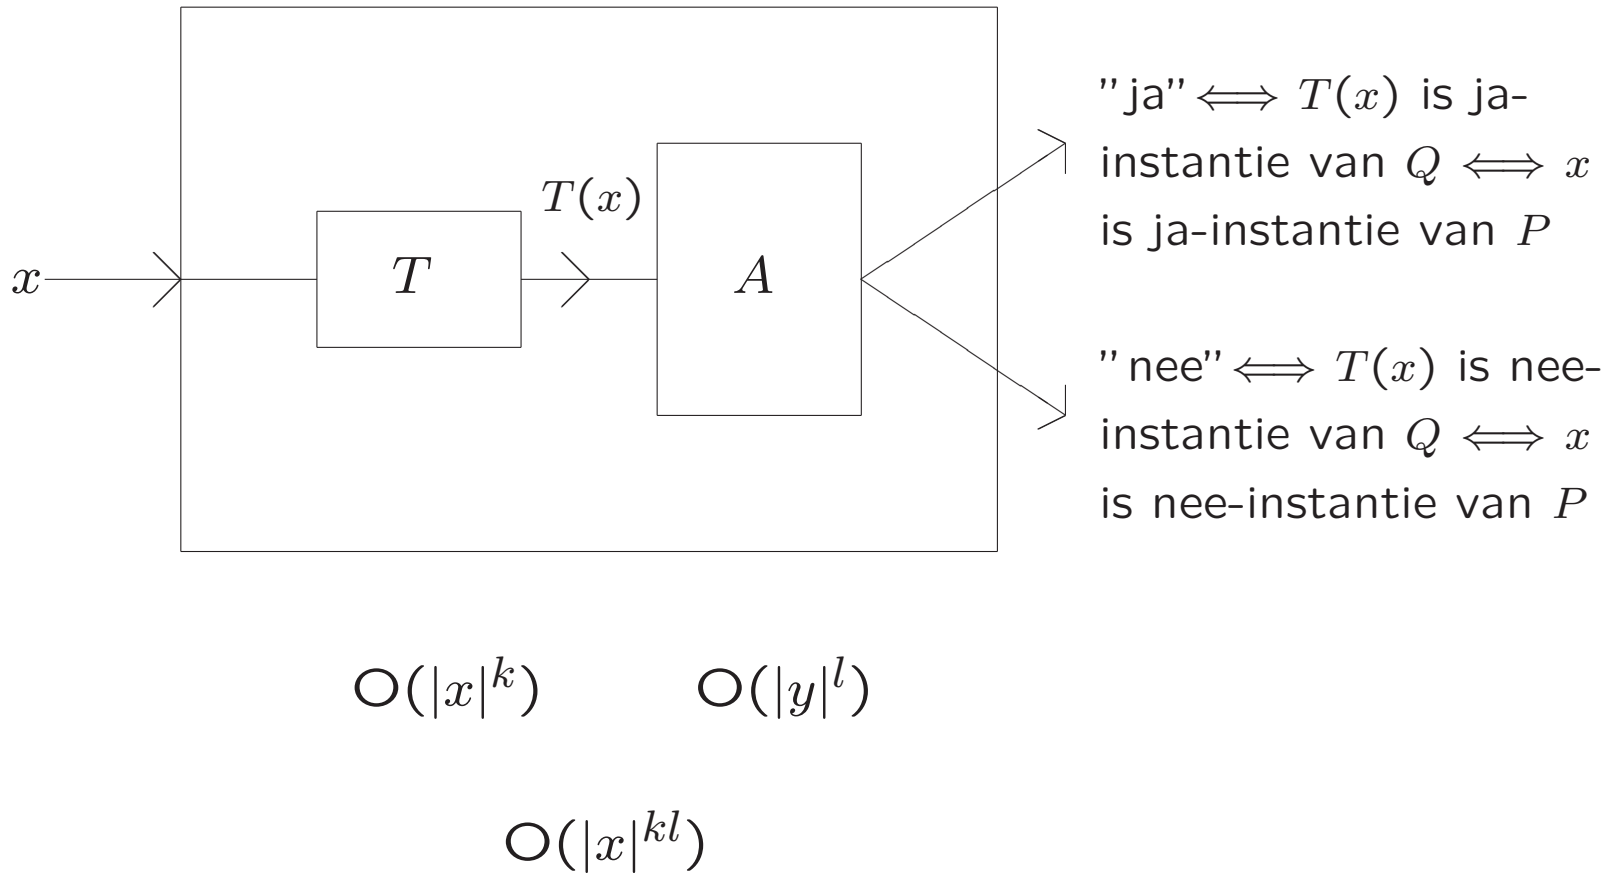
Definitie

Een probleem P is **polynomiaal reduceerbaar** (of polynomiaal transformeerbaar) naar Q als er een polynomiale reductie bestaat van P naar Q .

Notatie: $P \leq_P Q$.

Stelling

Als $P \leq_P Q$ en Q zit in \mathcal{P} , dan zit P ook in \mathcal{P} .



Definitie

Een probleem Q is **NP-hard** als **elk** probleem P in \mathcal{NP} polynomiaal reduceerbaar is tot Q , dat wil dus zeggen dat $P \leq_P Q$ **voor alle** $P \in \mathcal{NP}$.

Definitie

Een probleem Q is **NP-volledig** als

1. $Q \in \mathcal{NP}$
2. Q is NP-hard

Notatie

De klasse van NP-volledige problemen geven we aan met **\mathcal{NPC}** (NP-complete).

HP: gegeven een ongerichte graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonpad?

HC: gegeven een ongerichte graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonkring?

Transformeer een ongerichte graaf \mathcal{G} (invoer voor HP) naar een ongerichte graaf \mathcal{G}' (invoer voor HC) door één knoop toe te voegen en deze met een tak te verbinden met alle andere knopen. Noem deze transformatie T . Deze transformatie is een polynomiale reductie, dus er geldt (via deze T): **HP \leq_P HC**.

HC1: gegeven een *gerichte* graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonkring?

HC2: gegeven een *ongerichte* graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonkring?

Bewering: HC1 \leq_P HC2

Opmerking: er geldt ook: HC2 \leq_P HC1. Bedenk zelf een eenvoudige reductie.

Transformatie T die een gerichte graaf $\mathcal{G} = (V, E)$ op een ongerichte graaf $T(\mathcal{G}) = \mathcal{G}' = (V', E')$ afbeeldt:

- $V' = \{v_1, v_2, v_3 : v \in V\}$: elke knoop $v \in V$ wordt afgebeeld op een drietal knopen v_1, v_2, v_3 .
- $E' = \{(v_1, v_2), (v_2, v_3) : v \in V\} \cup \{(v_3, w_1) : (v, w) \in E\}$: binnen elk drietal knopen corresponderend met v loopt een tak tussen v_1 en v_2 en tussen v_2 en v_3 , en voor elke tak van v naar w in \mathcal{G} komt een tak in \mathcal{G}' tussen v_3 en w_1 .

Dan geldt:

1. T kan in polynomiaal begrensde tijd berekend worden (constructie van $T(\mathcal{G})$ uit \mathcal{G} is $O(|\mathcal{G}|)$)
2. \mathcal{G} is een ja-instantie voor HC1 $\iff \mathcal{G}'$ is een ja-instantie voor HC2, ofwel: \mathcal{G} heeft een gerichte Hamiltonkring $\iff \mathcal{G}'$ heeft een ongerichte Hamiltonkring

- maandag 21 april: 11.15-13.00 college
- maandag 21 april: 13.45-15.30 laatste werkcollege
- dinsdag 22 april: 11.15-13.00 laatste college
- **dinsdag 6 mei: 11.15-13.00 KI, dus geen wCom**
- tentamen: donderdag 5 juni 2008, 14.00-17.00
- vragenuur: ??????

Dertiende college complexiteit

21 april 2008

NP-volledigheid IV

$P \leq_P Q$ betekent dat er een polynomiale reductie T van P naar Q bestaat:

1. T beeldt elke invoer x van P af op een invoer $T(x)$ van Q .
2. De constructie van $T(x)$ uit x is polynomiaal ($O(|x|^k)$).
3. Voor elke x uit I (= invoerverzameling van P) geldt: x is een ja-instantie voor $P \iff T(x)$ is een ja-instantie voor Q .

Stelling

Als $P \leq_P Q$ en $Q \in \mathcal{P}$, dan $P \in \mathcal{P}$.

Definitie

Een probleem Q is **NP-hard** als **elk** probleem P in \mathcal{NP} polynomiaal reduceerbaar is tot Q , dat wil dus zeggen dat $P \leq_P Q$ **voor alle** $P \in \mathcal{NP}$.

Definitie

Een probleem Q is **NP-volledig** als

1. $Q \in \mathcal{NP}$
2. Q is NP-hard

Notatie

De klasse van NP-volledige problemen geven we aan met **\mathcal{NPC}** (NP-complete).

Stelling

Als een of ander NP-volledig probleem in \mathcal{P} zit, dan is $\mathcal{P} = \mathcal{NP}$.

Dit betekent dus: als één enkel NP-volledig probleem P polynomiaal begrensd is, dan zijn alle problemen uit \mathcal{NP} polynomiaal begrensd.

Omgekeerd: als een willekeurig probleem in \mathcal{NP} niet polynomiaal begrensd is, dan zijn alle NP-volledige problemen niet polynomiaal begrensd.

Lemma

\leq_P is **transitief**, dat wil zeggen: als $P_1 \leq_P P_2$ en $P_2 \leq_P P_3$ dan is $P_1 \leq_P P_3$.

Stelling

Stel P is een probleem waarvoor geldt dat $Q \leq_P P$ voor een of andere $Q \in \mathcal{NPC}$. Dan is P NP-hard.

Als bovendien $P \in \mathcal{NP}$, dan geldt dat $P \in \mathcal{NPC}$.

Dus door een bekend NP-volledig probleem te reduceren tot P reduceren we impliciet alle problemen uit \mathcal{NP} tot P . Dit geeft ons derhalve een **methode om aan te tonen dat een probleem P NP-volledig is.**

1. Bewijs dat $P \in \mathcal{NP}$
2. Kies een bekend NP-volledig probleem Q
3. Toon aan dat $Q \leq_P P$

Stap 3 valt uiteen in:

- 3a. Geef een functie T van I (de invoerverzameling van Q) naar I' (de invoerverzameling van P) die elke $x \in I$ afbeeldt op een element van I'
- 3b. Laat zien dat $T(x)$ uit x geconstrueerd kan worden in polynomiaal begrensde tijd ($O(|x|^k)$ voor zekere $k \geq 0$)
- 3c. Toon aan dat T voldoet aan: $x \in I$ is een ja-instantie voor $Q \iff T(x) \in I'$ is een ja-instantie voor P

In 1971 bewees **Stephen Cook** op een directe manier (dus door een reductie te geven van alle problemen uit \mathcal{NP} naar SAT) dat SAT NP-volledig is.

Stelling

Gegeven een willekeurig probleem $P \in \mathcal{NP}$. Dan is P reduceerbaar tot SAT: $P \leq_P \text{SAT}$.

Sindsdien is met behulp van de **reductiemethode** van zeer veel bekende problemen aangetoond dat ze NP-volledig zijn. Bijvoorbeeld voor enige voorbeeldproblemen:

$$\text{SAT} \leq_P \text{3SAT} \leq_P \text{Kliek} \leq_P \text{VC}$$

$$\text{3SAT} \leq_P \text{HC} \leq_P \text{TSP}$$

$$\text{SAT} \leq_P \text{3Kleur} \leq_P \text{4Kleur}$$

Schets van het bewijs

1. Omdat $P \in \mathcal{NP}$, is er een niet-deterministisch algoritme A (een **niet-deterministische Turingmachine**) voor P . Verder is A polynomiaal begrensd ($O(|x|^k)$).
2. Dit algoritme zal voor elke invoer x van P gemodelleerd worden als een logische formule $\phi = T(x)$ in CNF: deze ϕ beschrijft a.h.w. de berekening van A , werkend op x .
3. De formule ϕ is weliswaar lang, maar kan in hooguit $O(|x|^l)$ stappen geconstrueerd worden.
4. Een ja-executie vergt voor ja-instanties x hooguit $N = c \cdot |x|^k$ stappen (want A is polynomiaal begrensd).
5. Een waarmakende waardering voor ϕ correspondeert precies met een executie van A die een “ja” produceert (voor zekere string s dus).

Boolese variabelen in ϕ :

Q_i^q : op tijdstip i is de machine in toestand $q \in Q$, $0 \leq i \leq N$

H_{ij} : op tijdstip i scant de machine cel j , $0 \leq i, j \leq N$

S_{ij}^a : op tijdstip i bevat cel j symbool $a \in \Sigma$, $0 \leq i, j \leq N$

De formule ϕ is een conjunctie van:

- $Q_0^{\text{start}} \wedge \dots \wedge H_{00} \wedge S_{01}^{x_1} \wedge S_{02}^{x_2} \wedge S_{03}^{x_3} \dots$

de machine start in toestand start;

x bevindt zich op de posities 1 t/m $|x|$; ...

- $Q_N^{q_Y} \wedge H_{N0} \wedge \dots$

op tijdstip N stopt de berekening in de ja-toestand

- $\bigwedge_{0 \leq i \leq N} (\bigvee_{q \in Q} Q_i^q) \wedge \bigwedge_{0 \leq i \leq N} (\bigwedge_{p, q \in Q, p \neq q} (\neg Q_i^p \vee \neg Q_i^q))$

te allen tijde is de machine in precies één toestand

- $\bigwedge_{0 \leq i, j \leq N} (\bigvee_{a \in \Sigma} S_{ij}^a) \wedge \bigwedge_{0 \leq i, j \leq N} (\bigwedge_{a, b \in \Sigma, a \neq b} (\neg S_{ij}^a \vee \neg S_{ij}^b))$

te allen tijde bevat elke cel precies één symbool

- $\bigwedge_{0 \leq i \leq N} (\bigvee_{0 \leq j \leq N} H_{ij}) \wedge \bigwedge_{0 \leq i \leq N} (\bigwedge_{0 \leq j < k \leq N} (\neg H_{ij} \vee \neg H_{ik}))$

te allen tijde scant de machine precies één cel

- $Q_i^p \wedge H_{ij} \wedge S_{ij}^a \longrightarrow$
 $\bigvee_{((p,a),(q,b,d)) \in \delta} (Q_{i+1}^q \wedge H_{i+1,j+d} \wedge S_{i+1,j}^b)$

elke stap van de machine verloopt volgens de transitiefunctie δ

- $S_{ij}^a \wedge \neg H_{ij} \longrightarrow S_{i+1,j}^a$

elke cel die op tijdstip i niet gescand wordt bevat op tijdstip $i + 1$ hetzelfde symbool

Een waarmakende waardering correspondeert aldus precies met een echte executie van de niet-deterministische Turingmachine die eindigt in “ja” na een polynomiaal (nl. N) aantal stappen.

HC1: **gegeven** een *gerichte* graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonkring?

HC2: **gegeven** een *ongerichte* graaf $\mathcal{G} = (V, E)$.

Vraag: heeft \mathcal{G} een Hamiltonkring?

Bewering: $HC1 \leq_P HC2$

Opmerking: er geldt ook: $HC2 \leq_P HC1$. Bedenk zelf een eenvoudige reductie.

Transformatie T die een gerichte graaf $\mathcal{G} = (V, E)$ op een ongerichte graaf $T(\mathcal{G}) = \mathcal{G}' = (V', E')$ afbeeldt:

- $V' = \{v_1, v_2, v_3 : v \in V\}$: elke knoop $v \in V$ wordt afgebeeld op een drietal knopen v_1, v_2, v_3 .
- $E' = \{(v_1, v_2), (v_2, v_3) : v \in V\} \cup \{(v_3, w_1) : (v, w) \in E\}$: binnen elk drietal knopen corresponderend met v loopt een tak tussen v_1 en v_2 en tussen v_2 en v_3 , en voor elke tak van v naar w in \mathcal{G} komt een tak in \mathcal{G}' tussen v_3 en w_1 .

Dan geldt:

1. T kan in polynomiaal begrensde tijd berekend worden (constructie van $T(\mathcal{G})$ uit \mathcal{G} is $O(|\mathcal{G}|)$)
2. \mathcal{G} is een ja-instantie voor HC1 $\iff T(\mathcal{G})$ is een ja-instantie voor HC2, ofwel: \mathcal{G} heeft een gerichte Hamiltonkring $\iff \mathcal{G}'$ heeft een ongerichte Hamiltonkring

3SAT

Gegeven een logische formule ϕ in 3-CNF. Bestaat er een waardering die ϕ True maakt?

Definitie

Een logische formule ϕ staat in 3-CNF als ϕ een conjunctie is van clauses, waarbij elke clause een disjunctie is van drie verschillende literals.

Kliek

Gegeven een ongerichte graaf $\mathcal{G} = (V, E)$ en een geheel getal k ($0 \leq k \leq |V|$). Is er in \mathcal{G} een kliek ter grootte k ?

Definitie

Een kliek in een ongerichte graaf $\mathcal{G} = (V, E)$ is een deelverzameling $V' \subseteq V$ zodanig dat voor elk tweetal knopen $u, v \in V'$ ($u \neq v$) geldt dat $(u, v) \in E$. (M.a.w.: tussen elk tweetal knopen uit V' zit een tak.)

Er geldt: **3SAT \leq_P Kliiek**. Om dit aan te tonen moeten we een logische formule in 3-CNF afbeelden op een ongerichte graaf.

Zij ϕ een logische expressie (formule) in 3-CNF, met zeg m clausules: $\phi = C_1 \wedge C_2 \wedge \dots \wedge C_m$. Hierin is $C_r = l_1^r \vee l_2^r \vee l_3^r$ ($r = 1, \dots, m$) en l_1^r, l_2^r en l_3^r steeds verschillend bij vaste r .

Construeer nu een ongerichte graaf $\mathcal{G}_\phi = (V, E)$ als volgt.

Voor elke clausule C_r uit ϕ doen we 3 knopen v_1^r, v_2^r en v_3^r in V (deze corresponderen dus met l_1^r, l_2^r en l_3^r). \mathcal{G}_ϕ heeft derhalve $3m$ knopen.

Er komt een tak tussen twee knopen v_i^r en v_j^s als:

- v_i^r en v_j^s in verschillende drietallen zitten (dus $r \neq s$)
- de bijbehorende l_i^r en l_j^s zó zijn dat $l_i^r \neq \neg l_j^s$, met andere woorden: l_i^r en l_j^s zijn niet elkaars negatie

Definieer nu de transformatie T als: $T(\phi) = \langle \mathcal{G}_\phi, m \rangle$.

Dan geldt:

- T kan in polynomiaal begrensde tijd berekend worden.
- Er is een waardering die ϕ waarmaakt $\iff \mathcal{G}_\phi$ heeft een kliek ter grootte m .

Laat $\phi = C_1 \wedge C_2 \wedge C_3$, met $C_1 = x_1 \vee \neg x_2 \vee \neg x_3$, $C_2 = \neg x_1 \vee x_2 \vee x_3$ en $C_3 = x_1 \vee x_2 \vee x_3$. Hier is dus $m = 3$.

Dan $v_1^1 \leftrightarrow x_1, v_2^1 \leftrightarrow \neg x_2, v_3^1 \leftrightarrow \neg x_3$; alle uit clause C_1 , etcetera

- een waardering w die ϕ waarmaakt is bijvoorbeeld: $w(x_1) = w(x_2) = \text{False}$ en $w(x_3) = \text{True}$. Een bijbehorende klik in \mathcal{G}_ϕ ter grootte 3 is dan $\{v_2^1, v_3^2, v_3^3\}$ (*).
- een klik ter grootte 3 in \mathcal{G}_ϕ is bijvoorbeeld $\{v_1^1, v_2^2, v_3^3\}$. Een bijbehorende waardering is $w(x_1) = w(x_2) = w(x_3) = \text{True}$. Deze maakt ϕ waar.

(*) De bovenindex geeft aan met welke clause een knoop correspondeert.

SAT

Gegeven een logische formule ϕ in CNF. Bestaat er een waardering van de in ϕ voorkomende logische variabelen die ϕ True maakt?

Definitie

Een logische formule ϕ staat in **Conjunctive Normal Form** als ϕ een conjunctie is van clauses, waarin een clause een disjunctie is van literals.

3SAT

Gegeven een logische formule ϕ in 3-CNF. Bestaat er een waardering die ϕ True maakt?

Definitie

Een logische formule ϕ staat in **3-CNF** als ϕ een conjunctie is van clauses, waarbij elke clause een disjunctie is van **drie verschillende literals**.

Er geldt: **SAT \leq_P 3SAT**. Om dit aan te tonen moeten we een logische formule ϕ in CNF afbeelden op een logische formule ϕ' in 3-CNF. We gaan er voor het gemak van uit dat de l_1, l_2, \dots, l_k per clause al verschillend zijn (kan in $O(|\phi|^2)$ worden bewerkstelligd). Op clausuleniveau werkt de transformatie T als volgt:

$$l_1 \longrightarrow (l_1 \vee \tilde{l}_2 \vee \tilde{l}_3) \wedge (l_1 \vee \tilde{l}_2 \vee \neg \tilde{l}_3) \wedge (l_1 \vee \neg \tilde{l}_2 \vee \tilde{l}_3) \wedge (l_1 \vee \neg \tilde{l}_2 \vee \neg \tilde{l}_3)$$

$$l_1 \vee l_2 \longrightarrow (l_1 \vee l_2 \vee \tilde{l}_3) \wedge (l_1 \vee l_2 \vee \neg \tilde{l}_3)$$

$$l_1 \vee l_2 \vee l_3 \longrightarrow l_1 \vee l_2 \vee l_3$$

$$l_1 \vee l_2 \vee l_3 \vee l_4 \longrightarrow (l_1 \vee l_2 \vee \tilde{l}_5) \wedge (l_3 \vee l_4 \vee \neg \tilde{l}_5)$$

$$l_1 \vee l_2 \vee l_3 \vee l_4 \vee l_5 \longrightarrow (l_1 \vee l_2 \vee \tilde{l}_6) \wedge (l_3 \vee \neg \tilde{l}_6 \vee \tilde{l}_7) \wedge (l_4 \vee l_5 \vee \neg \tilde{l}_7)$$

En in het algemeen voor $k \geq 4$:

$$l_1 \vee l_2 \vee \dots \vee l_{k-1} \vee l_k \longrightarrow (l_1 \vee l_2 \vee \widetilde{l_{k+1}}) \wedge (l_3 \vee \neg \widetilde{l_{k+1}} \vee \widetilde{l_{k+2}}) \wedge (l_4 \vee \neg \widetilde{l_{k+2}} \vee \widetilde{l_{k+3}}) \wedge \dots \wedge (l_{k-2} \vee \neg \widetilde{l_{2k-4}} \vee \widetilde{l_{2k-3}}) \wedge (l_{k-1} \vee l_k \vee \neg \widetilde{l_{2k-3}})$$

Hierin zijn $\widetilde{l_{k+1}}, \widetilde{l_{k+2}}, \dots, \widetilde{l_{2k-3}}$ steeds nieuwe, frisse, logische variabelen.

Een clause met k (verschillende) literals wordt zo getransformeerd in een conjunctie van $k-2$ clauses met elk 3 verschillende literals.

Het beeld van een conjunctie van clauses definiëren we als een conjunctie van de beelden van de samenstellende clauses:

$$\phi = C_1 \wedge C_2 \wedge \dots \wedge C_m \longrightarrow T(C_1) \wedge T(C_2) \wedge \dots \wedge T(C_m) = T(\phi)$$

Voor deze transformatie T geldt:

- De constructie van $T(\phi)$ uit ϕ kan met een polynomiaal begrensd ($= O(|\phi|^k)$) algoritme.
- ϕ is een ja-instantie van SAT $\iff T(\phi)$ is een ja-instantie van 3SAT.
- Ofwel: er is een waardering die ϕ waarmaakt \iff er is een waardering die $T(\phi)$ waarmaakt.
- Conclusie uit de vorige punten: SAT \leq_P 3SAT.

- maandag 21 april: 13.45-15.30 laatste werkcollege
- dinsdag 22 april: 11.15-13.00 laatste college: oud tentamen
- **dinsdag 6 mei: 11.15-13.00 KI, dus geen wCom**
- tentamen: donderdag 5 juni 2008, 14.00-17.00
- vragenuur: ??????