

INF2220 - Algoritmer og datastrukturer

HØSTEN 2017

Institutt for informatikk, Universitetet i Oslo

INF2220, forelesning 10:
Tekstalgoritme

Pattern matching algorithms

Algoritmer for lokalisering av substrrenger

- ▶ Brute force
 - ▶ Enkleste tenkelige algoritme for å løse problemet
- ▶ `java.lang.String indexOf`
 - ▶ Vi ser på hvordan det gjøres i standard biblioteket
- ▶ Boyer Moore (Horspool)
 - ▶ Relativt komplisert algoritme, med rask **worst case**

Lokalisering av Substrenger

c	o	z	w	e	r	a	...	u
---	---	---	---	---	---	---	-----	---

Source

c	y	g
---	---	---

Pattern

- ▶ Fins nåla i høystakken?
- ▶ Hvis JA: hvor?

Lokalisering av Substrenger

c	o	z	w	e	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Fins nåla i høystakken?
- ▶ Hvis JA: hvor?

Lokalisering av Substrenger

c	o	z	w	e	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Fins nåla i høystakken?
- ▶ Hvis JA: hvor?

Lokalisering av Substrenger

c	o	z	w	e	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Fins nåla i høystakken?
- ▶ Hvis JA: hvor?

Brute force

Brute force (rå kraft) brukes ofte synonymt med

- ▶ unødvendig tung
- ▶ dårlig
- ▶ treg
- ▶ lite gjennomtenkt
- ▶ nødløsning

men er noen ganger nødvendig

- ▶ Brute force løsninger er typisk den første ideen vi får
- ▶ Stort sett hele dette kurset går ut på å unngå de

Brute force

c	o	z	c	y	g	a	...	u
---	---	---	---	---	---	---	-----	---

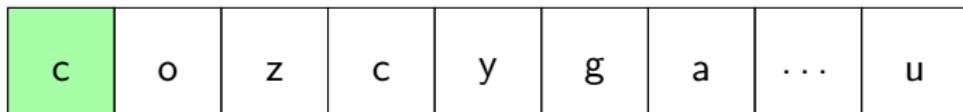
Høystakk

c	y	g
---	---	---

Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



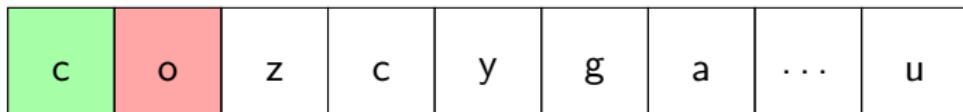
Høystakk



Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



Høystakk



Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force

c	o	z	c	y	g	a	...	u
---	---	---	---	---	---	---	-----	---

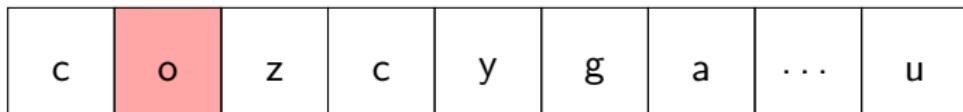
Høystakk

c	y	g
---	---	---

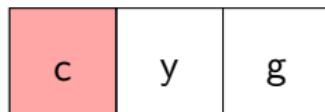
Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



Høystakk



Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force

c	o	z	c	y	g	a	...	u
---	---	---	---	---	---	---	-----	---

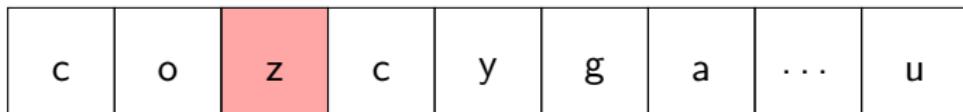
Høystakk

c	y	g
---	---	---

Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force

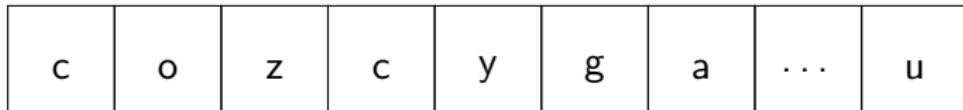


Høystakk

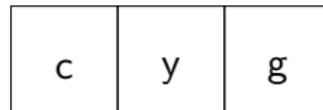
Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



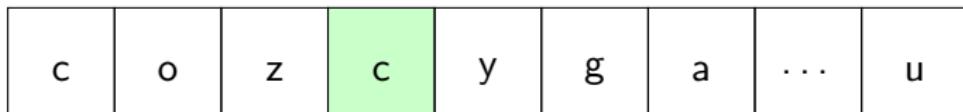
Høystakk



Nål

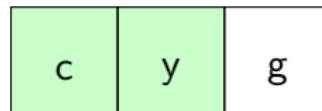
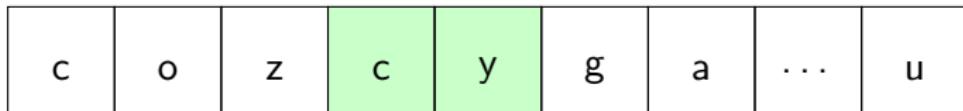
- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



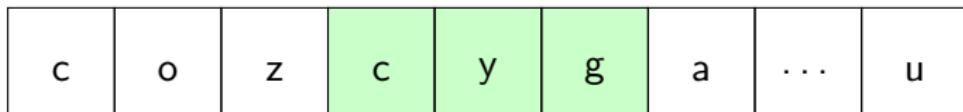
- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force

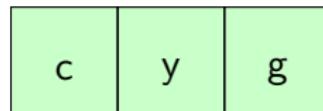


- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



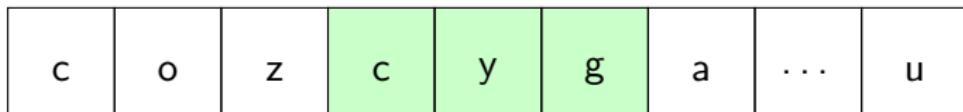
Høystakk



Nål

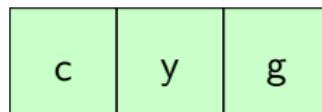
- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



Høystakk

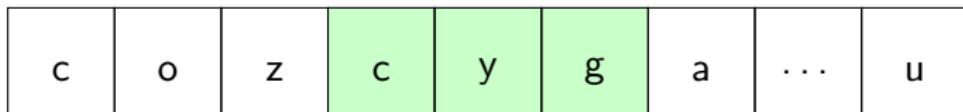
return 3;



Nål

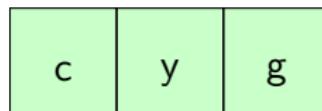
- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



Høystakk

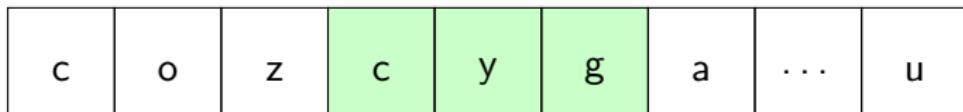
return 3;



Nål

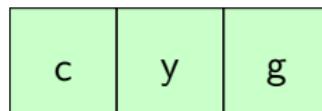
- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

Brute force



Høystakk

return 3;



Nål

- ▶ Var ikke det den første algoritmen du tenkte på?
- ▶ Hva blir kompleksiteten av et sånt søk?

java.lang.String indexOf

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

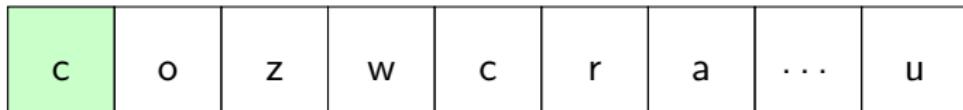
c	y	g
---	---	---

store: c

Nål

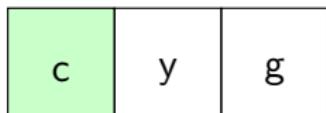
- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf



Høystakk

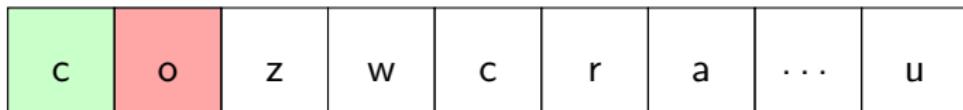
store: c



Nål

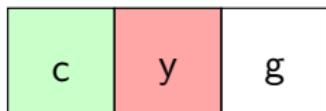
- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf



Høystakk

store: c



Nål

- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

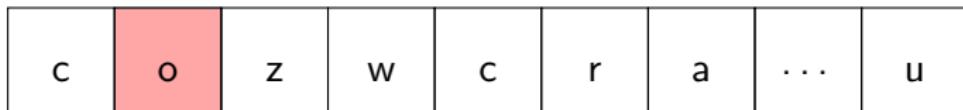
c	y	g
---	---	---

store: c

Nål

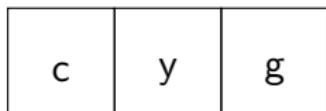
- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf



Høystakk

store: c



Nål

- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

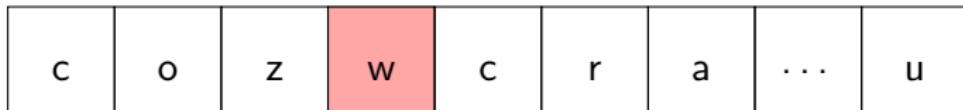
store: c

c	y	g
---	---	---

Nål

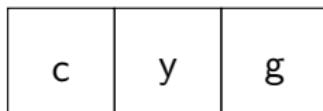
- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf



Høystakk

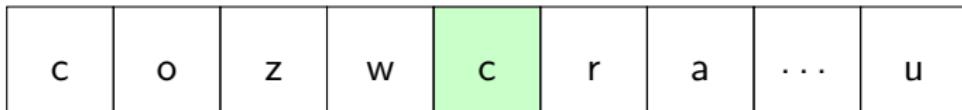
store: c



Nål

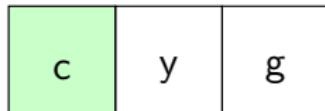
- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

java.lang.String indexOf



Høystakk

store: c



Nål

- ▶ Vi lagrer første element i **nål**
- ▶ Så leiter vi etter match på første element før vi flytter **nål**

Boyer Moore

- ▶ Skal vi øke hastigheten må vi minské antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre **rimelige** antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

Boyer Moore

- ▶ Skal vi øke hastigheten må vi minskes antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre rimelige antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

- ▶ Skal vi øke hastigheten må vi minskes antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre **rimelige** antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

- ▶ Skal vi øke hastigheten må vi minske antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre **rimelige** antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

Boyer Moore

- ▶ Skal vi øke hastigheten må vi minske antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre **rimelige** antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

Boyer Moore

- ▶ Skal vi øke hastigheten må vi minskes antall sammenligninger
 - ▶ Vi kan preprosessere informasjonen i **nål** og **høystakk**
 - ▶ Vi kan gjøre **rimelige** antagelser om input
- ▶ Boyer Moore antar at vi bare har 1-byte characters
- ▶ 1-byte characters gir oss 256 muligheter ($2^8 = 256$)
- ▶ Vi kan bruke den informasjonen til å preprosessere **nålen**

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet z ikke finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes 3 hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet z ikke finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes 3 hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet **z ikke** finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes **3** hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet **z ikke** finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes **3** hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet **z ikke** finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes **3** hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet **z ikke** finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes **3** hakk frem

Boyer Moore

c	o	z	w	c	r	a	...	u
---	---	---	---	---	---	---	-----	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ Vi matcher baklengs med Boyer Moore
- ▶ Merk at elementet **z** ikke finnes i nålen
- ▶ Dvs. etter første match kan nålen flyttes **3** hakk frem

—	—	z	—	—	—	—	—	—
c	y	g	—	—	—	—	—	—
—	c	y	g	—	—	—	—	—
—	—	c	y	g	—	—	—	—

- ▶ Ingen match for søkestrengen helt i starten av teksten eller de neste to posisjonene etter det
- ▶ Vi kan hoppe fremover og begynne å lete etter en match på den sjette plasseringen av teksten
- ▶ Informasjonen vi trenger for å beregne dette ligger i arrayen vi kaller **bad character shift**

Bad Character Shift

- ▶ Hvordan beregne **bad character shift**?
- ▶ Vi må raskt kunne svare på om en bokstav er med i **nålen**
- ▶ Bokstaver er 1-byte lange dvs. (**int**) bokstav $\in [0, 255]$
- ▶ **badCharShift** er en array **int[256]**
- ▶ Vi fyller denne med **shift** verdier ut i fra hva som er i **nålen**

Bad Character Shift

- ▶ Hvordan beregne **bad character shift**?
- ▶ Vi må raskt kunne svare på om en bokstav er med i **nålen**
- ▶ Bokstaver er 1-byte lange dvs. (**int**) bokstav $\in [0, 255]$
- ▶ **badCharShift** er en array **int[256]**
- ▶ Vi fyller denne med **shift** verdier ut i fra hva som er i **nålen**

Bad Character Shift

- ▶ Hvordan beregne **bad character shift**?
- ▶ Vi må raskt kunne svare på om en bokstav er med i **nålen**
- ▶ Bokstaver er 1-byte lange dvs. (**int**) bokstav $\in [0, 255]$
- ▶ **badCharShift** er en array **int[256]**
- ▶ Vi fyller denne med **shift** verdier ut i fra hva som er i **nålen**

Bad Character Shift

- ▶ Hvordan beregne **bad character shift**?
- ▶ Vi må raskt kunne svare på om en bokstav er med i **nålen**
- ▶ Bokstaver er 1-byte lange dvs. (**int**) bokstav $\in [0, 255]$
- ▶ **badCharShift** er en array **int[256]**
- ▶ Vi fyller denne med **shift** verdier ut i fra hva som er i **nålen**

Bad Character Shift

- ▶ Hvordan beregne **bad character shift**?
- ▶ Vi må raskt kunne svare på om en bokstav er med i **nålen**
- ▶ Bokstaver er 1-byte lange dvs. (**int**) bokstav $\in [0, 255]$
- ▶ **badCharShift** er en array **int[256]**
- ▶ Vi fyller denne med **shift** verdier ut i fra hva som er i **nålen**

bad character shift (forenklet)

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){

    badCharShift[i] = needle.length;

}

/* shift size = 1 for characters inside needle */

for(int i = 0; i < needle.length; i++){

    badCharShift[ (int) needle[i] ] = 1;

}
```

bad character shift (forenklet)

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){
    badCharShift[i] = needle.length;
}

/* shift size = 1 for characters inside needle */
for(int i = 0; i < needle.length; i++){
    badCharShift[ (int) needle[i] ] = 1;
}
```

bad character shift (forenklet)

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){

    badCharShift[i] = needle.length;

}

/* shift size = 1 for characters inside needle */
for(int i = 0; i < needle.length; i++){

    badCharShift[ (int) needle[i] ] = 1;

}
```

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`
- ▶ `badCharShift[103] == 1` `103 == (int) 'g'`
- ▶ **For alle andre verdier $x \in [0, 255]$**
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[121] == 1 121 == (int) 'y'`
- ▶ `badCharShift[103] == 1 103 == (int) 'g'`
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3 (needle.length == 3)`

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ `badCharShift[103] == 1` $103 == (\text{int}) \text{ 'g'}$
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ `badCharShift[103] == 1` $103 == (\text{int}) \text{ 'g'}$
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ `badCharShift[103] == 1` $103 == (\text{int}) \text{ 'g'}$
- ▶ **For alle andre verdier** $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift (forenklet)

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 1` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ `badCharShift[103] == 1` $103 == (\text{int}) \text{ 'g'}$
- ▶ **For alle andre verdier** $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 1` `99 == (int) 'c'`
- ▶ `badCharShift[97] == 3` `97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 1` `99 == (int) 'c'`
- ▶ `badCharShift[97] == 3` `97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

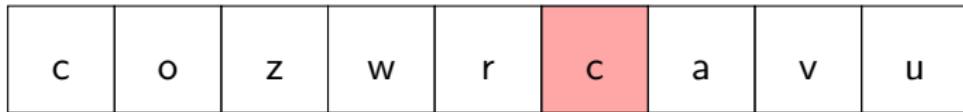
Høystakk

c	y	g
---	---	---

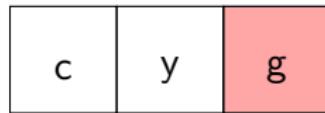
Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)



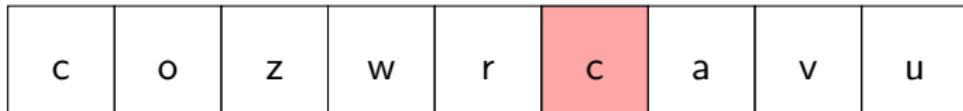
Høystakk



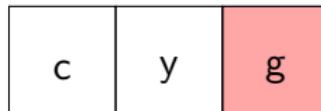
Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)



Høystakk



Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

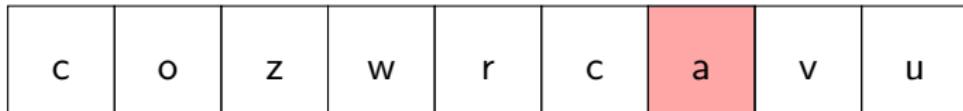
Høystakk

c	y	g
---	---	---

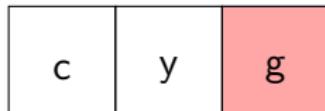
Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)



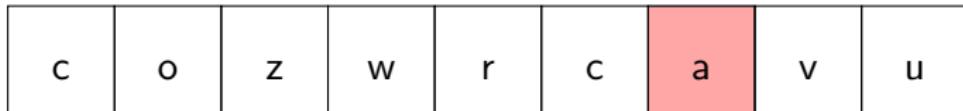
Høystakk



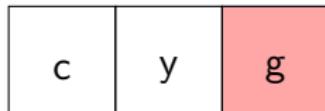
Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 1` `99 == (int) 'c'`
- ▶ `badCharShift[97] == 3` `97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)



Høystakk



Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 1` `99 == (int) 'c'`
- ▶ `badCharShift[97] == 3` `97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 1 99 == (int) 'c'`
- ▶ `badCharShift[97] == 3 97 == (int) 'a'`
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

return -1;

c	y	g
---	---	---

Nål

- ▶ badCharShift[122] == 3 122 == (int) 'z'
- ▶ badCharShift[99] == 1 99 == (int) 'c'
- ▶ badCharShift[97] == 3 97 == (int) 'a'
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift (forenklet)

c	o	z	w	r	c	a	v	u
---	---	---	---	---	---	---	---	---

Høystakk

return -1;

c	y	g
---	---	---

Nål

- ▶ badCharShift[122] == 3 122 == (int) 'z'
- ▶ badCharShift[99] == 1 99 == (int) 'c'
- ▶ badCharShift[97] == 3 97 == (int) 'a'
- ▶ Vi kan gjøre det bedre for bokstavene som er i nålen

bad character shift

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){
    badCharShift[i] = needle.length;
}

/* calculate bad shift up to needle.length - 1 */

int last = needle.length - 1;

for(int i = 0; i < last; i++){
    badCharShift[ (int) needle[i] ] = last - i;
}
```

bad character shift

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){

    badCharShift[i] = needle.length;

}

/* calculate bad shift up to needle.length - 1 */

int last = needle.length - 1;

for(int i = 0; i < last; i++){

    badCharShift[ (int) needle[i] ] = last - i;

}
```

bad character shift

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){

    badCharShift[i] = needle.length;

}

/* calculate bad shift up to needle.length - 1 */

int last = needle.length - 1;

for(int i = 0; i < last; i++){

    badCharShift[ (int) needle[i] ] = last - i;

}
```

bad character shift

```
int[] badCharShift = new int[256]; // assume 1-byte characters

for(int i = 0; i < badCharShift.length; i++){

    badCharShift[i] = needle.length;

}

/* calculate bad shift up to needle.length - 1 */

int last = needle.length - 1;

for(int i = 0; i < last; i++){

    badCharShift[ (int) needle[i] ] = last - i;

}
```

bad character shift

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ For alle andre verdier $x \in [0, 255]$
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ **For alle andre verdier $x \in [0, 255]$**
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift

Hvordan ser preprosesseringen ut hvis vi bruker **nålen** fra i sta?

c	y	g
---	---	---

Nål

- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$
- ▶ **For alle andre verdier $x \in [0, 255]$**
- ▶ `badCharShift[x] == 3` (`needle.length == 3`)

bad character shift

c	o	z	w	r	c	a	y	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift

c	o	z	w	r	c	a	y	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift

c	o	z	w	r	c	a	y	u
---	---	---	---	---	---	---	---	---

Høystakk

c	y	g
---	---	---

Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 2 99 == (int) 'c'`
- ▶ `badCharShift[121] == 1 121 == (int) 'y'`

bad character shift

c	o	z	w	r	c	a	y	u
---	---	---	---	---	---	---	---	---

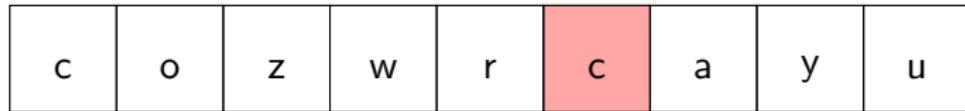
Høystakk

c	y	g
---	---	---

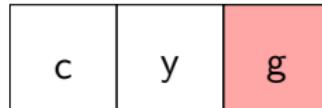
Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 2 99 == (int) 'c'`
- ▶ `badCharShift[121] == 1 121 == (int) 'y'`

bad character shift



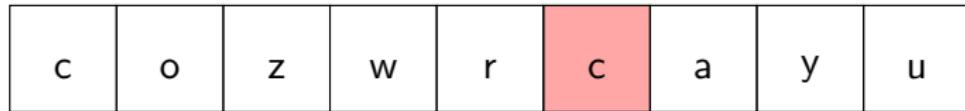
Høystakk



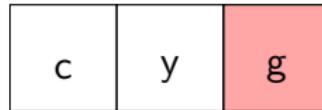
Nål

- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 2 99 == (int) 'c'`
- ▶ `badCharShift[121] == 1 121 == (int) 'y'`

bad character shift



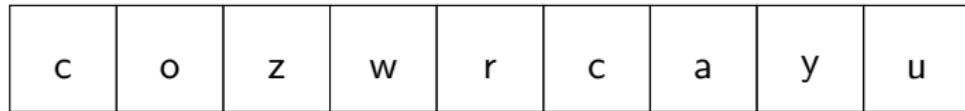
Høystakk



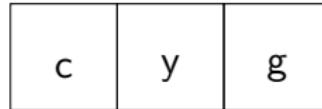
Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift



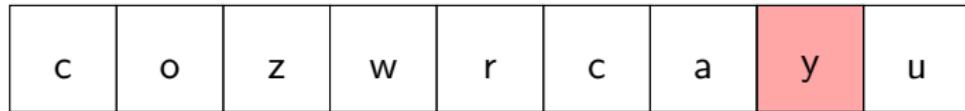
Høystakk



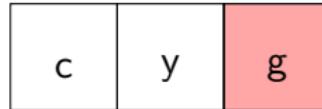
Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift



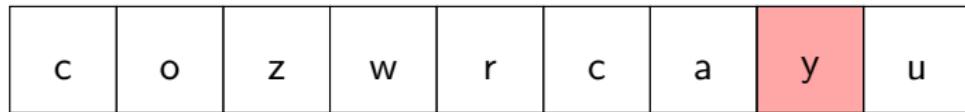
Høystakk



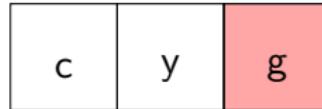
Nål

- ▶ `badCharShift[122] == 3` $122 == (\text{int}) \text{ 'z'}$
- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$

bad character shift



Høystakk



Nål

- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift

c	o	z	w	r	c	a	y	u
---	---	---	---	---	---	---	---	---

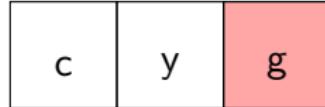
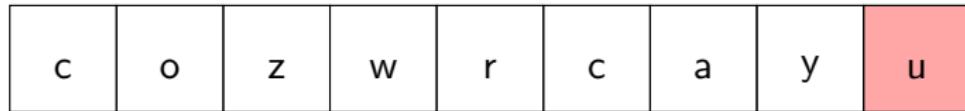
Høystakk

c	y	g
---	---	---

Nål

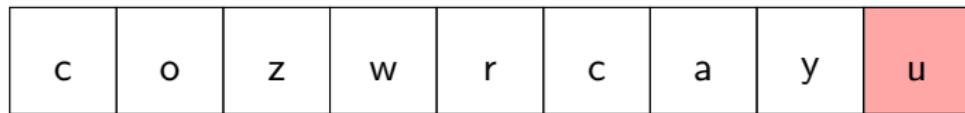
- ▶ `badCharShift[122] == 3 122 == (int) 'z'`
- ▶ `badCharShift[99] == 2 99 == (int) 'c'`
- ▶ `badCharShift[121] == 1 121 == (int) 'y'`

bad character shift

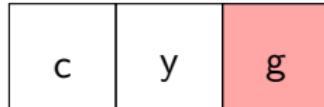


- ▶ `badCharShift[122] == 3` `122 == (int) 'z'`
- ▶ `badCharShift[99] == 2` `99 == (int) 'c'`
- ▶ `badCharShift[121] == 1` `121 == (int) 'y'`

bad character shift



return -1;



- ▶ `badCharShift[122] == 3` $122 == (\text{int}) \text{ 'z'}$
- ▶ `badCharShift[99] == 2` $99 == (\text{int}) \text{ 'c'}$
- ▶ `badCharShift[121] == 1` $121 == (\text{int}) \text{ 'y'}$

Boyer Moore Horspool

```
public int boyer_moore_horspool(char[] needle, char[] haystack){

    if ( needle.length > haystack.length ) { return -1; }

    int[] bad_shift = new int[CHAR_MAX]; // 256

    for(int i = 0; i < CHAR_MAX; i++){
        bad_shift[i] = needle.length;
    }

    int offset = 0, scan = 0;
    int last = needle.length - 1;
    int maxoffset = haystack.length - needle.length;

    for(int i = 0; i < last; i++){
        bad_shift[needle[i]] = last - i;
    }

    while(offset <= maxoffset){

        for(scan = last; needle[scan] == haystack[scan+offset]; scan--){

            if(scan == 0){ // match found!
                return offset;
            }
        }
        offset += bad_shift[haystack[offset + last]];
    }
    return -1;
}
```

Shift-verdien er basert på den siste byten av nålen, uansett hvor vi ikke fikk match.

shift basert på **d**, shift 4

a	a	c	d	—	—	—	—	—
a	b	c	d					
				a	b	c	d	

shift basert på **d**, shift 1

—	a	a	c	d	—	—	—	—
a	c	b	d	d				
		a	c	b	d	d		

- ▶ Bad character shift er effektiv til for eksempel å søke i tekst i naturlige språk fordi mismatches er sannsynlige
- ▶ Med få alfabeter er det sannsynlig å få matching nær slutten av nålen. I dette tilfellet kan vi ha nytte av å vurdere vellykket match-suffikser av nålen.

Boyer Moore

- ▶ Horspool er en forenkling av Boyer-Moore-streng-søkealgoritmen

Boyer-Moore-algoritmen er basert på:

1. å analysere nålen baklengs
2. **bad character shift**
3. **good suffix shift**

- ▶ **bad character shift** unngår å gjenta mislykkede sammenligninger mot et tegn i høystakken
- ▶ **good suffix shift** beregner hvor langt vi kan flytte nålen, basert på antall matchende bokstaver før mismatch
- ▶ justerer bare matchende nål-tegn mot høystakk-tegn som allerede har fått match
- ▶ **good suffix shift** er en array som er like lang som nålen

Boyer Moore

- ▶ Horspool er en forenkling av Boyer-Moore-streng-søkealgoritmen

Boyer-Moore-algoritmen er basert på:

1. å analysere nålen baklengs
2. **bad character shift**
3. **good suffix shift**

- ▶ **bad character shift** unngår å gjenta mislykkede sammenligninger mot et tegn i høystakken
- ▶ **good suffix shift** beregner hvor langt vi kan flytte nålen, basert på antall matchende bokstaver før mismatch
- ▶ justerer bare matchende nål-tegn mot høystakk-tegn som allerede har fått match
- ▶ **good suffix shift** er en array som er like lang som nålen

Boyer Moore

- ▶ Horspool er en forenkling av Boyer-Moore-streng-søkealgoritmen

Boyer-Moore-algoritmen er basert på:

1. å analysere nålen baklengs
2. **bad character shift**
3. **good suffix shift**

- ▶ **bad character shift** unngår å gjenta mislykkede sammenligninger mot et tegn i høystakken
- ▶ **good suffix shift** beregner hvor langt vi kan flytte nålen, basert på antall matchende bokstaver før mismatch
- ▶ justerer bare matchende nål-tegn mot høystakk-tegn som allerede har fått match
- ▶ **good suffix shift** er en array som er like lang som nålen

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

høystakk: prstabst**ubab**vqxrst

nål: qcabdab**dab**

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

høystakk: prstabst**ubab**vqxrst

nål: qcabd**ab**dab

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

høystakk: prstabst**ubab**vqxrst

nål: qcab**dabd**ab

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

høystakk: prstabst**ubab**vqxrst

nål: **qcab**dab**dab**

Good suffix shift (Case 1)

Antar at vi har fått match for **nål**[$i \dots n$]

Hvis **nål**[$i - 1$] er en mismatch og **nål** inneholder en annen kopi av **nål**[$i \dots n$] som ikke har tegnet **nål**[$i - 1$] som prefiks, flytt **nål** slik at kopien matcher substrengen som allerede var matchet av **nål**[$i \dots n$]

høystakk: prstabstubarbabvqxrst

nål: qcabdabdab

Good Suffix Shift

Anta nålen vi leter etter er: **fiskekake**

index	Mismatch	Shift	goodCharShift
0	e	1	goodCharShift[0] == 1
1	ke	9	goodCharShift[1] == 9
2	ake	4	goodCharShift[2] == 4
3	kake	9	goodCharShift[3] == 9
4	ekake	9	goodCharShift[4] == 9
5	kekake	9	goodCharShift[5] == 9
6	skekake	9	goodCharShift[6] == 9
7	iskekake	9	goodCharShift[7] == 9
8	fiskekake	9	goodCharShift[8] == 9

ke representerer en substrang i **fiskekake** som består av et tegn som ikke er en 'k' pluss et tegn 'e'

Good suffix shift (case 2)

Antar at $\mathbf{nål}[i \dots n]$ og substrang \mathbf{t} av høystakken matcher, men vi har en mismatch av $\mathbf{nål}[i - 1]$

Hva hvis $\mathbf{nål}[i \dots n]$ ikke er en substrang i $\mathbf{nål}[0 \dots i - 1]$?

Good suffix shift (case 2)

Antar at $\text{nål}[i \dots n]$ og substreng t av høystakken matcher, men vi har en mismatch av $\text{nål}[i - 1]$

Hva hvis $\text{nål}[i \dots n]$ ikke er en substreng i $\text{nål}[0 \dots i - 1]$?

- - - - X M A N P A N M A N - - - - -
A N P A N M A N

Good suffix shift (case 2)

Antar at $\mathbf{nål}[i \dots n]$ og substrang \mathbf{t} av høystakken matcher, men vi har en mismatch av $\mathbf{nål}[i - 1]$

Hva hvis $\mathbf{nål}[i \dots n]$ ikke er en substrang i $\mathbf{nål}[0 \dots i - 1]$?

- - - - X M A N P A N M A N - - - - -
A N P A N M A N

ops!

Good suffix shift (case 2)

Antar at $\text{nål}[i \dots n]$ og substreng t av høystakken matcher, men vi har en mismatch av $\text{nål}[i - 1]$

Hva hvis $\text{nål}[i \dots n]$ ikke er en substreng i $\text{nål}[0 \dots i - 1]$?

- - - - X M A N P A N M A N - - - - -
A N P A N M A N

Good suffix shift (case 2)

Antar at $\mathbf{nål}[i \dots n]$ og substrang \mathbf{t} av høystakken matcher, men vi har en mismatch av $\mathbf{nål}[i - 1]$

Hva hvis $\mathbf{nål}[i \dots n]$ ikke er en substrang i $\mathbf{nål}[0 \dots i - 1]$?

- - - - X M **A N** P A N M A N - - - - -
 A N P A N M A N

Case 2: flytt **nål** minst mulig slik at et *suffiks* av **t** matcher et *prefiks* av **nål**

Hvis ingen slik match, flytt **nål** med $|nål|$ posisjoner.

Good Suffix Shift

Anta nålen vi leter etter er: **ANPANMAN**

index	Mismatch	Shift	goodCharShift
0	N	1	goodCharShift[0] == 1
1	AN	8	goodCharShift[1] == 8
2	MAN	3	goodCharShift[2] == 3
3	NMAN	6	goodCharShift[3] == 6
4	ANMAN	6	goodCharShift[4] == 6
5	PANMAN	6	goodCharShift[5] == 6
6	NPANMAN	6	goodCharShift[6] == 6
7	ANPANMAN	6	goodCharShift[7] == 6

source: [wikipedia.org](https://en.wikipedia.org)

Neste forelesning: 2. november

PARALLEL SORTERING