

Datalogiforelæsning

Gerth Stølting Brodal

May 10, 1994

SRC Research
Report

124

A Block-sorting Lossless Data Compression Algorithm

M. Burrows and D.J. Wheeler

digital

Systems Research Center
130 Lytton Avenue
Palo Alto, California 94301

A Block-sorting Lossless Data Compression Algorithm

M. Burrows and D.J. Wheeler



Systems Research Center
130 Lytton Avenue
Palo Alto, California 94301

Burrows - Wheeler transformation



Michael Burrows



David J. Wheeler

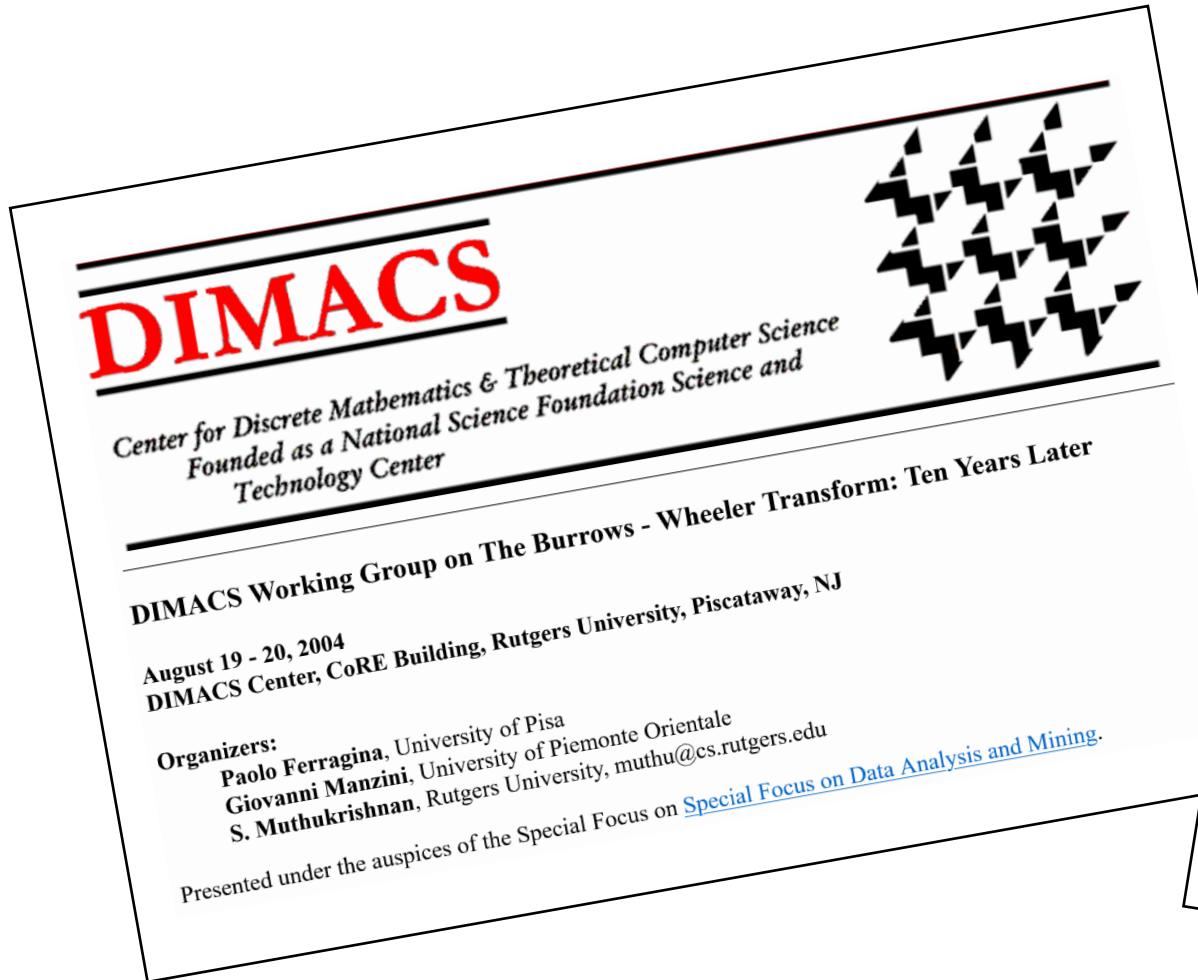
Opfundet af Wheeler (1927-2004) in 1983

Burrows var ph.d. studerende af Wheeler @ Cambridge

Teknisk rapport 1994

"Annual Data Compression Conference"
afviste at publicere resultatet

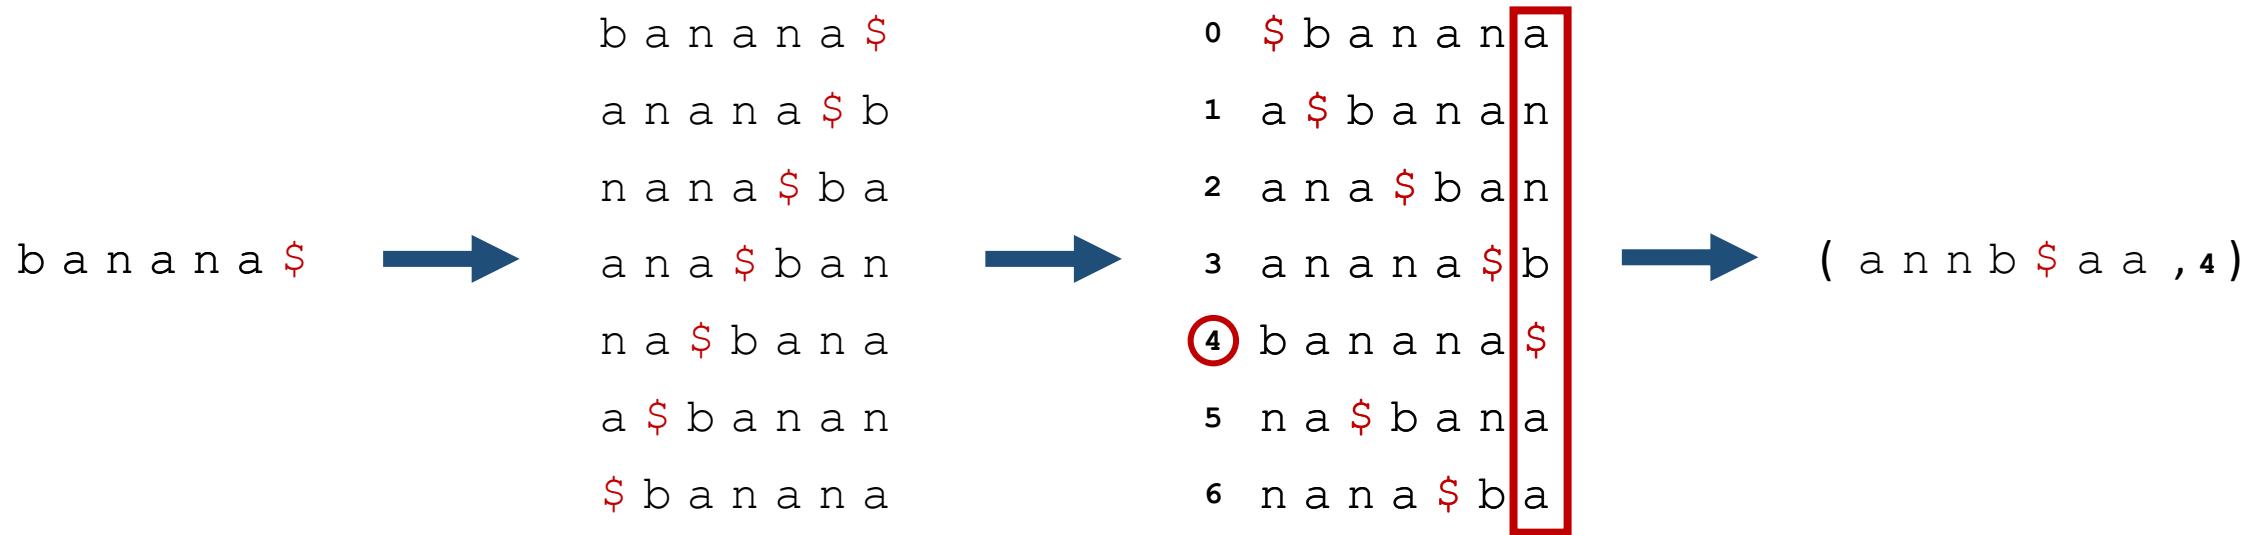
Det var åbenbart en god idé...



Report from Dagstuhl Seminar 19241
25 Years of the Burrows-Wheeler Transform
Edited by
Travis Gagie¹, Giovanni Manzini², Gonzalo Navarro³, and
Jens Stoye⁴



Burrows-Wheeler transformation



Input

En **streng**, som ender på et tegn **\$**, der ellers ikke forekommer og er mindre end alle andre tegn ($\$ < a < b < n$)

Trin 1

Konstruer alle **cykliske rotationer/skift** af strengen

Trin 2

Sorter alle rotationerne alfabetisk/leksikografisk

Output

Den **sidste kolonne** som en streng + **indeks** på rækken der indeholder input strengen

Burrows-Wheeler transformantionen af batman\$?

a) (bmn\$taa , 3)

b) (\$batman , 0)



c) (nmb\$taa , 3)

d) (\$aabmnt , 0)

e) (nmb\$aat , 3)

www.menti.com

1712 0722

batman\$



batman\$

atman\$b

tman\$ba

man\$bat

an\$batm

n\$batma

\$batman

\$batma**n**

an\$bat**m**

atman\$**b**

batman\$**a**

man\$ba**t**

n\$batma**a**

tman\$ba**a**



(nmb\$taa , 3)

Tre oplagte spørgsmål

- Kan transformation inverteres ?

(nmb\$taa , 3) → batman\$

- Kan transformationerne beregnes effektivt ?

somelongstring\$
1.000.000 tegn

\$somelongstring
elongstring\$som
g\$somelongstrin
gstring\$somealon
ing\$somelongstr
longstring\$some
melongstring\$so
ng\$somelongstrin
gstring\$someleo
melongstring\$so
ngstring\$somele
ring\$somealongst
somealongstring\$
string\$somealong
tring\$somealong

midlertidigt
1.000.000.000.000 tegn
men output kun
1.000.000 tegn

- Kan transformationen overhovedet bruges til noget ?

Google scholar giver +3400 citationer

Inverse Burrows-Wheeler transformation

Hvilket index får man fra Burrows-Wheeler transformationen?



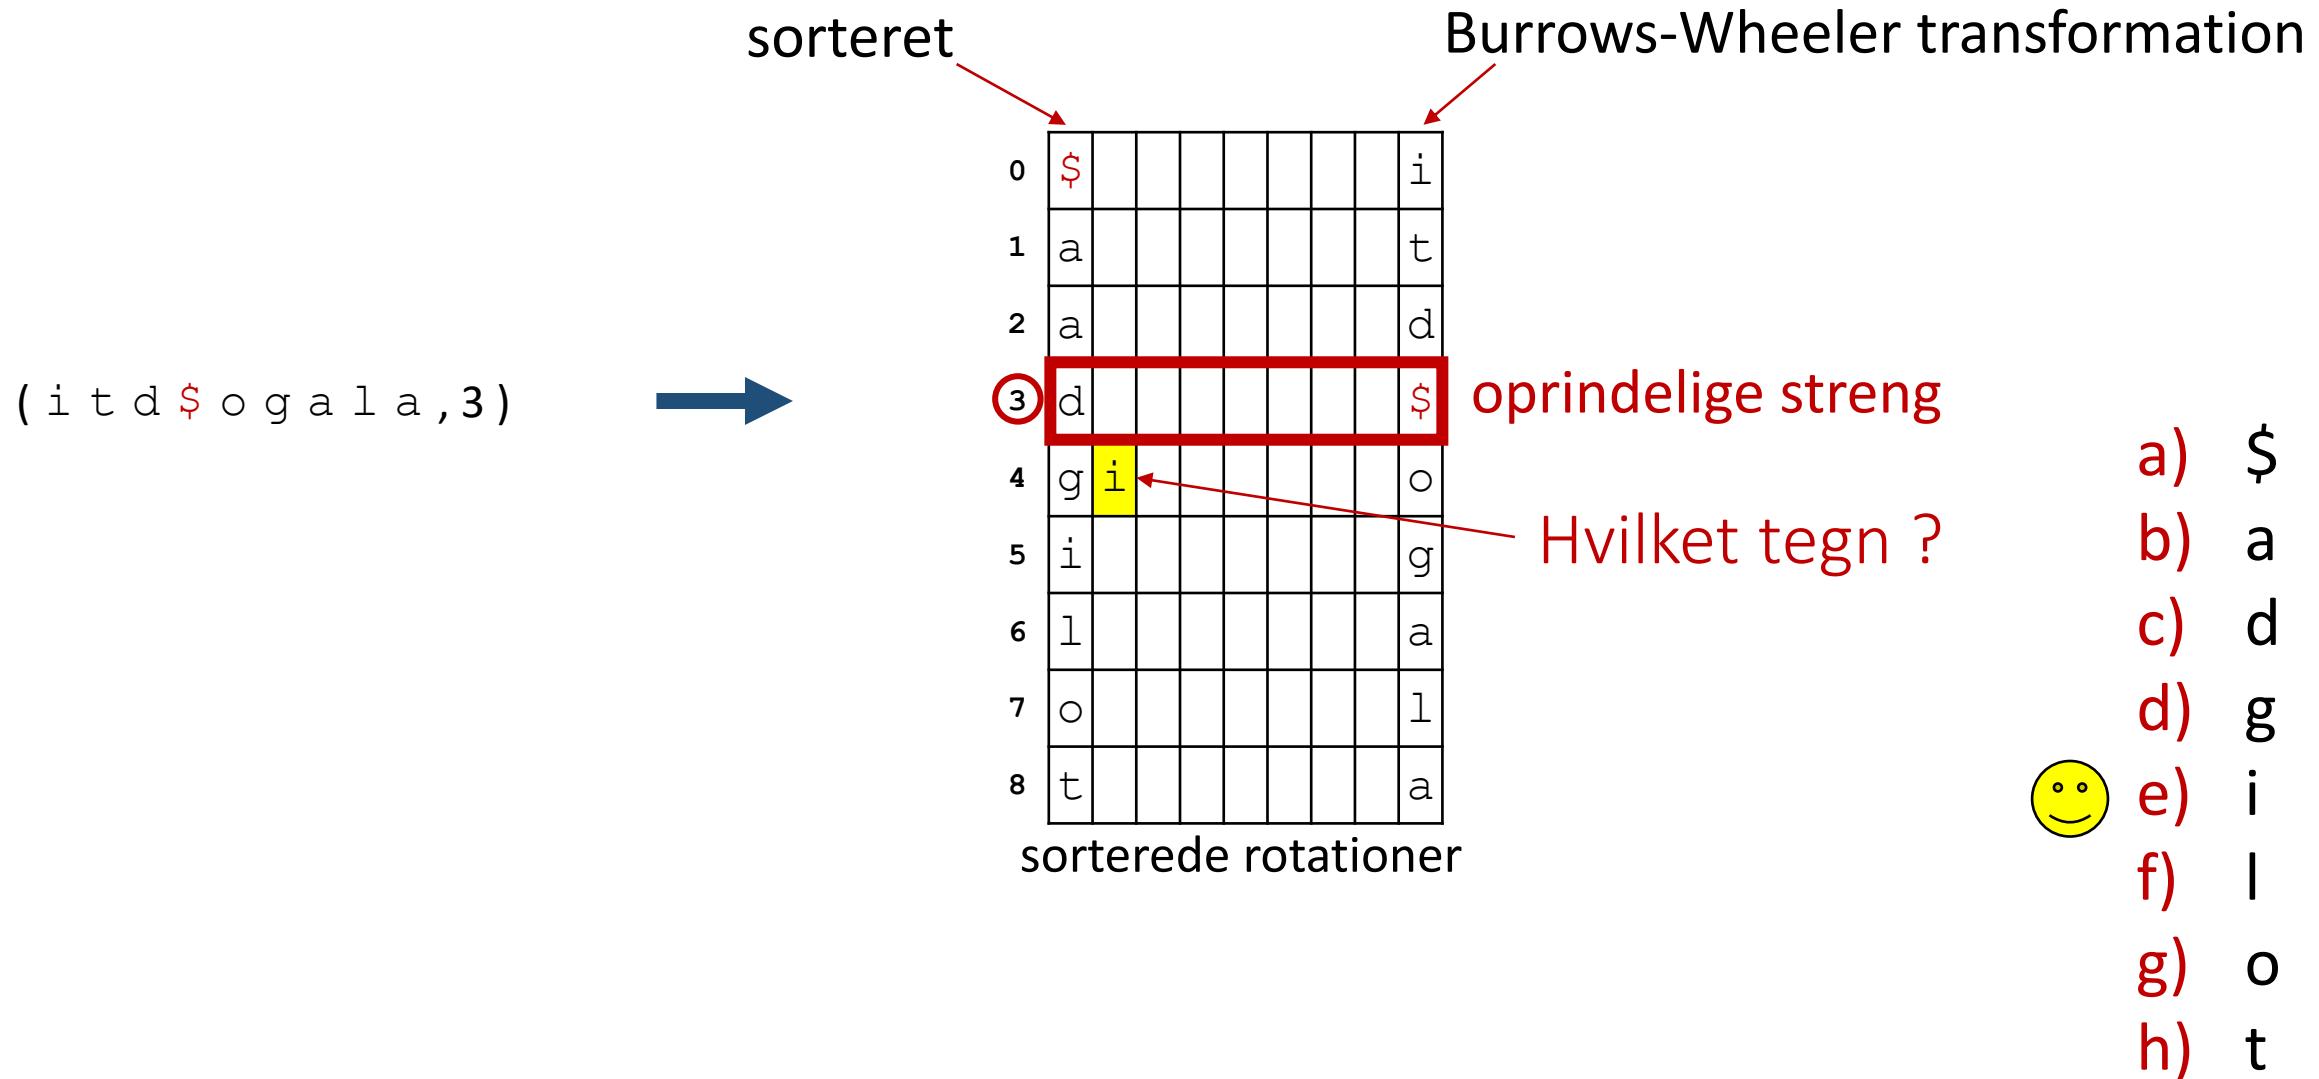
(i t d \$ o g a l a , _)

- a) 0
- b) 1
- c) 2
-  d) 3 = indekset på \$ i Burrows-Wheeler transformationen
- e) 4
- f) 5
- g) 6
- h) 7
- i) 8

Bemærk

Tilstrækkeligt enten at tilføje \$ til sidst i strengen eller gemme et indeks

Inverse Burrows-Wheeler transformation



Inverse Burrows-Wheeler transformation

(i t d \$ o g a l a , 3)



0	\$	d					i
1	a	l				t	
2	a	t				d	
3	d	a				\$	
4	g	i				o	
5	i	\$				g	
6	l	o				a	
7	o	g				l	
8	t	a				a	

sorterede rotationer

i \$ \$ d
t a a l
d a a t
\$ d da
o g g i
g i i \$
a l l o
l o o g
a t t a

sorter

da
g i
i \$
l o
o g
t a

to første
kolonner

Inverse Burrows-Wheeler transformation

(i t d \$ o g a l a , 3)



0	\$	d	a					i
1	a	l	o					t
2	a	t	a					d
3	d	a	t					\$
4	g	i	\$					o
5	i	\$	d					g
6	l	o	g					a
7	o	g	i					l
8	t	a	l					a

sorterede rotationer

i \$ d \$ d a
t a l a l o
d a t a t a
\$ d a dat
o g i sorter
g i \$ i \$ d
a l o l o g
l o g o g i
a t a t a l

dat g i \$
g i \$ i \$ d
a l o l o g
l o g o g i
a t a t a l

Inverse Burrows-Wheeler transformation

(i t d \$ o g a l a , 3)



0	\$	d	a	t	a	l	o	g	i
1	a	l	o	g	i	\$	d	a	t
2	a	t	a	l	o	g	i	\$	d
3	d	a	t	a	l	o	g	i	\$
4	g	i	\$	d	a	t	a	l	o
5	i	\$	d	a	t	a	l	o	g
6	l	o	g	i	\$	d	a	t	a
7	o	g	i	\$	d	a	t	a	l
8	t	a	l	o	g	i	\$	d	a

sorterede rotationer



d a t a l o g i \$

Invers Burrows-Wheeler transformation

Sætning

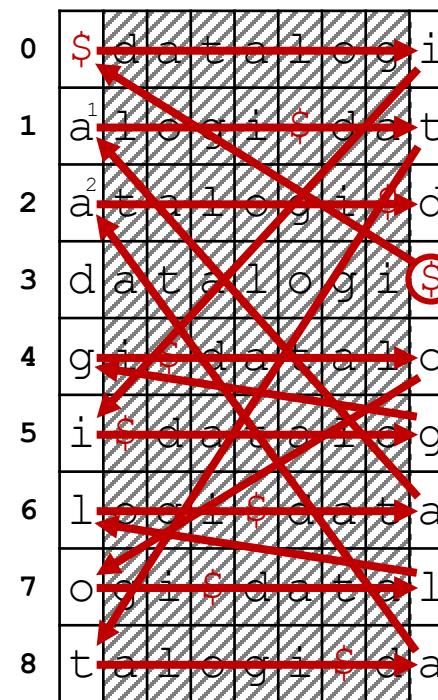
Man kan fra Burrows-Wheeler transformationen af en streng
rekonstruere den oprindelige streng

(i t d \$ o g a l a , 3) → d a t a l o g i \$

Hurtigere inverse Burrows-Wheeler transformation

Idé – konstruer kun første og sidste kolonne

(i t d \$ o g a l a , 3)



d a t a l o g i \$

Hurtigere inverse Burrows-Wheeler transformation

Idé – konstruer kun første og sidste kolonne

(i t d \$ o g a l a , 3)



0	\$	d	a	t	a	l	o	g	i	
1	a	1	o	g	i	\$	d	a	t	
2	a	2	1	o	g	i	1	d	a	
3	d	a	t	a	l	o	g	i	\$	
4	g	i	1	d	a	r	a	1	o	
5	i	1	d	a	r	2	o	g		
6	l	o	2	c	a	1	a			
7	o	1	c	d	a	1	2			
8	t	1	o	g	i	1	2	a		



d a t a l o g i \$

Python implementation

```
def BurrowsWheeler(text):
    S = sorted(text[i:] + text[:i] for i in range(len(text)))
    idx = S.index(text)
    bwt = ''.join(x[-1] for x in S)
    return (bwt, idx)

def InverseBurrowsWheeler(bwt, idx):
    S = [''] * len(bwt)
    for i in range(len(bwt)):
        S[i] = sorted(c + s for s, c in zip(S, bwt))
    return S[idx]

def EfficientInverseBurrowsWheeler(bwt, idx):
    r = []
    cnt = {}
    for char in bwt:
        r.append(cnt.get(char, 0))
        cnt[char] = cnt.get(char, 0) + 1
    s = 0
    for char in sorted(cnt):
        s, cnt[char] = s + cnt[char], s
    S = []
    for i in range(len(bwt)):
        S.append(bwt[idx])
        idx = cnt[bwt[idx]] + r[idx]
    return ''.join(reversed(S))
```

Den Grimme Ælling (Hans Christian Andersen, 1843)

Der var så dejligt ude på landet; det var sommer, kornet stod gult, havren grøn, høet var rejst i stakke nede i de grønne enge, og der gik storken på sine lange, røde ben. Sproget havde han lært af sin moder. Rundt om ager og eng var der store søer; jo, der var rigtignok dejligt derude på landet! Midt i solskin med dybe kanaler rundt om, og fra muren og ned til vandet voksede store træer, at små børn kunne stå oprejste under de største; der var lige så vidt este skov, og her lå en and på sin rede; hun skulle ruge sine små æller. Ked af det, fordi det varede så länge, og hun sjælden fik visit; de ømme om i kanalerne, end at løbe op og sidde under et skræppeblad for at svømme om i kanalene.

416 f at svømme om i kanalene
417 f det, fordi det var sten ved
418 f sin moder. Rundt om han lært at
419 fik visit; de andre ...n sjælden
420 for at snadre med h...ræppeblad
421 for det sprog havde ...ægyptisk,
422 fordi det varede så ...d af det,
423 fra muren og ned til...dt om, og
424 g der gik storken på...ne enge, o
425 g eng var der store ... om ager o
426 g fra muren og ned t...undt om, o
427 g havde han lært af ...r det spro
428 g her lå en and på s...te skov, o
429 g hun sjælden fik vi...å länge, o
430 g midt i skovene dyb...e skove, o
431 g ned til vandet vok...ra muren o
432 g sidde under et skr... løbe op o
433 g snakkede ægyptisk,...røde ben o
434 g var der store skov...ager og en
435 gammel herregård med...lå der en
436 ge sine små ællinger... skulle ru
437 ge så vildsamt derin...der var lidet
438 ge, og der gik stork... grønne en
439 ge, og hun sjælden f...ede så länge
440 ge, røde ben og snak...å sine lan

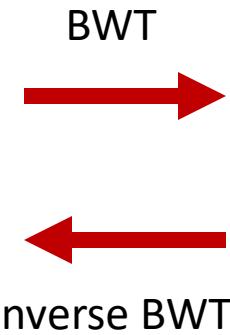
Burrows-Wheeler transformation

!.edtmned, rfeå;irkåiågr;,,ttr;ifdeår,gernd,,gnrnedeg,dglrrg;,,åemmtt, npnteteåeednnrrer, gfååeneeitentetgi, rtitrekeetrreeednrteelgurttrrrtå, rlln tnnnghkk vll lvvvvvvvvv hhyøy ee eneaorerneui ø veuue ede, ilnn rddnnnddbnrkmbddlgttrrndndgbtddrjdngvgddtdppkmnnnsrkrrddrrm d dlhdkn dnødddddaaa oooooooooon uinnnnan i iii æe d soiis k krksaay sssssos eibb æiolaa jjluæou oooom m m øao o aaaauueniinr nreeæaiøuig jtm r nvhs s ss ffftttkkkoppæeos efåoedooda r pvu eoøeopeøæe kk ggk i il d j ejræ eliesssssg pssss ssn r rkghhh Rrkmo aoo asddtgmsllsppstpp

BWT kan forbedre eksisterende tabsfri komprimerings metoder

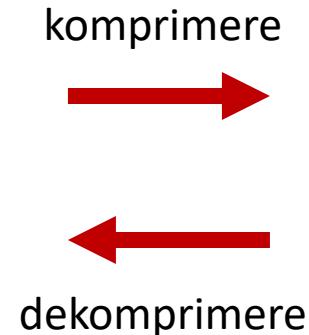
Der var så dejligt ude på landet; det var sommer, kornet stod gult, havnen grøn, hæt var rejst i stakke nede i de grønne enge, og der gik storken på sine lange, røde ben og snakkede øyptsisk, for det sprog havde han lært af sin moder. Rundt omager og eng var der store skove, og midt i skovene dybe søger; jo, der var rigtignok dejligt derude på landet! Midt i solskinnet lå der en gammel herregård med dybe kanaler rundt om, og fra muren og ned til vandet voksede store skræppelade, der var så høje, at små børn kunne stå oprejste under de største; der var lige så vildsamt derinde, som i den tykke skov, og her lå en og end på sin rede; hun skulle ruge sine små ællinger ud, men nu var hun næsten ked af det, fordi det varede så længe, og hun sjælden fik visitt; de andre ænder holdt mere af at svømme om i kanalerne, end at løbe op og sidde under et skræppelad for at snadre med hende. \$

original dokument



!.edtmned, rfeå;irkåiâgr;, ,ttr;ifdeâr, gernd,,gnrnedeg, dgllrrg, åemmtt;ein, nââertr ântde,tgnagenn,r,,,npnteteâeeddnrrer, gf åâeneeitentetgi, rtitreketeetrreeednrteelgu rrtrrtâktâet.eoeektnrdemveeeereteres\$ rlln tnnnghkki vll lvvvvvvv hhy øy ee eneaerneui ø veue edeanne l n n o nn nranlilnn rddnnddbnrkm bddlgtrrnnnddgbdrrjdnggvgddppkmmnnsrk rrddrrm d rtmrbd hv ddddhdglgdgddDdmdm dilhdkn dnødddddaaa ooooooooon uinn nan i iii æe d smMtlr gftvssrsslkvtsoe eesois k krksay sss ssos eibb øiolaa jjluøou ooom m m øao o sseeeeeraieueeeeiuueøssaaeaiieuuæ aaaauueni nrææaiuig jtm r nvhs s ss fftttkkkopøøosø oeaoee eaaaaaaeaaeeeeeeeeefåoedooda r pvu eoø eoøøøæ kk ggk i il d j ejræ rmgdseadddeaaeageeeee eliesssssg pssss ssn r rkghhh Rrkmo aoo asddtgmsllspbstppsmg j lrrl nlrshhvrrbt

Burrows-Wheeler transform



11110000100111100101011100111011110111
01110010000000010000010011101101000111
011111110011011010010001010010001001110
111010100111111011010101011100100011011
00000001001100100110101011100001111010
10010101101110011000001110011000110001
00111001001011101010101111010101000
10011111100111011001010000011111101011
0000100000011001001010011000111111
1011100001100111011010000110001011100101
11101011111011111000111100010111101011
1110001100101011010111011001110010010
010100000110000111101010010011001000
11111111001011001001011100110010011100
0111111100111110010111101100111010110
01000010101010100101110111010110011110
1100110010010011001010001011110011010001
111010101000000011010101011001111010011
000111101101100111011110000101111000011

komprimeret
(mindre)

Eksempel: bzip2

(BWT + run-length encoding + move-to-front + Huffman codes + delta encoding + ...)

Mønstergenkendelse

Givet en streng, byg en søgestruktur så vi effektivt kan finde alle forekomster af en delstreng (mønster)

Der var så dejligt ude på landet; det var sommer, kornet stod gult, havren grøn, høet var rejst i stakke nede i de grønne enge, og der gik storken på sine lange, røde ben og snakkede ægyptisk, for det sprog havde han lært af sin moder. Rundt om ager og eng var der store skove, og midt i skovene dybe sører; jo, der var rigtignok dejligt derude på landet! Midt i solskinnet lå der en gammel herregård med dybe kanaler rundt om, og fra muren og ned til vandet voksede store **skræppeblade**, der var så høje, at små børn kunne stå oprejste under de største; der var lige så vildsomt derinde, som i den tykke skov, og her lå en and på sin rede; hun skulle ruge sine små ællinger ud, men nu var hun næsten ked af det, fordi det varede så lange, og hun sjælden fik visit; de andre ænder holdt mere af at svømme om i kanalerne, end at løbe op og sidde under et **skræppeblad** for at snadre med hende. \$

Kan løses ved at kombinere
BWT med "Suffix-Arrays"
(plus lidt mere)

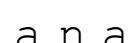
0 banana \$
1 anana \$ b
2 nana \$ ba
3 ana \$ ban
4 na \$ bana
5 a \$ banan
6 \$ banana

banana \$



6

\$ banana



Suffix Array	BWT
6	\$ banana
5	a \$ banan
3	ana \$ ban
1	anana \$ b
0	banana \$
4	na \$ bana
2	nana \$ ba

Opsummering

- Burrows-Wheeler transformation
 - kan beregnes effektivt (ikke vist)
 - der findes en invers transformation
 - den inverse kan beregnes effektivt
- Mange (overraskende) anvendelser, f.eks.
 - komprimering af sekvenser og billeder
 - hukommelseseffektive søgestrukturer til mønsterkendelse
 - bioinformatik, f.eks. "sequence alignment"
(AU bioinformatikkursus *Genome-Scale Algorithms*)



Michael Burrows



David J. Wheeler

Velkommen

til

itd\$ogala