

Algorithmen 2

Fortsetzung Übung Stringology

Florian Kurpicz

The slides are licensed under a Creative Commons Attribution-ShareAlike 4.0 International License © ⓘ ⓘ: www.creativecommons.org/licenses/by-sa/4.0 | commit cbff5ce compiled at 2024-01-16-14:11

Burrows-Wheeler-Transformation

Definition: Zyklische Rotation

Sei T ein Text der Länge n , dann ist die i -te **zyklische Rotation**

$$T^{(i)} = T[i..n]T[1..i]$$

- i -te zyklische Rotation ist die Konkatination des i -ten Suffixes und des $(i - 1)$ -ten prefixes

$T = \text{ababcabcabba\$}$

$T^{(1)}$	$T^{(2)}$	$T^{(3)}$	$T^{(4)}$	$T^{(5)}$	$T^{(6)}$	$T^{(7)}$	$T^{(8)}$	$T^{(9)}$	$T^{(10)}$	$T^{(11)}$	$T^{(12)}$	$T^{(13)}$
a	b	a	b	c	a	b	c	a	b	b	a	\$
b	a	b	c	a	b	c	a	b	b	a	\$	a
a	b	c	a	b	c	a	b	b	a	\$	a	b
b	c	a	b	c	a	b	b	a	\$	a	b	a
c	a	b	c	a	b	b	a	\$	a	b	a	b
a	b	c	a	b	b	a	\$	a	b	a	b	c
b	c	a	b	b	a	\$	a	b	a	b	c	a
c	a	b	b	a	\$	a	b	a	b	c	a	b
a	b	b	a	\$	a	b	a	b	c	a	b	c
b	b	a	\$	a	b	a	b	c	a	b	c	a
b	a	\$	a	b	a	b	c	a	b	c	a	b
a	\$	a	b	a	b	c	a	b	c	a	b	b
\$	a	b	a	b	c	a	b	c	a	b	b	a

Burrows-Wheeler-Transformation

Definition: Zyklische Rotation

Sei T ein Text der Länge n , dann ist die i -te **zyklische Rotation**

$$T^{(i)} = T[i..n]T[1..i]$$

- i -te zyklische Rotation ist die Konkatination des i -ten Suffixes und des $(i - 1)$ -ten prefixes

Definition: Burrows-Wheeler Transform (Alt.)

Sei T ein Text und M die Matrix, welche alle zyklischen Rotationen von T in lexikographischer Reihenfolge als **Spalten** enthält, dann ist die **BWT** die letzte **Zeile** von M

$T = \text{ababcabcabba\$}$

$T^{(1)} T^{(2)} T^{(3)} T^{(4)} T^{(5)} T^{(6)} T^{(7)} T^{(8)} T^{(9)} T^{(10)} T^{(11)} T^{(12)} T^{(13)}$

a	b	a	b	c	a	b	c	a	b	b	a	\$
b	a	b	c	a	b	c	a	b	b	a	\$	a
a	b	c	a	b	c	a	b	b	a	\$	a	b
b	c	a	b	c	a	b	b	a	\$	a	b	a
c	a	b	c	a	b	b	a	\$	a	b	a	b
a	b	c	a	b	b	a	\$	a	b	a	b	c
b	c	a	b	b	a	\$	a	b	a	b	c	a
c	a	b	b	a	\$	a	b	a	b	c	a	b
a	b	b	a	\$	a	b	a	b	c	a	b	c
b	b	a	\$	a	b	a	b	c	a	b	c	a
b	a	\$	a	b	a	b	c	a	b	c	a	b
a	\$	a	b	a	b	c	a	b	c	a	b	b
\$	a	b	a	b	c	a	b	c	a	b	b	a

Burrows-Wheeler-Transformation

Definition: Zyklische Rotation

Sei T ein Text der Länge n , dann ist die i -te **zyklische Rotation**

$$T^{(i)} = T[i..n]T[1..i]$$

- i -te zyklische Rotation ist die Konkatination des i -ten Suffixes und des $(i - 1)$ -ten prefixes

Definition: Burrows-Wheeler Transform (Alt.)

Sei T ein Text und M die Matrix, welche alle zyklischen Rotationen von T in lexikographischer Reihenfolge als **Spalten** enthält, dann ist die **BWT** die letzte **Zeile** von M

$T = \text{ababcabcabba\$}$

$T^{(13)} T^{(12)} T^{(1)} T^{(9)} T^{(6)} T^{(3)} T^{(11)} T^{(2)} T^{(10)} T^{(7)} T^{(4)} T^{(8)} T^{(5)}$

\$	a	a	a	a	a	b	b	b	b	b	c	c
a	\$	b	b	b	b	a	a	b	c	c	a	a
b	a	a	b	c	c	\$	b	a	a	a	b	b
a	b	b	a	a	a	a	c	\$	b	b	b	c
b	a	c	\$	b	b	b	a	a	b	c	a	a
c	b	a	a	b	c	a	b	b	a	a	\$	b
a	c	b	b	a	a	b	c	a	\$	b	a	b
b	a	c	a	\$	b	c	a	b	a	b	b	a
c	b	a	b	a	b	a	b	c	b	a	a	\$
a	c	b	c	b	a	b	b	a	a	\$	b	a
b	a	b	a	a	\$	c	a	b	b	a	c	b
b	b	a	b	b	a	a	\$	c	c	b	a	a
a	b	\$	c	c	b	b	a	a	a	a	b	b

Burrows-Wheeler-Transformation

Definition: Zyklische Rotation

Sei T ein Text der Länge n , dann ist die i -te **zyklische Rotation**

$$T^{(i)} = T[i..n]T[1..i]$$

- i -te zyklische Rotation ist die Konkatination des i -ten Suffixes und des $(i - 1)$ -ten prefixes

Definition: Burrows-Wheeler Transform (Alt.)

Sei T ein Text und M die Matrix, welche alle zyklischen Rotationen von T in lexikographischer Reihenfolge als **Spalten** enthält, dann ist die **BWT** die letzte **Zeile** von M

$T = \text{ababcabcabba}\$$

$T^{(13)} T^{(12)} T^{(1)} T^{(9)} T^{(6)} T^{(3)} T^{(11)} T^{(2)} T^{(10)} T^{(7)} T^{(4)} T^{(8)} T^{(5)}$

\$	a	a	a	a	a	b	b	b	b	b	c	c
a	\$	b	b	b	b	a	a	b	c	c	a	a
b	a	a	b	c	c	\$	b	a	a	a	b	b
a	b	b	a	a	a	a	c	\$	b	b	b	c
b	a	c	\$	b	b	b	a	a	b	c	a	a
c	b	a	a	b	c	a	b	b	a	a	\$	b
a	c	b	b	a	a	b	c	a	\$	b	a	b
b	a	c	a	\$	b	c	a	b	a	b	b	a
c	b	a	b	a	b	a	b	c	b	a	a	\$
a	c	b	c	b	a	b	b	a	a	\$	b	a
b	a	b	a	a	\$	c	a	b	b	a	c	b
b	b	a	b	b	a	a	\$	c	c	b	a	a
a	b	\$	c	c	b	b	a	a	a	a	b	b

Erste und Letzte Zeile

- zwei wichtige Zeilen in der Matrix
- es gibt eine spezielle Beziehung zwischen den beiden Zeilen
- alle anderen Zeilen werden nicht benötigt

Erste Zeile F

- enthält alle Zeichen von T in sortierter Reihenfolge

Letzte Zeile L

- ist die *BWT*

$T = \text{ababcabcabba\$}$

	$\tau(13)$	$\tau(12)$	$\tau(1)$	$\tau(9)$	$\tau(6)$	$\tau(3)$	$\tau(11)$	$\tau(2)$	$\tau(10)$	$\tau(7)$	$\tau(4)$	$\tau(8)$	$\tau(5)$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

Ränge der Zeichen

Definition: Rang (im Text)

Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen

$T = \text{ababcabcabba\$}$

	$T^{(13)}$	$T^{(12)}$	$T^{(1)}$	$T^{(9)}$	$T^{(6)}$	$T^{(3)}$	$T^{(11)}$	$T^{(2)}$	$T^{(10)}$	$T^{(7)}$	$T^{(4)}$	$T^{(8)}$	$T^{(5)}$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

Ränge der Zeichen

Definition: Rang (im Text)

Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen

T a b a b c a b c a b b a \$
 rang 1 1 2 2 1 3 3 2 4 4 5 5 1

$T = \text{ababcabcabba\$}$

	$T^{(13)}$	$T^{(12)}$	$T^{(1)}$	$T^{(9)}$	$T^{(6)}$	$T^{(3)}$	$T^{(11)}$	$T^{(2)}$	$T^{(10)}$	$T^{(7)}$	$T^{(4)}$	$T^{(8)}$	$T^{(5)}$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

Ränge der Zeichen

Definition: Rang (im Text)

Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

$T = \text{ababcabcabba\$}$

	$T^{(13)}$	$T^{(12)}$	$T^{(1)}$	$T^{(9)}$	$T^{(6)}$	$T^{(3)}$	$T^{(11)}$	$T^{(2)}$	$T^{(10)}$	$T^{(7)}$	$T^{(4)}$	$T^{(8)}$	$T^{(5)}$
F	\$	a	a	a	a	a	b	b	b	b	c	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

Ränge der Zeichen

Definition: Rang (im Text)

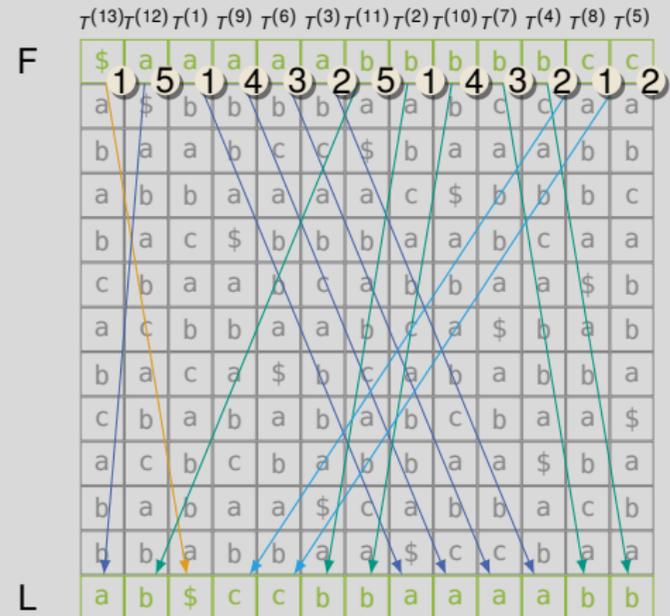
Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

$T = \text{ababcabcabba\$}$



Ränge der Zeichen

Definition: Rang (im Text)

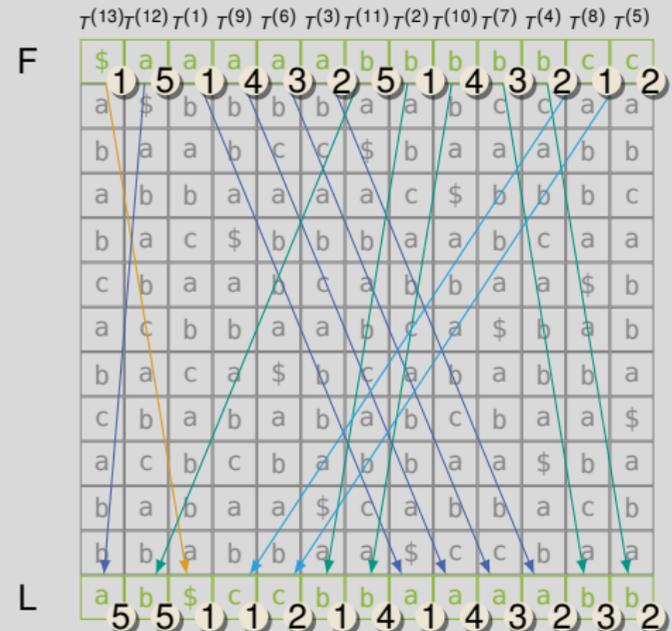
Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

$T = \text{ababcabcabba\$}$



Ränge der Zeichen

Definition: Rang (im Text)

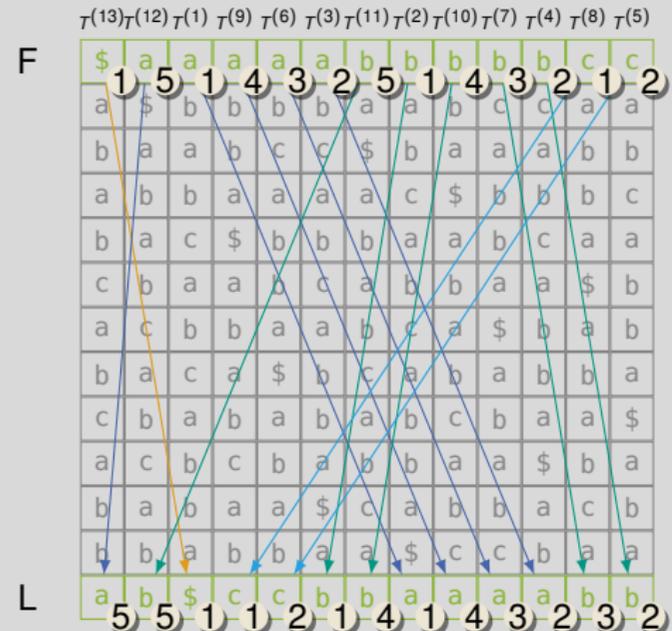
Sei T ein Text über dem Alphabet Σ , der **Rang** eines Zeichens an der Position $i \in [1, n]$ ist

$$\text{rang}(i) = |\{j \in [1, i]: T[i] = T[j]\}|$$

- der Rang entspricht der Anzahl gleicher Zeichen, die vorher im Text vorkommen
- für jedes Zeichen $\alpha \in \Sigma$ ist die Reihenfolge der Ränge in der ersten und letzten Zeile gleich

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

$T = \text{ababcabcabba\$}$



LF-Mapping (1/2)

- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: LF-Mapping

Sei T ein Text der Länge n und SA das Suffix-Array von T , dann ist das LF-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$

$T = \text{ababcabcabba\$}$

	$\tau(13)$	$\tau(12)$	$\tau(1)$	$\tau(9)$	$\tau(6)$	$\tau(3)$	$\tau(11)$	$\tau(2)$	$\tau(10)$	$\tau(7)$	$\tau(4)$	$\tau(8)$	$\tau(5)$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

LF-Mapping (1/2)

- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: LF-Mapping

Sei T ein Text der Länge n und SA das Suffix-Array von T , dann ist das LF-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$

$T = ababcabcabba\$$

	$\tau(13)$	$\tau(12)$	$\tau(1)$	$\tau(9)$	$\tau(6)$	$\tau(3)$	$\tau(11)$	$\tau(2)$	$\tau(10)$	$\tau(7)$	$\tau(4)$	$\tau(8)$	$\tau(5)$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	b	b	b	b	a	a	b	c	c	a	a	
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

LF-Mapping (1/2)

- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: *LF*-Mapping

Sei T ein Text der Länge n und SA das Suffix-Array von T , dann ist das *LF*-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$

$T = ababcabcabba\$$

	$\tau(13)$	$\tau(12)$	$\tau(1)$	$\tau(9)$	$\tau(6)$	$\tau(3)$	$\tau(11)$	$\tau(2)$	$\tau(10)$	$\tau(7)$	$\tau(4)$	$\tau(8)$	$\tau(5)$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	b	b	b	b	a	a	b	c	c	a	a	
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	a	a	b	c	a	a	
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

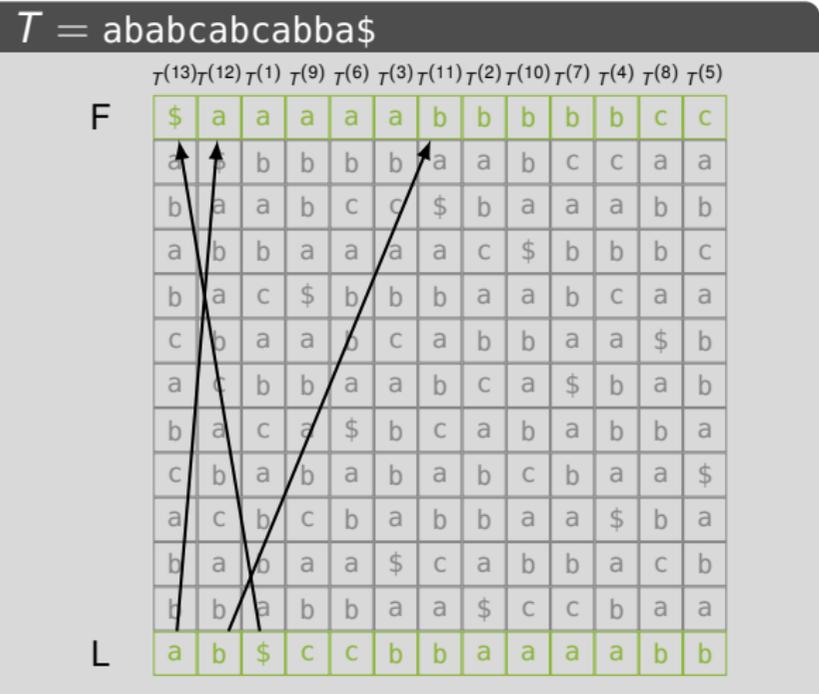
LF-Mapping (1/2)

- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: LF-Mapping

Sei T ein Text der Länge n und SA das Suffix-Array von T , dann ist das LF-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$



LF-Mapping (1/2)

- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: *LF*-Mapping

Sei T ein Text der Länge n und SA das Suffix-Array von T , dann ist das *LF*-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$

$T = ababcabcabba\$$

	$\tau(13)$	$\tau(12)$	$\tau(1)$	$\tau(9)$	$\tau(6)$	$\tau(3)$	$\tau(11)$	$\tau(2)$	$\tau(10)$	$\tau(7)$	$\tau(4)$	$\tau(8)$	$\tau(5)$
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	a	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	a	a	b	c	a	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b

LF-Mapping (1/2)

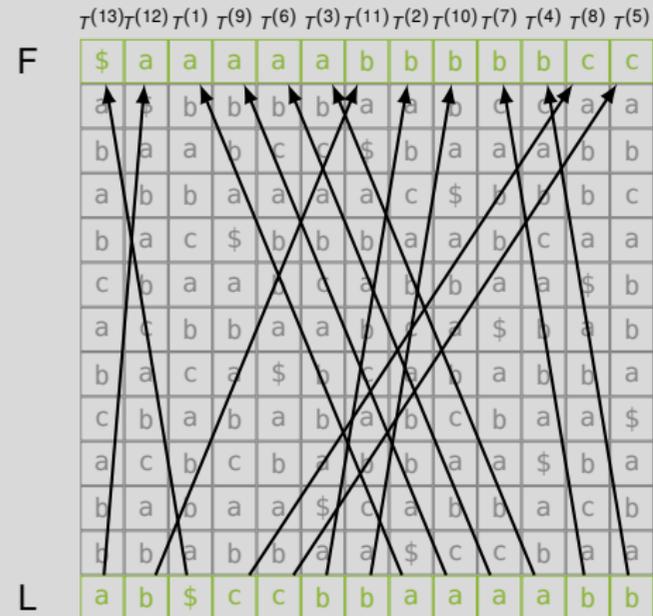
- wir möchten die Zeichen aus der letzten Zeile auf die erste Zeile abbilden
- warum?
 - ermöglicht Mustersuche
 - Transformation *BWT* zurück zu *T*

Definition: *LF*-Mapping

Sei *T* ein Text der Länge *n* und *SA* das Suffix-Array von *T*, dann ist das *LF*-Mapping eine Permutation von $[1, n]$, so dass

$$LF(i) = j \iff SA[j] = SA[i] - 1$$

T = ababcabcabba\$



LF-Mapping (2/2)

Definition: *C*-Array und *Rang*-Function

Sei T ein Text der Länge n über dem Alphabet Σ ,
 $\alpha \in \Sigma$ und $i \in [1, n]$, dann gilt

$$C[\alpha] = |\{i \in [1, n] : T[i] < \alpha\}|$$

und

$$\text{rang}_\alpha(i) = |\{j \in [1, i] : T[j] = \alpha\}|$$

- C enthält die absolute Anzahl kleinerer Zeichen
- rang_α enthält die Anzahl α s in Präfix $T[1..i]$

LF-Mapping (2/2)

Definition: *C*-Array und *Rang*-Function

Sei T ein Text der Länge n über dem Alphabet Σ ,
 $\alpha \in \Sigma$ und $i \in [1, n]$, dann gilt

$$C[\alpha] = |\{i \in [1, n] : T[i] < \alpha\}|$$

und

$$\text{rang}_\alpha(i) = |\{j \in [1, i] : T[j] = \alpha\}|$$

- C enthält die absolute Anzahl kleinerer Zeichen
- rang_α enthält die Anzahl α s in Präfix $T[1..i]$

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

- Ränge jetzt auf der *BWT*
- C ist exklusive Präfixsumme über Histogramm



LF-Mapping (2/2)

Definition: *C*-Array und *Rang*-Funktion

Sei T ein Text der Länge n über dem Alphabet Σ ,
 $\alpha \in \Sigma$ und $i \in [1, n]$, dann gilt

$$C[\alpha] = |\{i \in [1, n] : T[i] < \alpha\}|$$

und

$$\text{rang}_\alpha(i) = |\{j \in [1, i] : T[j] = \alpha\}|$$

- C enthält die absolute Anzahl kleinerer Zeichen
- rang_α enthält die Anzahl α s in Präfix $T[1..i]$

T	a	b	a	b	c	a	b	c	a	b	b	a	\$
rang	1	1	2	2	1	3	3	2	4	4	5	5	1

- Ränge jetzt auf der *BWT*
- C ist exklusive Präfixsumme über Histogramm



Definition: *LF*-Mapping (Alt.)

Gegeben die *BWT*, das *C*-array, und die *rang*-Funktion, dann gilt

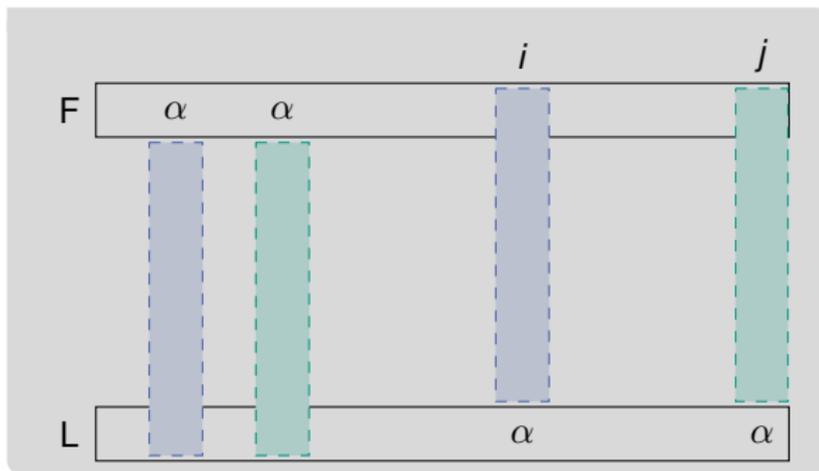
$$LF(i) = C[BWT[i]] + \text{rang}_{BWT[i]}(i)$$

Reversing the BWT (1/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

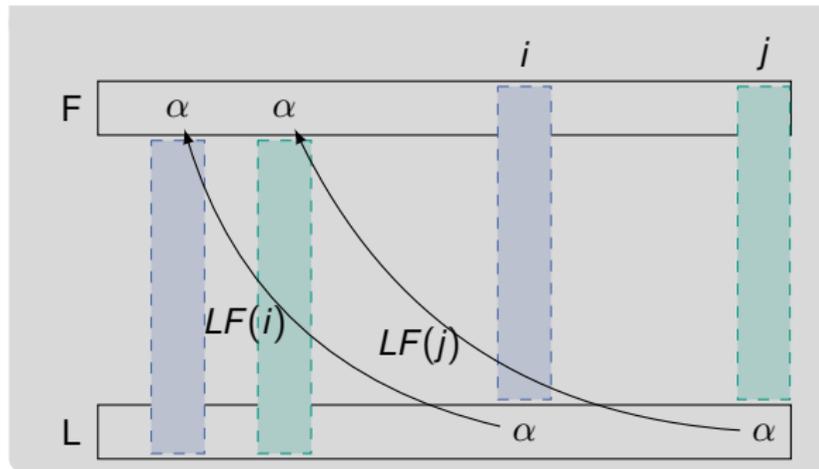
Reversing the BWT (1/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück



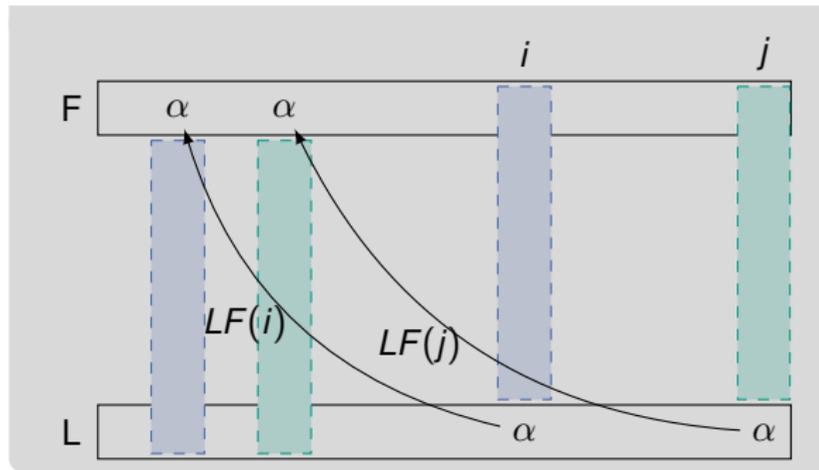
Reversing the BWT (1/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück



Reversing the BWT (1/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

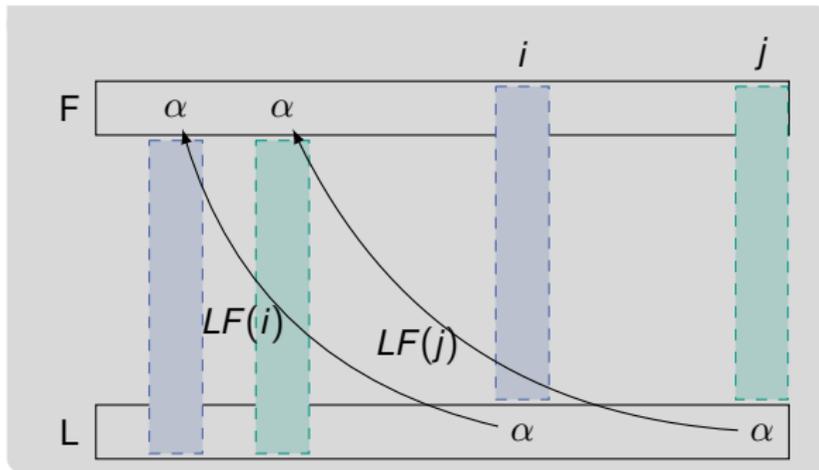


$T = ababcabcabba\$$

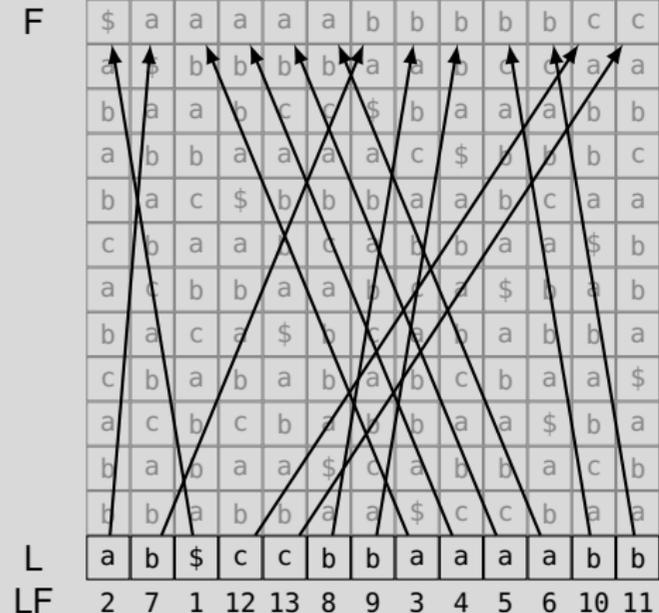
F	\$	a	a	a	a	a	b	b	b	b	b	c	c
	a	\$	b	b	b	b	a	a	b	c	c	a	a
	b	a	a	b	c	c	\$	b	a	a	a	b	b
	a	b	b	a	a	a	a	c	\$	b	b	b	c
	b	a	c	\$	b	b	b	a	a	b	c	a	a
	c	b	a	a	b	c	a	b	b	a	a	\$	b
	a	c	b	b	a	a	b	c	a	\$	b	a	b
	b	a	c	a	\$	b	c	a	b	a	b	b	a
	c	b	a	b	a	b	a	b	c	b	a	a	\$
	a	c	b	c	b	a	b	b	a	a	\$	b	a
	b	a	b	a	a	\$	c	a	b	b	a	c	b
	b	b	a	b	b	a	a	\$	c	c	b	a	a
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

Reversing the BWT (1/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück



$T = ababcabcabba\$$



Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}})]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$
- $T[11] = L[2] = b$ und $k = LF(2) = 7$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$
- $T[11] = L[2] = b$ und $k = LF(2) = 7$
- $T[10] = L[7] = b$ und $k = LF(7) = 9$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$
- $T[11] = L[2] = b$ und $k = LF(2) = 7$
- $T[10] = L[7] = b$ und $k = LF(7) = 9$
- $T[9] = L[9] = a$ und $k = LF(9) = 4$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}})]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$
- $T[11] = L[2] = b$ und $k = LF(2) = 7$
- $T[10] = L[7] = b$ und $k = LF(7) = 9$
- $T[9] = L[9] = a$ und $k = LF(9) = 4$
- $T[8] = L[4] = c$ und $k = LF(4) = 12$

Umkehrung der BWT (2/2)

- Zeichen (bzgl. Text) behalten Reihenfolge in L und F
- LF -Mapping gibt vorheriges Zeichen zurück

- $T[n] = \$$ und $T^{(n)}$ in erster Reihe
- wende LF -Mapping auf Ergebnis an und erhalte Zeichen

$$T[n - i] = L[\underbrace{LF(LF(\dots(LF(1))\dots))}_{i-1 \text{ times}}]$$

	1	2	3	4	5	6	7	8	9	0	11	12	13
L	a	b	\$	c	c	b	b	a	a	a	a	b	b
LF	2	7	1	12	13	8	9	3	4	5	6	10	11

- $T[13] = \$$ und $k = 1$
- $T[12] = L[1] = a$ und $k = LF(1) = 2$
- $T[11] = L[2] = b$ und $k = LF(2) = 7$
- $T[10] = L[7] = b$ und $k = LF(7) = 9$
- $T[9] = L[9] = a$ und $k = LF(9) = 4$
- $T[9] = L[4] = c$ und $k = LF(4) = 12$
- ...

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen
- $T = a^{n-1}$

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
 - Alphabet darf keine Rolle spielen
 - $T = a^{n-1}$
-
- Wie sieht die LZ78-Faktorisierung davon aus?

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
 - Alphabet darf keine Rolle spielen
 - $T = a^{n-1}$
-
- Wie sieht die LZ78-Faktorisierung davon aus?
 - $T = a|aa|aaa|\dots$

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen
- $T = a^{n-1}$

- Wie sieht die LZ78-Faktorisierung davon aus?
- $T = a|aa|aaa|\dots$

- Können wir das genauer sagen?

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen
- $T = a^{n-1}$

- Wie sieht die LZ78-Faktorisierung davon aus?
- $T = a|aa|aaa|\dots$

- Können wir das genauer sagen?

- $T = a|aa|aaa|\dots|a^{k-1}|a^k|a^{n-k(k+1)/2}$

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen
- $T = a^{n-1}\$$

- Wie sieht die LZ78-Faktorisierung davon aus?
- $T = a|aa|aaa|\dots$

- Können wir das genauer sagen?
- $T = a|aa|aaa|\dots|a^{k-1}|a^k|a^{n-k(k+1)/2}$
- für $k(k+1)/2 < n$

Eigenschaften von LZ78

Alte Klausuraufgabe

Zeigen Sie, dass die LZ78-Faktorisierung für einen Text der Länge n über einem konstanten Alphabet bis zu $\Theta(\sqrt{n})$ Faktoren erzeugt.

- Bei welchen Eingaben erzeugen wir möglichst viele Faktoren?
- Alphabet darf keine Rolle spielen
- $T = a^{n-1}\$$

- Wie sieht die LZ78-Faktorisierung davon aus?
- $T = a|aa|aaa|\dots$

- Können wir das genauer sagen?
- $T = a|aa|aaa|\dots|a^{k-1}|a^k|a^{n-k(k+1)/2}$
- für $k(k+1)/2 < n$
- also für $k \in \Theta(\sqrt{n})$