

Was kann das LCP-Array als Maß für die Komprimierbarkeit genutzt werden?

Überlegungen:

- Welche Texte sind gut komprimierbar?

↳ All-a-Text: $a|aa|a\dots|a \xrightarrow{LCP} (0, a)(1, n-1)$

↳ Texte mit vielen Wdh.: $\underbrace{abc\dots xyz}_a \alpha ade \alpha xyz \alpha$

- Welche Texte lassen sich nicht gut komprimieren?

↳ Texte mit wenigen Wdh. oder nur sehr kurzen Wdh.
 $\underbrace{abc}_{\alpha} \underbrace{ab}_{\beta} \underbrace{d}_{\gamma} \underbrace{abc}_{\alpha} \underbrace{abf}_{\delta} \dots$ Abspeichern der Faktoren kann teuer werden

→ Was bedeutet das für das LCP-Array

↳ All-a-Text: LCP: $n-1 | n-2 | n-3 | \dots | 0$

↳ Texten mit vielen Wdh.: $10|12|10|10|10|10|10|10|10|10| \dots$

↳ Wenige Wdh. $10|2|12|21| \dots$

Also etwas konkreter

↳ „Je höher die Summe der LCP-Werte ist, desto komprimierbarer sollte ein Text sein“
(evtl + Normierung durch die Länge des Textes)

↳ Was ist z.B. mit dem Maximum

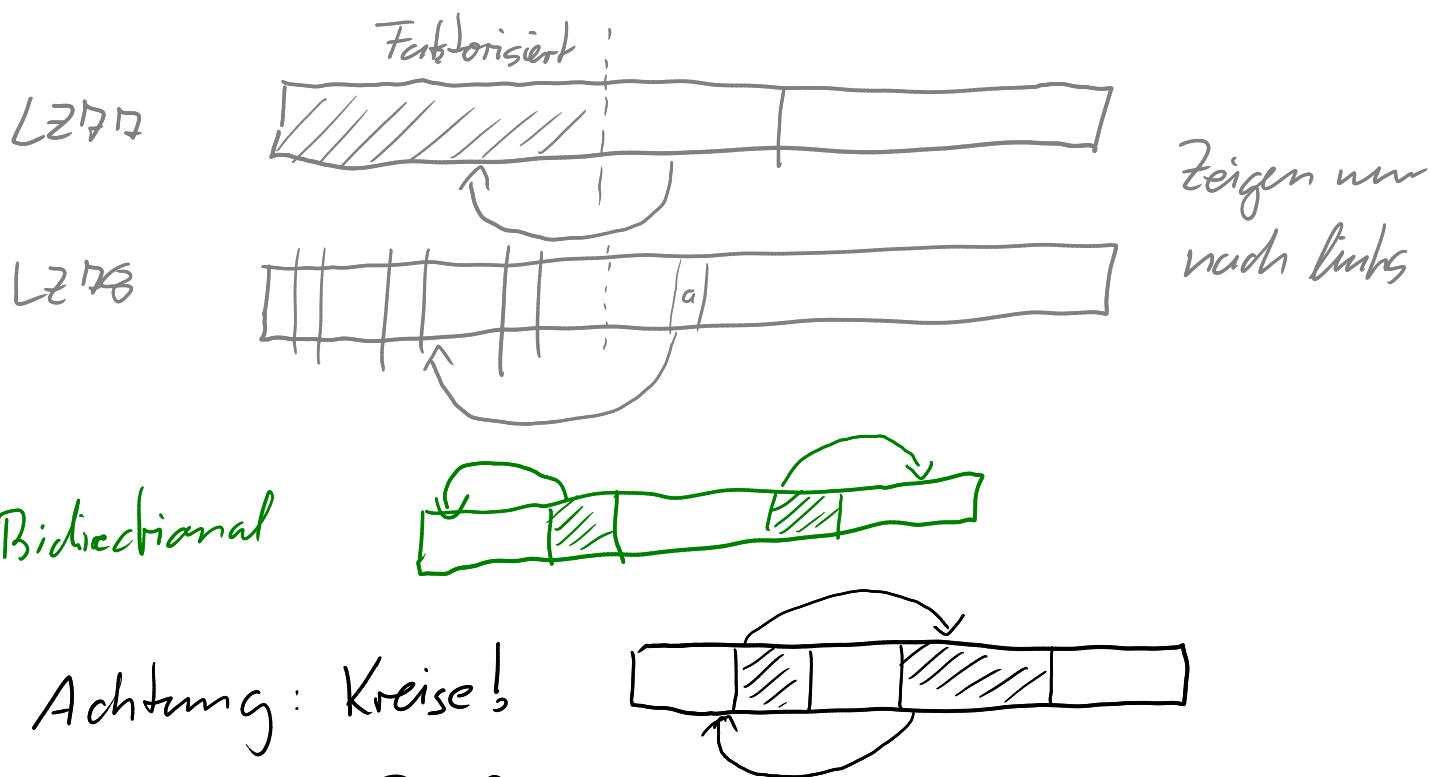
↳ $\underbrace{a\dots a}_{n/2} \underbrace{b\dots b}_{n/2}$

Das LCP-Array zum Komprimieren nutzen

Basierend auf „Bidirectional Text Compression in External Memory“, Dinklage et al. (ESA'19).

EM: ist uns egal (für diese Übung)

Bidirectional: Faktoren dürfen in beide Richtungen zeigen



Die Idee von PLCP-Comp

$$\text{PLCP}[\text{SA}[i]] = \text{LCP}[i]$$

↪ „LCP-Array in Textreihenfolge“

↪ Das PLCP-Array wird beim „engineering linear time“ - Algorithmen konstruiert



- ① Suche maximalen Wert im PLCP-Array
- ↳ Konstruiere aus diesem Wert einen Faktor
 - ↳ Faktorisieren ab Textpos. i : $(\phi[i], \underbrace{\text{PLCP}[i]}_{\substack{\text{Text-Pos.} \\ \text{Länge}}])$
- Mit wem möchte ich verglichen werden
- $$\phi[i] = SA[ISAC[i]-1]$$
- Hier kommen Faktoren in beide Richtungen zeigen
- Mit welchem Suffix kommt der LCP-Wort zustande

- ② PLCP-Array aktualisieren
- Alles was überdeckt ist löschen
 - Alles was ein Präfix von dem Faktor ist (*) muss reduziert werden (*)
- ③ Weiter bei ①, so lange sinnvolle Faktoren existieren

Die Implementierungen von LZ77 / LZ78

LZ77

Faktoren: Länge, Text Position (wenn Länge = 1, dann steht hier das Zeichen)

PSV :

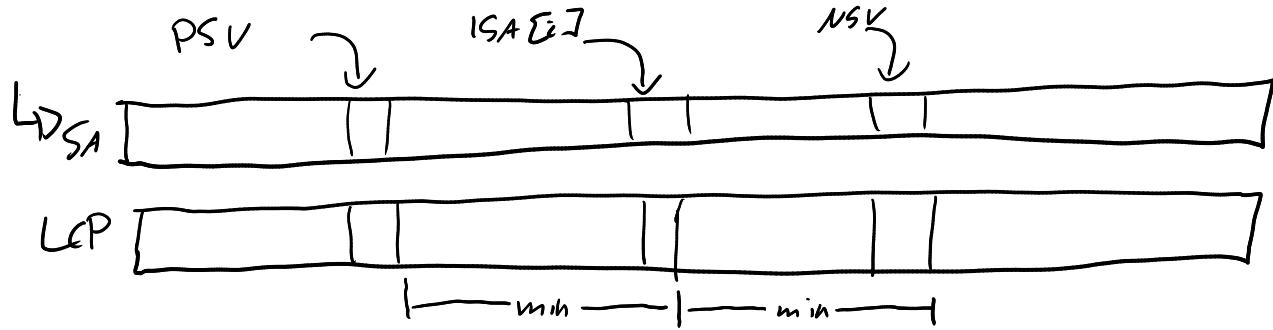
0	1	2	3	4
-1	-1	1	1	2

 ...

(NSV analog)

Berechnung der Faktoren

↳ i ist Textpos. ab der der nächste Faktor beg.



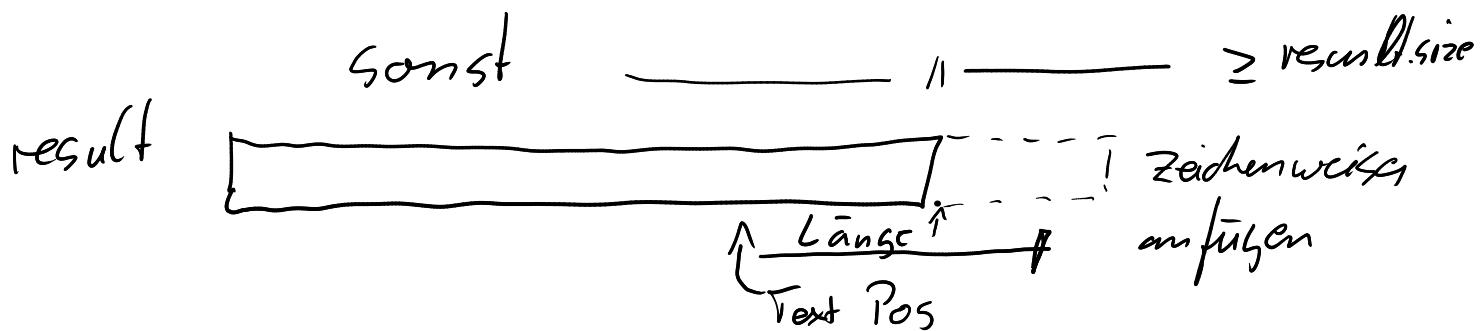
Struct LZ77 mit Konstruktor erlaubt Verwendung von emplace-back

↳ Konstruiert an der richtigen Stelle im Speicher

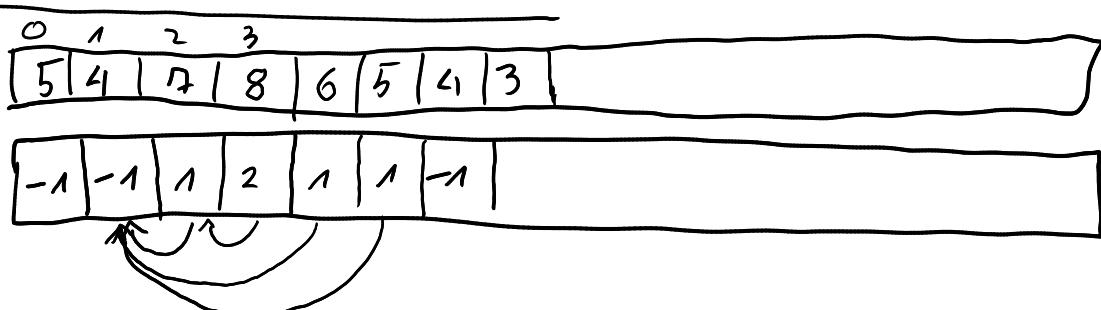
↳ Kann eine Kopie sparen

Beim Dekomprimieren

(1) Länge > 1 und factor.text_pos + factor.length < result.size



PSV in Linearcircit

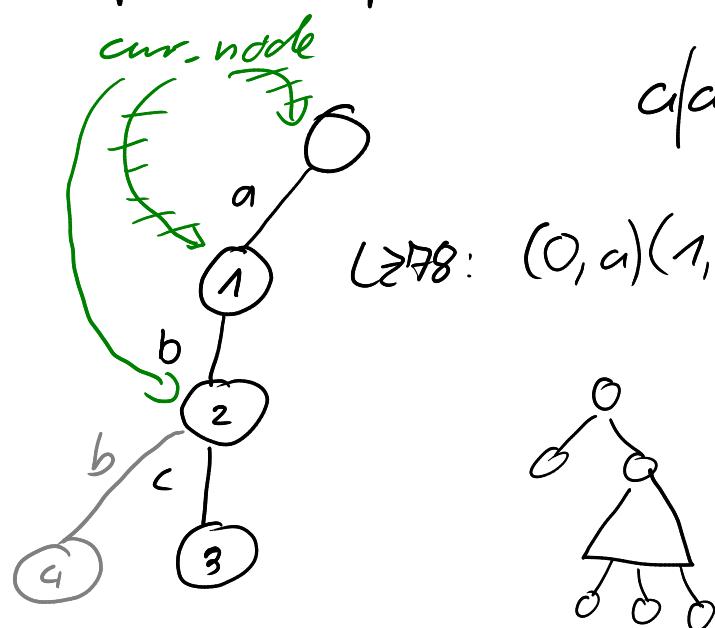


L 278

(als Zahl mit 1 beg.)

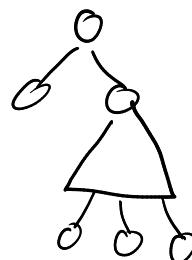
Faktoren: Referenz auf anderen Faktor, Zeichen

Ab(Cur):



a|ab|abc|abb

L 278: (0,a)(1,b)(2,c)(2,b)



Dekomprimieren

↳ Erzeuge Dictionary für alle Faktoren

Eingabe: Faktor-Nummer

Ausgabe: „String, den der Faktor hochst“
↳ Pfad von der Wurzel bis zum Knoten des Faktors

In der Implementierung geben wir
Textpos. + Länge zurück

Dict: $\{ \begin{matrix} 0 & 1 & 2 & 3 & 4 \\ \xi & (0,1) & (1,2) & (3,3) & (6,3) \end{matrix} \dots - (\quad) (\quad) \}$

0 1 2 3 4 5 6 7 8

result: a b a b c a b b