

Prüfe, ob es sich bei einem Array A der Länge n um ein Suffix-Array handelt (von T)

1. A ist eine Permutation der Zahlen $[0, n]$ ✓ Jedes Suffix muss genau einmal

im Suffix-Array vorkommen

2. Für alle i, j gilt

$$A^{-1}[i] \leq A^{-1}[j] \Leftrightarrow (T[i], A^{-1}[i+1]) \leq (T[j], A^{-1}[j+1])$$

Was bedeutet inverses SA? ($A[i]$)

↳ Wo steht T^i im SA

↳ Was kann daraus geschlossen werden?

↳ Wenn $A^{-1}[i] < A^{-1}[j]$ dann

$$T^i <_{\text{lex}} T^j$$

Beweis von 2.


Annahme: T^i und T^j sind zwei Suffixe mit
 $T^i >_{\text{lex}} T^j$ ABER $A^{-1}[i] < A^{-1}[j]$

Ugs.: "Wir haben mindestens zwei falsch eingesortierte Suffixe in unserem SA"

mit $i + j$ maximal

falls es mehrere falsch eingesortierte Suffixe gib ist das wichtig


Da $T^i >_{\text{lex}} T^j$ gilt entweder



① $T[i] > T[j] \rightarrow$ Widerspruch zur 2. Bedingung, denn $(T[i], \cdot) > (T[j], \cdot)$

② $T[i] = T[j]$ und

$$T^{i+1} >_{\text{lex}} T^{j+1}$$



$\rightarrow A^{-1}[i+1] > A^{-1}[j+1] \rightarrow$ hier ist die Maximalität von $i+1$ wichtig

\rightarrow Widerspruch zur 2. Bedingung, denn $(T[i], A^{-1}[i+1]) > (T[j], A^{-1}[j+1])$

$\frac{T}{T^j}$

Wir haben ein SA und wollen zeigen, dass 1. und 2. gilt.

1. Offensichtlich, da SA Permutation von $[0,n)$ ist

2. Wir haben alle Suffixe korrekt sortiert, d.h. wenn $T^i >_{\text{lex}} T^j$, dann ist $A^{-1}[i] > A^{-1}[j]$ und wenn

$A^{-1}[i] > A^{-1}[j]$ daraus folgen 2 Fälle

- ① $T[i] > T[j]$ also ist auch $(T[i], \cdot) > (T[j], \cdot)$
- ② $T[i] = T[j]$ und $T^{i+1} >_{\text{lex}} T^{j+1}$ also ist $(T[i], A^{-1}[i+1]) > (T[j], A^{-1}[j+1])$

→ Durch diese Eigenschaften können wir den SA-Check auf Sortieren reduzieren.
Besser als naiv mit quadratischer Laufzeit

Der Code

sa-tuples : $(\begin{smallmatrix} 0 \\ SA[0] \end{smallmatrix}) (\begin{smallmatrix} 1 \\ SA[1] \end{smallmatrix}) \dots (\begin{smallmatrix} n-1 \\ SA[n-1] \end{smallmatrix})$ sortiere nach 2. Komponente
 $(\begin{smallmatrix} SA^{-1}[0] \\ 0 \end{smallmatrix}) (\begin{smallmatrix} SA^{-1}[1] \\ 1 \end{smallmatrix}) \dots (\begin{smallmatrix} SA^{-1}[n-1] \\ n-1 \end{smallmatrix})$ Prüfe ob es sich um eine Permutation handelt



rhs : $(\begin{smallmatrix} SA^{-1}[0] \\ SA^{-1}[1] \\ T[0] \end{smallmatrix}), (\begin{smallmatrix} SA^{-1}[1] \\ SA^{-1}[2] \\ T[1] \end{smallmatrix}) \dots (\begin{smallmatrix} SA^{-1}[n-1] \\ 0 \\ T[n-1] \end{smallmatrix})$

Sortiere nach der i. Komponente dann überprüfe Zeichen und $SA^{-1}[i+1]$

SAIS-Code


- `std::vector::begin` → Pointer auf den Anfang
- nutzen `std::vector<bool>` um S-Suffixe zu markieren
 - ↳ Bitvektor (1 Bit pro Eintrag) → `types`
 - ↳ Enthält an Position i eine 1, wenn T^i ein S-Typ ist
 - ↳ Was ist mit den LMS-Suffixen (S^*)?
 - ① T^0 kann kein S^* sein
 - ② Für jedes LMS-Suffix gilt $\text{types}[i] \& \neg \text{types}[i]$
- nutzen `uint32_t::max` als Markierung
 - ↳ üblicher Trick, auch gern mit singed Integers hier dann negative Wert

- `fill_buckets` → gibt Gruppen zurück



- For-Schleifen können auf zwei Arten unterbrochen werden:
 - `break` → verlässt for-Schleife sofort
 - `continue` → macht sofort mit der nächsten Iteration weiter

- Verwende SA zum Speichern von Daten
↳ In jedem Aufruf max $n/2 = m$ LMS-Subst.



Im optimierten Code bei Klassifizierung

