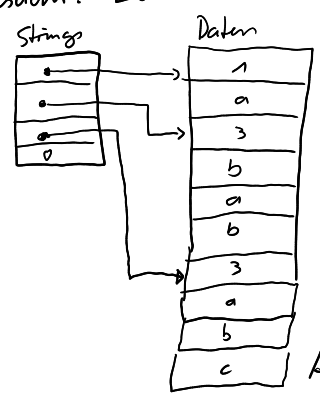


Wir möchten Strings in Zeit  $O(N + \sigma)$  sortieren  $\rightarrow$  Indizes beginnen bei 1!

Gegeben: Menge von Strings  $S = \{S_1, \dots, S_k\}$  der Längen  $n_i = |S_i|$  über einem Alphabet der Größe  $\sigma$ .

Wir definieren  $N := \sum n_i$  und sagen  $n_{max}$  die größte Länge ist

Gesucht: Lex. Sortierung der Strings



Idee: Fangen hinten an (LSD-Radix-Sort) und betrachten nur die Strings, die auch ein entsprechendes Zeichen haben.

z.B. 3  
1. 2  
1. 1



Das funktioniert weil kürzere Strings mit gleichem Präfix kleiner sind  $a <_{lex} abc$

"a", "bab", "abc"

Algorithmus besteht aus 3 Teilen:

- 1) Vorverarbeitung für das Alphabet
- 2) ——— für die Längen der Strings
- 3) Das eigentliche Sortieren

Schritt 1 - Identifikation der relevanten Zeichen in jeder Iteration

$\hookrightarrow$  Erzeuge Paare  $(l, S_i[l])$  für alle  $i \in [1, k]$  und  $l \in [1, n_i]$

In unserem Beispiel:  $(1, a), (1, b), (2, a), (3, b), (1, a), (2, b), (3, c)$

$\rightarrow$  Laufzeit für das Erzeugen:  $O(N)$  Zeit

$\hookrightarrow$  Sortiere Paare zunächst nach der 2. Komponente und anschließend stabil nach der 1. Komponente  $\rightarrow$  stabil: Wenn 2 Elemente den gleichen Schlüssel haben dann bleibt die Reihenfolge erhalten

Beispiel: 1.  $(1, a), (2, a), (1, a), (1, b), (3, b), (2, b), (3, c) \rightarrow O(N + \sigma)$  Zeit

2.  $(1, a), (1, a), (1, b), (2, a), (2, b), (3, b), (3, c) \rightarrow O(N)$  Zeit

$\rightarrow$  Laufzeit für das Sortieren:  $O(N + \sigma)$  Zeit

$\hookrightarrow$  NONEMPTY[l] enthält alle Zeichen, die als l-tes Zeichen in einem String vorkommen

Beispiel: NONEMPTY[1] = a, b  
NONEMPTY[2] = a, b  
NONEMPTY[3] = b, c

$\rightarrow$  Laufzeit für das Erstellen von NONEMPTY ist  $O(N)$  Zeit

Schritt 2 - Identifikation der relevanten Strings in jeder Iteration

$\hookrightarrow$  Erstelle Array LENGTH[l], welches Pointer auf die Strings der Länge l enthält

Beispiel: LENGTH[1] = "a" ! Nur Pointer, nicht die Strings selber!  
LENGTH[2] =  $\emptyset$   
LENGTH[3] = "bab", "abc"

$\rightarrow$  Laufzeit:  $O(N)$  Zeit da die max. Länge  $s_{max}$  und  $k$  durch  $O(N)$  abgeschätzt werden können

$\circledast$   $O(N_e)$  Zeit, wobei  $N_e$  die # der Strings ist mit  $n_i \geq l$

Schritt 3 - Sortieren

- Erstellen wir QUEUE (leer) für max. k Elemente  $\rightarrow O(N)$  Zeit
- Erstellen Q (leer) für  $\sigma$  Pointer  $\rightarrow O(\sigma)$  Zeit
- Für  $l = n_{max}$  bis 1 machen  $\rightarrow O(1)$  Zeit

$\hookrightarrow$  Füge LENGTH[l] vorne an QUEUE an  
 $\hookrightarrow$  So lange QUEUE nicht leer!

$\hookrightarrow$  Sei  $S_i$  das erste Element in QUEUE  
 $\hookrightarrow$  Entferne  $S_i$  aus QUEUE und füge es an  $Q[S_i[l]]$  an

$\hookrightarrow$  Für jedes j in NONEMPTY[l] mache  
 $\hookrightarrow$  Füge  $Q[j]$  hinten an QUEUE an  
 $\hookrightarrow$  Mache  $Q[j]$  leer

Alternativ führe Schleife \* unten zunächst für Strings in LENGTH[l] aus und dann für für QUEUE

ein Zeichen  $\circledast$

$O(\sigma_e)$  Zeit, wobei  $\sigma_e$  die # Zeichen in Länge l sind

⇒ Die Schleife wird  $\sigma_{\max}$  mal ausgeführt

→  $O\left(\sum_{k=1}^{\sigma_{\max}} (N_k + \sigma_k)\right)$  → Wir sehen in Summe  $\max N$  verschiedene Zeichen  
=  $O(N)$  → Wir gucken uns die Strings in Summe  $N$  mal an

⇒ Der Alg. hat eine Laufzeit von  $O(N + \sigma)$ .

→ Wir haben alles initialisiert und dann, ...

→ starte mit Länge 3 → Füge  $LENGTH[3] = "bab"$  und  $"abc"$  vorne an QUEUE an


↳  $Q[b] = "bab"$   
 $Q[c] = "abc"$  →  $QUEUE = "bab", "abc"$

→ weiter mit Länge 2 → Füge  $LENGTH[2]$  von QUEUE an

↳  $Q[a] = "bab"$   
 $Q[b] = "abc"$  →  $QUEUE = "bab", "abc"$

→ ende mit Länge 1 → Füge  $LENGTH[1] = "a"$  vorne an QUEUE an

↳  $Q[a] = "a", "abc"$   
 $Q[b] = "bab"$  →  $QUEUE = "a", "abc", "bab"$



Idee Präfix-Doubling  
 ist wichtig, nicht  
 die konkrete Variante  
 des Algorithmus.

Lambda - Funktionen

```
void foo (...) { // Body
```

```
int d = 12;
auto add = [d](int a, int b) {
    return a + b;
};
```


*Annotations: [d] is labeled 'Capture', (int a, int b) is labeled 'Parameter', and return a + b; is labeled 'Body'.*

```
class point {
    int x;
    int y;
};
```

alternativ Operation überladen

```
std::vector<point> data; // voll mit Daten
std::sort(data.begin(), data.end()); // sortierung nach Default - vom Datentyp
```

```
std::sort(data.begin(), data.end(),
    [](const point& a, const point& b) {
        if (a.x == b.x) {
            return a.y < b.y;
        }
        return a.x < b.x;
    });
```



std::sort benötigt "echt kleiner" Vergleich