Technische Universität München
Institut für Informatik
Lehrstuhl für Effiziente Algorithmen
Prof. Dr. Ernst W. Mayr
Dmytro Chibisov
Stefan Eckhardt
Hanjo Täubig

WS 2007/08
Aufgabenblatt 7
7. Januar 2008

Praktikum Algorithmen-Entwurf

(Abgabetermin: **Montag, den 7.01.2008,** 14.^{00}Uhr)

Suchen in Texten

Aufgabe 1 Suffix-Arrays

Schreiben Sie ein Programm, das für einen Eingabetext X der Länge n direkt einen Suffix Array in linear-logarithmischer Zeit $O(n \log n)$ konstruiert und dabei möglichst wenig Speicher verbraucht. Schreiben Sie weiterhin den Such-Algorithmus, um damit für Muster Y der Länge m in Zeit $O(m \log n)$ zu prüfen, ob das Muster im Text vorkommt. Falls das Muster vorkommt, soll die Anzahl der Vorkommen sowie die Position des lexikographisch kleinsten und des lexikographisch größten Vorkommens ausgegeben werden. Damit sind die Positionen gemeint, deren Suffix lexikographisch am kleinsten bzw. am größten ist. Dies entspricht den Einträgen, die man mit der binären Suche im Array **pos** findet.

Ihr Programm muß ohne Zuhilfenahme der LEDA-Bibliothek implementiert werden. Die Laufzeit für die Konstruktion des Suffix Arrays sowie die Laufzeit für die Bearbeitung jedes einzelnen Musters soll ausgegeben werden. Prüfen Sie anhand der ausgegebenen Zeiten, ob die Laufzeit Ihrer Implementierung tatsächlich linear mit der Textlänge bzw. mit der Musterlänge wächst.

Der Eingabetext besteht aus beliebigen ASCII-Zeichen (Typ `char`), die Alphabet-Größe ist also 256. Das Zeichen `$` ist das Schlußzeichen und kommt ausschließlich am Ende des Textes vor. Die Beispieleingaben stehen in den Text-Dateien `text1.txt` bis `text6.txt` bzw. in den Muster-Dateien `text1.pat` bis `text6.pat` (sowie die zugehörigen korrekten Ausgaben in `text1.sol` bis `text6.sol`) im WWW zur Verfügung. Jede Textdatei enthält einen Text, abgeschlossen mit `$`. Die Muster-Dateien enthalten eine Reihe von Mustern, die jeweils von einem `$` und einem Zeilenvorschub gefolgt sind. Ihr Programm bekommt den Namen der Eingabedatei und der Muster-Datei als Kommandozeilen-Parameter, die Ausgabe soll auf den Bildschirm erfolgen.

Hinweise

Beachten Sie das Beispiel für eine korrekte Ausgabe des Algorithmus auf der Rückseite dieses Aufgaben-Blattes.

Beispiel für Eingabe und Ausgabe des Algorithmus

Eingabe:

```
Heute programmieren wir
einen Algorithmus zur
Suche in Texten.$
te$
wir
ein$
xx$
```

Ausgabe:

```
Suffix-Array: Zeit 0.000238 Sek
Muster 1: 2 Vorkommen
          lex. kleinste Pos. 4, lex. groesste Pos. 59
          Zeit: 0.000012 Sek
Muster 2: 1 Vorkommen
          lex. kleinste Pos. 21, lex. groesste Pos. 21
          Zeit: 0.000006 Sek
Muster 3: 0 Vorkommen
          Zeit: 0.000002 Sek
```