

Übungen zur Vorlesung Sequenzanalyse

Universität Bielefeld, SS 2020

Prof. Dr. Jens Stoye · Dr. Marília D. V. Braga · Leonie R. Brockmann · Rebecca K. Pfeil

<https://gi.cebitec.uni-bielefeld.de/teaching/2020summer/sa>

Übungsblatt 8 vom 11.6.2020

Abgabe am 18.6.2020 bis 12:00 Uhr (mittags)

Aufgabe 1 (Links-Rechts-Partition)

(4 Punkte)

Die Links-Rechts-Partition $P_{lr}(s, t)$ einer Sequenz s bezüglich einer Sequenz t (siehe Abschnitt 3.8 im Skript) kann mit Hilfe eines Suffixbaums effizient berechnet werden.

- Überlege dir einen Algorithmus, der die Links-Rechts-Partition $P_{lr}(s, t)$ in linearer Zeit berechnet. (Hinweis: Verwende den Suffixbaum von t .) Gib die einzelnen Schritte deines Algorithmus' explizit und verständlich an.
- Verwende diesen Algorithmus, um $P_{lr}(s, t)$ für $s = \text{ABCCDBAABA}$ und $t = \text{BAABC}$ zu berechnen. Gib alle Zwischenschritte an.

Aufgabe 2 (Suffixbaum-Anwendungen)

(8 Punkte)

Gegeben sei die Sequenz $s = \text{CATAGCATATAG}$.

- Berechne den Suffixbaum von s . Sortiere dabei die von einem Knoten ausgehenden Kanten lexikographisch (mit $\$ < \text{A} < \text{C} < \text{G} < \text{T}$).
- Kürzeste eindeutige Substrings:
 - Finde alle eindeutigen Substrings in s mit Hilfe des Suffixbaums von s . Welche sind die kürzesten eindeutigen Substrings?
 - Beschreibe eine mögliche Anwendung für kürzeste eindeutige Substrings.
- Maximale Repeats:
 - Finde alle maximalen Repeats in s mit Hilfe des Suffixbaums von s . Gib alle Zwischenschritte des verwendeten Algorithmus' an.
 - Satz:** In jedem String der Länge n gibt es höchstens n Teilworte, die maximale Repeats sind. Argumentiere unter Berücksichtigung des Suffixbaums, warum diese Aussage korrekt ist.

Aufgabe 3 (Anwendungen des generalisierten Suffixbaums)

(8 Punkte)

Gegeben seien die Sequenzen $s = \text{TTCATAGTTC}$ und $t = \text{CATCATATAG}$.

- Berechne den generalisierten Suffixbaum T von s und t . Sortiere dabei die von einem Knoten ausgehenden Kanten lexikographisch (mit $\# < \$ < \text{A} < \text{C} < \text{G} < \text{T}$).
- Maximale gemeinsame Substrings (MEMs) mit Mindestlänge ℓ zweier Sequenzen s und t sind maximale Repeats in $s\#t$, von denen je ein Vorkommen in s und ein Vorkommen in t liegt, und die mindestens ℓ Zeichen lang sind.

Verwende den in Aufgabenteil 1 erstellten verallgemeinerten Suffixbaum T , um alle MEMs mit Mindestlänge $\ell = 2$ von s und t zu finden. Gehe dafür wie folgt vor:

- Finde Kandidaten: Markiere jeden inneren Knoten v von T , für den gilt:
 - Die String-Tiefe von v muss mindestens $\ell = 2$ betragen.
 - Der Teilbaum unter v enthält mindestens ein Blatt, das ein in s beginnendes Suffix repräsentiert und mindestens ein Blatt, das ein in t beginnendes Suffix repräsentiert.
 - Gib für jeden dieser Kandidaten v alle Vorkommen (Start- und Endpositionen) von $\text{string}(v)$ in s und in t an.
 - Welche Paare dieser Vorkommen sind maximal und repräsentieren daher MEMs von s und t ?
- Welche MEMs sind auch MUMs von s und t mit Mindestlänge $\ell = 2$?
 - Modifiziere den Algorithmus von Aufgabenteil 2, um direkt MUMs zu finden, ohne den Umweg über MEMs. Welche innere Knoten sind Kandidaten für MUMs der Mindestlänge 2?