

Algorithmen zur Sequenzanalyse

Wintersemester 2017/2018
Besprechung am 26.01.2018

Übungsblatt 6

Prof. Dr. E. Ohlebusch,
Institut für Theoretische Informatik

Aufgabe 6.1.

Berechnen Sie mit Hilfe von Algorithmus 27 im Skript das LCP-Array für den String $S = \text{annasanannas\$}$. Die Burrows-Wheeler-Transformierte von S ist $\text{BWT} = \text{ssn\$nnannnaaaa}$.

Aufgabe 6.2.

Die Burrows-Wheeler-Transformationen der Strings S und S^{rev} sind jeweils in einem Wavelet-Baum gespeichert, siehe Abbildungen 1 und 2. Ermitteln Sie mittels Algorithmus 29 im Skript, wie oft der String GTA in S vorkommt.

Aufgabe 6.3.

Erweitern Sie die Vorkommen (beginnend mit den gefundenen Vorkommen aus Aufgabe 2) jeweils mit einem Rückwärtssuchschritt um den Buchstaben c und versuchen Sie mit einem Vorwärtssuchschritt das Muster auf der anderen Seite mit dem Watson-Crick-Komplement von c zu erweitern. Wie lautet das längste Muster, dass Sie auf diese Weise finden können? Die Watson-Crick-Paarungen sind $A-T$ und $C-G$.

Aufgabe 6.4.

Die Zeitkomplexität eines Suchschrittes mittels Algorithmus 29 im Skript wird durch die Zeitkomplexität des Aufrufes der Prozedur $getBounds$ bestimmt. Die Ausführung von $getBounds$ erfordert $O(\log \sigma)$ Zeit, wenn man den Wavelet-Baum benutzt (Algorithmus 28 im Skript). Geben Sie eine Implementierung von $getBounds$ an, die mehr Platz als der Wavelet-Baum (nämlich $O(n\sigma)$ Bits) benötigt, sodass $getBounds$ in $O(1)$ Zeit ausgeführt werden kann.

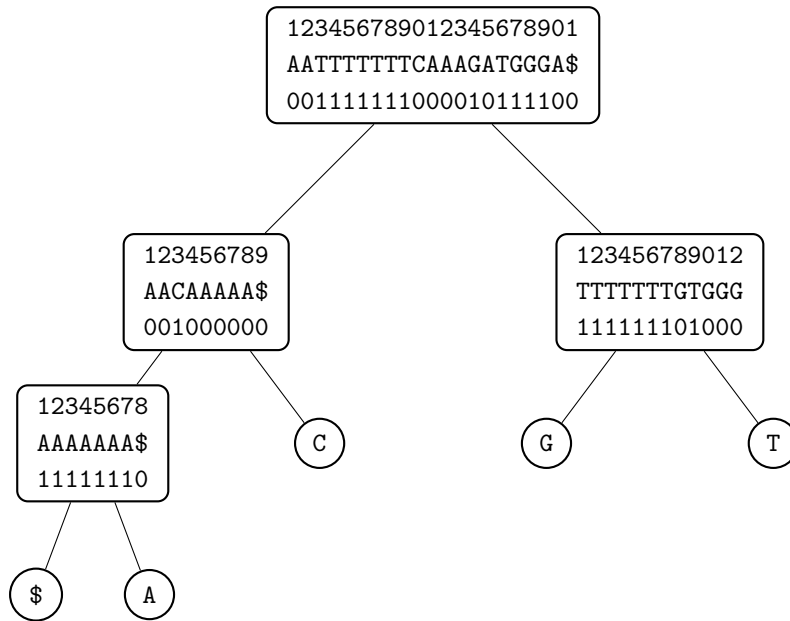


Abbildung 1: Wavelet-Baum von *AATTTTTTCAAAGATGGGA\$*

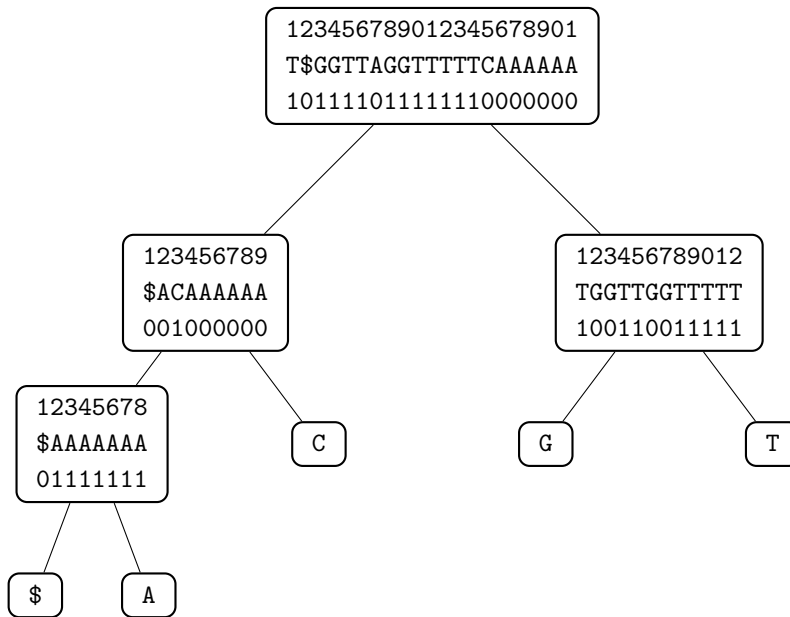


Abbildung 2: Wavelet-Baum von *T\$GGTTAGGTTTTCAAAAAA*