

Aufgabe 1 (8 Punkte)

Gib das Master-Theorem aus der **Vorlesung** an. Spezifiziere hierzu insbesondere die drei verschiedenen Fälle und gib an, welche Lösung der jeweilige Fall besitzt.

Bestimme die Asymptotik von $T(n)$ mithilfe des Master-Theorems aus der **Vorlesung** unter Angabe einer der drei Fälle (siehe oben) mit Begründung bzw. begründe, warum das Master-Theorem nicht anwendbar ist. Es gilt dabei immer $T(1) = 1$:

- a) $T(n) = 8 \cdot T(n/4) + n\sqrt{n}$.
 b) $T(n) = 3 \cdot T(n/4) + n \log(n)$.
 c) $T(n) = 4 \cdot T(n/2) + n^2 / \log(n)$.

Lösungsskizze

Seien $a, b, d \in \mathbb{N}$ mit $b > 1$, sei $f(n)$ eine Funktion und sei $\mathcal{C}(n)$ definiert durch die Rekursionsgleichung $\mathcal{C}(n) = a \cdot \mathcal{C}(n/b) + f(n)$ für $n > 1$ und $\mathcal{C}(1) = d$. Dann gilt:

$$\mathcal{C}(n) = \begin{cases} \Theta(n^{\log_b(a)}) & \text{falls } f(n) = O(n^{\log_b(a)-e}) \text{ für ein konstantes } e > 0 \\ \Theta(n^{\log_b(a)} \log(n)) & \text{falls } f(n) = \Theta(n^{\log_b(a)}) \\ \Theta(f(n)) & \text{falls } f(n) = \Omega(n^{\log_b(a)+e}) \text{ für ein konstantes } e > 0 \\ & \text{und } a \cdot f(n/b) \leq c \cdot f(n) \text{ für ein konstantes } c < 1 \end{cases}$$

- a) Für das Master-Theorem erhalten wir $a = 8$, $b = 4$ und $f(n) = \sqrt{n}$. Es gilt dann $\log_4(8) = \frac{\log_2(8)}{\log_2(4)} = \frac{3}{2}$ und somit $f(n) = n\sqrt{n} = n^{3/2} = \Theta(n^{\log_4(8)}) = \Theta(n^{\log_b(a)})$. Also gilt der zweite Fall des Master-Theorems und $T(n) = \Theta(f(n) \log(n)) = \Theta(n\sqrt{n} \log(n))$.
- b) Für das Master-Theorem erhalten wir $a = 3$, $b = 4$ und $f(n) = n \log(n)$. Es gilt $\log_4(3) \in (0, 1)$ und somit $f(n) = n \log(n) = \Omega(n^{\log_4(3)+e}) = \Omega(n^{\log_b(a)+e})$ für ein geeignetes $e \in (0, 1 - \log_4(3))$. Weiter ist

$$a \cdot f(n/b) = 3 \cdot \frac{n}{4} \log\left(\frac{n}{4}\right) \leq \frac{3}{4} \cdot n \log(n) \stackrel{!}{\leq} c \cdot f(n)$$

und somit gilt der dritte Fall des Master-Theorems mit $c = \frac{3}{4} < 1$. Damit gilt $T(n) = \Theta(f(n)) = \Theta(n \log(n))$.

- c) Für das Master-Theorem erhalten wir $a = 4$, $b = 2$ und $f(n) = n^2 / \log(n)$. Somit ist $\log_b(a) = \log_2(4) = 2$ und $f(n) = o(n^2)$. Es gilt weder

$$f(n) = n^2 / \log(n) = \Omega(n^{2+e}) = O(n^{\log_b(a)+e})$$

für ein $e > 0$ noch

$$f(n) = n^2 / \log(n) = \Theta(n^2) = \Theta(n^{\log_b(a)})$$

noch

$$f(n) = n^2 / \log(n) = O(n^{2-e}) = O(n^{\log_b(a)-e})$$

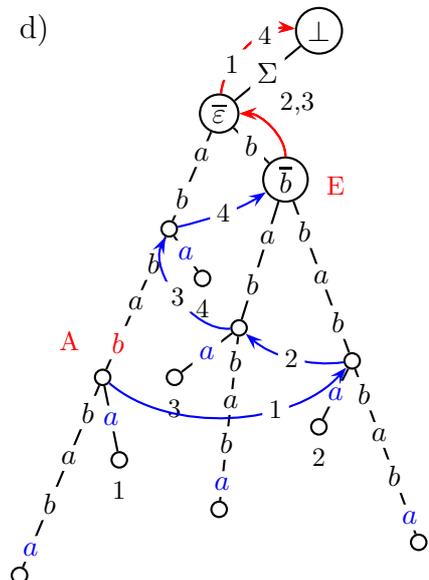
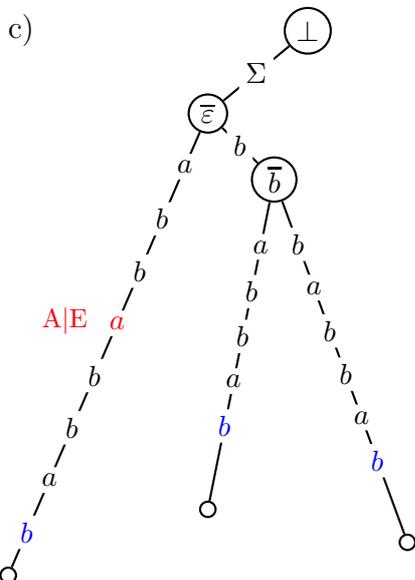
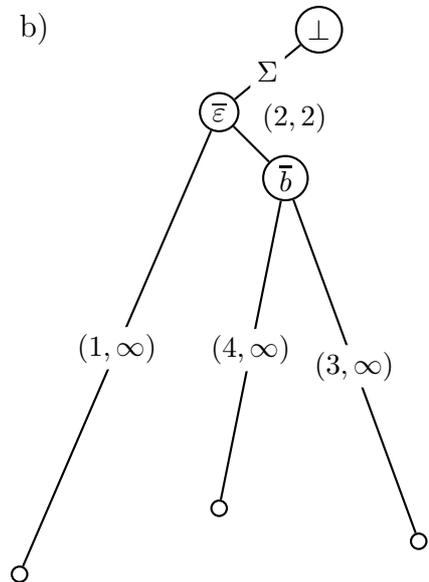
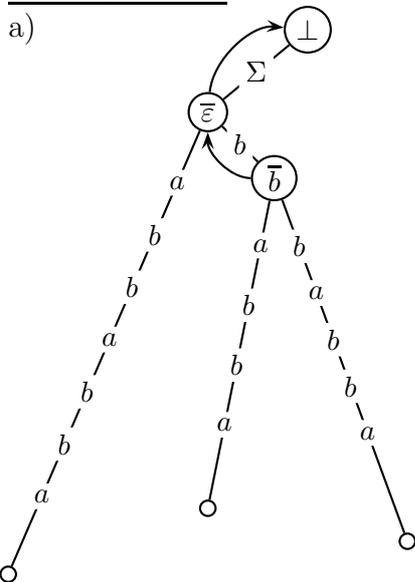
für ein $e > 0$, da $\log(n) = o(n^e)$ für alle $e > 0$ und somit $\frac{1}{\log(n)} = \omega(n^{-e})$.

Aufgabe 2 (8 Punkte)

Betrachte den unter a) abgebildeten Suffix-Baum für $s = s_1 \cdots s_7 = abbabba$. Der besseren Lesbarkeit wegen sind hierbei immer explizit die Kantenlabels statt der Referenzen angegeben.

- Zeichne alle Suffix-Links ein, die Ukkonens Algorithmus hierfür konstruiert hat.
- Gib die Kantenlabels so an, wie sie in Ukkonens Algorithmus verwendet werden.
- Führe Ukkonens Algorithmus für den Übergang von s auf $s' = s \cdot b = abbabbab$ aus. Gib für c) und d) alle Zwischenschritte an, markiere insbesondere die Position des aktiven Knotens und Endknotens im jeweiligen Suffix-Baum. Zeichne dabei nur die verwendeten und neu eingetragenen Suffix-Links mit jeweils einer anderen Farbe ein und nummeriere die neuen Blätter in der Reihenfolge der Einfügung.

Lösungsskizze



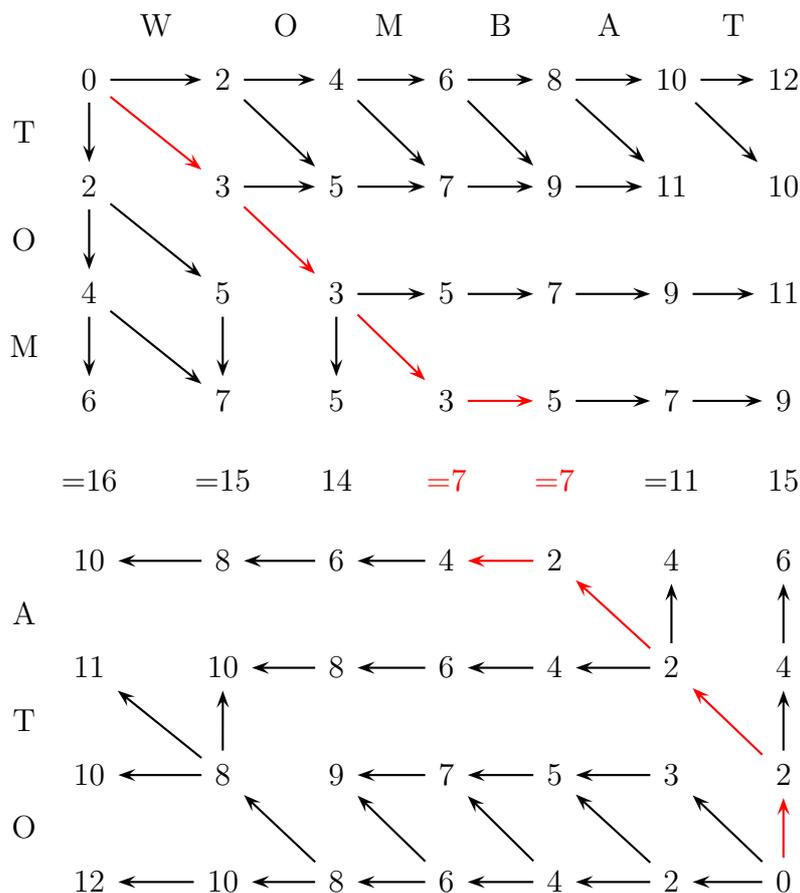
Aufgabe 3 (8 Punkte)

Betrachte die Wörter $s = \text{TOMATO}$ und $t = \text{WOMBAT}$. Berechne den ersten Schritt des Hirschberg-Algorithmus bei einem globalen Sequenzen-Alignment für s und t zur Rekonstruktion des Tracebacks. Bestimme insbesondere den bzw. die Schnittpunkte der Wörter s und t , d.h. die Teilwörter, für die der Hirschberg-Algorithmus rekursiv aufgerufen wird und gib das bzw. die zugehörigen Alignments an.

Zeichne dabei in der Tabelle auch die Traceback-Pfeile ein (die vom Hirschberg-Algorithmus nicht verwendet werden).

Die Kostenfunktion für ein Distanzmaß sei dabei mit 0 für ein Match, mit 3 für eine Substitution und mit 2 für eine Indel-Operation gegeben.

Lösungsskizze



Damit liegt der Schnittpunkt bei $(3, 3)$, d.h. $TOM|ATO$ versus $WOM|BAT$, oder $(3, 4)$, d.h. $TOM|ATO$ versus $WOMB|AT$.

Die beiden Alignments lauten gleich:

$$\left(\begin{array}{c} TOM-ATO \\ WOMBAT- \end{array} \right).$$

Aufgabe 4 (8 Punkte)

Löse die folgende Rekursionsgleichung **mit Hilfe von erzeugenden Funktionen**:

$$f_n = 3 \cdot f_{n-1} + 1 \quad \text{für } n \geq 1, \quad \text{und} \quad f_0 = 1.$$

Erinnerung: Für $a \in \mathbb{R}$ mit $|z| < |1/a|$ gilt $\frac{1}{1-az} = \sum_{n=0}^{\infty} (az)^n$.

Für zwei Folgen a_n und b_n gilt das Cauchy-Produkt: $\sum_{n=0}^{\infty} a_n \cdot \sum_{n=0}^{\infty} b_n = \sum_{n=0}^{\infty} \sum_{k=0}^n a_k \cdot b_{n-k}$.

Lösungsskizze

Es gilt:

$$\begin{aligned} F(z) &= \sum_{n=0}^{\infty} f_n z^n \\ &= f_0 + \sum_{n=1}^{\infty} f_n z^n \\ &= 1 + \sum_{n=1}^{\infty} (3 \cdot f_{n-1} + 1) z^n \\ &= 3 \sum_{n=0}^{\infty} f_n z^{n+1} + 1 + \sum_{n=1}^{\infty} z^n \\ &= 3z \sum_{n=0}^{\infty} f_n z^n + \sum_{n=0}^{\infty} z^n \\ &= 3z \cdot F(z) + \sum_{n=0}^{\infty} z^n. \end{aligned}$$

Also gilt $F(z) [1 - 3z] = \sum_{n=0}^{\infty} z^n$ und somit für $|z| < 1$:

$$\begin{aligned} F(z) &= \frac{1}{1-3z} \cdot \sum_{n=0}^{\infty} z^n \\ &= \sum_{n=0}^{\infty} (3z)^n \cdot \sum_{n=0}^{\infty} z^n \\ &\quad \text{mittels Cauchy-Produkt} \\ &= \sum_{n=0}^{\infty} \sum_{i=0}^n (3z)^i \cdot z^{n-i} \\ &= \sum_{n=0}^{\infty} z^n \sum_{i=0}^n 3^i \\ &= \sum_{n=0}^{\infty} \frac{3^{n+1} - 1}{3 - 1} \cdot z^n \\ &= \sum_{n=0}^{\infty} \frac{(3^{n+1} - 1)}{2} z^n \end{aligned}$$

Also ist $f_n = \frac{3^{n+1}-1}{2}$.

Probe: $\frac{3^{0+1}-1}{2} = \frac{2}{2} = 1 = f_0$ und $3 \cdot f_{n-1} + 1 = 3 \cdot \frac{3^{(n-1)+1}-1}{2} + 1 = \frac{3^{n+1}-3}{2} + \frac{2}{2} = \frac{3^{n+1}-1}{2} = f_n$.

Aufgabe 5 (8 Punkte)

Sei Σ ein Alphabet, seien $a, b \in \Sigma^*$ und sei w ein Kostenmaß $w : \overline{\Sigma}_0^2 \rightarrow \mathbb{R}_+$ mit $w(x, x) = 0$ und $w(x, y) = w(x, -) = w(-, y) = 1$ für $x \neq y \in \Sigma$.

Wenn in einem Alignment $(\bar{a}, \bar{b}) \in \mathcal{A}(a, b)$ zwei Substitutionen (x, y) und (y, x) mit $x \neq y \in \Sigma$ unmittelbar hintereinander vorkommen, wird dies eine *Transposition* genannt. Solche Transpositionen werden nun mit Kosten 1 anstelle von zwei Substitutionen mit insgesamt Kosten 2 bewertet.

Für ein Alignment $(\bar{a}, \bar{b}) \in \mathcal{A}(a, b)$ bezeichnet w^+ die zugehörigen *erweiterten Kosten*. Dies sind die minimalen Kosten, die unter Berücksichtigung von Transpositionen für ein Alignment möglich sind. Allgemein sind die Kosten für Insertionen, Deletionen, Substitutionen und Transpositionen dann jeweils 1.

Beispiele: $w^+ \begin{pmatrix} \text{Konten} \\ \text{Knoten} \end{pmatrix} = 1$ und $w^+ \begin{pmatrix} xyx \\ yxy \end{pmatrix} = 2$. Bei letzterem handelt es sich um eine Transposition (xy, yx) und eine Substitution (x, y) oder um eine Substitution (x, y) und eine Transposition (yx, xy) .

Die zur erweiterten Kostenfunktion w^+ gehörige *erweiterte Alignment-Distanz* wird mit \bar{d}^+ bezeichnet.

Beispiel: $\bar{d}^+(xxyx, xyxx) = 1$.

Finde einen möglichst effizienten Algorithmus (mit Laufzeit $O(nm)$), der die erweiterte Alignment-Distanz für zwei Wörter $a \in \Sigma^m$ und $b \in \Sigma^n$ findet.

Hinweis: Korrektheitsbeweis und Laufzeitanalyse nicht vergessen!

Lösungsskizze

Wir konstruieren wie beim Algorithmus von Needleman und Wunsch eine Distanzmatrix D . Dabei beinhaltet der Eintrag $D[i, j]$ die erweiterte Alignment-Distanz von $s_1 \cdots s_i$ mit $t_1 \cdots t_j$. Für die Rekursionsgleichungen erhalten wir dann für $i \geq 1$ und $j \geq 1$:

$$D[i, j] = \min \left\{ \begin{array}{l} D[i-1, j] + 1, \\ D[i, j-1] + 1, \\ D[i-1, j-1] + w(s_i, t_i), \\ D[i-2, j-2] + w^+(s_{i-1}s_i, t_{i-1}t_i) \end{array} \right\},$$

dabei gilt wiederum $w(x, x) = 0$ und $w(x, y) = w(x, -) = w(-, y) = 1$ für $x \neq y \in \Sigma$ sowie $w^+(xy, yx) = 1$ für $x \neq y \in \Sigma$. Der Eintrag $D[i-2, j-2] + w^+(s_{i-1}s_i, t_{i-1}t_i)$ wird dabei als ∞ interpretiert, wenn $i \leq 1$ oder $j \leq 1$.

Es stellt sich nun noch die Frage, welche Werte jeweils in der 1. Zeile bzw. in der 1. Spalte der Matrix stehen. Es gilt für $i \geq 0$ und $j \geq 0$:

$$D[0, j] = j \quad \text{und} \quad D[i, 0] = i$$

Die Korrektheit folgt nun aus der Tatsache, dass ein Alignment bzgl. der erweiterten Alignment-Distanz in der letzten Spalte entweder ein Indel, ein Match, eine Substitution oder in den letzten beiden Spalten eine Transposition besitzt.

Jeder Eintrag der Tabelle D lässt sich in konstanter Zeit ermitteln, von daher wird für das Erstellen der Tabellen Zeit $O(nm)$ benötigt. Die erweiterte Alignment-Distanz steht dann in $D[m, n]$.