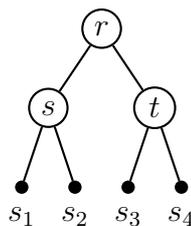


Aufgabe 1 (8 Punkte)

Berechne für den rechts angegebenen vollständigen Baum ein optimales **uniform** geliftetes Alignment mittels der dynamischen Programmierung.



d	s_1	s_2	s_3	s_4
s_1	0	3	1	3
s_2		0	4	5
s_3			0	2
s_4				0

Lösungsskizze

$$D[s, s_1] = (d(s_1, s_1)+0)+(d(s_1, s_2)+0) = 0+3 = 3$$

$$D[s, s_2] = (d(s_2, s_1)+0)+(d(s_2, s_2)+0) = 3+0 = 3$$

$$D[t, s_3] = (d(s_3, s_3)+0)+(d(s_3, s_4)+0) = 0+2 = 2$$

$$D[t, s_4] = (d(s_4, s_3)+0)+(d(s_4, s_4)+0) = 2+0 = 2$$

$$D[r, s_1] = (d(s_1, s_1)+D[s, s_1])+(d(s_1, s_3)+D[t, s_3]) = (0+3) + (1+2) = 6$$

$$D[r, s_2] = (d(s_2, s_2)+D[s, s_2])+(d(s_2, s_4)+D[t, s_4]) = (0+3) + (5+2) = 10$$

$$D[r, s_3] = (d(s_3, s_1)+D[s, s_1])+(d(s_3, s_3)+D[t, s_3]) = (1+3) + (0+2) = 6$$

$$D[r, s_4] = (d(s_4, s_2)+D[s, s_2])+(d(s_4, s_4)+D[t, s_4]) = (5+3) + (0+2) = 10$$

Damit sind die Lösungen:

$$r = s_1 \mid s_3$$

$$s = s_1$$

$$t = s_3$$

Aufgabe 2 (8 Punkte)

Verwende den Algorithmus von Carrillo und Lipman zur Berechnung eines Sequenzen-Alignments zwischen zwei Sequenzen $s = ATTG$ und $t = TG$. Hierzu sind für das Distanzmaß die **Gap-Kosten** von 3 und **Mismatch-Kosten** von 2 zu verwenden. Die **globale obere Schranke** für die Distanz von s und t ist mit 7 vorgegeben.

Hinweis: In der Übung wurde dies für 3 oder mehr Sequenzen implementiert, natürlich funktioniert das Verfahren auch mit nur 2 Sequenzen.

Gib die kombinierte **Prefix-/Suffix-Matrix** $P + S$ und dessen Herleitung an und **markiere alle Zellen**, die in den **Heap** aufgenommen wurden. Gib dabei ebenfalls die Berechnung der verwendeten **obere Schranke** im Relevanz-Test für das Sequenzpaar (s, t) an.

Lösungsskizze

P	T	G	6	S	T	G	12	$P + S$	T	G	18
A	0	3	6	A	6	9	12	A	6	12	18
T	3	2	5	T	3	6	9	T	6	8	14
T	6	3	4	T	0	3	6	T	6	6	10
T	9	6	5	T	3	0	3	T	12	6	8
G	12	9	6	G	6	3	0	G	18	12	6

Die in den Heap aufgenommenen Elemente sind rot bzw. kursiv dargestellt.

Die im Relevanz-Test verwendete obere Schranke für s und t lautet:

$$C_{s,t} := C - \sum_{(i,j) \neq (s,t)} d(s_i, s_j) = C - 0 = 7 - 0 = 7.$$

Aufgabe 3 (8 Punkte)

Betrachte die folgende Matrix mit den Werten $n_{a,b}$ für die PAM-Matrizen.

$n_{a,b}$	A	B	C
A	0	100	200
B	100	0	200
C	200	200	0

- a) Gib die allgemeine Formel für 1-PAM-Matrizen für die Werte $w(\cdot, \cdot)$ an:
- b) Berechne die Werte $w(\cdot, \cdot)$ der zugehörigen 1-PAM.
- c) Was bedeutet PAM? Was ist der prinzipielle Unterschied zwischen einer 2-PAM und einer Substitutionsmatrix basierend auf einer Mutationsrate von 2%?

Hinweis: Gib auch die Zwischenergebnisse an. Am Ende müssen die Logarithmen nicht ausgerechnet werden, auftretende Brüche aber weitestgehend gekürzt werden.

Lösungsskizze

- a) Es gilt für $a \neq b \in \Sigma$.

$$w(a, a) = \log\left(\frac{p_{a,a}}{p_a}\right) \quad \text{und} \quad w(a, b) = \log\left(\frac{p_{a,b}}{p_b}\right)$$

mit $p_a = \frac{1}{2n} \sum_{b \in \Sigma} n_{a,b}$ und $p_{a,b} = \frac{n_{a,b}}{200 \cdot n \cdot p_a}$ sowie $p_{a,a} = 1 - \sum_{\substack{b \in \Sigma \\ b \neq a}} p_{a,b}$.

- b) Es gilt zunächst

$$\begin{aligned}
 p_A &= \frac{100 + 200}{1000} = \frac{3}{10} \\
 p_B &= \frac{100 + 200}{1000} = \frac{3}{10} \\
 p_C &= \frac{200 + 200}{1000} = \frac{4}{10} \\
 p_{A,B} &= \frac{100}{200 \cdot 500 \cdot \frac{3}{10}} = \frac{1}{300} \\
 p_{A,C} &= \frac{200}{200 \cdot 500 \cdot \frac{3}{10}} = \frac{1}{150} \\
 p_{B,A} &= \frac{100}{200 \cdot 500 \cdot \frac{3}{10}} = \frac{1}{300} \\
 p_{B,C} &= \frac{200}{200 \cdot 500 \cdot \frac{3}{10}} = \frac{1}{150} \\
 p_{C,A} &= \frac{200}{200 \cdot 500 \cdot \frac{4}{10}} = \frac{1}{200} \\
 p_{C,B} &= \frac{200}{200 \cdot 500 \cdot \frac{4}{10}} = \frac{1}{200}
 \end{aligned}$$

$$\begin{aligned}
 p_{A,A} &= 1 - \frac{1}{300} - \frac{1}{150} = \frac{147}{150} = \frac{49}{50} \\
 p_{B,B} &= 1 - \frac{1}{300} - \frac{1}{150} = \frac{147}{150} = \frac{49}{50} \\
 p_{C,C} &= 1 - \frac{1}{200} - \frac{1}{200} = \frac{198}{200} = \frac{99}{100}
 \end{aligned}$$

$$\begin{aligned}
 w(A, B) &= \log\left(\frac{\frac{1}{300}}{\frac{3}{10}}\right) = \log\left(\frac{1}{90}\right) \\
 w(A, C) &= \log\left(\frac{\frac{1}{150}}{\frac{4}{10}}\right) = \log\left(\frac{1}{60}\right) \\
 w(B, A) &= \log\left(\frac{\frac{1}{300}}{\frac{3}{10}}\right) = \log\left(\frac{1}{90}\right) \\
 w(B, C) &= \log\left(\frac{\frac{1}{150}}{\frac{4}{10}}\right) = \log\left(\frac{1}{60}\right) \\
 w(C, A) &= \log\left(\frac{\frac{1}{200}}{\frac{3}{10}}\right) = \log\left(\frac{1}{60}\right) \\
 w(C, B) &= \log\left(\frac{\frac{1}{200}}{\frac{3}{10}}\right) = \log\left(\frac{1}{60}\right) \\
 w(A, A) &= \log\left(\frac{1 - \frac{3}{300}}{\frac{3}{10}}\right) = \log\left(\frac{297}{90}\right) = \log\left(\frac{33}{10}\right) \\
 w(B, B) &= \log\left(\frac{1 - \frac{3}{300}}{\frac{3}{10}}\right) = \log\left(\frac{297}{90}\right) = \log\left(\frac{33}{10}\right) \\
 w(C, C) &= \log\left(\frac{1 - \frac{2}{200}}{\frac{4}{10}}\right) = \log\left(\frac{198}{80}\right) = \log\left(\frac{99}{40}\right)
 \end{aligned}$$

c) PAM steht für *Percent Accepted Mutation* oder auch *Point Accepted Mutation*

Bei einer Substitutionsmatrix mit einer Mutationsrate von 2% wird zugrunde gelegt, dass eine Mutation einer Aminosäure mit einer Wahrscheinlichkeit von genau 2% auftritt. Bei einer 2-PAM werden hingegen in einem Schritt zwei Mutationen mit Wahrscheinlichkeit von 1% zugrunde gelegt, so dass die zugrunde gelegte Mutationsrate kleiner als 2% ist, da hierbei auch das Mutationspaar ($A \rightarrow B, B \rightarrow A$) nach außen neutral aussieht.

Aufgabe 4 (8 Punkte)

Wir betrachten vier verschiedene Typen von Münzen A_i für $i \in \{1, 2, 3, 4\}$. Eine Münze vom Typ A_i zeigt mit Wahrscheinlichkeit $\frac{i}{10}$, Kopf und mit der entsprechenden Gegenwahrscheinlichkeit Zahl. Wir wählen zufällig eine Münze (aus den vier Typen) und erhalten anschließend beim viermaligen Werfen dieser Münze genau zweimal Kopf.

- Gib die allgemeinen Formeln für den Maximum-Likelihood-Schätzer und den Maximum-A-Posteriori-Schätzer an.
- Bestimme die Likelihood-Funktion für dieses Ergebnis bezüglich des Parameterraums $\Theta = \{A_1, A_2, A_3, A_4\}$ und gib dann den Maximum-Likelihood-Schätzer für den Typ der gewählten Münze aus dem Parameterraum $\Theta = \{A_1, A_2, A_3, A_4\}$ an.
- Bestimme die Posteriori-Wahrscheinlichkeit für dieses Ergebnis bezüglich des Parameterraums $\Theta = \{A_1, A_2, A_3, A_4\}$ und gib dann den Maximum-A-Posteriori-Schätzer für den Typ der gewählten Münze aus dem Parameterraum $\Theta = \{A_1, A_2, A_3, A_4\}$ an, wobei die Priori-Wahrscheinlichkeit, dass wir einen Würfel vom Typ A_i zufällig ziehen, bei $\frac{5-i}{10}$ liegt.

Lösungsskizze

Sei $X_\theta \in \{0, 1, 2, 3, 4\}$ eine Zufallsvariable, die gemäß $\theta \in \Theta = \{A_1, A_2, A_3, A_4\}$ verteilt ist und die Anzahl von 4 Würfeln angibt, in denen Kopf erschienen ist.

- Der Maximum-Likelihood-Schätzer ist $\operatorname{argmax} \{ \operatorname{Ws}[x | M(\theta)] : \theta \in \Theta \}$.

Der Maximum-A-Posteriori-Schätzer ist $\operatorname{argmax} \{ f(\theta | x) : \theta \in \Theta \}$, wobei $f(\theta | x)$ eine vorgegebene Dichtefunktion für den Parameterraum ist, wenn die Daten gegeben sind (Posterior).

- Es gilt:

$$\begin{aligned} \operatorname{Ws}[X_\theta = 2 | \theta = A_1] &= \binom{4}{2} \left(\frac{1}{10}\right)^2 \cdot \left(\frac{9}{10}\right)^2 = 6 \cdot \frac{81}{10^4} \\ \operatorname{Ws}[X_\theta = 2 | \theta = A_2] &= \binom{4}{2} \left(\frac{2}{10}\right)^2 \cdot \left(\frac{8}{10}\right)^2 = 6 \cdot \frac{256}{10^4} \\ \operatorname{Ws}[X_\theta = 2 | \theta = A_3] &= \binom{4}{2} \left(\frac{3}{10}\right)^2 \cdot \left(\frac{7}{10}\right)^2 = 6 \cdot \frac{441}{10^4} \\ \operatorname{Ws}[X_\theta = 2 | \theta = A_4] &= \binom{4}{2} \left(\frac{4}{10}\right)^2 \cdot \left(\frac{6}{10}\right)^2 = 6 \cdot \frac{576}{10^4} \end{aligned}$$

Also ist $\operatorname{argmax} \{ \operatorname{Ws}[X_\theta = 1 | \theta] : \theta \in \Theta \} = A_4$. Somit ist A_4 der ML-Schätzer.

- Sei $Y \in \Theta = \{A_1, A_2, A_3, A_4\}$ eine Zufallsvariable. Es gilt nach der Regel von Bayes:

$$\operatorname{Ws}[Y = \theta | X = 2] = \frac{\operatorname{Ws}[Y = \theta] \cdot \operatorname{Ws}[X = 2 | Y = \theta]}{\operatorname{Ws}[X = 2]}.$$

Weiterhin gilt für $\theta \in \{A_1, A_2, A_3, A_4\}$:

$$\begin{aligned} \text{Ws}[Y = A_1] \cdot \text{Ws}[X = 2 \mid Y = A_1] &= \frac{4}{10} \cdot 6 \cdot \frac{81}{10^4} = 6 \cdot \frac{324}{10^5} \\ \text{Ws}[Y = A_2] \cdot \text{Ws}[X = 2 \mid Y = A_2] &= \frac{3}{10} \cdot 6 \cdot \frac{256}{10^4} = 6 \cdot \frac{768}{10^5} \\ \text{Ws}[Y = A_3] \cdot \text{Ws}[X = 2 \mid Y = A_3] &= \frac{2}{10} \cdot 6 \cdot \frac{441}{10^4} = 6 \cdot \frac{882}{10^5} \\ \text{Ws}[Y = A_4] \cdot \text{Ws}[X = 2 \mid Y = A_4] &= \frac{1}{10} \cdot 6 \cdot \frac{576}{10^4} = 6 \cdot \frac{576}{10^5} \end{aligned}$$

Somit gilt:

$$\operatorname{argmax}\{\text{Ws}[Y=\theta \mid X=1] : \theta \in \Theta\} = \operatorname{argmax}\{\text{Ws}[Y=\theta] \cdot \text{Ws}[X=1 \mid Y=\theta] : \theta \in \Theta\}.$$

Also ist $\operatorname{argmax}\{\text{Ws}[Y = \theta \mid X = 1] : \theta \in \Theta\} = A_3$, und somit ist A_3 der MAP-Schätzer.

Aufgabe 5 (8 Punkte)

Zeige, dass $\text{MINDIRECTEDTSP} \leq_{\text{PTAS}} \text{MINTSP}$. Gib dazu explizit eine PTAS-Reduktion (f, g, α) an und weise die erforderlichen Eigenschaften einer PTAS-Reduktion nach.

MINTSP (UNDIRECTED TRAVELING SALESPERSON)

Eingabe: Ein vollständiger ungerichteter Graph $G = (V, E)$ und Kantengewichten w .

Lösung: Ein ungerichteter Hamiltonscher Kreis, d.h. eine Permutation $(v_{\pi(1)}, \dots, v_{\pi(n)})$ der Knotenmenge V mit $\{v_{\pi(i)}, v_{\pi((i \bmod n)+1)}\} \in E$ und $n = |V|$.

Optimum: Minimiere $\sum_{i=1}^n w(v_{\pi(i)}, v_{\pi((i \bmod n)+1)})$ mit $n = |V|$.

MINDIRECTEDTSP (DIRECTED TRAVELING SALESPERSON)

Eingabe: Ein vollständiger gerichteter Graph $G = (V, E)$ und Kantengewichten w .

Lösung: Ein gerichteter Hamiltonscher Kreis, d.h. eine Permutation $(v_{\pi(1)}, \dots, v_{\pi(n)})$ der Knotenmenge V mit $(v_{\pi(i)}, v_{\pi((i \bmod n)+1)}) \in E$ und $n = |V|$.

Optimum: Minimiere $\sum_{i=1}^n w(v_{\pi(i)}, v_{\pi((i \bmod n)+1)})$ mit $n = |V|$.

Lösungsskizze

Wir werden im Folgenden die gerichteten Kanten durch ungerichtete Kanten ersetzen, die aber auch alle in derselben Richtung durchlaufen werden müssen. Zur Erinnerung: Eine PTAS-Reduktion ist ein Tripel (f, g, α) .

Hier ist $f(G, \epsilon)$ ist ein ungerichteter Graph, der aus G durch Ersetzen jedes Knotens v und jeder gerichteten Kante (v, x) wie folgt entsteht (und von ϵ unabhängig ist): Jeder Knoten v wird durch drei Knoten v', v^*, v'' und die ungerichteten Kanten $\{v', v^*\}$ und $\{v^*, v''\}$ ersetzt. Jede gerichtete Kante (v, x) wird durch die ungerichtete Kante $\{v'', x'\}$ ersetzt. Für die Gewichte gilt $w(v', v^*) = w(v^*, v'') = 0$ und $w(v'', x') = w(v, x)$.

Wir halten fest, dass jeder Hamiltonsche Kreis in $f(G, \epsilon)$, der v' (für ein $v \in V$) besucht, anschließend erst v^* und dann v'' besuchen muss (andernfalls kann v^* nie besucht werden).

g ist quasi die identische Abbildung mit $g(G, c', \epsilon) = c$ (ist also eigentlich unabhängig von G und ϵ). Genau genommen werden im Hamiltonschen Kreis c' die Teilpfade (v', v^*, v'') durch v ersetzt (aus dem dieses Tripel (v', v^*, v'') generiert wurde), so das man c erhält.

α ist die Identität: $\alpha(\epsilon) = \epsilon$.

Es bleibt zu zeigen: Für alle $x \in I$, $\epsilon \in \mathbb{Q}_+^*$ und $y' \in S'(f(x, \epsilon))$ (mit $\Gamma_\mu(\bar{x}, \bar{y}) := \frac{\mu^*(\bar{x})}{\mu(\bar{x}, \bar{y})}$) gilt: Ist $\Gamma_{\mu'}(f(x, \epsilon), y') \leq 1 + \alpha(\epsilon)$, dann ist $\Gamma_\mu(x, g(x, y', \epsilon)) \leq 1 + \epsilon$.

Da nach Konstruktion der Kantengewichte mittel f und bei der Rekonstruktion der Hamiltonsche Kreise mittels g die Gewichte der entsprechenden Hamiltonsche Kreise gleich bleiben, also $w(c') = w(g(G, c', \epsilon))$ gilt, bleiben also auch die Güten der zugehörigen Lösungen gleich, $\mu'(f(G), c') = \mu(G, g(c'))$. Somit bleibt auch die Approximationsgüte erhalten.

Wie man leicht nachweist, sind f , g und α in polynomieller Zeit berechenbar.