
Algorithmische Bioinformatik II

| | | |
|----------------|--------------|-----------------------|
| Vorname | Name | Matrikelnummer |
| | | |
| Reihe | Platz | Unterschrift |
| | | |

Hiermit stimme ich einer Veröffentlichung meines Klausurergebnisses dieser Semestralklausur unter Verwendung meiner Matrikelnummer im Internet zu. Ja Nein

_____ (Unterschrift)

Allgemeine Hinweise zur Semestralklausur

- Vor der Prüfung ist diese Seite mit Vornamen, Namen, Matrikelnummer, Reihe und Platz **leserlich mit Druckbuchstaben** zu versehen und zu unterschreiben.
 - Bitte **nicht** in *roter* oder *grüner* Farbe bzw. **nicht** mit Bleistift schreiben.
 - Der Studentenausweis und ein amtlicher Lichtbildausweis sind bereit zu halten.
 - Die reine Bearbeitungszeit beträgt **120 Minuten**.
 - Es sind insgesamt 40 Punkte zu erreichen, zum Bestehen sind 17 Punkte nötig.
-

Viel Erfolg!

Hörsaal verlassen von bis von bis

Vorzeitig abgegeben um

| | Hz | A1 | A2 | A3 | A4 | A5 | Σ |
|---------------|----|----|----|----|----|----|----------|
| Erstkorrektur | | | | | | | |
| Nachkorrektur | | | | | | | |
| Zweitprüfer | | | | | | | |

Aufgabe 1 (8 Punkte)

Gegeben seien $s_1 = \text{TACGG}$, $s_2 = \text{ACTGG}$, $s_3 = \text{ATGG}$ und $s_4 = \text{ATGGC}$. Konstruiere für diese Sequenzen ein mehrfaches Alignment mit Hilfe der Center-Star-Methode.

| d | s_1 | s_2 | s_3 | s_4 |
|-------|-------|-------|-------|-------|
| s_1 | 0 | 2 | 2 | 3 |
| s_2 | 2 | 0 | 1 | 2 |
| s_3 | 2 | 1 | 0 | 1 |
| s_4 | 3 | 2 | 1 | 0 |

Hierbei gilt $w(a, b) = 1$ und $w(a, a) = 0$ für alle $a \neq b \in \bar{\Sigma}$.

Lücken sollen dabei wiederverwendet werden.

Lösungsskizze

Wir wählen s_3 als Zentrum, da $\sum_{i=1}^4 d(s_i, s_c)$ für $c = 3$ mit dem Wert 4 minimal wird.

Für die paarweisen optimalen Alignments gilt:

$$\begin{aligned}
 (\bar{s}_1, \bar{s}_2) &= \begin{pmatrix} TAC-GG \\ -ACTGG \end{pmatrix} &
 (\bar{s}_1, \bar{s}_3) &= \begin{pmatrix} TACGG \\ -ATGG \end{pmatrix} &
 (\bar{s}_1, \bar{s}_4) &= \begin{pmatrix} TACGG- \\ -ATGCC \end{pmatrix} \\
 (\bar{s}_2, \bar{s}_3) &= \begin{pmatrix} ACTGG \\ A-TGG \end{pmatrix} &
 (\bar{s}_2, \bar{s}_4) &= \begin{pmatrix} ACTGG- \\ A-TGGC \end{pmatrix} \\
 & &
 (\bar{s}_3, \bar{s}_4) &= \begin{pmatrix} ATGG- \\ ATGGC \end{pmatrix}
 \end{aligned}$$

Wir bauen jetzt das MSA auf. Zuerst werden die paarweisen Alignments von (\bar{s}_3, \bar{s}_1) mit (\bar{s}_3, \bar{s}_2) gemischt:

$$\begin{array}{cccccc}
 s_3 & - & A & - & T & G & G \\
 s_1 & T & A & - & C & G & G \\
 s_2 & - & A & C & T & G & G
 \end{array}$$

Nun wird noch s_4 mittels (\bar{s}_3, \bar{s}_4) hinzugemischt:

$$\begin{array}{ccccccc}
 s_3 & - & A & - & T & G & G & - \\
 s_1 & T & A & - & C & G & G & - \\
 s_2 & - & A & C & T & G & G & - \\
 s_4 & - & A & - & T & G & G & C
 \end{array}$$

Aufgabe 2 (8 Punkte)

Betrachte die Sequenzen $s_1 = \text{CAT}$, $s_2 = \text{ATA}$ und $s_3 = \text{TCA}$. Berechne die C -optimalen Schnittpositionen mit Respekt zu $c_1 = 1$ und die daraus resultierenden mehrfachen Alignments gemäß des Divide-and-Conquer-Alignment-Algorithmus, wobei nach der **ersten** Rekursion bereits jeweils ein optimales Alignment für die jeweiligen Präfixe bzw. Suffixe berechnet wird.

Für die Kostenfunktion des SP-Distanzmaßes gelte $w(a, a) = 0$ und $w(a, b) = 1$ für alle $a \neq b \in \bar{\Sigma}$.

Lösungsskizze

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| P | 0 | A | 1 | T | 2 | A | 3 |
| C | 1 | 1 | 2 | 3 | | | |
| A | 2 | 1 | 2 | 2 | | | |
| T | 3 | 2 | 1 | 2 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| S | 2 | A | 2 | T | 2 | A | 3 |
| C | 1 | 2 | 1 | 2 | | | |
| A | 2 | 1 | 1 | 1 | | | |
| T | 3 | 2 | 1 | 0 | | | |

| | | | | | | | |
|-----|----------|----------|----------|----------|---|---|---|
| C | 0 | A | 1 | T | 2 | A | 4 |
| C | 0 | 1 | 1 | 3 | | | |
| A | 2 | 0 | 1 | 1 | | | |
| T | 4 | 2 | 0 | 0 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| P | 0 | T | 1 | C | 2 | A | 3 |
| C | 1 | 1 | 1 | 2 | | | |
| A | 2 | 2 | 2 | 1 | | | |
| T | 3 | 2 | 3 | 2 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| S | 2 | T | 1 | C | 2 | A | 3 |
| C | 3 | 2 | 1 | 2 | | | |
| A | 2 | 2 | 1 | 1 | | | |
| T | 3 | 2 | 1 | 0 | | | |

| | | | | | | | |
|-----|----------|----------|----------|----------|---|---|---|
| C | 0 | T | 0 | C | 2 | A | 4 |
| C | 2 | 1 | 0 | 2 | | | |
| A | 2 | 2 | 1 | 0 | | | |
| T | 4 | 2 | 2 | 0 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| P | 0 | T | 1 | C | 2 | A | 3 |
| A | 1 | 1 | 2 | 2 | | | |
| T | 2 | 1 | 2 | 3 | | | |
| A | 3 | 2 | 2 | 2 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| S | 2 | T | 2 | C | 2 | A | 3 |
| A | 1 | 1 | 1 | 2 | | | |
| T | 2 | 1 | 0 | 1 | | | |
| A | 3 | 2 | 1 | 0 | | | |

| | | | | | | | |
|-----|---|---|---|---|---|---|---|
| C | 0 | T | 1 | C | 2 | A | 4 |
| A | 0 | 0 | 1 | 2 | | | |
| T | 2 | 0 | 0 | 2 | | | |
| A | 4 | 2 | 1 | 0 | | | |

| | | | | | | | |
|-------|---|---|----------|---|---|---|---|
| $c=1$ | 2 | T | 2 | C | 2 | A | 6 |
| A | 3 | 2 | 2 | 5 | | | |
| T | 5 | 2 | 1 | 5 | | | |
| A | 9 | 6 | 4 | 5 | | | |

Somit ist $(1, 2, 2)$ C -optimaler Schnitt und damit ergeben sich folgende mehrfache Alignments:

| | | | | |
|---|---|--|---|---|
| – | C | | A | T |
| A | T | | A | – |
| T | C | | A | – |

Aufgabe 3 (8 Punkte)

Bestimme für die folgenden Blöcke von Sequenzen die zugehörigen Häufigkeiten $H(a, b)$ für die BLOSUM50-Matrix.

$$\begin{array}{ll}
 s_1^{(1)} = \text{ACCCA} & s_1^{(2)} = \text{CBBCACBAC} \\
 s_2^{(1)} = \text{ABACA} & s_2^{(2)} = \text{CCBCABCAA} \\
 s_3^{(1)} = \text{CBABA} & s_3^{(2)} = \text{BCBBABBAB} \\
 s_4^{(1)} = \text{ACABB} & s_4^{(2)} = \text{CBACABBBA}
 \end{array}$$

Lösungsskizze

Die Partitionierung nach mindestens 50%-Sequenzähnlichkeit ergibt:

$$\text{Block 1: } [1 : 4] = [1 : 3] \cup \{4\}$$

$$\text{Block 2: } [1 : 4] = [1 : 4]$$

Dabei sind im zweiten Block u.a. folgende Ähnlichkeiten von mindestens 55%: $s_1^{(2)}$ mit $s_2^{(2)}$, $s_2^{(2)}$ mit $s_3^{(2)}$ und $s_1^{(2)}$ mit $s_4^{(2)}$.

Somit ist nur Block 1 auszuwerten:

$$\begin{aligned}
 H(A, A) &= \frac{8}{3} = 2.\bar{6} \\
 H(A, B) &= \frac{3}{3} = 1 \\
 H(A, C) &= \frac{2}{3} = 0.\bar{6} \\
 H(B, B) &= \frac{2}{3} = 0.\bar{6} \\
 H(B, C) &= \frac{4}{3} = 1.\bar{3} \\
 H(C, C) &= \frac{2}{3} = 0.\bar{6}
 \end{aligned}$$

Aufgabe 4 (8 Punkte)

Sei $Z_n \in \{0, 1\}$ eine Zufallsvariable, die den Ausgang des n -ten Wurfs einer Münze beschreibt (wobei die beiden Ausgänge gleichwahrscheinlich sind).

Betrachte $X_0 := 2 \cdot Z_0$ und für $n > 0$

$$X_n := 3 \cdot Z_n + 2 \cdot Z_{n-1}.$$

- Begründe, dass $(X_n)_{n \in \mathbb{N}}$ eine Markov-Kette erster Ordnung ist.
- Bestimme das zu $(X_n)_{n \in \mathbb{N}}$ gehörige Markov-Modell (Q, P, π) .
- Gib für das Markov-Modell aus b) die stationäre Verteilung an.
- Begründe, dass das Markov-Modell aus b) ergodisch ist

Lösungsskizze

- a) Es gilt für $n \geq 1$, dass $Z_{n-1} = (3 \cdot Z_{n-1} + 2 \cdot Z_{n-2}) \bmod 2$ und somit:

$$\begin{aligned} X_n &= 3 \cdot Z_n + 2 \cdot Z_{n-1} \\ &= 3 \cdot Z_n + 2 \cdot ((3 \cdot Z_{n-1} + 2 \cdot Z_{n-2}) \bmod 2) \\ &= 3 \cdot Z_n + 2 \cdot (X_{n-1} \bmod 2) \end{aligned}$$

- b) Wir wählen $Q = \{q_0, q_2, q_3, q_5\}$, wobei i in q_i den Wertebereich $\{0, 2, 3, 5\}$ von X_n durchläuft. Dann ist $\pi = (0.5, 0.5, 0.0, 0.0)$ und

$$P = \begin{pmatrix} 0.5 & 0.0 & 0.5 & 0.0 \\ 0.5 & 0.0 & 0.5 & 0.0 \\ 0.0 & 0.5 & 0.0 & 0.5 \\ 0.0 & 0.5 & 0.0 & 0.5 \end{pmatrix}.$$

- c) Die stationäre Verteilung ist (wie man leicht nachrechnet) $(\frac{1}{4}, \frac{1}{4}, \frac{1}{4}, \frac{1}{4})$.
- d) Eine durch ein Markov-Modell induzierte Markov-Kette ist ergodisch, wenn sie irreduzibel und aperiodisch ist

Der Graph der Übergangswahrscheinlichkeiten P ist zusammenhängend, also kann jeder Zustand von jedem anderen Zustand mit positiver Wahrscheinlichkeit in endlich vielen Schritten erreicht werden, somit ist die Markov-Kette irreduzibel.

Die Periode $d_i := d_{q_i}$ eines Zustands $q_i \in Q$ ist definiert als

$$d_i := \text{ggT} \left\{ k \in \mathbb{N} : \begin{array}{l} \exists (q_0, \dots, q_k) \in Q^{k+1} \quad \wedge \quad q_0 = q_k = q \\ \wedge \quad \forall i \in [0 : k-1] p_{q_i, q_{i+1}} > 0 \end{array} \right\}.$$

Offensichtlich ist $d_0 = d_5 = 1$, da 1 in die ggT-Berechnung einfließt. Für d_2 gehen die Pfade (q_2, q_3, q_2) und (q_2, q_3, q_5, q_2) ein. Da $\text{ggT}(2, 3) = 1$ ist $d_2 = 1$. Für d_3 gehen die Pfade (q_3, q_2, q_3) und (q_3, q_2, q_0, q_3) ein. Da $\text{ggT}(2, 3) = 1$ ist $d_3 = 1$. Somit sind alle Zustände aperiodisch und damit auch die Markov-Kette.

Aufgabe 5 (8 Punkte)

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

MINEDGECOVER (MINEC)

Eingabe: Ein ungerichteter Graph $G = (V, E)$ mit $E = \{e_1, \dots, e_m\}$.

Lösung: Eine Teilmenge $E' \subseteq E$ der Kanten, so dass jeder Knoten mindestens ein Endpunkt einer Kante in E' ist, d.h. $\forall v \in V : \exists e \in E' : e \cap \{v\} \neq \emptyset$.

Optimum: Minimiere $|E'|$.

MINSAT

Eingabe: Eine Boolesche Formel F über $V(F) = X$.

Lösung: Eine erfüllende Belegung $B : X \rightarrow \mathbb{B}$, d.h. $B(F) = 1$.

Optimum: Minimiere $\mu(B) = |\{x \in X : B(x) = 1\}|$.

Achtung: Bei MINSAT ist **nicht** die Anzahl erfüllter Klauseln zu minimieren, sondern die Anzahl der auf wahr gesetzten Variablen.

Lösungsskizze

Somit muss also $f(G, \epsilon)$ eine Boolesche Formel F sein. Dazu ordnen wir jeder Kante $e_i \in E = \{e_1, \dots, e_m\}$ eine Variable $x_i \in X = \{x_1, \dots, x_m\}$ zu und für jeden Knoten $v \in V$ erzeugen wir eine Klausel $\{e_{i_1}, \dots, e_{i_{\ell_i}}\}$, wobei $\{e_{i_1}, \dots, e_{i_{\ell_i}}\}$ alle Kanten sind, die v_i als einen Endpunkt enthalten (d.h. $e_i \cap v_{i_j} \neq \emptyset$ für alle $i_j \in [1 : \ell_i]$). F ist dann die Konjunktion dieser Klauseln.

g ordnet einer erfüllenden Belegung $B : X \rightarrow \mathbb{B}$ eine Menge E' wie folgt zu:

$$E' := \{e_i \in E : B(x_i) = 1\}.$$

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

f , g und α sind offensichtlich in polynomieller Zeit berechenbar.

Offensichtlich gilt, dass für eine erfüllende Belegung B für F jede Klausel $\{e_{i_1}, \dots, e_{i_{\ell_i}}\}$ erfüllt ist. Dies impliziert dann natürlich einen Edge-Cover für G vermöge g , da dann jede Klausel durch eine erfüllende Variable abgedeckt ist, d.h. jeder Knoten ist mindestens Endpunkt einer Kante in E' . Umgekehrt kann man jedem Edge-Cover eine erfüllende Belegung für F zuordnen.

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

Sei $B \in S'(f(G, \epsilon))$ eine erfüllende Belegung für $f(G, \epsilon) = F$ und sei B^* eine erfüllende Belegung für F , die eine minimale Anzahl von Variablen auf **true** setzt. Gelte hierfür

$$\frac{\mu(B)}{\mu(B^*)} = \Gamma_{\mu'}(f(G, \epsilon), B) \leq 1 + \alpha(\epsilon) = 1 + \epsilon.$$

Also gilt dann nach Definition von g

$$\frac{|E'|}{|E^*|} = \frac{\mu(B)}{\mu(B^*)} \leq 1 + \epsilon.$$