

Seminar: Mathematische Biologie

A Phase Transition for the Score in Matching
Random Sequences Allowing Deletions

Julian Hüne

1 Einleitung

In diesem Seminarvortrag wird als Hauptresultat der Beweis eines Phasenübergangs zwischen linearer und logarithmischer Entwicklung von Trefferzahlen (scores) erbracht.

Hierfür benötigen wir ein endliches Alphabet \mathcal{A} . Auf \mathcal{A}^2 wird eine Trefferfunktion $s(a, b)$ und eine subadditive Lückenfunktion (gap weight function) $g(k)$ mit $k \geq 1$, die den positiven Wert für die Zuordnung eines Buchstaben des Alphabets zu einer Lücke angibt, definiert.

Definition 1. Sei $(\mu, \delta) \in [0, \infty]^2$

$$s : \mathcal{A}^2 \rightarrow \mathbb{R}, \quad s(a, b) = \begin{cases} +1, & a = b \\ -\mu, & a \neq b \end{cases} \quad (1)$$

$$g : \mathcal{A} \times \{-\} \rightarrow \mathbb{R}, \quad g(k) = \delta k \quad (2)$$

Die folgenden Sätze sind auch für allgemeinere s und g gültig. Der Einfachheit halber sollen jedoch diese studiert werden.

In diesem Modell definieren wir die Zufallsvariablen für die globale und lokale Trefferabgleichung (global alignment score/ local alignment score) wie folgt:

Die globale Trefferabgleichung S_n soll das Maximum über alle möglichen Abgleichungen von zwei Buchstabenfolgen $A = A_1 \dots A_n$ und $B = B_1 \dots B_n$ sein, wobei alle Buchstaben A_i und B_j unabhängig und identisch verteilte Zufallsvariablen eines endlichen Alphabets sind.

Definition 2. Für die globale Trefferabgleichung (global alignment score) gilt:

$$\begin{aligned} S_n &= S(A, B) = S(A_1 \dots A_n, B_1 \dots B_n) \\ &= \max_{l \in \{0, \dots, n\}} \{-\delta(n - l + n - l) + \sum_{k=1}^l s(A_{a(k)}, B_{b(k)})\}, \end{aligned} \quad (3)$$

wobei das Maximum über alle Abgleichungen ist, die durch die aufsteigenden Sequenzen:

$$\begin{aligned} 0 &= a(0) < a(1) < a(2) < \dots < a(l) < a(l+1) = n+1 \\ 0 &= b(0) < b(1) < b(2) < \dots < b(l) < b(l+1) = n+1 \end{aligned}$$

gegeben sind.

Die lokale Trefferabgleichung H_n ist nun die optimale Trefferzahl $S(I, J)$ mit $I \subset A$ und $J \subset B$ über alle möglichen Abgleichungen von zwei zusammenhängenden Buchstabenfolgen, d.h.

Definition 3. Für die lokale Trefferabgleichung (local alignment score) gilt:

$$\begin{aligned} H(A_1 \dots A_n, B_1 \dots, B_n) &\equiv H(A, B) \\ &\equiv H_n = \max\{S(I, J) : I \subset A, J \subset B\}, \end{aligned} \quad (4)$$

wobei $I = A_{g+1} \dots A_{g+i}$ und $J = B_{h+1} \dots B_{h+j}$ mit $1 \leq g+1 \leq g+i \leq n$ und $1 \leq h+1 \leq h+j \leq n$. Für $S(A_{g+1} \dots A_{g+i}, B_{h+1} \dots B_{h+j})$ gilt:

$$\begin{aligned} &S(A_{g+1} \dots A_{g+i}, B_{h+1} \dots B_{h+j}) \\ &= \max_{\substack{g=a(0)<a(1)<\dots<a(l+1)=g+i+1 \\ h=b(0)<b(1)<\dots<b(l+1)=h+j+1}} \{-\delta(i-l+j-l) + \sum_{k=1}^l s(A_{a(k)}, B_{b(k)})\} \end{aligned}$$

Das Hauptresultat, dass bewiesen werden soll, ist das folgende Theorem:

Theorem 1. Seien A_1, A_2, \dots und B_1, B_2, \dots zwei Buchstabenfolgen, wobei alle Buchstaben A_i und B_j unabhängig und identisch verteilte Zufallsvariablen eines endlichen Alphabets sind.

Bei der lokalen Trefferabgleichung (local alignment score)

$H_n = H(A_1 A_2 \dots A_n, B_1 B_2 \dots B_n)$ mit den Parametern μ und δ tritt ein Phasenübergang zwischen linearer Entwicklung in n für kleine μ und δ und logarithmischer Entwicklung in n für große μ und δ auf.

Beweis. Die Behauptung folgt unmittelbar durch Kombination von Satz 4, 5 und 6. \square

An die folgenden beiden Sätze sei erinnert:

Satz 1. Seien $A = A_1 \dots A_n$ und $B = B_1 \dots B_n$ mit A_i und B_j iid. Es existiert eine Konstante $\rho \geq \mathbb{E}(s(A, B))$, so dass:

$$\begin{aligned} \lim_{n \rightarrow \infty} \frac{S_n}{n} &= \rho \text{ fast sicher} \\ \rho = \rho(\mu, \delta) &= \lim_{n \rightarrow \infty} \frac{\mathbb{E}(S_n)}{n} = \sup_{n \geq 1} \frac{\mathbb{E}(S_n)}{n} \end{aligned} \quad (5)$$

Beweisidee: Überprüfe Kingman's Theorem und Subadditivität \square

Satz 2 (Korollar des Azuma-Hoeffding Lemma). Seien A_1, \dots, A_n und B_1, \dots, B_n zwei Buchstabenfolgen, wobei alle Buchstaben A_i und B_j unabhängig und identisch verteilte Zufallsvariablen eines endlichen Alphabets sind, und sei $\gamma > 0$. Dann gilt mit $c := \min\{2 + 4\delta, 2 + 2\mu\}$

$$\mathbb{P}\left(\frac{S_n}{n} - \rho \geq \gamma\right) \leq \exp\left(-\frac{\gamma^2 n}{2c^2}\right) \quad (6)$$

2 subadditive Folgen

Definition 4. Eine Folge $(a_n)_{n \in \mathbb{N}}$ heißt subadditiv, wenn

$$a_{n+m} \leq a_n + a_m \quad \forall n, m \in \mathbb{N} \quad (7)$$

Definition 5. Eine Folge $(a_n)_{n \in \mathbb{N}}$ heißt superadditiv, wenn

$$a_{n+m} \geq a_n + a_m \quad \forall n, m \in \mathbb{N} \quad (8)$$

Bemerkung 1. Die globale Trefferabgleichung (global alignment score) S_n ist eine superadditive Folge

$$S_{n+m} \geq S_n + S_m \quad (9)$$

Satz 3 (Fekete's Lemma). Für jede superadditive Folge $(a_n)_{n \in \mathbb{N}}$ existiert der Grenzwert $\lim_{n \rightarrow \infty} \frac{a_n}{n}$ und es gilt:

$$\lim_{n \rightarrow \infty} \frac{a_n}{n} = \sup_{m \geq 1} \frac{a_m}{m} \quad (10)$$

Ganz analog, existiert der Grenzwert $\lim_{n \rightarrow \infty} \frac{a_n}{n}$ für jede subadditive Folge $(a_n)_{n \in \mathbb{N}}$ und es gilt:

$$\lim_{n \rightarrow \infty} \frac{a_n}{n} = \inf_{m \geq 1} \frac{a_m}{m} \quad (11)$$

Beweis. Zunächst einmal gilt:

$$\limsup_{j \rightarrow \infty} \sup_{n \geq j} \frac{a_n}{n} \leq \sup_{m \geq 1} \frac{a_m}{m}$$

Also bleibt zu zeigen: $\forall m \in \mathbb{N}$ gilt: $\liminf_{j \rightarrow \infty} \inf_{n \geq j} \frac{a_n}{n} \geq \frac{a_m}{m}$

Sei $m \in \mathbb{N}$

und $n = km + l$ mit $0 \leq l < m$.

Mit mehrfachem Anwenden von (8) folgt:

$$a_n \geq ka_m + a_l$$

Division durch n ergibt

$$\begin{aligned} \frac{a_n}{n} &\geq \frac{ka_m + a_l}{n} = \frac{km}{km+l} \frac{a_m}{m} + \frac{s_l}{n} \\ \liminf_{j \rightarrow \infty} \inf_{n \geq j} \frac{a_n}{n} &\geq \liminf_{j \rightarrow \infty} \inf_{n \geq j} \left(\frac{km}{km+l} \frac{a_m}{m} + \frac{s_l}{n} \right) \\ &= \frac{a_m}{m} \end{aligned}$$

und so folgt die Behauptung, denn:

$$\sup_{m \geq 1} \frac{a_m}{m} \leq \liminf_{j \rightarrow \infty} \inf_{n \geq j} \frac{a_n}{n} \leq \limsup_{j \rightarrow \infty} \sup_{n \geq j} \frac{a_n}{n} \leq \sup_{m \geq 1} \frac{a_m}{m}$$

Die 2. Behauptung folgt ganz analog. □

3 Der Phasenübergang

Zuerst behandeln wir die Menge mit $\rho = 0$

Satz 4. Die Menge $\{(\mu, \delta) \in [0, \infty]^2 : \rho(\mu, \delta) = 0\}$ definiert eine Linie in dem Parameterraum $[0, \infty]^2$, die positive und negative Regionen $\{\rho < 0\}$ und $\{\rho > 0\}$ separiert.

Beweis. ρ ist monoton fallend in beiden Parametern. Dies folgt aus der Definition der globalen Trefferabgleichung (global alignment score).

Behauptung: Es gilt die globale Ungleichung $\rho(\mu + \epsilon, \delta + \frac{\epsilon}{2}) \geq \rho(\mu, \delta) - \epsilon$.

Es gilt

$$S_k = l * 1 - j\mu - i\delta \text{ mit } l, j, i, k \in \mathbb{N} \text{ s.d. } l + j + \frac{i}{2} = k$$

$$S'_k := l * 1 - j(\mu + \epsilon) - i(\delta + \frac{\epsilon}{2})$$

Somit folgt:

$$\begin{aligned} \frac{S'_k}{k} &= \frac{l * 1 - j(\mu + \epsilon) - i(\delta + \frac{\epsilon}{2})}{k} \\ &= \frac{l - j\mu - i\delta}{k} + \frac{-j\epsilon - i\frac{\epsilon}{2}}{k} = \frac{S_k}{k} - \frac{\epsilon(j + \frac{i}{2})}{k} \\ &\geq \frac{S_k}{k} - \frac{k\epsilon}{k} && (j + \frac{i}{2} \leq k) \\ &= \frac{S_k}{k} - \epsilon \end{aligned}$$

Dies gilt für alle $k \in \mathbb{N}$ und wir wissen, dass:

$$\frac{S_k}{k} \rightarrow \rho(\mu, \delta) \text{ fast sicher und } \frac{S'_k}{k} \rightarrow \rho(\mu + \epsilon, \delta + \frac{\epsilon}{2}) \text{ fast sicher}$$

So folgt:

$$\rho(\mu + \epsilon, \delta + \frac{\epsilon}{2}) \geq \rho(\mu, \delta) - \epsilon$$

Behauptung: ρ ist stetig.

sei $x_0 = (\mu_0, \delta_0) \in [0, \infty]^2$

Zu zeigen:

$\forall \epsilon > 0 \exists \nu > 0 : \forall x \text{ mit } \|x, x_0\|_1 \leq \nu \text{ gilt } |\rho(x) - \rho(x_0)| \leq \epsilon$

Setze $\nu := \frac{\epsilon}{2}$

Da ρ in beiden Parametern monoton fallend ist gilt:

$\exists Q, Q' \in \{x \in [0, \infty]^2 : \|x, x_0\|_1 \leq \frac{\epsilon}{2}\}$ mit

$Q = (\mu_0 + \frac{\epsilon}{4}, \delta_0 + \frac{\epsilon}{4})$ und $Q' = (\mu_0 - \frac{\epsilon}{4}, \delta_0 - \frac{\epsilon}{4})$, so dass gilt:

$$\begin{aligned}
|\rho(x), \rho(x_0)| &\leq |\rho(Q), \rho(Q')| \\
&= |\rho(\mu_0 + \frac{\epsilon}{4}, \delta_0 + \frac{\epsilon}{4}), \rho(\mu_0 - \frac{\epsilon}{4}, \delta_0 - \frac{\epsilon}{4})| \\
&= \rho(\mu_0 - \frac{\epsilon}{4}, \delta_0 - \frac{\epsilon}{4}) - \rho(\mu_0 + \frac{\epsilon}{4}, \delta_0 + \frac{\epsilon}{4}) \\
&\leq \rho(\mu_0 - \frac{\epsilon}{2}, \delta_0 - \frac{\epsilon}{4}) - \rho(\mu_0 + \frac{\epsilon}{2}, \delta_0 + \frac{\epsilon}{4}) \quad (\text{Monotonie von } \rho) \\
&\leq \rho(\mu_0 - \frac{\epsilon}{2}, \delta_0 - \frac{\epsilon}{4}) - \rho(\mu_0, \delta_0) + \frac{\epsilon}{2} \quad (\text{globale Ungleichung}) \\
&= \rho(\mu'_0, \delta'_0) - \rho(\mu'_0 + \frac{\epsilon}{2}, \delta'_0 + \frac{\epsilon}{4}) \quad (\mu'_0 := \mu_0 - \frac{\epsilon}{2}) \\
&\quad \delta'_0 := \delta_0 - \frac{\epsilon}{4} \\
&\leq \rho(\mu'_0, \delta'_0) - \rho(\mu'_0, \delta'_0) + \frac{\epsilon}{2} + \frac{\epsilon}{2} \quad (\text{globale Ungleichung}) \\
&= \epsilon
\end{aligned}$$

ρ ist nicht streng monoton fallend in beiden Parametern überall im Parameterraum $[0, \infty]^2$. Aber es gilt:

Behauptung: ρ ist streng monoton fallend in der (1,1)-Richtung in einer Umgebung der Linie $\rho = 0$.

Sei zunächst $(\mu, \delta) \in [0, \infty)^2$. Dafür setze $\gamma := \max\{\mu, 2\delta\}$.

Es gilt:

$$\begin{aligned}
S_k &= l - j\mu - \frac{i}{2}2\delta \quad (\text{mit } l, j, i, k \in \mathbb{N}, \text{ s.d. } l + j + \frac{i}{2} = k) \\
&\geq l - (j + \frac{i}{2})\gamma
\end{aligned}$$

Sei x der Anteil von nicht übereinstimmend abgeglichenen Buchstabenpaaren:

$$S_k \geq k(1 - x) - kx\gamma$$

Und somit:

$$\frac{S_k}{k} \geq (1 - x) - x\gamma \Leftrightarrow x \geq \frac{1 - \frac{S_k}{k}}{\gamma + 1} \quad (12)$$

Erhöht man bei solchen Abgleichungen die Parameter μ, δ um jeweils $\epsilon > 0$, so muss die Trefferzahl (score) um mindestens ϵx abnehmen, d.h. mit

$S'_k = l - j(\mu + \epsilon) - \frac{i}{2}2(\delta + \epsilon)$ folgt für alle $k \in \mathbb{N}$:

$$\begin{aligned}
\frac{S'_k}{k} &\leq \frac{S_k}{k} - \epsilon x \stackrel{(12)}{\leq} \frac{S_k}{k} - \epsilon \frac{1 - \frac{S_k}{k}}{\gamma + 1} \\
&= \frac{S_k}{k} + \epsilon \frac{\frac{S_k}{k}}{\gamma + 1} - \epsilon \frac{1}{\gamma + 1}
\end{aligned}$$

Und da wir außerdem wissen, dass gilt:

$$\begin{aligned}\frac{S_k}{k} &\rightarrow \rho(\mu, \delta) \text{ fast sicher} \\ \frac{S'_k}{k} &\rightarrow \rho(\mu + \epsilon, \delta + \epsilon) \text{ fast sicher,}\end{aligned}$$

folgt schließlich:

$$\begin{aligned}\rho(\mu + \epsilon, \delta + \epsilon) &\leq \rho(\mu, \delta) + \epsilon \frac{\rho(\mu, \delta)}{\gamma + 1} - \frac{\epsilon}{\gamma + 1} \\ &= \rho(\mu, \delta) - \epsilon \frac{1 - \rho(\mu, \delta)}{\gamma + 1} \\ &\leq \rho(\mu, \delta) - \epsilon \frac{1 - \rho(\mu, \delta)}{1 + \mu + 2\delta}\end{aligned}$$

Da wir uns in einer kleinen Umgebung von $\rho = 0$ befinden, gilt:

$$\rho(\mu + \epsilon, \delta + \epsilon) \leq \rho(\mu, \delta) - \underbrace{\epsilon \frac{1 - \rho(\mu, \delta)}{1 + \mu + 2\delta}}_{>0} < \rho(\mu, \delta)$$

Sei nun $\mu = \infty$ und $\delta \in [0, \infty)$. Auch dann gilt, dass $\rho(\infty, \delta)$ streng monoton fallend in der (1,1)-Richtung ist.

Da $\mu = \infty$ ist, werden nicht übereinstimmende Buchstaben jeweils zu einer Lücke abgeglichen. Das bedeutet: $S_k = l * 1 - \frac{i}{2}2\delta$. Somit folgt:

$$S_k \geq k(1 - x) - kx2\delta \Leftrightarrow x \geq \frac{1 - \frac{S_k}{k}}{2\delta + 1}$$

Und so folgt genauso auch hier:

$$\rho(\infty + \epsilon, \delta + \epsilon) \leq \rho(\infty, \delta) - \epsilon \frac{1 - \rho(\mu, \delta)}{1 + 2\delta} < \rho(\infty, \delta)$$

Sei als letztes $\delta = \infty$ und $\mu \in [0, \infty)$

Dieser Fall ist analog zu dem vorherigen. Die optimalen Abgleichungen von Sequenzen in diesem Fall beinhalten keine Lücken. \square

Bemerkung 2. Der Satz sagt nicht, dass für alle $\epsilon > 0$:

$\rho(\mu + \epsilon, \delta) < \rho(\mu, \delta)$ und $\rho(\mu, \delta + \epsilon) < \rho(\mu, \delta)$. Insbesondere das 1. ist falsch.

Definition 6. Für alle $q \in [0, \infty)$ definieren wir die Funktion $r : [0, \infty) \rightarrow [0, \infty]$ durch:

$$r(q) := \lim_{n \rightarrow \infty} \frac{-\log \mathbb{P}(S_n \geq qn)}{n} = \inf_{n \geq 1} \frac{-\log \mathbb{P}(S_n \geq qn)}{n} \quad (13)$$

Bemerkung 3. Wir setzen $\log(0) = -\infty$

Lemma 1. Der Grenzwert existiert und ist gleich dem Infimum.

Beweis. Dies beweisen wir mit Hilfe von Fekete's Lemma. Es gilt:

$$\begin{aligned}\mathbb{P}(S_{n+l} \geq q(n+l)) &\geq \mathbb{P}(S_n + S(A_{n+1} \dots A_{n+l}, B_{n+1} \dots B_{n+l}) \geq qn + ql) \\ &= \mathbb{P}(S_n + S_l \geq qn + ql) && \text{(identisch verteilt)} \\ &\geq \mathbb{P}(S_n \geq qn \wedge S_l \geq ql) \\ &= \mathbb{P}(S_n \geq qn) \mathbb{P}(S_l \geq ql) && \text{(Unabhängigkeit)}\end{aligned}$$

Somit folgt:

$$-\log(\mathbb{P}(S_m \geq qm)) \leq -\log(\mathbb{P}(S_n \geq qn)) + (-\log(\mathbb{P}(S_l \geq ql)))$$

Das zeigt, dass $-\log \mathbb{P}(S_n \geq qn)$ eine subadditive Folge ist. Aufgrund Fekete's Lemma wissen wir:

$$\lim_{n \rightarrow \infty} -\frac{\log \mathbb{P}(S_n \geq qn)}{n} = \inf_{n \geq 1} -\frac{\log \mathbb{P}(S_n \geq qn)}{n}$$

und der Grenzwert existiert. \square

Als nächstes werden einige Eigenschaften der Funktion r aufgeführt, die der Anschauung dienen und in den späteren Beweisen benötigt werden.

Bemerkung 4. r ist monoton steigend

Beweis. $\mathbb{P}(S_n \geq qn)$ ist für alle $n \in \mathbb{N}$ monoton fallend in q . Die Monotonie überträgt sich auch auf den Grenzwert. Somit ist r monoton steigend. \square

Bemerkung 5. Für $q \in [0, 1]$ gilt: $0 \leq r(q) < \infty$ und für $q > 1$: $r(q) = \infty$.

Beweis. $r(q) \geq 0$, denn:

$$-\frac{\log \mathbb{P}(S_n \geq qn)}{n} \geq 0 \quad \forall n \in \mathbb{N}$$

Und da r monoton steigend ist gilt für alle $q \in [0, 1]$:

$$\begin{aligned}r(q) &\leq r(1) = \inf_{n \geq 1} -\frac{\log \mathbb{P}(S_n \geq n)}{n} \\ &= \inf_{n \geq 1} -\frac{\log \mathbb{P}(A_i = B_i \quad \forall i \in \{1, \dots, n\})}{n} \\ &= \inf_{n \geq 1} -\frac{\log((\mathbb{P}(A_1 = B_1))^n)}{n} && \text{(iid)} \\ &= \inf_{n \geq 1} -\log(\mathbb{P}(A_1 = B_1)^{\frac{n}{n}}) \\ &= -\log \mathbb{P}(A_1 = B_1) && (14) \\ &< \infty\end{aligned}$$

Da $\frac{S_n}{n} \leq 1$ für alle $n \in \mathbb{N}$ gilt für $q > 1$:

$$\begin{aligned}\mathbb{P}(S_n \geq qn) &= 0 \quad \forall n \in \mathbb{N} \\ \Rightarrow r(q) &= \lim_{n \rightarrow \infty} -\log(0^{\frac{1}{n}}) = -\log(0) = \infty\end{aligned}$$

□

Bemerkung 6. Wenn $\rho(\mu, \delta) > q$, dann folgt $r(q)=0$.

Beweis. Wir wissen, dass

$$\frac{S_n}{n} \rightarrow \rho \text{ fast sicher}$$

S_n ist eine superadditive Folge, d.h. $S_{n+m} \geq S_n + S_m$. Somit folgt aus Fekete's Lemma

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = \sup_{n \geq 1} \frac{S_n}{n}$$

So gilt:

$$\rho \geq \frac{S_n}{n} \quad \forall n \in \mathbb{N} \text{ fast sicher}$$

Sei $q < \rho$ und setze $q = \rho - \epsilon$ mit $\epsilon > 0$. So folgt:

$$\begin{aligned}\mathbb{P}(S_n \geq qn) &= \mathbb{P}\left(\frac{S_n}{n} \geq \rho - \epsilon\right) = \mathbb{P}\left(\rho - \frac{S_n}{n} \leq \epsilon\right) \\ &= 1 - \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon\right) \\ &= 1 - \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon\right) - \underbrace{\mathbb{P}\left(-\rho + \frac{S_n}{n} > \epsilon\right)}_{=0, \text{ da } \rho \geq \frac{S_n}{n} \text{ f.s.}} \\ &= 1 - \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon \vee -\rho + \frac{S_n}{n} > \epsilon\right) \\ &= 1 - \mathbb{P}\left(\left|\rho - \frac{S_n}{n}\right| > \epsilon\right) \xrightarrow[n \rightarrow \infty]{\text{da } \frac{S_n}{n} \rightarrow \rho \text{ f.s.}} 1,\end{aligned}$$

denn aus fast sicherer Konvergenz folgt Konvergenz in Wahrscheinlichkeit.

Jetzt können wir zeigen, dass $r(q)=0$ gilt für alle $q < \rho$

$$\begin{aligned}0 \leq r(q) &= \lim_{n \rightarrow \infty} -\frac{1}{n} \log \mathbb{P}(S_n \geq qn) \\ &= \lim_{n \rightarrow \infty} -\log(\mathbb{P}(S_n \geq qn)^{\frac{1}{n}}) \\ &= -\log\left(\lim_{n \rightarrow \infty} \mathbb{P}(S_n \geq qn)^{\frac{1}{n}}\right) \quad (\text{Stetigkeit}) \\ &= -\log\left(\lim_{n \rightarrow \infty} (1 - \mathbb{P}\left(\left|\rho - \frac{S_n}{n}\right| \leq \epsilon\right))^{\frac{1}{n}}\right)\end{aligned}$$

$$\exists \epsilon' > 0 \text{ klein: } \exists N \in \mathbb{N} \forall n > N \mathbb{P}(|\rho - \frac{S_n}{n}| \leq \epsilon))^{\frac{1}{n}} < \epsilon'$$

$$\begin{aligned} &\leq -\log(\lim_{n \rightarrow \infty} (1 - \epsilon')^{\frac{1}{n}}) \\ &= -\log(1) = 0 \end{aligned}$$

□

Während S_k nur Trefferzahlen (scores) zwischen Sequenzen der Länge k angibt, hängt H_k von Sequenzen beliebiger Länge zwischen 1 und k ab.

Definition 7.

$$S_{i,j} := S(A_1 \dots A_i, B_1 \dots B_j) \quad (15)$$

$$r'(q) := \lim_{k \rightarrow \infty} -\frac{1}{k} \log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk)) \quad (16)$$

Lemma 2. *Es gilt:*

$$\begin{aligned} r(q) &= \lim_{k \rightarrow \infty} \frac{-\log \mathbb{P}(S_k \geq qk)}{k} \\ &= \lim_{k \rightarrow \infty} -\frac{1}{k} \log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk)) = r'(q) \end{aligned} \quad (17)$$

Beweis. Da $-\log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk))$ eine subadditive Folge ist (vgl. Lemma 1), folgt mit Fekete's Lemma:

$$\lim_{n \rightarrow \infty} -\frac{\log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk))}{k} = \inf_{n \geq 1} -\frac{\log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk))}{k}$$

und der Grenzwert existiert.

Zu zeigen: $r' \leq r$

Es gilt:

$$\{i, j : i = k \wedge j = k\} \subseteq \{i, j : i + j = 2k\}$$

Und somit:

$$\begin{aligned} \mathbb{P}(S_k \geq qk) &\leq \max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk) \\ \frac{-\log \mathbb{P}(S_k \geq qk)}{k} &\geq -\frac{1}{k} \log(\max_{i+j=2k} \mathbb{P}(S_{i,j} \geq qk)) \end{aligned}$$

Die Ungleichung bleibt im Grenzwert für $k \rightarrow \infty$ erhalten.

Also ist $r' \leq r$

Zu zeigen $r' \geq r$
 zeige daher:

$$r' \geq r - \epsilon \text{ für alle } \epsilon > 0$$

seien i, j und $k = \frac{i+j}{2}$ groß genug, s.d.:

$$r' \leq -\frac{1}{k} \log \mathbb{P}(S_{i,j} \geq qk) < r' + \epsilon \quad (18)$$

Es gilt zunächst einmal:

$$\begin{aligned} \mathbb{P}(S_{2k} = S_{2k,2k} \geq q(2k)) & \quad (19) \\ &= \mathbb{P}(S_{i+j,i+j} \geq q(2k)) \\ &\geq \mathbb{P}(S_{i,j} + S(A_{i+1} \dots A_{i+j}, B_{j+1} \dots B_{j+i}) \geq q(2k)) \quad (\text{Superadditivität}) \\ &= \mathbb{P}(S_{i,j} + S_{j,i} \geq q(2k)) \quad (\text{identisch verteilt}) \\ &= \mathbb{P}(S_{i,j} + S_{i,j} \geq q(2k)) \quad (\text{Symm. zw. A,B}) \\ &\geq \mathbb{P}(S_{i,j} \geq qk \wedge S_{i,j} \geq qk) \\ &= \mathbb{P}(S_{i,j} \geq qk) \mathbb{P}(S_{i,j} \geq qk) \quad (\text{Unabhängigkeit}) \\ &= (\mathbb{P}(S_{i,j} \geq qk))^2 \quad (20) \end{aligned}$$

Außerdem gilt weiter:

$$\begin{aligned} r = r(q) &\stackrel{Def}{\leq} -\frac{1}{2k} \log \mathbb{P}(S_{2k} \geq 2qk) \\ &\stackrel{(20)}{\leq} -\frac{1}{2k} \log (\mathbb{P}(S_{i,j} \geq qk))^2 \\ &= -\frac{1}{k} \log \mathbb{P}(S_{i,j} \geq qk) \stackrel{(18)}{<} r' + \epsilon \end{aligned}$$

$$\Rightarrow r = r' \quad \square$$

Als nächstes soll gezeigt werden, dass für große μ und δ die lokale Tref-ferabgleichung (local alignment score) sich logarithmisch in n entwickelt. Um dies zu beweisen, benötigen wir zunächst folgende Vorbemerkungen:

Lemma 3. Wenn $\rho(\mu, \delta) < 0$ und $q \geq 0$, dann ist auch $r(q) > 0$.

Beweis. Es gilt:

$$\begin{aligned} \mathbb{P}(S_n \geq qn) &= \mathbb{P}(S_n - \rho n \geq (q - \rho)n) \quad (q - \rho > 0) \\ &\stackrel{(6)}{\leq} \exp\left(\frac{-(q - \rho)^2 n}{2c^2}\right) \quad (\text{Azuma-Hoeff.-Ungl.}) \\ \Rightarrow \frac{-\log \mathbb{P}(S_n \geq qn)}{n} &\geq -\frac{1}{n} \log\left(\exp\left(\frac{-(q - \rho)^2 n}{2c^2}\right)\right) \\ &= \frac{(q - \rho)^2}{2c^2} \stackrel{\rho < 0, q \geq 0}{>} 0 \end{aligned}$$

Dies ist unabhängig von n , also gilt $r(q) > 0$. \square

Bemerkung 7. Es gilt sogar allgemeiner: wenn $q > \rho(\mu, \delta)$ folgt $r(q) > 0$.

Beweis. Dies ist sofort aus dem vorherigem Beweis ersichtlich. \square

Definition 8. Sei $\rho(\mu, \delta) < 0$, dann definiere:

$$b = b(\mu, \delta) = \max_{q \geq 0} \frac{q}{r(q)} = \max_{q \in [0,1]} \frac{q}{r(q)} \quad (21)$$

Bemerkung 8. Es gilt:

$b > 0$, da $r(1) \stackrel{(14)}{=} -\log \mathbb{P}(A_1 = B_1)$. Außerdem wird das Maximum auf dem Kompaktum $[0, 1]$ angenommen und ist endlich.

Die Idee dieser Definition ist die folgende:

Möchte man zwei Sequenzen der Länge n vergleichen und die lokale Trefferabgleichung (local alignment score) H_n bestimmen, so gibt es $(n - t + 1) * (n - t + 1)$ Möglichkeiten für eine Abgleichung der Länge t . $\mathbb{P}(S_t \geq qt)$ ist die Wahrscheinlichkeit, dass die Trefferzahl der Teilabgleichung S_t größer als qt ist. Die erwartete Anzahl von Abgleichungen der Länge t mit einer Trefferzahl von mindestens qt ist $(n - t + 1)^2 * \mathbb{P}(S_t \geq qt)$:

$X := \# \text{Abgleichungen der Länge } t \text{ mit } S_t \geq qt$

$X_{i,j} := 1_{\{\text{Sequenzstück von } i \text{ bis } i+t \text{ abgeglichen mit Sequenzstück von } j \text{ bis } j+t, \text{ mit } S_t \geq qt\}}$

$$X = \sum_{i=1}^{n-t+1} \sum_{j=1}^{n-t+1} X_{i,j}$$

$$\begin{aligned} \mathbb{E}[X] &= \mathbb{E}\left[\sum_{i=1}^{n-t+1} \sum_{j=1}^{n-t+1} X_{i,j}\right] = (n - t + 1)^2 \mathbb{E}[X_{i,j}] \quad (\text{identisch verteilt}) \\ &= (n - t + 1)^2 \mathbb{P}(S_t \geq qt) \end{aligned}$$

Hält man t fest, wird n groß und beachtet man, dass gilt:

$\mathbb{P}(S_t \geq qt) \cong \exp(-tr(q))$, so gilt für die erwartete Anzahl an Teilsequenzen mit einer Trefferzahl von mindestens qt approximativ:

$$\mathbb{E}[X] \cong n^2 \exp(-tr(q))$$

Nehmen wir weiter an, dass die lokale Trefferabgleichung (local alignment score) eindeutig ist. So gilt:

$$\begin{aligned} 1 &= n^2 \exp(-tr(q)) \\ t &= \frac{\log(n^2)}{r(q)} \end{aligned}$$

Und somit sollte für die maximale Trefferzahl gelten:

$$\max_{q \in [0,1]} qt = \max_{q \in [0,1]} \frac{q}{r(q)} \log(n^2) = 2b \log(n)$$

Satz 5. Für alle $(\mu, \delta) \in [0, \infty]^2$ mit $\rho(\mu, \delta) < 0$ gilt:

$$\mathbb{P}((1 - \epsilon)b < \frac{H_n}{\log(n)} < (2 + \epsilon)b) \rightarrow 1 \text{ für alle } \epsilon > 0$$

Beweis. Wir führen den Beweis in zwei Schritten, für die untere Grenze und für die obere Grenze.

1. Die untere Grenze
zu zeigen:

$$\mathbb{P}((1 - \epsilon)b \log(n) < H_n) \rightarrow 1 \text{ für alle } \epsilon > 0$$

Sei $\epsilon > 0$, sei $\gamma > 0$ klein genug und $q > 0$ mit $\frac{q}{r(q)} \approx b$, so dass

$$(1 - \epsilon)b\left(\frac{r(q) + \gamma}{q}\right) < 1 - \frac{\epsilon}{2} \quad (22)$$

Das ist möglich, denn:

$$\begin{aligned} \frac{r(q) + \gamma}{q} &\approx \frac{1}{b} + \frac{\gamma}{q} \\ \Rightarrow (1 - \epsilon)\left(1 + \frac{b\gamma}{q}\right) &< 1 - \frac{\epsilon}{2} \text{ für } \gamma \text{ klein genug} \end{aligned}$$

Sei $t = (1 - \epsilon)b \log(n)$.

Weiter setze $k = \lfloor \frac{t}{q} \rfloor$.

Damit existiert ein $c \in \mathbb{R}^+$: $k \approx c \log(n)$

Ist n groß genug (je größer n ist, desto größer ist k), so wird k die folgende Ungleichung erfüllen:

$$r(q) \leq -\frac{1}{k} \log(\mathbb{P}(S_k \geq qk)) \leq r(q) + \gamma \quad (23)$$

(Infimum Eigenschaft)

Außerdem gilt:

$$\begin{aligned} \mathbb{P}(S_k \geq qk) &= \exp\left(-k\left(-\frac{1}{k}\right) \log(\mathbb{P}(S_k \geq qk))\right) \\ &\stackrel{(23)}{\geq} \exp(-k(r(q) + \gamma)) \\ &\geq \exp\left(-t\left(\frac{r(q) + \gamma}{q}\right)\right) & k = \lfloor \frac{t}{q} \rfloor \leq \frac{t}{q} \\ &\stackrel{(22)}{\geq} \exp\left(-\left(1 - \frac{\epsilon}{2}\right) \log(n)\right) & t = (1 - \epsilon)b \log(n) \\ &= n^{-1 + \frac{\epsilon}{2}} \end{aligned}$$

Nun zerteile $A_1 \dots A_n$ und $B_1 \dots B_n$ in sich nicht überlappende Blöcke der Länge $k+1$. So haben wir ungefähr $\frac{n}{k} \approx \frac{n}{c \log(n)}$ unabhängige Möglichkeiten für eine hohe Trefferzahl.

Jeder Block hat mindestens die Wahrscheinlichkeit $n^{-1+\frac{\epsilon}{2}}$ eine hohe Trefferzahl (score) zu erreichen.

Schließlich gilt dann mit $j = k + 1$, so dass $t < qj$:

$$\begin{aligned}
& \mathbb{P}(H_n < (1 - \epsilon)b \log(n)) \\
&= \mathbb{P}(H_n < t) \leq \mathbb{P}(H_n < qj) \\
&= \mathbb{P}(\max\{S(I, J) : I \subset A, B \subset J\} < qj) \\
&\leq \mathbb{P}\left(\bigcap_{0 \leq i \leq \lfloor \frac{n}{j} \rfloor - 1} \{S(A_{ij+1} \dots A_{ij+j}, B_{ij+1} \dots B_{ij+j}) < qj\}\right) \quad (\text{Teilmenge}) \\
&= \mathbb{P}(S_j < qj)^{\lfloor \frac{n}{j} \rfloor} \quad (\text{iiid}) \\
&< (1 - n^{-1+\frac{\epsilon}{2}})^{\lfloor (\frac{n}{j}) \rfloor} \quad (\text{für großes } n) \\
&\longrightarrow 0 \text{ für } n \rightarrow \infty
\end{aligned}$$

Denn es gilt für kleine $\epsilon > 0$:

$$\begin{aligned}
a &:= 1 - \frac{\epsilon}{2} \\
1 - n^{-1+\frac{\epsilon}{2}} &= 1 - \frac{1}{n^a} = \frac{1}{1 + \frac{1}{n^a - 1}} =: \frac{1}{1 + \frac{1}{m}} \\
(1 - n^{-1+\frac{\epsilon}{2}})^{\lfloor \frac{n}{j} \rfloor} &= \frac{1}{(1 + \frac{1}{m})^{\lfloor \frac{n}{j} \rfloor}}
\end{aligned}$$

Zu zeigen:

$$(1 + \frac{1}{m})^{\lfloor \frac{n}{j} \rfloor} \rightarrow \infty$$

Weiter gilt:

$$(1 + \frac{1}{m})^{\lfloor \frac{n}{j} \rfloor} = (1 + \frac{1}{m})^{m \frac{1}{m} \lfloor \frac{n}{j} \rfloor}$$

Zu zeigen:

$$\frac{1}{m} \lfloor \frac{n}{j} \rfloor \rightarrow \infty$$

und das gilt, da für n groß genug $n^{1-a} > j$

2. die obere Grenze:

zu zeigen: $\mathbb{P}(H_n \geq (2 + \epsilon)b \log(n)) \rightarrow 0$ für $n \rightarrow \infty$

sei $t = (2 + \epsilon)b \log(n)$

$\mathbb{P}(H_n \geq (2 + \epsilon)b \log(n)) = \mathbb{P}(H_n \geq t)$

Nun schauen wir uns die Menge $\{H_n \geq t\}$ genauer an:

$\{H_n \geq t\}$ besteht aus höchstens n^4 verschiedenen Elementen (beide Start und Endpunkte frei wählbar zwischen 1 und n).

Wir teilen diese Menge in zwei Teilmengen, wobei die eine ein Vielfaches von $(n \log(n))^2$ Elemente beinhalten soll und die andere alle Restlichen.

$$\begin{aligned}
& \{H_n \geq t\} \\
&= \{\max\{S(I, J) : I \subset A, J \subset B\} \geq t\} \\
&\subseteq \left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j \leq 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq t\} \right] \\
&\quad \cup \left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j > 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq 0\} \right]
\end{aligned} \tag{24}$$

1. Vereinigungsmenge

Sei $k = \frac{i+j}{2}$ und $t = qk$

Jedes Element hat höchstens die Wahrscheinlichkeit:

$$\begin{aligned}
\mathbb{P}(S_{i,j} \geq t) &= \mathbb{P}(S_{i,j} \geq qk) \\
&\leq \exp(-kr(q))
\end{aligned}$$

$$r'(q) \leq -\frac{1}{k} \log \mathbb{P}(S_{i,j} \geq qk)$$

$$= \exp\left(-t \frac{r(q)}{q}\right)$$

$$= \exp\left(-(2 + \epsilon) \left(\max_c \frac{c}{r(c)}\right) (\log(n)) \frac{r(q)}{q}\right)$$

$$\leq \exp(-(2 + \epsilon) \log(n))$$

$$\text{denn } \max_c \frac{c}{r(c)} \geq \frac{q}{r(q)}$$

$$\Leftrightarrow \max_c \frac{c}{r(c)} \frac{r(q)}{q} \geq 1$$

$$= n^{-(2+\epsilon)}$$

Da die 1. Vereinigung höchstens $n^2(2C \log(n))^2$ Elemente beinhaltet, gilt:

$$\begin{aligned}
\mathbb{P}\left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j \leq 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq t\}\right] \\
\leq n^2(2C \log(n))^2 n^{-(2+\epsilon)} \\
= \frac{4C^2(\log(n))^2}{n^\epsilon} = \frac{8C^2 \log(n)}{n\epsilon n^{\epsilon-1}} \quad (\text{l'Hopital}) \\
= \frac{8C^2 \log(n)}{\epsilon n^\epsilon} = \frac{8C^2}{\epsilon^2 n^{\epsilon-1} n} \\
= \frac{8C^2}{\epsilon^2 n^\epsilon} \\
\rightarrow 0 \text{ für } n \rightarrow \infty
\end{aligned}$$

2. Vereinigungsmenge

Diese setzt sich höchstens aus n^4 Elementen der Form $\{S_{i,j} \geq 0\}$ zusammen.

Jedes dieser Elemente lässt sich wie folgt abschätzen:

Sei $k = \frac{i+j}{2} > C \log(n)$ und $C = \frac{5}{r(0)}$. Da $\rho < 0$, ist $r(0) > 0$.

Dann folgt:

$$\begin{aligned}
\mathbb{P}(S_{i,j} \geq 0) &\leq \exp(-kr(0)) & r'(0) &\leq -\frac{1}{k} \log \mathbb{P}(S_{i,j} \geq 0) \\
&\leq \exp(-(C \log(n))r(0)) \\
&= \exp(-5 \log(n)) = \frac{1}{n^5}
\end{aligned}$$

Und weiter gilt:

$$\begin{aligned}
\mathbb{P}\left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j \geq 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq 0\}\right] \\
\leq n^4 \frac{1}{n^5} = \frac{1}{n} \\
\rightarrow 0 \text{ für } n \rightarrow \infty
\end{aligned}$$

Schließlich setzen wir alles zusammen, so folgt:

$$\begin{aligned}
&\mathbb{P}(\{H_n \geq (2 + \epsilon)b \log(n)\}) \\
&\leq \mathbb{P}\left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j \leq 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq t\}\right] \\
&\quad + \mathbb{P}\left[\bigcup_{\substack{i_0, j_0 \in [1, n] \\ i, j \leq n, i+j \geq 2C \log(n)}} \{S(A_{i_0+1} \dots A_{i_0+i}, B_{j_0+1} \dots B_{j_0+j}) \geq 0\}\right] \\
&\leq \frac{8C^2}{\epsilon^2 n^\epsilon} + \frac{1}{n} \\
&\rightarrow 0 \text{ für } n \rightarrow \infty
\end{aligned}$$

□

Als letztes kommen wir zu dem Fall, dass $\rho(\mu, \delta) > 0$

Satz 6. Wenn $\rho = \rho(\mu, \delta) > 0$, dann gilt:

$$\begin{aligned} \frac{S_n}{n} &\rightarrow \rho \text{ in Wahrscheinlichkeit} \\ \text{und} \\ \frac{H_n}{n} &\rightarrow \rho \text{ in Wahrscheinlichkeit} \end{aligned}$$

Beweis. Es reicht zu zeigen:

$$\mathbb{P}(H_n > (1 + \epsilon)n\rho) \rightarrow 0 \text{ für } n \rightarrow \infty \quad (25)$$

und

$$\mathbb{P}(S_n < (1 - \epsilon)n\rho) \rightarrow 0 \text{ für } n \rightarrow \infty, \quad (26)$$

denn es gilt $H_n \geq S_n$ nach Definition und somit:

$$\begin{aligned} \mathbb{P}(S_n > (1 + \epsilon)n\rho) &\leq \mathbb{P}(H_n > (1 + \epsilon)n\rho) \\ \mathbb{P}(H_n < (1 - \epsilon)n\rho) &\leq \mathbb{P}(S_n < (1 - \epsilon)n\rho) \end{aligned}$$

Sind die beiden Gleichungen (siehe oben) gezeigt, so folgt:

$$\begin{aligned} \mathbb{P}(H_n < (1 - \epsilon)n\rho \vee (1 + \epsilon)n\rho < H_n) &\rightarrow 0 \text{ für } n \rightarrow \infty \\ \mathbb{P}(S_n < (1 - \epsilon)n\rho \vee (1 + \epsilon)n\rho < S_n) &\rightarrow 0 \text{ für } n \rightarrow \infty \end{aligned}$$

und somit die Beh., denn: sei $\epsilon > 0$

$$\begin{aligned} \mathbb{P}(H_n < (1 - \epsilon)n\rho \vee (1 + \epsilon)n\rho < H_n) &\xrightarrow{n \rightarrow \infty} 0 \\ \Leftrightarrow \mathbb{P}(|\frac{H_n}{n} - \rho| > \epsilon\rho) &\stackrel{\epsilon' := \rho\epsilon}{=} \mathbb{P}(|\frac{H_n}{n} - \rho| > \epsilon') \xrightarrow{n \rightarrow \infty} 0 \\ \Leftrightarrow \frac{H_n}{n} &\rightarrow \rho \text{ in Wahrscheinlichkeit} \end{aligned}$$

S_n ganz analog.

Wir zeigen zunächst die erste Gleichung: (26).

Laut Satz 1 gilt:

$$\frac{S_n}{n} \rightarrow \rho \text{ fast sicher}$$

Außerdem ist S_n eine superadditive Folge und somit folgt mit Fekete's Lemma:

$$\lim_{n \rightarrow \infty} \frac{S_n}{n} = \sup_{m \geq 1} \frac{S_m}{m} \Rightarrow \rho \geq \frac{S_n}{n} \quad \forall n \text{ fast sicher}$$

So gilt weiter:

$$\begin{aligned} \mathbb{P}(S_n < (1 - \epsilon)n\rho) &= \mathbb{P}\left(\frac{S_n}{n} - \rho < -\epsilon\rho\right) \\ &\stackrel{\epsilon' := \epsilon\rho}{=} \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon'\right) \\ &= \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon'\right) + \underbrace{\mathbb{P}\left(-\rho + \frac{S_n}{n} > \epsilon'\right)}_{=0, \text{ da } \rho \geq \frac{S_n}{n} \text{ f.s.}} \\ &= \mathbb{P}\left(\rho - \frac{S_n}{n} > \epsilon' \vee -\rho + \frac{S_n}{n} > \epsilon'\right) \\ &= \mathbb{P}\left(\left|\rho - \frac{S_n}{n}\right| > \epsilon'\right) \\ &= \mathbb{P}\left(\left|\frac{S_n}{n} - \rho\right| > \epsilon'\right) \stackrel{n \rightarrow \infty}{\xrightarrow{\text{da } \frac{S_n}{n} \rightarrow \rho \text{ f.s.}}} 0 \quad \forall \epsilon' > 0 \end{aligned}$$

Aus fast sicherer Konvergenz folgt Konvergenz in Wahrscheinlichkeit. Nun bleibt noch (25):

$$\mathbb{P}(H_n > (1 + \epsilon)n\rho) \rightarrow 0 \text{ für } n \rightarrow \infty$$

zu zeigen.

Seien $i, j, n \in \mathbb{N}$ und $k = \frac{i+j}{2} \leq n$

Mit Hilfe von Lemma 2 gilt:

$$\begin{aligned} r &:= r((1 + \epsilon)\rho) \\ &= \lim_{k \rightarrow \infty} \left(-\frac{1}{k} \log \mathbb{P}(S_k \geq (1 + \epsilon)\rho k)\right) \\ &\stackrel{(17)}{=} \inf_{k \geq 1} \left(-\frac{1}{k} \log \max_{i+j=2k} \mathbb{P}(S_{i,j} \geq (1 + \epsilon)\rho k)\right) \\ &= r' \end{aligned}$$

weiter gilt $r > 0$, denn es gilt $\rho > 0$ und somit:

$$\begin{aligned} \mathbb{P}(S_k \geq (1 + \epsilon)\rho k) &= \mathbb{P}\left(\frac{S_k}{k} - \rho \geq \epsilon\rho\right) \\ &\stackrel{(6)}{\leq} \exp\left(-\frac{\epsilon^2 \rho^2 k}{2c^2}\right) \quad (\text{Azuma-Hoeff.-Ungl.}) \end{aligned}$$

Und deshalb:

$$\begin{aligned} -\frac{1}{k} \log \mathbb{P}(S_k \geq (1 + \epsilon)\rho k) &\geq -\frac{1}{k} \log(\exp(-\frac{\epsilon^2 \rho^2 k}{2c^2})) \\ &= \frac{\epsilon^2 \rho^2}{2c^2} > 0, \text{ da } \rho \neq 0 \text{ und } \epsilon > 0 \end{aligned}$$

Dies ist unabhängig von k und damit gilt $r > 0$, so folgt weiter:

$$\begin{aligned} \mathbb{P}(S_{i,j} \geq (1 + \epsilon)\rho k) &= \exp(-k(-\frac{1}{k}) \log(\mathbb{P}(S_{i,j} \geq (1 + \epsilon)\rho k))) \\ &\leq \exp(-k(\inf_{k \geq 1}(-\frac{1}{k}) \log(\mathbb{P}(S_{i,j} \geq (1 + \epsilon)\rho k)))) \\ &\leq \exp(-k(\inf_{k \geq 1}(-\frac{1}{k}) \log(\max_{i+j=k} \mathbb{P}(S_{i,j} \geq (1 + \epsilon)\rho k)))) \\ &= \exp(-kr') \stackrel{(17)}{=} \exp(-kr) \end{aligned}$$

Weiter gilt:

$$\begin{aligned} \mathbb{P}(S_{i,j} \geq (1 + \epsilon)n\rho) &\leq \mathbb{P}(S_{i,j} \geq (1 + \epsilon)k\rho) & (n \geq k) \\ &\leq \exp(-rk) \end{aligned}$$

Nun ergibt sich aufgrund der Trefferfunktion:

$$\begin{aligned} S_{i,j} &= S(A_1 \dots A_i, B_1 \dots B_j) \\ &\leq k \end{aligned}$$

So bedingt $S_{i,j} \geq (1 + \epsilon)n\rho$:

$$k \geq (1 + \epsilon)n\rho$$

Somit:

$$\begin{aligned} \mathbb{P}(S_{i,j} \geq (1 + \epsilon)n\rho) &\leq \exp(-rk) \\ &\leq \exp(-r(1 + \epsilon)n\rho) \end{aligned}$$

Zu guter Letzt gilt:

$$\begin{aligned} \mathbb{P}(H_n \geq (1 + \epsilon)n\rho) &= \mathbb{P}(\max\{S(I, J) : I \subset A, J \subset B\} \geq (1 + \epsilon)n\rho) \\ &= \mathbb{P}(\bigcup_{\substack{i,j \\ k,l}} \{S(A_{i+1} \dots A_{i+k}, B_{j+1} \dots B_{j+l}) \geq (1 + \epsilon)n\rho\}) \\ &\leq n^4 \mathbb{P}(S_{i,j} \geq (1 + \epsilon)n\rho) \\ &\quad \text{(beide Start- und Endpunkte frei auswählbar)} \\ &\leq n^4 \exp(-r(1 + \epsilon)n\rho) \\ &\longrightarrow 0 \text{ für } n \rightarrow \infty \end{aligned}$$

□

Damit ist das Theorem bewiesen.

Vergleicht man zwei Sequenzen der Länge n und vorausgesetzt, dass $n \rightarrow \infty$, so gibt es einen Phasenübergang zwischen linearer und logarithmischer Entwicklung. Das bedeutet:

Wenn $\rho(\mu, \delta) > 0$ wächst H_n mindestens so schnell wie $\rho(\mu, \delta)n$ und wenn $\rho(\mu, \delta) < 0$ ist, wächst H_n höchstens so schnell wie $b(\mu, \delta) \log(n^2)$ und mindestens so schnell wie $b(\mu, \delta) \log(n)$.

Auf der Linie $\{(\mu, \delta) : \rho(\mu, \delta) = 0\}$ findet dieser Phasenübergang statt.

4 Fazit

In dieser Arbeit wurde der Phasenübergang bewiesen für unabhängig und identisch verteilte Zufallsvariablen eines endlichen Alphabets. Außerdem haben wir eine spezielle Trefferfunktion und eine bestimmte Lückenfunktion vorgegeben:

$$s(a, b) = \begin{cases} +1, & a = b \\ -\mu, & a \neq b \end{cases}$$

$$g(k) = \delta k \text{ mit } (\mu, \delta) \in [0, \infty]^2$$

Der vorgestellte Beweis lässt sich auf Sequenzen unterschiedlicher Länge erweitern. Außerdem ist nicht zwingend erforderlich, dass $A_1, A_2, \dots, B_1, B_2, \dots$ unabhängig und identisch verteilt sind. Es genügt auch, dass A_1, A_2, \dots unabhängig und identisch nach μ verteilt sind und B_1, B_2, \dots nach ν .

Zur genaueren Interpretation von biologischen Sequenzabgleichungen benötigt man häufig ein komplizierteres Trefferschema $s(a, b)$, sowie eine komplexe Lückenfunktion $g(k)$.

Eine Verallgemeinerung besteht darin, eine allgemeine Lückenfunktion zuzulassen. Mit einer beliebigen Lückenfunktion $g : \mathbb{N} \rightarrow \mathbb{R}^+$ wird die subadditive Kostenfunktion definiert:

$$w(i) = \min \left\{ \sum_{j=1}^l g(i_j) \mid l, i_1, \dots, i_l \in \mathbb{N}, \sum_{j=1}^l i_j = i \right\}$$

$$w(0) := 0$$

Diese bewertet das Löschen von i zusammenhängenden Buchstaben. Damit ergibt sich für die globale Trefferabgleichung (global alignment score) die folgende Formel:

$$S_{n,m} = \max_{\substack{l \in \{0, \dots, \min\{n,m\}\} \\ 0=a(0)<\dots<a(l+1)=m+1 \\ 0=b(0)<\dots<b(l+1)=n+1}} \left\{ - \sum_{k=1}^{l+1} w(a(k) - a(k-1) - 1) \right. \\ \left. + w(b(k) - b(k-1) - 1) + \sum_{k=1}^l s(A_{a(k)}, B_{b(k)}) \right\}$$

Auch in diesem Fall erhält man den Phasenübergang in etwas allgemeinerer Form.

Außerdem lassen sich die meisten Ergebnisse auch auf zwei irreduzible aperiodische Markovketten verallgemeinern.