

Idee: Drei Matrizen:

Raphael
r_reitzi@cs...

- M — enden in (Mis)Match,
- I — enden in Insertion
- D — ——— Deletion

- $M_{0,0} = 0$
 $M_{i,0} = \infty$
 $M_{j,0} = \infty$
 $M_{i,j} = p(S_i, T_j)$
 $+ \min \begin{cases} M_{i-1,j-1} \\ I_{i-1,j-1} \\ D_{i-1,j-1} \end{cases}$

- $I_{0,0} = \infty$
 $I_{i,0} = \infty$
 $I_{0,j} = p + j \cdot \sigma$
 $I_{i,j} = \sigma + \min \begin{cases} M_{i,j-1} + p \\ I_{i,j-1} \\ D_{i,j-1} + p \end{cases}$

- $D_{0,0} = \infty$
 $D_{i,0} = p + i \cdot \sigma$
 $D_{0,j} = \infty$
 $D_{i,j} = \sigma + \min \begin{cases} M_{i-1,j} + p \\ I_{i-1,j} + p \\ D_{i-1,j} \end{cases}$

Algorithmus: wie bisher, aber berechne

im Schritt (i,j) $M_{i,j}, I_{i,j}, D_{i,j}$

→ Laufzeit \approx Faktor 3

Ergebnis: $\min \{ M_{m,n}, I_{m,n}, D_{m,n} \}$

Erstmals beschrieben von

Notoh : An improved algorithm
for matching biological
sequences. (1982)

Alignment wie gehabt durch Backtrac.
(durch drei Tabellen)

6 a) $(M1), (M2), (M3)$ klar.

ad $(M4)$:

Gegeben optimale Alignments für
 $(x,y), (y,z)$.

Wir konstruieren Alignment für (x,z)
mit Kosten $\leq \text{Sim}(x,y) + \text{Sim}(y,z)$.

(gzz; das optimale Alignment ist höchstens besser.)

Beobachtung: Kosten werden spaltenweise berechnet.

↳ Idee: Alignments ineinander schieben und "zusammenschieben", bis die Werte passen.

1) Füge in Alignments $(x,y)/(y,z)$ ^{so wenig} _{wie möglich} Gap-Spalten ein, bis die y -Zeilen zusammenpassen.

$$\text{wichtig: } \delta(-, -) = 0$$

2) Kombinieren zu Spalten der Form

$$\begin{matrix} x \\ y \\ z \end{matrix} \begin{pmatrix} a \\ b \\ c \end{pmatrix} \in \left(\sum \cup \{-\} \right)^3$$

wichtig: keine Spalte $\begin{pmatrix} - \\ - \\ - \end{pmatrix}$

3) Spaltenweise Δ -Ungl. nachweisen, also dass

$$\text{" } \delta(a, c) \leq \delta(a, b) + \delta(b, c) \text{ "}$$

- $\begin{pmatrix} - \\ b \\ - \end{pmatrix} \rightsquigarrow b \neq - \rightsquigarrow \begin{pmatrix} - \\ - \end{pmatrix}$ (und dann weg)

$$\rightsquigarrow \underbrace{\delta(-, -)}_{\text{Beitrag zu } \text{Sim}(x, z)} = 0 \leq 2g = \underbrace{\delta(-, b)}_{\text{Beitrag zu } \text{Sim}(x, y)} + \underbrace{\delta(b, -)}_{\text{Beitrag zu } \text{Sim}(y, z)}$$

- $\begin{pmatrix} - \\ - \\ c \end{pmatrix} \rightsquigarrow \begin{pmatrix} - \\ c \end{pmatrix} \quad \left(\begin{pmatrix} a \\ - \end{pmatrix} \text{ Symmetrisch} \right)$

$$\rightsquigarrow \delta(-, c) = g \leq 0 + g = \delta(-, -) + \delta(-, c)$$

- $\begin{pmatrix} - \\ b \\ c \end{pmatrix} \rightsquigarrow \begin{pmatrix} - \\ c \end{pmatrix} \quad \left(\begin{pmatrix} a \\ b \\ - \end{pmatrix} \text{ Symmetrisch} \right)$

$$\rightsquigarrow \delta(-, c) = g \stackrel{p \geq 0}{\leq} g + p(b, c) = \delta(-, b) + \delta(b, c)$$

- $(*) \quad \begin{pmatrix} a \\ b \\ c \end{pmatrix} \rightsquigarrow \begin{pmatrix} a \\ c \end{pmatrix}$

$$\rightsquigarrow \delta(a, c) = p(a, c) \stackrel{\Delta\text{-Ungl. für } p}{\leq} p(a, b) + p(b, c)$$

$$= d(a,b) + d(b,c)$$

$$\cdot \begin{pmatrix} a \\ - \\ c \end{pmatrix} \rightsquigarrow \begin{pmatrix} a \\ - \\ -c \end{pmatrix}$$

$$\rightsquigarrow d(a,-) + d(-,c) = 2g$$

Kosten vor- wie nachher. \parallel

b) Vorschlag: Nehme "Fastmetrik"
(\rightsquigarrow Beweis wie in a) + ϵ) \square

$$\Sigma = \{a, b, c\}$$

$$0 < g < 1$$

$$P = \begin{pmatrix} 0 & 1 & 3 \\ 1 & 0 & 1 \\ 3 & 1 & 0 \end{pmatrix}$$

Klar: (M1-3)
erfüllt.

Aber:

$$p(a,b) + p(b,c) = 2$$

$$p(a,c) = 3$$

$\rightsquigarrow \Delta$ -Ungl. verletzt.

Beweis, dass Metrik, wie in a)
außer für (*) ; sonst brauchten
wir Δ -Ungl nicht.

$$\text{ad } (*) \quad \begin{pmatrix} A \\ B \\ C \end{pmatrix} \rightsquigarrow \begin{cases} \begin{pmatrix} A & - \\ - & C \end{pmatrix} & , \text{sonst } i) \\ \begin{pmatrix} A \\ C \end{pmatrix} & , B \in \{A, C\} \text{ ii)} \end{cases}$$

$A, B, C \neq -$

$$\rightsquigarrow i) \quad \delta(A, -) + \delta(-, C)$$

$$= 2g < 2 \stackrel{i)}{\leq} \delta(A, B) + \delta(B, C)$$

$$ii) \quad \delta(A, C) \stackrel{p \geq 0}{\leq} \delta(A, B) + \delta(B, C)$$

$\in \{ \delta(A, B), \delta(B, C) \}$

□

c) (M1-3) — s.o.

(M4) ähnlich, können aber nicht alles zerlegen.

Neues Symbol: \vdash — Start eines Gap

\rightsquigarrow Schreiben $\begin{pmatrix} a \\ \vdash \end{pmatrix} \xrightarrow{\text{cost } p+q}$ für die ersten (linken) Gaps, $\begin{pmatrix} a \\ - \end{pmatrix} \xrightarrow{\text{cost } q}$ sonst. (insertions analog.)



Werden \vdash zu $-$ und umgekehrt?

• Behandle viele Fälle wie oben;
genauer: $\rightsquigarrow \begin{pmatrix} a \\ c \end{pmatrix}$ (Δ -Ungl. gilt)

für:

$$\begin{pmatrix} a \\ b \\ c \end{pmatrix}, \begin{pmatrix} a \\ b \\ \bar{c} \end{pmatrix}, \begin{pmatrix} a \\ b \\ - \end{pmatrix}, \begin{pmatrix} \bar{c} \\ b \\ c \end{pmatrix}, \begin{pmatrix} - \\ b \\ c \end{pmatrix},$$

$$\begin{pmatrix} \bar{c} \\ \bar{c} \\ c \end{pmatrix}, \begin{pmatrix} - \\ - \\ c \end{pmatrix}, \begin{pmatrix} a \\ \bar{c} \\ \bar{c} \end{pmatrix}, \begin{pmatrix} a \\ - \\ - \end{pmatrix},$$

$$\begin{pmatrix} \bar{c} \\ b \\ \bar{c} \end{pmatrix}, \begin{pmatrix} - \\ b \\ - \end{pmatrix}, \begin{pmatrix} \bar{c} \\ b \\ - \end{pmatrix}, \begin{pmatrix} - \\ b \\ \bar{c} \end{pmatrix}$$

- Übrig bleiben Blöcke der Form

z.B.

$$\begin{pmatrix} a & a & \bar{c} & a \\ \bar{c} & \bar{c} & \bar{c} & \bar{c} \end{pmatrix}$$

$$\begin{pmatrix} u \\ - \\ w \end{pmatrix}, \quad u, w$$

$$\leadsto \begin{pmatrix} u & | & - \\ \vdots & & w \end{pmatrix}$$

, dann passt es.

□

Siehe: Waterman, Smith, Beyer (1976)

Some biological sequence metrics.

d) (M2) geht kaputt:

- für semi-global (x, xy) bzw. (x, yx)

• für local (x, y, z, y)

haben Score 0, aber die Worte sind
i.A. nicht gleich.

(Ann: $\mathcal{J}(a, a) = 0$ f.a. a ; sonst ist aber
 $\text{Sim}(x, x) \neq 0 \leadsto \mathcal{J}(M_2)$)