

Theorem

The greedy algorithm to compute a superstring is a 3-approximation algorithm for MCCSP.

Proof:

Greedy: $(S_{j_1}, S_{j_2}, \dots, S_{j_n})$

Optimum: $(S_{i_1}, S_{i_2}, \dots, S_{i_n})$

Wir zeigen: $\langle S_{j_k}, S_{j_{k+1}} \rangle$ kann höchstens drei Merges der optimalen Lösung unmöglich machen.

1. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_\ell}, S_{i_{\ell+1}} \rangle$ für $\ell \in [1:n-1]$
→ beide identisch, kein Merge verhindert

2. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_\ell}, S_{i_{\ell+m}} \rangle$, $m > 1$,
→ höchstens 2 Merges unmöglich, nämlich

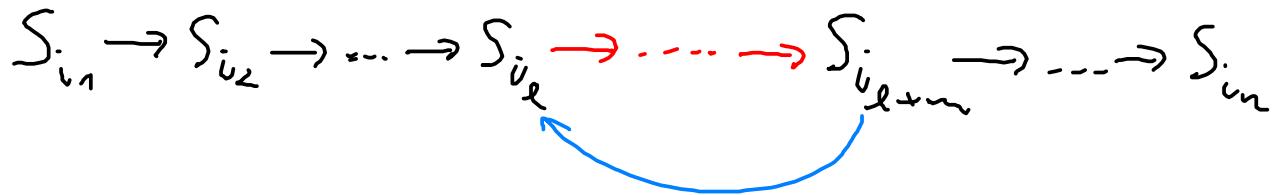
$$\frac{S_{j_k}}{\overbrace{\quad\quad\quad}^{l+1} S_{j_{k+1}}}$$

$\langle S_{i_\ell}, S_{i_{\ell+1}} \rangle$ und

$\langle S_{i_{\ell+m-1}}, S_{i_{\ell+m}} \rangle$

3. Fall: $\langle S_{j_k}, S_{j_{k+1}} \rangle = \langle S_{i_{\ell+m}}, S_{i_\ell} \rangle$ für geeignetes
→ höchstens 3 Merges unmöglich

$\langle S_{i_{e+1}}, S_{i_{e+2}} \rangle$, $\langle S_{i_{e-1}}, S_i_e \rangle$ und einer der Merges $\langle S_{i_1}, S_{i_{e+1}} \rangle, \dots, \langle S_{i_{e+m-1}}, S_{i_{e+m}} \rangle$, da Anwendung zu Z₇Kel führte



↖ schließt Z₇Kel \Rightarrow eine der Kanten \rightarrow unmöglich.

$M_x \triangleq$ Menge der Merges von Algorithmus $x \in \{g, o\}$

$V(m) \subseteq M_o \triangleq$ Menge der von $m = \langle S_{j_{k+1}}, S_{j_{k+2}} \rangle \in M_g$ verhinderten Merges

Für $ov(m)$, $m \in M_g$, Länge des durch m verschmolzenen Overlaps, gilt:

$$(H_{m \in M_g}): (ov(m) \geq \frac{1}{3} \left(\sum_{m' \in V(m)} ov(m') \right)) \quad (*)$$

↑ max. 3 Summanden

dem Greedy wählt unter verl. Merges immer den mit max. Overlap \rightarrow von m verhindelter Merge hat ov Overlap $> ov(m)$.

Außerdem gilt

$$(Hm' \in M_0) : (m' \in M_g) \vee ((\exists m \in M_g \setminus M_0) : \underline{(m' \in V(m))})$$

(*)

denn für $m' = \langle S, \bar{S} \rangle \in M_g$ muß es in M_g Merges geben, die S und \bar{S} mit anderen Wörtern verbinden, wodurch m' verhindert wird. Ein solcher Merge kann nicht in M_0 liegen, da er ja $m' \in M_0$ verhindert.

Betrachte nun

$$\sum_{m \in M_g} ov(m) = \sum_{m \in M_g \cap M_0} ov(m) + \sum_{m \in M_g \setminus M_0} ov(m)$$

Es gilt:

$$\sum_{m \in M_g \cap M_0} ov(m) \geq \frac{1}{3} \sum_{m \in M_0 \cap M_g} ov(m) \quad \text{und}$$

$$\sum_{\substack{m \in M_g \setminus M_0 \\ \subseteq M_g}} \text{ov}(m) \stackrel{(*)}{\geq} \sum_{m \in M_g \setminus M_0} \frac{1}{3} \sum_{m' \in V(m)} \text{ov}(m')$$

$$\stackrel{(**)}{\geq} \frac{1}{3} \sum_{m' \in M_0 \setminus M_g} \text{ov}(m') \quad m' \in M_0 \subseteq M_g$$

$$\Rightarrow \frac{\text{Comp}(w_0)}{\text{Comp}(w_1)} = \frac{\sum_{m' \in M_0} \text{ov}(m')}{\sum_{m \in M_g} \text{ov}(m)} \leq \frac{\sum_{m' \in M_0} \text{ov}(m')}{\frac{1}{3} \sum_{m' \in M_0} \text{ov}(m')} = 3$$

Using more elaborate reasoning one can show:

Theorem

The greedy algorithm to compute a superstring is a 2-approximation algorithm for MCCSP. \square

Alternative Procedure

Idea: Do not use a single cycle to cover all vertices but a set of cycles

\rightsquigarrow cycle-cover for which each vertex must be part of exactly one cycle.

Here: Cycle-cover of minimal cost (according to distance graph).

Remark: A minimal cycle-cover can be computed in time $O(n^3)$ (whereas the restriction to edges to be covered by at least one cycle leads to an NP -complete problem).

Def.: Sei $G = (V, E, g)$ ein vollständiger Digraph mit Kantengewichten $g: E \rightarrow \mathbb{N}$. Ein Cycle-Cover von

G besteht aus einer Menge $\mathcal{K} = \{K_1, \dots, K_e\}$ gerichtete Kreise in G , so dass jeder Knoten in V in genau einem Kreis $K_i \in \mathcal{K}$ vorkommt.

Kosten: \sum Kantengewichte aller Kreise.

Approximation: Construct a single cycle (solution to TSP) from the minimal cycle-cover.

Steps:

1. Identify each cycle $c \in \mathcal{C}$ by one of its vertices \rightsquigarrow set of vertices R .
2. Compute a minimal cycle-cover for the subgraph induced by $R \rightsquigarrow$ set of cycles \mathcal{C}' .
3. For each $c \in \mathcal{C}'$ delete the edge corresponding to a merge of minimal overlap \rightsquigarrow broken cycles are considered as merged strings.
4. Concatenate these strings and expand each of its elements by the cycle from \mathcal{C} it represents.

$$K_1 = \textcircled{a_1} \rightarrow a_2 \rightarrow \dots \rightarrow a_n \rightarrow a_1 = \langle a_1, a_2, \dots, a_n \rangle$$

$$K_2 =$$

:

$$K_7 = \textcircled{g_1} \rightarrow g_2 \rightarrow g_3 \rightarrow g_1$$

$\textcircled{\text{ }} \text{Repräsentant}$

r_{K_i}

alle zusammen = R

Cover for r_{K_i} :

$$K'_1 = a_1 \rightarrow b_1 \rightarrow c_1 \rightarrow a_1$$

$$K'_2 = d_1 \rightarrow e_1 \rightarrow d_1$$

$$U_3' = f_7 \not\rightarrow g_7 \rightarrow f_7$$

$$U_1 = \langle b_1, c_1, a_1 \rangle$$

$$U_2 = \langle e_1, d_1 \rangle$$

$$U_3 = \langle g_1, f_1 \rangle$$

$$\leadsto w' = U_1 U_2 U_3$$

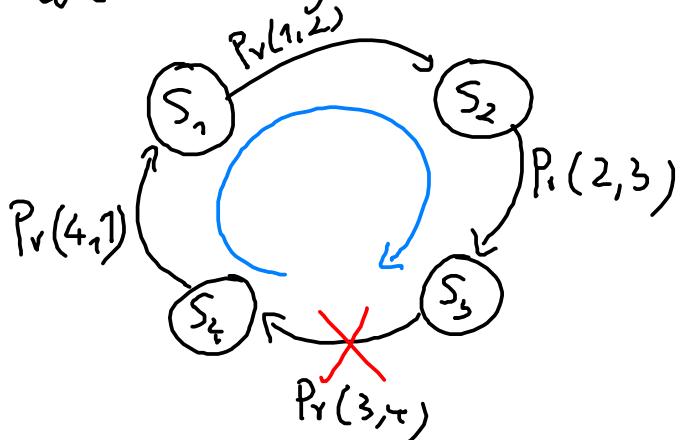
In w' ersetzen wir die Repräsentanten durch die zu ihnen geh., 'Kreise'

Theorem

The algorithm just outlined is a 3-approximation algorithm for SCSP.

Proof:

Optimale Lösung (TSP) sei:



Kosten für SCSP

$$\begin{aligned} \text{Kosten TSP: } & P_r(1,2) + P_r(2,3) \longrightarrow P_r(4,1) + P_r(1,2) \\ & + P_r(3,4) < P_r(4,1) + P_r(2,3) + |S_3| \end{aligned}$$

Es gilt: $|S_i| > P_r(i,j) \Rightarrow$ Kosten TSP stets untere Schranke für SCSP. Außerdem sind Kosten

eines min. Cycle-Cover untere Schranke für Kosten

TSP

$$\Rightarrow \text{cost}(\mathcal{K}) = \text{Opt}_{cc}(\text{DG}(S)) \leq \text{Opt}_{SCS}(S)$$

$$\text{cost}(\mathcal{K}') = \text{Opt}_{cc}(\text{DG}(R)) \leq \text{Opt}_{SCS}(R)$$

Außerdem $\text{cost}(\mathcal{K}') \leq \text{cost}(\mathcal{K})$ (o)

$$|U_i| = \text{cost}(k'_i) + \text{minor}(k'_i)$$

↑ min. Overlap der Kreise k'_i

$$|w'| \leq \text{cost}(\mathcal{K}') + \sum_{k' \in \mathcal{K}'} \text{minor}(k') \quad (*)$$

Ersetzen wir in w' alle Repräsentanten durch „Kreis“

$$\rightarrow Y_n = a_n \rightarrow \underbrace{P_1(1,2) \cdot P_1(2,3) \cdots P_1(4,1)}_{\mathcal{K}} \cdot a_1$$

w' verlängert sich um Gewicht ↑

$$|w| \leq |w'| + \text{cost}(\mathcal{K})$$

$$\stackrel{(*)}{\leq} \text{cost}(\mathcal{K}') + \sum_{k' \in \mathcal{K}'} \text{minor}(k') + \text{cost}(\mathcal{K})$$

$$\stackrel{(o)}{\leq} 2 \cdot \text{cost}(\mathcal{K}) + \sum_{k' \in \mathcal{K}'} \text{minor}(k')$$

Jeder Kreis mind.

Nur gilt offensichtlich

$$\sum_{k' \in \mathcal{K}'} \text{minor}(k') \leq \frac{1}{2} \cdot \sum_{k' \in \mathcal{K}'} \sum_{(s_i, s_j) \in k'} \text{ov}(s_i, s_j)$$

2 Kanten

$$\Rightarrow |w| \leq 2 \cdot \text{cost}(\mathcal{K}) + \frac{1}{2} \sum_{k' \in \mathcal{K}'} \sum_{(s_i, s_j) \in k'} \text{ov}(s_i, s_j)$$

Lemma: K_1, K_2 zwei Kreise in min. CC \mathcal{K} und $w_1 \in K_1, w_2 \in K_2$ zwei Wörter in diesen Kreisen.

Dann gilt

$$\text{ov}(w_1, w_2) \leq \text{cost}(K_1) + \text{cost}(K_2)$$



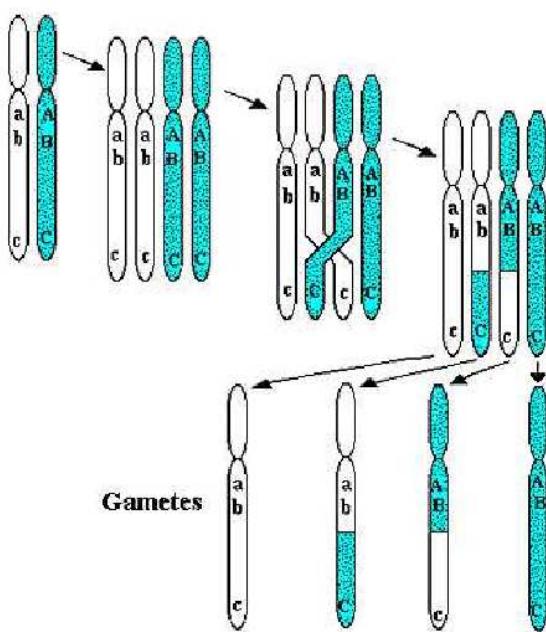
$$\sum_{k' \in \mathcal{K}'} \sum_{(s_i, s_j) \in k'} \text{ov}(s_i, s_j) < \sum_{k' \in \mathcal{K}'} \sum_{(s_i, s_j) \in k'} (\text{cost}(K_i) + \text{cost}(K_j))$$

$$= 2 \cdot \text{cost}(\mathcal{K})$$

$$\Rightarrow |w| \leq 3 \cdot \text{cost}(\mathcal{K})$$

$$\leq 3 \cdot \text{Opt}_{\text{SCS}}(S)$$

□



Crossing-over and recombination during meiosis

