

SHORTEST COMMON SUPERSTRING

Eingabe: eine Menge U von n Strings;

Ausgabe: ein String S minimaler Länge der alle Strings in U als Teilstrings enthält;

(Ein String u ist ein endliches Wort über einem endlichen Alphabet Σ .)

Es ist annehmbar dass kein String in U Teilstring eines anderen ist.

Anwendung:

Sequenzierung:

die Reihenfolge von Basenpaaren in einem DNA-Molekül zu bestimmen

Einführung

Def. 1: Für Strings u und v ist $\text{overlap}(u, v)$ die *Länge* des längsten Suffix von u der auch Präfix von v ist.

Def. 2: $\text{Präfix}(u, v)$ ist der nicht von v überdeckte Präfix in u .

Def. 3: Eine Bijektion $\pi : \{1, 2, \dots, n\} \rightarrow U$ definiert eine Reihenfolge der Strings in U ,

$$\pi(1), \pi(2), \dots, \pi(n)$$

und damit den kürzesten Superstring $S(\pi)$

für diese Reihenfolge:

$$S(\pi) = \text{Präfix}(\pi(1), \pi(2)) \cdot \dots \cdot \text{Präfix}(\pi(n-1), \pi(n)) \cdot \pi(n)$$

$S(\pi)$ ist der durch π induzierte Superstring von U

Beobachtungen

Behauptung 1. Wenn S^* ein kürzester Superstring ist, dann existiert eine Reihenfolge π mit $S^* = S(\pi)$.

Behauptung 2.

$$|S(\pi)| = \sum_{u \in U} |u| - \sum_{i=1}^{n-1} \text{overlap}(\pi(i), \pi(i+1))$$

Also: wir brauchen eine Reihenfolge der Strings in U die die Summe der Overlaps maximiert!

1. Greedy-Superstring Algorithmus

Sei U die Menge der Strings

REPEAT

- bestimme zwei Strings $u \neq v$ mit maximalem $\text{overlap}(u, v)$;
- 'verschmelze' u und v zu einem String

UNTIL $|U| = 1$;

Gib den einzigen String in U als Superstring aus.

Theorem: Der Greedy-Superstring algorithmus ist 4-approximativ.
(Ohne Beweis.)

Vermutung: Er ist sogar 2-approximativ.

Overlap-Graph

- sei $G(U, E)$ ein *vollständiger gerichteter* Graph über den Strings in U als Knoten; mit $\text{overlap}(u, v)$; als Kantengewichten
- eine Reihenfolge der Strings mit maximaler Summe der Overlaps

=

ein Hamiltonscher Pfad mit maximalem Gesamtgewicht seiner Kanten

- leider ist max-HAMILTONSCHER-PFAD NP-schwer ...
- ... man verwendet Approximationsalgorithmen

2. Noch ein Algorithmus (Vorbereitung)

- (leider ist max-HAMILTONSCHER-PFAD NP-schwer)
- suche (*gerichtete*) *Kreis-Zerlegung* (*directed cycle cover*) mit maximalem Gewicht

Definition:

Die Kantenmenge $E' \subseteq E$ ist eine Kreis-Zerlegung



E' besteht aus disjunkten Kreisen die gemeinsam jeden Knoten einmal überdecken



jeder Knoten hat eine eingehende und eine ausgehende Kante

Fragen

1. Wie berechnet man eine maximale *Kreis-Zerlegung*?
2. Wie benutzt man die Kreis-Zerlegung für SHORTEST COMMON SUPERSTRING?
3. Approximationsfaktor?

1. Ein Greedy Algorithmus für maximale Kreis-Zerlegung

Eingabe: ein Overlap-Graph

setze $E' = \emptyset$ (initialisiere Kreis-Zerlegung)

REPEAT

- bestimme Kante $(u, v) \in E$ mit maximalem Gewicht;
setze $E := E \setminus \{(u, v)\}$, und $E' := E' \cup \{(u, v)\}$
- entferne aus E alle aus u ausgehende und in v eingehende Kanten

UNTIL $E = \emptyset$

Theorem: Der Algorithmus berechnet eine maximale Kreis-Zerlegung im Overlap-Graph.

NUR IM OVERLAP-GRAPH OPTIMAL !!

Der Beweis dass dieser Greedy Algorithmus optimal ist benutzt das folgende

Lemma:

Falls

$$\text{overlap}(u, v) \geq \text{overlap}(u, v^*)$$

und

$$\text{overlap}(u, v) \geq \text{overlap}(u^*, v)$$

dann gilt

$$\text{overlap}(u, v) + \text{overlap}(u^*, v^*) \geq \text{overlap}(u^*, v) + \text{overlap}(u, v^*)$$

2. Ein Kreis im Overlap-Graph

Ein gerichteter Kreis $C(u_1, u_2, \dots, u_m, u_1)$ im Overlap-Graph entspricht einem String

$$v = \text{Praefix}(u_1, u_2) \cdot \text{Praefix}(u_2, u_3) \cdot \dots \cdot \text{Praefix}(u_m, u_1).$$

Beobachtung 1: v^∞ bezeichne den unendlich oft mit sich selbst konkatenierten String v .

All die u_1, u_2, \dots, u_m sind Teilstrings von v^∞ .

v wird auch *Zyklus* genannt,

und alle u_i (länger als v) sind zyklisch mit Periode v

Die Kreise einer Kreis-Zerlegung

Der Zyklus v von einem Kreis $C(u_1, u_2, \dots, u_m, u_1)$ hat Länge

$$|v| = \sum_{i=1}^m |\text{Praefix}(u_i, u_{i+1})| = \sum_{i=1}^m |u_i| - \sum_{i=1}^m \text{overlap}(u_i, u_{i+1}) \quad \text{mod } m.$$

wobei $m + 1 = 1 \pmod m$

Beobachtung 2: Seien C_1, \dots, C_l die Kreise einer Kreis-Zerlegung E' , und die Strings v_1, v_2, \dots, v_l ihre Zyklen. Dann gilt

$$\sum_{k=1}^l |v_k| = \sum_{i=1}^n |u_i| - \sum_{(u,v) \in E'} \text{overlap}(u, v) = \sum_{i=1}^n |u_i| - \text{Gewicht der } E'.$$

Zyklus-Überdeckung

Definition: Die Zyklen aller Kreise v_1, v_2, \dots, v_ℓ ergibt eine Zyklus-Überdeckung von U weil jeder $u \in U$ von einem v_k zyklisch überdeckt wird.

Beobachtung 3.: v_1, v_2, \dots, v_ℓ ist eine *minimale* Zyklus-Überdeckung
(d.h. $\sum_k |v_k|$ minimal)



E' eine Kreis-Zerlegung mit maximalem Gewicht.

Theorem: Sei $S^* = S(\pi)$ ein *Shortest Common Superstring* von U , dann gilt

$$|S^*| \geq \sum_{k=1}^{\ell} |v_k|$$

Algorithmus für SHORTEST COMMON SUPERSTRING

1. Bestimme eine Kreis-Zerlegung mit maximalem Gewicht C_1, C_2, \dots, C_ℓ im Overlap-Graph
2. sei v_k der Zyklus von Kreis $C_k = (u_1^k, u_2^k, \dots, u_{m_k}^k)$
3. Sei S_k der Zyklus v_k *aufgebrochen*,
so dass S_k jeden String in C_k enthält;
dann gilt $|S_k| \leq |u_1^k| + |v_k|$.
4. Gib die Konkatenation aller S_k als Superstring aus:

$$S = S_1 \cdot S_2 \cdot \dots \cdot S_\ell$$

3. Approximationsfaktor

Theorem 1: Der obige Algorithmus für SHORTEST COMMON SUPERSTRING ist 4-approximativ.

Theorem 2: Bei 'nicht-periodischen Strings', also wenn in jedem Kreis C_k einen String u_i^k gibt mit $|u_i^k| \leq |v_k|$ ist er 2-approximativ.

Approximationsfaktor Analyse

Sei S' ein kürzester Superstring aller ersten Strings in jedem Kreis:

$$u_1^1, u_1^2, \dots, u_1^k, \dots, u_1^\ell$$

Dann gilt

$$\begin{aligned} |S^*| &\geq |S'| = \sum_{k=1}^{\ell} |u_1^k| - \sum_{k=1}^{\ell-1} \text{overlap}(u_1^k, u_1^{k+1}) \geq \\ &\sum_{k=1}^{\ell} |u_1^k| - \sum_{k=1}^{\ell-1} (|v_k| + |v_{k+1}|) \geq \sum_{k=1}^{\ell} |u_1^k| - 2 \cdot \sum_{k=1}^{\ell} |v_k| \\ \Rightarrow \quad &\sum_{k=1}^{\ell} |u_1^k| \leq |S^*| + 2 \cdot \sum_{k=1}^{\ell} |v_k| \leq 3 \cdot |S^*| \end{aligned}$$