

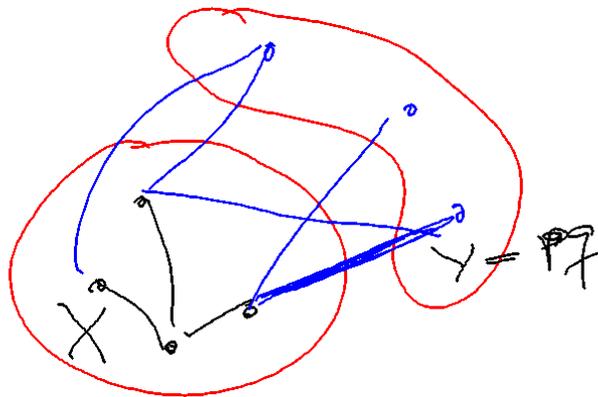
Script generated by TTT

Title: Seidl: GAD (29.06.2016)

Date: Wed Jun 29 13:22:32 CEST 2016

Duration: 44:20 min

Pages: 23



Graphen Minimale Spannäume

Algorithmus Jarník-Prim: findet minimalen Spannbaum

Eingabe : $G = (V, E)$, $c : E \mapsto \mathbb{R}_+$, $s \in V$

Ausgabe : Minimaler Spannbaum in Array *pred*

```
d[v] = ∞ for all v ∈ V \ s;
d[s] = 0;  pred[s] = ⊥;
pq = ⟨⟩;  pq.insert(s, 0);
while ¬pq.empty() do
  v = pq.deleteMin();
  forall {v, w} ∈ E do
    newWeight = c(v, w);
    if newWeight < d[w] then
      pred[w] = v;
      if d[w] == ∞ then pq.insert(w, newWeight);
    else
      if w ∈ pq then pq.decreaseKey(w, newWeight);
      d[w] = newWeight;
```

H. Seidl (TUM) GAD SS'16 558

Pattern Matching Naiver Algorithmus

Naiver Algorithmus: Beispiele

t = a a a a a a a a a a

a a a b

a a a b

a a a b

H. Seidl (TUM) GAD SS'16 564

Naiver Algorithmus: Implementation

Funktion NaiveSearch(char $t[]$, int n , char $s[]$, int m)

```

int  $i := 0$ ,  $j := 0$ ;
while ( $i \leq n - m$ ) do
  while ( $t[i + j] = s[j]$ ) do
     $j++$ ;
    if ( $j = m$ ) then
      return TRUE;
     $i++$ ;
   $j := 0$ ;
return FALSE;

```

Analyse des naiven Algorithmus

- zähle Vergleiche von Zeichen,
- äußere Schleife wird $(n - m + 1)$ -mal durchlaufen,
- die innere Schleife wird maximal m -mal durchlaufen.
- maximale Anzahl von Vergleichen: $(n - m + 1)m$,
- Laufzeit: $O(nm)$

Bessere Idee

- frühere **erfolgreiche** Zeichenvergleiche ausnutzen
- Idee:
Suchwort so weit nach rechts verschieben, dass in dem Bereich von t , in dem bereits beim vorherigen Versuch erfolgreiche Zeichenvergleiche durchgeführt wurden, nun nach dem Verschieben auch wieder die Zeichen in diesem Bereich übereinstimmen

Rand und eigentlicher Rand

Definition

Ein Wort r heißt **Rand** eines Wortes w , wenn r **Präfix und Suffix** von w ist. (Für jedes Wort w ist das leere Wort ε ein Rand von w , genau wie w selbst.)

Ein Rand r eines Wortes w heißt **eigentlicher Rand**, wenn $r \neq w$ und wenn es außer w selbst keinen längeren Rand gibt.

Rand und eigentlicher Rand

Beispiel

Das Wort $w = \text{aabaabaa}$ besitzt folgende Ränder:

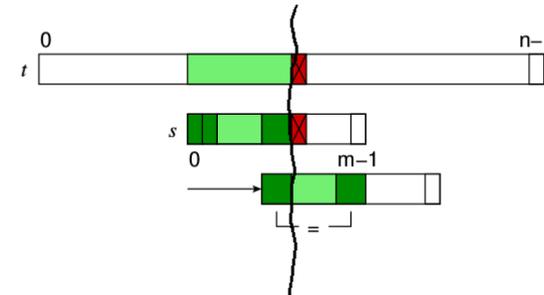
- ϵ
- a
- aa
- **aabaa**
- **aabaabaa** = w .

Der eigentliche Rand ist aabaa.

Beachte: bei der Darstellung des Rands im Wort können sich Präfix und Suffix in der Wortmitte überlappen.

Shift-Idee

- Pattern s so verschieben, dass im bereits gematchten Bereich wieder Übereinstimmung herrscht.
- Dazu müssen überlappendes Präfix und Suffix dieses Bereichs übereinstimmen.



Shifts und sichere Shifts

Definition

Eine Verschiebung der Anfangsposition i des zu suchenden Wortes (also eine Indexerhöhung $i \rightarrow i'$) heißt **Shift**.

Ein Shift von $i \rightarrow i'$ heißt **sicher**, wenn s nicht als Teilwort von t an der Position $k \in [i + 1 : i' - 1]$ vorkommt, d.h., $s \neq t_k \cdots t_{k+m-1}$ für alle $k \in [i + 1 : i' - 1]$.

- Sinn eines sicheren Shifts: dass man beim Verschieben des Suchworts kein eventuell vorhandenes Vorkommen von s in t überspringt

Sichere Shifts

Definition

Sei $\partial(s)$ der eigentliche Rand von s und sei

$$\text{border}[j] = \begin{cases} -1 & \text{für } j = 0 \\ |\partial(s_0 \cdots s_{j-1})| & \text{für } j \geq 1 \end{cases}$$

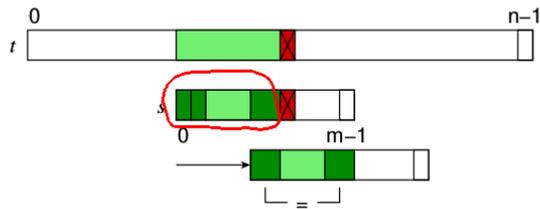
die Länge des eigentlichen Rands des Präfixes der Länge j .

Lemma

Ist das Präfix der Länge j gematcht (also gilt $s_k = t_{i+k}$ für alle $k \in [0 : j - 1]$) und haben wir ein Mismatch an der nächsten Position j ($s_j \neq t_{i+j}$), dann ist der Shift $i \rightarrow i + j - \text{border}[j]$ sicher.

Shift-Idee

- Pattern s so verschieben, dass im bereits gematchten Bereich wieder Übereinstimmung herrscht.
- Dazu müssen überlappendes Präfix und Suffix dieses Bereichs übereinstimmen.



Sichere Shifts

Definition

Sei $\partial(s)$ der eigentliche Rand von s und sei

$$\text{border}[j] = \begin{cases} -1 & \text{für } j = 0 \\ |\partial(s_0 \cdots s_{j-1})| & \text{für } j \geq 1 \end{cases}$$

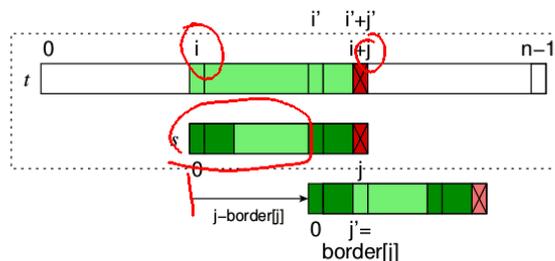
die Länge des eigentlichen Rands des Präfixes der Länge j .

Lemma

Ist das Präfix der Länge j gematcht (also gilt $s_k = t_{i+k}$ für alle $k \in [0 : j - 1]$) und haben wir ein Mismatch an der nächsten Position j ($s_j \neq t_{i+j}$), dann ist der Shift $i \rightarrow i + j - \text{border}[j]$ sicher.

Sichere Shifts

Shift um $j - \text{border}[j]$



Sichere Shifts

Beweis.

- (siehe Skizze)

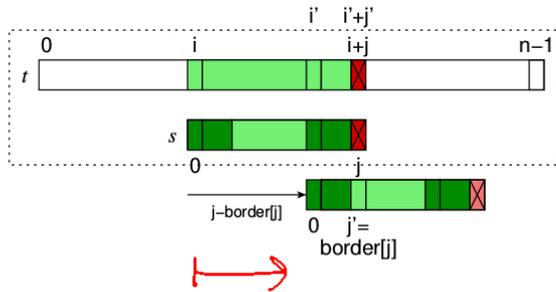
$$s_0 \cdots s_{j-1} = t_i \cdots t_{i+j-1}, \\ s_j \neq t_{i+j}$$

- Der eigentliche Rand von $s_0 \cdots s_{j-1}$ hat die Länge $\text{border}[j]$.
- Verschiebt man s um $j - \text{border}[j]$ nach rechts, so liegt der linke Rand von $s_0 \cdots s_{j-1}$ nun genau da, wo vorher der rechte Rand lag, d.h. im Präfix/Suffix-Überlappungsbereich besteht Übereinstimmung zwischen Präfix, Suffix und Text.
- Da es keinen längeren Rand von $s_0 \cdots s_{j-1}$ als diesen gibt (außer $s_0 \cdots s_{j-1}$ selbst), ist dieser Shift sicher.



Sichere Shifts

Shift um $j - \text{border}[j]$



KMP-Algorithmus

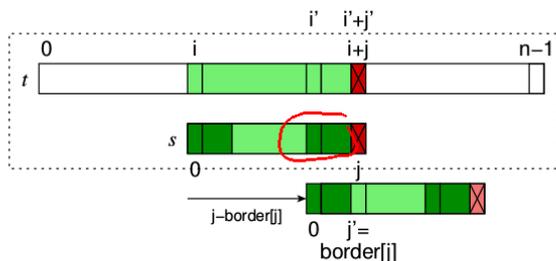
Funktion $\text{KMP}(t[], n, s[], m)$

```

int border[m + 1];
computeBorders(border, m, s);
int i := 0, j := 0;
while i ≤ n - m do
    while t[i + j] = s[j] do
        j++;
        if j = m then
            return TRUE;
    i := i + (j - border[j]); // Es gilt j - border[j] > 0
    j := max{0, border[j]};
return FALSE;
    
```

Sichere Shifts

Shift um $j - \text{border}[j]$



Sichere Shifts

Beweis.

- (siehe Skizze)

$$s_0 \cdots s_{j-1} = t_i \cdots t_{i+j-1},$$

$$s_j \neq t_{i+j}$$

- Der eigentliche Rand von $s_0 \cdots s_{j-1}$ hat die Länge $\text{border}[j]$.
- Verschiebt man s um $j - \text{border}[j]$ nach rechts, so liegt der linke Rand von $s_0 \cdots s_{j-1}$ nun genau da, wo vorher der rechte Rand lag, d.h. im Präfix/Suffix-Überlappungsbereich besteht Übereinstimmung zwischen Präfix, Suffix und Text.
- Da es keinen längeren Rand von $s_0 \cdots s_{j-1}$ als diesen gibt (außer $s_0 \cdots s_{j-1}$ selbst), ist dieser Shift sicher.



KMP-Algorithmus

Funktion $\text{KMP}(t[], n, s[], m)$

```

int border[m + 1];
computeBorders(border, m, s);
int i := 0, j := 0;
while i ≤ n - m do
  while t[i + j] = s[j] do
    j++;
    if j = m then
      return TRUE;
    i := i + (j - border[j]);           // Es gilt j - border[j] > 0
    j := max{0, border[j]};
return FALSE;

```



KMP-Algorithmus

Funktion $\text{KMP}(t[], n, s[], m)$

```

int border[m + 1];
computeBorders(border, m, s);
int i := 0, j := 0;
while i ≤ n - m do
  while t[i + j] = s[j] do
    j++;
    if j = m then
      return TRUE;
    i := i + (j - border[j]);           // Es gilt j - border[j] > 0
    j := max{0, border[j]};
return FALSE;

```



Laufzeit des KMP-Algorithmus: erfolglose Vergleiche

Nach **erfolglosem** Vergleich (Mismatch) wird $(i + j)$ nie kleiner:

- Seien dazu i und j die Werte vor einem erfolglosen Vergleich und i' und j' die Werte nach einem erfolglosen Vergleich.
- Wert vor dem Vergleich: $i + j$
- Wert nach dem Vergleich:
 $i' + j' = (i + j - \text{border}[j]) + (\max\{0, \text{border}[j]\})$.
- Fallunterscheidung: $\text{border}[j]$ negativ oder nicht.
 - ▶ $\text{border}[j] < 0$, also $\text{border}[j] = -1$, dann muss $j = 0$ sein.
 Das bedeutet $i' + j' = i' + 0 = (i + 0 - (-1)) + 0 = i + 1$.
 - ▶ $\text{border}[j] \geq 0$, dann gilt $i' + j' = i + j$
- Also wird $i + j$ nach einem erfolglosen Vergleich nicht kleiner.



Laufzeit des KMP-Algorithmus

- Nach jedem erfolglosen Vergleich wird $i \in [0 : n - m]$ erhöht.
- i wird nie verkleinert.

⇒ maximal $n - m + 1$ erfolglose Vergleiche

- Nach einem **erfolgreichen** Vergleich wird $i + j$ um 1 erhöht.
- maximal n erfolgreiche Vergleiche, da $i + j \in [0 : n - 1]$.
- insgesamt **maximal $2n - m + 1$** Vergleiche

