

Script generated by TTT

Title: Seidl: GAD (14.07.2015)

Date: Tue Jul 14 13:48:17 CEST 2015

Duration: 147:32 min

Pages: 105

Graphen Minimale Spannäume



H. Seidl (TUM) GAD SS'15 568

Graphen Minimale Spannäume

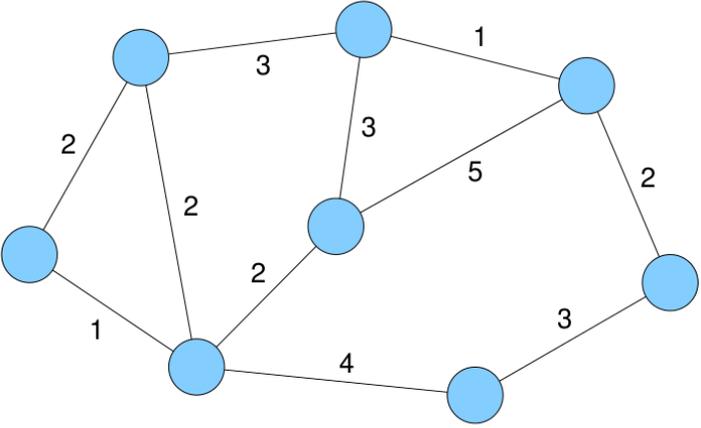


H. Seidl (TUM) GAD SS'15 569

Graphen Minimale Spannäume

Minimaler Spannbaum

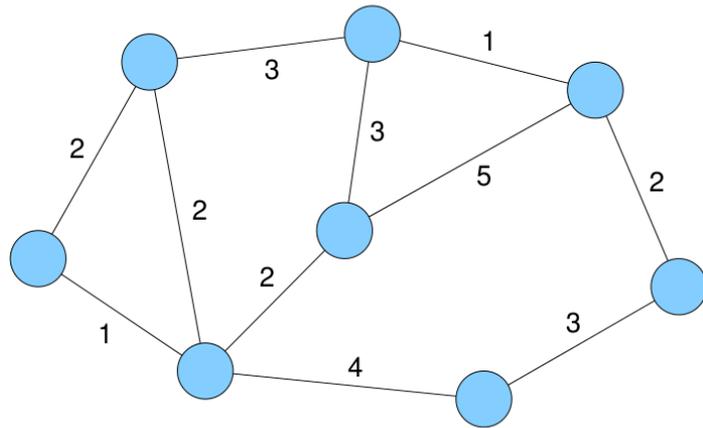
Frage: Welche Kanten nehmen, um mit minimalen Kosten alle Knoten zu verbinden?



H. Seidl (TUM) GAD SS'15 570

Minimaler Spannbaum

Frage: Welche Kanten nehmen, um mit minimalen Kosten alle Knoten zu verbinden?



Minimaler Spannbaum

Eingabe:

- ungerichteter Graph $G = (V, E)$
- Kantenkosten $c : E \mapsto \mathbb{R}_+$

Ausgabe:

- Kantenmenge $T \subseteq E$, so dass Graph (V, T) verbunden und $c(T) = \sum_{e \in T} c(e)$ minimal

Beobachtung:

- T formt immer einen **Baum** (wenn Kantengewichte echt positiv)
- ⇒ Minimaler Spannbaum (MSB) / Minimum Spanning Tree (MST)

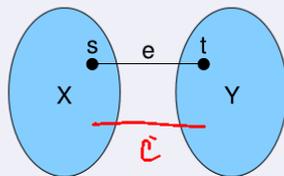
Minimaler Spannbaum

Lemma

Sei

- (X, Y) eine **Partition** von V (d.h. $X \cup Y = V$ und $X \cap Y = \emptyset$) und
- $e = \{s, t\}$ eine **Kante mit minimalen Kosten** mit $s \in X$ und $t \in Y$.

Dann gibt es einen minimalen Spannbaum T , der e enthält.



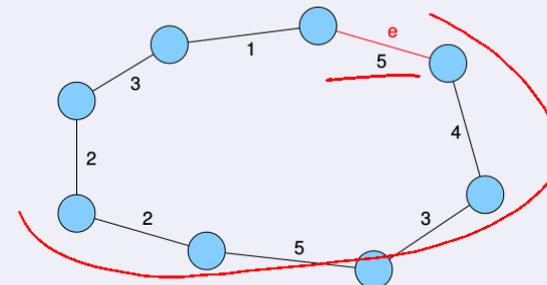
Minimaler Spannbaum

Lemma

Betrachte

- beliebigen **Kreis C** in G
- eine Kante **e** in C mit **maximalen Kosten**

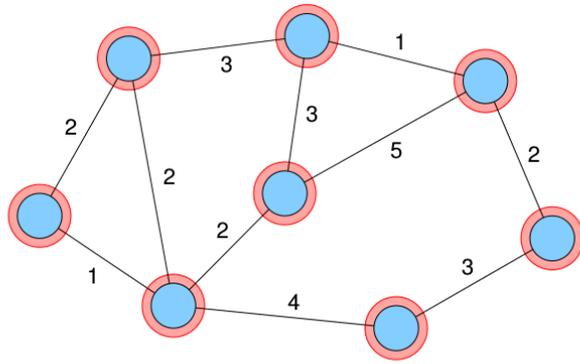
Dann ist jeder **MSB** in G ohne **e** auch ein **MSB** in G



Minimaler Spannbaum

Regel:

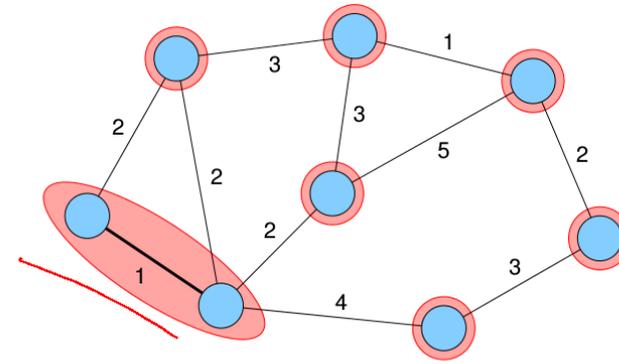
- wähle wiederholt Kante mit minimalen Kosten, die zwei Zusammenhangskomponenten verbindet
- bis nur noch eine Zusammenhangskomponente übrig ist



Minimaler Spannbaum

Regel:

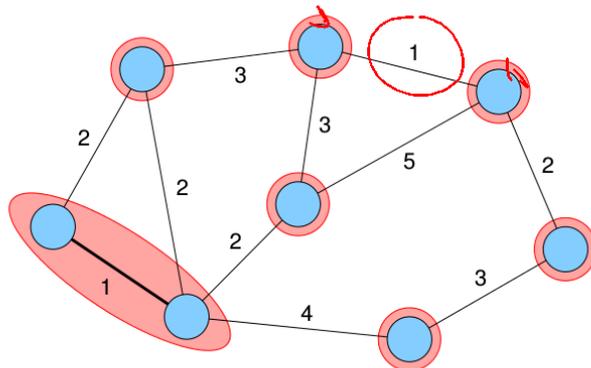
- wähle wiederholt Kante mit minimalen Kosten, die zwei Zusammenhangskomponenten verbindet
- bis nur noch eine Zusammenhangskomponente übrig ist



Minimaler Spannbaum

Regel:

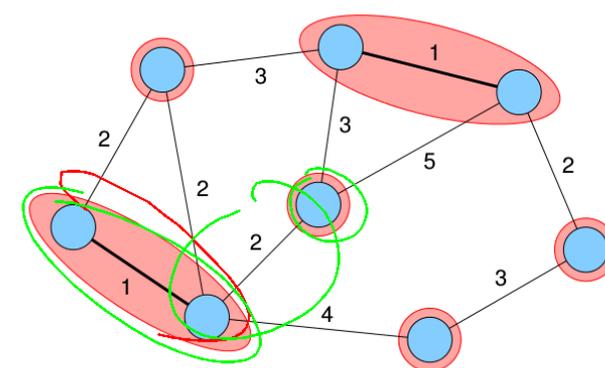
- wähle wiederholt Kante mit minimalen Kosten, die zwei Zusammenhangskomponenten verbindet
- bis nur noch eine Zusammenhangskomponente übrig ist



Minimaler Spannbaum

Regel:

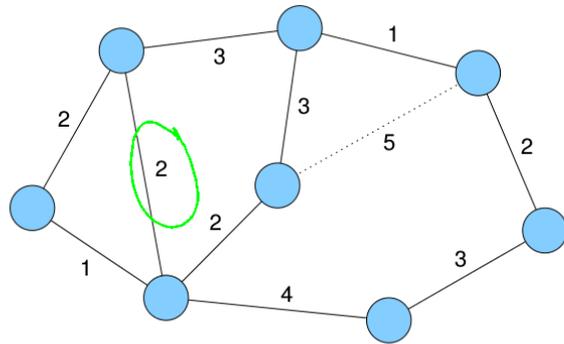
- wähle wiederholt Kante mit minimalen Kosten, die zwei Zusammenhangskomponenten verbindet
- bis nur noch eine Zusammenhangskomponente übrig ist



Minimaler Spannbaum

Regel:

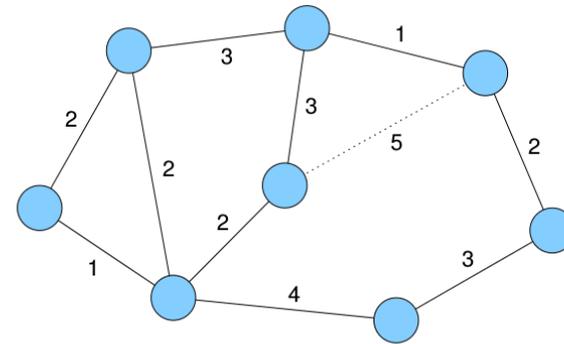
- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Regel:

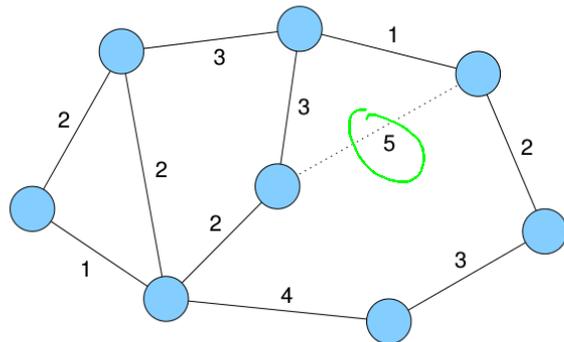
- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Regel:

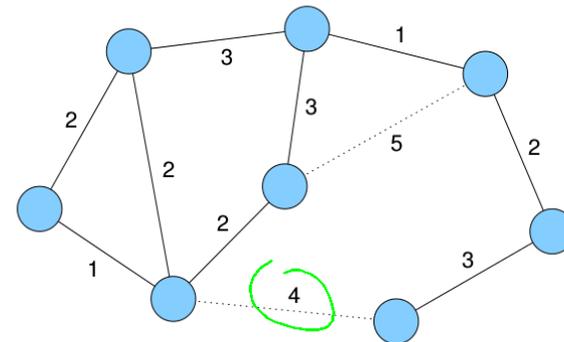
- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Regel:

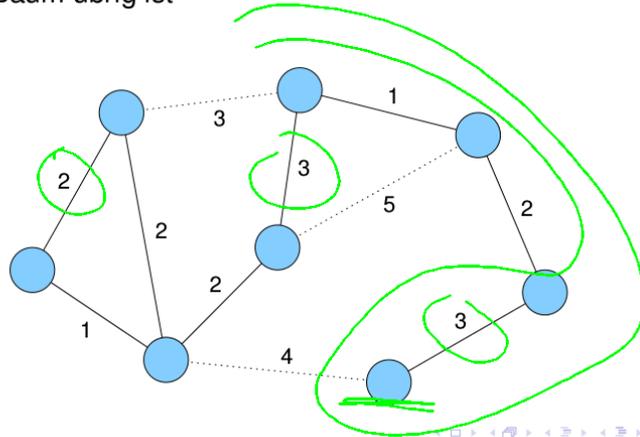
- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Regel:

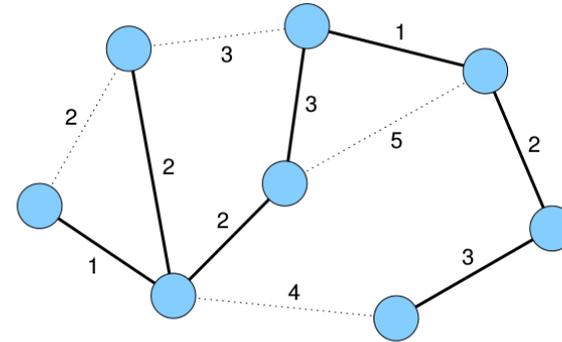
- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Regel:

- lösche wiederholt Kante mit maximalen Kosten, so dass Zusammenhang nicht zerstört
- bis ein Baum übrig ist



Minimaler Spannbaum

Problem: Wie implementiert man die Regeln effizient?

Strategie aus dem ersten Lemma:

- **sortiere** Kanten aufsteigend nach ihren Kosten
- setze $T = \emptyset$ (leerer Baum)
- **teste** für jede Kante $\{u, v\}$ (in aufsteigender Reihenfolge), ob u und v schon in einer Zusammenhangskomponente (also im gleichen Baum) sind
- falls nicht, füge $\{u, v\}$ zu T hinzu (nun sind u und v im gleichen Baum)

Minimaler Spannbaum

Problem: Wie implementiert man die Regeln effizient?

Strategie aus dem ersten Lemma:

- **sortiere** Kanten aufsteigend nach ihren Kosten
- setze $T = \emptyset$ (leerer Baum)
- **teste** für jede Kante $\{u, v\}$ (in aufsteigender Reihenfolge), ob u und v schon in einer Zusammenhangskomponente (also im gleichen Baum) sind
- falls nicht, füge $\{u, v\}$ zu T hinzu (nun sind u und v im gleichen Baum)

Algorithmus von Kruskal

```

Set<Edge> MST_Kruskal (V, E, c) {
  T = ∅;
  S = sort(E); // aufsteigend sortieren
  foreach (e = {u, v} ∈ S)
    if (u und v in verschiedenen Bäumen in T)
      T = T ∪ e;
  return T;
}

```

Problem:

- Umsetzung des Tests auf gleiche / unterschiedliche Zusammenhangskomponente

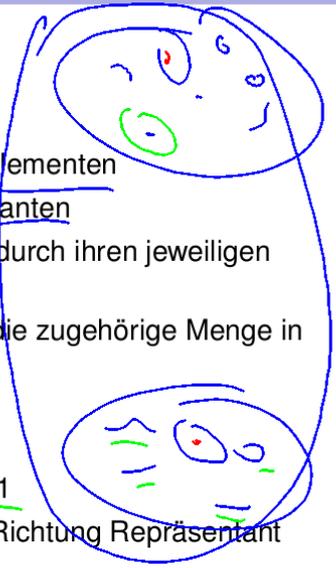
Union-Find-Datenstruktur

Union-Find-Problem:

- gegeben sind (disjunkte) Mengen von Elementen
- jede Menge hat genau einen Repräsentanten
- union soll zwei Mengen vereinigen, die durch ihren jeweiligen Repräsentanten gegeben sind
- find soll zu einem gegebenen Element die zugehörige Menge in Form des Repräsentanten finden

Anwendung:

- Knoten seien nummeriert von 0 bis $n - 1$
- Array int parent[n], Einträge verweisen Richtung Repräsentant
- anfangs parent[i]=i für alle i



Union-Find-Datenstruktur

```

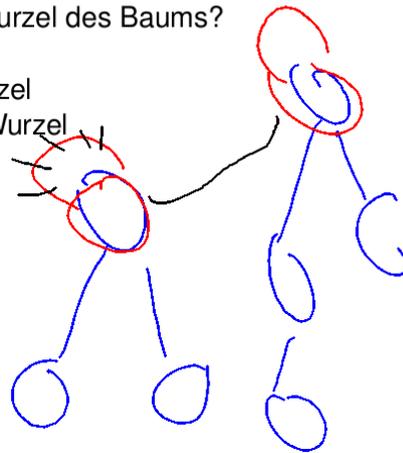
int find(int i) {
  if (parent[i] == i) return i; // ist i Wurzel des Baums?
  else { // nein
    k = find( parent[i] ); // suche Wurzel
    parent[i] = k; // zeige direkt auf Wurzel
    return k; // gibt Wurzel zurück
  }
}

```

```

union(int i, int j) {
  int ri = find(i);
  int rj = find(j); // suche Wurzeln
  if (ri != rj)
    parent[ri] = rj; // vereinigen
}

```



Union-Find-Datenstruktur

```

int find(int i) {
  if (parent[i] == i) return i; // ist i Wurzel des Baums?
  else { // nein
    k = find( parent[i] ); // suche Wurzel
    parent[i] = k; // zeige direkt auf Wurzel
    return k; // gibt Wurzel zurück
  }
}

```

```

union(int i, int j) {
  int ri = find(i);
  int rj = find(j); // suche Wurzeln
  if (ri != rj)
    parent[ri] = rj; // vereinigen
}

```

Algorithmus von Kruskal

```

Set<Edge> MST_Kruskal (V, E, c) {
  T = ∅;
  S = sort(E); // aufsteigend sortieren
  for (int i = 0; i < |V|; i++)
    parent[i] = i;
  foreach (e = (u, v) ∈ S)
    if (find(u) ≠ find(v)) {
      T = T ∪ e;
      union(u, v); // Bäume von u und v vereinigen
    }
  return T;
}

```

Gewichtete union-Operation mit Pfadkompression

- Laufzeit von `find` hängen von der **Höhe des Baums** ab
 - deshalb wird am Ende von `find` jeder Knoten auf dem Suchpfad direkt unter die Wurzel gehängt, damit die Suche beim nächsten Mal direkt zu diesem Knoten kommt (**Pfadkompression**)
 - weiterhin sollte bei union der niedrigere Baum unter die Wurzel des höheren gehängt werden (**gewichtete Vereinigung**)
- ⇒ Höhe des Baums ist dann $O(\log n)$

Union-Find-Datenstruktur

```

int find(int i) {
  if (parent[i] == i) return i; // ist i Wurzel des Baums?
  else { // nein
    k = find(parent[i]); // suche Wurzel
    parent[i] = k; // zeige direkt auf Wurzel
    return k; // gibt Wurzel zurück
  }
}

union(int i, int j) {
  int ri = find(i);
  int rj = find(j); // suche Wurzeln
  if (ri ≠ rj)
    parent[ri] = rj; // vereinigen
}

```

Union-Find-Datenstruktur

```

int find(int i) {
  if (parent[i] == i) return i; // ist i Wurzel des Baums?
  else { // nein
    k = find(parent[i]); // suche Wurzel
    parent[i] = k; // zeige direkt auf Wurzel
    return k; // gibt Wurzel zurück
  }
}

union(int i, int j) {
  int ri = find(i);
  int rj = find(j); // suche Wurzeln
  if (ri ≠ rj)
    parent[ri] = rj; // vereinigen
}

```

Gewichtete union-Operation mit Pfadkompression

- Laufzeit von find hängen von der **Höhe des Baums** ab
 - deshalb wird am Ende von find jeder Knoten auf dem Suchpfad direkt unter die Wurzel gehängt, damit die Suche beim nächsten Mal direkt zu diesem Knoten kommt (**Pfadkompression**)
 - weiterhin sollte bei union der niedrigere Baum unter die Wurzel des höheren gehängt werden (**gewichtete Vereinigung**)
- ⇒ Höhe des Baums ist dann $O(\log n)$

Union-Find-Datenstruktur

```

int find(int i) {
    if (parent[i] == i) return i; // ist i Wurzel des Baums?
    else { // nein
        k = find( parent[i] ); // suche Wurzel
        parent[i] = k; // zeige direkt auf Wurzel
        return k; // gibt Wurzel zurück
    }
}

union(int i, int j) {
    int ri = find(i);
    int rj = find(j); // suche Wurzeln
    if (ri != rj)
        parent[ri] = rj; // vereinigen
}

```

Gewichtete union-Operation mit Pfadkompression

- Laufzeit von find hängen von der **Höhe des Baums** ab
 - deshalb wird am Ende von find jeder Knoten auf dem Suchpfad direkt unter die Wurzel gehängt, damit die Suche beim nächsten Mal direkt zu diesem Knoten kommt (**Pfadkompression**)
 - weiterhin sollte bei union der niedrigere Baum unter die Wurzel des höheren gehängt werden (**gewichtete Vereinigung**)
- ⇒ Höhe des Baums ist dann $O(\log n)$

Union-Find-Datenstruktur

```

int find(int i) {
    if (parent[i] == i) return i; // ist i Wurzel des Baums?
    else { // nein
        k = find( parent[i] ); // suche Wurzel
        parent[i] = k; // zeige direkt auf Wurzel
        return k; // gibt Wurzel zurück
    }
}

union(int i, int j) {
    int ri = find(i);
    int rj = find(j); // suche Wurzeln
    if (ri != rj)
        parent[ri] = rj; // vereinigen
}

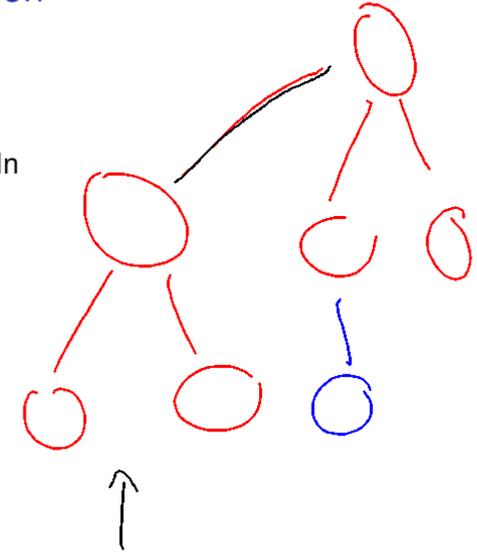
```

Gewichtete union-Operation mit Pfadkompression

- Laufzeit von find hängen von der **Höhe des Baums** ab
 - deshalb wird am Ende von find jeder Knoten auf dem Suchpfad direkt unter die Wurzel gehängt, damit die Suche beim nächsten Mal direkt zu diesem Knoten kommt (**Pfadkompression**)
 - weiterhin sollte bei union der **niedrigere Baum** unter die **Wurzel des höheren** gehängt werden (**gewichtete Vereinigung**)
- ⇒ Höhe des Baums ist dann $O(\log n)$

Gewichtete union-Operation

```
union(int i, int j) {
  int ri = find(i);
  int rj = find(j); // suche Wurzeln
  if (ri != rj)
    if (height[ri] < height[rj])
      parent[ri] = rj;
    else {
      parent[rj] = ri;
      if (height[ri] == height[rj])
        height[ri]++;
    }
}
```



union / find - Kosten

Situation:

- Folge von union / find -Operationen auf einer Partition von n Elementen, darunter $n - 1$ union-Operationen

Komplexität:

- amortisiert $\log^* n$ pro Operation, wobei

$$\log^* n = \min\{i \geq 1 : \underbrace{\log \log \dots \log n}_{i\text{-mal}} \leq 1\}$$

- bessere obere Schranke: mit inverser Ackermannfunktion (Vorlesung Effiziente Algorithmen und Datenstrukturen I)
- Gesamtkosten für Kruskal-Algorithmus: $O(m \log m)$ (Sortieren)

union / find - Kosten

Situation:

- Folge von union / find -Operationen auf einer Partition von n Elementen, darunter $n - 1$ union-Operationen

Komplexität:

- amortisiert $\log^* n$ pro Operation, wobei

$$\log^* n = \min\{i \geq 1 : \underbrace{\log \log \dots \log n}_{i\text{-mal}} \leq 1\}$$

- bessere obere Schranke: mit inverser Ackermannfunktion (Vorlesung Effiziente Algorithmen und Datenstrukturen I)
- Gesamtkosten für Kruskal-Algorithmus: $O(m \log m)$ (Sortieren)

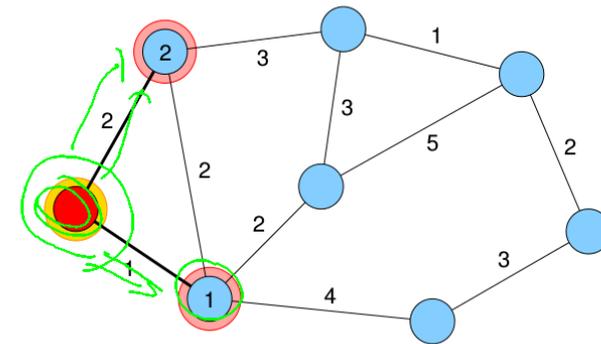
Algorithmus von Prim

Problem: Wie implementiert man die Regeln effizient?

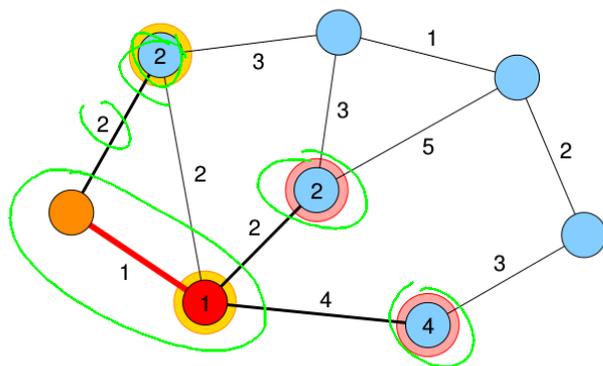
Alternative Strategie aus dem ersten Lemma:

- betrachte wachsenden Baum T , anfangs bestehend aus beliebigem einzelnen Knoten s
 - füge zu T eine Kante mit minimalem Gewicht von einem Baumknoten zu einem Knoten außerhalb des Baums ein (bei mehreren Möglichkeiten egal welche)
- ⇒ Baum umfasst jetzt 1 Knoten/Kante mehr
- wiederhole Auswahl bis alle n Knoten im Baum

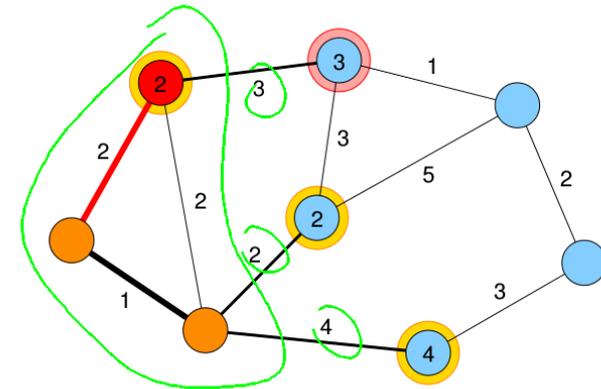
Algorithmus von Prim



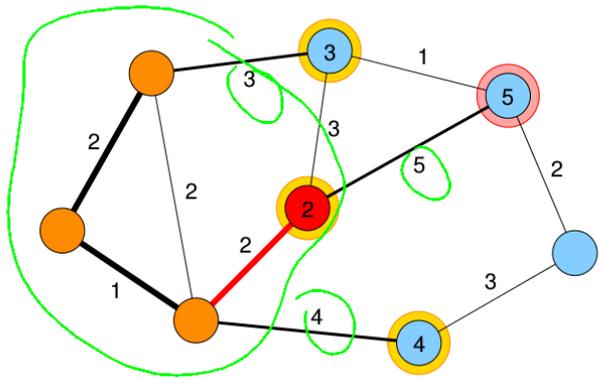
Algorithmus von Prim



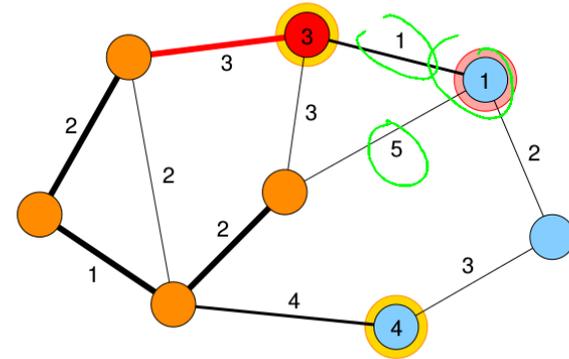
Algorithmus von Prim



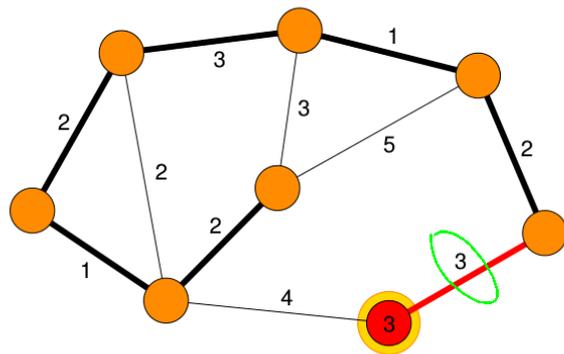
Algorithmus von Prim



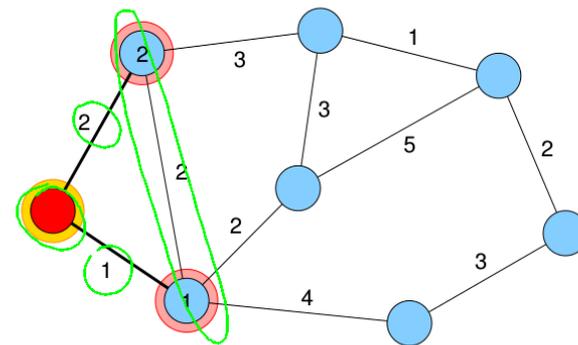
Algorithmus von Prim



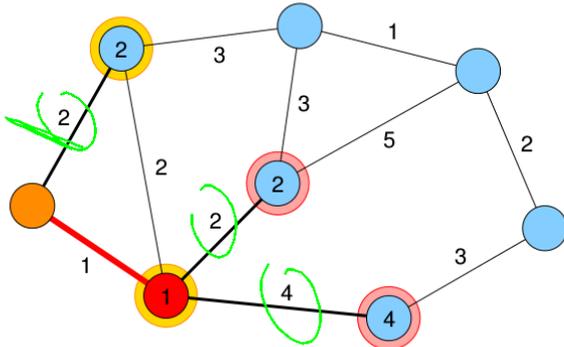
Algorithmus von Prim



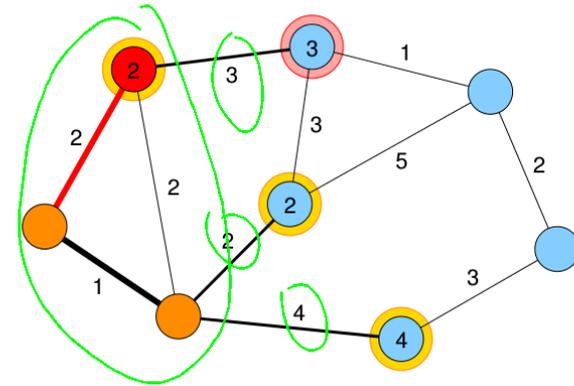
Algorithmus von Prim



Algorithmus von Prim



Algorithmus von Prim



Algorithmus Jarník-Prim: findet minimalen Spannbaum

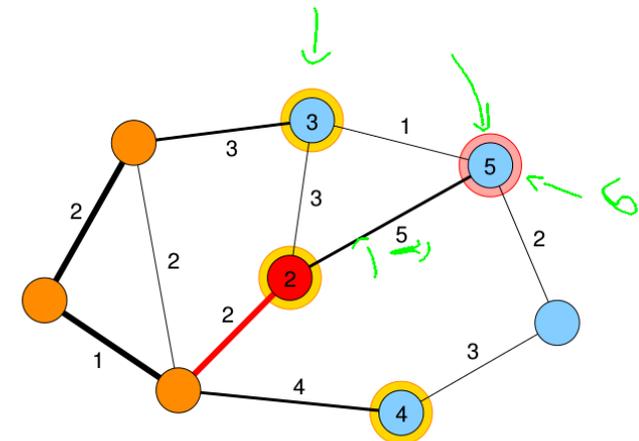
Eingabe : $G = (V, E)$, $c : E \mapsto \mathbb{R}_+$, $s \in V$

Ausgabe : Minimaler Spannbaum in Array *pred*

```

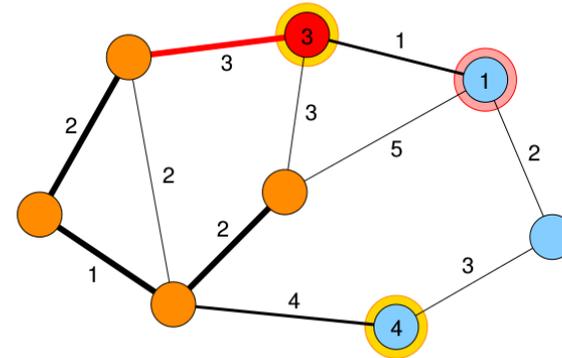
d[v] = ∞ for all v ∈ V \ s;
d[s] = 0; pred[s] = ⊥;
pq = ⟨⟩; pq.insert(s, 0);
while ¬pq.empty() do
    v = pq.deleteMin();
    forall the {v, w} ∈ E do
        newWeight = c(v, w);
        if newWeight < d[w] then
            pred[w] = v;
            if d[w] == ∞ then pq.insert(w, newWeight);
       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

Algorithmus von Prim

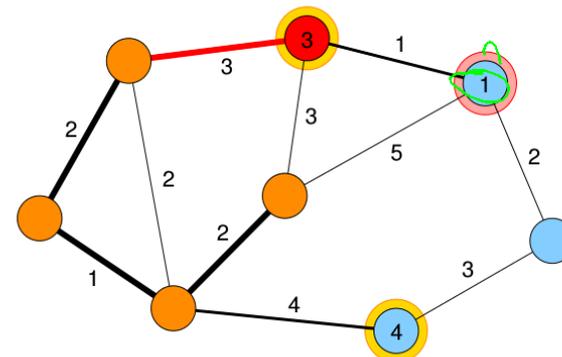


Algorithmus Jarník-Prim: findet minimalen Spannbaum**Eingabe** : $G = (V, E)$, $c : E \mapsto \mathbb{R}_+$, $s \in V$ **Ausgabe** : Minimaler Spannbaum in Array *pred* $d[v] = \infty$ for all $v \in V \setminus s$; $d[s] = 0$; $pred[s] = \perp$; $pq = \langle \rangle$; $pq.insert(s, 0)$;**while** $\neg pq.empty()$ **do** $v = pq.deleteMin()$; **forall the** $\{v, w\} \in E$ **do** $newWeight = c(v, w)$; **if** $newWeight < d[w]$ **then** $pred[w] = v$; **if** $d[w] == \infty$ **then** $pq.insert(w, newWeight)$; **else** **if** $w \in pq$ **then** $pq.decreaseKey(w, newWeight)$; $d[w] = newWeight$;

Algorithmus von Prim

**Algorithmus Jarník-Prim:** findet minimalen Spannbaum**Eingabe** : $G = (V, E)$, $c : E \mapsto \mathbb{R}_+$, $s \in V$ **Ausgabe** : Minimaler Spannbaum in Array *pred* $d[v] = \infty$ for all $v \in V \setminus s$; $d[s] = 0$; $pred[s] = \perp$; $pq = \langle \rangle$; $pq.insert(s, 0)$;**while** $\neg pq.empty()$ **do** $v = pq.deleteMin()$; **forall the** $\{v, w\} \in E$ **do** $newWeight = c(v, w)$; **if** $newWeight < d[w]$ **then** $pred[w] = v$; **if** $d[w] == \infty$ **then** $pq.insert(w, newWeight)$; **else** **if** $w \in pq$ **then** $pq.decreaseKey(w, newWeight)$; $d[w] = newWeight$;

Algorithmus von Prim



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 the {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;

```

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 the {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;

```

Jarník-Prim-Algorithmus

Laufzeit:

$$O(n \cdot (T_{\text{insert}}(n) + T_{\text{deleteMin}}(n)) + m \cdot T_{\text{decreaseKey}}(n))$$

Binärer Heap:

- alle Operationen $O(\log n)$, also
- gesamt: $O((m + n) \log n)$

Fibonacci-Heap: amortisierte Kosten

- $O(1)$ für insert und decreaseKey,
- $O(\log n)$ deleteMin
- gesamt: $O(m + n \log n)$

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 the {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;

```

Jarník-Prim-Algorithmus

Laufzeit:

$$O(n \cdot (T_{\text{insert}}(n) + T_{\text{deleteMin}}(n)) + m \cdot T_{\text{decreaseKey}}(n))$$

Binärer Heap:

- alle Operationen $O(\log n)$, also
- gesamt: $O((m+n) \log n)$

Fibonacci-Heap: amortisierte Kosten

- $O(1)$ für insert und decreaseKey,
- $O(\log n)$ deleteMin
- gesamt: $O(m+n \log n)$

Algorithmus Jarník-Prim: findet minimalen Spannbaum

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

Ausgabe : Minimaler Spannbaum in Array *pred*

$d[v] = \infty$ for all $v \in V \setminus s$;

$d[s] = 0$; $pred[s] = \perp$;

$pq = \langle \rangle$; $pq.insert(s, 0)$;

while $\neg pq.empty()$ **do**

$v = pq.deleteMin()$;

forall the $\{v, w\} \in E$ **do**

$newWeight = c(v, w)$;

if $newWeight < d[w]$ **then**

$pred[w] = v$;

if $d[w] == \infty$ **then** $pq.insert(w, newWeight)$;

else

if $w \in pq$ **then** $pq.decreaseKey(w, newWeight)$;

$d[w] = newWeight$;

Jarník-Prim-Algorithmus

Laufzeit:

$$O(n \cdot (T_{\text{insert}}(n) + T_{\text{deleteMin}}(n)) + m \cdot T_{\text{decreaseKey}}(n))$$

Binärer Heap:

- alle Operationen $O(\log n)$, also
- gesamt: $O((m+n) \log n)$

Fibonacci-Heap: amortisierte Kosten

- $O(1)$ für insert und decreaseKey,
- $O(\log n)$ deleteMin
- gesamt: $O(m+n \log n)$

Übersicht

10 Pattern Matching

- Naiver Algorithmus
- Knuth-Morris-Pratt-Algorithmus
- Edit-Distanz

Alphabet, Wörter, Wortlänge, Wortmengen

Definition

Ein Alphabet Σ ist eine endliche Menge von Symbolen.

Wörter über Σ sind endliche Folgen von Symbolen aus Σ (meist $w = w_0 \cdots w_{n-1}$ oder $w = w_1 \cdots w_n$).

Notation:

$|w|$ Länge des Wortes w (Anzahl der Zeichen in w)

ε leeres Wort (Wort der Länge 0)

Σ^* Menge aller Wörter über Σ

Σ^+ Menge aller Wörter der Länge ≥ 1 über Σ ($\Sigma^+ = \Sigma^* \setminus \{\varepsilon\}$)

Σ^k Menge aller Wörter über Σ der Länge k

Präfix, Suffix, Teilwort

Definition

$[a : b] := \{n \in \mathbb{Z} \mid a \leq n \wedge n \leq b\}$ für $a, b \in \mathbb{Z}$

Sei $w = w_1 \cdots w_n$ ein Wort der Länge n über Σ , dann heißt

- w' Präfix von w , wenn $w' = w_1 \cdots w_\ell$ mit $\ell \in [0 : n]$
- w' Suffix von w , wenn $w' = w_\ell \cdots w_n$ mit $\ell \in [1 : n + 1]$
- w' Teilwort von w , wenn $w' = w_i \cdots w_j$ mit $i, j \in [1 : n]$

Für $w' = w_i \cdots w_j$ mit $i > j$ soll gelten $w' = \varepsilon$.

Das leere Wort ε ist also Präfix, Suffix und Teilwort eines jeden Wortes.

Textsuche

Problem:

Gegeben: Text $t \in \Sigma^*$; $|t| = n$;
Suchwort $s \in \Sigma^*$; $|s| = m \leq n$

Gesucht: $\exists i \in [0 : n - m]$ mit $t_i \cdots t_{i+m-1} = s$?
(bzw. alle solchen Positionen i)

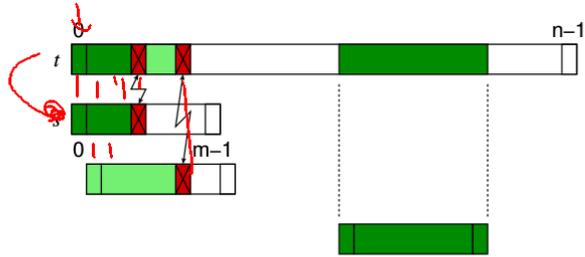
Übersicht

10 Pattern Matching

- Naiver Algorithmus
- ~~Knuth-Morris-Pratt-Algorithmus~~
- Edit-Distanz

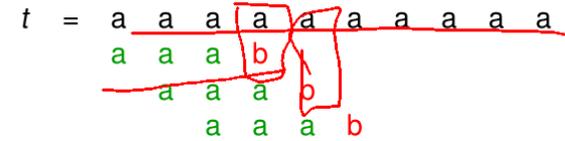


Naiver Algorithmus



- Suchwort s Zeichen für Zeichen mit Text t vergleichen
- wenn zwei Zeichen nicht übereinstimmen (Mismatch), dann s um eine Position „nach rechts“ schieben und erneut s mit t vergleichen
- Vorgang wiederholen, bis s in t gefunden wird oder bis klar ist, dass s in t nicht enthalten ist

Naiver Algorithmus: Beispiele



Naiver Algorithmus: Beispiele



Naiver Algorithmus: Implementation

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

```

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++;
  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: $O(nm)$

Übersicht

- 10 Pattern Matching
 - Naiver Algorithmus
 - Knuth-Morris-Pratt-Algorithmus
 - Edit-Distanz

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

xx y xx

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:

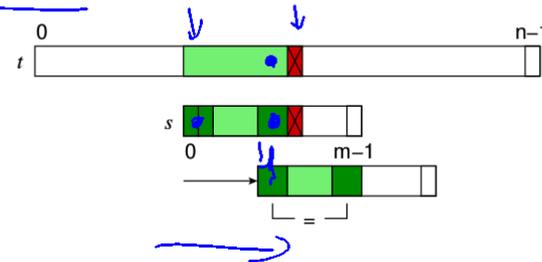
- ϵ
- a
- aa
- aabaa
- aabaabaa = w.

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

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

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

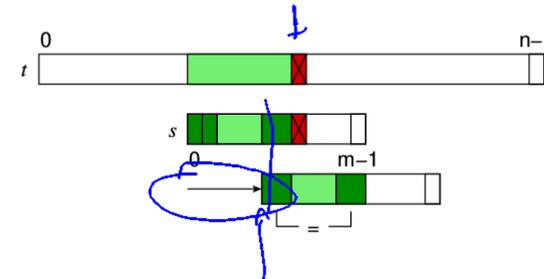
die Länge des eigentlichen Rands des Präfixes der Länge j .

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.

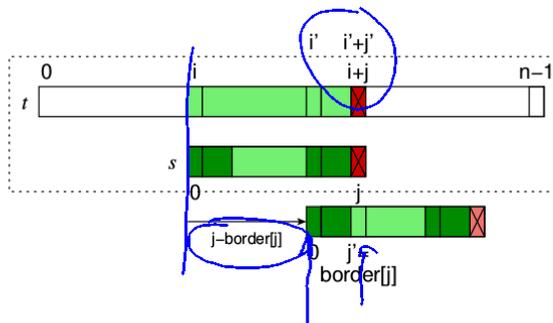
Shift-Idee

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



Sichere Shifts

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



Sichere Shifts

Beweis.

- (siehe Skizze)

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

- Der eigentliche Rand von $s_0 \dots s_{j-1}$ hat die Länge $\text{border}[j]$.
- Verschiebt man s um $j - \text{border}[j]$ nach rechts, so liegt der linke Rand von $s_0 \dots s_{j-1}$ 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 $s_0 \dots s_{j-1}$ als diesen gibt (außer $s_0 \dots s_{j-1}$ selbst), ist dieser Shift sicher.

□

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

Beweis.

- (siehe Skizze)

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

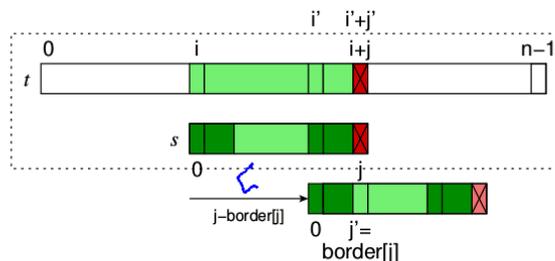
$$s_j \neq t_{i+j}$$

- 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

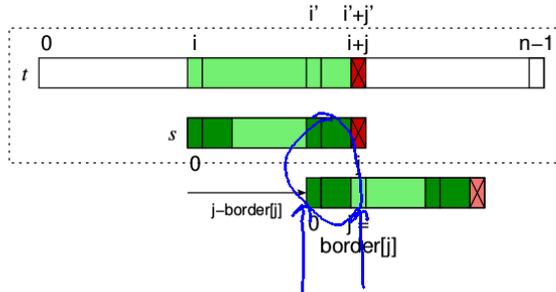
Funktion $\text{KMP}(t[], n, s[], m)$

```

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



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: 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 $n - m + 1$ erfolgreiche 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

Laufzeit des KMP-Algorithmus

- Nach jedem erfolglosen Vergleich wird $i \in [0 : n - m]$ erhöht.
 - i wird nie verkleinert.
- ⇒ maximal $n - m + 1$ erfolgreiche 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

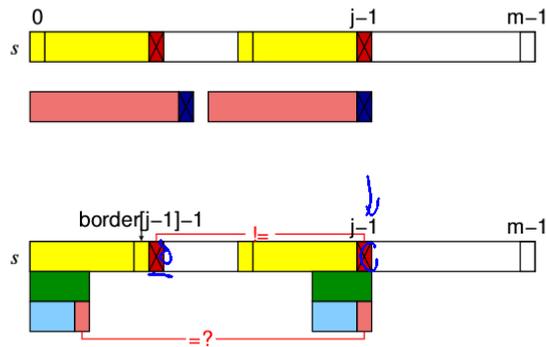
Berechnung der border-Tabelle

- $border[]$ -Tabelle:
speichert für jedes Präfix $s_0 \dots s_{j-1}$ der Länge $j \in \{0 \dots m\}$ von Suchstring s die Größe des eigentlichen Rands
- Initialisierung: $border[0] = -1$ und $border[1] = 0$
- Annahme: $border[0], \dots, border[j-1]$ sind schon berechnet
- Ziel: Berechnung von $border[j]$
(Länge des eigentlichen Rands von Präfix der Länge j)

Berechnung der border-Tabelle

- Der eigentliche Rand $s_0 \dots s_k$ von $s_0 \dots s_{j-1}$ kann um maximal ein Zeichen länger sein als der eigentliche Rand von $s_0 \dots s_{j-2}$, denn $s_0 \dots s_{k-1}$ ist auch ein Rand von $s_0 \dots s_{j-2}$ (oberer Teil der Abbildung).
- Ist $s_{border[j-1]} = s_{j-1}$, so ist $border[j] = border[j-1] + 1$.
- Andernfalls müssen wir ein kürzeres Präfix von $s_0 \dots s_{j-2}$ finden, das auch ein Suffix von $s_0 \dots s_{j-2}$ ist.
- Der nächstkürzere Rand eines Wortes ist offensichtlich der eigentliche Rand des zuletzt betrachteten Randes dieses Wortes.
- Nach Konstruktion der Tabelle $border$ ist das nächstkürzere Präfix mit dieser Eigenschaft das der Länge $border[border[j-1]]$.

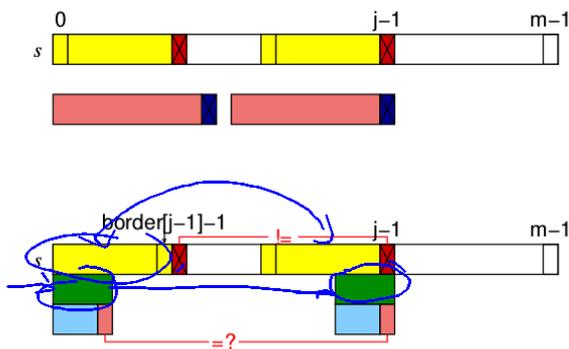
Berechnung der border-Tabelle



Berechnung der border-Tabelle

- Der eigentliche Rand $s_0 \dots s_k$ von $s_0 \dots s_{j-1}$ kann um maximal ein Zeichen länger sein als der eigentliche Rand von $s_0 \dots s_{j-2}$, denn $s_0 \dots s_{k-1}$ ist auch ein Rand von $s_0 \dots s_{j-2}$ (oberer Teil der Abbildung).
- Ist $s_{border[j-1]} = s_{j-1}$, so ist $border[j] = border[j-1] + 1$.
- Andernfalls müssen wir ein kürzeres Präfix von $s_0 \dots s_{j-2}$ finden, das auch ein Suffix von $s_0 \dots s_{j-2}$ ist.
- Der nächstkürzere Rand eines Wortes ist offensichtlich der eigentliche Rand des zuletzt betrachteten Randes dieses Wortes.
- Nach Konstruktion der Tabelle *border* ist das nächstkürzere Präfix mit dieser Eigenschaft das der Länge $border[border[j-1]]$.

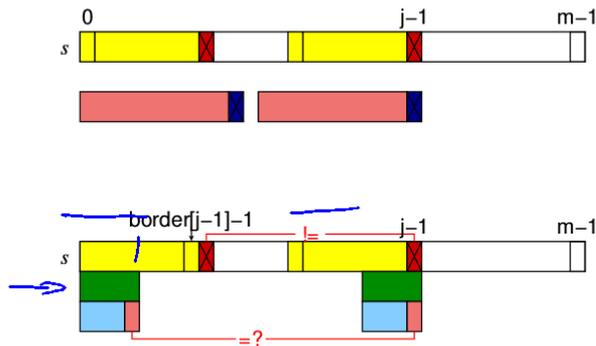
Berechnung der border-Tabelle



Berechnung der border-Tabelle

- Der eigentliche Rand $s_0 \dots s_k$ von $s_0 \dots s_{j-1}$ kann um maximal ein Zeichen länger sein als der eigentliche Rand von $s_0 \dots s_{j-2}$, denn $s_0 \dots s_{k-1}$ ist auch ein Rand von $s_0 \dots s_{j-2}$ (oberer Teil der Abbildung).
- Ist $s_{border[j-1]} = s_{j-1}$, so ist $border[j] = border[j-1] + 1$.
- Andernfalls müssen wir ein kürzeres Präfix von $s_0 \dots s_{j-2}$ finden, das auch ein Suffix von $s_0 \dots s_{j-2}$ ist.
- Der nächstkürzere Rand eines Wortes ist offensichtlich der eigentliche Rand des zuletzt betrachteten Randes dieses Wortes.
- Nach Konstruktion der Tabelle *border* ist das nächstkürzere Präfix mit dieser Eigenschaft das der Länge $border[border[j-1]]$.

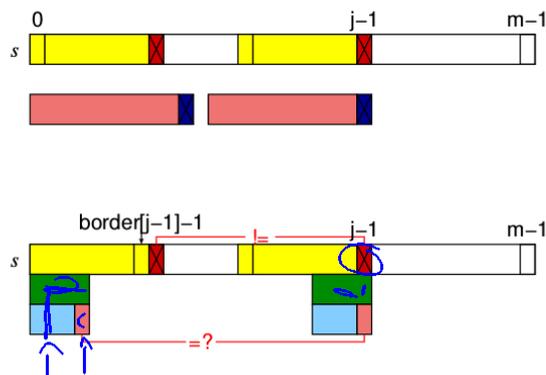
Berechnung der border-Tabelle



Berechnung der border-Tabelle

- Der eigentliche Rand $s_0 \cdots s_k$ von $s_0 \cdots s_{j-1}$ kann um maximal ein Zeichen länger sein als der eigentliche Rand von $s_0 \cdots s_{j-2}$, denn $s_0 \cdots s_{k-1}$ ist auch ein Rand von $s_0 \cdots s_{j-2}$ (oberer Teil der Abbildung).
- Ist $s_{border[j-1]} = s_{j-1}$, so ist $border[j] = border[j-1] + 1$.
- Andernfalls müssen wir ein kürzeres Präfix von $s_0 \cdots s_{j-2}$ finden, das auch ein Suffix von $s_0 \cdots s_{j-2}$ ist.
- Der nächstkürzere Rand eines Wortes ist offensichtlich der eigentliche Rand des zuletzt betrachteten Randes dieses Wortes.
- Nach Konstruktion der Tabelle $border$ ist das nächstkürzere Präfix mit dieser Eigenschaft das der Länge $border[border[j-1]]$.

Berechnung der border-Tabelle



Berechnung der border-Tabelle

- teste nun, ob sich dieser Rand von $s_0 \cdots s_{j-2}$ zu einem eigentlichen Rand von $s_0 \cdots s_{j-1}$ erweitern lässt
- solange wiederholen, bis wir einen Rand gefunden haben, der sich zu einem Rand von $s_0 \cdots s_{j-1}$ erweitern lässt
- Falls sich kein Rand von $s_0 \cdots s_{j-2}$ zu einem Rand von $s_0 \cdots s_{j-1}$ erweitern lässt, so ist der eigentliche Rand von $s_0 \cdots s_{j-1}$ das leere Wort und wir setzen $border[j] = 0$.

Algorithmus zur Berechnung der border-Tabelle

Prozedur computeBorders(int *border*[], int *m*, char *s*[])

```
border[0] := -1;
border[1] := 0;
int i := 0;
for (int j := 2; j ≤ m; j++) do
  // Hier gilt:  $i = \text{border}[j-1]$ 
  while ( $i \geq 0$ ) && ( $s[i] \neq s[j-1]$ ) do
     $i := \text{border}[i]$ ;
  i++;
  border[j] := i;
```

Algorithmus zur Berechnung der border-Tabelle

Prozedur computeBorders(int *border*[], int *m*, char *s*[])

```
border[0] := -1;
border[1] := 0;
int i := 0;
for (int j := 2; j ≤ m; j++) do
  // Hier gilt:  $i = \text{border}[j-1]$ 
  while ( $i \geq 0$ ) && ( $s[i] \neq s[j-1]$ ) do
     $i := \text{border}[i]$ ;
  i++;
  border[j] := i;
```

Laufzeit der Berechnung der border-Tabelle

- maximal $m - 1$ **erfolgreiche** Vergleiche, da jedes Mal $j \in [2 : m]$ um 1 erhöht und nie erniedrigt wird
- Betrachte für die Anzahl **erfolgloser** Vergleiche den Wert i .
Zu Beginn ist $i = 0$.
- i wird genau $(m - 1)$ Mal um 1 erhöht, da die for-Schleife $(m - 1)$ Mal durchlaufen wird.
- Bei einem erfolglosen Vergleich wird i um mindestens 1 erniedrigt.
- i kann maximal $(m - 1) + 1 = m$ Mal erniedrigt werden, da immer $i \geq -1$ gilt. Es gibt also höchstens m **erfolglose** Vergleiche.
- Gesamtzahl der Vergleiche $\leq 2m - 1$

Laufzeit der Berechnung der border-Tabelle

- maximal $m - 1$ **erfolgreiche** Vergleiche, da jedes Mal $j \in [2 : m]$ um 1 erhöht und nie erniedrigt wird
- Betrachte für die Anzahl **erfolgloser** Vergleiche den Wert i .
Zu Beginn ist $i = 0$.
- i wird genau $(m - 1)$ Mal um 1 erhöht, da die for-Schleife $(m - 1)$ Mal durchlaufen wird.
- Bei einem erfolglosen Vergleich wird i um mindestens 1 erniedrigt.
- i kann maximal $(m - 1) + 1 = m$ Mal erniedrigt werden, da immer $i \geq -1$ gilt. Es gibt also höchstens m **erfolglose** Vergleiche.
- Gesamtzahl der Vergleiche $\leq 2m - 1$

Laufzeit des KMP-Algorithmus

Theorem

Der Algorithmus von Knuth, Morris und Pratt benötigt maximal $2n + m$ Vergleiche, um festzustellen, ob ein Muster s der Länge m in einem Text t der Länge n enthalten ist.

Der Algorithmus lässt sich leicht derart modifizieren, dass er alle Positionen der Vorkommen von s in t ausgibt, ohne dabei die asymptotische Laufzeit zu erhöhen.

Donald E. Knuth, James H. Morris, Jr. and Vaughan R. Pratt
Fast Pattern Matching in Strings
SIAM Journal on Computing 6(2):323–350, 1977.

Übersicht

- 10 Pattern Matching
 - Naiver Algorithmus
 - Knuth-Morris-Pratt-Algorithmus
 - Edit-Distanz