

Vorlesungsskript  
**Theoretische Informatik III**  
Sommersemester 2008

Prof. Dr. Johannes Köbler  
Humboldt-Universität zu Berlin  
Lehrstuhl Komplexität und Kryptografie

21. April 2008

# Inhaltsverzeichnis

<b>1</b>	<b>Einleitung</b>	<b>1</b>
<b>2</b>	<b>Suchprobleme</b>	<b>4</b>
2.1	Suchen von Mustern in Texten . . . . .	4
2.2	String-Matching mit endlichen Automaten . . . . .	5
2.3	Der Knuth-Morris-Pratt-Algorithmus . . . . .	7

# Kapitel 1

## Einleitung

In der VL ThI 2 standen folgende Themen im Vordergrund:

- Welche Probleme sind lösbar? (Berechenbarkeitstheorie)
- Welche Rechenmodelle sind adäquat? (Automatentheorie)
- Welcher Aufwand ist nötig? (Komplexitätstheorie)

Dagegen geht es in der VL ThI 3 in erster Linie um folgende Frage:

- Wie lassen sich eine Reihe von praktisch relevanten Problemstellungen möglichst effizient lösen? (Algorithmik)

Der Begriff *Algorithmus* geht auf den persischen Gelehrten Muhammed Al Chwarizmi (8./9. Jhd.) zurück. Der älteste bekannte nicht-triviale Algorithmus ist der nach *Euklid* benannte Algorithmus zur Berechnung des größten gemeinsamen Teilers zweier natürlicher Zahlen (300 v. Chr.). Von einem Algorithmus wird erwartet, dass er jede *Problemeingabe* nach endlich vielen Rechenschritten löst (etwa durch Produktion einer Ausgabe). Ein Algorithmus ist ein „Verfahren“ zur Lösung eines Entscheidungs- oder Berechnungsproblems, das sich prinzipiell auf einer Turingmaschine implementieren lässt (Churchsche These bzw. Church-Turing-These).

### Die Registermaschine

Bei Aussagen zur Laufzeit von Algorithmen beziehen wir uns auf die Registermaschine (engl. Random Access Machine; RAM). Dieses Modell ist etwas flexibler als die Turingmaschine, da es den unmittelbaren Lese- und Schreibzugriff (random access) auf eine beliebige Speichereinheit (Register) erlaubt. Als Speicher stehen beliebig viele Register zur Verfügung, die jeweils eine beliebig große natürliche Zahl speichern können. Auf den Registerinhalten sind folgende arithmetische Operationen in einem Rechenschritt ausführbar: Addition, Subtraktion, abgerundetes Halbieren und Verdoppeln.

Die Laufzeit von RAM-Programmen wird wie bei TMs in der Länge der Eingabe gemessen. Man beachte, dass bei arithmetischen Problemen (wie etwa Multiplikation, Division, Primzahltests, etc.) die Länge einer Zahleingabe  $n$  durch die Anzahl  $\lceil \log n \rceil$  der für die Binärkodierung von  $n$  benötigten Bits gemessen wird. Dagegen bestimmt bei nicht-arithmetischen Problemen (z.B. Graphalgorithmen oder Sortierproblemen) die Anzahl der gegebenen Zahlen die Länge der Eingabe.

## Asymptotische Laufzeit und Landau-Notation

**Definition 1** Seien  $f$  und  $g$  Funktionen von  $\mathbb{N}$  nach  $\mathbb{R}^+$ . Wir schreiben  $f(n) = O(g(n))$ , falls es Zahlen  $n_0$  und  $c$  gibt mit

$$\forall n \geq n_0 : f(n) \leq c \cdot g(n).$$

Die Bedeutung der Aussage  $f(n) = O(g(n))$  ist, dass  $f$  „nicht wesentlich schneller“ als  $g$  wächst. Formal bezeichnet der Term  $O(g(n))$  die Klasse aller Funktionen  $f$ , die obige Bedingung erfüllen. Die Gleichung  $f(n) = O(g(n))$  drückt also in Wahrheit eine Element-Beziehung  $f \in O(g(n))$  aus.  $O$ -Terme können auch auf der linken Seite vorkommen. In diesem Fall wird eine Inklusionsbeziehung ausgedrückt. So steht  $n^2 + O(n) = O(n^2)$  für die Aussage  $\{n^2 + f \mid f \in O(n)\} \subseteq O(n^2)$ .

### Beispiel 2

- $7 \log(n) + n^3 = O(n^3)$  ist richtig.
- $7 \log(n)n^3 = O(n^3)$  ist falsch.
- $2^{n+O(1)} = O(2^n)$  ist richtig.
- $2^{O(n)} = O(2^n)$  ist falsch (siehe Übungen).

◀

Es gibt noch eine Reihe weiterer nützlicher Größenvergleiche von Funktionen.

**Definition 3** Wir schreiben  $f(n) = o(g(n))$ , falls es für jedes  $c > 0$  eine Zahl  $n_0$  gibt mit

$$\forall n \geq n_0 : f(n) \leq c \cdot g(n).$$

Damit wird ausgedrückt, dass  $f$  „wesentlich langsamer“ als  $g$  wächst. Außerdem schreiben wir

- $f(n) = \Omega(g(n))$  für  $g(n) = O(f(n))$ , d.h.  $f$  wächst mindestens so schnell wie  $g$
- $f(n) = \omega(g(n))$  für  $g(n) = o(f(n))$ , d.h.  $f$  wächst wesentlich schneller als  $g$ , und
- $f(n) = \Theta(g(n))$  für  $f(n) = O(g(n)) \wedge f(n) = \Omega(g(n))$ , d.h.  $f$  und  $g$  wachsen ungefähr gleich schnell.

# Kapitel 2

## Suchprobleme

### 2.1 Suchen von Mustern in Texten

In diesem Abschnitt betrachten wir folgende algorithmische Problemstellung.

**String-Matching (STRINGMATCHING):**

**Gegeben:** Ein Text  $x = x_1 \cdots x_n$  und ein Muster  $y = y_1 \cdots y_m$  über einem Alphabet  $\Sigma$ .

**Gesucht:** Alle Vorkommen von  $y$  in  $x$ .

Wir sagen  $y$  kommt in  $x$  an Stelle  $i$  vor, falls  $x_{i+1} \cdots x_{i+m} = y$  ist. Typische Anwendungen finden sich in Textverarbeitungssystemen (emacs, grep, etc.), sowie bei der DNS- bzw. DNA-Sequenz-analyse.

**Beispiel 4** Sei  $\Sigma = \{A,C,G,U\}$ .

Text  $x = \text{AUGACG}\mathbf{AUGAUGUAGGUAGCGUAG}\mathbf{AUGAUGUAG}$ ,  
Muster  $y = \text{AUG AUG UAG}$ .

Das Muster  $y$  kommt im Text  $x$  an den Stellen **6** und **24** vor.

◀

Bei naiver Herangehensweise kommt man sofort auf folgenden Algorithmus.

**Algorithmus 5** NAIV-STRING-MATCHER

- 1 **Eingabe:** Text  $x = x_1 \cdots x_n$  und Muster  $y = y_1 \cdots y_m$
- 2  $V \leftarrow \emptyset$
- 3 **for**  $i := 0$  **to**  $n - m$  **do**
- 4     **if**  $x_{i+1} \cdots x_{i+m} = y_1 \cdots y_m$  **then**  $V \leftarrow V \cup \{i\}$  **end**
- 5 **Ausgabe:**  $V$

Die Korrektheit von `naiv-String-Matcher` ergibt sich wie folgt:

- In der **for**-Schleife testet der Algorithmus alle potentiellen Stellen, an denen  $y$  in  $x$  vorkommen kann, und
- fügt in Zeile 4 genau die Stellen  $i$  zu  $V$  hinzu, für die  $x_{i+1} \cdots x_{i+m} = y$  ist.

Die Laufzeit von `naiv-String-Matcher` lässt sich nun durch folgende Überlegungen abschätzen:

- Die **for**-Schleife wird  $(n - m + 1)$ -mal durchlaufen.
- Der Test in Zeile 4 benötigt maximal  $m$  Vergleiche.

Dies führt auf eine Laufzeit von  $O(nm) = O(n^2)$ . Für Eingaben der Form  $x = a^n$  und  $y = a^{\lfloor n/2 \rfloor}$  ist die Laufzeit tatsächlich  $\Theta(n^2)$ .

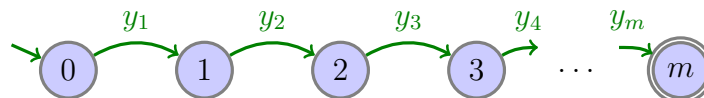
## 2.2 String-Matching mit endlichen Automaten

Durch die Verwendung eines endlichen Automaten lässt sich eine erhebliche Effizienzsteigerung erreichen. Hierzu konstruieren wir einen DFA  $M_y$ , der jedes Vorkommen von  $y$  in der Eingabe  $x$  durch Erreichen eines Endzustands anzeigt.  $M_y$  erkennt also die Sprache

$$L = \{x \in \Sigma^* \mid y \text{ ist Suffix von } x\}.$$

Konkret konstruieren wir  $M_y$  wie folgt:

- $M_y$  hat  $m + 1$  Zustände, die den  $m + 1$  Präfixen  $y_1 \cdots y_k$ ,  $k = 0, \dots, m$ , von  $y$  entsprechen.
- Liest  $M_y$  im Zustand  $k$  das Zeichen  $y_{k+1}$ , so wechselt  $M_y$  in den Zustand  $k + 1$ , d.h.  $\delta(k, y_{k+1}) = k + 1$  für  $k = 0, \dots, m - 1$ :



- Falls das nächste Zeichen  $a$  nicht mit  $y_{k+1}$  übereinstimmt (engl. *Mismatch*), wechselt  $M_y$  in den Zustand

$$\delta(k, a) = \max\{j \leq m \mid y_1 \cdots y_j \text{ ist Suffix von } y_1 \cdots y_k a\}.$$

$M_y$  speichert also in seinem Zustand die maximale Präfixlänge  $k$ , für die  $y_1 \cdots y_k$  ein Suffix der gelesenen Eingabe ist:

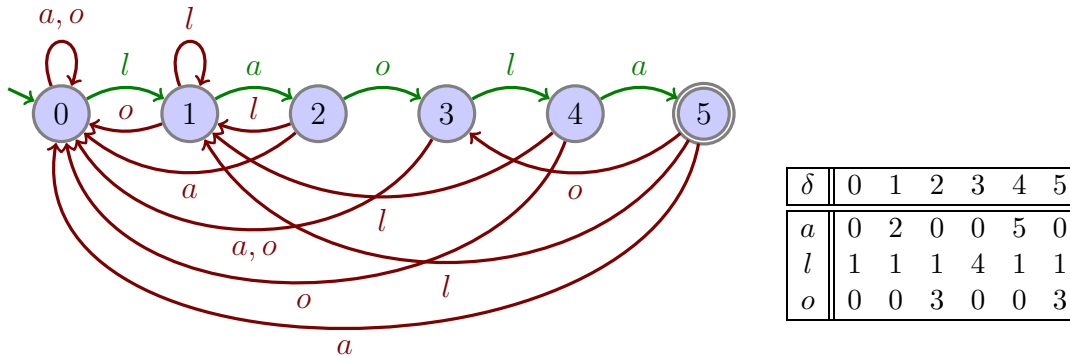
$$\hat{\delta}(0, x) = \max\{k \leq m \mid y_1 \cdots y_k \text{ ist Suffix von } x\}.$$

Die Korrektheit von  $M_y$  folgt aus der Beobachtung, dass  $M_y$  isomorph zum Äquivalenzklassenautomaten  $M_{R_L}$  für  $L$  ist.  $M_{R_L}$  hat die Zustände  $[y_1 \cdots y_k]$ ,  $k = 0, \dots, m$ , von denen nur  $[y_1 \cdots y_m]$  ein Endzustand ist. Die Überföhrungsfunktion ist definiert durch

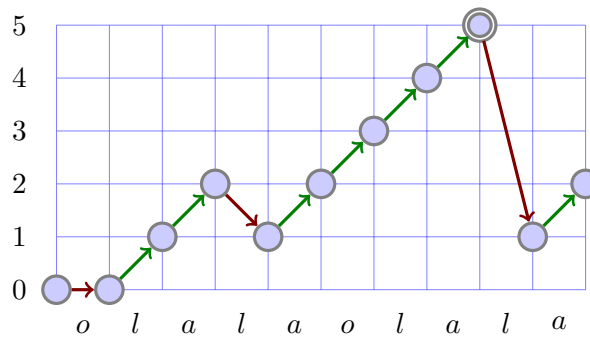
$$\delta([y_1 \cdots y_k], a) = [y_1 \cdots y_j],$$

wobei  $y_1 \cdots y_j$  das längste Präfix von  $y = y_1 \cdots y_m$  ist, welches Suffix von  $y_1 \cdots y_j a$  ist (siehe Übungen).

**Beispiel 6** Für das Muster  $y = laola$  ergibt sich folgender DFA  $M_y$ :



$M_y$  macht bei der Suche nach dem Muster  $y = laola$  im Text  $x = olalaolala$  folgende Übergänge:



◁

Insgesamt erhalten wir somit folgenden Algorithmus.

**Algorithmus 7** DFA-STRING-MATCHER

- 1 **Eingabe:** Text  $x = x_1 \cdots x_n$  und Muster  $y = y_1 \cdots y_m$
- 2 konstruiere den DFA  $M_y = (Z, \Sigma, \delta, 0, m)$  mit  $Z = \{0, \dots, m\}$
- 3  $V \leftarrow \emptyset$

```

4    $k \leftarrow 0$ 
5   for  $i := 1$  to  $n$  do
6      $k \leftarrow \delta(k, x_i)$ 
7     if  $k = m$  then  $V \leftarrow V \cup \{i - m\}$  end
8   Ausgabe:  $V$ 

```

Die Korrektheit von `DFA-String-Matcher` ergibt sich unmittelbar aus der Tatsache, dass  $M_y$  die Sprache

$$L(M_y) = \{x \in \Sigma^* \mid y \text{ ist Suffix von } x\}$$

erkennt. Folglich fügt der Algorithmus genau die Stellen  $j = i - m$  zu  $V$  hinzu, für die  $y$  ein Suffix von  $x_1 \cdots x_i$  (also  $x_{j+1} \cdots x_{j+m} = y$ ) ist.

Die Laufzeit von `DFA-String-Matcher` ist die Summe der Laufzeiten für die Konstruktion von  $M_y$  und für die Simulation von  $M_y$  bei Eingabe  $x$ , wobei letztere durch  $O(n)$  beschränkt ist. Für  $\delta$  ist eine Tabelle mit  $(m + 1) \|\Sigma\|$  Einträgen

$$\delta(k, a) = \max\{j \leq k + 1 \mid y_1 \cdots y_j \text{ ist Suffix von } y_1 \cdots y_k a\}$$

zu berechnen. Jeder Eintrag  $\delta(k, a)$  ist in Zeit  $O(k^2) = O(m^2)$  berechenbar. Dies führt auf eine Laufzeit von  $O(\|\Sigma\|m^3)$  für die Konstruktion von  $M_y$  und somit auf eine Gesamtlaufzeit von  $O(\|\Sigma\|m^3 + n)$ . Tatsächlich lässt sich  $M_y$  sogar in Zeit  $O(\|\Sigma\|m)$  konstruieren.

## 2.3 Der Knuth-Morris-Pratt-Algorithmus

Durch eine Modifikation des Rücksprungmechanismus' lässt sich die Laufzeit von `DFA-String-Matcher` auf  $O(n + m)$  verbessern. Hierzu vergegenwärtigen wir uns folgende Punkte:

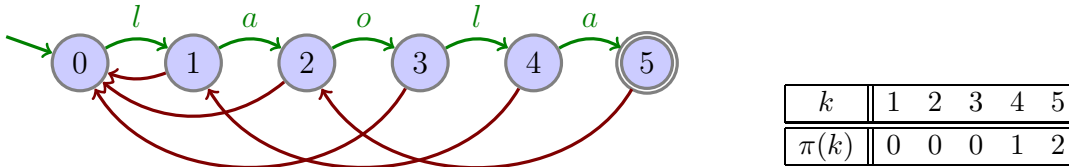
- Tritt im Zustand  $k$  ein Mismatch  $a \neq y_{k+1}$  auf, so ermittelt  $M_y$  das längste Präfix  $p$  von  $y_1 \cdots y_k$  ist, das zugleich Suffix von  $y_1 \cdots y_k a$  ist, und springt in den Zustand  $k' = |p|$ .
- Im Fall  $k' \neq 0$  hat  $p$  also die Form  $p = p'a$ , wobei  $p'$  sowohl echtes Präfix als auch echtes Suffix von  $y_1 \cdots y_k$  ist.
- Die Idee beim KMP-Algorithmus ist nun, unabhängig von  $a$  auf das nächst kleinere Präfix  $\tilde{p}$  von  $y_1 \cdots y_k$  zu springen, das auch Suffix von  $y_1 \cdots y_k$  ist.
- Dies wird solange wiederholt, bis das Zeichen  $a$  „passt“ (d.h. auch  $\tilde{p}a$  ist Präfix von  $y_1 \cdots y_k$ ) oder der Zustand 0 erreicht wird.



Der KMP-Algorithmus besucht also alle Zustände, die auch  $M_y$  besucht, führt aber die Rücksprünge in mehreren Etappen aus. Die Sprungadressen werden durch die so genannte *Präfixfunktion*  $\pi : \{1, \dots, m\} \rightarrow \{0, \dots, m-1\}$  ermittelt:

$$\pi(i) = \max\{j \leq i-1 \mid y_1 \cdots y_j \text{ ist Suffix von } y_1 \cdots y_i\}.$$

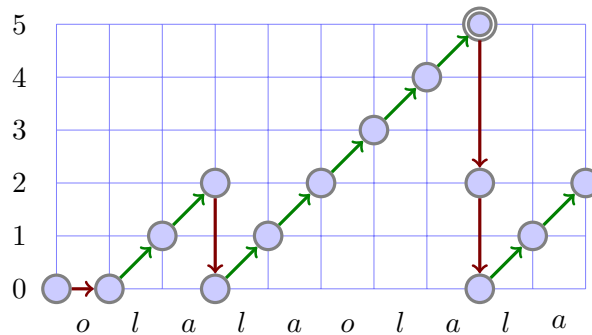
**Beispiel 8** Für das Muster  $y = laola$  ergibt sich folgende Präfixfunktion  $\pi$ :



Wir können uns die Arbeitsweise dieses Automaten wie folgt vorstellen:

1. Erlaubt das nächste Eingabezeichen einen Übergang vom aktuellen Zustand  $k$  nach  $k+1$ , so führe diesen aus.
2. Ist ein Übergang nach  $k+1$  nicht möglich und  $k \geq 1$ , so springe in den Zustand  $\pi(k)$  ohne das nächste Zeichen zu lesen.
3. Andernfalls (d.h.  $k=0$  und ein Übergang nach 1 ist nicht möglich) lies das nächste Zeichen und bleibe im Zustand 0.

Der KMP-Algorithmus macht bei der Suche nach dem Muster  $y = laola$  im Text  $x = olalaolala$  folgende Übergänge:



◁

Auf die Frage, wie sich die Präfixfunktion  $\pi$  möglichst effizient berechnen lässt, werden wir später zu sprechen kommen. Wir betrachten zunächst das Kernstück des KMP-Algorithmus.

#### Algorithmus 9 KMP-STRING-MATCHER

- 1 **Eingabe:** Text  $x = x_1 \cdots x_n$  und Muster  $y = y_1 \cdots y_m$

```

2    $\pi \leftarrow \text{KMP-Prefix}(y)$ 
3    $V \leftarrow \emptyset$ 
4    $k \leftarrow 0$ 
5   for  $i := 1$  to  $n$  do
6     while  $(k > 0 \wedge x_i \neq y_{k+1})$  do  $k \leftarrow \pi(k)$  end
7     if  $x_i = y_{k+1}$  then  $k \leftarrow k + 1$  end
8     if  $k = m$  then  $V \leftarrow V \cup \{i - m\}; k \leftarrow \pi(k)$  end
9   Ausgabe:  $V$ 

```

Die Korrektheit von `KMP-String-Matcher` ergibt sich einfach daraus, dass `KMP-String-Matcher` den Zustand  $m$  an genau den gleichen Textstellen besucht wie `DFA-String-Matcher`, und somit wie dieser alle Vorkommen von  $y$  im Text  $x$  findet.

Für die Laufzeitanalyse von `KMP-String-Matcher` (ohne die Berechnung von `KMP-Prefix`) stellen wir folgende Überlegungen an.

- Die Laufzeit ist proportional zur Anzahl der Zustandsübergänge.
- Bei jedem Schritt wird der Zustand um maximal Eins erhöht oder echt verkleinert.
- Da der Zustand nicht negativ werden kann, kann er nicht öfter verkleinert werden als er erhöht wird.
- Die Anzahl der Zustandsübergänge, bei denen der Zustand erhöht wird bzw. unverändert bleibt, ist durch die Länge  $n$  des Textes beschränkt.
- Daher finden höchstens  $2n = O(n)$  Zustandsübergänge statt.

Nun kommen wir auf die Frage zurück, wie sich die Präfixfunktion  $\pi$  effizient berechnen lässt. Die Aufgabe besteht darin, für jedes Präfix  $y_1 \cdots y_i$ ,  $i \geq 1$ , das längste echte Präfix zu berechnen, das zugleich Suffix von  $y_1 \cdots y_i$  ist. Eine einfache Überlegung zeigt, dass der KMP-Algorithmus bei der Suche des Musters  $y$  im Text  $y_2 \cdots y_m$  in dem nach Lesen von  $y_i$  erreichten Zustand  $k$  gerade das längste Präfix von  $y$  liefert, das zugleich Suffix von  $y_2 \cdots y_i$  ist, d.h.  $\pi(i) = k$ .

#### Algorithmus 10 `KMP-PREFIX`

```

1   Eingabe: Muster  $y = y_1 \cdots y_m$ 
2    $\pi(1) \leftarrow 0$ 
3    $k \leftarrow 0$ 
4   for  $i := 2$  to  $m$  do
5     while  $(k > 0 \wedge y_i \neq y_{k+1})$  do  $k \leftarrow \pi(k)$  end

```

```
6   if  $y_i = y_{k+1}$  then  $k \leftarrow k + 1$  end  
7    $\pi(i) \leftarrow k$   
8   Ausgabe:  $\pi$ 
```

KMP-`Prefix` führt bei Eingabe  $y = y_1 \cdots y_m$  genau die gleichen Zustandsübergänge aus wie KMP-`String-Matcher` bei Eingabe  $y$  und  $x = y_2 \cdots y_m$ . Daher ist seine Laufzeit durch  $O(m)$  beschränkt.

Zudem ergibt sich aus der Korrektheit von KMP-`String-Matcher`, dass KMP-`Prefix` bei der Suche nach dem Muster  $y$  im Text  $x = y_2 \cdots y_m$  in dem nach Lesen von  $y_i$  angenommenen Zustand  $k$  jeweils die maximale Länge eines Präfixes von  $y$  speichert, das zugleich Suffix von  $y_2 \cdots y_i$  ist. D.h. es gilt  $\pi(i) = k$ , womit auch die Korrektheit von KMP-`Prefix` bewiesen ist.