

Algorithmen und Datenstrukturen (für ESE) WS 2010 / 2011

Vorlesung 13, Montag, 31. Januar 2011
(String Matching)

Prof. Dr. Hannah Bast
Lehrstuhl für Algorithmen und Datenstrukturen
Institut für Informatik
Universität Freiburg

Blick über die Vorlesung heute

■ Organisatorisches

- Ihre Erfahrungen mit dem Ü12 (Editierdistanz)
- Das ist heute die **vorletzte** Vorlesung
- Die Klausur ist immer noch am **30. März 14:00 – 16:30 Uhr**

■ String Matching

- Das was man für `std::string::find` machen muss
- Wir lernen **drei** Algorithmen dazu kennen
 - den trivialen und zwei ziemlich clevere
- **Übungsblatt 13:**
 - Laufzeit für die ersten beiden, Programm für den dritten

Ihre Erfahrungen mit dem Ü12 (Edit.dist)

- Zusammenfassung von Ihrem Feedback [31.1 14:48]
 - Das Verfahren haben fast alle gut verstanden
 - Und fanden es auch relativ leicht zu implementieren
 - Das Schwierigste war die Folge der Operationen
 - Den Beweis fanden die meisten schwierig und haben ihn aus Zeitgründen weggelassen

String Matching — Definition

■ Definition

- Gegeben zwei Zeichenketten / strings:
 - ein (typischerweise langer) **Text** (engl. **text**)
 - ein (typischerweise kurzes) **Muster** (engl. **pattern**)
- Finde alle Vorkommen des Musters im Text

■ Notation

- die Länge des Textes nennen wir **n**
- die Länge des Musters nennen wir **m**

TEXT 0 1 2 3 4 5 ... 8 12
 DUBIDUBADUBIDUBIDUBADUX
MUSTER DUBI

AUSGABE : 0, 8, 12

String Matching — Naiver Algorithmus

■ Beschreibung des Algorithmus

- Gehe den Text von links nach rechts durch
- Prüfe an jeder Stelle ob das Muster passt, indem man es Buchstabe für Buchstabe mit dem Text dort vergleicht
- Den jeweiligen Ausschnitt (der Größe m) aus dem Text nennen wir **Fenster** (engl. **window**)
- Laufzeit offensichtlich $O(n \cdot m)$
 - im besten Fall auch schneller → **Übungsaufgabe**

0 1 2 3 4 5 ...
DUBI DUDU DUBADUBIDUBIDUTS
 ↓ FENSTER
DUBI

BABABABABABABA
BABA

String Matching — Rabin-Karp

■ Idee des Algorithmus

- Wir schieben wieder ein Fenster der Größe m über den Text
- Und schauen an jeder Stelle ob es zu dem Muster passt
- Nehmen wir an die Buchstaben sind die Ziffern $0..9$
- Dann kann man das Muster als (große) ganze Zahl auffassen
- Und das Fenster ebenso
- Wenn wir das Fenster um eins nach rechts verschieben, kann man die Zahl für das neue Fenster leicht aus der Zahl für das alte Fenster berechnen:

TEXT: 0 1 2 3 4 5 . . .
0 8 5 2 1 2 4 1 2 3 2 3 2 5 1 9 2 3 2 4
MUSTER: 2 3 2

$232 \rightarrow -200, \times 10, + 3$
 $323 \rightarrow -300, \times 10, + 2$
 $232 \rightarrow -200, \times 10, + 5$

■ Laufzeit

- Wenn wir mit den Zahlen in konstanter Zeit operieren könnten, wäre die Laufzeit nur $O(n)$
- Aber diese Zahlen können sehr groß werden

■ Zusätzlicher Trick

- Wir rechnen mit den Zahlen modulo einer Primzahl p
- Muster und Fenster sind dann Zahlen aus $\{0, \dots, p-1\}$
- Wenn das Muster zu einem Fenster passt, sind die Zahlen gleich, aber wenn es nicht passt, können sie auch gleich sein (auch wenn es "unwahrscheinlich" ist)
- Wenn die Zahlen gleich sind (aber nur dann), überprüfen wir wie beim naiven Algorithmus Buchstabe für Buchstabe
- Laufzeit jetzt → Übungsaufgabe

String Matching — Rabin-Karp

TEXT ^{0 1 2 3 4 5 . . .}
 5 7 8 2 3 2 3 2 5 4 2 3 2 4 2 1

MUSTER 2 3 2

$$p = 5$$

$$\begin{aligned} 578 \bmod 5 &= 3 \\ 232 \bmod 5 &= 2 \end{aligned} \quad \neq$$

$$\begin{aligned} 782 \bmod 5 &= 2 \\ 232 \bmod 5 &= 2 \end{aligned} \quad = , \text{ aber kein Match}$$

⋮

$$\begin{aligned} 232 \bmod 5 &= 2 \\ 232 \bmod 5 &= 2 \end{aligned} \quad = \rightarrow \text{AUSGABE: 3}$$

$$\begin{aligned} x \cdot y \bmod p \\ &= (x \bmod p)(y \bmod p) \\ \text{Schlüsselwort: } \mathbb{Z}/p\mathbb{Z} \end{aligned}$$

■ Idee des Algorithmus

- Wenn man die ersten k Zeichen des Musters mit den ersten k Zeichen eines Fensters im Text verglichen hat ... und jetzt das Fenster im Text um eins weiter schiebt ... dann hat man $k-1$ Zeichen dieses Fensters schon mal mit dem Muster verglichen
- Man möchte gerne vermeiden, die nochmal anzuschauen
- Wie das gehen könnte, sieht man am besten an einem Beispiel → nächste Folie

String Matching — Knuth-Morris-Pratt

■ Vorverarbeitung des Musters

- Für jede Stelle $j \in \{1, \dots, m\}$ des Musters P berechnen wir **vor**, an welcher Stelle des Musters wir weitermachen, wenn es an Stelle $j+1$ einen Mismatch gibt oder wenn $j = m$
- Für Stelle j ist das $\text{shift}[j] = \min^{max} \{ k : P[j-k+1..j] = P[1..k] \}$
- Das lässt sich leicht in Zeit $O(m)$ berechnen → Üb.aufgabe
- Man sieht leicht, dass $\text{shift}[j-1] < j$

↓
MUSTER D U B I D U B A D U
SHIFTs 0 0 0 0 1 2 3 0 1 2

D U D U B D U D U
0 0 1 2 0 1 2 3 4

A B C D E F
0 0 0 0 0 0

A A A A A A A
0 1 2 3 4 5 6

■ Laufzeit

- Sei i der Index des aktuellen Zeichens im Text
- In jeder Iteration **erhöhen** wir i oder es **bleibt gleich**
- Wenn i gleich bleibt, verschieben wir das Muster im Bild (siehe Beispiel Folie 10) um **mindestens eins nach rechts**
 - die Verschiebung ist gerade $j - \text{shift}[j-1] > 0$
- Da man höchstens n mal nach rechts gehen kann, gibt es also höchstens **$2n$** Iterationen
- In jeder Iteration gibt es nur konstant viele Operationen
- Damit ist die Laufzeit **$O(n)$**

■ Rabin-Karp Algorithmus

- [Richard Karp](#) und [Michael Rabin](#)

Efficient randomized pattern matching

1987 IBM Journal of Research and Development

■ Knuth-Morris-Pratt Algorithmus

- [Donald Knuth](#) und [James Morris](#) und [Vaughan Pratt](#)

Fast pattern matching in strings

1977 SIAM Journal on Computing

■ String Matching

- In Mehlhorn/Sanders:

gar nicht!

- In Wikipedia

<http://de.wikipedia.org/wiki/String-Matching-Algorithmus>

<http://de.wikipedia.org/wiki/Rabin-Karp-Algorithmus>

<http://de.wikipedia.org/wiki/Knuth-Morris-Pratt-Algorithmus>

+ auf den Englischen Seiten steht wie immer mehr

- Interaktive Demo

<http://tinyurl.com/6hs46c7>

