Anfrage-Sprachen

Teil 1

Viele Folien in diesem Abschnitt sind eine deutsche Übersetzung der Folien von Raymond J. Mooney (http://www.cs.utexas.edu/users/mooney/ir-course/). Ein weiterer großer Anteil wurde mit freundlicher Genehmigung von Peter Becker übernommen (http://www2.inf.fh-rhein-sieg.de/~pbecke2m/retrieval/).

Boolesche Anfragen

- Schlüsselworte kombiniert mit Booleschen Operatoren:
  - ODER: (e_1 OR e_2)
  - UND: (e_1 AND e_2)
  - ABER: (e_1 BUT e_2) erfüllt e_1 aber **nicht** e_2
- Negation nur eingeschränkt als ABER erlaubt, um den invertierten Index nutzen zu können: effektives Bearbeiten von e_1 durch inv. Index, dann Filtern der Ergebnisse.
- Problem: Untrainierte Anwender haben Probleme mit Boolescher Logik.

Boolsche Retrieval mit invertierten Indizes

- Einzelnes Schlüsselwort: Finde die gesuchten Dokumente durch Verwendung des invertierten Index.
- ODER: Finde auf rekursive Weise e_1 und e_2 bilde die Vereinigung der Ergebnisse.
- UND: Finde auf rekursive Weise e_1 und e_2 und bilde den Durchschnitt der Ergebnisse.
- ABER: Finde auf rekursive Weise e_1 und e_2 und bilde die Mengendifferenz der Ergebnisse.

“Natürlichsprachige” Anfragen

- Volltext-Anfragen als beliebige Strings.
- Typischerweise werden sie nur wie ein “bag of words” im Vektorraum-Modell behandelt und mit Standard-Vektor-Retrieval-Methoden verarbeitet.

Phrasen-Anfragen

- Findet Dokumente, die spezifische Phrasen (geordnete Listen zusammenhängender Wörter) enthalten
  - “information theory”
- Kann intervenierende Stopworte und/oder Stemming zulassen.
  - “buy camera” matches:
    “buy a camera”
    “buying the cameras”
    etc.

Phrasen-Retrieval mit invertierten Indizes

- Muss einen invertierten Index verwenden, der auch die *Positionen* der Schlüsselworte in den Dokumenten speichert.
- Finde Dokumente und Positionen für jedes individuelle Wort, bilde Durchschnitt der Treffermengen, und prüfe abschließend auf den richtigen Zusammenhang der Schlüsselwort-Positionen.
- Am besten beginnt man die Prüfung der Zusammenhänge mit dem am wenigsten häufigen Wort in der Phrase.

Phrasensuche

Aufgabe: Finde die Menge D von Dokumenten, bei denen alle Schlüsselworte ($k_1 \ldots k_m$) in einer Phrase vorkommen (verwende UND-Anfrageverarbeitung).

Intitialisiere eine leere Menge, R, von gefundenen Dokumenten.

Für jedes Dokument d in D:

Suche für jedes k_i die Folge der Positionen P_i der Vorkommen in d

Bestimme die kürzeste Folge P_s der P_i's

Für jede Position p des Schlüsselworts k_s in P_s

Für jedes Schlüsselwort k_i außer k_s

Verwende die binäre Suche, um eine Position ($p - s + i$) in der Folge P_i zu finden.

Falls für jedes Schlüsselwort die korrekte Position gefunden wurde, füge d zu R hinzu

Gib R aus.

Näherungsanfragen

- Liste von Termen mit zusätzlichen maximalen Abstandsbeschränkungen zwischen den Termen.
- Beispiel: “dogs” und “race” in 4 Worten passt zu “…dogs will begin the race…”
- Man kann zusätzlich Stemming verwenden und/oder Stopwörter ignorieren.

Näherungs-Retrieval mit invertiertem Index

- Benutze Ansatz ähnlich wie bei Phrasensuche, um alle Dokumente zu finden, die die Schlüsselwörter enthalten.
- Finde bei der binären Suche nach den Positionen der verbleibenden Schlüsselwörter die nächste Position von k_i nach p und überprüfe, dass diese innerhalb des maximal zulässigen Abstands ist.

String-Matching

- Erlaubt allgemeinere Stringvergleiche in Anfragen, während der vorher diskutierte Ansatz die Worte als atomare Einheiten (Tokens) betrachtet.
- Erfordert für effiziente Bearbeitung komplexere Datenstrukturen und Algorithmen als invertierte Indizes.

String Matching

- Die Suche von einem Muster in einem Text wird auch als *String Matching* oder *Pattern Matching* bezeichnet.
- Generell besteht die Aufgabe darin, einen String (das *Muster*, *Pattern*) der Länge m in einem Text der Länge n zu finden, wobei $n > m$ gilt.
- Je nach Freiheitsgraden bei der Suche unterscheidet man verschiedene Arten von String-Matching-Problemen.

Arten von String-Matching-Problemen

- **Exaktes String-Matching:** Wo tritt ein String *pat* in einem Text *text* auf? Beispiel: fgrep
- **Matching von Wortmengen:** Gegeben sei eine Menge *S* von Strings. Wo tritt in einem Text ein String aus *S* auf? Beispiel: agrep
- **Matching regulärer Ausdrücke:** Welche Stellen in einem Text passen auf einen regulären Ausdruck? Beispiel: grep, egrep
- **Approximatives String-Matching:** Welche Stellen in einem Text passen am besten auf ein Muster (Best-Match-Anfrage)?

Arten von String-Matching-Problemen

- Welche Stellen in einem Text stimmen mit einem Muster bis auf *d* Fehler überein (Distance-Match-Anfrage)? Beispiel: agrep
- **Editierdistanz:** Wie kann man am “günstigsten” einen String *s* in einen String *t* überführen? Beispiel: diff

Einfache Strukturen

- Prefix: Struktur, die zum Wortanfang passt.
  - “anti” passt zu “antiquity”, “antibody”, etc.
- Suffix: Struktur, die zum Wortende passt:
  - “ix” passt zu “fix”, “matrix”, etc.
- Substring: Struktur, die zu einer willkürlichen Teilfolge von Zeichen passt.
  - “rapt” passt zu “enrapture”, “velociraptor” etc.
- Range: Stringpaar, das zu jedem Wort passt, das lexikographisch (alphabetisch) dazwischen liegt.
  - “tin” to “tix” passt zu “tip”, “tire”, “title”, etc.

Anwendungen

- Wo braucht man String-Matching-Verfahren? Z.B.:
  - Volltextdatenbanken
  - Retrievalsysteme
  - Suchmaschinen
  - Bioinformatik
- In diesem Abschnitt lernen wir effiziente Algorithmen für String-Matching kennen.

Bezeichnungen

- Ein *Alphabet* ist eine endliche Menge Σ von Symbolen. $|\Sigma|$ bezeichnet die Kardinalität von Σ.
- Ein *String (Zeichenkette,Wort) s* über einem Alphabet ist eine endliche Folge von Symbolen aus Σ. $|s|$ bezeichnet die *Länge* von *s*.
- ε bezeichnet den *leeren String*.
- Wenn *x* und *y* Strings sind, dann bezeichnet *xy* die *Konkatenation* von *x* und *y*.

Bezeichnungen

- $s[i]$ bezeichnet das i-te Element eines Strings s ($1 \leq i \leq |s|$).
- $s[i\ldots j]$ bezeichnet den String $s[i]s[i+1]\ldots s[j]$. Für $i > j$ gelte
- $s[i\ldots j] = \varepsilon$.
- Für einen String s (mit $m = |s|$) bezeichnet s^{-1} die *Umkehrung*
- $s[m]s[m-1]\ldots s[1]$ von s.
- Für zwei Strings x und y gilt $x = y$ genau dann, wenn $|x| = |y| = m$
- und $x[i] = y[i]$ f ür alle $1 \leq i \leq m$ gilt.
- Wenn $w = xyz$ ein String ist, dann ist x ein *Präfix* und z ein *Suffix*
- von w.
- Gilt $w \neq x$ ($w \neq z$), dann ist x (z) ein *echter Präfix (echter Suffix)* von w.

- Ein String x (mit $m = |x|$) heißt *Substring (Faktor)* von y, wenn ein i existiert mit $x = y[i...i+m-1]$. Andere Sprechweisen: x tritt in y an Position i auf bzw. Position i ist ein *Match* für x in y.
- x (mit $m = |x|$) heißt *Subsequenz* von y, wenn Positionen $i_1 < i_2 < ... < i_m$ existieren mit $x = y[i_1]y[i_2]...y[i_m]$.

Exaktes String-Matching

- **Problem 6.1. [Exaktes String-Matching]** Gegeben sind die Strings *pat* und *text*.
  - (a) Man bestimme, ob pat ein Substring von text ist.
  - (b) Man bestimme die Menge aller Positionen, an denen *pat* in *text* auftritt. Diese Menge wird mit MATCH(*pat*; *text*) bezeichnet.
- Im folgenden wird nur die Variante (a) von Problem 6.1 betrachtet.
- Algorithmen für die Variante (b) erhält man durch einfache Modifikationen der Algorithmen für (a).
- Im folgenden sei $m = |pat|$ und $n = |text|$.

Naiver Ansatz

- Der naive Ansatz besteht darin, für jede Position von *text* (bzw. solange *pat* ab der aktuellen Position in *text* passt) von neuem zu testen, ob *pat* an dieser Position auftritt.
- Das allgemeine Schema für solch einen naiven Algorithmus lautet:

- **for** i := 1 **to** n-m+1 **do**

  man prüfe, ob *pat* = *text*[i...i+m-1] gilt

- Die Prüfung kann nun "von links nach rechts" oder "von rechts nach links" erfolgen.
- Dies führt zu unterschiedlichen naiven Algorithmen und darauf aufbauend zu unterschiedlichen Ansätzen der Verbesserung:
  - „von links nach rechts" → Algorithmus von Morris und Pratt
  - „von rechts nach links" → Algorithmus von Boyer und Moore
- Wir betrachten hier nur die zweite Variante.

Der Algorithmus von Boyer und Moore

- Der Algorithmus von Boyer und Moore kann als eine verbesserte Variante eines naiven String-Matching-Algorithmus angesehen werden, bei dem *pat* mit *text* von rechts nach links verglichen wird.

- **Algorithmus 6.1 [naives String-Matching von rechts nach links]**

i := 1
while i \leq n-m+1 **do**
    j := m
    while j \geq 1 **and** *pat*[j] = *text*[i+ j-1] **do** j := j-1 **end**
    if j = 0 **then return true**
    i := i + 1
    end
return false

Analyse des naiven Algorithmus

- **Satz 6.1.** *Der naive Algorithmus 6.1 löst Problem 6.1 in Zeit* O(nm) *und Platz* O(m).

- Für $pat = ba^{m-1}$ und $text = a^n$ benötigt Algorithmus 6.1 $(n-m+1)m = nm - m^2 + m$ Zeichenvergleiche (Worst Case).

- Bei einem binären Alphabet und zufällig erzeugten *pat* und *text* (jedes Zeichen unabhängig und jedes Symbol mit Wahrscheinlichkeit 1/2) ergibt sich für die durchschnittliche Anzahl an Zeichenvergleichen: $(2-2^{-m})n + O(1)$

Analyse des naiven Algorithmus

- Trotz der im Durchschnitt linearen Laufzeit lohnt sich der Einsatz von “besseren” String-Matching-Algorithmen, denn:
  - die nachfolgenden String-Matching-Algorithmen haben sich nicht nur in der Theorie, sondern auch in der Praxis als erheblich effizienter erwiesen, und
  - die Realität gehorcht nicht immer den Gesetzen der Wahrscheinlichkeitstheorie.

Der Algorithmus von Boyer und Moore

- Der Algorithmus von Boyer und Moore basiert auf der folgenden Überlegung:
- Tritt in Algorithmus 1.6 an Stelle *j* ein Mismatch auf und kommt *pat*[*j*+1...*m*] nicht ein weiteres mal in *pat* als Substring vor, so kann *pat* gleich um *m* Zeichen nach rechts verschoben werden.

- Vergleicht man dagegen von links nach rechts, kann *pat* nach einem Mismatch an Position *j* nie um mehr als *j* Positionen nach rechts verschoben werden. (Dies ist das Prinzip des Algorithmus von Morris und Pratt).

Veranschaulichung

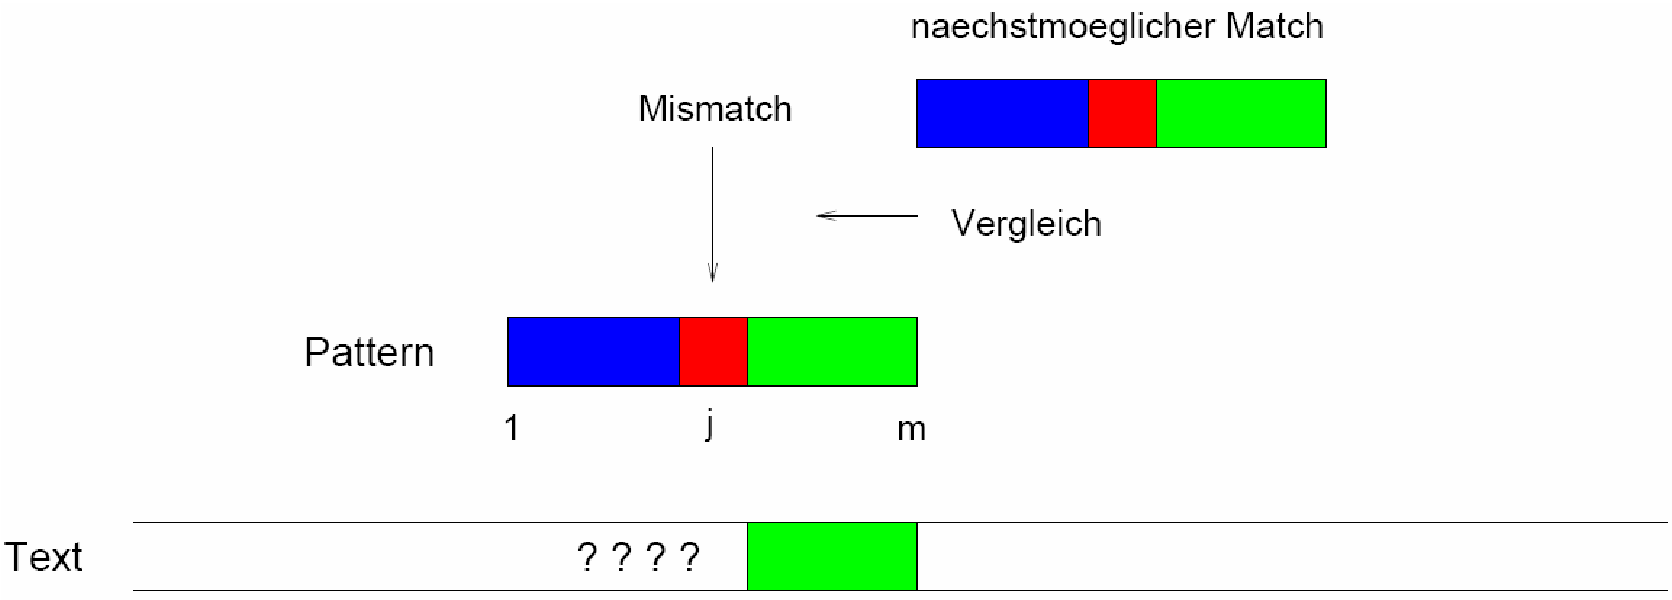

- Kommt es in Algorithmus 6.1 an Stelle j von *pat* zu einem Mismatch, so gilt

  $pat[j+1 \ldots m] = text[i+j \ldots i+m-1]$ und

  $pat[j] \neq text[i+j-1]$.

- Dies kann wie folgt ausgenutzt werden: Angenommen, *pat* tritt in *text* an einer Position $i+s$ mit $i < i+s < i+m$ auf. Dann müssen die beiden folgenden Bedingungen gelten:

  (BM1) $\forall j < k \leq m$: $k \leq s \vee pat[k-s] = pat[k]$

  (BM2) $s < j \Rightarrow pat[j-s] \neq pat[j]$

Veranschaulichung

```
                     j − s
                       ↓
   pat:        - - - - a b c b c

 pat:        - - - - a b c b c
                         ↑
                         j
text: - - - - - - a b c a b c - - - - -
            ↑           ↑
            i       i + j − 1
```

Damit man keinen Match verpasst, muss *s* möglichst klein gewählt werden.

Veranschaulichung

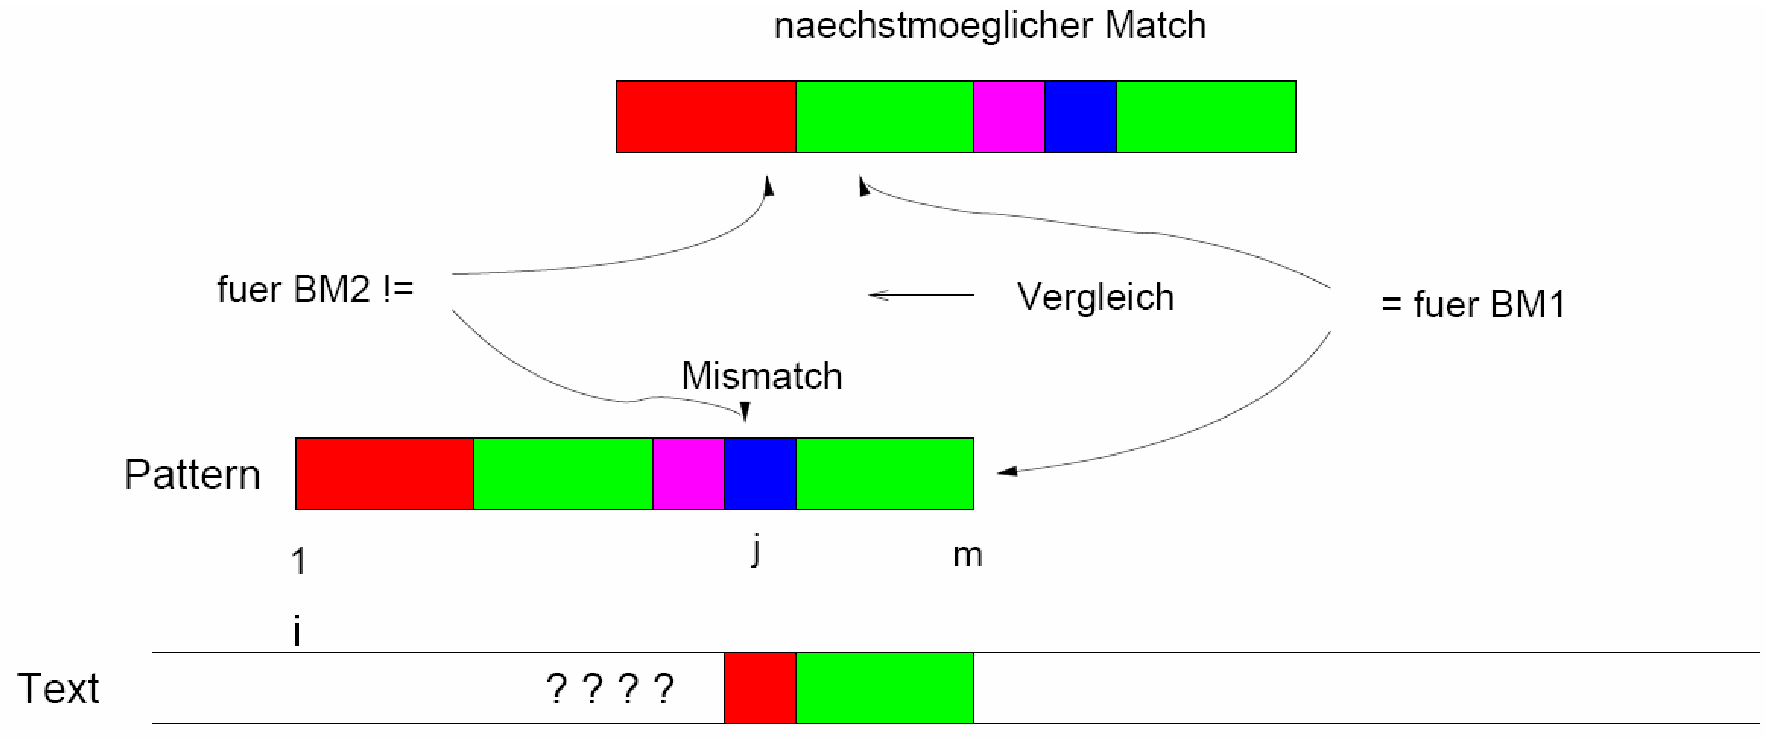

Wdh.: Angenommen, es gibt einen Mismatch an Stelle *j* von *pat*, und *pat* tritt in *text* an einer Position $i+s$ mit $i < i+s < i+m$ auf. Dann gelten die beiden folgenden Bedingungen:

(BM1) $\forall\, j < k \le m: \quad k \le s \;\vee\; pat[k\text{-}s] = pat[k]$

(BM2) $s < j \rightarrow \quad pat[j\text{-}s] \neq pat[j]$