
Algorithmen und Datenstrukturen

Prof. Dr. Ralf Möller

Universität zu Lübeck

Institut für Informationssysteme

Tanya Braun (Übungen)


sowie viele Tutoren

Danksagung

Die nachfolgenden Präsentationen wurden mit einigen Änderungen übernommen aus:

- „Algorithmen und Datenstrukturen“
gehalten von Sven Groppe an der UzL

Idee: Ausnutzung von gemeinsamen Präfixen



Trie

- Repräsentation von Mengen von Zeichenketten
- Name stammt nach *Edward Fredkin* von re**TRIE**val
 - Anwendungen von Tries finden sich im Bereich des *Information Retrieval*
 - Informationsrückgewinnung aus bestehenden komplexen Daten (Beispiel Internet-Suchmaschine)
 - auch Radix-Baum oder Suffix-Baum genannt
- Relativ **kompakte Speicherung von Daten** insbesondere mit **gemeinsamen Präfixen**

Trie


- Voraussetzung
 - Daten darstellbar als Folge von Elementen aus einem (endlichen) Alphabet
 - Beispiele
 - Zeichenkette „Otto“ besteht aus Zeichen ,O‘, ,t‘, ,t‘ und ,o‘ (Alphabet ist alle Zeichen)
 - Zahl 7 ist darstellbar als Folge von Bits 111 (Alphabet ist {0, 1})
 - Unter den Elementen aus dem Alphabet besteht eine Ordnung




Trie - Definition

- Sei Σ das **Alphabet** der zu speichernden Wörter inklusive $\perp$ für „leeres Zeichen“
- Dann ist ein **Trie ein Baum**
 - Jeder Knoten hat **0 bis maximal $|\Sigma|$ Kinder**
 - Jede Kante ist durch **genau einen Bezeichner aus Σ** gekennzeichnet
 - Die Kanten zu den Kindern eines Knotens haben **unterschiedliche Bezeichner**
 - d.h. es gibt *keine* Kanten eines Knotens mit demselben Bezeichner
 - in der Regel werden die Kanten sortiert dargestellt und gespeichert
 - **$\perp$ steht nur über einen Blattknoten** und auch nur wenn der Elternknoten des Blattknotens weitere Kindsknoten besitzt
- Der Wert eines Blattknotens ergibt sich aus der **Konkatenation der Kantenbezeichner** von der Wurzel zum Blattknoten


Beispiel: Suche nach **ape**




Beispiel: Suche nach **organ**




Beispiel: Suche nach **apricot**




Beispiel: Suche nach **org**




Einfügen: Beispiel **apricot**




Beispiel: Einfügen von **org**




Beispiel: Einfügen von **ape-man**



Löschen von *ape*




Löschen von *organism*



Implementierungsmöglichkeiten

- Feld



- Zeigerstruktur
 - Kinder in Liste
 - Kinder in Feld
 - Größe Kinderanzahl
 - Größe $|\Sigma|$


Komplexität der Basisoperationen (Suchen, Einfügen, Löschen)

- Alle Basisoperationen hängen ab
 - von der Tiefe t des Tries
 - t ist gleich der (maximalen) Länge der eingefügten Wörter
 - sowie der Kosten $f(|\Sigma|)$ pro Knoten für diese Operation
 - Abhängig von Speicherstruktur des Tries, siehe vorherige Folie $O(t \cdot f(|\Sigma|))$
- Bei geeigneter Implementation oder kleinem $|\Sigma|$:
 $O(t)$


Patricia Tries

- In Tries haben viele Knoten nur 1 Kind und es bilden sich oft lange “Ketten” mit solchen Knoten
- **Idee:** Diese lange “Ketten” zusammenfassen
 - **Konsequenz:** Kanten sind nicht nur mit einem Zeichen, sondern mit Teilwörtern beschriftet

Trie:




Patricia Trie:




Bedingungen:

- Ausgehende Kanten eines Knotens starten *niemals* mit demselben Zeichen!
- Knoten haben 0 oder 2 bis $|\Sigma|$ viele Kinder, *niemals* hat ein Knoten 1 Kind!

Trie (binär):




Patricia Trie:





Konsequenzen für die Basisoperationen

- Suchen
 - Anstatt Vergleich von Zeichen nun Vergleich von Teilzeichenketten, sonst keine wesentliche Änderung gegenüber Suchen in Tries
- Einfügen
 - **Neuer Sonderfall:** Aufteilen eines Knotens, „falls Bezeichner der eingehenden Kante (echte) Teilzeichenkette des einzufügenden Wortes ist“
- Löschen
 - **Neuer Sonderfall:** Nach Löschen überprüfen, ob Knoten vereinigt werden können



Beispiel Suchen nach *ape*





Sonderfall beim Einfügen von *organization* bzw. *org*



Beispiel für neuen Sonderfall beim Löschen von *apple*



Zwischenschritt:



Komplexität

- Ergebnisse für Basisoperationen korrelieren asymptotisch mit denen der Tries
 - D.h. bei geeigneter Implementierung $O(t)$ mit t Tiefe des Patricia Tries, welches mit der maximalen Länge der eingefügten Wörter korreliert
- Da Patricia Tries i.d.R. weniger Knoten haben, sind in der Praxis
 - Patricia Tries *schneller* und
 - haben *geringeren Speicherplatzverbrauch*

Zusammenfassung

- Trie
 - n-äres Alphabet
 - Speichern von Zeichenketten
 - binäres Alphabet
 - Speichern von z.B. Zahlen
- Patricia Trie
 - kompaktere Darstellung
 - n-äres Alphabet
 - binäres Alphabet