

Formale Methoden 1

Gerhard Jäger

Gerhard.Jaeger@uni-bielefeld.de

Uni Bielefeld, WS 2007/2008

23. Januar 2008

Das Pumping-Lemma

- Seien L eine **unendliche** reguläre Sprache über ein endliches Alphabet Σ .
- Es gibt einen NFA A , der L erkennt.
- Es gibt eine Zahl n , so dass A n Zustände hat.
- Fast alle Wörter in L bestehen aus mehr als n Buchstaben.
 - Sei $x \in L$, mit $l(x) > n$.
 - Es gibt einen Lauf von A , der x erkennt.
 - Weil A n Zustände hat und $l(x) > n$, wird mindestens ein Zustand von A mehrfach besucht. Sei Z derjenige Zustand, der als erster mehrfach besucht wird.
 - x lässt sich als $y \frown z \frown w$ darstellen, so dass
 - zwischen Startzustand und Z wird y erkannt,
 - zwischen dem ersten und dem zweiten Besuch von Z wird z erkannt, und
 - zwischen dem zweiten Besuch von Z und dem Endzustand wird w erkannt.

Das Pumping-Lemma

- Also:
 - die Schleife von Z nach Z , während der x erkannt wird, kann beliebig oft wiederholt werden.
- Also: $x \frown y^i \frown z \in L$, für beliebige $i \geq 0$.

Das Pumping-Lemma

Diese Überlegungen gelten für beliebige unendliche reguläre Sprachen.

Theorem

Sei L eine unendliche reguläre Sprache über das Alphabet Σ . Dann gibt es eine Zahl n , so dass sich alle Wörter $x \in L$ mit $l(x) \geq n$ zerlegen lassen in $x = y \frown z \frown w$, so dass folgende Eigenschaften erfüllt sind:

- 1 $l(z) \geq 1$,
- 2 $l(y) + l(z) \leq n$, und
- 3 für alle $i \in \mathbb{N}$ gilt: $y \frown z^i \frown w \in L$.

Anwendungen des Pumping-Lemmas

Das Pumping-Lemma ist nützlich, wenn man beweisen will, dass eine bestimmte Sprache **nicht** regulär ist.

- Beispiel: $L = \{a^m b^m \mid m > 0\}$ ist nicht regulär.
- Beweis:
 - Angenommen, L wäre regulär.
 - Dann gibt es ein n mit der im Pumping-Lemma genannten Eigenschaft (die Anzahl der Zustände des Automaten, der L erkennt).
 - $a^n b^n \in L$.
 - $a^n b^n = x \frown y \frown z$, mit $l(x \frown y) \leq n$, $l(y) \geq 1$, und $x \frown z \in L$.
 - $y = a^j$, für ein $j \geq 1$.
 - Also $x \frown z = a^{n-j} b^n \in L$, was einen Widerspruch zur Definition von L darstellt.
 - Also ist L nicht regulär.

Anwendungen des Pumping-Lemmas

- $L = \{a^n b^m \mid m \geq n\}$ ist nicht regulär.
- Beispiel: $L = \{a^n b^m \mid m > n > 0\}$ ist nicht regulär.
- Beweis:
 - Angenommen, L wäre regulär.
 - Dann gibt es ein $n > 0$ mit der im Pumping-Lemma genannten Eigenschaft.
 - $a^n b^n \in L$.
 - $a^n b^n = x \frown y \frown z$, mit $l(x \frown y) \leq n$, $l(y) \geq 1$, und $x \frown y^z \in L$.
 - $y = a^j$, für ein $j \geq 1$.
 - Also $x \frown y^{n \cdot m} \frown z \in L$, was einen Widerspruch zur Definition von L darstellt.
 - Also ist L nicht regulär.

Anwendungen des Pumping-Lemmas

- Auf ähnliche Weise lässt sich zeigen, dass die folgenden Sprachen nicht regulär sind:
 - $\{w \frown w \mid w \in \Sigma^*\}$ (die „Kopiersprache“)
 - $\{w \frown w^R \mid w \in \Sigma^*\}$ (die „Spiegel-Sprache“ oder „Palindrom-Sprache“)
- Komplizierter:

$$L = \{x \in \{a, b\}^* \mid \text{Anzahl der } a \text{ in } x = \text{Anzahl der } b \text{ in } x\}$$

Anwendungen des Pumping-Lemmas

Zum Beweis, dass L nicht regulär ist, benötigt man die folgende Einsicht:

Theorem

Wenn L_1 und L_2 regulär sind, dann ist auch $L_1 \cap L_2$ regulär.

Zunächst ist zu zeigen, dass das Komplement einer regulären Sprache auch regulär ist. Das ist nahezu offensichtlich: wenn ein DFA A die Sprache L akzeptiert., dann muss man lediglich die Endzustände in A in Nicht-Endzustände und die Nicht-Endzustände in Endzustände umwandeln, um einen DFA zu erhalten, der $\Sigma^* - L$ akzeptiert. In der letzten Vorlesung hatten wir gesehen, dass die Vereinigung zweier regulärer Sprachen auch regulär ist.

Wenn L_1 und L_2 also regulär sind, dann sind das auch $\overline{L_1}$ und $\overline{L_2}$, also auch $\overline{L_1} \cap \overline{L_2}$, also auch $\overline{\overline{L_1} \cap \overline{L_2}}$, was nach dem de-Morganschen Gesetz gleich $L_1 \cap L_2$ ist.

Anwendungen des Pumping-Lemmas

- Beweis, dass
 $L = \{x \in \{a, b\}^* \mid \text{Anzahl der } a \text{ in } x = \text{Anzahl der } b \text{ in } x\}$
nicht regulär ist:
 - a^*b^* ist regulär, weil diese Sprache durch einen regulären Ausdruck beschrieben wird.
 - Angenommen, L ist regulär. Dann muss auch $L \cap a^*b^* = \{a^n b^n \mid n \geq 0\}$ regulär sein.
 - Oben wurde gezeigt, dass diese Sprache nicht regulär ist. Also ist auch L nicht regulär.

Ist Deutsch regulär?

Mit Hilfe des Pumping-Lemmas lässt sich zeigen, dass natürliche Sprachen nicht regulär sind. Ein mögliches Argument fürs Deutsche geht folgendermaßen:

- Mit Hilfe von „**entweder** ... **oder** ...“ kann man im Deutschen beliebig lange Sätze konstruieren:

***Entweder** es regnet, **oder** es schneit.*

***Entweder** Hans glaubt, dass es **entweder** regnet **oder** dass es hagelt, **oder** es schneit.*

***Entweder** Hans glaubt, dass es **entweder** so aussieht, als ob es **entweder** kalt regnet **oder** warm regnet, **oder** dass es hagelt, **oder** es schneit.*

...

- Insbesondere gibt es eine unendlich lange Liste S_i von Sätzen wachsender Länge, so dass S_i genau i mal **entweder** enthält, und in denen alle **entweder**s allen **oder**s vorangehen.

Ist Deutsch regulär?

- Zu jedem *entweder* in einem deutschen Satz gehört ein *oder*; die Anzahl der *oders* ist also mindestens so groß wie die Zahl der *entweder*s.
- Reguläre Sprachen sind unter Tilgung von einzelnen Elementen von Σ abgeschlossen: Wenn ich einen bestimmten Buchstaben, z.B. a , in jedem Wort einer regulären Sprache L tilge, erhalte ich wieder eine reguläre Sprache. (Beweis: Ersetze in dem regulären Ausdruck, der L beschreibt, alle Vorkommen von a durch ϵ .)
- D' enthält die unendliche Sequenz S'_i , das Resultat der Tilgung aller Morphem außer *entweder* und *oder* in S_i

Ist Deutsch regulär?

- Angenommen, Deutsch ist regulär. Genauer gesagt würde das bedeuten, dass die Menge D der grammatischen deutschen Sätze eine reguläre Sprache ist über das Alphabet $\Sigma =$ die Menge aller deutschen Morpheme.
- Dann ist auch die Sprache D' regulär, die man erhält, wenn man in allen deutschen Sätzen alle Morpheme außer *entweder* und *oder* tilgt.
- Sei n die Zahl der Zustände des Automaten, der D' akzeptiert.
- $S'_n = \text{entweder}^n \text{oder}^m$, mit $m \geq n$.
- Nach dem Pumping-Lemma gibt es eine Zahl $k \geq 1$, so dass $\text{entweder}^{n+i \cdot k} \text{oder}^m \in D'$, für alle $i \in \mathbb{N}$.

Ist Deutsch regulär?

- Es gibt also Sätze in D' , in denen die Zahl der *entweder*s die Zahl der *oder*s übersteigt.
- Also gibt es auch Sätze in D , in denen die Zahl der *entweder*s die Zahl der *oder*s übersteigt.
- Das steht im Widerspruch zu der Beobachtung, dass zu jedem *entweder* ein anderes *oder* gehört.
- Also ist D keine reguläre Sprache.

Derartige Klammer-Konstruktionen wie das deutsche *entweder ... oder ...* gibt es vermutlich in allen natürlichen Sprachen.¹ Daher sind Typ-3-Grammatiken unzulänglich, um natürliche Sprachen vollständig zu beschreiben.

¹Über die südamerikanische Sprache Pirahã wird behauptet, dass es dort keine derartigen Konstruktionen gebe, was aber umstritten ist; siehe <http://de.wikipedia.org/wiki/Piraha>.