

Ringableitungen entfernen

Eine Ringableitung liegt vor, wenn es Variablen B_1, \dots, B_r gibt, so dass in P Regeln $B_i \rightarrow B_{i+1}$ für $i = 1, \dots, r - 1$ existieren, und außerdem $B_r \rightarrow B_1$ eine Regel aus P ist (und $r \geq 2$).

Wenn eine solche Ringableitung existiert, streichen wir alle Variablen B_i und ersetzen sie in allen Regeln durch die *neue* Variable B . Die Regel $B \rightarrow B$ wird entfernt.

Alle Ableitungen der ursprünglichen Grammatik können mit der abgewandelten Regelmenge immer noch gebildet werden.

Andererseits gilt in der ursprünglichen Grammatik $B_i \Rightarrow_G^* B_j$ für alle Paare i, j . Daher können wir Ableitungen gemäß der abgewandelten Grammatik zurück übersetzen in Ableitungen der ursprünglichen Grammatik, wenn an den „Nahtstellen“ diese Übergänge benutzt werden.

Variablen anordnen

Wenn alle Ringableitungen eliminiert sind, können wir die Variablen in einem Graph ohne Zyklen darstellen: Eine Kante (A, B) existiert genau dann, wenn $(A, B) \in P$ gilt.

Dieser endliche zyklensfreie Graph muss Knoten vom Ausgangsgrad 0 haben. Wir wählen einen solchen als *letzten* Knoten in der Ordnung und entfernen ihn aus dem Graph. Der neue Graph hat wieder einen solchen Knoten vom Ausgangsgrad 0, der der vorletzte in der Ordnung wird, usw.

Nun seien die Knoten geordnet: $V = \{A_1, \dots, A_n\}$ und in P kann $A_i \rightarrow A_j$ nur dann vorkommen, wenn $i < j$ gilt.

Jetzt eliminieren wir sukzessive Regeln der Form $A_i \rightarrow A_j$, indem wir *Abkürzungen* einführen, beginnend bei $i = n - 1$.

Abkürzungen und Pseudoterminale

Die Beseitigung der Regel $A_{n-1} \rightarrow A_n$ schaffen wir, indem wir für jede Regel $A_n \rightarrow v$ auch die Regel $A_{n-1} \rightarrow v$ einführen.

Das tun wir natürlich nur, wenn die Regel $A_{n-1} \rightarrow A_n$ wirklich vorhanden war!

Dieses Vorgehen iterieren wir so lange, wie noch Regeln $A_i \rightarrow A_j$ mit $i < j$ vorhanden sind – und zwar von hinten nach vorne.

Wir rekapitulieren: Jetzt gilt für jede Regel (u, v) in P entweder $v \in \Sigma$ oder $|v| \geq 2$.

Als nächstes werden Terminale, die in Regeln (u, v) mit $|v| > 1$ vorkommen, durch neue Variablen (eine Variable für jedes Terminal) ersetzt, z.B. a durch V_a , und dann die Regel $V_a \rightarrow a$ ergänzt.

Nun haben alle Regeln die Form (u, v) , wobei entweder $v \in \Sigma$ gilt oder $v \in V^*$, aber dann $|v| > 1$.

Letzter Schritt

Die störenden Regeln, die wir jetzt noch haben, sind von der Form $A \rightarrow C_1 \dots C_k$ mit $k \geq 2$. Für $k = 2$ sind diese schon so, wie in der CNF vorgesehen. Aber was machen wir bei $k > 2$?

Wir wählen neue Variablen D_2, \dots, D_{k-1} und ersetzen die eine Regel $A \rightarrow C_1 \dots C_k$ durch folgende $k - 1$ Regeln:

$$A \rightarrow C_1 D_2$$

$$D_2 \rightarrow C_2 D_3$$

usw. bis

$$D_{k-1} \rightarrow C_{k-1} C_k$$

Auch durch diese letzte Anpassung wird die erzeugte Sprache nicht geändert. Also erhalten wir den folgenden Satz...

Satz (Chomsky-Normalform)

Satz: Zu jeder kontextfreien Grammatik G mit $\varepsilon \notin L(G)$ gibt es eine Grammatik G' in Chomsky-Normalform, so dass

$$L(G) = L(G')$$

gilt.

Der Beweis für diesen Satz, den wir in dieser Einheit geführt haben, war konstruktiv – d.h. wir können G' sogar konstruieren!

Schema zur Herstellung einer CNF

Wir werden immer genau nach dem Schema vorgehen, das durch den Beweis der Existenz einer CNF vorgegeben ist:

1) Ringableitungen entfernen

Nun bilden die Variablen mit Regeln der Form (A, B) einen azyklischen Graph.

2) Variablen anordnen

Nun können die Regeln der Form (A, B) eliminiert werden.

3) Abkürzungen verwenden

Jetzt gibt es keine Regeln der Form (A, B) mehr.

4) Pseudoterminale einführen

Danach stören nur noch Regeln der Form (A, v) mit $|v| > 2$.

5) $A \rightarrow C_1 \dots C_k$ mit $k \geq 3$ jeweils durch $k - 1$ Regeln ersetzen.

Die CNF ist fertig.

Erstes Beispiel zur CNF

Wir betrachten die Grammatik $S \rightarrow aSb \mid ab$, mit der die Sprache

$$L = \{a^n b^n \mid n \geq 1\}$$

erzeugt wird.

Es gibt keine Ringableitungen. Das Anordnen der Variablen und Verwenden von Abkürzungen entfällt auch, weil in der gegebenen Grammatik nur eine Variable vorkommt.

Wir führen Pseudoterminale V_a und V_b ein und erhalten:

$$S \rightarrow V_a S V_b \mid V_a V_b \quad V_a \rightarrow a \quad V_b \rightarrow b$$

Wir brauchen eine neue Variable C und erhalten als Endergebnis:

$$\begin{array}{ll} S \rightarrow V_a C \mid V_a V_b & V_a \rightarrow a \\ C \rightarrow S V_b & V_b \rightarrow b \end{array}$$