

Algorithmus:

```
2N  result = ∅;           // Ergebnis-Menge
int  count[P];             // Zähler für jede Regel
2P  rhs[N];             // Vorkommen in rechten Seiten

forall (A ∈ N)  rhs[A] = ∅; // Initialisierung
forall ((A, i) ∈ P)  {
    count[(A, i)] = 0;      //
    init(A, i);           // Initialisierung von rhs
}
...

```

Die Hilfsfunktion **init** zählt die Nichtterminal-Vorkommen in der rechten Seite und vermerkt sie in der Datenstruktur **rhs** :-)


```

...
 $2^P$   $W = \{r \mid \text{count}[r] = 0\};$  // Workset
while ( $W \neq \emptyset$ ) {
  ( $A, i$ ) = extract( $W$ );
  if ( $A \notin \text{result}$ ) {
     $\text{result} = \text{result} \cup \{A\};$  //
    forall ( $r \in \text{rhs}[A]$ ) {
       $\text{count}[r]--;$  //
      if ( $\text{count}[r] == 0$ )  $W = W \cup \{r\};$  //
    }
  }
}


```

Die Menge W verwaltet die Regeln, deren rechte Seiten nur produktive Nichtterminale enthalten :-))


... im Beispiel:




... im Beispiel:




... im Beispiel:



... im Beispiel:



... im Beispiel:



Laufzeit:

- Die Initialisierung der Datenstrukturen erfordert lineare Laufzeit.
- Jede Regel wird maximal einmal in W eingefügt.
- Jedes A wird maximal einmal in $result$ eingefügt.
 \implies Der Gesamtaufwand ist **linear** in der Größe der Grammatik :-)

Korrektheit:

- Falls A in der j -ten Iteration der **while**-Schleife in $result$ eingefügt, gibt es einen Ableitungsbaum für A der Höhe maximal $j - 1$:-)
- Für jeden Ableitungsbaum wird die Wurzel einmal in W eingefügt :-)

Diskussion:

- Um den Test $(A \in \text{result})$ einfach zu machen, repräsentiert man die Menge `result` durch ein **Array**.
- W wie auch die Mengen `rhs[A]` wird man dagegen als **Listen** repräsentieren :-)


Diskussion:

- Um den Test $(A \in \text{result})$ einfach zu machen, repräsentiert man die Menge `result` durch ein **Array**.
- Wie auch die Mengen `rhs[A]` wird man dagegen als **Listen** repräsentieren :-)
- Der Algorithmus funktioniert auch, um **kleinste** Lösungen von Booleschen Ungleichungssystemen zu bestimmen :-)
- Die Ermittlung der produktiven Nichtterminale kann benutzt werden, um festzustellen, ob $\mathcal{L}(G) \neq \emptyset$ ist (\rightarrow Leerheitsproblem)

Idee für Erreichbarkeit:

Abhängigkeits-Graph

... hier:




Knoten: Nichtterminale

Kanten: (A, B) falls $B \xrightarrow{\alpha_1} A \alpha_2 \in P$

Idee für Erreichbarkeit:

Abhängigkeits-Graph

... hier:




Knoten: Nichtterminale

Kanten: (A, B) falls $B \xrightarrow{\alpha_1} A \alpha_2 \in P$

Idee für Erreichbarkeit:

... hier:


Abhängigkeits-Graph




Knoten: Nichtterminale

Kanten: (A, B) falls $B \xrightarrow{\alpha_1} A \alpha_2 \in P$


Das Nichtterminal A ist erreichbar, falls es im Abhängigkeitsgraphen einen Pfad von A nach S gibt $(:-)$




Das Nichtterminal A ist erreichbar, falls es im Abhängigkeitsgraphen einen Pfad von A nach S gibt $(:-)$




Das Nichtterminal A ist erreichbar, falls es im Abhängigkeitsgraphen einen Pfad von A nach S gibt $(:-)$



Das Nichtterminal A ist erreichbar, falls es im Abhängigkeitsgraphen einen Pfad von A nach S gibt $(:-)$



Das Nichtterminal A ist erreichbar, falls es im Abhängigkeitsgraphen einen Pfad von A nach S gibt $(:-)$



Fazit:

- Erreichbarkeit in gerichteten Graphen kann mithilfe von **DFS** in **linearer Zeit** berechnet werden.
- Damit kann die Menge aller erreichbaren und produktiven Nichtterminale in **linearer Zeit** berechnet werden :-)

Fazit:

- Erreichbarkeit in gerichteten Graphen kann mithilfe von **DFS** in **linearer Zeit** berechnet werden.
- Damit kann die Menge aller erreichbaren und produktiven Nichtterminale in **linearer Zeit** berechnet werden :-)

Eine Grammatik G heißt **reduziert**, wenn alle Nichtterminale von G sowohl produktiv wie erreichbar sind ...

Fazit:

- Erreichbarkeit in gerichteten Graphen kann mithilfe von **DFS** in **linearer Zeit** berechnet werden.
- Damit kann die Menge aller erreichbaren und produktiven Nichtterminale in **linearer Zeit** berechnet werden :-)

Eine Grammatik G heißt **reduziert**, wenn alle Nichtterminale von G sowohl produktiv wie erreichbar sind ...

Satz

Zu jeder kontextfreien Grammatik $G = (N, T, P, S)$ mit $\mathcal{L}(G) \neq \emptyset$ kann in **linearer Zeit** eine reduzierte Grammatik G' konstruiert werden mit

$$\mathcal{L}(G) = \mathcal{L}(G')$$

Konstruktion:

1. Schritt:

Berechne die Teilmenge $N' \subseteq N$ aller produktiven und erreichbaren Nichtterminale von G .

Da $\mathcal{L}(G) \neq \emptyset$ ist insbesondere $S \in N'$:-)

Konstruktion:

1. Schritt:

Berechne die Teilmenge $N' \subseteq N$ aller produktiven und erreichbaren Nichtterminale von G .

Da $\mathcal{L}(G) \neq \emptyset$ ist insbesondere $S \in N'$:-)

2. Schritt:

Konstruiere: $P' = \{A \rightarrow \alpha \in P \mid A \in N' \wedge \alpha \in (N' \cup T)^*\}$

Konstruktion:

1. Schritt:

Berechne die Teilmenge $N' \subseteq N$ aller produktiven und erreichbaren Nichtterminale von G .

Da $\mathcal{L}(G) \neq \emptyset$ ist insbesondere $S \in N'$:-)

2. Schritt:

Konstruiere: $P' = \{A \rightarrow \alpha \in P \mid A \in N' \wedge \alpha \in (N' \cup T)^*\}$

Ergebnis: $G' = (N', T, P', S)$:-)

... im Beispiel:

$$S \rightarrow a B B \quad | \quad b D$$

$$A \rightarrow B c$$

$$B \rightarrow S d \quad | \quad C$$

$$C \rightarrow a$$

$$D \rightarrow B D$$

... im Beispiel:

$$S \rightarrow a B B \quad | \quad b D$$

$$A \rightarrow B c$$

$$B \rightarrow S d \quad | \quad C$$

$$C \rightarrow a$$

$$D \rightarrow B D$$

... im Beispiel:


$$S \rightarrow a B B$$

$$B \rightarrow S d \quad | \quad C$$

$$C \rightarrow a$$

2.2 Grundlagen: Kellerautomaten

Durch kontextfreie Grammatiken spezifizierte Sprachen können durch Kellerautomaten (Pushdown Automata) akzeptiert werden:



Der Keller wird z.B. benötigt, um korrekte Klammerung zu überprüfen :-)




Friedrich L. Bauer, TUM



Klaus Samelson, TUM

Kellerautomaten für kontextfreie Sprachen wurden erstmals vorgeschlagen von Michel Schützenberger und Antony G. Öttinger:



Marcel-Paul Schützenberger
(1920-1996), Paris



Antony G. Öttinger, Präsident der
ACM 1966-68

Beispiel:

Zustände: $0, 1, 2$

Anfangszustand: 0

Endzustände: $0, 2$

0	a	11
1	a	11
11	b	2
12	b	2

Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

Achtung:

- Wir unterscheiden **nicht** zwischen Kellersymbolen und Zuständen :-)
- Das rechteste / oberste Kellersymbol repräsentiert den Zustand :-)
- Jeder Übergang liest / modifiziert einen oberen Abschnitt des Kellers :-)

Formal definieren wir deshalb einen **Kellerautomaten (PDA)** als ein Tupel:

$M = (Q, T, \delta, q_0, F)$ wobei:

- Q eine endliche Menge von Zuständen;
- T das Eingabe-Alphabet;
- $q_0 \in Q$ der Anfangszustand;
- $F \subseteq Q$ die Menge der Endzustände und
- $\delta \subseteq Q^+ \times (T \cup \{\epsilon\}) \times Q^*$ eine endliche Menge von Übergängen ist (das Programm :-)

Formal definieren wir deshalb einen **Kellerautomaten (PDA)** als ein Tupel:

$M = (Q, T, \delta, q_0, F)$ wobei:

- Q eine endliche Menge von Zuständen;
- T das Eingabe-Alphabet;
- $q_0 \in Q$ der Anfangszustand;
- $F \subseteq Q$ die Menge der Endzustände und
- $\delta \subseteq Q^+ \times (T \cup \{\epsilon\}) \times Q^*$ eine endliche Menge von Übergängen ist (das Programm :-)

Mithilfe der Übergänge definieren wir **Berechnungen** von Kellerautomaten :-)

Der jeweilige **Berechnungszustand** (die aktuelle **Konfiguration**) ist ein Paar:

$$(\gamma, w) \in Q^* \times T^*$$

bestehend aus dem **Kellerinhalt** und dem noch zu lesenden Input.

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

(0, *a a a b b b*)

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$(0, \quad a a a b b b) \quad \vdash \quad (11, \quad a a b b b)$$

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$\begin{array}{c} (0, \quad a a a b b b) \quad \vdash \quad (1 1, \quad a a b b b) \\ \vdash \quad (1 1 1, \quad a b b b) \end{array}$$

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$\begin{array}{c} (0, \quad a a a b b b) \quad \vdash \quad (11, \quad a a b b b) \\ \vdash \quad (111, \quad a b b b) \\ \vdash \quad (1111, \quad b b b) \end{array}$$

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$\begin{array}{l} (0, \quad a a a b b b) \quad \vdash \quad (1 1, \quad a a b b b) \\ \quad \vdash \quad (1 1 1, \quad a b b b) \\ \quad \vdash \quad (1 1 1 1, \quad b b b) \\ \quad \vdash \quad (1 1 2, \quad b b) \end{array}$$

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$\begin{array}{l} (0, \quad a a a b b b) \quad \vdash \quad (1 1, \quad a a b b b) \\ \quad \vdash \quad (1 1 1, \quad a b b b) \\ \quad \vdash \quad (1 1 1 1, \quad b b b) \\ \quad \vdash \quad (1 1 2, \quad b b) \\ \quad \vdash \quad (1 2, \quad b) \end{array}$$

... im Beispiel:

Zustände: 0, 1, 2

Anfangszustand: 0

Endzustände: 0, 2

0	<i>a</i>	11
1	<i>a</i>	11
11	<i>b</i>	2
12	<i>b</i>	2

$$\begin{array}{ll} (0, \quad a a a b b b) & \vdash (1 1, \quad a a b b b) \\ & \vdash (1 1 1, \quad a b b b) \\ & \vdash (1 1 1 1, \quad b b b) \\ & \vdash (1 1 2, \quad b b) \\ & \vdash (1 2, \quad b) \\ & \vdash (2, \quad \epsilon) \end{array}$$

Ein Berechnungsschritt wird durch die Relation $\vdash \subseteq (Q^* \times T^*)^2$ beschrieben, wobei

$$(\alpha \gamma, x w) \vdash (\alpha \gamma', w) \quad \text{für} \quad (\gamma, x, \gamma') \in \delta$$

Ein Berechnungsschritt wird durch die Relation $\vdash \subseteq (Q^* \times T^*)^2$ beschrieben, wobei

$$(\alpha \gamma, x w) \vdash (\alpha \gamma', w) \quad \text{für} \quad (\gamma, x, \gamma') \in \delta$$

Bemerkungen:

- Die Relation \vdash hängt natürlich vom Kellerautomaten M ab :-)
- Die reflexive und transitive Hülle von \vdash bezeichnen wir mit \vdash^* .
- Dann ist die von M akzeptierte Sprache:

$$\mathcal{L}(M) = \{w \in T^* \mid \exists f \in F : (q_0, w) \vdash^* (f, \epsilon)\}$$

Ein Berechnungsschritt wird durch die Relation $\vdash \subseteq (Q^* \times T^*)^2$ beschrieben, wobei

$$(\alpha\gamma, xw) \vdash (\alpha\gamma', w) \quad \text{für} \quad (\gamma, x, \gamma') \in \delta$$

Bemerkungen:

- Die Relation \vdash hängt natürlich vom Kellerautomaten M ab :-)
- Die reflexive und transitive Hülle von \vdash bezeichnen wir mit \vdash^* .
- Dann ist die von M akzeptierte Sprache:

$$\mathcal{L}(M) = \{w \in T^* \mid \exists f \in F : (q_0, w) \vdash^* (f, \epsilon)\}$$

Wir akzeptieren also mit **Endzustand** und leerem Keller :-)

Der Kellerautomat M heißt **deterministisch**, falls jede Konfiguration maximal eine Nachfolge-Konfiguration hat.

Das ist genau dann der Fall wenn für verschiedene Übergänge
 $(\gamma_1, x, \gamma_2), (\gamma'_1, x', \gamma'_2) \in \delta$ gilt:

Ist γ_1 ein Suffix von γ'_1 , dann muss $x \neq x' \wedge x \neq \epsilon \neq x'$ sein.

Der Kellerautomat M heißt **deterministisch**, falls jede Konfiguration maximal eine Nachfolge-Konfiguration hat.

Das ist genau dann der Fall wenn für verschiedene Übergänge $(\gamma_1, x, \gamma_2), (\gamma'_1, x', \gamma'_2) \in \delta$ gilt:

Ist γ_1 ein Suffix von γ'_1 , dann muss $x \neq x' \wedge x \neq \epsilon \neq x'$ sein.

... im Beispiel:

0	a	11
1	a	11
11	b	2
12	b	2

ist das natürlich der Fall :-))

Satz

Zu jeder kontextfreien Grammatik $G = (N, T, P, S)$ kann ein PDA M konstruiert werden mit $\mathcal{L}(G) = \mathcal{L}(M)$.

Der Satz ist für uns so wichtig, dass wir **zwei** Konstruktionen angeben :-)

Satz

Zu jeder kontextfreien Grammatik $G = (N, T, P, S)$ kann ein PDA M konstruiert werden mit $\mathcal{L}(G) = \mathcal{L}(M)$.

Der Satz ist für uns so wichtig, dass wir **zwei** Konstruktionen angeben :-)

Konstruktion 1: Shift-Reduce-Parser

- Die Eingabe wird sukzessive auf den Keller geschiftet.
- Liegt oben auf dem Keller eine **vollständige rechte Seite** (ein **Handle**) vor, wird dieses durch die zugehörige linke Seite ersetzt (**reduziert**) :-)

Beispiel:

$$\begin{array}{l} S \rightarrow A B \\ A \rightarrow a \\ B \rightarrow b \end{array}$$

Der Kellerautomat:

Zustände: q_0, f, a, b, A, B, S ;
Anfangszustand: q_0
Endzustand: f

q_0	a	$q_0 a$
a	ϵ	A
A	b	$A b$
b	ϵ	B
$A B$	ϵ	S
$q_0 S$	ϵ	f

Allgemein konstruieren wir einen Automaten $M_G^{(1)} = (Q, T, \delta, q_0, F)$ mit:

- $Q = T \cup N \cup \{q_0, f\}$ (q_0, f neu);
- $F = \{f\}$;
- Übergänge:

$$\begin{aligned}\delta = & \{ (q, x, q x) \mid q \in Q, x \in T \} \cup && // \text{ Shift-Übergänge} \\ & \{ (q \alpha, \epsilon, q A) \mid q \in Q, A \rightarrow \alpha \in P \} \cup && // \text{ Reduce-Übergänge} \\ & \{ (q_0 S, \epsilon, f) \} && // \text{ Abschluss } :-\end{aligned}$$

Allgemein konstruieren wir einen Automaten $M_G^{(1)} = (Q, T, \delta, q_0, F)$ mit:

- $Q = T \cup N \cup \{q_0, f\}$ (q_0, f neu);
- $F = \{f\}$;
- Übergänge:

$$\begin{aligned} \delta = & \{ (q, x, q x) \mid q \in Q, x \in T \} \cup && // \text{ Shift-Übergänge} \\ & \{ (q \alpha, \epsilon, q A) \mid q \in Q, A \rightarrow \alpha \in P \} \cup && // \text{ Reduce-Übergänge} \\ & \{ (q_0 S, \epsilon, f) \} && // \text{ Abschluss } :-) \end{aligned}$$

Eine Beispiel-Berechnung:

$$\begin{aligned} (q_0, a b) & \vdash (q_0 a, b) \vdash (q_0 A, b) \\ & \vdash (q_0 A b, \epsilon) \vdash (q_0 A B, \epsilon) \\ & \vdash (q_0 S, \epsilon) \vdash (f, \epsilon) \end{aligned}$$

Allgemein konstruieren wir einen Automaten $M_G^{(1)} = (Q, T, \delta, q_0, F)$ mit:

- $Q = T \cup N \cup \{q_0, f\}$ (q_0, f neu);
- $F = \{f\}$;
- Übergänge:

$$\begin{aligned} \delta = & \{ (q, x, q x) \mid q \in Q, x \in T \} \cup & // \text{ Shift-Übergänge} \\ & \{ (q \alpha, \epsilon, q A) \mid q \in Q, A \rightarrow \alpha \in P \} \cup & // \text{ Reduce-Übergänge} \\ & \{ (q_0 S, \epsilon, f) \} & // \text{ Abschluss } :-) \end{aligned}$$

Eine Beispiel-Berechnung:

$$\begin{array}{llll} (q_0, a b) & \vdash & (q_0 \boxed{a}, b) & \vdash (q_0 A, b) \\ & \vdash (q_0 A \boxed{b}, \epsilon) & \vdash (q_0 \boxed{A B}, \epsilon) \\ & \vdash (q_0 S, \epsilon) & \vdash (f, \epsilon) \end{array}$$

Offenbar gilt:

- Die Folge der Reduktionen entspricht einer **reversen Rechtsableitung** für die Eingabe `:-)`
- Zur Korrektheit zeigt man, dass für jedes q gilt:

$$(q, w) \vdash^* (q A, \epsilon) \quad \text{gdw.} \quad A \rightarrow^* w$$

- Der Kellerautomat $M_G^{(1)}$ ist i.a. nicht-deterministisch `:-)`
- Um ein deterministisches Parse-Verfahren zu erhalten, muss man die Reduktionsstellen identifizieren \implies **LR-Parsing**