

Script generated by TTT

Title: Simon: Compilerbau (02.05.2012)

Date: Wed May 02 14:11:53 CEST 2012

Duration: 85:12 min

Pages: 63

Lexikalische Analyse

Kapitel 5: Design eines Scanners

Bemerkungen:

- Bei einem Eingabewort der Länge n werden maximal $\mathcal{O}(n)$ Mengen konstruiert
- Ist eine Menge bzw. eine Kante des DFA einmal konstruiert, heben wir sie in einer Hash-Tabelle auf.
- Bevor wir einen neuen Übergang konstruieren, sehen wir erst nach, ob wir diesen nicht schon haben

Zusammenfassend finden wir:

Satz:

Zu jedem regulären Ausdruck e kann ein deterministischer Automat $A = \mathcal{P}(A_e)$ konstruiert werden mit

$$\mathcal{L}(A) = \llbracket e \rrbracket$$

Design eines Scanners

Eingabe (vereinfacht): eine Menge von Regeln:

e_1	{ action ₁ }
e_2	{ action ₂ }
...	
e_k	{ action _k }

Design eines Scanners

int counter;
String

Eingabe (vereinfacht): eine Menge von Regeln:

e_1 { action₁ }
 e_2 { action₂ }
...
 e_k { action_k }

Ausgabe: ein Programm, das

- ... von der Eingabe ein maximales Präfix w liest, das $e_1 | \dots | e_k$ erfüllt;
- ... das minimale i ermittelt, so dass $w \in [e_i]$;
- ... für w action _{i} ausführt.

53 / 160

Implementierung:

Idee:

- Konstruiere den DFA $\mathcal{P}(A_e) = (Q, \Sigma, \delta, \{q_0\}, F)$ zu dem Ausdruck $e = (e_1 | \dots | e_k)$;
- Definiere die Mengen:

$$F_1 = \{q \in F \mid q \cap \text{last}[e_1] \neq \emptyset\}$$

$$F_2 = \{q \in (F \setminus F_1) \mid q \cap \text{last}[e_2] \neq \emptyset\}$$

$$\dots$$

$$F_k = \{q \in (F \setminus (F_1 \cup \dots \cup F_{k-1})) \mid q \cap \text{last}[e_k] \neq \emptyset\}$$

- Für Eingabe w gilt: $\delta^*(q_0, w) \in F_i$ genau dann wenn der Scanner für w action _{i} ausführen soll


54 / 160

Implementierung:

Idee (Fortsetzung):

- Der Scanner verwaltet zwei Zeiger $\langle A, B \rangle$ und die zugehörigen Zustände $\langle q_A, q_B \rangle \dots$
- Der Zeiger A merkt sich die letzte Position in der Eingabe, nach der ein Zustand $q_A \in F$ erreicht wurde;
- Der Zeiger B verfolgt die aktuelle Position.

s t d o u t . w r i t e l n (" H a l l o ") ;




55 / 160

Implementierung:

Idee (Fortsetzung):

- Der Scanner verwaltet zwei Zeiger $\langle A, B \rangle$ und die zugehörigen Zustände $\langle q_A, q_B \rangle \dots$
- Der Zeiger A merkt sich die letzte Position in der Eingabe, nach der ein Zustand $q_A \in F$ erreicht wurde;
- Der Zeiger B verfolgt die aktuelle Position.




55 / 160

Implementierung:

Idee (Fortsetzung):

- Ist der aktuelle Zustand $q_B = \emptyset$, geben wir Eingabe bis zur Position A aus und setzen:

$$\begin{aligned} B &:= A; & A &:= \perp; \\ q_B &:= q_0; & q_A &:= \perp \end{aligned}$$




56 / 160

Implementierung:

Idee (Fortsetzung):

- Ist der aktuelle Zustand $q_B = \emptyset$, geben wir Eingabe bis zur Position A aus und setzen:

$$\begin{aligned} B &:= A; & A &:= \perp; \\ q_B &:= q_0; & q_A &:= \perp \end{aligned}$$




56 / 160

Implementierung:

Idee (Fortsetzung):

- Ist der aktuelle Zustand $q_B = \emptyset$, geben wir Eingabe bis zur Position A aus und setzen:

$$\begin{aligned} B &:= A; & A &:= \perp; \\ q_B &:= q_0; & q_A &:= \perp \end{aligned}$$



56 / 160

Erweiterung: Zustände

- Gelegentlich ist es nützlich, verschiedene **Scanner-Zustände** zu unterscheiden.
- In unterschiedlichen Zuständen sollen verschiedene Tokenklassen erkannt werden können.
- In Abhängigkeit der gelesenen Tokens kann der Scanner-Zustand geändert werden

Beispiel: Kommentare

Innerhalb eines Kommentars werden Identifier, Konstanten, Kommentare, ... nicht erkannt

57 / 160

Eingabe (verallgemeinert): eine Menge von Regeln:

```
<state> { e1 { action1 yybegin(state1); }  
          e2 { action2 yybegin(state2); }  
          ...  
          ek { actionk yybegin(statek); }  
        }
```

- Der Aufruf `yybegin (statei);` setzt den Zustand auf `statei`.
- Der Startzustand ist (z.B. bei **JFlex**) `YYINITIAL`.

... im Beispiel:

```
<YYINITIAL> { /*" { yybegin(COMMENT); }  
<COMMENT> { "*/" { yybegin(YYINITIAL); }  
            . | \n { }  
          }
```

58 / 160


Bemerkungen:

- `"."` matcht alle Zeichen ungleich `"\n"`.
- Für jeden Zustand generieren wir den entsprechenden Scanner.
- Die Methode `yybegin (STATE);` schaltet zwischen den verschiedenen Scannern um.
- Kommentare könnte man auch direkt mithilfe einer geeigneten Token-Klasse implementieren. Deren Beschreibung ist aber ungleich komplizierter
- Scanner-Zustände sind insbesondere nützlich bei der Implementierung von **Präprozessoren**, die in einen Text eingestreute Spezifikationen expandieren sollen.

59 / 160

Themengebiet: Syntaktische Analyse

Die syntaktische Analyse




- Die syntaktische Analyse versucht, Tokens zu größeren Programmeinheiten zusammen zu fassen.

60 / 160

61 / 160

Die syntaktische Analyse



- Die syntaktische Analyse versucht, Tokens zu größeren Programmeinheiten zusammen zu fassen.
- Solche Einheiten können sein:
 - Ausdrücke;
 - Statements;
 - bedingte Verzweigungen;
 - Schleifen; ...

61 / 160

Diskussion:


Auch Parser werden i.a. nicht von Hand programmiert, sondern aus einer Spezifikation **generiert**:



62 / 160

Diskussion:

Auch Parser werden i.a. nicht von Hand programmiert, sondern aus einer Spezifikation **generiert**:



Spezifikation der hierarchischen Struktur: kontextfreie Grammatiken

Generierte Implementierung: Kellerautomaten + X

62 / 160

Ende der Präsentation. Klicken Sie zum Schließen.

Grundlagen: Kontextfreie Grammatiken

- Programme einer Programmiersprache können unbeschränkt viele Tokens enthalten, aber nur endlich viele Token-Klassen
- Als endliches Terminal-Alphabet T wählen wir darum die Menge der Token-Klassen.
- Die Schachtelung von Programm-Konstrukten lässt sich elegant mit Hilfe von kontextfreien Grammatiken beschreiben ...

64 / 160

Grundlagen: Kontextfreie Grammatiken

- Programme einer Programmiersprache können unbeschränkt viele Tokens enthalten, aber nur endlich viele Token-Klassen
- Als endliches Terminal-Alphabet T wählen wir darum die Menge der Token-Klassen.
- Die Schachtelung von Programm-Konstrukten lässt sich elegant mit Hilfe von kontextfreien Grammatiken beschreiben ...


Definition:

Eine kontextfreie Grammatik (CFG) ist ein 4-Tupel $G = (N, T, P, S)$ mit:

- N die Menge der Nichtterminale,
- T die Menge der Terminale,
- P die Menge der Produktionen oder Regeln, und
- $S \in N$ das Startsymbol



Noam Chomsky



John Backus

64 / 160

Konventionen

Die Regeln kontextfreier Grammatiken sind von der Form:

$$A \rightarrow \alpha \text{ mit } A \in N, \alpha \in (N \cup T)^*$$

65 / 160

Konventionen

Die Regeln kontextfreier Grammatiken sind von der Form:

$$A \rightarrow \alpha \text{ mit } A \in N, \alpha \in (N \cup T)^*$$

... im Beispiel:

$$\begin{aligned} S &\rightarrow a S b \\ S &\rightarrow \epsilon \end{aligned}$$

Spezifizierte Sprache: $\{a^n b^n \mid n \geq 0\}$

65 / 160

Konventionen

Die Regeln kontextfreier Grammatiken sind von der Form:

$$A \rightarrow \alpha \text{ mit } A \in N, \alpha \in (N \cup T)^*$$

... im Beispiel:

$$\begin{aligned} S &\rightarrow aSb \\ S &\rightarrow \epsilon \end{aligned}$$

Spezifizierte Sprache: $\{a^n b^n \mid n \geq 0\}$

Konventionen:

In Beispielen ist die Spezifikation der Nichtterminale und Terminale i.a. implizit:

- Nichtterminale sind: $A, B, C, \dots, \langle \text{exp} \rangle, \langle \text{stmt} \rangle, \dots;$
- Terminale sind: $a, b, c, \dots, \text{int}, \text{name}, \dots;$

65 / 160

... weitere Beispiele:

$$\begin{aligned} S &\rightarrow \langle \text{stmt} \rangle \\ \langle \text{stmt} \rangle &\rightarrow \langle \text{if} \rangle \mid \langle \text{while} \rangle \mid \langle \text{rexpr} \rangle; \\ \langle \text{if} \rangle &\rightarrow \text{if} (\langle \text{rexpr} \rangle) \langle \text{stmt} \rangle \text{ else } \langle \text{stmt} \rangle \\ \langle \text{while} \rangle &\rightarrow \text{while} (\langle \text{rexpr} \rangle) \langle \text{stmt} \rangle \\ \langle \text{rexpr} \rangle &\rightarrow \text{int} \mid \langle \text{lexpr} \rangle \mid \langle \text{lexpr} \rangle = \langle \text{rexpr} \rangle \mid \dots \\ \langle \text{lexpr} \rangle &\rightarrow \text{name} \mid \dots \end{aligned}$$

Weitere Konventionen:

- Für jedes Nichtterminal sammeln wir die rechten Regelseiten und listen sie gemeinsam auf
- Die j -te Regel für A können wir durch das Paar (A, j) bezeichnen ($j \geq 0$).

66 / 160

... weitere Beispiele:

$$\begin{aligned} S &\rightarrow \langle \text{stmt} \rangle \\ \langle \text{stmt} \rangle &\rightarrow \langle \text{if} \rangle \mid \langle \text{while} \rangle \mid \langle \text{rexpr} \rangle; \mid \{ \text{Stmt-List} \} \\ \langle \text{if} \rangle &\rightarrow \text{if} (\langle \text{rexpr} \rangle) \langle \text{stmt} \rangle \text{ else } \langle \text{stmt} \rangle \\ \langle \text{while} \rangle &\rightarrow \text{while} (\langle \text{rexpr} \rangle) \langle \text{stmt} \rangle \\ \langle \text{rexpr} \rangle &\rightarrow \text{int} \mid \langle \text{lexpr} \rangle \mid \langle \text{lexpr} \rangle = \langle \text{rexpr} \rangle \mid \dots \\ \langle \text{lexpr} \rangle &\rightarrow \text{name} \mid \dots \\ \text{StmtList} &\rightarrow \text{stmt Stmtlist} \mid \epsilon \end{aligned}$$

66 / 160

Weitere Grammatiken:

$E \rightarrow E+E$	$E * E$	(E)	name	int
$E \rightarrow E+T$	T			
$T \rightarrow T * F$	F			
$F \rightarrow (E)$	name	int		

Die beiden Grammatiken beschreiben die gleiche Sprache

67 / 160

Weitere Grammatiken:

$E \rightarrow E+E^0$	$E * E^1$	$(E)^2$	name ³	int ⁴
$E \rightarrow E+T^0$	T^1			
$T \rightarrow T * F^0$	F^1			
$F \rightarrow (E)^0$	name ¹	int ²		

Die beiden Grammatiken beschreiben die gleiche Sprache

67 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: \underline{E}

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \boxed{E} + \boxed{T}$

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \underline{E} + T$
 $\rightarrow \underline{T} + T$

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \underline{E} + \underline{T}$
 $\rightarrow \underline{T} + \underline{T}$
 $\rightarrow \underline{T} * \underline{F} + \underline{T}$

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \underline{E} + \underline{T}$
 $\rightarrow \underline{T} + \underline{T}$
 $\rightarrow \underline{T} * \underline{F} + \underline{T}$
 \square

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \underline{E} + \underline{T}$
 $\rightarrow \underline{T} + \underline{T}$
 $\rightarrow \underline{T} * \underline{F} + \underline{T}$
 $\rightarrow \underline{T} * \text{int} + \underline{T}$
 $\rightarrow \underline{F} * \text{int} + \underline{T}$
 $\rightarrow \text{name} * \text{int} + \underline{T}$
 $\rightarrow \text{name} * \text{int} + \underline{F}$
 \square

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel: $\underline{E} \rightarrow \underline{E} + \underline{T}$
 $\rightarrow \underline{T} + \underline{T}$
 $\rightarrow \underline{T} * \underline{F} + \underline{T}$
 $\rightarrow \underline{T} * \text{int} + \underline{T}$
 $\rightarrow \underline{F} * \text{int} + \underline{T}$
 $\rightarrow \text{name} * \text{int} + \underline{T}$
 $\rightarrow \text{name} * \text{int} + \underline{F}$
 $\rightarrow \text{name} * \text{int} + \text{int}$

Definition

Eine Ableitung \rightarrow ist eine Relation auf Wörtern über $N \cup T$, mit

$\alpha \rightarrow \alpha'$ gdw. $\alpha = \alpha_1 A \alpha_2 \wedge \alpha' = \alpha_1 \beta \alpha_2$ für ein $A \rightarrow \beta \in P$

68 / 160

Ableitung

Grammatiken sind **Wortersetzungssysteme**. Die Regeln geben die möglichen Ersetzungsschritte an. Eine Folge solcher Ersetzungsschritte $\alpha_0 \rightarrow \dots \rightarrow \alpha_m$ heißt **Ableitung**.

... im Beispiel:

$$\begin{aligned} E &\rightarrow E + T \\ &\rightarrow T + T \\ &\rightarrow T * F + T \\ &\rightarrow T * \text{int} + T \\ &\rightarrow F * \text{int} + T \\ &\rightarrow \text{name} * \text{int} + T \\ &\rightarrow \text{name} * \text{int} + F \\ &\rightarrow \text{name} * \text{int} + \text{int} \end{aligned}$$

Definition

Eine Ableitung \rightarrow ist eine Relation auf Wörtern über $N \cup T$, mit

$\alpha \rightarrow \alpha'$ gdw. $\alpha = \alpha_1 A \alpha_2 \wedge \alpha' = \alpha_1 \beta \alpha_2$ für ein $A \rightarrow \beta \in P$

Den reflexiven und transitiven Abschluss von \rightarrow schreiben wir: \rightarrow^*

68 / 160

Ableitung

Bemerkungen:

- Die Relation \rightarrow hängt von der Grammatik ab
- In jedem Schritt einer Ableitung können wir:
 - * eine Stelle auswählen, **wo** wir ersetzen wollen, sowie
 - * eine Regel, **wie** wir ersetzen wollen.
- Die von G spezifizierte Sprache ist:

$$\mathcal{L}(G) = \{w \in T^* \mid S \rightarrow^* w\}$$

69 / 160

Ableitung

Bemerkungen:

- Die Relation \rightarrow hängt von der Grammatik ab
- In jedem Schritt einer Ableitung können wir:
 - * eine Stelle auswählen, **wo** wir ersetzen wollen, sowie
 - * eine Regel, **wie** wir ersetzen wollen.
- Die von G spezifizierte Sprache ist:

$$\mathcal{L}(G) = \{w \in T^* \mid S \rightarrow^* w\}$$

Achtung:


Die Reihenfolge, in der disjunkte Teile abgeleitet werden, ist unerheblich

69 / 160

Ableitungsbaum

Ableitungen eines Symbols stellt man als **Ableitungsbaum** dar:

... im Beispiel:

$$\begin{aligned} E &\xrightarrow{0} E + T \\ &\xrightarrow{1} T + T \\ &\xrightarrow{0} T * F + T \\ &\xrightarrow{2} T * \text{int} + T \\ &\xrightarrow{1} F * \text{int} + T \\ &\xrightarrow{1} \text{name} * \text{int} + T \\ &\xrightarrow{1} \text{name} * \text{int} + F \\ &\xrightarrow{2} \text{name} * \text{int} + \text{int} \end{aligned}$$


Ein Ableitungsbaum für $A \in N$:

innere Knoten: Regel-Anwendungen

Wurzel: Regel-Anwendung für A

Blätter: Terminale oder ϵ

Die Nachfolger von (B, i) entsprechen der rechten Seite der Regel

70 / 160

Spezielle Ableitungen

Beachte:


Neben beliebigen Ableitungen betrachtet man solche, bei denen stets das **linkeste** (bzw. **rechteste**) Vorkommen eines Nichtterminals ersetzt wird.

- Diese heißen **Links-** (bzw. **Rechts-**) Ableitungen und werden durch Index L bzw. R gekennzeichnet.
- Links-(bzw. Rechts-) Ableitungen entsprechen einem links-rechts (bzw. rechts-links) **preorder**-DFS-Durchlauf durch den Ableitungsbaum
- **Reverse** Rechts-Ableitungen entsprechen einem links-rechts **postorder**-DFS-Durchlauf durch den Ableitungsbaum

71 / 160

Spezielle Ableitungen


... im Beispiel:



72 / 160

Spezielle Ableitungen

... im Beispiel:




Links-Ableitung: $(E,0) (E,1) (T,0) (T,1) (F,1) (F,2) (T,1) (F,2)$

72 / 160

Spezielle Ableitungen

... im Beispiel:




Links-Ableitung: $(E,0) (E,1) (T,0) (T,1) (F,1) (F,2) (T,1) (F,2)$

Rechts-Ableitung: $(E,0) (T,1) (F,2) (E,1) (T,0) (F,2) (T,1) (F,1)$

72 / 160

Spezielle Ableitungen

... im Beispiel:



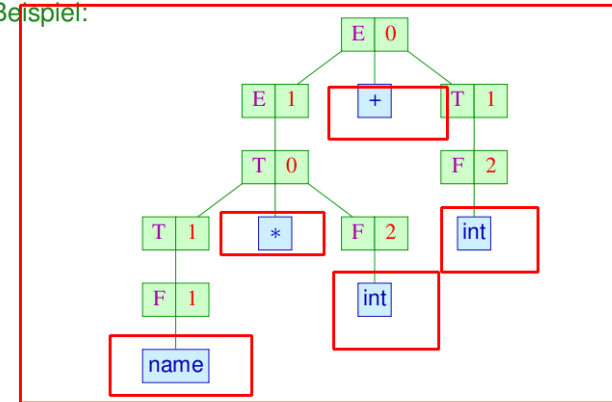
Links-Ableitung: $(E, 0) (E, 1) (T, 0) (T, 1) (F, 1) (F, 2) (T, 1) (F, 2)$
 Rechts-Ableitung: $(E, 0) (T, 1) (F, 2) (E, 1) (T, 0) (F, 2) (T, 1) (F, 1)$
 Reverse Rechts-Ableitung: $(F, 1) (T, 1) (F, 2) (T, 0) (E, 1) (F, 2) (T, 1) (E, 0)$

72 / 160

Eindeutige Grammatiken

Die Konkatination der Blätter des Ableitungsbaums t bezeichnen wir auch mit $yield(t)$.

... im Beispiel:



liefert die Konkatination:

name * int + int .

73 / 160

Eindeutige Grammatiken

Definition:

Die Grammatik G heißt **eindeutig**, falls es zu jedem $w \in T^*$ maximal einen Ableitungsbaum t von S gibt mit $yield(t) = w$.

... in unserem Beispiel:

$E \rightarrow E+E^0$	$E*E^1$	$(E)^2$	name ³	int ⁴
$E \rightarrow E+T^0$	T^1			
$T \rightarrow T*F^0$	F^1			
$F \rightarrow (E)^0$	name ¹	int ²		

Die zweite ist eindeutig, die erste nicht

74 / 160

Fazit:

- Ein Ableitungsbaum repräsentiert eine mögliche hierarchische Struktur eines Wortes.
- Bei Programmiersprachen sind wir nur an Grammatiken interessiert, bei denen die Struktur stets eindeutig ist
- Ableitungsbäume stehen in eins-zu-eins-Korrespondenz mit Links-Ableitungen wie auch (reversen) Rechts-Ableitungen.
- Links-Ableitungen entsprechen einem **Topdown**-Aufbau des Ableitungsbaums.
- Reverse Rechts-Ableitungen entsprechen einem **Bottom-up**-Aufbau des Ableitungsbaums.

75 / 160

Kapitel 2: Grundlagen: Kellerautomaten


Beispiel:

Zustände: 0, 1, 2
Anfangszustand: 0
Endzustände: 0, 2

0	a	11
1	a	11
11	b	2
x2	b	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

Beispiel:

Zustände: 0, 1, 2
Anfangszustand: 0
Endzustände: 0, 2

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

Konventionen:

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

... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2

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

(0, ~~aaabbb~~) ⊢ (11, aabbb)

... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2

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

(0, aaabbb) ⊢ (11, aabbb)
 ⊢ (111, abbb)

... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2

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

(0, aaabbb) ⊢ (11, aabbb)
 ⊢ (111, abbb)
 ⊢ (1111, bbb)

... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2


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

(0, aaabbb) ⊢ (11, aabbb)
 ⊢ (111, abbb)
 ⊢ (1111, bbb)
 ⊢ (112, bb)

... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2


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



... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2

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



... im Beispiel:

Zustände: 0, 1, 2
 Anfangszustand: 0
 Endzustände: 0, 2

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

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

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

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

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

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

Deterministischer Kellerautomat

Definition:

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

Kellerautomaten



Satz:

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

Der Satz ist für uns so wichtig, dass wir **zwei** Konstruktionen für Automaten angeben, motiviert durch die beiden speziellen Ableitungsmöglichkeiten:

- M_G^L zur Bildung von **Linksableitungen**
- M_G^R zur Bildung von **reversen Rechtsableitungen**

Syntaktische Analyse

Kapitel 3: Top-down Parsing