

Die Anwendung von Regeln $t_1 \rightarrow t'_1, t_2 \rightarrow t'_2$ in einem Wort $\alpha, \beta, \gamma \in (T \cup N)^*$

$$\begin{aligned} \alpha \circ t_1 \circ \beta \circ t_2 \circ \gamma &\rightarrow \\ [\alpha \circ t'_1 \circ \beta \circ t'_2 \circ \gamma \rightarrow] & \quad \alpha \circ t'_1 \circ \beta \circ t'_2 \circ \gamma \rightarrow \\ \alpha \circ t'_1 \circ \beta \circ t'_2 \circ \gamma & \end{aligned}$$

heißt vertauschbar.

Bemerkung: Formal ist jede Ableitung ein Wort aus $(T \cup N \cup \{\rightarrow\})^*$. Vertauschbarkeit definiert eine Relation auf der Menge der Ableitungen. Wir können zu dieser Relation die transitive, symmetrische, reflexive Hülle bilden.

ist logisch korrekte Äquivalenzrelation

Stehen zwei Ableitungen in dieser Relation, dann heißen sie strukturell äquivalent.

- (i) Ch-2-Grammatiken (kontextfreie Grammatiken) können wir aufgrund der einfachen Struktur ihrer Regeln jeder Ableitung auf das Axiom einen Strukturbau zuordnen.

Beispiel: Nichtterminalzeichen $N = \{z\}$

Terminalzeichen


$T = \{"(,)", +, *, a\}$, Axiom z

Regeln: $z \vdash z \rightarrow z$

$z \vdash z \rightarrow z$

$a \rightarrow z$

$(z) \rightarrow z$



Ableitungsbau, Strukturbau

Strukturbäume erben genau die Struktur der Ableitungen (Ch-2 und Ch-3)

Wichtig: Zwei Ableitungen sind genau dann strukturell äquivalent, wenn sie den gleichen Strukturbau darstellen.
d.h. Strukturbäume sind Normalform in der Klasse der strukturell äquivalenten Ableitungen.

Ein Strukturbau für eine Ch-2-Grammatik ist ein endlich verzweigender Baum (geordneter Baum):

(1) Die Wurzel ist das Axiom.


(2) Jeder Teilbaum hat folgende Eigenschaften:

(a) Er ist genau ein Terminalzeichen und hat keine Teilbäume

(b) Er hat als Wurzel ein Nichtterminalzeichen; dann gilt:
die Wurzel seiner Teilbäume können zu dem Wort w konkateniert werden und es gilt $w \rightarrow x$ ist eine Regel der Grammatik

Anmerkung zum Bsp:

Grammatik hat zwei Strukturbäume!



für jedes Wort gibt es ein Strukturbau → eindeutig bestimmt

Eine Grammatik heißt eindeutig, wenn für jedes Wort $w \in T^*$ mit $w \xrightarrow{*} z$ alle Ableitungen auf z strukturell äquivalent sind.
 Dann existiert genau ein Strukturbaum für jedes Wort im Sprachschatz.
Feststellung: Die Grammatik aus obigem Beispiel ist nicht eindeutig.

1.2.4. Sackgassen, unendliche Ableitungen

Ch-2-Gi werden praktisch eingesetzt, um

- (1) eine formale Sprache zu definieren
- (2) jedem Wort im Sprachschatz einen Strukturbaum (am besten eindeutig) zuzuordnen.

Ein Wort w heißt „im Sprachschatz“, bzw. reduzierbar oder auch von der Grammatik akzeptiert, wenn gilt $w \xrightarrow{*} z$.

Aufgaben für eine gegebene Grammatik:

- (1) Stelle fest, ob ein gegebenes Wort im Sprachschatz ist.
- (2) Ermittle (falls es im Sprachschatz ist) den Strukturbaum.

Naive Idee: Wende ^{auf} das gegebene Wort Regeln an. Wir erhalten eine Ableitung $w \xrightarrow{} w_1 \xrightarrow{} w_2 \xrightarrow{} w_3 \xrightarrow{} \dots$ Fragstellung:
Ist w im Sprachschatz?

Wir erhalten zwei Möglichkeiten:

- (1) Die Ableitung führt zu einem Wort, auf das keine Regel mehr anwendbar ist.

(2) Die Ableitung bricht nicht ab und kann unendlich fortgesetzt werden.

Falls (1) gilt und das Wort, auf das keine Regel mehr anwendbar ist, das Axiom ist, so ist w im Sprachschatz.

Falls (1) gilt und das Wort, auf das keine Regel mehr anwendbar ist, nicht das Axiom ist, dann können wir daraus nicht schließen, dass w nicht im Sprachschatz ist. Wir sprechen von einer Sackgasse.

$$w \xrightarrow{} \dots \xrightarrow{} w_k \xrightarrow{} \dots \xrightarrow{} z \quad (w \text{ ist im Sprachschatz})$$

\swarrow \nwarrow w_{k+1} w_{k+2} \dots w_i \dots w_n

w_{k+1} nicht auf Wurzel reduzierbar; Sackgasse.

Eine unendliche Ableitung (Fall (2)) sagt auch nicht darüber aus, ob das Wort im Sprachschatz ist.


Zwei Arten von unendlichen Ableitungen

$$w \xrightarrow{} \dots \xrightarrow{} w_k \xrightarrow{} \dots \xrightarrow{} z \xleftarrow{} \dots \xleftarrow{} w_i \xleftarrow{} \dots \xleftarrow{} w_n$$

\swarrow \nwarrow w_{k+1} w_{k+2} \dots w_i \dots w_n

Endlicher, aber unendlicher

Algorithmus zur Feststellung, ob ein Wort im Sprachschatz ist:



für Endl., Ch-2, Ch-3
 für Ch-0 gibt es keinen Algorithmus, der
 aussagt wann, dass ein Wort nicht im
 Sprachschatz ist.

(ein Wort liegt im
 Sprachschatz, falls es unter jeder abrechnen
 da Menge unendlich)


Beispiel: Einfache arithmetische Ausdrücke als Ch-2-Gi. $T = \{a, \dots, z, +, *, (,)\}$

Regeln: $a \rightarrow R$
 $b \rightarrow R$
 $R+R \rightarrow R$
 $E+R \rightarrow E$
 $R \rightarrow E$
 $(E) \rightarrow R$

BNF: $\langle R \rangle ::= a \dots z$
 $\langle R \rangle ::= \langle R \rangle + \langle R \rangle$
 $\langle E \rangle ::= \langle E \rangle + \langle R \rangle \mid \langle R \rangle$

$N = \{R, E\}$ Wurzel E

Strukturbaum:



1. Frage:

Mat die Grammatik Sackgassen?

[a]


Sackgasse

2. Frage:

Ist die Grammatik eindeutig?

nein

nicht eindeutig!



+ Allgemeine Form eines Ausdrucks: $a_1 * a_2 * a_3 * a_4 \dots a_n + b_1 * b_2 \dots +$

Lösung: Vorgegebene
Klammerung bei +
(entspr. bei *)



Neue Grammatik, T wie vorher

$$a \rightarrow F$$

$$z \rightarrow F$$

$$F+R \rightarrow R$$

$$R+A \rightarrow A$$

$$F \rightarrow R$$

$$R \rightarrow A$$

$$A \rightarrow E$$

$$(E) \rightarrow F$$

Die Grammatik ist eindeutig,
aber nicht sackgassenfrei.

Ziel erreicht:

Strukturschichten eindeutig zugeordnet.

\Rightarrow dadurch werden die + / * - Regeln
festgelegt, auch "*" vor "+".

$$N = \{F, R, A, E\}$$

Faktor Term Additiver Ausdruck (Expression)
Ausdruck

Sackgassen sind nicht schlimm
solange sie vermieden sind
(Wortauszeichnung: Sackgasse im
Straßennetznamen)

$$w_0 \rightarrow w_1 \rightarrow w_2 \rightarrow \dots \rightarrow \dots \rightarrow w_n$$

$$\begin{array}{l} w_0 \rightarrow w_1 \\ w_0 \rightarrow w_1' \rightarrow \dots \\ w_0 \rightarrow w_1' \rightarrow \dots \end{array} \quad \boxed{w_1' \rightarrow w_{1'}' \rightarrow w_{1''}} \rightarrow \dots \rightarrow w_n$$

Jeweils Regeln voneinander,
kommen aber zum gleichen Ziel.
Weist ja eine "hier" Zeichenkette
dann sind die einzelnen
Zeilen strukturrell äquivalent.

In den Ableitungen für ein Wort über einer Grammatik können wir
eine sogenannte Linkableitung (analog Rechtableitung) auszeichnen.
Wir erhalten eine Linkableitung.
Dies ist eine Ableitung, in der jeweils so weit links wie möglich eine Regel
angewendet wird. (Linkskreduktion)

Achtung: (1) l.d.R. sind Linkableitungen nicht eindeutig.

(2) In der Menge der strukturrell äquivalenten Ableitungen sind
Linkableitungen eindeutig.

Eine Linkableitung führt für ein Wort im Sprachraum nicht unbedingt
zum Axiom.

Begriff: Akzeptierende Linkableitung: Regeln werden so weit links wie
möglich angewendet, Regeln die nicht zum Axiom führen
(zu einer Sackgasse führen) werden übersprungen.

1.3. Chomsky-3-Sprachen, endl. Automaten, reguläre Ausdrücke

25.4.03 (Fr)

Wir betrachten 3 Beschreibungsmittel für formale Sprachen:

- reguläre Ausdrücke
- endliche Automaten
- Ch-3-G

Wir werden zeigen: Alle 3 Beschreibungsmittel haben die gleiche Beschreibungsmächtigkeit. Sie beschreiben die gleiche Klasse formaler Sprachen, genannt reguläre Sprachen.

1.3.1. Reguläre Ausdrücke (RA)

Gegeben Zeichenmenge T . Die Syntax und Semantik der regulären Ausdrücke (RA) ist wie folgt gegeben:

(1) Einfache reg. Ausdrücke

$$\begin{array}{c} x \text{ mit } x \in T \text{ ist RA mit Sprache } \{x\} \\ \epsilon \text{ ist RA mit Sprache } \{\epsilon\} \\ [] \text{ ist RA mit Sprache } \emptyset \end{array}$$

(2) Zwammengesetzte RA (Seien X und Y RA)

$$\begin{array}{ll} [XY] \text{ ist RA mit Sprache } L_X \cup L_Y & (\text{Vereinigung d. Sprachen}) \\ [XY] \text{ ist RA mit Sprache } \{x \cdot y : x \in L_X \wedge y \in L_Y\} & \\ X^* \text{ ist RA mit Sprache } \{x_1 \dots x_n : n \in \mathbb{N} \wedge x_1, \dots, x_n \in L_X\} & \end{array}$$

wobei L_X die formale Sprache zu RA X sei und L_Y die formale Sprache zu RA Y .

Bsp. $a[a b]^* = \{aa, caab, \dots\}$ formale Sprache

$aa[b a]^* = \{caaa, caaab, \dots\}$ formale Sprache

Die beiden formalen Sprachen sind unterschiedlich.

$$X^+ = XX^*$$

Gesetze der RA: $\begin{array}{l} [[X|Y]|Z] = [X|[YZ]] \\ [[XY]|Z] = [X|[YZ]] \end{array}$

$$\begin{array}{l} [X|Y] = [Y|X] \\ [[X|Y]|Z] = [[Z|X]|YZ] \end{array}$$

"Kommutativität"
"Distributivität"

$$[Z|[X|Y]] = [[Z|X]|ZY]$$

$$()^* = \epsilon$$

ϵ Einzlement

$$X\epsilon = X$$

$\{\}$ Nullelement

$$X[] = \{\}$$

$$X^* = XX^* | \epsilon$$

$$X^* = [X|\epsilon]^*$$

1.3.2. Endliche Automaten (EA)

Endlicher Automat $A = (S, T, \delta, s_0, S_f, \delta)$

S endliche Menge von Zuständen
 T endliche Menge von Eingangszeichen

(beliebige Menge \rightarrow auch unendl. Automaten)

$s_0 \in S$ Anfangszustand

$S_f \subseteq S$ Menge der Endzustände

$\delta: S \times \{T\} \rightarrow P(S)$ \rightarrow Potenzmenge zu S : Menge der Teilmengen von S

Kategorie ohne Eingangszeichen

δ Übergangsfunktion

$\delta(s, t)$ ist die Menge der Nachfolgezustände zu $s \in S, t \in T \cup \{\epsilon\}$

Deterministischer Automat: $\delta(s, \epsilon) \subseteq \{s\}$

d.h. ϵ -Übergänge gibt es nicht


$$|\delta(s, t)| \leq 1 \quad \text{für alle } s \in S, t \in T$$

d.h. es gibt höchstens eine Nachfolgezustand.

Partieller Automat: $\exists t \in T, s \in S \quad \delta(s, t) = \emptyset$

ϵ -freier Automat: $\delta(s, \epsilon) \subseteq \{s\}$ für alle $s \in S$

d.h. keine spontanen Übergänge



Übergangstabelle für Zustandsautomaten

δ	E	a	b
S_0	\emptyset	{ S_1 }	\emptyset
S_1	\emptyset	{ S_1 }	\emptyset
S_2	\emptyset	\emptyset	{ S_1 }

! Notation: wir schreiben $s_1 \xrightarrow{a} s_2$ falls $s_2 \in \delta(s_1, a)$

Jedem Wort $w \in T^*$ ordnen wir eine Relation \xrightarrow{w} auf den Zuständen zu:

$$\xrightarrow{\epsilon}^* = (\xrightarrow{E})^*$$

$$\xrightarrow{ca}^* = \xrightarrow{\epsilon}^* \circ \xrightarrow{c} \circ \xrightarrow{\epsilon}^*$$

$$\xrightarrow{w_1 w_2}^* = \xrightarrow{w_1}^* \circ \xrightarrow{w_2}^* \quad w_1, w_2 \in T^*$$

wir schreiben $\delta^*(s, w)$ für $\{s': s \xrightarrow{w} s'\}$

Damit können wir die Sprache charakterisieren, die durch einen endl. Automaten A beschrieben wird:

$$L(A) = \{w \in T^*: \exists z \in S: s_0 \xrightarrow{w} z\}$$

d.h. es ex. ein ϵ -Weg nach s'
alle Markierungen der Pfeile sind ϵ

$\xrightarrow{ca}^* = \xrightarrow{\epsilon}^* \circ \xrightarrow{c} \circ \xrightarrow{\epsilon}^*$


$\xrightarrow{w_1 w_2}^* = \xrightarrow{w_1}^* \circ \xrightarrow{w_2}^*$

1.3.3. Äquivalenz der Darstellungsformen

Zunächst beantworten wir die Frage, ob Automaten mit spontanen Übergängen beschreibungsmächtiger sind als Automaten ohne spontane Übergänge.

Satz: Zu jedem endl. Automaten existiert ein ϵ -freier endl. Automat, der die gleiche Sprache akzeptiert

Beweisidee: Wir konstruieren zu einem gegebenen EA einen ϵ -freien EA mit gleicher Sprache:



Es entsteht ein Automat ohne $\xrightarrow{\epsilon}^*$ -Zyklen (ϵ -Schlingen können weggelassen werden).

(2) $\xrightarrow{\epsilon}^*$ -Wege (Zyklusfrei): Durchschalten von ϵ -Übergängen

Bsp.

durchschalten

Aus $\xrightarrow{a} \xrightarrow{\epsilon} \xrightarrow{a}$ wird für alle Kanten in den Knoten A .

Satz: Zu jedem ϵ -freien nichtdet. Automaten existiert ein (epsilon-freies) det. Automat mit gleichem Sprachumfang

Beweisidee: Wir konstruieren zu dem Automaten mit Zustandsmenge S einen Automaten mit Zustandsmenge $P(S)$. \square



1.3.4. Äquivalenz RA, EA, Ch-3-6

Satz: Zu jedem endl. Automaten existiert ein regulärer Ausdruck, der die gleiche Sprache beschreibt.

Beweis: konstruktiv! Wir geben zu einem gegebenen EA einen RA mit gleicher Sprache.

Zustandsmenge: $S = \{s_1, \dots, s_n\}$

o.B.d.A. sei EA ϵ -frei.

Wir konstruieren eine Familie formaler Sprachen

$$L(i, j, k) \subseteq T^*$$

wobei $i, j \in \{1, \dots, n\}$, $k \in \{0, \dots, n\}$

und die dazugehörige RA $E(i, j, k)$ die jeweils die formale Sprache $L(i, j, k)$ beschreiben. Dabei sei

$$L(i, j, k) = \{w \in T^*: s_i \xrightarrow{\underbrace{w}_{k}} s_j\}.$$

Dabei betrachten wir in $\xrightarrow{\underbrace{w}_k}$ nur Pfade im Übergangsgraphen mit Zwischenzuständen s_l mit $l \leq k$.

$$L(i, j, 0) = \{s_j : s_j \in \delta(s_i, a)\}$$

$$E(i, j, 0) = \underbrace{s_i | \dots | s_j}_{\text{Menge aller } a \in T \text{ mit } s_i \xrightarrow{a} s_j}$$

$$L(i, j, k+1) = L(i, j, k) \cup \{uvw: u \in L(i, k+1, k) \wedge v \in L(k+1, k+1, k) \wedge w \in L(k+1, j, k)\}$$

$$E(i, j, k) = E(i, j, k) \mid E(i, k+1, k) E(k+1, k+1, k)^* E(k+1, j, k)$$

Die Sprache des EA sind die Wege von s_1 (Anfangszustand) zu Endzuständen

$$S_2 = \{s_{2_1}, \dots, s_{2_p}\}.$$

Dies entspricht den RA

$$E(1, 2_1, n) \mid \dots \mid E(1, 2_p, n) \quad a$$

Star-Operator auf Sprache angewendet