

Was bisher geschah

Sprache L ist vom Chomsky-Typ i gdw.

eine Grammatik $G = (N, T, P, S)$ mit $L(G) = L \setminus \{\varepsilon\}$ existiert.

Chomsky-Hierarchie: G ist vom Chomsky-Typ

0 immer,

1 , $\forall (l \rightarrow r) \in P : |l| \leq |r|$ (monoton, kontextsensitiv)

2 , $\forall (l \rightarrow r) \in P : |l| \leq |r| \wedge l \in N$ (kontextfrei)

3 , $\forall (l \rightarrow r) \in P : |l| \leq |r| \wedge l \in N \wedge r \in (T \cup (T \circ N))$ (regulär)

reguläre Sprachen ($\mathcal{L}_3 = \text{REG} = \text{REC}(\text{NFA}) = \text{REC}(\text{DFA})$):

- ▶ endliche Repräsentation durch
 - ▶ Darstellung als reguläre Ausdrücke
 - ▶ Erzeugung durch reguläre Grammatiken,
 - ▶ Akzeptanz durch NFA (DFA, ε -NFA, ...),
- ▶ abgeschlossen unter $\cup, \cap, \overline{}, \circ, *, R$

Fragen für kontextfreie Sprachen

Wiederholung:

Eine Sprache $L \subseteq X^*$ heißt genau dann **kontextfrei**, wenn für eine kontextfreie Grammatik (Chomsky-Typ 2) G gilt $L \setminus \{\varepsilon\} = L(G)$.

CF ($= \mathcal{L}_2$): Menge aller kontextfreien Sprachen

- ▶ Unter welchen der Operationen $\cup, \cap, \bar{}, \circ, *, ^R$ ist CF abgeschlossen?
- ▶ Gibt es ein passendes (deterministisches, eindeutiges) Maschinenmodell für kontextfreie Sprachen?
- ▶ Existieren algorithmische Lösungsverfahren für folgende Probleme für kontextfreie Sprachen:
 - ▶ Wortproblem
 - ▶ Leerheit, Vollständigkeit, Endlichkeit
 - ▶ Inklusion, Gleichheit, Disjunktheit

Kontextfreie Grammatiken – Wiederholung

Grammatik $G = (N, T, P, S)$ vom Chomsky-Typ 2

Alle Regeln in P haben die Form $l \rightarrow r$ mit

$l \in N$ und $r \in (N \cup T)^+$

w in G ableitbar gdw. $S \rightarrow_P^* w$

Grammatik $G = (N, T, P, S)$ erzeugt die Sprache

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

Beispiel: Grammatik $G = (\{S\}, \{a, b\}, \{S \rightarrow aSb \mid ab\}, S)$

- ▶ ist vom Chomsky-Typ 2
- ▶ Ableitung für $aaabbb$ in G : $S \rightarrow aSb \rightarrow aaSbb \rightarrow aaabbb$
- ▶ G erzeugt die Sprache $L(G) = \{a^n b^n \mid n > 0\}$
(vom Chomsky-Typ 2)

Für $L = \{a^n b^n \mid n > 0\}$ gilt $L \in \text{CF} \setminus \text{REG}$, d.h.

- ▶ L ist kontextfrei.
- ▶ L ist nicht regulär. (Wie kann man das zeigen?)

WH: Schubfachschluss-Prinzip

Schubfachschluss-Prinzip (Pigeonhole principle):

Für $|O| > |S|$ existiert keine injektive Funktion $f : O \rightarrow S$.

$$\forall O \forall S \forall f : ((|O| > |S| \wedge f : O \rightarrow S) \rightarrow \exists x \exists y : (x \neq y \wedge f(x) = f(y)))$$

Anschaulich:

Verteilt man mehr als n Objekte in n Schubfächer, dann gibt es (wenigstens) ein Schubfach, welches (wenigstens) zwei Objekte enthält.

Beispiele:

- ▶ Von 13 Personen haben mindestens zwei im selben Monat Geburtstag.
- ▶ Wieviele Karten aus einem Skatblatt muss man ziehen, damit zwei derselben Farbe dabei sind?
- ▶ vier verschiedenfarbige Paare Socken im Dunklen:
Wieviele Socken muss man (blind) nehmen, damit ein vollständiges Paar dabei ist?
- ▶ Bei jeder Wanderung mit $> n$ Pausen in einem Gebiet mit n Rastplätzen waren wenigsten zwei Pausen am selben Platz.

Nichtreguläre Sprachen

Fakt

Die Sprache $L = \{a^n b^n \mid n > 0\}$ ist nicht NFA-akzeptierbar.

WH Definition REC(NFA): $L \in \text{REC(NFA)}$ gdw. \exists NFA $A : (L(A) = L)$

Vorbereitung für Beweis (indirekt):

$$\begin{aligned} \forall L \subseteq X^* : L \notin \text{REC(NFA)} & \text{ gdw. } \neg \exists A : (L(A) = L) & \text{ gdw. } \forall A : \neg (L(A) = L) \\ & \text{ gdw. } \forall A : (\underbrace{(L(A) = L)}_{\text{Annahme } P(A)} \rightarrow \underbrace{\neg (L(A) = L)}_{\text{Folgerung } \neg P(A)}) \end{aligned}$$

Beweis: Annahme: für NFA $A = (X, Q, \delta, I, F)$ mit $|Q| = k$ gilt $L(A) = L$

Wegen $a^k b^k \in L$ existiert ein akzeptierender Pfad für $a^k b^k$ in A :

$$q_0 \xrightarrow{a} q_1 \xrightarrow{a} \dots \xrightarrow{a} q_k \xrightarrow{b} q_{k+1} \xrightarrow{b} \dots \xrightarrow{b} q_{2k} \quad \text{mit } q_0 \in I, q_{2k} \in F$$

SFS: O: Positionen im a^k -Teil $|\{0, \dots, k\}| > k$, S: Zustände $|Q| = k$

Nach SFS existieren $i, j \in \{0, \dots, k\}$ mit $i < j$ und $q_i = q_j$.

$$q_0 \xrightarrow{a} q_1 \xrightarrow{a} \dots \xrightarrow{a} q_i = q_j \xrightarrow{a} q_{j+1} \xrightarrow{a} \dots \xrightarrow{a} q_k \xrightarrow{b} q_{k+1} \xrightarrow{b} \dots \xrightarrow{b} q_{2k}$$

ist also akzeptierender Pfad für $a^{k-(j-i)} b^k$ in A , d.h. $a^{k-(j-i)} b^k \in L(A)$

Aus $a^{k-(j-i)} b^k \notin L$ folgt $\neg (L(A) = L)$ im Widerspruch zur Annahme.

Also ist die Annahme falsch, d.h. es existiert kein NFA A mit $L = L(A)$.

Weitere nichtreguläre Sprachen

hilfreiches Prinzip:

Da REC(NFA) unter \cap abgeschlossen ist, d.h. $\forall L, L', L'' \subseteq X^*$

$$(L \cap L' = L'' \wedge L \in \text{REC(NFA)} \wedge L' \in \text{REC(NFA)}) \rightarrow L'' \in \text{REC(NFA)}$$

gilt für alle Sprachen L, L', L'' : (ÜA)

$$(L \cap L' = L'' \wedge L' \in \text{REC(NFA)} \wedge L'' \notin \text{REC(NFA)}) \rightarrow L \notin \text{REC(NFA)}$$

- ▶ $L = \{w \in \{a, b\}^* \mid |w|_a = |w|_b > 0\} \notin \text{REC(NFA)}$
(wegen $L \cap \underbrace{L(a^*b^*)}_{\in \text{REC(NFA)}} = \{a^n b^n \mid n > 0\} \notin \text{REC(NFA)}$)
- ▶ $L = \{w \in \{a, b\}^* \mid 2|w|_a = |w|_b \in \mathbb{N}\} \notin \text{REC(NFA)}$
(wegen $L \cap L(a^*b^*) = \{a^n b^{2n} \mid n > 0\} \notin \text{REC(NFA)}$
nach Schubfachschluss).
- ▶ $L = \{w \in \{a, b\}^* \mid w = w^R\} \notin \text{REC(NFA)}$ (Palindrome)
(wegen $L \cap L(a^*ba^*) = \{a^n ba^n \mid n \in \mathbb{N}\} \notin \text{REC(NFA)}$)
- ▶ $L = \{a^{(n^2)} \mid n \in \mathbb{N}\} \notin \text{REC(NFA)}$
(nach Schubfachschluss, Wortlängen)

Ableitungsbäume für kontextfreie Grammatiken

Beispiel: Grammatik $G = (N, T, P, E)$ mit $N = \{E, F\}$,
 $T = \{a, b, c, (,), +, *\}$,

$$P = \{E \rightarrow (E + E), E \rightarrow F * F, F \rightarrow E, E \rightarrow a, E \rightarrow b, E \rightarrow c\}$$

Ableitung für $w = (c * a + (b + a * a))$

allgemein: Grammatik $G = (N, T, P, S)$

Ableitung $S \rightarrow_P w_1 \rightarrow_P w_2 \rightarrow_P \dots \rightarrow_P w_n = w$ für w in G

Ableitungsbaum zu einem Wort w in der kontextfreien Grammatik G (induktive Definition):

- ▶ Wurzel mit Markierung S
- ▶ für jeder Anwendung einer Regel $A \rightarrow_P r_1 \dots r_n$:
Verzweigung bei Symbol A in n Kinder mit Markierungen $r_1 \dots, r_n$
- ▶ Markierung der Blätter (von links nach rechts): Wort w

Ein Ableitungsbaum repräsentiert i.A. mehrere Ableitungen.

Rechts- und Linksableitungen

Eine Ableitung für w in G heißt

Linksableitung, falls in jedem Schritt das am weitesten links stehende Nichtterminal

Rechtsableitung, falls in jedem Schritt das am weitesten rechts stehende Nichtterminal

ersetzt wird.

Zu jedem Ableitungsbaum für w in G existieren

- ▶ genau eine Linksableitung für w in G und
- ▶ genau eine Rechtsableitung für w in G .

Abschlusseigenschaften von CF

Satz

Sind L_1 und L_2 kontextfreie Sprachen, dann sind auch kontextfrei:

- ▶ $L_1 \cup L_2$
- ▶ $L_1 \circ L_2$
- ▶ L_1^*
- ▶ L_1^R

Konstruktionen für $L_i = L(G_i)$ mit $G_i = (N_i, T_i, P_i, S_i)$ für $i \in \{1, 2\}$,
wobei $N_1 \cap N_2 = \emptyset$ (falls nötig, umbenennen)

neues Nichtterminal $S' \notin N_1 \cup N_2$

$$L_1 \cup L_2 = L(G_U) \text{ mit } G_U = (N_1 \cup N_2 \cup \{S'\}, T_1 \cup T_2, P_U, S'),$$

wobei $P_U = P_1 \cup P_2 \cup \{S' \rightarrow S_1, S' \rightarrow S_2\}$

$$L_1 \circ L_2 = L(G_o) \text{ mit } G_o = (N_1 \cup N_2 \cup \{S'\}, T_1 \cup T_2, P_o, S'),$$

wobei $P_o = P_1 \cup P_2 \cup \{S' \rightarrow S_1 S_2\}$

$$L_1^* = L(G_*) \text{ mit } G_* = (N_1 \cup \{S'\}, T_1, P_*, S'), \text{ wobei}$$

$P_* = P_1 \cup \{S' \rightarrow \varepsilon, S' \rightarrow S_1 S'\}$

$$L_1^R \text{ (war ÜA 3.4)}$$

noch offen: CF abgeschlossen unter $\bar{\quad}, \cap$?

Mehrdeutige kontextfreie Grammatiken

Kontextfreie Grammatik G heißt

eindeutig , falls für jedes Wort $w \in L(G)$
genau ein Ableitungsbaum in G existiert.

mehrdeutig , sonst.

Beispiel: Ableitungsbäume für $w = aaa$ in der Grammatik
 $G = (N, T, P, E)$ mit $N = \{S\}$, $T = \{a\}$, $P = \{S \rightarrow SS, S \rightarrow a\}$

Eindeutigkeit von Grammatiken ist wichtig beim Entwurf von
Programmiersprachen (Syntax)

„dangling else“-Problem:

```
<Anw> ::= if <Ausdr> then <Anw>
```

```
<Anw> ::= if <Ausdr> then <Anw> else <Anw>
```

Was bedeutet:

```
if C1 then if C2 then A else B
```

(Anwendungen im Modul Prinzipien von Programmiersprachen)

Inhärent mehrdeutige Sprachen

Sprachen L , für die keine eindeutige Grammatik G mit $L = L(G)$ existieren, heißen **inhärent mehrdeutig**.

Fakt

Die kontextfreie Sprache

$$L = \{a^l b^m c^n \mid l, m, n > 0 \wedge (l = m \vee m = n)\}$$

ist inhärent mehrdeutig.