Theoretische Informatik I

Einheit 2.5

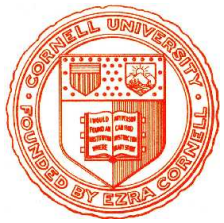

Eigenschaften regulärer Sprachen

1. Abschlusseigenschaften
2. Prüfen von Eigenschaften
3. Wann sind Sprachen nicht regulär?

Wichtige Eigenschaften formaler Sprachen

- **Abschlusseigenschaften**
  - Wie können Sprachen elegant zusammengesetzt werden?
  - Erlaubt schematische Komposition von Sprachbausteinen
- **Entscheidbarkeitsfragen**
  - Kann man bestimmte Eigenschaften automatisch testen?
  - Wortproblem (Zugehörigkeit eines Wortes zur Sprache)
  - Vergleiche zwischen Sprachen (nichtleer, Teilmenge, gleich, ...)
- **Grenzen einer Sprachklasse**
  - Wie einfach strukturiert müssen die Sprachen der Klasse sein?
  - Welche Sprachen gehören nicht zur Klasse?

Aus theoretischer Sicht sind das die wirklich interessanten Fragen

Abschlusseigenschaften, wozu?

Zeige, dass bestimmte Operationen auf regulären Sprachen wieder zu regulären Sprachen führen

- **Wiederverwendung von "Sprachmodulen"**
  - Schematische Komposition von
    - Grammatiken zur Erzeugung von Sprachen
    - Automaten zur Erkennung von Sprachen
    - Regulären Ausdrücken
- **Schematische Konstruktion ist effektiver**
  - Fehlerfreier Aufbau sehr komplexer Grammatiken / Automaten
  - \+ Schematische Optimierung / Minimierung
  - Konstruktion "von Hand" oft fehleranfällig
- **Beispiel: Literale einer Programmiersprache**
  - Bilde Automaten für Tokenklassen: Zahlen, Bezeichner, Schlüsselwörter, ...
  - Konstruktion liefert Automaten für alle Arten von Literalen

Abschlusseigenschaften, präzisiert

Zeige: L_1, L_2 regulär $\Rightarrow$ L_1 *op* L_2 regulär

- **Es gilt Abgeschlossenheit unter neun Operationen**
  - Die Vereinigung zweier regulärer Sprachen ist regulär $L_1 \cup L_2$
  - Das Komplement einer regulären Sprache ist regulär $\overline{L}$
  - Der Durchschnitt zweier regulärer Sprachen ist regulär $L_1 \cap L_2$
  - Die Differenz zweier regulärer Sprachen ist regulär $L_1 - L_2$
  - Die Spiegelung einer regulären Sprache ist regulär L^R
  - Die Hülle einer regulären Sprache ist regulär L^*
  - Die Verkettung zweier regulärer Sprachen ist regulär $L_1 \circ L_2$
  - Das Bild einer regulären Sprache unter Homomorphismen ist regulär $h(L)$
  - Das Urbild ... " " ... unter Homomorphismen ist regulär $h^{-1}(L)$
- **Nachweis durch Verwendung aller Modelle**
  - DEA, (ϵ-)NEA, reguläre Ausdrücke, Typ-3 Grammatiken
  - Modelle sind ineinander umwandelbar – **wähle das passendste**

Abschluss unter Vereinigung, Verkettung, Hülle

Beweisführung mit regulären Ausdrücken

- **L_1, L_2 regulär $\Rightarrow$ $L_1 \cup L_2$ regulär**

  L_1, L_2 regulär

  $\Rightarrow$ Es gibt reguläre Ausdrücke E_1, E_2 mit $L_1 = L(E_1)$, $L_2 = L(E_2)$

  $\Rightarrow$ $L_1 \cup L_2 = L(E_1) \cup L(E_2) = L(E_1{+}E_2)$ **regulär**

- **L_1, L_2 regulär $\Rightarrow$ $L_1 \circ L_2$ regulär**

  L_1, L_2 regulär

  $\Rightarrow$ Es gibt reguläre Ausdrücke E_1, E_2 mit $L_1 = L(E_1)$, $L_2 = L(E_2)$

  $\Rightarrow$ $L_1 \circ L_2 = L(E_1) \circ L(E_2) = L(E_1 \circ E_2)$ **regulär**

- **L regulär $\Rightarrow$ L^* regulär**

  L regulär

  $\Rightarrow$ Es gibt einen regulären Ausdruck E mit $L = L(E)$

  $\Rightarrow$ $L^* = (L(E))^* = L(E^*)$ **regulär**

Beweisführung mit endlichen Automaten

- **L regulär $\Rightarrow$ $\overline{L}$ regulär**

  Komplementiere akzeptierende Zustände des erkennenden Automaten

  L regulär

  $\Rightarrow$ Es gibt einen DEA $A = (Q, \Sigma, \delta, q_0, F)$ mit $L = L(A)$

  $\Rightarrow$ $\overline{L} = \overline{L(A)} = \{w \in \Sigma^* \mid \hat{\delta}(q_0, w) \notin F\} = \{w \in \Sigma^* \mid \hat{\delta}(q_0, w) \in Q - F\}$

  $= L((Q, \Sigma, \delta, q_0, Q-F))$ **regulär**

- **Beispiel: Komplementierung von `(0+1)*01`**

  – Zugehöriger DEA

  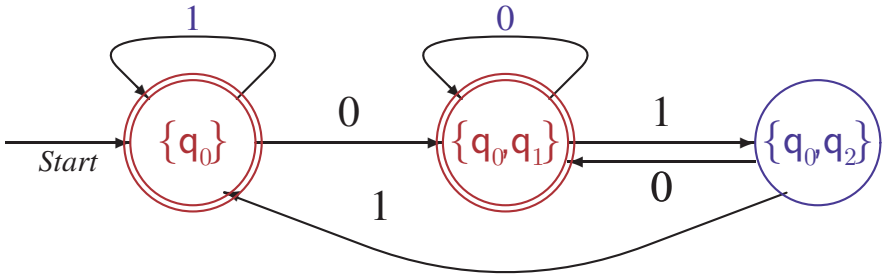

  – Komplementautomat erkennt Wörter die nicht mit 01 enden

  – Regulärer Ausdruck durch Zustandseliminationsverfahren erzeugbar

Abschluss unter Durchschnitt und Differenz

- **Einfache mathematische Beweise**

  L_1, L_2 **regulär** $\Rightarrow$ $L_1 \cap L_2 = \overline{\overline{L_1} \cup \overline{L_2}}$ **regulär**

  L_1, L_2 **regulär** $\Rightarrow$ $L_1 - L_2 = L_1 \cap \overline{L_2}$ **regulär**

- **Produktkonstruktion auf endlichen Automaten**

  Simultane Abarbeitung von Wörtern in beiden Automaten

  L_1, L_2 **regulär**

  $\Rightarrow$ Es gibt DEAs $A_1 = (Q_1, \Sigma, \delta_1, q_{0,1}, F_1)$

  und $A_2 = (Q_2, \Sigma, \delta_2, q_{0,2}, F_2)$

  mit $L_1 = L(A_1)$, $L_2 = L(A_2)$

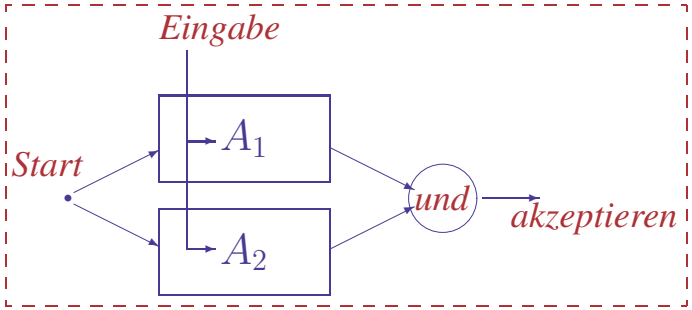

$\Rightarrow$ $L_1 \cap L_2 = \{w \in \Sigma^* \mid \hat{\delta}_1(q_{0,1}, w) \in F_1 \ \wedge \ \hat{\delta}_2(q_{0,2}, w) \in F_2\}$

$= \{w \in \Sigma^* \mid (\hat{\delta}_1(q_{0,1}, w), \ \hat{\delta}_2(q_{0,2}, w)) \in F_1 \times F_2\}$

Konstruiere $A = (Q_1 \times Q_2, \Sigma, \delta, (q_{0,1}, q_{0,2}), F_1 \times F_2)$

mit $\delta((p, q), a) = (\delta_1(p,a), \delta_2(q,a))$ für $p \in Q_1$, $q \in Q_2$, $a \in \Sigma$

$\Rightarrow$ $L_1 \cap L_2 = L(A)$ **regulär**

Produktkonstruktion am Beispiel

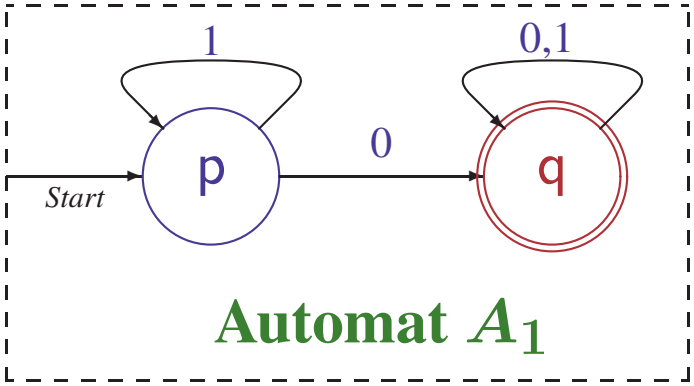

Automat A_1

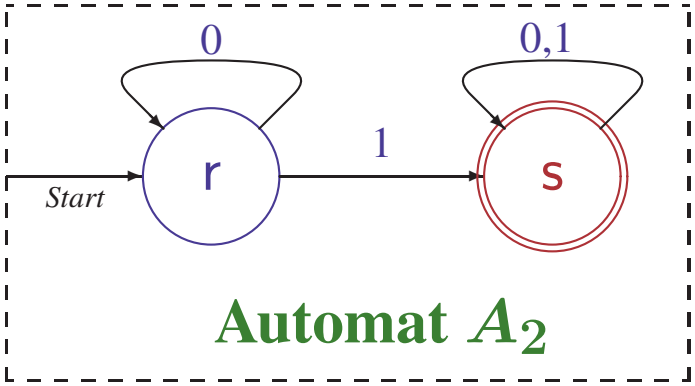

Automat A_2

Automat $A_1 \times A_2$

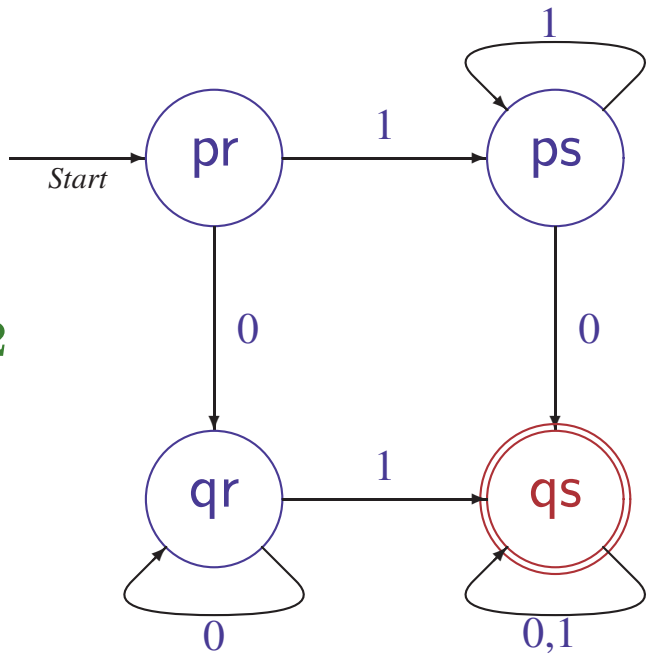

Abschluss unter Spiegelung

L regulär $\Rightarrow$ L^R=$\{w_n..w_1 \mid w_1..w_n \in L\}$ regulär

- **Beweisführung mit Automaten**
  - Bilde Umkehrautomaten zu $A = (Q, \Sigma, \delta, q_0, F)$ mit L=$L(A)$
    - Umkehrung der Pfeile im Diagramm: $\delta^R(q, a) = \{q' | \delta(q', a) = q\}$
    - q_0 wird zum akzeptierenden Zustand: $F^R = \{q_0\}$
    - Neuer Startzustand q_0^R mit ϵ-Übergängen zu allen $q \in F$
- **Induktiver Beweis mit regulären Ausdrücken**

  Sei $L = L(E)$ für einen regulären Ausdruck
  - Für $E \in \{\emptyset, \epsilon, \mathtt{a}\}$ ist $L^R = L = L(E)$ regulär
  - Für $E = E_1 + E_2$ ist $L^R = (L(E_1) \cup L(E_2))^R = L(E_1)^R \cup L(E_2)^R$ regulär
  - Für $E = E_1 \circ E_2$ ist $L^R = (L(E_1) \circ L(E_2))^R = L(E_2)^R \circ L(E_1)^R$ regulär
  - Für $E = E_1^*$ ist $L^R = L(E_1^*)^R = (L(E_1)^R)^*$ regulär
- **Beispiel: Spiegelung von $L(\mathtt{(0+1)0^*})$**
  - $L^R = L(\mathtt{(0^*)}^R\mathtt{(0+1)}^R) = L(\mathtt{(0}^R\mathtt{)^*(0}^R\mathtt{+1}^R\mathtt{)}) = L(\mathtt{0^*(0+1)})$

Bild und Urbild unter Homomorphismen

- **Homomorphismus $h{:}\Sigma^* \to \Sigma'^*$**
  - Funktion, die eindeutig durch Verhalten auf Symbolen definiert ist
  - $h{:}\Sigma^* \to \Sigma'^*$ ist Homomorphismus, wenn $h(v_1..v_n) = h(v_1)..h(v_n)$ für $v_i \in \Sigma$
    Für $h_1(a) = 01$, $h_1(b) = 0101$ muß $h_1(aa) = 0101$, $h_1(ab) = 010101$ sein
  - Homomorphismen sind mit endlichen (Ein-/Ausgabe) Automaten berechenbar
- **Bild einer Menge L unter einer Funktion h**
  - Menge aller Funktionswerte von h bei Eingaben aus L
  - $h(L) = \{h(w) \mid w \in L\} \subseteq \Sigma'^*\}$
  - z.B. $h_1(\{ab, aa, b\}) = \{0101, 010101\}$, $h_1(\{a, b\}^*) = \{01\}^*$
- **Urbild einer Menge L unter einer beliebigen (!) Funktion h**
  - Menge aller Eingaben, deren Funktionswerte in L liegen
  - $h^{-1}(L) = \{w \in \Sigma^* \mid h(w) \in L\}$
  - z.B. $h_1^{-1}(\{0101\}) = \{aa, b\}$,
    $h_1^{-1}(\{0101, 11, 1\}) = \{aa, b\}$,
    $h_1^{-1}(L((0101)^*)) = \{w \in \{a, b\}^* \mid \#_a(w) \text{ gerade}\}$

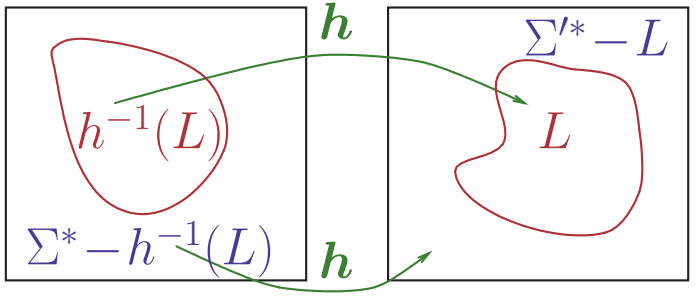

Abschlusseigenschaft: Bild unter Homomorphismen

$L \subseteq \Sigma^*$ regulär, $h: \Sigma^* \to \Sigma'^*$ Homomorphismus $\Rightarrow$ $h(L)$ regulär

Beweis mit Grammatiken

L regulär

$\Rightarrow$ Es gibt eine Typ-3 Grammatik $G = (V, \Sigma, P, S)$ mit $L = L(G)$

$\Rightarrow$ $h(L) = h(L(G)) = \{h(v_1)..h(v_n) \in \Sigma'^* \mid S \xrightarrow{*} v_1..v_n\}$

Für $A \to a\,B \in P$ erzeuge Regeln $A \to a_1 B_1$, $B_1 \to a_2 B_2$,...,$B_{k-1} \to a_k B$,
wobei $h(a) = a_1..a_k$ und alle B_i neue Hilfsvariablen

Sei P_h die Menge dieser Regeln, V_h die Menge ihrer Hilfsvariablen

Für $G_h = (V_h, \Sigma', P_h, S)$ gilt $A \to a\,B \in P \Leftrightarrow A \xrightarrow{*}_{G_h} h(a)\,B$
und $S \xrightarrow{*}_{G} v_1..v_n \Leftrightarrow S \xrightarrow{*}_{G_h} h(v_1)..h(v_n)$

$\Rightarrow$ **$h(L)$** $= \{h(v_1)..h(v_n) \in \Sigma'^* \mid S \xrightarrow{*}_{G_h} h(v_1)..h(v_n)\} = L(G_h)$ **regulär**

– Sonderbehandlung für $h(a)=\epsilon$ erforderlich, da Regel $A \to B$ unzulässig

---

Beweis mit regulären Ausdrücken in Hopcroft, Motwani, Ullman §4.2.3

Abschluss: Urbild unter Homomorphismen

$L \subseteq \Sigma'^*$ regulär, $h: \Sigma^* \to \Sigma'^*$ Homomorphismus $\Rightarrow$ $h^{-1}(L)$ regulär

Beweis mit endlichen Automaten

Berechnung von h vor Abarbeitung der Wörter im Automaten

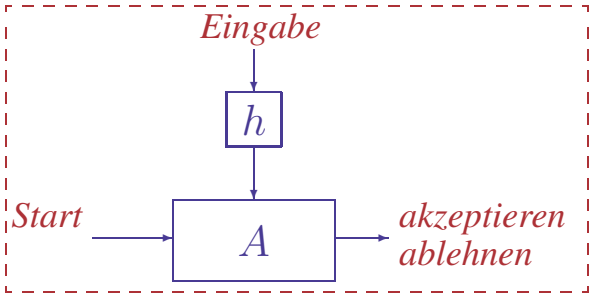

L regulär

$\Rightarrow$ Es gibt einen DEA $A = (Q, \Sigma', \delta, q_0, F)$

mit $L = L(A) = \{v \in \Sigma'^* \mid \hat{\delta}(q_0, v) \in F\}$

$\Rightarrow$ $h^{-1}(L) = \{w \in \Sigma^* \mid \hat{\delta}(q_0, h(w)) \in F\}$

Konstruiere $A_h = (Q, \Sigma, \delta_h, q_0, F)$ mit $\delta_h(q, a) = \hat{\delta}(q, h(a))$

Dann gilt $\hat{\delta}_h(q, w) = \hat{\delta}(q, h(w))$ für alle $q \in Q$ und $w \in \Sigma^*$

$\Rightarrow$ **$h^{-1}(L) = \{w \in \Sigma^* \mid \hat{\delta}_h(q_0, w) \in F\} = L(A_h)$ regulär**

Nachweis von $L \in \mathcal{L}_3$ mit Abschlusseigenschaften

- $\boldsymbol{L_1 = \{a^n b^m c^k \mid k, n, m \in \mathbb{N} \wedge n \geq 2 \geq k \neq 0\} \in \mathcal{L}_3}$

  Beweis: Es ist $L_1 = \{a^n \mid n \geq 2\} \circ \{b^m \mid m \in \mathbb{N}\} \circ \{cc, c\}$

  $= h_1(\{0^n \mid n \geq 2\}) \circ h_2(\{0^m \mid m \in \mathbb{N}\}) \circ h_3(\{00, 0\})$

  wobei $h_1(0) = a, h_2(0) = b, h_3(0) = c$

  $= h_1(\{0\}^* \circ \{0\} \circ \{0\}) \circ h_2(\{0\}^*) \circ h_3(\{0\} \circ \{0\} \cup \{0\})$

- **Jede reguläre Sprache ist nur aus $\{0\} \in \mathcal{L}_3$ konstruierbar**

  Beweis: Konstruiere Sprache beliebiger regulärer Ausdrücke induktiv

  – Für $a \in \Sigma$ ist $L(\mathtt{a}) = \{a\} = h(\{0\})$, wobei $h(0) = a$ Homomorphismus

  – $L(\emptyset) = \{\} = \{0\} - \{0\}$

  – $L(\epsilon) = \{\epsilon\} = \{0\}^* - (\{0\} \circ \{0\}^*)$

  – $L(E \circ F) = L(E) \circ L(F)$ konstruierbar, wenn $L(E)$ und $L(F)$ konstruierbar

  – $L(E^*) = (L(E))^*$ konstruierbar, wenn $L(E)$ konstruierbar

  – $L(E + F) = L(E) \cup L(F)$ konstruierbar, wenn $L(E)$ und $L(F)$ konstruierbar

  – $L((E)) = L(E)$ konstruierbar, wenn $L(E)$ konstruierbar

Nachweis von $L \notin \mathcal{L}_3$ mit Abschlusseigenschaften

- **Verwende Umkehrung der Abschlusseigenschaften**

  $h(L) \notin \mathcal{L}_3 \Rightarrow L \notin \mathcal{L}_3$, $\quad h^{-1}(L) \notin \mathcal{L}_3 \Rightarrow L \notin \mathcal{L}_3$,

  $\overline{L} \notin \mathcal{L}_3 \Rightarrow L \notin \mathcal{L}_3$, $\quad L \cap L' \notin \mathcal{L}_3 \wedge L' \in \mathcal{L}_3 \Rightarrow L \notin \mathcal{L}_3$, $\ldots$

  Methodik: Zeige, daß die Annahme $L \in \mathcal{L}_3$ dazu führt, daß eine als nichtregulär bekannte Sprache regulär sein müsste

  Ausgangspunkt: $L_{01} = \{0^n 1^n \mid n \in \mathbb{N}\}$ ist nicht regulär (Beweis auf Folie 28)

- **Anwendungsbeispiele**
  - $\boldsymbol{L_2 = \{(^m)^m \mid m \in \mathbb{N}\} \notin \mathcal{L}_3}$

    Wähle Homomorphismus h:$\{(,)\} \to \{0,1\}$ mit $h(() = 0$, $h()) = 1$

    Dann ist $h(L_3) = \{0^m 1^m \mid m \in \mathbb{N}\} = L_{01} \notin \mathcal{L}_3$, also $L_2 \notin \mathcal{L}_3$
  - $\boldsymbol{L_3 = \{w \in \{0,1\}^* \mid |w|_0 = |w|_1\} \notin \mathcal{L}_3}$ ($|w|_1$: Anzahl Einsen in w)

    Es gilt $L_3 \cap L(0^* \circ 1^*) = L_{01} \notin \mathcal{L}_3$, also $L_3 \notin \mathcal{L}_3$ (korrekte Klammerausdrücke $\notin \mathcal{L}_3$)
  - $\boldsymbol{L_4 = \{a^n b^m c^n \mid n, m \in \mathbb{N}\} \notin \mathcal{L}_3}$,

    Wähle $h(a) = 0, h(b) = \epsilon, h(c) = 1$, dann ist $h(L_4) = L_{01} \notin \mathcal{L}_3$
  - $\boldsymbol{L_5 = \{a^n b^m c^k \mid n \neq m \vee k \neq m\} \notin \mathcal{L}_3}$, da $\overline{L_5} = \{a^n b^n c^n \mid n \in \mathbb{N}\}$

Tests für Eigenschaften regulärer Sprachen

- **Welche Eigenschaften sind automatisch prüfbar?**
  - Ist die Sprache eines Automaten leer?
  - Zugehörigkeit: Ist ein Wort w Element der Sprache eines Automaten?
  - Äquivalenz: Beschreiben zwei Automaten dieselbe Sprache?

  Gleiche Fragestellung für Grammatiken und reguläre Ausdrücke
- **Wechsel der Repräsentation ist effektiv**
  - NEA $\mapsto$ DEA: Teilmengenkonstruktion (exponentielle Aufblähung möglich)
  - ϵ-NEA $\mapsto$ DEA: Hüllenbildung + Teilmengenkonstruktion
  - DEA $\mapsto$ ϵ-NEA/NEA: Modifikation der Präsentation (Mengenklammern)
  - DEA $\mapsto$ RA: Zustandselimination (oder R_{ij}^k-Methode)
  - RA $\mapsto$ ϵ-NEA: induktive Konstruktion von Automaten
  - DEA $\mapsto$ Typ-3 Grammatik: Regeln für Überführungsschritte einführen
  - Typ-3 Grammatik $\mapsto$ NEA: Überführungstabelle codiert Regeln

  Es reicht, Tests für ein Modell zu beschreiben

Prüfe, ob eine reguläre Sprache leer ist

- **Nichttriviales Problem**
  - Automaten: Gibt es überhaupt einen akzeptierenden Pfad?
  - Reguläre Ausdrücke: Wird mindestens ein einziges Wort charakterisiert?
  - Grammatiken: Wird überhaupt ein Wort aus dem Startzustand erzeugt?
- **Erreichbarkeitstest für DEA $A = (Q, \Sigma, \delta, q_0, F)$**
  - Wegen $\hat{\delta}(q_0, \epsilon) = q_0$ ist q_0 in 0 Schritten erreichbar
  - q in k Schritten erreichbar, $\delta(q, a)=q' \Rightarrow q'$ in $k+1$ Schritten erreichbar
  - $L(A)=\{\} \Leftrightarrow$ **kein $q \in F$ in maximal $|Q|$ Schritten erreichbar**
- **Induktive Analyse für reguläre Ausdrücke**
  - $L(\emptyset)=\{\}$, $L(\epsilon)\neq\{\}$, $L(\mathtt{a})\neq\{\}$
  - $L((E))=\{\} \Leftrightarrow L(E)=\{\}$ — keine Änderung
  - $L(E+F)=\{\} \Leftrightarrow L(E)=\{\} \wedge L(F)=\{\}$ — Vereinigung von Elementen
  - $L(E \circ F)=\{\} \Leftrightarrow L(E)=\{\} \vee L(F)=\{\}$ — Elemente beider Sprachen nötig
  - $L(E^*)\neq\{\}$, — ϵ gehört immer zu $L(E^*)$

Test auf Zugehörigkeit (Wortproblem)

- **Unterschiedlich schwierig je nach Repräsentation**
  - Automaten: Gibt es einen akzeptierenden Pfad für das Wort w?
  - Reguläre Ausdrücke: Wird w von der Charakterisierung erfasst?
  - Grammatiken: Kann w aus dem Startzustand erzeugt werden?
- **Abarbeitung durch DEA $A = (Q, \Sigma, \delta, q_0, F)$**
  - Bestimme $q := \hat{\delta}(q_0, w)$ und teste $q \in F$
  - Maximal $|w| + |F|$ Arbeitsschritte

Test für andere Repräsentationen durch Umwandlung in DEA

Test auf Äquivalenz von Sprachen

- **Wann sind zwei reguläre Sprachen gleich?**
  - Nichttrivial, da Beschreibungsformen sehr verschieden sein können
    - Verschiedene Automaten, Grammatiken, Ausdrücke, Mischformen, ...
- **Gibt es eine "kanonische" Repräsentation?**
  - z.B. · Transformiere alles in deterministische endliche Automaten
    - Erzeuge Standardversion mit kleinstmöglicher Anzahl von Zuständen
  - Äquivalenztest prüft dann, ob der gleiche Standardautomat erzeugt wird
- **Wie standardisiert man Automaten?**
  - Entferne Zustände, die vom Startzustand unerreichbar sind
  - Fasse Zustände zusammen, die für alle Wörter "äquivalent" sind
    - Es führen exakt dieselben Wörter zu akzeptierenden Zuständen
  - Ergibt **minimalen äquivalenten Automaten**

Äquivalenztest für Zustände

- **Äquivalenz der Zustände p und q ($p \cong q$)**
  - Für alle Wörter $w \in \Sigma^*$ gilt $\hat{\delta}(p,w) \in F \Leftrightarrow \hat{\delta}(q,w) \in F$
  - Die Wörter müssen nicht zum gleichen Zustand führen
- **Positives Prüfverfahren schwierig**
  - Man muss alle Wörter überprüfen, die von einem Zustand ausgehen
  - Man kann sich auf Wörter der maximalen Länge $|Q|$ beschränken
  - Besser: Nichtäquivalente (unterscheidbare) Zustände identifizieren
- **Methodik: verwende einen Table-Filling Algorithmus**

  Markiere Unterscheidbarkeit von Zuständen in Tabelle
  - Start: $p \ncong q$, falls $p \in F$ und $q \notin F$
  - Iteration: $p \ncong q$, falls $\delta(p,a) \ncong \delta(q,a)$ für ein $a \in \Sigma$

  In jeder Iteration werden nur noch ungeklärte Paare überprüft

  Nach maximal $|Q|^2/2$ Iterationen sind alle Unterschiede bestimmt

Äquivalenztest am Beispiel

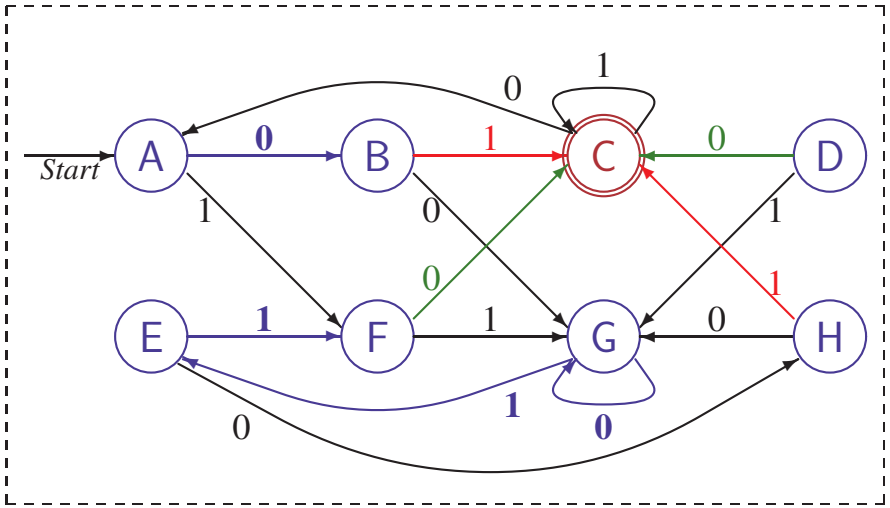

	A	B	C	D	E	F	G	H
A	■	×	×	×		×	×	×
B	■	■	×	×	×	×	×	
C	■	■	■	×	×	×	×	×
D	■	■	■	■	×		×	×
E	■	■	■	■	■	×	×	×
F	■	■	■	■	■	■	×	×
G	■	■	■	■	■	■	■	×
H	■	■	■	■	■	■	■	■

Tabelle der Unterschiede

1. Unterscheide akzeptierende Zustände (C) von allen anderen

2a. Eingabesymbol 0: Nur D und F führen zu akzeptierenden Zuständen

2b. Eingabesymbol 1: Nur B und H führen zu akzeptierenden Zuständen

3. Überprüfe Nachfolger von {A,E}, {A,G}, {B,H}, {D,F} und {E,G}.

4. Überprüfung von {A,E}, {B,H} und {D,F} gibt keine Unterschiede

Äquivalenzklassen sind {A,E}, {B,H}, {D,F}, {C} und {G}

Konstruiere äquivalenten DEA mit minimaler Menge von Zuständen

- **Entferne überflüssige Zustände**
  - q ist überflüssig, wenn $\hat{\delta}(q_0, w) \neq q$ für alle Wörter $w \in \Sigma^*$
  - Reduziere Q zu Menge der erreichbaren Zustände (Verfahren auf Folie 15)
- **Fasse äquivalente Zustände zusammen**
  - Bestimme Menge der Äquivalenzklassen von Q
  - Setze Q' als Menge der Äquivalenzklassen von Q
  - Setze $\delta'(S, a)$ als Äquivalenzklasse von $\delta(q, a)$ für ein beliebiges $q \in S$
    Wohldefiniert, da alle Nachfolger äquivalenter Zustände äquivalent sind

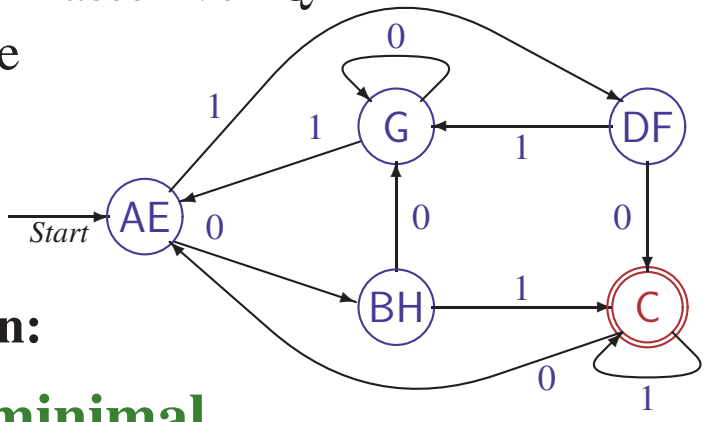

Anwendung auf Beispielautomaten:

Resultierender Automat ist minimal

Äquivalenztest für Sprachen

- **Prüfverfahren**
  - Standardisiere Beschreibungsform in zwei disjunkte DEAs A_1 und A_2
  - Vereinige Automaten zu $A = (Q_1 \cup Q_2 \cup \{q'\}, \Sigma, \delta_1 \cup \delta_2, q', F_1 \cup F_2)$
    A enthält A_1 und A_2 als unabhängige Teile
  - Bilde Äquivalenzklassen von A
    und teste ob $q_{0,1}$ und $q_{0,2}$ äquivalent sind
- **Zwei DEAs für $L(\epsilon + (0+1)^*0))$**
  - Äquivalenzklassen sind {A,C,D} (alle Endzustände)
    und {B,E} (alle Nicht-Endzustände)
  - **Da A und C äquivalent sind,**
    sind die Automaten äquivalent

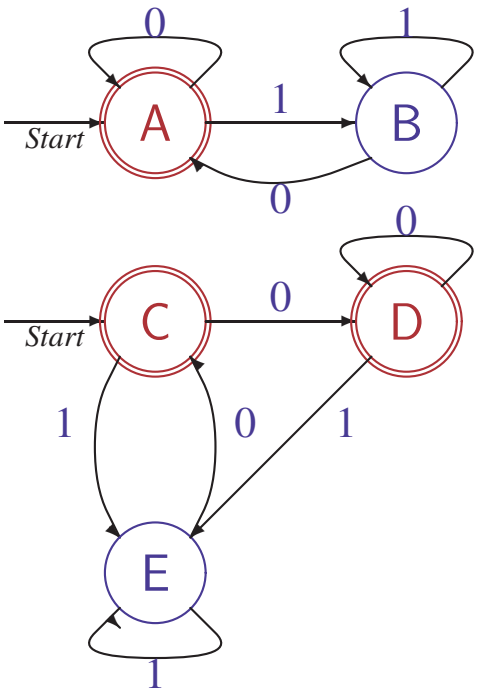

- **Automaten teilen Sprachen in Äquivalenzklassen**
  - Wörter, die zum gleichen Zustand führen, sind ununterscheidbar
  - Wörter, die zu äquivalenten Zuständen führen, sind ununterscheidbar

    Jede Fortsetzung der Wörter führt zum "gleichen" Ergebnis

    $\hat{\delta}(q_0,u)\cong\hat{\delta}(q_0,v)$ bedeutet $\hat{\delta}(q_0,u\,w)\in F \Leftrightarrow \hat{\delta}(q_0,v\,w)\in F$ für alle $w\in\Sigma^*$
- **Äquivalenzklassen hängen nur von der Sprache ab**
  - Für $L\subseteq\Sigma^*$ definiere Äquivalenzrelation $\sim_L$ auf Σ^*:
    - $\boldsymbol{u\sim_L v} \equiv u\,w\in L \Leftrightarrow v\,w\in L$ gilt für alle $w\in\Sigma^*$

      $\sim_L$ ist eine Äquivalenzrelation $\mapsto$ Übung
  - Die Äquivalenzklasse eines Wortes v ist $\boldsymbol{[v]_L = \{u\in\Sigma^* \mid u\sim_L v\}}$
    - Äquivalenzklassen sind disjunkt oder identisch

      Gibt es $w\in[u]_L\cap[v]_L$ dann ist $u\sim_L v$, also $z\in[u]_L\Leftrightarrow z\in[v]_L$ für alle z
  - $\boldsymbol{\Sigma^*/L}$ bezeichnet die Menge der Äquivalenzklassen modulo $\sim_L$

Äquivalenzklassen der Sprache $L = \{0^n 1^m \mid n, m \in \mathbb{N}\}$

- $[\epsilon]_L = \{u \in \{0,1\}^* \mid u \sim_L \epsilon\} = \{u \mid \forall w.\ uw \in L \Leftrightarrow w \in L\} = \{0^k \mid k \in \mathbb{N}\}$

  $[0]_L = [00]_L = [000]_L = \ldots = [\epsilon]_L$, weil $0 \in [\epsilon]_L$, $00 \in [\epsilon]_L$, $000 \in [\epsilon]_L$, $\ldots$

- $[1]_L = \{u \mid \forall w.\ uw \in L \Leftrightarrow 1w \in L\} = \{u \mid \forall w.\ uw \in L \Leftrightarrow \exists j. w = 1^j\}$

  $= \{0^k 1^i \mid k \in \mathbb{N}, i > 0\}$

  $[01]_L = [1]_L$, weil $01 \in [1]_L$

- $[10]_L = \{u \mid \forall w.\ uw \in L \Leftrightarrow 10w \in L\} = \{u \mid \forall w.\ uw \notin L\} = \{0,1\}^* - L$

  Grund: für $L = \{0^n 1^m \mid n, m \in \mathbb{N}\}$ gilt $u \notin L \Rightarrow \forall w.\ uw \notin L$ (Umkehrung gilt immer)

- Wegen $[\epsilon]_L \cup [1]_L = L$ folgt: $\{0,1\}^*/L = \{[\epsilon]_L, [1]_L, [10]_L\}$

Reguläre Sprachen haben nur endlich viele Äquivalenzklassen

Äquivalenzklassen der Sprache $L = \{0^n 1^n \mid n \in \mathbb{N}\}$

- $[\epsilon]_L = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow w \in L\} = \{\epsilon\}$
- $[0]_L = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow 0w \in L\}$
  $= \{u \mid \forall w.\ u\,w \in L \Leftrightarrow \exists n.w{=}0^n 1^{n+1}\} = \{0\}$
- $[1]_L = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow 1w \in L\} = \{u \mid \forall w.\ u\,w \notin L\}$
  $= \{0,1\}^* - \{0^n 1^m \mid n \geq m\}$
- $[00]_L = \ldots = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow \exists n.w{=}0^n 1^{n+2}\} = \{00\}$
- $[01]_L = \ldots = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow w = \epsilon\} = L - \{\epsilon\}$
- $[10]_L = [11]_L = [1]_L$, weil $10 \in [1]_L$, $11 \in [1]_L$
- $[000]_L = \ldots = \{u \mid \forall w.\ u\,w \in L \Leftrightarrow \exists n.w{=}0^n 1^{n+3}\} = \{000\}$
- Zeige: **Es gibt unendlich viele Klassen in $\{0,1\}^*/L$**
  – z.B. sind alle Klassen $[0^k]_L$ (= $\{0^k\}$) verschieden

  Für den Beweis dieser Aussage muß man die Klassen nicht exakt bestimmen. Es reicht:
  "Für $k{\neq}j$ und $w{=}1^k$ ist $0^k w \in L$, aber $0^j w \notin L$, also $0^k \not\sim_L 0^j$ also $[0^k]_L{\neq}[0^j]_L$"

Nichtreguläre Sprachen haben unendlich viele Äquivalenzklassen

Der Satz von Myhill/Nerode

Eine Sprache L ist regulär, g.d.w Σ^*/L endlich ist

Beweis

$\Rightarrow$: Es sei L eine reguläre Sprache

Dann gibt es einen minimalen DEA $A = (Q, \Sigma, \delta, q_0, F)$ mit $L = L(A)$

Da A minimal ist, gilt für beliebige Wörter $u, v \in \Sigma^*$

$\hat{\delta}(q_0, u) = \hat{\delta}(q_0, v) \Leftrightarrow (\hat{\delta}(q_0, u\,w) \in F \Leftrightarrow \hat{\delta}(q_0, v\,w) \in F)$ für alle $w \in \Sigma^*$

$\Leftrightarrow (u\,w \in L \Leftrightarrow v\,w \in L)$ für alle $w \in \Sigma^* \Leftrightarrow u \sim_L v$

Damit ist $|\Sigma^*/L|$ (der Index von L) gleich der Anzahl der Zustände in A

$\Leftarrow$: Es sei Σ^*/L endlich.

Konstruiere einen DEA $A = (\Sigma^*/L\ , \Sigma, \delta, [\epsilon]_L, F)$

mit $\delta([u]_L, a) = [u\,a]_L$ für alle $a \in \Sigma$ und $F = \{[v]_L \mid v \in L\}$

δ ist wohldefiniert, weil $u\,a \sim_L v\,a$ für alle $a \in \Sigma$ gilt, wenn $u \sim_L v$

und es gilt $w \in L(A) \Leftrightarrow \hat{\delta}([\epsilon]_L, w) \in F \Leftrightarrow [w]_L \in F \Leftrightarrow w \in L$

Grenzen regulärer Sprachen

Wie zeigt man, dass eine Sprache L nicht regulär ist?

- **Direkter Nachweis**
  - Zeige, dass kein endlicher Automat genau die Wörter von L erkennt
  - Sprache muss unendlich sein und komplizierte Struktur haben
    (Anzahl der Äquivalenzklassen muss unendlich sein)
  - Technisches Hilfsmittel: Pumping Lemma
- **Verwendung der Abschlusseigenschaften** (Folie 13)
  - Zeige, dass Regularität von L dazu führen würde, dass eine als nichtregulär bekannte Sprache regulär sein müsste
  - Häufige Technik: (Ur-)bild unter Homomorphismen

Das Pumping Lemma für reguläre Sprachen

- **Warum ist $\{0^n 1^n \mid n \in \mathbb{N}\}$ nicht regulär?**
  - Ein DEA muss alle Nullen beim Abarbeiten zählen und dann vergleichen
  - Für $n > |Q|$ muss ein Zustand von A doppelt benutzt worden sein
  - Eine δ-Schleife mit k Zuständen bedeutet, dass A auch $0^{n+k}1^n$ akzeptiert
- **Allgemeine Version: Pumping Lemma**

  Für jede reguläre Sprache $L \in \mathcal{L}_3$ gibt es eine Zahl $n \in \mathbb{N}$, so dass jedes Wort $w \in L$ mit Länge $|w| \geq n$ zerlegt werden kann in $w = x\,y\,z$ mit den Eigenschaften

  (1) $y \neq \epsilon$,

  (2) $|x\,y| \leq n$ und

  (3) für alle $k \in \mathbb{N}$ ist $x\,y^k\,z \in L$ (Beweis folgt)
- **Aussage ist wechselseitig konstruktiv**
  - Die Zahl n kann zu jeder regulären Sprache L bestimmt werden
  - Die Zerlegung $w = x\,y\,z$ kann zu jedem Wort $w \in L$ bestimmt werden

Anwendungen des Pumping Lemmas

$L_1 = \{0^m 1^m \mid m \in \mathbb{N}\}$ ist nicht regulär

- **Verwende Kontraposition des Pumping Lemmas**

  Eine Sprache L ist nicht regulär, wenn es kein $n \in \mathbb{N}$ gibt, so dass jedes $w \in L$ mit $|w| \geq n$ zerlegbar ist in $w = x\,y\,z$ mit den Eigenschaften

  (1) $y \neq \epsilon$, (2) $|x\,y| \leq n$ und (3) für alle $k \in \mathbb{N}$ ist $x\,y^k\,z \in L$

  Umformulierung: Ziehe Negation in die Bedingungen hinein

  L ist nicht regulär, wenn es für jedes $n \in \mathbb{N}$ ein $w \in L$ mit $|w| \geq n$ gibt so dass für jede Zerlegung $w = x\,y\,z$ mit den Eigenschaften

  (1) $y \neq \epsilon$ und (2) $|x\,y| \leq n$ ein $k \in \mathbb{N}$ existiert mit $x\,y^k\,z \notin L$

- **Kontrapositionsbeweis für $L_1 \notin \mathcal{L}_3$**
  - Sei $n \in \mathbb{N}$ beliebig. Wir wählen $w = 0^m 1^m$ für ein $m > n$
  - Sei $w = x\,y\,z$ eine beliebige Zerlegung mit $y \neq \epsilon$ und $|x\,y| \leq n$
    Dann gilt $x = 0^i$, $y = 0^j$ $z = 0^{m-i-j}1^m$ für ein $j \neq 0$ und $i + j \leq n$.
  - Wir wählen $k = 0$. Dann ist $x\,y^0\,z = 0^{m-j}1^m \notin L_1$

  Aufgrund des Pumping Lemmas kann L_1 also nicht regulär sein.

Beweis des Pumping Lemmas

Für jede Sprache $L \in \mathcal{L}_3$ gibt es ein $n \in \mathbb{N}$, so dass jedes $w \in L$ mit $|w| \geq n$ zerlegbar ist in $w = x\,y\,z$ mit den Eigenschaften

(1) $y \neq \epsilon$, (2) $|x\,y| \leq n$ und (3) für alle $k \in \mathbb{N}$ ist $x\,y^k\,z \in L$

- **Beweis mit Automaten**
  - Sei L regulär und $A = (Q, \Sigma, \delta, q_0, F)$ ein DEA mit $L = L(A)$
  - Wähle $n = |Q|$. Betrachte $w = a_1..a_m$ mit $|w| \geq n$ und $p_i := \hat{\delta}(q_0, a_1..a_i)$
  - Dann gibt es i, j mit $0 \leq i < j \leq n$ und $p_i = p_j$ (Schubfachprinzip)
  - Zerlege w in $w = x\,y\,z$ mit $x = a_1..a_i$, $y = a_{i+1}..a_j$ und $z = a_{j+1}..a_m$

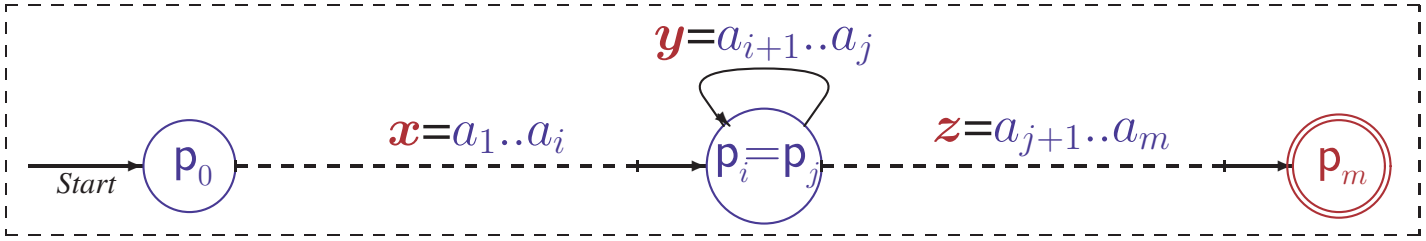

  - Per Konstruktion gilt $y \neq \epsilon$, $|x\,y| \leq n$ und $\hat{\delta}(p_i, y^k) = p_i$ für alle $k \in \mathbb{N}$
  - Also $\hat{\delta}(q_0, x\,y^k\,z) = \hat{\delta}(p_i, y^k\,z) = \hat{\delta}(p_i, y\,z) = \hat{\delta}(q_0, x\,y\,z) = \hat{\delta}(q_0, w) \in F$

Anwendungen des Pumping Lemmas II

$$L_2 = \{w \in \{1\}^* \mid |w| \text{ ist Primzahl}\} \notin \mathcal{L}_3$$

- **Beweis folgt dem gleichen Schema**
  - Sei $n \in \mathbb{N}$ beliebig.
  - Wir wählen $w = 1^p$ für eine Primzahl $p > n+1$
  - Sei $w = x\,y\,z$ eine beliebige Zerlegung mit $y \neq \epsilon$ und $|x\,y| \leq n$

    Dann gilt $x = 1^i$, $y = 1^j$ $z = 1^{p-i-j}$ für ein $j \neq 0$ und $i+j \leq n$.
  - Wir wählen $k = p-j$.

    Dann ist $x\,y^k\,z = 1^i\,1^{j(p-j)}\,1^{p-i-j} = 1^{i+j(p-j)+p-i-j} = 1^{(j+1)(p-j)} \notin L_2$

Aufgrund des Pumping Lemmas kann L_2 also nicht regulär sein.

Eigenschaften regulärer Sprachen im Rückblick

- **Abschlusseigenschaften**
  - Operationen $\cup$, $\cap$, $\overline{\ }$, -, ^{R}, $\circ$, *, h, h^{-1} erhalten Regularität von Sprachen
  - Verwendbar zum Nachweis von Regularität oder zur Widerlegung
- **Automatische Prüfungen**
  - Man kann testen ob eine reguläre Sprache leer ist
  - Man kann testen ob ein Wort zu einer regulären Sprache gehört
  - Man kann testen ob zwei reguläre Sprachen gleich sind
- **Minimierung von Automaten**
  - Ein Automat kann minimiert werden, indem man äquivalente Zustände zusammenlegt und unerreichbare Zustände entfernt
- **Pumping Lemma**
  - Wiederholt man einen bestimmten Teil ausreichend großer Wörter einer regulären Sprache beliebig oft, so erhält man immer ein Wort der Sprache
  - Verwendbar zur Widerlegung von Regularität

Zusammenfassung: reguläre Sprachen

- **Drei Modelle**
  - Endliche Automaten (DEA, NEA, ϵ-NEA) erkennen Wörter einer Sprache
  - Reguläre Ausdrücke beschreiben Struktur der Wörter
  - (Typ 3) Grammatiken erzeugen Wörter einer regulären Sprache
- **Alle drei Modelle sind äquivalent**
  - ϵ-NEA $\mapsto$ DEA: Teilmengenkonstruktion
  - DEA $\mapsto$ Typ-3 Grammatik: Verwandle Überführungsfunktion in Regeln
  - Typ-3 Grammatik $\mapsto$ NEA: Verwandle Regeln in Überführungsfunktion
  - DEA $\mapsto$ Reguläre Ausdrücke: Erzeuge Ausdrücke für Verarbeitungspfade oder eliminiere Zustände in RA Automaten
  - Reguläre Ausdrücke $\mapsto$ NEA: Iterative Konstruktion von Automaten
- **Wichtige Eigenschaften von $\mathcal{L}_3$**
  - Abgeschlossen unter $\cup$, $\cap$, $\overline{\ }$, -, ^{R}, $\circ$, *, h, h^{-1}
  - Entscheidbarkeit des Wortproblems und Gleichheit von Sprachen
  - Endliche Automaten können automatisch minimiert werden
  - Nachweis der Nichtregularität von Sprachen mit dem Pumping Lemma