

Reguläre Sprachen: Regularität widerlegen, Satz von Myhill-Nerode, Eigenschaften regulärer Sprachen

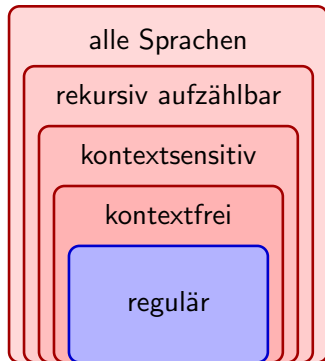
Prof. Dr. David Sabel

LFE Theoretische Informatik



Letzte Änderung der Folien: 4. Juni 2019

Motivation zum Pumping-Lemma



Formalismen zur Darstellung von regulären Sprachen:

- Endliche Automaten
- Reguläre Ausdrücke
- Reguläre Grammatiken

Wie zeigt man, dass eine formale Sprache **nicht regulär** ist?


⇒ Das Pumping-Lemma ist ein Werkzeug dafür!

Inhaltsübersicht

- Nichtregularität beweisen: Das Pumping-Lemma
- Der Satz von Myhill-Nerode
- Minimierung von Automaten
- Abschlusseigenschaften regulärer Sprachen
- Entscheidbarkeitsresultate für reguläre Sprachen

Idee des Pumping-Lemmas: Beispiel

Beispiel: DFA M :




- Von M erkannte Wörter der Länge 3, 4, 5, 6, ...
- Beobachtung 1: Jedes Wort z mit Länge > 3 , das M erkennt, **muss** mindestens eine **Schleife durchlaufen**.
- Beobachtung 2: Wenn wir die **Schleife mehrfach durchlaufen**, wird das entsprechende Wort immer noch erkannt, d.h.

Wörter in $L(M)$ mit Länge > 3 können wir **aufpumpen** und verbleiben in der Sprache $L(M)$

Idee des Pumping-Lemmas: Allgemeiner


Gilt das allgemein?



- Wenn ein endlicher Automat n Zustände hat, dann müssen akzeptierte Wörter der Länge $\geq n$ eine Schleife durchlaufen
- Diese Wörter kann man aufpumpen: uvw , $uvvw$, $uvvww$, ...
Allgemein: $uv^i w$ für $i = 0, 1, 2, \dots$ liegen in der erkannten Sprache

Beweis des Pumping-Lemmas (1)

- Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA, der L akzeptiert mit $|Z| = n$.
- Jeder Lauf für ein $z \in L$ besucht $|z| + 1$ Zustände. Sei $|z| \geq n$. Sei $q_0, q_1, \dots, q_{|z|}$ die besuchte Folge mit $q_0 = z_0$ und $q_{|z|} \in E$.
- Da $|Z| = n$, wird spätestens nach Lesen von n Zeichen ein Zustand erneut besucht
- Sei q_k (mit $k \leq n$) der erste Zustand, der bereits besucht wurde:
D.h. es gibt $j < k$, sodass $q_k = q_j$ und k ist minimal, $z = uvw$ mit




Das Pumping-Lemma

Lemma 4.9.1 (Pumping-Lemma)

Jede reguläre Sprache L hat die folgende Pumping-Eigenschaft:
Es gibt eine Zahl $n \in \mathbb{N}_{>0}$, sodass jedes Wort $z \in L$, welches Mindestlänge n hat (d.h. $|z| \geq n$), als $z = uvw$ geschrieben werden kann, so dass gilt:


- $|uv| \leq n$
- $|v| \geq 1$
- für alle $i \geq 0$: $uv^i w \in L$.

Die Zahl n nennt man auch die Pumping-Konstante der Sprache L



Beweis des Pumping-Lemmas (2)

...
D.h. es gibt $j < k$, sodass $q_k = q_j$ und k ist minimal, $z = uvw$ mit



Wir zeigen nun die drei geforderten Eigenschaften der Zerlegung:

- Aus $j < k$ folgt $|v| \geq 1$.
- Aus $k \leq n$ folgt $|uv| \leq n$.
- Aus $q_j = q_k$ folgt $\hat{\delta}(q_0, u) = q_j = \hat{\delta}(q_0, uv) = q_k$ und somit $\hat{\delta}(q_0, uvw) = \hat{\delta}(q_0, uvw) = q_{|z|} \in E$, d.h. $uv^0 w \in L(M)$.
Sei $i > 0$. Aus $\hat{\delta}(q_j, v) = q_k = q_j$ folgt $\hat{\delta}(q_j, v^i) = q_j$ und daher $\hat{\delta}(uv^i w) = \hat{\delta}(q_k, v^i w) = \hat{\delta}(q_j, w) = q_{|z|} \in E$.
Daher gilt $uv^i w \in L(M)$ für alle $i \in \mathbb{N}$. □

Zur Erinnerung: Pumping-Eigenschaft

Es gibt eine Zahl $n \in \mathbb{N}_{>0}$, sodass jedes Wort $z \in L$, welches Mindestlänge n hat (d.h. $|z| \geq n$), als $z = uvw$ geschrieben werden kann, so dass gilt:

- $|uv| \leq n$
- $|v| \geq 1$
- für alle $i \geq 0$: $uv^i w \in L$.

Als prädikatenlogische Formel:

$$\begin{aligned} &\exists n \in \mathbb{N}_{>0}: \\ &\forall z \in L: \\ &(|z| \geq n \Rightarrow \\ &\exists u, v, w: (z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L))) \end{aligned}$$

Warum erfüllen **endliche Sprachen** das Pumping-Lemma?

Wähle n größer als die Länge des längsten Worts!

Umformung der negierten Pumping-Eigenschaft

$$\begin{aligned} &\neg(\exists n \in \mathbb{N}_{>0}: \forall z \in L: (|z| \geq n \Rightarrow \exists u, v, w: (z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L)))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: \neg(\forall z \in L: (|z| \geq n \Rightarrow \exists u, v, w: (z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L)))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: (\neg(|z| \geq n) \Rightarrow \exists u, v, w: (z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L)))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: ((|z| \geq n) \wedge \neg(\exists u, v, w: (z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L)))))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: ((|z| \geq n) \wedge (\forall u, v, w: (\neg(z=uvw \wedge |uv| \leq n \wedge |v| \geq 1 \wedge \forall i \geq 0: (uv^i w \in L)))))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: ((|z| \geq n) \wedge (\forall u, v, w: (\neg(z=uvw \wedge |uv| \leq n \wedge |v| \geq 1) \vee \neg(\forall i \geq 0: (uv^i w \in L)))))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: ((|z| \geq n) \wedge (\forall u, v, w: ((z=uvw \wedge |uv| \leq n \wedge |v| \geq 1) \Rightarrow \neg(\forall i \geq 0: (uv^i w \in L)))))) \\ \leftrightarrow &\forall n \in \mathbb{N}_{>0}: (\exists z \in L: ((|z| \geq n) \wedge (\forall u, v, w: ((z=uvw \wedge |uv| \leq n \wedge |v| \geq 1) \Rightarrow \exists i \geq 0: uv^i w \notin L)))) \end{aligned}$$

Formale Sprache L erfüllt **nicht** die Pumping-Eigenschaft:

Für **jede** Zahl $n \in \mathbb{N}_{>0}$ **gibt es** ein Wort $z \in L$ mit $|z| \geq n$, sodass für **jede** Zerlegung $z = uvw$ mit

- $|uv| \leq n$ und
- $|v| \geq 1$

ein $i \geq 0$ **existiert** mit $uv^i w \notin L$.

- Pumping-Lemma:
Sprache regulär \implies Sprache erfüllt die Pumping-Eigenschaft
- Zeige, dass eine Sprache nicht regulär ist, durch Kontraposition:

Sprache erfüllt **nicht** die Pumping-Eigenschaft
 \implies Sprache ist **nicht** regulär

Anwendung des Pumping-Lemmas

Satz

Die Sprache $L = \{a^j b^j \mid j \in \mathbb{N}\}$ ist nicht regulär.

Beweis: Wir zeigen, dass L die Pumping-Eigenschaft **nicht erfüllt** und schließen mit dem Pumping-Lemma, dass L **nicht regulär** ist:

- Sei $n \in \mathbb{N}_{>0}$ beliebig. Wir wählen $z \in L$:
 $z = a^n b^n$ (damit ist auch $|z| \geq n$ erfüllt).
- Sei $z = uvw$ eine beliebige Zerlegung von z , sodass $|uv| \leq n$ und $|v| \geq 1$.
- Dann ist $u = a^r, v = a^s$ mit $r + s \leq n, s > 0$ und $w = a^t b^n$ mit $r + s + t = n$.
Daher können wir z.B. $i = 2$ wählen und erhalten
 $uv^i w = uv^2 w = a^r a^s a^s a^t b^n = a^{n+s} b^n \notin L$, da $s > 0$. □

Beweise Nicht-Regularität als Spiel

Sei L die formale Sprache.

- 1 Der **Gegner** wählt die Zahl $n \in \mathbb{N}_{>0}$.
- 2 **Wir** wählen das Wort $z \in L$ mit $|z| \geq n$.
- 3 Der **Gegner** wählt Zerlegung $z = uvw$ mit $|uv| \leq n$ und $|v| \geq 1$.
- 4 **Wir** gewinnen das Spiel, wenn wir ein $i \geq 0$ angeben können, sodass $uv^i w \notin L$.

Wenn wir das Spiel **für alle Wahlmöglichkeiten des Gegners** gewinnen, dann haben wir die Nichtregularität von L nachgewiesen.

Beispiel

Satz

Die Sprache $L = \{a^n \mid n \text{ ist Quadratzahl}\}$ ist nicht regulär.

- 1 Sei $n \in \mathbb{N}_{>0}$ vom Gegner gewählt.
- 2 Wir wählen $z = a^{n^2} \in L$.
- 3 Sei $z = uvw$ vom Gegner zerlegt, sodass $|uv| \leq n$ und $|v| \geq 1$.
- 4 Wir wählen $i = 2$, d.h. wir betrachten $uv^2w = a^k$.
 - $1 + n^2 \leq k$ (denn $|v| \geq 1$)
 - $k \leq n^2 + n$ (denn $|uv| \leq n$ und daher $|v| \leq n$).

Dann kann k jedoch keine Quadratzahl sein, denn $n^2 + n = (n + 1) \cdot n < (n + 1)^2$.

Daher gilt $uv^2w \notin L$.

Das Pumping-Lemma zeigt somit, dass L nicht regulär ist. \square

Beispiel

Satz

Die Sprache $L = \{a^p \mid p \text{ ist Primzahl}\}$ ist nicht regulär.

Wir zeigen, dass wir das eben eingeführte Spiel stets gewinnen:

- 1 Sei $n \in \mathbb{N}_{>0}$ vom Gegner gewählt.
- 2 Wir wählen $z \in L$ als $z = a^p$ mit p ist die nächste Primzahl, die größer gleich n ist.
- 3 Der Gegner wählt Zerlegung $z = uvw$ mit $uvw = a^p$, $|uv| \leq n$, $|v| \geq 1$ (und damit $s \geq 1$).
- 4 Wir wählen $i = p + 1$. Dann ist $uv^i w \notin L$, denn $uv^i w = a^r (a^s)^{p+1} a^t = a^{r+s \cdot (p+1)+t} = a^{r+s \cdot p+s+t} = a^{s \cdot p+p} = a^{p \cdot (s+1)}$ und für $s \geq 1$ folgt, dass $p \cdot (s + 1)$ keine Primzahl sein kann. \square

Beispiel

Satz

Die Sprache $L = \{a^{2^n} \mid n \in \mathbb{N}\}$ ist nicht regulär.

Beweis:

- Sei $n \in \mathbb{N}_{>0}$ beliebig.
- Sei $z \in L$ mit $|z| \geq n$ das Wort $z = a^{2^n}$.
- Sei $z = uvw$ mit $|uv| \leq n$ und $|v| = k \geq 1$.
- Dann ist $1 \leq k \leq n$ und $uv^2w = a^{2^n+k}$ und $2^n + k \neq 2^l$ da $2^n + k < 2^{n+1} = 2^n + 2^n$ denn $k \leq n < 2^n$.
Daher ist $uv^2w \notin L$.

Mit dem Pumping-Lemma folgt, dass L nicht regulär ist. \square

Satz

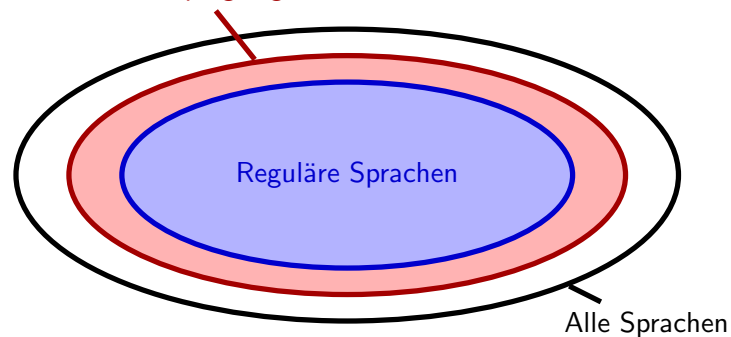
Die Sprache $L = \{w \in \{a, b\}^* \mid w \text{ ist Palindrom}\}$ ist nicht regulär.

- Sei $n \in \mathbb{N}_{>0}$ beliebig.
- Wir wählen $z = a^n b a^n \in L$ als Wort mit Mindestlänge n .
- Sei $z = uvw$ mit $|uv| \leq n$ und $|v| \geq 1$.
- Dann ist $uv^0w = a^k b a^n$ mit $k = n - |v| < n$ kein Palindrom.

Mit dem Pumping-Lemma folgt, dass L nicht regulär ist. \square

Mengendiagramm

Sprachen, die die Pumping-Eigenschaft erfüllen



Wichtige Konsequenz

Das Pumping-Lemma kann nicht verwendet werden, um zu zeigen, dass eine Sprache regulär ist.

Pumping-Eigenschaft ist nicht hinreichend

Lemma

Es gibt Sprachen, die die Pumping-Eigenschaft erfüllen aber nicht regulär sind. Die Sprache $L = \{a^k b^l c^l \mid k, l \in \mathbb{N}\} \cup \{b, c\}^*$ ist eine solche Sprache.

Beweis, dass L die Pumping-Eigenschaft erfüllt:

- Sei $n \geq 1$ beliebig.
- Sei $z \in L$ mit $|z| \geq n$
- Wenn $z \in \{b, c\}^*$, zerlege $z = uvw$ mit $u = \varepsilon, v$ das erste Symbol von z und w der $n - 1$ -Zeichen lange Suffix von z . Offensichtlich gilt $|v| \geq 1, |uv| \leq n$ und $uv^i w \in \{b, c\}^* \subseteq L$ für alle $i \in \mathbb{N}$.
- Wenn z von der Form $a^k b^l c^l$ ist und $z \notin \{b, c\}^*$, dann muss $k > 0$ gelten und wir zerlegen $z = uvw$ mit $u = \varepsilon, v = a, w = a^{k-1} b^l c^l$. Da $|v| = 1, |uv| \leq n$ und $uv^i w = a^{k+i-1} b^l c^l \in L$ für alle $i \in \mathbb{N}$, erfüllt L die Eigenschaften des Pumping-Lemmas.

Beweis, dass L nicht regulär ist folgt **später!**

Zusammenfassung Pumping-Lemma

- Das Pumping-Lemma formuliert **eine notwendige Bedingung** für **reguläre** Sprachen:

Sehr informell:

Wörter einer regulären Sprache können aufgepumpt werden, wenn sie lang genug sind.

- Anwendung:

L erfüllt die **Pumping-Eigenschaft nicht**

$\implies L$ **nicht regulär**

- Das Pumping-Lemma gibt **keine hinreichende Bedingung** für reguläre Sprachen, d.h. Regularität kann **nicht** mit dem Pumping-Lemma gezeigt werden.
- Nicht-Regularität widerlegen funktioniert nicht in jedem Fall mit dem Pumping-Lemma!

Die Nerode-Relation

Definition (Nerode-Relation \sim_L)

Sei L eine formale Sprache über Σ . Die **Nerode-Relation** $\sim_L \subseteq \Sigma^* \times \Sigma^*$ zu L ist definiert für alle Worte $u, v \in \Sigma^*$ durch:

$$u \sim_L v \iff \forall w \in \Sigma^* : uw \in L \iff vw \in L$$

Informell: $u \sim_L v$, wenn sich ihr Enthaltensein in L gleich verhält bezüglich beliebiger Erweiterung um denselben Suffix.

Beispiel: $L = \{ab^n \mid n \in \mathbb{N}\}$

- Gilt $a \sim_L ab$? ✓
- Gilt $a \sim_L b$? × (z.B. $w = \varepsilon$ oder $w = b^i$)
- Gilt $\varepsilon \sim_L a$? × (z.B. $w = b^i$ oder $w = ab^i$)
- Gilt $aa u \sim_L aav$ mit $u, v \in \{a, b\}^*$? ✓
- Gilt $ab^i \sim_L ab^j$? ✓
- Gilt $aa u \sim_L bv$ mit $u, v \in \{a, b\}^*$? ✓

Beispiel: Index

$L = \{ab^n \mid n \in \mathbb{N}\}$, $Index(\sim_L) = ?$

- $[\varepsilon]_{\sim_L} = \{\varepsilon\}$
- $[a]_{\sim_L} = \{a, ab, abb, abbb, \dots\}$
- $[aa]_{\sim_L} = \{aa u \mid u \in \{a, b\}^*\} \cup \{bu \mid u \in \{a, b\}^*\} \cup \{abuav \mid u, v \in \{a, b\}^*\}$
- $\{a, b\}^* = [\varepsilon]_{\sim_L} \cup [a]_{\sim_L} \cup [aa]_{\sim_L}$
- Daher $Index(\sim_L) = 3$

Die Nerode-Relation (2)

Satz

Die Nerode-Relation ist eine Äquivalenzrelation.

Beweis: einfach

Erinnerung: Index einer Äquivalenzrelation:

- Äquivalenzklasse $[u]_{\sim_L} = \{w \mid u \sim_L w\}$
- Der **Index** einer Äquivalenzrelation ist die **Anzahl ihrer disjunkten Äquivalenzklassen** $\Sigma^* = [u_1]_{\sim_L} \cup [u_2]_{\sim_L} \dots$
- Der Index kann auch unendlich sein.

Satz von Myhill und Nerode

Theorem (Satz von Myhill und Nerode)

Eine formale Sprache L ist genau dann **regulär**, wenn der **Index** von \sim_L **endlich** ist.

Unabhängig bewiesen von John Myhill (1957) und Anil Nerode (1958)

Damit haben wir eine genaue(!) Charakterisierung der regulären Sprachen

Beweis des Satzes von Myhill und Nerode

Teil 1: Wenn L regulär ist, dann ist der Index von \sim_L endlich.

- Sei L regulär und $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA mit $L(M) = L$.
- Sei $\approx_M \subseteq (\Sigma^* \times \Sigma^*)$ definiert als: $u \approx_M v \iff \widehat{\delta}(z_0, u) = \widehat{\delta}(z_0, v)$
„ $u \approx_M v$, wenn u, v auf M zum gleichen Zustand führen.“
- \approx_M ist eine Äquivalenzrelation
- $Index(\approx_M) = |Z|$ (und damit endlich)
- Wir zeigen: $u \approx_M v \implies u \sim_L v$ (d.h. \approx_M verfeinert \sim_L)
Dann gilt auch $Index(\sim_L) \leq Index(\approx_M) = |Z|$ (und damit endlich).
- Sei $u \approx_M v$ und $w \in \Sigma^*$. Dann gilt:

$$\begin{aligned}\widehat{\delta}(q_0, uw) &= \widehat{\delta}(\widehat{\delta}(q_0, u), w) \\ &= \widehat{\delta}(\widehat{\delta}(q_0, v), w) = \widehat{\delta}(q_0, vw)\end{aligned}$$

und damit $uw \in L \iff vw \in L$. Da w beliebig, zeigt dies $u \sim_L v$.

Beweis des Satzes von Myhill und Nerode

Teil 2: Wenn der Index von \sim_L endlich ist, dann ist L regulär.

- Sei der Index von \sim_L endlich.
- $\Sigma^* = [u_1]_{\sim_L} \cup \dots \cup [u_n]_{\sim_L}$ für $n \in \mathbb{N}_{>0}$
- Konstruiere **Nerode-Automaten**:
DFA $M = (Z, \Sigma, \delta, [\varepsilon]_{\sim_L}, E)$ mit
 - $Z = \{[u_1]_{\sim_L}, \dots, [u_n]_{\sim_L}\}$,
 - $\delta([u_i]_{\sim_L}, a) = [u_i a]_{\sim_L}$ für alle $a \in \Sigma$ und
 - $E = \{[u_i]_{\sim_L} \mid i \in \{1, \dots, n\}, u_i \in L\}$.
- Es gilt:
g.d.w. $w \in L(M)$
g.d.w. $\widehat{\delta}([\varepsilon]_{\sim_L}, w) \in E$
g.d.w. $[w]_{\sim_L} \subseteq L$
g.d.w. $w \in L$
Daher gilt: $L(M) = L$

Anwendung des Satzes von Myhill und Nerode

Da der Satz eine hinreichende und notwendige Bedingung für reguläre Sprachen liefert, könnte man ihn verwenden, um

- 1 Regularität nachzuweisen: Zeige $Index(\sim_L)$ ist endlich.
„oft einfacher: gebe endlichen Automaten an, die L akzeptiert“
- 2 Nichtregularität nachzuweisen: Zeige $Index(\sim_L)$ ist unendlich.
„wird insbesondere dann benutzt, wenn das Pumping-Lemma nicht funktioniert“

Wie zeigt man $Index(\sim_L) = \infty$?

Rezept: Finde unendlich viele Äquivalenzklassen $[u_1]_{\sim_L}, [u_2]_{\sim_L}, \dots$, die paarweise verschieden sind ($[u_i]_{\sim_L} \cap [u_j]_{\sim_L} = \emptyset$ für $i \neq j$):

- Finde für $i = 1, 2, \dots$ Worte u_i und w_i , sodass alle u_i paarweise verschieden und alle w_i paarweise verschieden und:
 $u_i w_i \in L$ aber $u_j w_i \notin L$ für alle $i \neq j$.
- Dann sind $[u_1]_{\sim_L}, [u_2]_{\sim_L}, [u_3]_{\sim_L}, \dots$ paarweise disjunkt

Beachte: Es ist **nicht** notwendig, **alle** Äquivalenzklassen der disjunkten Zerlegung von Σ^* zu finden!

Beispiel

Betrachte $L = \{a^n b^n \mid n \in \mathbb{N}_{>0}\}$ und deren Nerode-Relation \sim_L .

- Für $u_i = a^i b$ für $i \in \mathbb{N}_{>0}$ gilt:

$[u_i]_{\sim_L} =$ alle Worte, denen noch $i - 1$ b 's fehlen, um in L enthalten zu sein

$$\begin{aligned} [u_1]_{\sim_L} &= \{ab, a^2b^2, \dots\} = L \\ [u_2]_{\sim_L} &= \{a^2b, a^3b^2, a^4b^3, \dots\} \\ [u_3]_{\sim_L} &= \{a^3b, a^4b^2, a^5, b^3, \dots\} \\ &\dots \end{aligned}$$

- Sei $w_i = b^{i-1}$ für $i \in \mathbb{N}_{>0}$
- $u_i w_i = a^i b^i \in L$, aber $u_i w_j = a^i b^j \notin L$ für $i \neq j$
- Daher gilt: $[u_i]_{\sim_L} \cap [u_j]_{\sim_L} = \emptyset$ und $Index(\sim_L) = \infty$
- Mit dem Satz von Myhill und Nerode folgt: L ist nicht regulär.

Bemerkung: $a^i \notin [u_i]_{\sim_L}$, denn $a^i a b^{i+1} \in L$ aber $u_i a b^{i+1} \notin L$

Beispiel: Reguläre Sprache


Sei L Sprache über $\{a, b\}$ mit $L = \{uaav \mid uv \in \{a, b\}^*\}$

Die disjunkten Äquivalenzklassen von \sim_L sind:

- $[\varepsilon]_{\sim_L} =$ alle Worte ohne zwei aufeinanderfolgende a 's, die nicht mit a enden
- $[a]_{\sim_L} =$ alle Worte ohne zwei aufeinanderfolgende a 's, die mit a enden
- $[aa]_{\sim_L} = L$

Daher folgt $Index(\sim_L) = 3$ und L ist regulär.

Nerode-Automat dazu:



Nicht-reguläre Sprache, die die Pumping-Eigenschaft hat

Satz

Die Sprache $L = \{a^k b^l c^l \mid k, l \in \mathbb{N}\} \cup \{b, c\}^*$ ist nicht regulär.

Beweis:

- Betrachte $[u_i]_{\sim_L} = [ab^i c]_{\sim_L}$ für $i \in \mathbb{N}_{>0}$.
- Mit $w_i = c^{i-1}$ gilt:
 $u_i w_i = ab^i c^i \in L$, aber $u_i w_j = ab^i c^j \notin L$ für $i \neq j$.
- Daher sind alle $[u_i]_{\sim_L}$ disjunkt und $Index(\sim_L) = \infty$.
- Mit dem Satz von Myhill und Nerode folgt:
 L ist nicht regulär. □

Minimalautomat

Satz

Der Nerode-Automat einer regulären Sprache L ist der sogenannte **Minimalautomat**, d.h. jeder DFA M' , mit $L(M') = L$ hat mindestens so viele Zustände wie der Nerode-Automat. Zudem sind alle minimalen DFAs (bis auf Umbenennung von Zuständen) identisch.

Beweis (Teil 1): (Minimalität):

- Sei $M = (Z, \Sigma, \delta, z_0, E)$ der Nerode-Automat der Sprache L
- Sei $M' = (Z', \Sigma, \delta', z'_0, E')$ ein beliebiger DFA mit $L(M') = L$.
- Der Beweis des Satzes von Myhill und Nerode zeigt:
 - $\approx_{M'}$ ist eine Verfeinerung von \sim_L ($\approx_{M'} \subseteq \sim_L$)
 - $\approx_M = \sim_L$

Daher ist $Index(\approx_{M'}) \geq Index(\approx_M)$ und daher auch $|Z'| = Index(\approx_{M'}) \geq |Z| = Index(\approx_M)$.

Minimalautomat

Beweis (Teil 2): (alle minimalen DFA bis auf Umbenennung identisch):

- Sei $M = (Z, \Sigma, \delta, z_0, E)$ der Nerode-Automat der Sprache L und $M' = (Z', \Sigma, \delta', z'_0, E')$ ein minimaler DFA mit $L(M') = L$
- Minimalität impliziert $|Z| = |Z'|$.
- Da $\approx_{M'} \subseteq \sim_L$ gilt: $\approx_{M'} = \sim_L$.
- Da auch $\sim_L = \approx_M$ gilt, folgt:

$$f : Z \rightarrow Z' \text{ mit } f([u]_{\approx_M}) = f([u]_{\sim_L}) := [u]_{\approx_{M'}}$$

ist ein Isomorphismus auf den Zuständen

- Es gilt auch

$$\begin{aligned} f(\delta([u]_{\sim_L}, a)) &= f([ua]_{\sim_L}) \\ &= [ua]_{\approx_{M'}} \\ &= \delta'([u]_{\approx_{M'}}, a) \\ &= \delta'(f([u]_{\sim_L}), a) \end{aligned}$$

- D.h. die Automaten M und M' verhalten sich (bis auf die Umbenennung f) identisch.


Minimalautomaten: NFAs

Der vorherige Satz zeigt:

Der Nerode-Automat ist eindeutig und minimal.

Für **NFAs** gilt das im Allgemeinen nicht!

Beispiel:



Beide Automaten erkennen $\{ua \mid u \in \{a, b\}^*\}$ und haben eine minimale Zustandsanzahl, aber sind strukturell verschieden!

Äquivalenzklassenautomat

Definition (Äquivalenzklassenautomat)

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA. Wir nennen zwei Zustände $z, z' \in Z$ äquivalent und schreiben $z \equiv z'$ falls gilt:

$$\text{für alle } w \in \Sigma^* : \widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E.$$

Der **Äquivalenzklassenautomat** zu M ist der DFA

$M' = (Z', \Sigma, \delta', z'_0, E')$ mit

$$\begin{aligned} Z &= \{[z]_{\equiv} \mid z \in Z\}, \\ z'_0 &= [z_0]_{\equiv}, \\ E' &= \{[z]_{\equiv} \mid z \in E\} \text{ und} \\ \delta'([z]_{\equiv}, a) &= [\delta(z, a)]_{\equiv}. \end{aligned}$$

Äquivalenzklassenautomat (2)

Der Automat ist wohldefiniert:

- E' ist wohldefiniert:
Aus $z \equiv z'$ folgt, dass $z \in E \iff z' \in E$ gilt (dies folgt mit $w = \varepsilon$ aus $z \equiv z'$, denn $\widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E$)
- $\delta([z]_{\equiv}, a)$ ist eindeutig für alle $[z]_{\equiv} \in Z', a \in \Sigma$,
d.h. aus $z \equiv z'$ folgt $\delta(z, a) \equiv \delta(z', a)$:

Sei $z \equiv z'$, dann gilt $\widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E$ und damit auch $\widehat{\delta}(z, aw) \in E \iff \widehat{\delta}(z', aw) \in E$ und damit auch $\widehat{\delta}(\delta(z, a), w) \in E \iff \widehat{\delta}(\delta(z', a), w) \in E$. D. h. es gilt dann auch $\delta(z, a) \equiv \delta(z', a)$.

Äquivalenzklassenautomat: Korrektheit und Minimalität

Satz

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA und $M' = (Z', \Sigma, \delta', z'_0, E')$ der Äquivalenzklassenautomat zu M . Dann gilt

- 1 $L(M) = L(M')$
- 2 Falls alle Zustände in Z vom Startzustand z_0 erreichbar sind, dann ist M' minimal.

Beweis (Teil 1):

Sei $w \in \Sigma^*$. Dann gilt:

- M durchläuft die Zustandsfolge $q_0, \dots, q_{|w|}$ entlang w und akzeptiert w genau dann, wenn $q_{|w|} \in E$ gilt.
- M' durchläuft die Zustandsfolge $[q_0]_{\equiv}, \dots, [q_{|w|}]_{\equiv}$ und akzeptiert w genau dann, wenn $[q_{|w|}]_{\equiv} \in E'$ gilt.

Da per Definition $[q_{|w|}]_{\equiv} \in E'$ genau dann gilt, wenn $q_{|w|} \in E$ gilt, folgt, dass M und M' dieselben Worte akzeptieren.

Äquivalenzklassenautomat: Korrektheit und Minimalität(2)

Satz

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA und $M' = (Z', \Sigma, \delta', z'_0, E')$ der Äquivalenzklassenautomat zu M . Dann gilt

- 1 $L(M) = L(M')$
- 2 Falls alle Zustände in Z vom Startzustand z_0 erreichbar sind, dann ist M' minimal.

Beweis (Teil 2):

- Da alle $z \in Z$ erreichbar, sind alle $z' \in Z'$ erreichbar.
- Für Minimalität genügt es zu zeigen: $|Z'| \leq \text{Index}(\sim_L)$
- Zeige für jede Äquivalenzklasse $[v]_{\sim_L}$:
für alle $u \in [v]_{\sim_L}$ ist $\widehat{\delta}(z'_0, u)$ derselbe Zustand
(dann gibt es nicht mehr als $\text{Index}(\sim_L)$ erreichbare Zustände.)
- Da alle $z' \in Z'$ erreichbar, gilt damit $|Z'| = \text{Index}(\sim_L)$

Äquivalenzklassenautomat: Korrektheit und Minimalität(3)

Satz

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA und $M' = (Z', \Sigma, \delta', z'_0, E')$ der Äquivalenzklassenautomat zu M . Dann gilt

- 1 $L(M) = L(M')$
- 2 Falls alle Zustände in Z vom Startzustand z_0 erreichbar sind, dann ist M' minimal.

Beweis (Teil 2, Forts.):

- Seien $u, u' \in [v]_{\sim_L}$, d. h. $u \sim_L u'$. Dann gilt
 $\forall w \in \Sigma^* : uw \in L \iff u'w \in L$,
woraus folgt: $\forall w \in \Sigma^* : \widehat{\delta}(z'_0, uw) \in E' \iff \widehat{\delta}(z'_0, u'w) \in E'$
woraus folgt: $\forall w \in \Sigma^* : \widehat{\delta}(\widehat{\delta}(z'_0, u), w) \in E' \iff \widehat{\delta}(\widehat{\delta}(z'_0, u'), w) \in E'$
woraus folgt: $\widehat{\delta}(z'_0, u) \equiv \widehat{\delta}(z'_0, u')$
woraus folgt: $[\widehat{\delta}(z'_0, u)]_{\equiv} = [\widehat{\delta}(z'_0, u')]_{\equiv}$.

Zustandsminimierung von DFAs

Idee:

- Berechne äquivalente Zustände (bezüglich \equiv)
- Bilde Äquivalenzklassenautomat, indem äquivalente Zustände verschmolzen werden.

Berechnung äquivalenter Zustände

Ideen

- Markiere Paare von Zuständen, die **verschieden sein müssen** (initial alle $\{z, z'\}$ mit $z \in E, z' \notin E$).
- Vervollständige das Markieren, durch Untersuchen von Übergängen:
 - Wenn $\{z, z'\}$ noch nicht markiert: Prüfe für jedes $a \in \Sigma$, ob die beiden Nachfolger $\{\delta(z, a), \delta(z', a)\}$ markiert sind.
 - Falls ja, dann markiere $\{z, z'\}$.
 - Wiederhole, bis sich nichts mehr ändert.
- Alle am Ende unmarkierten Paare sind äquivalente Zustände..

Korrektheit

Satz

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA, der keine unerreichbaren Zustände hat. Algorithmus 3 berechnet äquivalente Zustandspaare von M und es gibt keine weitere äquivalenten Paare.

Beweis (Teil 1): Wird $\{z, z'\}$ markiert, dann gilt $z \not\equiv z'$.

- Wir zeigen: Für jedes markierte Paar $\{z, z'\}$ gibt es Wort w mit $\neg(\widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E)$
- Induktion über Anzahl Schleifeniterationen bis $\{z, z'\}$ markiert wird.
- Basis: 0 Iterationen, $\{z, z'\}$ wird vor der Schleife markiert, $w = \varepsilon$ erfüllt Behauptung.
- Schritt: Mehr als 0 Iterationen. Dann wird $\{z, z'\}$ markiert, weil es $a \in \Sigma$ und ein markiertes Paar $\{q, q'\}$ gibt mit $\delta(z, a) = q$ und $\delta(z', a) = q'$. Induktionsannahme liefert Wort w' mit $\neg(\widehat{\delta}(q, w') \in E \iff \widehat{\delta}(q', w') \in E)$.
- Mit $w = aw'$ folgt: $\neg(\widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E)$.

Algorithmus 3: Berechnung aller äquivalenten Zustände

Eingabe: DFA $M = (Z, \Sigma, \delta, z_0, E)$, der keine unerreichbaren Zustände hat
Ausgabe: Zustandspaare $\{z, z'\}$ mit $z \neq z'$ für die gilt $z \equiv z'$

Beginn

stelle Tabelle T aller Zustandspaare $\{z, z'\}$ mit $z \neq z'$ und $z, z' \in Z$ auf; markiere alle Paare $\{z, z'\}$ in T mit $z \in E$ und $z' \notin E$;

wiederhole

für jedes unmarkierte Paar $\{z, z'\}$ in T tue

für jedes $a \in \Sigma$ tue

wenn $\{\delta(z, a), \delta(z', a)\}$ in T markiert ist dann

markiere $\{z, z'\}$ in T ;

Ende

Ende

Ende

bis sich T nicht mehr verändert;

return $\{\{z, z'\} \mid \{z, z'\} \text{ ist nicht markiert in } T\}$

Ende

Korrektheit (2)

Satz

Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA, der keine unerreichbaren Zustände hat. Algorithmus 3 berechnet äquivalente Zustandspaare von M und es gibt keine weitere äquivalenten Paare.

Beweis (Teil 2): Wenn $z \not\equiv z'$, dann markiert Alg. 3 das Paar $\{z, z'\}$

- Beweis durch Widerspruch. Annahme es gibt Paare $z \not\equiv z'$, die Alg. 3 nicht markiert. Wähle Paar $\{z, z'\}$, für welches es ein **minimal langes** Wort w gibt mit $\neg(\widehat{\delta}(z, w) \in E \iff \widehat{\delta}(z', w) \in E)$.
- Wenn $w = \varepsilon$, dann wird $\{z, z'\}$ vor Schleife markiert. Widerspruch!
- Wenn $w = aw'$ mit $a \in \Sigma$, dann gilt: Wenn $\{\delta(z, a), \delta(z', a)\}$ vom Algorithmus markiert wird, dann auch $\{z, z'\}$. Daher: $\{\delta(z, a), \delta(z', a)\}$ wird nicht markiert. Aber dann gilt für w' :
 $\neg(\widehat{\delta}(\delta(z, a), w') \in E \iff \widehat{\delta}(\delta(z', a), w') \in E)$ und $|w'| < |w|$.
Widerspruch zur Minimalität!

- Darstellung der Tabelle T :
zweidimensionales Array der Größe $|Z| \times |Z|$
- Ermöglicht konstanten Zugriff auf Markierungen
- Pro Durchlauf der Schleife: $O(|Z|^2|\Sigma|)$
- Anzahl der Durchläufe ist durch $|Z|^2$ begrenzt, da es nur $|Z|^2$ Paare gibt und mindestens 1 Paar pro Durchlauf markiert wird
- Restliche Schritte: Konstante Laufzeit
- Daher: Algorithmus 3 kann in Zeit $O(|Z|^4 \cdot |\Sigma|)$ implementiert werden
- Tatsächlich gibt es effizientere Implementierungen:
 $O(|\Sigma| \cdot |Z| \log |Z|)$

Eingabe: DFA $M = (Z, \Sigma, \delta, z_0, E)$

Ausgabe: Minimaler DFA M' mit $L(M) = L(M')$


Beginn

- entferne Zustände aus M , die nicht vom Startzustand aus erreichbar sind;
- berechne äquivalente Zustände mit Algorithmus 3;
- erzeuge den Äquivalenzklassenautomaten, indem die berechneten äquivalenten Zustände vereinigt werden;

Ende

Beispiel zur Minimierung

Sei $\Sigma = \{a, b, c\}$ und der folgende DFA M gegeben:



z_1	X				
z_2	X				
z_3	X				
z_4	X	X	X	X	
z_5	X	X	X	X	
	z_0	z_1	z_2	z_3	z_4


- alle Zustände sind von z_0 aus erreichbar
- äquivalente Zustände berechnen: Tabelle T erstellen
- Initiales Markieren: $\{z, z'\}$ mit $z \in \{z_0, z_1, z_2, z_3\}$ und $z' \in \{z_4, z_5\}$
- $\{z_0, z_1\}$, da $\{\delta(z_0, c), \delta(z_1, c)\} = \{z_3, z_4\}$ bereits markiert ist,
- $\{z_0, z_2\}$, da $\{\delta(z_0, c), \delta(z_2, c)\} = \{z_3, z_4\}$ bereits markiert ist, und
- $\{z_0, z_3\}$, da $\{\delta(z_0, c), \delta(z_3, c)\} = \{z_3, z_5\}$ bereits markiert

Beispiel zur Minimierung (2)

Ergibt $z_1 \equiv z_3$, $z_1 \equiv z_2$, $z_2 \equiv z_3$, $z_4 \equiv z_5$ und daher die Äquivalenzklassen

$$[z_0]_{\equiv} = \{z_0\}, [z_1]_{\equiv} = \{z_1, z_2, z_3\}, [z_4]_{\equiv} = \{z_4, z_5\}$$

und den Minimalautomaten



Abschlusseigenschaften

Satz

Die regulären Sprachen sind abgeschlossen bezüglich Vereinigung, Produkt und Kleeneschem Abschluss.

Beweis:

Vereinigung, Produkt und Kleenescher Abschluss werden durch reguläre Ausdrücke erzeugt und sind daher reguläre Sprachen:

- Benutze reguläre Ausdrücke α_1, α_2 mit $L(\alpha_i) = L_i$.
- $(\alpha_1|\alpha_2)$ erzeugt $L(\alpha_1|\alpha_2) = L(\alpha_1) \cup L(\alpha_2) = L_1 \cup L_2$,
- $\alpha_1\alpha_2$ erzeugt $L(\alpha_1\alpha_2) = L(\alpha_1)L(\alpha_2) = L_1L_2$ und
- $(\alpha_1)^*$ erzeugt $L(\alpha_1)^* = L_1^*$.

Abschlusseigenschaften (2)

Satz

Die regulären Sprachen sind abgeschlossen bezüglich Komplementbildung.

Beweis:

- Sei $M = (Z, \Sigma, \delta, z_0, E)$ ein DFA der L akzeptiert.
- Dann akzeptiert $\bar{M} = (Z, \Sigma, \delta, z_0, Z \setminus E)$ die Sprache \bar{L} (d. h. das Komplement von L):
Offensichtlich gilt $(\hat{\delta}(z_0, w) \in E) \iff \neg(\hat{\delta}(z_0, w) \in Z \setminus E)$
- Daher ist \bar{L} regulär.

Abschlusseigenschaften (3)

Satz

Die regulären Sprachen sind abgeschlossen bezüglich Schnitt.

Beweis:

- Folgt aus $L_1 \cap L_2 = \overline{\overline{L_1} \cup \overline{L_2}}$ und da reguläre Sprachen abgeschlossen bez. Vereinigung und Komplementbildung.

Alternativ:

- Seien $M_1 = (Z_1, \Sigma, \delta_1, z_{01}, E_1)$ und $M_2 = (Z_2, \Sigma, \delta_2, z_{02}, E_2)$ DFAs, die $L_1 = L(M_1)$ und $L_2 = L(M_2)$ akzeptieren.
- **Produktautomat** von M_1 und M_2 ist der DFA $M = (Z_1 \times Z_2, \Sigma, \delta, (z_{01}, z_{02}), E_1 \times E_2)$ mit $\delta((z, z'), a) = (\delta_1(z, a), \delta_2(z', a))$ für alle $a \in \Sigma$ und $(z, z') \in Z_1 \times Z_2$.
- M akzeptiert $L_1 \cap L_2$, denn es gilt:
 $\hat{\delta}((z_{01}, z_{02}), w) \in (E_1, E_2) \iff (\hat{\delta}_1(z_{01}, w) \in E_1 \wedge \hat{\delta}_2(z_{02}, w) \in E_2)$.

Abschlusseigenschaften zusammengefasst

Theorem (Abschlusseigenschaften der regulären Sprachen)

Die regulären Sprachen sind abgeschlossen bezüglich Vereinigung, Schnitt, Komplementbildung, Produkt und Kleeneschem Abschluss.

Nichtregularität zeigen mit Abschlusseigenschaften (1)

Satz

Die Sprache $L = \{a^n \mid n \text{ ist keine Primzahl}\}$ ist nicht regulär.

Beweis durch Widerspruch:

- Annahme L ist regulär.
- Dann ist \bar{L} auch regulär.
- $\bar{L} = \{a\}^* \setminus L = \{a^n \mid n \text{ ist eine Primzahl}\}$ ist nicht regulär (bereits gezeigt)
- Widerspruch! Daher ist L nicht regulär.

Entscheidbarkeitsresultate: Wortproblem

- Bereits gezeigt: Das Wortproblem für Typ 1,2,3-Sprachen ist entscheidbar.
- Für DFAs ist das Wortproblem in Linearzeit in der Länge des Wortes lösbar, denn die Berechnung von $\hat{\delta}(z_0, w)$ braucht für einen DFA nur $|w|$ Schritte.


Nichtregularität zeigen mit Abschlusseigenschaften (2)

Satz

Die Sprache $L = \{w \in \{a, b\}^* \mid \#_a(w) = \#_b(w)\}$ ist nicht regulär.

Beweis durch Widerspruch:

- Annahme: L ist regulär.
- Sprache $L' = \{a^n b^m \mid n, m \in \mathbb{N}\}$ ist regulär, da der folgende NFA mit ε -Übergängen L' erkennt:



- Da L und L' regulär sind, ist auch $L \cap L'$ regulär.
- $L \cap L' = \{a^j b^j \mid j \in \mathbb{N}\}$ ist aber nicht regulär (wie bereits gezeigt)
- Widerspruch! D.h. L ist nicht regulär.

Entscheidbarkeitsresultate: Leerheitsproblem

Satz

Das Leerheitsproblem für reguläre Sprachen ist entscheidbar.

Beweis:

- Sei L reguläre Sprache und sei M ein DFA mit $L(M) = L$.
- Dann gilt $L = \emptyset$ genau dann, wenn es keinen Pfad vom Startzustand zu einem Endzustand in M gibt.
- Dies kann man leicht mit einer Tiefensuche auf dem Zustandsgraph von M überprüfen.

Endlichkeitsproblem für reguläre Sprachen

Satz

Das Endlichkeitsproblem für reguläre Sprachen ist entscheidbar.

Beweis:

- Sei L regulär und M ein DFA mit $L(M) = L$
- Es gilt $|L| < \infty$ g.d.w. es keinen Pfad vom Startzustand zu einem Endzustand gibt, der eine Schleife enthält.
- Prüfe dies mit einer Tiefensuche auf dem Zustandsgraph von M .

Schnittproblem für reguläre Sprachen

Satz

Das Schnittproblem für reguläre Sprachen ist entscheidbar.

Beweis:

- Seien L_1, L_2 reguläre Sprachen.
- Seien M_1, M_2 DFAs mit $L(M_i) = L_i$.
- Berechne den Produktautomaten M mit $L(M) = L_1 \cap L_2$
- Prüfe das Leerheitsproblem für $L(M)$.

Äquivalenzproblem für reguläre Sprachen

Satz

Das Äquivalenzproblem für reguläre Sprachen ist entscheidbar.

Beweis:

- Seien L_1, L_2 reguläre Sprachen.
- Seien M_1, M_2 DFAs mit $L(M_i) = L_i$.
- Berechne die Minimalautomaten von M_1 und M_2
- Prüfe die Minimalautomaten auf Isomorphie.

Zusammenfassung

- Pumping-Lemma
(Pumping-Eigenschaft notwendig, nicht hinreichend!)
- Der Satz von Myhill-Nerode:
 L regulär g.d.w. $Index(\sim_L) < \infty$
- Nicht-Regularität nachweisen:
Pumping-Lemma oder $Index(\sim_L) = \infty$
- Äquivalenzklassenautomat und Minimierung von DFAs
- Abschlusseigenschaften regulärer Sprachen
- Entscheidbarkeitsresultate für reguläre Sprachen