

# Theoretische Grundlagen des Software Engineering

## 2: Eigenschaften von regulären Sprachen

Stephan Schulz  
schulz@eprover.org

# Alphabet

**Definition:** Ein **Alphabet**  $\Sigma$  ist eine nichtleere, endliche Menge von Symbolen.

- ▶ Die Symbole heißen auch **Buchstaben** oder **Zeichen** des Alphabets.

Beispiele:

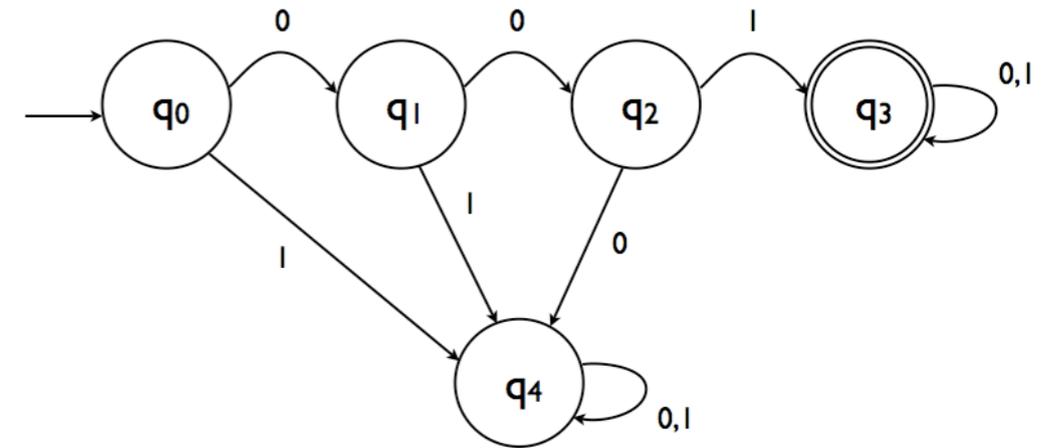
- ▶  $\Sigma = \{0, 1\}$  (Binäralphabet)
- ▶  $\Sigma = \{a, \dots, z\}$  (Kleinbuchstaben)
- ▶  $\Sigma = \{x \mid x \text{ ist ein ASCII-Zeichen}\}$

# Endliche Automaten: Formale Definition

**Definition:** Ein (deterministischer) endlicher Automat ist ein 5-Tupel  $A=(Q, \Sigma, \delta, q_0, F)$ , wobei

- ▶  $Q$  ist eine endliche Menge (die Zustände)
- ▶  $\Sigma$  ist ein Alphabet
- ▶  $\delta:Q\times\Sigma\rightarrow Q$  ist die Übergangsfunktion
- ▶  $q_0\in Q$  ist der Startzustand
- ▶  $F\subseteq Q$  ist die Menge der akzeptierenden Zustände

# Beispiel EA

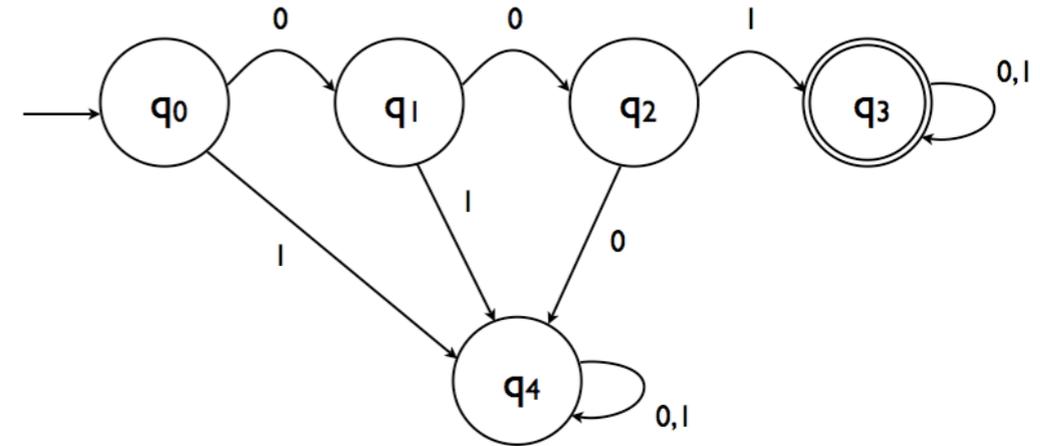


$$A = (Q, \Sigma, \delta, q_0, F)$$

- ▶  $Q = \{q_0, q_1, q_2, q_3, q_4\}$
- ▶ Der Startzustand ist  $q_0$
- ▶  $\Sigma = \{0, 1\}$
- ▶  $F = \{q_3\}$

$\delta$	0	1
$q_0$	$q_1$	$q_4$
$q_1$	$q_2$	$q_4$
$q_2$	$q_4$	$q_3$
$q_3$	$q_3$	$q_3$
$q_4$	$q_4$	$q_4$

# Automaten als Übergangstabellen



$$A = (Q, \Sigma, \delta, q_0, F)$$

▶  $\Sigma = \{0, 1\}$

▶  $Q = \{q_0, q_1, q_2, q_3, q_4\}$

▶ Der Startzustand ist  $q_0$

▶  $F = \{q_3\}$

$\delta$		0 1	
		0	1
→	$q_0$	$q_1$	$q_4$
	$q_1$	$q_2$	$q_4$
	$q_2$	$q_4$	$q_3$
*	$q_3$	$q_3$	$q_3$
	$q_4$	$q_4$	$q_4$

# Automaten als Übergangstabellen

$$A = (Q, \Sigma, \delta, q_0, F)$$

- ▶  $\Sigma$  implizit aus Tabelle
- ▶  $Q$  implizit aus Tabelle
- ▶  $q_0$ : Markiert mit  $\rightarrow$
- ▶  $F$ : Markiert mit  $*$
- ▶  $\delta$ : Tabelle

Automat ist vollständig beschrieben!

$\delta$		0 1	
		0	1
$\rightarrow$	$q_0$	$q_1$	$q_4$
	$q_1$	$q_2$	$q_4$
	$q_2$	$q_4$	$q_3$
$*$	$q_3$	$q_3$	$q_3$
	$q_4$	$q_4$	$q_4$

# $L(A)$

**Definition:** Sei  $A = (Q, \Sigma, \delta, q_0, F)$  ein endlicher Automat

- ▶  $A$  **akzeptiert** ein Wort  $w \in \Sigma^*$ , wenn er beim Start in Zustand  $q_0$  nach Verarbeitung des Wortes in einem Zustand  $q \in F$  ist
- ▶  $L(A) = \{w \in \Sigma^* \mid A \text{ akzeptiert } w\}$  ist die **Sprache von  $A$** 
  - Auch: "A erkennt  $L(A)$ "

# Erweiterte Übergangsfunktion

Idee:

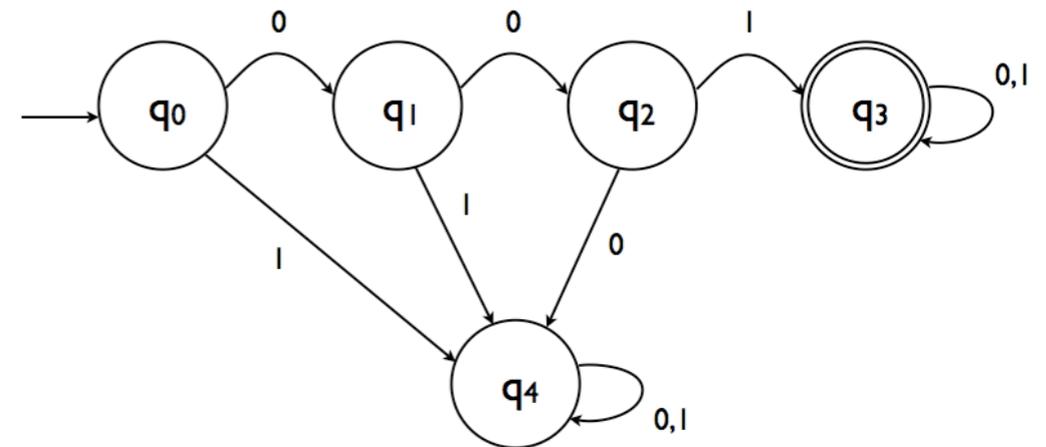
- ▶ Die Übergangsfunktion  $\delta$  ist auf Tupeln  $(q, a) \in Q \times \Sigma$  definiert, wobei  $a$  ein Zeichen des Alphabets ist.
- ▶ Wir wollen die Übergangsfunktion zu einer Funktion  $\hat{\delta} : Q \times \Sigma^* \rightarrow Q$  auf Zuständen und Worten erweitern
- ▶  $\hat{\delta}$  berechnet zu einem Zustand  $q$  und einem Wort  $w$  den Zustand, den der Automat bei Start in  $q$  nach Abarbeitung von  $w$  hat

# Erweiterte Übergangsfunktion

**Definition:** Sei  $A = (Q, \Sigma, \delta, q_0, F)$  ein endlicher Automat mit Übergangsfunktion  $\delta$ . Die **erweiterte Übergangsfunktion**  $\hat{\delta}$  ist rekursiv definiert wie folgt:

- ▶  $\hat{\delta}(q, x) = q$  falls  $x = \epsilon$  (Basisfall)
- ▶ Ansonsten kann  $x$  als  $wa$  mit  $w \in \Sigma^*$  und  $a \in \Sigma$  geschrieben werden und es gilt  $\hat{\delta}(q, wa) = \delta(\hat{\delta}(q, w), a)$

# Beispiel



$$\begin{aligned}
 \hat{\delta}(q_0, 00101) &= \delta(\hat{\delta}(q_0, 0010), 1) \\
 &= \delta(\delta(\hat{\delta}(q_0, 001), 0), 1) \\
 &= \delta(\delta(\delta(\hat{\delta}(q_0, 00), 1), 0), 1) \\
 &= \delta(\delta(\delta(\delta(\hat{\delta}(q_0, 0), 0), 1), 0), 1) \\
 &= \delta(\delta(\delta(\delta(\delta(\hat{\delta}(q_0, \epsilon), 0), 0), 1), 0), 1) \\
 &= \delta(\delta(\delta(\delta(\delta(q_0, 0), 0), 1), 0), 1) \\
 &= \delta(\delta(\delta(\delta(q_1, 0), 1), 0), 1) \\
 &= \delta(\delta(\delta(q_2, 1), 0), 1) \\
 &= \delta(\delta(q_3, 0), 1) \\
 &= \delta(q_3, 1) \\
 &= q_3
 \end{aligned}$$

$\delta$	0	1
q0	q1	q4
q1	q2	q4
q2	q4	q3
q3	q3	q3
q4	q4	q4

# Verträglichkeit von $\hat{\delta}$

**Lemma 1:** Sei  $A = (Q, \Sigma, \delta, q_0, F)$  ein endlicher Automat. Dann gilt für alle  $u, v \in \Sigma^*$ ,  $q \in Q$ :  $\hat{\delta}(q, uv) = \hat{\delta}(\hat{\delta}(q, u), v)$

## Verträglichkeit von $\hat{\delta}$

**Lemma I:** Sei  $A = (Q, \Sigma, \delta, q_0, F)$  ein endlicher Automat. Dann gilt für alle  $u, v \in \Sigma^*$ ,  $q \in Q$ :  $\hat{\delta}(q, uv) = \hat{\delta}(\hat{\delta}(q, u), v)$

**Beweis:** Induktion nach  $|v|$

**IA:**  $|v|=0$ , also  $|v|=\epsilon$ .

▶ Dann gilt:  $\hat{\delta}(q, uv) = \hat{\delta}(q, u) = \hat{\delta}(\hat{\delta}(q, u), \epsilon) = \hat{\delta}(\hat{\delta}(q, u), v) \quad \checkmark$

**IV:** Behauptung gelte für  $v$  mit  $|v|=k$

**IS:**  $k \rightarrow k+1$ . Sei also o.B.d.A.  $v=wa$ ,  $w \in \Sigma^*$ ,  $a \in \Sigma$ .

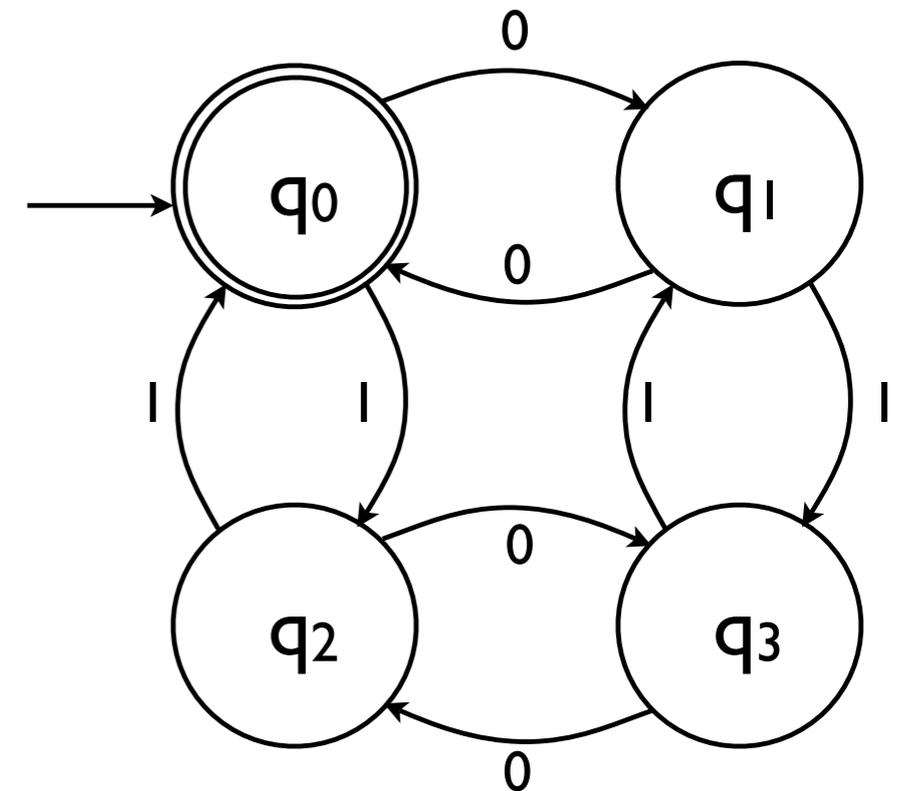
▶  $\hat{\delta}(q, uv) = \hat{\delta}(q, uwa) = \delta(\hat{\delta}(q, uw), a)$

$=_{(IV)} \delta(\hat{\delta}(\hat{\delta}(q, u), w), a) = \hat{\delta}(\hat{\delta}(q, u), wa) = \hat{\delta}(\hat{\delta}(q, u), v) \quad \checkmark \quad \text{q.e.d.}$

# Beispiel

$$\begin{aligned} \hat{\delta}(q_0, 00101101) &= q_0 \\ &= \hat{\delta}(\hat{\delta}(0010), 1101) \\ &= \hat{\delta}(q_3, 1101) \end{aligned}$$

$$\begin{aligned} \hat{\delta}(q_0, 0111100) &= \hat{\delta}(\hat{\delta}(q_0, 011), 11100) \\ &= \hat{\delta}(q_1, 11100) = q_3 \end{aligned}$$



$\delta$	0	1
$\rightarrow^* q_0$	$q_1$	$q_4$
$q_1$	$q_2$	$q_4$
$q_2$	$q_4$	$q_3$
$q_3$	$q_3$	$q_3$

# $L(A)$ und reguläre Sprachen

**Definition:** Sei  $A = (Q, \Sigma, \delta, q_0, F)$  ein endlicher Automat und  $\hat{\delta}$  die erweiterte Übergangsfunktion zu  $\delta$ .

- ▶  $A$  **akzeptiert** ein Wort  $w \in \Sigma^*$ , wenn  $\hat{\delta}(q_0, w) \in F$
- ▶  $L(A) = \{w \in \Sigma^* \mid \hat{\delta}(q_0, w) \in F\}$  ist die **Sprache von  $A$**
- ▶ Eine Sprache  $L$  heißt **reguläre Sprache**, wenn es einen endlichen Automaten  $A$  gibt, so dass  $L = L(A)$

# Grenzen

**Theorem 1:** Es gibt Sprachen, die nicht regulär sind.

**Beweis:** Allgemein später (“Pumping Lemma”). En Detail:

▶ Idee:

- Endliche Automaten haben nur endlich viel Speicher
- Manche Sprachen erfordern unbeschränktes Gedächtnis
- Einfaches Beispiel:  $\{a^n b^n \mid n \in \mathbf{N}\} = \{ab, aabb, aaabbb, \dots\}$  ist nicht regulär

# Beweis (I)

**Behauptung:** Sei  $\Sigma = \{a, b\}$  und  $L = \{a^n b^n \mid n \in \mathbf{N}\}$ . Dann existiert kein endlicher Automat  $A$  mit  $L(A) = L$ .

Beweis per Widerspruch.

Annahme: Es existiert EA  $A = (Q, \Sigma, \delta, q_0, F)$  mit  $L(A) = L$ .

- ▶ Sei  $k = |Q|$
- ▶ Betrachte  $w = a^{k+1}$ . Es existieren  $i, j \in \mathbf{N}$  mit  $1 \leq i < j \leq k+1$  so dass  $\hat{\delta}(q_0, a^i) = \hat{\delta}(q_0, a^j)$ , denn  $A$  muss beim Verarbeiten von  $a^{k+1}$  mindestens einen Zustand mehrfach durchlaufen.
- ▶ Sei  $x = a^i$ ,  $u = a^{j-i}$ ,  $v = a^{k+1-j}$ . Dann ist  $w = xuv$  und  $xv = a^{k+1-(j-i)}$

## Beweis (2)

- ▶ Nach Konstruktion gilt  $\hat{\delta}(q_0, x) = \hat{\delta}(q_0, xu)$ .
- ▶ Nach Lemma I gilt:
  - $\hat{\delta}(q_0, xuv) = \hat{\delta}(\hat{\delta}(q_0, xu), v) = \hat{\delta}(\hat{\delta}(q_0, x), v) = \hat{\delta}(q_0, xv)$
- ▶ Sei  $\hat{\delta}(q_0, a^{k+1}b^{k+1}) = q$ . Nach Lemma I gilt weiter:

$$\begin{aligned}
 q = \hat{\delta}(q_0, a^{k+1}b^{k+1}) &= \hat{\delta}(\hat{\delta}(q_0, a^{k+1}), b^{k+1}) \\
 &= \hat{\delta}(\hat{\delta}(q_0, xuv), b^{k+1}) \\
 &= \hat{\delta}(\hat{\delta}(q_0, xv), b^{k+1}) \\
 &= \hat{\delta}(q_0, xvb^{k+1}) \\
 &= \hat{\delta}(q_0, a^{k+1-(j-i)}b^{k+1})
 \end{aligned}$$

# Beweis (3)

## Fallunterscheidung

### ▶ Fall 1: $q \in F$

- Dann  $a^{k+1-(j-i)}b^{k+1} \in L(A)$ , also  $L(A) \neq \{a^n b^n \mid n \in \mathbf{N}\}$ 
  - Widerspruch zur Annahme!

### ▶ Fall 2: $q \notin F$

- Dann  $a^{k+1}b^{k+1} \notin L(A)$ , also  $L(A) \neq \{a^n b^n \mid n \in \mathbf{N}\}$ 
  - Widerspruch zur Annahme!

## Beweis (4) (für ganz genaue)

Fall 1 und Fall 2 decken alle Möglichkeiten ab. Die Annahme es existiert EA  $A=(Q, \Sigma, \delta, q_0, F)$  mit  $L(A)=L$  ist also falsch.

Ergo: Es existiert kein endlicher Automat mit  $L(A)=L$

$\Rightarrow L(A)$  ist keine reguläre Sprache

q.e.d.

# Operationen auf Sprachen

## Definition:

- ▶ Sei  $A$  eine Menge,  $B \subseteq A$ . Das **Komplement von  $B$**  (in Bezug auf  $A$ ) ist die Menge  $\overline{B} = A \setminus B$
- ▶ Seien  $A, B \subseteq \Sigma^*$  Mengen von Worten über einem Alphabet  $\Sigma$ .
  - $A \circ B = \{ab \mid a \in A, b \in B\}$  ist die Konkatenation von  $A$  und  $B$
  - $A^* = \{x_1 x_2 \dots x_n \mid n \in \mathbf{N}_0\}$  ist der **(Kleene-)Abschluss** von  $A$ , der  $*$ -Operator heisst auch der **“Kleene-Star”**.

# Anmerkung

Der \*-Operator hat auf Alphabeten und Sprachen ähnliche, aber verschiedene Wirkung.

- ▶  $\Sigma^*$  ist die Menge der Worte, die aus Buchstaben von  $\Sigma$  gebildet werden kann.
- ▶  $L^*$  ist die Menge der Worte, die durch Konkatenation von Worten aus  $L$  gebildet werden kann.

*Stephen Cole Kleene (1909-1994)*, Schüler von Alonzo Church, wichtige Beiträge zu Sprachen (reguläre Ausdrücke!) und Berechenbarkeitstheorie.

# Beispiele



Sei  $\Sigma = \{h, o, i, e\}$  und  $L_1 = \{ho, hi\}$ ,  $L_2 = \{he, di\}$

$$\Sigma^* = \{\epsilon, h, o, i, e, hh, ho, hi, he, oh, oo, oi, oe, ih, ih, ii, ie, eh, eo, ei, ee, hhh, hoh, hih, heh, \dots\}$$

$$L_1 \cup L_2 = \{ho, hi, he, di\}$$

$$L_1 \circ L_2 = \{hohe, hode, hihe, hidi\}$$

$$L_2 \circ L_1 = \{heho, hehi, diho, dihi\}$$

$$L_1^* = \{\epsilon, ho, hi, hohi, hiho, hoho, hiho, \dots\}$$

$$L_1^* \cup L_2^* = \{\epsilon, ho, hi, he, di, hoho, hohi, hihi, hiho, hehe, hedi, didi, dihe, \dots\}$$

$$(L_1 \cup L_2)^* = \text{Minnie the Moocher}$$

## Beispiele (2)

Sei  $\Sigma = \{0, 1\}$ ,  $L_1 = \{0\}^*$ ,  $L_2 = \{1\}^*$

$$\Sigma^* = \{\epsilon, 0, 1, 00, 01, 10, 11, 000, 001, 010, \dots\}$$

$$L_1 \cup L_2 = \{\epsilon, 0, 1, 00, 11, 000, 111, 0000, 1111, \dots\}$$

$$L_1 \circ L_2 = \{\epsilon, 0, 1, 00, 11, 001, 011, 000, 111, \dots\} = \{0^i 1^j\}$$

$$\overline{L_1} = \{w \in \Sigma^* \mid w \text{ enthält mindestens eine } 1\}$$

$$L_1^* = L_1$$

$$L_1^* \cup L_2^* = L_1 \cup L_2$$

$$(L_1 \cup L_2)^* = \Sigma^*$$

# Abgeschlossenheit

**Theorem 2:** Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen.

- (a)  $\overline{L_1}$  ist eine reguläre Sprache.
- (b)  $L_1 \cup L_2$  ist eine reguläre Sprache.
- (c)  $L_1 \cap L_2$  ist eine reguläre Sprache.
- (d)  $L_1 \circ L_2$  ist eine reguläre Sprache.
- (e)  $L_1^*$  ist eine reguläre Sprache.
- (f) Jede endliche Sprache ist regulär

## Beweis (Theorem 2a)

**Behauptung:** Sei  $L_1$  eine reguläre Sprache. Dann ist  $\overline{L_1}$  eine reguläre Sprache.

**Beweis:**  $L_1$  ist reguläre Sprache.

- ▶ Dann existiert EA  $A=(Q, \Sigma, \delta, q_0, F)$  mit  $L(A)=L_1$
- ▶ Betrachte  $A'=(Q, \Sigma, \delta, q_0, F')$  mit  $F'=Q \setminus F (= \overline{F})$
- ▶  $L(A') = \overline{L_1}$ , denn:
  - Fall 1:  $w \in L(A) \Rightarrow \hat{\delta}(q_0, w) \in F \Rightarrow \hat{\delta}(q_0, w) \notin F' \Rightarrow w \notin L(A')$
  - Fall 2:  $w \notin L(A) \Rightarrow \hat{\delta}(q_0, w) \notin F \Rightarrow \hat{\delta}(q_0, w) \in F' \Rightarrow w \in L(A')$
- ▶ Also: Es existiert EA  $A'$  mit  $L(A') = \overline{L_1}$ , also ist  $\overline{L_1}$  regulär

## Beweis (Theorem 2b)

**Behauptung:** Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen. Dann gilt:  
 $L_1 \cup L_2$  ist eine reguläre Sprache.



Idee?

# Beispiel

**Definition:** Sei  $w \in \Sigma^*$ ,  $a \in \Sigma$ .  $|w|_a$  bezeichnet die Anzahl von Vorkommen von  $a$  in  $w$ .

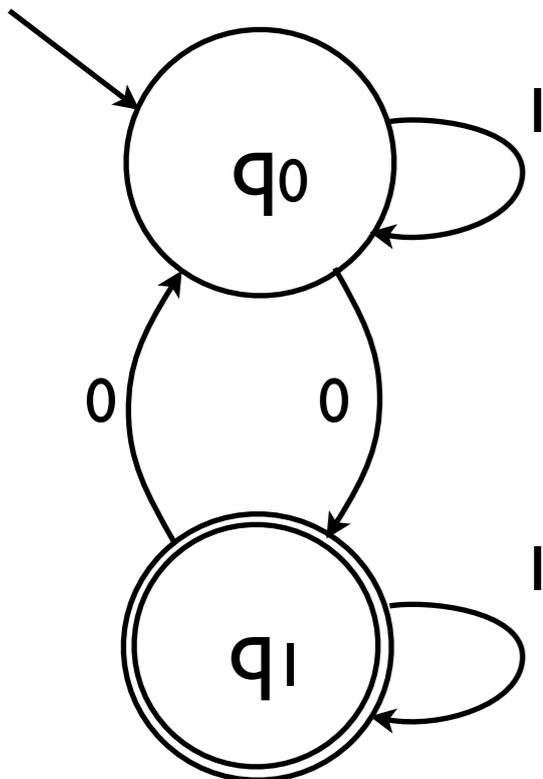
**Beispiel:** Sei  $\Sigma = \{0, 1\}$

- ▶  $L_1 = \{w \mid |w|_0 \bmod 2 = 1\}$ ,  $L_2 = \{w \mid |w|_1 \bmod 3 = 0\}$ 
  - $L_1$  ist die Menge aller Worte mit einer ungeraden Zahl von Vorkommen von 0. Z.B.  $\{0, 110, 00101\} \subseteq L_1$
  - $L_2$  ist die Menge aller Worte, bei denen die Anzahl der Vorkommen von 1 durch 3 teilbar ist.  
Z.B.  $\{\epsilon, 111, 10101\} \subseteq L_2$

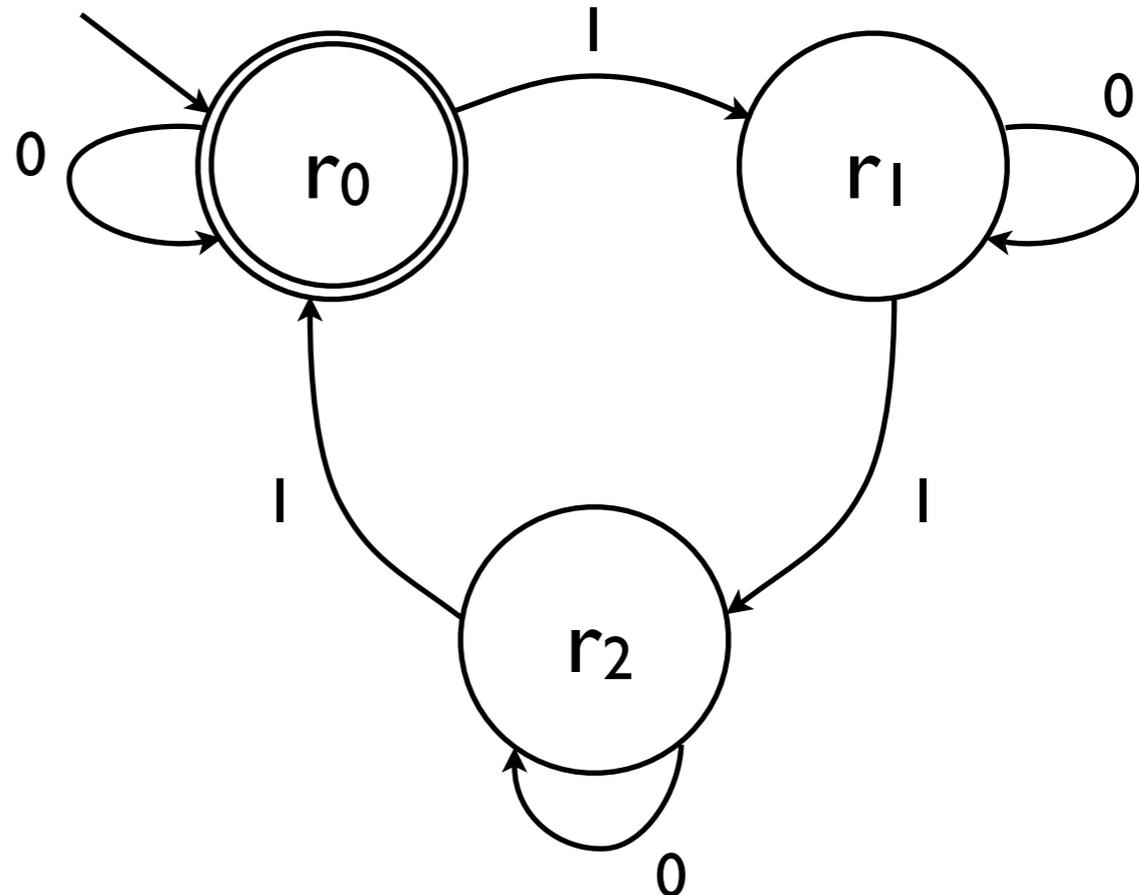
# Beispiel (fortgesetzt)

$L_1 = \{w \mid |w|_0 \bmod 2 = 1\}$ ,  $L_2 = \{w \mid |w|_1 \bmod 3 = 0\}$  sind regulär.

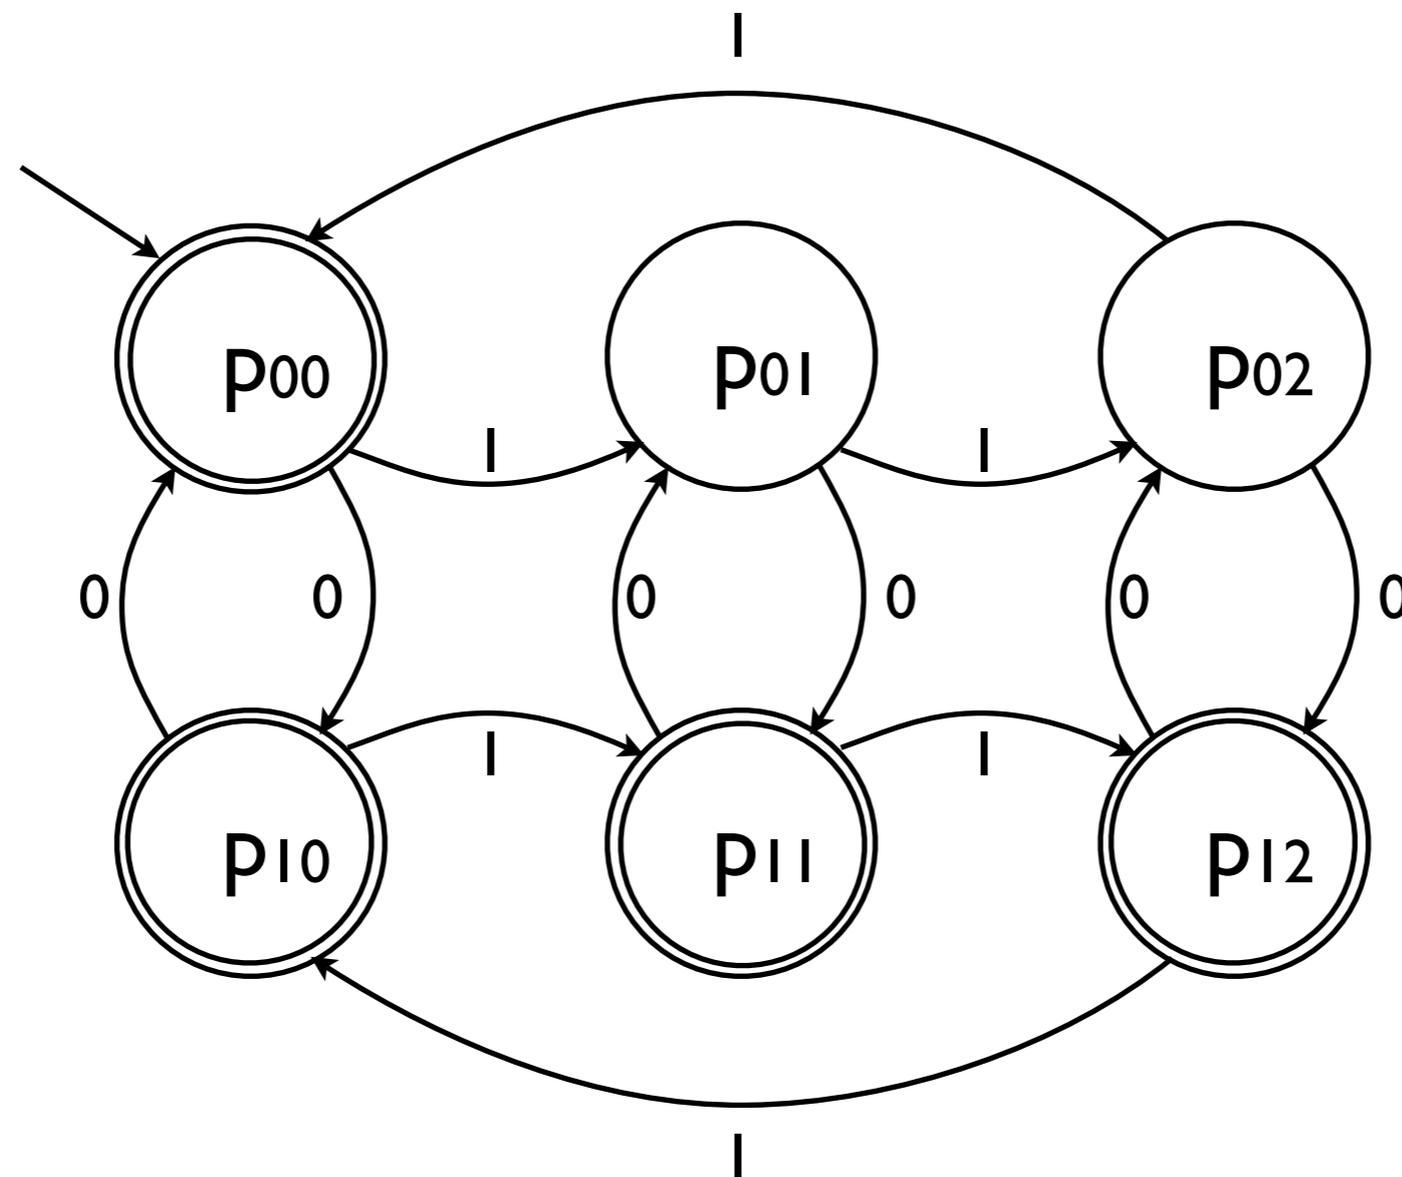
$L_1$



$L_2$



# Beispiel - EA für $L_1UL_2$ ?



## Beweis (Theorem 2b)

**Behauptung:** Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen. Dann gilt:  
 $L_1 \cup L_2$  ist eine reguläre Sprache.

Beweisidee:

- ▶ Per Definition existieren endliche Automaten  $A_1$  und  $A_2$  mit  $L_1 = L(A_1)$  und  $L_2 = L(A_2)$ . Wir konstruieren einen endlichen Automaten  $A$  aus  $A_1$  und  $A_2$  so, dass  $L(A) = L_1 \cup L_2$ .
- ▶ Zustände von  $A$  sind Paare von Zuständen aus  $A_1$  bzw  $A_2$ .
- ▶ Akzeptierende Zustände sind Zustände, in denen ein Element des Paares in seinem Automaten akzeptiert.

# Beweis (Theorem 2b, fortgesetzt)

Also:

- ▶  $L_1$  ist regulär  $\Rightarrow \exists A_1 = (Q_1, \Sigma, \delta_1, q_1, F_1)$  mit  $L_1 = L(A_1)$
- ▶  $L_2$  ist regulär  $\Rightarrow \exists A_2 = (Q_2, \Sigma, \delta_2, q_2, F_2)$  mit  $L_2 = L(A_2)$
- ▶ Konstruiere  $A = (Q, \Sigma, \delta, q_0, F)$  wie folgt....

# Beweis (Theorem 2b, fortgesetzt)

- ▶ Konstruiere  $A=(Q, \Sigma, \delta, q_0, F)$  wie folgt:
  - $Q=Q_1 \times Q_2$
  - $\Sigma$  bleibt unverändert
  - $q_0=(q_1, q_2)$
  - $F=\{(r,s) \mid r \in F_1 \text{ oder } s \in F_2\}$
  - $\delta((r,s), a)=(\delta_1(r, a), \delta_2(s, a))$  für alle  $r \in Q_1, s \in Q_2, a \in \Sigma$
- ▶ Dann gilt:  $L(A) = L_1 \cup L_2$ . Formal: Induktion!

Beachte:  $|Q| = |Q_1| \cdot |Q_2|$  - Also: A kann deutlich größer werden.

## Beweis (Theorem 2c)

**Behauptung:** Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen. Dann gilt:  
 $L_1 \cap L_2$  ist eine reguläre Sprache.



Übung!

# Beweis (Theorem 2d+2e)

**Behauptung:** Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen.

(d)  $L_1 \circ L_2$  ist eine reguläre Sprache.

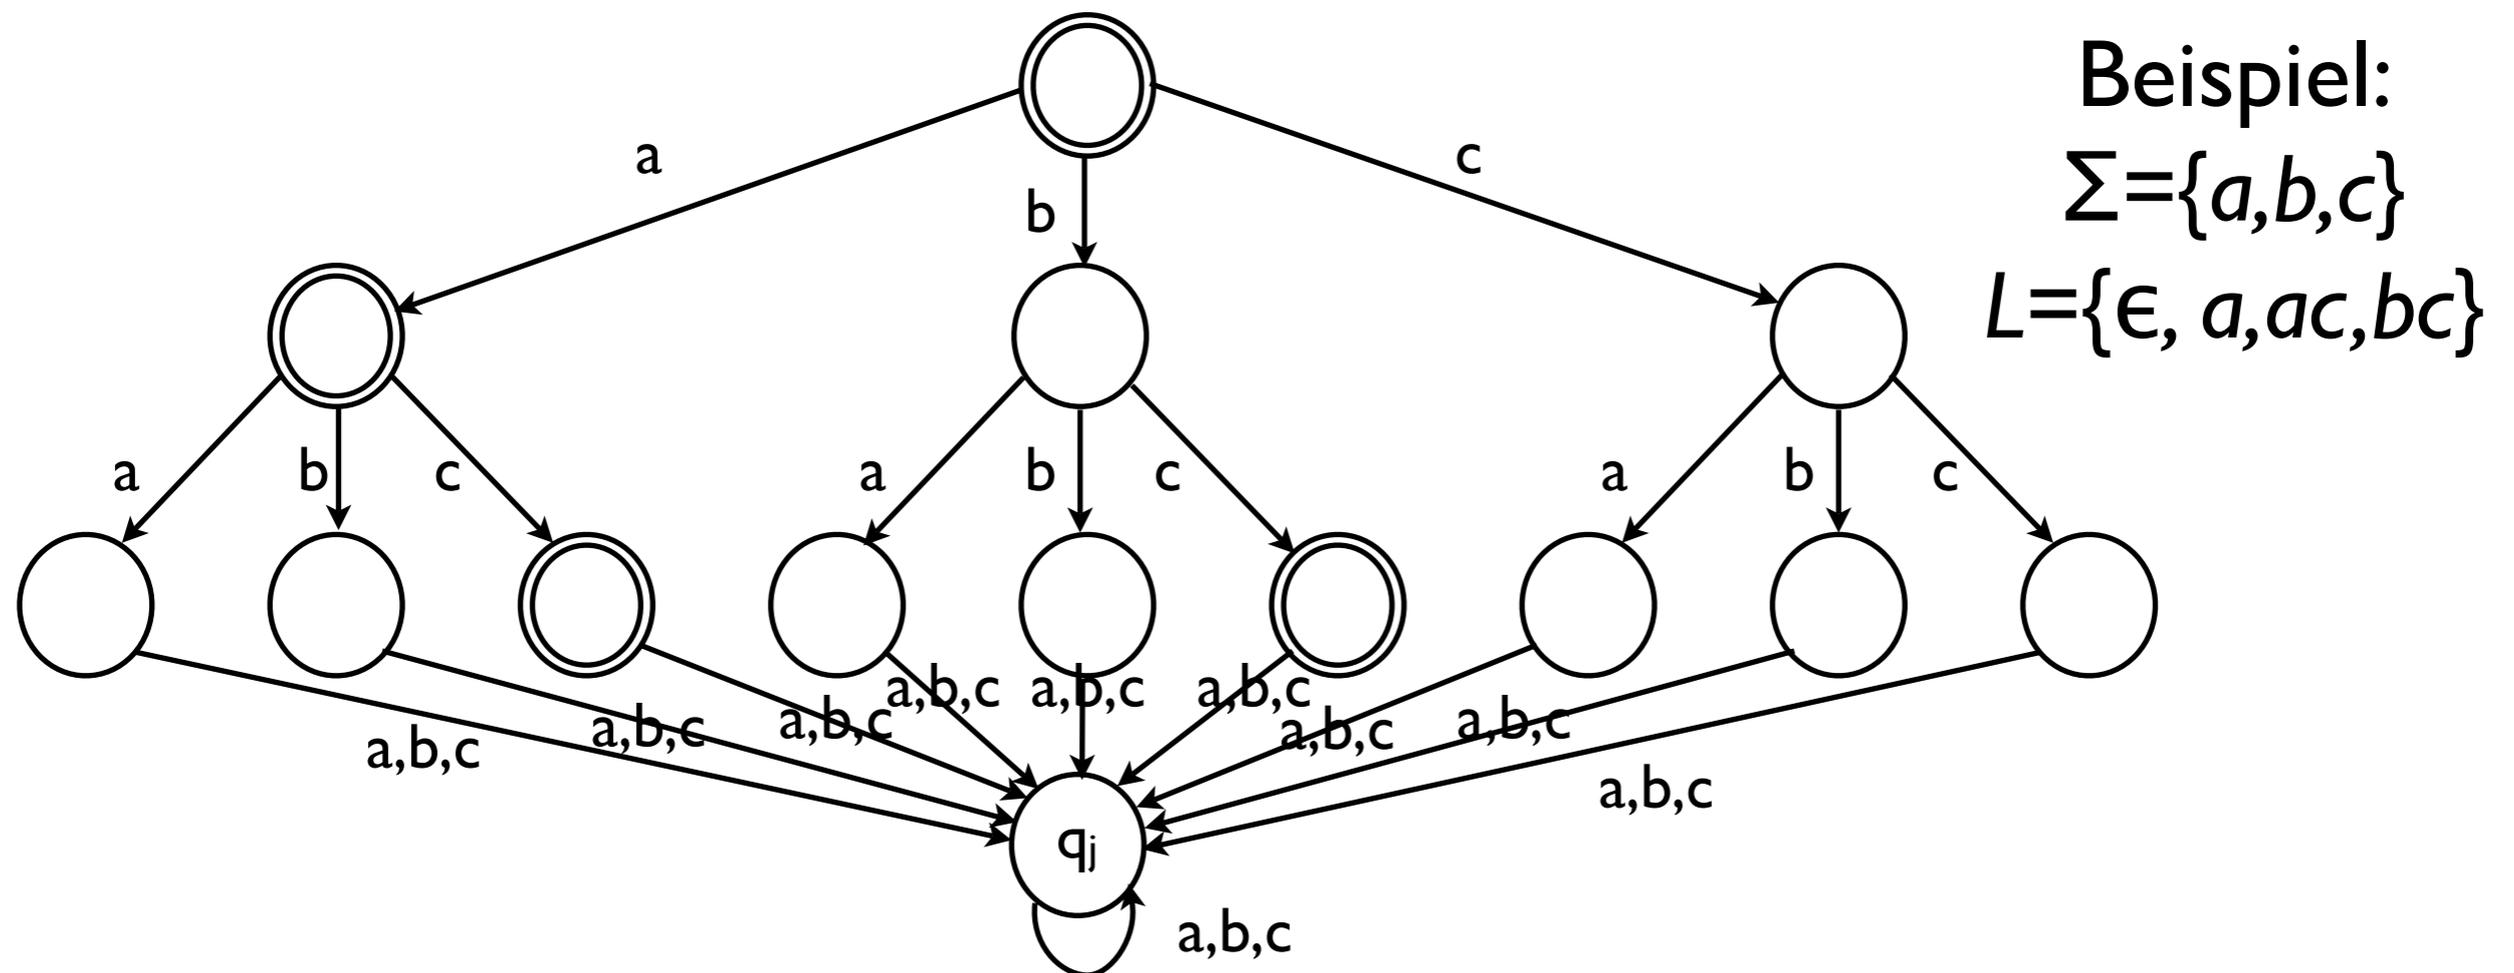
(e)  $L_1^*$  ist eine reguläre Sprache

Machen wir mit  
Nichtdeterminismus  
später

# Beweisidee (Theorem 2f)

**Behauptung:** Jede endliche Sprache  $L$  ist regulär.

**Idee:** Konstruiere endlichen Automaten als geeigneten **Trie** mit Tiefe = Länge des längsten Wortes in  $L+1$

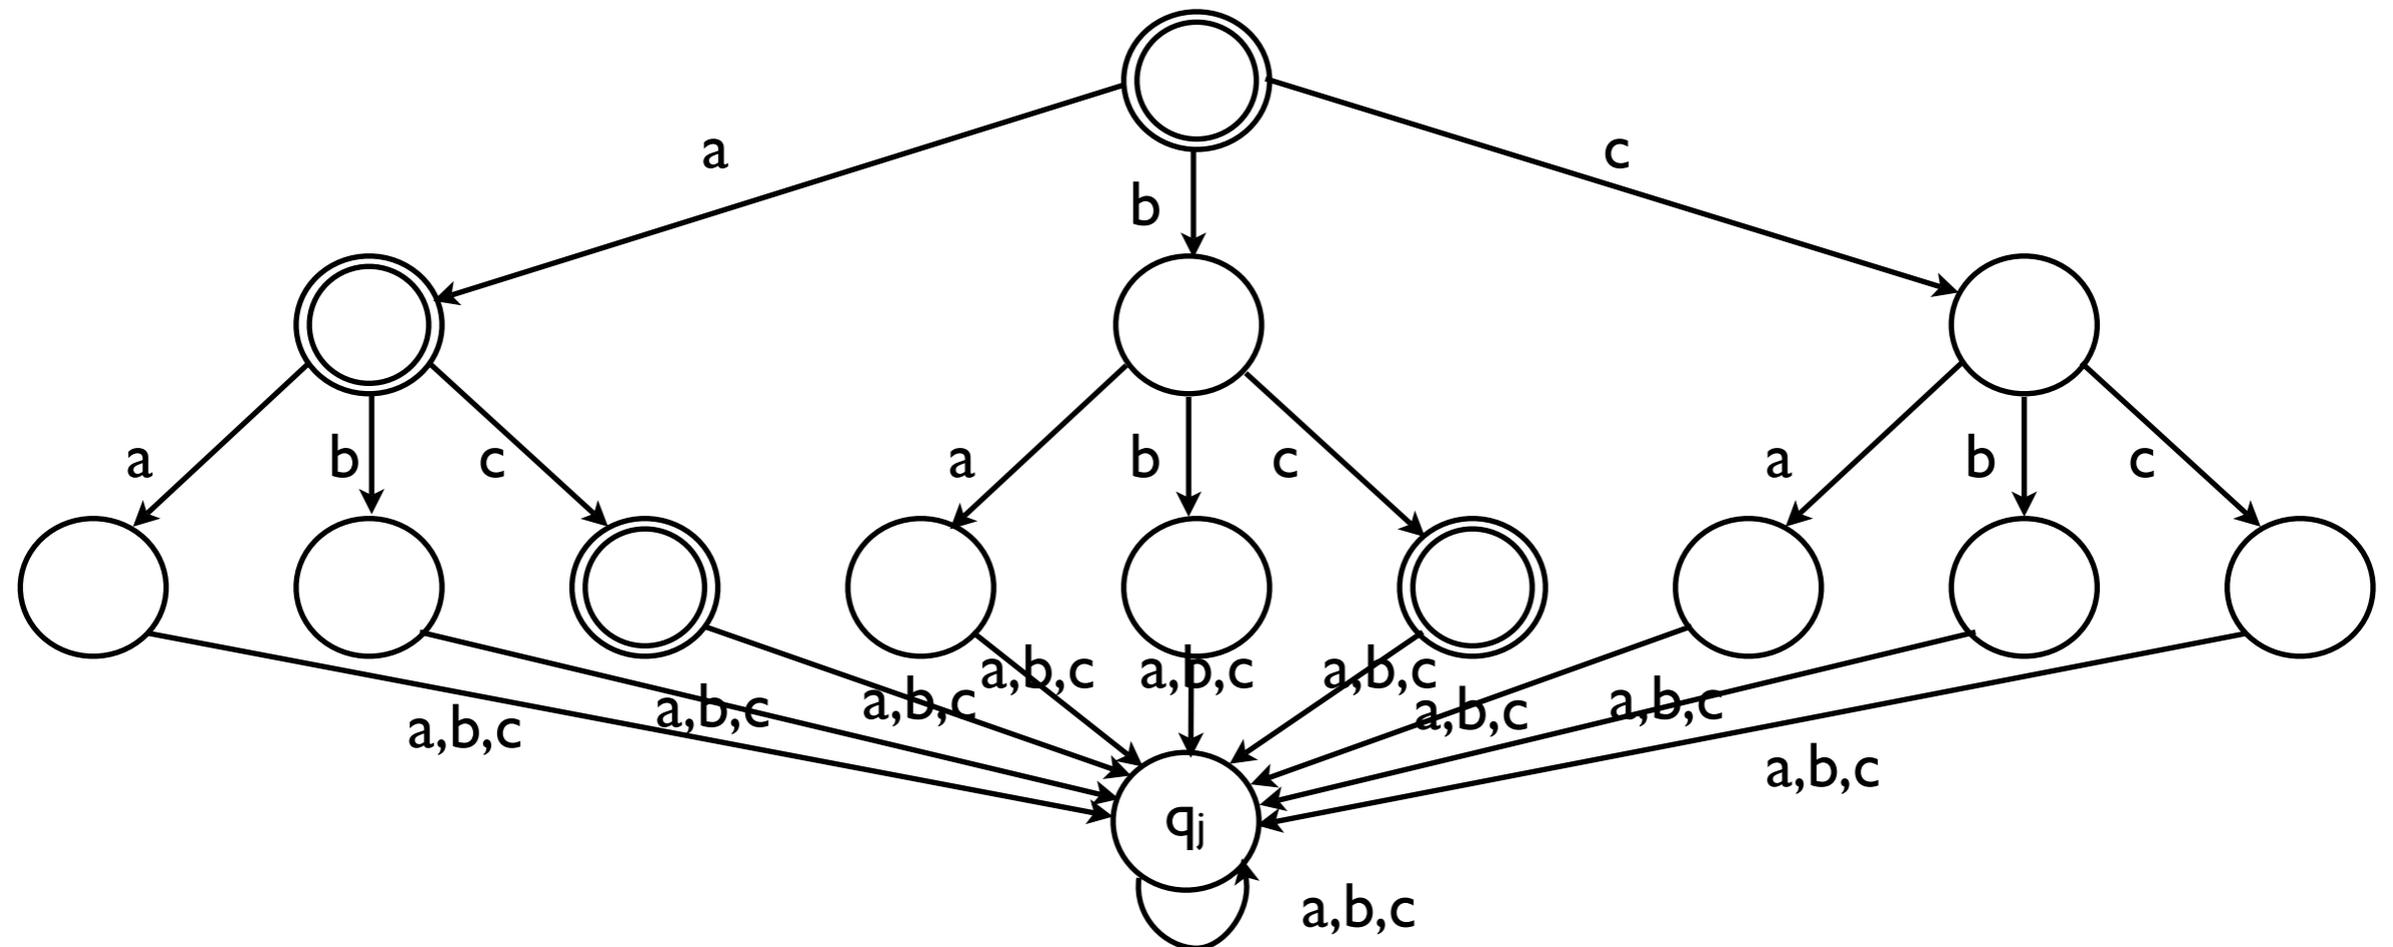


# Konvention

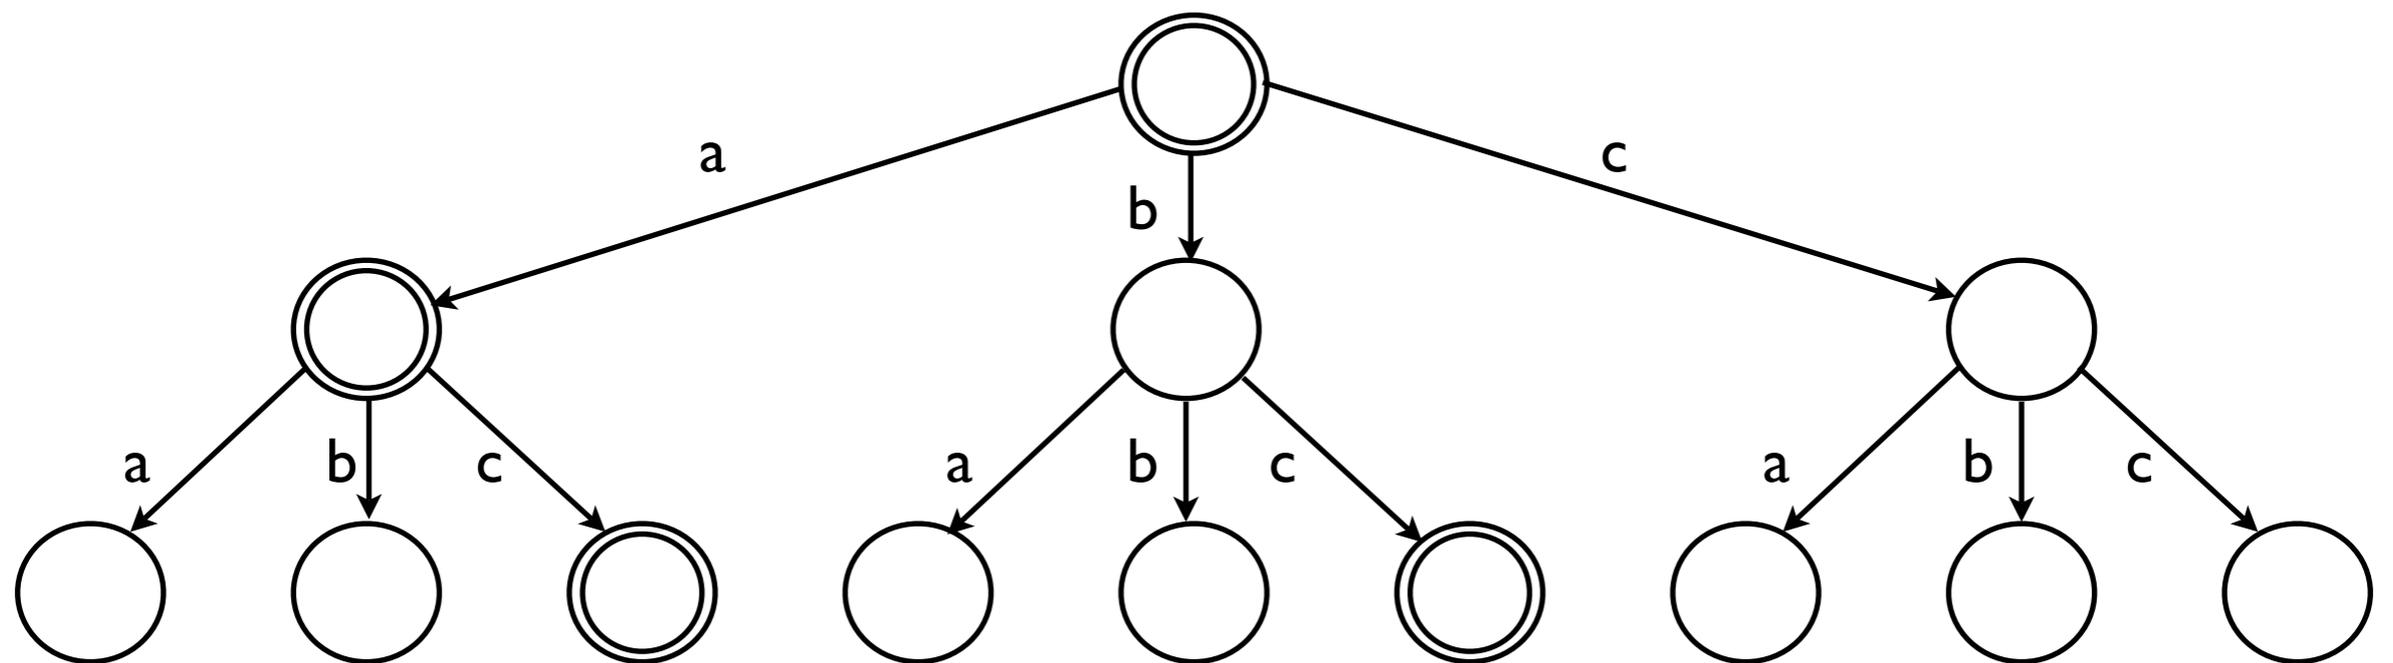
Der Automat aus dem letzten Beispiel hat einen “junk”-Zustand  $q_j$  mit den Eigenschaften

- ▶  $q_j \notin F$
- ▶  $\delta(q_j, a) = q_j$  für alle  $a \in \Sigma$

Wenn in der Spezifikation eines (deterministischen) Automaten ein Übergang  $\delta(q, a)$  fehlt, dann ergänzen wir automatisch einen solchen Junk-Zustand  $q_j$  und wählen  $\delta(q, a) = q_j$ .



≡



**Ende**

# Aufgaben

- ▶ Zeigen Sie: Seien  $A, B \subseteq M$  Mengen. Dann gilt:  $A \setminus B = A \cap \overline{B}$ , wobei  $\overline{B}$  das Komplement von  $B$  in Bezug auf  $M$  ist.
- ▶ Sei  $\Sigma = \{a, b, c\}$ . Sei  $L_1 = \{w \mid |w|_a \bmod 2 = 0\}$ ,  $L_2 = \{ubcbv \mid u, v \in \Sigma^*\}$ 
  - Konstruieren sie endliche Automaten für  $L_1, L_2, L_1 \cap L_2$ .
- ▶ Zeigen Sie Theorem 2c: Seien  $L_1, L_2 \in \Sigma^*$  reguläre Sprachen. Dann gilt:  $L_1 \cap L_2$  ist eine reguläre Sprache.