Theoretische Informatik I

Einheit 2.3

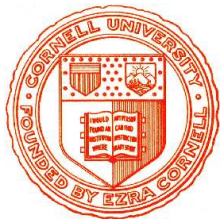

Reguläre Ausdrücke

1. Anwendungen
2. Syntax und Semantik
3. Vereinfachungsregeln
4. Beziehung zu endlichen Automaten

Eine algebraische Beschreibung für Sprachen

- **Automaten beschreiben Abarbeitung von Sprachen**
  - **Operationale Semantik**: Symbole führen zu Zustandsänderungen
  - Bestimmte Wörter bzw. Symbolketten werden durch Zustände akzeptiert
  - Für Automaten ist Sprache $\hat{=}$ Menge der akzeptierten Wörter
- **Wie beschreibt man Eigenschaften von Wörtern?**
  - **Deklarative Semantik**: äußere Form von Zeichenreihen einer Sprache

    z.B. *Wörter haben eine führende Null, dann beliebig viele Einsen*
  - Anwendungen brauchen präzise Beschreibungssprache für Wörter
    - Grundeinheiten von Programmiersprachen, Suchmuster für Browser, ...
- **Reguläre Ausdrücke als formale Syntax**
  - Kurze, prägnante Beschreibung des Aufbaus der Wörter einer Sprache

    z.B. `01*`: "Zuerst eine Null, dann beliebig viele Einsen"

Anwendung: Textsuche

- **Suche nach Mustern in Texten**
  - Suche ob/wo/wie oft eine bestimmte Zeichenkette im Text erscheint
  - Textmuster kann Platzhalter enthalten
- **Beschreibe Textmuster durch reguläre Ausdrücke**
  - Zahl: Ziffernfolge dann evtl. Punkt und nichtleere Ziffernfolge
  - Formaler Ausdruck:

    $(0+1+..+9)^*(\epsilon+(.(0+1+..+9)(0+1+..+9)^*))$
- **Vielfältige Anwendungen**
  - Google Suche nach einfachen Texten
  - Erweiterte Google Suche nach Textmustern
  - Unix Kommando grep: suche nach Textmustern in Dateien
  - Programmiersprachen wie PERL und AWK
  - Textsuche und Textersetzung in Emacs
  - Lexikalische Analyse in Compilern

Anwendung: Lexikalische Analyse

Wichtigster Grundbestandteil von Compilern

- **Reguläre Ausdrücke beschreiben Token**
  - Logische Grundeinheiten von Programmiersprachen
  - z.B. Schlüsselwörter, Bezeichner, Dezimalzahlen, ...
- **"Lexer" transformieren reguläre Ausdrücke in Analyseprogramme**
  - Analyse kann die Token der Programmiersprache identifizieren
  - Zugrundeliegende Technik:
    Umwandlung regulärer Ausdrücke in DEAs

Reguläre Ausdrücke präzisiert (Syntax)

- **Syntax: Terme über $\Sigma \cup \{\emptyset, \epsilon, +, \circ, ^*, (,)\}$**

  Reguläre Ausdrücke sind induktiv wie folgt definiert

  – $E = \mathtt{a}$ ist ein regulärer Ausdruck für jedes $a \in \Sigma$

  – $E = \emptyset$ und $F = \epsilon$ sind reguläre Ausdrücke

  – Sind E und F reguläre Ausdrücke, dann sind auch

  $E \circ F$, E^*, $E + F$ und (E) sind reguläre Ausdrücke

  Mehr Ausdrücke möglich, aber nicht erforderlich

- **Konventionen zur Vereinfachung**

  – $E \circ F$ wird üblicherweise als EF abgekürzt

  – Definitorische Abkürzungen: $E^+ \equiv EE^*$, $[a_1 \ldots a_n] \equiv a_1 + \ldots + a_n$

  – Prioritätsregelungen ermöglichen, überflüssige Klammern wegzulassen

  · * ("Sternoperator") bindet stärker als $\circ$, und dies stärker als $+$

  · Verkettung $\circ$ und Alternative $+$ sind assoziativ

Reguläre Ausdrücke präzisiert (Semantik)

- **Reguläre Ausdrücke beschreiben Sprachen über Σ**
- **Die Sprache $L(E)$ ist induktiv definiert**
  - Für für alle $a \in \Sigma$ ist $L(\mathsf{a}) = \{a\}$ (einelementige Sprache, die nur a enthält)

    $L(\emptyset)$ ist die leere Sprache (üblicherweise geschrieben als $\emptyset$ oder $\{\}$)

    $L(\epsilon) = \{\epsilon\}$ (einelementige Sprache, die nur das leere Wort enthält)
  - $L(E \circ F) = L(E) \circ L(F) = \{v\,w \mid v \in L(E) \wedge w \in L(F)\}$

    $\circ$ steht für die Verkettung (der Wörter) zweier Sprachen
  - $L(E^*) = (L(E))^* = \{w_1 w_2 .. w_n \mid n \in \mathbb{N} \wedge w_i \in L(E)\}$

    * steht für Verkettung beliebig vieler Wörter einer Sprache (Kleene'sche Hülle)
  - $L(E + F) = L(E) \cup L(F) = \{w \in \Sigma^* \mid w \in L(E) \ \vee \ w \in L(F)\}$

    $+$ steht für die Vereinigung zweier Sprachen
  - $L((E)) = L(E)$

Sprachen vs. Ausdrücke

- **Sprachen sind Mengen von Wörtern**
  - Abstraktes semantisches Konzept: Ungeordnete Kollektion von Wörtern
  - Beschreibung von Mengen (auf Folie, Tafel,...) benötigt textuelle Notation
  - Notation benutzt Kurzschreibweisen wie $\cup$, $\circ$, * für Mengenoperationen

    ... aber ist selbst nur ein Hilfsmittel zur Kommunikation
- **Reguläre Ausdrücke sind Terme**
  - Eine syntaktische Beschreibungsform, die ein Computer versteht
  - Reguläre Ausdrücke werden zur Beschreibung von Sprachen benutzt

    und sind ähnlich zur Standardnotation von Mengen
- **Reguläre Ausdrücke sind selbst keine Sprachen**
  - Unterscheide Ausdruck E von Sprache des Ausdrucks $L(E)$
  - Man verzichtet auf den Unterschied wenn der Kontext eindeutig ist

Beispiele regulärer Ausdrücke

- $\mathtt{a}^*\mathtt{b}\mathtt{a}^*$
  - steht für die Menge aller Wörter über Σ={a,b}, die genau ein b enthalten
  - $L(\mathtt{a}^*\mathtt{b}\mathtt{a}^*) = \{w \in \Sigma^* \mid w \text{ enthält genau ein } b\} = \{w \in \Sigma^* \mid |w|_b{=}1\}$
- $\Sigma^*\mathtt{b}\Sigma^*$
  - steht für $\{w \in \Sigma^* \mid w \text{ enthält mindestens ein } b\} = \{w \in \Sigma^* \mid |w|_b \geq 1\}$
- $\mathtt{a}^*(\mathtt{b}+\epsilon)\mathtt{a}^*$
  - steht für $\{w \in \Sigma^* \mid w \text{ enthält maximal ein } b\} = \{w \in \Sigma^* \mid |w|_b \leq 1\}$
- $\mathtt{a}\emptyset$
  - steht für die leere Sprache, denn die Verkettung einer Sprache mit der leeren Sprache ist immer leer
- $\emptyset^*$
  - steht für die Menge $\{\epsilon\}$, denn die beliebige Verkettung von Wörtern einer Menge enthält immer das leere Wort

Entwicklung regulärer Ausdrücke

Beschreibe Menge aller Wörter, in denen 0 und 1 abwechseln

1. Regulärer Ausdruck für die Sprache $\{01\}$

– 0 repräsentiert $\{0\}$, 1 repräsentiert $\{1\}$

– Also ist $L(01) = L(0) \circ L(1) = \{0\} \circ \{1\} = \{01\}$

2. Erzeuge $\{01, 0101, 010101, ..\}$ durch Sternbildung

– $L((01)^*) = L(01)^* = \{01\}^* = \{\epsilon, 01, 0101, 010101, \ldots\}$

3. Manche Wörter nicht erfaßt

– Start mit Eins statt Null: $(10)^*$

– Start und Ende mit Null: $(01)^*0$

– Start und Ende mit Eins: $(10)^*1$

Vollständiger Ausdruck: $(01)^* + (10)^* + (01)^*0 + (10)^*1$

4. Es geht auch kürzer

– Optional 1 am Anfang oder 0 am Ende: $(\epsilon+1)(01)^*(\epsilon+0)$

Bestimmung der Semantik von $(\epsilon+1)(01)^*(\epsilon+0)$

$$
\begin{aligned}
& L((\epsilon+1)(01)^*(\epsilon+0)) \\
= {} & L((\epsilon+1)) \circ L((01)^*) \circ L((\epsilon+0)) \\
= {} & L(\epsilon) \cup L(1) \circ L((01))^* \circ L(\epsilon) \cup L(0) \\
= {} & \{\epsilon\} \cup \{1\} \circ (L(0) \circ L(1))^* \circ \{\epsilon\} \cup \{0\} \\
= {} & \{\epsilon, 1\} \circ \{01\}^* \circ \{\epsilon, 0\} \\
= {} & \{\epsilon, 1\} \circ \{w \mid \exists n \in \mathbb{N}.\ w = \underbrace{01 \ldots 01}_{n-mal}\} \circ \{\epsilon, 0\} \\
= {} & \{w \mid \exists n \in \mathbb{N}.\ w = \underbrace{01 \ldots 01}_{n-mal} \vee w = 1\underbrace{01 \ldots 01}_{n-mal} \\
& \qquad \vee w = \underbrace{01 \ldots 01}_{n-mal}0 \vee w = 1\underbrace{01 \ldots 01}_{n-mal}0\}
\end{aligned}
$$

= Die Menge aller Wörter, in denen 0 und 1 abwechseln

(Mühsamer Beweis durch Induktion)

"Rechenregeln" für reguläre Ausdrücke

Wie zeigt man $(01)^*+(10)^*+(01)^*0+(10)^*1 \cong (\epsilon+1)(01)^*(\epsilon+0)$?

- **Definiere Äquivalenz von Ausdrücken**
  - $E \cong F$, falls $L(E) = L(F)$

  Beweise algebraische Gesetze regulärer Ausdrücke
  - Liefert Hilfsmittel zur Vereinfachung regulärer Ausdrücke

- **Gesetze für Einheiten und Annihilatoren**
  - $\emptyset+E \cong E \cong E+\emptyset$: $L(\emptyset+E) = L(\emptyset)\cup L(E) = \emptyset\cup L(E) = L(E)$
  - $\epsilon\circ E \cong E \cong E\circ\epsilon$: $L(\epsilon\circ E) = L(\epsilon)\circ L(E) = \{\epsilon\}\circ L(E) = L(E)$
  - $\emptyset\circ E \cong \emptyset \cong E\circ\emptyset$: $L(\emptyset\circ E) = L(\emptyset)\circ L(E) = \emptyset\circ L(E) = \emptyset = L(\emptyset)$

  Kommutativitätsgesetz für +
  - $E+F \cong F+E$: $L(E+F) = L(E)\cup L(F) = L(F)\cup L(E) = L(F+E)$
  - Kommutativität von $\circ$ gilt nicht: $= L(01) = \{01\} \neq \{10\} = L(10)$

"Rechenregeln" für reguläre Ausdrücke II

- **Gesetze fürAssoziativität von $\circ$ und $+$**
  - $(E \circ F) \circ G \cong E \circ (F \circ G)$:

    $L((E \circ F) \circ G) = L(E \circ F) \circ L(G) = L(E) \circ L(F) \circ L(G) = L(E) \circ L(F \circ G) = L(E \circ (F \circ G))$
  - $(E + F) + G \cong E + (F + G)$:

    $L((E + F) + G) = L(E + F) \cup L(G) = L(E) \cup L(F) \cup L(G) = \ldots = L(E + (F + G))$
- **Distributivgesetze**
  - $(E + F) \circ G \cong E \circ G + F \circ G$:

    $L((E + F) \circ G) = (L(E) \cup L(F)) \circ L(G)$

    $= \{w \in \Sigma^* \mid \exists u \in L(E) \cup L(F). \exists v \in L(G). w = uv\}$

    $= \{w \in \Sigma^* \mid \exists u \in L(E). \exists v \in L(G). w = uv \vee \exists u \in L(F). \exists v \in L(G). w = uv\}$

    $= \{w \in \Sigma^* \mid \exists u \in L(E). \exists v \in L(G). w = uv\} \cup \{w \in \Sigma^* \mid \exists u \in L(F). \exists v \in L(G). w = uv\}$

    $= L(E) \circ L(G) \cup L(F) \circ L(G) = L(E \circ G + F \circ G)$
  - $G \circ (E + F) \cong G \circ E + G \circ F$
- **Idempotenz von $+$:** $E + E \cong E$
- **Hüllengesetze:** $\emptyset^* \cong \epsilon$, $\epsilon^* \cong \epsilon$, $(E^*)^* \cong E^*$

  $E^+ \cong E \circ E^* \cong E^* \circ E$, $E^* \cong \epsilon + E^+$

Beweismethodik für weitere Äquivalenzen

- **Beispiel: Nachweis von $(E+F)^* \cong (E^*F^*)^*$**
  - Sei $w \in L((E+F)^*)$
  - Dann $w = w_1..w_k$ mit $w_i \in L(E)$ oder $w_i \in L(F)$ für alle i
  - Dann $w = w_1..w_k$ mit $w_i \in L(E^*F^*)$ für alle i (semantisches Argument)
  - Also $w \in L((E^*F^*)^*)$ Umkehrung analog
- **Beweis verwendet keine Information über E und F**
  - Man könnte genauso gut $(a+b)^* \cong (a^*b^*)^*$ testen
    $(E+F)^* \cong (E^*F^*)^*$ gilt, weil $(a+b)^* \cong (a^*b^*)^*$ gilt
- **Allgemeines Beweisverfahren**
  - E regulärer Ausdruck mit Metavariablen $E_1,..,E_m$ für Sprachen $L_1,..,L_m$
  - Ersetze im Beweis für $E \cong F$ alle Metavariablen durch Symbole $a \in \Sigma$
  - Teste Äquivalenz der konkreten Ausdrücke mit automatischem Prüfverfahren
    ↦ Einheit 2.5

  Korrektheitsbeweis: Induktion über Struktur regulärer Ausdrücke

Sprachen regulärer Ausdrücke sind endlich erkennbar

Für jeden regulären Ausdruck E gibt es einen ϵ-NEA A mit

– A hat genau einen akzeptierenden Zustand q_f

– Der Startzustand von A ist in keinem $\delta_A(q, a)$ enthalten

– Für alle $a \in \Sigma$ ist $\delta_A(q_f, a) = \emptyset$

– $L(E) = L(A)$

Beweis durch strukturelle Induktion über Aufbau regulärer Ausdrücke

- **Induktionsanfänge**

  – Für $E = \epsilon$ wähle $A =$

  – Für $E = \emptyset$ wähle $A =$

  – Für $E =$ a wähle $A =$

  – **Korrektheit offensichtlich**, da jeweils maximal ein Zustandsübergang

Umwandlung regulärer Ausdrücke in Automaten

- **Induktionsannahme: seien A_1 und A_2 ϵ-NEAs für E_1 und E_2**
- **Induktionsschritt**
  - Für $E = E_1 + E_2$ wähle $A =$

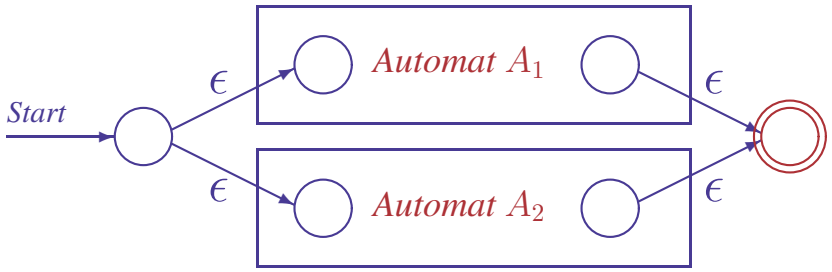

  - Für $E = E_1 \circ E_2$ wähle

$A =$

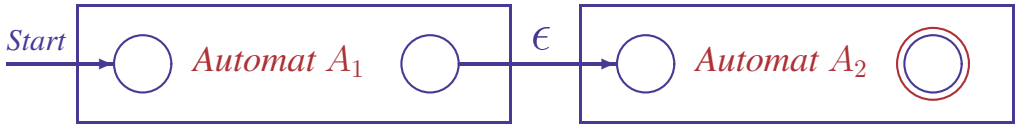

  - Für $E = E_1^*$ wähle $A =$

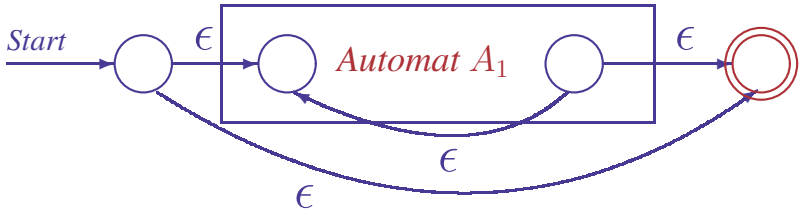

  - Für $E = (E_1)$ wähle $A = A_1$

Korrektheit der Umwandlungen

- **Klammern ändern nichts**
  - Es ist $L((E_1)) = L(E_1) = L(A_1) = L(A)$
- **Verkettung ist Verschaltung von Automaten**

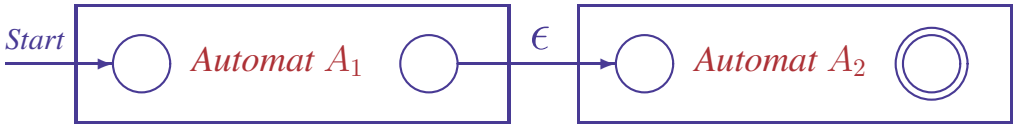

Es gilt $w \in L(E_1 \circ E_2)$

$\Rightarrow\ w \in L(E_1) \circ L(E_2) = L(A_1) \circ L(A_2)$

$\Rightarrow\ \exists u \in L(A_1).\exists v \in L(A_2).w = uv$

$\Rightarrow\ \exists u, v \in \Sigma^*.w = uv \wedge q_{f,1} \in \hat{\delta}_1(q_{0,1}, u) \wedge q_{f,2} \in \hat{\delta}_2(q_{0,2}, v)$

$\Rightarrow\ \exists u, v \in \Sigma^*.w = uv \wedge q_{0,2} \in \hat{\delta}(q_{0,1}, u) \wedge q_{f,2} \in \hat{\delta}(q_{0,2}, v)$ ($q_{0,2} \in \epsilon$-Hülle$(q_{f,1})$)

$\Rightarrow\ q_{f,2} \in \hat{\delta}(q_{0,1}, w)$ (Definition $\hat{\delta}$)

$\Rightarrow\ w \in L(A)$

Argument ist umkehrbar, also $w \in L(A) \Rightarrow w \in L(E_1 \circ E_2)$

- **Sternbildung und Vereinigung ähnlich**

Umwandlung regulärer Ausdrücke am Beispiel

Konstruiere endlichen Automaten für `(0+1)*1(0+1)`

- **Teilautomat für** `(0+1)`

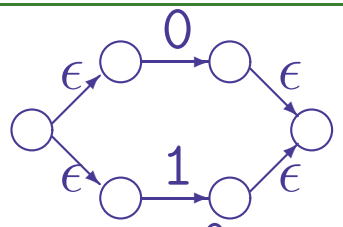

- **Teilautomat für** `(0+1)*`

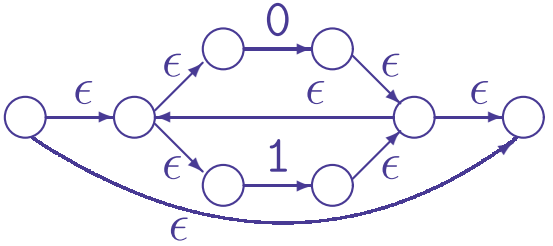

- **Automat für** `(0+1)*1(0+1)`

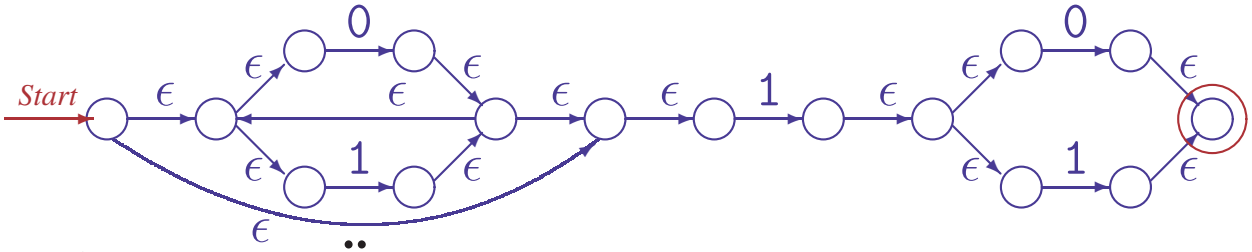

- **Elimination von ϵ-Übergängen**

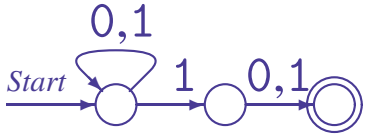

Umwandlung von (ϵ-)NEAs in reguläre Ausdrücke

- **Ursprünglich: Pfadanalyse im Übergangsdiagramm**
  - Spezialisierung eines allgemeinen Verfahrens für Pfadanalyse in Graphen
  - Definiere reguläre Ausdrücke für Pfade durch Automaten
  - Berechnung Ausdrücke iterativ und kombiniere alle relevanten Ausdrücke
  - Kompliziertes und aufwendiges Verfahren

Mehr dazu im Anhang

- **Effizienterer Zugang: Elimination von Zuständen**
  - Beschreibe Übergänge $q_i \xrightarrow{a \in \Sigma} q_j$ durch reguläre Ausdrücke
  - Beginne mit regulären Ausdrücken für direkte Übergänge
  - Entferne einzelne Zustände und beschreibe die entstehenden Ausdrücke
  - Liefert Ausdrücke für Übergänge zwischen Start- und Endzuständen
- **Technisches Hilfsmittel: verallgemeinerte NEAs (VNEAs)**
  - NEA, dessen Überführungsfunktion δ auf regulären Ausdrücken arbeitet
  - A akzeptiert w, wenn es einen Pfad $w = v_1..v_m$ von q_0 zu einem $q \in F$ gibt und alle v_i in der Sprache des entsprechenden regulären Ausdrucks liegen
  - Konsistente Formalisierung mühsam und ohne Erkenntnisgewinn

Zustandselimination in VNEAs

- **Ursprünglicher NEA**

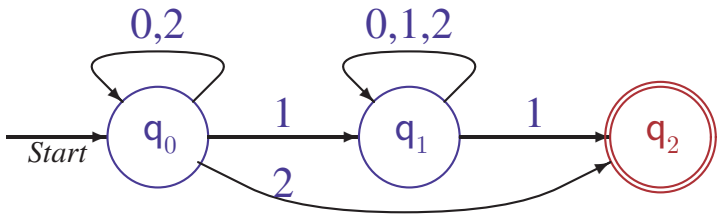

- **Zugehöriger VNEA**

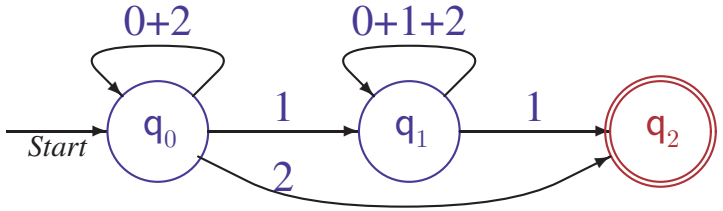

- **Nach Elimination von q_1**

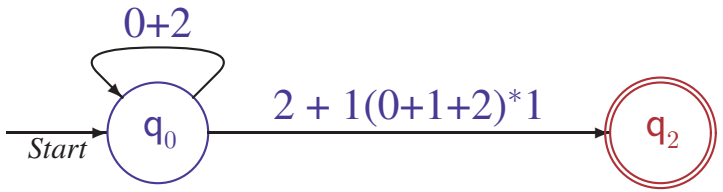

  – Ausdruck für Übergang von q_0 nach q_2 ergibt sich aus Übergang q_0 nach q_1, Schleife bei q_1, Übergang q_1 nach q_2 und existierendem Ausdruck für direkten Übergang von q_0 nach q_2

Allgemeine Zustandselimination in VNEAs

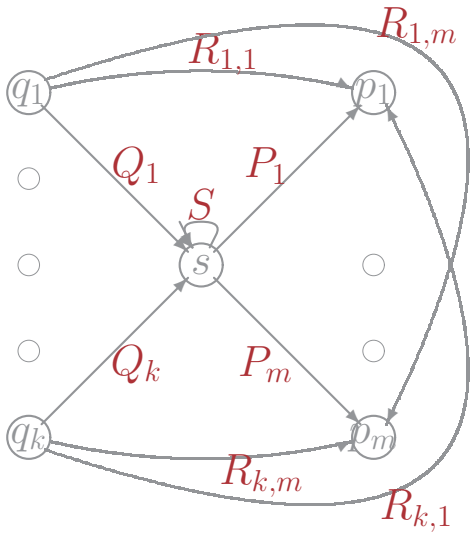

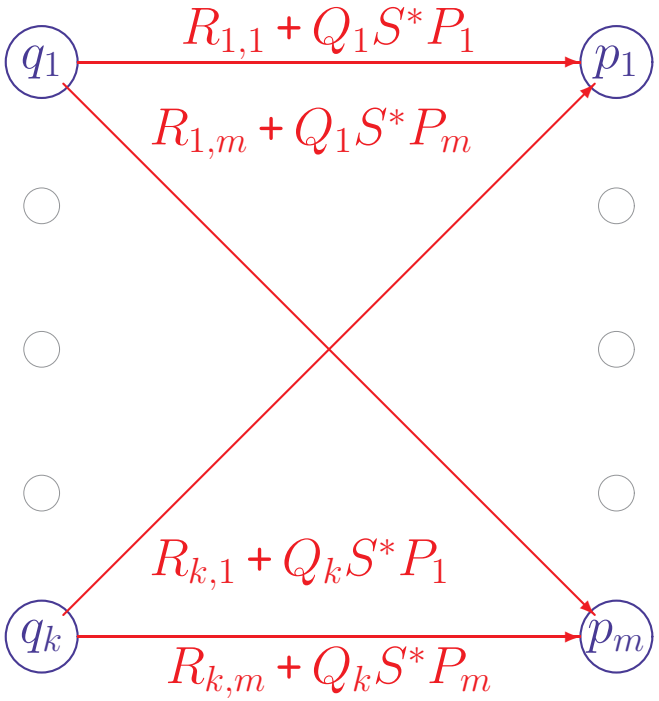

Eliminiere Zustand s
mit Vorgängern $q_1, .., q_k$
und Nachfolgern $p_1, .., p_m$

jedes p_i kann auch einer der Zustände $q_1, .., q_k$ sein

– Eliminiere Pfad von q_1 nach p_1 über s: $R_{1,1} + Q_1 S^* P_1$
– Eliminiere Pfad von q_1 nach p_m über s: $R_{1,m} + Q_1 S^* P_m$
– Eliminiere Pfad von q_k nach p_1 über s: $R_{k,1} + Q_k S^* P_1$
– Eliminiere Pfad von q_k nach p_m über s: $R_{k,m} + Q_k S^* P_m$

Umwandlung durch Zustandselimination

1. **Ergänze neuen Anfangszustand p_0 und Endzustand p_f**
   - ϵ-Übergang von neuem zu altem Anfangszustand
   - ϵ-Übergang von allen alten Endzuständen zum neuen Endzustand
   - $\mapsto$ Anfangs- und Endzustand haben keine ein- bzw. ausgehenden Kanten
2. **Transformiere endlichen Automaten in VNEA**
   - Ersetze Beschriftungen mit Symbolen $a \in \Sigma$ durch reguläre Ausdrücke
3. **Eliminiere alle Zustände außer p_0 und p_f**
   - Iterative Anwendung des Eliminationsverfahrens
   - Vereinfache entstehende Ausdrücke nach jedem Schritt
4. **Extrahierte regulären Ausdruck aus VNEA**
   - Zielausdruck ist Beschriftung der Kante von p_0 nach p_f

Umwandlung NEA → RA: einfaches Beispiel

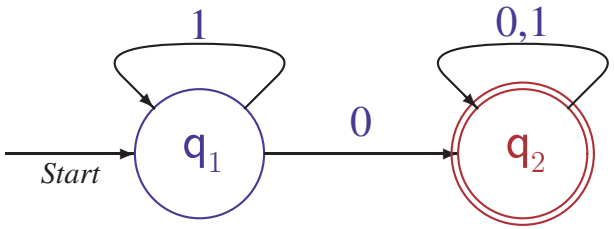

1. Ergänze neuen Anfangs- und Endzustand

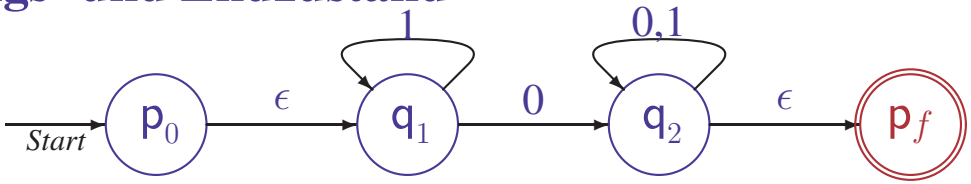

2. Transformiere Automaten in VNEA

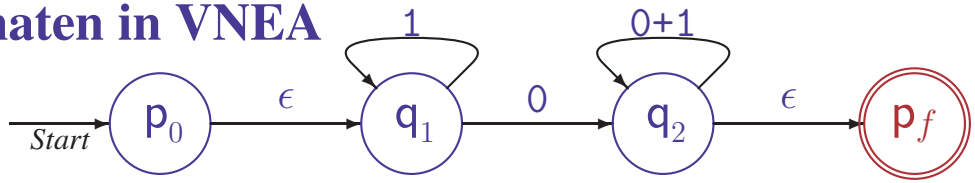

3. Eliminiere Zwischenzustände

– Eliminiere q_1

– Eliminiere q_2

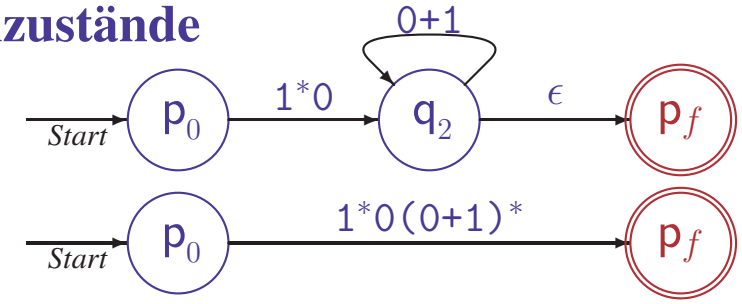

4. Extrahierter Ausdruck ist `1*0(0+1)*`

Umwandlung mit Pfadanalyseverfahren würde 12 aufwendige Schritte erfordern

Umwandlung NEA → RA am Beispiel

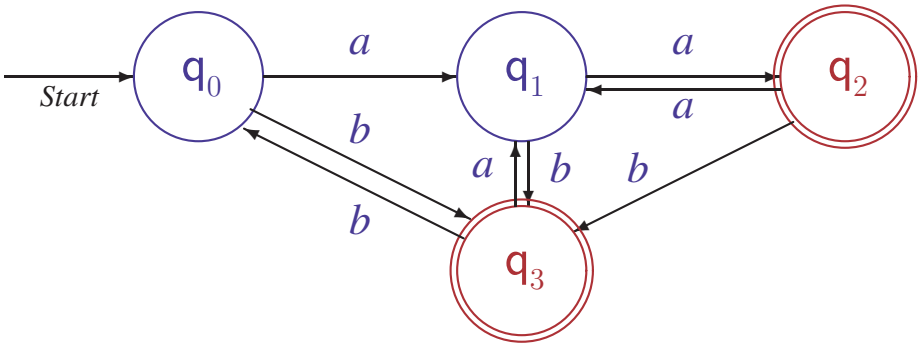

1. Ergänze neuen Anfangs- und Endzustand

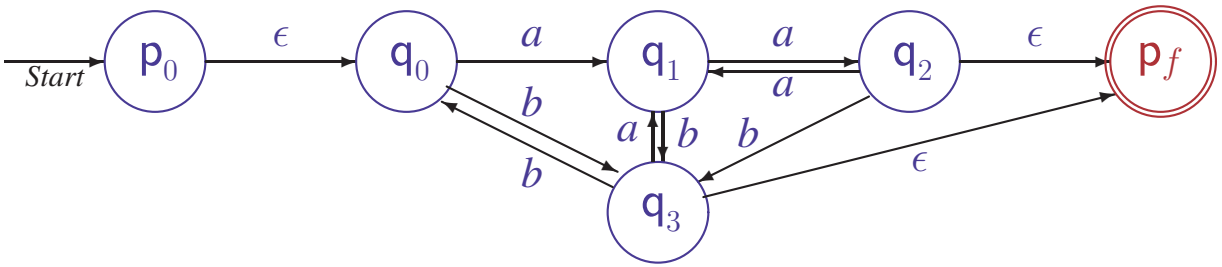

2. Transformiere Automaten in VNEA

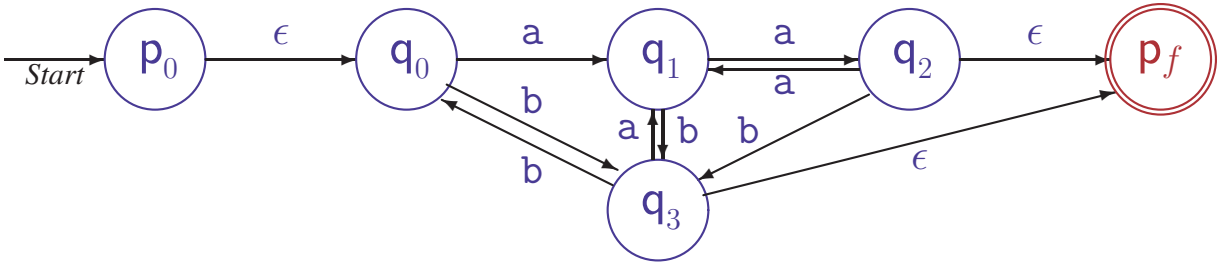

Umwandlung NEA → RA am Beispiel (II)

1. Ergänze neuen Anfangs- und Endzustand
2. Transformiere Automaten in VNEA

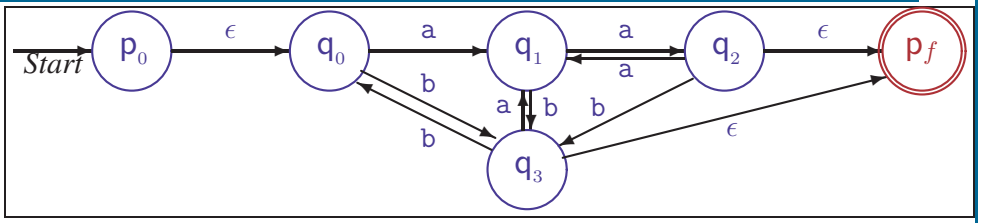

3. **Eliminiere Zwischenzuständen**

– Eliminiere q_0

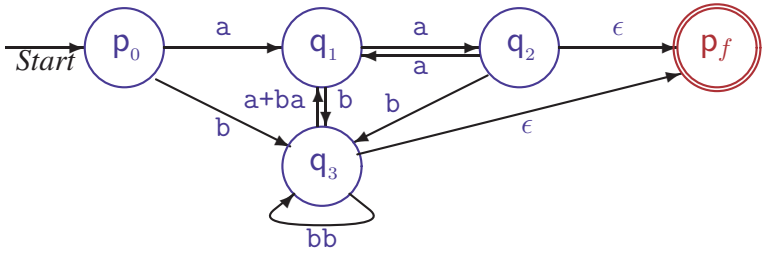

– Eliminiere q_2

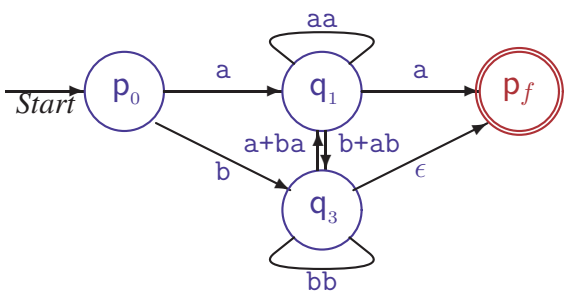

– Eliminiere q_3

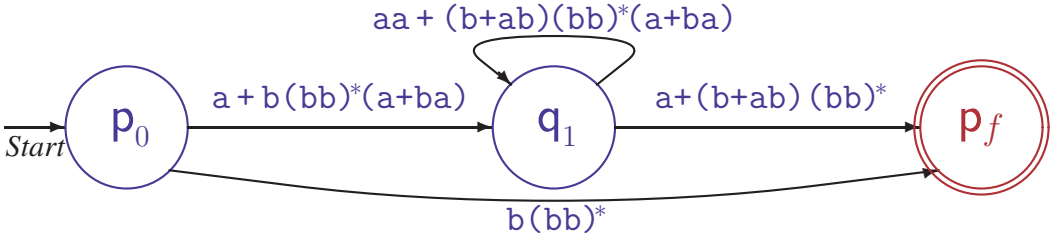

4. **Extrahierter Ausdruck ergibt sich nach Elimination von q_1**

– $b(bb)^* + (a + b(bb)^*(a+ba))(aa + (b+ab)(bb)^*(a+ba))^*(a+(b+ab)(bb)^*)$

Reguläre Ausdrücke – Zusammenfassung

- **Algebraische Notation für Sprachen**
  - ϵ, $\emptyset$, Symbole des Alphabets, Vereinigung, Verkettung, Sternoperator
  - Äquivalent zu endlichen Automaten
  - Gut zum Nachweis algebraischer Gesetze von Sprachen
  - Anwendung in Programmiersprachen und Suchmaschinen
- **Transformation in endliche Automaten**
  - Iterative Konstruktion von ϵ-NEAs
  - Nachträgliche Optimierung durch Elimination von ϵ-Übergängen
- **Transformation von Automaten in Ausdrücke**
  - Konstruktion durch Elimination von Zuständen in VNEAs
  - Historisch: Konstruktion von Ausdrücken für Abarbeitungspfade
  - Nachträgliche Optimierungen durch Anwendung algebraischer Gesetze

ANHANG

Originalmethode: allgemeines Graphanalyseverfahren

- **Gegeben DEA $A = (\{q_1, ..q_n\}, \Sigma, \delta, q_1, \{q_{f_1}, ..q_{f_m}\})$**
- **Definiere Ausdrücke für Pfade durch A**
  - R_{ij}^k : Regulärer Ausdruck für Menge der Wörter w mit $\hat{\delta}(q_i, w) = q_j$, so dass für alle $\epsilon \neq v \sqsubseteq w$ $(v \neq w)$ gilt: $\hat{\delta}(q_i, v) = q_m \Rightarrow m \leq k$

    (Abarbeitung von w berührt keinen Zustand größer als k)
- **Setze die R_{ij}^k zu Ausdruck für $L(A)$ zusammen**
  - Per Definition ist R_{ij}^n ein Ausdruck für Wörter w mit $\hat{\delta}(q_i, w) = q_j$
  - Setze $R = R_{1f_1}^n + ... + R_{1f_m}^n$
  - Dann gilt $L(R) = \bigcup_{j=1}^{m} \{w \in \Sigma^* \mid \hat{\delta}(q_1, w) = q_{f_j}\}$

    $= \{w \in \Sigma^* \mid \exists q \in \{q_{f_1}, .., q_{f_m}\}.\ \hat{\delta}(q_1, w) = q\} = L(A)$

Iterative Bestimmung der Ausdrücke R_{ij}^k

- **Basisfall R_{ij}^0:** Pfad darf zwischendurch keine Zustände berühren
  - Pfadlänge 0 (nur für $i{=}j$): $\epsilon \in L(R_{ii}^0)$
  - Pfadlänge 1: $\{a \in \Sigma \mid \delta(q_i, a) = q_j\} \subseteq L(R_{ij}^0)$
  - Ergebnis: $\boldsymbol{R_{ii}^0} = \epsilon + \mathsf{a}_1 + \ldots + \mathsf{a}_k$, wobei $\{a_1, .., a_k\} = \{a \in \Sigma \mid \delta(q_i, a){=}q_j\}$

    $\boldsymbol{R_{ij}^0} = \emptyset + \mathsf{a}_1 + \ldots + \mathsf{a}_k$ $(i{\neq}j)$

- **Schrittfall R_{ij}^k** $(0{<}k{\leq}n)$: zwei Alternativen
  - Wörter $w \in L(R_{ij}^k)$, deren Pfad q_k nicht enthält, gehören zu $L(\boldsymbol{R_{ij}^{k-1}})$
  - Wörter $w \in L(R_{ij}^k)$, deren Pfad q_k enthält:

    Zerlege w in $uz_1..z_pv$ mit $\hat{\delta}(q_i, u){=}q_k \wedge \forall l{\leq}p.\hat{\delta}(q_k, z_l){=}q_k \wedge \hat{\delta}(q_k, v){=}q_j$

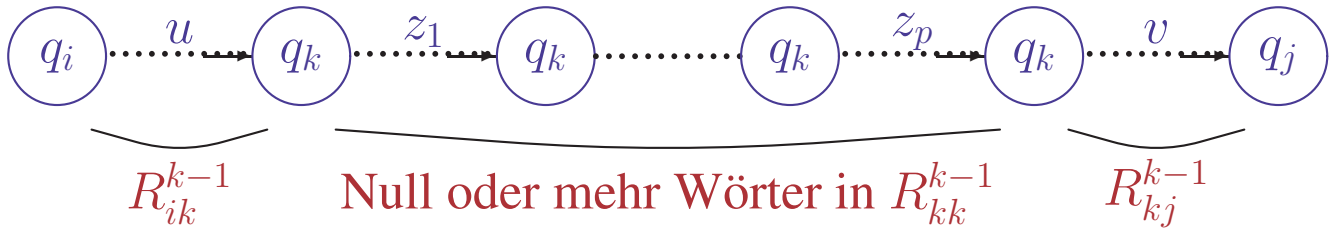

  - Ergebnis: $\boldsymbol{R_{ij}^k = R_{ij}^{k-1} + R_{ik}^{k-1} \circ (R_{kk}^{k-1})^* \circ R_{kj}^{k-1}}$

Umwandlung von Automaten am Beispiel

- **Basisfall**

$R^0_{11} = \epsilon + 1$
$R^0_{12} = 0$
$R^0_{21} = \emptyset$
$R^0_{22} = \epsilon + 0 + 1$

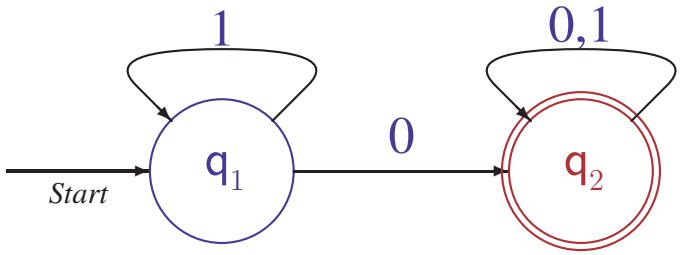

- **Stufe 1**

$R^1_{11} = R^0_{11} + R^0_{11}(R^0_{11})^* R^0_{11} = \epsilon + 1 + (\epsilon + 1)(\epsilon + 1)^*(\epsilon + 1) \mapsto 1^*$
$R^1_{12} = R^0_{12} + R^0_{11}(R^0_{11})^* R^0_{12} = 0 + (\epsilon + 1)(\epsilon + 1)^* 0 \mapsto 1^*0$
$R^1_{21} = R^0_{21} + R^0_{21}(R^0_{11})^* R^0_{11} = \emptyset + \emptyset(\epsilon + 1)^*(\epsilon + 1) \mapsto \emptyset$
$R^1_{22} = R^0_{22} + R^0_{21}(R^0_{11})^* R^0_{12} = \epsilon + 0 + 1 + \emptyset(\epsilon + 1)^* 0 \mapsto \epsilon + 0 + 1$

- **Stufe 2**

Gebraucht wird nur R^2_{12}

$R^2_{11} = R^1_{11} + R^1_{12}(R^1_{22})^* R^1_{21} = 1^* + 1^*0(\epsilon+0+1)^*\emptyset \mapsto 1^*$
$R^2_{12} = R^1_{12} + R^1_{12}(R^1_{22})^* R^1_{22} = 1^*0 + 1^*0(\epsilon+0+1)^*(\epsilon+0+1) \mapsto 1^*0(0+1)^*$
$R^2_{21} = R^1_{21} + R^1_{22}(R^1_{22})^* R^1_{21} = \emptyset + (\epsilon+0+1)(\epsilon+0+1)^*\emptyset \mapsto \emptyset$
$R^2_{22} = R^1_{22} + R^1_{22}(R^1_{22})^* R^1_{22} = (\epsilon+0+1)+(\epsilon+0+1)(\epsilon+0+1)^*(\epsilon+0+1) \mapsto (0+1)^*$

Regulärer Ausdruck des Automaten ist: $1^*0(0+1)^*$

Das Pfadanalyseverfahren ist zu kompliziert

- **Konstruktion aller R_{ij}^k ist aufwendig**
  - Es müssen mehr als n^3 Ausdrücke R_{ij}^k erzeugt werden
  - Ausdrücke R_{ij}^k können viermal so groß wie die R_{ij}^{k-1} werden
  - Ohne Vereinfachung der R_{ij}^k sind bis zu $n^3 * 4^n$ Symbole zu erzeugen
- **Optimierungen des Verfahrens sind möglich**
  - Vermeide Vielfachkopien der R_{ij}^{k-1}
  - Vereinfache Ausdrücke R_{ij}^k direkt nach Erzeugung
  - Liefert keine grundsätzliche Verbesserung

Zustandselimination ist erheblich effizienter