

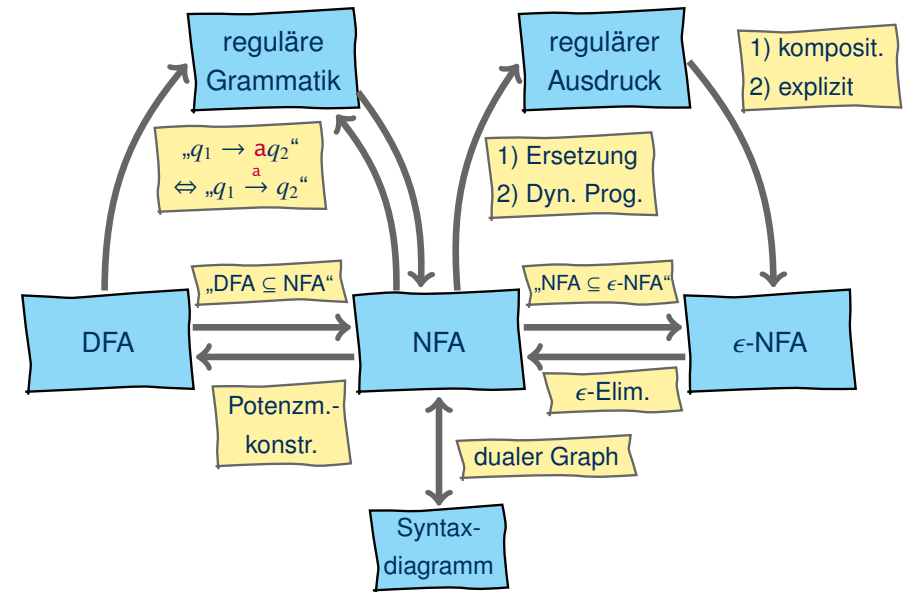
FORMALE SYSTEME

8. Vorlesung: Minimale Automaten

Markus Krötzsch

TU Dresden, 7. November 2016

Darstellungen von Typ-3-Sprachen



Markus Krötzsch, 7. November 2016

Formale Systeme

Folie 3 von 30

Minimierung von Automaten

Automaten verkleinern

Wir haben bereits Methoden kennengelernt, um Automaten zu vereinfachen:

- Entfernen von Zuständen, die von keinem Anfangszustand aus erreichbar sind
- Entfernen von Zuständen, von denen aus kein Endzustand erreicht werden kann

Erhalten wir damit den kleinstmöglichen äquivalenten Automaten?

Nein – ein einfaches Gegenbeispiel:


Beispiel: Sei \mathcal{M} ein endlicher Automat, bei dem alle Zustände erreichbar sind und einen Endzustand erreichen können. Der Vereinigungsautomat^a $\mathcal{M} \oplus \mathcal{M}$ akzeptiert die selbe Sprache, hat nur erreichbare Zustände, aber die doppelte Zustandszahl.

^aHierbei müssen die Zustände einer Kopie von \mathcal{M} umbenannt werden.

Ein interessanteres Beispiel

Der Vereinigungsautomat ist immer ein NFA. Nichtdeterminismus macht es einfach, nicht-minimale Automaten zu finden.

Interessanter sind nicht-minimale DFAs:



Dieser DFA hat keine offensichtlich überflüssigen Zustände, aber der folgende kleinere DFA erkennt die selbe Sprache 1^*0 :



Äquivalenz von Zuständen

Für einen DFA $\mathcal{M} = \langle Q, \Sigma, \delta, q_0, F \rangle$ und einen Zustand $q \in Q$ sei $\mathcal{M}_q = \langle Q, \Sigma, \delta, q, F \rangle$ der abgewandelte DFA mit Startzustand q .

Zwei Zustände $p, q \in Q$ sind **\mathcal{M} -äquivalent**, in Symbolen $p \sim_{\mathcal{M}} q$, wenn gilt:


$$L(\mathcal{M}_p) = L(\mathcal{M}_q)$$

das heißt wenn für jedes Wort $w \in \Sigma^*$ gilt:

$$\delta(p, w) \in F \text{ genau dann wenn } \delta(q, w) \in F.$$

Wenn der Automat \mathcal{M} klar ist, schreiben wir einfach \sim statt $\sim_{\mathcal{M}}$.

Beispiel:



$$L(\mathcal{M}_A) = \{1\}^*\{0\} = L(\mathcal{M}_C)$$

$$L(\mathcal{M}_B) = \{\epsilon\}$$

$$\sim A \sim C$$

Automaten minimieren?

Wie kann man Automaten weiter minimieren?

Beobachtungen:

- Zur Erkennung von Wörtern muss der Automat nur seinen aktuellen Zustand kennen
- Wichtig ist, wohin man vom aktuellen Zustand aus gelangt, wenn man das restliche Wort einliest
- Es ist nicht relevant, auf welchem Weg man zu diesem Zustand gelangt ist

Idee: Zwei Zustände sind gleichwertig, wenn man ausgehend von beiden Zuständen die selbe Sprache akzeptieren kann

→ Gleichwertige Zustände könnten verschmolzen werden . . .

Eigenschaften von $\sim_{\mathcal{M}}$

Definition (kurz): $q \sim_{\mathcal{M}} p$ genau dann wenn $L(\mathcal{M}_p) = L(\mathcal{M}_q)$.

Damit sehen wir leicht:

- \sim ist **reflexiv**: $q \sim q$
- \sim ist **symmetrisch**: wenn $q_1 \sim q_2$ dann $q_2 \sim q_1$
- \sim ist **transitiv**: wenn $q_1 \sim q_2$ und $q_2 \sim q_3$ dann $q_1 \sim q_3$

(jeweils für alle $q, q_1, q_2, q_3 \in Q$)

Eigenschaft: \sim ist eine **Äquivalenzrelation**.

Außerdem gilt für alle $a \in \Sigma$

- wenn $q_1 \sim q_2$ dann $\delta(q_1, a) \sim \delta(q_2, a)$, falls diese Übergänge definiert sind (daher nehmen wir im Folgenden oft eine totale Übergangsfunktion an)

Eigenschaft: \sim ist **verträglich** mit der Übergangsfunktion.

Notation für Äquivalenzrelationen

Wir verwenden die bei Äquivalenzen üblichen Begriffe:

Wir schreiben $[q]_{\sim}$ für die \sim -Äquivalenzklasse von q , d.h.

$$[q]_{\sim} = \{p \in Q \mid q \sim p\}.$$

Für eine Menge $P \subseteq Q$ schreiben wir P/\sim für den Quotienten von P und \sim :


$$P/\sim = \{[p]_{\sim} \mid p \in P\}.$$

(Die Quotientenbildung heißt Faktorisierung; sie entspricht dem „Verschmelzen“ äquivalenter Zustände.)


Wie immer gilt:

- Wenn $q_1 \sim q_2$ dann $[q_1]_{\sim} = [q_2]_{\sim}$
- Unterschiedliche Äquivalenzklassen sind disjunkt, d.h. $[q_1]_{\sim} \neq [q_2]_{\sim}$ impliziert $[q_1]_{\sim} \cap [q_2]_{\sim} = \emptyset$
- Die Äquivalenzklassen partitionieren Q , d.h. Q ist die Vereinigung der (disjunkten) Klassen

Beispiel



Es ergibt sich der folgende Quotientenautomat:



Der Quotientenautomat

Wir vereinfachen Automaten, indem wir äquivalente Zustände verschmelzen:

Für einen DFA $\mathcal{M} = \langle Q, \Sigma, \delta, q_0, F \rangle$ mit totaler Übergangsfunktion ist der Quotientenautomat \mathcal{M}/\sim gegeben durch $\mathcal{M}/\sim = \langle Q/\sim, \Sigma, \delta_{\sim}, [q_0]_{\sim}, F/\sim \rangle$ wobei gilt:

- $Q/\sim = \{[q]_{\sim} \mid q \in Q\}$
- $\delta_{\sim}([q]_{\sim}, a) = [\delta(q, a)]_{\sim}$
- $F/\sim = \{[q]_{\sim} \mid q \in F\}$

Diese Definition ergibt Sinn, da gilt:

- wenn $[q]_{\sim} = [p]_{\sim}$ dann $[\delta(q, a)]_{\sim} = [\delta(p, a)]_{\sim}$ (Verträglichkeit von \sim und δ ; benötigt totale Übergangsfunktion)
- wenn $[q]_{\sim} = [p]_{\sim}$ dann $q \in F$ gdw. $p \in F$ (Übung)

\rightsquigarrow Definition unabhängig vom gewählten Repräsentanten von $[q]_{\sim}$

Korrektheit Quotientenautomat

Satz: Für jeden totalen DFA \mathcal{M} gilt $\mathbf{L}(\mathcal{M}) = \mathbf{L}(\mathcal{M}/\sim)$.

Beweis: Für alle $w \in \Sigma^*$ gilt:

- | | | |
|---------------------------------|--|---------------------------|
| $w \in \mathbf{L}(\mathcal{M})$ | gdw. $\delta(q_0, w) \in F$ | laut Definition |
| | gdw. $[\delta(q_0, w)]_{\sim} \in F/\sim$ | wie zuvor bemerkt (Übung) |
| | gdw. $\delta_{\sim}([q_0]_{\sim}, w) \in F/\sim$ | Lemma ♥ |
| | gdw. $w \in \mathbf{L}(\mathcal{M}/\sim)$ | laut Definition |

Lemma ♥: Für beliebige $q \in Q$ und $w \in \Sigma^*$ gilt:

$$[\delta(q, w)]_{\sim} = \delta_{\sim}([q]_{\sim}, w).$$

Beweis durch Induktion über $|w|$ (Übung)

□

Berechnung von $\sim_{\mathcal{M}}$

Wie kann man $\sim_{\mathcal{M}}$ praktisch ermitteln?

Zuvor bemerkten wir:

- (1) Wenn $q_1 \sim q_2$ dann $q_1 \in F$ gdw. $q_2 \in F$
- (2) Wenn $q_1 \sim q_2$ dann $\delta(q_1, a) \sim \delta(q_2, a)$

Umgekehrt gilt also:

- (1') Wenn $q_1 \in F$ und $q_2 \notin F$ dann $q_1 \not\sim q_2$
- (2') Wenn $\delta(q_1, a) \not\sim \delta(q_2, a)$ dann $q_1 \not\sim q_2$

Tatsächlich ist $\not\sim$ die kleinste Relation, die (1') und (2') erfüllt.

\rightsquigarrow Wir können $\not\sim$ (und damit auch \sim) durch rekursive Anwendung der Regeln (1') und (2') berechnen

Darstellung von $\not\sim$ im Algorithmus

Die Anweisung „speichere $q \not\sim p$ “ könnte umgesetzt werden als:

$$\not\sim := \not\sim \cup \{\langle q, p \rangle, \langle p, q \rangle\}$$

Es ist aber nicht nötig, alle Paare in $\not\sim$ einzeln zu speichern:

- $\not\sim$ ist irreflexiv, d.h. man muss $q \not\sim q$ nicht betrachten
- $\not\sim$ ist symmetrisch, d.h. man muss jeweils nur entweder $q \not\sim p$ oder $p \not\sim q$ betrachten

\rightsquigarrow Halb-Tabelle genügt zum Eintragen der möglichen Paare

Beispiel: Für einen DFA mit Zuständen $Q = \{A, B, C, D, E\}$ genügt eine Tabelle mit zehn Feldern (statt $5^2 = 25$).

(dazu reihen wir Zustände vertikal in umgekehrter Reihenfolge)

	A	B	C	D
E				
D				
C				
B				


Algorithmus zur Berechnung von $\sim_{\mathcal{M}}$

Eingabe: DFA $\mathcal{M} = \langle Q, \Sigma, \delta, q_0, F \rangle$

Ausgabe: $\sim_{\mathcal{M}}$

- Initialisiere $\not\sim := \emptyset$
- (Regel 1) Für jedes Paar von Zuständen $\langle q, p \rangle \in Q \times Q$: falls $q \in F$ und $p \notin F$, dann „speichere $q \not\sim p$ “
- (Regel 2) Für jedes Paar $\langle q, p \rangle \in Q \times Q \setminus \not\sim$ und jedes $a \in \Sigma$: falls $\delta(q, a) \not\sim \delta(p, a)$ dann „speichere $q \not\sim p$ “
- Wiederhole die Anwendung von Regel 2 solange, bis es keine Änderungen mehr gibt
- Das Ergebnis ist $(Q \times Q) \setminus \not\sim$

Beispiel Quotientenautomat



- (1) $q \in F$ und $p \notin F$ impliziert $q \not\sim p$
- (2) $\delta(q, a) \not\sim \delta(p, a)$ impliziert $q \not\sim p$


Wir tragen in der Tabelle jeweils die Wörter ein, die $q \not\sim p$ zeigen:

	A	B	C	D
E	ϵ	ϵ	ϵ	ϵ
D	0		0	
C		0		
B	0			


Weitere Abarbeitung von Regel (2) führt nicht mehr zu Änderungen

$$\sim = \{\langle B, D \rangle, \langle D, B \rangle, \langle A, C \rangle, \langle C, A \rangle\} \cup \{\langle q, q \rangle \mid q \in Q\}$$

Beispiel Quotientenautomat



Quotientenautomat:



Korrektheit Minimalautomat

Satz: \mathcal{M}_r ist bezüglich der Zustandsmenge der minimale DFA mit totaler Übergangsfunktion, der die Sprache $\mathbf{L}(\mathcal{M})$ erkennt.

Beweisplan:

- (Behauptung 1) \mathcal{M}_r erkennt $\mathbf{L}(\mathcal{M})$: Dies folgt aus der Korrektheit der Quotientenbildung bei Automaten
- (Behauptung 2) \mathcal{M}_r ist minimal für diese Eigenschaft: Wir werden dies in mehreren Schritten zeigen:
 - Wir konstruieren einen weiteren minimalen Automaten $\mathcal{M}_{\mathbf{L}}$ direkt aus \mathbf{L}
 - Wir zeigen, dass $\mathcal{M}_{\mathbf{L}}$ und \mathcal{M}_r bis auf Umbenennung von Zuständen gleich sind

Damit ist auch die behauptete Eindeutigkeit gezeigt.

Reduktion von Automaten

Wir können das bisher gezeigte zusammenfassen:

Sei \mathcal{M} ein DFA mit totaler Übergangsfunktion. Der **reduzierte Automat** \mathcal{M}_r ergibt sich durch folgende Schritte:

- (1) Entferne alle unerreichbaren Zustände aus \mathcal{M}
- (2) Berechne den Quotientenautomaten

Dieses Verfahren erzeugt den gewünschten minimalen DFA:

Satz: \mathcal{M}_r ist bezüglich der Zustandsmenge der minimale DFA mit totaler Übergangsfunktion, der die Sprache $\mathbf{L}(\mathcal{M})$ erkennt.

Zudem stellt sich heraus, dass dieser minimale DFA eindeutig ist:

Satz: Alle minimalen DFA mit totaler Übergangsfunktion, die $\mathbf{L}(\mathcal{M})$ erkennen, sind bis auf Umbenennung von Zuständen gleich (sie sind **isomorph**). Daher hängt \mathcal{M}_r nur von $\mathbf{L}(\mathcal{M})$ ab, nicht von \mathcal{M} .

Die Nerode-Rechtskongruenz

Für eine Sprache $\mathbf{L} \subseteq \Sigma^*$ ist die **Nerode-Rechtskongruenz** $\approx_{\mathbf{L}}$ wie folgt definiert. Für Wörter $u, v \in \Sigma^*$ sei $u \approx_{\mathbf{L}} v$ wenn gilt:

für alle $w \in \Sigma^*$ gilt $uw \in \mathbf{L}$ genau dann wenn $vw \in \mathbf{L}$.

Wenn \mathbf{L} klar ist, dann schreiben wir einfach \approx statt $\approx_{\mathbf{L}}$

Anders gesagt: zwei Wörter v und u sind kongruent, wenn man in einem Wort das Präfix v gegen u vertauschen kann, ohne dass dies den Status des Worts bezüglich \mathbf{L} verändert

Dies kann mit der Idee der Zustandsäquivalenz verglichen werden:

(Rückblick) Für Zustände $p, q \in Q$ sei $p \sim q$ wenn gilt:

für alle $w \in \Sigma^*$ gilt $\delta(p, w) \in F$ genau dann wenn $\delta(q, w) \in F$.

Eigenschaften von \approx

Definition (kurz): $u \approx_{\mathbf{L}} v$ wenn für alle $w \in \Sigma^*$ gilt: $uw \in \mathbf{L}$ genau dann wenn $vw \in \mathbf{L}$.

Damit sehen wir leicht:

- \approx ist reflexiv: $u \approx u$
- \approx ist symmetrisch: wenn $u \approx v$ dann $v \approx u$
- \approx ist transitiv: wenn $u \approx v$ und $v \approx w$ dann $u \approx w$

(jeweils für alle $u, v, w \in \Sigma^*$)

Eigenschaft: \approx ist eine Äquivalenzrelation.

Außerdem gilt für alle $w \in \Sigma^*$

- wenn $u \approx v$ dann $uw \approx vw$

Eigenschaft: \approx ist verträglich mit der Konkatination von rechts.

Dies rechtfertigt die Bezeichnung **Rechtskongruenz**.

Beispiel

Die Sprache $\mathbf{L} = \{\mathbf{a}\}^*\{\mathbf{b}\}^*$ hat die folgenden Nerode-Äquivalenzklassen:

- $[\epsilon]_{\approx} = \{\mathbf{a}\}^*$: für jedes $v \in [\epsilon]_{\approx}$ ist $vw \in \mathbf{L}$ gdw. $w \in \mathbf{L}$
- $[\mathbf{b}]_{\approx} = \{\mathbf{a}\}^*\{\mathbf{b}\}^+$: für jedes $v \in [\mathbf{b}]_{\approx}$ ist $vw \in \mathbf{L}$ gdw. $w \in \{\mathbf{b}\}^*$
- $[\mathbf{ba}]_{\approx} = \Sigma^* \setminus \mathbf{L}$: für jedes $v \in [\mathbf{ba}]_{\approx}$ ist $vw \notin \mathbf{L}$ für alle $w \in \Sigma^*$

Die endliche Sprache $\mathbf{L} = \{\mathbf{a}, \mathbf{ab}, \mathbf{ba}\}$ hat die folgenden Nerode-Äquivalenzklassen:

- $[\epsilon]_{\approx} = \{\epsilon\}$: $\epsilon w \in \mathbf{L}$ gdw. $w \in \mathbf{L}$
- $[\mathbf{a}]_{\approx} = \{\mathbf{a}\}$: $\mathbf{a}w \in \mathbf{L}$ gdw. $w \in \{\epsilon, \mathbf{b}\}$
- $[\mathbf{ab}]_{\approx} = \{\mathbf{ab}, \mathbf{ba}\}$: für jedes $v \in [\mathbf{ab}]_{\approx}$ ist $vw \in \mathbf{L}$ gdw. $w = \epsilon$
- $[\mathbf{b}]_{\approx} = \Sigma^* \setminus \{\epsilon, \mathbf{a}, \mathbf{ab}, \mathbf{ba}\}$: für jedes $v \in [\mathbf{b}]_{\approx}$ ist $vw \notin \mathbf{L}$ für alle $w \in \Sigma^*$

Beispiel (2)

Die Sprache $\mathbf{L} = \{\mathbf{a}^n\mathbf{b}^n \mid n \geq 0\}$ hat die folgenden Nerode-Äquivalenzklassen:

- $[\epsilon]_{\approx} = \{\epsilon\}$: $\epsilon w \in \mathbf{L}$ gdw. $w \in \mathbf{L}$
- $[\mathbf{a}]_{\approx} = \{\mathbf{a}\}$: $\mathbf{a}w \in \mathbf{L}$ gdw. $w \in \{\mathbf{a}^n\mathbf{b}^{n+1} \mid n \geq 0\}$
- $[\mathbf{aa}]_{\approx} = \{\mathbf{aa}\}$: $\mathbf{aa}w \in \mathbf{L}$ gdw. $w \in \{\mathbf{a}^n\mathbf{b}^{n+2} \mid n \geq 0\}$
- $[\mathbf{aaa}]_{\approx} = \{\mathbf{aaa}\}$: $\mathbf{aaa}w \in \mathbf{L}$ gdw. $w \in \{\mathbf{a}^n\mathbf{b}^{n+3} \mid n \geq 0\}$
- ... unendlich viele Äquivalenzklassen $[\mathbf{a}^n]_{\approx} = \{\mathbf{a}^n\}$

Es gibt weitere Formen von Äquivalenzklassen, z.B. $[\mathbf{aab}]_{\approx} = \{\mathbf{a}^{n+1}\mathbf{b}^n \mid n \geq 0\}$.

$\rightsquigarrow \mathbf{L} = \{\mathbf{a}^n\mathbf{b}^n \mid n \geq 0\}$ hat unendlich viele Nerode-Äquivalenzklassen

\approx und reguläre Sprachen

Satz: Wenn \mathbf{L} regulär ist, dann hat $\approx_{\mathbf{L}}$ endlich viele Äquivalenzklassen.

(Die Zahl der Äquivalenzklassen wird auch als **Index** bezeichnet)

Beweis: Wir erhalten diese Eigenschaft aus der Darstellung von \mathbf{L} mit einem DFA.

Für einen DFA $\mathcal{M} = \langle Q, \Sigma, \delta, q_0, F \rangle$ definieren wir eine Relation $\approx_{\mathcal{M}}$ wie folgt. Für Wörter $u, v \in \Sigma^*$ sei $u \approx_{\mathcal{M}} v$ wenn gilt:

$$\delta(q_0, u) = \delta(q_0, v).$$

Offensichtlich ist $\approx_{\mathcal{M}}$ eine Äquivalenzrelation (Eigenschaften „geerbt“ von $=$) mit endlichem Index (es gibt nur endlich viele Zustände).

≈ und reguläre Sprachen (2)

Satz: Wenn L regulär ist, dann hat \approx_L endlich viele Äquivalenzklassen.

Beweis (Fortsetzung): Behauptung: $\approx_M \subseteq \approx_L$ das heißt

wenn $u \approx_M v$ dann $u \approx_L v$

Wir betrachten einen DFA \mathcal{M} mit $L = L(\mathcal{M})$.

- Seien $u, v \in \Sigma^*$ Wörter mit $u \approx_M v$
- Dann ist $\delta(q_0, u) = \delta(q_0, v)$
- Dann gilt, für alle $w \in \Sigma^*$, $\delta(q_0, uw) = \delta(q_0, vw)$
- Dann gilt, für alle $w \in \Sigma^*$, $\delta(q_0, uw) \in F$ gdw. $\delta(q_0, vw) \in F$
- Dann gilt, für alle $w \in \Sigma^*$, $uw \in L(\mathcal{M})$ gdw. $vw \in L(\mathcal{M})$
- Dann ist $u \approx_{L(\mathcal{M})} v$ und also $u \approx_L v$

Damit ist die Behauptung gezeigt.

≈ und reguläre Sprachen (3)

Satz: Wenn L regulär ist, dann hat \approx_L endlich viele Äquivalenzklassen.

Beweis (Fortsetzung): Wir haben gezeigt, dass $\approx_M \subseteq \approx_L$.

→ Jede \approx_L -Äquivalenzklasse besteht aus einer oder mehr \approx_M -Äquivalenzklassen

→ Der Index von \approx_L ist kleiner oder gleich dem Index von \approx_M

→ Der Index von \approx_L ist endlich □

Anmerkung: Der letzte Teil ist eine allgemeine Eigenschaft aller Äquivalenzrelationen: wenn $R \subseteq S$, dann ist der Index von R größer oder gleich dem Index von S .

Der Satz von Myhill und Nerode

Das vorige Resultat kann noch verstärkt werden:

Satz (Myhill & Nerode): Eine Sprache L ist genau dann regulär, wenn \approx_L endlich viele Äquivalenzklassen hat.

Beweis: Die Richtung „ \Rightarrow “ haben wir soeben gezeigt.

Für die Richtung „ \Leftarrow “ zeigen wir, wie man einen DFA \mathcal{M}_L für L erhalten kann, wenn \approx_L endlich viele Äquivalenzklassen hat.

Der DFA $\mathcal{M}_L = \langle Q, \Sigma, \delta, q_0, F \rangle$ ist wie folgt definiert:

- $Q = \{[w]_{\approx} \mid w \in \Sigma^*\}$ ist die (endliche) Menge der \approx -Äquivalenzklassen
- $q_0 = [\epsilon]_{\approx}$
- $F = \{[w]_{\approx} \mid w \in L\}$
- $\delta([w]_{\approx}, a) = [wa]_{\approx}$

Anmerkung: Diese Definition von F und δ ist zulässig, weil sie nicht vom gewählten Repräsentanten w abhängt (da \approx eine Rechtskongruenz ist)

Satz von Myhill und Nerode: Beweis

Beweis (Fortsetzung): Wir müssen noch zeigen, dass $L = L(\mathcal{M}_L)$.

$w \in L(\mathcal{M}_L)$ gdw. $\delta(q_0, w) \in F$

gdw. $\delta([\epsilon]_{\approx}, w) \in F$

gdw. $[w]_{\approx} \in F$ wegen $\delta([u], v) = [uv]$
(Induktion über $|v|$)

gdw. $w \in L$ □

Zusammenfassung und Ausblick

Im **Quotientenautomaten** werden äquivalente Zustände verschmolzen

Äquivalente Zustände in einem (totalen) DFA können rekursiv ermittelt werden

Der **Satz von Myhill und Nerode** charakterisiert reguläre Sprachen und liefert einen direkt konstruierten DFA für eine Sprache

Offene Fragen:

- Wie geht es weiter mit dem Beweis der Eindeutigkeit des Minimalautomaten?
- Wie aufwändig sind die verschiedenen Konstruktionen auf regulären Sprachen?
- Welche Sprachen sind nicht regulär?