Compilerbau

Wintersemester 2009 / 2010

Dr. Heiko Falk

Technische Universität Dortmund

Lehrstuhl Informatik 12

Entwurfsautomatisierung für Eingebettete Systeme

Kapitel 3

Lexikalische Analyse (Scanner)

Gliederung der Vorlesung

- Kapitel 1: Compiler – Abhängigkeiten und Anforderungen
- Kapitel 2: Interner Aufbau von Compilern
- **Kapitel 3: Lexikalische Analyse (Scanner)**
  - Von Regulären Ausdrücken zu Nichtdeterministischen Automaten
  - Von Nichtdeterministischen zu Deterministischen Automaten
  - Automaten-Minimierung
  - Praktische Umsetzung: FLEX
- Kapitel 4: Syntaktische Analyse (Parser)
- Kapitel 5: Semantische Analyse
- Kapitel 6: Instruktionsauswahl
- Kapitel 7: Register-Allokation
- Kapitel 8: Code-Optimierung
- Kapitel 9: Ausblick

Aufgabe der Lexikalischen Analyse (1)

- Zeichenweises Einlesen des Quellprogramms vom Start der Datei bis zum Ende
- Verwaltung eines Zeigers auf die aktuelle Position in der Quell-Datei

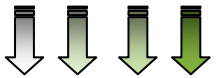

```
int main()
{
  int val = 41;

  return ++val;
}
```

Aufgabe der Lexikalischen Analyse (2)

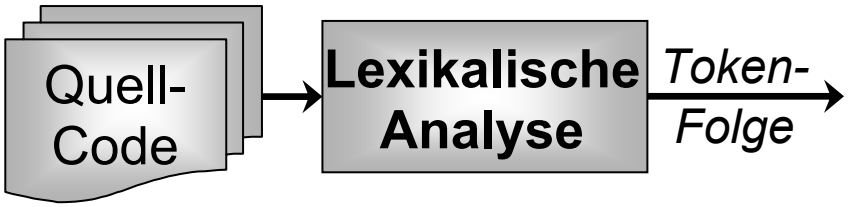

- Bestimmen des *längsten* Präfix der restlichen Quelldatei ab der aktuellen Position, der ein Wort besonderer Bedeutung der Quellsprache ist.

```
int main()
{
  int val = 41;
  return ++val;
}
```

Beispiel: Ab aktueller Position muss für C, C++, Java, … das Wort '**++**' erkannt werden, und nicht bloß '**+**'.

☞ Längste Präfixe!

Aufgabe der Lexikalischen Analyse (3)

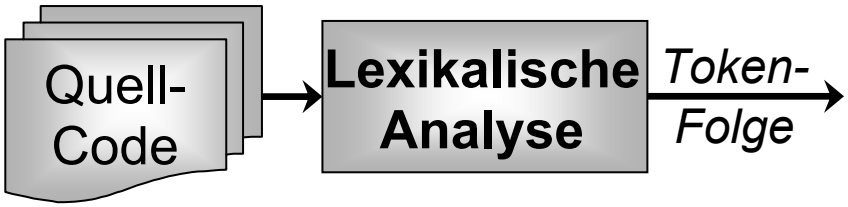

- Umwandeln des gefundenen Wortes von einer (unhandlichen) Zeichenkette in effizientere Codierung (Token)

```
int main()
{
  int val = 41;
        ⇓
  return ++val;
}
```

Beispiel: Erzeugung des Tokens

- (id, `val`) für den Bezeichner *(Identifier)* `val`, oder
- (1, 17) falls 1 der Code für Bezeichner ist und `val` der 17. gefundene Bezeichner ist.

Worte einer Sprache

- Eine endliche, nichtleere Menge von Zeichen $\sum$ heißt *Alphabet*.
- Ein *Wort x* über $\sum$ der Länge *n* ist eine endliche Folge von Zeichen aus $\sum$: $x : x_1 x_2 \ldots x_n$ mit $x_i \in \sum$

Spezielle Worte und Mengen von Worten:

ε		*Leeres Wort ohne Zeichen*
$\sum^0$	$\{ x \mid x : \varnothing \rightarrow \sum \} = \{ \varepsilon \}$	*Menge aller Worte ohne Zeichen*
$\sum^n$	$\{ x \mid x : \{1, \ldots, n\} \rightarrow \sum \}$	*Menge aller Worte der Länge n über* $\sum$
$\sum^*$	$\bigcup_{n \geq 0} \sum^n$	*Menge aller Worte über* $\sum$
$\sum^+$	$\bigcup_{n \geq 1} \sum^n$	*Menge aller nichtleeren Worte über* $\sum$
$x.y$	$x_1 \ldots x_n y_1 \ldots y_m$	*Konkatenation von* $x = x_1 \ldots x_n$ *und* $y = y_1 \ldots y_m$

Formale Sprachen

- *Formale Sprachen* über $\sum$ sind Teilmengen von $\sum^*$, d.h. Mengen irgendwelcher Worte über $\sum$.

Operationen auf formalen Sprachen L, L_1, L_2:

$L_1 \cup L_2$		*Vereinigung von Sprachen*
$L_1 L_2$	$\{ x.y \mid x \in L_1, y \in L_2 \}$	*Konkatenation von Sprachen*
$\overline{L}$	$\sum^* - L$	*Komplement einer Sprache*
L^n	$\{ x_1. \ldots .x_n \mid x_i \in L, 1 \leq i \leq n \}$	*n-fache Konkatenation*
L^*	$\bigcup_{n \geq 0} L^n$	*Abschluss einer Sprache*
L^+	$\bigcup_{n \geq 1} L^n$	*Nichtleerer Abschluss*

Zusammenhang Scanner ↔ Sprachen

- Die vom Scanner erkannten Worte der Quellsprache bilden eine nichtleere *reguläre Sprache*.
- Reguläre Sprachen lassen sich mit Hilfe *regulärer Ausdrücke* beschreiben.
- Reguläre Sprachen können durch *endliche Automaten* erkannt werden.

Grundlegender Ablauf zum Entwurf eines Scanners:

- ☞ Beschreibung der Worte der Quellsprache mit Hilfe regulärer Ausdrücke.
- ☞ (Automatisierte) Überführung der regulären Ausdrücke in endliche Automaten, die die Worte der Quellsprache erkennen.

Reguläre Sprachen

Definition *(Reguläre Sprache)*:

Sei $\sum$ ein Alphabet.

- $\varnothing$ und $\{ \varepsilon \}$ sind reguläre Sprachen über $\sum$.
- Für alle $a \in \sum$ ist $\{ a \}$ eine reguläre Sprache.
- Sind R_1 und R_2 reguläre Sprachen über $\sum$, so auch
  - $R_1 \cup R_2$
  - $R_1 R_2$ und
  - R_1^*

Reguläre Ausdrücke

Definition *(Regulärer Ausdruck)*:

Sei $\sum$ ein Alphabet.

- $\underline{\varnothing}$ ist ein regulärer Ausdruck für die reguläre Sprache $\varnothing$
- $\underline{\varepsilon}$ ist ein regulärer Ausdruck für die reguläre Sprache $\{ \varepsilon \}$
- a (für $a \in \sum$) ist ein regulärer Ausdruck für die reguläre Sprache $\{ a \}$
- Sind r_1 und r_2 reguläre Ausdrücke für die regulären Sprachen R_1 und R_2, so ist
  - $r_1|r_2$ ein regulärer Ausdruck für die reguläre Sprache $R_1 \cup R_2$,
  - $r_1 r_2$ ein regulärer Ausdruck für die reguläre Sprache $R_1 R_2$,
  - r_1^* ein regulärer Ausdruck für die reguläre Sprache R_1^*.

Reguläre Ausdrücke und Sprachen

Beispiel:

Sei $\sum = \{ a, b \}$ ein Alphabet.

	Regulärer Ausdruck	Reguläre Sprache	Worte
▪	$a\|b$	$\{ a, b \}$	a, b
▪	ab^*a	$\{a\}\{b\}^*\{a\}$	aa, aba, $abba$, $abbba$, …
▪	$(ab)^*$	$\{ ab \}^*$	ε, ab, $abab$, …
▪	$abba$	$\{a\}\{b\}\{b\}\{a\}$	$abba$

Nichtdeterministische Endliche Automaten

Definition *(Nichtdeterministischer Endlicher Automat, NEA)*:

Ein *nichtdeterministischer endlicher Automat* ist ein Tupel

$M = (\Sigma, Q, q_0, F, \Delta)$ mit

- Σ: endliches **Eingabealphabet**
- Q: endliche Menge von **Zuständen**
- $q_0 \in Q$: **Anfangszustand**
- $F \subseteq Q$: Menge der **akzeptierenden Endzustände**
- $\Delta \subseteq Q \times (\Sigma \cup \{\varepsilon\}) \times Q$: Relation der **Zustandsübergänge**

Schritte eines NEAs

Definition *(Schrittrelation)*:

Sei $M = (\Sigma, Q, q_0, F, \Delta)$ ein NEA. Ein Paar (q, w) mit $q \in Q$ und $w \in \Sigma^*$ heißt *Konfiguration*. Die *Schrittrelation* $\overset{}{\underset{M}{\vdash}}$ setzt Konfigurationen in Beziehung:

$(q, ew) \overset{}{\underset{M}{\vdash}} (p, w) \Leftrightarrow (q, e, p) \in \Delta$ und $e \in \Sigma \cup \{ \varepsilon \}$

$\overset{*}{\underset{M}{\vdash}}$ bezeichnet die transitive Hülle der Schrittrelation.

In Worten: Die Schrittrelation $\overset{}{\underset{M}{\vdash}}$ modelliert einen einzelnen Zustandsübergang von M von aktuellem Zustand q in Folgezustand p für ein Eingabezeichen e bzw. ε und ein Rest-Wort w.

$\overset{*}{\underset{M}{\vdash}}$ modelliert eine ganze Folge einzelner Schritte für ein Wort w.

Arbeitsweise von NEAs

Eingabeband:

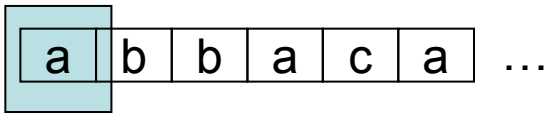

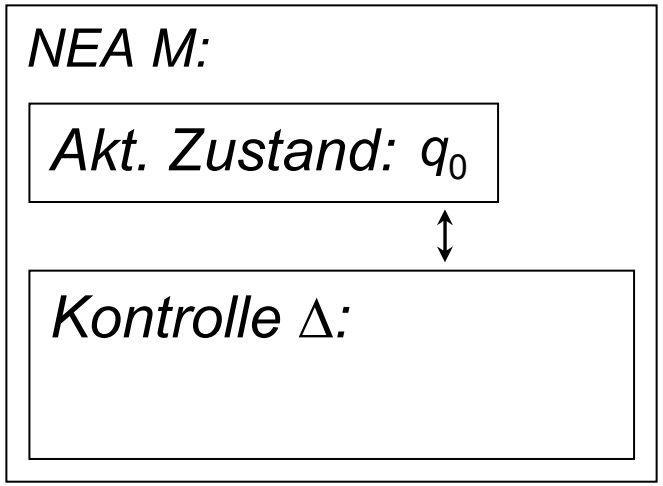

Start des Automaten:

- Lesekopf steht auf erstem Zeichen der Eingabe
- Speicher des Automaten enthält Anfangszustand q_0

Arbeitsweise von NEAs

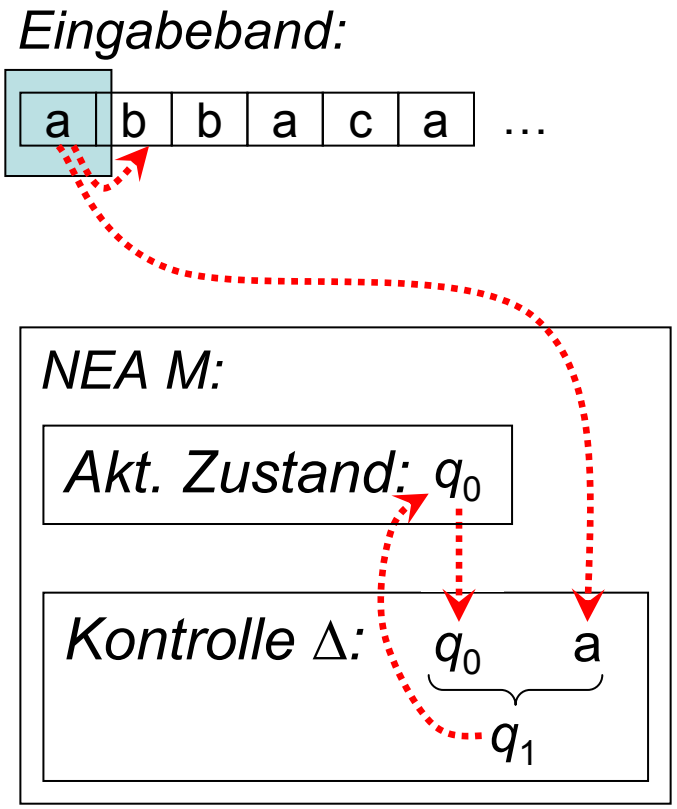

Pro Verarbeitungsschritt:

- „Raten" der aktuellen Eingabe *e*: entweder aktuelles Zeichen unter Lesekopf oder 'ε'.
  (☞ *Nichtdeterminismus)*
- Berechnen des Folgezustands q_{i+1} anhand von aktuellem Zustand q_i und Eingabe *e*: $q_{i+1} \in \Delta(q_i, e)$
- Abspeichern von q_{i+1}
- Nur falls Zeichen von Eingabeband gelesen wurde: Lesekopf um eine Position nach rechts bewegen.

Arbeitsweise von NEAs

Eingabeband:

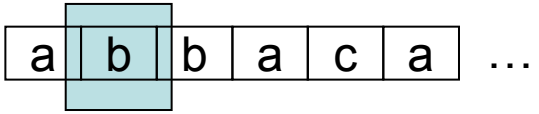

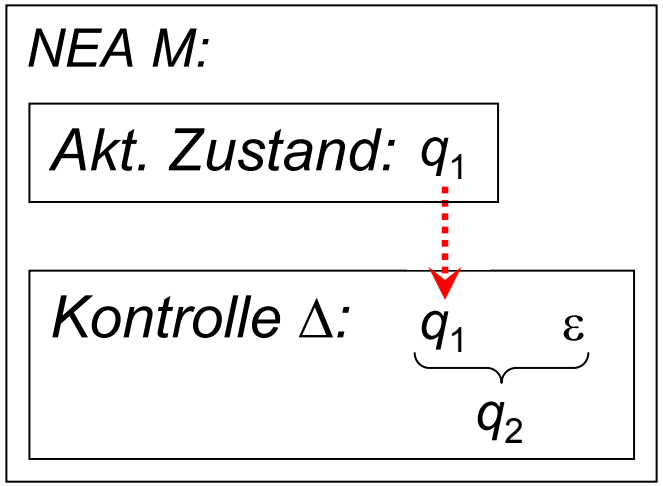

Pro Verarbeitungsschritt:

- „Raten" der aktuellen Eingabe *e*: entweder aktuelles Zeichen unter Lesekopf oder 'ε'.
  (☞ *Nichtdeterminismus)*
- Berechnen des Folgezustands q_{i+1} anhand von aktuellem Zustand q_i und Eingabe *e*: $q_{i+1} \in \Delta(\, q_i, e\,)$
- Abspeichern von q_{i+1}
- Nur falls Zeichen von Eingabeband gelesen wurde: Lesekopf um eine Position nach rechts bewegen.

Arbeitsweise von NEAs

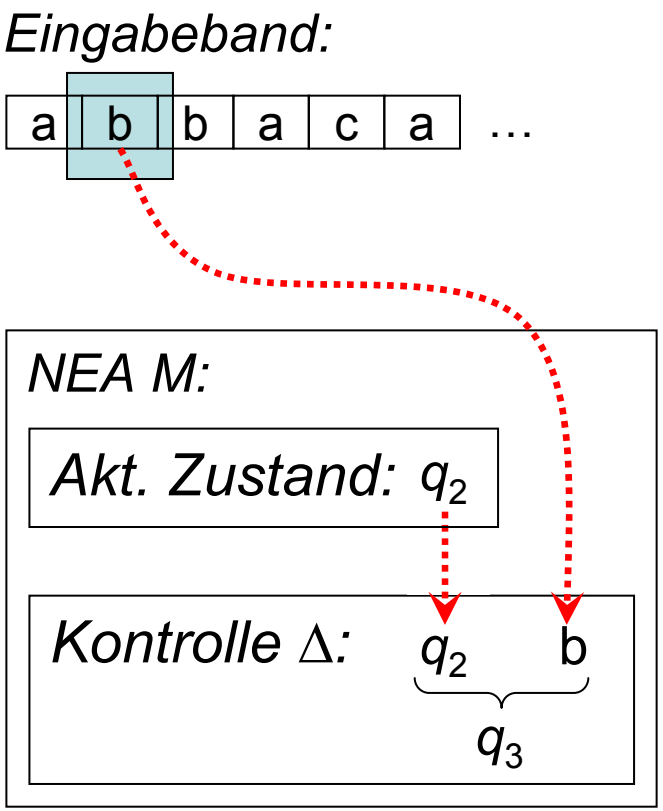

Pro Verarbeitungsschritt:

- „Raten" der aktuellen Eingabe *e*: entweder aktuelles Zeichen unter Lesekopf oder 'ε'.
  (☞ *Nichtdeterminismus)*
- Berechnen des Folgezustands q_{i+1} anhand von aktuellem Zustand q_i und Eingabe *e*: $q_{i+1} \in \Delta(\, q_i, e\,)$
- Abspeichern von q_{i+1}
- Nur falls Zeichen von Eingabeband gelesen wurde: Lesekopf um eine Position nach rechts bewegen.

Arbeitsweise von NEAs

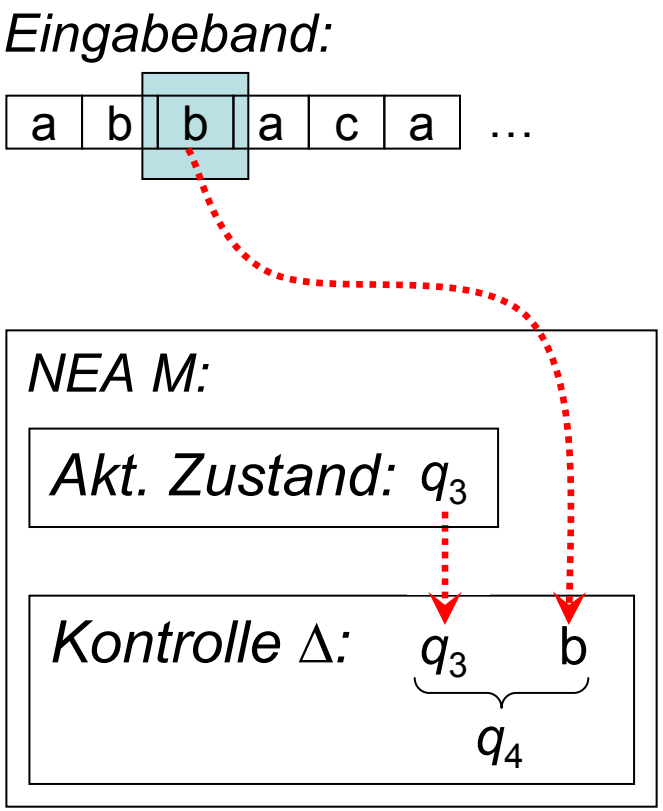

Pro Verarbeitungsschritt:

- „Raten" der aktuellen Eingabe *e*: entweder aktuelles Zeichen unter Lesekopf oder 'ε'.
  (☞ *Nichtdeterminismus)*
- Berechnen des Folgezustands q_{i+1} anhand von aktuellem Zustand q_i und Eingabe *e*: $q_{i+1} \in \Delta(\, q_i, e\,)$
- Abspeichern von q_{i+1}
- Nur falls Zeichen von Eingabeband gelesen wurde: Lesekopf um eine Position nach rechts bewegen.

Arbeitsweise von NEAs

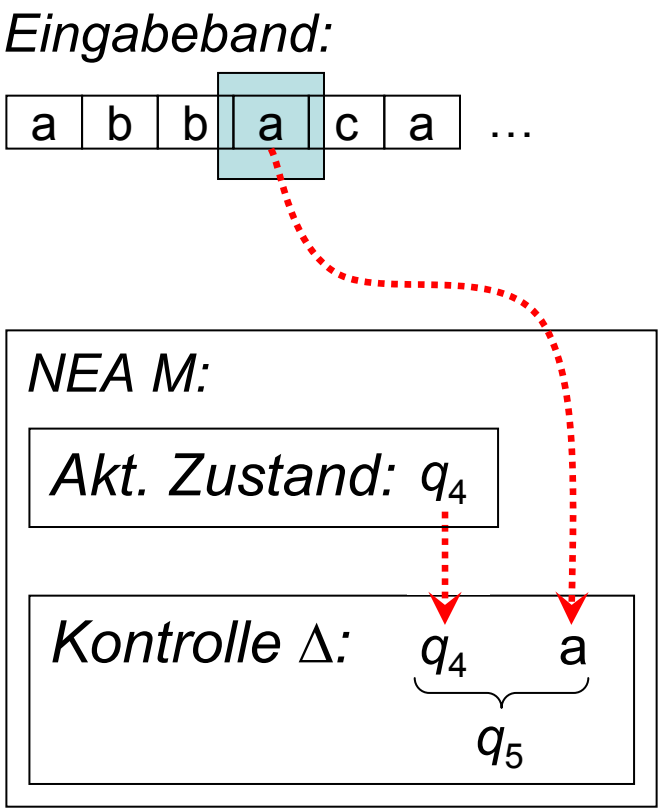

Pro Verarbeitungsschritt:

- „Raten" der aktuellen Eingabe *e*: entweder aktuelles Zeichen unter Lesekopf oder 'ε'.
  (☞ *Nichtdeterminismus)*
- Berechnen des Folgezustands q_{i+1} anhand von aktuellem Zustand q_i und Eingabe *e*: $q_{i+1} \in \Delta(q_i, e)$
- Abspeichern von q_{i+1}
- Nur falls Zeichen von Eingabeband gelesen wurde: Lesekopf um eine Position nach rechts bewegen.

Ein NEA als Scanner (1)

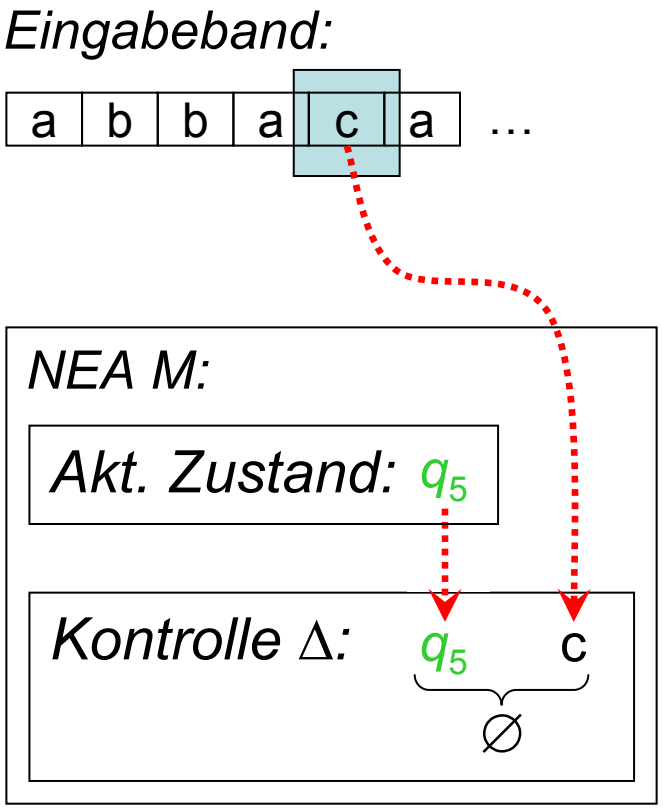

Gültiges Wort gefunden, wenn

- aktueller Zustand q_i ein Endzustand ist, d.h. $q_i \in F$, und
- für aktuelle Eingabe *e* kein weiterer Übergang möglich ist, d.h. $\Delta(q_i, e) = \varnothing$
- Gefundenes Wort: *abba*

Ein NEA als Scanner (2)

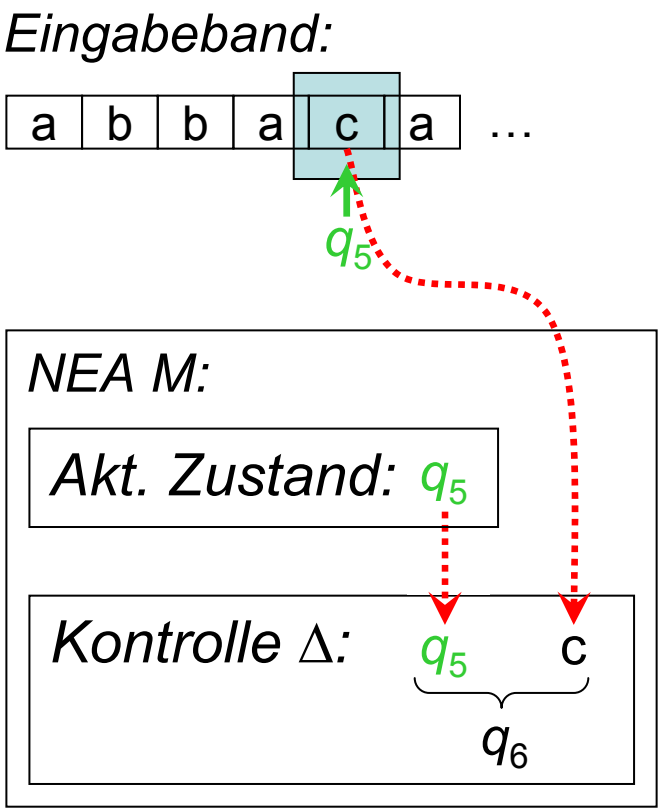

Gültiges Wort evtl. nicht-maximaler Länge gefunden, wenn

- aktueller Zustand q_i ein Endzustand ist, d.h. $q_i \in F$, und
- für aktuelle Eingabe *e* noch weitere Übergänge möglich sind, d.h. $\Delta(q_i, e) = q_{i+1} \neq \emptyset$

☞ Speichere aktuellen Zustand und Position des Lesekopfes in separatem Speicher zwischen.

☞ Fahre mit Folgezustand und Eingabe *e* wie gewohnt fort.

Ein NEA als Scanner (3)

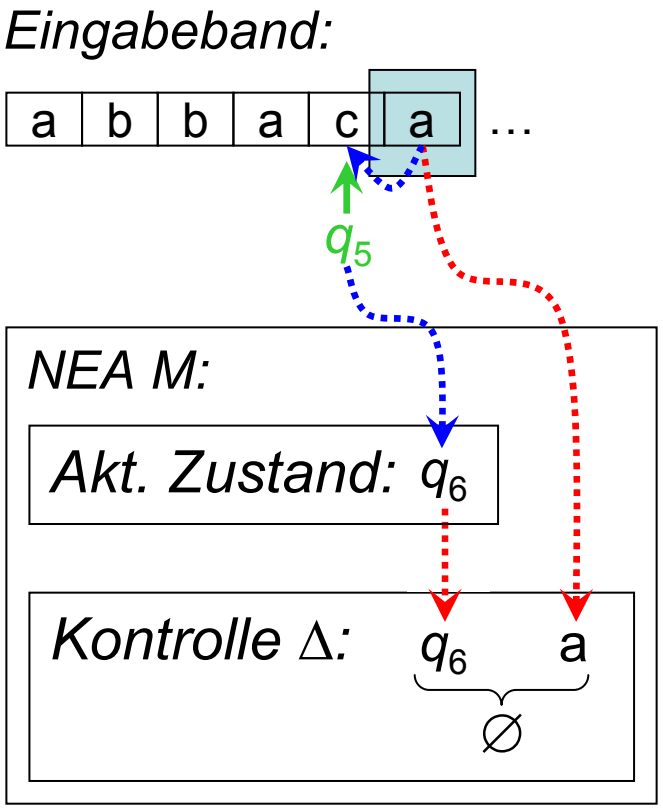

Entdeckung fehlerhafter Worte:

- Ist $\Delta(q_i, e) = \emptyset$, aber q_i kein akzeptierender Endzustand ($q_i \notin F$):
  - lade letzten Endzustand und Position des Lesekopfes aus separatem Speicher;
  - akzeptiere Wort, das nach diesem „Backtracking" erkannt wurde.
- Gefundenes Wort: *abba*

Ein NEA als Scanner (4)

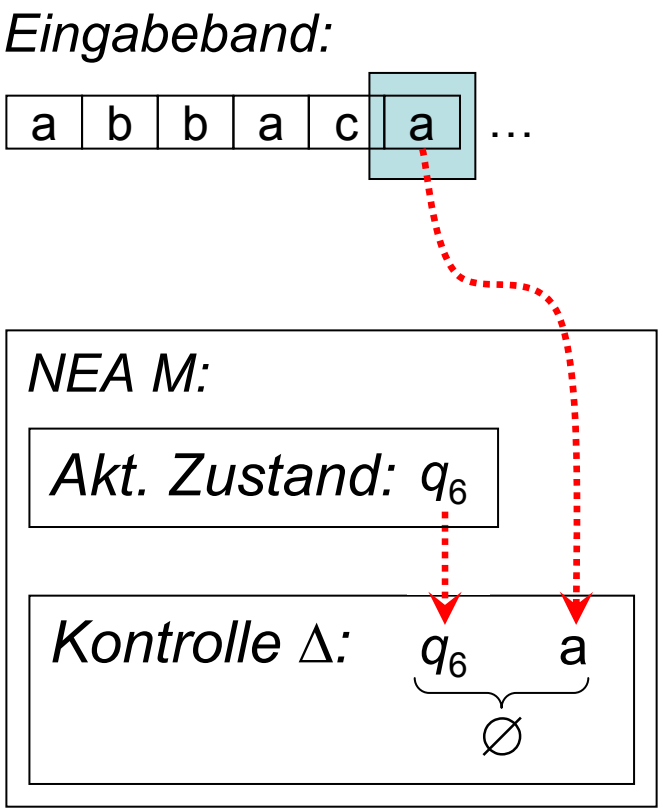

Entdeckung fehlerhafter Worte:

- Ist $\Delta(q_i, e) = \emptyset$, aber q_i kein akzeptierender Endzustand ($q_i \notin F$), und
- enthält separater Speicher noch keinen Endzustand:

☞ Die komplette bisher gelesene Eingabe repräsentiert kein Wort der Sprache.

☞ Abbruch mit Fehlermeldung

Beispiel: NEA für ganze und reale Konstanten

Zu erkennende Worte:

- Ganzzahlige Konstanten: alle Zahlen bestehend aus Ziffern `0` – `9`
  z.B. `042`
- Realzahlige Konstanten:
  - Bestehen aus Vorkommateil, einem '`.`' als Dezimalpunkt und einem Nachkommateil
  - Vorkommateil ist eine ganzzahlige Konstante wie oben
  - Nachkommateil ist eine ganzzahlige Konstante wie oben, optional gefolgt von '`E`' und einem zweistelligen dezimalen Exponenten

  z.B. `42.08E15`

Beispiel: NEA für ganze und reale Konstanten

Zustandsübergangsdiagramm:

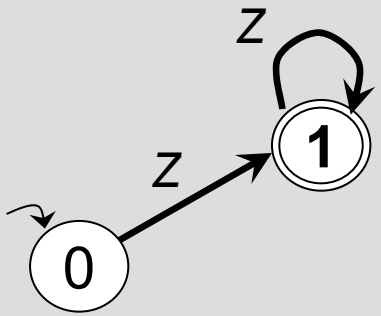

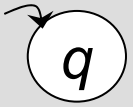

Startzustand

Akzeptierender Endzustand

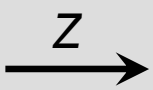

Zustandsübergang für eine der Ziffern aus **0** – **9**

- Dieser Teilautomat akzeptiert beliebige ganzzahlige Konstanten, die aus mindestens einer Ziffer bestehen.
- Regulärer Ausdruck für diesen Teilautomaten: ZZ^*

Beispiel: NEA für ganze und reale Konstanten

Zustandsübergangsdiagramm:

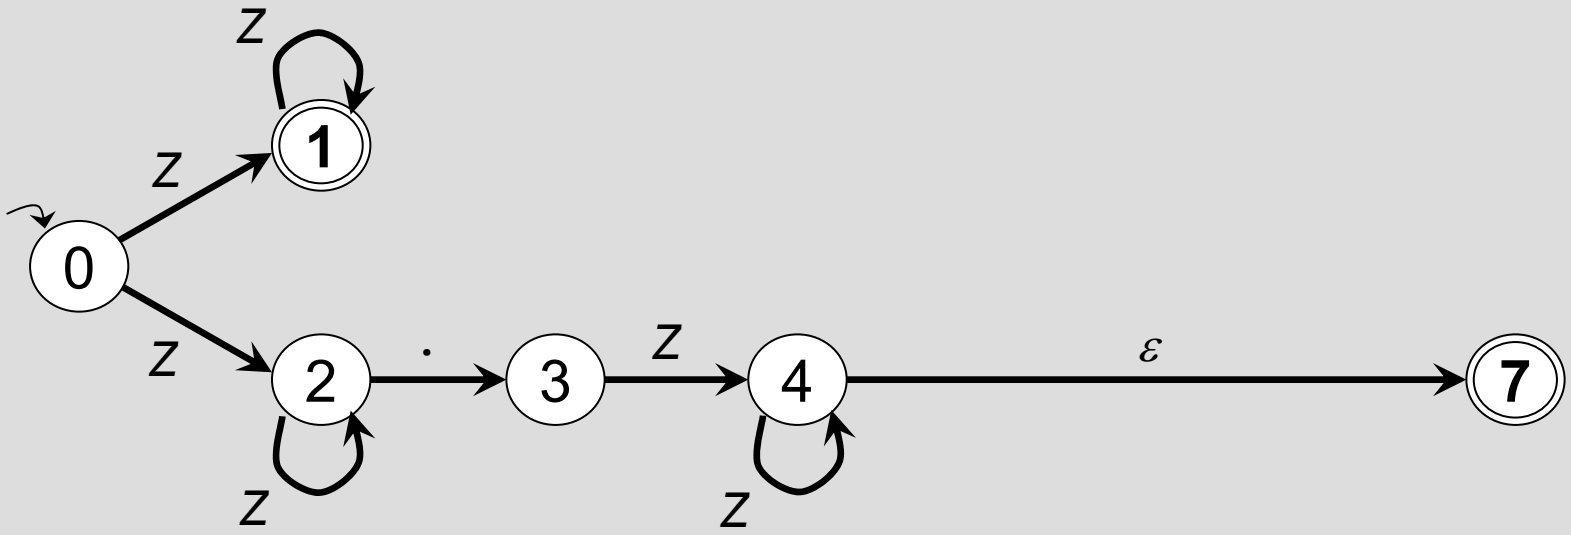

- Zusätzlich: Teilautomat akzeptiert beliebige reale Konstanten, deren Vor- & Nachkommateile aus mindestens einer Ziffer bestehen, getrennt durch ‘ . ’.
- Regulärer Ausdruck für diesen Teilautomaten: $ZZ^*(\varepsilon \mid .ZZ^*)$

Beispiel: NEA für ganze und reale Konstanten

Zustandsübergangsdiagramm:

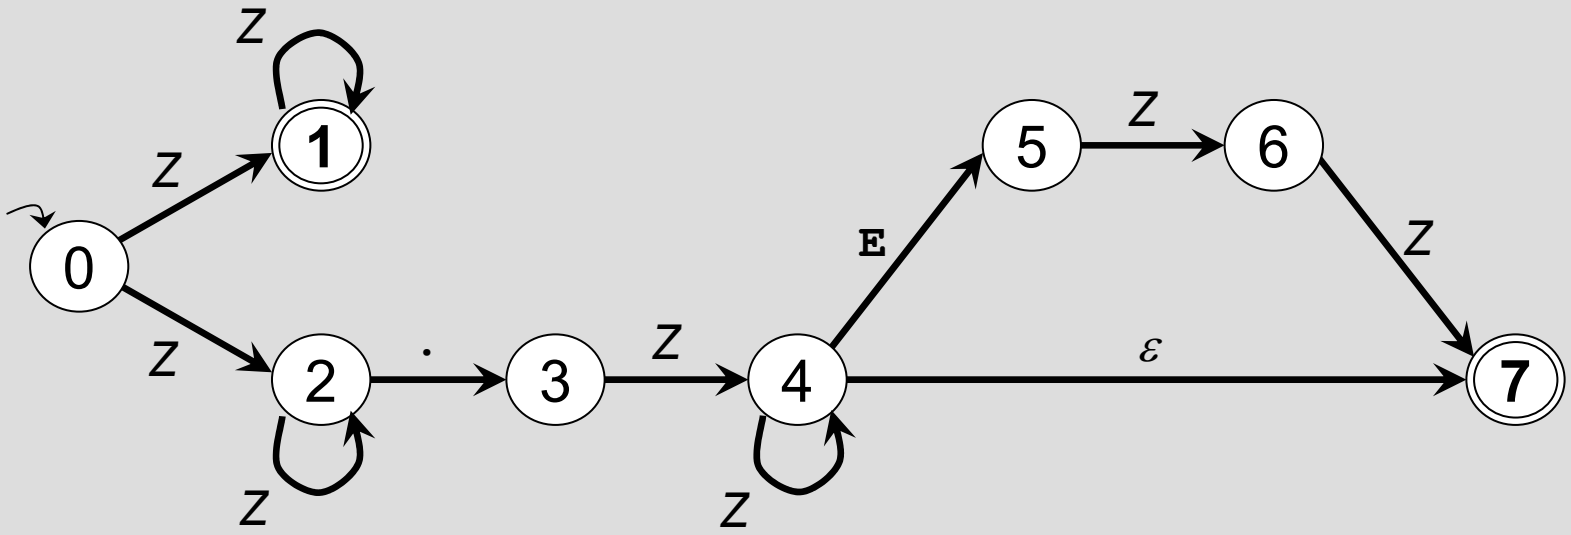

- Zusätzlich: Automat akzeptiert Nachkommateile mit optionalem zweistelligem Exponenten
- Regulärer Ausdruck für den kompletten Automaten:
  $ZZ^*(\underline{\varepsilon} \mid (\,.ZZ^*(\underline{\varepsilon} \mid \mathbf{E}ZZ)))$

NEA-Erzeugung aus Regulären Ausdrücken

Algorithmus:

Eingabe: Endliches nichtleeres Alphabet $\sum$, regulärer Ausdruck r über $\sum$

Ausgabe: Übergangsdiagramm eines NEAs M, der die von r beschriebene reguläre Sprache R akzeptiert.

- ***Initialisierung:***

  Zustände: $Q = \{ q_0, q_f \}$

  Anfangszustand: q_0

  Endzustand: q_f

  Zustandsübergang: Für Eingabe r

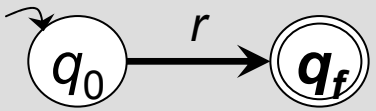

NEA-Erzeugung aus Regulären Ausdrücken

Algorithmus *(Fortsetzung)*:

- ***Schrittweise Zerlegung*** von *r* gemäß syntaktischer Struktur und Verfeinerung des aktuellen Übergangsdiagramms.
  Anwendung folgender Regeln, bis alle Kanten von *M* mit Zeichen aus $\sum$ oder ε markiert sind:

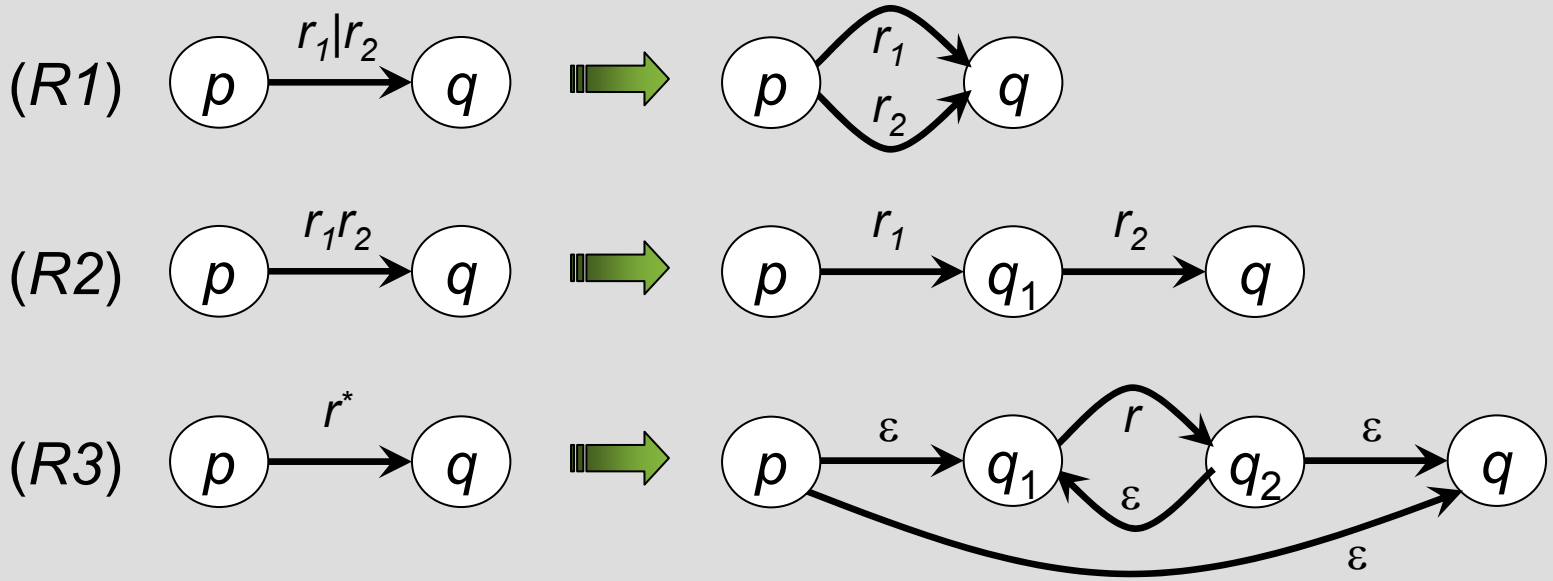

Erzeugung eines NEAs

Beispiel: Sei $\sum = \{ a, 0 \}$ ein Alphabet. $r = a(a|0)^*$ beschreibt die Menge der Worte über $\sum$, die mit einem a beginnen.

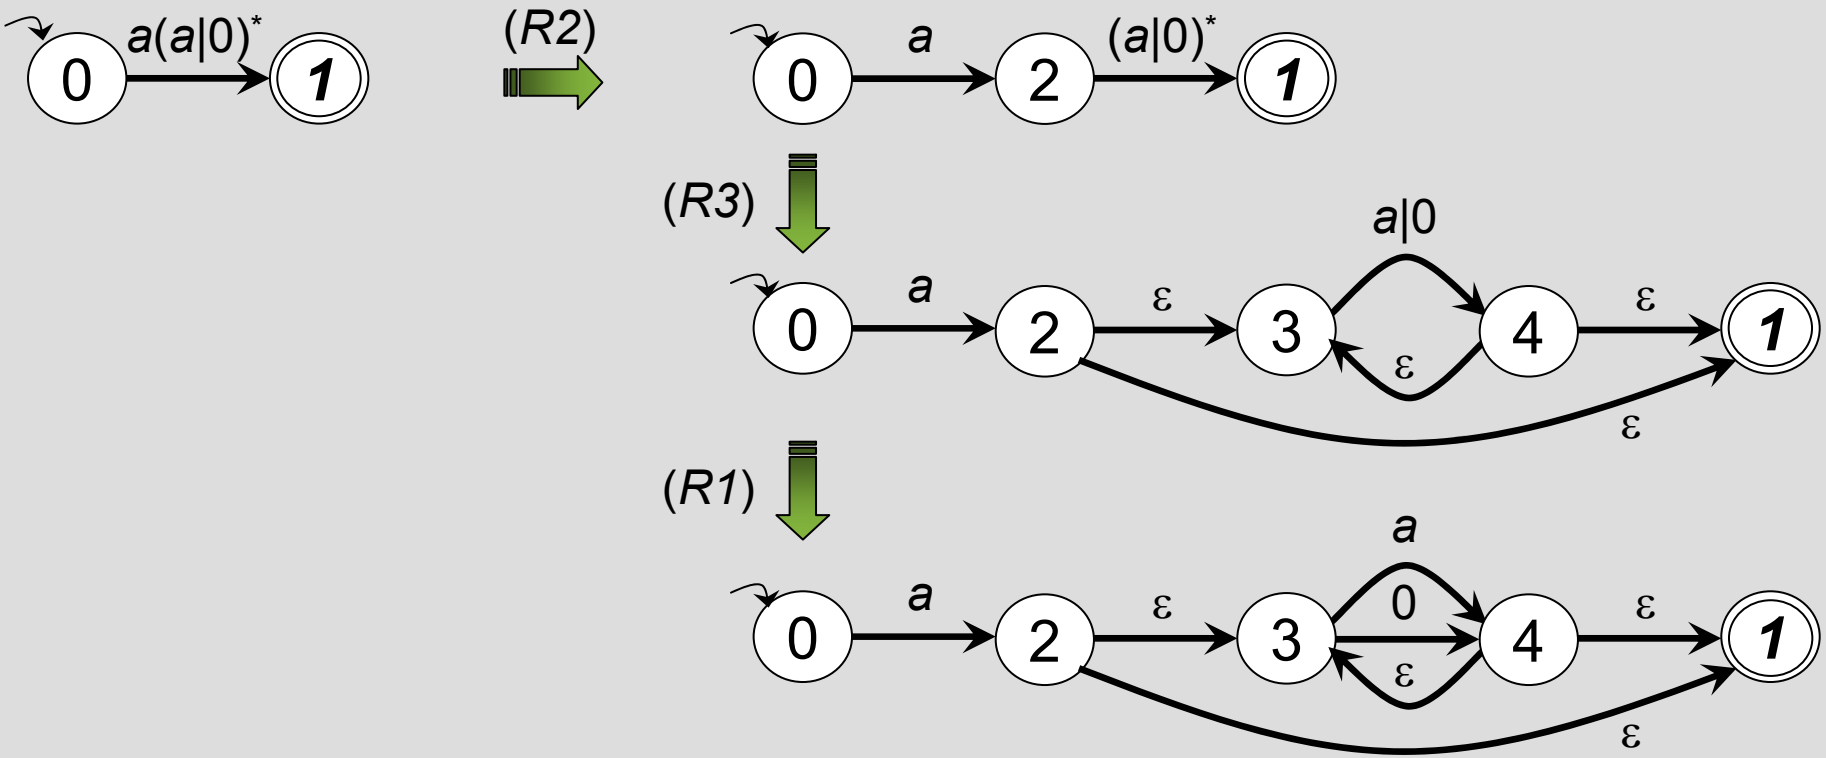

Gliederung der Vorlesung

- Kapitel 1: Compiler – Abhängigkeiten und Anforderungen
- Kapitel 2: Interner Aufbau von Compilern
- **Kapitel 3: Lexikalische Analyse (Scanner)**
  - Von Regulären Ausdrücken zu Nichtdeterministischen Automaten
  - Von Nichtdeterministischen zu Deterministischen Automaten
  - Automaten-Minimierung
  - Praktische Umsetzung: FLEX
- Kapitel 4: Syntaktische Analyse (Parser)
- Kapitel 5: Semantische Analyse
- Kapitel 6: Instruktionsauswahl
- Kapitel 7: Register-Allokation
- Kapitel 8: Code-Optimierung
- Kapitel 9: Ausblick

Problem eines Scanners mit NEAs

Nichtdeterminismus:

Der NEA, der gemäß vorigem Abschnitt als Scanner für einen regulären Ausdruck *r* erzeugt wird, müsste an zwei Stellen *raten*:

- Er müsste zuerst entscheiden, ob er ein Zeichen der Eingabe liest oder einen ε-*Übergang* macht, falls $\Delta(q_i, \varepsilon)$ definiert ist.
- Da Δ eine Übergangs*relation* ist, kann es für einen aktuellen Zustand q_i und eine Eingabe *e* mehrere Folgezustände q_{i+1} geben:
  $\Delta(q_i, e) = \{ q', q'', q''', \ldots \}$
  Der NEA muss entscheiden, welchen der möglichen Folgezustände er annimmt.

Deterministische Endliche Automaten

Ausweg:

Überführen des für regulären Ausdruck *r* generierten NEAs *M* in deterministischen endlichen Automaten *M'*:

Für jeden NEA *M*, der eine Sprache *L* akzeptiert, gibt es einen DEA *M'*, der *L* akzeptiert.

Definition *(Deterministischer Endlicher Automat, DEA)*:

Sei $M = (\Sigma, Q, q_0, F, \Delta)$ ein NEA. *M* heißt *deterministischer endlicher Automat*, wenn Δ eine partielle Funktion δ: $Q \times \Sigma \rightarrow Q$ ist.

In Worten: In einem DEA gibt es keine ε-Übergänge, und für jeden aktuellen Zustand q_i und jede Eingabe *e* gibt es höchstens einen Folgezustand $q_{i+1} = \delta(\, q_i, e\,)$.

Umwandlung NEA → DEA (1)

Grundsätzliche Idee:

Ein Zustand q' des DEA M' repräsentiert alle diejenigen Zustände q von M, die M vom Startzustand q_0 aus für ein Wort w nach q überführen – einschließlich aller möglichen ε-Übergänge.

Definition *(ε-Folgezustände)*:

Sei $M = (\Sigma, Q, q_0, F, \Delta)$ ein NEA und $q \in Q$. Die *ε-Folgezustände* von q sind:

$$\varepsilon\text{-FZ}(q) = \{ p \in Q \mid (q, \varepsilon) \overset{*}{\underset{M}{\vdash}} (p, \varepsilon) \}$$

d.h. alle Folgezustände p von q (inkl. q), die allein durch ε-Übergänge angenommen werden können. Für Zustandsmengen $S \subseteq Q$ gilt:

$$\varepsilon\text{-FZ}(S) = \bigcup_{q \in S} \varepsilon\text{-FZ}(q)$$

Umwandlung NEA → DEA (2)

Algorithmus:

Eingabe: NEA $M = (\Sigma, Q, q_0, F, \Delta)$

Ausgabe: DEA $M' = (\Sigma, Q', q_0', F', \delta)$

- ***Initialisierung:***

Anfangszustand:	$q_0' = \varepsilon\text{-FZ}(q_0)$
Zustände:	$Q' = \{ q_0' \}$
Endzustände:	$F' = \varnothing$
Zustandsübergänge:	$\delta = \varnothing$
Hilfsmarkierung:	marked[q_0'] = false;

Anfangs enthält M' den einzigen Zustand q_0'. q_0' modelliert den Startzustand q_0 von M und alle weiteren Zustände, die von q_0 aus mit fortgesetzten ε-Übergängen angenommen werden können.

Umwandlung NEA → DEA (3)

Algorithmus *(Fortsetzung)*:

- for (<alle Zustände $S = \{ q_{S,1}, q_{S,2}, q_{S,3}, \ldots\} \in Q'$ mit
  marked[S] == false>)
  - *// Nur Zustände bearbeiten, die noch nicht betrachtet wurden.*

    marked[S] = true;

  - *// Aktueller Zustand S des DEA ist akzeptierend, wenn er*
    // irgend einen akzeptierenden Zustand des NEA enthält.

    if (<S enthält Zustand $q_{S,i} \in Q$ mit $q_{S,i} \in F$>)
    - $F' = F' \cup S$;

…

Umwandlung NEA → DEA (4)

Algorithmus *(Fortsetzung)*:

- for (<alle Zustände $S = \{ q_{S,1}, q_{S,2}, q_{S,3}, \ldots\} \in Q'$ mit marked[S] == false>)

  …

  - for (<alle Buchstaben $a \in \Sigma$>)
    - *// Alle ε-Folgezustände ermitteln, die M für Eingabe a an-*
      // nehmen kann, ausgehend von jedem NEA-Zustand $q_{S,i}$.
      T = ε-FZ({ $p \in Q \mid (q_{S,i}, a, p) \in \Delta$ und $q_{S,i} \in S$ });
    - if ($T \notin Q'$)
      - $Q' = Q' \cup T$; *// Füge Menge T aller möglichen*
      - marked[T] = false; *// Folgezustände zu Q' hinzu.*

    …

Umwandlung NEA → DEA (5)

Algorithmus *(Fortsetzung)*:

- for (<alle Zustände $S = \{ q_{S,1}, q_{S,2}, q_{S,3}, \ldots\} \in Q'$ mit
  marked[S] == false>)

  …

  - for (<alle Buchstaben $a \in \Sigma$>)

    …

    - *// Füge neuen Zustandsübergang von aktuellem Zustand S*
      // zu Folgezustand T unter Eingabe a hinzu.
      $\delta = \delta \cup \{ (S, a) \rightarrow T \}$;

Erzeugung eines DEAs (1)

Beispiel: Sei $\sum = \{ a, 0 \}$ ein Alphabet, $r = a(a|0)^*$.

NEA:

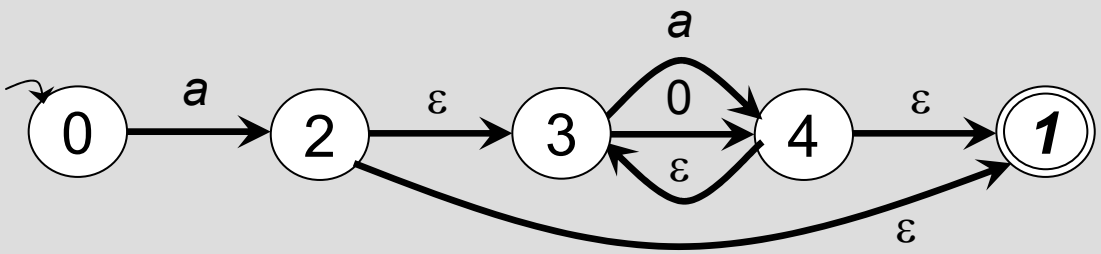

Startzustand: $0' = \{ 0 \}$

Initiale Zustandsmenge: $Q' = \{ 0' \}$

Erzeugung eines DEAs (2)

Beispiel:

NEA:

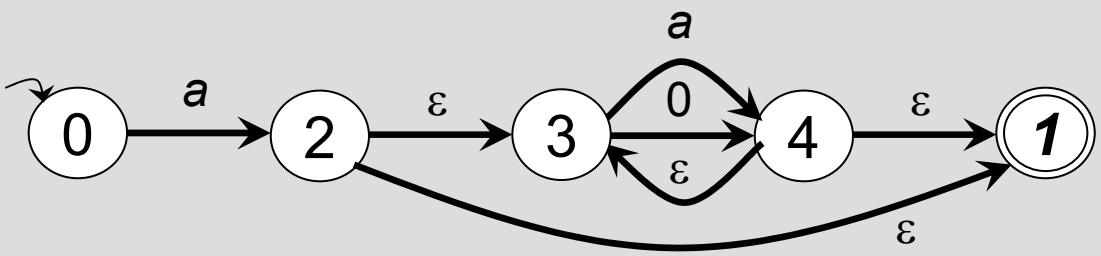

Akt. Zustand *S*:

0' = { 0 }

Neues *Q'*:

{ 0' , *1'* , ∅ } mit

1' = { 2 , 3 , *1* }

(Teil-) DEA:

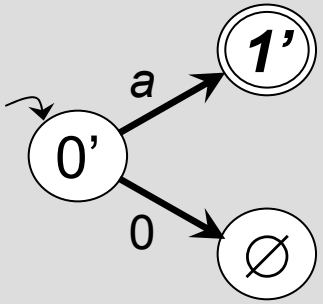

⇐ *Spezieller Fehler-Zustand*

Erzeugung eines DEAs (3)

Beispiel:

NEA:

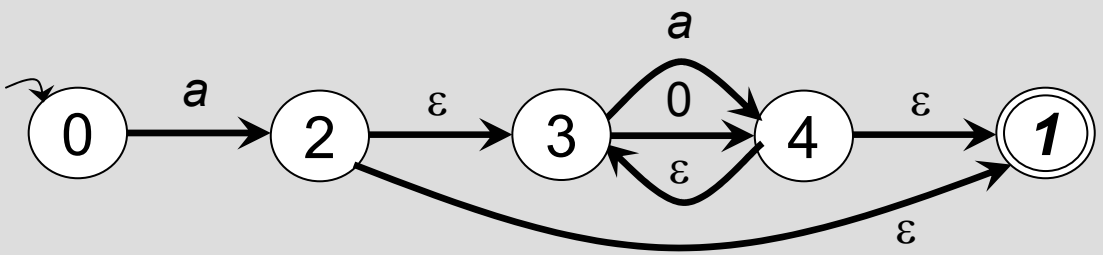

Akt. Zustand *S*:

1' = { 2, 3, *1* }

Neues *Q'*:

{ 0', *1'*, *2'*, ∅ } mit

2' = { 4, 3, *1* }

(Teil-) DEA:

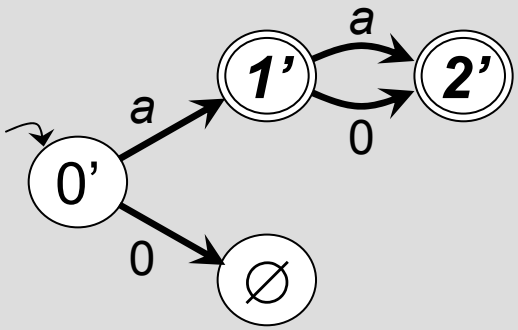

Erzeugung eines DEAs (4)

Beispiel:

NEA:

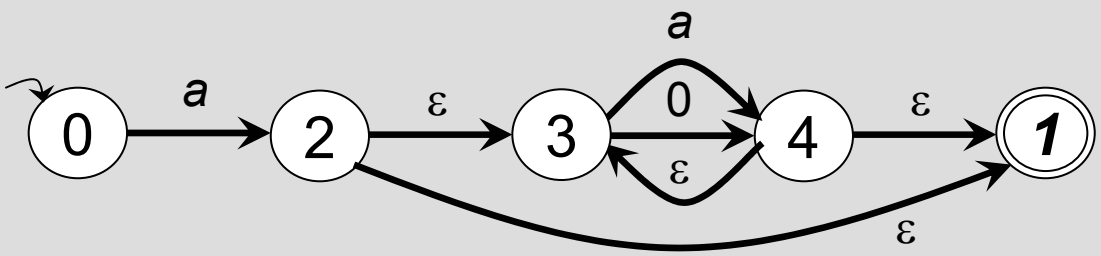

Akt. Zustand *S*:

2' = { 4, 3, **1** }

Neues *Q'*:

{ 0', **1'**, **2'**, ∅ }

(Teil-) DEA:

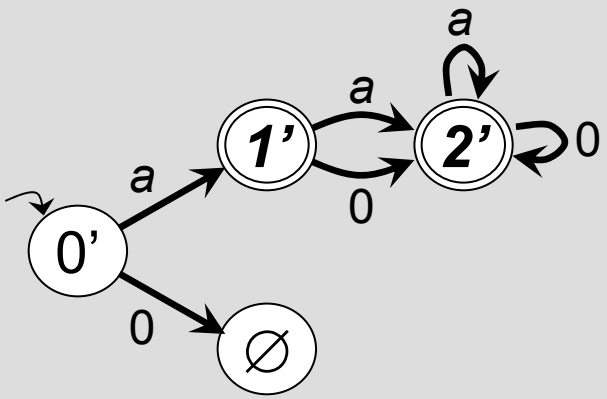

Erzeugung eines DEAs (5)

Beispiel:

NEA:

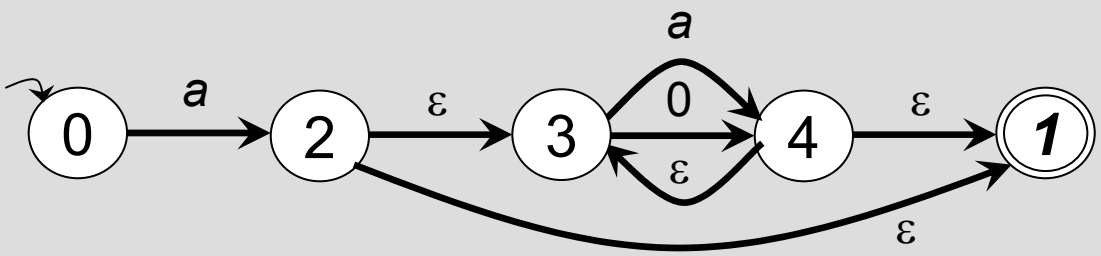

Akt. Zustand *S*:

∅

Neues *Q'*:

{ 0' , 1' , 2' , ∅ }

(Teil-) DEA:

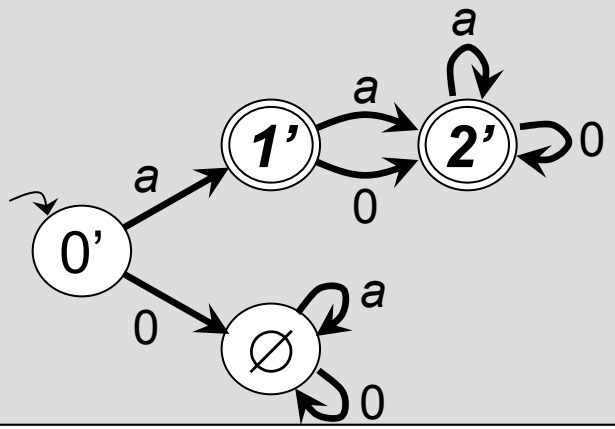

Gliederung der Vorlesung

- Kapitel 1: Compiler – Abhängigkeiten und Anforderungen
- Kapitel 2: Interner Aufbau von Compilern
- **Kapitel 3: Lexikalische Analyse (Scanner)**
  - Von Regulären Ausdrücken zu Nichtdeterministischen Automaten
  - Von Nichtdeterministischen zu Deterministischen Automaten
  - Automaten-Minimierung
  - Praktische Umsetzung: FLEX
- Kapitel 4: Syntaktische Analyse (Parser)
- Kapitel 5: Semantische Analyse
- Kapitel 6: Instruktionsauswahl
- Kapitel 7: Register-Allokation
- Kapitel 8: Code-Optimierung
- Kapitel 9: Ausblick

Motivation

Redundante Zustände:

DEAs, die gemäß vorigem Abschnitt erzeugt werden, enthalten in der Regel viele redundante Zustände:

- Ist DEA in Zustand 1’ oder 2’, so akzeptiert er.
- Ist DEA in Zustand 1’, so wechselt er für *alle* weitere Eingaben von einem akzeptierenden in einen weiteren akzeptierenden Zustand (dito für 2’).

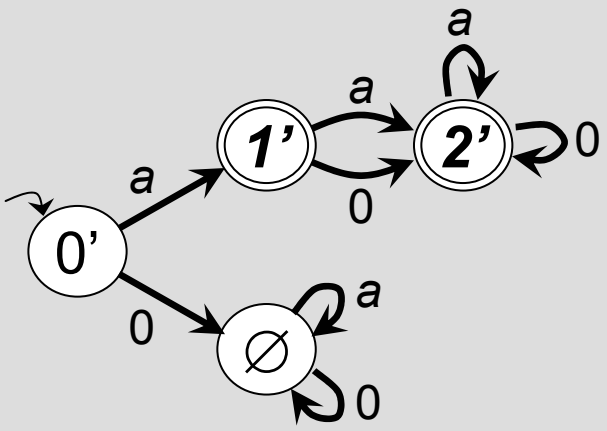

☞ 1’ und 2’ sind also bzgl. der Akzeptanz des DEAs äquivalent – der DEA verhält sich stets gleich, egal ob er in 1’ oder 2’ ist.

☞ 1’ und 2’ können zu einem Zustand zusammengefasst werden.

Äquivalenz von Zuständen

Definition *(Äquivalenz)*:

Sei $M' = (\Sigma, Q', q_0', F', \delta)$ ein DEA. Zwei Zustände p und q aus Q' sind *äquivalent*, genau dann wenn für jedes Wort $w \in \Sigma^*$ gilt:

$(p, w) \overset{*}{\underset{M'}{\vdash}}$ und $(q, w) \overset{*}{\underset{M'}{\vdash}}$ führen beide entweder ausschließlich in Zustände aus F' oder ausschließlich in Zustände aus $Q' - F'$.

Anschaulich:

- entweder nur Übergänge →
- oder nur Übergänge ⇢

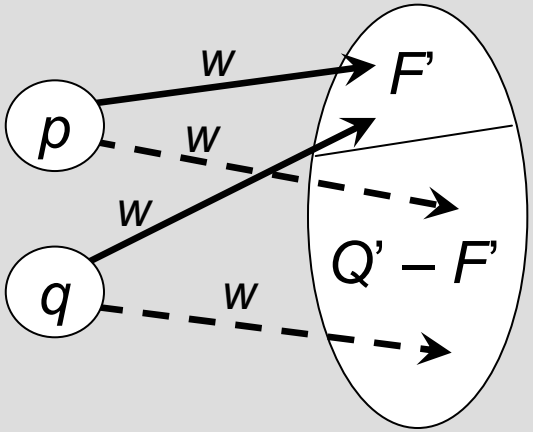

Folgerungen… (1)

…für einen Algorithmus zur Automaten-Minimierung:

- Der Algorithmus zerlegt die Zustandsmenge Q' des DEA M' in eine Partition P: $Q' = P_1 \cup P_2 \cup P_3 \cup \ldots = P$
- Eine Teilmenge $P_i \in P$ enthält Zustände, von denen *angenommen* wird, dass sie äquivalent sind.
- Der Algorithmus startet mit der Partition $P = F' \cup \{Q' - F'\}$, d.h. es wird optimistisch angenommen, dass jeweils alle akzeptierenden und nicht akzeptierenden Zustände äquivalent sind.
- Wird für eine Teilmenge $P_i \in P$ festgestellt, dass sie inäquivalente Zustände enthält, so wird P_i wiederum zerlegt in $P_{i,1}$ und $P_{i,2}$.
- Am Ende enthalten alle Teilmengen P_i nur Zustände, die auch tatsächlich äquivalent sind.

Folgerungen… (2)

…für einen Algorithmus zur Automaten-Minimierung:

- Seien p und q Zustände einer Teilmenge P_i, $a \in \Sigma$ ein Eingabezeichen, $x = \delta(p, a)$ der Folgezustand von p unter Eingabe a und $y = \delta(q, a)$ der Folgezustand von q.
  p und q sind *inäquivalent*, wenn x und y in unterschiedlichen Teilmengen liegen, d.h. $x \in P_j$, $y \in P_k$ und $P_j \neq P_k$.

Anschaulich:

☞ p und q sind inäquivalent.

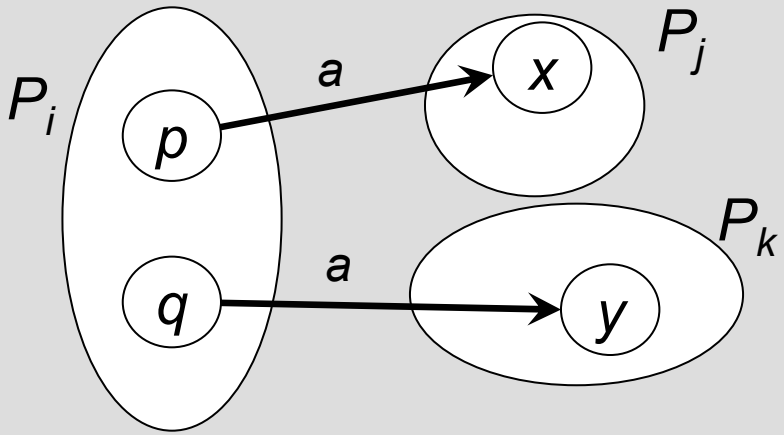

Automaten-Minimierung (1)

Algorithmus:

Eingabe: DEA $M' = (\Sigma, Q', q_0', F', \delta)$

Ausgabe: DEA $M'_{min} = (\Sigma, Q'_{min}, q'_{0,min}, F'_{min}, \delta_{min})$

- **Initialisierung:**
  Partition P: $P = \{ F', Q' - F' \};$
  Abbruchkriterium: bool modified = true;

Automaten-Minimierung (2)

Algorithmus *(Fortsetzung)*:

- while (modified)
  - P' = P; modified = false;
  - for (<alle Teilmengen $P_i \in P$>)
    - for (<alle Buchstaben $a \in \Sigma$>)
      - *// Teste auf inäquivalente Zustände innerhalb von P_i.*
        ($P_{i,1}$, $P_{i,2}$) = split(P_i, a);
      - *// Enthält P_i inäquivalente Zustände bzgl. Eingabe a?*
        if (($P_{i,1}$!= ∅) && ($P_{i,2}$!= ∅))
        - P' = (P' \ P_i) U $P_{i,1}$ U $P_{i,2}$; *// Ersetze P_i durch $P_{i,1}$*
        - modified = true; break; *// und $P_{i,2}$.*
  - P = P';

Automaten-Minimierung (3)

Zerlegung von P_i bzgl. Eingabe a – Hilfsfunktion split:

- Vor Aufruf von split:
  - P_i hat für Eingabe a Übergänge z.B. nach P_j, P_k und P_l.

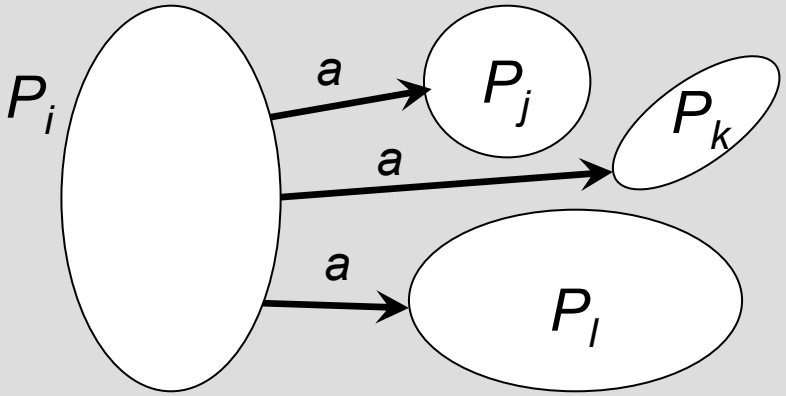

- Zerlegung mit Hilfe von split:
  - Wähle eine der Ziel-Mengen aus, z.B. P_j.
  - Zerlege P_i in alle Zustände, die für a nach P_j führen, und Rest.

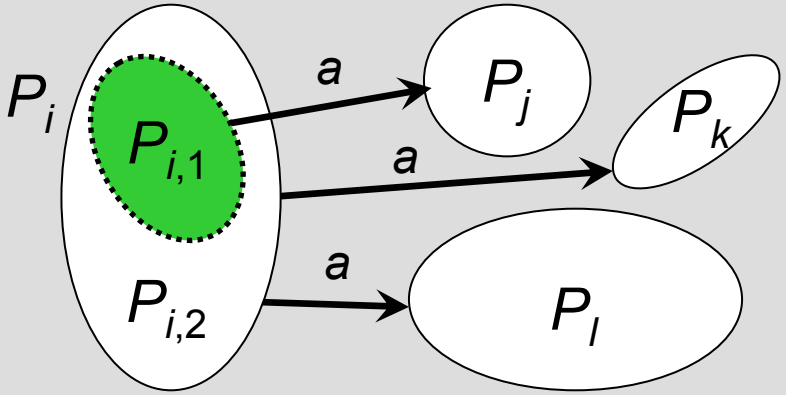

Automaten-Minimierung (4)

Algorithmus *(Fortsetzung)*:

- **Aufbau des minimierten DEAs:**

  $Q'_{min} = P$

  $\delta_{min}(P_i, a) = P_j$ wenn $\delta(q, a) = p$ mit $a \in \sum$ und $p \in P_j$ für ein (und damit für alle) $q \in P_i$.

  $q'_{0,min} =$ Die Teilmenge $P_k \in P$, die q_0' enthält

  $F'_{min} =$ Die Teilmengen $P_l \in P$, die einen Zustand aus F' enthalten

Automaten-Minimierung (5)

Beispiel:

- Nebenstehender DEA
  $M' = (\Sigma = \{a, 0\}, Q' = \{0', 1', 2', \varnothing\}, \delta,$
  $q_0' = 0', F' = \{1', 2'\})$
  soll minimiert werden.
- Für beide Zustände 1' und 2' und beliebige Worte $w \in \Sigma^*$ gilt:
  $(1', w) \overset{*}{\underset{M'}{\rightarrow}} \in F'$ und $(2', w) \overset{*}{\underset{M'}{\rightarrow}} \in F'$

☞ 1' und 2' sind äquivalent.

- Keine weiteren Zustände sind äquivalent, da sie zu jeweils anderem Akzeptanz-Verhalten führen.

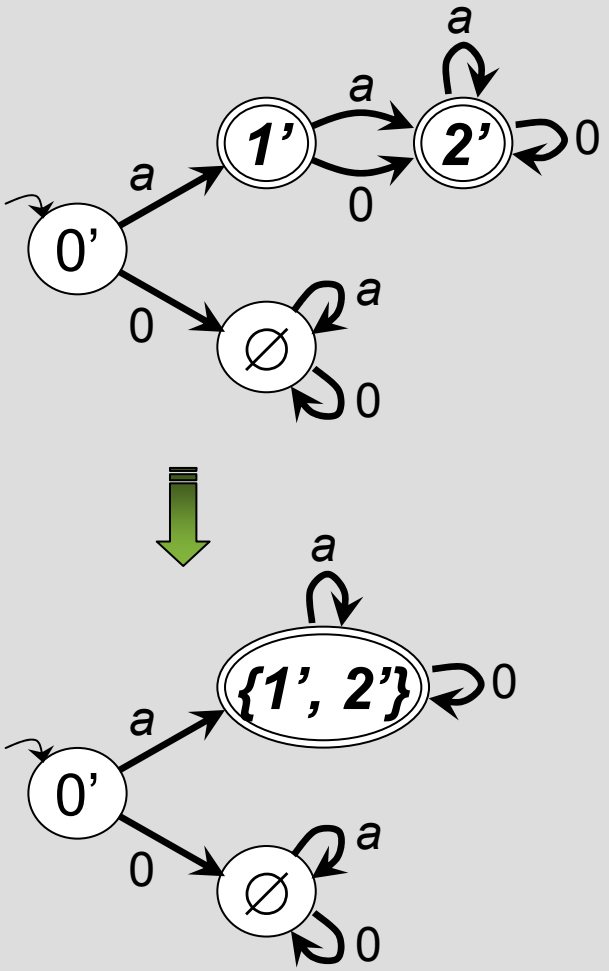

Gliederung der Vorlesung

- Kapitel 1: Compiler – Abhängigkeiten und Anforderungen
- Kapitel 2: Interner Aufbau von Compilern
- **Kapitel 3: Lexikalische Analyse (Scanner)**
  - Von Regulären Ausdrücken zu Nichtdeterministischen Automaten
  - Von Nichtdeterministischen zu Deterministischen Automaten
  - Automaten-Minimierung
  - Praktische Umsetzung: FLEX
- Kapitel 4: Syntaktische Analyse (Parser)
- Kapitel 5: Semantische Analyse
- Kapitel 6: Instruktionsauswahl
- Kapitel 7: Register-Allokation
- Kapitel 8: Code-Optimierung
- Kapitel 9: Ausblick

Scanner-Generierung

Implementierung eines Scanners:

- Stark von Quellsprache abhängige Aufgabe.
- Theoretische Grundlagen der lexikalischen Analyse bestens erforscht, effiziente Algorithmen zur Erzeugung eines Scanners auf Basis regulärer Ausdrücke existieren.
- Per-Hand-Implementierung eines Scanners bei vorhandenem theoretischen Unterbau nicht mehr vertretbar.
  (Und auch nicht gewünscht, da diese Aufgabe schlichtweg zu technisch und „langweilig“ ist…)

☞ Statt dessen: Verwendung sog. *Scanner-Generatoren*

Scanner-Generatoren

- Sog. *Meta-Programme*, d.h. Programme, die Programme als Ausgabe erzeugen.
- Ein *Scanner-Generator* erhält eine Beschreibung der zu erkennenden regulären Ausdrücke als Eingabe und erzeugt daraus einen Scanner für eben diese Ausdrücke.

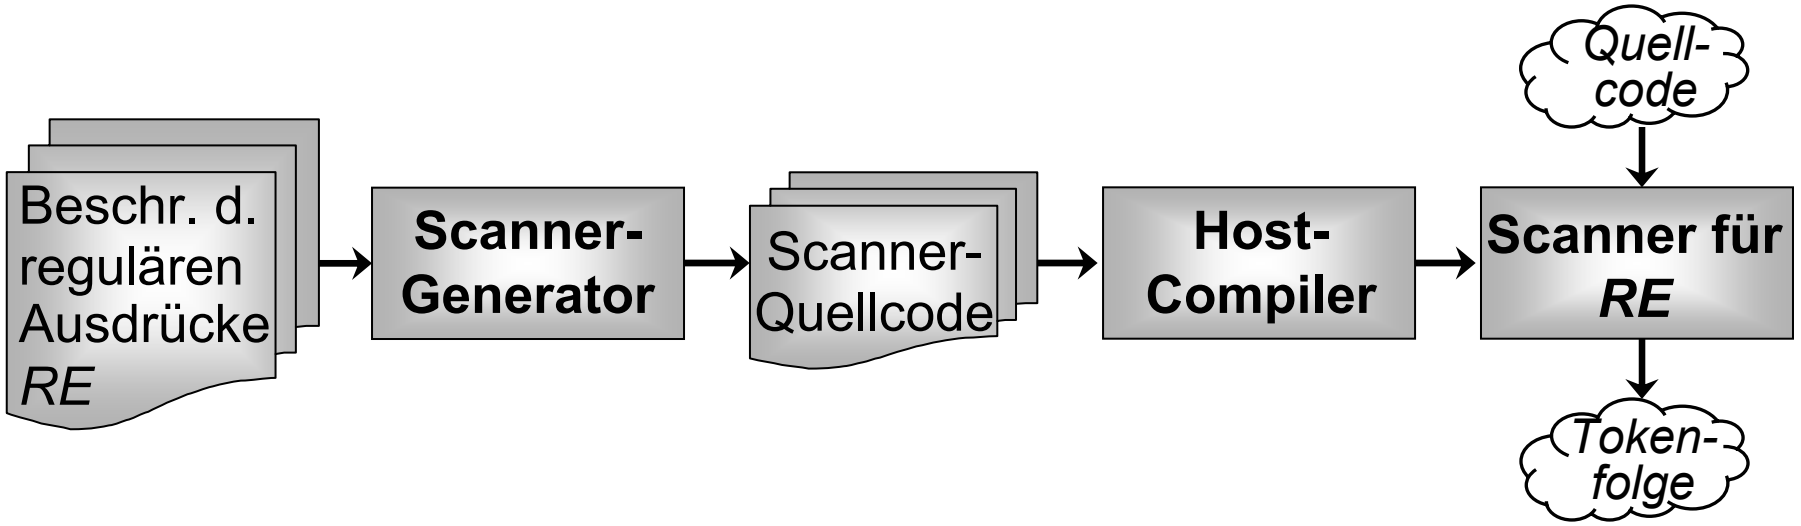

Scanner-Generierung mit FLEX (1)

Grundlegender Aufbau einer FLEX Scanner-Beschreibung

- FLEX: *Fast Lexical Analyzer Generator*
  Weit verbreiteter Scanner-Generator, GNU open source
- Generiert aus Beschreibung C-Code eines Scanners
- Eingabedatei für FLEX:

Scanner-Generierung mit FLEX (2)

Präambel

- Eine Präambel ist stets in `%{` und `%}` einzuschließen.
- Es können mehrere Präambeln pro FLEX-Datei vorkommen.
- Eine Präambel enthält beliebigen C-Code, der unverändert an den Beginn des von FLEX erzeugten Codes kopiert wird:

```
%{
  /* Counter, in which line a word was found. */
  unsigned int lineCounter = 1;

  /* Forward declaration of helper function. */
  void incrementLineCounter();
%}
```

Scanner-Generierung mit FLEX (3)

Definitionen

- Definitionen erlauben, die Beschreibung regulärer Ausdrücke zu vereinfachen.
- Eine Definition führt für einen regulären Ausdruck einen Namen ein, der an späterer Stelle im FLEX-File verwendet werden kann:

```
digit [0-9]
letter [a-zA-Z]
identifier {letter}({letter}|{digit})*
```

- Zeichenklassen werden innerhalb von `[ ]` aufgeführt. Bereiche von Zeichen können mit – angegeben werden.
- Reguläre Ausdrücke können mit Hilfe der Operatoren `*`, `+`, `?`, `|` und Konkatenation gebildet werden.

Scanner-Generierung mit FLEX (4)

Regeln

- Regeln bestehen aus einem *Muster*, d.h. einem regulären Ausdruck, und einer *Aktion*, d.h. einem Stück C-Code.
- Die Aktion muss in der selben Zeile wie das Muster starten.
- Die Aktion wird ausgeführt, wenn der Scanner ein Symbol als zum Muster gehörend erkannt hat:

```
 /* Matches integer numbers.
    yytext is a pointer to the matched string.
    Rules start in column 0. Any indented parts
    are directly copied to the output file. */
{digit}+  printf( "%d: number %d\n",
                  lineCounter, atoi( yytext ) );
```

Scanner-Generierung mit FLEX (5)

Regeln *(Fortsetzung)*

```
  /* Matches operators. Longer C code snippets for
     actions can be enclosed in { … } */
"+"|"++"|"-"|"--"|"*"|"/"|"="|"==" {
  printf( "%d: operator %s\n",
          lineCounter, yytext );
}
  /* Matches keywords of some fictive programming
     language. */
if|then|else|for|while|do|to {
  printf( "%d: keyword %s\n",
          lineCounter, yytext );
}
```

Scanner-Generierung mit FLEX (6)

Regeln *(Fortsetzung)*

```
   /* Matches identifiers. Used names of
      definitions in a rule's pattern must be
      enclosed in { … } */
{identifier}  printf( "%d: identifier %s\n",
                      lineCounter, yytext );

[ \t]  /* Consumes white spaces and tabs. */

   /* Consumes new-line characters. Increments
      line counter. */
\n  incrementLineCounter();
```

Scanner-Generierung mit FLEX (7)

Regeln *(Fortsetzung)*

- Werden in Regeln Namen für reguläre Ausdrücke verwendet, die im Definitionsteil deklariert wurden, so sind diese Namen in `{ }` einzuschließen: **`{digit}+`**
- ☞ Dies verhindert, dass die Regel auf die Zeichenkette „**`digit`**“ reagiert.
- Die Zeichenkette „**`while`**“ bspw. wird durch die Muster der Keyword- und Identifier-Regeln erfasst.
- ☞ FLEX erkennt „**`while`**“ als Schlüsselwort, da die Keyword-Regel in der FLEX-Datei vor der Identifier-Regel steht.

Scanner-Generierung mit FLEX (8)

C-Funktionen

- Beliebige C-Funktionen können für Hilfszwecke angegeben werden.
- Hilfsfunktionen können innerhalb von Aktionen aufgerufen werden.

```
/* Increment global variable lineCounter by 1. */
void incrementLineCounter() { lineCounter++; }

/* A complete C program needs a main function. */
int main() {
  yylex();          /* Invoke scanner. */
  printf( "Read lines: %d\n", lineCounter );
  return 0; }
```

Literatur

- Reinhard Wilhelm, Dieter Maurer, *Übersetzerbau*, 2. Auflage, Springer, 1997. *(☞ Kapitel 7)*
  ISBN 3-540-61692-6
- Andrew W. Appel, *Modern compiler implementation in C*, Cambridge University Press, 1998. *(☞ Kapitel 2)*
  ISBN 0-521-58390-X
- J. Eliot B. Moss, Compiler Techniques – Fall 2008, 2008. *(☞ Foliensatz 6)*
  `http://www-ali.cs.umass.edu/~moss/610.html`

Zusammenfassung

- **Reguläre Ausdrücke: Eleganter Mechanismus, um Worte einer Sprache zu spezifizieren.**
- **Nichtdeterministische Automaten können reguläre Ausdrücke maximaler Länge erkennen, sind aber wegen „Ratens“ ungeeignet für eine reale Implementierung.**
- **Aus nichtdeterministischen Automaten für reguläre Ausdrücke können deterministische Automaten erzeugt werden.**
- **Minimierung liefert deterministischen Automaten mit minimaler Zustandsmenge.**
- **FLEX: Ein Standard-Werkzeug zur Scanner-Generierung.**