Compiler: Scanner

Prof. Dr. Oliver Braun

Letzte Änderung: 10.05.2017 15:49

Scanner

- erster Schritt des Prozesses der das Eingabeprogramm verstehen muss
- Scanner = lexical analyzer
- ein Scanner
  - liest eine Zeichen-Strom
  - produziert einen Strom von Wörtern
- aggregiert Zeichen um Wörter zu bilden
- wendet eine Menge von Regeln an um zu entscheiden ob ein Wort akzeptiert wird oder nicht
- weist dem Wort eine syntaktische Kategorie zu, wenn es akzeptiert wurde

Wörter erkennen — Beispiel

`new` erkennen

Pseudo Code

```
c = nextChar();
if (c == 'n')
    then begin;
        c = nextChar();
        if (c == 'e')
            then begin;
                c = nextChar();
                if (c == 'w')
                    then report success;
                    else try something else;
            end;
            else try something else;
    end;
    else try something else;
```

Wörter erkennen — Beispiel

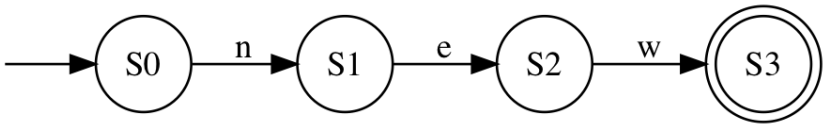

Zustandsübergangsdiagramm `new`

Haskell:

```
recognizeNew :: String -> Bool
recognizeNew ('n':'e':'w':_) = True
recognizeNew _               = False
```

Verschiedene Wörter erkennen

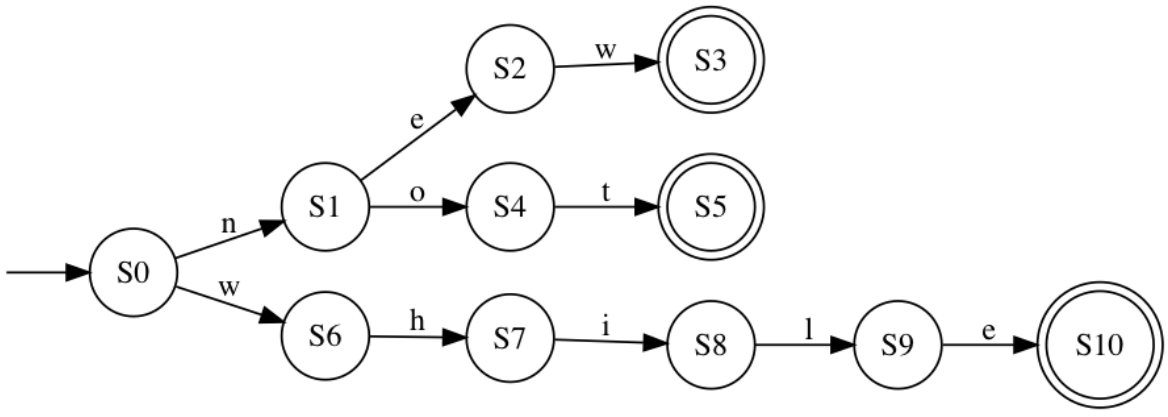

Zustandsübergangsdiagramm `new-not-while`

Ein Formalismus für Recognizer

Zustandsübergangsdiagramme können als mathematische Objekte betrachtet werden, sog. ***Endliche Automaten*** *(*finite automata*)*

Ein Endlicher Automat (EA)

(engl. *finite automaton (FA)*)

ist ein Tupel $(S, \Sigma, \sigma, s_0, S_A)$ mit

- S ist die endlichen Menge von Zuständen im EA, sowie ein Fehlerzustand s_e.
- Σ ist das vom EA genutzte Alphabet. Typischerweise ist es die Vereinigungsmenge der Kantenbezeichnungen im Zustandsübergangsdiagramm.
- $\sigma(s, c)$ ist die Zustandsübergangsfunktion. Es bildet jeden Zustand $s \in S$ und jedes Zeichen $c \in \Sigma$ auf den Folgezustand an. Im Zustand s_i mit dem Eingabezeichen c, nimmt der EA den Übergang $s_i \overset{c}{\mapsto} \sigma(s_i, c)$.
- $s_0 \in S$ ist der ausgewählte Startzustand.
- S_A ist die Menge von akzeptierenden Zuständen, mit $S_A \subseteq S$. Jeder Zustand in S_A wird als doppelt umrandeter Kreis im Zustandsübergangsdiagramm dargestellt.

Beispiel

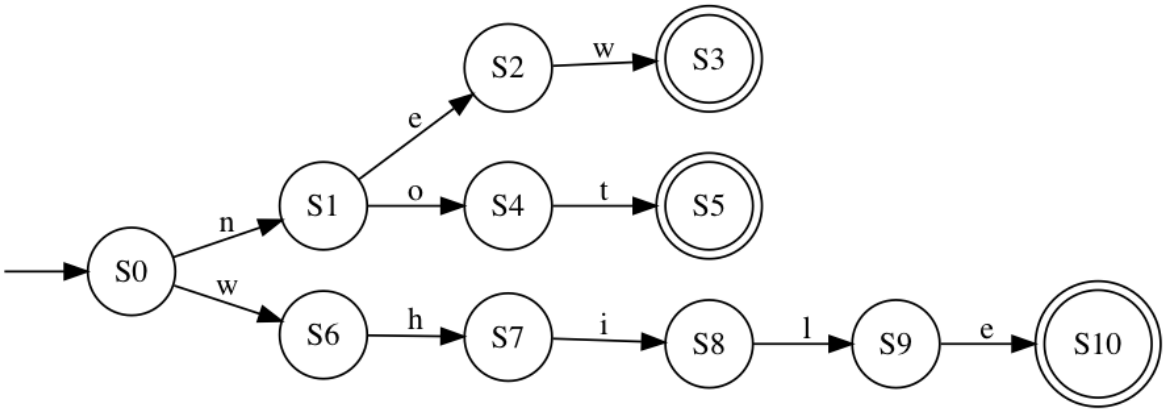

Zustandsübergangsdiagramm `new-not-while`

$S = \{s_0, s_1, s_2, s_3, s_4, s_5, s_6, s_7, s_8, s_9, s_{10}, s_e\}$

$\Sigma = \{\mathtt{e}, \mathtt{h}, \mathtt{i}, \mathtt{l}, \mathtt{n}, \mathtt{o}, \mathtt{t}, \mathtt{w}\}$

$\sigma = \{s_0 \overset{n}{\mapsto} s_1, s_0 \overset{w}{\mapsto} s_6, s_1 \overset{e}{\mapsto} s_2, \ldots\}$

$s_0 = s_0$

$S_A = \{s_3, s_5, s_{10}\}$

Übung: Ergänzen Sie σ durch die fehlenden Abbildungen.

Beispiel in Haskell

Code auf GitHub

`https://github.com/ob-cs-hm-edu/compiler-ea1.git`

Positive Zahlen erkennen

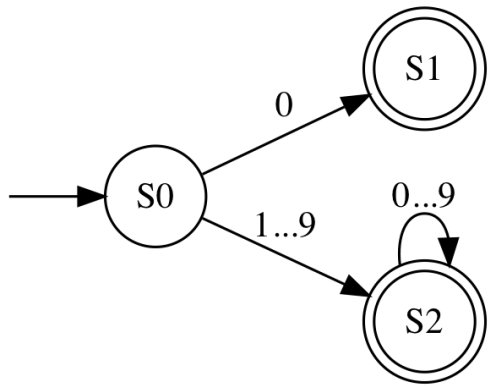

Zustandsübergangsdiagramm für positive Zahlen

Übung: Geben Sie den endlichen Automaten als Tupel an.

Reguläre Ausdrücke

Reguläre Ausdrücke

- die Menge der Wörter die von einem endlichen Automaten $\mathcal{F}$ akzeptiert wird, bildet eine Sprache, die $L(\mathcal{F})$ bezeichnet wird
- das Zustandsübergangsdiagramm des EA spezifiziert diese Sprache
- intuitiver ist die Spezifikation mit **regulären Ausdrücken** (*regular expressions (REs)*)
- die Sprache die durch einen RE beschrieben wird, heisst **reguläre Sprache**
- REs sind äquivalent zu EAs

Formalisierung regulärer Ausdrücke

Ein regulärer Ausdruck r beschreibt

- eine Menge von Zeichenketten, genannt *Sprache*, bezeichnet mit $L(r)$,
- bestehend aus Zeichen aus einem Alphabet Σ
- erweitert um ein Zeichen ϵ das die leere Zeichenkette repräsentiert

Operationen

Ein regulärer Ausdruck wird aus drei Grundoperationen zusammengesetzt

Alternative Die Alternative oder Vereinigung von zwei Mengen von Zeichenketten R and S, wird geschrieben $R|S$ und ist $\{x|x \in R \text{ or } x \in S\}$.

Verkettung Die Verkettung zweier Mengen R and S, wird geschrieben RS und enthält alle Zeichenketten, die entstehend wenn an ein Element aus R ein Element aus S angehängt wird, also $\{xy|x \in R \text{ and } y \in S\}$.

Kleenesche Hülle Die Kleenesche Hülle, oder Kleene-Stern, einer Menge R, wird geschrieben R^* und ist $\bigcup_{i=0}^{\infty} R^i$. Das sind also alle Verkettungen von R mit sich selbst, null bis unendlich mal.

Zusätzlich wird oft genutzt

Endliche Hülle R^i, für ein positives i

Positive Hülle R^+, als Kurzschreibweise für RR^*

Definition regulärer Ausdrücke

Die Menge der REs über einem Alphabet Σ ist definiert durch

1. Wenn $a \in \Sigma$, dann ist a ein RE der die Menge beschreibt, die nur a enthält.
2. Wenn r und s REs sind die $L(r)$ and $L(s)$ beschreiben, dann gilt:
   - $r|s$ ist ein RE
   - rs ist ein RE
   - r^* ist ein RE
3. ϵ ist ein RE der die Menge beschreibt, die nur die leere Zeichenkette enthält.

Vorrang und Intervalle, ...

Reihenfolge des Vorrangs (vom höchsten):

- Klammern
- Hülle
- Verkettung
- Alternative

Zeichenintervalle können durch das erste und letzte Element verbunden mit drei Punkten umschloßen von eckigen Klammern beschrieben werden, z.B. [0...9].

Komplementbildungs-Operator^ ist die Menge $\Sigma - c$
Escape Sequenzen wie in Zeichenketten, z.B. $\backslash n$

Beispiele

- Bezeichner in manchen Programmiersprachen
  $([A...Z]|[a...z])([A...Z]|[a...z]|[0...9])^*$
- positive ganze Zahlen
  $0|[1...9][0...9]^*$
- positive reelle Zahlen
  $(0|[1...9][0...9]^*)(\epsilon|.[0...9]^*)$

PCRE - Perl Compatible Regular Expressions

Reguläre Ausdrücke in der Praxis

- es gibt verschiedene “Geschmacksrichtungen” regulärer Ausdrücke
- wir verwenden im Praktikum und in der Klausur PCRE (Perl Compatible Regular Expressions)

Sonderzeichen in PCRE

Zeichen mit besonderer Bedeutung in PCRE

Sonderzeichen	Bedeutung
\	um das folgende Sonderzeichen zu maskieren
^	Zeilenanfang
.	ein beliebiges Zeichen (außer Zeilenumbruch)
$	Zeilenende oder Ende der Zeichenkette
|	Alternative
()	Gruppierung
[]	Umschließt eine Zeichenklasse

Quantifikatoren

Quantifikator	Bedeutung
`*`	matche null- oder mehrmals
`+`	matche ein- oder mehrmals
`?`	matche null- oder einmal
`{n}`	matche genau `n`-mal
`{n,}`	matche mindestens `n`-mal
`{n,m}`	matche mindestens `n`- und höchstens `m`-mal

Backtracking

- wenn ein quantifiziertes Teilpattern dazu führen würde, dass der Rest nicht mehr matched, wird Backtracking verwendet
- Beispiel: Zeichenkette `aaaa`
- Regulärer Ausdruck: `a+a`
  - `a+` würde schon die gesamte Zeichenkette matchen
  - durch Backtracking matched `a+` auf die ersten drei as und das zweite a im RE auf das vierte in der Zeichenkette

Zu gierige REs

- durch Hintanstellen von ? wird nur auf das Minimum gematcht
- Beispiel: Zeichenkette `aaab`
- Regulärer Ausdruck `a+(a|b)` matcht auf `aaab`
- Regulärer Ausdruck `a+?(a|b)` matcht auf `aa`

Kein Backtracking

- durch Hintanstellen von + wird das Backtracking ausgeschaltet
- Beispiel: Zeichenkette aaaa
- Regulärer Ausdruck a+a matcht auf aaaa
- Regulärer Ausdruck a++a matcht gar nicht

Zeichenklassen

Sequenz	Bedeutung
`[...]`	eines der statt `...` enthaltenen Zeichen, auch `[a-z]` möglich
`[^...]`	keines der enthaltenen Zeichen
`[[:...:]]`	Posix-Klassen, z.B. `digit`, `upper`
`\w`	alphanumerisches Zeichen oder _
`\W`	kein alphanumerisches Zeichen oder _
`\s`	Whitespace
`\S`	kein Whitespace
`\d`	Dezimalziffer
`\D`	keine Dezimalziffer
...	

Gruppierung und Referenzierung

- Teilausdrücke in Klammern werden erfasst
- und können referenziert werden
- Beispiel: Zeichenkette `Hallo Hans`
- Regulärer Ausdruck `(..).*\1` matcht auf `Hallo Ha`

und viel viel mehr

- Lookaround Assertions
  - z.B. matche ein Wort auf das ein Tabulator folgt: `\w+(?=\t)`
- Rekursive Subpattern
  - z.B. matche geklammerte Ausdrücke: `\((?>[^)(]+|(?R))*\)`
  - `(?>S)` ist eine non-backtracking-group und verhindert daher zeitraubendes Backtracking
- ...
- Doku z.B. unter http://perldoc.perl.org/perlre.html

Von regulären Ausdrücken zu Scannern

Konstruktionszyklus

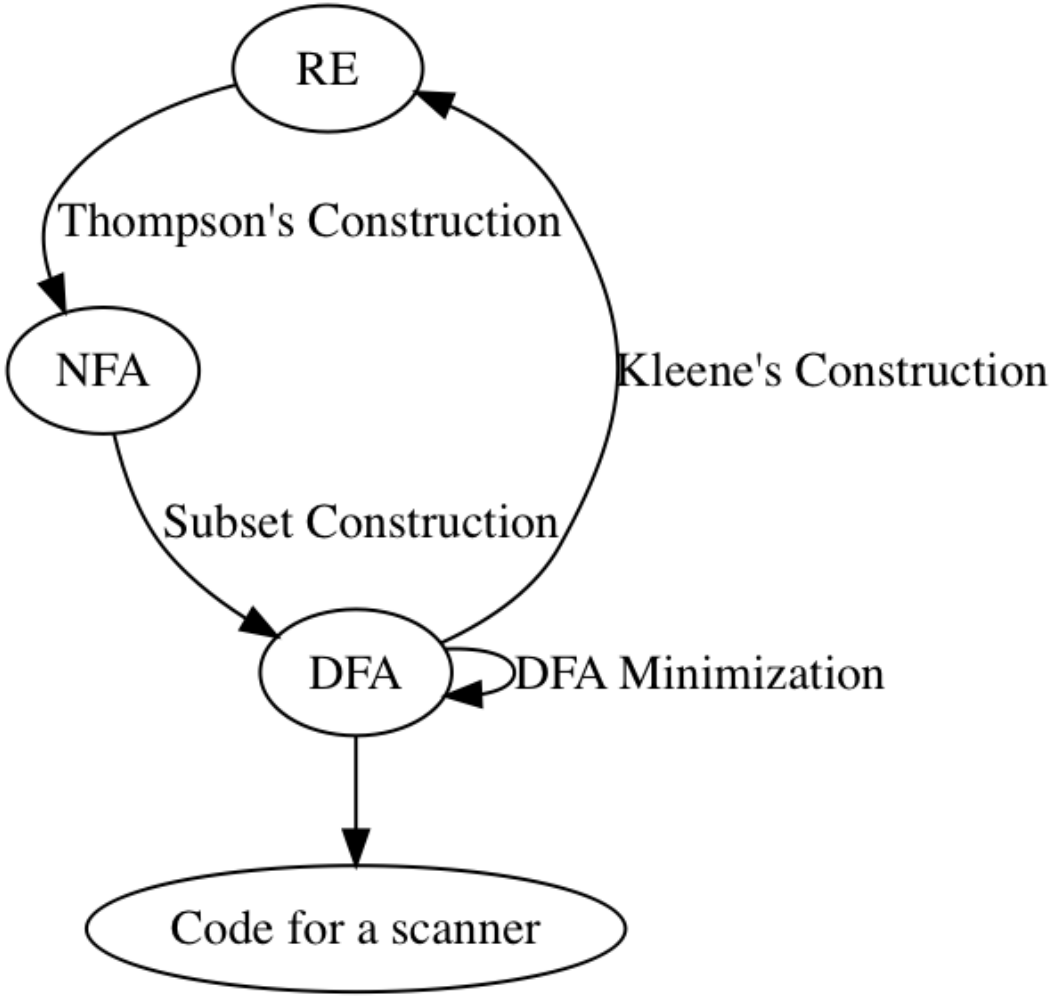

Konstruktionszyklus

Konstruktion von EAs

- gegeben seien die beiden EAs

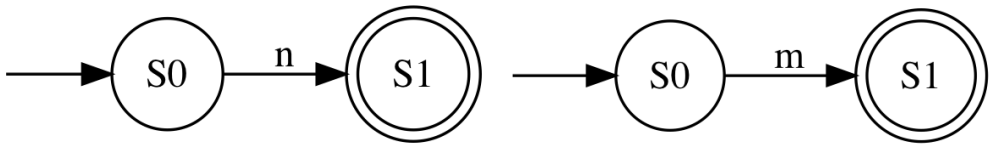

- Wir können einen ϵ-Übergang, der die leere Zeichenkette akzeptiert, einfügen und so einen EA für *nm* konstruieren.

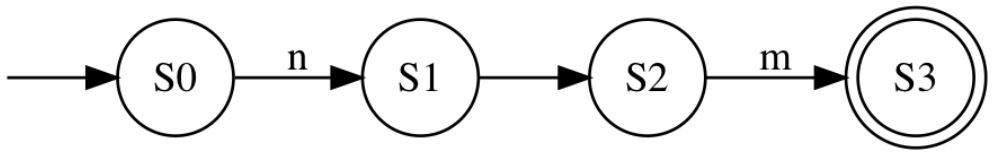

- Im zweiten Schritt können wir den ϵ-Übergang eliminieren.

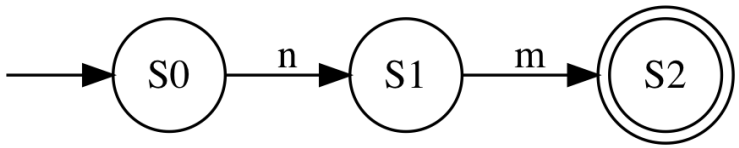

Nichtdeterministischer Endlicher Automat

- angenommen wir wollen die folgenden beiden EAs konkatenieren

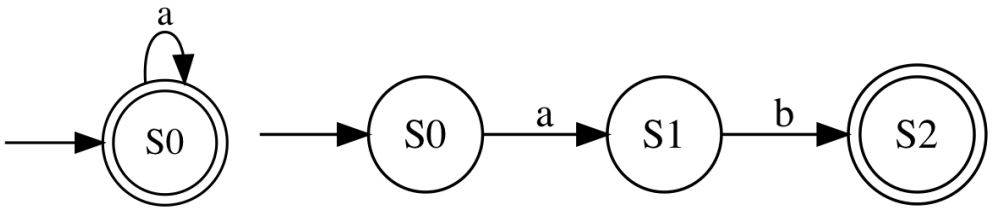

- mit einem ϵ-Übergang bekommen wir

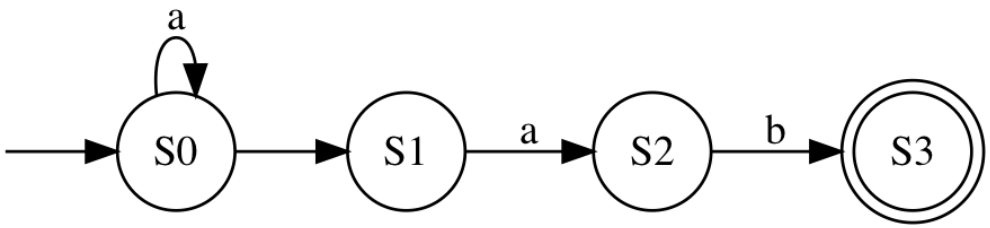

Das ist ein **NEA**, weil es von einem Zustand mehrere Übergänge mit einem Zeichen gibt.

Äquivalenz von NEAs und DEAs

- NEAs und DEAs sind äquivalent bzgl. ihrer Ausruckskraft
- jeder NEA kann durch einen DEA simuliert werden
- DEA für a^*ab ist

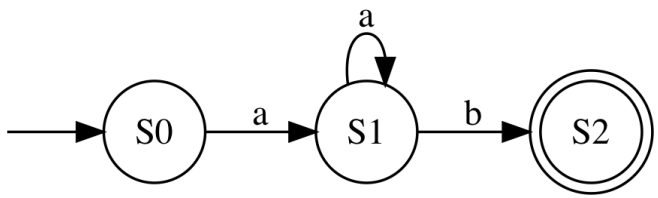

das ist der selbe wie für aa^*b

RE nach NEA: Thompson's Construction

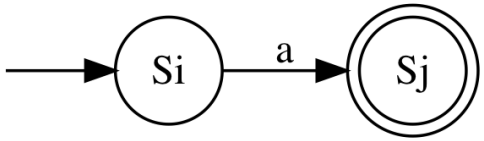

NEA für *a*

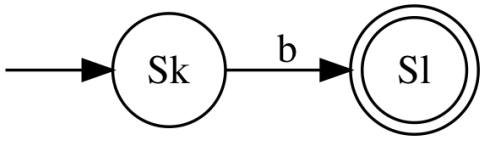

NEA für *b*

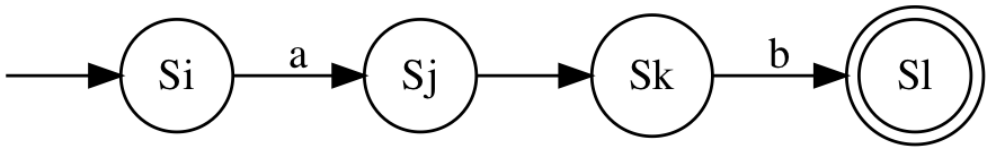

NEA für *ab*

RE nach NEA: Thompson's Construction (2)

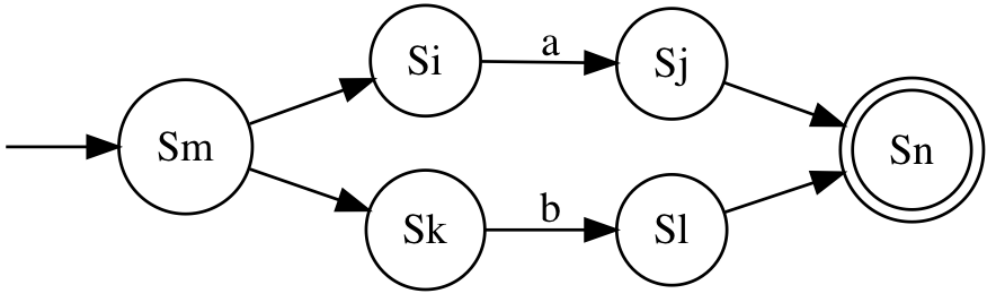

NEA für $a|b$

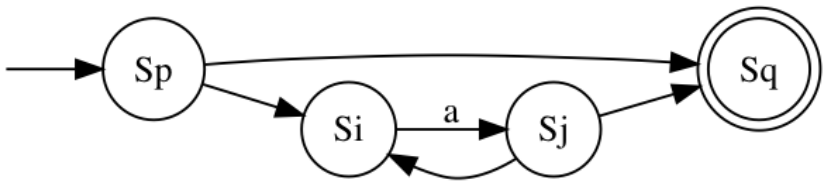

NEA für a^*

Anwendung von Thompson's Construction

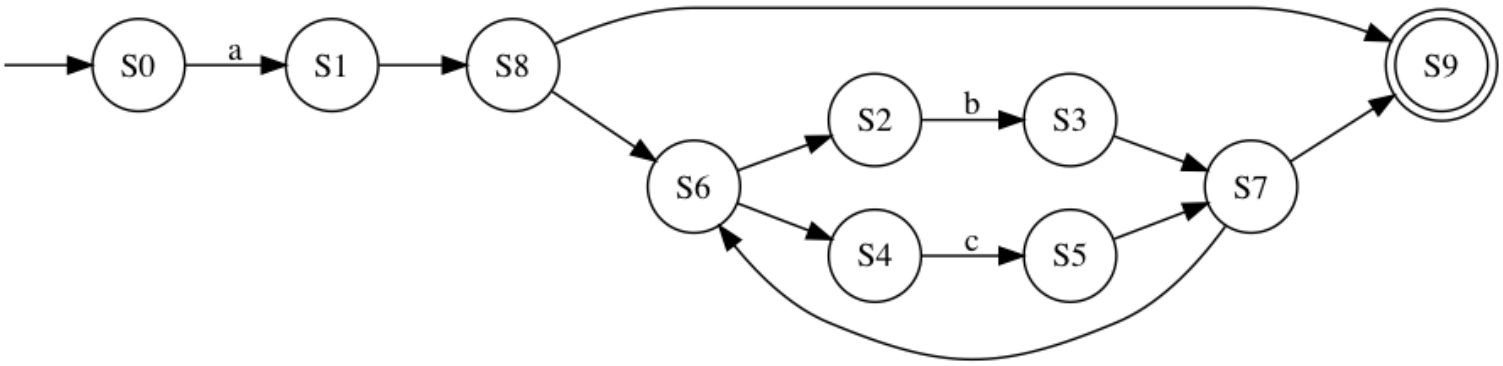

NEA für $a(b|c)^*$

Haskell-Datentyp für Reguläre Ausdrücke

- Datentyp für reguläre Ausdrücke

```
data RE = PrimitiveRE Char
        | ConcatenatedRE RE RE
        | AlternativeRE RE RE
        | ClosureRE RE
```

- Beispiele
  - a: `PrimitiveRE 'a'`
  - a^*: `ClosureRE (PrimitiveRE 'a')`
  - ab:
    `ConcatenatedRE (PrimitiveRE 'a') (PrimitiveRE 'b')`
  - $a|b$:
    `AlternativeRE (PrimitiveRE 'a') (PrimitiveRE 'b')`

Beispiel: RE $(aa^*a|(c|d)^*b)^*e$ in Haskell

```
ConcatenatedRE
      (ClosureRE
        (AlternativeRE
          (ConcatenatedRE
            (PrimitiveRE 'a')
            (ConcatenatedRE
              (ClosureRE
              (PrimitiveRE 'a'))
              (PrimitiveRE 'a')))
          (ConcatenatedRE
            (ClosureRE
              (AlternativeRE
                (PrimitiveRE 'c')
                (PrimitiveRE 'd')))
            (PrimitiveRE 'b'))))
      (PrimitiveRE 'e')
```

Haskell-Datentyp für NFAs

```haskell
data NFAState = NFAState
  { nfaStateNumber :: Integer
  }
data NFA = NFA
  { -- nfaStates   :: Set NFAState -- wird berechnet
    -- nfaBigSigma :: [Char]      -- wird berechnet
    nfaSigma :: Set ((NFAState, Maybe Char), NFAState)
  , nfaStart :: NFAState
  , nfaAcceptingStates :: Set NFAState
  }
```

Beispiel: NFA in Haskell für *ab*

```
NFA
  { nfaSigma = Set.fromList
               [ ((NFAState 0, Just 'a'), NFAState 1)
               , ((NFAState 1, Nothing ), NFAState 2)
               , ((NFAState 2, Just 'b'), NFAState 3)
               ]
  , nfaStart = NFAState 0
  , nfaAcceptingStates = Set.singleton $ NFAState 3
  }
```

Beispiel: NFA in Haskell für $a|b$

```
NFA
  { nfaSigma = Set.fromList
               [ ((NFAState 0, Nothing ), NFAState 1)
               , ((NFAState 0, Nothing ), NFAState 3)
               , ((NFAState 1, Just 'a'), NFAState 2)
               , ((NFAState 3, Just 'b'), NFAState 4)
               , ((NFAState 2, Nothing ), NFAState 5)
               , ((NFAState 4, Nothing ), NFAState 5)
               ]
  , nfaStart = NFAState 0
  , nfaAcceptingStates = Set.singleton $ NFAState 5
  }
```

Thompson's Construction in Haskell

ThompsonsConstruction.hs @ GitHub

NEA nach DEA: Die Teilmengenkonstruktion

die Teilmengenkonstruktion nimmt einen NEA

- $(N, \Sigma, \sigma_N, n_0, N_A)$

und produziert einen DEA

- $(D, \Sigma, \sigma_D, d_0, D_A)$

Algorithmus zur Teilmengenkonstruktion

```
q_0 = epsilonClosure({n_0});
Q = q_0;
Worklist = {q_0};
while (Worklist /= {}) do
    remove q from Worklist;
    for each character c elem Sigma do
        t = epsilonClosure(Delta(q,c));
        T[q,c] = t;
        if t not elem Q then
            add t to Q and to Worklist;
    end;
end;
```

Von Q nach D

- jedes $q_i \in \mathtt{Q}$ benötigt einen Zustand $d_i \in D$
- wenn q_i einen akzeptierenden Zustand im NEA enthält, dann ist d_i ein Endzustand des DEA
- σ_D kann direkt aus $\mathtt{T}$ konstruiert werden durch die Abbildung von q_i nach d_i
- der Zustand der aus q_0 konstruiert werden kann, ist d_0

Beispiel

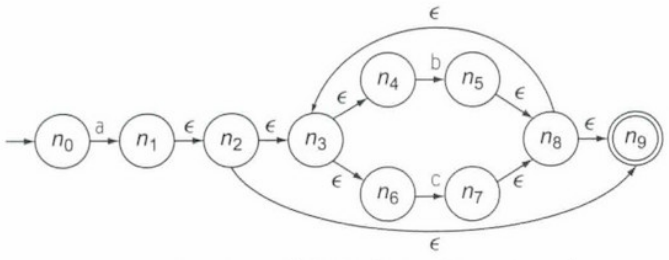

(a) NFA for "$a(b \mid c)^*$" (With States Renumbered)

Set Name	DFA States	NFA States	ϵ-closure(Delta(q,*))		
			a	b	c
q_0	d_0	n_0	$\{n_1, n_2, n_3, n_4, n_6, n_9\}$	– none –	– none –
q_1	d_1	$\{n_1, n_2, n_3, n_4, n_6, n_9\}$	– none –	$\{n_5, n_8, n_9, n_3, n_4, n_6\}$	$\{n_7, n_8, n_9, n_3, n_4, n_6\}$
q_2	d_2	$\{n_5, n_8, n_9, n_3, n_4, n_6\}$	– none –	q_2	q_3
q_3	d_3	$\{n_7, n_8, n_9, n_3, n_4, n_6\}$	– none –	q_2	q_3

(b) Iterations of the Subset Construction

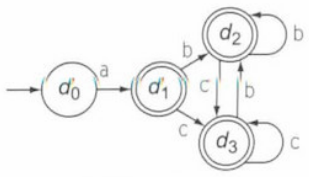

(a) Resulting DFA

Aus Cooper & Torczon, Engineering a Compiler

Haskell-Datentyp für NFAs

```haskell
data DFAState = DFAState Integer

data DFA = DFA
  { -- dfaStates    :: Set DFAState -- wird berechnet
    -- dfaBigSigma :: [Char]       -- wird berechnet
    dfaSigma  :: Set ((DFAState, Char), DFAState)
  , dfaStart  :: DFAState
  , dfaAcceptingStates :: Set DFAState
  }
```

- Wesentlicher Unterschied zum `NFA` ist die σ-Funktion, die hier keinen ϵ-Übergang zulässt
  - `Char` statt `Maybe Char`

Teilmengenkonstruktion in Haskell

SubsetConstruction.hs @ GitHub

FixPunkt-Berechnungen

- die Teilmengenkonstruktion ist ein Beispiel einer Berechnung eines Fixpunkts
- diese ist eine Berechnungsart die an vielen Stellen in der Informatik genutzt wird
- eine monotone Funktion wird wiederholt auf ihr Ergebnis angewendet
- die Berechnung terminiert wenn sie einen Zustand erreicht bei dem eine weitere Iteration das selbe Ergebnis liefert
- das ist ein Fixpunkt
- im Compilerbau sind auch häufig Fixpunkt-Berechnung zu finden

Erzeugen eines minimal DFA aus einem beliebigen DFA: Hopcroft's Algorithmus

- der mit der Teilmengenkonstruktion hergeleitete DEA kann eine sehr große Anzahl von Zuständen haben
  - damit benötigt ein Scanner viel Speicher
- Ziel: äquivalente Zustände finden
- Hopcroft's Algorithmus konstruiert eine Partition $P = \{p_1, p_2, ...p_m\}$ der DEA-Zustände
- gruppiert die Zustände bzgl. des Verhaltens
  - wenn $d_i \overset{c}{\mapsto} d_x, d_j \overset{c}{\mapsto} d_y$ und $d_i, d_j \in p_s$, dann müssen d_x und d_y in der selben Teilmenge p_t sein
  - d.h. wir splitten bei Zeichen die von einem Zustand in p_s bleiben und beim anderen nicht (nicht kann auch sein, dass es keine Transition für diesen Buchstaben gibt)
- jede Teilmenge $p_s \in P$ muss maximal groß sein

Hopcroft's Algorithmus

```
T = { D_A, { D - D_A}};
P = {};
while (P /= T) do
    P = T;
    T = {};
    for each set p in P do
        T = T `union` Split(p);
    end;
end;

Split(S) {
    for each c in Sigma do
        if c splits S into s1 and s2
            then return {s1,s2};
    end;
    return S;
}
```

Beispiel

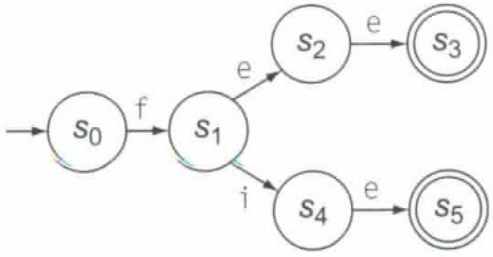

(a) DFA for "*fee* | *fie*"

Step	Current Partition	Examines		
		Set	Char	Action
0	$\{\{s_3,s_5\},\{s_0,s_1,s_2,s_4\}\}$	—	—	—
1	$\{\{s_3,s_5\},\{s_0,s_1,s_2,s_4\}\}$	$\{s_3,s_5\}$	*all*	*none*
2	$\{\{s_3,s_5\},\{s_0,s_1,s_2,s_4\}\}$	$\{s_0,s_1,s_2,s_4\}$	e	*split* $\{s_2,s_4\}$
3	$\{\{s_3,s_5\},\{s_0,s_1\},\{s_2,s_4\}\}$	$\{s_0,s_1\}$	f	*split* $\{s_1\}$
4	$\{\{s_3,s_5\},\{s_0\},\{s_1\},\{s_2,s_4\}\}$	*all*	*all*	*none*

(b) Critical Steps in Minimizing the DFA

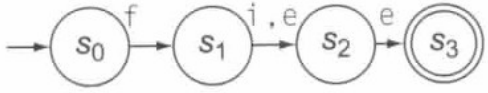

(c) The Minimal DFA (States Renumbered)

Aus Cooper & Torczon, Engineering a Compiler

Hopcroft's Algorithmus in Haskell

Hopcroft.hs @ GitHub

Vom DEA zum Recognizer

- aus dem minimalen DEA kann der Code für den Recognizer hergeleitet werden
- der Recognizer muss als Ergebnis liefern
  - die erkannte Zeichenkette
  - die syntaktische Kategorie
- um Wortgrenzen zu erkennen, können wir Trennzeichen, z.B. Leerzeichen, zwischen die Wörter schreiben
- das bedeutet aber, wir müssten `2 + 5` statt `2+5` schreiben

Eine andere Art zu erkennen

- der Recognizer muss das längste Wort finden, dass zu einem der regulären Ausdrücke passt
- er muss solange weiter machen bis er einen Zustand s erreicht von dem es keinen Übergang mit dem folgenden Zeichen gibt
- wenn s ein Endzustand ist, gibt der Scanner das Wort und die syntaktische Kategorie zurück
- sonst muss er den letzten Endzustand finden (backtracking)
- wenn es keinen gibt $\Rightarrow$ Fehlermeldung
- es kann im ursprünglichen NEA mehrere Zustände geben, die passen
  - z.B. ist `new` ein Schlüsselwort aber auch ein Bezeichner
- der Scanner muss entscheiden können welche Kategorie er vorzieht

Implementierung von Scannern

Table-Driven Scanner

- nutzt das Gerüst eines Scanners zur Steuerung und
- eine Menge von generierten Tabellen die das sprachspezifische Wissen enthalten
- der Compilerbauer muss eine Menge von lexikalischen Mustern (REs) zur Verfügung stellen
- der Scanner-Generator erzeugt die Tabellen

Beispiel

```
NextWord()
  state ← s0 ;
  lexeme ← " ";
  clear stack;
  push(bad);

  while (state≠se) do
    NextChar(char);
    lexeme ← lexeme + char;
    if state ∈ SA
        then clear stack;
    push(state);
    cat ← CharCat[char];
    state ← δ[state,cat];
  end;

  while(state ∉ SA and
        state≠bad) do
    state ← pop();
    truncate lexeme;
    RollBack();
  end;

  if state ∈ SA
    then return Type[state];
    else return invalid;
```

r	0, 1, 2, ..., 9	EOF	**Other**
Register	*Digit*	*Other*	*Other*

The Classifier Table, *CharCat*

	Register	***Digit***	***Other***
s_0	s_1	s_e	s_e
s_1	s_e	s_2	s_e
s_2	s_e	s_2	s_e
s_e	s_e	s_e	s_e

The Transition Table, δ

s_0	s_1	s_2	s_e
invalid	*invalid*	*register*	*invalid*

The Token Type Table, *Type*

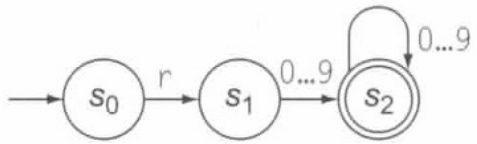

The Underlying DFA

Exzessiven Rollback vermeiden

- gegeben sei der RE $ab|(ab)^*c$
- für *abababc* gibt der Scanner die gesamte Zeichenkette als einzelnes Wort zurück
- für *abababab* muss der Scanner alle Zeichen lesen bevor er entscheiden kann, dass der längste Präfix *ab* ist
  - als nächstes liest er *ababab* und erkennt *ab*
  - ...

  im schlechsten Fall: quadratische Laufzeit
- der *Maximal Munch Scanner* (*munch* heisst mampfen) vermeidet so ein Verhalten durch drei Eigenschaften
  1. ein globaler Zähler für die Position im Eingabe-Zeichenstrom
  2. ein Bit-Array um sich Übergänge in "Sackgassen" zu merken
  3. eine Initialisierungsroutine die vor jedem neuen Wort aufgerufen wird
- er merkt sich spezifische Paare (Zustand, Position im Eingabestrom) die nicht zu einem akzeptierenden Zustand führen können

Direct-Coded Scanners

- Um die Performanz eines Table-Driven Scanners zu verbessen, müssen wir die Kosten reduzieren vom
  - Lesen des nächsten Zeichens
  - Berechnen des nächsten Zustandübergangs
- Direct-Coded Scanners reduzieren die Kosten der Berechnung des nächsten Zustandübergangs durch
  - ersetzen der expliziten Repräsentation durch eine implizite
  - und dadurch Vereinfachung des zweistufigen Tabellenzugriffs

Overhead des Tabellen-Lookups

- der Table-Driven Scanner macht zwei Tabellen-Lookups, einer in `CharCat` und einer in σ
- um das `i`. Element von `CharCat` zu bekommen, muss die Adresse $\texttt{@CharCat}_0 + i \times w$ berechnet werden
  - $\texttt{@CharCat}_0$ ist eine Konstante die die Startadresse von `CharCat` im Speicher bezeichnet
  - w ist die Anzahl Bytes von jedem Element in `CharCat`
- für $\sigma(state, cat)$ ist es $\texttt{@}\sigma_0 + (\texttt{state} \times \texttt{numberofcolumsin}\,\sigma + \texttt{cat}) \times w$

Ersatz für die while-Schleife des Table-Driven Scanners

- ein Direct-Coded Scanner hat für jeden Zustand ein eigenes spezialisiertes Codefragment
- er übergibt die Kontrolle direkt von Zustands-Codefragment zu Zustands-Codefragment
- der Scanner-Generator kann diesen Code direkt erzeugen
- der Code widerspricht einigen Grundsätzen der strukturierten Programmierung
- aber nachdem der Code generiert wird, besteht keine Notwendigkeit ihn zu lesen oder gar zu debuggen

Beispiel

erkennt $r[0...9]^+$

```
s_init : lexeme ← " ";
         clear stack;
         push(bad);
         goto s_0 ;

s_0 :    NextChar(char);
         lexeme ← lexeme + char;
         if state ∈ S_A
             then clear stack;
         push(state);
         if (char='r')
             then goto s_1 ;
             else goto s_out ;

s_1 :    NextChar(char);
         lexeme ← lexeme + char;
         if state ∈ S_A
             then clear stack;
         push(state);
         if ('0'≤char≤'9')
             then goto s_2 ;
             else goto s_out ;

s_2 :    NextChar(char);
         lexeme ← lexeme + char;
         if state ∈ S_A
             then clear stack;
         push(state);
         if '0'≤char≤'9'
             then goto s_2 ;
             else goto s_out

s_out :  while (state ∉ S_A and
                 state ≠ bad) do
             state ← pop();
             truncate lexeme;
             RollBack();
         end;
         if state ∈ S_A
             then return Type[state];
             else return invalid;
```

Aus Cooper & Torczon, Engineering a Compiler

Hand-coded Scanner

- generierte Scanner benötigen eine kurze, konstante Zeitspanne pro Zeichen
- viele Compiler (kommerzielle und Open Source) benutzen handgeschriebene Scanner
- z.B. wurde *flex* entwickelt um das *gcc* Projekt zu unterstützen
- aber *gcc 4.0* nutzt handgeschriebene Scanner in mehreren Frontends
- handgeschriebene Scanner können den Overhead der Schnittstellen zwischen Scanner und dem Rest des Systems reduzieren
- eine umsichtige Implementierung kann die Mechanismen verbessern, die
  - Zeichen lesen und
  - Zeichen manipulieren

  außerdem die Operationen
  - die benötigt werden um eine Kopie des aktuellen Lexem als Output zu erzeugen