Patrick Simianer
Visualisierung regulärer Ausdrücke

Patrick Simianer
2010-06-28

Endliche Automaten HS bei Dr. Karin Haenelt
Universitiät Heidelberg im Sommersemester 2010

Gliederung

Visualisierung regulärer Ausdrücke

Wie soll die Visualisierung aussehen?

1. Hervorheben von ***Matches*** oder **Gruppen** in einem String oder Text
2. Darstellung und Simulation anhand eines **Automaten**

1. Es existieren bereits viele Implementierungen, basierend auf RE-Implementierung der jeweiligen Sprache.
   → Keine „*step by step*“-Visualisierung möglich
2. Grafische Umsetzung schwierig, eigene RE-Implementierung nötig
   → Jeder Schritt der Erkennung nachvollziehbar

Visualisierung regulärer Ausdrücke /2

1. Wie können reguläre Ausdrücke möglichst einfach und effizient implementiert werden?
   - „Herkömmliche“ *backtracking*-Methode (*Perl*, *PCRE*)

   ⇒ Direkte Konstruktion eines **endlichen Automaten**

2. Soll der Automat dargestellt werden – und wenn ja, wie?

   ⇒ **Ja**, im besten Fall mit Animationen...

3. In welcher Umgebung können alle Teile (1. Parser, 2. GUI, 3. Visualisierung) gut implementiert werden?

   ⇒ Im **Browser** (1. *JavaScript*, 2. *HTML*, 3. *SVG*)

Protoypisches Vorgehen

1. **Parsen** des Ausdrucks
2. Umsetzung in einen **nichtdeterministischen endlichen Automaten**
3. Übersetzung des NDEA in einen **deterministischen** endlichen Automaten
4. Grafische **Darstellung** des Automaten und dessen **Simulation** durch Animation

Umsetzung im Browser: *JavaScript* (*Raphaël* für *SVG*, *jQuery*), *HTML+CSS*

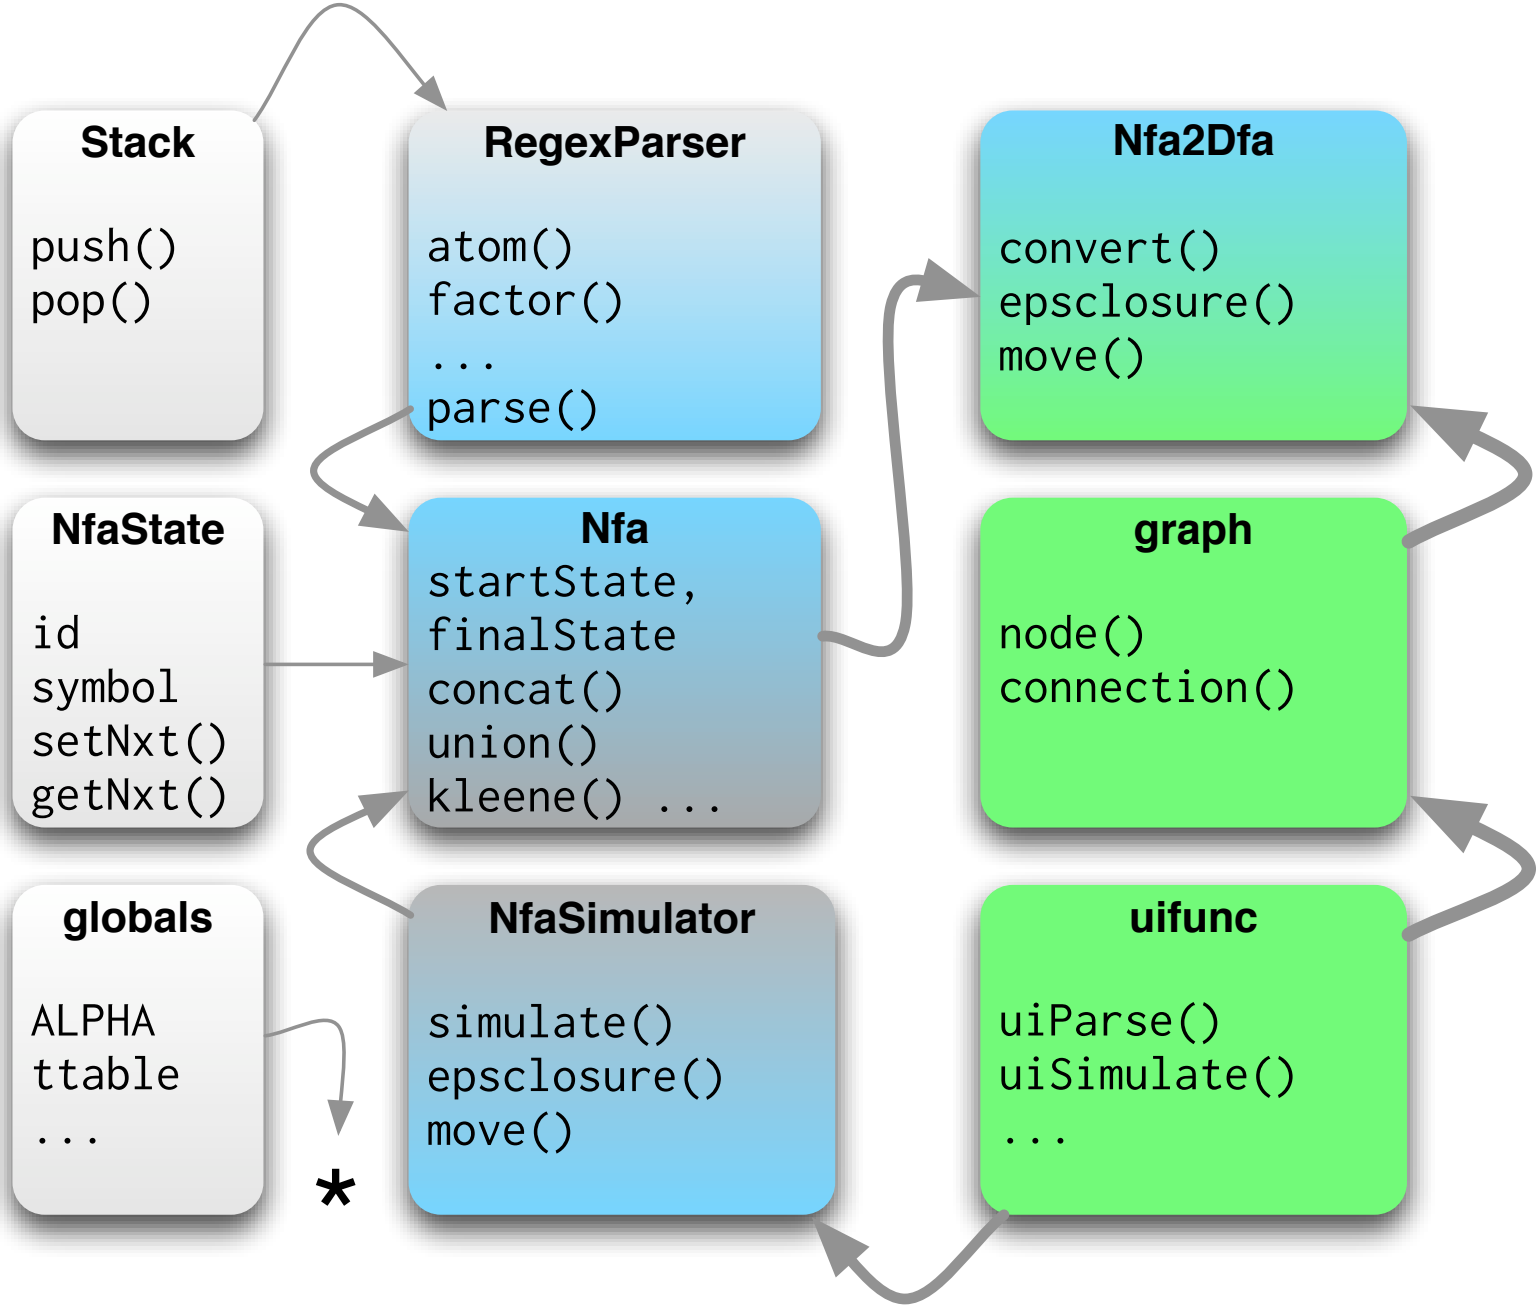

Abbildung: Konkreter System-Aufbau

Recursive Descent-Methode

Grammatik:

expr	$\rightarrow$	term | term | expr
term	$\rightarrow$	factor | term
factor	$\rightarrow$	atom kleene
atom	$\rightarrow$	literal | (expr)
kleene	$\rightarrow$	$*$ kleene | ϵ
literal	$\rightarrow$	a | b | c | %

Code:

```
RegexParser.prototype.expr = function() {
    var nfa = this.term();
    if (this.trymatch('|')) {
        return nfa.union(this.expr());
    };
    return nfa;
};
```

- Nahezu direktes Übersetzen einer Grammatik[1] in den Quelltext des Parsers, *top-down* (LL(1))
- $\forall$ Nichtterminale $\exists$ Funktion, welche die rechte Seite der jeweiligen Regel behandelt
- Direkte Erzeugung des NDEA, mittels Konstruktion nach Thompson in $O(|r|)$ ($|r|$ Länge des regulären Ausdrucks)
- Ergebnis: Automat mit max. $2|r|$ Zuständen, $4|r|$ Transitionen

[1] keine Links-Rekursionen, sonst: Endlosschleife

Konstruktion nach Thompson

Konkatenation: `ab`

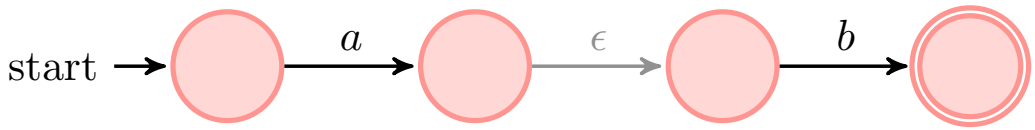

Hülle: `a*`

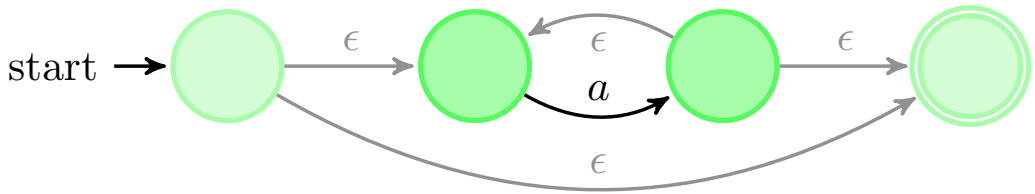

Vereinigung: `(a|b)`

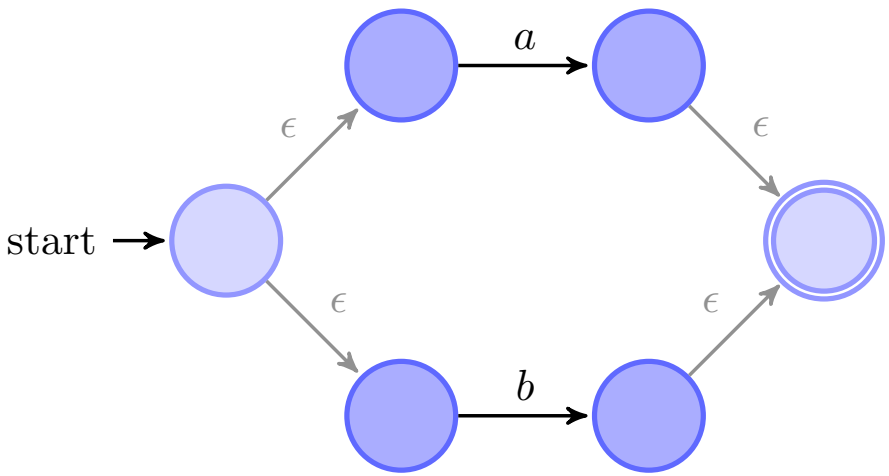

Thompsons Algorithmus: Beispiel

Regulärer Ausdruck: `a(a|b)c*`

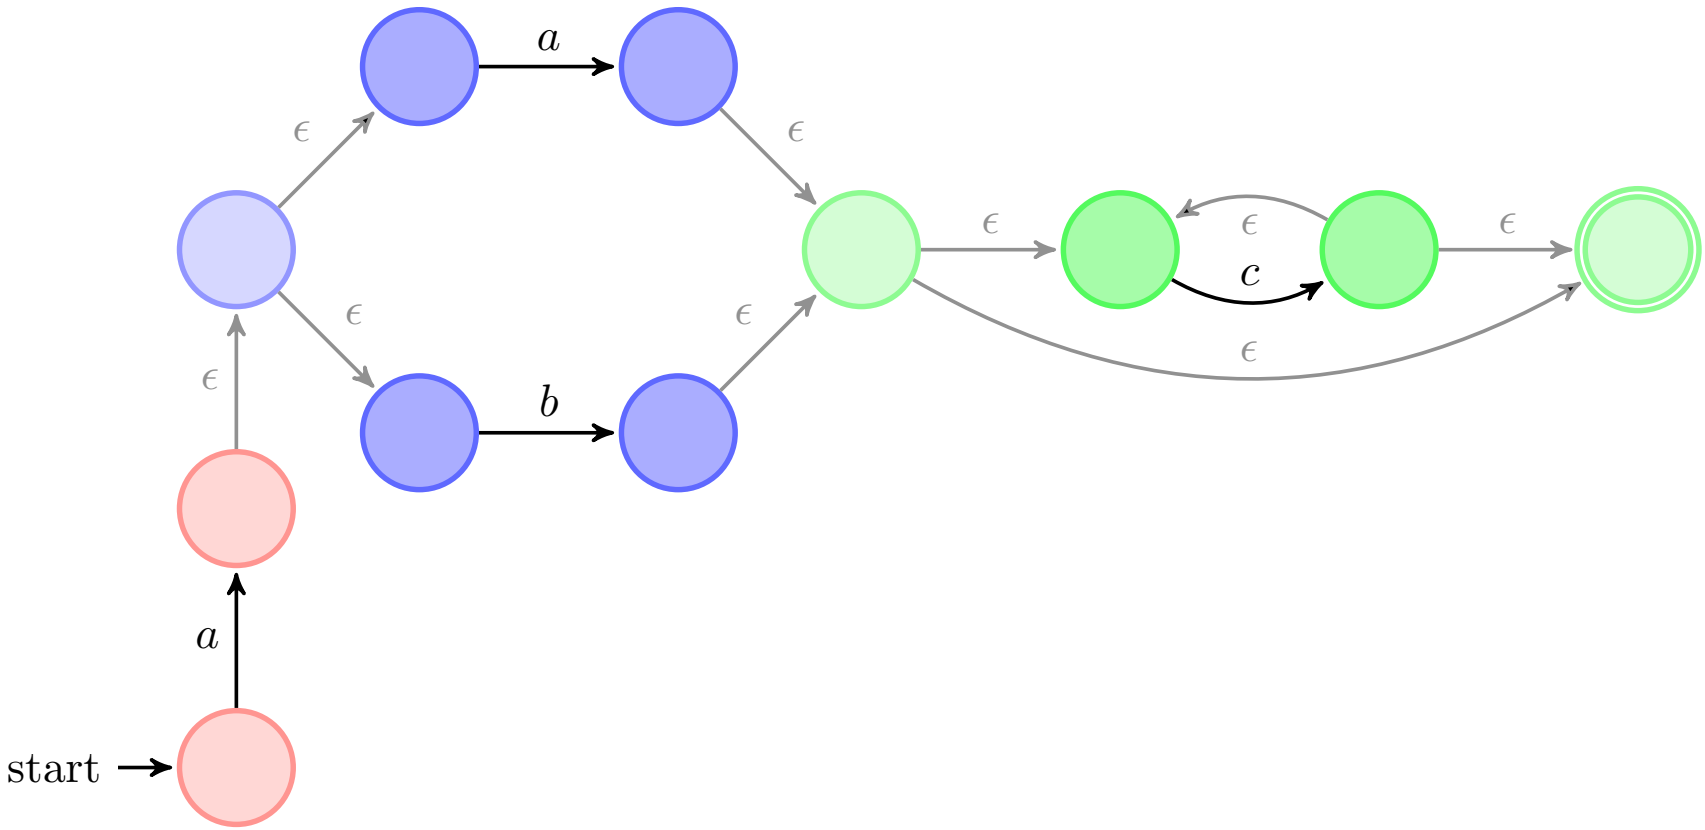

Einleitung

Warum den erzeugten NDEA in einen DEA überführen?

trade-off:

	NDEA	DEA
Platzbedarf	$2\|r\| = m$, $4\|r\| = n$	2^m
Erstellungszeit	$O(\|r\|)$	$O(\|r\|^2 2^{\|r\|})$, $O(\|r\|^3)$
Simulation	$O(\|x\|(m+n))$ $\approx O(\|x\| * \|r\|)$	$O(\|x\|)$

$|x|$ Länge des Eingabe-Strings; bei Erstellungszeit DEA: links *worst-case*, rechts der Durchschnitsfall

- Die hier erzeugten NDEA umfassen für gewöhnlich sehr viele Zustände, die Darstellung eines DEA ist praktikabler

ϵ-Abschluss

Pseudo-Code

```
epsclosure(dState): stack s
foreach nState in dState {
 s.push(nState)
}
while s not empty {
 nState1 = s.pop()
 foreach nState1 e> nState2 {
  if nState2 not in dState {
   dState.add(nState2)
   s.push(nState2)
  }
 }
}
return dState
```

```
nfa2dfa(NFA): stack s, DFA d
s.push(epsclosure(nfa.start))
d.add(epsclosure(nfa.start))
while s not empty {
 dState1 = s.pop()
 foreach ch in ALPHA {
  dState2 = move(dState1, ch)
  next = epsclosure(dState2)
  if next not in DFA {
   d.add(dState ch> next)
  }
 }
}
return d
```

a e> b: ϵ-Übergang von Z. a nach b; a ch> b: Übergang mit Zeichen ch

- **Formal:** $\forall p \in Q : E(\{p\}) = \{q \in Q : p \rightarrow_\epsilon q\}$ (ϵ-Abschl. v. a. p aus Q)
- **Simulation** des NDEA, oder vollständige Erzeugung eines **DEA**

NDEA $\rightarrow$ DEA Beispiel

Regulärer Ausdruck: `(a|b)*`

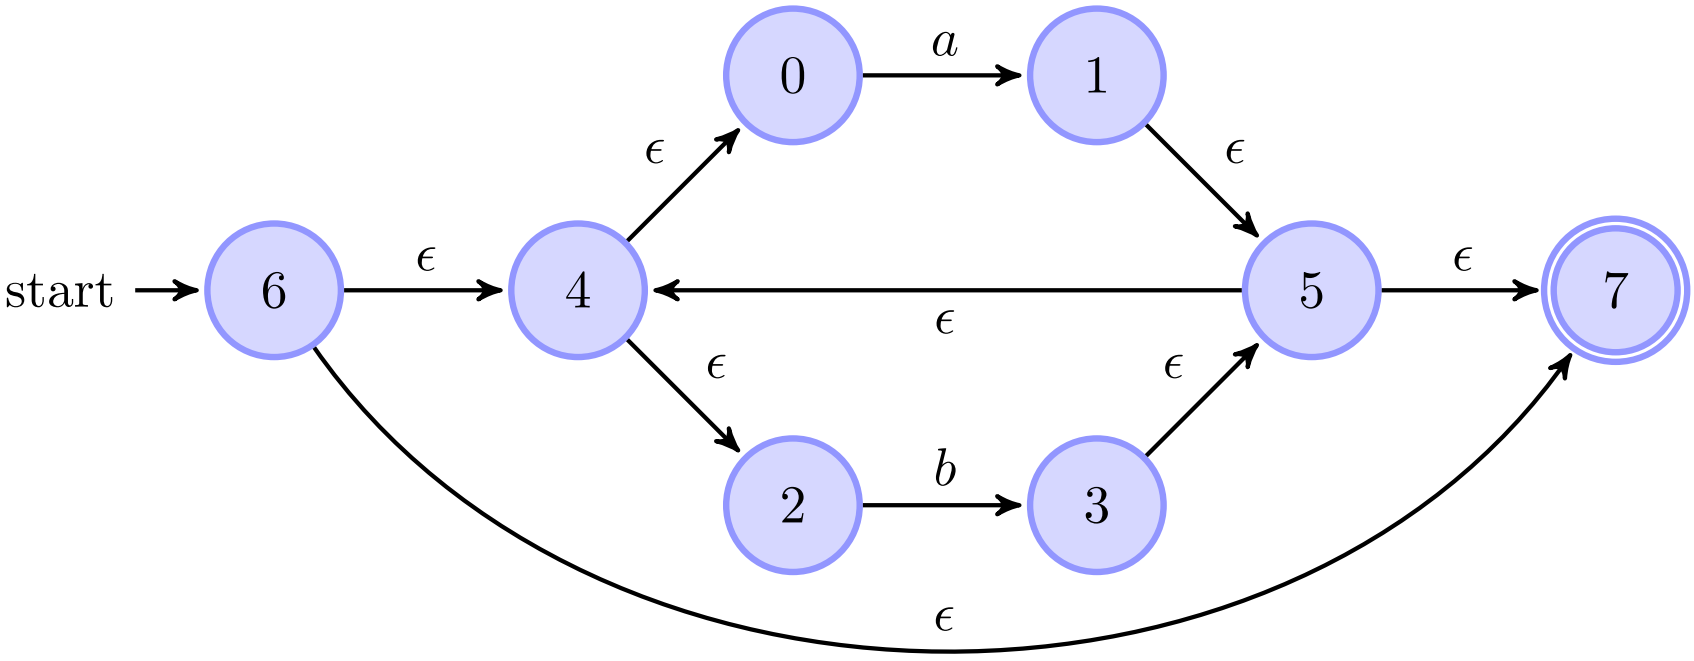

NDEA $\rightarrow$ DEA Beispiel /2

Dfa ID	Symbol	$\rightarrow$Dfa ID
{6, 7, 4, 0, 2}	a	{1, 5, 7, 4, 0, 2}
	b	{3, 5, 7, 4, 0, 2}
{1, 5, 7, 4, 0, 2}	a	{1, 5, 7, 4, 0, 2}
	b	{3, 5, 7, 4, 0, 2}
{3, 5, 7, 4, 0, 2}	a	{1, 5, 7, 4, 0, 2}
	b	{3, 5, 7, 4, 0, 2}

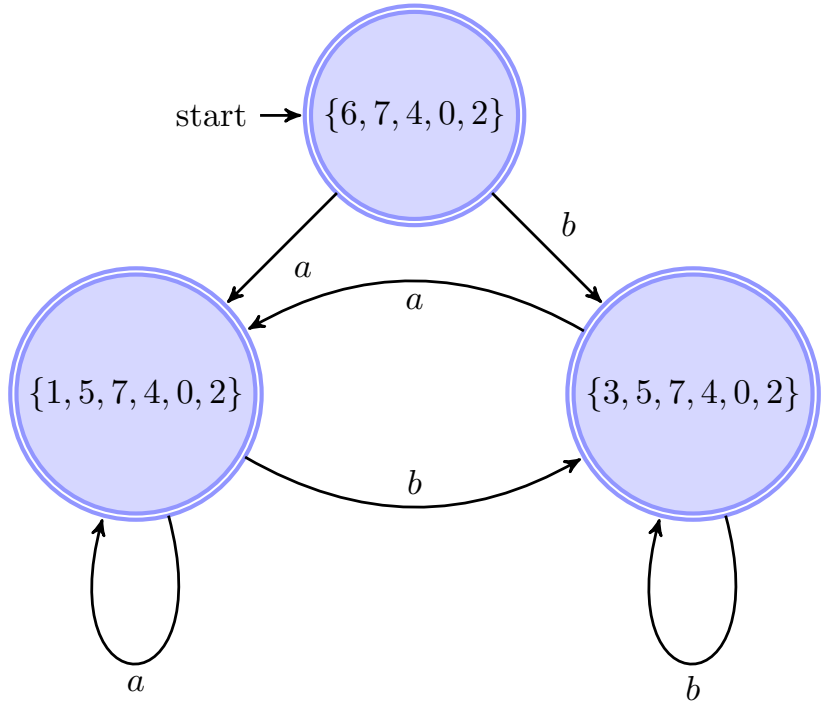

Fragen?

Literatur I


Alfred V. Aho, Ravi Sethi, and Jeffrey David Ullman.
Compilers. Principles, Techniques & Tools.
Addison-Wesley, Reading, Mass. [u.a.], repr. with corr. edition, 1986.
Literaturverz. S. 752 - 779.


Russ Cox.
Regular Expression Matching Can Be Simple And Fast.
2007.
[Online; abgerufen 2010-06-06].


Hans Werner Lang.
Algorithmen in Java.
Oldenbourg, Wiesbaden, 2006.

Literatur II


Gonzalo Navarro and Mathieu Raffinot.
Compact dfa representation for fast regular expression search, 2001.


K. Thompson.
Regular expression search algorithm.
Comm. Assoc. Comp. Mach., 11(6):419–422, 1968.


Gertjan van Noord.
The treatment of epsilon moves in subset construction.
In *IN FINITE-STATE METHODS IN NATURAL LANGUAGE PROCESSING, ANKARA. CMP-LG/9804003*, pages 61–76, 1998.

Ressourcen

- *Raphaël* JavaScript SVG Library (`http://raphaeljs.com/`)
- *jQuery* JavaScript Library (`http://jquery.com/`)
- Scalable Vector Graphics (*SVG*) 1.1 Specification (`http://www.w3.org/TR/SVG/`)
- Writing your own regular expression parser (`http://www.codeproject.com/KB/recipes/OwnRegExpressionsParser.aspx`)

Demo

Weiterentwicklung

- Vorhanden: $*$, `|`, `()`
- Zeichenklassen: `.`, `\w`, `\d`, `[ ]`, ... $\rightarrow$ Einfach implementierbar, Vorverarbeitung der Eingabe
- Operatoren: $+$, `?`, $\{m, n\}$, ... $\rightarrow$ Ebenfalls durch Vorverarbeitung lösbar, beziehungsweise durch Anpassung des Automaten
- *Lookahead* oder *lookbehind* sind leider nicht ohne Weiteres mit endlichen Automaten zu implementieren, da die zugrunde liegenden Grammatiken nicht mehr regulär wären.