

1 Einleitung

Reguläre Ausdrücke

- Was ist das ?
- Tut das weh?
- Kann man etwas dagegen machen

Motivation

Werkzeuge

- find
- grep
- sed
- awk

Standards

- ERE
- BRE
- PCRE



2 Ein wenig Theorie

Worum geht's?

wichtige Begriffe

- Sprache {Aal, Aas, Abakus, ..., Zylinder, Zyniker, Zynismus}
- Wort Abakus
- Alphabet $\Sigma = \{a, b, \dots, z, ä, ö, ü, ß, A, B, \dots, Z, Ä, Ö, Ü\}$

Wortmengen

Beschreibung

- extensional $\Sigma_t = \{a, b, c, d, e, f, g, h, 1, 2, 3, 4, 5, 6, 7, 8\}$
- intensional $\{a_1, a_2, a_3, \dots, b_1, b_2, \dots, h_7, h_8\}$
- reguläre Ausdrücke $\{xy \mid x \in \{a, \dots, h\}, y \in \{1, \dots, 8\}\}$

[a-h][1-8]



2.1 Syntax

Basisregeln

$$\begin{array}{l} S \rightarrow \emptyset \\ S \rightarrow \varepsilon \end{array}$$

$$S \rightarrow a$$

Rekursive Regeln

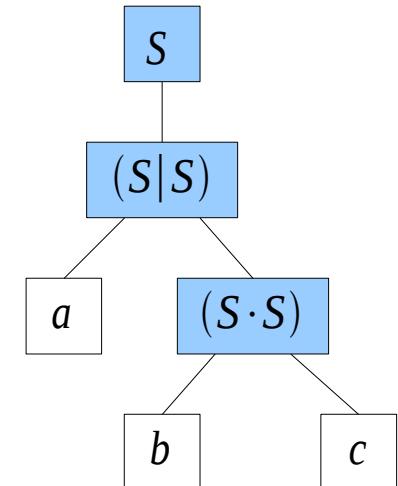
$$\begin{array}{l} S \rightarrow (S \cdot S) \\ S \rightarrow (S | S) \\ S \rightarrow (S^*) \end{array}$$

$$S \rightarrow (S)$$

Beispiel

$(a | (b \cdot c))$

$$\begin{aligned} S \rightarrow (S | S) &\rightarrow (a | S) \rightarrow (a | (S \cdot S)) \\ &\rightarrow (a | (b \cdot S)) \rightarrow (a | (b \cdot c)) \end{aligned}$$



... nur was hat das eigentlich alles zu bedeuten?



2.2 Semantik

Basisregeln

$$\begin{aligned} L(\emptyset) &:= \emptyset \\ L(\varepsilon) &:= \{\varepsilon\} \end{aligned}$$

$$L(a) := \{a\}$$

Rekursive Regeln

$$\begin{aligned} L(R \cdot S) &:= \{rs \mid r \in L(R), s \in L(S)\} \\ L(R|S) &:= L(R) \cup L(S) \\ L(S^*) &:= \bigcup_{i=0}^{\infty} L(R^i) \end{aligned}$$

$$L((S)) := L(S)$$

Beispiel

$$\begin{aligned} L(a|(b \cdot c)) &= \\ &= L(a) \cup L((b \cdot c)) \\ &= \{a\} \cup \{rs \mid r \in L(b), s \in L(c)\} \\ &= \{a\} \cup \{rs \mid r \in \{b\}, s \in \{c\}\} \\ &= \{a\} \cup \{bc\} \\ &= \{a, bc\} \end{aligned}$$



2.3 Klammern „sparen“

Vorrangregeln

(von stark nach schwach)

- * Kleen'sche Hülle
- Verkettung
- | Alternative

Beispiele

$$\begin{aligned}(a|(b \cdot c)) &= a|bc \\ ((a|b) \cdot c) &= (a|b)c \\ (a|(b \cdot (c^*))) &= a|bc^* \\ (a|((b \cdot c)^*)) &= a|(bc)^*\end{aligned}$$

Zeit für ein erstes Experiment!

Was trifft ...

- grep -Ew "a|bc"
- grep -Ew "a|bc*"'

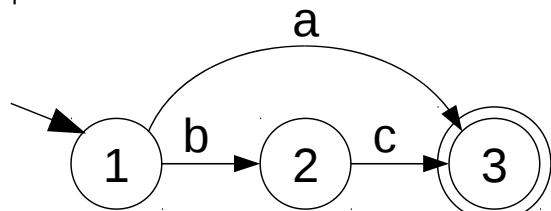
- grep -Ew "a|bc*"
- grep -Ew "a|(bc)*"

... und wie beschreibt man $\{a^n b a^n | n \in \mathbb{N}\}$?

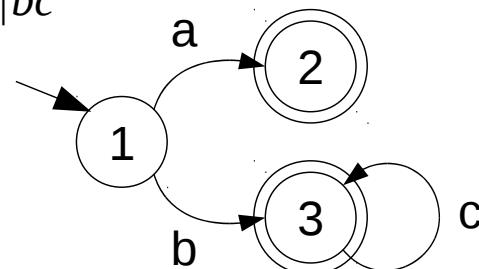


2.4 Implementierung

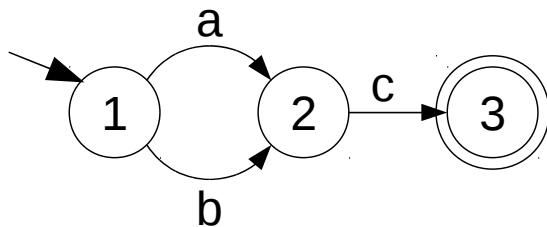
Endliche Automaten

 $a|bc$ 

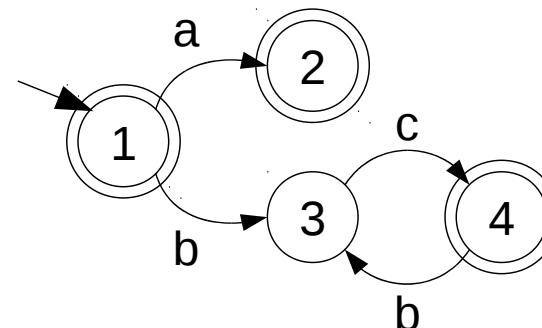
	a	b	c
1	3	2	-
2	-	-	3
3	-	-	-

 $a|bc^*$ 

	a	b	c
1	2	3	-
2	-	-	-
3	-	-	3

 $(a|b)c$ 

	a	b	c
1	2	2	-
2	-	-	3
3	-	-	-

 $a|(bc)^*$ 

	a	b	c
1	2	3	-
2	-	-	-
3	-	-	4
4	-	-	3



2.5 Abkürzungen

Zeichenklassen

- [...] eines der Zeichen ...
- [^ ...] keines der Zeichen ...
- [a - z] ein Zeichen im „Bereich“ a – z

Wiederholungen

- * beliebig oft
- + mindestens ein Mal
- ? höchstens ein Mal
- {m} genau m-Mal
- {m,} mindestens m-Mal
- {m,n} mindestens m, höchstens n-Mal



2.6 Erweiterungen

Anker

gegen implizites `.**`

- `^` Zeilenanfang
- `$` Zeilenende

Rückwärts - Referenz

- `\n` Treffer des n-ten Teilausdrucks



3 Standards

- POSIX – BRE Basic Regular Expressions
- POSIX – ERE Extended Regular Expressions
- PCRE Perl Compatible Regular Expressions

Beim Lesen unbedingt beachten!

Interpretation eines Zeichens hängt ab von

- Kontext (bracket expression [...])
- Position

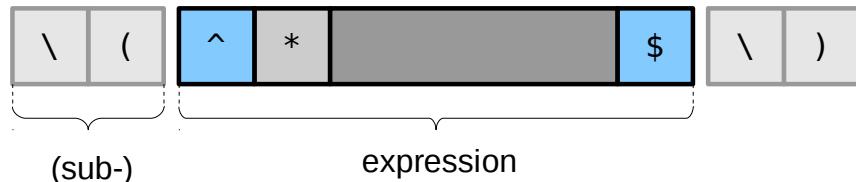
verschiedene Arten von Zeichen

- gewöhnliche Zeichen
- spezielle Zeichen
- „spezielle“ gewöhnliche Zeichen

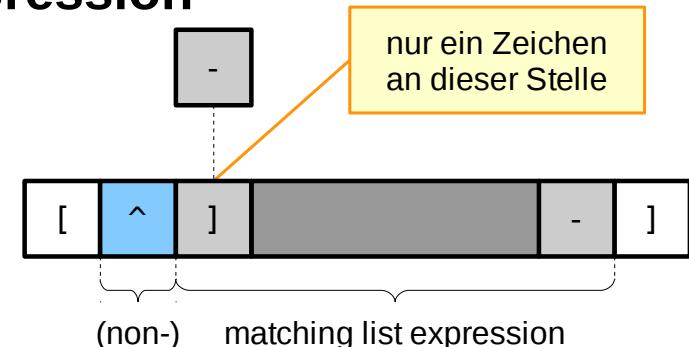


3.1 POSIX – Basic Regular Expressions (BRE)

Regular Expression



Bracket Expression



spezielle Zeichen

\	Escape
.	beliebiges Zeichen
[...]	Zeichenklasse
*	Wiederholung – beliebig oft
^	Anker – Zeilenanfang
\$	Anker – Zeilenende

spezielle gewöhnliche Zeichen

\(...\)	Gruppierung
\{...\}	Wiederholung – n bis m Mal
\n	Rückwärts Referenz

spezielle Zeichen

^	keines der Zeichen
...–...	Bereich von ... bis ...
[: ... :]	POSIX Zeichenklasse
[=...=]	Equivalence-Class
[.....]	Collating-Element

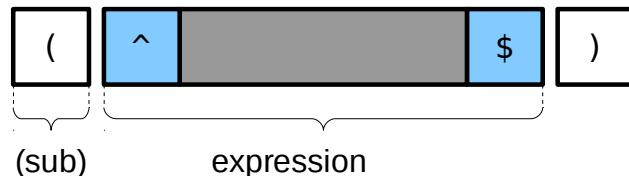
POSIX Zeichenklassen

[:alnum:]	[:cntrl:]	[:lower:]	[:space:]	[:alpha:]	[:digit:]
[:print:]	[:upper:]	[:blank:]	[:graph:]	[:punct:]	[:xdigit:]



3.2 POSIX – Extended Regular Expressions (ERE)

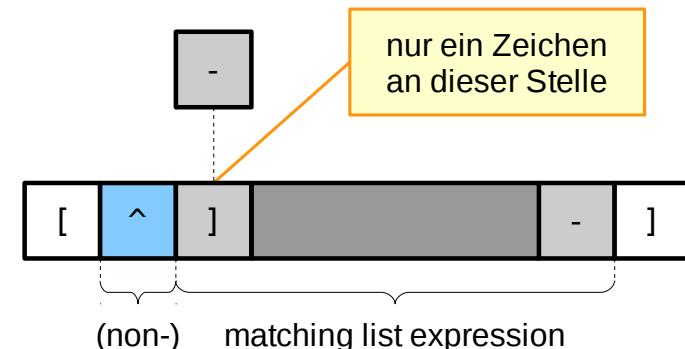
Regular Expression



spezielle Zeichen

\	Escape
.	beliebiges Zeichen
[...]	Zeichenklasse
(...)	Gruppierung
	Alternative
^	Anker – Zeilenanfang
\$	Anker – Zeilenende
?	Wiederholung – maximal einmal
*	Wiederholung – beliebig oft
+	Wiederholung – mindestens einmal
{...}	Wiederholung – n bis m Mal

Bracket Expression



spezielle Zeichen

^	keines der Zeichen
...–...	Bereich von ... bis ...
[: ... :]	POSIX Zeichenklasse
[=...=]	Equivalence-Class
[.....]	Collating-Element

POSIX Zeichenklassen

[:alnum:]	[:cntrl:]	[:lower:]	[:space:]	[:alpha:]	[:digit:]
[:print:]	[:upper:]	[:blank:]	[:graph:]	[:punct:]	[:xdigit:]

3.3 Perl Compatible Regular Expressions (PCRE)

Kurzübersicht (unvollständig!)

spezielle Zeichen

\	Escape
.	beliebiges Zeichen
[...]	Zeichenklasse
(...)	Gruppierung – mit Speicherung Teilergebnis
(?:...)	Gruppierung – ohne Speicherung
	Alternative
^	Anker – Zeilenanfang
\$	Anker – Zeilenende
Wiederholungen (nicht gierig mit nachgestelltem ?)	
?	Wiederholung – maximal einmal
*	Wiederholung – beliebig oft
+	Wiederholung – mindestens einmal
{...}	Wiederholung – n bis m Mal
Zusicherungen	
(?=...)	Nachfolgemuster
(<!=...)	Vorgängermuster

Optionen (?...)

i ignore case
U default ungreedy

spezielle gewöhnliche Zeichen

\w	\W	Wort-Zeichen	(kein ...)
\s	\S	Whitespace	(kein ...)
\d	\D	Ziffer	(keine ...)
\Pc	\pc	Eigenschaft	(keine ...)
\b	\B	Anker – Wortanfang	(kein ...)
\A		Anker – Stringanfang	
\Z		Anker – String-/Zeilenende	
\z		Anker – (nur) Stringende	
\z		Anker – letzte Treffer-Position	
\n		Rückwärts-Referenz	

Bracket Expression

\	Escape
^	keines der Zeichen
...–...	Bereich von ... bis ...
[: . :]	POSIX Zeichenklasse

