Reguläre Ausdrücke in Perl

Die wichtigsten Elemente auf einen Blick

Zeichen und Zeichenklassen

a	Zeichenliteral, hier „a“, trifft nur auf das genaue Zeichen zu.
.	Any-Zeichen, trifft auf ein beliebiges Zeichen außer \n zu.
[0-9a-f]	Klasse, trifft auf ein Zeichen aus 0, 1, 2, 3, 4, 5, 6, 7, 8, 9, a, b, c, d, e, f zu.
[^chars1-3]	Trifft auf ein beliebiges Zeichen außer c, h, a, r, s, 1, 2 oder 3 zu.

Metazeichen-Äquivalenzklassen

\w	[a-zA-Z0-9_]	Ein „Wort-Zeichen“ (alphanumerische Zeichen plus _).
\d	[0-9]	Ein beliebiges numerisches Zeichen.
\s	[\t\n\r\f]	Ein beliebiges Whitespace-Zeichen.
\W	[^a-zA-Z0-9_]	Ein beliebiges Zeichen außer „Wort-Zeichen“ (Negation zu \w).
\D	[^0-9]	Ein beliebiges Zeichen außer numerische Zeichen (Negation zu \d).
\S	[^ \t\n\r\f]	Ein beliebiges Zeichen außer Whitespace-Zeichen (Negation zu \s).

Quantoren

*	Das vorhergehende Zeichen tritt beliebig oft auf (0 bis unendlich).
+	Das vorhergehende Zeichen tritt mindestens einmal auf.
?	Das vorhergehende Zeichen tritt nicht oder genau einmal auf.
{n}	Das vorhergehende Zeichen tritt genau n-mal auf.
{n,m}	Das vorhergehende Zeichen tritt mindestens n- und höchstens m-mal auf.
{n,}	Das vorhergehende Zeichen tritt mindestens n-mal auf.
<Quantor>?	Bescheidenheitsquantor, nimmt <Quantor> die Gier. Siehe auch unten.

Anker, Gruppierung und Alternation

^	Trifft auf den Beginn der Zeile zu.
$	Trifft auf das Ende der Zeile zu.
(regex)	Gruppiert „regex“ zu einem regulären Unterausdruck.
|	Alternation, logische Oder-Verknüpfung über gesamten (Unter-)Ausdruck.

Operatoren

m/ausdruck/	Match-Operator, erkennt das Auftreten von „ausdruck“ (und extrahiert)
s/ausdruck/string/	Substitutionsoperator, ersetzt „ausdruck“ durch „string“.
tr/klasse1/klasse2/	Transliterationsoperator, ersetzt Zeichen in „klasse1“ durch „klasse2“.

Operationsmodi für m/ausdruck/igsmo

i	Ignoriere Groß- und Kleinschreibung.
g	Globales Matching, setzt nach dem ersten Auftreten fort.
s	Behandle gesamte Eingabe als einen einzigen String.
m	Trenne Eingabe in Zeilen und wende Ausdruck auf jede Zeile einzeln an.
o	Kompiliere den regulären Ausdruck nur einmal. Vorsicht mit Variablen!

Operationsmodi für s/ausdruck/string/igsmeo

i	Ignoriere Groß- und Kleinschreibung.
g	Globales Matching, setzt nach dem ersten Auftreten fort.
s	Behandle gesamte Eingabe als einen einzigen String.
m	Trenne Eingabe in Zeilen und wende Ausdruck auf jede Zeile einzeln an.
e	Führe „string“ als Perlcode aus.
o	Kompiliere den regulären Ausdruck nur einmal. Vorsicht mit Variablen!

Operationsmodi für tr/klasse1/klasse2/ds

d	Lösche alle Zeichen, die gematcht aber nicht ersetzt wurden.
s	Fasse mehrfach auftretende Zeichen beim Ersetzen zusammen.

Reguläre Ausdrücke in Perl

Wichtig zu wissen

1. Reguläre Ausdrücke matchen, wenn nicht explizit anders angefordert, Zeichen und nicht Bytes. Dies ist üblicherweise nur bei Verwendung von locales und für Multibyte-Zeichensätze wie Unicode UTF-8, UTF-16, etc wichtig.
2. Möchte man innerhalb des regulären Ausdrucks die Zeichen /\[](){}.+*?^$| matchen, muss man diese mit Backslashes quoten, z.B. \/, \\, \[, \], etc.
3. Möchte man innerhalb einer Zeichenklasse die Zeichen [,], – oder ^ aufzählen, muss man diese mit Backslashes quoten, z.B. \[, \-, etc.
4. Im Einzeilen-Modus (s) trifft das Any-Zeichen „.“ auch auf \n zu.
5. Quantoren sind stets gierig, d.h. auf „babcabab“ matcht `/a.*a/` vom ersten bis zum letzten a, also „abcaba“. Um dies zu verhindern, versieht man Quantoren zusätzlich mit dem Bescheidenheitsquantor „?“, so matcht `/a.*?a/` nur vom ersten bis zum zweiten a, also „abca“.
6. Reguläre Ausdrücke verhalten sich wie double-quoted strings, daher sind dort alle Metazeichen erlaubt, die auch in ““-Strings verwendet werden können, z.B. \n, \r, etc.
7. Den Match-Operator m// kann man auch durch // abkürzen, den Transliterationsoperator tr/// kann man auch als y/// schreiben.

Praktische Anwendung in Perl

Einfacher Match

```
if($a =~ m/^\d+$/){...}
```

Führt Block nur dann aus, wenn in $a nicht leer ist und ausschließlich aus Ziffern besteht.

Match auf Laufvariable

```
print if(/^foo/i);
```

Gibt den String in der Laufvariable $_ aus, wenn dieser mit der Zeichenfolge „foo“ beginnt. Gross-/Kleinschreibung wird dabei ignoriert.

Einfache Substitution

```
$a =~ s/(Tee|Leber)wurst/Käse/g;
```

Ersetzt sämtliche Vorkommen der Zeichenfolgen „Teewurst“ und „Leberwurst“ durch „Käse“.

Extraktion von Daten per Match

```
if($a =~ /^\w+\s+(\w+)\s*(.*?)$/){
  printf(“%s\t%s“,$2,$1);
}
```

Falls der String in $a mindestens zwei durch beliebig viel Whitespace getrennte Wörter enthält, lade das zweite Wort in $1 und alles was den 2 Wörtern folgt in $2, wobei dieser Rest auch leer sein kann und eventuell anführender Whitespace nicht mit in $2 geladen wird.

Laden von Daten per Match in ein Array

```
@b = ($a =~ /([^\s]+wurst)\s?/gi);
```

Lade sämtliche Zeichenfolgen aus dem String $a, die auf „wurst“ enden, in das Array @b. Die Zeichenketten sind dabei durch beliebigen Whitespace getrennt.

Gruppierungsvariablen in Substitution verwenden

```
$a =~ s/(Fleisch|Leber)wurst/$1käse/g;
```

Ersetzt sämtliche Vorkommen der Zeichenfolgen „Fleischwurst“ und „Leberwurst“ durch „Fleischkäse“ bzw. „Leberkäse“.

Reguläre Ausdrücke in Perl

Übersetzung in deterministische endliche Automaten

^ab+c$

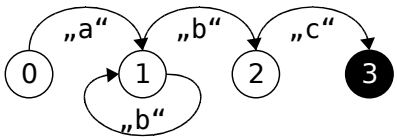

^a.*b$

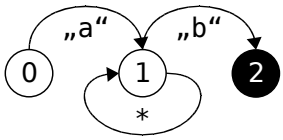

^a[bcd]e?f$

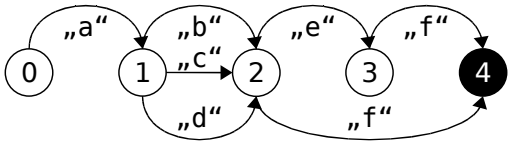

^Adam|Eva$

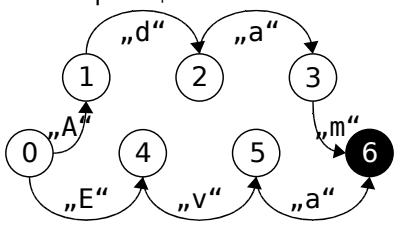

^Mein F(reu|ei)nd, der (ganz)*ho+he Baum\.$