

RA - Einführung

- **Reguläre Ausdrücke** sind eine (*primitive?*) **Programmiersprache**, die das **Aussehen von Texten** (*Zeilen, Strings*) beschreibt, indem sie festlegen
 - welche **Zeichen**
 - in welcher **Reihenfolge**
 - mit welcher **Häufigkeit**
 - unter welchen **Randbedingungen**darin vorkommen sollen.
- Mit Regulären Ausdrücken können im wesentlichen **Texte gesucht, umgeformt und gelöscht** werden.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

138

RA - Einführung

- Neben **normalen Zeichen** kennen sie noch **Metazeichen** (z.B. `.` `*` `?` `[ ]` `^` `$`), die nicht für sich selbst, sondern für **spezielle Funktionen** stehen.
- Viele **UNIX-Programme** verwenden Reguläre Ausdrücke zur Textsuche (*und Textbearbeitung*):
 - Suchprogramme: `grep`, `egrep`, `find`
 - Editoren: `ed`, `ex`, `vi`, `emacs`
 - Stream-Editor: `sed`
 - Skript- und Programmiersprachen: `awk`, `perl`, `php`, `python`, `ruby`, `tcl/tk`, `lua`, `java`, `C`, `C++`, ...
 - Server: `apache`, `sendmail`, `postfix`

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

139

RA - Einführung

- Da die Programme, die Reguläre Ausdrücke verwenden, **zu verschiedenen Zeitpunkten entstanden**, gibt es (*leider*) unterschiedliche Arten:
 - **Standard / Basic RA (BRE)**: Mindestsatz, überall gleich.
 - **Erweiterte / Extended RA (ERE)**: Erweiterungen, nicht überall vorhanden, nicht überall gleich.
 - **Perl** bietet eine **Obermenge** aller bekannten Möglichkeiten.
 - Dokumentation dazu erhält man durch:
 - `man 7 regex` (**Linux**)
 - `man -s 5 regex` (**Solaris, HP-UX**)

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

140

RA - Einführung

Achtung

- Bitte das sogenannte **"Wildcard Pattern Matching"** der Shell für **Dateinamen** nicht mit den Regulären Ausdrücken verwechseln:
 - Einfacher und weniger leistungsfähig.
 - Für **Dateinamen** gedacht, nicht für **Texte**.
 - **Metazeichen**: `*` `?` `[abc]` `[^abc]` `!abc`
 - Teilweise die gleichen Metazeichen.
 - *Aber teilweise eine völlig andere Wirkung.*
 - Suchen automatisch **vollständige** Dateinamen.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

141

RA - Einführung

Begriffe

- Reguläre Ausdrücke (*engl. Regular Expressions* = **RegExp, RE, RA**) heißen auch **Pattern (Muster)**.
- Wenn ein Regulärer Ausdruck auf einen Text **paßt**, dann **"matcht"** er diesen Text.
- **Konkatenation (Sequenz, Verkettung)** hängt Zeichen zu einer Zeichenkette aneinander `a•b•c` (*impliziter Operator in Regulären Ausdrücken*).
- Ein **Literal** ist ein Zeichen, das für sich selbst steht.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

142

RA - Besonderheiten

Achtung!

- Wird ein Kommando mit Argumenten aufgerufen, dann werden die **Metazeichen** in den Parametern **zuerst von der Shell interpretiert** und erst danach das Ergebnis an das Kommando übergeben.

Sollen also **Metazeichen** (wie sie z.B. in Regulären Ausdrücken vorkommen) an ein Kommando übergeben werden, so sind sie vor der Shell durch **Quotieren** mit `\C`, `"..."` und `'...'` zu schützen.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

143

RA - Besonderheiten

Beispiel

- Das Kommando (*allgemein* `grep MUSTER DATEI...`)
`grep abc* kap*`
wird von der Shell folgendermaßen **expandiert**, wenn die Dateien `array`, `bug`, `comp`, `kap1` und `kap2` im aktuellen Verzeichnis vorhanden sind:
`grep array bug comp kap1 kap2`
- D.h. es wird das **Muster** `array` in 4 Dateien gesucht.
- Um das **Muster** daher **Anführungszeichen** setzen:
`grep "[abc]"* kap*` oder
`grep '[abc]*' kap*`

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

144

RA - Besonderheiten

Besonderheiten von Regulären Ausdrücken

- **Jedes** Zeichen hat eine Bedeutung (*auch Leerzeichen und Tabulator*).
- Der **erste** passende Text wird gefunden (**left-most**).
`xx*` findet `abcxxxdefxxghixxxxijklmn`
– Kann in Perl auch umgekehrt werden (**right-most**).
- Der **längste** passende Text wird gefunden (**greedy**).
`xx*` findet nicht `abcxxxdef` sondern `abcxxxxdef`
– Kann in Perl auch umgekehrt werden (**non-greedy**)

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

145

RA - Besonderheiten

Besonderheiten von Regulären Ausdrücken

- Normalerweise muß nur ein **Teil des Textes** passen (*Unterschied zur **Dateinamen-Expansion** der Shell*).
– D.h. sind nicht automatisch "**verankert**" (*durch spezielle Metazeichen aber erzwingbar*).
- Trifft ein Regulärer Ausdruck **nicht am Textanfang** zu, dann wird ein Zeichen weiter **erneut probiert** bis zum Ende des Textes (*aufwendige Suche!*)
`xx*` findet `abcxxxxxxxxdef`
`^xx*` findet in `abcxxxxxxxxdef` nichts

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

146

RA - Besonderheiten

Besonderheiten von Regulären Ausdrücken

- **Zeilenvorschub** `"\n"` kann *nicht* gesucht werden (*aßer durch perl-Tricks*).
- **Quotierung** eines Metazeichens `C` ist nur durch `\C` möglich, aber *nicht* mit `"..."` oder `'...'` (z.B. `\"`).
- Einige **normale Zeichen** werden durch ein `"\"` davor zu einem Metazeichen (z.B. `\s \d \w \b`).
- **Keine vollständige Programmiersprache:**
 - "**Klammerengebirge**" *nicht* erkennbar (*kann nicht rechnen*).
 - **Negation** eines Musters oft *nicht* ausdrückbar.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

147

RA - Standard-Metazeichen

Standard-Metazeichen (*immer verfügbar*)

<code>.</code>	Ein beliebiges Zeichen (<i>aßer Zeilenende \n</i>)
<code>C*</code>	0-unendlich Wiederholungen des Zeichens <code>C</code>
<code>^</code>	Zeilenanfang (<i>nur am Anfang des Musters</i>)
<code>\$</code>	Zeilenende (<i>nur am Ende des Musters</i>)
<code>[abc]</code>	Ein Zeichen aus Zeichenmenge <code>abc</code> (<i>kein , !</i>)
<code>[a-z]</code>	Ein Zeichen aus Zeichenmenge <code>a, b, ..., z</code>
<code>[^abc]</code>	Ein Zeichen <i>nicht</i> aus der Zeichenmenge <code>abc</code> , (d.h. eines der anderen 253 ASCII-Zeichen)
<code>\C</code>	Sonderbedeutung des Metazeichens <code>C</code> aufheben

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

148

RA - Standard-Metazeichen


Beispiel

<code>made</code>	Zeile enthält die Zeichenfolge <code>made</code>
<code>.ade</code>	Zeile enthält <code>ade</code> mit mind. einem Zeichen davor
<code>xx*y</code>	Zeile enthält bel. viele <code>x</code> (<i>mind. 1x</i>) direkt vor <code>y</code>
<code>^made</code>	Zeile beginnt mit <code>made</code>
<code>made\$</code>	Zeile endet mit <code>made</code>
<code>^...\$</code>	Zeile enthält genau 3 beliebige Zeichen
<code>[A-Za-z]</code>	Zeile enthält einen Buchstaben
<code>[0-9]</code>	Zeile enthält eine Ziffer
<code>[^aeiou]</code>	Zeile enthält ein Zeichen, das kein Vokal ist

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

149




Übung 17a

- Suchen Sie in gedicht mit less, grep oder vi per Regulären Ausdrücken nach Zeilen, die:
 - Text made enthalten.
 - Text made am **Anfang** / **Ende** enthalten.
 - **Nur** aus dem Text made / MADE bestehen.
 - Text made in beliebiger **Groß/Kleinschreibung** enthalten.
 - **2x** Text made enthalten.
 - Text made am **Anfang** und am **Ende** enthalten.
 - **Genau 6 Buchstaben** umfassen.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

150



Übung 17b

- Suchen Sie in gedicht mit less, grep oder vi per Regulären Ausdrücken nach Zeilen, die:
 - Ein (oder mehr) **Leerzeichen** am Ende enthalten.
 - **Leer** sind (erst eine Definition dafür überlegen!).
 - **Nur Großbuchstaben** enthalten.
 - **Kein einziges a oder e** enthalten.
 - Analog Zeilen, die auch kein A oder E enthalten.
 - **Genau ein** o (Oh) enthalten.
 - Analog Zeilen, die **genau zwei** o enthalten.
 - Analog Zeilen, die **genau drei** o enthalten.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

151

RA - Erweiterte Metazeichen

Erweiterte Metazeichen (nicht immer verfügbar)

<code>C?</code>	0 / 1 Wiederholung des Zeichens <i>C</i> (optional)
<code>C+</code>	1-unendlich Wiederholungen des Zeichens <i>C</i>
<code>C B</code>	Linker Teil <i>C</i> oder rechter Teil <i>B</i> (Alternative)
<code>(...)</code>	Klammerung mehrerer Zeichen (<i>für</i> * + ?)
<code>C{M,N}</code>	M-N-malige Wiederholung des Zeichens <i>C</i>
<code>C{M,}</code>	Mindestens <i>M</i> Wiederholungen des Zeichens <i>C</i>
<code>C{N,}</code>	Mindestens <i>N</i> Wiederholungen des Zeichens <i>C</i>

– Der Backslash vor \{ und \} ist eventuell wegzulassen.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

152

RA - Erweiterte Metazeichen


Beispiel

<code>abc?ba</code>	Zeile mit abba oder abcba paßt
<code>x+y</code>	Zeile enthält bel. viele <i>x</i> (<i>mind. 1x</i>) direkt vor <i>y</i>
<code>(ab yz)</code>	Paßt auf Zeilen mit ab oder yz
<code>x\{5,7\}</code>	Zwischen 5 und 7 <i>x</i> hintereinander
<code>x\{5,}</code>	Mindestens 5 <i>x</i> hintereinander
<code>x\{5\}</code>	Genau 5 <i>x</i> hintereinander
<code>xxxxx</code>	Genau 5 <i>x</i> hintereinander

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

153



Übung 17c

- Suchen Sie in gedicht mit less, egrep oder vi per **erweiterten** Regulären Ausdr. nach Zeilen, die:
 - Das Wort katze oder kate enthalten.
 - Ein oder mehrere "=" direkt hintereinander enthalten.
 - **Mindestens zwei gleiche Vokale** aa, ee, ii, oo, uu **direkt hintereinander** enthalten.
 - Text made am **Anfang** oder am **Ende** enthalten.
 - **60x** das Zeichen "=" direkt hintereinander enthalten.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

154

RA - Weitere Metazeichen

Weitere Metazeichen (nicht immer verfügbar)

<code><</code>	Wortanfang (Übergang Leerzeichen → Zeichen)
<code>></code>	Wortende (Übergang Zeichen → Leerzeichen)

Metazeichen für Suchen + Ersetzen

<code>\(... \)</code>	Muster zur späteren Verwendung merken (bis zu 9 Speicher möglich, die Reihenfolge der Klammer \ (numeriert die Speicher durch)
<code>\N</code>	<i>N</i> -ten über \ (... \) gemerkten Text einfügen
<code>&</code>	Gesamter gefundener Text (<i>im Ersetzungsteil</i>)

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

155

RA - Weitere Metazeichen

Beispiel

```
\<ma      man, made, macht, aber nicht normal
ade\>     schade, made, ade, aber nicht maden
\<[Mm]ade\> Die Worte Made oder made,
          aber nicht maden und nomaden
im \ (Theater|Museum\ ) ist es schön
Speichert passendes Textstück in \1
\1        Ergibt dann Theater oder Museum
\(\<[A-Za-z]+\>\) [ ]+\1
          Zwei gleiche Worte hintereinander
```

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

156

RA - Weitere Metazeichen

• Nicht alle Programme verstehen alle Metazeichen:

```
grep, sed und vi kennen keine erweiterten Metazeichen.
vi kann zusätzlich \< \> und \[ \], \A.
sed und vi können zusätzlich \ ( \ ) und \W.
egrep und awk können alle erw. Metaz. bis auf \< \>
```

• Viele Programme unterscheiden die Groß/Kleinschreibung, einige tun dies nicht (z.B. less).

- Durch eine **Option** oder Einträge in **Konfigurationsvariablen/dateien** einstellbar.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

157

Übung 17d

- **Suchen** Sie in gedicht mit **less**, **egrep** oder **vi** **per erweiterten** Regulären Ausdr. nach Zeilen, die:
 - Mit "m" beginnende **Wörter** enthalten.
 - Mit "ade" endende **Wörter** enthalten.
 - Zwei **gleiche Wörter** hintereinander enthalten.
 - Zwei **gleiche Wörter** mit einem Wort dazwischen enthalten.
 - Zwei **gleiche Wörter** am Zeilenanfang und am Zeilenende enthalten.

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

158

RA - Suchen und Ersetzen

Suchen und Ersetzen

- Neben Textsuche kann bei manchen Werkzeugen (**vi**, **sed**) oder Skriptsprachen (**perl**) der gefundene Text auch **ersetzt** werden (*unter Verwendung des Suchergebnisses*, **substitute**, **global**).
- Dazu müssen allerdings **Suchmuster** und **Ersatztext** irgendwie getrennt werden (*meist durch "/"*):

```
s/made/MARMELADE/g
```

- Das Zeichen "/" ist dann durch "\" darzustellen

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

159

RA - Suchen und Ersetzen

Beispiel

```
s/[Uu]nix/UNIX/g    Text Unix oder unix durch
                    UNIX ersetzen
s/.*/(&)/           Klammern um Zeile setzen
s/^/ /              Zeile einrücken
s/ *$//             Leerzeichen am Zeilenende entf.
s/TAB/ /            Tabs durch 4 Leerzeichen ersetz.
s/^(...)\(...\)/\2\1/ Spalten 1-3 mit 4-5 vertauschen
```

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

160

Übung 17e

- Führen Sie mit **vi** oder **sed** folgende **Ersetzungen** auf der Datei **gedicht** durch (mit Hilfe des Befehls **[: %] s / SUCH / ERSATZ / g**):

- Das Wort "made" überall durch **MARMELADE** **ersetzen**.
 - Analog, nur **Groß/Kleinschreibung** ignorieren.
- Die **ersten 3 Zeichen** jeder Zeile **löschen**.
- Alle **Leerzeichen** entfernen.
- Alle **Vokale** entfernen.
- Jedes Wort "made" im Text **verdoppeln** (egal ob es groß oder klein geschrieben ist).

Version 3.1
7.9.2004

UNIX Aufbaukurs
© Thomas Birnhäler, OSTC GmbH

161



Übung 17f



- Führen Sie mit `vi` oder `sed` folgende **Ersetzungen** auf der Datei `columns` mit folgendem Inhalt durch:

```
0000000001111111112222222223...  
123456789012345678901234567890...
```

- Spalten 1-10 **löschen**.
- Spalten 11-20 **löschen**.
- Die letzten 5 Spalten **löschen**.
- Spalten 1-5 mit den Spalten 6-10 **vertauschen**.
- Spalten 1-5 mit den Spalten 11-15 **vertauschen**.
- Spalten 1-5 mit den letzten 5 Spalten **vertauschen**.



Übung 17g



Zusatzaufgabe

- Welche **Ersatzdarstellungen** der Metazeichen

`* ? + [ ] \ SPACE`

lassen sich mit Hilfe folgender Metazeichen angeben:

`{ } ( ) | * [ ]`

- Vergleichen Sie **Reguläre Ausdrücke** und die Muster zur **Dateinamen-Expansion** miteinander.
 - Welche Gemeinsamkeiten bzw. Unterschiede gibt es?
 - Warum sind diese Unterschiede vorhanden?