

Perl-Praxis

Komplexe Datenstrukturen

Jörn Clausen
joern@TechFak.Uni-Bielefeld.DE

Übersicht

- Hashes
- Referenzen
- komplexe Datenstrukturen

Hashes

- dritter grundlegender Datentyp von Perl
- Paare aus *keys* und *values*
- Notation: `%hash` ganzes Hash, `$hash{key}` einzelner Wert
- Schlüssel ist eindeutiger String
- Zuweisung einzelner Paare:

```
$days{jan} = 31;  
$days{feb} = 28;  
$days{mar} = 31;
```

- Verwendung:

```
$hours = ($days{jan} + $days{feb}) * 24;
```

Aufgaben

- Wieviele Schlüssel enthält das folgende Hash:

```
$hash{1}      = 1;  
$hash{1.0}   = 2;  
$hash{'1'}   = 3;  
$hash{'1.0'} = 4;
```

4
3
3
3
3

Ausgabe:

```
print $hash{1}, "\n";  
print $hash{1.0}, "\n";  
print $hash{'1'}, "\n";  
print $hash{'1.0'}, "\n";
```

- Schlüssel sind Strings:

Definition von Hashes

- Zuweisung durch Liste:

```
%days = ('jan', 31, 'feb', 28, 'mar', 31);
```

- schlecht lesbar
- schlecht erweiterbar, fehleranfällig
- besser:

```
%days = ( jan => 31,  
          feb => 28,  
          mar => 31 );
```

- => impliziert quotes um Schlüssel

Verwendung von Hashes

- Liste aller Schlüssel eines Hashes:

```
@months = keys(%days);
```

- typische Verwendung:

```
foreach $mon (keys(%days)) {  
    print "$mon has $days{$mon} days\n";  
}
```

- Reihenfolge der Schlüssel undefiniert
- lexikographisch sortiert:

```
foreach $mon (sort(keys(%days))) { ... }
```

- values liefert Liste aller Werte

Aufgaben

- Auch aus Hashes kann man *slices* extrahieren. Welcher *funny character* gehört an die Stelle des Fragezeichens?

```
?days{jan,mar}
```

- Lies die Datei `/etc/passwd` ein und extrahiere jeweils den Account-Namen und den tatsächlichen Namen der dort eingetragenen Benutzer. Speichere die Informationen in einem Hash und gib anschließend eine sortierte Liste aller Benutzer aus.

```
%users = ();
open(PW, '/etc/passwd') || die "can't open password file: ${\n}";
while ($line = <PW>) {
    # ($acc, $name) = ($line =~ /\(\w+\)(?:[~:][^:]*){3,3}:[^:]*[0,4]?
    ($acc, $name) = (split(/\:/, $line))[0,4];
    $users{$acc} = $name if $name;
}
close(PW);
foreach $acc (sort(keys(%users))) {
    print "In real life, $acc is known as $users{$acc}\n";
}
```

Einige Felder können leer sein.

```
root:x:0:0:1:Super-User:/:sbin/sh
```

- Die Passwortdatei enthält Zeilen dieser Form:
werden.
- Da der Slice eine Liste von skalaren Werten zurückliefert, muß ein "@" verwendet

Verwendung von Hashes, cont.

- alternative Methode:

```
while (($month, $days) = each(%days)) {  
    print "$month has $days days\n";  
}
```

- Zuweisung an Skalar liefert nur Schlüssel:

```
$month = each(%days);
```

- `each`, `keys`, `values` benutzen selben Zähler
- Verhalten bei Veränderung des Hashes undefiniert

Hash als Menge

- Benutze nur Schlüssel, ignoriere Werte
- 6 aus 49, ohne Zusatzzahl:

```
while (keys(%numbers) < 6) {  
    $randnum = int(rand(49)) + 1;  
    $numbers{$randnum} = 1;  
}  
print join(", ", keys(%numbers)), "\n";
```

Dieses Beispiel ließe sich auch mit einem Array lösen. Allerdings würde es potentiell mehr Speicher belegen, bis zu 50 Einträge. Außerdem ließe sich nicht so leicht überprüfen, ob bereits sechs unterschiedliche Zahlen gezogen wurden. Falls die Elemente der Menge keine Zahlen sind, kann man kein Array verwenden.

Schlüssel oder Wert?

- Arten des "Vorhandenseins":

```
%hash = ( a => 1,  
          b => 0,  
          c => undef );  
foreach $x ('a','b','c','d') {  
    print "$x is true\n"      if $hash{$x};  
    print "$x is defined\n"  if defined($hash{$x});  
    print "$x exists\n"     if exists($hash{$x});  
}
```

- Wert und Schlüssel löschen:

```
delete($hash{a});
```

```
a is true  
a is defined  
a exists  
b is defined  
b exists  
c exists
```

Aufgaben

- Zähle die Häufigkeit der Wörter in einem beliebigen Text (z.B. den beiden Theaterstücken). Gib eine sortierte Liste der Wörter aus, mit den häufigsten Wörtern oben und den seltensten Wörtern unten.
- Ändere das Programm so ab, daß die Häufigkeit der Buchstaben gezählt wird.
- Ist es möglich, einem Schlüssel eine Liste von Werten zuzuordnen? Was passiert hier:

```
%hash = ( a => (1, 2, 3),  
          b => (4, 5, 6),  
          c => (7, 8, 9) );
```

Es gelten die bisher vorgestellten Regeln: ">" ist nur eine alternative Schreibweise für ",", und Listen werden flachgeklopft. Daraus ergibt sich das gezeigte Ergebnis.

```
a => 1, 2 => 3, b => 4, 5 => 6, c => 7, 8 => 9
```

- Das Hash enthält die folgenden Paare:

```
@words = (split(//, $line)): # count letters
```

- Durch Ändern des Trennmusters kann man die Anzahl der Buchstaben bzw. Zeichen zählen:

```
while ($line = <>) {  
  chomp($line);  
  @words = (split(//, $line)): # count words  
  foreach $word (@words) {  
    $words{lc($word)}++;  
  }  
  foreach $word (sort({$words{$b} <=> $words{$a}} keys(%words))) {  
    print ">>>$word\n";  
  }  
}
```

- Anzahl der Wörter:

Referenzen

- Verweise auf Daten
- ähnlich zu Zeigern, aber einfacher
- keine Pointer-Arithmetik
- zwei Arten:
 - symbolische Referenzen
 - „echte“ Referenzen
- analog zu *symbolic links* und *hard links*
- Grundlage komplexer Datenstrukturen

Referenzen, cont.

- Referenzen definieren:

```
$scalar = 'Joe User';           $scalar_ref = \ $scalar;
@array  = (1, 2, 3, 4, 5);     $array_ref  = \@array;
%hash   = (a=>1, b=>2);       $hash_ref   = \%hash;
```

- Referenz selbst ist Skalar

- Dereferenzierung:

```
$name = $$scalar_ref;
@nums = @$array_ref;           $num = $$array_ref[2];
%rel  = %$hash_ref;           $val = %$hash_ref{a};
```

Aufgaben

- Überzeuge Dich davon, daß man eine Referenz auf ein Array bilden kann:

```
@array = (1, 2, 3, 4, 5);  
$array_ref = \@array;
```

und diese anschließend wieder dereferenzieren kann:

```
foreach $num (@$array_ref) ...
```

- Welchen Wert hat `$array_ref`?
- Was passiert, wenn Du den „falschen“ funny character zur Dereferenzierung verwendest:

```
$what = $$array_ref;  
@what = @$hash_ref;
```

abgebrochen.

Not an ARRAY reference at ...

bzw.

Not a SCALAR reference at ...

- Perl läßt sich durch einen falschen funny character nicht austricksen. Das Programm wird mit Fehlermeldungen

```
ARRAY(0x34288)
```

- Die Referenz enthält den Typ des referenzierten Objekts und eine Speicheradresse:

Referenzen, cont.

- alternative Notation:

```
$num = $array_ref->[2];  
$val = $hash_ref->{a};
```

- funktioniert auch über mehrere Ebenen:

```
$scalar_ref_ref = \ $scalar_ref;  
$name = $$$scalar_ref_ref;
```

- anonyme Referenzen:

```
$array_ref = [1, 2, 3, 4, 5];  
$hash_ref = {a=>1, b=>2};
```

komplexe Datenstrukturen

- Hash von Listen:

```
%hash = ( a => [1, 2, 3],  
          b => [4, 5, 6],  
          c => [7, 8, 9] );
```

- Zugriff auf einen Hash-Wert (eine Liste):

```
$array_ref = $hash{b};  
$num = $array_ref->[1];
```

- partielle Dereferenzierung:

```
@a = @$hash{a};    # funktioniert nicht  
@a = @{$hash{a}};
```

komplexe Datenstrukturen, cont.

- Zugriff auf ein Element in einer Liste:

```
$val = $hash{b}->[2];
```

- -> kann zwischen Klammern weggelassen werden:

```
$val = $hash{b}[2];
```

- beachte: %hash echtes Hash, daher kein -> vor erster Klammer
- und: -> nicht mit => verwechseln

LoLs, ...

- *list of lists:*

```
@atoms = ( ['Wasserstoff', 'H', 1],  
          ['Helium',      'He', 4],  
          ['Lithium',     'Li', 6] );
```

- Zugriff:

```
$atoms[1]->[2]  
$atoms[0][1]
```

... HoHs, ...

- *hash of hashes:*

```
%atoms = ( H => { name => 'Wasserstoff',  
              mass => 1 },  
          He => { name => 'Helium',  
              mass => 4 },  
          Li => { name => 'Lithium',  
              mass => 6 } );
```

- Zugriff:

```
$atoms{He}->{mass}  
$atoms{Li}{name}
```

... und Kombinationen

- *hash of lists:*

```
%atoms = ( H => ['Wasserstoff', 1],  
           He => ['Helium', 4],  
           Li => ['Lithium', 6] );
```

- *list of hashes:*

```
@atoms = ( { name => 'Wasserstoff',  
            symbol => 'H', mass => 1 },  
          { name => 'Helium',  
            symbol => 'He', mass => 4 },  
          { name => 'Lithium',  
            symbol => 'Li', mass => 6 } );
```

dynamische Datenstrukturen

- komplexe Datenstrukturen dynamisch erzeugen:

```
@names = ('Wasserstoff', 'Helium', 'Lithium');
@symbols = ('H', 'He', 'Li');
@masses = (1, 4, 6);

while (@names) {
    $name = shift(@names);
    $symbol = shift(@symbols);
    $mass = shift(@masses);
    push(@atoms, { name => $name,
                  symbol => $symbol,
                  mass => $mass } );
}
```

Visualisierung

- zur Fehlersuche hilfreich:

```
use Data::Dumper;  
%atoms = ...  
print Dumper \%atoms;
```

- use sehen wir uns später genauer an
- Ausgabe:

```
$VAR1 = {  
    'H' => [  
        'Wasserstoff',  
        1  
    ],  
    ...  
}
```

Aufgaben

- Der Befehl „ypcat group“ gibt den Inhalt der im NIS gespeicherten Gruppen-Informationen aus. Parse die Ausgabe und speichere die Informationen in den Hashes %groups und %users. Es soll folgendes möglich sein:

```
$gid      = $groups{www}{gid};
@members = @{$groups{www}{members}};
@groups  = @{$users{joern}};
```

```
while ($line = <>) {
    chomp($line);
    ($group, $gid, $users) = (split(/:/, $line))[0,2,3];
    $groups{$group}{gid} = $gid;
    @users = split(/,/, $users);
    # does not work, have to scope @users for this
    # $groups{$group}{members} = \@users;
    foreach $user (@users) {
        push(@{$groups{$group}{members}}, $user);
        push(@{$users}{$user}, $group);
    }
}
```

Die Schlüssel „gid“ und „members“ sind statisch, die anderen Schlüssel werden aus den gelesenen Daten erzeugt.

```
%groups = { 'www' => { gid => 121,
    members => [ 'anke', 'joern', ... ] },
  'sopratut' => { gid => 10230,
    members => [ 'anke', 'joern', ... ] },
  ... };
%users = { 'joern' => [ 'www', 'tex', 'xml', ... ],
  'anke' => [ 'sfb', 'www', ... ],
  ... };
```

- Es sind zwei Datenstrukturen zu erstellen: