

FUNKTIONEN UND FORMELN IN

Referent: Daniel Laskow

Betreuer: Eugen Betke

Programmierung in R

Arbeitsbereich Wissenschaftliches Rechnen

Universität Hamburg

01.06.2016

Gliederung

- Arithmetische Operatoren
- Funktionen aus der Statistik
- Eigene Funktionen
- Plotten von Ergebnissen
- Statistische Modelle
- Zusammenfassung

Arithmetische Operatoren

Operator	Beschreibung	Beispiel	Ausgabe
+ - * /	Addition, Subtraktion usw.	10/3	[1] 3.333333
** oder ^	Potenzieren	2^3	[1] 8
%%	Ganzzahlige Division	10%%4	[1] 2
%	Modulo	10%%3	[1] 1

- Die Operatoren funktionieren auch mit Vektoren, Matrizen, Arrays und Data Frames

```
>vektor=c(1,2,3,4)
>vektor^2
[1] 1 4 9 16
>m=matrix(vektor, nrow=2, byrow=TRUE)
>m*5
      [,1] [,2]
[1,]  5 10
[2,] 15 20
```

```
> y = matrix(c(1,2,3,4), nrow=2)
> y*y
      [,1] [,2]
[1,]  1  9
[2,]  4 16
> y^y
      [,1] [,2]
[1,]  1 27
[2,]  4 256
```

Funktionen aus der Statistik

<code>mean(x)</code>	Arithmetisches Mittel	$\frac{1}{n} \sum_{i=1}^n x_i = \frac{x_1 + \dots + x_n}{n}$
<code>median(x)</code>	Median	$x_1, x_2, \underline{x_3}, x_4, x_5$
<code>var(x)</code>	Varianz	$\frac{1}{n} \sum_{i=1}^n (x_i - \bar{x})^2$
<code>sd(x)</code>	Standardabweichung	$\sqrt{\text{var}(x)}$
<code>cumsum(x)</code>	Kumulierte Summe	$\sum_{x \in A} x$
<code>cumprod(x)</code>	Kumuliertes Produkt	$\prod_{x \in A} x$

Grundlegendes

- Funktionen sind vom Datentyp „function“, Syntax ist wie folgt

```
myfunction <- function(arg1, arg2, ... ){      [1]
  statements
  return(object)
}
```

- Parameter müssen nicht übergeben werden bspw. ist der folgende Aufruf gültig

```
>myfunction2 <- function(a, b){
  return(1)
}
>myfunction2()
[0] 1
```

- Parameter mit Anfangsbelegungen sind auch möglich

```
myfunction3 <- function(arg1, arg2=5, arg3=2 ){...}
```

Beispiel 1

```
fakultaet <- function(n) {  
  if(n == 0 )  
    1  
  else  
    n * fakultaet(n - 1 )  
}
```

```
> fakultaet(5)  
[1] 120  
>y <- fakultaet(5)  
>y  
[1] 120
```

Beispiel 2.1

```
wahrscheinlichkeit <- function(k,n,p) {  
  (fakultaet(n)/(fakultaet(k)*fakultaet(n-k))) * p^(k) * (1-p)^(n-k)  
}
```

- Bekannt als Wahrscheinlichkeitsfunktion einer Binomialverteilung

$$B(n, p, k) = \binom{n}{k} p^k (1 - p)^{n-k}$$

- Ähnliche Funktion in R: `dbinom(k,n,p)`
- Unterschied: k kann auch ein Vektor, Matrix usw. sein

```
> dbinom(seq(1:3), 13, 0.4)  
[1] 0.01131927 0.04527707 0.11067729
```

Beispiel 2.2

```
wahrscheinlichkeit <- function(k,n,p) {  
  x = c()  
  for(i in k)  
  {  
    x = append(x, (fakultaet(n)/(fakultaet(i)*fakultaet(n-i))) * p^(i)  
      * (1-p)^(n-i))  
  }  
  return(x)  
}
```

```
>u = c(1,2,5)  
>wahrscheinlichkeit(u,10,0.3)  
[1] 0.1210608 0.2334744 0.1029193  
>wahrscheinlichkeit(5,10,0.3)  
[1] 0.1029193
```

Beispiel 3

```
cumWahrscheinlichkeit <- function(k,n,p){  
  a=0  
  for (i in 0:k){  
    a = a + wahrscheinlichkeit(i,n,p)  
  }  
  return(a)  
}
```

- Bekannt als kumulierte Wahrscheinlichkeitsfunktion einer Binomialverteilung


$$F(n, p, k) = \sum_{i=0}^k \binom{n}{i} p^i (1-p)^{n-i}$$

- Ähnliche Funktion in R: `pbinom(k, n, p)`


Plotten von Ergebnissen

```
>k= seq(1:30)
```

```
>plot(k, wahrscheinlichkeit(k, 30, 0.3), type = "l")
```



```
>curve(x^3+4*x^2+5, from=-10, to=10)
```



Formeln

- Verwendung in statistischen Modellen
- Formelnotation

Operatoren	Beispiel	Beschreibung
+	$y \sim x + z$	Einfluss einer Variable
-	$y \sim . -x, \text{data}=d$	Variable aus der Formel löschen
:	$y \sim x : z$	Interaktion zweier Variablen hinzufügen
*	$y \sim x * z$	Direkter Einfluss und Interaktion zweier Variablen
^	$y \sim (x+z+w)^3$	Direkter Einfluss und alle möglichen Interaktionen
-1 oder +0	$y \sim x + z - 1$	Kein Interzept

- Erlaubt sind auch mathematische Operationen z.B. $y \sim \log(x) + I(z+5)$


Nutzen davon ist

- Erkennung von Variableneinfluss
- Vorhersagen zu machen

Lineares Modell Beispiel 1.1

```
>x <- rnorm(100, sd = 20)
>y <- x + rnorm(100, sd = 9)
>plot(y ~ x)
>model <- lm(y ~ x)
>abline(model)
```

- x und y sind hierbei jeweils 100 zufällige Werte



Lineares Modell Beispiel 1.2

Zusammenfassung eines linearen Modells

```
>summary(lm(y ~ x))
```

Residuals:

Min	1Q	Median	3Q	Max
-24.3014	-6.5649	0.8644	6.0194	27.8797

Coefficients:

	Estimate	Std. Error	t value	Pr(> t)
(Intercept)	0.05374	0.97350	0.055	0.956
x	0.96420	0.05117	18.843	<2e-16 ***

...

Residual standard error: 9.718 on 98 degrees of freedom

Multiple R-squared: 0.7837, Adjusted R-squared: 0.7815

F-statistic: 355.1 on 1 and 98 DF, p-value: < 2.2e-16

Vorhersage eines Werts

```
>wert = data.frame(x=120)
```

```
>predict(model, wert)
```


1

115.7574

Trendlinie folgt also der Funktion $y = 0,9642x + 0,05374$

Lineares Modell Beispiel 2

```
>a = read.csv(file.choose(), header=TRUE, sep=",")
>model = lm(a$cons ~ a$temp)
>plot(a$cons ~ a$temp)
>abline(model)
>summary(model)
...
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept) 0.2068621  0.0247002   8.375 4.13e-09 ***
a$temp      0.0031074  0.0004779   6.502 4.79e-07 ***
...
Residual standard error: 0.04226 on 28 degrees of freedom
Multiple R-squared:  0.6016,    Adjusted R-squared:  0.5874
F-statistic: 42.28 on 1 and 28 DF,  p-value: 4.789e-07
```



Trendlinie folgt also der Funktion $a\$cons = 0.0031074 \cdot a\$temp + 0,2068621$

Lineares Modell Beispiel 3

```
>a = read.csv(file.choose(), header=TRUE, sep=",")
>model = lm(a$cons ~ a$temp + a$price + a$income)
>#plot(a$cons~a$temp+a$price+a$income)
>summary(model)
...
Coefficients:
              Estimate Std. Error t value Pr(>|t|)
(Intercept)  0.1973151  0.2702162   0.730  0.47179
a$temp       0.0034584  0.0004455  7.762  3.1e-08 ***
a$price     -1.0444140  0.8343573  -1.252  0.22180
a$income     0.0033078  0.0011714   2.824  0.00899 **
...
Residual standard error: 0.03683 on 26 degrees of freedom
Multiple R-squared:  0.719,    Adjusted R-squared:  0.6866
F-statistic: 22.17 on 3 and 26 DF, p-value: 2.451e-07
```

Vergleich von statistischen Modellen

```
> model1<-lm(a$cons ~ a$temp + a$price)
> model2<-lm(a$cons ~ a$temp)
> anova(model1, model2)
```

Analysis of Variance Table

Model 1: a\$cons ~ a\$temp + a\$price

Model 2: a\$cons ~ a\$temp

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	27	0.046090				
2	28	0.050009	-1	-0.0039194	2.296	0.1413

```
> model3<-lm(a$cons ~ a$temp)
> model4<-lm(a$cons ~ a$temp + a$income)
> anova(model4, model3)
```

Analysis of Variance Table

Model 1: a\$cons ~ a\$temp + a\$income

Model 2: a\$cons ~ a\$temp

	Res.Df	RSS	Df	Sum of Sq	F	Pr(>F)
1	27	0.037399				
2	28	0.050009	-1	-0.012611	9.1044	0.005506

- Der P-Wert gibt die Signifikanz des Unterschiedes an, je kleiner er ist, desto höher ist die Signifikanz des Unterschiedes
- Im ersten Beispiel ist der Unterschied nicht signifikant, da der P-Wert mit $0.1413 > 0.05$ ist
- Im zweiten Beispiel ist der Unterschied signifikant, da der P-Wert mit $0.005506 < 0.05$ ist

Zusammenfassung

- Mathematische Operationen sind flexibel
- Viele wichtige Funktionen aus der Statistik sind bereits in R implementiert
- Funktionen sind vom Datentyp „function“
- Der zuletzt berechnete Ausdruck einer Funktion wird zurückgegeben oder explizit mit `return(x)`
- Die Parameter einer Funktion haben keinen vorbestimmten Typ
- Mit Formeln kann man statistische Modelle beschreiben
- Mit `lm(Formel)` macht man Lineare Modelle, mit `summary(model)` macht man Zusammenfassungen, mit `abline(model)` macht man Trendlinien
- Vergleiche von Modellen macht man mit `anova(model1, model2)`, der P-Wert gibt die Signifikanz des Unterschiedes an

Literatur

- [1] Robert I. Kabacoff, "User-written Functions", <http://www.statmethods.net/management/userfunctions.html>, 23.05.2016
- Richard Hahn, „Statistical Formula Notation in R“ , <http://faculty.chicagobooth.edu/richard.hahn/teaching/formulanotation.pdf>, 18.05.2016
- „Using R for Linear Regression“, <http://www.montefiore.ulg.ac.be/~kvansteen/GBIO0009-1/ac20092010/Class8/Using%20R%20for%20linear%20regression.pdf>, 18.05.2016
- Jim Frost, „Regression Analysis“, <http://blog.minitab.com/blog/adventures-in-statistics/regression-analysis-how-do-i-interpret-r-squared-and-assess-the-goodness-of-fit>, 18.05.2016
- Vincent Arel-Bundock, „Datasets“, <https://vincentarelbundock.github.io/Rdatasets/datasets.html>, 18.05.2016
- „Formula“, <https://stat.ethz.ch/R-manual/R-devel/library/stats/html/formula.html>, 18.05.2016
- „Modeling in R“, http://www.springer.com/cda/content/document/cda_downloaddocument/9781461444749-c1.pdf?SGWID=0-0-45-1344211-p174513603, 18.05.2016
- Steven Buechler, „Statistical Models in R“, <http://www3.nd.edu/~steve/Rcourse/Lecture8v1.pdf>, 18.05.2016
- „Lineares Modell“, https://de.wikipedia.org/wiki/Lineares_Modell, 18.05.2016