Programmieren in Anwendungen

Annette Bieniusa

Technische Universität Kaiserslautern

bieniusa@cs.uni-kl.de

12.06.2014

Überblick

Fallstudie 2: UFO-Sichtungen

Aus: Drew Conway, John Myles White: Machine Learning for Hackers - Case Studies and Algorithms to Get You Started. O'Reilly Media, Februar 2012.

Daten zu UFO-Sichtungen

- Rund 60.000 Datensätze gesammelt durch das National UFO Reporting Center in den letzten Jahrhunderten
- Daten zum Download:

  `https://github.com/johnmyleswhite/ML_for_Hackers/tree/master/01-Introduction`
- Aufbau des Datensatzes

DateOccured	Zeitpunkt der Beobachtung
DateReported	Zeitpunkt der Meldung
Location	Ort
ShortDescription	Kurzbeschreibung
Duration	Dauer
LongDescription	Ausführliche Beschreibung

Import des Datensatzes

- Einträge sind durch Tabulator voneinander getrennt (.tsv - Datei)
- Datentypen (Zahlen, Strings, Faktoren, etc.) werden heuristisch ermittelt
- Hier ist die Umwandlung von Strings in Faktoren unerwünscht
- Leerer String soll durch NAërsetzt werden

```
ufo <- read.delim(file="ufo_awesome.tsv",sep="\t",
       na.strings="", header=FALSE,
       stringsAsFactors=FALSE)
```

Struktur von Datensätzen

- Mit der Funktion `str()` erhält man einen Überblick zur Struktur eines Datensatzes.

```
> str(ufo)
'data.frame': 61870 obs. of  6 variables:
 $ V1: chr  "19951009" "19951010" "19950101" "19950510" ...
 $ V2: chr  "19951009" "19951011" "19950103" "19950510" ...
 $ V3: chr  " Iowa City, IA" " Milwaukee, WI" " Shelton, WA" ...
 $ V4: chr  NA NA NA NA ...
 $ V5: chr  NA "2 min." NA "2 min." ...
 $ V6: chr  "Man repts. witnessing flash ...
```

Schritt 1: Benennung der Spalten

- Benannte Spalten vereinfachen den Umgang mit den Daten, da weniger Verwechslungen und Vertippen möglich

```
names(ufo) <- c("DateOccurred","DateReported",
"Location","ShortDescr", "Duration","LongDescr")
```

Schritt 2: Datumskonvertierung

- Datumsformat scheint "YYYYMMDD" (year-month-day)

```
> ufo$DateOccurred <- as.Date(ufo$DateOccurred,
                              format="%Y%m%d")
Fehler in strptime(x, format, tz = "GMT") :
  Eingabe-Zeichenkette ist zu lang
```

- Offensichtlich haben einige Eingaben das falsche Format!
- Ausweg: Ausfiltern der fehlerhaften Datensätze oder Ausbessern von Hand mit `fix()` (häufig nicht möglich)

```
good.rows <- ifelse(nchar(ufo$DateOccurred) == 8 &
                    nchar(ufo$DateReported) == 8,
                    TRUE,FALSE)
ufo_clean <- ufo[good.row,]
```

- Dann Datumseinträge `DateOccurred` und `DateReported` konvertieren mit `as.Date()`, wie oben

Filtern von Datensätzen

- Einfache Filterkriterien

$==$	gleich
$!=$	ungleich
$>, >=$	größer (gleich)
$<, <=$	kleiner (gleich)

- Bei kategoriellen Daten durch `%in%`

```
haar %in% c("blond","braun")
```

- Kombination von Filterkriterien

&	Und
|	Oder
!	Negation

Schritt 3: Bearbeitung der Ortsinformation

- Ortsformat ist scheinbar “Stadt, Staat”

```
get.location <- function(l) {
  split.location <- tryCatch(strsplit(l, ",")[[1]],
                             error = function(e) return(c(NA, NA)))
  clean.location <- gsub("^ ","",split.location)
  if (length(clean.location) > 2) {
    return(c(NA,NA))
  } else {
    return(clean.location)
  }
}
```

- `strsplit(x,",")`
  trennt die Zeichenkette bei Komma, das folgende [[1]] unquoted den Ergebnisvektor
- `gsub("^ ","",x)`
  entfernt alle Leerzeichen am Anfang der Zeichenkette x

Schritt 3: Bearbeitung der Ortsinformation

- Erstellen einer Matrix mit der Stadt-Staat-Information durch Anwenden von get.location mittels `lapply()` und Zusammenfassen der resultierenden Liste durch do.call() und `rbind()`
- Hinzufügen dieser Matrix zum Datensatz

```
city.state <- lapply(ufo$Location, get.location)
location.matrix <- do.call(rbind, city.state)
ufo <- transform(ufo,
                 USCity = location.matrix[, 1],
                 USState = location.matrix[, 2],
                 stringsAsFactors = FALSE)
```

Schritt 4: Filtern nach US-Staaten

- `state.abb` ist ein Vektor mit Abkürzungen der US-Staatennamen
- `match()` liefert den Index in `state.abb`, der die passende Abkürzung enthält
- Falls keine passt, wird `NA` gesetzt
- Schließlich wird nach den Einträgen mit korrekten US-Staaten gefiltert

```
ufo$USState <- state.abb[match(ufo$USState, state.abb)]
ufo.us <- subset(ufo, !is.na(USState))
```

Ergebnis: Bearbeiteter Datensatz

```
> head(ufo.us)
  DateOccurred DateReported              Location ShortDescription Duration
1   1995-10-09   1995-10-09         Iowa City, IA              <NA>     <NA>
2   1995-10-10   1995-10-11         Milwaukee, WI              <NA>   2 min.
3   1995-01-01   1995-01-03           Shelton, WA              <NA>     <NA>
4   1995-05-10   1995-05-10          Columbia, MO              <NA>   2 min.
5   1995-06-11   1995-06-14           Seattle, WA              <NA>     <NA>
6   1995-10-25   1995-10-24  Brunswick County, ND              <NA>  30
min.

                                                                LongDescription
1 Man repts. witnessing &quot;flash, followed by a classic UFO, ...
2 Man  on Hwy 43 SW of Milwaukee sees large, bright blue light ...
3 Telephoned Report:CA woman visiting daughter witness discs and ...
4 Man repts. son&apos;s bizarre sighting of small humanoid creature ...
5 Anonymous caller repts. sighting 4 ufo&apos;s in NNE sky, 45 deg. ...
6 Sheriff&apos;s office calls to rept. that deputy, 20 mi. SSE of ...

            USCity USState
1        Iowa City       IA
2        Milwaukee       WI
3          Shelton       WA
4         Columbia       MO
5          Seattle       WA
6 Brunswick County       ND
```

Fortsetzung folgt...

Programmieren in R (Teil 2)

Eigenheiten von R

- Variablen müssen nicht deklariert werden, sondern werden durch die erste Zuweisung verwendbar
- Indizierung startet mit 1, nicht mit 0
- Zuweisung zu einem nicht existenten Index eines Vektors erweitert den Vektor (ähnlich bei Matrix, Listen, ...)

```
> z <- 1:5
> z[7] <- 9
> z
[1]  1  2  3  4  5 NA  9
```

- Kommentare beginnen mit #

Typische Fehlerquellen

- Verwechslung von Groß/Kleinschreibung: `length()` und `Length()` sind verschiedene Funktionen!
- Verwenden von Funktionen ohne das notwendige Package geladen zu haben
- Vergessen von Anführungszeichen beim Laden, Installieren etc. von Packages
- Jeder Funktionsaufruf braucht Klammern, auch ohne Parameter!

Factors

- Datenwerte entstammen oft Kategorien, diese können eine Ordnung implizieren
- Beispiel: Geschlecht (m/w/sonstiges) [ungeordnet], Schulnoten (sehr gut, gut, befriedigend, ausreichend, mangelhaft, ungenügend) [geordnet]
- In R werden diese Datenwerte `factors` genannt
- Eine Ordnung kann mit spezifiziert werden, standardmässig wird die alphabetische Ordnung der Kategorien genommen
- `str()` gibt einen Überblick über die Struktur
- Intern werden die Factor-Datenwerte als Integer gespeichert, die den einzelnen Werten zugeordnet sind
  $\rightarrow$ wesentlich effizienter als Strings

Factors mit Ordnung

```
> noten <- c("sehr gut", "mangelhaft","gut","gut")
> noten <- factor(noten, order = TRUE)
> noten
[1] sehr gut   mangelhaft gut
Levels: gut < mangelhaft < sehr gut
> noten <- factor(noten, order = TRUE,
                  levels=c("sehr gut","gut","mangelhaft"))
> noten
[1] sehr gut   mangelhaft gut
Levels: sehr gut < gut < mangelhaft
> str(noten)
 Ord.factor w/ 3 levels "sehr gut"<"gut"<..: 1 3 2
```

Umkodieren von Variablen

- Beispiel: Gegeben ein Datensatz mit den Teilnehmern einer Veranstaltung
- Spalte `teilnehmer$alter` bezeichnet das Alter
- Gewünschte neue Variable im Datensatz:
  Welcher der Teilnehmer ist minderjährig?

```
status <- (teilnehmer$alter < 18) * 1
          + (teilnehmer$alter >= 18) * 2
```

- Umwandlung von numerischem Wert in Faktor

```
status_factor <- factor(status,
    labels = c("minderjaehrig","volljaehrig"))
```

- Häufigkeit der einzelnen Faktoren/Kategorien

```
table(status_factor)
```

Datenvisualisierung mit ggplot2

Was ist ggplot2?

- ggplot2 ist ein R-Package für Datenvisualisierung
- Unkomplizierte, intuitive Erstellung von modernen Grafiken
- ggplot2 basiert auf der "grammar of graphics"
- Modifikation der Plotkomponenten auf hoher Abstraktionsebene durch Layern (Schichten)

- Installation: `install.packages(‘‘ggplot2’’)`
- Einbindung in den Workspace: `library(ggplot2)`

Anwendungsbeispiel: Datensatz diamonds

- Standardmäßig im ggplot2-Package enthalten
- Beinhaltet Eigenschaften zu fast 54.000 Diamanten

```
> head(diamonds)
  carat       cut color clarity depth table price  ...
1  0.23     Ideal     E     SI2  61.5    55   326  ...
2  0.21   Premium     E     SI1  59.8    61   326  ...
3  0.23      Good     E     VS1  56.9    65   327  ...
4  0.29   Premium     I     VS2  62.4    58   334  ...
5  0.31      Good     J     SI2  63.3    58   335  ...
6  0.24 Very Good     J    VVS2  62.8    57   336  ...
```

Eigenschaften:

- carat: Gewicht des Diamanten
- cut: Qualität des Schliffs
- color: Farbe (von J bis D) etc. (siehe `help(diamonds)`)

Struktur von diamonds

```
> str(diamonds)
'data.frame': 53940 obs. of  10 variables:
 $ carat  : num  0.23 0.21 0.23 0.29 0.31 0.24 0.24 0.26 0.22...
 $ cut    : Ord.factor w/ 5 levels "Fair"<"Good"<..: 5 4 2 4 ...
 $ color  : Ord.factor w/ 7 levels "D"<"E"<"F"<"G"<..: 2 2 2 ...
 $ clarity: Ord.factor w/ 8 levels "I1"<"SI2"<"SI1"<..: 2 3 5...
 $ depth  : num  61.5 59.8 56.9 62.4 63.3 62.8 62.3 61.9 65.1...
 $ table  : num  55 61 65 58 58 57 57 55 61 61 ...
 $ price  : int  326 326 327 334 335 336 336 337 337 338 ...
 $ x      : num  3.95 3.89 4.05 4.2 4.34 3.94 3.95 4.07 3.87 ...
 $ y      : num  3.98 3.84 4.07 4.23 4.35 3.96 3.98 4.11 3.78...
 $ z      : num  2.43 2.31 2.31 2.63 2.75 2.48 2.47 2.53 2.49...
```

Datenvisualisierung mit ggplot2

qplot - Quick plot

qplot(data, x, y = NULL, ..., facets = NULL,
margins = FALSE, geom = "auto", stat = list(NULL),
position = list(NULL), xlim = c(NA, NA),
ylim = c(NA, NA), log = "", main = NULL,
xlab = deparse(substitute(x)),
ylab = deparse(substitute(y)), asp = NA)

Wichtigste Parameter in rot!

- data: Datensatz mit `x`,`y`,... Spalten
- geom: siehe nächste Seite
- `x`lim, ylim: Achsenabschnitte
- `x`lab, ylab: Achsenbeschriftung
- `m`ain: Überschrift

Einfache Geometrien

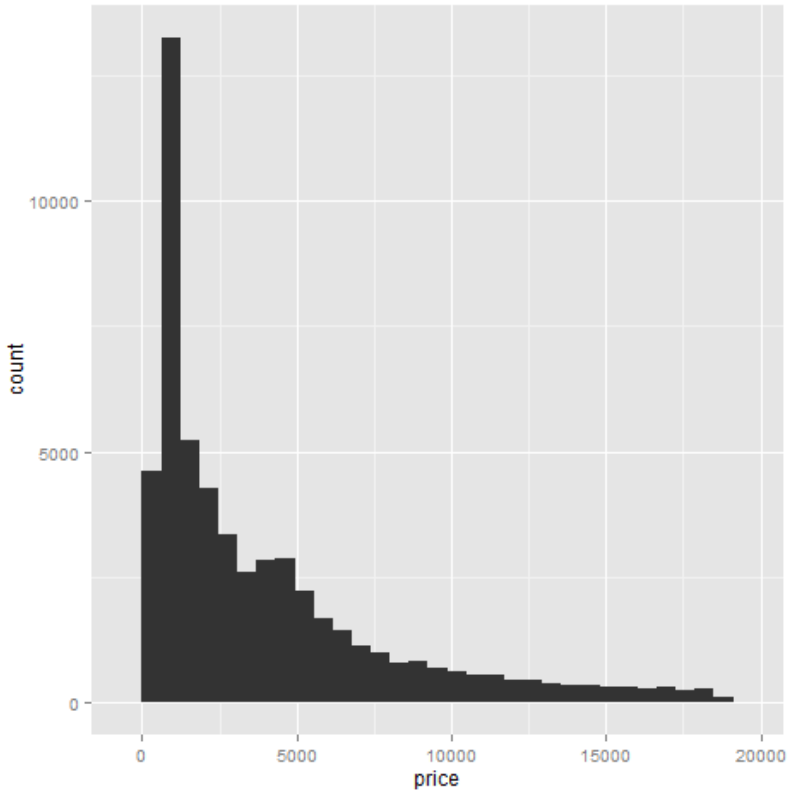

(a) qplot(data=diamonds,price)

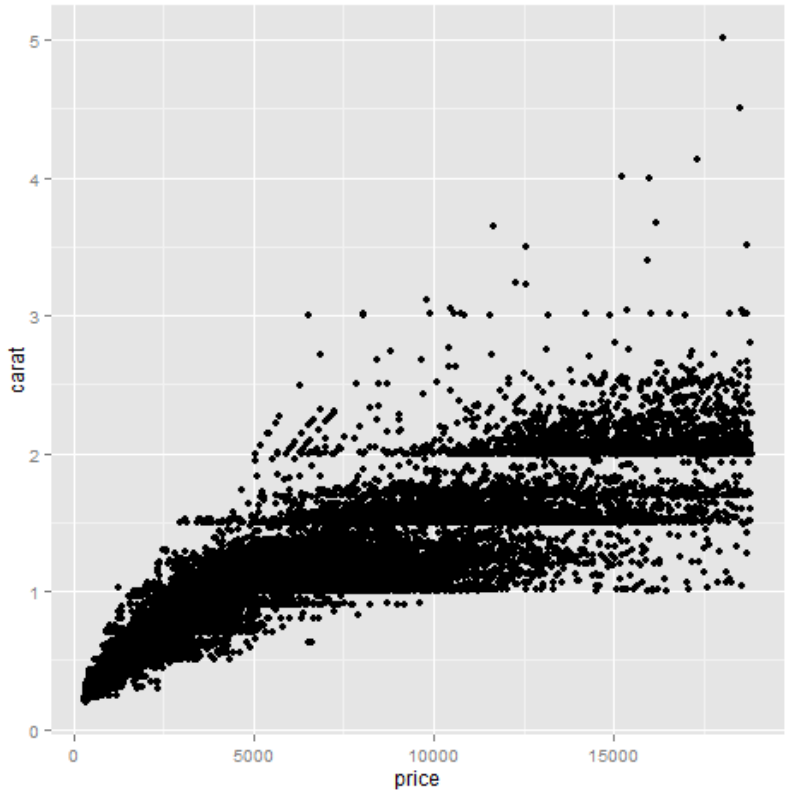

(b) qplot(data=diamonds,price,carat)

Standardwerte für Geometrien

Eindimensionale Geometrien (falls nur x spezifiert ist)

- geom = "histogram" Histogramm (Standard), `binwidth = ...` gibt die Größe des Bins an
- geom = "freqpoly" und geom="density" Frequenz- und Dichteplot

Zweidimensionale Geometrien (falls x und y spezifiert sind)

- geom = "point" Scatterplot (Standard)
- geom = "smooth" Glättung
- geom = "boxplot" Box-and-whisker Plot, liefert Informationen zur Verteilung der Daten
- geom="path" und geom="line" Verbindungslinien zwischen den Datenpunkten, oft genutzt für zeitliche Entwicklungen

Plot mit Beschriftung

```
qplot(data=diamonds, price, carat, main="ggPlot2!",
      xlab="Preis", ylab="Karat")
```

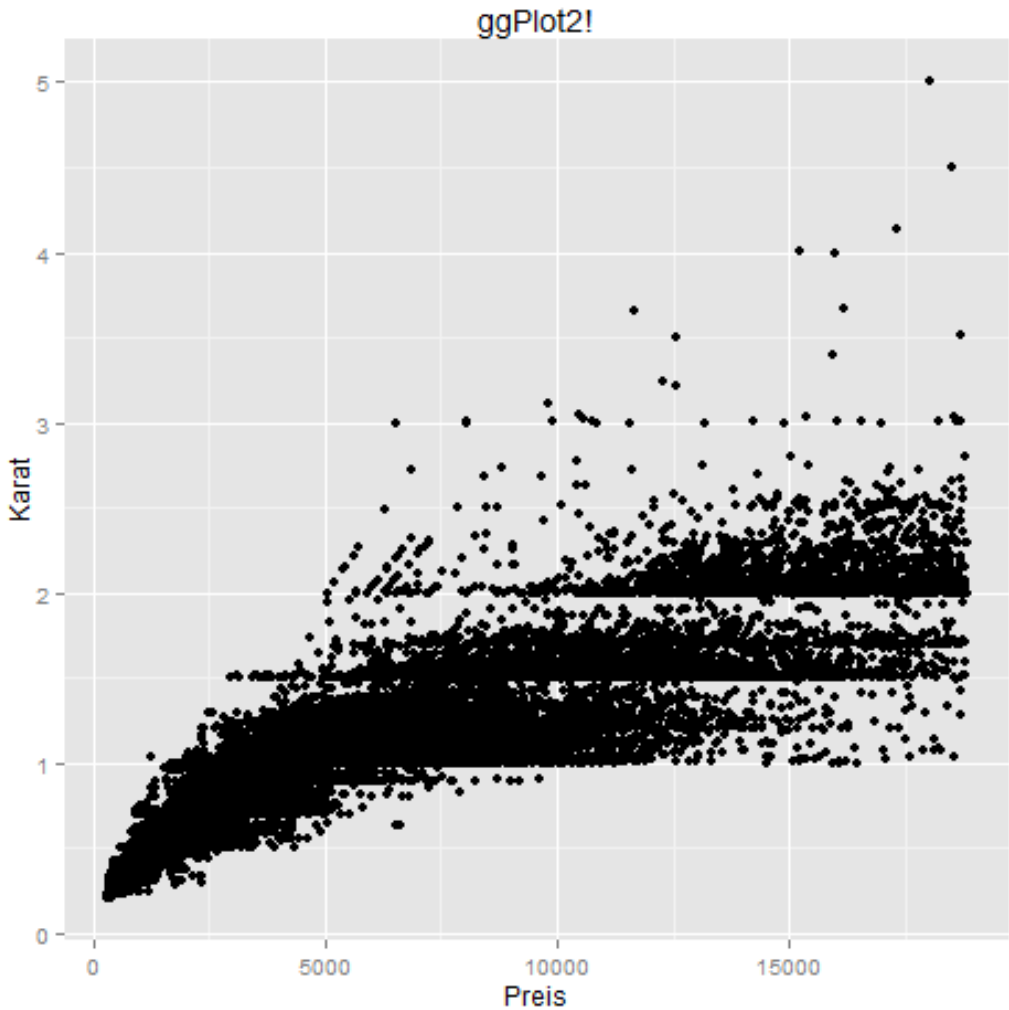

Weitere Aspekte: Farbe

```
qplot(data=diamonds, price, carat, color=color)
```

Weitere Aspekte: Alpha-Wert

```
qplot(data=diamonds, price, carat, color=color,
      alpha=cut)
```

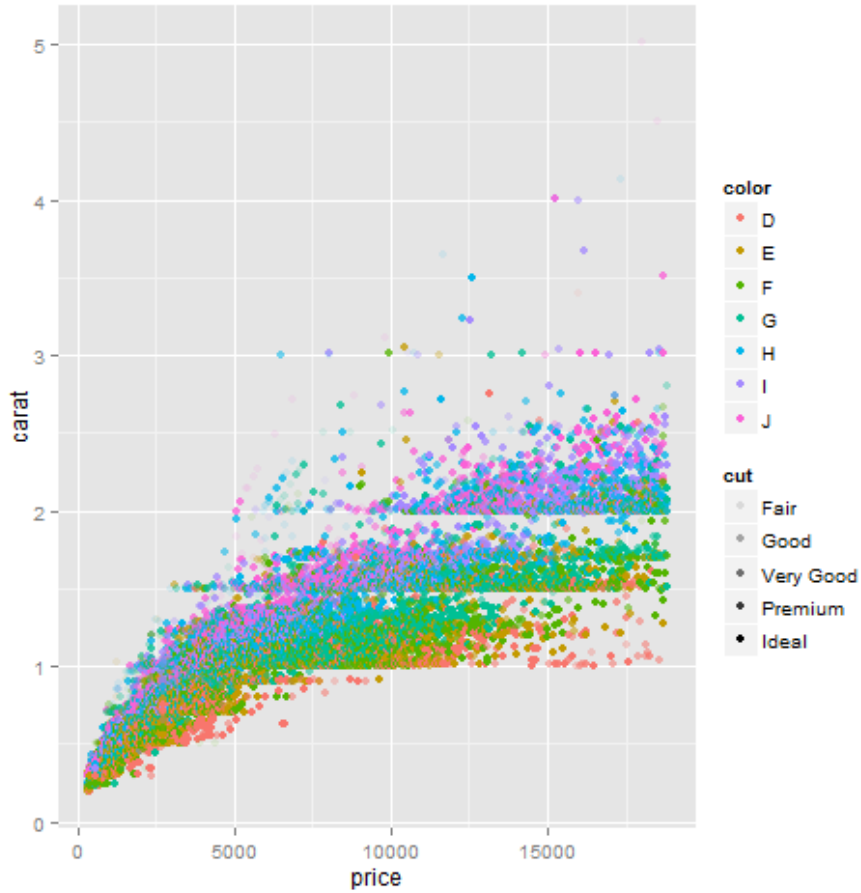

Weitere Information: `http://ggplot2.org/book/qplot.pdf`

Datenvisualisierung mit ggplot2

ggplot - Grafik für Fortgeschrittene

- Grundanweisung: ggplot(data, aes)
- Die Äesthetik definiert, wie Datenvariablen auf visuelle Eigenschaften der benutzten Geometrie übertragen werden: aes(x, y, color, alpha, size,...)
- Eine Äesthetik ist für alle folgenden Layer gültig
- Inkrementelle Ploterstellung durch Addition von Anweisungen mithilfe von +

Histogramm

```
myPlot <- ggplot(data=diamonds, aes(x=price))
myPlot <- myPlot + geom_bar()
```

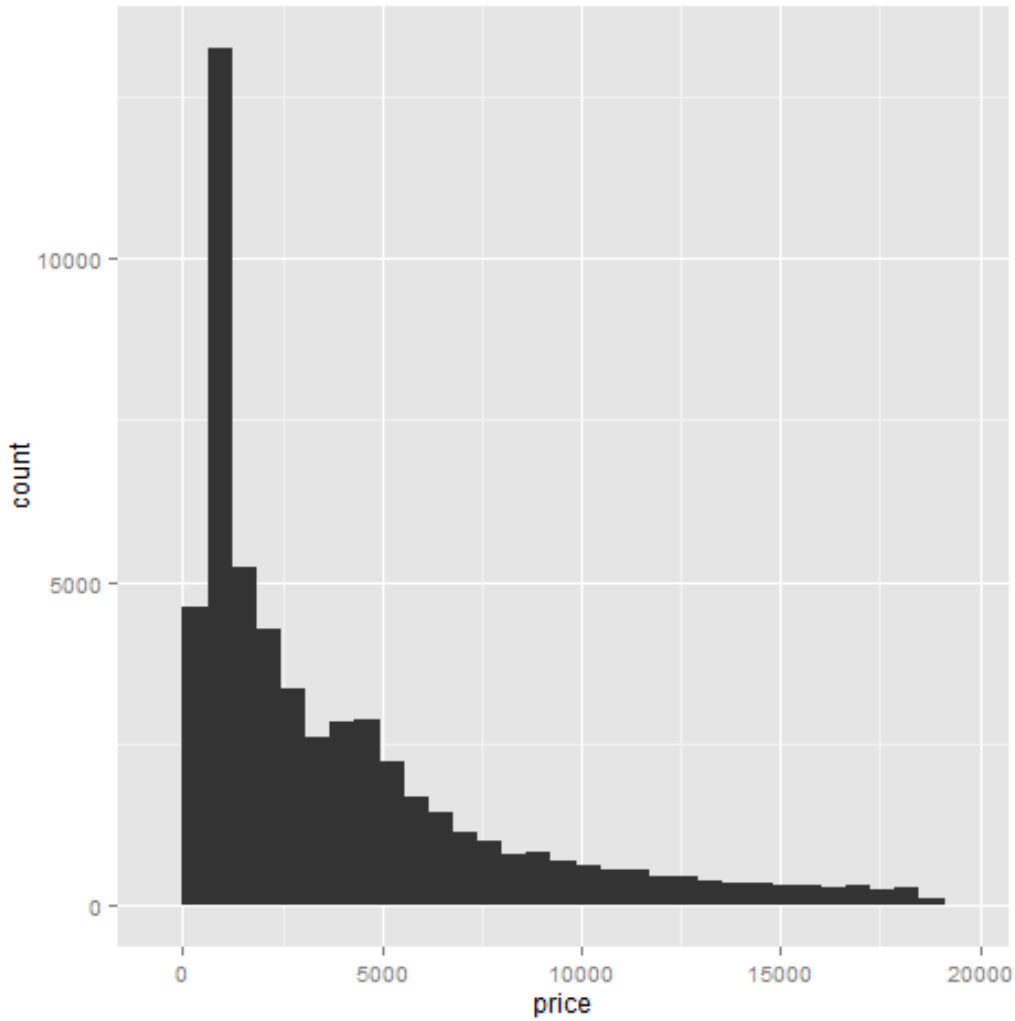

Scatterplot

```
myPlot <- ggplot(data=diamonds, aes(x=price, y=carat))
myPlot + geom_point() + ggtitle("ggPlot2")
       + xlab("Preis") + ylab("Karat")
```

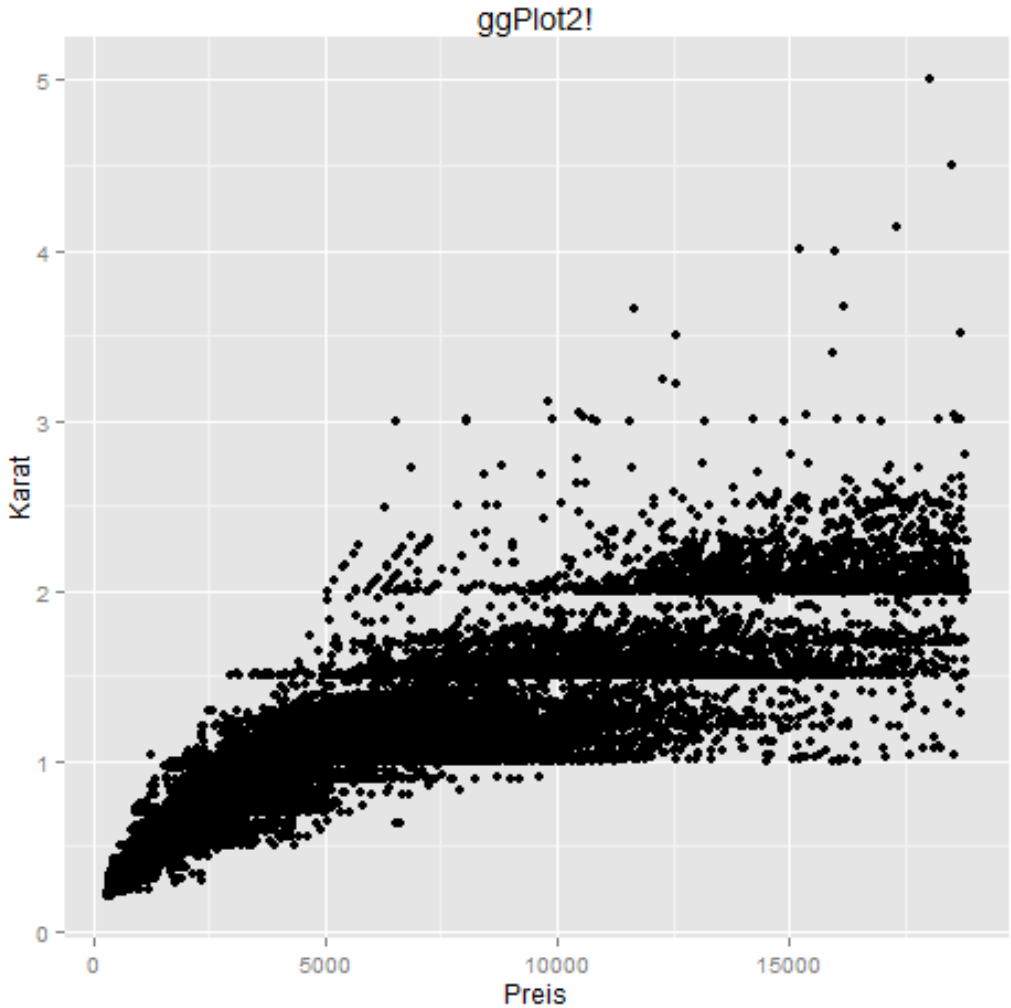

Scatterplot mit Farbe

```
myPlot + geom_point(aes(color=color))
```

Scatterplot mit Farbe und Alphawert

```
myPlot + geom_point(aes(color=color, alpha=cut))
```

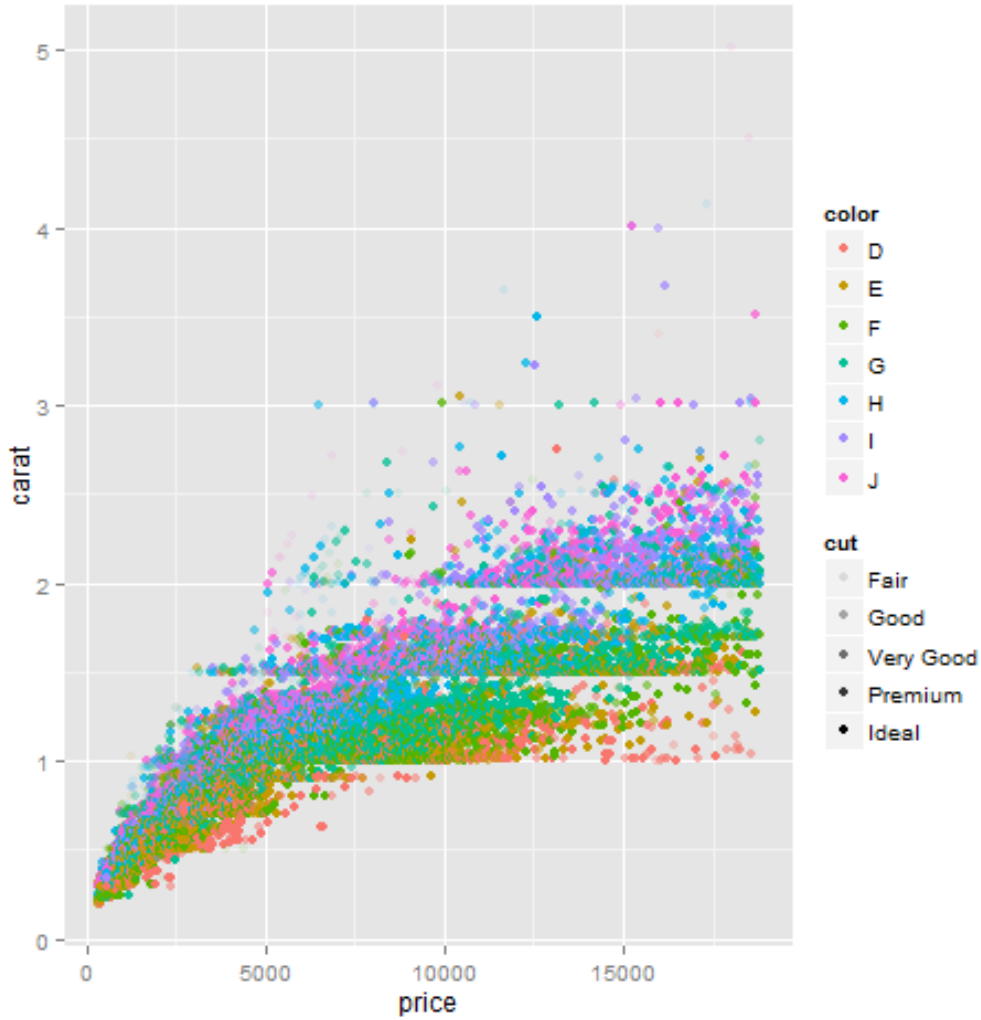

Wechsel der Koordinaten

```
myPlot + geom_point(aes(color=color, alpha=cut))
       + coord_flip()
```

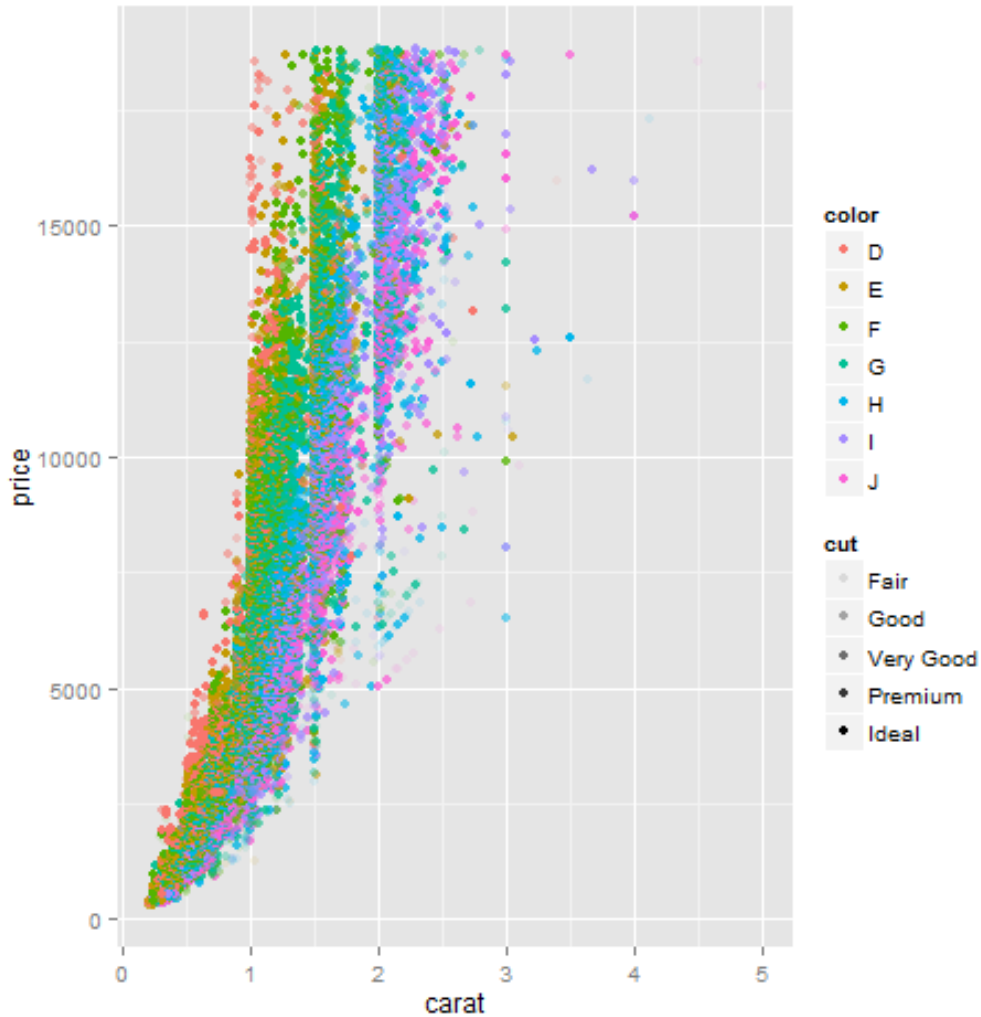

Einschub - Facetten

Facetten dienen der Aufsplitterung von Diagrammen in die einzelnen Kategorien eines Parameters:

+ **facet_grid(horizontal ~ vertical)**
  - Gruppiere in der Horizontalen nach den Werten von cut
    `facet_grid(cut ~ .)`
  - Gruppiere in der Vertikalen nach den Werten von cut
    `facet_grid(. ~ cut)`
+ **facet_wrap(~ vertical)**
  - Automatische Platzierung der Facetten neben- und untereinander
  - Parameter *ncol=x* begrenzt das Wrapping horizontal

Aufteilung mit Facette cut

```
myPlot + geom_point(aes(color=color, alpha=cut))
       + coord_flip() + facet_wrap(~ cut)
```

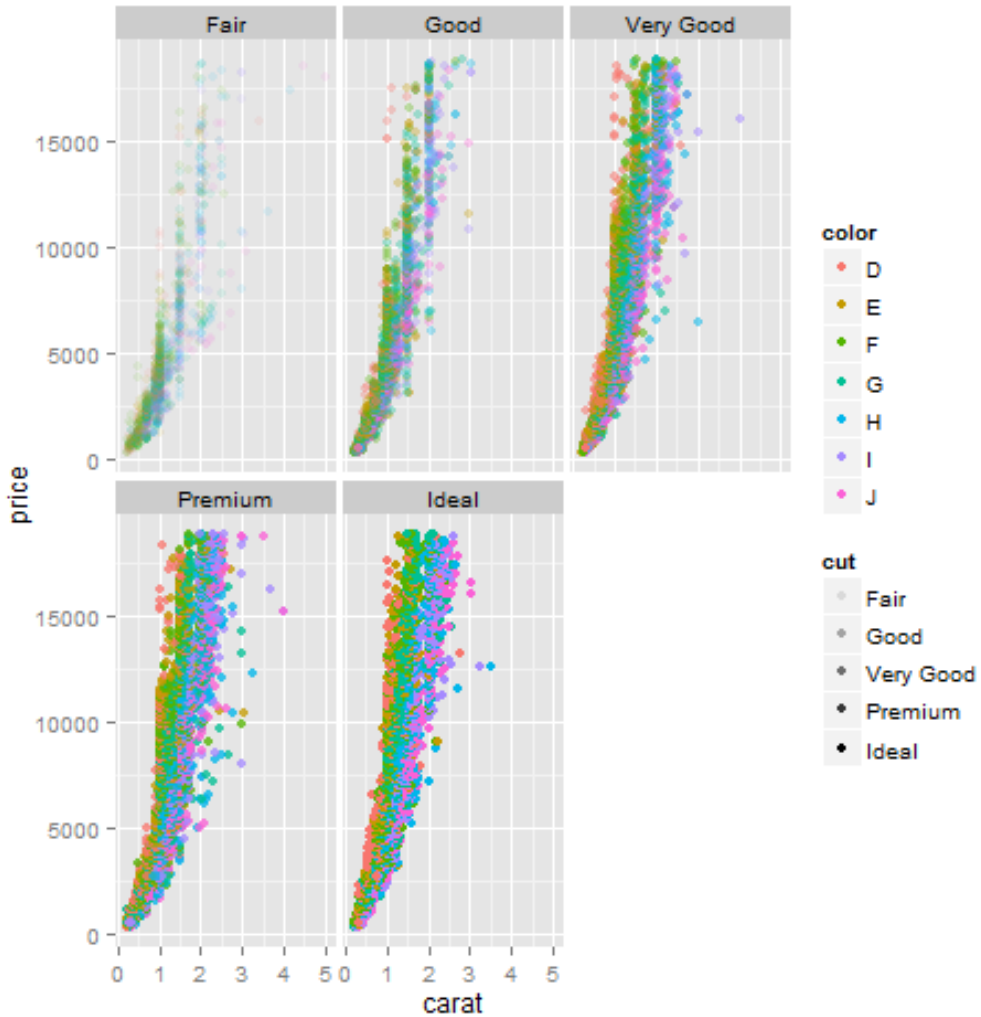

Glättung zur Visualisierung von Trends

```
myPlot + geom_smooth(aes(color=color, alpha=cut))
       + coord_flip() + facet_wrap(~ cut)
```

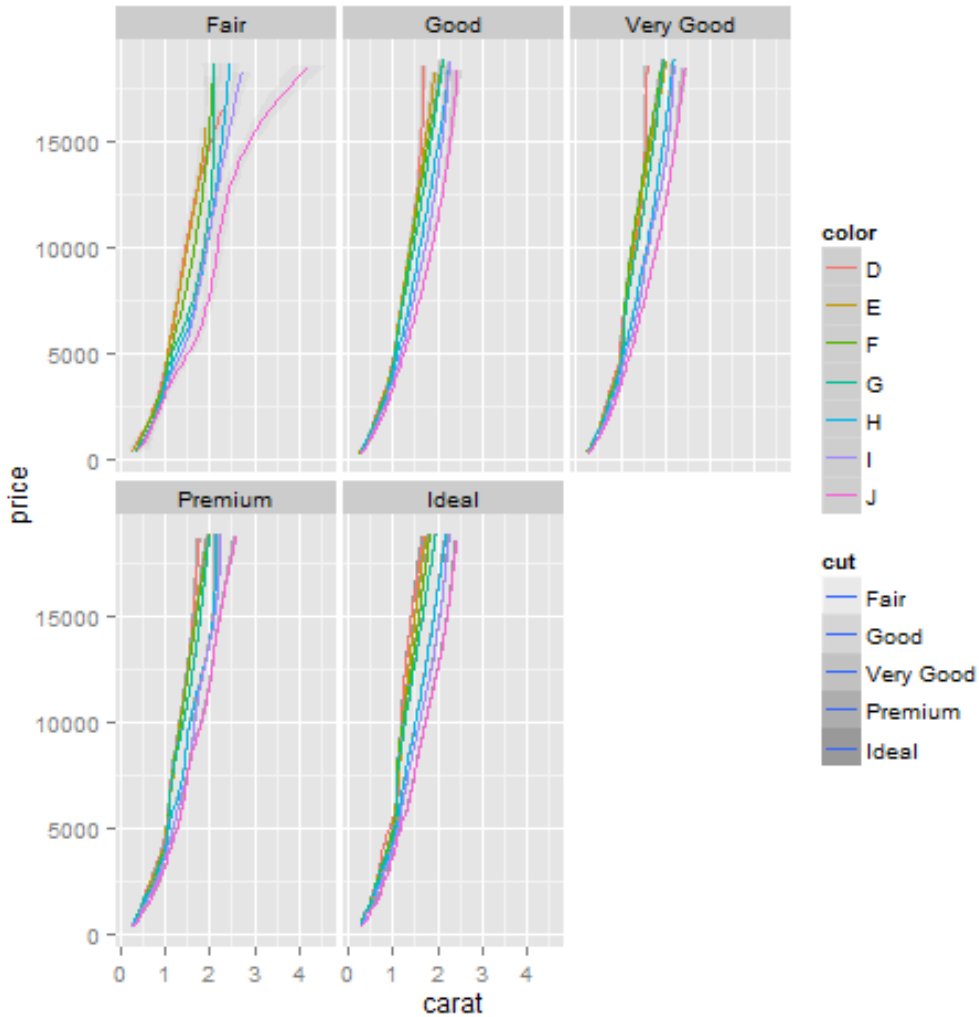

Säulendiagramm

```
myPlot2 <- ggplot(data=diamonds, aes(x=clarity))

+ geom_bar(
    data=w, #Definition eigener Data frame
    width=x, #Einstellung der Breite
    aes(fill=y), #Füllfarbe der Balken abhängig von y
    position="z" #Anordnung der gefärbten Balken
    )
```

Beispiel: Säulendiagramm

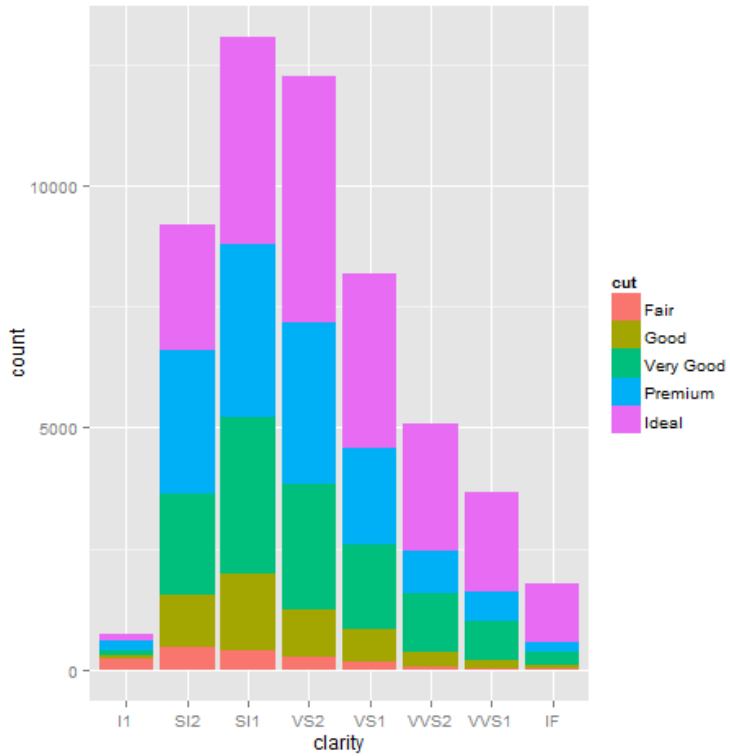

(c) aes(fill=cut), position="stack"

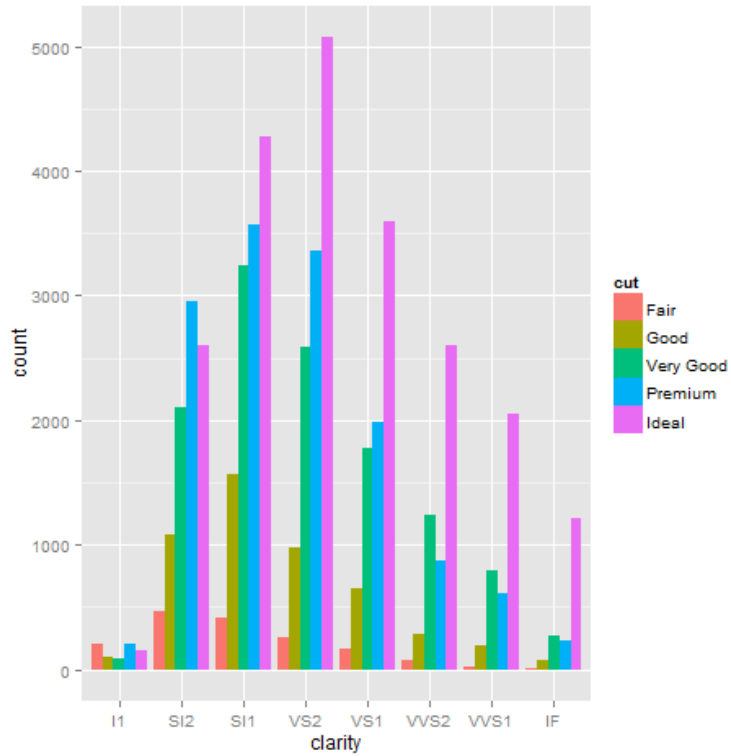

(d) aes(fill=cut), position="dodge"

Kreisdiagramme als spezielle Säulendiagramme

+ geom_bar() + coord_polar(

theta="x" #welche Achse bildet den Kreisumfang, "x"/"y"

)

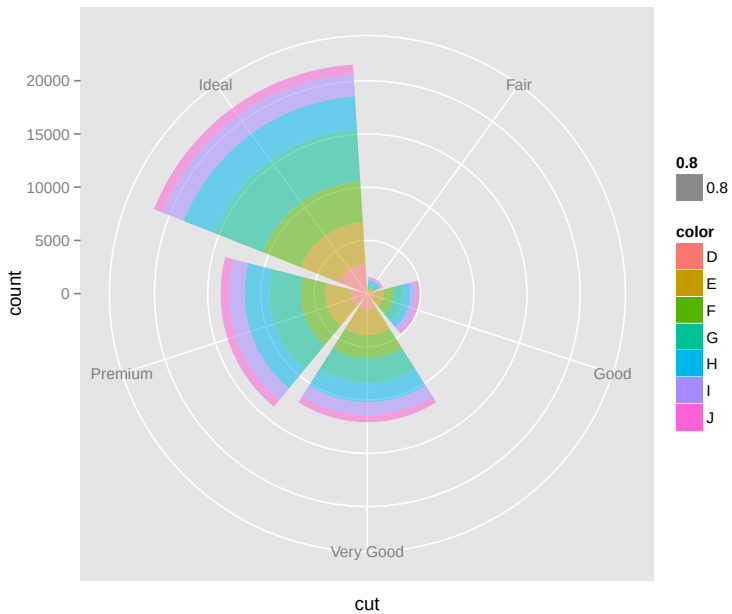

(e) theta="x"

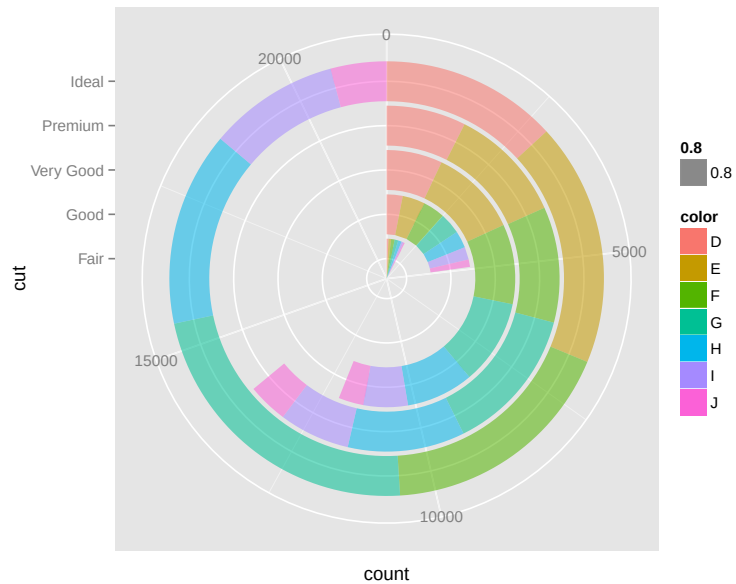

(f) theta="y"

Frequency polygon

```
geom_freqpoly(
    data=w, #Definition eigener Data frame
    aes(group=x,color=x),
    #Linien nach Kriterium x, Farben der Kriterien
    position="z" #Anordnung der Linien
    )
```

Beispiel: Frequency polygon

```
myPlot2 + geom_freqpoly(aes(group=cut, color=cut),
                        position="stack")
```

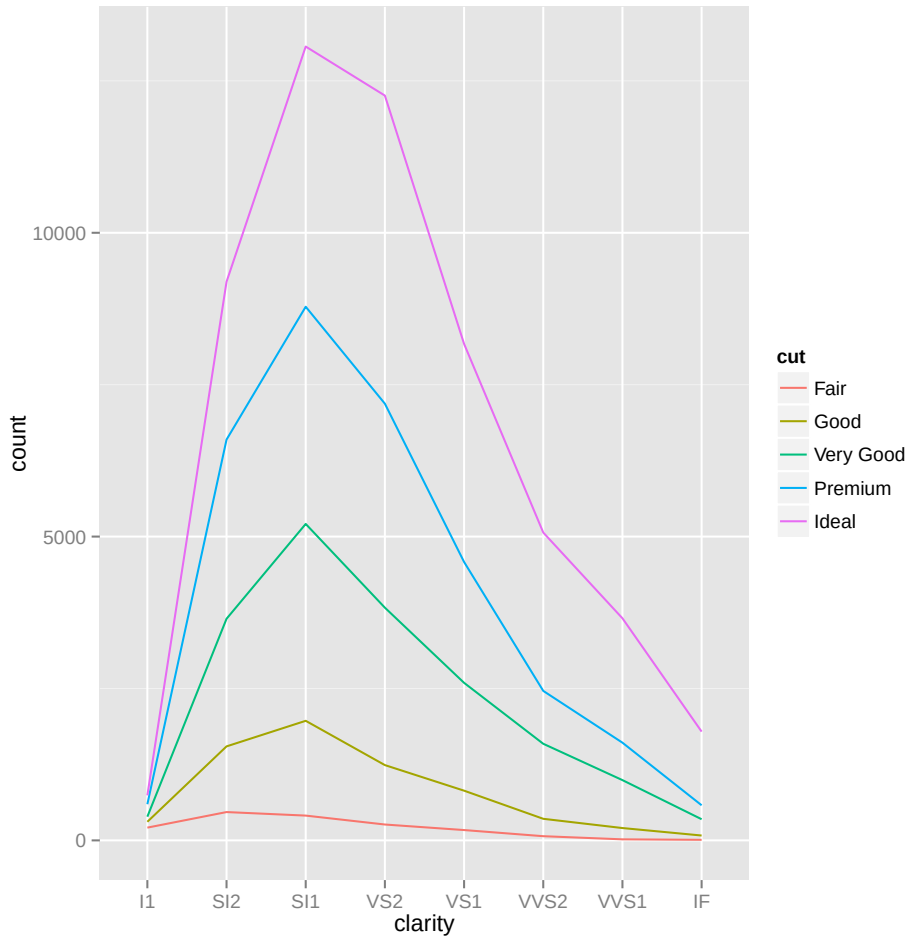

Dichteauswertung “density“

```
myPlot2 + geom_density(aes(fill=clarity, alpha=0.5))
```

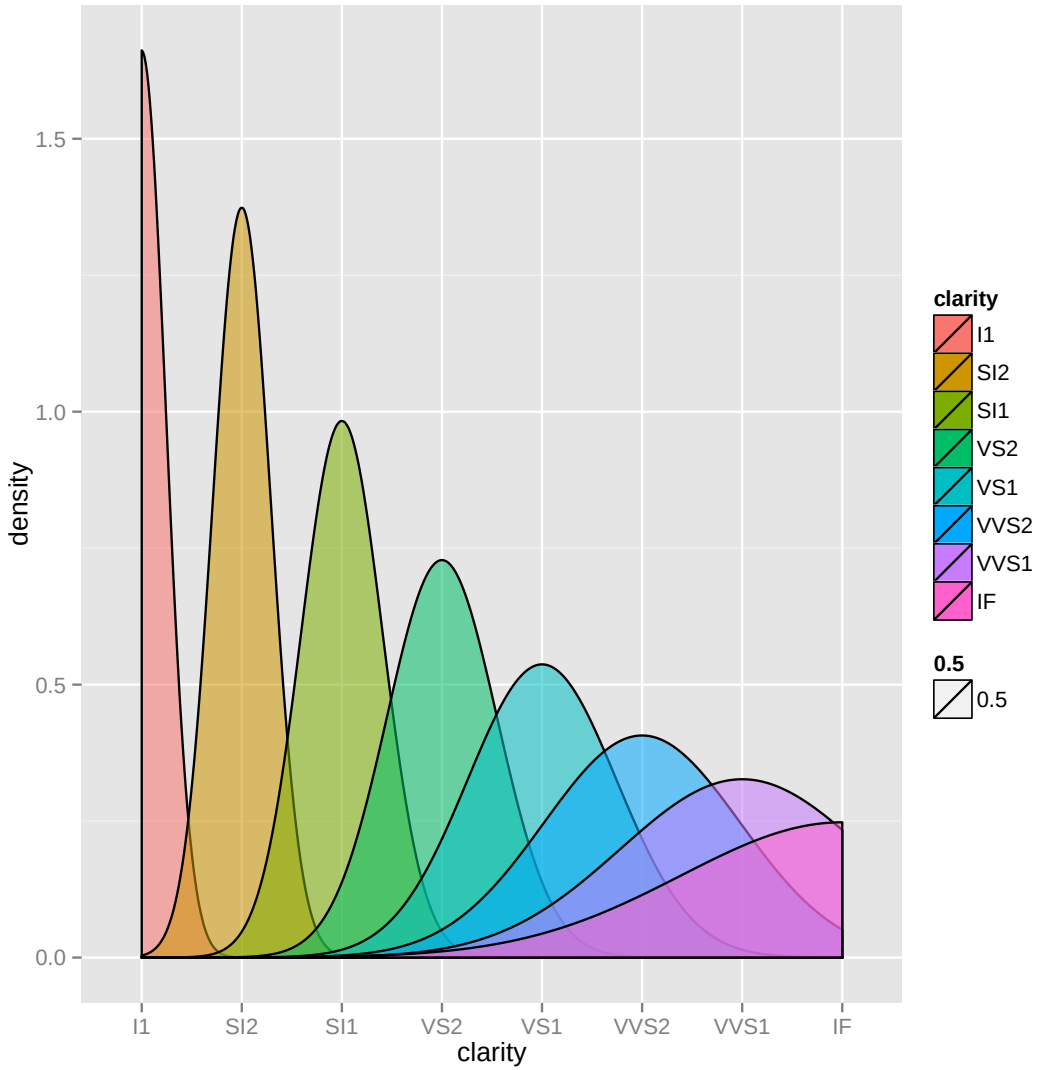

...und viele mehr

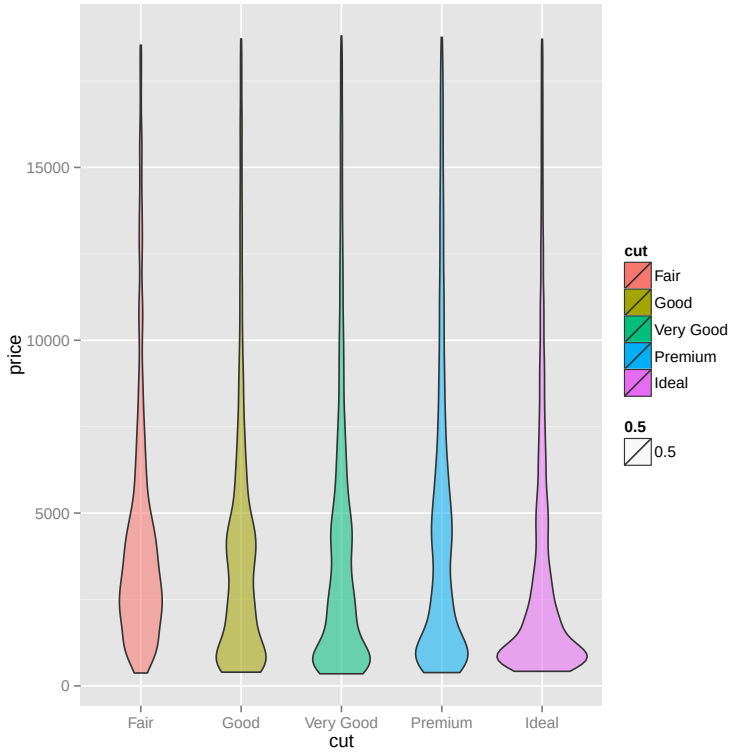

(g) geom_violin()

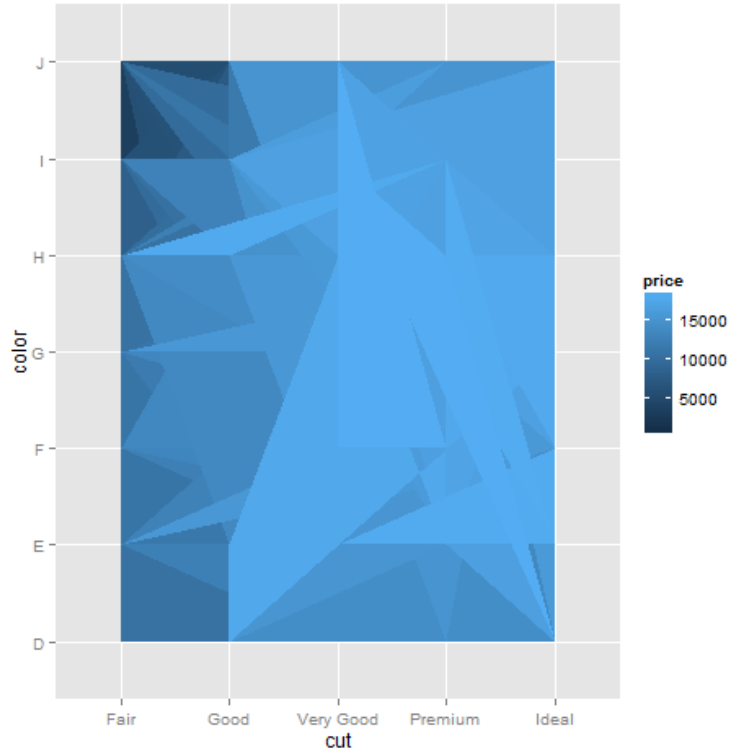

(h) geom_polygon()

Weitere Ideen und Möglichkeiten:
`http://docs.ggplot2.org/current/`

Fallstudie 2: UFO-Sichtungen (Fortsetzung)

Visualisierung der Daten

- Ziel: Zeitlicher Verlauf der Sichtungen pro US-Staat
- Beschränkung auf die Zeit nach 1990, da davor nur sporadische Sichtungen

```
> summary(ufo.us$DateOccurred)
        Min.      1st Qu.       Median         Mean     ...
"1400-06-30" "1999-09-07" "2004-01-10" "2001-02-13"     ...
ufo.us <- subset(ufo.us, DateOccurred >= as.Date("1990-01-01"))
```

Schritt 5: Aggregieren nach Monat und Jahr

- Hinzufügen eines weiteren Aspekts, nämlich Jahr und Monat der Beobachtung
- strftime() formatiert das Datum nach dem angegebenen Muster
- ddply() nimmt den Datensatz, splittet ihn in die verschiedenen Untergruppen (hier: Staat und Jahr-Monat) und wendet die Funktion `nrow` auf die Untergruppen an
- Der resultierende Vektor ist geordnet nach Staaten (alphabetisch) und Datum (chronologisch)

```
> ufo.us$YearMonth <- strftime(ufo.us$DateOccurred, format = "%Y-%m")
> sightings.counts <- ddply(ufo.us, .(USState,YearMonth), nrow)
> head(sightings.counts)
  USState YearMonth V1
1      AK   1936-10  1
2      AK   1943-04  1
3      AK   1949-06  1
4      AK   1954-02  1
5      AK   1955-06  1
```

Schritt 6: Ergänzung fehlender Einträge

- Erstellen eines (geordneten) Vektors mit allen Jahr-Monat-Variationen und Konvertierung in passendes Stringformat
- Kombinieren mit den US-Staaten
- Zusammenfassen der resultierenden Liste zu einem Vektor

```
date.range <- seq.Date(from = as.Date(min(ufo.us$DateOccurred)),
                       to = as.Date(max(ufo.us$DateOccurred)),
                       by = "month")
date.strings <- strftime(date.range, "%Y-%m")
states.dates <- lapply(state.abb, function(s) cbind(s, date.strings))
states.dates <- data.frame(do.call(rbind, states.dates),
                           stringsAsFactors = FALSE)
```

Schritt 6: Ergänzung fehlender Einträge

- Zusammenfügen der beiden (geordneten) Datensätze
- all=TRUE bewirkt, dass fehlende Einträge in sightings.counts mit NA ergänzt werden

```
all.sightings <- merge(states.dates,
                       sightings.counts,
                       by.x = c("s", "date.strings"),
                       by.y = c("USState", "YearMonth"),
                       all = TRUE)
```

Schritt 7: Konvertieren der Datentypen

- Benennung der Spalten
- Ersetzen von `NA` durch 0
- Umwandeln der Datum-Strings in Datum-Objekte
- Umwandeln der Staatenkürzel in Factors

```
names(all.sightings) <- c("State", "YearMonth", "Sightings")
all.sightings$Sightings[is.na(all.sightings$Sightings)] <- 0
all.sightings$YearMonth <- as.Date(rep(date.range, length(state.abb)))
all.sightings$State <- as.factor(all.sightings$State)
```

Schritt 8: Generieren der Graphik

- facet_wrap() liefert Plots für jeden Staat in einem 10x5 Raster
- theme_bw() ändert den Standard-Style zu einem Style mit weißem Hintergrund
- scale_color_manual() setzt dunkelblau als Linienfarbe
- scale_x_date() rastert die x-Achse als Datumformat im Abstand von 5 Jahren

```
state.plot <-
  ggplot(all.sightings, aes(x=YearMonth,y=Sightings)) +
  geom_line(aes(color="darkblue")) +
  facet_wrap(~State, nrow=10, ncol=5) +
  theme_bw() +
  scale_color_manual(values=c("darkblue"="darkblue"),guide="none") +
  scale_x_date(breaks="5 years", labels=date_format('%Y')) +
  xlab("Years") +
  ylab("Number of Sightings") +
  ggtitle("Number of UFO sightings by U.S. State (1990-2010)")
```

UFO-Sichtungen in den einzelnen US-Staaten (1990-2010)