Frühjahrstagung des VDSt
in Saarbrücken

Amt für Statistik Berlin-Brandenburg

Clusteranalyse mit der Open Source-Software R

Dienstag, 1. April 2008

Hartmut Bömermann hartmut.boemermann@statistik-bbb.de

Inhalt

- Statistiksystem R
- Clusteranalyse
- Kartierung der Ergebnisse
- Fazit

Statistiksystem R

R ist

- eine Umgebung für die statistische Analyse, graphische Exploration und Darstellung;
- ein Dialekt der Sprache S (AT&T Bell) und
- eine freie Implementierung dieser Sprache (kommerziell S-Plus).

- GNU General Public License
- Internetsoftware: Entwickler- und Nutzergemeinschaft, Internetbibliothek
  (anders als SAS, SPSS, Zwischenstellung Stata)
- Plattform: Windows, Linux und Mac OS X

- Anwendung: Ökonomie, Biologie, Geologie/Geodaten, Lehre („Statistiklabor“)

Statistiksystem R

Anlaufstelle ist der CRAN-Server:

- R-Programm, Erweiterungsmodule, Community

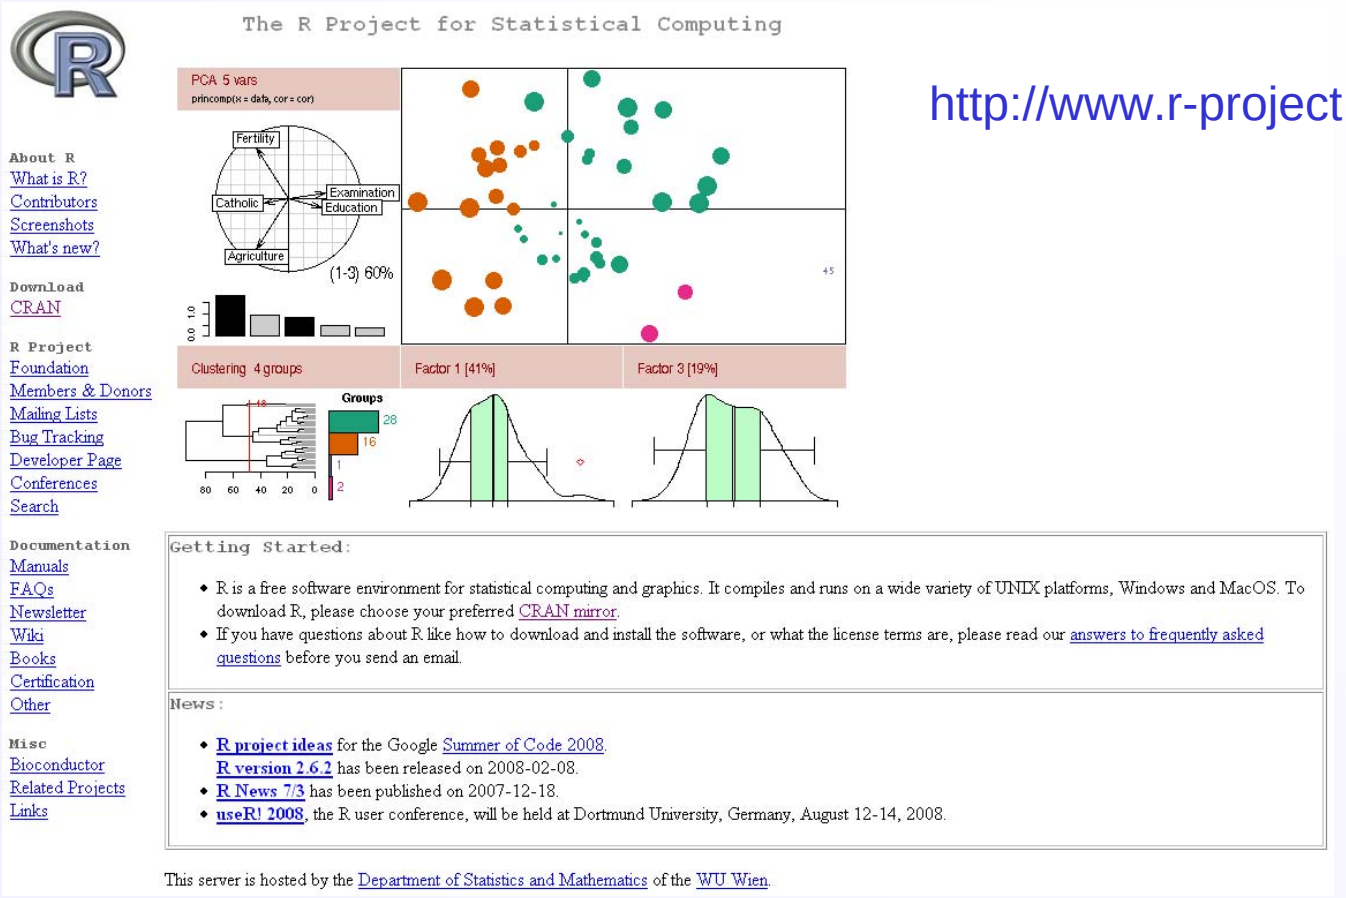

http://www.r-project.org/

Clusteranalyse: Ablauf

Daten einlesen:

Clusteranalyse_Fruehjahrstagung_2008-04_a.R

```
# Lese Excel-Tabelle ein ----------------------------------------------
options(digits=3)
setwd("D:/Buero/Statistik/AfS/Kommunalstat/Workplace/Cluster-AG/Daten/")

library(RODBC)
channel<-odbcConnectExcel("EWR200706E_Matrix.xls")
sqlTables(channel)
sqlQuery(channel, "select * from \"Tabelle1$\"")
EWR07 <- sqlQuery(channel, "select * from \"Tabelle1$\"")
odbcCloseAll()
```

Darstellung im Editor Tinn-R

Clusteranalyse: Ablauf

Variablen berechnen und Datei speichern:

Clusteranalyse_Fruehjahrstagung_2008-04_a.R

```
ed<-edit(EWRO7)     # Daten im Editor anzeigen

# Anteilsvariablen berechnen ----------------------------------------

EWRO7$pE00U01 <- with(EWRO7,100 * E_E00_01/E_E)
EWRO7$pE01U02 <- with(EWRO7,100 * E_E01_02/E_E)
EWRO7$pE02U03 <- with(EWRO7,100 * E_E02_03/E_E)

EWRO7$pE85U90 <- with(EWRO7,100 * E_E85_90/E_E)
EWRO7$pE90U95 <- with(EWRO7,100 * E_E90_95/E_E)
EWRO7$pE95U99 <- with(EWRO7,100 * E_E95_110/E_E)

save(EWRO7, file="EWRO7.Rdata")

setwd("D:/Buero/Statistik/AfS/Kommunalstat/Workplace/Cluster-AG/Daten/")
load("EWRO7.RData")
```

Clusteranalyse: Ablauf

Deskriptive Statistiken berechnen:

```
print(weighted.mean(pEOOUO1,E_E))   # gewichteter Mittelwert
print(c(SD=sd(pEOOUO1),IQR=IQR(pEOOUO1),Range=diff(range(pEOOUO1))))
```

Ergebnis:

```
[1] 1.66
   SD    IQR Range
0.556 0.595 4.688
```

Clusteranalyse: Ablauf

Histogramme:

```
# Histogramm 1 Sturges ------------------------------------------------------

layout(matrix(1:30,6,5), widths=c(1,1,1,1,1), heights=c(3,3,3,3,3,3))
par(col.axis="blue", mar=c(4,4,2,1), oma=c(1,1,1,1), cex=0.6, las=1)

i <- 0
repeat{
  i <- i + 1
  hist(data.matrix(EWR07[i+40]), breaks = "Sturges", probability=FALSE, main="", xlab=names(EWR07[i+40]))
  if(i==30) break
}
```

Clusteranalyse: Ablauf

Histogramme:

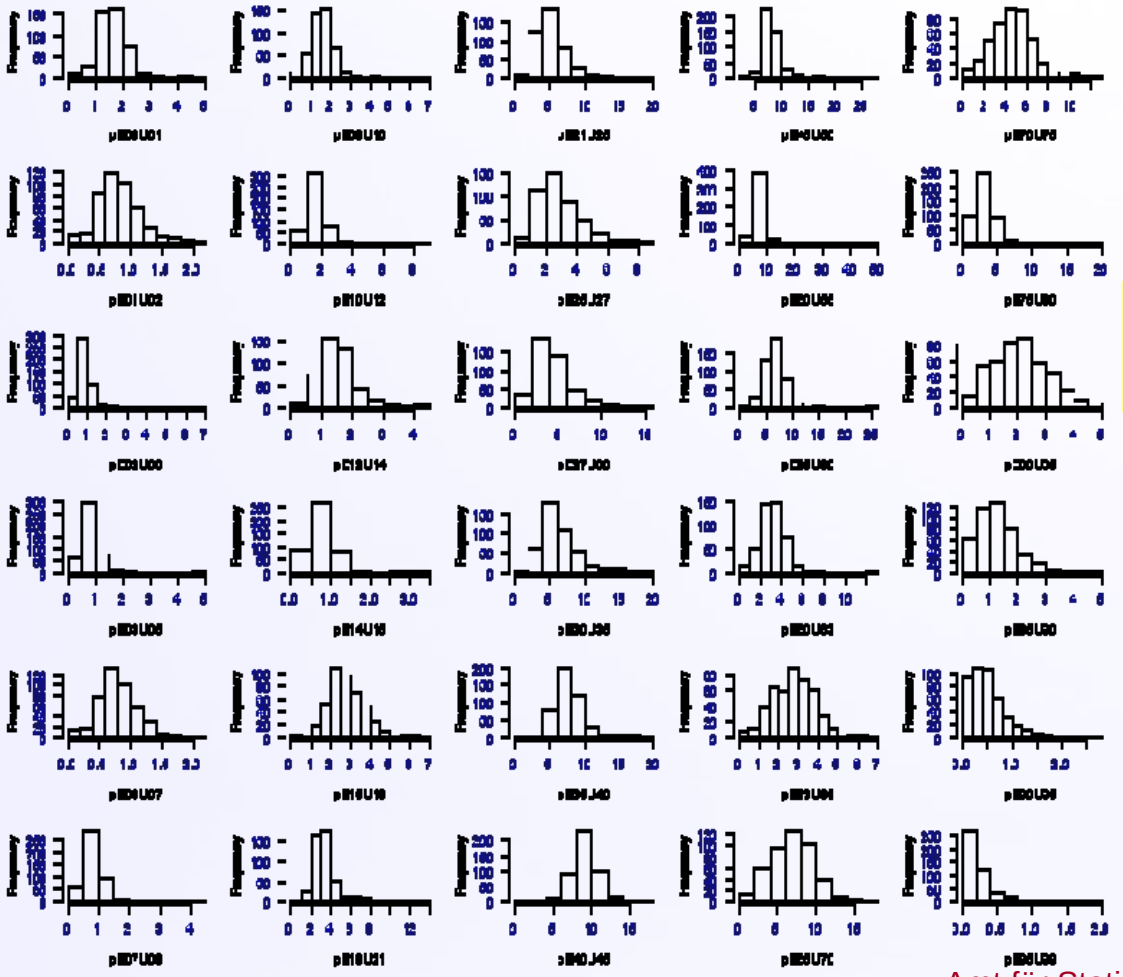

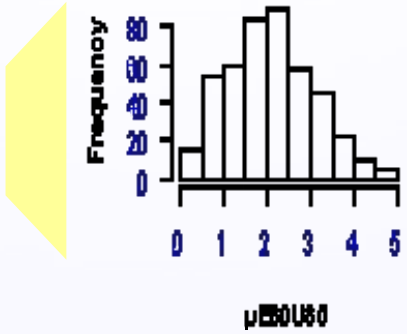

Clusteranalyse: Ablauf

Boxplot:

```
# Boxplot ------------------------------------------------------------------

layout(matrix(1:30,6,5), widths=c(1,1,1,1,1), heights=c(3,3,3,3,3,3))
par(col.axis="blue", mar=c(4,4,2,1), oma=c(1,1,1,1), cex=0.6, las=1)

i <- 0
repeat{
  i <- i + 1
  {boxplot(EWR07[i+40], pars = list(boxwex = 0.8, staplewex = 0.6, outwex = 0.8),
  horizontal=TRUE, xlab="", ylim = c(0, 10), notch = FALSE, border = par("fg"))
  title(names(EWR07[i+40]), cex.main=0.8, adj=0)
  }
  if(i==30) break
}
```

Clusteranalyse: Ablauf

Boxplot:

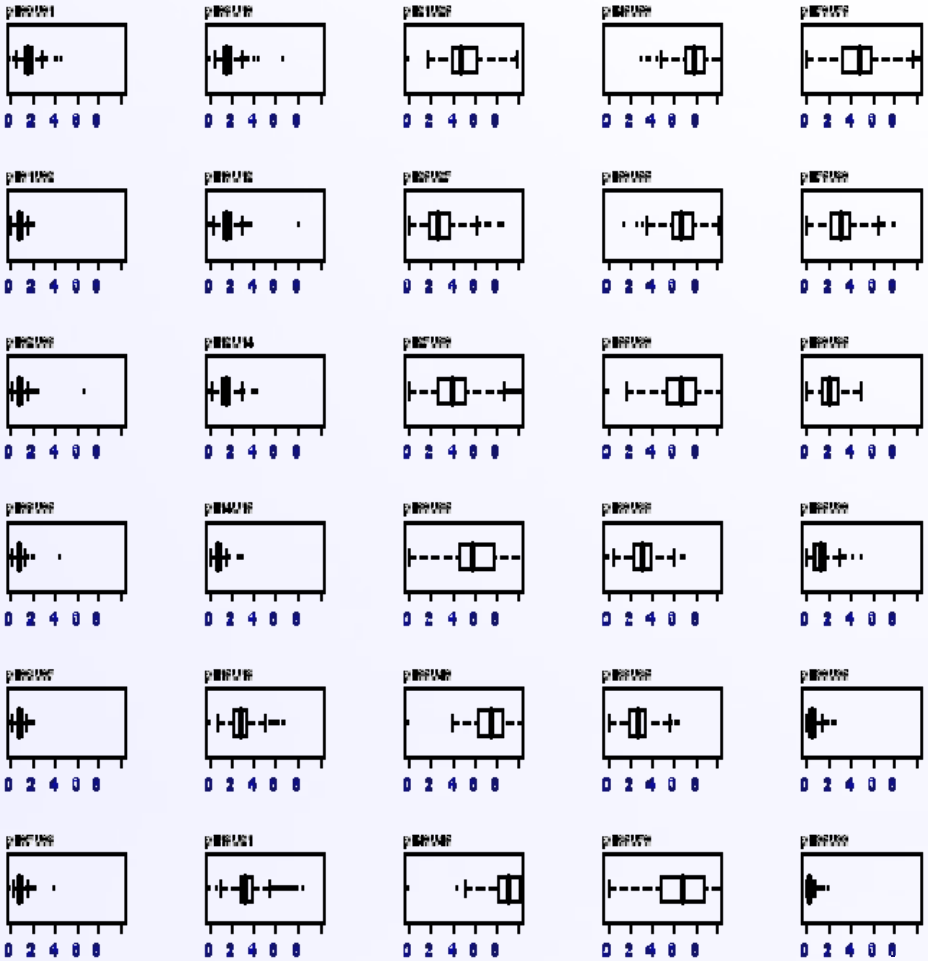

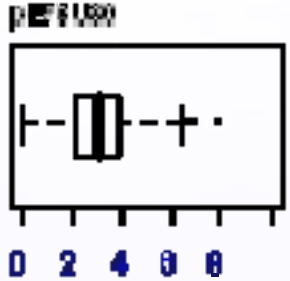

Clusteranalyse: Ablauf

Cluster berechnen, Dendrogramm zeichnen:

```
# ------------------------- HClust -----------------------------------------
require(graphics)

HClust.1 <- hclust(dist(scale(model.matrix(~-1 + as.matrix(EWR07[41:70])^2, EWR07))) , method= "ward")


# ----- Dendrogramm  1
par(col.axis="blue", cex=0.6)
plot(HClust.1, main= "Cluster Dendrogram", xlab= "#Obs", sub="Method=ward; Distance=euclidian", hang=-1, labels=F)
```

Clusteranalyse: Ablauf

Dendrogramm:

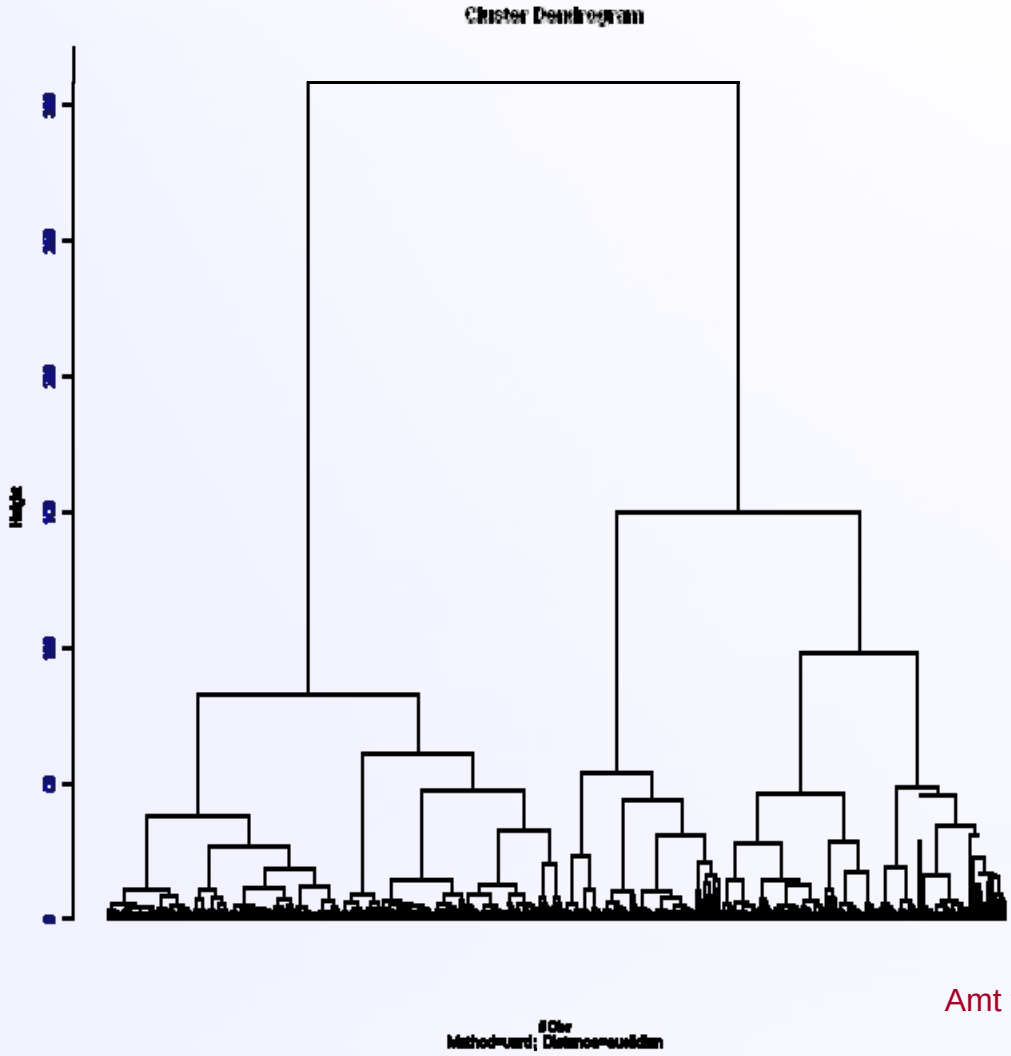

Clusteranalyse: Ablauf

Dendrogramme:

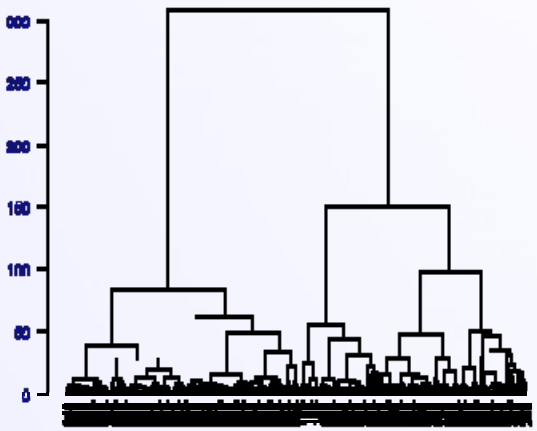

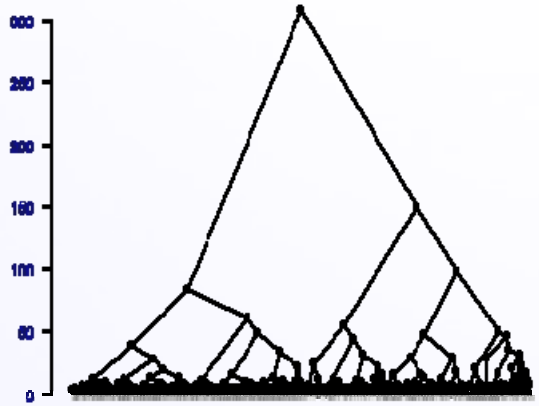

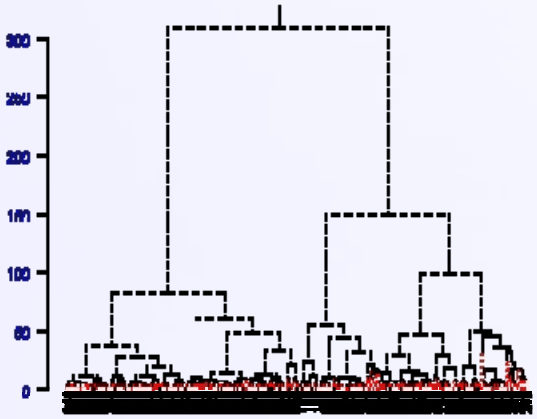

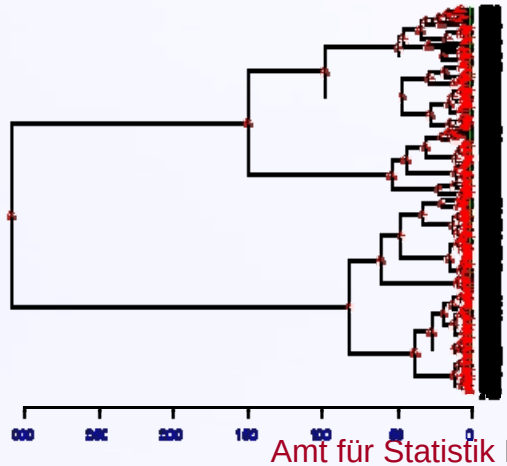

Clusteranalyse: Ablauf

Clusteranalyse:

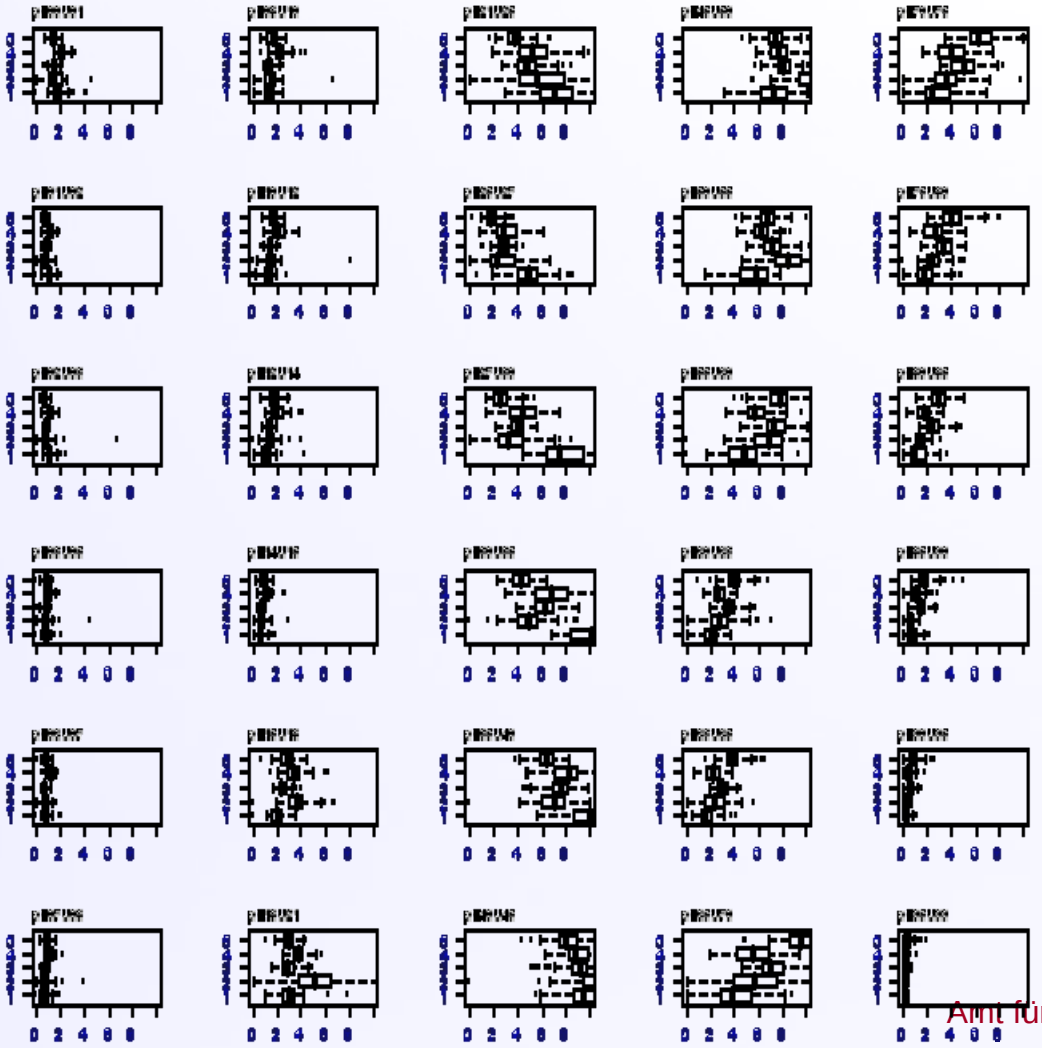

Clusteranalyse: Ablauf

Kartieren:

MapInfo-Geometrie einlesen

```
# --------------------------- Mapping Faelle der nclust-Loesung ---------------
library(rgdal)
library(RColorBrewer)
library(classInt)

setwd("D:/Buero/Statistik/AfS/Kommunalstat/Workplace/Cluster-AG/MapInfo/")
lor <- readOGR("LOR_PLR.TAB", "LOR_PLR")

# ------ MAP
plotvar <- clusternum                                    # Vektor erzeugt mit cutree
plotclr <- brewer.pal(nclust,"YlOrRd")                   # Blues, BuPu, PuOr
                                                         # BuGn GnBu Greens Greys Oranges OrRd PuBu
                                                         # PuBuGn PuRd Purples RdPu Reds YlGn YlGnBu Yl

colnum <- classIntervals(plotvar, nclust, style="fixed", fixedBreaks = seq(1, nclust, by=1),all.inside=T)
colcode <- findColours(colnum, plotclr)

plot(lor, xlim=c(5000,48000), ylim=c(4000,35000))
plot(lor, col=colcode, add=T)

# points(lor$X, lor$Y, pch=16, col="red", cex=0.5)

title("Clusterlösung", sub="LOR=447, Cluster=")
legend(43000,35000, legend=names(attr(colcode, "table")), fill=attr(colcode, "palette"), cex=0.6, bty="n")
```

Clusteranalyse: Ablauf

Kartieren:

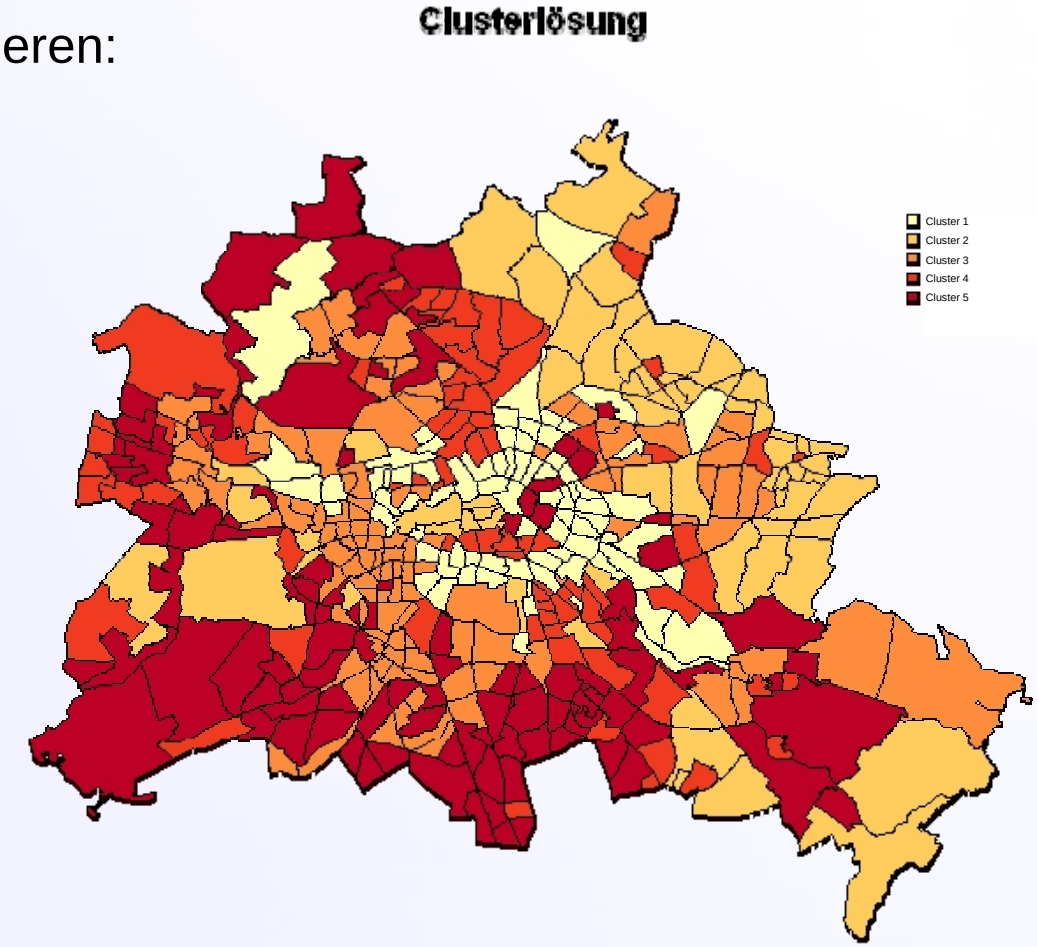

Fazit

- + Programm ist frei verfügbar
- + breites statistisches Instrumentarium
- + ständige Weiterentwicklung
- + vielfältige Grafikmöglichkeiten
- + MapInfo-, ESRI-Geometrien einlesbar
- + Steuerung über Syntax (leichte Wiederholbarkeit von Läufen)
- + grosse Nutzer- und Entwicklergruppe
- + vielfältige Hilfestellungen

- - nicht intuitiv
- - nur rudimentäre graphische Editoren (ebenfalls GNU)
- - Einarbeitungsaufwand
- - geringere Effizienz

- AfS: ergänzend zu anderen Statistikprogrammen