

Häufigkeitsdiagramme

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

PROC UNIVARIATE PROC GCHART

```
PROC GCHART <DATA=sasdatei>;  
    VBAR variablenliste </Optionen>;  
        /* vertikales Histogramm */  
    HBAR var.list </Optionen>;  
        /* horizontales Histogramm */  
    PIE var.list </Optionen>; /* Kreisdiagr  
    STAR var.list </Optionen>; /* Sterndiag  
    BLOCK var.list </Optionen>;  
        /* 3 dim. Balkendiagramm */  
RUN;
```

Häufigkeitsdiagramme

Optionen (1)

VBAR3D, HBAR3D, PIE3D anstelle von VBAR, HBAR, PIE liefern schönere Bilder.

DISCRETE Zusammenfassung von Ausprägungen wird unterdrückt, d.h. für jeden Wert wird eine Säule erzeugt.

LEVELS = anzahl gewünschte Anzahl Säulen

TYPE = FREQ Häufigkeiten (Standard)

= PERCENT Prozente

= CFREQ kum. Häufigkeiten

= CPERCENT kum. Prozente

= SUM Summen (nur mit SUMVAR)

SUMVAR = anzahl Anzahl ist bereits aufsummierte Häufigkeit

Häufigkeitsdiagramme

Optionen (2)

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

MIDPOINTS = Mittelpunkte der Balken.
Balken haben alle die gleiche Breite!

GROUP= Gruppierungsvariable

SUBGROUP= Gruppierungsvariable, gemeinsame
Auswertung

PATTERNID=Musterzuordnung
Vergleiche die PATTERN-Anweisung

Descr_Gchart_1a.sas

Descr_Gchart_1b.sas

Descr_Gchart_3.sas 3a, 3b

Descr_Gchart_1.sas

Häufigkeitsdiagramme

Design der Diagramme

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

PATTERN x_n

C=

V=

C, COLOR

Farbe: blue,cyan,red,black...
black ist Voreinstellung

V, VALUE

Wert: star,plus point,...

x

Muster:

X_n : schraffiert

S_n : Solid

R_n : ///

L_n : \\

n

1-5: Dichte des Musters.

Histogramme und Dichteschätzung

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Auch Prozedur UNIVARIATE liefert Histogramme

```
PROC UNIVARIATE;  
    HISTOGRAM varname </Optionen>;  
RUN;
```

Sie liefert auch Tabellen von Histogrammen;

```
PROC UNIVARIATE;  
    CLASS Klassenvariablen;  
    HISTOGRAM varname </Optionen>;  
RUN;
```

Descr_Plot_Kuehl.sas

Desc_ZweidimHisto_Heroin.sas

Histogramme und Dichteschätzung

Optionen

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

CBARLINE=	Farbe des Histogramms
WBARLINE=	Dicke der Histogrammlinien
L=	Linientyp (Standard: 1, solid)
MIDPOINTS=	wie bei GPLOT
KERNEL	Nichtparametr. Dichteschätzung
COLOR=	Farbe der Dichtekurve
NORMAL	Parametrische Dichteschätzung (Normalverteilung)
GAMMA	Parametrische Dichteschätzung (Gammaverteilung)

Parametrische Dichteschätzung

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Vorgabe: Modell, z.B. Normalverteilung oder
Gammaverteilung

Lediglich die Parameter werden geschätzt.

```
PROC UNIVARIATE;
```

```
    HISTOGRAM varn/normal gamma; /*Parametri
```

```
    HISTOGRAM varn/kernel; /*Nichtparametri
```

```
RUN;
```

Parametrische Dichteschätzung

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Vorgabe: Modell, z.B. Normalverteilung oder
Gammaverteilung

Lediglich die Parameter werden geschätzt.

```
PROC UNIVARIATE;
```

```
    HISTOGRAM varn/normal gamma; /*Parametri
```

```
    HISTOGRAM varn/kernel; /*Nichtparametri
```

```
RUN;
```

Frage: Wie wird geschätzt?

bei Normalverteilung ist das klar: \bar{X} und s^2 sind
optimale Schätzungen für μ und σ^2 .

Parametrische Dichteschätzung

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Vorgabe: Modell, z.B. Normalverteilung oder
Gammaverteilung

Lediglich die Parameter werden geschätzt.

```
PROC UNIVARIATE;
```

```
    HISTOGRAM varn/normal gamma; /*Parametri
```

```
    HISTOGRAM varn/kernel; /*Nichtparametri
```

```
RUN;
```

Frage: Wie wird geschätzt?

bei Normalverteilung ist das klar: \bar{X} und s^2 sind
optimale Schätzungen für μ und σ^2 .

Wie findet man (gute) Schätzungen bei anderen
Verteilungen?

Schätzmethoden

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Momentenmethode

Man drückt den zu schätzenden Parameter durch die Momente, z.B. $\mathbf{E}(X)$, $\mathbf{E}(X^2)$, aus.

Dann werden die Momente durch die empirischen Momente, hier \bar{X} , $\frac{1}{n} \sum X_i^2$ ersetzt.

Maximum-Likelihood-Schätzung

Es wird der Schätzwert für den unbekannt Parameter ermittelt, bei dem die Beobachtungen am meisten für diesen Parameter sprechen (most likely).

Normalverteilung $\mathcal{N}(\mu, \sigma^2)$

\bar{X} und $\hat{\sigma}^2 = \frac{1}{n} \sum X_i^2 - \bar{X}^2$ sind Momentenschätzungen für μ und σ^2 . Sie sind auch ML-schätzungen für μ und σ^2 .

Maximum-Likelihood-Schätzung

$X_i \sim \mathcal{N}(\mu, 1)$ unabhängig

Likelihood: $L_n := f_{X_1, \dots, X_n}(x_1, \dots, x_n)$, die gemeinsame Dichtefunktion der X_i .

$$L_n(\mu) = \prod_{i=1}^n f_{X_i}(x_i) \quad (\text{Unabhängigkeit})$$

$$= \prod_{i=1}^n \frac{1}{\sqrt{2\pi}} e^{-(x_i - \mu)^2/2}$$

$$\ln L_n(\mu) = -n \ln(\sqrt{2\pi}) + \sum_{i=1}^n \left(-\frac{(x_i - \mu)^2}{2} \right)$$

$$\frac{\partial L_n(\mu)}{\partial \mu} = \sum_{i=1}^n (x_i - \mu)$$

Nullsetzen liefert: $\hat{\mu} = \bar{X}$.

Nichtparametrische Dichteschätzung

Überlagerung der Daten mit einer (Dichte-) Funktion

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

$K(t)$ eine Kernfunktion,

$$\int K(t) dt = 1, \quad \int tK(t) dt = 0,$$
$$\int t^2 K(t) dt = 1, \quad \int K^2(t) dt < \infty$$

Nichtparametrische Dichteschätzung

Überlagerung der Daten mit einer (Dichte-) Funktion

Werkzeuge der
empirischen
Forschung

W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

$K(t)$ eine Kernfunktion,

$$\int K(t) dt = 1, \quad \int tK(t) dt = 0,$$
$$\int t^2 K(t) dt = 1, \quad \int K^2(t) dt < \infty$$

Dichteschätzung oder Dichtefunktionsschätzung.

$$\hat{f}(x) = \frac{1}{n} \sum_{i=1}^n \frac{1}{h} K\left(\frac{x - x_i}{h}\right)$$

x_1, \dots, x_n : die Beobachtungen.

h : ein sogenannter Glättungsparameter.

Dichteschätzung

Motivation Kern-Dichteschätzung

Werkzeuge der
empirischen
Forschung


W. Kössler

Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik



Descr_Dichteschaetzung.sas

Dichteschätzung, Beispiel

Werkzeuge der
empirischen
Forschung

W. Kössler



Einleitung

Datenbehandlung

Wkt.rechnung

Beschreibende
Statistik

Kühlaggregate



Histogramm

Parametrische Dichteschätzung (Gamma)

Nichtparametrische Dichteschätzung