

Grafische Darstellung bivariater Daten: Handwerkszeug der deskriptiven Statistik

Thorsten Dickhaus

Beuth Hochschule für Technik

31. Oktober 2012

Multivariate Daten: Mietspiegel-Daten

```
> miete <- read.table(file="miete03.dat", header=TRUE)
> str(miete)
'data.frame':   2053 obs. of  13 variables:
 $ GKM      : num  741 716 528 554 698 ...
 $ QM       : int   68 65 63 65 100 81 55 79 52 77 ...
 $ QMKM     : num   10.9 11.01 8.38 8.52 6.98 ...
 $ Rooms    : int    2 2 3 3 4 4 2 3 1 3 ...
 $ BJ       : num   1918 1995 1918 1983 1995 ...
 $ lage_gut : int    1 1 1 0 1 0 0 0 0 0 ...

 $ bez      : int    2 2 2 16 16 16 6 6 6 6 ...
 $ wohnbest : int    0 0 0 0 0 0 0 0 0 0 ...
 $ ww0      : int    0 0 0 0 0 0 0 0 0 0 ...
 $ zh0      : int    0 0 0 0 0 0 0 0 0 0 ...
 $ badkach0 : int    0 0 0 0 0 0 0 0 0 0 ...
 $ badextra : int    0 0 0 1 1 0 1 0 0 0 ...
 $ kueche   : int    0 0 0 0 1 0 0 0 0 0 ...
```

Übersicht

1 Diskrete Merkmale

2 Stetige Merkmale

Übersicht

1 Diskrete Merkmale

2 Stetige Merkmale

Abgeleitete Variablen

Hier: Klassierung von Baujahr und Quadratmeterzahl

```
> miete$BJKL<-1*(BJ<=1918)+2*(BJ<=1948)*(BJ>1919)+3*(BJ<=1965)  
      *(BJ>1948)+4*(BJ<=1977)*(BJ>1965)+5*(BJ<=1983)  
      *(BJ>1977)+6*(BJ>1983)  
  
> miete$QMKL<-1*(QM<=50)+2*(QM>50)*(QM<=80)+3*(QM>80)
```

Zwei diskrete Merkmale: Kontingenztafeln

Mögliche Werte für Merkmal 1: $a_1, a_2, \dots, a_k$

Mögliche Werte für Merkmal 2: $b_1, b_2, \dots, b_\ell$

Beobachtung x : Matrix der absoluten Häufigkeiten aller Kombinationen (a_i, b_j) , $1 \leq i \leq k$, $1 \leq j \leq \ell$ in der Stichprobe vom Umfang n

Darstellung als **Kontingenztafel** (auch: $(k \times \ell)$ -Feldertafel):

	b_1	b_2	$\dots$	b_ℓ	Σ
a_1	x_{11}	x_{12}	$\dots$	$x_{1\ell}$	$n_{1.}$
a_2	x_{21}	x_{22}	$\dots$	$x_{2\ell}$	$n_{2.}$
$\dots$	$\dots$	$\dots$	$\dots$	$\dots$	$\dots$
a_k	x_{k1}	x_{k2}	$\dots$	$x_{k\ell}$	$n_{k.}$
Σ	$n_{.1}$	$n_{.2}$	$\dots$	$n_{.\ell}$	n

Randhäufigkeiten, marginale Verteilungen



Der Vektor $\mathbf{n} = (n_{1.}, n_{2.}, \dots, n_{k.}, n_{.1}, n_{.2}, \dots, n_{.\ell}) \in \mathbb{N}^{k+\ell}$ heißt **Vektor der (empirischen) Randhäufigkeiten**.

Die (empirische) diskrete Verteilung, die durch die Randhäufigkeiten eines Merkmals gegeben ist, bezeichnet man als **Randverteilung** oder auch **marginale Verteilung** dieses Merkmals.

```
> h<-numeric(6)
> for(i in 1:6){
+ h[i]<-length(which(BJKL==i))}
> names(h)<-c("vor_1918", "1919-1948", "1948-1965", "1966-1977",
+ "1978-1983", "Neubau")

> pie(h,col=rainbow(6))
> barplot(h,col=heat.colors(6),density=100)
```

Grafische Darstellung von Randverteilungen



Grafische Darstellung bivariater diskreter Verteilungen



R Code: **mosaicplot** und **assocplot**

```
> miete$QM_KML <- 1 * (QM_KM <= 8) + 2 * (QM_KM > 8) * (QM_KM <= 10)
+ 3 * (QM_KM > 10) * (QM_KM <= 12) + 4 * (QM_KM > 12);



> par(mfrow=c(1, 2));
> mosaicplot(table(miete$QM_KML, miete$lage_gut), col=TRUE,
+               xlab="QM_KML", ylab="Gute_Lage");
> assocplot(table(miete$QM_KML, miete$lage_gut),
+               xlab="QM_KML", ylab="Gute_Lage");

> par(mfrow=c(1, 2));
> mosaicplot(table(miete$BJKL, miete$QM_KL), col=TRUE,
+               xlab="BJKL", ylab="QM_KL");
> assocplot(table(miete$BJKL, miete$QM_KL),
+               xlab="BJKL", ylab="QM_KL");
```

Miete versus Wohnlage



Baujahr versus Wohnungsgröße



Übersicht

1 Diskrete Merkmale

2 Stetige Merkmale

Multivariate stetige Verteilungen

Modell: $\mathbf{X}_1, \dots, \mathbf{X}_n \in \mathbb{R}^p$ i.i.d. $\sim f$, f Verteilungsdichte auf $\mathbb{R}^p$.

Definition (p -dimensionaler Kern)


Ein **Kern** ist eine Funktion $\mathcal{K} : \mathbb{R}^p \rightarrow \mathbb{R}$ mit

$$\int_{\mathbb{R}^p} \mathcal{K}(\mathbf{y}) d\mathbf{y} = 1 \quad \text{und}$$


Regularitätsbedingungen:


- $\mathcal{K}$ ist radialsymmetrische Wahrscheinlichkeitsdichte
- Existierendes zweites Moment $\mu_2(\mathcal{K})$





Gauß-Kernschätzer auf $\mathbb{R}$ ($n = 5$)



Gauß-Kernschätzer auf $\mathbb{R}$ ($n = 9$)



Gauß-Kernschätzer auf $\mathbb{R}$ ($n = 50$)



p -dim. Kernfunktionen, Kerndichteschätzer

Beispiele:

uniformer Kern $\mathcal{K}(\mathbf{x}) = \frac{1}{v_p}$ für $\mathbf{x}^T \mathbf{x} \leq 1$,

Gaußkern $\mathcal{K}(\mathbf{x}) = \frac{1}{(2\pi)^{p/2}} \exp\left(-\frac{1}{2}\mathbf{x}^T \mathbf{x}\right)$,

Epanechnikovkern $\mathcal{K}(\mathbf{x}) = \frac{1+p/2}{v_p}(1 - \mathbf{x}^T \mathbf{x}), \mathbf{x}^T \mathbf{x} \leq 1$.

Definition



Sei $\mathcal{K} : \mathbb{R}^p \rightarrow \mathbb{R}$ ein Kern.

$$\hat{f}_n(\mathbf{x}) = \frac{1}{nh^p} \sum_{i=1}^n \mathcal{K}\left(\frac{\mathbf{x} - \mathbf{X}_i}{h}\right), \mathbf{x} \in \mathbb{R}^p$$

heißt multivariater Kerndichteschätzer mit Bandweite h und Kern $\mathcal{K}$.

Darstellung zweidimensionaler Kernfunktionen

Gaußkern und Epanechnikovkern mit $p = 2$



Bandweitenwahl

Bias und Varianz:

$$\text{Bias}_h \left(\hat{f}_n(\mathbf{x}) \right) = \frac{h^2}{2} \mathbb{H}_f(\mathbf{x}) \mu_2(\mathcal{K}) + o(h^2) ,$$

$$\text{Var}_h \left(\hat{f}_n(\mathbf{x}) \right) = \frac{1}{nh^p} \|\mathcal{K}\|_2^2 f(\mathbf{x}) + o \left(n^{-1} h^{-p} \right) .$$

Minimierung des MISE:

$$(h_{opt})^{p+4} = \frac{p}{n} \frac{\|\mathcal{K}\|_2^2}{\mu_2^2(\mathcal{K}) \int_{\mathbb{R}^p} \mathbb{H}_f^2(\mathbf{y}) d\mathbf{y}} \Rightarrow h_{opt} \sim n^{-1/(p+4)} .$$

Verschiedene Bandweiten in unterschiedliche Richtungen

Allgemeiner als in obiger Definition kann man den multivariaten Kerndichteschätzer mit einer **Bandweitenmatrix** H definieren:

$$\hat{f}_n(\mathbf{x}) = \frac{1}{n|H|} \sum_{i=1}^n \mathcal{K}\left(H^{-1}(\mathbf{x} - \mathbf{X}_i)\right), \mathbf{x} \in \mathbb{R}^p.$$

Zuvor: $H = h\mathbb{1}_p$, wobei $\mathbb{1}_p$ die p -dimensionale Einheitsmatrix bezeichnet

In $\mathbb{R}$: Diagonalmatrix H angebbbar.

R Code: Zweidimensionale Kerndichteschätzung





```
> library(MASS)
> library(KernSmooth)
> data(faithful)
> x<-faithful$eruptions
> y<-faithful$waiting

> par(mfrow=c(2,2),pty="m")
> plot(y,x,ylab="eruption",
      xlab="waiting") #Scatterplot, Streubild

> z<-kde2d(x,y,lims=c(0,6,35,100))
> zz<-bkde2D(faithful,range.x=list(c(0,6),c(35,100)),
+ bandwidth=c(bw.SJ(x),bw.SJ(y))) #b: binned
> image(z,xlab="eruption",ylab="waiting")
> image(zz$fhat,xlab="eruption",ylab="waiting") #Heat-Maps


> persp(z,col="slategrey",theta=35,xlim=c(0,6),ylim=c(35,100),
+ ticktype="detailed",xlab="eruption",ylab="waiting",zlab="")
```

Zweidimensionale Kerndichteschätzung



Kontur-Plots, 3D-Plots

```
> contour(zz$x1, zz$x2, zz$fhat)  
  
> persp(zz$x1, zz$x2, zz$fhat, col="slategrey",  
+ theta=35, xlim=c(0,6), ylim=c(35,100),  
+ ticktype="detailed", xlab="eruption",  
+ ylab="waiting", zlab="")
```



Zusammenhänge zwischen stetigen Variablen

Drei Ursprungsgeraden zur Beschreibung des Zusammenhangs zwischen den stetigen Merkmalen „Quadratmeterzahl“ und „Gesamtkaltmiete“:

```
plot(miete$QM, miete$GKM, xlab="Quadratmeter",  
      ylab="Kaltmiete");  
abline(0, mean(QMKM), col="blue", lwd=2);  
abline(0, mean(QMKM)+sd(QMKM), col="red", lty=4, lwd=2);  
abline(0, mean(QMKM)-sd(QMKM), col="red", lty=4, lwd=2);
```

