

Methoden der Statistik

Kapitel 2: Deskriptive Statistik

Thorsten Dickhaus

Weierstraß-Institut für Angewandte Analysis und Stochastik Berlin

Wintersemester 2013/2014



Übersicht

- 1 Abschnitt 2.1: Univariate Merkmale
- 2 Abschnitt 2.2: Multivariate Merkmale

Übersicht

1 Abschnitt 2.1: Univariate Merkmale

2 Abschnitt 2.2: Multivariate Merkmale

Univariate Daten:

Michelson's Lichtgeschwindigkeits-Daten

1	850	1	1
2	740	2	1
3	900	3	1
4	1070	4	1
5	930	5	1
6	850	6	1
7	950	7	1
8	980	8	1
9	980	9	1
10	880	10	1
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮

Interpretation der Daten

1	850	1	1
2	740	2	1
3	900	3	1
4	1070	4	1
⋮	⋮	⋮	⋮
⋮	⋮	⋮	⋮

- Erste Spalte : Fortlaufende Nummer der Messungen (1-100)
Zweite Spalte : (Gemessene Geschwindigkeit - 299.000) in km/s
Dritte Spalte : Fortlaufende Nummer in der Messreihe (1-20)
Vierte Spalte : Nummer der Messreihe (1-5)

Einlesen der Daten

```
> l<-read.table("lightspeed.dat")
> str(l)
'data.frame': 100 obs. of 4 variables:
 $ V1: int 1 2 3 4 5 6 7 8 9 10 ...
 $ V2: int 850 740 900 1070 930 850 950 980 980 880 ...
 $ V3: int 1 2 3 4 5 6 7 8 9 10 ...
 $ V4: int 1 1 1 1 1 1 1 1 1 1 ...
> attributes(l)
> dim(l)
[1] 100 4
> is.matrix(l)
[1] FALSE
> is.list(l)
[1] TRUE
> mode(l)
[1] "list"
> speed<-l$V2
```

Variablen

```
> names(l)
[1] "V1" "V2" "V3" "V4"
> names(l) <- c("No", "Speed", "ExNo", "Ex")
> attach(l)
```

The following object(s) are masked from l (position 3) :

Ex ExNo No Speed

```
> ex1 <- subset(l, Ex == 1)
> s <- ex1$Speed
```

Statistische Kenngrößen

(Arithmetischer) Mittelwert $\bar{x} = n^{-1} \sum_{i=1}^n x_i$:

```
> mean(s) [1] 909
```

Standardabweichung $\sqrt{(1/(n-1)) \sum_i (x_i - \bar{x})^2}$:

```
> sd(s) [1] 104.9260
```

Median $med = x_{[(n+1)/2]}$:

```
> median(s) [1] 940
```

Median absoluter Abweichungen $MAD = n^{-1} \sum_i |x_i - med(\mathbf{x})|$:

```
> mad(s) [1] 88.956
```

Statistische Kenngrößen

Schiefe (skewness):

$$v(X) = \frac{\mathbb{E}[(X - \mathbb{E}X)^3]}{\text{Var}(X)^{3/2}}.$$

Die Schiefe einer empirischen Verteilung:

$$v_e(\mathbf{x}) = \frac{n^{-1} \sum_i (x_i - \bar{x})^3}{(n^{-1} \sum_i (x_i - \bar{x})^2)^{3/2}}$$

```
> skew<-function(x){  
+   skewness <- ((sqrt(length(x)))*  
+     sum((x-mean(x))^3))/(sum((x-mean(x))^2)^(3/2))  
+   return(skewness)}  
> skew(s)  
[1] -0.890699
```


Die **summary**-Funktion

```
> summary(ex1)
```

No	Speed	ExNo	Ex
Min. : 1.00	Min. : 650	Min. : 1.00	Min. :1
1st Qu.: 5.75	1st Qu.: 850	1st Qu.: 5.75	1st Qu.:1
Median :10.50	Median : 940	Median :10.50	Median :1
Mean :10.50	Mean : 909	Mean :10.50	Mean :1
3rd Qu.:15.25	3rd Qu.: 980	3rd Qu.:15.25	3rd Qu.:1
Max. :20.00	Max. :1070	Max. :20.00	Max. :1

Der Box–Whisker–Plot

>**boxplot**(s)




R Code: Herausnehmen von Ausreißern

```
> strim<-s[which(s>700) ]  
> summary( strim )
```

Min.	1st Qu.	Median	Mean	3rd Qu.	Max.
740.0	865.0	950.0	922.6	980.0	1070.0

Vergleich der Messreihen

```
> boxplot(l$Speed~l$Ex)
```



Empirische Verteilungsfunktion

Seien $X_1, \dots, X_n$ reellwertige iid. Zufallsvariablen mit $X_1 \sim F$ und $X = (X_1, \dots, X_n)^t$.

$$\hat{F}_n(t) := \frac{\#\{x_i | x_i \leq t, i \in \{1, \dots, n\}\}}{n} = \sum_{i=1}^n \frac{1}{n} \mathbb{1}_{(-\infty, t]}(x_i) .$$


Satz von **Glivenko–Cantelli** liefert fast sichere gleichmäßige Konvergenz:

$$\lim_{n \rightarrow \infty} \sup_{t \in \mathbb{R}} |\hat{F}_n(t) - F(t)| = 0 \quad \mathbb{P}_F - f.s.$$

> `ecdf(er)`
Empirical CDF

Call: `ecdf(er)` *#er: eruptions of a geysir*

Empirische Verteilungsfunktion



Diskrete Merkmale, Stabdiagramme

Die empirische Verteilungsfunktion ist eine rechtsseitig stetige, monoton wachsende Treppenfunktion, die an den Beobachtungspunkten springt.

Ist X_1 diskret verteilt, so ist $\mathcal{L}(X_1)$ festgelegt durch seine Wahrscheinlichkeitsfunktion, also durch die Angabe der Werte $\mathbb{P}_F(X_1 = k), k \in \text{supp}(X_1)$.


Auf der beschreibenden Ebene (empirisches Maß) führt das zu **Stabdiagrammen** der relativen Häufigkeiten der beobachteten Werte.

Stabdiagramm und empirische Verteilungsfunktion

simanz = 5000; werte <- **rbinom**(n=simanz, size=10, prob=0.15)

plot(ecdf(werte), **col**='blue',
main='Computersimulation: Binomialverteilung')

lines(**sort**(**unique**(werte)), **table**(werte)/simanz,
type='h', **col**='red', lwd=2)



Stetiges Merkmal

Modellannahme:

$X_1, \dots, X_n$ reellwertige iid. Zufallsvariablen, deren Verteilung die Dichte f bezüglich des Lebesgue–Maßes besitzt.

Datenbeispiel:

272 beobachtete Ausbrüche des “Old Faithful”–Geysirs im Yellowstone National Park mit Eruptionsdauer sowie der Wartezeit bis zum nächsten Ausbruch

```
> data(faithful)
> er<-faithful$eruptions
```

Histogramm–Schätzer

Das Histogramm ist ein **stückweise konstanter** Dichteschätzer.

Vorgehen: Wähle Intervalle („Klassen“, englisch: bins) I_k

$$I_k = (a_{k-1}, a_k], k \in \{1, \dots, K\}$$


$$n_k := \#\{x_i \in I_k, i \in \{1, \dots, n\}\}$$

$$\hat{f}_{hist}(x) = \frac{n_k}{n} \frac{1}{a_k - a_{k-1}} \mathbb{1}_{\{I_k\}}(x)$$


Im Falle gleicher Intervalllängen mit

$a_k - a_{k-1} \equiv h \quad \forall k \in \{1, \dots, K\}$:

$$\hat{f}_{hist}(x) = \frac{n_k}{nh} \mathbb{1}_{\{I_k\}}(x)$$



```
> hist(er, freq=FALSE,col="grey")
```



Nachteil des Histogramm-Schätzers:


Schätzer hängt von der Wahl der **Klassen-Längen** und des **Startwertes a_0** ab!

Gleitendes Histogramm

Durch den gleitenden Histogramm-Schätzer

$$\begin{aligned}\hat{f}_{GH}(x) &:= \frac{\hat{F}_n(x+h) - \hat{F}_n(x-h)}{2h} = \frac{\#\{x_i | x_i \in (x-h, x+h]\}}{2hn} \\ &= \frac{1}{nh} \sum_{i=1}^n \mathcal{K}_R\left(\frac{x-x_i}{h}\right) \quad \text{mit } \mathcal{K}_R(t) = (1/2)\mathbb{1}_{[-1,1]}(t),\end{aligned}$$

bei dem **jede Beobachtung Mittelpunkt eines bins** ist, lässt sich das Startwertproblem lösen.



Kernfunktionen

Definition

Eine Funktion $\mathcal{K} : \mathbb{R} \rightarrow \mathbb{R}$ heißt **Kern**, falls gilt:

① $\int \mathcal{K}(x) dx = 1, \mathcal{K}(x) \geq 0 \quad \forall x \in \mathbb{R}, \mathcal{K}(x) = \mathcal{K}(-x)$

Regularitätsbedingungen:

② $\sup_{x \in \mathbb{R}} \mathcal{K}(x) = M < \infty$

③ $|x|\mathcal{K}(x) \rightarrow 0$ für $|x| \rightarrow 0, \int x^2 \mathcal{K}(x) dx =: k_2 < \infty$

Kernfunktionen: Beispiele

Beispiele für Kernfunktionen:

Rechteckskern $\mathcal{K}(x) = \frac{1}{2} \mathbb{1}_{[-1,1]}(x),$


Dreieckskern $\mathcal{K}(x) = (1 - |x|) \mathbb{1}_{[-1,1]}(x),$

Gaußkern $\mathcal{K}(x) = \frac{1}{\sqrt{2\pi}} \exp(-x^2/2),$

Bisquarekern $\mathcal{K}(x) = \frac{15}{16} (1 - x^2)^2 \mathbb{1}_{[-1,1]}(x),$

Epanechnikovkern $\mathcal{K}(x) = \frac{3}{4} (1 - x^2) \mathbb{1}_{[-1,1]}(x).$

Grafische Darstellung verschiedener Kernfunktionen



Univariater Kerndichteschätzer

Definition

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


$$\hat{f}_n(t) = \frac{1}{nh} \sum_{i=1}^n \mathcal{K} \left(\frac{t - x_i}{h} \right) = \int \frac{1}{h} \mathcal{K} \left(\frac{t - x}{h} \right) \hat{F}_n(dx)$$

heißt (univariater) Kerndichteschätzer mit Bandweite h und Kern $\mathcal{K}$.


Mit $\tilde{\mathcal{K}}(t) := \int_{-\infty}^t \mathcal{K}(x) dx$ lässt sich auch $F(t)$ schätzen durch

$$\int \tilde{\mathcal{K}} \left(\frac{t - x}{h} \right) \hat{F}_n(dx) = \frac{1}{n} \sum_{i=1}^n \tilde{\mathcal{K}} \left(\frac{t - x_i}{h} \right).$$


Gauß-Kernschätzer ($n = 5$)







Gauß-Kernschätzer ($n = 9$)



Gauß-Kernschätzer ($n = 50$)





Kernschätzung: Feinkalibrierung

Entscheidende Schwierigkeit: Wahl der Bandweite!

h zu groß $\rightarrow$ *oversmoothing*

$\rightarrow$ lokale Extrema werden nicht erkannt, zu glatt

h zu klein $\rightarrow$ *undersmoothing*

$\rightarrow$ lokale Moden, Schätzer ist „hairy“

Bias

Satz

Wenn $\mathcal{K} : \mathbb{R} \rightarrow \mathbb{R}$ ein Kern ist, der die oben genannten Regularitätsbedingungen erfüllt, und $f \in \mathcal{C}^2(\mathbb{R})$, so gilt:

$$\mathbb{E}_f[\hat{f}_n(x)] - f(x) = \frac{h^2}{2} f''(x) \int x^2 \mathcal{K}(x) dx + o(h^2) .$$

Bias

Beweis über Taylor-Entwicklung von f :

$$\begin{aligned}f(x - ht) &= f(x) - htf'(x) + \frac{h^2 t^2}{2} f''(x) + o(h^2 t^2) \\ \mathbb{E}_f[\hat{f}_n(x)] - f(x) &= \int \frac{1}{h} \mathcal{K}\left(\frac{x-y}{h}\right) f(y) dy - f(x) \\ &= -hf'(x) \underbrace{\int y \mathcal{K}(y) dy}_{=0} + \\ &\quad \frac{h^2 f''(x)}{2} \underbrace{\int y^2 \mathcal{K}(y) dy}_{=k_2} + o(h^2 t^2) \\ &= \frac{h^2 f''(x)}{2} k_2 + o(h^2 t^2).\end{aligned}$$

Varianz

Satz

Wenn $\mathcal{K} : \mathbb{R} \rightarrow \mathbb{R}$ ein Kern ist, der die oben genannten Regularitätsbedingungen erfüllt, und $f \in \mathcal{C}(\mathbb{R})$, so gilt:

$$\mathbb{V}\text{ar}_f \left(\hat{f}_n(x) \right) = \frac{1}{nh} f(x) \int \mathcal{K}^2(y) dy + o \left(n^{-1} h^{-1} \right) .$$

Varianz

Beweis:

$$\begin{aligned}\mathbb{V}\text{ar}\left(\hat{f}_n(x)\right) &= \frac{1}{n^2 h^2} \sum_{i=1}^n \mathbb{V}\text{ar}\left(\mathcal{K}\left(\frac{x-x_i}{h}\right)\right) \\ &= \frac{1}{nh^2} \int \mathcal{K}^2\left(\frac{x-y}{h}\right) f(y) dy - \frac{1}{n} \left(\mathbb{E}[\hat{f}_n(x)]\right)^2 \\ &= \frac{1}{nh} \int \mathcal{K}^2(y) f(x-yh) dy - n^{-1} \left(\mathbb{E}[\hat{f}_n(x)]\right)^2 \\ &= \frac{1}{nh} f(x) \int \mathcal{K}^2(y) dy + o\left(n^{-1} h^{-1}\right).\end{aligned}$$

Mean Squared Error: Bias–Varianz–Zerlegung

$$\begin{aligned}\mathbb{E}_f \left[\left(\hat{f}_n(x) - f(x) \right)^2 \right] &= \text{Bias}(\hat{f}_n(x|h))^2 + \text{Var}(\hat{f}_n(x|h)) \\ &= h^4 \left(\frac{f''(x)}{2} k_2 \right)^2 + \frac{1}{nh} f(x) \int \mathcal{K}^2(y) dy + o \left(h^4 + n^{-1} h^{-1} \right)\end{aligned}$$

⇒ **Trade–Off** zwischen Bias und Varianz möglich!

Anmerkung:

Bias hängt nicht explizit vom Stichprobenumfang n ab.

Für Konsistenz muss indes $h \equiv h(n) \rightarrow 0$ und $nh \rightarrow \infty$ für $n \rightarrow \infty$ gelten!

Optimaler Kern

Minimierung des MISE bezüglich h ergibt **optimale Bandweite**:

$$h_{opt} = \frac{(\int \mathcal{K}^2(y) dy)^{1/5}}{n^{1/5} k_2^{1/5} \left(\int (f''(y))^2 dy \right)^{1/5}} . \quad (1)$$

Setzt man h_{opt} in den MISE ein, erhält man

$$\text{MISE} \approx \frac{5}{4} \left(k_2^{2/5} \left(\int \mathcal{K}^2(y) dy \right)^{4/5} \right) \left(\int (f''(y))^2 dy \right)^{1/5} .$$

Minimal für **Epanechnikov-Kern**:

$$\mathcal{K}_e(x) = \frac{3}{4\sqrt{5}} \left(1 - \frac{x^2}{5} \right) \mathbb{1}_{[-5,5]}(x) .$$

Optimaler Kern

Setzt man h_{opt} in den MISE ein, erhält man

$$\text{MISE} \approx \frac{5}{4} \left(k_2^{2/5} \left(\int \mathcal{K}^2(y) dy \right)^{4/5} \right) \left(\int (f''(y))^2 dy \right)^{1/5}.$$

Minimal für **Epanechnikov-Kern**:

$$\mathcal{K}_e(x) = \frac{3}{4\sqrt{5}} \left(1 - \frac{x^2}{5} \right) \mathbb{1}_{[-5,5]}(x).$$

Effizienz $eff(\mathcal{K})$ für $\mathcal{K} \neq \mathcal{K}_e$ und n gegeben:

Zahl $eff(\mathcal{K})$ löst Gleichung $\text{MISE}(n, \mathcal{K}) = \text{MISE}(n \cdot eff(\mathcal{K}), \mathcal{K}_e)$.

Gauß-Kern: Effizienz von ca. 0.95,

Rechteck-Kern: Effizienz von ca. 0.93.

Übersicht

1 Abschnitt 2.1: Univariate Merkmale

2 Abschnitt 2.2: Multivariate Merkmale

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 ...
```

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 $\mathbf{n} = (n_{1.}, n_{2.}, \dots, n_{k.}, n_{.1}, n_{.2}, \dots, n_{.l}) \in \mathbb{N}^{k+l}$ 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$QMKNL <- 1 * (QMKNL <= 8) + 2 * (QMKNL > 8) * (QMKNL <= 10)
+ 3 * (QMKNL > 10) * (QMKNL <= 12) + 4 * (QMKNL > 12);



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

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

Miete versus Wohnlage



Baujahr versus Wohnungsgröße



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 $\mu_2(\mathcal{K})$

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);
```

