


Stochastik–Praktikum

Nichtparametrische Dichteschätzung

Thorsten Dickhaus

Humboldt-Universität zu Berlin

12.10.2010



Einleitung

Zunächst:

$X_1, \dots, X_n$ reellwertige i. i. d. 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
```

Übersicht

- 1 Histogramm–Schätzer und empirische Verteilungsfunktion
- 2 Univariate Kerndichteschätzung
- 3 Bandweitenwahl für Kernschätzer
- 4 Multivariate Kerndichteschätzung

Histogramm–Schätzer

Intervalle („bins“) I_s :

$$I_s = (a_{s-1}, a_s], s \in \{1, \dots, d\}$$


$$n_s := \#\{x_i \in I_s, i \in \{1, \dots, n\}\}$$

$$\hat{f}_{hist}(x) = \frac{n_s}{n} \frac{1}{a_s - a_{s-1}} \mathbb{1}_{\{I_s\}}(x)$$


Im Falle gleicher Intervalllängen mit

$a_s - a_{s-1} \equiv h \ \forall s \in \{1, \dots, d\}$:

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



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



Nachteil des Histogramm-Schätzers:

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


Empirische Verteilungsfunktion

$$F_n(x) = \frac{\#\{x_i | x_i \leq x, i \in \{1, \dots, n\}\}}{n} = \sum_{i=1}^n \frac{1}{n} \mathbb{1}_{(-\infty, x]}(x_i) .$$

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

$$\lim_{n \rightarrow \infty} \sup_{x \in \mathbb{R}} |F_n(x) - F(x)| = 0 \quad \mathbb{P}_f - f.s.$$

```
> ecdf(er)
Empirical CDF
Call: ecdf(er)
x[1:126] = 1.6, 1.667, 1.7, ..., 5.067, 5.1
> summary(ecdf(er))
Empirical CDF: 126 unique values with summary
  Min. 1st Qu. Median Mean 3rd Qu. Max.
1.600 2.271 3.841 3.472 4.429 5.100
```


Empirische Verteilungsfunktion

Gleitendes Histogramm

Durch den gleitenden Histogramm-Schätzer

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

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



Übersicht

- 1 Histogramm–Schätzer und empirische Verteilungsfunktion
- 2 Univariate Kerndichteschätzung**
- 3 Bandweitenwahl für Kernschätzer
- 4 Multivariate Kerndichteschätzung

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

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 der Kernfunktionen



Univariater Kerndichteschätzer

Definition

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


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

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 schätzen durch:

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


Gauß-Kernschätzer (fünf Moden)







Gauß-Kernschätzer (neun Moden)



Gauß-Kernschätzer (50 Moden)





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“

Übersicht

- 1 Histogramm–Schätzer und empirische Verteilungsfunktion
- 2 Univariate Kerndichteschätzung
- 3 Bandweitenwahl für Kernschätzer**
- 4 Multivariate Kerndichteschätzung

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 :

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

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:

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

Varianz

Beweis:

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

Mean Squared Error: Bias–Varianz–Zerlegung

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

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

Anmerkung:

Bias hängt nicht explizit vom Stichprobenumfang n ab.

Optimaler Kern

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

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

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.

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Andere Methoden zur Bandweitenwahl

Methoden der ersten Generation:

- Silverman's „rule of thumb“
- biased und unbiased cross validation

Methoden der zweiten Generation:

- Plug-in Methode von Sheather and Jones
- smoothed Cross Validation
- Kontrastmethoden
- Bootstrap/Jackknife–Methoden

Silverman's „rule of thumb“

Unter Normalverteilungsannahme ($f = \varphi$) kann man die optimale Bandweite (1) in Abhängigkeit von σ berechnen:

$$\int (f''(x))^2 dx = \sigma^{-5} \int (\varphi(x))^2 dx = \frac{3}{8\sqrt{\pi}} \sigma^{-5} \approx 0.212 \sigma^{-5},$$

$$\Rightarrow h_{opt} = \left(\frac{4}{3}\right)^{1/5} \sigma n^{-1/5} \approx 1.06 \sigma n^{-1/5}.$$

Schätzt man σ aus den Daten, lässt sich damit auch h_{opt} schätzen.

Kleinste-Quadrate-Kreuzvalidierung

Betrachte integrierten quadratischen Fehler

$$\int (\hat{f} - f)^2 = \int \hat{f}^2 - 2 \int \hat{f}f + \int f^2.$$

Entscheidend: Mittleren Term schätzen.


(Leave one out) Least Squares Cross Validation (LSCV):

$$\hat{f}_{-i}(x) = \frac{1}{(n-1)h} \sum_{j \neq i} \mathcal{K} \left(\frac{x - X_j}{h} \right).$$

Da der Bias nur von h und $\mathcal{K}$ abhängt, aber nicht von n , gilt:

$$\mathbb{E}_f \left[\frac{1}{n} \sum_i \hat{f}_{-i}(X_i) \right] = \mathbb{E}_f \left[\hat{f}_n(X_n) \right] = \mathbb{E}_f \left[\hat{f}(X) \right].$$

Vergleich von Bandweiten



Übersicht

- 1 Histogramm–Schätzer und empirische Verteilungsfunktion
- 2 Univariate Kerndichteschätzung
- 3 Bandweitenwahl für Kernschätzer
- 4 Multivariate Kerndichteschätzung**

mehrdimensionale Kernfunktionen

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

Definition (p -dimensionaler Kern)

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
- Beschränkter Träger oder zumindest $|\mathbf{x}|\mathcal{K}(\mathbf{x}) \rightarrow 0$ für $|\mathbf{x}| \rightarrow 0$

Mehrdimensionale Kernfunktionen

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

Multivariater Kernschätzer

Definition

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

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

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

Multivariater Kernschätzer

Definition

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

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

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

Bias und Varianz:

$$\text{Bias}_h \left(\hat{f}_n(\mathbf{x}) \right) = \frac{h^2}{2} \Delta f(\mathbf{x}) \int y_1^2 \mathcal{K}(\mathbf{y}) d\mathbf{y} + o(h^2),$$

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

Multivariater Kernschätzer

Definition

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

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



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

Minimierung des MISE:

$$h_{opt}^{p+4} = \frac{p}{n} \frac{\int \mathcal{K}^2(\mathbf{y}) d\mathbf{y}}{\left(\int \mathcal{K}(\mathbf{y}) d\mathbf{y} \right)^2} \left(\int (\Delta f(\mathbf{y}))^2 d\mathbf{y} \right).$$

Darstellung zweidimensionaler Kernfunktionen

Gaußkern und Epanechnikovkern mit $p = 2$



Verschiedene Bandweiten in unterschiedliche Richtungen

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

$$\hat{f}_n(\mathbf{x}) = \frac{1}{n|H|^{1/2}} \mathcal{K} \left(H^{-1/2}(\mathbf{x} - \mathbf{X}_i) \right), \mathbf{x} \in \mathbb{R}^p.$$

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")

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

Zweidimensionale Kerndichteschätzung



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



Literatur



Bernard W. Silverman

Density estimation for statistics and data analysis.

Chapman and Hall/CRC, 1986.



Simon J. Sheather and M.C. Jones

A Reliable Data-Based Bandwidth Selection Method for
Kernel Density Estimation.

Journal of the Royal Statistical Society, 53(3):683-690,
1991.



David W. Scott

Multivariate Density Estimation: Theory, Practice and
Visualization.

New York: Wiley, 1992.

Literatur



J. Steven Marron and Peter Hall and Byeong U. Park
Smoothed Cross–Validation.

Probability Theory and Related Fields, 92:1-20, 2003.



A. R. Mugdadi and Ibrahim A. Ahmad

A Bandwidth Selection for Kernel Density Estimation of
Functions of Random Variables.

Computational Statistics and Data Analysis, 47(1):49-62,
1992.