

Übungen zur Funktionalen Datenanalyse

(Zu bearbeiten bis Montag, den 07.05.2012)

1. Lade die Datei `data02.dat` von der Homepage. Sie enthält (zufällige) Messzeitpunkte x_i in der ersten, und zu diesen Zeitpunkten gemessene Werte y_i in der zweiten Spalte ($1 \leq i \leq 200$). Man kann davon ausgehen, dass die Messwerte zufällige Messfehler ε_i enthalten, die unabhängig und identisch verteilt sind, mit $E(\varepsilon_i) = 0$.

Passen zunächst ein lineares Modell an die Daten an. Verwende dann den Nadaraya-Watson-Schätzer mit einem Rechteckskern und versuche eine passende Bandbreite zu finden. Plote die Punkte, sowie die geschätzten Regressionsfunktionen.

Hinweis: Evtl. ist die Funktion `ksmooth()` hilfreich.

(4 Punkte)

2. Der Datensatz `BostonHousing` enthält Ergebnisse einer Volkszählung aus dem Jahr 1970, zu 506 Gebieten der Stadt Boston. Der Datensatz ist im Paket `mlbench` enthalten und kann mit dem Befehl `data(BostonHousing)` verfügbar gemacht werden. Wir vermuten, dass der prozentuale Anteil an Bewohnern eines Bezirks, die der Unterschicht zugerechnet werden (Spalte `lstat`) den Immobilienpreis des Bezirks beeinflusst. Der Median des Hauspreises des Bezirks befindet sich im Datensatz in der Spalte `medv`.

Passen zunächst ein lineares Modell an. Schätze dann die Regressionsfunktion mit dem Nadaraya-Watson-Schätzer, wie er in der Funktion `npreg` im Paket `np` implementiert ist. Verwende jeweils den Gleichverteilungs-, den Normalverteilungs- und den Epanechnikov-Kern. Verwende jeweils einmal die automatisch ermittelte Bandbreite und einmal eine Bandbreite Deiner Wahl. Plote die Datenpunkte, sowie die Ergebnisse der Schätzungen.

Hinweis: Der Kern kann in der Funktion `npreg()` mit der Option `ckertype="Name"` gewählt werden.

(4 Punkte)

3. X_1, \dots, X_n sei eine Stichprobe zur Dichte $f \in C_2$. Die Dichte f kann mit einem Kerndichteschätzer

$$\hat{f}_n(x; h) := \frac{1}{nh} \sum_{j=1}^n K\left(\frac{x - X_j}{h}\right)$$

geschätzt werden. Dabei sei K ein Kern der Ordnung $(0, 2)$ und $h > 0$.

(a) Zeige: $E\left(\frac{1}{h} K\left(\frac{x - X_1}{h}\right)\right) = f(x) + f''(x) \int_{\mathbb{R}} \frac{h^2}{2} y^2 K(y) dy + o(h^2)$.

(b) Zeige: $\text{Var}(\hat{f}_n(x; h)) = \frac{1}{nh} f(x) \|K\|_2^2 + \mathcal{O}\left(\frac{1}{n}\right)$

(2 + 2 Punkte)