

Oulun yliopisto  
 Matemaattisten tieteiden laitos  
 Funktioiden estimointi  
 10. harjoitus, viikko 13, 2014

1. Muodostamme  $d$ -ulotteisen satunnaisvektorin  $X$  tiheysfunktion  $f$  ydinestimääntöfunktion  $\hat{f}_n(\cdot; H)$  siten, että otos on  $X_1, \dots, X_n$ , ydin on  $K$  ja  $H = h^2 A$ , jossa  $h > 0$  ja  $A$  on positiivisesti definitti  $d \times d$  matriisi.

Osoita, että seuraavalla tavalla saadaan sama estimaatti.

- (i) Määritellään satunnaisvektori  $Y = A^{-1/2} X$  ja sen jakaumasta otos  $Y_i = A^{-1/2} X_i$ .
  - (ii) Ilmaistaan  $X$ :n tiheysfunktio  $f$  satunnaisvektorin  $Y$  tiheysfunktion  $f_Y$  avulla.
  - (iii) Sijoitetaan tulokseen funktion  $f_Y$  tilalle sen ydinestimääntöfunktion  $\hat{f}_Y$ , joka perustuu otokseen  $Y_1, \dots, Y_n$  ja silotusparametrimatriisiin  $h^2 I_d$ .
2. Osoita seuraavat tiheysfunktion  $k$ -lähinaapuriestimaattorin  $\hat{f}_n(\cdot; k)$  ominaisuudet.

- (a) Kun  $k = 1$ , niin estimaatilla  $\hat{f}_n(\cdot; k)$  on napa jokaisessa otospisteessä (ts.  $|\hat{f}_n(x; k)| \rightarrow \infty$ , kun  $x \rightarrow X_i$ ).
- (b) Jos  $k > 1$ , niin  $\hat{f}_n(\cdot; k)$  on jatkuva, mutta derivaatta  $\hat{f}'_n(\cdot; k)$  ei ole jatkuva. (Oletetaan, että otospisteet  $X_1, \dots, X_n$  ovat kaikki erisuuria; näin tapahtuu todennäköisyydellä yksi, jos kyseessä on i.i.d. otos jostakin tiheydestä  $f$ .)
- (c) Integraali  $\int \hat{f}_n(x; k) dx$  on ääretön kaikilla  $k$ .

3. Olkoon satunnaismuuttujaparilla  $(X, Y)$  (ts. vektorilla  $[X \ Y]^T$ ) kaksiulotteinen normaalijakauma  $N(\mu, \Sigma)$ .

- (a) Perustelee, miksi kovarianssimatriisi voidaan aina kirjoittaa muotoon

$$\Sigma = \begin{bmatrix} \sigma_X^2 & \rho \sigma_X \sigma_Y \\ \rho \sigma_X \sigma_Y & \sigma_Y^2 \end{bmatrix},$$

jossa  $-1 \leq \rho \leq 1$ .

- (b) Tarkista, että  $Y$  voidaan kirjoittaa homoskedastisen mallin muotoon

$$Y = m(X) + \sigma \varepsilon,$$

jossa  $\varepsilon$  ja  $X$  ovat riippumattomia,  $\mathbb{E}(\varepsilon) = 0$  ja  $\text{Var}(\varepsilon) = 1$ , ja jossa

$$m(x) = \mu_Y + \rho \frac{\sigma_Y}{\sigma_X} (x - \mu_X),$$

kun kirjoitetaan  $\mu_X = \mathbb{E}X$  ja  $\mu_Y = \mathbb{E}Y$ . Määrää  $\sigma$  suureiden  $\rho$ ,  $\sigma_X$  ja  $\sigma_Y$  avulla. (Oletamme, että  $\Sigma$  on positiivisesti definiitti.)

4. Osoita s. 123 laskuharjoitukseksi jätetty tosiasia: kun  $X$ :n ja  $Y$ :n yhteisjakauksen tiheysfunktio estimoidaan ydinestimaattorilla  $\hat{f}_n(x, y; h^2 I_2)$ , jossa ytimenä on tuloydin  $L(x, y) = K(x)K(y)$  ja  $K$  on kertaluvun kaksi ydin, niin lauseke

$$\frac{\int y \hat{f}_n(x, y; h^2 I_2) dy}{\int \hat{f}_n(x, y; h^2 I_2) dy}$$

on Nadarayan-Watsonin estimaattori pisteessä  $x$ .

5. Kokeile regressiofunktion estimointia `motorcycle`-aineistolla, jonka saat käyttöösi kurssin kotisivun <http://cc.oulu.fi/~11h/FE2007> kautta (tiedosto `mcyc.m`). Aineisto sisältää moottoripyörän törmäyskokeesta mitattuja testinuken pään kiihtyvyyksiä ( $y$ ) ajan ( $x$ ) funktiona.

- (a) Kokeile regressiofunktion estimointia Nadarayan-Watsonin estimaattorilla eri  $h$ :n arvoilla. Käytä Gaussin ydintä.
- (b) Piirrä arvot  $(X_i, W_h(x - X_i))$ , kun  $x$  on lähellä aineiston pienintä ajanhetkeä, ja toisaalta, kun  $x$  on aineiston keskivaiheilla jollakin hyväksi katsomallasi  $h$ :n arvolla. (Tässä  $W_h(x - X_i)$  määriteltiin luennoilla siten, että Nadarayan-Watsonin estimaattori voidaan kirjoittaa arvojen  $Y_i$  painotettuna keskiarvona,  $\hat{m}_n(x; h) = \sum_i W_h(x - X_i) Y_i$ ).