

Neparametriskās statistikas metodes ar pielietojumu laikrindu prognozēšanai

J. Valeinis¹

¹Latvijas Universitāte, Rīga

21.maijs, 2010

Neparametriskās statistikas metodes:

- Blīvuma funkcijas novērtēšana ar kodolu metodēm;
- Regresijas funkcijas novērtējums ar kodolu metodēm un lokālā regresija;
- Butstrapa datu pārkārtošanas metodes;
- Empīriskā ticamības funkcija u.t.t.

Parametriskās metodes (pieņēmumi par populācijas sadalījumu):

- Vislielākās (maksimālās) ticamības funkcijas metode;
- Parametriskā regresija;
- t -tests u.t.t.

Histogramma

Doti X_1, X_2, \dots, X_n iid, kur $X_i \sim f$. Histogramma punktā x :

$$\hat{f}_n(x) = \frac{1}{2hn} \# \{X_i \in [x-h, x+h]\} = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right),$$

kur $K(u) = 0.51_{\{|u| \leq 1\}}$ ir vienmērīgā sadalījuma blīvuma funkcija (kodols) intervālā $[-1, 1]$.

- Histogramma ir neparametrisks blīvuma funkcijas novērtējums!
- Ideja: iegūt gludus (labākus) novērtējumus izvēloties citus (gludus) kodolus!

Kodolu neparametriskais blīvuma funkcijas novērtējums:

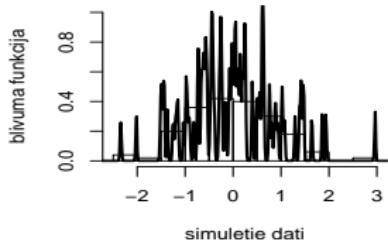
$$\hat{f}_n(x) = \frac{1}{nh} \sum_{i=1}^n K\left(\frac{x - X_i}{h}\right),$$

kur K -kodols, h -joslas platoms.

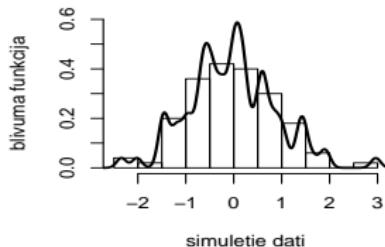
- kodola izvēle K parasti nav būtiska, parasti izvēlas $N(0, 1)$ blīvuma funkciju (Gausa kodols);
- problēma: h izvēle!

Simulēti dati: h izvēle

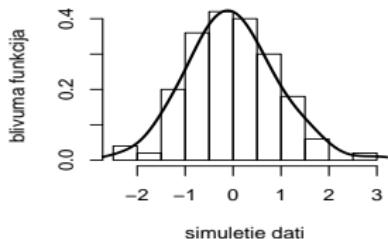
$N(0,1)$, $n=100$, $h=0.01$



$N(0,1)$, $n=100$, $h=0.1$



$N(0,1)$, $n=100$, $h=0.4$



$N(0,1)$, $n=100$, $h=1.5$

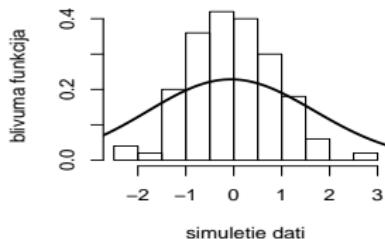


Figure: Kodolu gludināšana ar dažādiem h , kodols - Gausa

Simulēti dati: kodolu izvēle

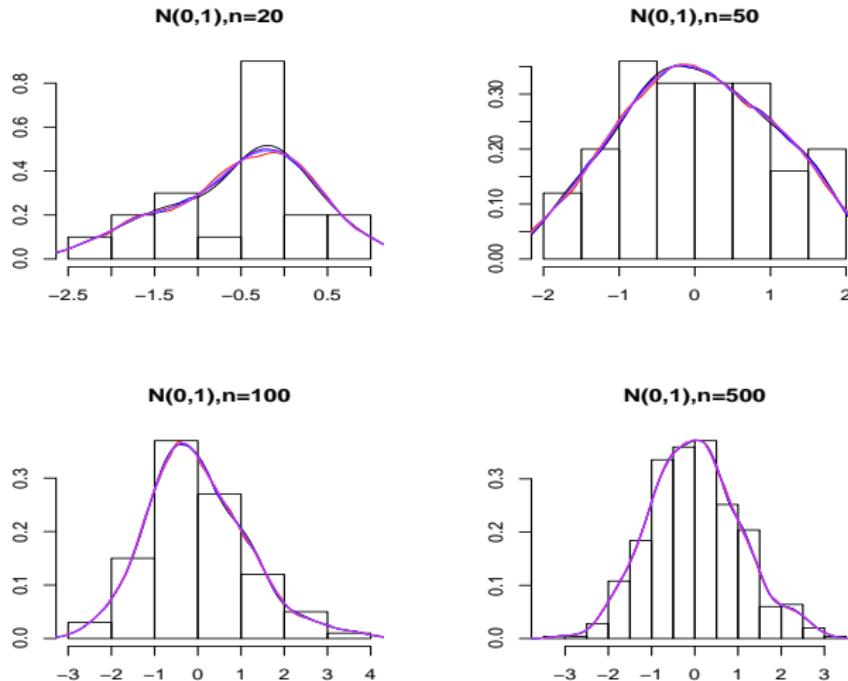


Figure: Kodolu gludināšana ar dažādiem kodoliem: "gaussian", "biweight", "epanechnikov", "rectangular", "triangular", "cosine", h -krosvalidācijas metode

Simulēti dati: histogramma & kodolu novērtējums

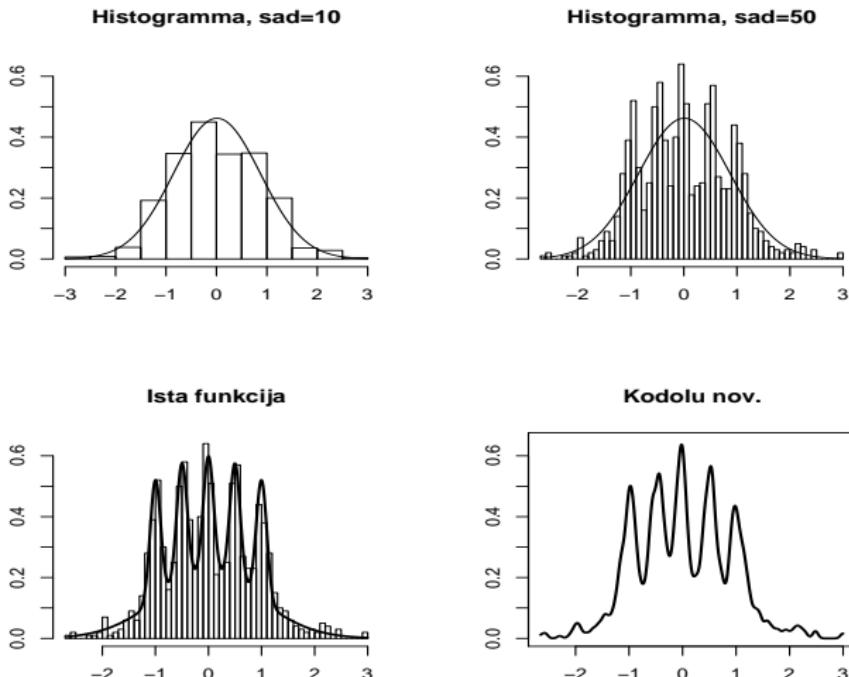


Figure: $n=1000$, p -vērtība KS-testam, Shapiro testam ir < 0.05

Vidējā kvadrātiskā kļūda (MSE) novērtējumam $\hat{f}_n(x)$:

$$\begin{aligned} MSE(\hat{f}_n(x)) &= E((\hat{f}_n(x) - f(x))^2) = \\ &= \frac{h^4}{4} f''(x)^2 \mu_2(K)^2 + \frac{1}{nh} \|K\|_2^2 f(x) + o(h^4) + o\left(\frac{1}{nh}\right), \end{aligned}$$

kur $\mu_2(K) = \int s^2 K(s) ds$ un $\|K\|_2^2 = \int K^2(s) ds$.

- Ideja: mizinimizēt integrētā vidējo kvadrātisko kļūdu:
 $\int MSE(f_n(x)) dx$.

- Optimālais h :

$$h_{opt} = \left(\frac{\|K\|_2^2}{\|f''\|_2^2 \{\mu_2(K)\}^2 n} \right)^{1/5} \sim n^{-1/5}.$$

- Problēma: h_{opt} satur nezināmo f'' .
- "Rule of thumb": ja dati normāli sadalīti, tad $\|f''\|_2^2 = \sigma^{-5} \int \{\varphi''(x)\}^2 dx = \sigma^{-5} \frac{3}{8\sqrt{\pi}} \approx 0.212 \sigma^{-5}$. Tad

$$h_{opt} \approx 1.06 \hat{\sigma} n^{-1/5}.$$

Joslas platumā izvēle: krosvalidācijas metode

Integrētā kvadrātiskā klūda $ISE(h) = ISE(\hat{f}_n)$:

$$\begin{aligned} ISE(\hat{f}_n) &= \int (\hat{f}_n(x) - f(x))^2 dx = \\ &= ISE(h) = \int \hat{f}_n^2(x) dx - 2 \int \{\hat{f}_n f\}(x) dx + \int f^2(x) dx. \end{aligned}$$

- Izvērosim, ka $\int \{\hat{f}_n f\}(x) dx = E(\hat{f}_n(X))$.
- Krosvalidācijas ideja: $E\{\widehat{\hat{f}_h(X)}\} = \frac{1}{n} \sum_{i=1}^n \hat{f}_{h,-i}(X_i)$, kur

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

Lineārā (parametriskā) regresija

Doti datu pāri $(X_1, Y_1), \dots, (X_n, Y_n)$. Regresijas vienādojums

$$Y_i = a + bX_i + \epsilon_i, \quad \mathbb{E}(\epsilon_i) = 0, \quad i = 1, \dots, n,$$

Pieņēmumi: 1) ϵ_i ir neatkarīgi, vienādi sadalīti 2) $\epsilon_i \sim N(0, \sigma^2)$ (homoskedastisks modelis)

Polinomiālā regresija (ar pakāpi n):

$$Y_i = a_0 + a_1 X_i + a_2 X_i^2 + \dots + a_n X_i^n + \epsilon_i.$$

Parametrus a un b novērtē pēc mazāko kvadrātu metodes

$$\sum_{i=1}^n \epsilon_i^2 = \sum_{i=1}^n (Y_i - (a + bX_i))^2 \rightarrow \min!$$

iegūst

$$\hat{b} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad \hat{a} = \bar{y} - \hat{b}\bar{x}.$$

Korelācijas koeficients

$$\rho_{XY} = \frac{\text{cov}(X, Y)}{\sqrt{D(X)}\sqrt{D(Y)}} = \frac{E(XY) - E(X)E(Y)}{\sqrt{D(X)}\sqrt{D(Y)}}.$$

Īpašības

- ① $-1 \leq \rho_{XY} \leq 1$;
- ② Ja $Y = a + bX$, tad $\rho_{XY} = 1$ vai $\rho_{XY} = -1$;
- ③ Ja X un Y neatkarīgi, tad $\rho_{XY} = 0$;
- ④ $R^2 = \rho_{XY}^2$ raksturo, cik liela proporcija no Y datiem tiek izskaidrota ar X datiem.

LIDAR dati: lineārā regresija

Y - logaritms no divu lāzeru mēriju attiecības; X - attālums.

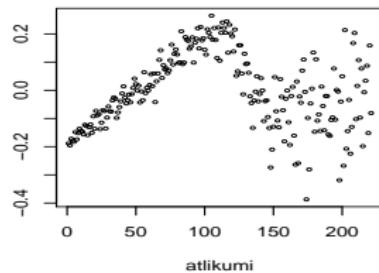
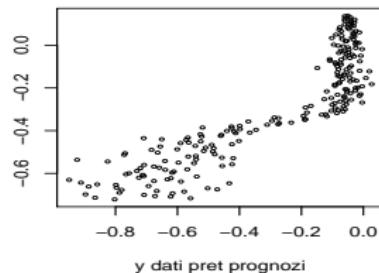
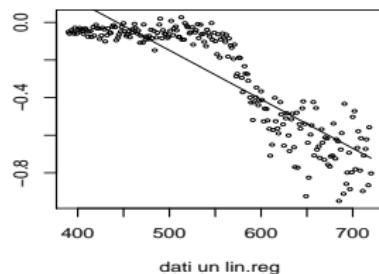
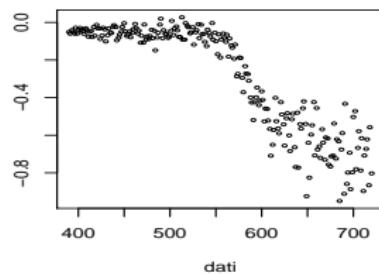


Figure: Lineārā regresija, $n=221$, $R^2 = 0.7827$, normalitāti nevar noraidīt, koeficienti ir nozīmīgi (tas ir var noraidīt $H_0 : a = 0$ un $H_0 : b = 0$)

LIDAR dati: lineārā regresija

Y - logaritms no divu lāzeru mēriju attiecības; X - attālums.

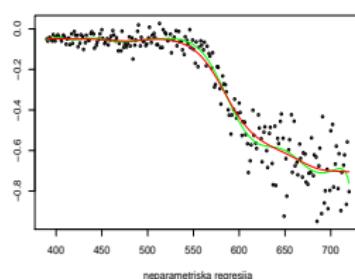
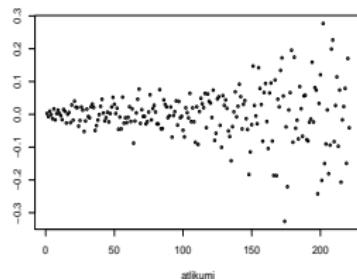
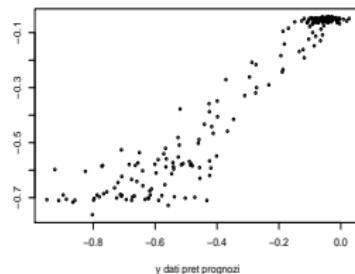
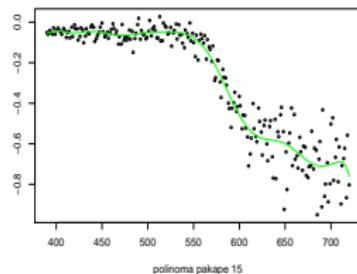


Figure: Polinomiālā (zaļa krāsa) un neparametriskā (sarkanā) regresija,
 $n=221$, $R^2 = 0.9253$, koeficienti ir nozīmīgi līdz 10 kārtai

Polinomu regresija: R izdruka

Coefficients:

		Estimate	Std. Error	t value	Pr(> t)
(Intercept)		-0.291156	0.005381	-54.108	< 2e-16 ***
poly(xx.data, 15)1		-3.706758	0.079994	-46.338	< 2e-16 ***
poly(xx.data, 15)2		-1.091555	0.079994	-13.645	< 2e-16 ***
poly(xx.data, 15)3		0.754951	0.079994	9.438	< 2e-16 ***
poly(xx.data, 15)4		0.617134	0.079994	7.715	5.20e-13 ***
poly(xx.data, 15)5		-0.254850	0.079994	-3.186	0.00167 **
poly(xx.data, 15)6		-0.369616	0.079994	-4.621	6.76e-06 ***
poly(xx.data, 15)7		0.135033	0.079994	1.688	0.09293 .
poly(xx.data, 15)8		0.246893	0.079994	3.086	0.00231 **
poly(xx.data, 15)9		-0.074803	0.079994	-0.935	0.35083
poly(xx.data, 15)10		-0.238201	0.079994	-2.978	0.00325 **
poly(xx.data, 15)11		-0.084672	0.079994	-1.058	0.29109

Signif. codes: 0 ‘***’ 0.001 ‘**’ 0.01 ‘*’ 0.05 ‘.’ 0.1 ‘ ’ 1

Residual standard error: 0.07999 on 205 degrees of freedom

Multiple R-squared: 0.9253, Adjusted R-squared: 0.9198

F-statistic: 169.2 on 15 and 205 DF, p-value: < 2.2e-16

Neparametriskā (kodolu) regresija

Doti datu pāri $(X_1, Y_1), \dots, (X_n, Y_n)$. Regresijas vienādojums

$$Y_i = r(X_i) + \epsilon_i, \quad \mathbb{E}(\epsilon_i) = 0, \quad i = 1, \dots, n,$$

kur $r(x) = \mathbb{E}(Y|X = x)$.

1. Nadaraya-Watson (1978) kodolu novērtējums

$$\hat{r}(x) = \frac{\sum_{i=1}^n K\left(\frac{x-X_i}{h}\right) Y_i}{\sum_{j=1}^n K\left(\frac{x-X_j}{h}\right)},$$

kur K ir kodols (blīvuma funkcija) un h - joslas platums.

Neparametriskā (kodolu) regresija

2. Lokālais lineārais regresijas novērtējums: ideja minimizēt

$$\sum_{i=1}^n (Y_i - a - b(X_i - x))^2 K\left(\frac{X_i - x}{h}\right)$$

Rezultāts:

$$\hat{r}_n(x) = \frac{\sum_{i=1}^n b_i(x) Y_i}{\sum_{j=1}^n b_j(x)},$$

$$b_i(x) = K\left(\frac{X_i - x}{h}\right) (S_{n,2}(x) - (X_i - x) S_{n,1}(x)),$$

$$S_{n,j}(x) = \sum_{i=1}^n K\left(\frac{X_i - x}{h}\right) (X_i - x)^j, \quad j = 1, 2.$$

Lokālais lineārais novērtējums uzlabo robežu novirzi kodolu novērtējumam (svārīgi prognozēšanai)

Neparametriskā (kodolu) regresija: SP500 index

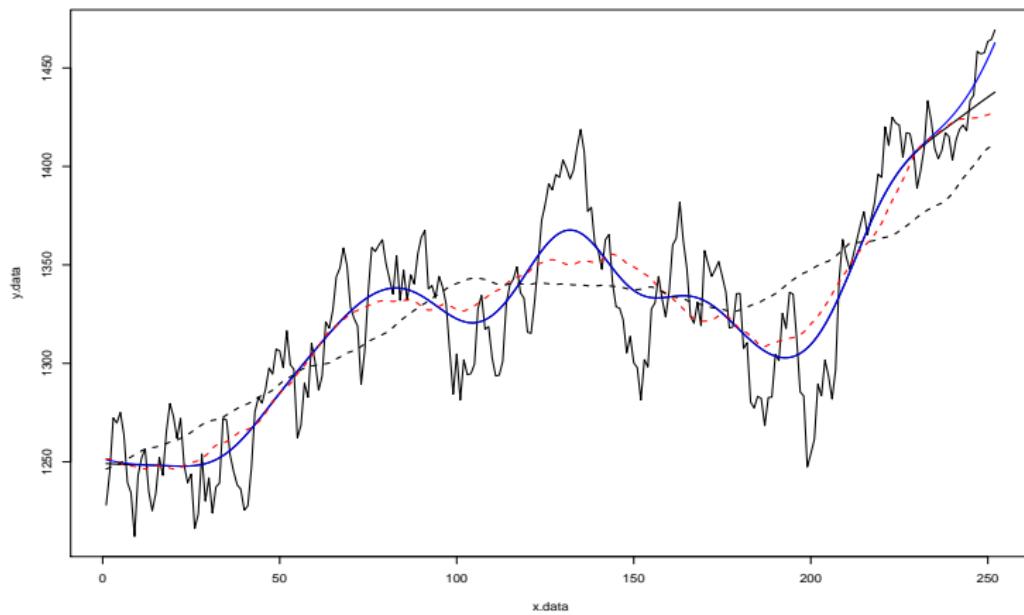


Figure: Neparametriskie regresijas novērtējumi (zilā svītra - lokālais lineārais nov.; melnā svītra - kodolu nov.; sarkanā - slīdošais vidējais (21 dienu intervāls); melnā raustītā - slīdošais vidējais (41 dienu intervāls)).

- Joslas platura noteikšana atkarīgiem datiem (laikrindām, ARIMA modeļiem, jauktiem procesiem). Parastās metodes (krosvalidācija utt.) īsti nestrādā.
- Prognozes veikšana ar neparametrisko regresiju.
- Citi neparametriski gludinātāji: splaini, Veivletu regresija, utt.
- Butstrapa metodes neparametriskajā regresijā.
- Maģistra darbi: Haralds Plivčs (2009), Natālija Saveljeva (2009)