

# Jádrové odhady regresní funkce pro korelovaná data

Lajdová D., Koláček J., Horová I.

Ústav matematiky a statistiky MÚ Brno

Finanční matematika v praxi III., Podlesí  
3.9.-4.9. 2013



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

# Obsah

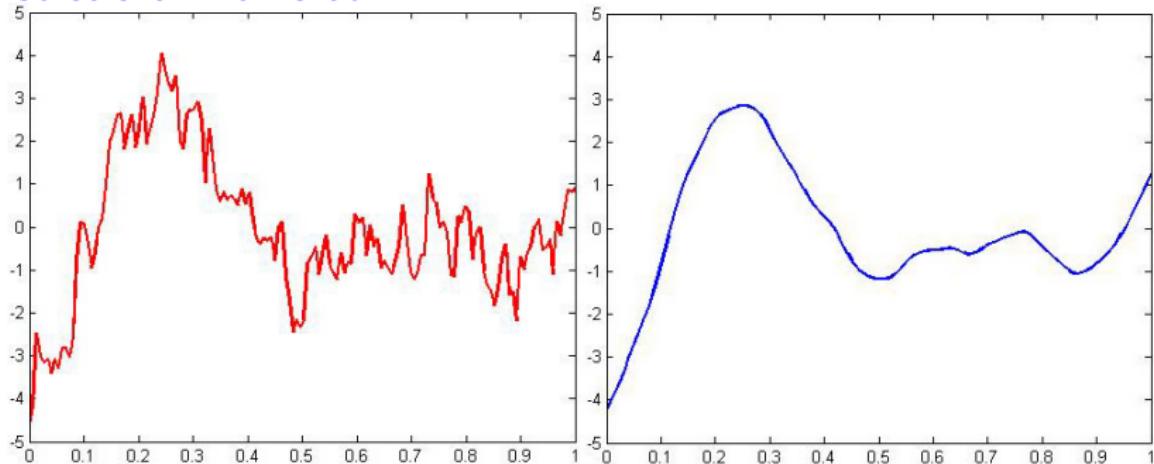
- Motivace
- Základní definice a postup
- Korelovaná data
- Reálná data

# Motivace

Co se snažíme získat?

# Motivace

Co se snažíme získat?



# Regresní model

## Standardní regresní model

$$Y_i = m(x_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

kde

- $m$  - neznámá regresní funkce
- $Y_i$  - měřená data
- $x_i$  - body, ve kterých se provádí měření
- $\varepsilon_i$  - chyby

# Jádro

Co je to jádro?

# Jádro

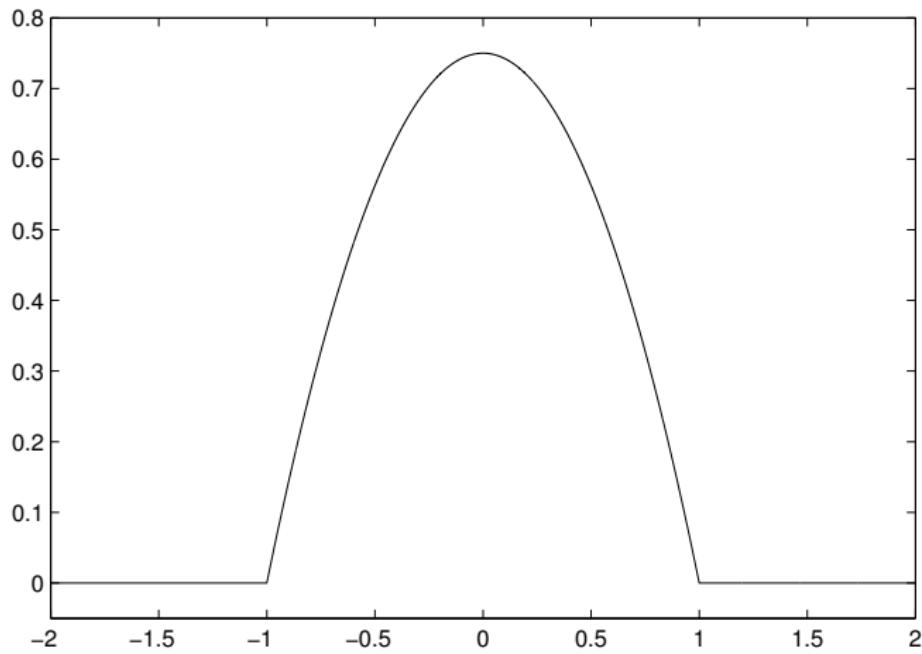
## Co je to jádro?

- Jádro  $K$  je reálná funkce splňující podmínky:

- $K \in \text{Lip}[-1, 1]$ ,  $K(-1) = K(1) = 0$
- $\text{support}(K) = [-1, 1]$

$$\bullet \int_{-1}^1 x^j K(x) dx = \begin{cases} 1 & j = 0 \\ 0 & j = 1 \\ \beta_2 \neq 0 & j = 2 \end{cases}$$

## Epanečníkovo jádro



## Jak se používá?

## Jak se používá?

Nadaraya-Watsonův odhad regresní funkce

$$\hat{m}(x, h) = \sum_{i=1}^n \frac{K_h(x_i - x)}{\sum_{j=1}^n K_h(x_j - x)} Y_i,$$

kde

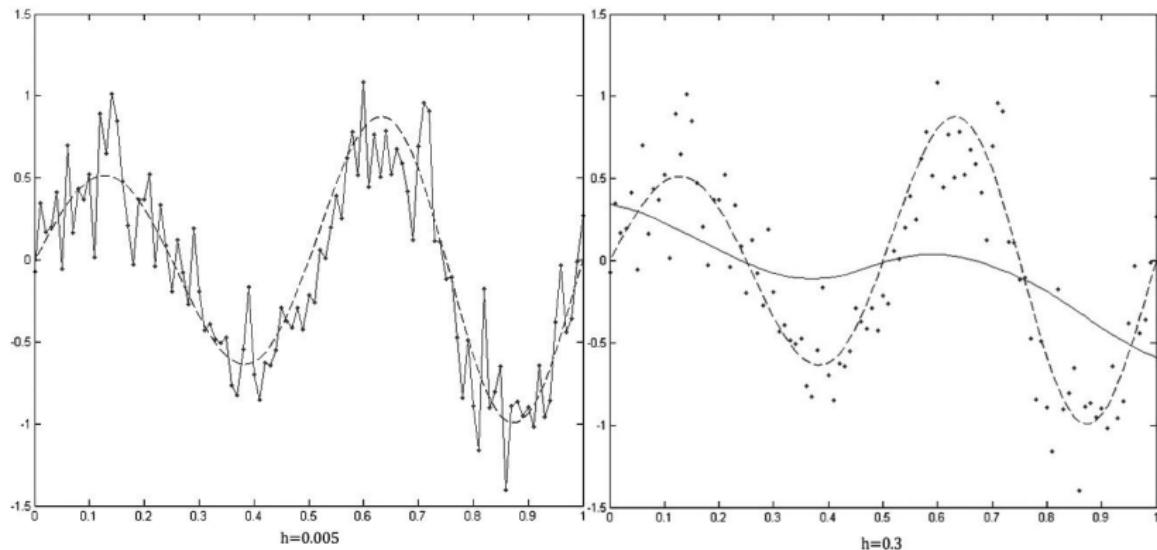
- $K_h(\cdot) = \frac{1}{h} K\left(\frac{\cdot - x}{h}\right)$
- $h$  - vyhlazovací parametr

# Vyhlažovací parametr

Co se stane, když ho zvolíme špatně?

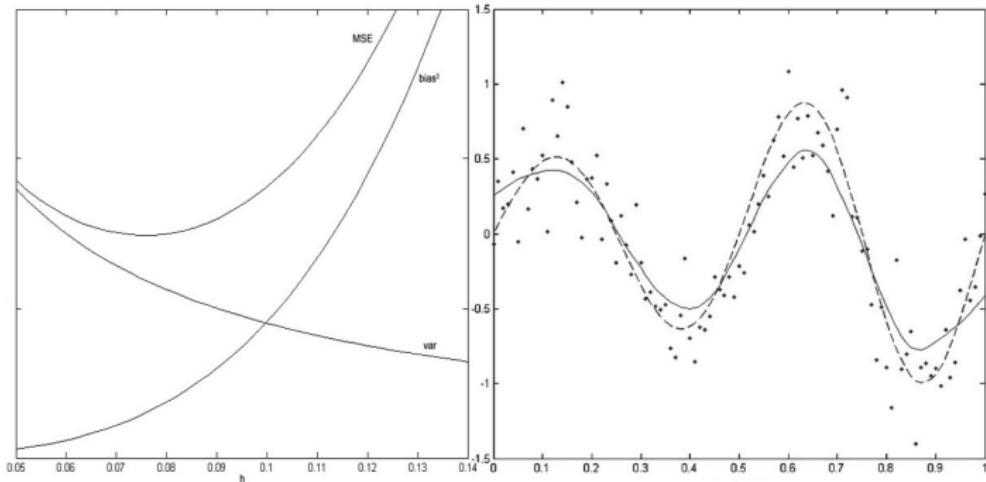
# Vyhlažovací parametr

Co se stane, když ho zvolíme špatně?

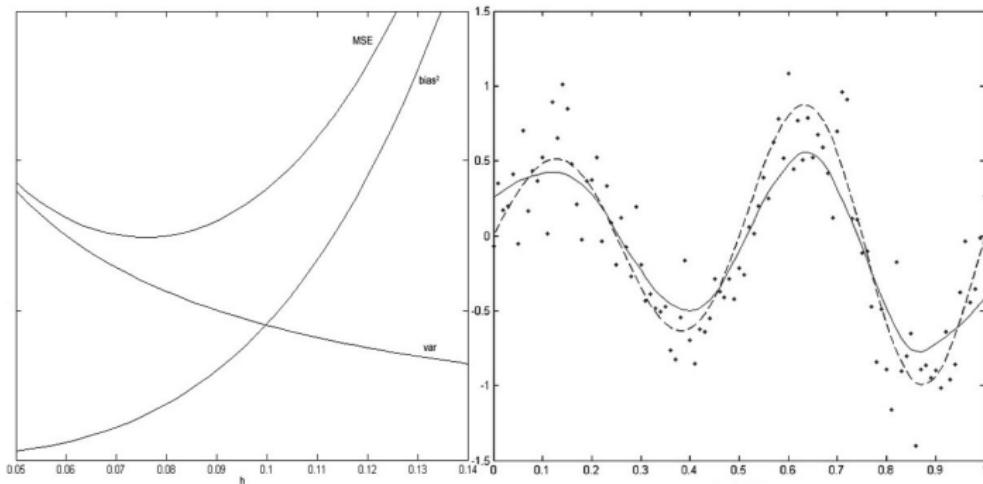


## Jaká je optimální hodnota?

## Jaká je optimální hodnota?



## Jaká je optimální hodnota?



$$h_{opt} = \left( \frac{\sigma^2 \int_{-1}^1 K^2(x) dx}{n \beta_2^2 A_2} \right)^{1/5}, \quad A_2 = \int_0^1 m''(x)^2 dx$$

# Krosvalidační metoda

Jak zvolit správné  $h$ ?

# Krosvalidační metoda

Jak zvolit správné  $h$ ?

$$CV(h) = \frac{1}{n} \sum_{j=1}^n \left( \hat{m}_{-j}(x_j, h) - Y_j \right)^2 \rightarrow \min,$$

kde  $\hat{m}_{-j}(x_j, h)$  je odhad  $m(x_j, h)$ , kde je  $x_j$  smazáno

# Regresní model s korelovanými chybami

Jak se náš model změní?

# Regresní model s korelovanými chybami

Jak se náš model změní?

$$Y_i = m(x_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

kde

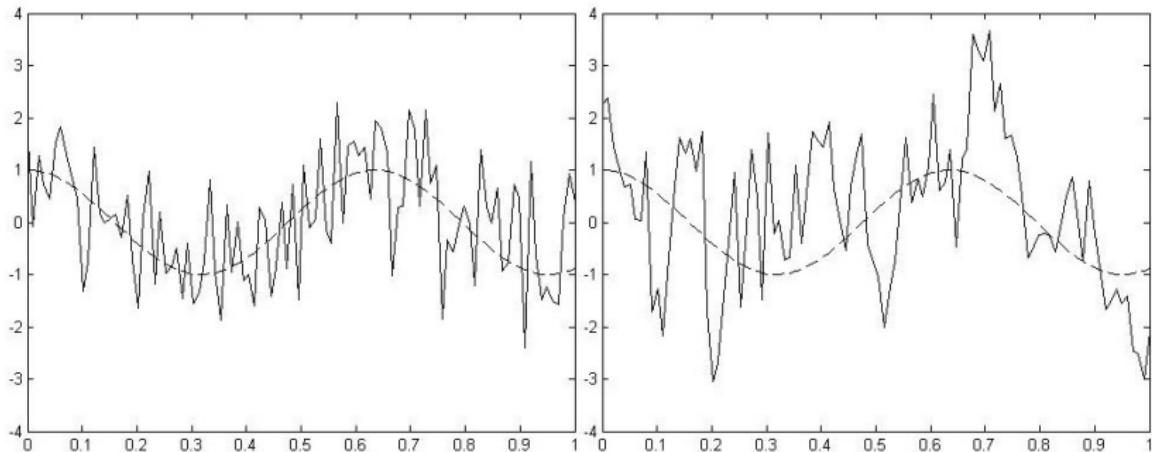
- $\varepsilon_i$  - neznámý kauzální ARMA proces, neboli

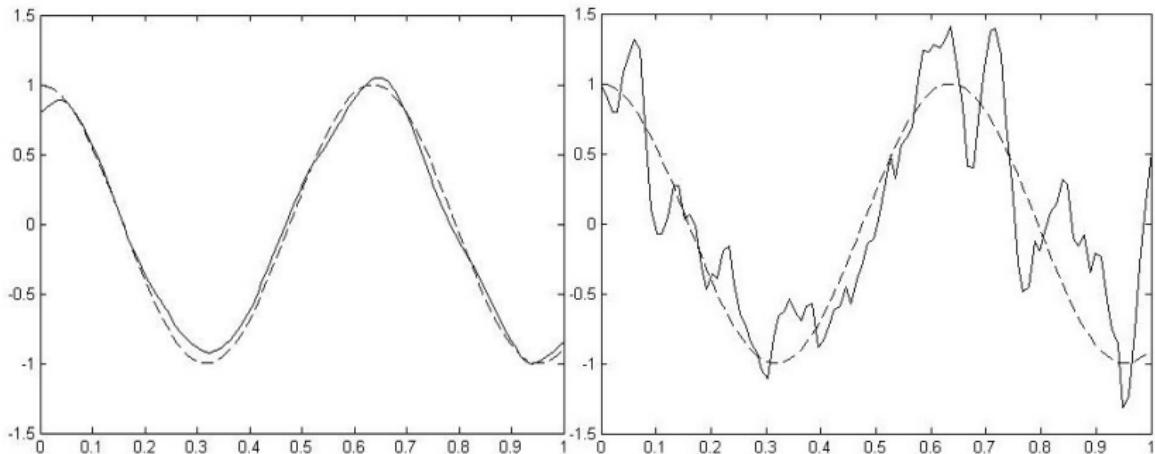
$$\text{E}(\varepsilon_i) = 0, \quad \text{var}(\varepsilon_i) = \sigma^2$$

$$\text{cov}(\varepsilon_i, \varepsilon_j) = \gamma_{|i-j|} = \sigma^2 \rho_{|i-j|}, \quad \text{corr}(\varepsilon_i, \varepsilon_j) = \rho_{|i-j|}$$

## Proč prostě nepoužijeme předchozí metodu?

## Proč prostě nepoužijeme předchozí metodu?





# Plug-in přístup

Můžeme nějak využít optimální hodnotu  $h$ ?

# Plug-in přístup

Můžeme nějak využít optimální hodnotu  $h$ ?

$$h_{opt} = \left( \frac{S \int_{-1}^1 K^2(x) dx}{n \beta_2^2 A_2} \right)^{1/5},$$

$$S = \sum_{k=-\infty}^{\infty} \gamma_k, A_2 = \int_0^1 m''(x)^2 dx$$

# Plug-in přístup

Můžeme nějak využít optimální hodnotu  $h$ ?

$$h_{opt} = \left( \frac{S \int_{-1}^1 K^2(x) dx}{n \beta_2^2 A_2} \right)^{1/5},$$

$$S = \sum_{k=-\infty}^{\infty} \gamma_k, A_2 = \int_0^1 m''(x)^2 dx$$

$$\hat{h}_{PI} = \left( \frac{\hat{S} \int_{-1}^1 K^2(x) dx}{n \beta_2^2 \hat{A}_2} \right)^{1/5}$$

Jak odhadnout  $S$  a  $A_2$ ?

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

- odhadnutím chyb pomocí nějakého počátečního vyhlazení (průměr, přehlazení, ...)

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

- odhadnutím chyb pomocí nějakého počátečního vyhlazení (průměr, přehlazení, ...) - nefunguje

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

- odhadnutím chyb pomocí nějakého počátečního vyhlazení (průměr, přehlazení, ...) - nefunguje
- odhadnutím spektrální hustoty

$$f(\lambda) = \frac{1}{2\pi} \sum_{t=-\infty}^{\infty} e^{-it\lambda} \gamma_t$$

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

- odhadnutím chyb pomocí nějakého počátečního vyhlazení (průměr, přehlazení, ...) - nefunguje
- odhadnutím spektrální hustoty

$$f(\lambda) = \frac{1}{2\pi} \sum_{t=-\infty}^{\infty} e^{-it\lambda} \gamma_t$$

- odhad  $A_2$

## Jak odhadnout $S$ a $A_2$ ?

- odhad  $S$

- odhadnutím chyb pomocí nějakého počátečního vyhlazení (průměr, přehlazení, ...) - nefunguje
- odhadnutím spektrální hustoty

$$f(\lambda) = \frac{1}{2\pi} \sum_{t=-\infty}^{\infty} e^{-it\lambda} \gamma_t$$

- odhad  $A_2$

- pracuje se na tom - viz [Koláček \(2008\)](#)

# Částečná krosvalidace (PCV)

Dá se nějak obejít korelace?

# Částečná krosvalidace (PCV)

Dá se nějak obejít korelace?

- rozdělení pozorování do  $g$  skupin tak, že vezmeme každé  $g$ -té pozorování
- minimalizace průměru obyčejných CV každé skupiny

$$CV^*(h) = g^{-1} \sum_{k=1}^g CV_k(h) \longrightarrow \min$$

# Částečná krosvalidace (PCV)

Dá se nějak obejít korelace?

- rozdělení pozorování do  $g$  skupin tak, že vezmeme každé  $g$ -té pozorování
- minimalizace průměru obyčejných CV každé skupiny

$$CV^*(h) = g^{-1} \sum_{k=1}^g CV_k(h) \longrightarrow \min$$

$h$  minimalizující  $CV^*(h)$

$$\hat{h}_{CV}^* = \arg \min CV^*(h) \implies \hat{h}_{PCV(g)} = g^{-1/5} h_{CV}^*$$

# Částečná krosvalidace (PCV)

Dá se nějak obejít korelace?

- rozdělení pozorování do  $g$  skupin tak, že vezmeme každé  $g$ -té pozorování
- minimalizace průměru obyčejných CV každé skupiny

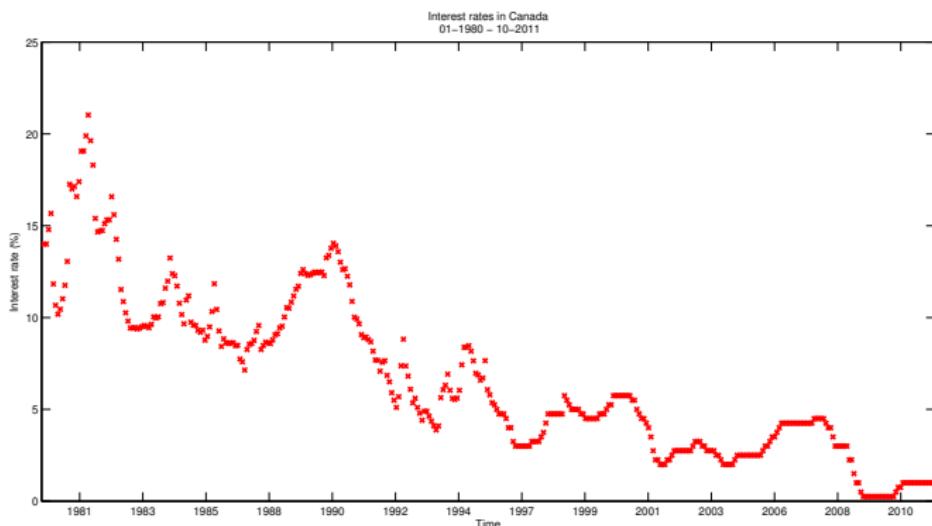
$$CV^*(h) = g^{-1} \sum_{k=1}^g CV_k(h) \longrightarrow \min$$

$h$  minimalizující  $CV^*(h)$

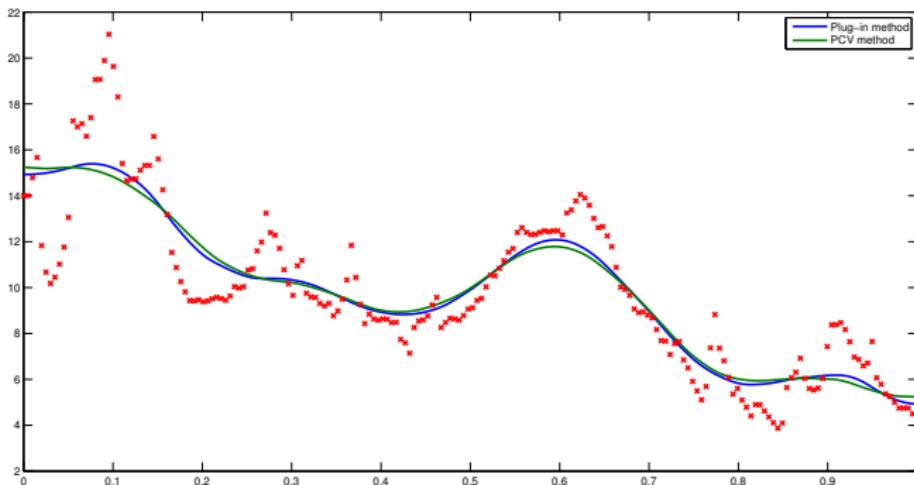
$$\hat{h}_{CV}^* = \arg \min CV^*(h) \implies \hat{h}_{PCV(g)} = g^{-1/5} h_{CV}^*$$

Ale volba  $g$  závisí  $\gamma_k, K, A_2$

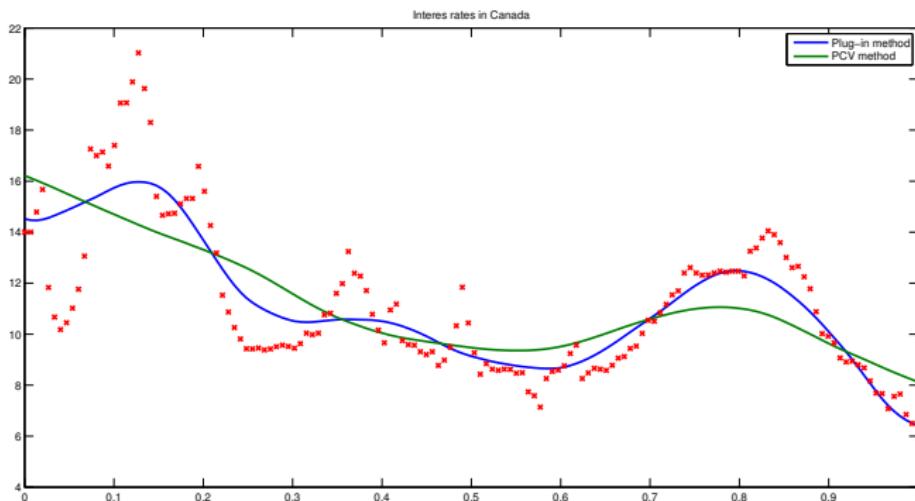
# Úroková míra CB Kanda - 1980-2011



# Prvních 200 měsíců



# Prvních 150 měsíců



# References

-  Altman, N.S.  
Kernel Smoothing of Data With Correlated Errors  
*Journal of the American Statistical Association*, Vol.85, No.411 (Sep., 1990), pp.749-759
-  Bowman, A.W. - Azzalini, A.  
Applied Smoothing Techniques for Data Analysis  
*Clarendon Press, Oxford, 1997*
-  Chu, C.-K. - Marron, J.S.  
Comparison of two bandwidth selectors with dependent errors  
*The Annals of statistics*, Vol.19, No.4 (1991), pp.1906-1918
-  Härdle, W. - Vieu, P.  
Kernel Regression Smoothing of Time Series  
*Journal of Time Series Analysis*, Vol.13, No.3, (May, 1992), pp.209–232

# References



Herrmann, E. - Gasser, T. - Kneip, A.

Choice of Bandwidth for Kernel Regression when Residuals are Correlated  
*Biometrika*, Vol.79, No.4 (Dec., 1992), pp.783-795



Koláček, J.

Plug-in method for nonparametric regression  
*Computational Statistics*, Vol.23, No.1 (Jan., 2008), pp.63-78



Opsomer, J. - Wang, Y. - Yang, Y.

Nonparametric Regression with Correlated Errors  
*Statistical Science*, Vol.16, No.2 (May, 2001), pp.134-153

Děkuji za pozornost