

# NMFM 332 | Statistika pro finanční matematiky 2

---

MFF UK | Letný semester 2022/2023 (prezenčná výuka)



Matúš Maciak | @K151  
<http://www.karlin.mff.cuni.cz/~maciak>

Prednáška: Čt: 09:00–10:30 @K6

Cvičenie: Po: 15:20–18:50 @K2

# Harmonogram výuky

- 14× prednáška / 11× cvičenie | 6 tématických okruhov;
- Korekvizita:** NMFM301 - Statistika pro finanční matematiky;  
*(NMFM301 musí být alespoň zapsán současně s předmětem NMFM310)*
- Deterministické modely**
  - Vyrovnávání dat, klouzavé průměry;
  - Diferenciální rovnice a modely růstu;
  - Lineární regulace a lineární soustavy;
- Stochastické modely**
  - Markovovy řetězce s diskrétním časem a stavovým prostorem;
  - Časové řady, ARMA procesy;
  - Poissonův proces a příbuzné modely;
- Ďalšie podrobnosti:** <http://www.karlin.mff.cuni.cz/~maciak>  
Outline NMFM332: <https://www2.karlin.mff.cuni.cz/~maciak/NMFM332/nmfm332-outline2023.pdf>

## Doplňujúca/doporučená literatúra

- Mandl, P.: **Pravděpodobnostní dynamické modely.**  
Academia Praha, 1985.
- Prášková, Z., Lachout, P.: **Základy náhodných procesů I.**  
Matfyzpress, Praha, 2012.
- Prášková, Z.: **Základy náhodných procesů II.**  
Karolinum, Praha, 2004.

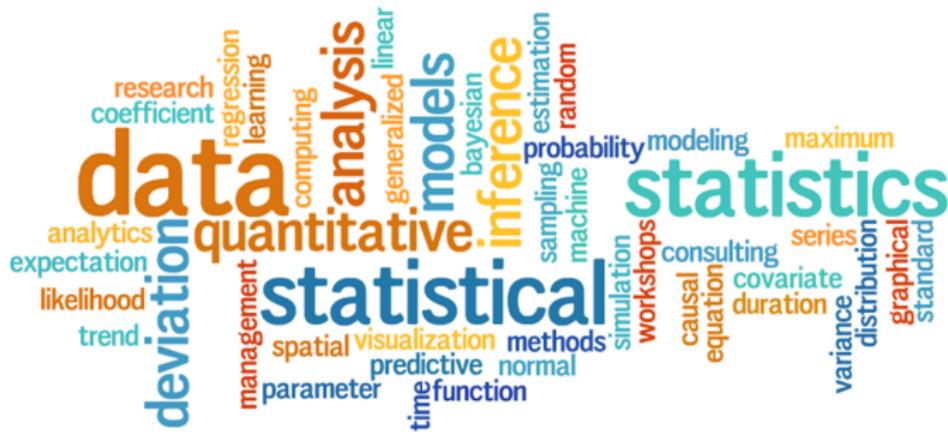
## Doplňujúca/doporučená literatúra

- Mandl, P.: **Pravděpodobnostní dynamické modely.**  
Academia Praha, 1985.
  - Prášková, Z., Lachout, P.: **Základy náhodných procesů I.**  
Matfyzpress, Praha, 2012.
  - Prášková, Z.: **Základy náhodných procesů II.**  
Karolinum, Praha, 2004.
- +
- doplňujúce bibliografické odkazy a referencie uvedené v priebehu prednášky;  
*(Samotný PDF súbor so slidami z prednášky není postačujúcim materiálom pre úspešné zloženie skúšky; Súčasťou skúšky sú aj teoretické odvodenia a dôkazy, ktoré nie sú explicitne uvedené v slidoch, ale budú odvodené vrámci prednášky)*

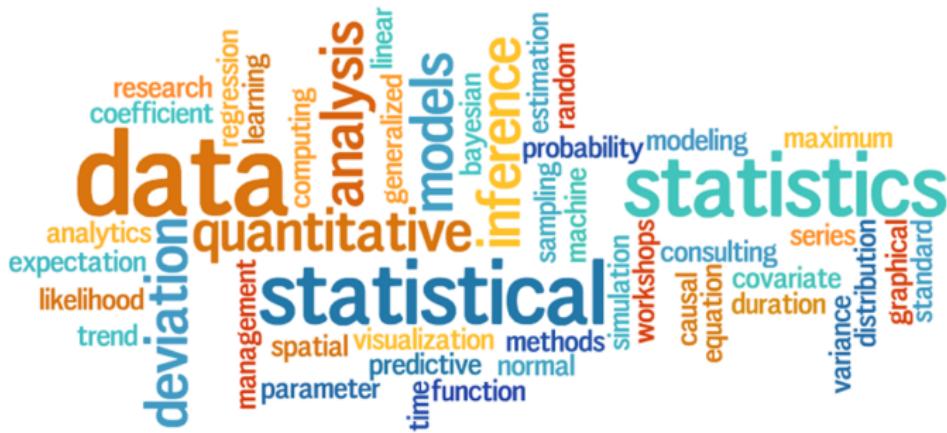
Kapitola 1

# Vyrovnávání dat

# Čo sú to data? Čo je to model? Big data?



# Čo sú to data? Čo je to model? Big data?



- (Anglické) slovo "data" prvykrát použité v roce 1640;
- V zmysle "transmittable and storables computer information" v roku 1946;
- V zmysle "data processing" bolo prvykrát použité v roku 1954;
- Data – konkrétně hodnoty kvalitativních a kvantitatívnych premenných;
- Merané, zbierané, analyzované, reportované a interpretované hodnoty;
- Big data - objemné, rôznorodé, ale strukturované informace (offline/online);

# Data v matematike, stochastike a štatistike

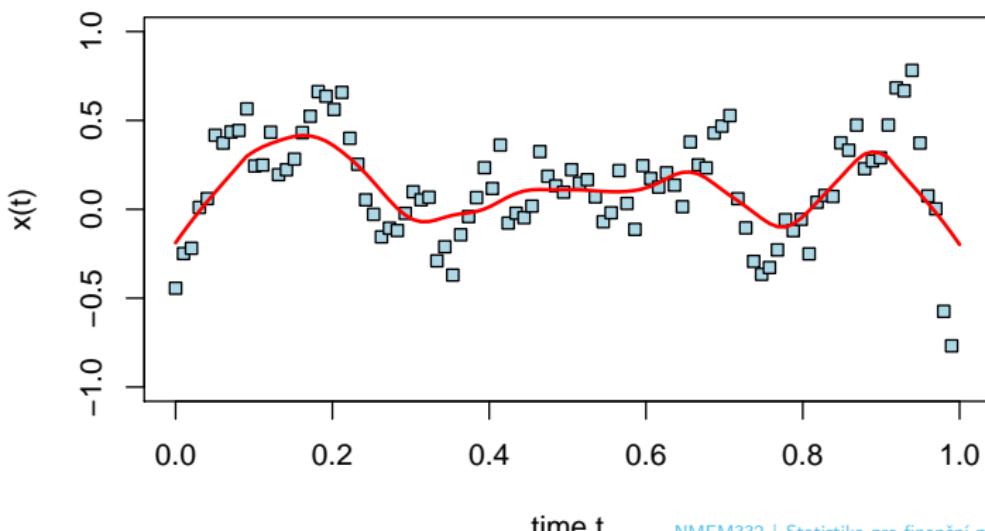
- Data (informácie) môžeme kategorizovať podľa rôznych kritérií, ale z hľadiska matematiky/štatistiky je podstatne rozlišovať **deterministický** a **stochastický** charakter dat;
- V štatistike sa často využíva pojem **náhodný výber**; (nezávisle, stejně rozdelené náhodné veličiny – *i.i.d.* z anglického "*Independent and Identically Distributed* random variables")
- V praxi často **časovo závislá štruktúra pozorovaní** – napr. časové řady; (vývoj hodnot v čase – resp. v diskrétnych časových okamžikoch)
  - napr. hodnota kurzu  $x(t)$  pro  $t \in \{t_1, \dots, t_n\}$ ;
  - alebo vzájomne porovnanie, napr.  $x(t)$  vs.  $y(t)$ ;
  - alebo data  $(x_1, y_1)^\top, \dots, (x_n, y_n)^\top$ , pro uspořádané indexy;
- **Závislé** a často **nestejně rozdelené náhodné veličiny** – n.i.n.i.d.; (jak takéto data analyzovať a jaké (vhodné) metódy/modely používať?)

# Vyrovnávání dat

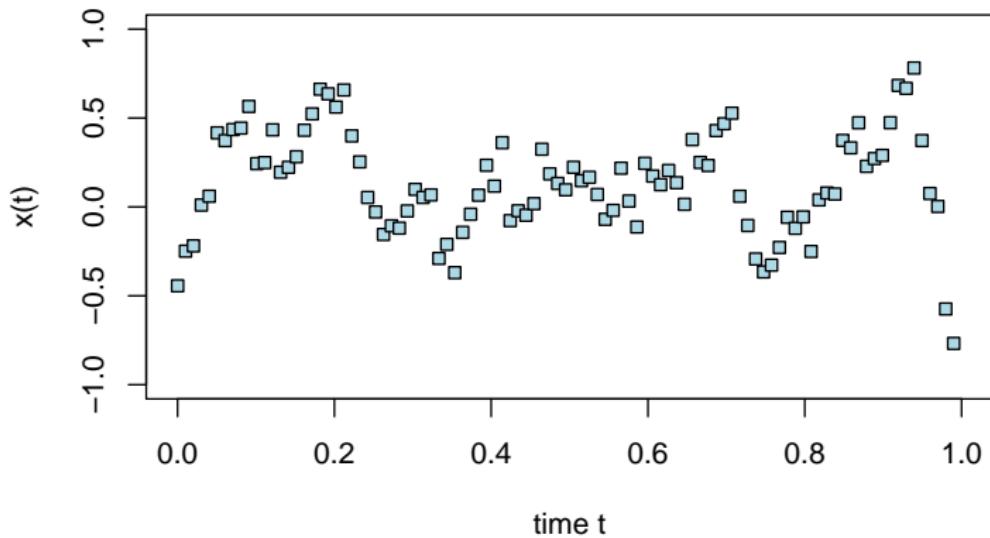
Jedná sa o preloženie dat vhodnou (hladkou) křivkou, která v určitom zmysle vystihuje nejakú základnú vlastnosť dat, ale neberie v potaz drobné chyby, nepresnosti, alebo fluktuace (charakterizace dat).

## Vyrovnávaní dat

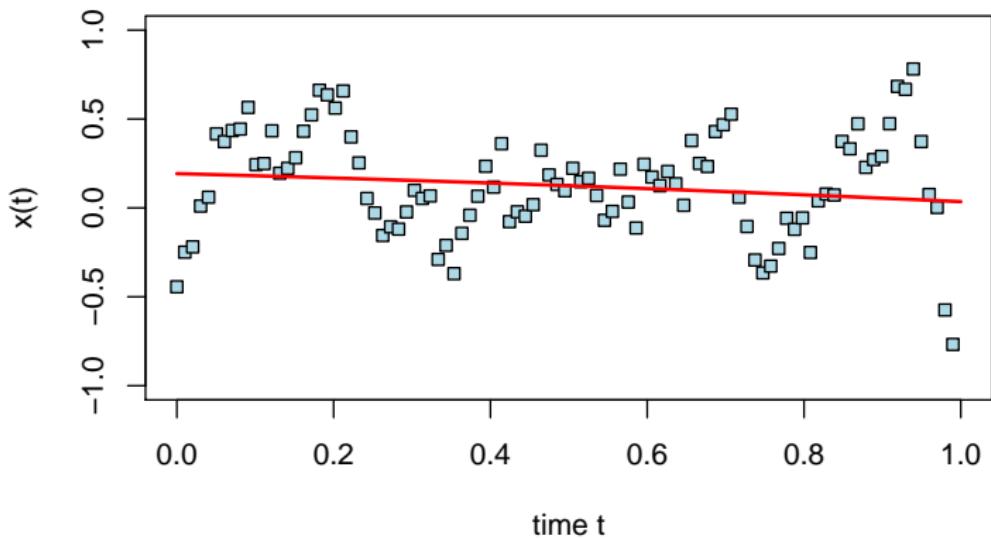
Jedná sa o preloženie dat vhodnou (hladkou) křivkou, která v určitom zmysle vystihuje nejakú základnú vlastnosť dat, ale neberie v potaz drobné chyby, nepresnosti, alebo fluktuace (charakterizace dat).



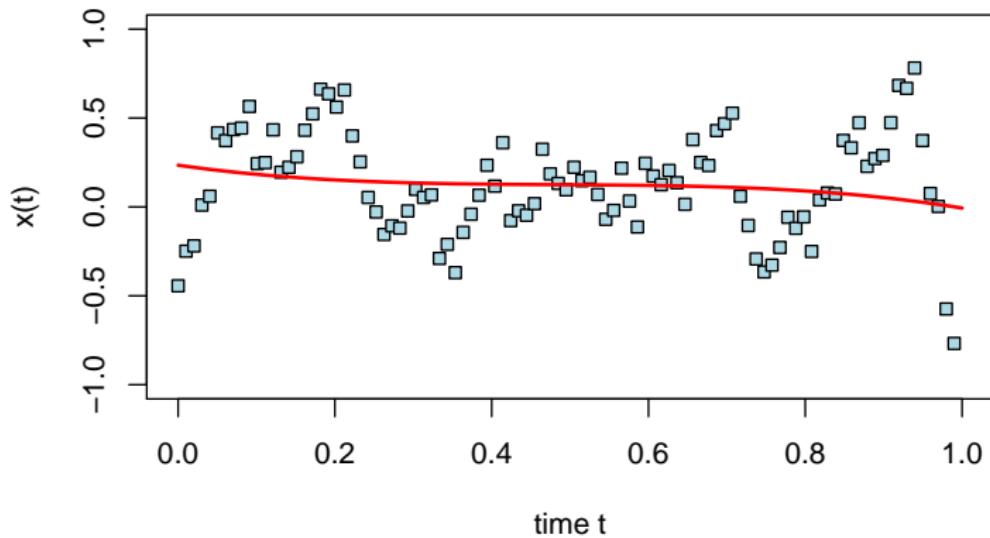
# Jak volit "hladku křivku"? A musí být vždy hladká?



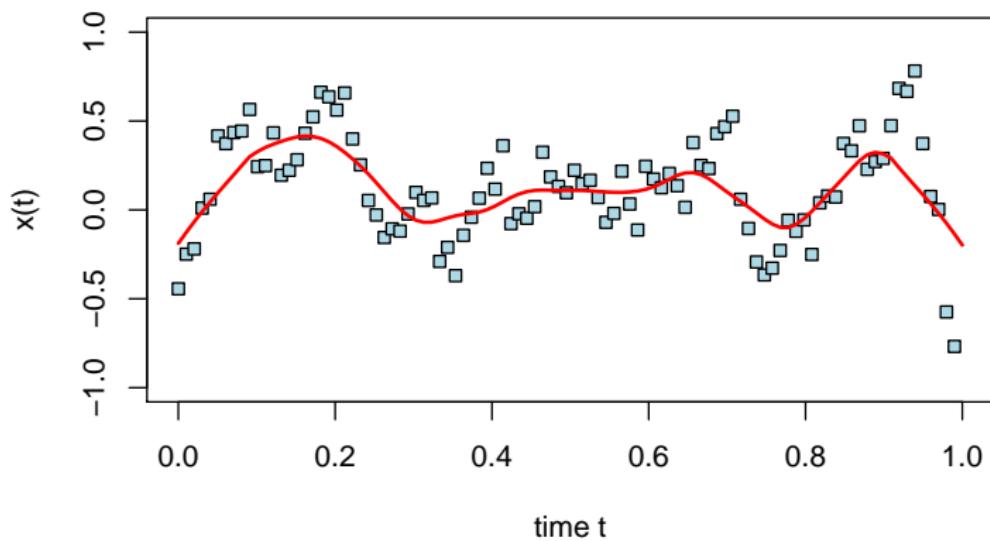
# Jak volit "hladku křivku"? A musí byt' vždy hladká?



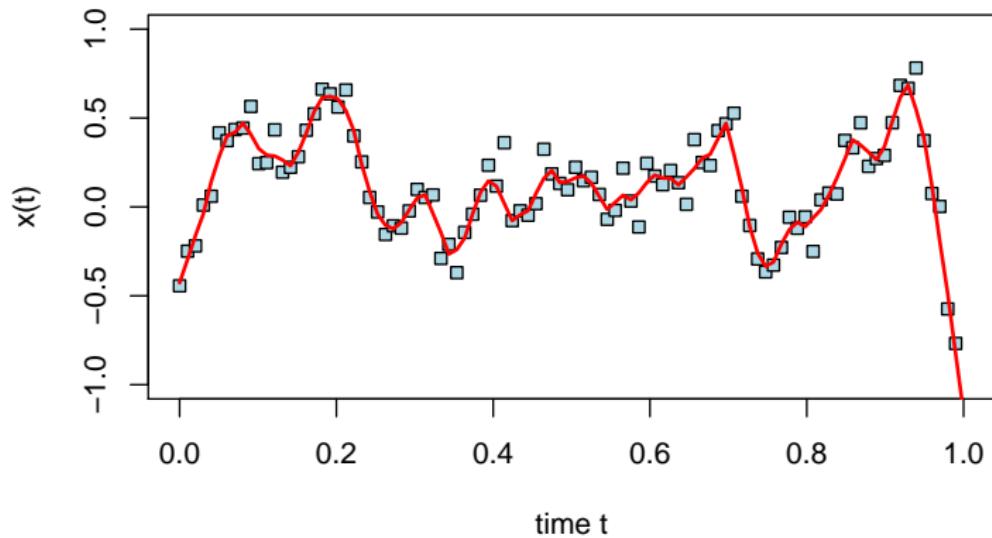
# Jak volit "hladku křivku"? A musí být vždy hladká?



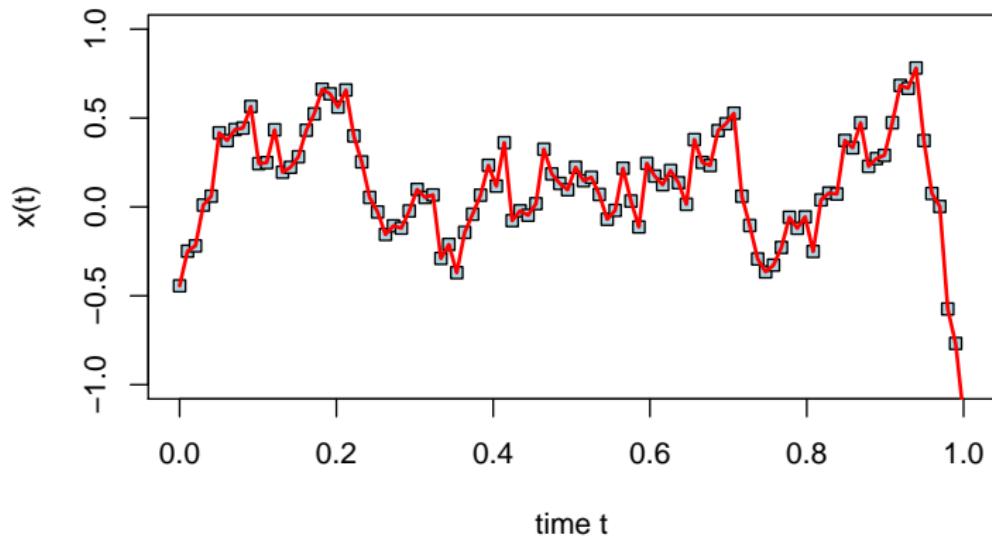
# Jak volit "hladku křivku"? A musí byt' vždy hladká?



# Jak volit "hladku křivku"? A musí být vždy hladká?



# Jak volit "hladku křivku"? A musí být vždy hladká?



# Od parametrických až po neparametrické postupy

V zásade rozlišujeme **tri základné prístupy** pri modelovaní dat, resp. pri prekladaní dat (ne nutně hladkou) křivkou. Základný rozdíl je v celkové míře **flexibility/adaptivity** a **zložitosti/komplexity** výsledného modelu.

## □ Parametrický postup

- **jednoduchosť**  
(jednoduchý model, výpočet, aj interpretácia, priamočiaré vlastnosti)
- **málo flexibilný**  
(príliš triviálny model, ktorý často nedostatečne vystihuje podstatu dat)

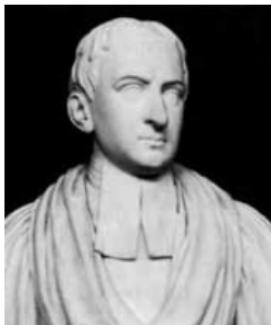
## □ Neparametrický postup

- **výborná flexibilita**  
(bez nutných predpokladov na konkrétny parametrický tvar křivky)
- **príliš zložitý**  
(pomerne náročný na výpočet, zložité vlastnosti a tiež interpretácia)

## □ Semiparametrický postup

- **dostatečne flexibilný, akceptovatelná zložitosť**  
(bez predpokladov na konkrétny tvar, ale pomocou (skrytých) parametrov)
- **málo intuitívny**  
(kombinácia dobrých, ale aj zlých vlastností predchádzajúcich postupov)

# Kde, kedy a ako to začalo?



o Roger Cotes (1682 – 1716)



o Tobias Mayer (1723 – 1762)

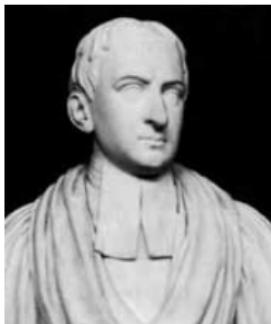


o Pierre-Simon Laplace (1749–1827)



o Roger Joseph Boscovich (1711 – 1787)

# Kde, kedy a ako to začalo?



o Roger Cotes (1682 – 1716)



o Tobias Mayer (1723 – 1762)



o Pierre-Simon Laplace (1749–1827)



o Roger Joseph Boscovich (1711 – 1787)

- 1722 – kombinácia viacerých rôznych pozorovaní uskutočnených za stejných podmínek, namiesto presnej replikácie experimentu (**method of averages**);
- 1750 – štúdium pohybu Mesiaca kolem země v roce 1750 (Tobias Mayer) a sledovanie vzájomného pohybu Jupitera a Saturnu (Laplace);
- 1757 – kombinácia viacerých rôznych pozorovaní uskutočnených za rôznych (kontrolovaných) podmienok pri štúdiu tvaru Zeme Boscovichom (**least absolute deviations**);
- 1799 – chyba aproximácie meraná ako absulútne vzdialenosť vs. kvadrát vzdialenosť vs. metóda vedúca k jej minimalizácii (Laplace vs. Gauss);

# Kalibrácia metódou najmenších štvorcov



Adrien-Marie Legendre (1752 – 1833)



Johann Carl Friedrich Gauss (1777 – 1855)

- Legendre** využil metódu najmenších štvorcov na **fitovanie lineárnych rovnic** na rovnaké data, ktoré využil Laplace na meranie veľkosti a tvaru Zeme. Metóda je popísaná ako algebraicka procedúra;
- Gauss** tvrdil, že metóda je mu známa už od roku 1795. Prepojil metódu najmenších štvorcov least s **princípmi teórie pravdepodobnosti** a definoval metódu odhadovania, ktorá minimalizuje chybu – normálne rozdelenie;

# Metóda nejmenších čtverců

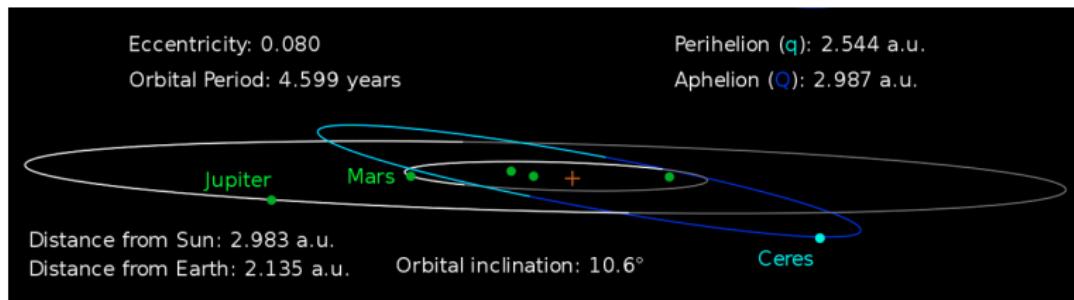


Charles Friedrich Gauss (1777 – 1855)

- metóda sa postupne vyvinula v súvislosti s **astronómiou** a **geodéziou** pri riešení problémov s **navigáciou lodí**;
- **P.Laplace** a **T. Mayer** využili tzv. **metodu priemerov** pre vysvetlenie pohybov nebeských telies již v roce **1750**;
- prvýkrát publikovaná (**Legendre, 1805**) ako algebraický nástroj na **fitovanie lineárnych rovníc** na data;
- **C.F. Gauss** v **1809** publikuje prácu o metode najmenších štvorcov a dáva ju súvislosti s **teóriou pravdepodobnosti** a **normálnym rozdelením**;

## Dôkaz fungovania metódy: Znovuobjavenie Ceres

- ❑ Talianský astronom Giuseppe Piazzi objavil asteroid Ceres 1. Januára 1801 a sledoval ho 40 dní až kým sa asteroid nestratil za žiarou Slnka – posledné pozorovanie (z celkových 24) urobil 11. Februára, 1801.
- ❑ Na základe týchto dat sa astronomovia rozhodli určiť polohu Ceresu po následnom výstupe zpoza Slnka, ale bez nutnosti riešiť zložité Keplerové nelineárne rovnice planetárnych pohybov.
- ❑ Na základe článku a dat publikovaných v časopise *Monatliche Correspondenz* v Septembe 1801, J.C.F. Gauss (v tom čase 24 ročný) bol jediný, kto úspšene predikoval polohu pri znovaobjavení Ceresu.
- ❑ Maďarský astronón Heinrich W. M. Olbers následne našiel Ceres na odhadnutej polohe 31. Decembra, 1801.



# Parametrické vrovnávanie dat

## Křivka jednoznačne určená niekoľkými parametrami

- predem zvolíme tvar hladké křivky napr. parabola  $x \longrightarrow a + bx + cx^2$ ;
- neznáma křivka definovaná pomocou neznámych parametrov  $a, b, c \in \mathbb{R}$ ;
- parametre majú konkrétnu a často priamočiaru interpretáciu;
- odhadu parametrov minimalizáciou súčtu štvorcov odchyiek;
- volba počtu parametrov  $\Rightarrow$  konkrétny tvar a flexibilita křivky;
- rozhodnutí mezi celkovým počtem parametrov a velikosti součtu čtverců;

# Parametrické vyrovnávanie dat

## Křivka jednoznačne určená niekoľkými parametrami

- predem zvolíme tvar hladké křivky napr. parabola  $x \longrightarrow a + bx + cx^2$ ;
- neznáma křivka definovaná pomocou neznámych parametrov  $a, b, c \in \mathbb{R}$ ;
- parametre majú konkrétnu a často priamočiaru interpretáciu;
- odhadu parametrov minimalizáciou súčtu štvorcov odchyiek;
- volba počtu parametrov  $\Rightarrow$  konkrétny tvar a flexibilita křivky;
- rozhodnutí mezi celkovým počtem parametrov a velikosti součtu čtverců;

## There is no free lunch!

- pro dostatečne veľký počet parametrov  $\Rightarrow$  interpolace dat;
- interpolacie  $\Rightarrow$  nulový součet čtverců  $\Rightarrow$  žiadne vyhlazení dat;
- tzv. **Bias-variance Trade-off** (vychýlenie vs. variabilita);  
(rozhodnutie vzhľadom k celkovej flexibilite a komplexite finálneho modelu)

# Metoda nejmenších čtverců – algebraicky

- predpokládame jednoduché data  $\{(x_i, y_i) \in \mathbb{R}^2; i = 1, \dots, n\}$ ;
- obecně predpokládame tvar nějaké (hladké) křivky

$$x \longrightarrow a_1 f_1(x) + a_2 f_2(x) + \cdots + a_p f_p(x),$$

pro nějaké **neznámé parametry**  $a_1, \dots, a_p \in \mathbb{R}$ ;

- označme **odhadnuté hodnoty parametrov** jako  $\hat{a}_1, \dots, \hat{a}_p \in \mathbb{R}$ ;
- pak vyrovnanú hodnotu v datech  $\{(x_i, y_i); i = 1, \dots, n\}$  lze zapsat jako

$$\hat{y}_i = \hat{a}_1 f_1(x_i) + \hat{a}_2 f_2(x_i) + \cdots + \hat{a}_p f_p(x_i),$$

kde  $\hat{y}_i$  značí **vyrovnanú hodnotu** príslušnú hodnotě  $y_i$ ;

- pro skrátený zápis pomocou vektorov používame (**bold**) značení

$$\mathbf{y} = (y_1, \dots, y_n)^\top, \quad \hat{\mathbf{y}} = (\hat{y}_1, \dots, \hat{y}_n)^\top;$$

# Metóda nejmenších čtverců – maticovo

- explicitne po zložkách dostaneme vyrovnané hodnoty ako

$$\hat{\mathbf{y}} = \begin{pmatrix} \hat{y}_1 \\ \vdots \\ \hat{y}_n \end{pmatrix} = \begin{pmatrix} f_1(x_1) & f_2(x_1) & \dots & f_p(x_1) \\ f_1(x_2) & f_2(x_2) & \dots & f_p(x_2) \\ \vdots & \vdots & \ddots & \vdots \\ f_1(x_n) & f_2(x_n) & \dots & f_p(x_n) \end{pmatrix} \cdot \begin{pmatrix} \hat{a}_1 \\ \vdots \\ \hat{a}_p \end{pmatrix}$$

- stručný/alternatívny zápis v maticovom tvare ako

$$\hat{\mathbf{y}} = \mathbb{F} \cdot \hat{\mathbf{a}},$$

kde  $\hat{\mathbf{a}} = (\hat{a}_1, \dots, \hat{a}_p)^\top$  je vektor odhadnutých parametrov a  $\mathbb{F}$  je príslušná matica (niekedy aj tzv. matica modelu);

- odhady neznámych parametrov  $a_1, \dots, a_p \in \mathbb{R}$  jsou definované tak, že minimalizují nejmenší čtverce (součet čtverců odchýlek)

$$\begin{aligned} S(\mathbf{y}) &= \sum_{i=1}^n \left( y_i - \sum_{j=1}^p \hat{a}_j f_j(x_i) \right)^2 = \sum_{i=1}^n (y_i - \hat{y}_i)^2 = \|\mathbf{y} - \hat{\mathbf{y}}\|_2^2 \\ &= (\mathbf{y} - \mathbb{F}\hat{\mathbf{a}})^\top (\mathbf{y} - \mathbb{F}\hat{\mathbf{a}}) = SSe; \end{aligned}$$

# Metóda nejmenších čtverců – formálně

- formálně zapsané, odhad parametrov  $a_1, \dots, a_p$  jsou definované jako riešenie minimalizačného problému

$$\begin{aligned}
 (\hat{a}_1, \dots, \hat{a}_p)^\top &= \underset{a_1, \dots, a_p \in \mathbb{R}}{\operatorname{Argmin}} \sum_{i=1}^n \left( y_i - \sum_{j=1}^p a_j f_j(x_i) \right)^2 \\
 &= \underset{\mathbf{a} \in \mathbb{R}^p}{\operatorname{Argmin}} \|\mathbf{y} - \mathbf{F}\mathbf{a}\|_2^2;
 \end{aligned} \tag{1}$$

- Ide o konvexný problém (minimalizácia konvexnej funkcie, cez konvexnú množinu) a teda existuje globálne minimum, ktoré je riešením normálnych rovíc. Ak má  $\mathbf{F}$  plnú hodnosť, tak existuje jednoznačné riešenie;

## Samostatný úkol

- Ukážte, že problém (1) je naozaj konvexný problém. Za akých podmienok má matica  $\mathbf{F} \in \mathbb{R}^{n \times p}$  plnú hodnosť?
- Dokážte, že dosažené řešení je skutečně globálnim minimem.
- Jaké je řešení úlohy (1), ak by  $\mathbf{F}$  neměla plnou hodnost?

# Metoda nejmenších čtverců – příklad

## Príklad

Uvažujte data  $(y_1, x_1)^\top, \dots, (x_n, y_n)^\top$ , které chceme preložit jednoduchou přímkou, t.j.  $x \rightarrow a_1 + a_2 x$ , pro dva neznámé parametry  $a_1, a_2 \in \mathbb{R}$ .

Najděte explicitné řešení pro rovnici vyhlažovací přímky (t.j., odhady  $\hat{a}_1$  a  $\hat{a}_2$ ).

# Metoda nejmenších čtverců – příklad

## Príklad

Uvažujte data  $(y_1, x_1)^\top, \dots, (x_n, y_n)^\top$ , které chceme preložit jednoduchou přímkou, t.j.  $x \rightarrow a_1 + a_2 x$ , pro dva neznámé parametry  $a_1, a_2 \in \mathbb{R}$ .

Najděte explicitné řešení pro rovnici vyhlažovací přímky (t.j., odhady  $\hat{a}_1$  a  $\hat{a}_2$ ).

## Pravděpodobnostní/stochastická interpretace:

- náhodný vektor  $\mathbf{Y} = (Y_1, \dots, Y_n)^\top$  a jeho realizace  $\mathbf{y} = (y_1, \dots, y_n)^\top$ ;
- predpokládáme, že platí model  $\mathbf{Y} = \mathbb{F}\mathbf{a} + \boldsymbol{\varepsilon}$ ;
- vektor náhodných chyb  $\boldsymbol{\varepsilon} = (\varepsilon_1, \dots, \varepsilon_n)^\top \sim (\mathbf{0}, \sigma^2 \mathbb{I})$ ;
- z vlastnosti střední hodnoty a rozptylu lze přepsát jako

$$\mathbb{E} \mathbf{Y} = \mathbb{F}\mathbf{a} \quad \text{Var } \mathbf{Y} = \sigma^2 \mathbb{I},$$

pro jednotkovou matici  $\mathbb{I} = \text{Diag}\{1, \dots, 1\}$ , typu  $n \times n$ ;

# Regresní model – teoretické vlastnosti odhadu

**Věta:** Střední hodnota a rozptyl odhadu parametru v lineární regrese

Mějme lineárný regresní model  $\mathbf{Y} = \mathbb{F}\mathbf{a} + \boldsymbol{\varepsilon}$ , pro vektor náhodných chyb se složkami s nulovou střední hodnotou  $E\boldsymbol{\varepsilon} = (E\varepsilon_1, \dots, E\varepsilon_n)^\top = (0, \dots, 0)^\top$  a rozptylovou matici  $\text{Var } \boldsymbol{\varepsilon} = \sigma^2 \mathbb{I}$ . Pak platí, že

- odhad parametru  $\mathbf{a} \in \mathbb{R}^p$  metódou nejmenších čtverců je **nestranný** a jeho **rozptyl** je  $\sigma^2(\mathbb{F}^\top \mathbb{F})^{-1}$ ;
- jsou-li navíc  $(y_i, \varepsilon_i)^\top$ , pro  $i = 1, \dots, n$  nezávislé a stejně rozdelené (*i.i.d.*), pak je  $\hat{\mathbf{a}}$  **(silně) konzistentní odhad vektoru  $\mathbf{a}$** ;
- plati-li navíc  $\varepsilon_i \sim N(0, \sigma^2)$  pak odhad parametrů  $a_1, \dots, a_p$  mají také normálné rozdělení a platí, že  $\hat{\mathbf{a}} \sim N_p(\mathbf{a}, \sigma^2(\mathbb{F}^\top \mathbb{F})^{-1})$ ;

Gauss-Marková věta říká, že odhad  $\hat{\mathbf{a}}$  je **nejlepší, nestranný, lineární odhad vektoru parametrov  $\mathbf{a} \in \mathbb{R}^p$**  (tzv. BLUE – Best Linear Unbiased Estimate)

## Parametricky $\Rightarrow$ Semiparametrický postup

Parametre, ktoré sa nachádzajú v modeli nemajú priamy vzťah na tvar neznámej krvky a taktiež nemajú intuitívnu interpretáciu, ako tomu bolo v prípadě parametrických modelov.

- SPLINY - po částech (lokálne) parametrické vyhlazování;**  
*(neznáma krvka je počas definovaná pomocí parametrov, ale parametre nedefinujú priamo tvar dané krvky)*
- Vyhazovanie je proto mnohem flexibilnejší a adaptívnejší;**  
*(kromě samotných neznámych parametrov sú ale potrebné dodatečné parametry – tzv. uzly a tiež množina tzv. bázických funkcií—resp. splinová báze)*
- uzly definujú podintervaly definičného oboru krvky;**  
*(dôležitá je pak otázka, ako uzly správne voliť; v podintervalech sú časti krvky definované rôzne, ale celková krvka má hezké, predem dané vlastnosti)*

# Lokální vyhlazování pomocí Splinů

## Definice: Spline

Nechť  $\xi_1 < \xi_2 < \dots < \xi_k$  je posloupnost vnitřních uzlů (bodů) z definičního oboru  $\mathcal{D} = [\xi_0, \xi_{k+1}]$ . Pak splinem řádu  $\ell \in \mathbb{N} \cup \{0\}$  nazveme libovolnou funkci  $f$  takovou, která je v každém intervalu  $[\xi_j, \xi_{j+1}]$ , pro  $j = 0, \dots, k$  polynomem stupně  $\ell$  a která má v celém definičním oboru  $\mathcal{D} = \bigcup_{j=0}^k [\xi_j, \xi_{j+1}]$  spojité derivace (jednostranné derivace v krajních bodech) až do řádu  $(\ell - 1)$  (včetně).

# Lokální vyhlazování pomocí Splinů

## Definice: Spline

Nechť  $\xi_1 < \xi_2 < \dots < \xi_k$  je posloupnost vnitřních uzelů (bodů) z definičního oboru  $\mathcal{D} = [\xi_0, \xi_{k+1}]$ . Pak splinem řádu  $\ell \in \mathbb{N} \cup \{0\}$  nazveme libovolnou funkci  $f$  takovou, která je v každém intervalu  $[\xi_j, \xi_{j+1}]$ , pro  $j = 0, \dots, k$  polynomem stupně  $\ell$  a která má v celém definičním oboru  $\mathcal{D} = \bigcup_{j=0}^k [\xi_j, \xi_{j+1}]$  spojité derivace (jednostranné derivace v krajních bodech) až do řádu  $(\ell - 1)$  (včetně).

## Príklad

Uvažujte interval  $(0, 1)$  jako definiční obor  $\mathcal{D}$ . Definujte posloupnost uzelů  $0 < \xi_1 < \xi_2 < 1$  a navrhněte spline třetího řádu ( $\ell = 3$ ) na  $\mathcal{D}$  tak, aby splňoval definici.

# Různe splinové bázy

Existuje celá řada různých způsobů, jak definovat splinovu bazu a sestrojit spline.

Nektěré metody jsou intuitivné a jednoduché, ale výpočetně náročné pro velké  $n \in \mathbb{N}$ .

Jiné jsou poměrně zložité a hodně špatně interpretovatelné, ale zase výpočetně stabilnější.

## □ Truncated Splines

- jednoduché, intuitívne, jednoduché na odvodenie;
- výpočetne nestabilné hlavne pre velké  $n \in \mathbb{N}$  (alebo/a veľké  $p \in \mathbb{N}$ );

## □ B-Splines

- výpočetně stabilné a jednoduché pro invertování  $\mathbb{F}$ ;
- obecně pro  $\ell \in \mathbb{N}$  nelze explicitně vyjádriť (napr. De Boor rekurze);

## □ Ortogonálne spliny

- výpočetne veľmi jednoduché, okamžitá invertibilita, numerická stabilita;
- netriviálne na vytvorenie, náročné na interpretáciu;

# Různe splinové bázy

Existuje celá řada různých způsobů, jak definovat splinovu bazu a sestrojit spline.

Nektěré metody jsou intuitivní a jednoduché, ale výpočetně náročné pro velké  $n \in \mathbb{N}$ .

Jiné jsou poměrně složité a hodně špatně interpretovatelné, ale zase výpočetně stabilnější.

## □ Truncated Splines

- jednoduché, intuitívne, jednoduché na odvodenie;
- výpočetne nestabilné hlavne pre velké  $n \in \mathbb{N}$  (alebo/a veľké  $p \in \mathbb{N}$ );

## □ B-Splines

- výpočetně stabilné a jednoduché pro invertování  $\mathbb{F}$ ;
- obecně pro  $\ell \in \mathbb{N}$  nelze explicitně vyjádriť (napr. De Boor rekurze);

## □ Ortogonálne spliny

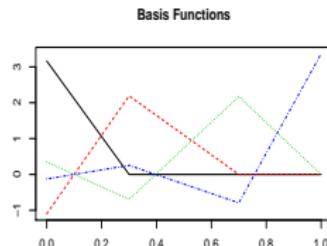
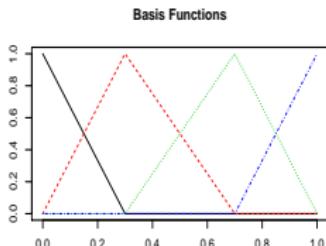
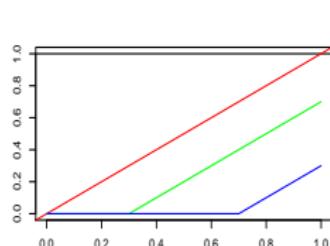
- výpočetne veľmi jednoduché, okamžitá invertibilita, numerická stabilita;
- netriviálne na vytvorenie, náročné na interpretáciu;

## □ Mnoho jiných ...

- Box spliny, M-Spliny, T-Spliny;
- ... ....

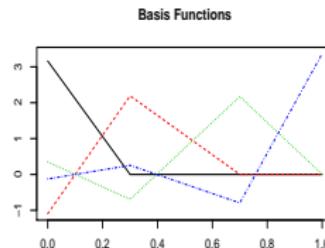
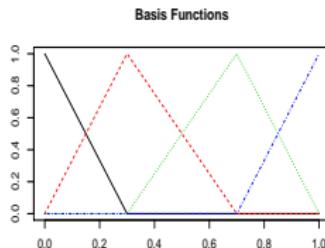
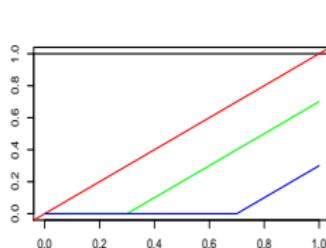
# Porovnání: T-spliny, B-spliny, O-spliny

- Uzly:  $\xi_1 = 0.3, \xi_2 = 0.7$ ; Stupeň  $\ell = 1$  (lineárne spliny (báze));

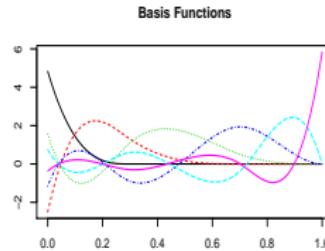
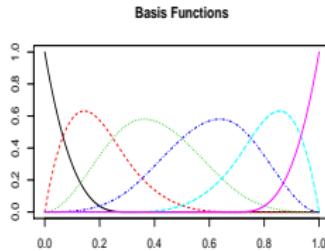
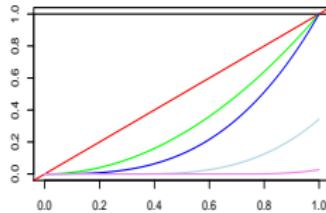


# Porovnání: T-spliny, B-spliny, O-spliny

- Uzly:  $\xi_1 = 0.3, \xi_2 = 0.7$ ; Stupeň  $\ell = 1$  (lineárne spliny (báze));



- Uzly:  $\xi_1 = 0.3, \xi_2 = 0.7$ ; Stupeň  $\ell = 3$  (kubické spliny (báze));



# Truncated splines – "zkosené" spliny

## Príklad

- mějme uzly  $\xi_1 < \xi_2 < \xi_3$  uvnitř  $\mathcal{D}$ , a nechť  $\ell = 1$  (lineární spliny);  
Pak příslušné funkce  $f_1(x), \dots, f_p(x)$  mají následující tvar:

$$\begin{aligned}f_1(x) &= 1, & f_2(x) &= x, & f_3(x) &= (x - \xi_1)_+, \\f_4(x) &= (x - \xi_2)_+, \\f_5(x) &= (x - \xi_3)_+\end{aligned}$$

- pro stejné uzly  $\xi_1 < \xi_2 < \xi_3$  uvnitř  $\mathcal{D}$ , a řád  $\ell = 3$  (kubické spliny);  
Příslušné funkce  $f_1(x), \dots, f_p(x)$  mají tvar:

$$\begin{aligned}f_1(x) &= 1, & f_2(x) &= x, & f_5(x) &= (x - \xi_1)_+^3, \\f_3(x) &= x^2, & f_4(x) &= x^3, & f_6(x) &= (x - \xi_2)_+^3, \\f_7(x) &= (x - \xi_3)_+^3\end{aligned}$$

Pro splinové bázy obecně platí, že  $p = \ell + k + 1$ , kde  $\ell \in \mathbb{N}$  je stupeň splinové bázy, resp. řád splinu a  $k \in \mathbb{N} \cup \{0\}$  je počet vnitřních uzelů  $\xi_1 < \dots < \xi_k \in \mathcal{D}$ .

## Semiparametrický $\Rightarrow$ Neparametrický postup

Bez parametrov - žiadny konkrétny tvar neznáme křivky, ani zápis neznámej křivky pomocí lineárnej kombinace funkci bázy.

- Klouzavé průměry (KP)** – lokálny neparametrický postup vyhlazování; (*schopný zachytit trend – t.j. směr a míru pohybu pozorovaných hodnot*)
- nevystupují tady žiadne neznáme parametre, ktoré bychom odhadovali; (*výsledná vyhlazovací křivka je pouze funkci pozorovaných dat*)
- jedná se o tzv. **lokální vyrovnávání** pozorovaných dat; (*v daném bodě  $x \in \mathcal{D}$  závisí výrovnání pouze od několika sousedů*)
- formálne zapsáno, pro pozorování  $y_i$  získame hodnotu  $\hat{y}_i$  ako

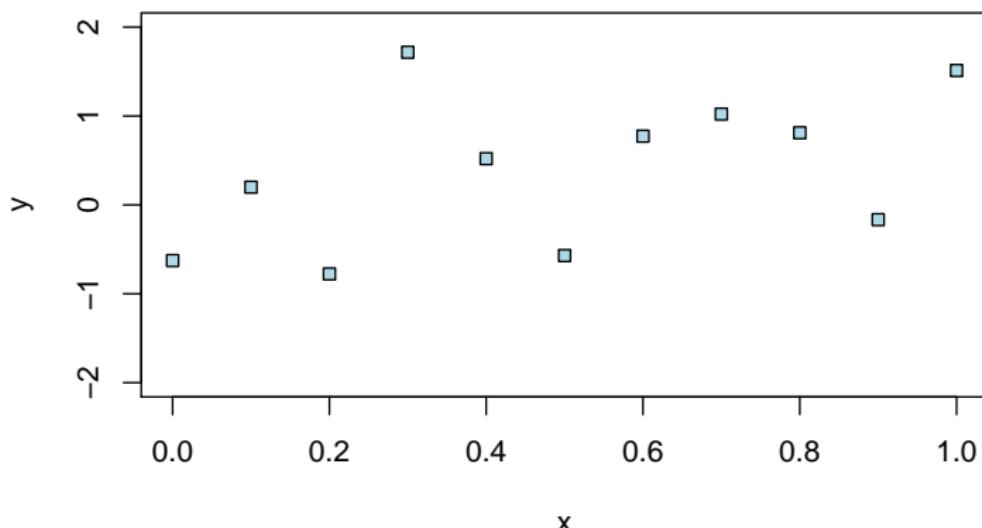
$$\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j} \quad \text{pro } i = r+1, \dots, n-r,$$

čo je vlastne vážený priemer niekoľko predchádzajúcich pozorovaní a rovnakého počtu následujúcich pozorovaní;

- pro váhy  $w_j$  pláti, že  $\sum_{j=-r}^r w_j = 1$ ;  
(číslo  $r \in \mathbb{N}$  se nazýva **dĺžka klouzavého průměru**)

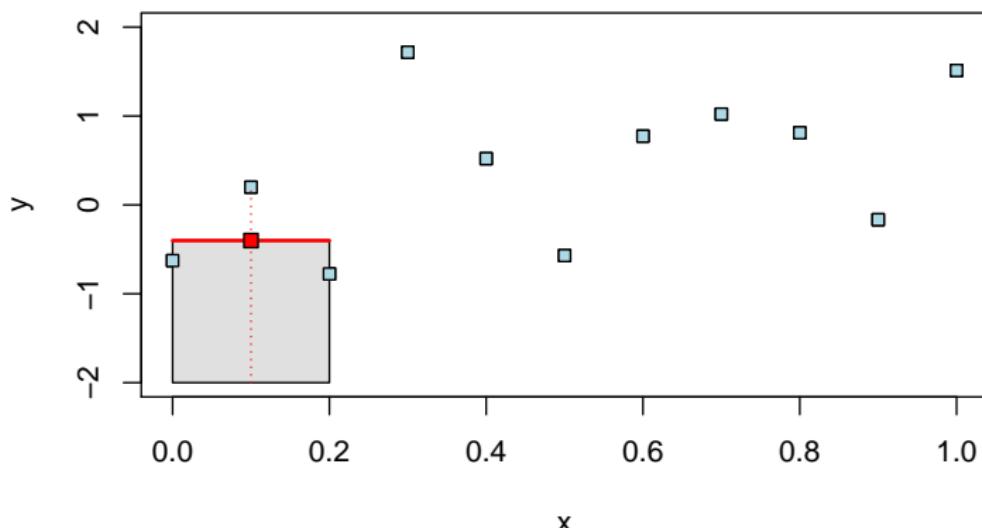
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



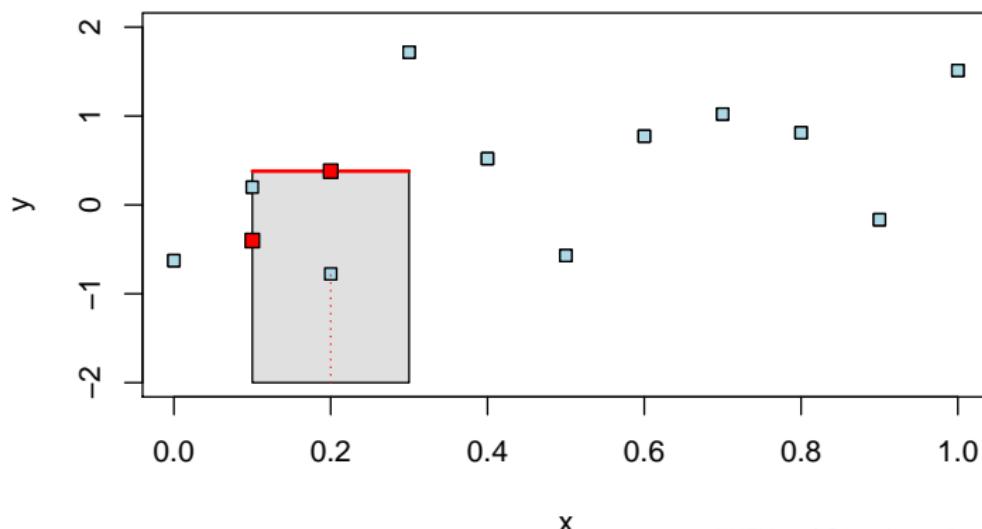
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



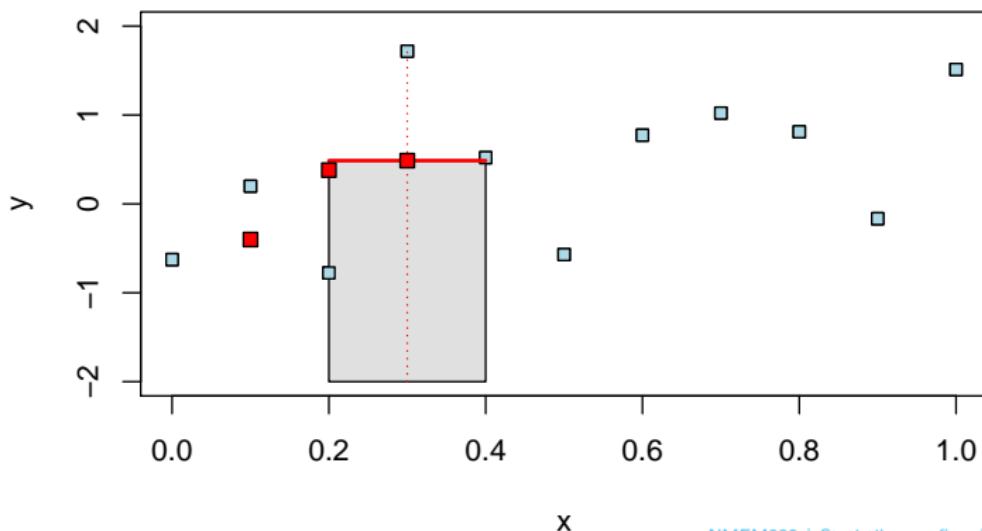
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



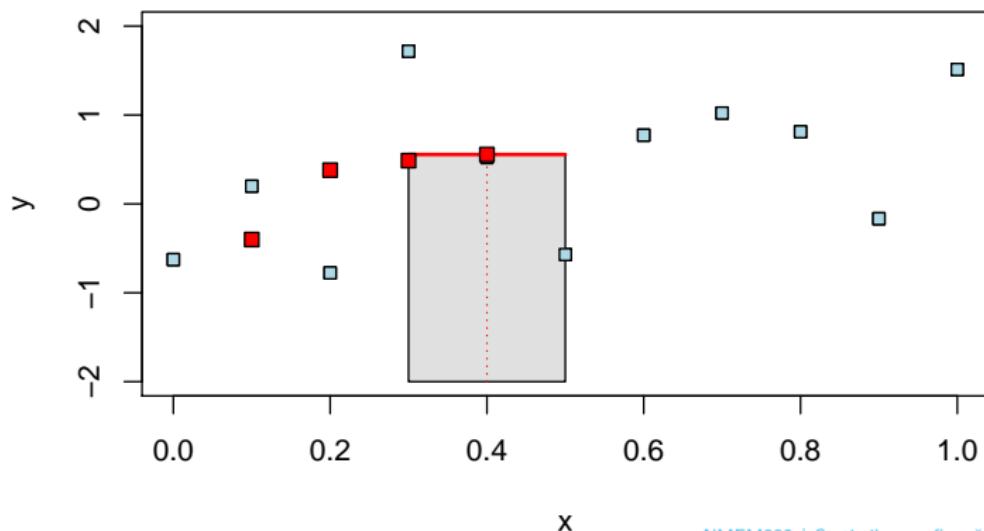
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



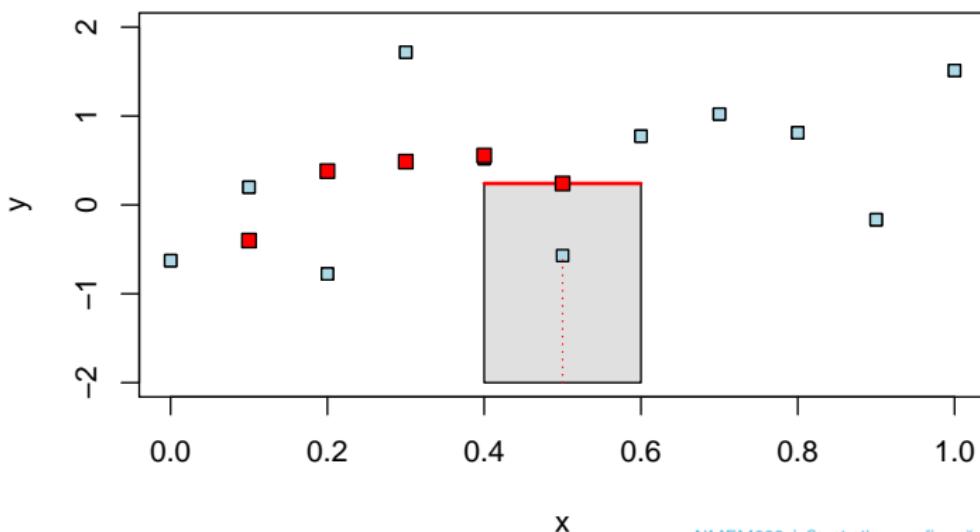
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



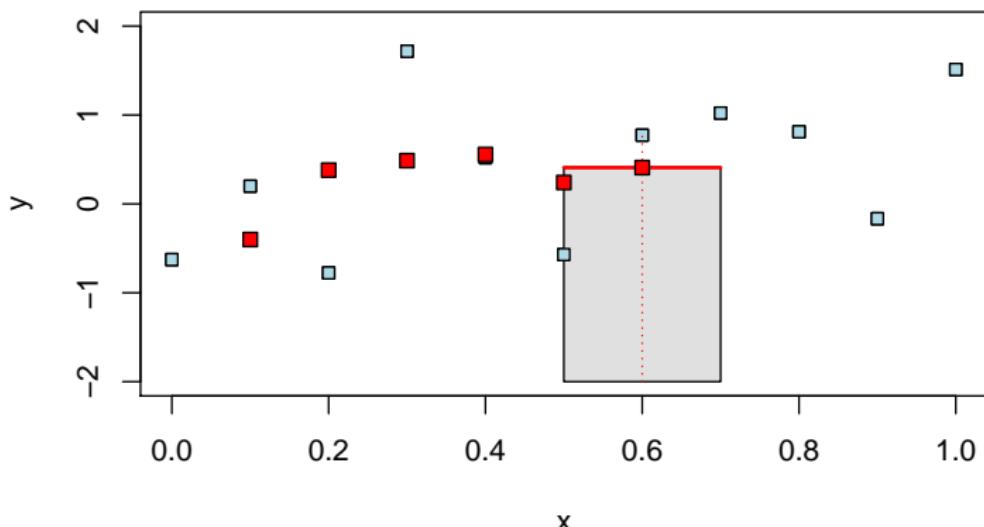
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



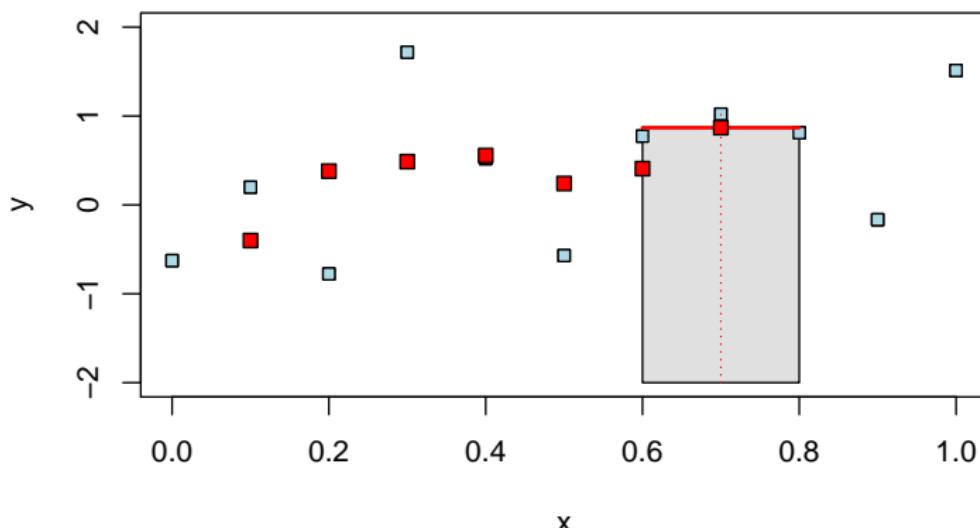
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



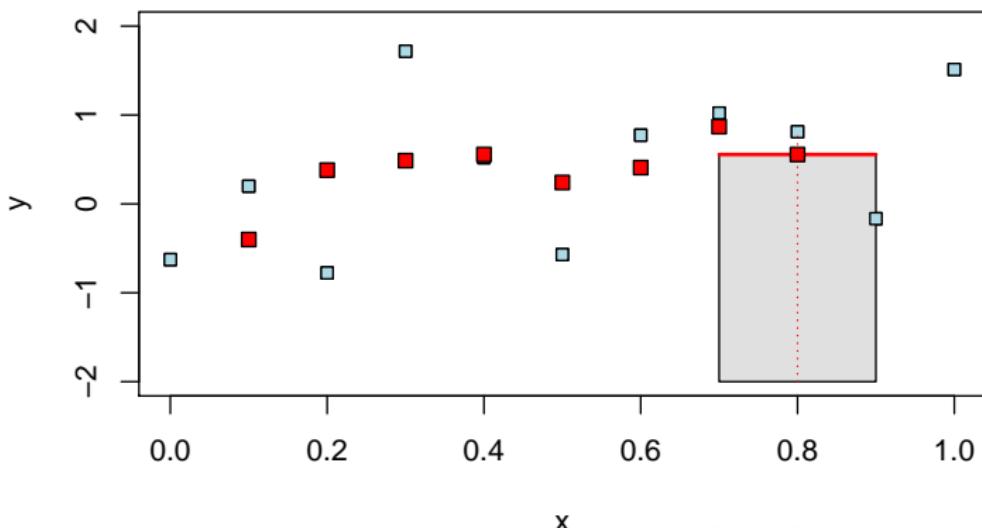
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



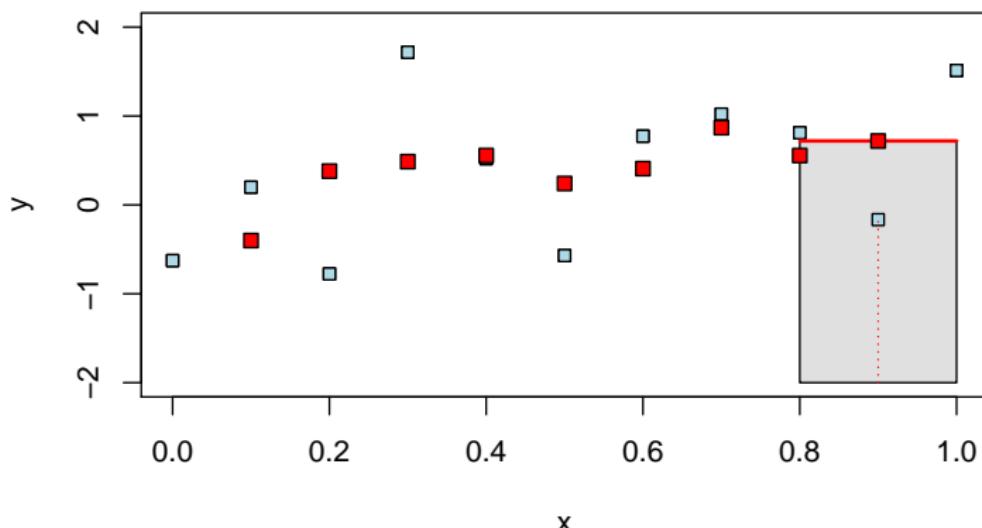
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



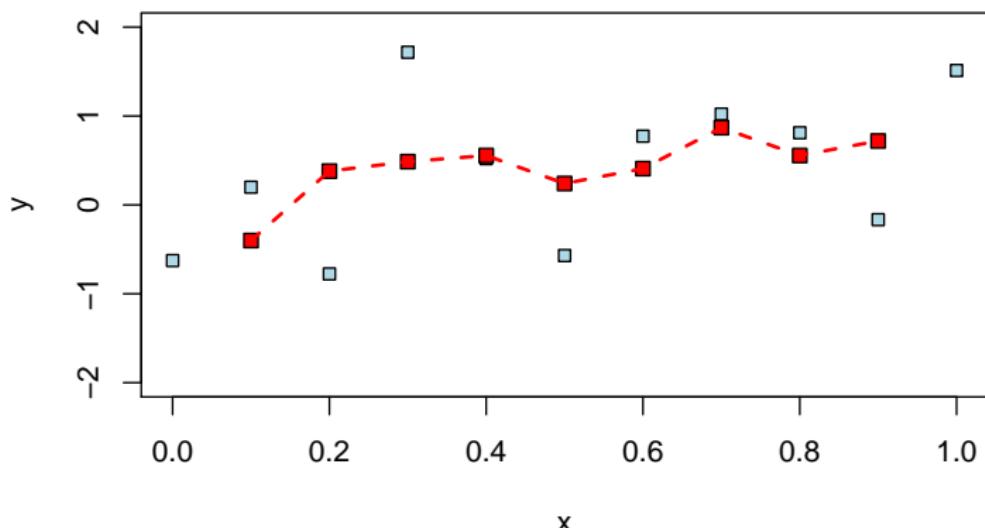
## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



## Obyčejné (aritmetické) klouzavé průměry (KP)

- vyhlazené hodnoty jsou definovány jako  $\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j}$ , ale pouze pro data  $y_i$  kde  $i = r+1, \dots, n-r$ ;
- pro váhy  $w_j$  platí, že  $w_j = \frac{1}{2r+1}$  a tiež  $\sum_{j=-r}^r w_j = 1$ ;
- pro  $r=1$  dostaneme  $\hat{y}_i$  pomocí  $y_i$  a dvou vedlejších sousedů;



# Jak definovat váhy $w_j$ pro KP?

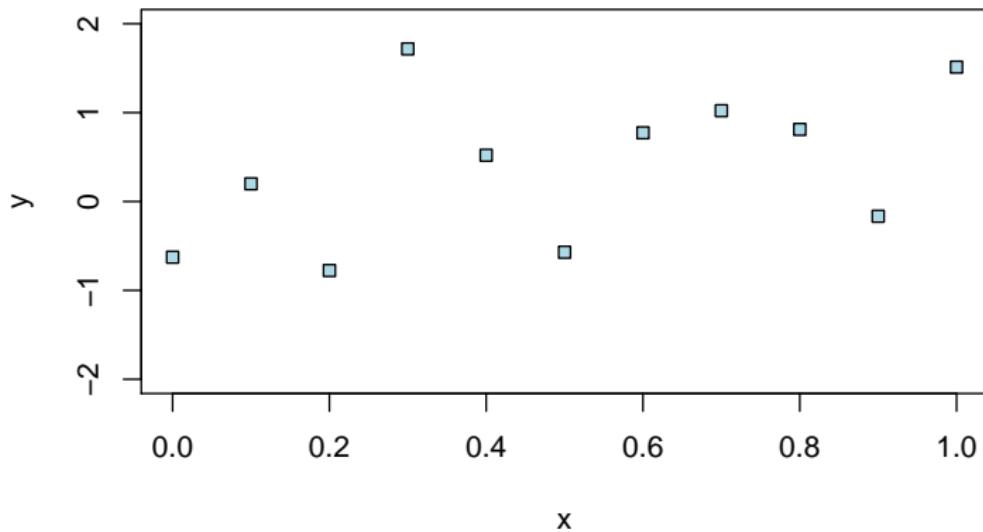
- Stejné váhy pro všechny  $j = -r, \dots, r$ :
  - jednoduchost,  $w_j = \frac{1}{2r+1}$  a vyrovnaná hodnota  $\hat{y}_i$  je pouze obyčejný aritmetický průměr z  $2r+1$  okolních hodnot, navíc nezáporne váhy;
  - není vyrovnán počáteční a koncový úsek dat (potřebná data nejsou k dispozici) a obecně se nejedná o hladkou křivku v  $\mathcal{D}$ ;

# Jak definovat váhy $w_j$ pro KP?

- Stejné váhy pro všechny  $j = -r, \dots, r$ :
  - jednoduchost,  $w_j = \frac{1}{2r+1}$  a vyrovnaná hodnota  $\hat{y}_i$  je pouze obyčejný aritmetický průměr z  $2r+1$  okolních hodnot, navíc nezáporne váhy;
  - není vyrovnán počáteční a koncový úsek dat (potřebná data nejsou k dispozicii) a obecně se nejedná o hladkou křivku v  $\mathcal{D}$ ;
- Obecně různé váhy pro  $w_j, j = -r, \dots, r$ :
  - při správne volbě lze dosáhnout hladkou křivku v celém definičním oboru  $\mathcal{D}$  a lze vyrovnat aj počátečné a koncové hodnoty;
  - nutnosť dodatečných výpočtov, prípadně zavedenie nějakých ďalších (rušivých/ladiacích) parametru;

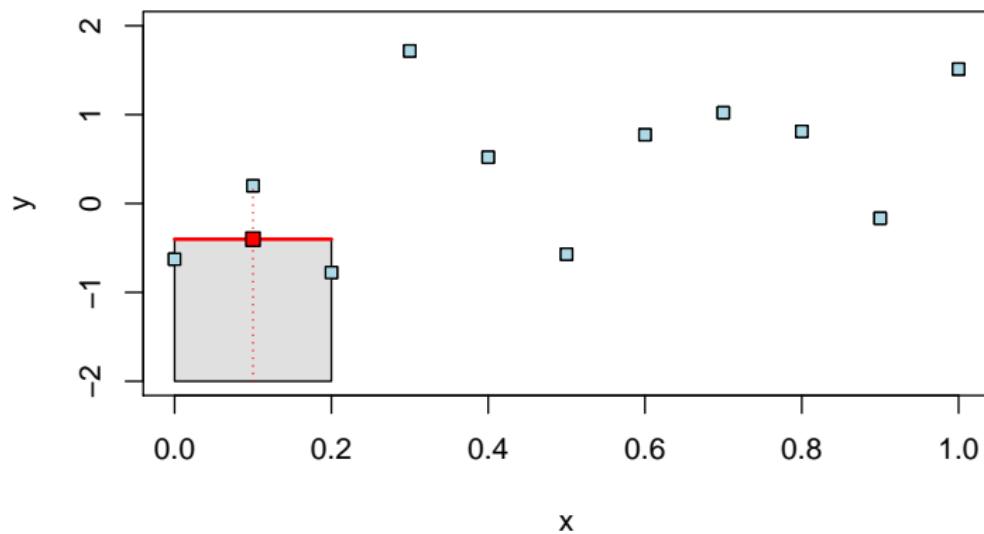
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



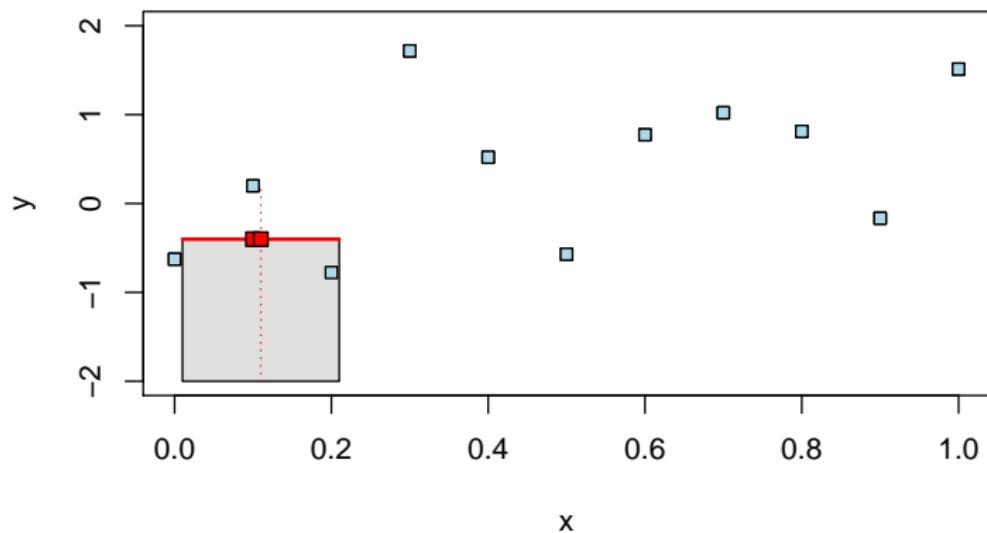
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



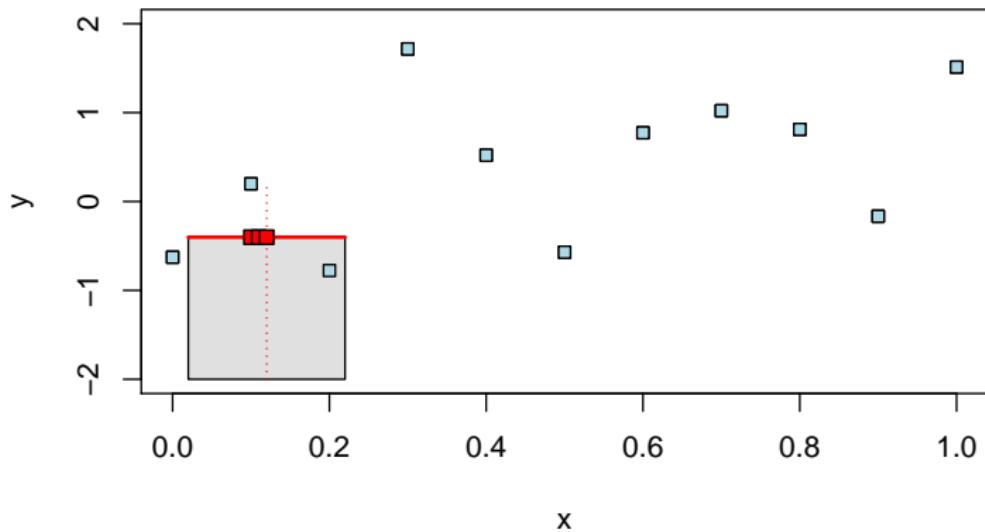
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



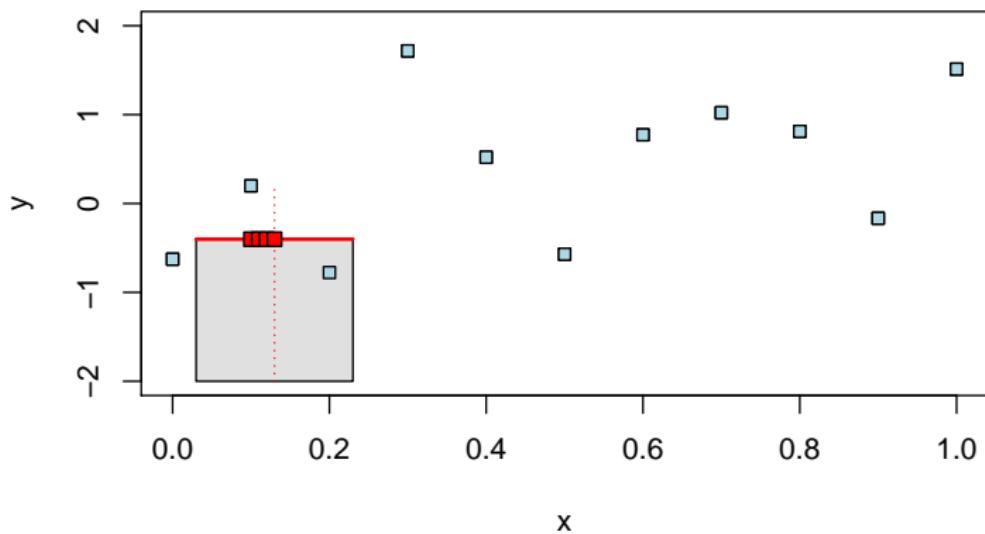
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



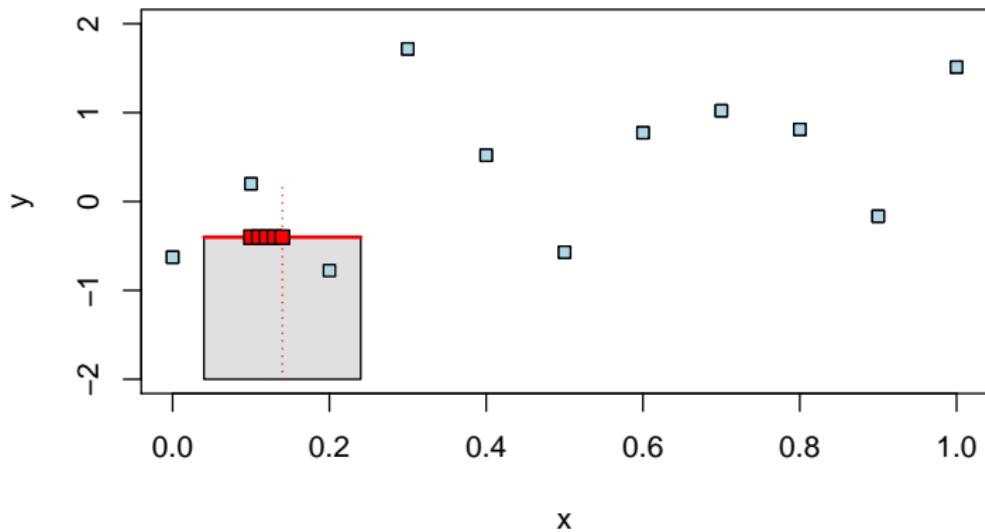
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



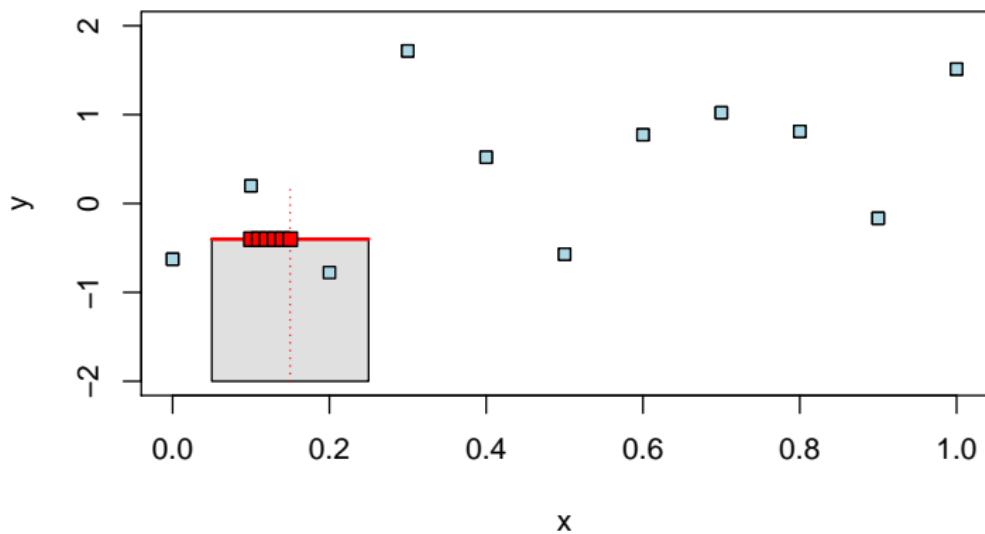
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



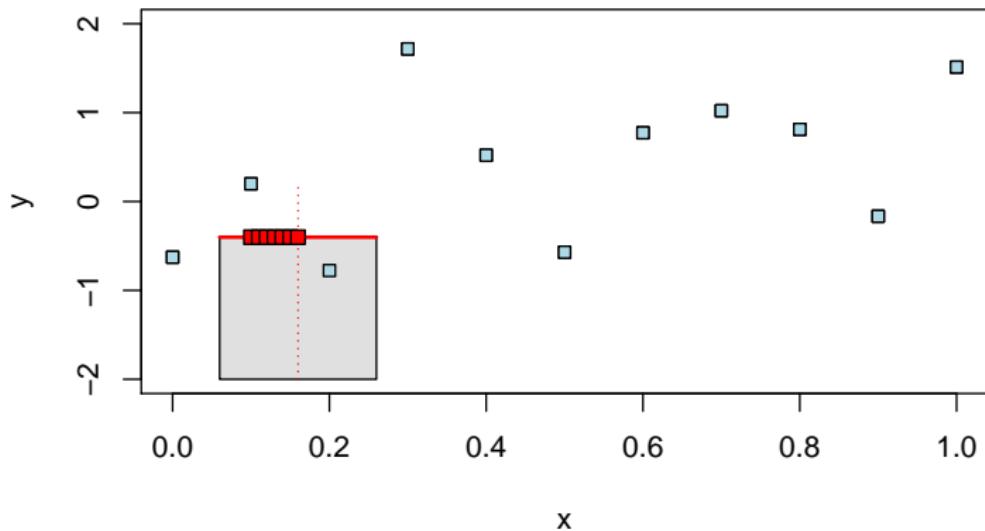
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



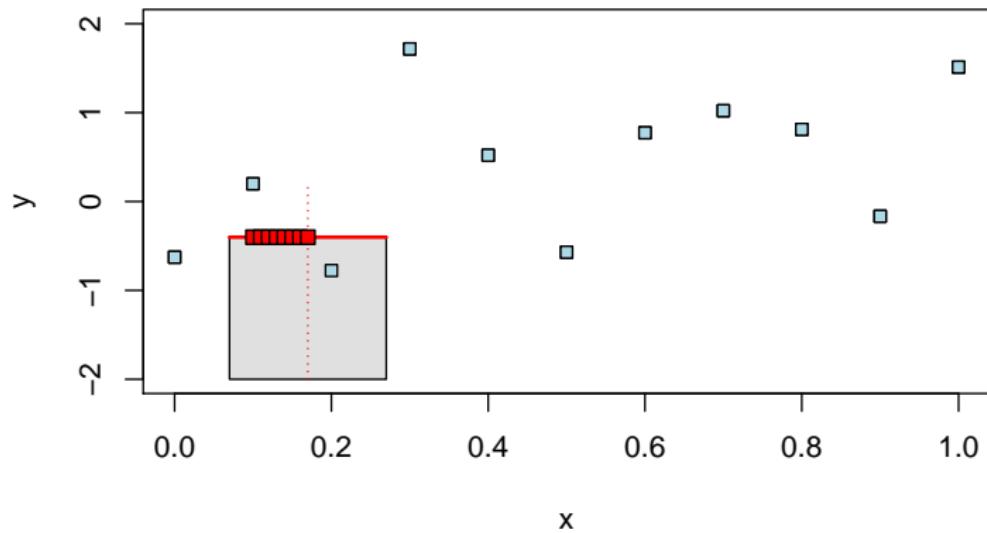
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



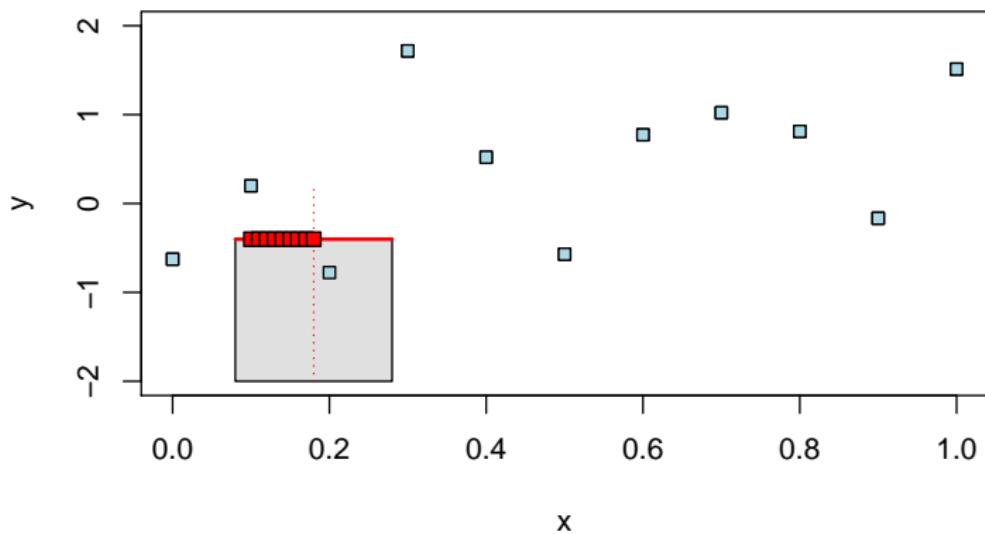
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



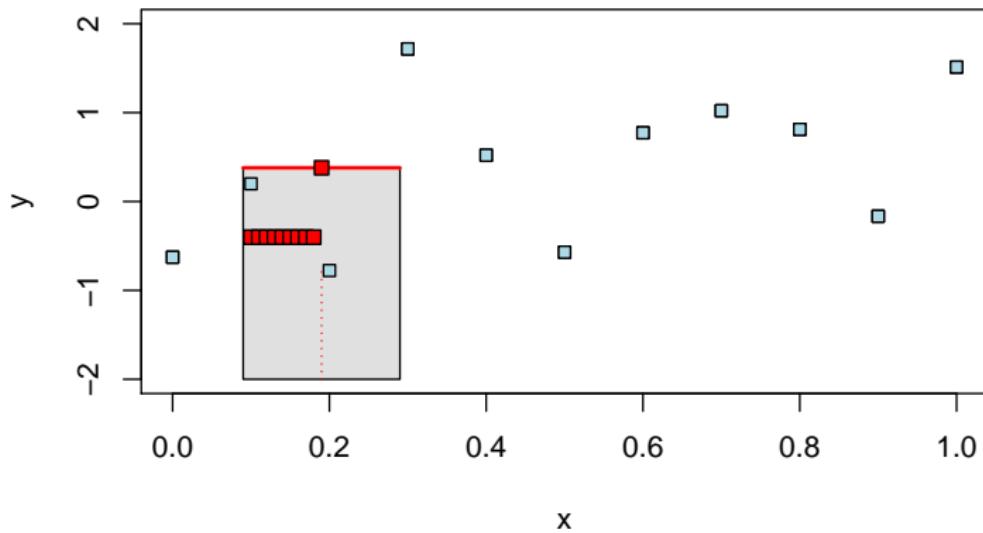
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



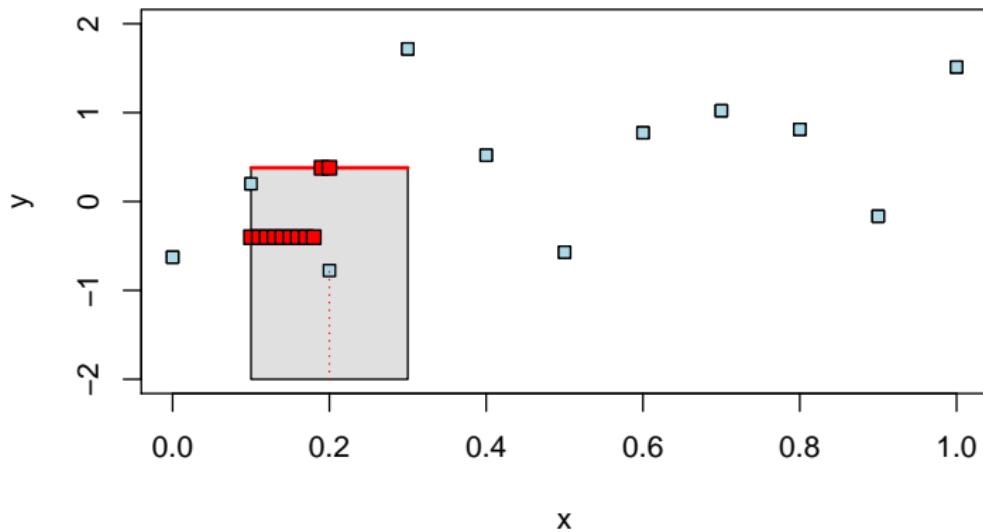
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



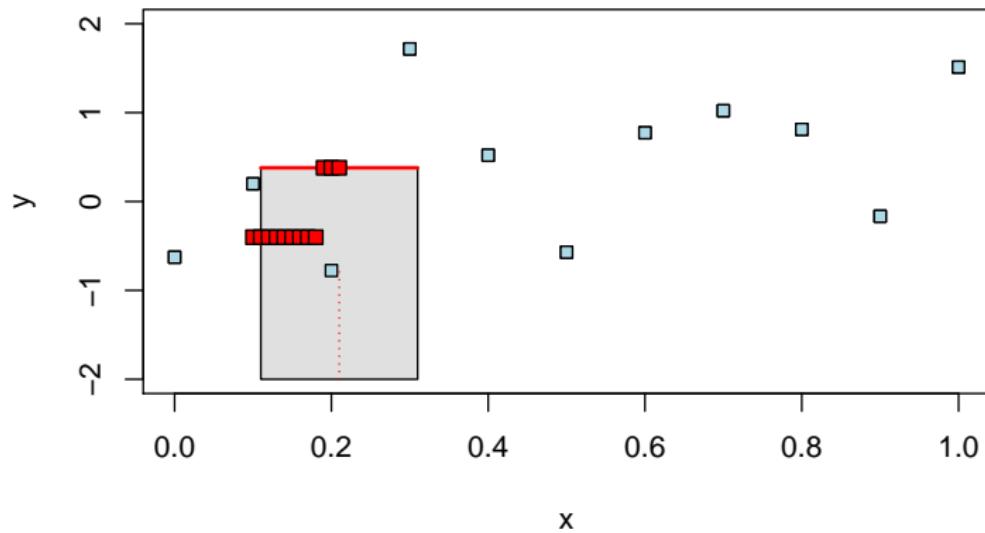
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



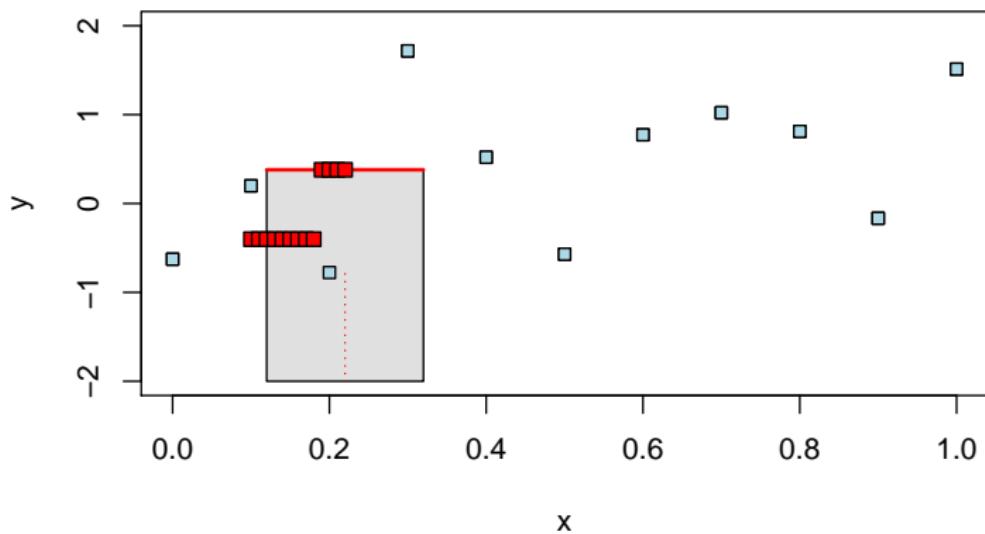
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



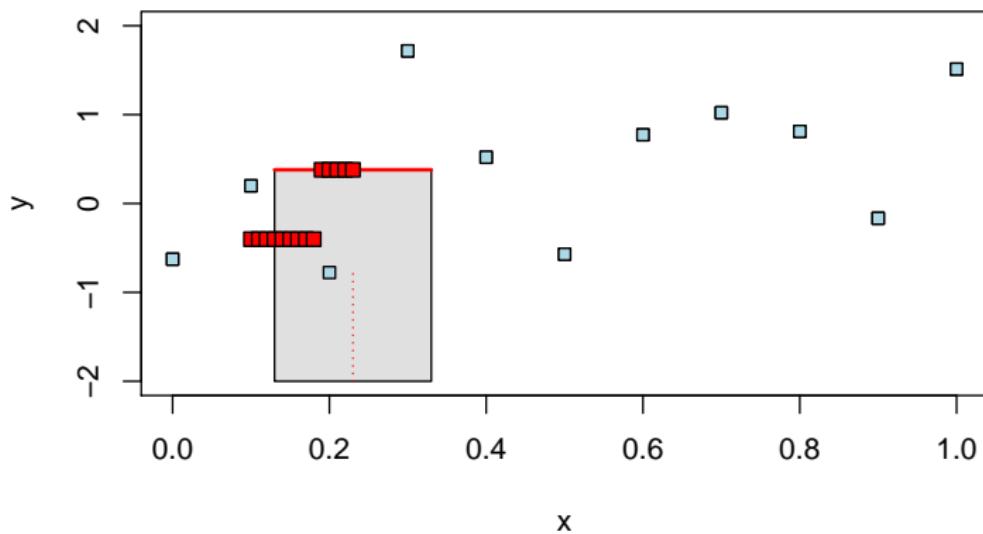
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



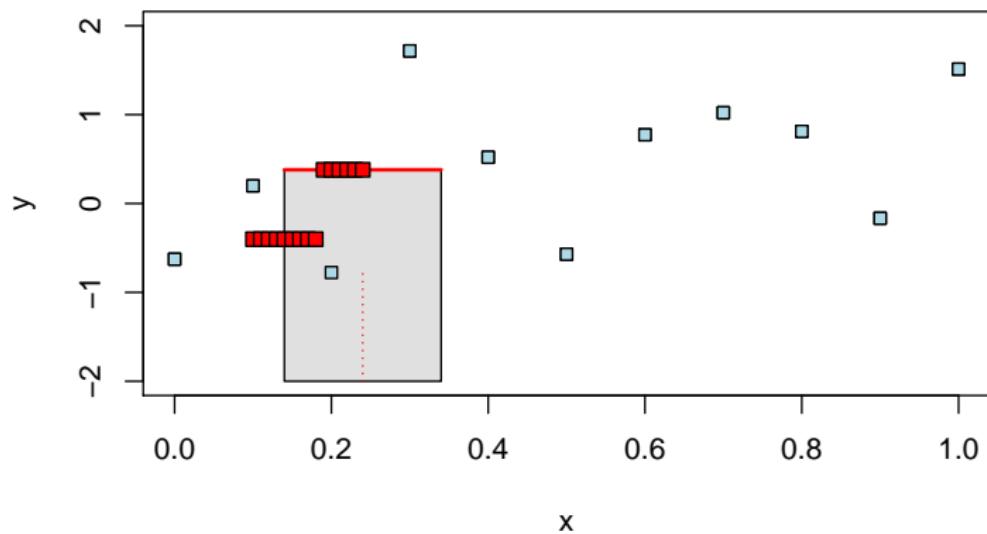
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



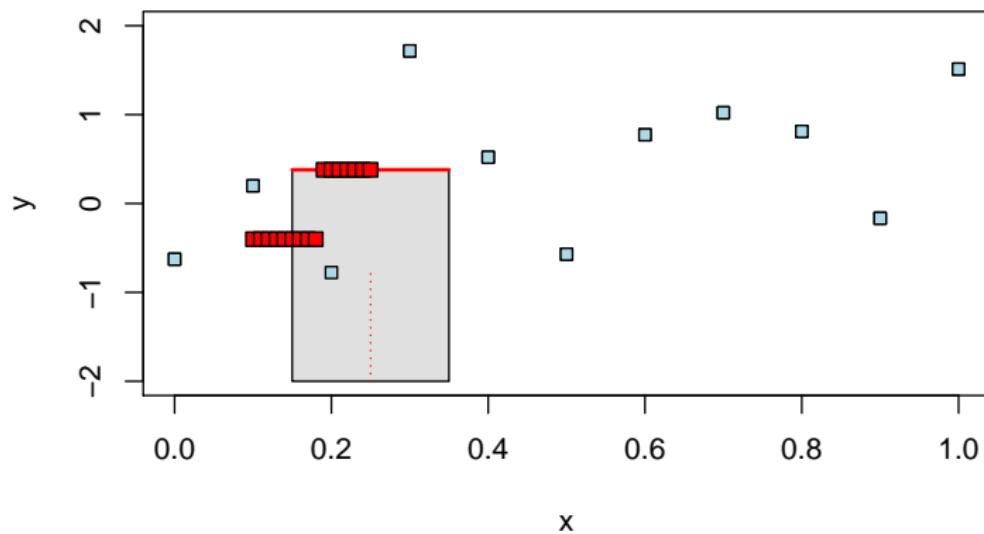
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



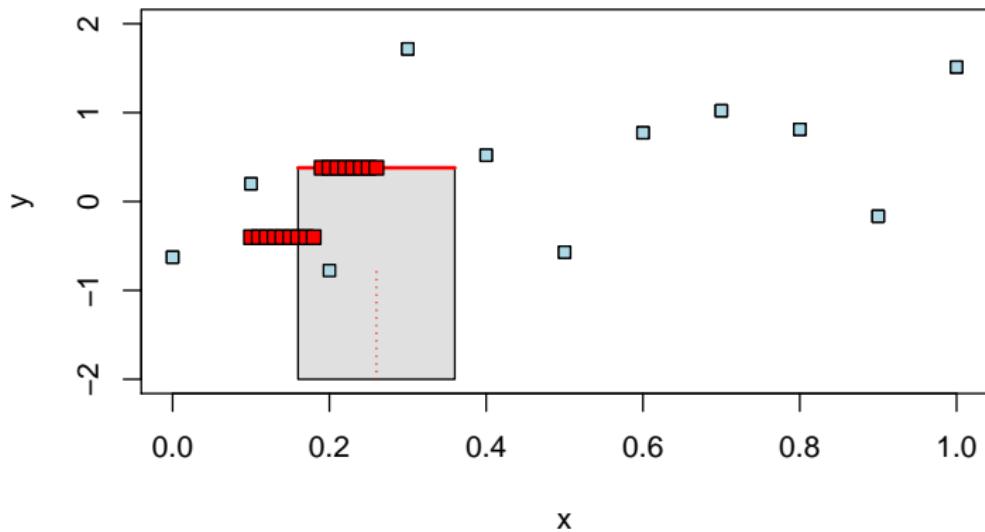
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



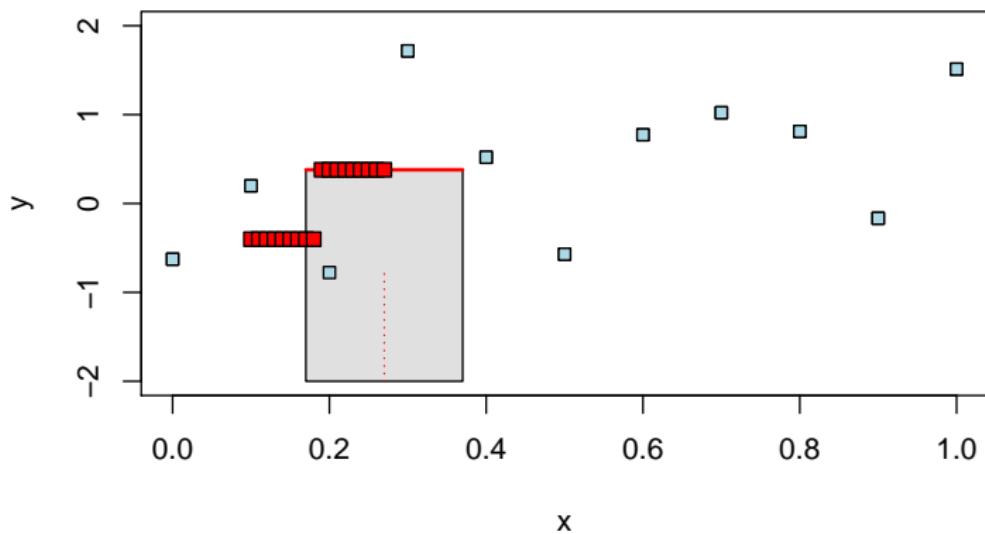
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



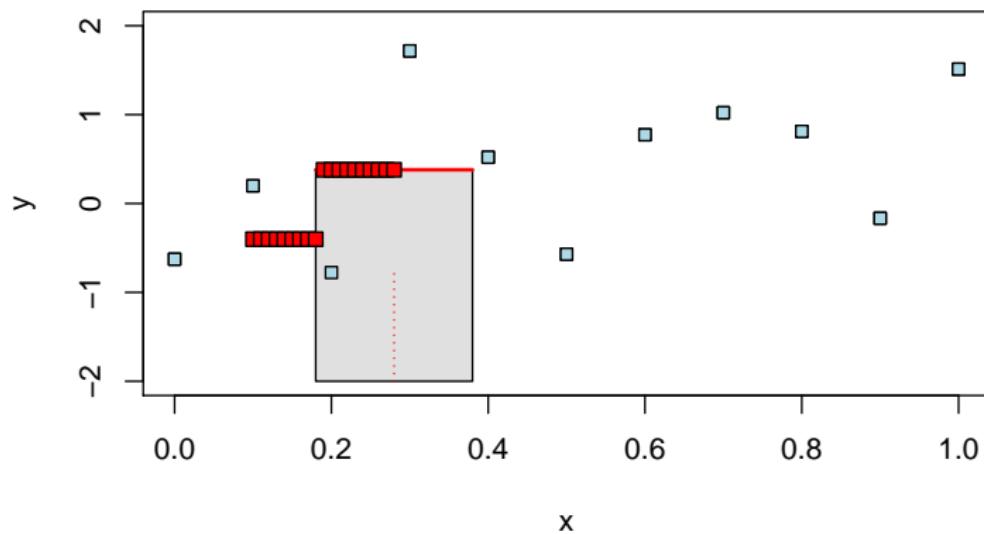
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



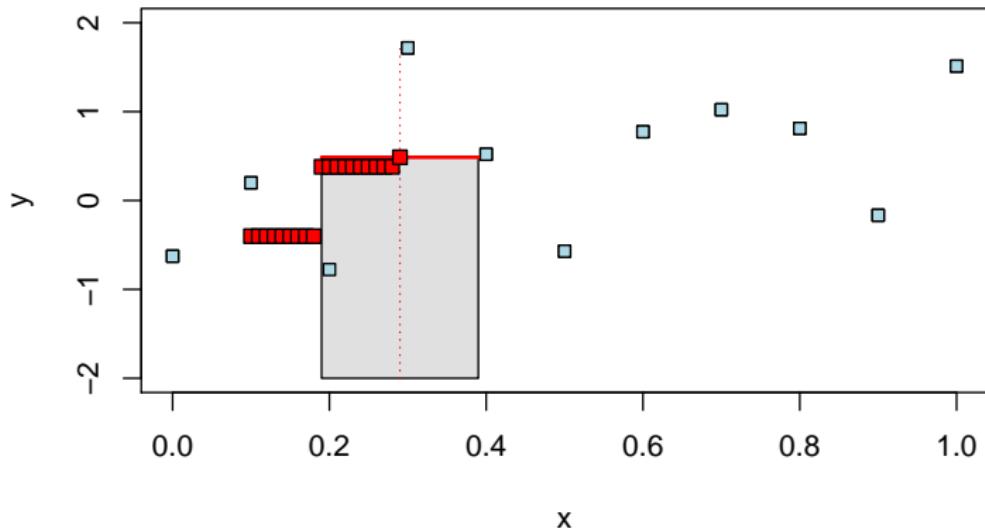
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



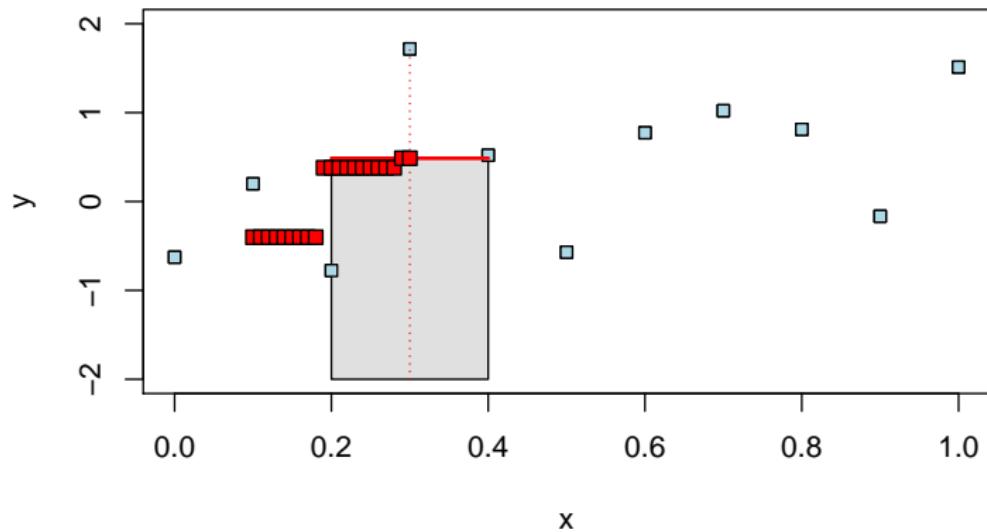
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



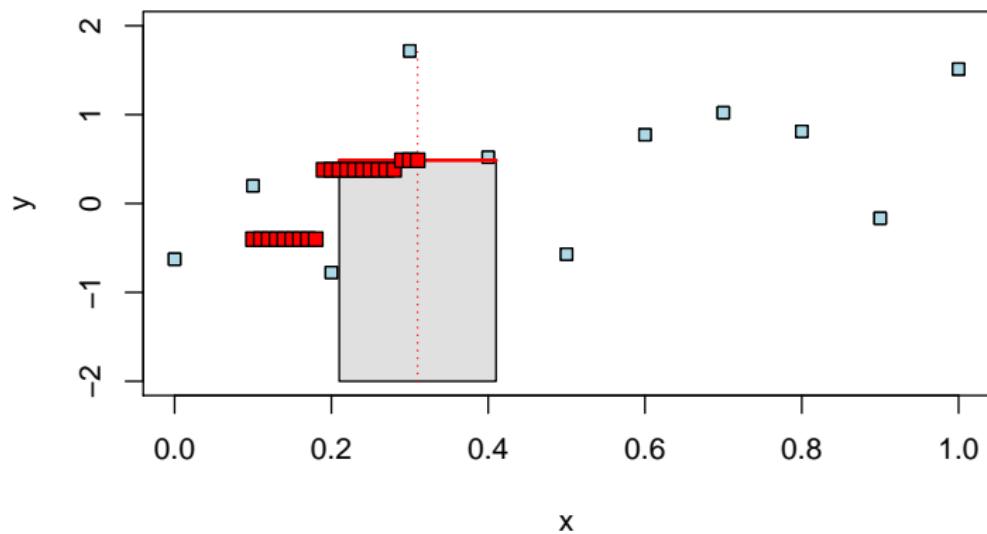
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



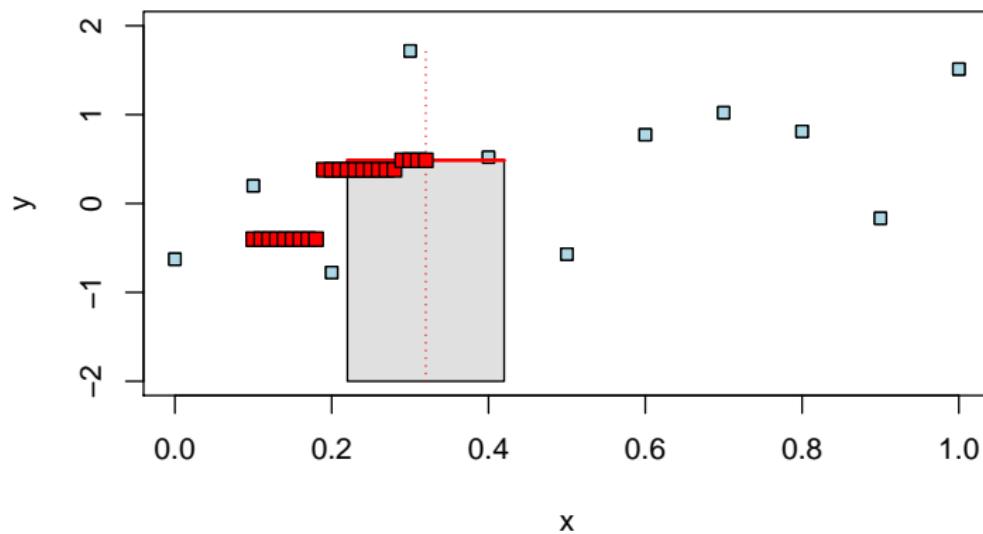
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



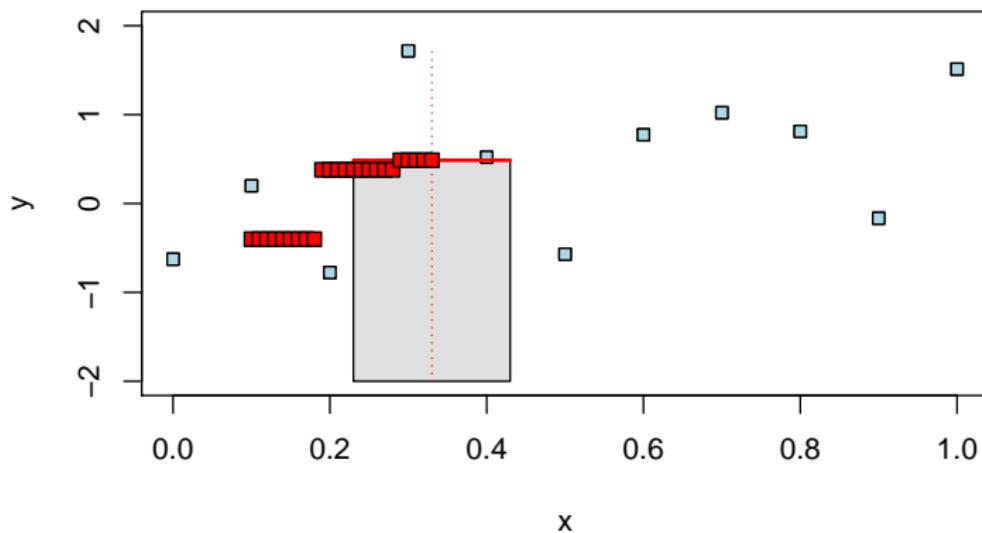
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



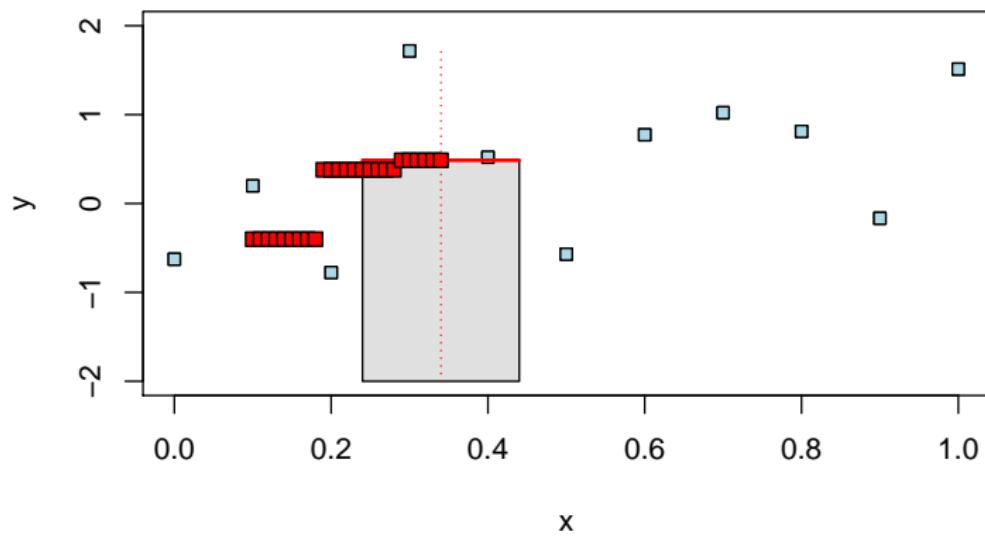
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



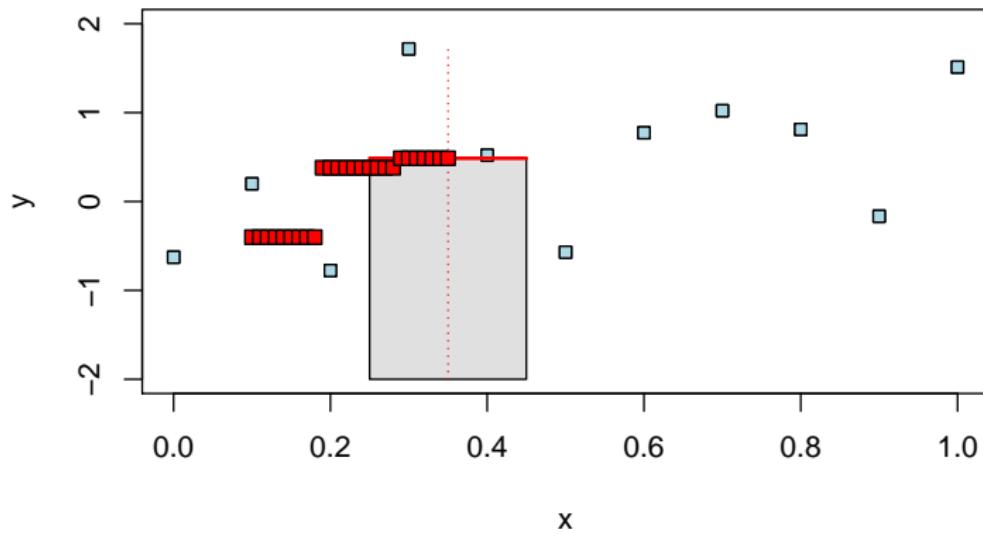
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



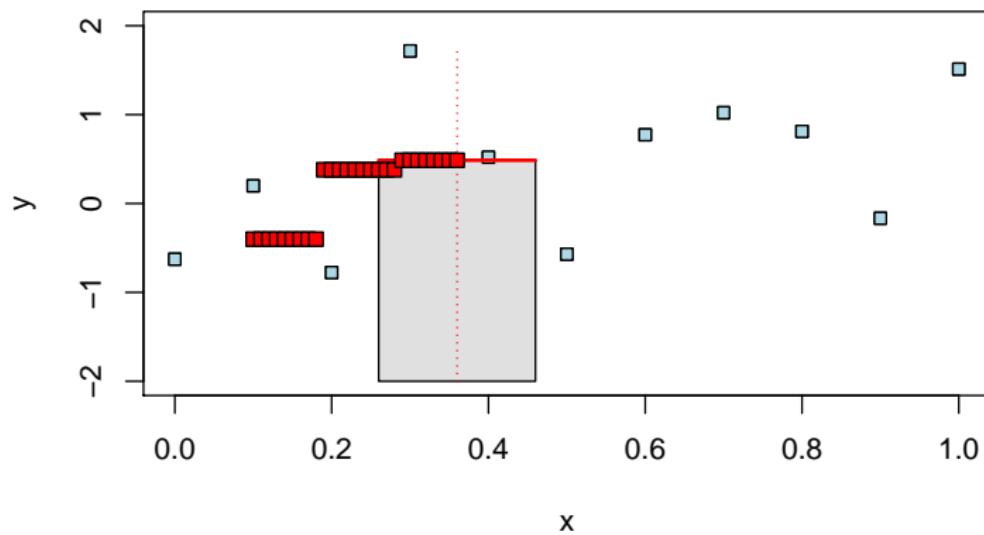
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



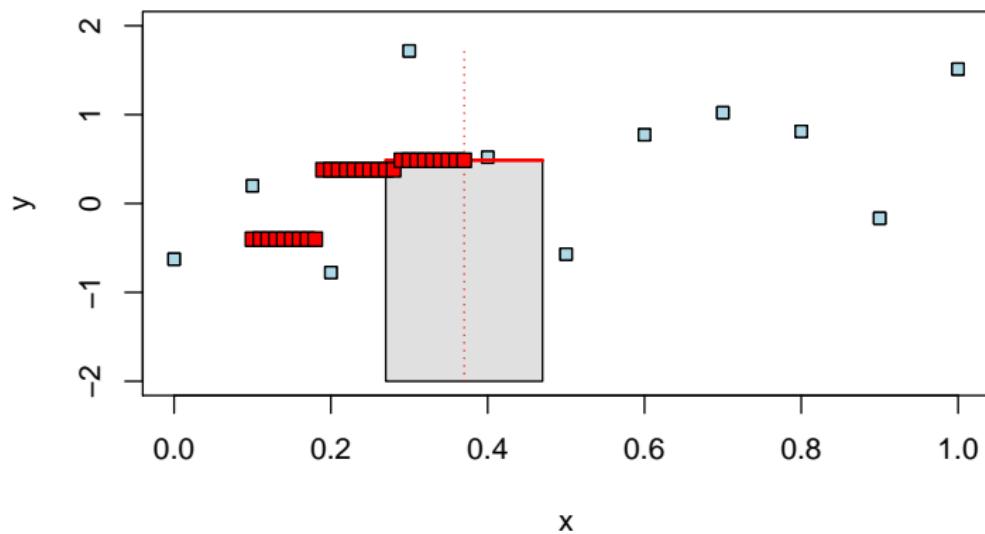
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



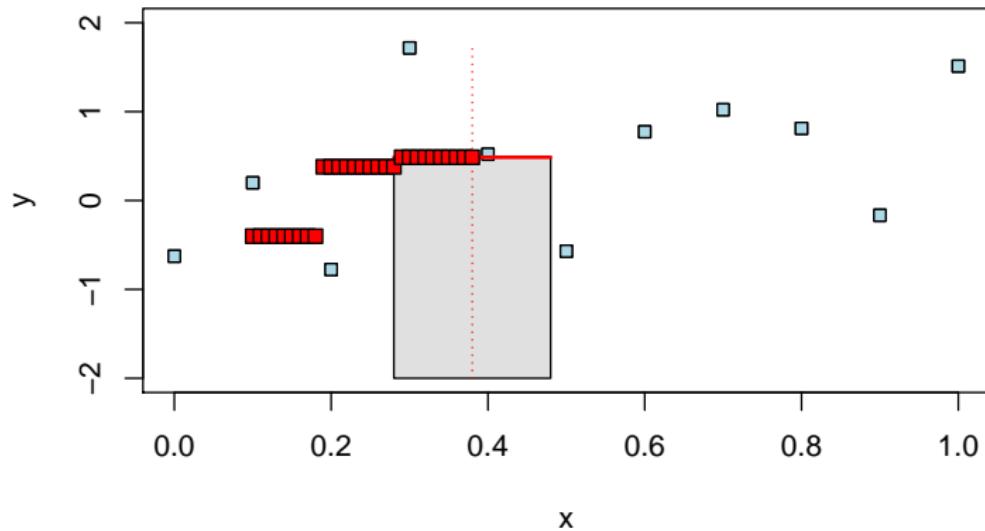
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



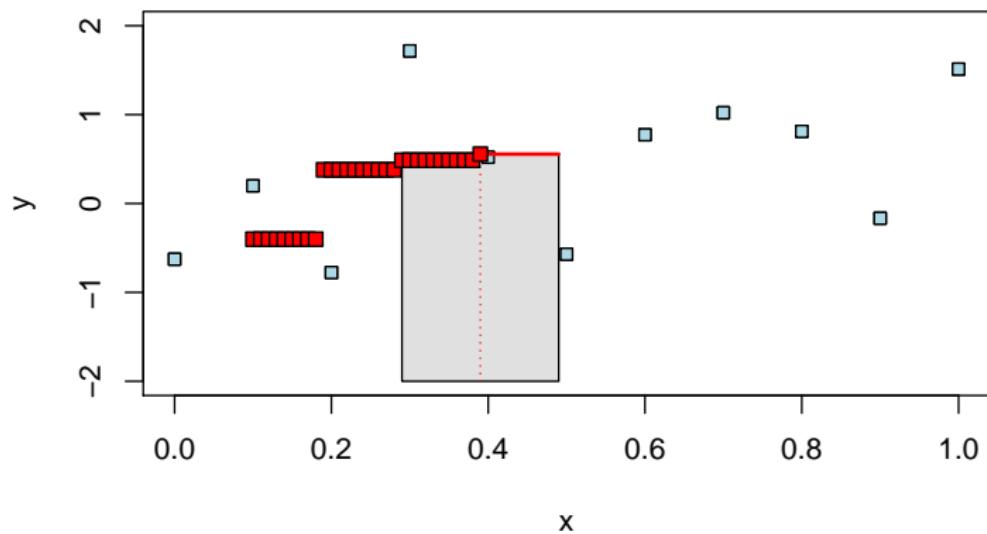
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



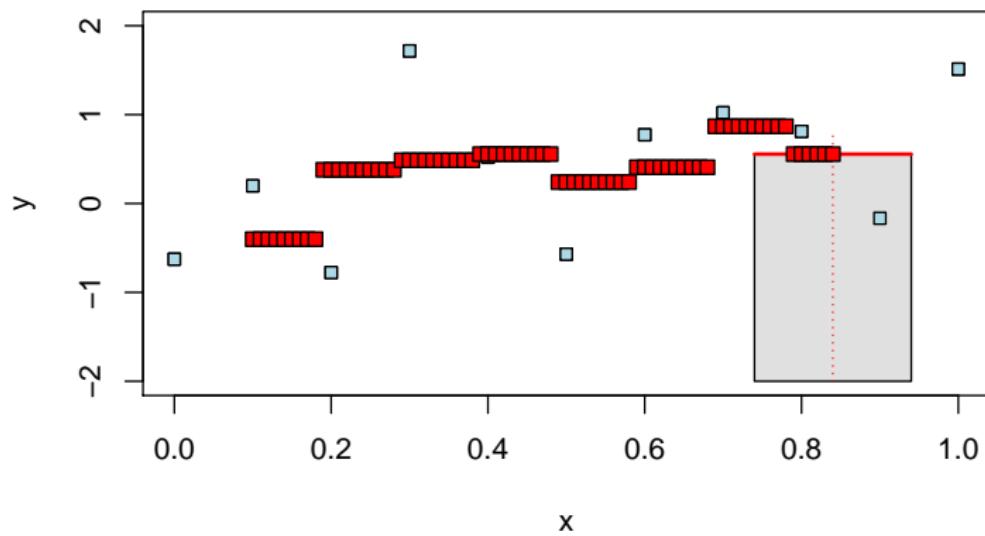
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



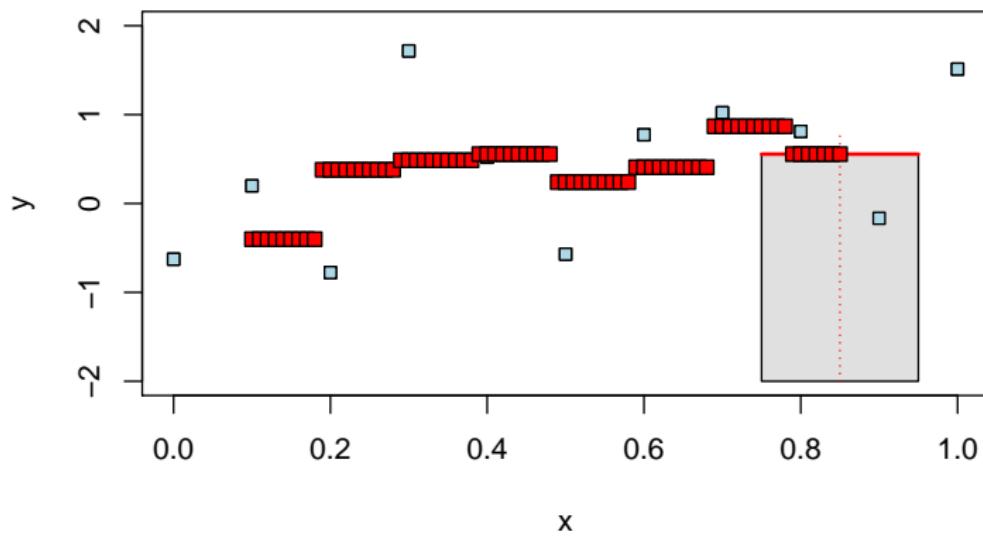
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



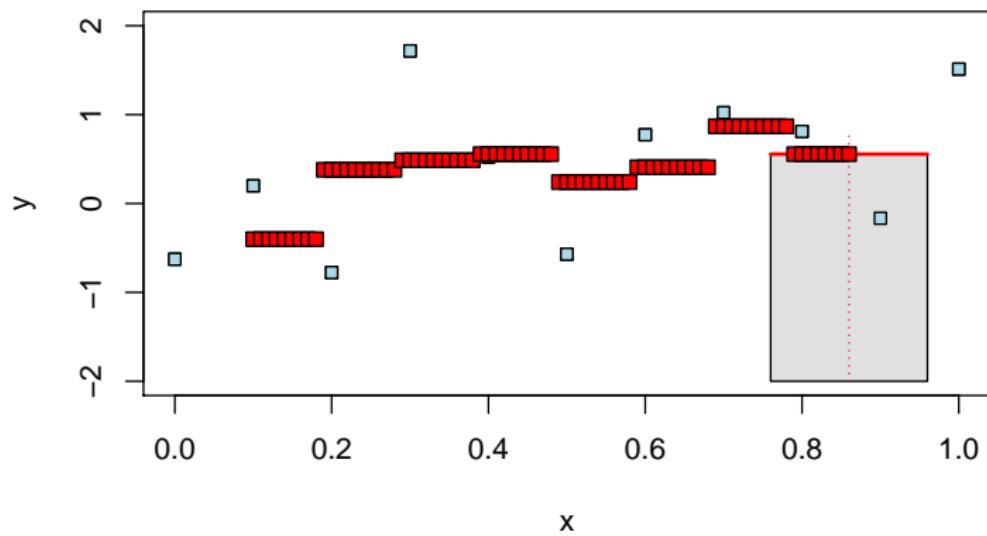
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



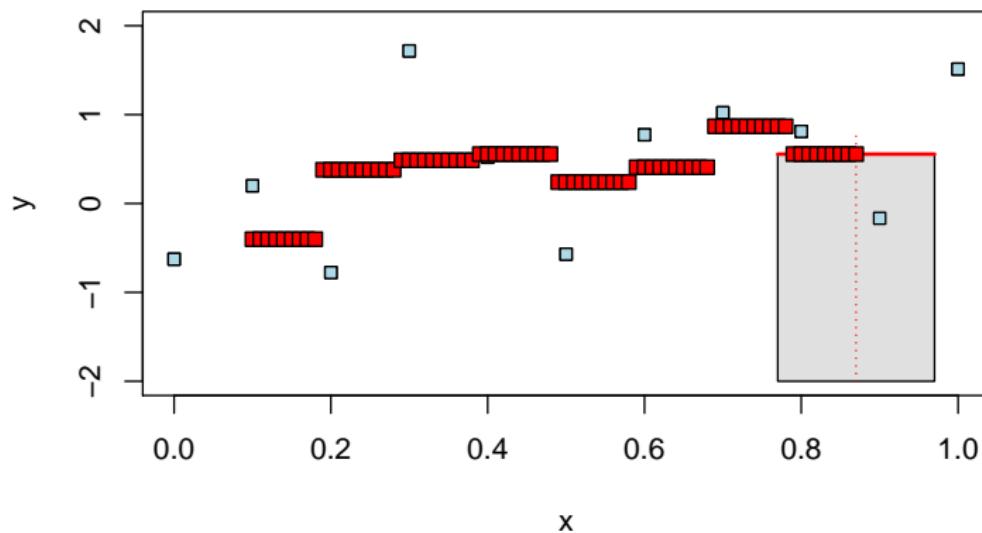
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



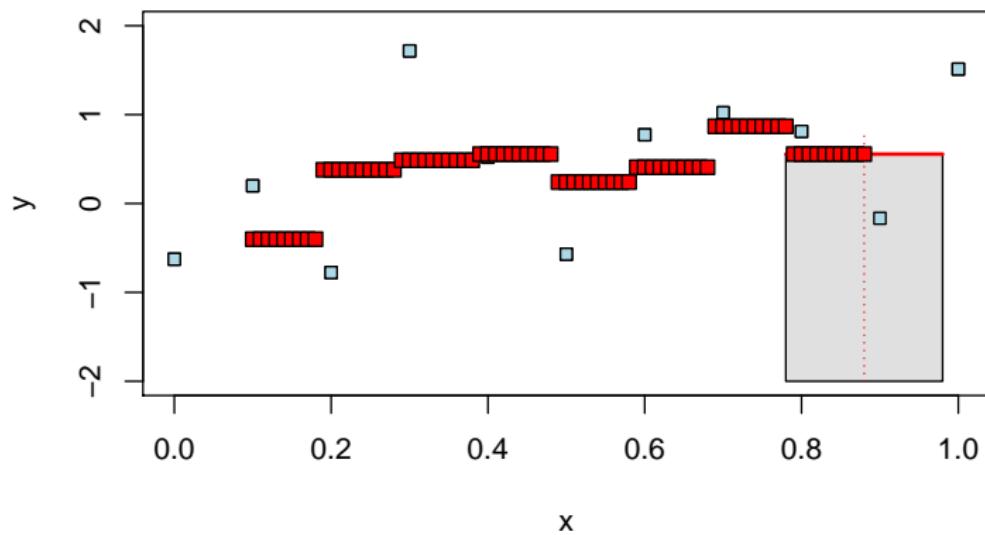
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



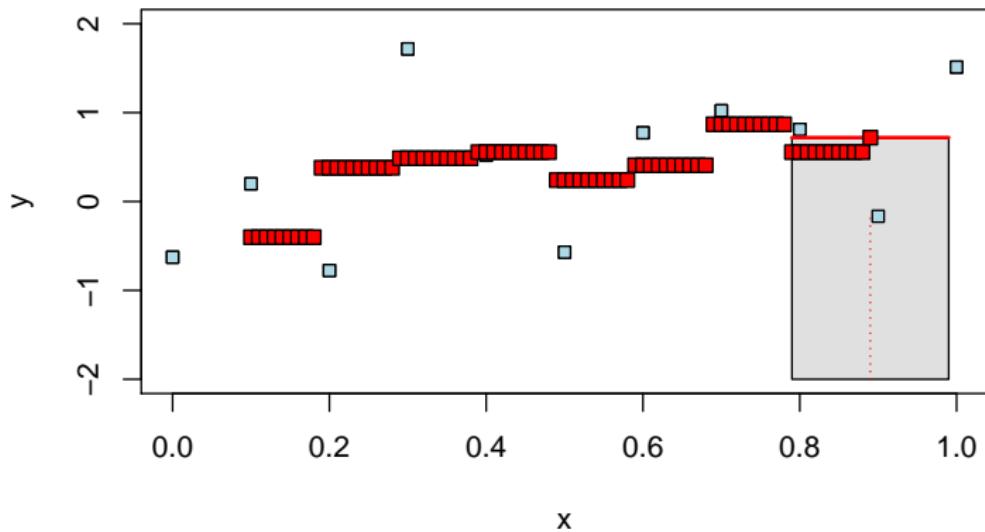
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



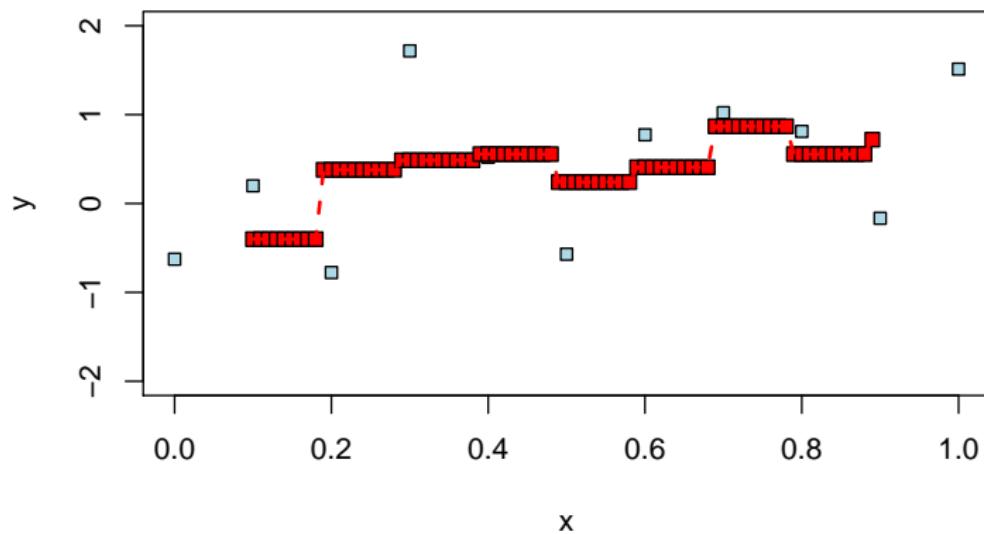
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



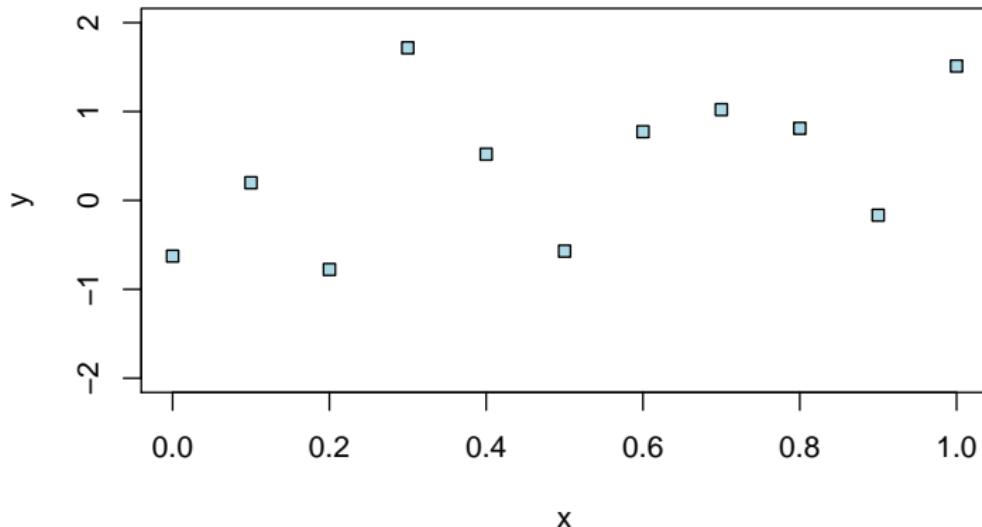
## Obyčejné aritmetické klouzavé průměry

- Pri určitém zobecnění pro libovolné  $x \in \mathcal{D}$  nedostaneme nutně hladkou křivku, ale pouze po částech konstantné "vyhlazení".



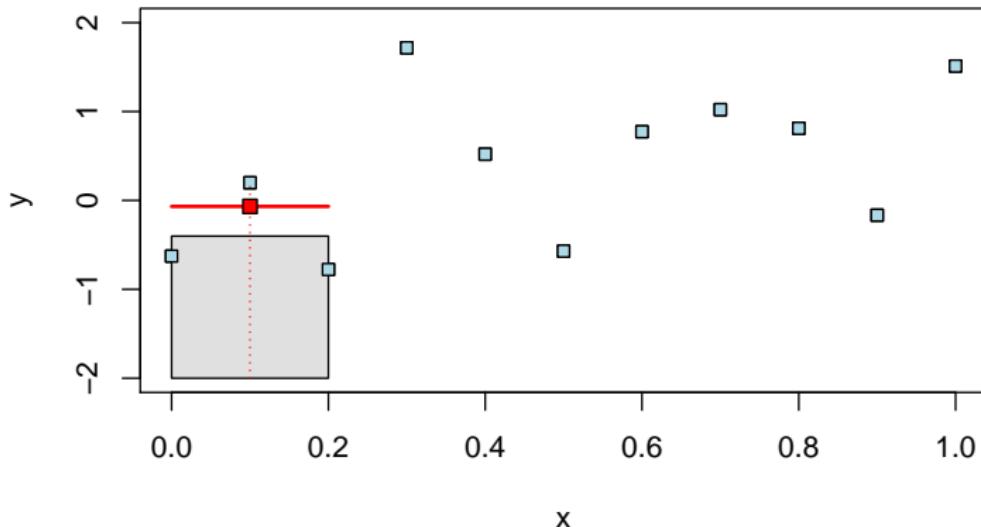
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



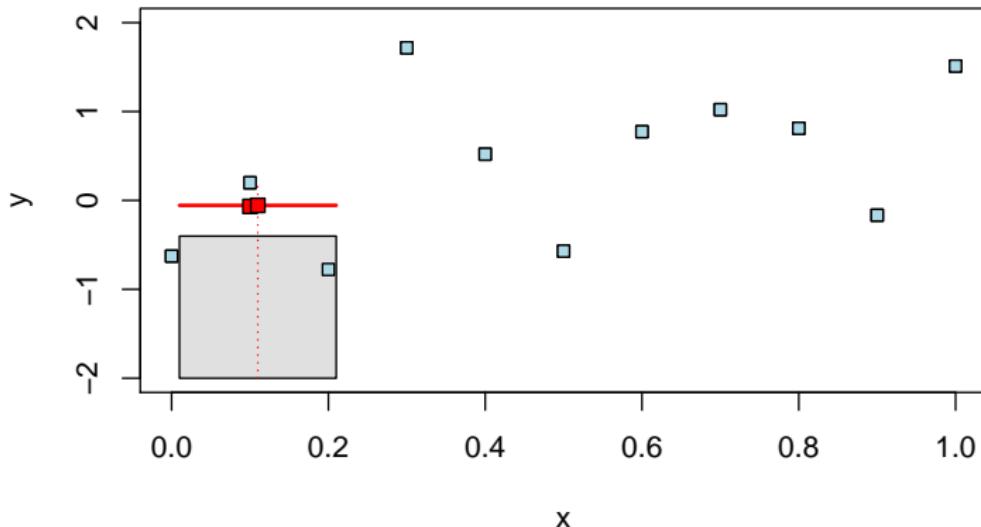
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



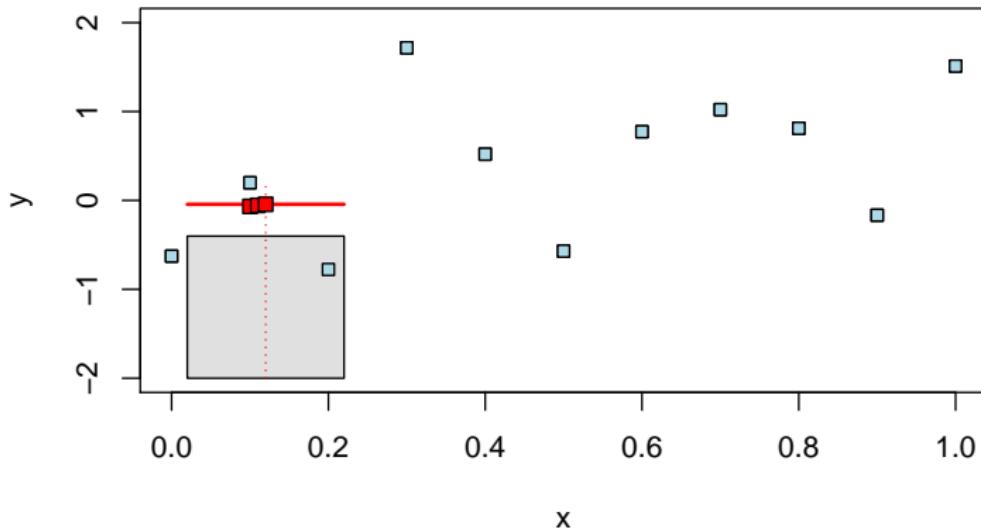
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



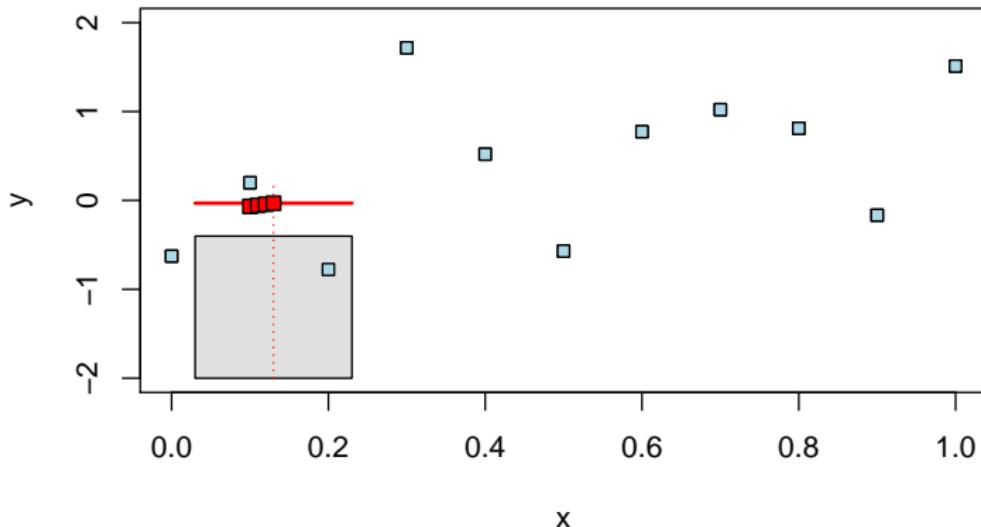
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



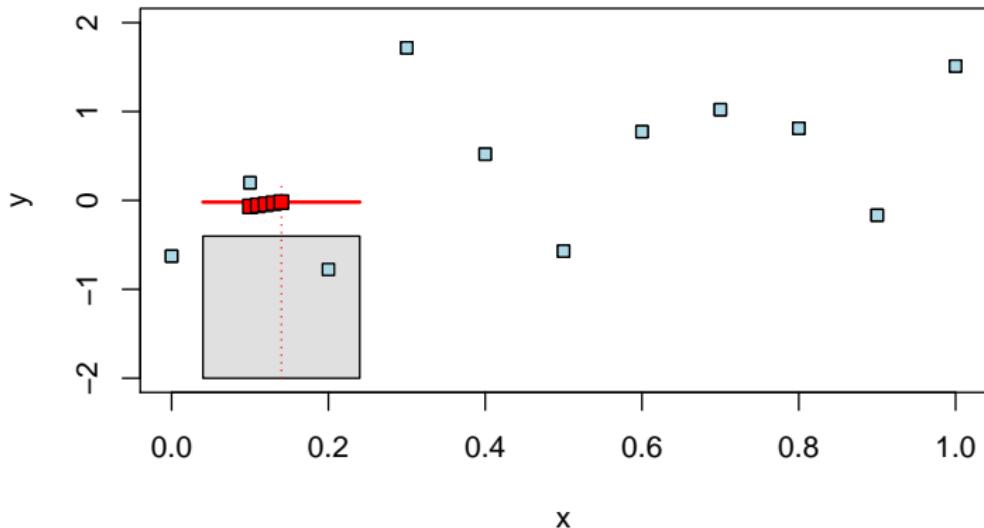
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



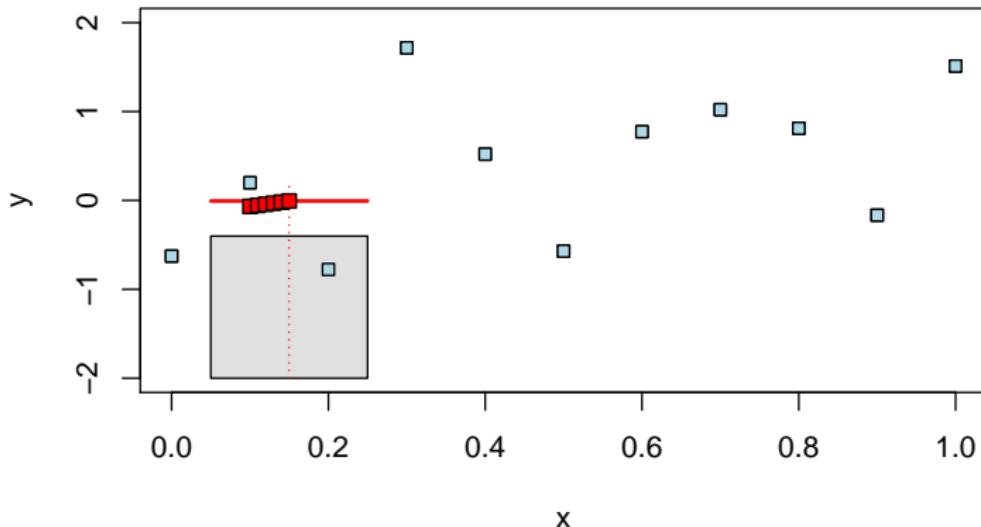
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



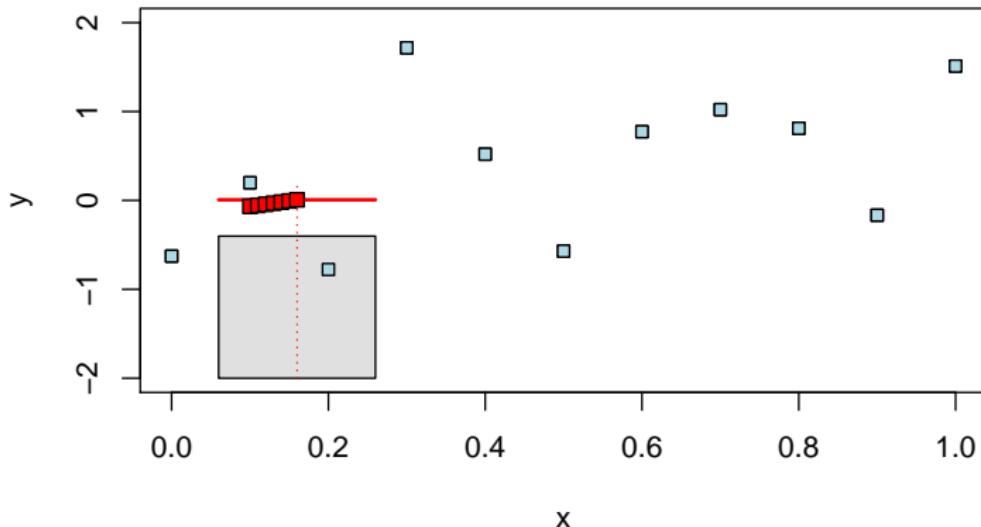
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



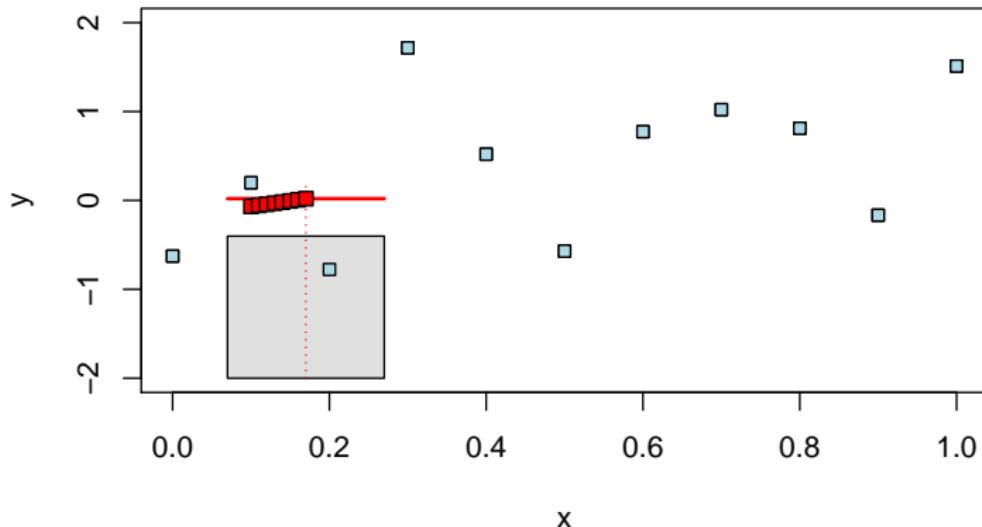
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



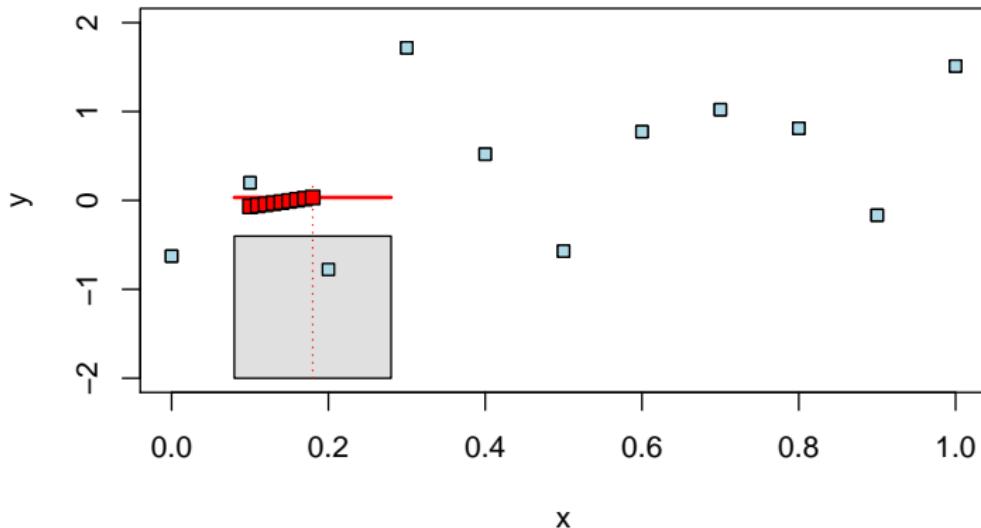
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



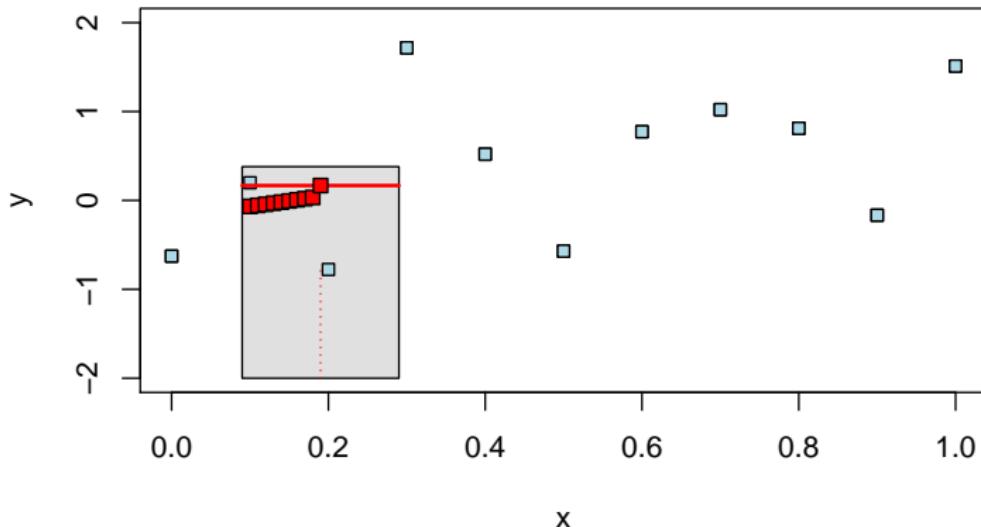
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



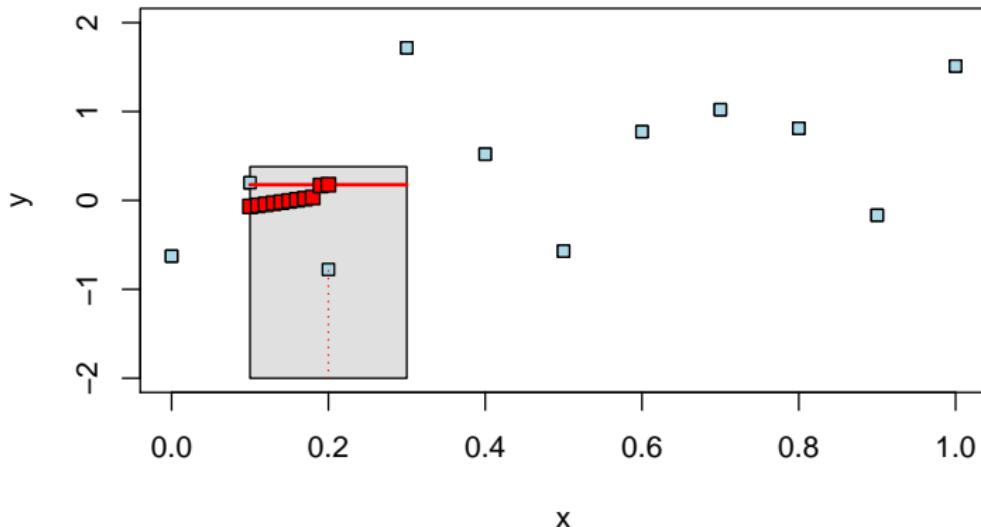
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



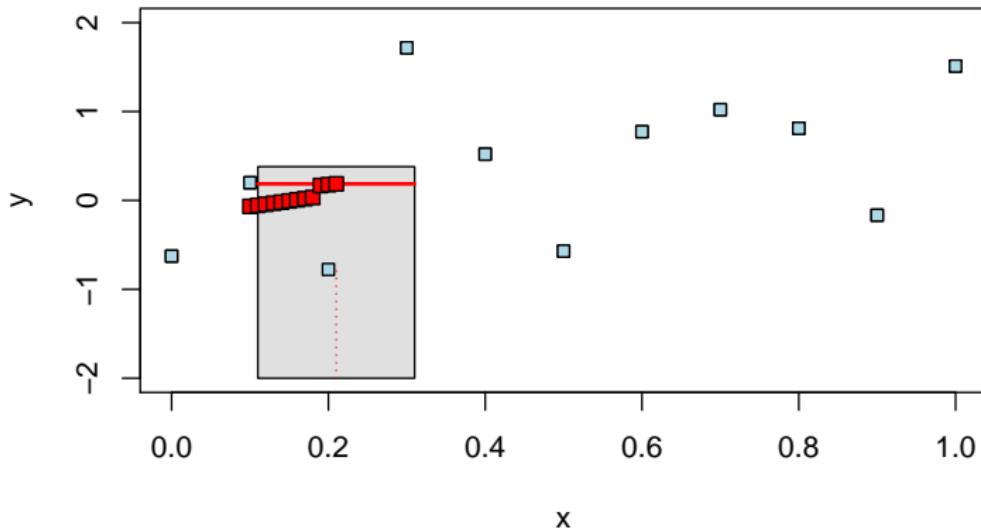
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



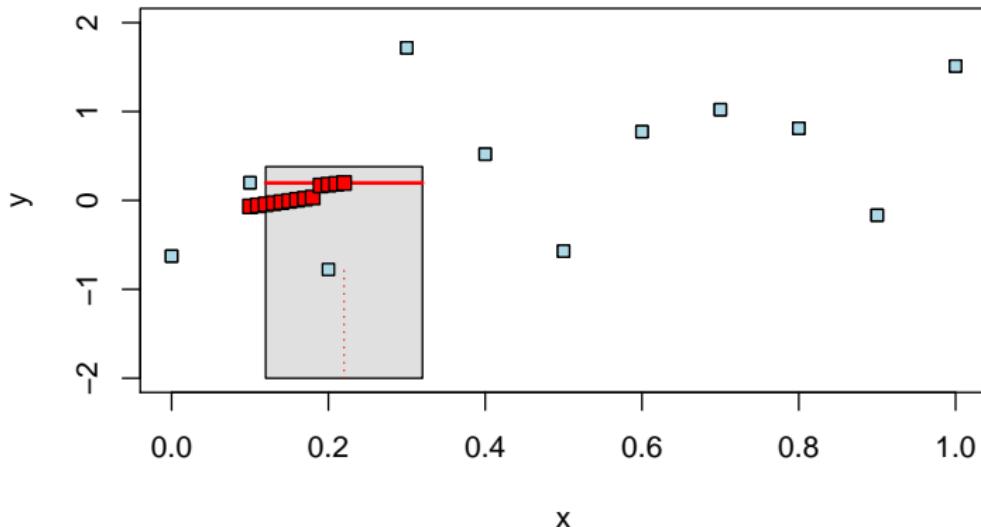
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



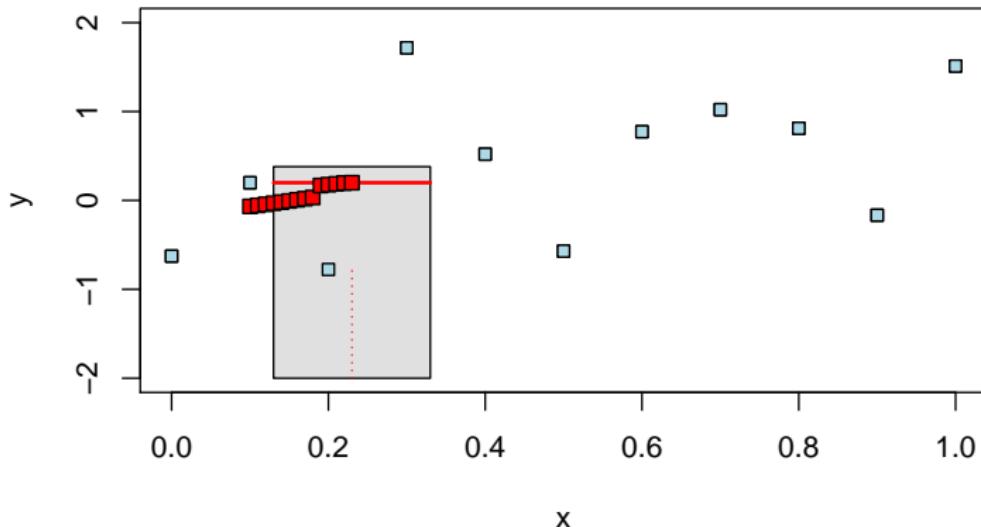
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



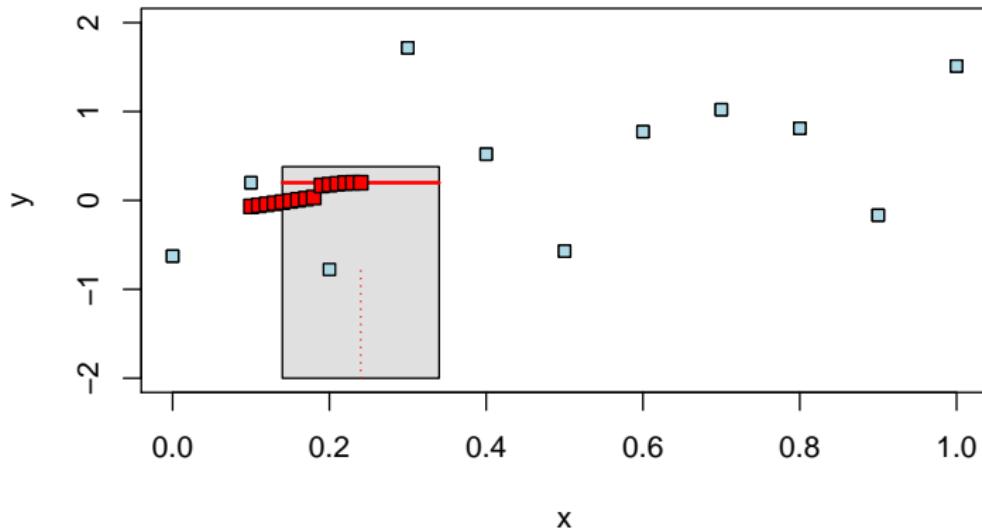
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



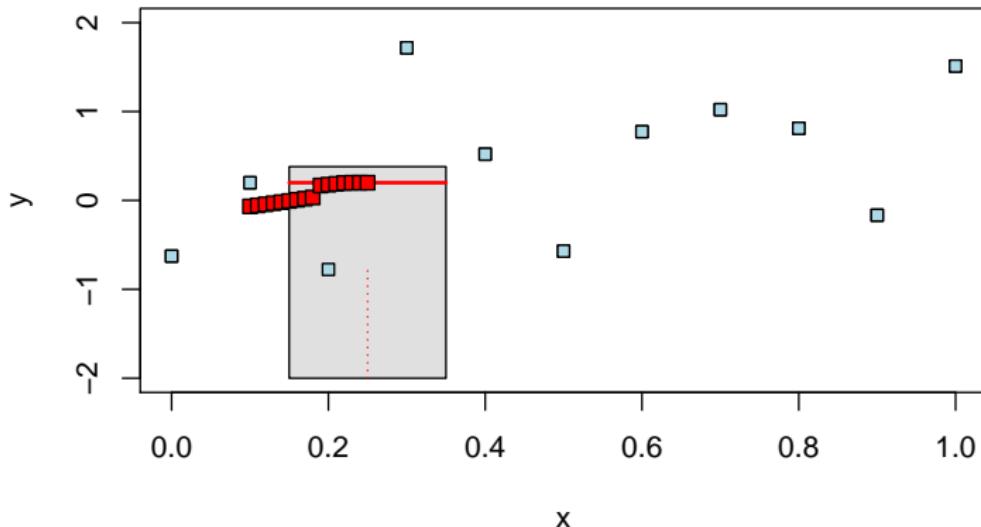
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



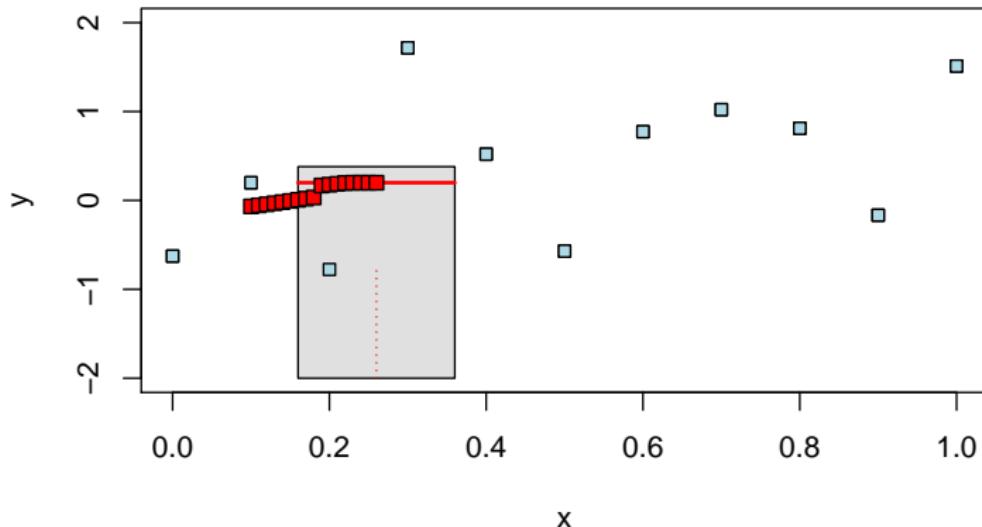
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



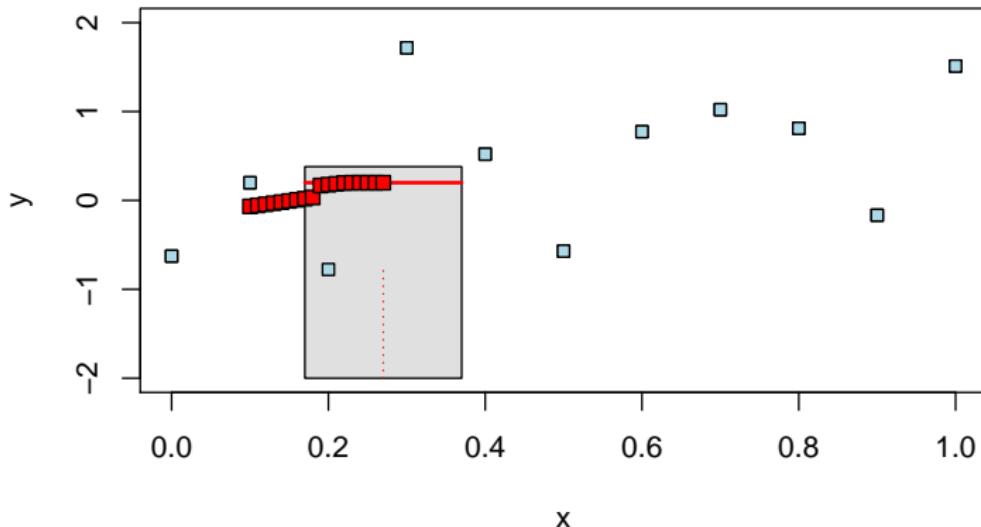
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



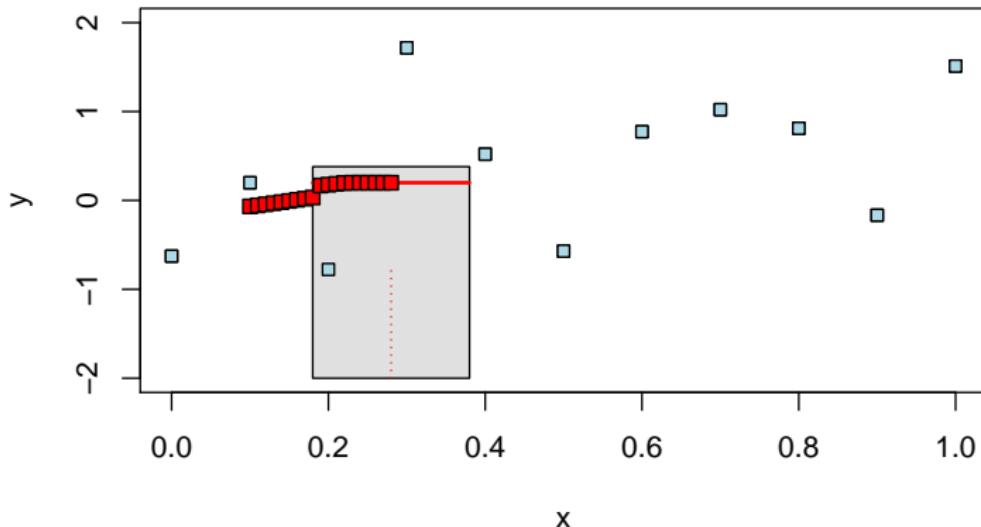
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



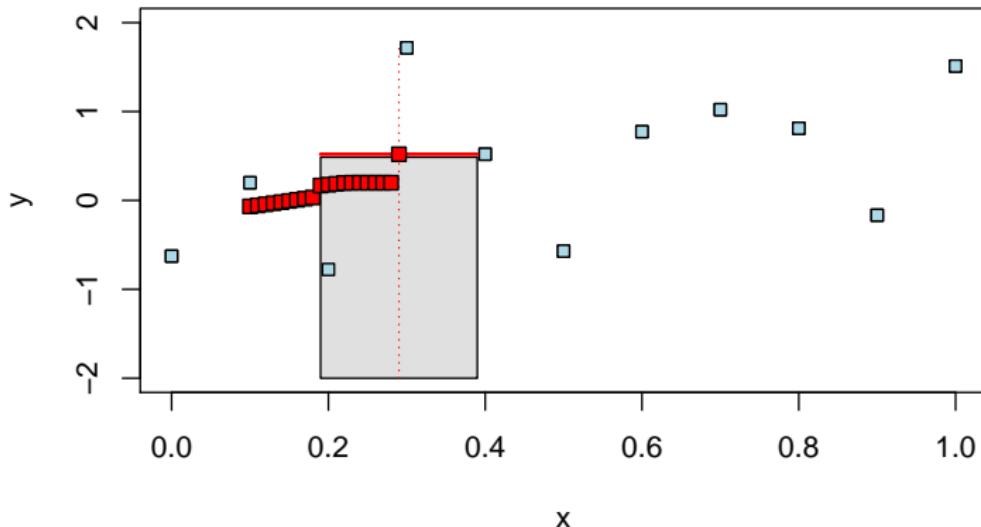
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



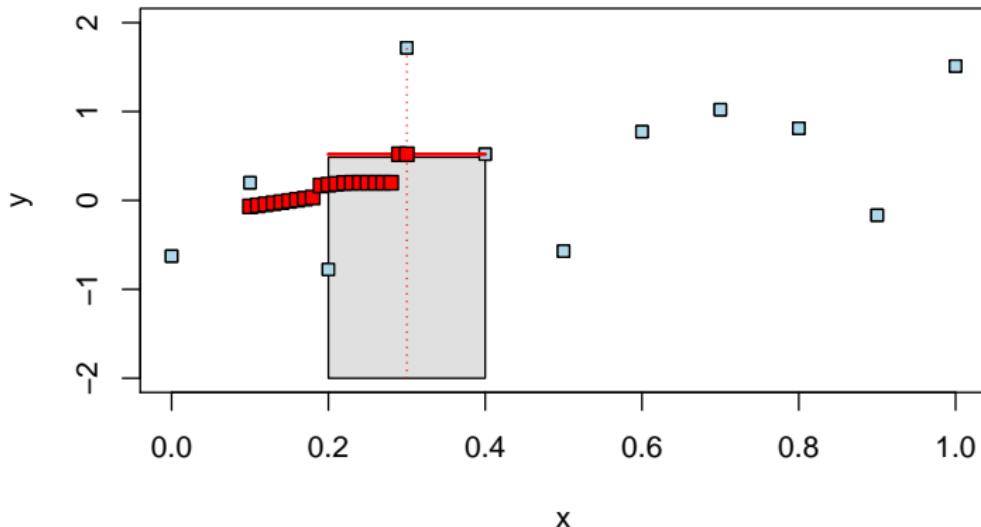
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



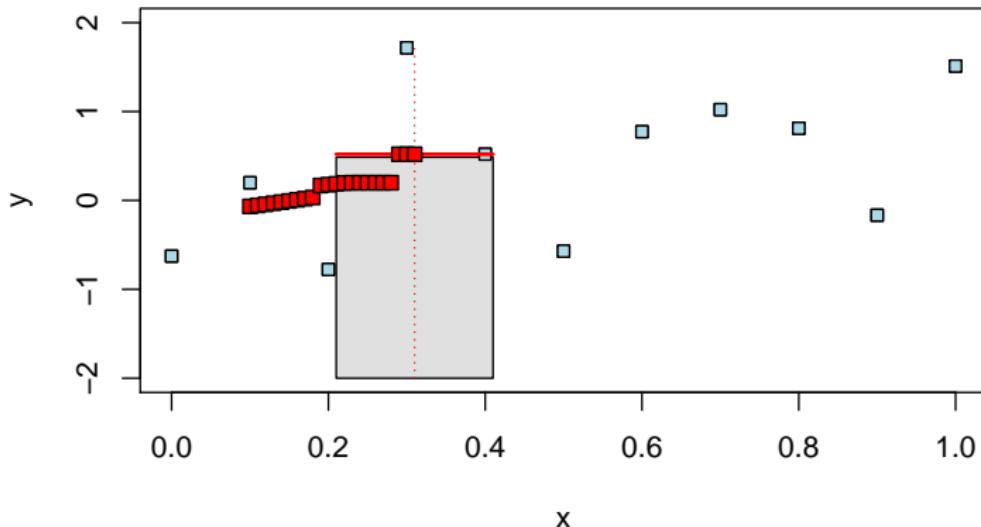
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



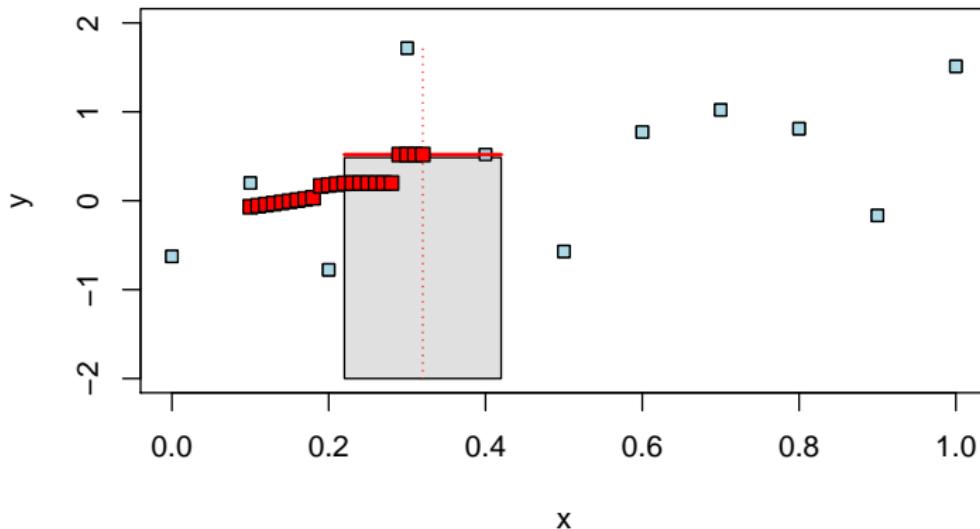
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



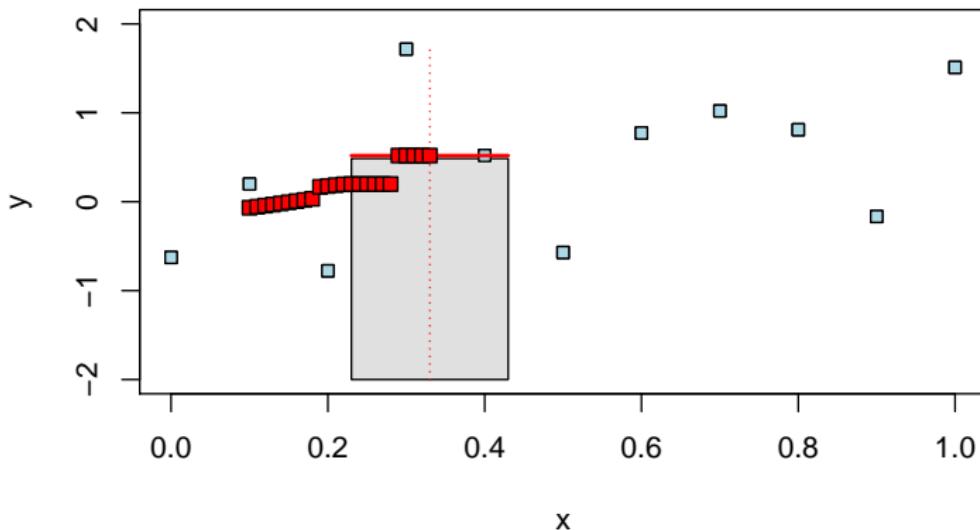
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



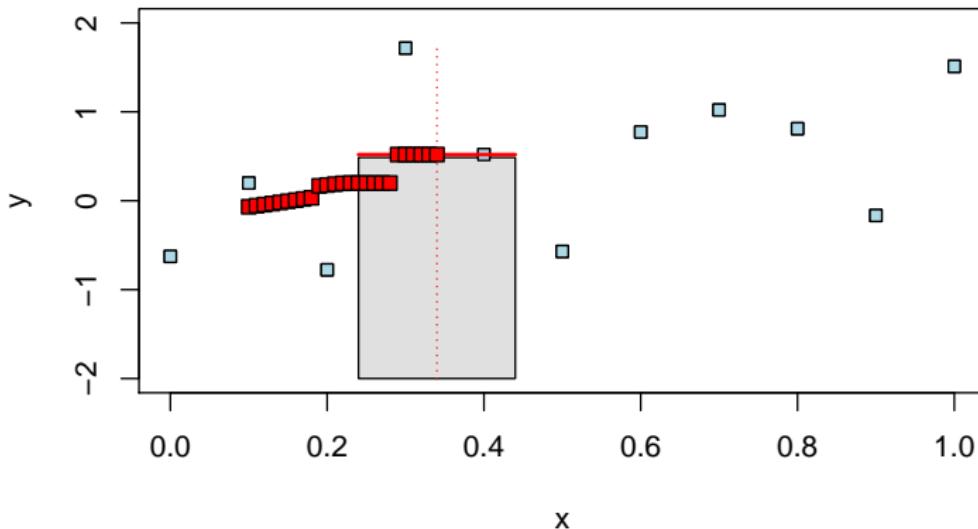
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



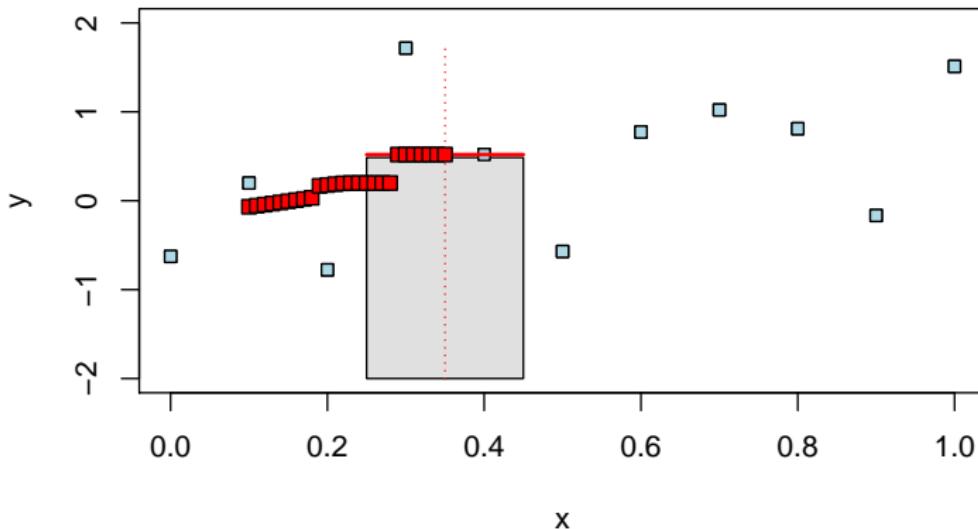
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



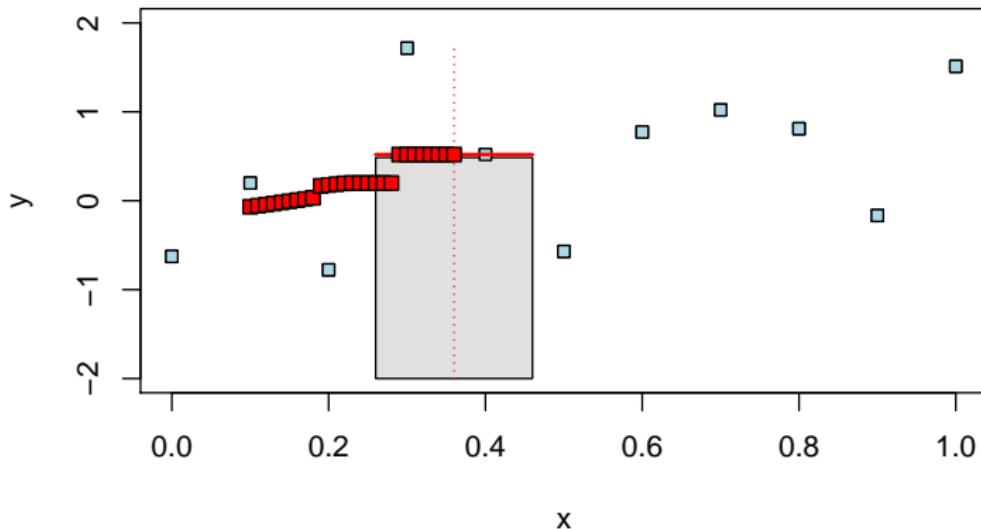
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



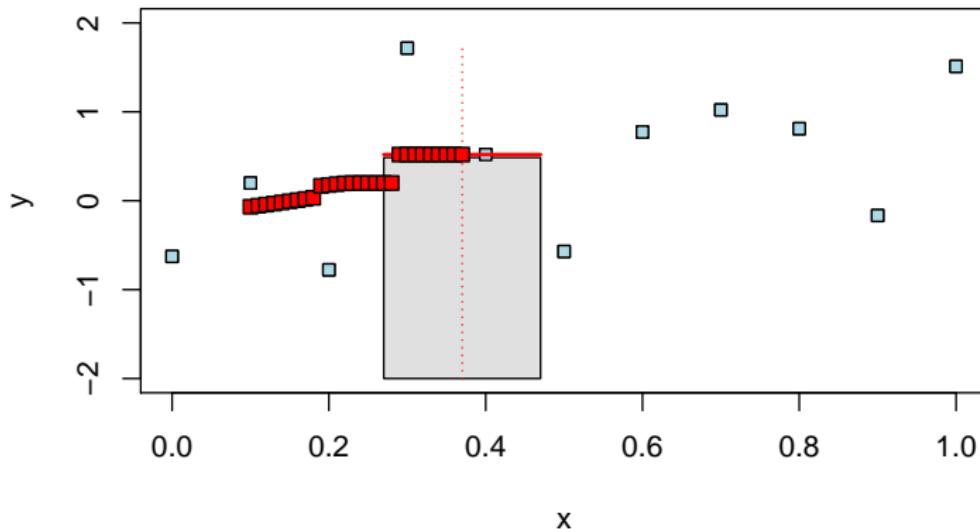
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



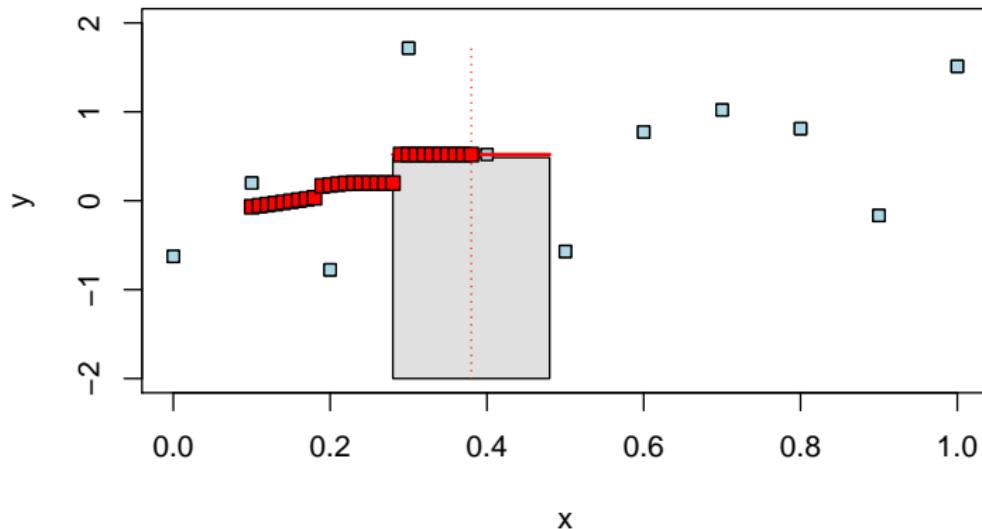
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



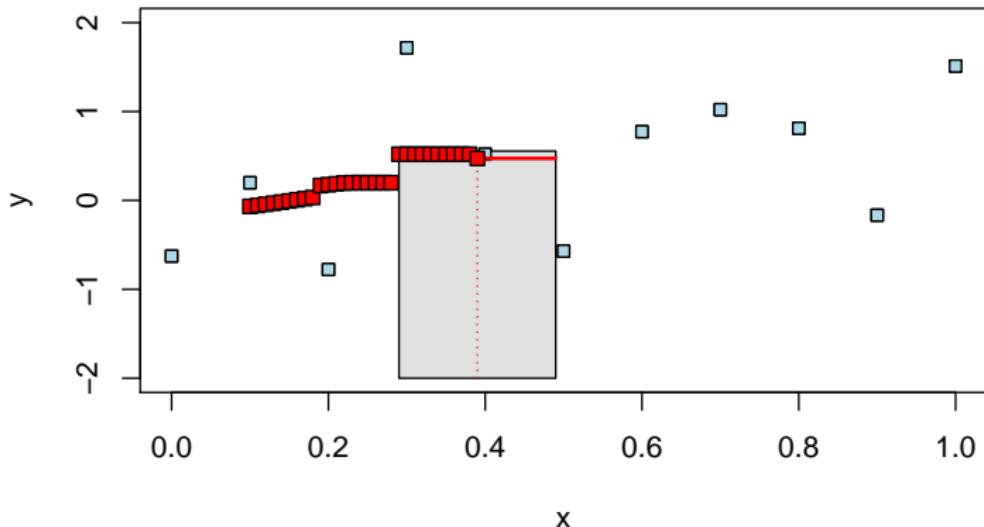
## Vážené klouzavé průměry

- Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



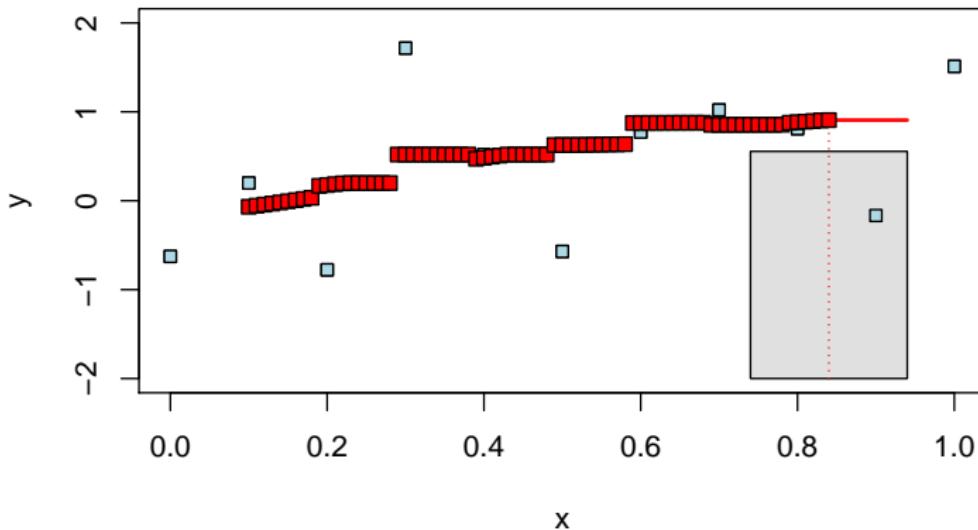
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



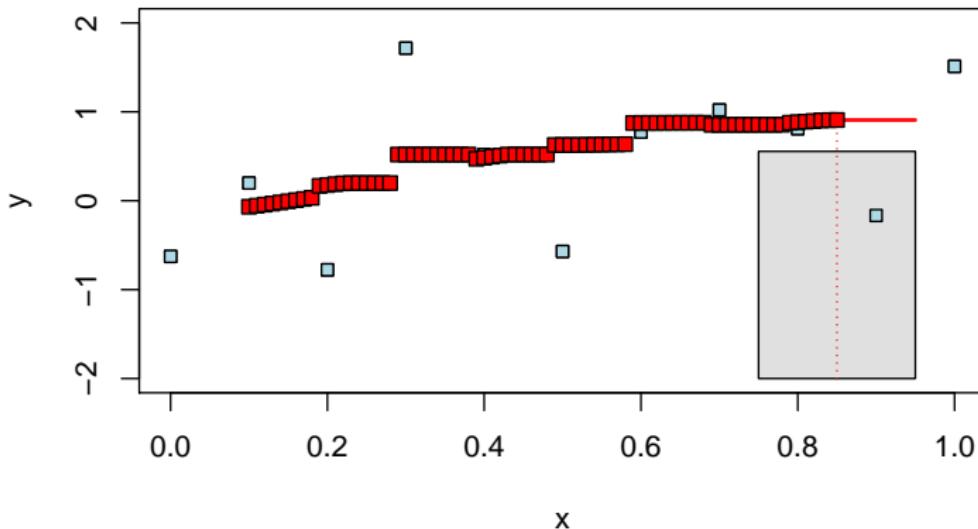
## Vážené klouzavé průměry

- Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



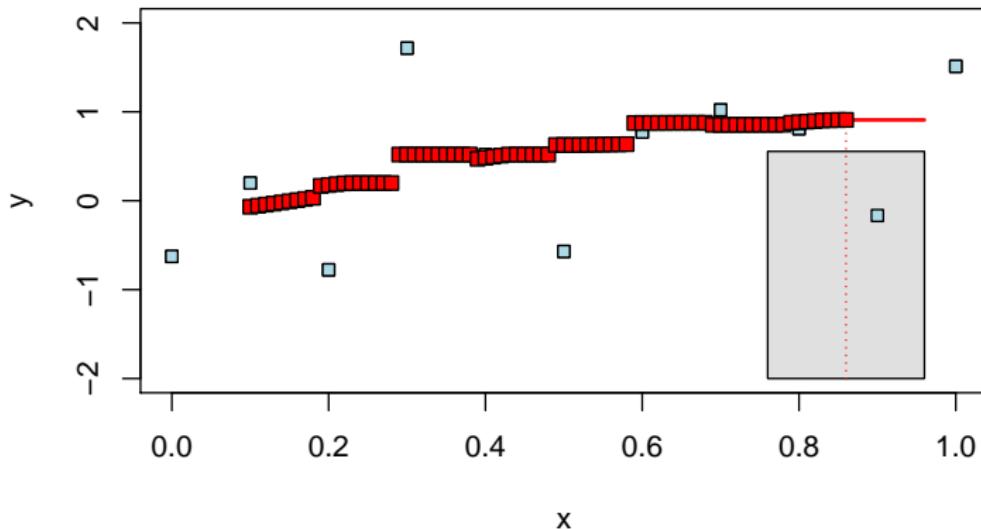
## Vážené klouzavé průměry

- Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



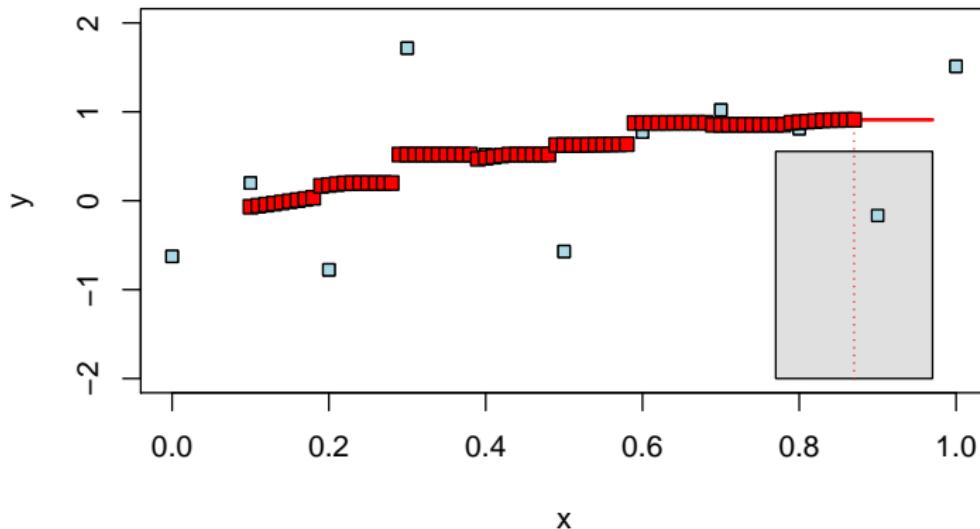
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



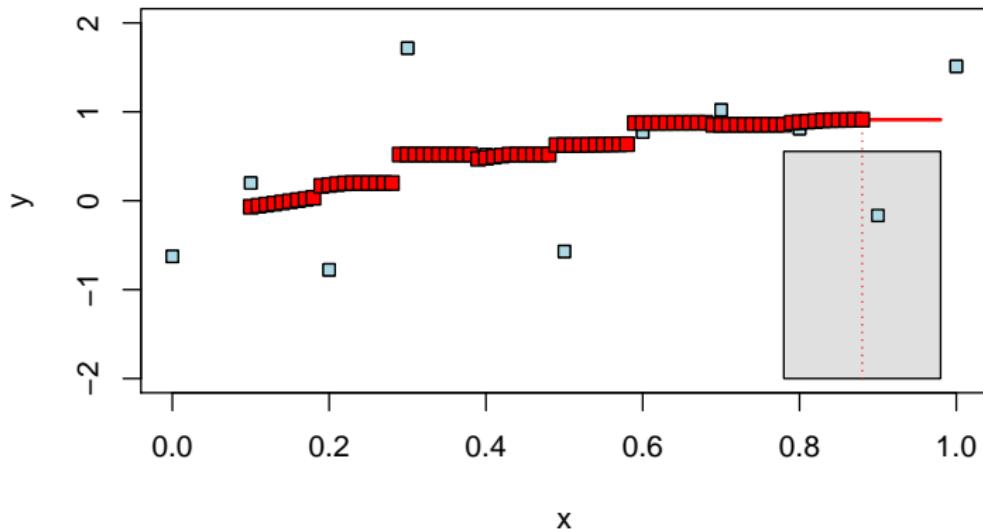
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



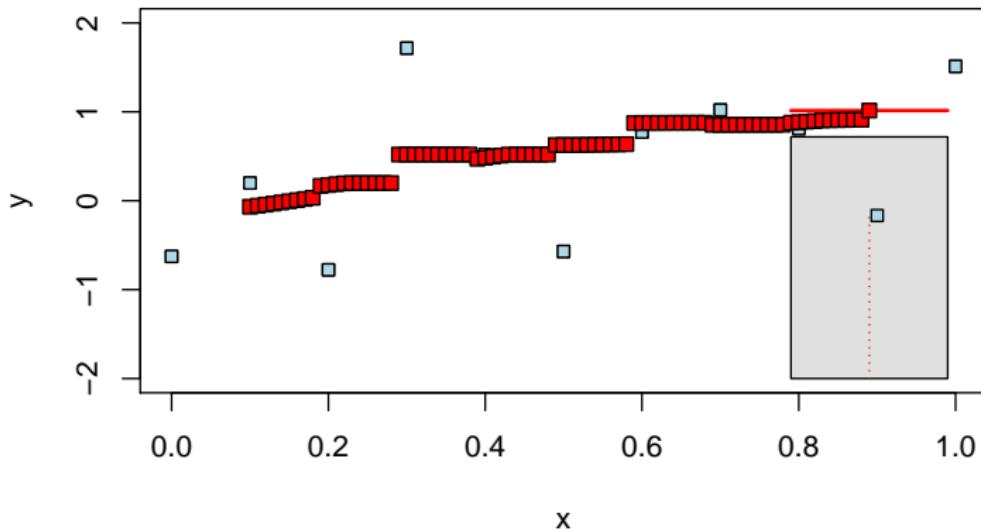
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



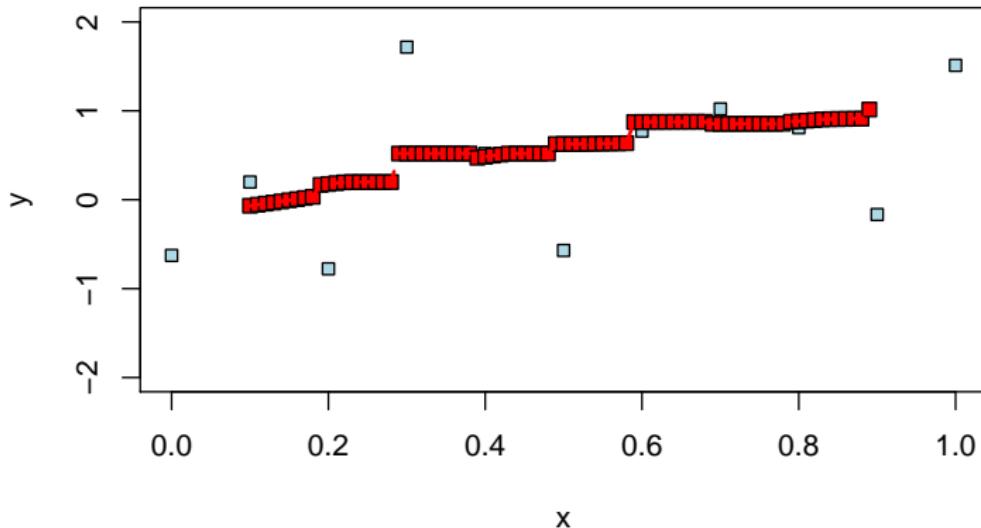
## Vážené klouzavé průměry

- Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



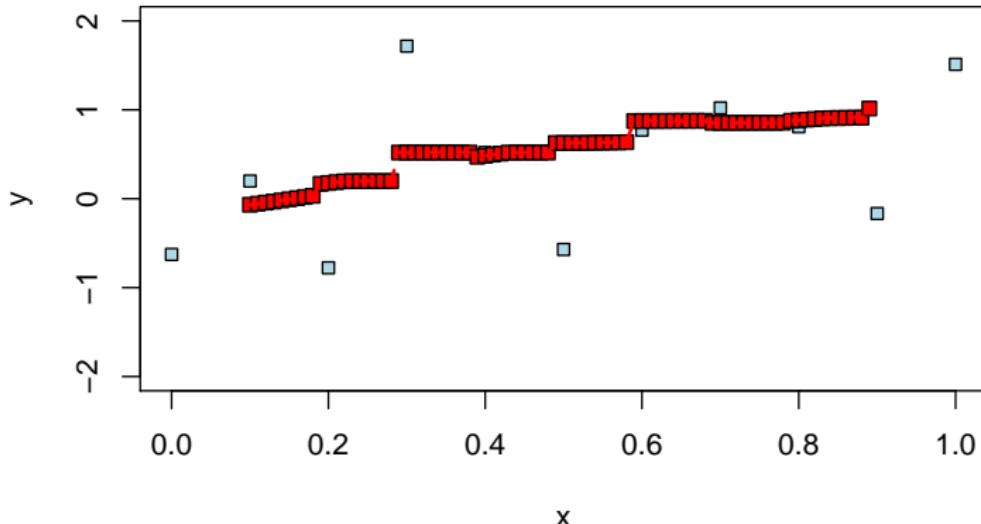
## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



## Vážené klouzavé průměry

- ❑ Avšak pro vhodnú volbu vyhlazovacích váh je možné získat určitým zobecněním hladkú křivku v celém definičním oboru  $\mathcal{D}$ .



- ❑ Výsledná křivka nevypadá úplně hladce, ale to je z důvodu příliš hrubého gridu bodů z  $\mathcal{D}$ ) v kterých počítame vážený průměr.

# Konstrukce KP vyrovnaním úseků polynomy

- **IDEA:** váhy  $w_j$  pro vyrovnaní hodnot  $y_i$  volíme tak, že  $2r+1$  členů řady, t.j. hodnoty  $y_{i-r}, \dots, y_i, \dots, y_{i+r}$ , approximujeme vhodným polynomem stupně  $p \in \mathbb{N}$ ; Vyrovnaná hodnota  $\hat{y}_i$  je pak hodnota polynomu, ktorá odpovídá pozorování  $y_i$ .
- hodnota  $p \in \mathbb{N}$  se nazýva řad klouzavého průměru;
- formálně zapsáno, pro pozorování  $y_{i-r}, \dots, y_{i+r}$  uvažujeme polynom

$$y_{i+u} \approx c_0 + c_1 u + c_2 u^2 + \dots + c_p u^p \quad \text{pro } u = -r, \dots, r; \quad (2)$$

- resp. zapsáno v maticovém tvaru  $\mathbf{y}_{(i:r)} \approx \mathbb{F}\mathbf{c}$ , kde

$$\mathbf{y}_{(i:r)} = \begin{pmatrix} y_{i-r} \\ \vdots \\ y_{i+r} \end{pmatrix} \approx \begin{pmatrix} 1 & (-r) & (-r)^2 & \dots & (-r)^p \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & r & r^2 & \dots & r^p \end{pmatrix} \cdot \begin{pmatrix} c_0 \\ \vdots \\ c_p \end{pmatrix}$$

- vyrovnanou hodnotu  $\hat{y}_i$  pro  $y_i$  pak dostaneme dosazením  $u = 0$  do (2);

## Váhy pomocí projekční matice

- ❑ pro část pozorování  $\mathbf{y}_{(i:r)} = (y_{i-r}, \dots, y_{i+r})^\top$  máme pro vyrovnání vztah

$$\hat{\mathbf{y}}_{(i:r)} = \mathbb{F} \cdot \hat{\mathbf{c}};$$

- ❑ pro odhadnuté parametry  $\hat{\mathbf{c}} = (\hat{c}_1, \dots, \hat{c}_p)^\top$  zase platí

$$\hat{\mathbf{c}} = (\mathbb{F}^\top \mathbb{F})^{-1} \mathbb{F}^\top \mathbf{y}_{(i:r)};$$

- ❑ pro vyrovnané hodnoty  $\hat{\mathbf{y}}_{(i:r)} = (\hat{y}_{i-r}, \dots, \hat{y}_{i+r})^\top$  proto dostaneme

$$\hat{\mathbf{y}}_{(i:r)} = \mathbb{F}(\mathbb{F}^\top \mathbb{F})^{-1} \mathbb{F}^\top \mathbf{y}_{(i:r)} = \mathbb{H} \mathbf{y}_{(i:r)};$$

- ❑ matice  $\mathbb{H} = \mathbb{F}(\mathbb{F}^\top \mathbb{F})^{-1} \mathbb{F}^\top$  se nazýva **projekční matici**;
- ❑ projekční matici definuje linárne zobrazení z  $\mathbb{R}^{2r+1}$  do  $p+1$  rozměrného podprostoru (projekce z  $\mathbb{R}^{2r+1}$  do  $\mathbb{R}^{p+1}$ ) v  $\mathbb{R}^{2r+1}$ ;
- ❑ projekční matici  $\mathbb{H}$  je typu  $(2r+1) \times (p+1)$  a v prostředním řádku obsahuje váhy pro vyrovnání hodnoty  $y_i$ ;

## Váhy $w_j$ vs. parametre $c_1, \dots, c_p$

- pro vyhlazené hodnoty  $\hat{y}_i$ , pro  $i = r + 1, \dots, n - r$ , máme obecně

$$\hat{y}_i = \sum_{j=-r}^r w_j y_{i+j} = \mathbf{h}_{r+1}^\top \mathbf{y}_{(i:r)} = \hat{c}_1,$$

kde  $\mathbf{h}_{r+1} = (h_{(r+1)1}, \dots, h_{(r+1)(2r+1)})^\top = (w_{-r}, \dots, w_r)^\top$ , je  $(r+1)$ -ní řádek projekční matici  $\mathbb{H} = (\mathbf{h}_1, \dots, \mathbf{h}_{2r+1})^\top$ ;

- maticově můžeme také použít vyjádření ve tvaru

$$\hat{\mathbf{y}}_{(i:r)} = \mathbb{H} \mathbf{y}_{(i:r)} = \mathbb{F} (\mathbb{F}^\top \mathbb{F})^{-1} \mathbb{F}^\top \mathbf{y}_{(i:r)} = \mathbb{F} \hat{\mathbf{c}},$$

přičemž vyhlazená hodnota  $\hat{y}_i$ , která nás zajíma, je  $(r+1)$ -ní element vektoru  $\hat{\mathbf{y}}_{(i:r)} = (\hat{y}_{i-r}, \dots, \hat{y}_{i+r})^\top$ ;

- je důležité si uvědomit, že váhy  $w_{-r}, \dots, w_r$  nezávisí na indexu  $i = r + 1, \dots, n - r$  a pro každou vyhlazenou hodnotu  $\hat{y}_i$  jsou stejné; (váhy  $w_{-r}, \dots, w_r$  závisí pouze na matici  $\mathbb{F}$ , která je pořád stejná)
- naproti tomu odhadnuté parametre  $\hat{\mathbf{c}} = (\hat{c}_1, \dots, \hat{c}_p)^\top$  na indexu  $i = r + 1, \dots, n - r$  závisí, a pro každé  $\hat{y}_i$  jsou parametry obecně různé; (odhady  $\hat{c}_1, \dots, \hat{c}_p$  totíž závisia na matici  $\mathbb{F}$ , ale tiež na vektore  $\mathbf{y}_{(i:r)}$ )

## Odhad parametrů $c_0, \dots, c_p$

- ❑ odhad parametrov  $c_0, \dots, c_p$  pomocou metódy nejmenších čtverců;

### Samostatný úkol

Jak vypadá v tomhle případě matici  $\mathbb{F}$  a jak se mení v závislosti na požadovanej hodnote  $y_i$ , pro  $i = -r, \dots, r$ , kterú chceme vyhľazovať?

Jak vypadá soustava normálných rovníc a příslušná projekční matice?

### Príklad

Uvažujte kubický polynom pro  $p = 3$  a  $r = 2$ . Polynom pro určení váh je ve tvaru  $y_{i+u} \approx c_0 + c_1 u + c_2 u^2 + c_3 u^3$ , kde  $c_0, \dots, c_3 \in \mathbb{R}$  jsou neznámé parametry.

- ❑ sestavte příslušnou matici  $\mathbb{F}$ ;
- ❑ nájděte projekčnou matici  $\mathbb{H} = \mathbb{F}(\mathbb{F}^\top \mathbb{F})^{-1} \mathbb{F}^\top$ ;
- ❑ nájděte váhy  $w_j$ , pro  $j = -2, 1, 0, 1, 2$  a spočtěte  $\hat{y}_i$ , pro  $i = 3, \dots, n-2$ ;

## Vyrovnávané hodnoty a predikce

- na rozdíl od klasických aritmetických klouzavých průměrů je možné využít vážené klouzavé průměry aj k vyrovnání počátečních a koncových hodnot;
- pro vyhlazení napr. koncového úseku stačí v (2) vhodne dosadit za  $u$ ;

Napr. pro  $r = 1$  a  $p = 1$ , máme  $y_{i+u} \approx c_0 + c_1 u$ , pro  $u = -1, 0, 1$  a  $i = 2, \dots, n-1$ ;

Pro vylazení  $y_n$  dosadíme:  $i \leftarrow n-1$  a  $u \leftarrow 1 \Rightarrow y_n = y_{(n-1)+1} \approx c_0 + c_1$  a  $\hat{y}_n = \hat{c}_0 + \hat{c}_1$ ;

- analogicky lze použít výraz (2) i pro budoucí predikce;

Napr. pro  $r = 2$  a  $p = 2$ , máme  $y_{i+u} \approx c_0 + c_1 u + c_2 u^2$ , pro  $u = -2, \dots, 2$  a  $i = 3, \dots, n-2$ ;

Predikce  $y_{n+1}$ :  $i \leftarrow n-2$  a  $u \leftarrow 3 \Rightarrow y_{n+1} = y_{(n-2)+3} \approx c_0 + 3c_1 + 9c_2$  a  $\hat{y}_{n+1} = \hat{c}_0 + 3\hat{c}_1 + 9\hat{c}_2$ ;

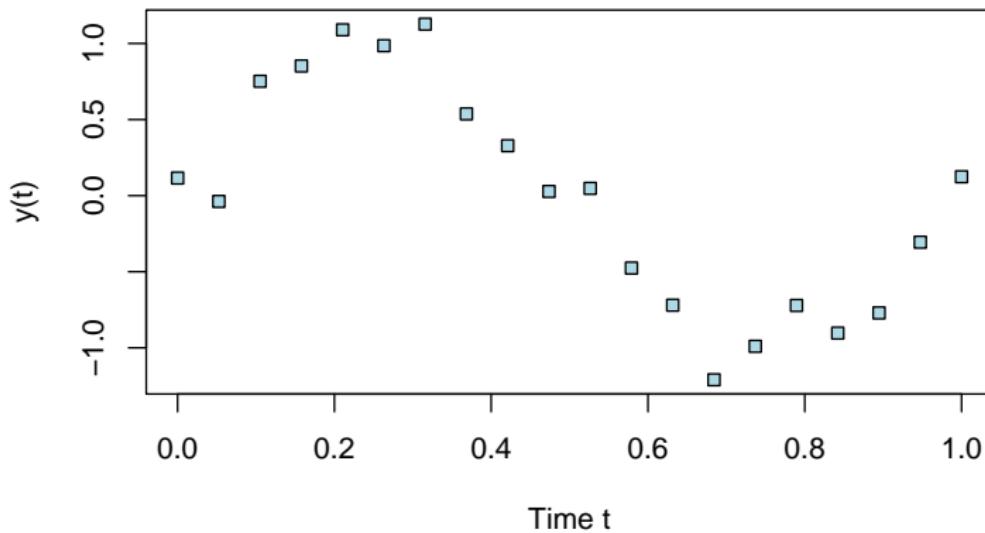
### Príklad

Uvažujte kubický polynom pro  $p = 3$  a  $r = 2$ . Polynom pro určení váh je ve tvaru  $y_{i+u} \approx c_0 + c_1 u + c_2 u^2 + c_3 u^3$ , kde  $c_0, \dots, c_3 \in \mathbb{R}$  jsou neznámé parametry.

- spočtěte predikci o jeden krok dopředu a explicitně vyjádříte váhy pro vážený průměr;

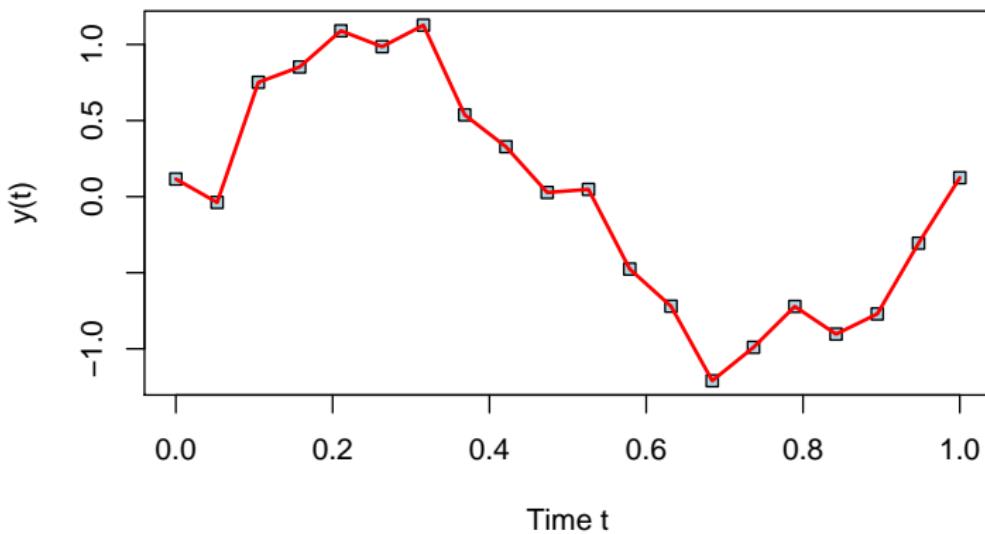
## Vychýlení vs. variabilita

- ❑ Jak zvolit/vybrat vhodnou míru vyhlazení?
- ❑ Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



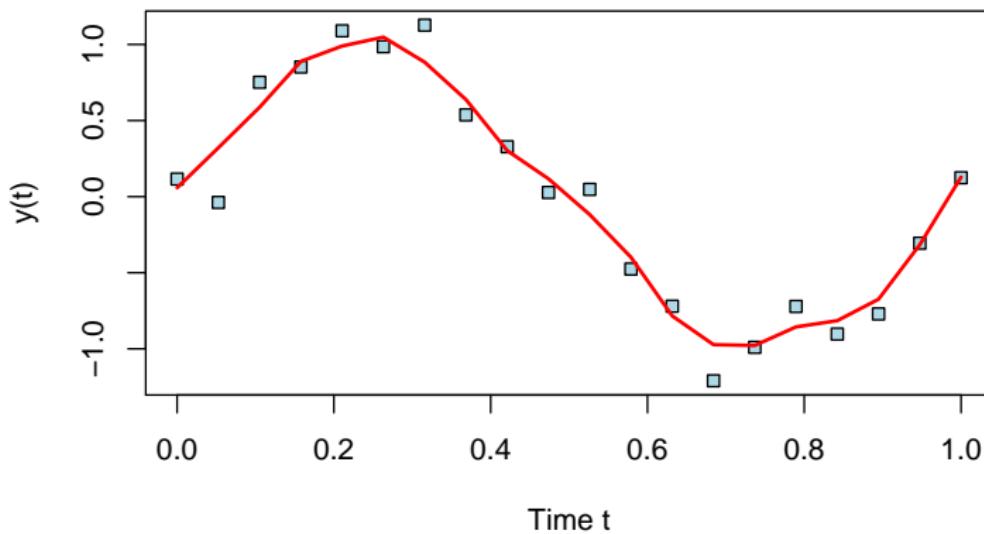
## Vychýlení vs. variabilita

- Jak zvolit/vybrat vhodnou míru vyhlazení?
- Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



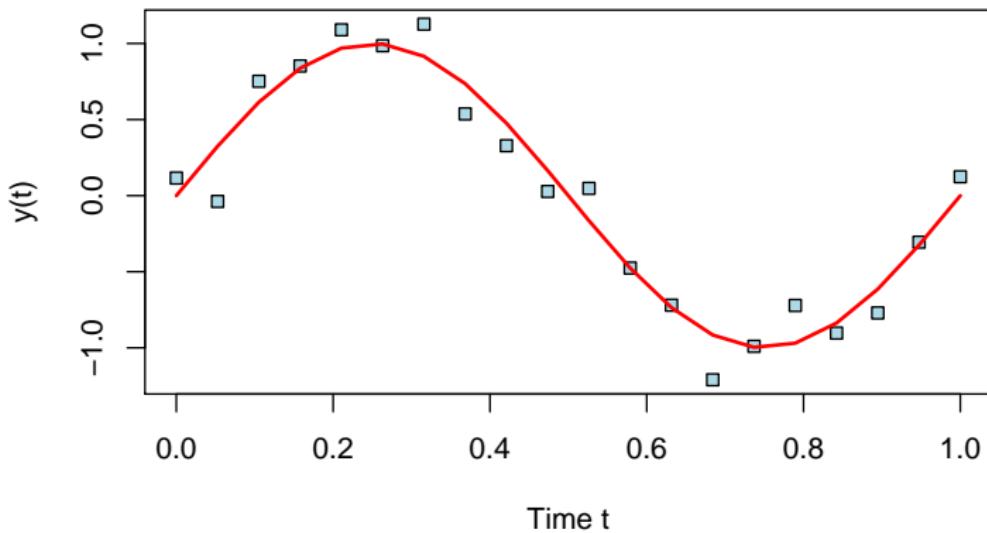
## Vychýlení vs. variabilita

- Jak zvolit/vybrat vhodnou míru vyhlazení?
- Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



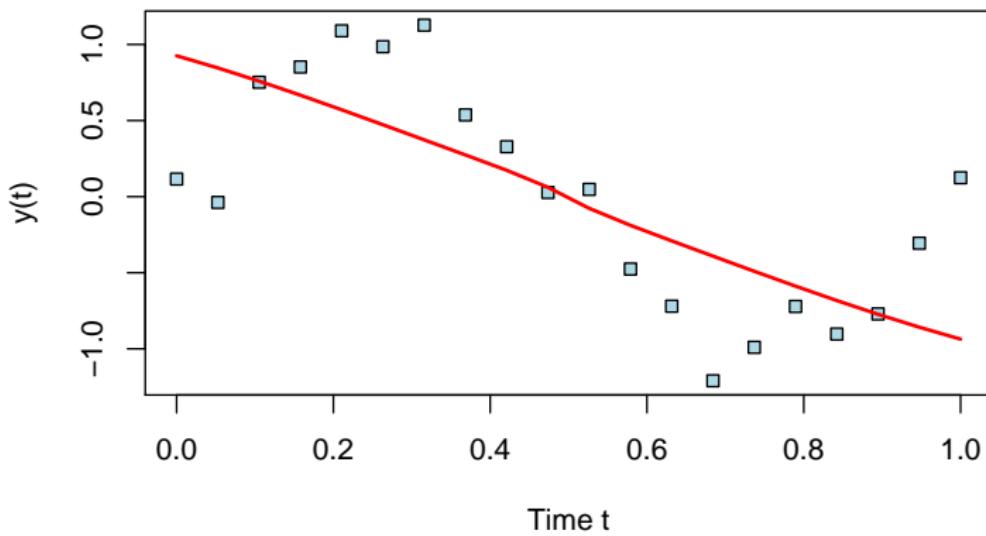
# Vychýlení vs. variabilita

- ❑ Jak zvolit/vybrat vhodnou míru vyhlazení?
- ❑ Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



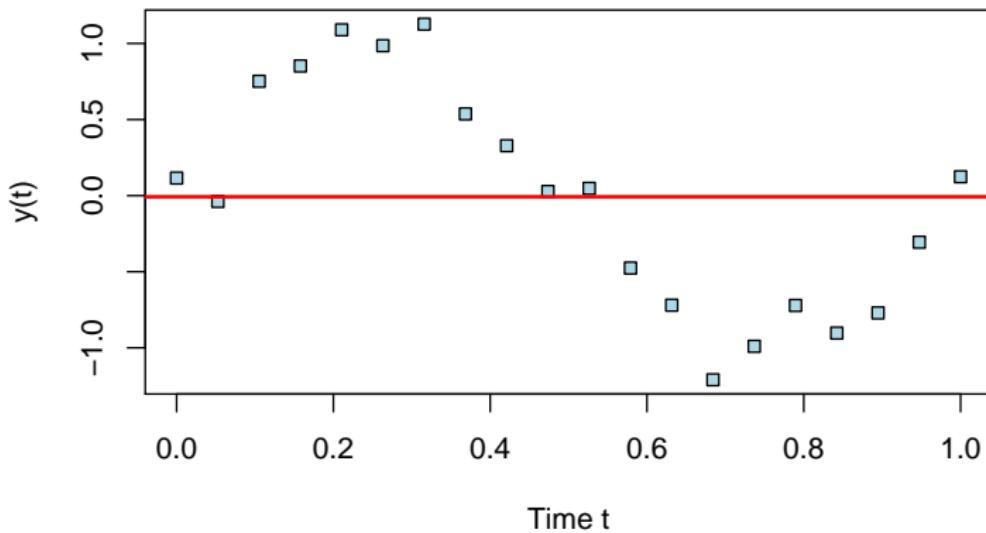
## Vychýlení vs. variabilita

- ❑ Jak zvolit/vybrat vhodnou míru vyhlazení?
- ❑ Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



## Vychýlení vs. variabilita

- ❑ Jak zvolit/vybrat vhodnou míru vyhlazení?
- ❑ Lze aplikovat nějaké optimálne kritérum pomocí kterého se rozhodnout?



## Whittacker-Hendersonová metoda

Základním úkolem vyhlazování dat je odhadnout hladký, pomalu se měnící trend. Zároveň chceme dosáhnout co nejlepší zhody mezi původními daty a vylazenými daty (zhodu mezi daty a modelem);

- Dokonalé vyhlazení**

⇒ příliš velký součet čtverců odchylek, a malá zhoda s původními daty;

- Dokonalá zhoda s daty**

⇒ nulový součet čtverců odchylek, príliš velká variabilita, interpolace;

## Whittacker-Hendersonová metoda

Základnou úlohou vyhlazování dat je odhadnout hladký, pomalu se měnící trend. Zároveň cheme dosáhnout co nejlepší zhodu mezi původními daty a vylazenými daty (zhodu mezi daty a modelem);

- Dokonalé vyhlazení**

⇒ příliš velký součet čtverců odchylek, a malá zhoda s původními daty;

- Dokonalá zhoda s daty**

⇒ nulový součet čtverců odchylek, príliš velká variabilita, interpolace;

### Whittacker/Hendersonova metoda

Metoda, která umožňuje hledat kompromis mezi těmito dvěma požadavky tím, že jim přiděluje rozdílnou váhu. Výrovnané hodnoty minimalizují kritérium

$$M(\hat{y}) = \underbrace{\sum_{i=1}^n (y_i - \hat{y}_i)^2}_{\text{součet čtverců}} + \lambda \cdot \underbrace{\sum_{i=r+1}^n (\Delta^r \hat{y}_i)^2}_{\text{penalta}}$$

kde  $\lambda > 0$  je nějaký vhodně zvolený ladící parametr.

## Whitttacker-Hendersonová metoda

- W-H metoda nepředpokláda žádny konkrétny tvar prokladané křivky;
- symbol  $\Delta^r \hat{y}_i$  označuje rekuzivnou  $r$ -tou zpětnou diferenci posloupnosti  $\hat{y}_i$ ;
- obecně platí, že  $\Delta^0 \hat{y}_i = \hat{y}_i$  a  $\Delta^1 \hat{y}_i = \Delta \hat{y}_i = \hat{y}_i - \hat{y}_{i-1}$ ;
- pro  $r$ -tou zpětnou diferenci platí  $\Delta^r \hat{y}_i = \Delta^{r-1} \hat{y}_i - \Delta^{r-1} \hat{y}_{i-1}$ ;
- obecně lze také zapsat pomocí binomické formule

$$\Delta^r \hat{y}_i = \binom{r}{0} \hat{y}_i - \binom{r}{1} \hat{y}_{i-1} + \cdots + (-1)^r \binom{r}{r} \hat{y}_{i-r},$$

# Whittacker-Hendersonová metoda

- W-H metoda nepředpokláda žádny konkrétny tvar prokladané křivky;
- symbol  $\Delta^r \hat{y}_i$  označuje rekuzivnou  $r$ -tou zpětnou diferenci posloupnosti  $\hat{y}_i$ ;
- obecně platí, že  $\Delta^0 \hat{y}_i = \hat{y}_i$  a  $\Delta^1 \hat{y}_i = \Delta \hat{y}_i = \hat{y}_i - \hat{y}_{i-1}$ ;
- pro  $r$ -tou zpětnou diferenci platí  $\Delta^r \hat{y}_i = \Delta^{r-1} \hat{y}_i - \Delta^{r-1} \hat{y}_{i-1}$ ;
- obecně lze také zapsat pomocí binomické formule

$$\Delta^r \hat{y}_i = \binom{r}{0} \hat{y}_i - \binom{r}{1} \hat{y}_{i-1} + \cdots + (-1)^r \binom{r}{r} \hat{y}_{i-r},$$

## IDEA:

Rekurzívní zpětná differenze je diskrétné zobecnění pojmu derivace. Základnou myšlenkou je penalizovať příliš velké rozdíly v danej  $r$ -tej differenci. Napr. pro  $r = 1$  penalizujeme příliš velké rozdíly v první differenci, t.j. pro  $\lambda \rightarrow \infty$  dostaneme vyhlazení ve tvaru prímky.

## Whittacker-Hendersonová metoda

- kritérium  $M(\hat{\mathbf{y}})$  lze zapsát aj v maticovém tvaru jako

$$M(\hat{\mathbf{y}}) = (\mathbf{y} - \hat{\mathbf{y}})^T (\mathbf{y} - \hat{\mathbf{y}}) + \lambda \cdot \hat{\mathbf{y}}^T \mathbb{K}^T \mathbb{K} \hat{\mathbf{y}};$$

- matice  $\mathbb{K}$  je typu  $(n - r) \times n$  a má tvar

$$\mathbb{K} = \begin{pmatrix} (-1)^r & \dots & -\left( \begin{array}{c} r \\ 1 \end{array} \right) & 1 & \dots & 0 \\ \vdots & (-1)^r & \dots & -\left( \begin{array}{c} r \\ 1 \end{array} \right) & \dots & \vdots \\ \vdots & \vdots & \vdots & \vdots & \vdots & \vdots \\ 0 & \dots & (-1)^r & \dots & -\left( \begin{array}{c} r \\ 1 \end{array} \right) & 1 \end{pmatrix}$$

- derivováním podle  $\hat{\mathbf{y}}$  dostaneme soustavu normálních rovnic

$$\nabla_{\hat{\mathbf{y}}} M(\hat{\mathbf{y}}) = \left( \frac{\partial M(\hat{\mathbf{y}})}{\partial \hat{y}_1}, \dots, \frac{\partial M(\hat{\mathbf{y}})}{\partial \hat{y}_n} \right) = 2\mathbf{y} - 2\hat{\mathbf{y}} + 2\lambda \mathbb{K}^T \mathbb{K} \hat{\mathbf{y}}$$

- riešime soustavu rovnic  $\nabla_{\hat{\mathbf{y}}} M(\hat{\mathbf{y}}) = 0 \implies$  řešení ve tvaru

$$\hat{\mathbf{y}} = (\mathbb{I} + \lambda \mathbb{K}^T \mathbb{K})^{-1} \mathbf{y};$$

## Zhrnutí

- ❑ Data jako posloupnost **deterministických** nebo **stochastických** veličin;
- ❑ Různe metody vyhlazování dat – prokladání vhodnou (hladkou) křivkou;
  - ❑ **Parametrické metody**  
(jednoduché, ale málo flexibilné)
  - ❑ **Semiparametrické metody**  
(vyrovnaní jako lineární kombinace funkci báze, poměrně dobrá flexibilita)
  - ❑ **Neparametrické metody**  
(bez omezení na tvar prokladáné křivky, nelze ale vyjadřit explicitně)
- ❑ V některých případech lze dokonce konstruovat predikci do budoucnosti;  
*(není vhodné používat na predikci o moc kroků dopredu...)*
- ❑ Základným rozhodovacím kritériom pre dobrý model je jeho využitie;  
*(flexibilita/adaptivita modelu vs. jeho zložitosť/komplexita)*
- ❑ Při vyhlazování dat pamatovat na vztah medzi vychýlením a variabilitou;  
*(prílišné vyhlazení  $\equiv$  malá variabilita a příliš velké odchýlky | vice versa)*
- ❑ Whittacker-Henderson - regularizační neparametrický postup;  
*(vhodnou volbou  $\lambda > 0$  a  $r \in \mathbb{N} \cup \{0\}$  lze dosáhnout požadovaný tvar)*

## Kapitola 2

# Diferenciální rovnice a modely růstu

# Modely růstu – motivace

Modely velikosti populace, kde velikost změny (růstu/poklesu) závisí na aktuálnem stavu (velikosti) populace.

(obecně řečeno, jedná se o model dynamiky nějaké populace)

## Široké uplatnění týchto modelů v ...

- mikrobiologie, virologie, či biologie**  
(pandemický vývoj, napr. Covid-19 ...)
- fyzika, chémia, alebo mechanika**  
(štiepenie, nukleárne reakcie, lavíny, ...)
- mikro/makro ekonómia a finance**  
(pyramidové schémy, modely kapitálu, ...)
- IT, informatika, technika**  
(výpočetná sila a zložitost, singularity, ...)

## Modely růstu – formálně

- jedná se **víceparametrický deterministický (nelineární) model** pro modelování růstu (stavu) nějaké populace (počet obyvatelstva, zásoby nějakého statku, objem komodity, atd') v závislosti na velikosti;
- zaužívané značení:  $y(t) \geq 0$  jako stav (velikost) populace **v čase**  $t \in \mathbb{R}$ ;
- model určen pomocí **diferenciální rovnice**, čo umožňuje vyjádřit **závislost rychlosti růstu na velikosti populace** v čase  $t \in \mathbb{R}$ ;
- **IDEA:** očekáváme, že populace by měla růst rychleji, když je velká, naopak výrazne pomalejšie, ked' je malá;
- diferenciální rovnice často v tvaru, který v určitem zmyslu modeluje lineární závislost růstu na velikosti:

$$\frac{dy}{dt} = a \cdot y \cdot g\left(\frac{y}{k}\right)$$

kde  $y \equiv y(t)$  je funkce  $t \in \mathbb{R}$  a  $a, k > 0$  jsou **neznámé parametry**;

## Korekce lineární závislosti růstu na velikosti

Funkce  $g(\cdot)$  v zápisu diferenciální rovnice se používá ke korekci lineární závislosti růstu na velikosti populace – bez této korekce je totiž většina modelů praktický nesmyslných;

- **Volba  $g(x) = 1$ : Klasický model exponenciálního růstu**

$$\frac{dy}{dt} = a \cdot y \implies \text{řešení } y(t) = be^{at};$$

→ pro nějaké parametry  $a, b > 0$ ;

- **Volba  $g(x) = 1 - x$ : Model logistického růstu**

$$\frac{dy}{dt} = a \cdot y \cdot \left(1 - \frac{y}{k}\right) \implies \text{řešení } y(t) = \frac{k}{1 + be^{-at}};$$

→ pro nějaké parametry  $a, b, k > 0$ ;

- **Volba  $g(x) = -\log x$ : Model Gomertzovej křivky**

$$\frac{dy}{dt} = -a \cdot y \cdot \log\left(\frac{y}{k}\right) \implies \text{řešení } y(t) = k \cdot \exp\{-be^{-at}\};$$

→ pro nějaké parametry  $a, b, k > 0$ ;

# Modely růstu

## Príklad

Uvažujte jednoduchý model exponenciálního růstu. Ukážte, že funkce

$$y(t) = be^{at}$$

je skutečně řešením diferenciální rovnice  $dy/dt = ay$ .

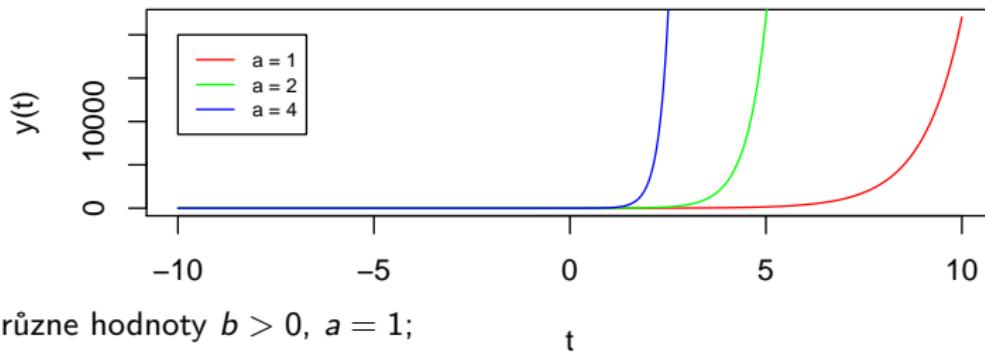
## Príklad

Uvažujte model logistického růstu pro nějaké obecné  $k > 0$ .

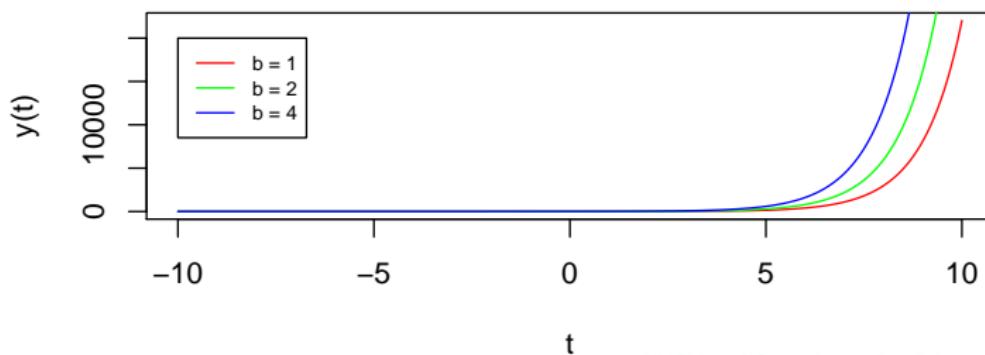
- ukážte, že funkce  $y(t) = \frac{k}{1+be^{-at}}$  je řešením diferenciální rovnice  $dy/dt = ay(1 - y/k)$
- najděte inflexní bod a dokážte, že křivka logistického růstu je symetrická kolem tohoto bodu;

## Modely exponenciálneho rústu

- ❑ rôzne hodnoty  $a > 0$ ,  $b = 1$ ;

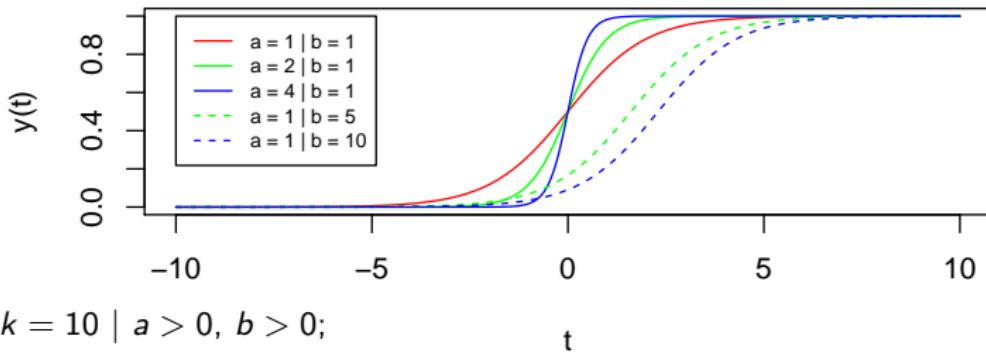


- ❑ rôzne hodnoty  $b > 0$ ,  $a = 1$ ;

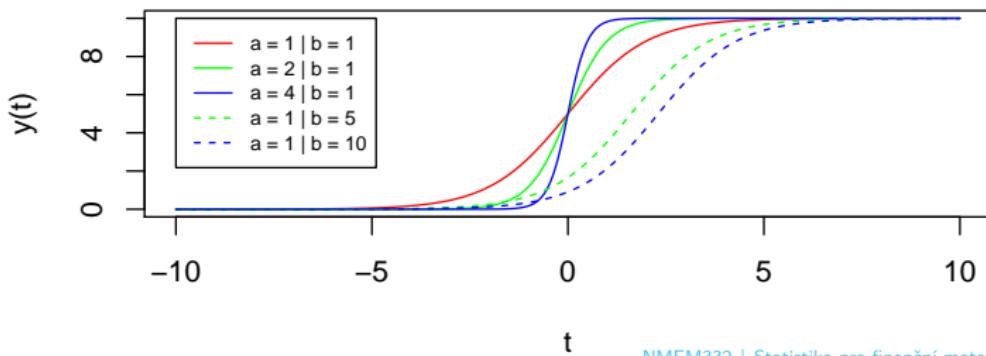


## Modely logistického růstu

- $k = 1 \mid a > 0, b > 0;$

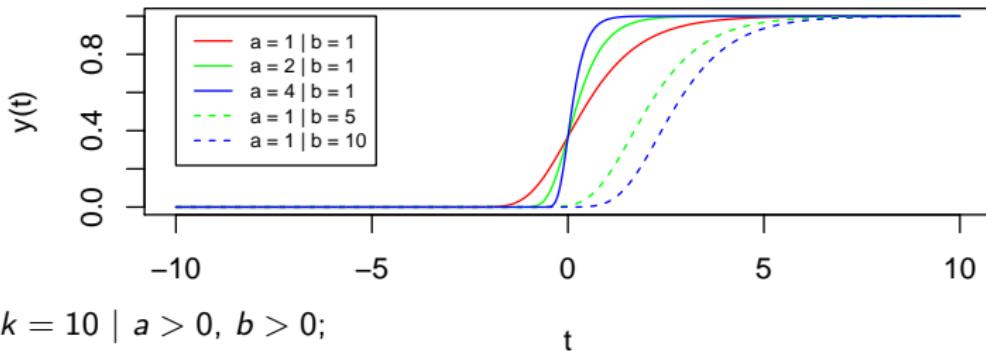


- $k = 10 \mid a > 0, b > 0;$

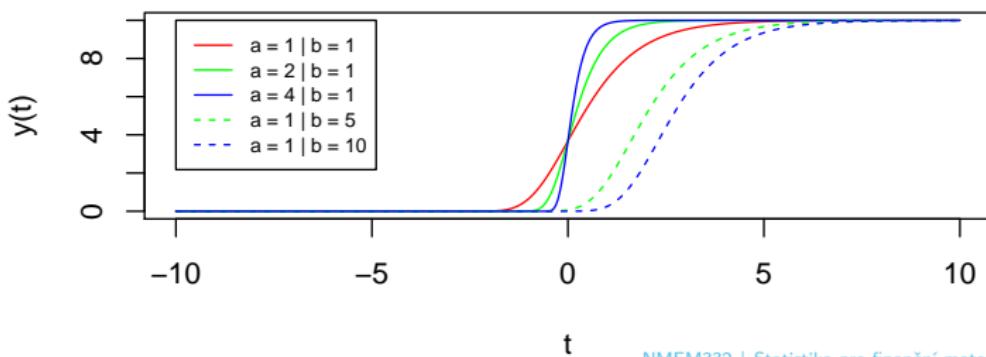


## Modely Gompertzové křivky

- $k = 1 \mid a > 0, b > 0;$



- $k = 10 \mid a > 0, b > 0;$



# Modely růstu – praktické aplikace

## □ Model exponenciálního růstu

- model neomezeného růstu při neomezených zdrojích;
- aplikovatelný pouze v krátkodobém časovém horizontu;
- v praxi většinou nedostupnost zdrojů při určitem stavu populace;

## □ Model logistického růstu

- model s korekcí pro saturovanou hodnotu – parametr  $k > 0$ ;
- inflexní bod pro  $t_0 = \frac{\ln b}{a}$ , kde  $y(t_0) = k/2$  (symetrie vzhledem k  $t_0$ );
- pro celkový stav populace vždy platí, že  $0 < y(t) < k$  pro  $t \in \mathbb{R}$ ;
- hodnota  $(1 - y/k)$  omezuje nové přirůstky pro velkou populaci (málo zdrojů) – jedná se o tzv. sigmoidální křivku (sigmoid function);

## □ Gompertzová křivka

- zbecněná sigmoidální křivka (prudký nárůst, pomalejší saturace);
- inflexní bod pro  $t \in \mathbb{R}$ , kde  $y(t) = k/e$  (ale není symetrická);
- častá aplikace např. pro tabulky úmrtnosti, růst nádorů, počet mobilních telefonů v populaci, a pod.;

## Odhady parametrů v nelineárních modelech růstu

Základní problém spočívá v tom, že funkce, kterou chceme proložit daty, není lineární funkcí hledaných (neznámých) parametrů – koeficientů.

Nelze proto přímo aplikovat metodu nejmenších čtverců a stejně tak nelze získat explicitní řešení.

### Co lze využít?

- preparametrisování modelu do lineárního tvaru;
- approximace modelu a aplikace iterativních postupů;
- numerické (approximativní) řešení pomocí počítačů;

# Odhady parametrů v nelineárních modelech růstu

Základní problém spočívá v tom, že funkce, kterou chceme proložit daty, není lineární funkcí hledaných (neznámých) parametrů – koeficientů.

Nelze proto přímo aplikovat metodu nejmenších čtverců a stejně tak nelze získat explicitní řešení.

## Co lze využít?

- preparametrisování modelu do lineárního tvaru;
- approximace modelu a aplikace iterativních postupů;
- numerické (approximativní) řešení pomocí počítačů;

## Aplikace na data

$t$	$t_1$	$t_2$	$t_3$	...	$t_n$
$y$	$y(t_1)$	$y(t_2)$	$y(t_3)$	...	$y(t_n)$

# Odhad parametrů pro exponenciální růst

- základní diferenciální rovnice a příslušné řešení:

$$\frac{dy}{dt} = a \cdot y \quad \text{a} \quad y(t) = b e^{at},$$

pro nějaké neznáme parametry  $a, b > 0$ ;

- rovnici lze logaritmovat a vyjádřit ve tvaru

$$\log(y(t)) = \log(b) + at;$$

- následně lze metodu nejmenších čtverců aplikovat na data

$$(t_1, \log(y(t_1)))^\top, \dots, (t_n, \log(y(t_n)))^\top,$$

a odhadnout neznáme parametry  $a, \tilde{b} \in \mathbb{R}$ , pro  $\tilde{b} = \log(b)$

## Samostatný úkol

Uvažujte jednoduchý exponenciální růst a najděte řešení pro odhad parametrů  $\log(b) \in \mathbb{R}$  a  $a > 0$ . Vyjádřete příslušnou matici  $\mathbb{F}$  a spočtěte také projekční matici  $\mathbb{H}$ . Najděte vhodné odhady pro  $a, b > 0$ .

# Odhad parametrů pro logistický růst

- základní diferenciální rovnice a příslušné řešení:

$$\frac{dy}{dt} = a \cdot y \cdot \left(1 - \frac{y}{k}\right) \quad \text{a} \quad y(t) = \frac{k}{1 + be^{-at}};$$

pro nějaké neznámé parametry  $a, b > 0$ ;

- diferenciální rovnici lze approximovat pomocí diferenční rovnice

$$\frac{\Delta y_{t_i}}{\Delta t_i} = ay_{t_i} \left(1 - \frac{y_{t_i}}{k}\right)$$

- následně lze metodu nejmenších čtverců aplikovat na data

$$\left(y_{t_2}, \frac{\Delta y_{t_2}}{\Delta t_2 y_{t_2}}\right)^T, \dots, \left(y_{t_n}, \frac{\Delta y_{t_n}}{\Delta t_n y_{t_n}}\right)^T; \quad (3)$$

pro parametre  $a$  a  $a/k$ . Parametr  $b > 0$  pak vyjádřit z rovnice pro řešení.

## Samostatný úkol

Uvažujte jednoduchý logistický růst a najděte řešení pro odhad parametrů  $a, k > 0$ . Najděte také vhodný odhad pro parametr  $b > 0$ .

## Vylepšení odhadů pro logistický růst

Odhady parametrů  $a, b, k > 0$  získané v předchozím kroku jsou hodně hrubé jelikož jsme diferenciální rovnici diskretizovali – t.j. approximovali pomocí diferenční rovnice. Získané odhady ale lze vylepšit – opět pomocí metody nejmenších čtverců.

- řešení diferenciální rovnice lze také parametrisovat jako

$$y(t) = \frac{k}{1 + be^{-at}} = \frac{d}{c + e^{-(\hat{a}_1 + \epsilon)t}},$$

pro  $a = \hat{a}_1 + \epsilon$ ,  $b = \frac{1}{c}$  a  $k = \frac{d}{c}$  (kde  $\hat{a}_1$  je odhad z předchozího kroku).

- pro hodnoty  $\epsilon t$  hodně malé, lze použít Taylorov rozvoj

$$e^{-\epsilon t} \approx 1 - \epsilon t;$$

- následně dostaneme approximaci pro  $y_{t_i}$  ve tvaru

$$y_{t_i} \approx \frac{d}{c + e^{-\hat{a}_1 t_i} (1 - \epsilon t_i)}, \quad i = 1, \dots, n;$$

- metodu nejmenších čtverců následně aplikovat na model

$$y_{t_i} e^{-\hat{a}_1 t_i} \approx d - c y_{t_i} + \epsilon t_i y_{t_i} e^{-\hat{a}_1 t_i}, \quad i = 1, \dots, n;$$

# Vylepšení odhadů pro logistický růst

## Samostatný úkol

Uvažujte logistický model růstu a navrhněte, jak by měla vypadat matice  $\mathbb{F}$  pro vylepšení odhadu parametrů  $a, b, k > 0$  pomocí nové parametrisace

$$y(t) = \frac{k}{1 + be^{-at}} = \frac{d}{c + e^{-(\hat{a}_1 + \epsilon)t}},$$

pro  $a = \hat{a}_1 + \epsilon$ ,  $b = \frac{1}{c}$  a  $k = \frac{d}{c}$ , kde  $\hat{a}_1$  je odhad získaný metodou nejmenších čtverů, aplikovaných na data v (3). Nájděte soustavu lineárních rovníc pro odhad neznámých parametrů  $d, c$  a  $\epsilon$ .

- dosazením odhadov  $\hat{d}, \hat{c}$  a  $\hat{\epsilon}$  do vyjadření původních parametrů  $a, b$  a  $k$  dostaneme vylepšené odhady  $\hat{a}, \hat{b}$  a  $\hat{k}$ ;
- tenhle postup lze iterativně opakovat a získat ještě přesnější odhadы;

## Odhad parametrů pre Gomertzov model

- základní **diferenciální rovnice** a příslušné řešení:

$$\frac{dy}{dt} = a \cdot y \cdot \log(y/k) \quad \text{a} \quad y(t) = k \cdot \exp\{-be^{-at}\};$$

pro nějaké neznáme parametry  $a, b, k > 0$ ;

- nelze efektivně využít ani logaritmování, ani approximaci pomocí differencí;
- riešenie lze získať riešením problému **nelinerných najmenších štvorcov** a to pomocou počítačov a **numerických—iteratívnych postupov**;
- v praxi sa využívajú numerické postupy založené na rozličných modeloch a rôznych teoretických predpokladoch...

## Odhad parametrů pre Gomertzov model

- základní **diferenciální rovnice** a příslušné řešení:

$$\frac{dy}{dt} = a \cdot y \cdot \log(y/k) \quad \text{a} \quad y(t) = k \cdot \exp\{-be^{-at}\};$$

pro nějaké neznáme parametry  $a, b, k > 0$ ;

- nelze efektivně využít ani logaritmování, ani approximaci pomocí differencí;
- riešenie lze získať riešením problému **nelinerných najmenších štvorcov** a to pomocou počítačov a **numerických—iteratívnych postupov**;
- v praxi sa využívajú numerické postupy založené na rozličných modeloch a rôznych teoretických predpokladoch...
  - nelineárne najmenšie štvorce
  - metóda maximálnej viero hodnosti
  - Kalmanov filter
  - kombinácie predchádzajúcich metód
  - rôzne algoritmické (iteratívne) postupy

Numerické porovnanie rôznych postupov napr. v článku Patmanidis et al.(2017): Comparing Methods for Parameter Estimation of the Gompertz Tumor Growth Model. *20th IFAC World Congress, Jul 2017, Toulouse, France.* pp.12203 - 12209.  
DOI:10.1016/j.ifacol.2017.08.2289

## Newton-Raphson: Algoritmus

**IDEA:** Odhad neznámých parametrů pomocí minimalizace součtu čtverců—hledáme ale **argument minima** nelineární funkce (ne nutně konvexní). Napr. pro logistickou křivku řešíme

$$S(a, b, k) = \underset{a, b, k > 0}{\operatorname{Argmin}} \sum_{i=1}^n \left( y_{t_i} - \frac{k}{1 + be^{-at_i}} \right)^2,$$

kde předpokládame, že máme pozorování  $y_{t_1}, \dots, y_{t_n}$  v časech  $t_1, \dots, t_n$ ;

- předpokládame, že existují nějaké **počátečné hodnoty**  $a_0, b_0, k_0 > 0$ , které jsou dostatečně blízko skutečným (neznámym) hodnotám, pro které je dosaženo minimum;
- **Newton-Raphsonová metoda** pak spočívá v approximaci  $S(a, b, k)$  pomocí Taylorové řady v okolí bodu  $(a_0, b_0, k_0)^\top$ ;
- opakovaným postupom – **iteracemi** – získame finálné řešení;  
*(finálné řešení je pouze approximace skutečného řešení... dokonalost approximace závisí od volby počátečních hodnot  $a_0, b_0, k_0 > 0$  a také od celkového počtu uskutečněných iterací)*

## Newton-Raphson: Teoretické odvození

- Taylorov rozvoj pro  $S(a, b, k)$  v bodě  $(a_0, b_0, k_0)$ :

$$\begin{aligned} S(a, b, k) &= S(a_0, b_0, k_0) + \nabla S(a_0, b_0, k_0)^T (a - a_0, b - b_0, k - k_0)^T \\ &\quad + \frac{1}{2}(a - a_0, b - b_0, k - k_0) \nabla^2 S(a_0, b_0, k_0) (a - a_0, b - b_0, k - k_0)^T \\ &\quad + R(\tilde{a}, \tilde{b}, \tilde{k}); \end{aligned}$$

- Hledáme bod, pro který  $\nabla S(a, b, k) = 0 \Rightarrow$  obe strany derivujeme a položíme rovné hodnoty  $(0, 0, 0)^T$ ;
- Po úprave dostaneme rovnicu

$$\nabla S(a_0, b_0, k_0) = (-1) \cdot \nabla^2 S(a_0, b_0, k_0) (a - a_0, b - b_0, k - k_0)^T$$

a řešíme jako soustavu rovnic pro neznámé parametry  $a, b, k \in \mathbb{R}$ ;

- Pro iterovaný postup definujeme obecně **krok**  $\ell \in \mathbb{N}$  následovně:

$$\nabla S(a_{\ell-1}, b_{\ell-1}, k_{\ell-1}) = -\nabla^2 S(a_{\ell-1}, b_{\ell-1}, k_{\ell-1}) (a_\ell - a_{\ell-1}, b_\ell - b_{\ell-1}, k_\ell - k_{\ell-1})^T;$$

- postup opakujeme, až když nedosáhneme požadovanou přesnost, t.j.  $|a_\ell - a_{\ell-1}| < \epsilon$ ,  $|b_\ell - b_{\ell-1}| < \epsilon$  a  $|k_\ell - k_{\ell-1}| < \epsilon$ , pro nějaké malé  $\epsilon > 0$ ;

# Obecné modely růstu populace

- Dynamika populace lineárne závisla na velikosti populace:

$$\frac{dy}{dt} = a \cdot y \cdot g\left(\frac{y}{k}\right)$$

- Dynamika populace v obecnom modelu:

$$\frac{dy}{dt} = f(y, t)$$

Funkcia  $f(y, t)$  môže obecně predstavovať ľubovoľnú známu/neznámu, parametrickú/neparametrickú, lineárnu/nelineárnu funkciu, ktorá vyjadruje rýchlosť rastu populácie v čase  $t$ , v závislosti na aktuálnej veľkosti populácie  $y$ .

# Príklad: Covid-19 pandémia v USA

- **Data:** analýza na základe denných prírastkov novo-nakazených v Spojených štátach (US) v čase od 22.Januára 2020 do 6.Apríla 2020;
- Logistický (viac-parametrický) model rastu populácie infikovaných:

$$y(t) = y_{min} + \frac{y_{max} - y_{min}}{(1 + e^{-R(t-t_{mid})})^{\alpha}}$$

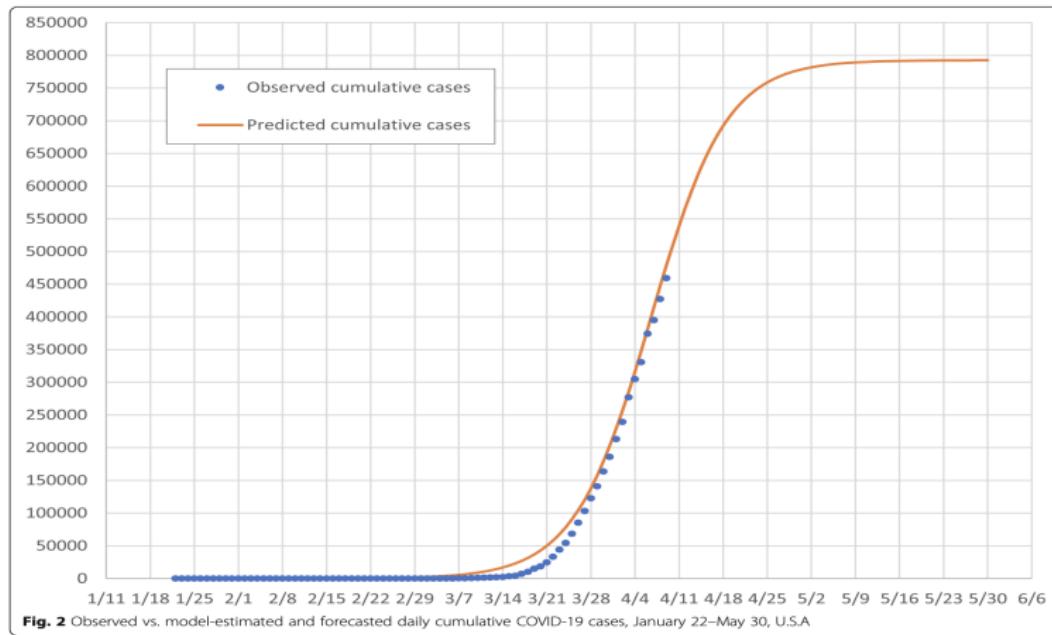
- $y(t)$  celkové počty nakazených obyvateľov v jednotlivých dňoch;
- $y_{min}, y_{max}$  minimálny a maximálny počet nakazených v US počas pandémie;
- $R$  miera denného exponenciálneho nárastu (číslo R);
- $t_{mid}$  odhadnutý vrchol pandémie (stabilné denné prírastky);
- $\alpha$  parameter asymetrie vzhládom k vrcholu pandémie  $t_{mid}$ ;
- Denný nárast nových prípadov—**prvá derivácia  $y'(t)$** ;  
(vyjadrením prvej derivácie dostaneme rovnicu pre dynamiku)

Chen et al. (2020). Reconstructing and forecasting the COVID-19 epidemic in the United States using a 5-parameter logistic growth model, *Global Health Research and Policy*, 5:25. DOI: 10.1186/s41256-020-00152-5

# Covid-19 pandémia – celková predikcia

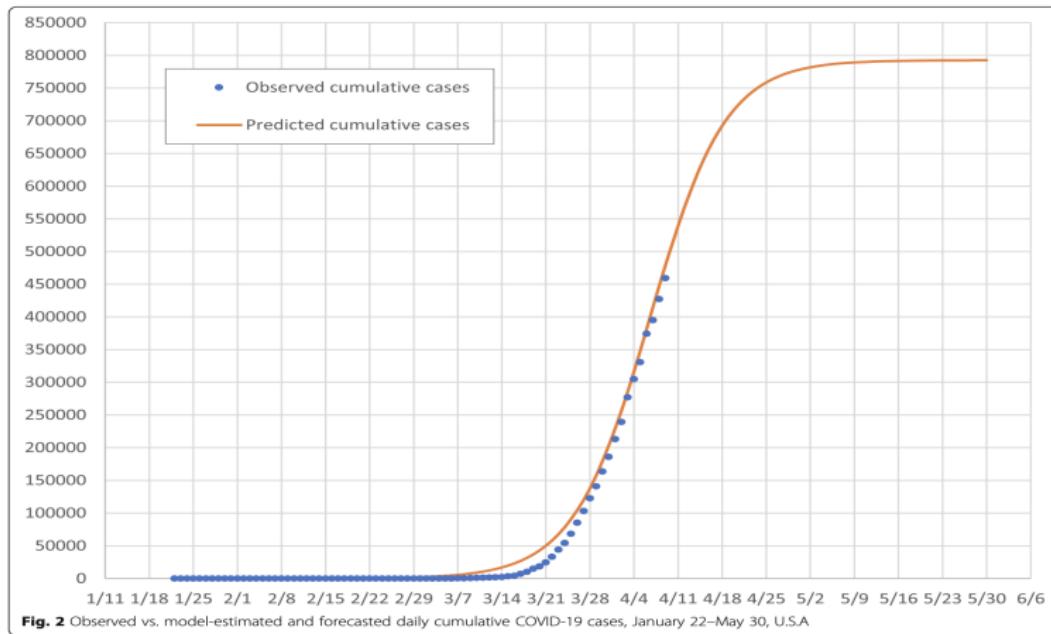
Data Usage	Days	Date	Reported Cases		Predicted		Under-reported
			Total	Daily	Daily	Total	
<b>Reconstruction</b>	54	3/15/2020	3487	1253	3108	19,781	16,294
	55	3/16/2020	4226	739	3623	23,141	18,915
	56	3/17/2020	7038	2812	4218	27,054	20,016
	57	3/18/2020	10,442	3404	4902	31,606	21,164
	58	3/19/2020	15,219	4777	5687	36,892	21,673
	59	3/20/2020	18,747	3528	6584	43,019	24,272
<b>Fitting</b>	60	3/21/2020	<b>24,583</b>	<b>5836</b>	<b>7603</b>	<b>50,102</b>	<b>25,519</b>
	61	3/22/2020	<b>33,404</b>	<b>8821</b>	<b>8755</b>	<b>58,269</b>	<b>24,865</b>
	62	3/23/2020	<b>44,183</b>	<b>10,779</b>	<b>10,047</b>	<b>67,658</b>	<b>23,475</b>
	63	3/24/2020	<b>54,453</b>	<b>10,270</b>	<b>11,485</b>	<b>78,411</b>	<b>23,958</b>
	64	3/25/2020	<b>68,440</b>	<b>13,987</b>	<b>13,070</b>	<b>90,676</b>	<b>22,236</b>
	65	3/26/2020	<b>85,356</b>	<b>16,916</b>	<b>14,797</b>	<b>104,598</b>	<b>19,242</b>
	66	3/27/2020	<b>103,321</b>	<b>17,965</b>	<b>16,656</b>	<b>120,315</b>	<b>16,994</b>
	67	3/28/2020	<b>122,653</b>	<b>19,332</b>	<b>18,624</b>	<b>137,947</b>	<b>15,294</b>
	68	3/29/2020	<b>140,904</b>	<b>18,251</b>	<b>20,670</b>	<b>157,589</b>	<b>16,685</b>
	69	3/30/2020	<b>163,539</b>	<b>22,635</b>	<b>22,750</b>	<b>179,298</b>	<b>15,759</b>
	70	3/31/2020	<b>186,101</b>	<b>22,562</b>	<b>24,810</b>	<b>203,082</b>	<b>16,981</b>
	71	4/1/2020	<b>213,144</b>	<b>27,043</b>	<b>26,784</b>	<b>228,889</b>	<b>15,745</b>
	72	4/2/2020	<b>239,279</b>	<b>26,135</b>	<b>28,600</b>	<b>256,597</b>	<b>17,318</b>
	73	4/3/2020	<b>277,205</b>	<b>37,926</b>	<b>30,180</b>	<b>286,010</b>	<b>8805</b>
	74	4/4/2020	<b>304,826</b>	<b>27,621</b>	<b>31,453</b>	<b>316,855</b>	<b>12,029</b>
<b>Forecast</b>	75	4/5/2020	330,891	26,065	32,352	348,791	17,900
	76	4/6/2020	374,329	43,438	32,830	381,419	7090
	77	4/7/2020	395,011	20,682	32,860	414,302	19,291
	78	4/8/2020	427,460	32,449	32,436	446,987	19,527
	79	4/9/2020	459,165	31,705	31,582	479,030	19,865
	80	4/10/2020	492,416	33,251	30,340	510,021	17,605

# Covid-19 pandémia – celková predikcia



- Celkový predikovaný počet Covid-19 prípadov v US v priebehu celej pandémie: 792 548;

# Covid-19 pandémia – celková predikcia



- ❑ Celkový predikovaný počet Covid-19 prípadov v US v priebehu celej pandémie: **792 548**;
- ❑ Počet Covid-19 prípadov v US: **103 mil.** a cez 1.1 milión úmrtí (Unor 2023);

## To conclude...

- ❑ Diferencialní modely a modely růstu jako vhodné a užitečné nástroje pro modelování růstu populací v závislosti na jejích velikosti.
- ❑ Jedná sa o nelineárne parametrické modely, pričomž na odhad neznámych parametrov nelze priamo aplikovať metodu najmenších čtvercov.
  - ❑ Model exponenciálneho rústu – jednoduchý model ale aplikovateľný pouze v krátkodobem časovom horizonte (predpoklad neomezeného (lineárneho) rústu pri neomezených zdrojoch);
  - ❑ Model logistického rústu – modifikácia predchozího modelu pomocí dodatečného parametrov – tzv. saturačnej hladiny pre maximálnu úroveň modelované populácie;
  - ❑ Model Gompertzovej kŕivky – rozšírenie modelu logistického rústu pre prípady s nesymetrickým počátečným nárústem a konečnou saturáciu – model asymetrický kolem inflexného bodu;
- ❑ Odhady neznámych parametrov v týchto modelech pomocí iteratívnych postupov, aproximácií, alebo preparametrisácií pôvodných rovníc, tak aby bolo možné aplikovať metodu najmenších čtvercov;
- ❑ Nutné používať premyslene a veľmi opatrne hlavne vzhľadom k predikciám.

Kapitola 3

# Systémy Lineární Regulace

# Čo to je?

- matematický model pre dynamiku rôznych systémov/procesov;  
*(sústavy rovníc, diferenciálne alebo diferenčné rovnice)*
- matematická teória systémov s dôrazom na ich kontrolu (reguláciu);  
*(predikcia reakcie systému na základe jeho stavu a daných vstupov)*
- interný/externý popis (charakterizácia) dynamických procesov;  
*(teoretické aj empirické vlastnosti systému, stabilita procesu)*
- konečne rozmerné, lineárne, diskrétne a časovo invariantné systémy;  
*(lineárizácia nelineárnych systémov, approximácia)*

# Čo to je?

- matematický model pre dynamiku rôznych systémov/procesov;  
*(sústavy rovníc, diferenciálne alebo diferenčné rovnice)*
- matematická teória systémov s dôrazom na ich kontrolu (reguláciu);  
*(predikcia reakcie systému na základe jeho stavu a daných vstupov)*
- interný/externý popis (charakterizácia) dynamických procesov;  
*(teoretické aj empirické vlastnosti systému, stabilita procesu)*
- konečne rozmerné, lineárne, diskrétné a časovo invariantné systémy;  
*(lineárizácia nelineárnych systémov, approximácia)*

Matematický model pre fyzikálne zákonitosti, chemické reakcie, biológiu a chovanie jedincov (sociológia), ekonomicke procesy a finančné trhy... vývoj určitej charakteristiky v čase (dynamika) na základě znalosti určujúcich premenných...

Antsaklis P. and Michel A. (2007). A Linear System Primer. Birkhäuser Boston.

ISBN-13: 978-0-8176-4460-4

# Model lineární regulace

- budeme uvažovať deterministické data (posloupnost)  $\{y_t, u_t\}_{t=0}^{\infty}$ ;
- definujeme **model lineární regulace**, ktorý vstupné data – t.j. posloupnosť  $u_0, u_1, u_2, \dots$ , pôvodne na výstupne data – posloupnosť  $y_0, y_1, y_2, \dots$ , a to pomocí specifické lineárnej transformácie – tzv. **lineárnej regulace**;
- matematicky lze model lineární regulace zapísat formálne ako

$$y_t = \sum_{j=0}^t h_j u_{t-j} = \sum_{j=0}^{\infty} h_j u_{t-j},$$

pre čas  $t \in \mathbb{N} \cup \{0\}$ , alebo  $t \in \mathbb{Z}$  ak  $y_{-j} = u_{-j} = 0$  pre  $j \in \mathbb{N}$ ;  
(t.j. hodnoty pre záporné indexy sú dodefinované nulou)

- neznáme parametre  $h_j$  pro  $j = 0, 1, \dots$ , určují konkrétní tvar výsledného modelu lineární regulace (kontrola/regulace systému);
- vliv posloupnosti  $u_0, u_1, u_2, \dots$  na  $y_0, y_1, y_2, \dots$  nemusí byt prímy, ale napr. prostredníctvím ďalších stavov systému – tzv. **lineárnej soustavy**;

# Příklad 1: Model jednotkového impulzu

**Definice:** Model jednotkového impulzu (unit pulse)

Vstupní posloupnost ve tvaru  $u_0 = 1, u_1 = 0, u_2 = 0, \dots$ , nazývame **jednotkový impulz**. Odezvou systému lineární regulace na jednotkový impulz (vstup) je pak posloupnost  $h_0, h_1, h_2, \dots$  (výstup), která se nazýva **impulzní charakteristika** soustavy lineární regulace.

## Samostatný úkol

Z definice modelu lineární regulace lze okamžitě ověřit, že platí:

- pro  $t = 0$ :  $y_0 = h_0 u_0 = h_0$ ;
- pro  $t = 1$ :  $y_1 = h_0 u_1 + h_1 u_0 = h_1$ ;
- pro  $t = 2$ :  $y_2 = h_0 u_2 + h_1 u_1 + h_2 u_0 = h_2$ ;
- pro  $t \in \mathbb{N}$ :  $y_t = h_0 u_t + \dots + h_t u_0 = h_t$ ;

## Příklad 2: Model jednotkového skoku

**Definice:** Model jednotkového skoku (unit step )

Vstupní posloupnost ve tvaru  $u_t = 1$  pro  $t = 0, 1, 2, \dots$  nazývame **jednotkový skok** (t.j. v čase  $t = 0$  se hodnoty  $u_t$  změní z 0 na 1). Odezvou systému lineární regulace na jednotkový skok je pak posloupnost, která se nazýva **přechodová charakteristika** soustavy lineární regulace. Navíc platí, že

$$y_t = \sum_{j=0}^{\infty} h_j u_{t-j} = \sum_{j=0}^t h_j u_{t-j} = \sum_{j=0}^t h_j.$$

K analýze linárních soustav se obecně hodí používat tzv. vytvořující funkce pro číselné posloupnosti a speciálně tzv. **z-transformace**.

## Z-transformace

**Z-transformace** se obecně používá pro vyjádření signálu s diskrétním časem (t.j. posloupnosti reálních, nebo komplexních čísel) pomocí reprezentácie vrámci **komplexnej frekvenčnej domény**. Jedná se o diskrétni verzi Laplacovej transformáce.

### Definice: Z-transformace (jednostranná)

Pro libovolnou posloupnost reálných čísel  $\{a_k; k \in \mathbb{N} \cup \{0\}\}$  definujeme její **z-transformaci** jako funkci

$$A(z) = \sum_{j=0}^{\infty} a_j z^{-j}, \quad \text{obecně pro libovolné } z \in \mathbb{C}.$$

- V teórii se také používá tzv. **bilaterální (oboustranná) z-transformace**; Pro oboustrannú z-transformaci platí  $A(z) = \sum_{j=-\infty}^{\infty} a_j z^{-j}$ , pro  $z \in \mathbb{C}$ ;

# Definice značení pro z-transformaci

Samostatný úkol (*opakování*)

- Nekonečná řada  $A(z) = \sum_{j=0}^{\infty} a_j z^{-j}$  konverguje pro  $|z| > z_0$  a diverguje pro  $|z| < z_0$ , pro nějaké  $z_0 \in [0, \infty]$ ;
- Množina  $\{z \in \mathbb{C}; |A(z)| < \infty\}$  se často v literatuře značí jako ROC oblast (tzn. "Region Of Convergence");
- na kružnici  $|z| = z_0$  se řada může chovat libovolně (konvergovat pro některé body a divergovat pro jiné);

- pro **posloupnost vstupů**  $\{u_t; t \in \mathbb{N} \cup \{0\}\}$  budeme značit příslušnú z-transformaci jako funkci  $U(z)$  (t.j.  $U(z) = \sum_{j=0}^{\infty} u_j z^{-j}$ );
- pro **posloupnost výstupů**  $\{y_t; t \in \mathbb{N} \cup \{0\}\}$  budeme značit příslušnú z-transformaci jako funkci  $Y(z)$  (t.j.  $Y(z) = \sum_{j=0}^{\infty} y_j z^{-j}$ );
- pro **impulzní charakteristiku**  $\{h_t; t \in \mathbb{N} \cup \{0\}\}$  budeme značit příslušnú z-transformaci jako funkci  $H(z)$  (t.j.  $H(z) = \sum_{j=0}^{\infty} h_j z^{-j}$ );

# Impulzní přenosová funkce soustavy

**Definice:** Impulzní přenosová funkce (transfer function)

Funkce

$$H(z) = \sum_{j=0}^{\infty} h_j z^{-j}, \quad \text{pro } z \in \mathbb{C}$$

se nazýva **(impulzní) přenosová funkce (lineární) soustavy**.

Samostatný úkol

Ukážte, že pro impulzní přenosovou funkci soustavy platí, že

$$Y(z) = H(z) \cdot U(z),$$

pro taková  $z \in \mathbb{C}$ , že  $H(z)$  a  $U(z)$  konvergují.

# Impulzní přenosová funkce soustavy

**Definice:** Impulzní přenosová funkce (transfer function)

Funkce

$$H(z) = \sum_{j=0}^{\infty} h_j z^{-j}, \quad \text{pro } z \in \mathbb{C}$$

se nazýva **(impulzní) přenosová funkce (lineární) soustavy**.

Samostatný úkol

Ukážte, že pro impulzní přenosovou funkci soustavy platí, že

$$\begin{aligned} Y(z) &= \sum_{j=0}^{\infty} y_j z^{-j} = \sum_{j=0}^{\infty} \left( \sum_{\ell=0}^{\infty} h_{\ell} u_{j-\ell} \right) z^{-j} = \sum_{\ell=0}^{\infty} h_{\ell} z^{-\ell} \left( \sum_{j=0}^{\infty} u_{j-\ell} z^{-(j-\ell)} \right) \\ &= \sum_{\ell=0}^{\infty} h_{\ell} z^{-\ell} \cdot \sum_{j=-\ell}^{\infty} u_j z^{-j} = \sum_{\ell=0}^{\infty} h_{\ell} z^{-\ell} \cdot \sum_{j=0}^{\infty} u_j z^{-j} = H(z) \cdot U(z), \end{aligned}$$

pro taková  $z \in \mathbb{C}$ , že  $H(z)$  a  $U(z)$  konvergují.

## Příklad: Bakaláři na austrálské univerzitě

### Príklad

Chceme modelovat závislost počtu bakalářských promoci na počtu studentů zapsaných v předchozích letech do prvního ročníka.

- počet studentů zapsaných do studia v roce  $t$  je  $u_t$  (vstup);  
(do prvního ročníku teda nastoupí v roce  $t + 1$ )
- počet studentů, který v roce  $t$  ukončí studium je  $y_t$  (výstup);

# Příklad: Bakaláři na austrálské univerzitě

## Príklad

Chceme modelovať závislost počtu bakalářských promoci na počtu studentů zapsaných v předchozích letech do prvního ročníka.

- počet studentů zapsaných do studia v roce  $t$  je  $u_t$  (vstup);  
(do prvního ročníku teda nastoupí v roce  $t + 1$ )
- počet studentů, který v roce  $t$  ukončí stúdium je  $y_t$  (výstup);
- celkový systém stúdia je ale omnoho komplikovanejší a mezi počtom zapísaných študentov (hodnotou  $u_t$ ) a počtom promovaných študentov (hodnota  $y_t$ ) existuje niekoľko ďalších "medzistavov systému" (t.j. jednotlivé ročníky štúdia);
- po prvom ročníku student bud' pokračuje ve stúdiu v druhom ročníku, prípadne prvý ročník opakuje (analogicky aj u nasledujúcich ročníkov);
- jak tieto stavy zahrnúť do celkového systému?

# Aplikace: Bakaláři na univerzitě v Austrálii

## Príklad

- bakalářský titul lze na austrálkej univerzitě získat ve třetím roce studia (tzv. Pass Degree), nebo pokračovat ve čtvrtém roce a získat výšší, tzv. Honours Degree;
- nechť počet studentů v  $i$ -tém ročníku v roce  $t$  je  $x_t^{(i)}$  pro  $i = 1, \dots, 4$ ;
- nechť podíl studentů, kteří přejdou z  $i$ -tého do  $j$ -tého ročníka v následujícím školním roce je  $p_{ij}$  a podíl studentů, kteří skončí v  $i$ -tém ročníku:  $q_i$  (odsledované/odhadnuté z historických dat);
- zřejme platí, že  $p_{ii} + p_{i(i+1)} + q_i = 1$  pro všechny  $i = 1, 2, 3, 4$ ; (niektoré pravdepodobnosti vhodne dodefinujeme nulou)

## Příklad: Bakaláři na australských univerzitách

### Príklad

- ❑ vzhľadom k systému bakalářského stúdia v Austrálii lze psať, že

$$y_t = c_3 x_t^{(3)} + c_4 x_t^{(4)},$$

pro  $c_3, c_4 \in (0, 1)$  proporce studentu, kteří v třetím a čtvrtém roce promují (odsledované z historických dat).

- ❑ zřejme také platí následující:

$$x_{t+1}^{(1)} = u_t + p_{11} x_t^{(1)}; \quad (4)$$

$$x_{t+1}^{(i+1)} = p_{i(i+1)} x_t^{(i)} + p_{(i+1)(i+1)} x_t^{(i+1)}, \quad \text{pro } i = 1, 2, 3; \quad (5)$$

- ❑ proporce odhadnuté pomocí historických statistik na univerzitách:

$$p_{12} = 0.61; p_{23} = 0.71; p_{34} = 0.16; c_3 = 0.81; c_4 = 0.91;$$

$$p_{11} = 0.15; p_{22} = 0.11; p_{33} = 0.10; p_{44} = 0.05;$$

# Jak teda závisí $\{y_t\}$ na posloupnosti $\{u_t\}$ ?

## Príklad

- Obecně můžeme pro  $x_t^{(i)}$  psát, že

$$x_t^{(i)} = \sum_{j=0}^{\infty} f_j^{(i)} u_{t-j}, \quad (6)$$

kde  $f_j^{(i)}$  je podíl těch, co se zapsali před  $j$  lety a teď jsou v  $i$ -tému ročníku a platí, že  $f_0^{(i)} = 0$  pro všechny  $i = 1, 2, 3, 4$ ;

- Přímym dosazením do (4) dostaneme

$$\sum_{j=0}^{\infty} f_j^{(1)} u_{t+1-j} = u_t + p_{11} \sum_{j=0}^{\infty} f_j^{(1)} u_{t-j};$$

- Porovnáním koeficientu dostaneme:  
 $f_1^{(1)} = 1, f_2^{(1)} = p_{11} f_1^{(1)} = p_{11}, f_3^{(1)} = p_{11} f_2^{(1)} = p_{11}^2, \dots, f_n^{(1)} = p_{11}^{n-1}$ ;

# Příklad: Bakaláři na australských univerzitách

## Príklad

- celkový počet studentů v prvním ročníku v roce  $t$  lze vyjádřit jako součet nově zapsaných a recyklovaných studentů:

$$x_t^{(1)} = u_{t-1} + \sum_{j=2}^{\infty} (p_{11})^{j-1} u_{t-j};$$

- Následně dosadíme (6) do výrazu (5):

$$\sum_{j=0}^{\infty} f_j^{(i+1)} u_{t+1-j} = p_{i(i+1)} \sum_{j=0}^{\infty} f_j^{(i)} u_{t-j} + p_{(i+1)(i+1)} \sum_{j=0}^{\infty} f_j^{(i+1)} u_{t-j};$$

- Zjednodušení: obecně předpokládame, že  $f_j^{(i)} = 0$ , pro  $j < i$ ;

# Příklad: Bakaláři na australských univerzitách

## Príklad

- Postupně dostaneme:

$$f_2^{(2)} = p_{12}f_1^{(1)} + p_{22}f_1^{(2)} = p_{12}$$

$$f_3^{(3)} = p_{23}f_2^{(2)} + p_{33}f_2^{(3)} = p_{23}f_2^{(2)} = p_{12}p_{23}$$

a obecně:

$$f_{j+1}^{(i+1)} = p_{i(i+1)}f_j^{(i)} + p_{(i+1)(i+1)}f_j^{(i+1)}$$

- Celkově pro  $y_t$  teda máme:

$$\begin{aligned}y_t &= c_3x_t^{(3)} + c_4x_t^{(4)} = \sum_{j=0}^{\infty} \left( c_3f_j^{(3)} + c_4f_j^{(4)} \right) u_{t-j} \\&= 0.3508u_{t-3} + 0.1901u_{t-4} + 0.0567u_{t-5} + 0.0131u_{t-6} + \dots\end{aligned}$$

# Maticový zápis | Stavový model

- Příklad o bakalářích na australských univerzitách lze také zapsát i pomocí alternativného maticového zápisu (více kompaktně);
- Nechť  $\mathbf{x}_t = (x_t^{(1)}, \dots, x_t^{(4)})^\top$  jsou **stavy systému**. Pak celý problém lze zapsat jako

$$\mathbf{x}_{t+1} = \underbrace{\begin{pmatrix} p_{11} & 0 & 0 & 0 \\ p_{12} & p_{22} & 0 & 0 \\ 0 & p_{23} & p_{33} & 0 \\ 0 & 0 & p_{34} & p_{44} \end{pmatrix}}_{\mathbb{A}} \mathbf{x}_t + \underbrace{\begin{pmatrix} 1 \\ 0 \\ 0 \\ 0 \end{pmatrix}}_b u_t;$$

$$y_t = \underbrace{(0, 0, c_3, c_4)}_c \cdot \mathbf{x}_t + \underbrace{0}_d \cdot u_t.$$

- Uvedený zápis definuje **lineární stavovou soustavu** v obecném tvaru; (vstupní posloupnost  $u_t$ , stavy systému  $\mathbf{x}_t$ , výstupní posloupnost  $y_t$ )

## Stavový model – obecně

- uvažujeme systém, jehož stav lze popsat vektorem  $\mathbf{x} \in \mathbb{R}^r$ ;
- vývoj systému pak definujeme pomocí posloupnosti  $\{\mathbf{x}_t; t \in \mathbb{N} \cup \{0\}\}$ ;
- předpokládame, že stav systému v čase  $t = 0$  je  $\mathbf{x}_0 = \mathbf{0} \in \mathbb{R}^r$ ;
- následující stavy systému v čase  $t + 1$  jsou popsány pomocí modelu

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t,$$

pre vstupnú hodnotu  $u_t$ , nějakou čtvercovou matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$  a vektor  $\mathbf{b} \in \mathbb{R}^r$ ;

- nepozorujeme ale přímo stavy systému, ale pouze výstup  $y_t$  ve tvaru

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t,$$

opět pro vstup  $u_t$ , nějaký vektor  $\mathbf{c} \in \mathbb{R}^r$  a skalár  $d \in \mathbb{R}$ ;

## Stavový model – obecně

- uvažujeme systém, jehož stav lze popsat vektorem  $\mathbf{x} \in \mathbb{R}^r$ ;
- vývoj systému pak definujeme pomocí posloupnosti  $\{\mathbf{x}_t; t \in \mathbb{N} \cup \{0\}\}$ ;
- předpokládame, že stav systému v čase  $t = 0$  je  $\mathbf{x}_0 = \mathbf{0} \in \mathbb{R}^r$ ;
- následující stavy systému v čase  $t + 1$  jsou popsány pomocí modelu

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t,$$

pre vstupnú hodnotu  $u_t$ , nějakou čtvercovou matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$  a vektor  $\mathbf{b} \in \mathbb{R}^r$ ;

- nepozorujeme ale přímo stavy systému, ale pouze výstup  $y_t$  ve tvaru

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t,$$

opět pro vstup  $u_t$ , nějaký vektor  $\mathbf{c} \in \mathbb{R}^r$  a skalár  $d \in \mathbb{R}$ ;

(Ize samozřejmě zobecnit i pro vícerozměrný výstup systému  $\mathbf{y}_t \in \mathbb{R}^q$ )

## Stavový model – obecně

- uvažujeme systém, jehož stav lze popsat vektorem  $\mathbf{x} \in \mathbb{R}^r$ ;
- vývoj systému pak definujeme pomocí posloupnosti  $\{\mathbf{x}_t; t \in \mathbb{N} \cup \{0\}\}$ ;
- předpokládame, že stav systému v čase  $t = 0$  je  $\mathbf{x}_0 = \mathbf{0} \in \mathbb{R}^r$ ;
- následující stavy systému v čase  $t + 1$  jsou popsány pomocí modelu

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t,$$

pre vstupnú hodnotu  $u_t$ , nějakou čtvercovou matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$  a vektor  $\mathbf{b} \in \mathbb{R}^r$ ;

- nepozorujeme ale přímo stavy systému, ale pouze výstup  $y_t$  ve tvaru

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t,$$

opět pro vstup  $u_t$ , nějaký vektor  $\mathbf{c} \in \mathbb{R}^r$  a skalár  $d \in \mathbb{R}$ ;

(Ize samozřejmě zobecnit i pro vícerozměrný výstup systému  $\mathbf{y}_t \in \mathbb{R}^q$ )

- Jak získat z tohto modelu přímou závislost výstupní posloupnosti  $y_t$  na vstupních datech  $u_t$  ve tvaru  $y_t = \sum_{j=0}^{\infty} h_j u_{t-j}$ ?

# Obecný model systému lineární regulace

- namísto původního systému rovníc stačí uvažovat obecný zápis ve tvaru

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t$$

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t$$

- pro posloupnost vstupov  $\{u_t\}_{t=0}^{\infty}$  a výstupov  $\{y_t\}_{t=0}^{\infty}$ ;
- pro (skryté/nepozorované) stav systému – t.j. posloupnost  $\{\mathbf{x}_t\}_{t=0}^{\infty}$ ;
- pro obecnou matici  $\mathbb{A}$  typu  $r \times r$  která modeluje vztahy (závislosti) medzi jednotlivými stavmi systému;
- vektor  $\mathbf{b} \in \mathbb{R}^r$  (ktorý modeluje závislosť stavov systému na vstupnej posloupnosti) a vektor  $\mathbf{c}$  (ktorý modeluje závislosť výstupu na jednotlivých stavoch systému);
- konstana  $d \in \mathbb{R}$ , ktorá modeluje priamu závislosť výstupu na vstupných hodnotách;

# Stavový model a stavové rovnice

- namísto původního systému rovníc máme obecný tvar

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t$$

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t$$

- budeme uvažovat systém rovníc ve tvaru

$$\sum_{t=0}^{\infty} \mathbf{x}_{t+1} z^{-t} = \underbrace{\mathbb{A} \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{\mathbf{X}(z)} + \underbrace{\mathbf{b} \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

$$\sum_{t=0}^{\infty} y_t z^{-t} = \underbrace{\mathbf{c}^\top \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{Y(z)} + \underbrace{d \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

↪ kde jsme původní rovnice postupně vynásobili faktorem  $z^{-t}$  a pak sečetli přes všechny možné hodnoty pro  $t = 0, 1, 2, \dots$ ;

# Stavový model a stavové rovnice

- namísto původního systému rovníc máme obecný tvar

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t$$

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t$$

- budeme uvažovat systém rovníc ve tvaru

$$z \sum_{t=0}^{\infty} \mathbf{x}_{t+1} z^{-t-1} = \underbrace{\mathbb{A} \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{\mathbf{X}(z)} + \underbrace{\mathbf{b} \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

$$\underbrace{\sum_{t=0}^{\infty} y_t z^{-t}}_{Y(z)} = \underbrace{\mathbf{c}^\top \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{\mathbf{X}(z)} + \underbrace{d \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

↪ kde jsme původní rovnice postupně vynásobili faktorem  $z^{-t}$  a pak sečetli přes všechny možné hodnoty pro  $t = 0, 1, 2, \dots$ ;

# Stavový model a stavové rovnice

- namísto původního systému rovníc máme obecný tvar

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t$$

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t$$

- budeme uvažovat systém rovníc ve tvaru

$$z \sum_{t=-1}^{\infty} \mathbf{x}_{t+1} z^{-t-1} = \underbrace{\mathbb{A} \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{X(z)} + \underbrace{\mathbf{b} \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

$$\underbrace{\sum_{t=0}^{\infty} y_t z^{-t}}_{Y(z)} = \underbrace{\mathbf{c}^\top \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{X(z)} + \underbrace{d \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

↪ kde jsme původní rovnice postupně vynásobili faktorem  $z^{-t}$  a pak sečetli přes všechny možné hodnoty pro  $t = 0, 1, 2, \dots$ ;

# Stavový model a stavové rovnice

- namísto původního systému rovnic

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t$$

$$y_t = \mathbf{c}^\top \mathbf{x}_t + du_t$$

- budeme uvažovat systém rovnic ve tvaru

$$z \underbrace{\sum_{t=-1}^{\infty} \mathbf{x}_{t+1} z^{-t-1}}_{\mathbf{X}(z)} = \underbrace{\mathbb{A} \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t}}_{\mathbf{X}(z)} + \underbrace{\mathbf{b} \sum_{t=0}^{\infty} u_t z^{-t}}_{U(z)}$$

$$\underbrace{\sum_{t=0}^{\infty} y_t z^{-t}}_{Y(z)} = \mathbf{c}^\top \sum_{t=0}^{\infty} \mathbf{x}_t z^{-t} + d \sum_{t=0}^{\infty} u_t z^{-t}$$

↪ kde jsme původní rovnice postupně vynásobili faktorem  $z^{-t}$  a pak sečetli přes všechny hodnoty pro  $t = 0, 1, 2, \dots$ ;

## Stavový model – řešení

- systém rovníc v maticovém zápisu:

$$z\mathbf{X}(z) = \mathbb{A}\mathbf{X}(z) + \mathbf{b}U(z)$$

$$Y(z) = \mathbf{c}^\top \mathbf{X}(z) + dU(z)$$

- pokud existuje inverze  $(z\mathbb{I} - \mathbb{A})^{-1}$ , lze řešení pro  $\mathbf{X}(z)$  získat jako:

$$z\mathbf{X}(z) - \mathbb{A}\mathbf{X}(z) = \mathbf{b}U(z)$$

$$(z\mathbb{I} - \mathbb{A})\mathbf{X}(z) = \mathbf{b}U(z)$$

$$\mathbf{X}(z) = (z\mathbb{I} - \mathbb{A})^{-1} \cdot \mathbf{b}U(z)$$

- následně pak pro  $Y(z)$  získame řešení ve tvaru:

$$Y(z) = \mathbf{c}^\top \mathbf{X}(z) + dU(z)$$

$$= [\mathbf{c}^\top \cdot (z\mathbb{I} - \mathbb{A})^{-1} \mathbf{b} + d] U(z)$$

# Přenosová funkce soustavy

**Definice:** Přenosová funkce soustavy (transfer function)

Funkce  $H(z) = [\mathbf{c}^\top \cdot (z\mathbb{I} - \mathbb{A})^{-1} \mathbf{b} + d]$  se nazýva **přenosová funkce soustavy** a platí, že

$$Y(z) = H(z)U(z),$$

pro každé  $z \in \mathbb{C}$ , pro které funkce  $Y(z)$  a  $U(z)$  konvergují.

## Samostatný úkol

Oveřte, že pro libovolnou matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$ , vektory  $\mathbf{b}, \mathbf{c} \in \mathbb{R}^r$  a reální číslo  $d \in \mathbb{R}$ , takové, že inverzní matice  $(z\mathbb{I} - \mathbb{A})^{-1}$  existuje, je funkce  $H(z)$  funkci z  $\mathbb{R}$  do  $\mathbb{R}$ , pro  $z \in \mathbb{R}$  (tzn., ověřte příslušné rozměry v zápisu funkce  $H$ ).

# Přenosová funkce soustavy – vyjádření

## Samostatný úkol

Přenosovou funkci soustavy lze také vyjádřit jako podíl dvou polynomů stupně nejvýše  $r$ . Platí, že

$$\begin{aligned} H(z) &= \left[ \mathbf{c}^\top \cdot (z\mathbb{I} - \mathbb{A})^{-1} \mathbf{b} + d \right] = \frac{\mathbf{c}^\top \text{Adj}(z\mathbb{I} - \mathbb{A}) \mathbf{b} + d \cdot \det(z\mathbb{I} - \mathbb{A})}{\det(z\mathbb{I} - \mathbb{A})} \\ &= \frac{N(z)}{D(z)} = \frac{n_0 z^r + \cdots + n_r}{d_0 z^r + \cdots + d_r} = \frac{n_0 + \cdots + n_r z^{-r}}{d_0 + \cdots + d_r z^{-r}}, \end{aligned}$$

kde  $N(z)$  a  $D(z)$  jsou příslušné polynomy  $n_0 + \cdots + n_r z^{-r}$  a  $d_0 + \cdots + d_r z^{-r}$  (resp. prvních  $r$  prvků příslušných  $z$ -transformací).

# Příklad: Bakaláři na australských univerzitách

## Príklad

- pro model s bakaláři na australských univerzitách máme

$$\mathbb{A} = \begin{pmatrix} p_{11} & 0 & 0 & 0 \\ p_{12} & p_{22} & 0 & 0 \\ 0 & p_{23} & p_{33} & 0 \\ 0 & 0 & p_{34} & p_{44} \end{pmatrix}, \quad \mathbf{b} = (1, 0, 0, 0)^\top,$$

$$\mathbf{c} = (0, 0, c_3, c_4)^\top, \quad d = 0;$$

- pro matici  $(z\mathbb{I} - \mathbb{A})$  dostaneme vyjádření ve tvaru

$$(z\mathbb{I} - \mathbb{A}) = \begin{pmatrix} z - p_{11} & 0 & 0 & 0 \\ -p_{12} & z - p_{22} & 0 & 0 \\ 0 & -p_{23} & z - p_{33} & 0 \\ 0 & 0 & -p_{34} & z - p_{44} \end{pmatrix};$$

- a pro determinant matice  $(z\mathbb{I} - \mathbb{A})$  dostaneme

$$\det(z\mathbb{I} - \mathbb{A}) = (z - p_{11})(z - p_{22})(z - p_{33})(z - p_{44});$$

# Příklad: Bakaláři na australských univerzitách

## Príklad

- vzhledem k tvaru vektorů  $\mathbf{b}, \mathbf{c} \in \mathbb{R}^r$  stačí pro adjungovanou matici spočítat prvky na pozici [3,1] a [4,1];
- pro **přenosovou funkci soustavy** pak přímo dostaneme

$$H(z) = \frac{c_3 p_{12} p_{23}(z - p_{44}) + c_4 p_{12} p_{23} p_{34}}{(z - p_{11})(z - p_{22})(z - p_{33})(z - p_{44})}$$

- pomocí přenosové funkce soustavy  $H(z)$  dostaneme příme vyjádření počtu promujících bakalářů v závislosti na počtu zapsaných studentů (vyjadrenie prostredníctvom spektrálnej domény) – bez explicitnej prítomnosti jednotlivých (skrytých) stavov systému;

# Zhrnutí předchozí přednášky/opakování

## □ Modely lineární regulace

↪ posloupnost výstupních dat je vyjádřená jako specifická lineární funkce vstupních dat, t.j.  $y_t = h_0 u_t + \dots + h_t u_0$ , pro  $t \in \mathbb{N} \cup \{0\}$   
a vhodné zvolené parametry  $h_0, \dots, h_t, \dots \in \mathbb{R}$ ;

## □ Z-transformace a impulzní přenosová funkce;

↪ impulzní přenosová funkce  $Y(z) = H(z)U(z)$  jako nástroj pro reprezentaci výstupnej posloupnosti  $\{y_t\}$  vo frekvenčnej doméně pomocí z-transformace vstupu  $\{u_t\}$  a parametru  $\{h_t\}$ :  
 $U(z) = \sum_{j=0}^{\infty} u_j z^{-j}$  a  $H(z) = \sum_{j=0}^{\infty} h_j z^{-j}$ ;

## □ Lineární soustavy;

↪ komplexný systém lineární regulace, kde mezi vstupní a výstupní posloupnosti existuje navíc množina stavov  $\mathbf{x}_t = (x_t^{(1)}, \dots, x_t^{(r)})^\top$ ;

## □ Obecný zápis lineární soustavy

$$\mathbf{x}_{t+1} = \mathbb{A}\mathbf{x}_t + \mathbf{b}u_t;$$

$$y_t = \mathbf{c} \cdot \mathbf{x}_t + d \cdot u_t,$$

pro matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$ , vektory  $\mathbf{b}, \mathbf{c} \in \mathbb{R}^r$  a skalár  $d \in \mathbb{R}$ ;

## Obecný model

- v praxi je výhodnější uvažovat obecnou situaci, kdy výstup v čase  $t$  závisí také na předchozích výstupech, t.j., uvažujeme rovnici

$$d_0 y_t + \cdots + d_r y_{t-r} = n_0 u_t + \cdots + n_r u_{t-r}, \quad (7)$$

pro  $d_0 \neq 0$ ;

- co lze také ekvivalentně přepsát jako

$$y_t = \underbrace{-\frac{d_1}{d_0} y_{t-1} - \cdots - \frac{d_r}{d_0} y_{t-r}}_{\text{autoregresní část soustavy}} + \underbrace{\frac{n_0}{d_0} u_t + \cdots + \frac{n_r}{d_0} u_{t-r}}_{\text{regresní část soustavy}}$$

pro  $d_0 \neq 0$ ;

- délky pro autoregresní a regresní část mohou být obecně různé ( $k \neq l$ );  
 ↳ některé koeficienty  $d_1, \dots, d_k, n_0, \dots, n_l$  mohou být nulové;
- **IDEA:** Opět chceme najít vyjádření ve tvaru  $y_t = \sum_{k=0}^{\infty} h_k y_{t-k}$ ;

## Obecný model

- analogickým postupem (vynásobíme členem  $z^{-t}$  a sečteme přes všechny hodnoty  $t$ ) dostaneme vyjádření (7) ve tvaru

$$\begin{aligned} & \sum_{t=0}^{\infty} (d_0 z^{-0} y_t z^{-t} + \dots + d_r z^{-r} y_{t-r} z^{-(t-r)}) \\ &= \sum_{t=0}^{\infty} (n_0 z^0 u_t z^{-t} + \dots + n_r z^{-r} u_{t-r} z^{-(t-r)}) \end{aligned}$$

- díky zavedenému značení  $u_{-t} = y_{-t} = 0$  pro  $t \in \mathbb{N}$  můžeme psát

$$(d_0 z^{-0} + \dots + d_r z^{-r}) \sum_{t=0}^{\infty} y_t z^{-t} = (n_0 z^0 + \dots + n_r z^{-r}) \sum_{t=0}^{\infty} u_t z^{-t};$$

- co lze také přepsát do obecného tvaru lineárního modelu jako

$$d(z^{-1}) Y(z) = n(z^{-1}) U(z)$$

pro  $d(x) = d_0 + d_1 x + \dots + d_r x^r$  a  $n(x) = n_0 + n_1 x + \dots + n_r x^r$ ;

## Obecný model – některé vlastnosti

- obecně i zde platí, že  $Y(z) = H(z)U(z)$ , pro takové  $z \in \mathbb{C}$ ,  
že  $H(z)$  a  $U(z)$  konvergují;
- důkazem tedy dostaneme, že

$$d(z^{-1})Y(z) = d(z^{-1})H(z)U(z) = n(z^{-1})U(z),$$

pro takové  $z \in \mathbb{C}$ , že pravá strana konverguje;

- pro přenosovou funkci soustavy máme

$$H(z) = \frac{n(z^{-1})}{d(z^{-1})} = \frac{n_0 + \cdots + n_r z^{-r}}{d_0 + \cdots + d_r z^{-r}};$$

- rovnice (7) se někdy zapisuje ve tvaru

$$(d_0 + \cdots + d_r z^{-r})y_t = (n_0 + \cdots + n_r z^{-r})u_t$$

nebo zjednodušene  $d(z^{-1})y_t = n(z^{-1})u_t$ , kde  $z$  se interpretuje jako  
operátor posunutí, t.j.,  $zx_t = x_{t+1}$  a  $z^{-1}$  jako operátor zpětného posunutí,  
t.j.,  $z^{-1}x_t = x_{t-1}$ ;

# Obecný model – příklad

## Príklad

Předpokládame jednoduchý model lineárního systému ve tvaru

$$y_{t+1} - ay_t = u_{t+1} \quad \text{resp.} \quad (1 - az^{-1})y_t = u_t.$$

- pro přenosovou funkci soustavy dostaneme

$$H(z) = \frac{1}{1 - az^{-1}} = \frac{z}{z - a};$$

- lze jednoduše rozvinout jako

$$H(z) = \sum_{k=0}^{\infty} a^k z^{-k};$$

- pro impulzní charakteristiku soustavy teda máme  $y_t = h_t = a^t$ ;
- pro přechodovou charakteristiku soustavy máme  $y_t = \sum_{k=0}^t h_k$ ;

# Stabilita lineární soustavy

## □ Stabilita soustavy

Jedná se o základní vlastnost, která se u lineárních soustav zkoumá.

**Definice:** Stabilita lineární soustavy

Řekneme, že lineární soustava je stabilní, pokud platí, že

$$\lim_{t \rightarrow \infty} h_t = 0. \quad (8)$$

- Alternativně lze říct, že **odezva soustavy na jednotkový impuls se postupně vytráci**, pokud je soustava stabilní;
- (8) je zároveň nutná podmínka k tomu, aby **přechodová charakteristika soustavy**, teda řada  $\sum_{k=0}^{\infty} h_k$ , byla **konvergentní** (ale ne postačující);

# Stabilita lineární soustavy

**Věta:** Stabilita lineární soutavy

Soustava odpovídající obecnému modelu s přenosovou funkcí ve tvaru

$$H(z) = \frac{n(z^{-1})}{d(z^{-1})} = \frac{N(z)}{D(z)},$$

kde  $N(z) = n_0 z^r + \dots + n_r z^0$  a  $D(z) = d_0 z^r + \dots + d_r z^0$  jsou ne-soudělné polynomy, je stabilní právě tehdy, když se všechny kořeny polynomu  $D(z)$  nacházejí uvnitř jednotkového kruhu v komplexní rovině.

Príklad

Jeli  $h_k = a^k$ , pak je soustava stabilní právě tehdy, když je  $|a| < 1$ .

## Stabilita stavového modelu

- pro stavový model obecně platí:  $D(z) = \det(z\mathbb{I} - \mathbb{A})$ ;
- kořeny  $D(z)$  jsou právě všechná vlastní čísla maticy  $\mathbb{A}$  a jsou v absolutní hodnotě menší než hodnota 1;

### Príklad

Uvažujme nějakou stabilní soustavu a jednotkový skok  $1 = u_0 = u_1 = \dots$ , jako vstup. Pak pro přechodovou charakteristiku soustavy, posloupnost  $y_t$  dostaneme

$$\lim_{t \rightarrow \infty} y_t = \lim_{t \rightarrow \infty} \sum_{k=0}^t h_k y_{t-k} = \lim_{t \rightarrow \infty} \sum_{k=0}^t h_k = \sum_{k=0}^{\infty} h_k = y_{\infty}$$

a soustava se tedy v nekonečném horizontu ustálí na nové úrovni. Obecně tedy předpoklad  $h_t \rightarrow 0$  není postačující k tomu, aby řada  $\sum_{k=0}^{\infty} h_k$  byla konvergentní.

- Pokud jsou ale kořeny  $D(z)$  v jednotkovém kruhu (podmínka stability), pak také řada  $\sum_{k=0}^{\infty} h_k$  konverguje absolutně.

# Příklad: Bakaláři na austrálské univerzitě

## Príklad

- kořeny polynomu  $D(z) = \det(z\mathbb{I} - \mathbb{A})$  jsou jednoduché;  
(s násobnosti jedna): pravděpodobnosti  $p_{11}, p_{22}, p_{33}, p_{44}$ ;
- stabilitu teda dostaneme pro  $p_{ii} < 1$  pro  $\forall i \in \{1, 2, 3, 4\}$ ;  
(teda postup do vyššího ročníku, resp. ukončení studia v poslednom ročníku, je možný s kladnou pravděpobnosti)

# Zhrnutí a opakování

## □ Modely lineární regulace & lineární soustavy

↪ modely, které posloupnost výstupních dat  $\{y_t\}$  modelují jako linární funkci vstupních dat  $\{u_t\}$ , t.j.  $y_t = h_0 u_t + \dots + h_t u_0$ , pro  $t \in \mathbb{N} \cup \{0\}$ ;

## □ Obecný maticový zápis systému se stavů $x_t = (x_{t1}, \dots, x_{tr})^\top$

$$x_{t+1} = \mathbb{A}x_t + \mathbf{b}u_t;$$

$$y_t = \mathbf{c} \cdot x_t + d \cdot u_t,$$

pro nějakou matici  $\mathbb{A} \in \mathbb{R}^{r \times r}$ , vektory  $\mathbf{b}, \mathbf{c} \in \mathbb{R}^r$  a skalár  $d \in \mathbb{R}$ ;

## □ Řešení pomocí přenosové funkce soustavy

↪ cílem je najít vyjádření závislosti výstupné posloupnosti na vstupních datech prostřednictvím tzv. přenosové funkce soustavy:  $Y(z) = H(z)U(z)$ ;

$$H(z) = \sum_{k=0}^{\infty} h_k z^{-k} = [\mathbf{c}^\top \cdot (z\mathbb{I} - \mathbb{A})^{-1} \mathbf{b} + d] = N(z)/D(z)$$

## □ Základní vlastnosti/charakteristiky lineární soustavy

□ impulzní charakteristika:  $y_t \equiv h_t$  (stabilita pro  $h_t \rightarrow 0$ );

□ přechodová charakteristika:  $y_t \equiv \sum_{k=0}^t h_k$  (ustálení pro  $\sum_k h_k < \infty$ );

Kapitola 4

# Markovské řetězce

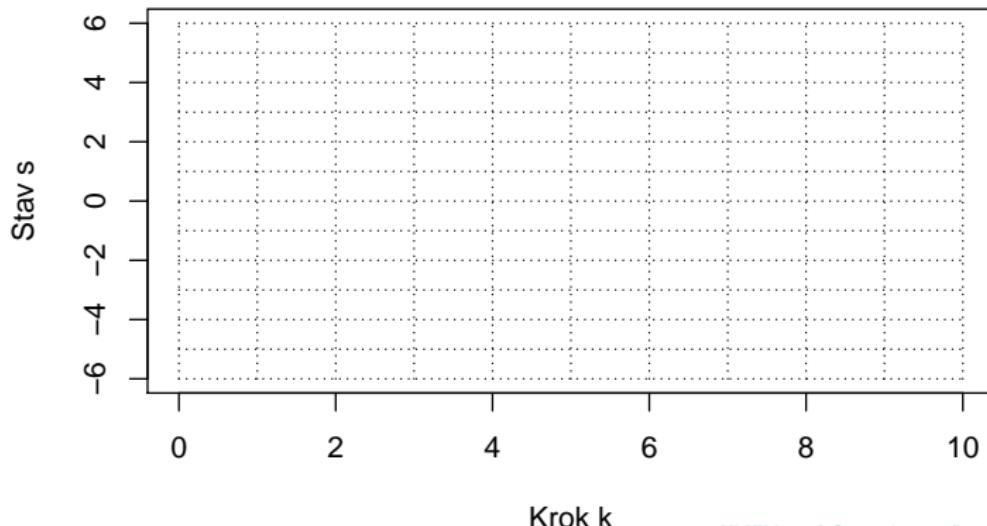
# Deterministické data → Stochastické data

- ☐ v **deterministických modelech** je výstup (reakce) jednoznačně definovaný pomocí vstupu (akce) – napr. **model lineární soustavy**;
- ☐ v **stochastických modelech** je přítomen náhodný element, který přináší do výstupu jistou míru neurčitosti – napr. **náhodná procházka**;



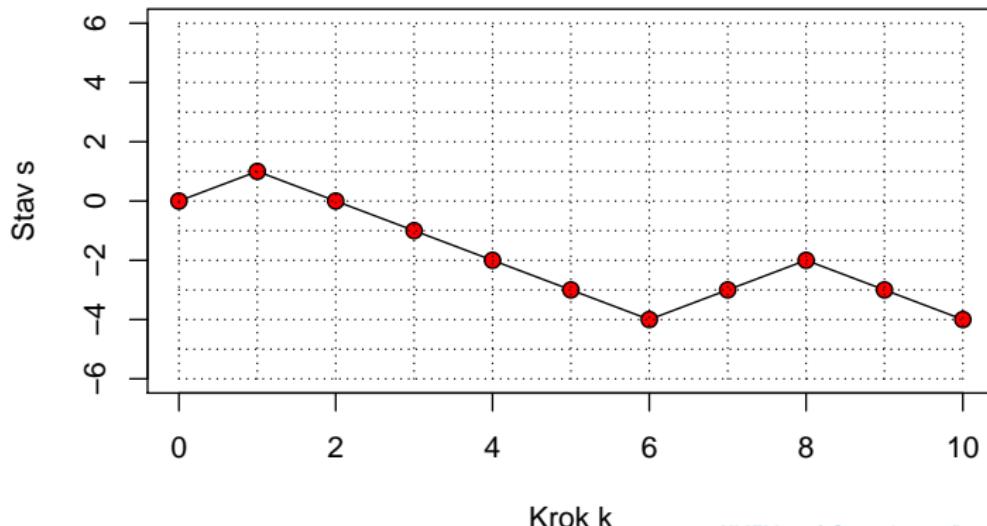
## Náhodná procházka na přímce

- házíme symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- když padne hlava, posuneme se na ose napravo, když líce, tak nalevo;  
(po každom počte hodov sledujeme aktuálnu pozíciu/polohu)



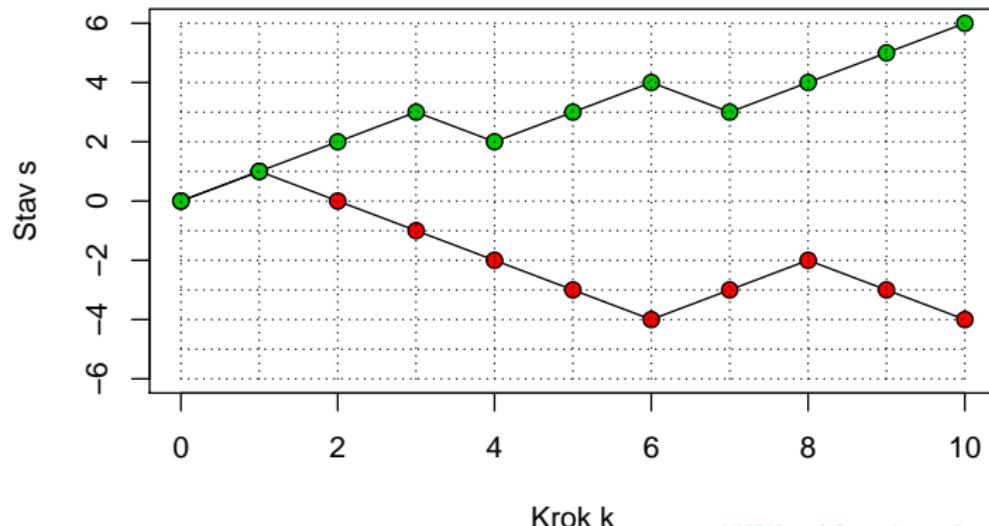
## Náhodná procházka na přímce

- házíme symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- když padne hlava, posuneme se na ose napravo, když líce, tak nalevo; (po každom počte hodov sledujeme aktuálnu pozíciu/polohu)



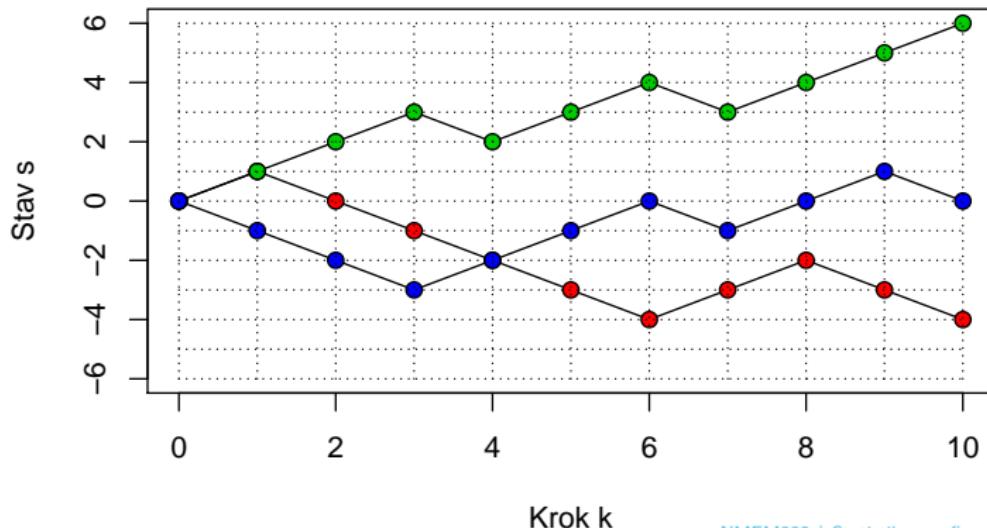
## Náhodná procházka na přímce

- házíme symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- když padne hlava, posuneme se na ose napravo, když líce, tak nalevo; (po každom počte hodov sledujeme aktuálnu pozíciu/polohu)



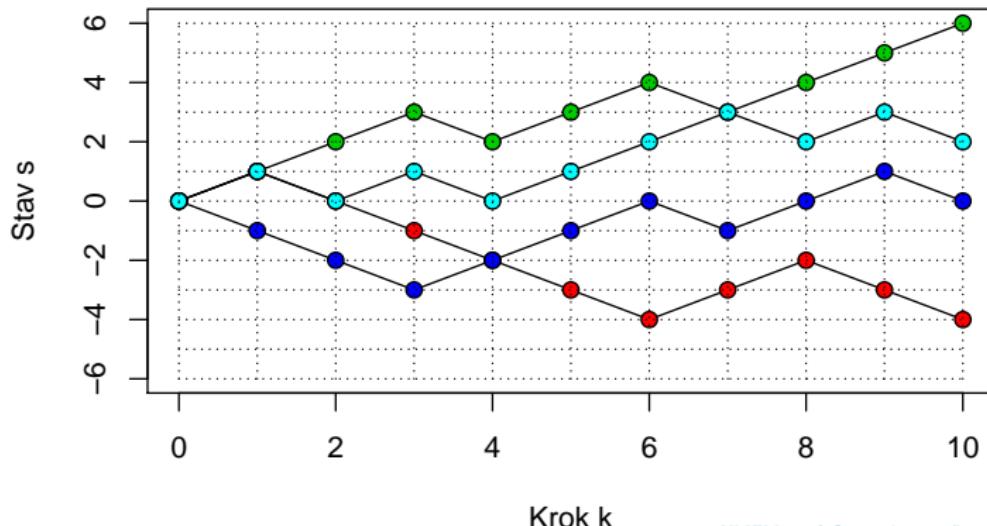
## Náhodná procházka na přímce

- ❑ házime symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- ❑ záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- ❑ když padne hlava, posuneme se na ose napravo, když líce, tak nalevo; (po každom počte hodov sledujeme aktuálnu pozíciu/polohu)



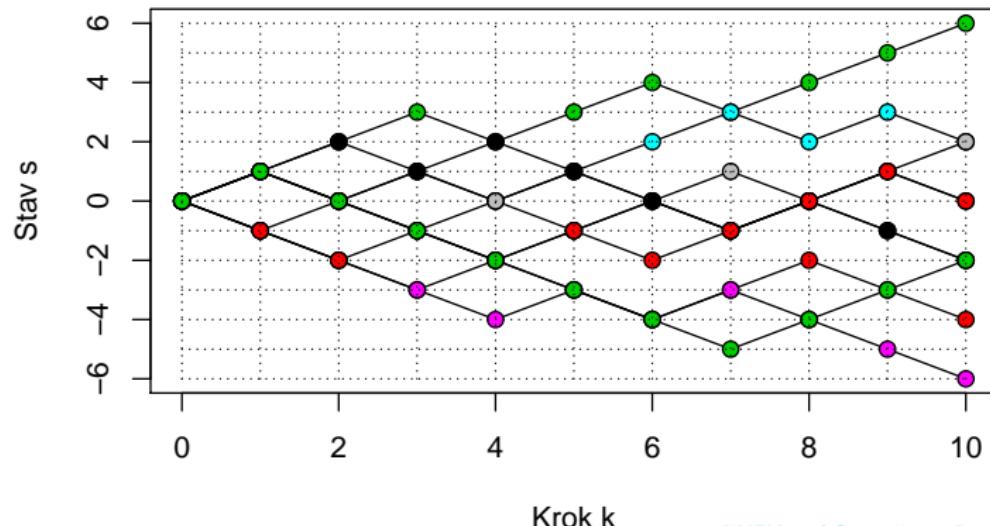
## Náhodná procházka na přímce

- házime symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- když padne hlava, posuneme se na ose napravo, když líce, tak nalevo; (po každom počte hodov sledujeme aktuálnu pozíciu/polohu)

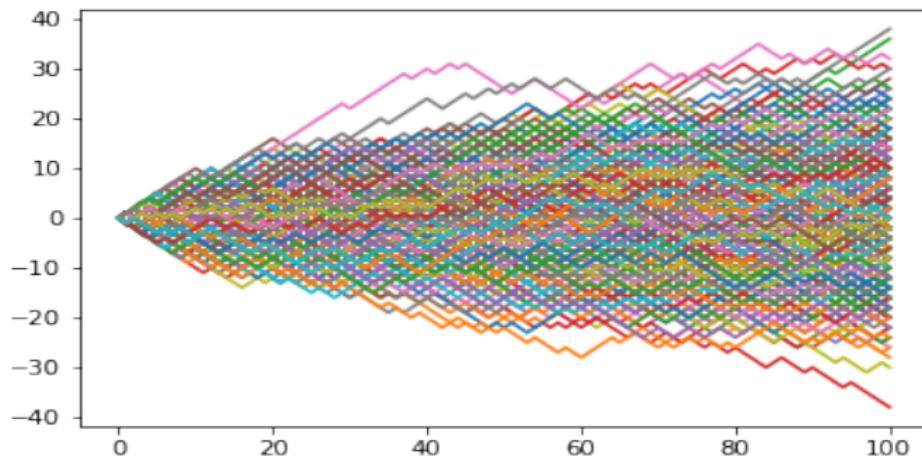


## Náhodná procházka na přímce

- házime symetrickou minci (pravděpodobnost, že padne hlava je  $1/2$ );
- záčínáme v počátku, t.j. počátečný stav je v bodě nula;
- když padne hlava, posuneme se na ose napravo, když líce, tak nalevo; (po každom počte hodov sledujeme aktuálnu pozíciu/polohu)



# Náhodná procházka na přímce II



# Stochastické celočíselné posloupnosti

- uvažujme nějakou posloupnost  $\{X_n; n \in \mathbb{N}\}$ , která nabýva pouze celočíselné hodnoty (konečne, nebo spočetne mnoho);
- hodnoty  $n \in \mathbb{N}$  interpretujeme jako časové okamžiky, ve kterých posloupnost  $\{X_n\}$  nabýva své hodnoty;
- množina  $S \subseteq \mathbb{Z}$  všech možných stavů posloupnosti  $\{X_n\}$ , které může posloupnost hypoteticky nabývat, se nazýva stavový prostor;
- hodnoty  $s \in S$ , které může posloupnost  $\{X_n\}$  hypoteticky (ale ne nutně) nabývat, nazývame stavy;
- budeme uvažovat pouze diskrétní časové okamžiky a posloupnosti, kde  $S$  je nejvýše spočetná množina;
- stav posloupnosti  $\{X_n\}$  v nějakém konkrétním čase  $n \in \mathbb{N}$  závisí na předchozích stavech, ale závislost není deterministická;
- stav posloupnosti  $\{X_n\}$  v čase  $n \in \mathbb{N}$  je vyjádřen prostředníctvím pravděpodobnostního modelu (zahrnuje v sobě míru neurčitosti);

# Markovský řetězec a markovská vlastnost

**Definice:** Markovův řetězec

Řekneme, že posloupnost celočíselných náhodných veličín  $\{X_n\}_{n=0}^{\infty}$  se nazýva **Markovův řetězec** (markovský řetězec), jestliže platí, že

$$P[X_{n+1} = j | X_n = i_n, \dots, X_0 = i_0] = P[X_{n+1} = j | X_n = i_n],$$

pro každé  $n \geq 0$  a každé  $i_0, \dots, i_n \in \mathbb{Z}$  takové, že

$$P[X_n = i_n, \dots, X_0 = i_0] > 0.$$

Množina všech stavů je v tomto případě množina  $\mathbb{Z}$ , t.j.,  $\mathcal{S} \equiv \mathbb{Z}$ .

**Markovskou vlastností** nazývame fakt, že výsledek v čase  $n + 1$  závisí pouze na stavu daného řetězce v čase  $n$  (tudíž na stave v předchozím kroku, neboli v přítomnosti), nikoli na minulosti, t.j. na posloupnosti realizovaných stavů před časem  $n$ .

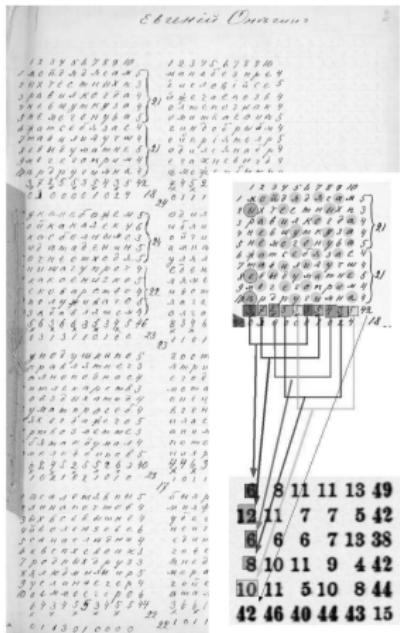
# Markovský řetězec a markovská vlastnost



# Příklady aplikace Markovských řetězců

- **První aplikace:** Andrei A. Markov použil Markovský řetězec na analýzu 20.000 listů z Pushkinovej básne Eugeny Onegin a studoval pravděpodobnosti výskytu samohlásek a souhlasek na základě předchozího výskytu (samohlásek a souhlasek);
- **Teória informaci:** striktně povedané, každý proces pri ktorom zdroj prenáša nějaké informace, je markovský řetězec (Shannonova teórie);
- **Informatika (IT):** aplikácia pre vyhľadávanie algoritmy (napr. Google), hodnotenie web stránok (PageRank), computer performance evaluation;
- **Marketing:** systémy hromadné obsluhy, modelování správania zákazníkov/klientov a modelování změn ich preferencí;
- **Finance a business:** modelování různých finančních trhů, změny různých stavů, jejich chování a pod.
- **Matematika:** simulačné metody, rozhodovací algoritmy, analýza a spracování dat, atd' .;

# Markovský řetězec a Eugeny Onegini



- prvních 800 písmen z celkových 20.000 listů v Pushkinovom Eugeny Oneginovi;
- výskyt jednotlivých písmen zapsán pomocí 40 čtvercových matíc typu  $10 \times 10$ ;
- spodní matice typu  $6 \times 6$  zobrazuje frekvenčný výskyt některých písmen v 500 případech;
- na základě této analýzy sa ukázalo, že není žádny matematický rozdíl mezi kostkou, kterou hodíme 1000 krát a 1000 kostkami, které hodíme pouze jednou, ale všechny naraz;

Hilgers, P. and Langville, A. (2006). The Five Greatest Applications of Markov Chains.  
MAM 2006: Markov Anniversary Meeting . Raleigh 2006.

# Markovský řetězec a Eugeny Onegin

## VII

He was too young to have been blighted  
by the cold world's corrupt finesse;

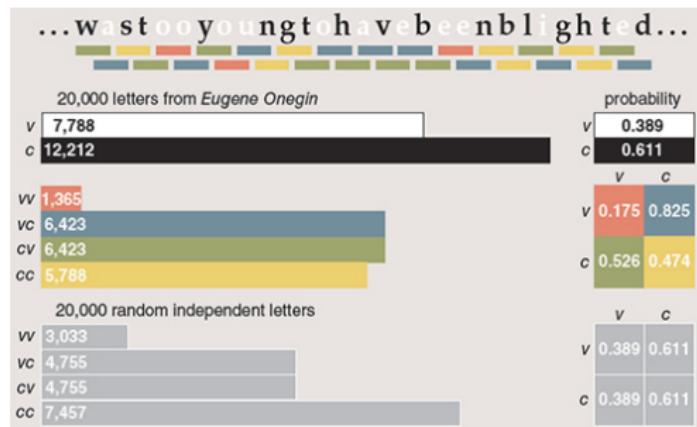
his soul still blossomed out, and lighted  
at a friend's word, a girl's caress.

In heart's affairs, a sweet beginner,  
he fed on hope's deceptive dinner;

the world's éclat, its thunder-roll,  
still captivated his young soul.

He sweetened up with fancy's icing  
the uncertainties within his heart;

for him, the objective on life's chart  
was still mysterious and enticing –  
something to rack his brains about,  
suspecting wonders would come out.



# Pravděpodobnosti přechodu

**Definice:** Pravděpodobnost přechodu

Pravděpodobnost  $p_{ij}(n, n+1) \in [0, 1]$ , pro  $i, j \in \mathcal{S}$ , definovanou jako

$$p_{ij}(n, n+1) = P[X_{n+1} = j | X_n = i],$$

nazývame pravděpodobnost přechodu ze stavu  $i$  v čase  $n$  do stavu  $j$  v čase  $n+1$ ;

- je intuitivně zřejmé, že pro nějaký konkrétný stav  $i \in \mathcal{S}$  a čas  $n \in \mathbb{N}$  dostaneme posloupnost  $\{p_{is}(n, n+1)\}_{s \in \mathcal{S}}$ , která definuje rozdělení pravděpodobnosti na množině stavů  $\mathcal{S}$ ;
- vyjádřeno matematicky:

$$\forall_{n \in \mathbb{N}} \quad \forall_{i \in \mathcal{S}} \quad \sum_{s \in \mathcal{S}} p_{is}(n, n+1) = 1$$

# Homogenita Markovského řetězce

**Definice:** Homogenní Markovský řetězec

Markovský řetězec se nazýva homogenní, jestliže platí, že

$$p_{ij} = p_{ij}(n, n+1),$$

pro všechny  $i, j \in \mathcal{S}$ , tudíž pravděpodobnosti přechodů zo stavu  $i$  do stavu  $j$  nezávisí na čase  $n$ .

- pro konkrétny stav  $i \in \mathcal{S}$  dostaneme opět rozdělení pravděpodobnosti  $\{p_{is}\}_{s \in \mathcal{S}}$  na množine stavů  $\mathcal{S}$ ;

# Počáteční rozdělení řetězce

**Definice:** Počáteční rozdělení

Pravděpodobnosti  $p_i \in [0, 1]$ , pro  $i \in \mathcal{S}$ , které jsou definovány jako

$$p_i = P[X_0 = i],$$

pro  $i \in \mathcal{S}$ , nazývame počáteční rozdělení řetězce.

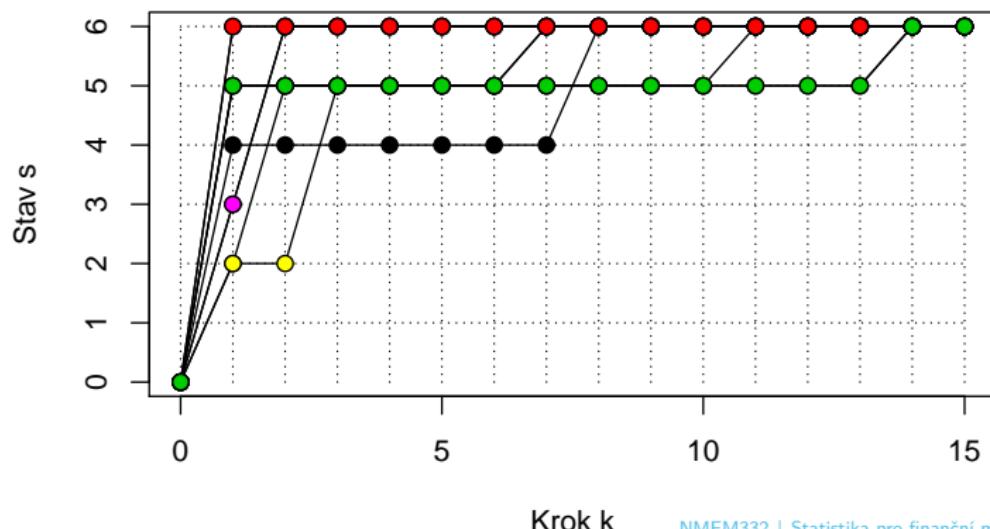
- v případě homogenních Markových řetězců se obvykle přechodové pravděpodobnosti zapisují v maticovém tvaru – tzv. matici přechodových pravděpodobností (resp. přechodová matice):  $\mathbb{P} = (p_{ij})_{i,j \in \mathcal{S}}$ ;
- matice přechodových pravděpodobnosti se také (obecně) nazýva aj stochastická matice, protože součet prvků v každém řádku je roven hodnotě jedna (každý řádek definuje rozdělení pravděpodobnosti na  $\mathcal{S}$ );
- počátečné rozdělení  $\{p_i\}_{i \in \mathcal{S}}$  Markovského řetězce se zapisuje pomocí vektoru pravděpodobnosti počátečného rozdělení:  $\mathbf{p} = (p_1, \dots, p_{|\mathcal{S}|})^\top$ ;

# Matice přechodových pravděpodobnosti

- matice přechodových pravděpodobnosti je definována jako  $\mathbb{P} = (p_{ij})_{i,j=1}^{|S|}$ ;  
*(pro nejvýše spočetný stavový prostor  $S$  a stavy  $i, j \in S$ )*
- matice přechodových pravděpodobnosti může být **obecně nekonečná**;  
*(pro nekonečnou, ale nejvýše spočetnou množinu stavů  $S$ )*
- matice přechodových pravděpodobnosti je **stochastická matice**;  
*(z každého stavu se někam musíme v dalším kroku dostat, nebo zůstat)*
- vektor počátečného rozdělení řetezce má **součet jedna**;  
*(v nějakom stave  $s \in S$  musí řetězec začít)*
- obecně řádky přechodové matice  $\mathbb{P} = (p_{ij})_{i,j=1}^{|S|}$  značí výchozí stav  $i \in S$  a v sloupcích matice se uvádějí koncové stavy  $j \in S$ ;

## Příklad: Dosažené maximum na hrací kostce

- obecně v  $n$ -tém tahu sledujeme dosažené maximum v  $n$  hodech;
- minimální hodnota (stav) je jedna, maximální (stav) je hodnota 6;  
(resp. v čase nula můžeme začínat ve stavu 0 – nebylo maximum dosaženo)



# Příklad: Dosažené maximum na hrací kostce

## Príklad

Házime spravodlivou hrací kostkou a sledujeme dosažené maximum v  $n \in \mathbb{N}$  hodech. Množina stavů je  $\mathcal{S} = \{1, \dots, 6\}$  a matici přechodových pravděpodobností pak můžeme zapsát jako

$$\mathbb{P} = \begin{pmatrix} \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ 0 & \frac{2}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ 0 & 0 & \frac{3}{6} & \frac{1}{6} & \frac{1}{6} & \frac{1}{6} \\ 0 & 0 & 0 & \frac{4}{6} & \frac{1}{6} & \frac{1}{6} \\ 0 & 0 & 0 & 0 & \frac{5}{6} & \frac{1}{6} \\ 0 & 0 & 0 & 0 & 0 & 1 \end{pmatrix}, \quad (9)$$

kde  $p_{ij}$  značí pravděpodobnost přechodu ze stavu  $i$  (řádek) do stavu  $j$  (sloupec), pro libovolné  $i, j \in \mathcal{S}$ .

# Existence cesty v Markovském řetězci

- ☐ v souvislosti s Markovskými řetězci je někdy důležité vyšetřit existenci cesty z nějakého stavu  $i \in \mathcal{S}$  do nějakého jiného stavu  $j \in \mathcal{S}$ ;

**Věta:** Existence cesty v Markovském řetězci

Nechť  $\{X_n\}_{n=0}^{\infty}$  je homogénní Markovský řetězec s nejvýše spočetnou množinou stavů  $\mathcal{S}$ , počátečním rozdělením  $(p_i; i \in \mathcal{S})$  a maticou přechodových pravděpodobností  $\mathbb{P} = (p_{ij})_{i,j \in \mathcal{S}}$ .

Pak platí, že

$$P[X_0 = i_0, X_1 = i_1, \dots, X_n = i_n] = p_{i_0} p_{i_0 i_1} \dots p_{i_{n-1} i_n},$$

pro libovolné stavy  $i_0, \dots, i_n \in \mathcal{S}$ .

## Pravděpodobnosti přechodů vyšších řádů

- existence cesty ze stavu  $i \in \mathcal{S}$  do stavu  $j \in \mathcal{S}$  v  $n$  krocích souvisí s přechodovými pravděpodobnostmi vyšších řádů – pravděpodobnostmi  $p_{ij}^{(n)}$ ;

**Definice:** Pravděpodobnost přechodu v  $n$  krocích

Nechť  $p_{ij}^{(0)} = \mathbb{I}_{\{i=j\}}$  a  $p_{ij}^{(1)} = p_{ij}$ . Pak pravděpodobnost

$$p_{ij}^{(n+1)} = \sum_{k \in \mathcal{S}} p_{ik}^{(n)} p_{kj}$$

se nazýva pravděpodobnost přechodu ze stavu  $i$  do stavu  $j$  po  $(n+1)$  krocích (resp.  $p_{ik}^{(n)}$ ) je pravděpodobnost přechodu  $n$ -tého řádu ze stavu  $i$  do stavu  $k$ .

- pro matici přechodových pravděpodobnosti  $n$ -tého řádu pak používame značení  $\mathbb{P}^{(n)} = (p_{ij}^{(n)})_{i,j \in \mathcal{S}}$ ;

# Pravděpodobnost přechodu $n$ -tého řádu

**Věta:** Pravděpodobnost přechodu v  $n$ -tém kroku

Nechť  $m \in \mathbb{N} \cup \{0\}$  a  $i, j \in \mathcal{S}$ . Pak platí, že

$$P[X_{m+n} = j | X_m = i] = p_{ij}^{(n)}.$$

Pro matici přechodových pravděpodobností  $n$ -tého řádu zároveň platí, že

$$\mathbb{P}^{(n)} = \mathbb{P}^n.$$

- stejně jako matice  $\mathbb{P}$  aj matice přechodových pravděpodobností vyšších řádů  $\mathbb{P}^{(m)}$ , jsou **stochastické matice**, t.j. součet prvků v každém řádku je roven hodnotě jedna;

# Příklad: Dosažené maximum na hrací kostce

## Príklad

Házime spravedlivou hrací kostkou a sledujeme dosažené maximum v  $n \in \mathbb{N}$  hodech. Množina stavů je  $\mathcal{S} = \{1, \dots, 6\}$  a matici přechodových pravděpodobností pak můžeme zapsát jako v (9).

Pro přechodové pravděpodobnosti vyšších řádů máme

$$p_{ij}^{(n)} = \begin{cases} 0 & \text{pro } i > 0; \\ \left(\frac{j}{6}\right)^n & \text{pro } i = j; \\ \left(\frac{j}{6}\right)^n - \left(\frac{j-1}{6}\right)^n & \text{pro } j > i; \end{cases}$$

## Samostatný úkol

Spočtěte matici přechodových pravděpodobnosti pro dosažené maximum na hrací kostce po  $n = 2$  a  $n = 3$  hodech.

# Chapman-Kolmogorova věta

## Věta: Chapman-Kolmogorov

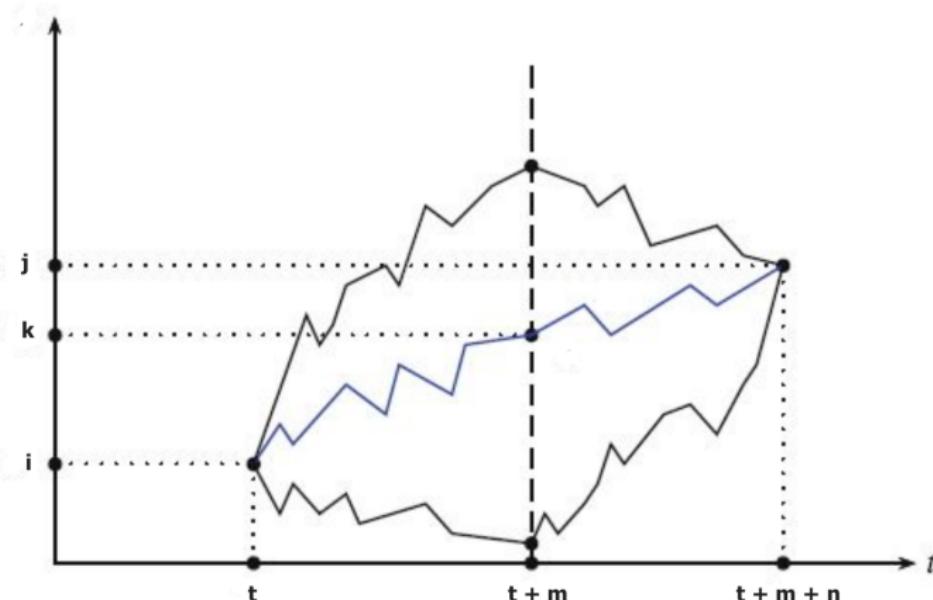
Nechť  $\{X_n\}_{n=0}^{\infty}$  je homogenní Markovský řetězec. Pak pro libovolná  $n, m \in \mathbb{N}$  platí, že

$$p_{ij}^{(n+m)} = \sum_{k \in \mathbb{S}} p_{ik}^{(n)} p_{kj}^{(m)}.$$

### □ IDEA:

Pro pravděpodobnost cesty zo stavu  $i \in \mathcal{S}$  do stavu  $j \in \mathcal{S}$  v  $n + m$  krocích, se stačí podívat na všechny možné dosažitelné stavy  $k \in \mathcal{S}$  po  $n$  krocích a pak všechny možné cesty zo stavu  $k \in \mathcal{S}$  do stavu  $j \in \mathcal{S}$  v  $m$  krocích.

# Chapman-Kolmogorova věta



# Zhrnutí předchozí přednášky/opakování

## □ Markovské řetězce

- Posloupnosti celočíselných náhodných veličin:  $\{X_n; n \in \mathbb{N}\}$ ;  
(uvažujeme pouze diskrétní čas a diskrétně stavy);
- Množina stavů  $\mathcal{S}$  je nejvýše spočetná (např.  $\mathcal{S} \equiv \mathbb{Z}$ );
- Platí Markovská vlastnost:  $P[X_{n+1} = j | X_n, \dots, X_1] = P[X_{n+1} = j | X_n]$ ;
- **Homogenita:** nezávislost přechodov mezi stavy na čase  $n \in \mathbb{N}$ ;

## □ Pravděpodobnosti přechodov a počátečné rozdělení

- Pravděpodobnost přechodu ze stavu  $i$  do stavu  $j$  (v jednom kroku):

$$p_{ij} = P[X_{n+1} = j | X_n = i]$$

- Pravděpodobnost přechodu ze stavu  $i$  do  $j$   $n$ -tého řádů (v  $n$  krokoch):

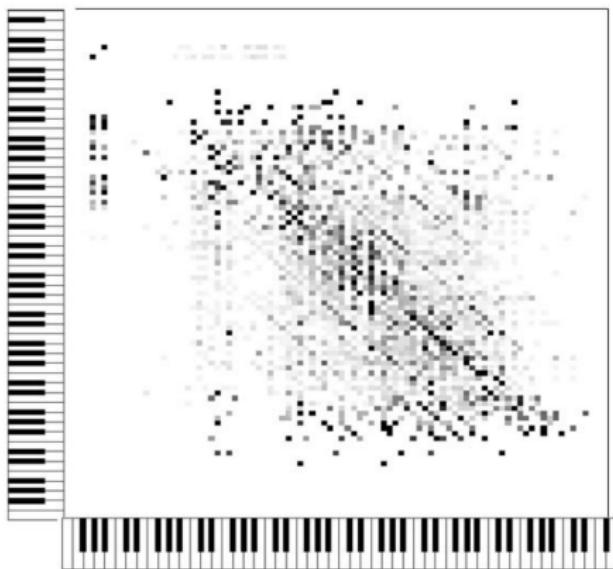
$$p_{ij}^{(n)} = P[X_{m+n} = j | X_m = i]$$

- Počátečné rozdělení Markovského řetězce pro stavu  $i \in \mathcal{S}$ :

$$p_i = P[X_0 = i]$$

- Pro každé  $i \in \mathcal{S}$  se jedná o rozdělení pravdepodobností na  $\mathcal{S}$ ;  
(t.j.,  $\sum_{k \in \mathcal{S}} p_{ik} = \sum_{k \in \mathcal{S}} p_{ik}^{(n)} = \sum_{k \in \mathcal{S}} p_k = 1$  pro  $\forall n \in \mathbb{N}$ )

# Reprezentace Markovského řetězce



I. Stravinsky "The Fire-bird" suite melody

- pomocí matice přechodových pravděpodobnosti  $\mathbb{P} = (p_{ij})_{i,j \in \mathcal{S}}$ ;
- případně matice přechodových pravděpodobnosti vyšších řádů  $\mathbb{P}^{(n)}$ ;
- orientovaný graf s vrcholy pro stavy a váhami pro jednotlivé hrany;
- obrazek ilustrující matici přechodových pravděpodobnosti;

# Klasifikace stavů Markovského řetězce

**Definice:** Dosažitelnost stavu v Markovském řetězci

Řekneme, že nějaký stav  $j \in \mathcal{S}$  je **dosažitelný** ze stavu  $i \in \mathcal{S}$ , pokud existuje číslo  $n \in \mathbb{N}$  takové, že  $p_{ij}^{(n)} > 0$ .

- pro vyjádření faktu, že stav  $j$  je dosažitelný ze stavu  $i$  (ne nutně v jednom kroku), používame značení  $i \rightarrow j$ ;

**Definice:** Nerozložitelnost Markovského řetězce

Řekneme, že Markovský řetězec je **nerozložitelný**, pokud každý stav je dosažitelný z každého stavu.

- dosažitelnost stavů v Markovském řetězci a nerozložitelnost řetězce nemusí byt patrná pouze z pohledu na samotnou matici  $\mathbb{P}$ ;

# Rozložitelnost a nerozložitelnost řetězce

## Príklad

Uvažujme Markovský řetězec se čtyřprvkovou množinou stavů  $S$  a maticou přechodových pravděpodobnosti

$$\mathbb{P} = \begin{pmatrix} 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 1 & 0 \\ 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 \end{pmatrix}$$

- jedná se o rozložitelný Markovský řetězec protože stav 1 nelze dosáhnout ze žádného jiného stavu 2,3 a 4;
- pro nerozložitelnost řetězce by stačilo například umožnit přechod ze stavu 2 do stavu 1, t.j., definovat  $p_{21} > 0$ ;

## Samostatný úkol

Reprezentujte Markovský řetězec z příkladu pomocí vhodného grafu.

# Uzavřená množina stavů

**Definice:** Množna uzavřených stavů

Řekneme, že neprázdná množina stavů  $\mathcal{C} \subset \mathcal{S}$  je uzavřená množina, pokud každý stav vně množiny  $\mathcal{C}$  není dosažitelný z žádneho stavu množiny  $\mathcal{C}$ .

□ **IDEA:**

Jakmile řetězec jednou vejde do nějakého stavu  $s \in \mathcal{C}$ , pak již nemůže řetězec nabýt zádneho jiného stavu, kromě stavů v množine  $\mathcal{C}$ .

□ uzavřenosť ve zmyslu *nemůžeme ven, ale pořád můžeme dovnitř*;

**Věta:** Nerozložitelnost řetězce I

Markovský řetězec je nerozložitelný právě tehdy, kdýž neexistuje žádna uzavřená množina  $\mathcal{C} \subset \mathcal{S}$ , taková, že  $\mathcal{C} \neq \mathcal{S}$ .

# Rozložitelnost a nerozložitelnost řetězce

**Věta:** Uzavřená množina stavů

Množina stavů  $\mathcal{C} \subset \mathcal{S}$ , taková, že  $\mathcal{C} \neq \mathcal{S}$  je uzavřená právě tehdy, když platí, že

$$p_{jk} = 0 \quad \text{pro} \quad \forall j \in \mathcal{C} \quad \text{a} \quad \forall k \notin \mathcal{C}.$$

**Věta:** Nerozložitelnost řetězce II

Řetězec je rozložitelný právě tehdy, když po vhodném přečíslování stavů řetězce (a teda příslušnou permutaci řádků a sloupců matice  $\mathbb{P}$ ) je matice přechodových pravděpodobností ve tvaru

$$\mathbb{P} = \begin{pmatrix} \mathbb{P}_1 & \mathbf{0} \\ \mathbb{Q} & \mathbb{R} \end{pmatrix},$$

kde  $\mathbb{P}_1$  a  $\mathbb{R}$  jsou čtvercové matice a  $\mathbb{P}_1$  je navíc stochastická.

# Doba prvního vstupu (návratu) do stavu

**Definice:** Doba prvního vstupu

Pro libovolný stav  $i \in \mathcal{S}$  definujeme

$$\nu_i = \inf\{n \in \mathbb{N}; X_n = i\}$$

jako **čas prvního vstupu** (resp. **doba prvního návratu** řetězce  $\{X_n; n \in \mathbb{N}\}$  do stavu  $i \in \mathcal{S}$ , t.j., záleží na počátečním rozdělení).

- analogicky lze definovat i obecný čas  $k$ -tého vstupu (návratu) řetězce do stavu  $i \in \mathcal{S}$  jako

$$\nu_i(k) = \inf\{n > \nu_i(k-1); X_n = i\},$$

kde definujeme  $\nu_i(1) \equiv \nu_i$ , pro  $i \in \mathcal{S}$ ;

## Doba mezi návraty do stavu

Pro doby, které Markovský řetězec stráví mezi jednotlivými návraty do daného stavu  $i \in \mathcal{S}$  se obecně zavádí značení

- $T_i(1) = \nu_i = \nu_i(1)$ : doba do prvního návratu/vstupu do stavu  $j \in \mathbb{S}$ ;
- $T_i(2) = \nu_i(2) - \nu_i(1)$ : doba mezi prvním a druhým návratem/vstupem;
- $T_i(k) = \nu_i(k) - \nu_i(k-1)$ : doba mezi  $k$ -tym a  $(k-1)$ -vým návratem;
  
- Samozrejme platí, že

$$\nu_i(k) = T_i(1) + T_i(2) + \cdots + T_i(k);$$

Poznámka:

Je vhodné rozlišovat **návrat do stavu  $i \in \mathcal{S}$**  (pokud již řetězec v tomto stavu v minulosti byl) a **vstup do stavu  $i \in \mathcal{S}$**  (pokud řetězec v daném stavu ještě nebyl).

V praxi (ovšem ne nutně vždy a všude) se obecně používá vyjádření o prvním vstupu do stavu  $i \in \mathcal{S}$  ("nultý" návrat) a pak o  $k$ -tému návratu (t.j.,  $(k+1)$ -ní vstup).

# Trvalý a přechodný stav v Markovském řetězci

**Definice:** Trvalý stav

Stav  $i \in \mathcal{S}$  takový, že platí

$$P_i[\nu_i < \infty] = P[\nu_i < \infty | X_0 = i] = 1,$$

se nazýva trvalý stav řetězce  $\{X_n; n \in \mathbb{N}\}$ .

**Definice:** Přechodný stav

Stav  $i \in \mathcal{S}$  takový, že platí

$$P_i[\nu_i = \infty] = P[\nu_i = \infty | X_0 = i] > 0,$$

se nazýva přechodný (transientní) stav řetězce  $\{X_n; n \in \mathbb{N}\}$ .

# Přechodný a trvalý nulový a nenulový stav

- Trvalý stav je teda takový, že řetězec, který vychází ze stavu  $i \in \mathbb{S}$  (proto podmínka, že  $X_0 = i$ ), se v konečné mnoha krocích do tohto stavu vráti s pravděpodobností 1;
- V opačném případě (t.j., existuje kladná pravděpodobnost, že řetězec, který začal ve stavu  $i \in \mathbb{S}$ , se již nikdy do tohto stavu nevráti) řekneme, že stav je přechodný.

**Definice:** Trvalý nulový a nenulový stav

- Trvalý stav  $i \in \mathcal{S}$  takový, že  $E_i \nu_i = \infty$ , se nazýva **nulový stav**;
- Trvalý stav  $i \in \mathcal{S}$  takový, že  $E_i \nu_i < \infty$ , se nazýva **nenulový stav**;

Střední hodnoty v definici jsou definované vzhledem k pravděpodobnostní míře  $P_i[\cdot] = P[\cdot | X_0 = i]$  (t.j., záleží na počátečném rozdělení);

# Klasifikace stavů v Markovském řetězci

- Do trvalého stavu se Markovský řetězec vrátí nekonečne mnoho krát s pravděpodobností 1.
- Do přehodného stavu se Markovský řetězec vráti nekonečne mnoho krát s pravděpodobností nula.
- Nechť  $f_i^{(n)} = P_i[\nu_i = n]$  (první návrat v čase  $n$ ) a nechť  $f_i^{(0)} = 0$ . Pak je zřejmé, že stav  $i \in \mathcal{S}$  je trvalý, právě tehdy, když platí, že

$$\sum_{n=1}^{\infty} f_i^{(n)} = \sum_{n=0}^{\infty} f_i^{(n)} = 1;$$

- Pro střední hodnotu  $E_i \nu_i$  platí:  $E_i \nu_i = \sum_{n=1}^{\infty} n P_i[\nu_i = n] = \sum_{n=1}^{\infty} n f_i^{(n)}$ ;
- Obecně pro  $n \geq 1$  platí, že  $p_{ii}^{(n)} = P_i[X_n = i] = \sum_{k=1}^n f_i^{(k)} p_{ii}^{(n-k)}$ ;
- Obecně pro  $n \geq 0$  a  $i \neq j$  platí  $p_{ij}^{(n)} = P_i[X_n = j] = \sum_{k=1}^n f_{ij}^{(k)} p_{jj}^{(n-k)}$ , kde  $f_{ij}^{(n)} = P_i[\nu_j = n] = P[\nu_j = n | X_0 = i]$  (první vstup v čase  $n$ );

# Periodický a neperiodický stav

## Definice: Periodický stav

Stav  $i \in \mathcal{S}$  v homogénním Markovském řetězci  $\{X_n; n \in \mathbb{N}\}$  se nazýva **periodický s periodou  $d \in \mathbb{N}$** , pokud platí, že

$$d = NSD(n > 0; p_{ii}^{(n)} > 0) > 1,$$

teda největší společný dělitel pro čas návratu do stavu  $i$  je větší jako jedna.

- Pokud platí, že  $NSD = 1$ , pak řekneme, že stav  $i \in \mathbb{N}$  je **aperiodický** neboli **neperiodický**.

# Stavy stejného typu

**Definice:** Stavy stejného typu

Řekneme, že dva stavy jsou stejného typu, pokud platí, že oba stavy jsou trvalé/přechodné, nulové/nenulové a periodické/neperiodické, so stejnou periodou  $d > 1$ .

Príklad

- ❑ Ověřte, že v Markovském řetězci s přechodovou matici

$$\mathbb{P} \begin{pmatrix} 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & p & (1-p) & 0 \\ 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 \\ 0 & 1 & 0 & 0 & 0 \end{pmatrix},$$

jsou všechny stavy periodické, s periodou  $d = 3$  pro  $p \in (0, 1)$ .

- ❑ Co se stane, když do procesu přidáme jednu smyčku typu  $p_{ii} > 0$ ?

# Klasifikace stavů v Markovském řetězci I

**Věta:** Trvalý a trvalý nulový stav

- Stav  $i \in \mathcal{S}$  je trvalý  $\Leftrightarrow \sum_{n=0}^{\infty} p_{ii}^{(n)} = \infty$ ;
- Stav  $i \in \mathcal{S}$  je přechodný  $\Leftrightarrow \sum_{n=0}^{\infty} p_{ii}^{(n)} < \infty$ ;
- Trvalý stav  $i \in \mathcal{S}$  je nulový  $\Leftrightarrow p_{ii}^{(n)} \rightarrow 0$  pro  $n \rightarrow \infty$ ;

**Věta:** Trvalé vs. přechodné stavy

V nerozložitelném Markovském řetězci s  $\mathcal{S} = \{0, 1, 2, \dots\}$  jsou všechny stavy trvalé tehdy a jen tehdy, když jediné řešení soustavy

$$x_i = \sum_{j=1}^{\infty} p_{ij} x_j, \quad i = 1, 2, \dots, \quad (10)$$

v intervalu  $[0, 1]$  je triviální, t.j.  $x_i = 0$  pro všechny  $i = 1, 2, \dots$

Všechny stavy jsou přechodné  $\Leftrightarrow$  existuje netriviální řešení (10).

## Klasifikace stavů v Markovském řetězci II

**Věta:** Řetězec s konečně mnoha stavů

- V Markovském řetězci s konečnou množinou stavů  $\mathcal{S}$  nemohou být všechny stavy přechodné.
- V Markovském řetězci s konečnou množinou stavů  $\mathcal{S}$  neexistují stavy trvalé nulové.

**Věta:** Stavy stejného typu

Uvažujme Markovský řetězec s množinou stavů  $\mathcal{S}$ .

- Když pro libovolné dva stavы  $i, j \in \mathcal{S}$  existuje cesta  $i \rightarrow j \rightarrow i$ , pak jsou oba stavy  $i$  a  $j$  stejného typu.
- Pokud  $i \rightarrow j \not\rightarrow i$ , pak stav  $i$  je přechodný.
- V nerozložitelném řetězci jsou všechny stavy stejného typu.

# Absorbčné a ergodické stavy

- V případě Markovských procesů je užitečné ještě definovat tzv. absorbční stav a ergodický stav procesu.

## Definice: Absorbční stav

Stav, ze kterého není dosažitelný žádný jiný stav, se nazýva **absorbčný**.

## Definice: Ergodický stav

Stav, který je trvalý, nenulový a neperiodický, se nazýva **ergodický**.

# Příklad: Dosažené maximum na hrací kostce

## Príklad

- stav  $i \in \mathcal{S}$  je trvalý  $\Leftrightarrow \sum_{n=0}^{\infty} p_{ii}^{(n)} = \infty$ , pro  $i = 1, \dots, 6$ ;
  - v našem případě platí:  $p_{ii}^{(n)} = \left(\frac{i}{6}\right)^n$ ;
  - pro  $i = 1, \dots, n$  je řada konvergentní;
  - pro  $i = 6$  je suma divergentní;
- stav  $i = 6$  je proto trvalý, stavy  $i = 1, \dots, 5$  jsou přechodné;
- je stav  $i = 6$  nulový nebo nenulový?
  - podle definice:  $E_i \nu_i = 1 \cdot 1 = 1 < \infty$ ;
  - stav  $i = 6$  je proto trvalý nenulový;
  - střední doba návratu do stavu  $i = 6$  je 1 ( $\nu_6 = 1$ );
  - množina stavů  $\{6\}$  je uzavřená, a stav je absorbční;

# Příklad: Náhodná procházka

## Príklad

- otázka zní, jak se chovají pravděpodobnosti  $p_{ii}^{(n)}$ ?
- z povahy řetězce je zřejmé, že  $p_{ii}^{(n)} = 0$  pro  $n \in \mathbb{N}$  liché;
- pro pravděpodobnosti  $p_{ii}^{(2n)}$  pak dostaneme:

$$p_{ii}^{(2n)} = \binom{2n}{n} 2^{-2n} = \frac{(2n)! 2^{-2n}}{(n!)^2} \approx \frac{(2n)^{2n} e^{-2n} \sqrt{4\pi n} 2^{-2n}}{n^{2n} e^{-2n} 2\pi n} = \frac{1}{\sqrt{n\pi}} \rightarrow 0,$$

kde jsme využili Stirlingovou approximaci  $n! \approx n^n e^{-n} \sqrt{2\pi n}$ ;

- tudíž platí, že  $p_{ii}^{(n)} \rightarrow 0$ , pro  $n \rightarrow \infty$ ;
- zároveň platí, že  $\sum_{n=1}^{\infty} p_{ii}^{(n)} = \infty$ ;
- všechny stavy jsou proto trvalé nulové;

# Příklad: Človeče nezlob se!

## Samostatný úkol

Uvažujte hru Človeče nezlob se, kde hrací plocha má pouze 15 stanovišť. Hráč se posune o kolik kroků dopředu, kolik hodil bodů na kostce. Když hodí hodnotu šest, háže opět a posune se o počet kroků daný součtem bodů v jednotlivých hodech. Hráč končí, když se hráč vrátí spátky na štartovací pozici – t.j. políčko č. 15.

Jak vypadá matice přechodových pravděpodobností? Klasifikujte stavy Markovského procesu.



# Zhrnutí/opakování

- Homogénní Markovské řetězce s diskrétným časem  $n \in \mathbb{N}$  a nejvýše spočetnou množinou stavu  $\mathcal{S}$ ;
- Klasifikace stavů v Markovském řetězci:
  - Trvalé nulové a nenulové stavy;
  - Přechodné stavy;
  - Neperiodické a periodické stavy s periodou  $d > 1$ ;
  - Absorbční a ergodické stavy;
- Rozložitelnost a nerozložitelnost řetězce:
  - Dosažitelnost stavů (existence cesty  $i \rightarrow j \rightarrow i$ );
  - Existence uzavřené podmnožiny stavů  $\Rightarrow$  rozložitelnost řetězce;
- Zavedené veličiny a značení:
  - Počáteční a přechodové pravděpodobnosti:  $p_i, p_{ij}, p_{ij}^{(n)}$  pro  $i, j \in \mathcal{S}$ ;
  - Čas prvního (obecně  $k$ -tého) návratu/vstupu do stavu  $i \in \mathcal{S}$ :  $\nu_i(k)$ ;
  - Čas mezi  $k$ -tým a  $(k - 1)$ -ním vstupem do stavu  $i \in \mathcal{S}$ :  $T_i(k)$ ;
  - Podmíněná pravděpodobnost počátečním stavem:  $P_i[\cdot] = P[\cdot | X_0 = i]$ ;
  - Pravděpodobnost návratu/vstupu do stavu  $i \in \mathcal{S}$  v čase  $n \in \mathbb{N}$ :  $f_i^{(n)}, f_{\ell i}^{(n)}$ ;

# Chování Markovských řetězců pro $n \rightarrow \infty$

- Homogénní Markovský řetězec  $\{X_n; n \in \mathbb{N}\}$  s diskrétním časem a nejvýše spočetnou množinou stavů  $\mathcal{S}$ ;
- Zajíma nás dlouhodobé chování Markovských řetězců, t.j., pro  $n \rightarrow \infty$ ;
- Jaké je marginální rozdělení náhodnej veličiny  $X_n$ , pro  $n \rightarrow \infty$ ;
- Obecně, náhodné veličiny  $X_n$  mají různe rozdělení pro různa  $n \in \mathbb{N}$ ;

# Chování Markovských řetězců pro $n \rightarrow \infty$

- ❑ Homogénní Markovský řetězec  $\{X_n; n \in \mathbb{N}\}$  s diskrétním časem a nejvýše spočetnou množinou stavů  $\mathcal{S}$ ;
- ❑ Zajíma nás dlouhodobé chování Markovských řetězců, t.j., pro  $n \rightarrow \infty$ ;
- ❑ Jaké je marginální rozdělení náhodnej veličiny  $X_n$ , pro  $n \rightarrow \infty$ ;
- ❑ Obecně, náhodné veličiny  $X_n$  mají různe rozdělení pro různa  $n \in \mathbb{N}$ ;
  
- ❑ **Oázka:** Lze něco obecně říct o rozdělení  $X_n$ , pro  $n \rightarrow \infty$ ?
  - ❑ např., rozdělení je stejné pro všechny  $n \geq n_0$ , pro nějaké vhodně zvolené  $n_0 \in \mathbb{N}$ ;
  - ❑ nebo rozdělení náhodne veličiny  $X_n$  konverguje k nějakému limitnímu rozdělení pro  $n \rightarrow \infty$ ;
  - ❑ nebo existuje nějaké rozdělení Markovského řetězce, které zaručuje nějaký jednoduchý princip fungovania – "stabilitu" Markovského řetězce;

# Stacionární rozdělení Markovského řetězce

**Definice:** Stacionární rozdělení Markovského řetězce

Řekneme, že pravděpodobnostné rozdělení  $\pi = (\pi_i; i \in \mathcal{S})$  na množine stavů  $\mathcal{S}$  je **stacionární rozdělení Markovského řetězce**, pokud platí, že

$$\pi_j = \sum_{i \in \mathcal{S}} \pi_i p_{ij},$$

pro všechny  $j \in \mathcal{S}$ . Maticově lze také zapsát jako

$$\boldsymbol{\pi}^\top = \boldsymbol{\pi}^\top \mathbb{P},$$

pro matici přechodových pravděpodobnosti  $\mathbb{P} = (p_{ij})_{i,j \in \mathcal{S}}$ .

## Samostatný úkol

Vysvětlete, co znamená, že  $\pi = (\pi_i; i \in \mathcal{S})$  je pravděpodobnostné rozdělení na množine stavů  $\mathcal{S}$ . Všimněte si, že  $\pi = (\pi_1, \dots, \pi_{|\mathcal{S}|})^\top$  nezávisí na čase  $n \in \mathbb{N}$ .

# Limitní rozdělení Markovského řetězce

**Definice:** Limitní rozdělení Markovského řetězce

Řekneme, že pravděpodobnostné rozdělení  $\mathcal{P} = (p_i; i \in \mathcal{S})$  na množině stavů  $\mathcal{S}$  je **limitní rozdělení Markovského řetězce**, pokud platí, že

$$p_i = \lim_{n \rightarrow \infty} p_i(n),$$

kde  $p_i(n) = P[X_n = i]$ , pro  $i \in \mathcal{S}$ .

Samostatný úkol

Ukážte, ze pro Markovský řetězec s maticou přechodových pravděpodobnosti

$$\mathbb{P} = \begin{pmatrix} 1/2 & 1/2 & 0 & 0 \\ 1/2 & 1/2 & 0 & 0 \\ 0 & 0 & 1/2 & 1/2 \\ 0 & 0 & 1/2 & 1/2 \end{pmatrix}$$

neexistuje limitní rozdělení.

## Limitní vs. stacionární rozdělení

- **Stacionární rozdělení** Markovského řetězce se vztahuje pouze k pravděpodobnostem přechodu  $p_{ij}$ , pro  $i, j \in \mathcal{S}$ . Nezávisí teda na počátečném rozdělení Markovského řetězce.
- **Limitní rozdělení** se vztahuje k rozdělení celého Markovského řetězce. Je tedy ovplivněno i počátečním rozdělením Markovského řetězce.
- Snadno lze nahlédnout, že pokud je počáteční rozdělení řetězce rovno stacionárnímu rozdělení  $\pi$ , pak je i rozdělení řetězce ve všech dalsích časech  $n \in \mathbb{N}$ , t.j. rozdělení  $(p_i(n); i \in \mathcal{S})$ , rovné rozdělení  $\pi$ .

**Věta:** Stritně stacionární proces

V případě, že počáteční rozdělení řetězce je stejné jako stacionární rozdělení, pak pro všechny  $k \in \mathbb{N}$ , pro libovolnou posloupnost stavů  $i_0, \dots, i_k \in \mathcal{S}$  a libovolný čas  $n \in \mathbb{N}$  platí

$$P[X_0 = i_0, \dots, X_k = i_k] = P[X_n = i_0, \dots, X_{n+k} = i_k].$$

Takový řetězec se nazýva **striktně stacionární**.

## Limitní rozdělení $\Rightarrow$ stacionární rozdělení

**Věta:** Limitní rozdělení a stacionární rozdělení

Nechť existuje limitní rozdělení  $\mathcal{P} = (p_i; i \in \mathcal{S})$  Markovského řetězce  $\{X_n; n \in \mathbb{N}\}$ . Pak je toto rozdělení zároveň stacionárním rozdělením Markovského řetězce a tudíž platí, že

$$\mathcal{P} = \boldsymbol{\pi}.$$

- Opačná implikace samozřejme obecně neplatí: není pravda, že existence stacionárního rozdělení by byla postačující podmínka pro existenci limitního rozdělení Markovského řetězce;

# Nerozložitelnost a existence stacionárního rozdělení

**Věta:** Nerozložitelnost a existence stacionárního rozdělení

Nechť  $\{X_n; n \in \mathbb{N}\}$  je nerozložitelný Markovský řetězec s množinou stavů  $S$ . Pak **stacionární rozdelení** existuje právě když všechny stavy jsou trvalé nenulové. Existence je navíc jednoznačna.

- Jsou-li navíc všechny stavy neperiodické, je **stacionární rozdelení i limitním rozdelením** a platí

$$\lim_{n \rightarrow \infty} p_j(n) = \lim_{n \rightarrow \infty} p_{ij}^{(n)} = \pi_j = \frac{1}{E_j \nu_j} = \frac{1}{\mu_j},$$

- Jsou-li všechny stavy periodické, pak

$$\lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_j(k) = \lim_{n \rightarrow \infty} \frac{1}{n} \sum_{k=1}^n p_{ij}^{(k)} = \pi_j.$$

Bez důkazu

## Nerozložitelnost a neexistence stacionárního rozdělení

**Věta:** Neexistence stacionárního rozdělení v nerozložitelném MŘ

Nechť  $\{X_n; n \in \mathbb{N}\}$  je nerozložitelný Markovský řetězec s množinou stavů  $\mathcal{S}$ . Pak platí, že

- jsou-li všechny stavy Markovského řetězce přechodné, nebo všechny jsou trvalé nulové, pak **stacionrní rozdělení neexistuje**.

- stačí si uvědomit, že jsou-li všechny stavy MŘ přechodné, nebo trvalé nulové, pak musí platit, že

$$p_{ij}^{(n)} \rightarrow 0, \quad \text{pre } n \rightarrow \infty \text{ a } \forall i, j \in \mathcal{S}$$

- z definicie stacionarného rozdelenia ale dostaneme spor s faktom, že sa má jednat o pravdepodobnostné rozdělení, tudíž že platí

$$\sum_{i \in \mathcal{S}} \pi_i = 1$$

## Příklad: Nehodové pojištění s bonusem

- V konečném nerozložitelném řetězci stacionární rozdělení vždy existuje.  
*(všechny stavы jsou totiž trvalé nenulové)*
- Stacionární rozdělení nerozložitelného řetězce nepopisuje pouze limity absolutních pravděpodobností jednotlivých stavů, ale popisuje také četnosti návratu do jednotlivých stavů, čas který daný Markovský řetězec v jednotlivých stavech stráví.

### Príklad

Uvažujeme nehodové pojištění se třemi různymi úrovněmi:

- základní sazba (stav 1);
- sazba s bonusem 30 % (stav 2);
- sazba s bonusem 50 % (stav 3);

Rok bez pojistní události znamená postup do lepší pojistní kategorie pro příští rok (když taková možnost existuje). Jedná pojistní událost v průběhu roka znamená posun o jednu kategorii níž (pokud to lze) pro další rok. V případě většího počtu události posun do základní kategorie.

# Příklad: Nehodové pojištění s bonusem

## Príklad

- situaci chceme modelovat pomocí Markovského řetězce;
- počet pojistních událostí  $Y_n$  v daném roce  $n \in \mathbb{N}$  má Poissonovo rozdělení s parametrem  $\lambda > 0$ ;
- náhodná veličina  $X_{n+1}$  je definovaná následovně:

$$X_{n+1} = \begin{cases} \min(X_n + 1, 2) & \text{pro } Y_n = 0 \\ \max(X_n - 1, 0) & \text{pro } Y_n = 1 \\ 0 & \text{pro } Y_n > 1 \end{cases}$$

- ukážte, že  $\{X_n; n \in \mathbb{N}\}$  je Markovský řetězec;
- najděte matici přechodových pravděpodobnosti  $\mathbb{P}$ ;
- nájděte soustavu rovnic pro nalezení stacionárního rozdělení;

# Počet přechodů stavem $j \in \mathcal{S}$

**Definice:** Počet přechodů daným stavem

Náhodná veličina

$$N_j(n) = \sum_{k=1}^n \mathbb{I}_{\{X_k=j\}},$$

se nazýva počet přechodů stavem  $j \in \mathbb{S}$  v prvních  $n \in \mathbb{N}$  krocích (resp. počet návratů do stavu  $j \in \mathcal{S}$ ).

- počet návratů do stavu  $j$  (náhodná veličina  $N_j(n)$ ) úzce souvisí s časmi návratu do stavu  $j \in \mathcal{S}$ ;

# Počet přechodů, časy návratů a klasifikace

- Limitním přechodem získame celkový počet návratu do stavu  $j \in \mathcal{S}$  jako

$$N_j = \lim_{n \rightarrow \infty} N_j(n) = \lim_{n \rightarrow \infty} \sum_{k=1}^n \mathbb{I}_{\{X_k=j\}} = \sum_{k=1}^{\infty} \mathbb{I}_{\{X_k=j\}}.$$

- Snadno se nahlédne, že platí nasledující:

- $N_j \geq k \Leftrightarrow \nu_j(k) < \infty$ ;
- $N_j = k \Leftrightarrow \nu_j(k) < \infty \wedge \nu_j(k+1) = \infty$ ;

## Věta: 0 – 1 zákon

- ak je stav  $j \in \mathcal{S}$  přechodný, pak  $P_j[N_j = \infty] = 0$  (nula)
- ak je stav  $j \in \mathcal{S}$  trvalý, pak  $P_j[N_j = \infty] = 1$  (jedna)

Bez důkazu

# Počet přechodů $N_j(n)$ a stacionární rozdělení

**Věta:** Stacionární rozdělení v řetězci s trvalými nenulovými stavy

V nerozložitelném Markovském řetězci s trvalými nenulovými a neperiodickými stavami platí, že

$$\lim_{n \rightarrow \infty} \frac{N_j(n)}{n} = \pi_j, \quad \text{s pravděpodobností 1}$$

pro všechny stavy  $j \in \mathcal{S}$ .

**Věta:** Asymptotická normalita

V nerozložitelném MŘ s trvalými nenulovými stavami a konečnými rozptyly dob návratu, t.j.,  $\sigma_j^2 = \text{Var}[\nu_i] < \infty$  navíc platí, že

$$\lim_{n \rightarrow \infty} P \left[ \frac{N_j(n) - \frac{n}{\mu_i}}{\sqrt{n\sigma_i^2 / \mu_i^3}} \right] = \Phi(x), \quad \forall x \in \mathbb{R}$$

## Příklad: Stacionární rozdělení

### Príklad

Uvažujme Markovský řetězec s množinou stavů  $S = \{0, 1, 2, \dots\}$  a maticou přechodových pravděpodobností

$$\mathbb{P} = \begin{pmatrix} q & p & 0 & 0 & \cdots \\ q & 0 & p & 0 & \cdots \\ 0 & q & 0 & p & \cdots \\ 0 & 0 & q & 0 & \cdots \\ \vdots & \vdots & \vdots & \vdots & \ddots \end{pmatrix},$$

pro nějake vhodně zvolené  $p > 0$  a  $q > 0$ , takové, že  $p + q = 1$ .

- Nájděte stacionární rozdělení pro daný Markovský řetězec.
- Využijte existenci stacionárního rozdelení ke klasifikaci stavů MŘ.

# Zhrnutí/opakování

- ❑ Homogénní Markovské řetězce s diskrétným časem  $n \in \mathbb{N}$  a nejvýše spočetnou množinou stavov  $\mathcal{S}$ ;
- ❑ Rozložitelnost a nerozložitelnost řetězce:
  - ❑ Konečné vs. nekonečná množina stavov;
  - ❑ Existence cesty: dosažitelnost stavů (stavy stejného typu);
  - ❑ Uzavřené podmnožiny stavů  $\Rightarrow$  rozložitelnost řetězce;
  - ❑ Počty a časy přechodu, návratu a vstupu do daného stavu;
- ❑ Klasifikace stavů v Markovském řetězci:
  - ❑ Přechodné stavy;
  - ❑ Trvalé nulové a trvalé nenulové stavy;
  - ❑ Neperiodické/periodické stavы (s periodou  $d > 1$ );
  - ❑ Absorbční stavы a ergodické stavы;
- ❑ Limitní a stacionární rozdělení Markovského řetězce
  - ❑ Limitní rozdělení - popisuje chování celého Markovského řetězce včetne počátečného rozdělení;
  - ❑ Stacionární rozdělení - vyjadruje určitou stabilitu řetězce vzhledem k pravdepodobnostem přechodu;

Kapitola 5

# Časové řady

# Nádodné procesy vs. časové řady

## □ Stochastický/náhodný proces

↪ posloupnost (reálných) náhodných veličín  $\{X_t; t \in T\}$  definovaných na stejném pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$ ;

## □ Časová řada (proces)

↪ stochastický proces indexovaný celočíselnou množinou  $T$  ( $T \equiv \mathbb{N}$ , nebo  $T \equiv \mathbb{Z}$ ) (resp. stochastický proces s diskrétnym časom);

□ v niektorých literárnych zdrojoch sa pod pojmom **časová řada** rozumí již nějaká konkrétní **realizace náhodného procesu**  $\{X_t; t \in T\}$ , t.j., posloupnosť konkrétních hodnot  $X_1, X_2, \dots$ , neboli  $x_1, x_2, \dots$ ;

# Bílý šum

**Definice:** Bílý šum

Posloupnost centrovaných a **nekorelovaných** náhodných veličín  $\{X_t; t \in T\}$  s kladným konečným rozptyлом se nazýva **bílý šum**.

**Definice:** Striktní bílý šum

Posloupnost **nezávislých, stejně rozdelených**, nedegenerovaných a centrovaných náhodných veličín  $\{X_t; t \in T\}$  se nazýva **striktní bílý šum**.

- v podstatě je bílý šum náhodný **signál s rovnoměrnou spektrální hustotou**; (*analógie s bílým světem, které obsahuje všechny ostatní frekvence*)

# Příklad: Bílý šum a striktní bílý šum

## Príklad

- ❑ posloupnost nezávislých náhodných veličín z rozdělení  $N(0, 1)$  je **bílý šum** a zároveň aj **striktní bílý šum** (obecně  $N(0, \sigma^2)$ );
  - ❑ posloupnost nezávislých náhodných veličín z rozdělení  $C(0, 1)$  je **striktní bílý šum**, ale není to **bílý šum** – neexistuje totiž ani střední hodnota, ani konečný rozptyl;
  - ❑ posloupnost nekorelovaných náhodných veličín z nějakého obecného rozdělení  $F$  je **bílý šum**, pokud jsou veličiny centrované (t.j. s nulovou střední hodnotou) a s konečným rozptylem; Pokud navíc je rozdělení  $F$  normální, pak se jedná o **striktní bílý šum**;
- 
- ❑ **Striktní bílý šum** a **bílý šum** jsou obecně časové řady s nejjednodušší závislostní struktúrou – nekorelované, neboli dokonce nezávislé. Zároveň v sobě nenesou žádnou informaci, jedna se pouze o náhodné chyby, stochastické fluktuace.

# Silná stacionarita

**Definice:** Silná stacionarita

Řekneme, že posloupnost náhodných veličín  $\{X_t; t \in T\}$  je **striktně stacionární** (resp. silně stacionární), pokud pro  $\ell \in \mathbb{N}$ , libovolné  $k_1, \dots, k_\ell \in T$  a každé  $h > 0$  takové, že  $k_1 + h, \dots, k_\ell + h \in T$  platí, že

$$\mathcal{L}(X_{k_1}, \dots, X_{k_\ell}) = \mathcal{L}(X_{k_1+h}, \dots, X_{k_\ell+h}).$$

- **Silná stacionarita** znamená, že libovolná  $\ell$ -tice náhodných veličích je stejně rozdělená v libovolném časovém okamžiku;
- Z definice samozřejmě plyne, že pro silně stacionární posloupnost  $\{X_t; t \in T\}$  jsou náhodné veličiny  $X_t$  **stejně rozdelené** pro všechny  $t \in T$ ;

# Slabá stacionarita

**Definice:** Slabá stacionarita

Řekneme, že posloupnost náhodných veličín  $\{X_t; t \in T\}$  je slabě stacionární, pokud platí:

- $EX_t = \mu$  pro všechna  $t \in T$  (t.j., nezávisí na  $t$ );
- $R(k) = E[(X_{t+k} - \mu)(X_t - \mu)]$  (t.j., nezávisí na  $t \in T$ );

- funkce  $R(k)$  se nazýva autokovarianční funkce posloupnosti;
- hodnota  $R(0) = E(X - \mu)^2$  je rozptyl posloupnosti (konstantní v čase);
- funkce  $r(k) = R(k)/R(0)$  se nazýva autokorelační funkce posloupnosti;
- samozřejmě platí, že  $R(k) = R(-k)$  pro libovolné  $k \in \mathbb{N}$ ;

# Příklad: Bílý šum a striktní bílý šum

## Príklad

- pokud má silně stacionární posloupnost konečné druhé momenty, pak je zřejmě slabě stacionární;
- pokud je posloupnost náhodných veličin gausovská (t.j. všechny konečně-rozměrná rozdělení jsou normální) a slabě stacionární, pak je také silně stacionární;
- striktní bílý šum je silně (striktně) stacionární (nezávislé a stejně rozdělené náhodné veličiny);
- bílý šum je obecně slabě stacionární (centrované a nekorelované náhodné veličiny);

# Klouzavé průměry řádu $q \in \mathbb{N}$

**Definice:**  $MA(q)$  proces

Nechť posloupnost  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum s konečným rozptylem  $\sigma^2 < \infty$ . Pak náhodnou posloupnost

$$X_t = a_0 \varepsilon_t + a_1 \varepsilon_{t-1} + \cdots + a_q \varepsilon_{t-q}, \quad \text{pro } t \in \mathbb{Z},$$

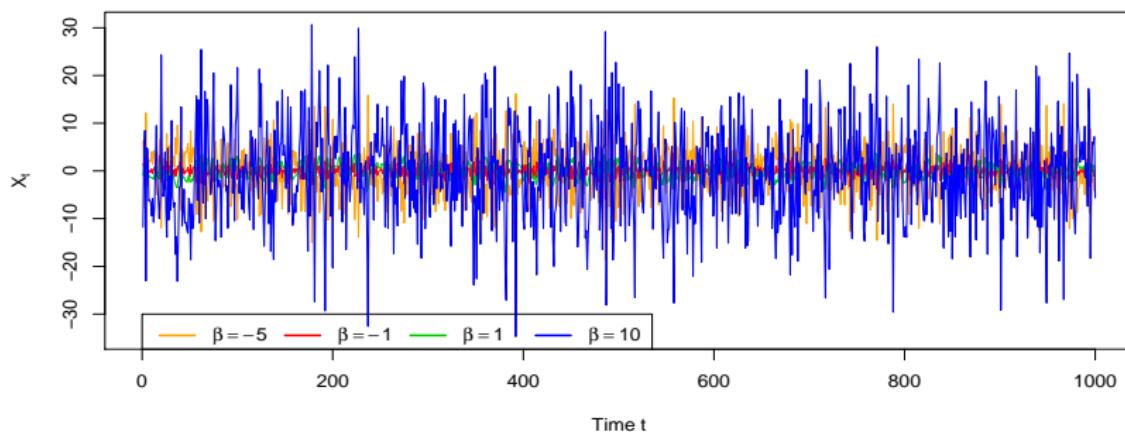
a pro nějaké koeficienty  $a_0, \dots, a_q \in \mathbb{R}$ , takové, že  $a_0 \neq 0 \neq a_q$ , nazývame posloupnost klouzavých průměrů řádu  $q$ .

- obecně majú  $MA(q)$  procesy složitejší korelační strukturu než bílý šum, avšak složky  $X_t$  a  $X_{t+k}$  jsou nekorelované pro  $k > q$ .

# Příklad: $MA(1)$ proces

## Príklad

- nechť  $X_t = \varepsilon_t + \beta\varepsilon_{t-1}$ , pro  $\{\varepsilon_t; t \in \mathbb{Z}\}$  bílý šum;
- Pro jaké hodnoty  $\beta \in \mathbb{R}$  je  $\{X_t; t \in \mathbb{Z}\}$  stacionární?
- Jak je definovaná autokovarianční a autokorelační funkce?



## Autoregresní model řádu $p \in \mathbb{N}$

Definice:  $AR(p)$  proces

Nechť posloupnost  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum s konečným rozptylem  $\sigma^2 < \infty$ . Pak náhodnou posloupnost

$$d_0 X_t + d_1 X_{t-1} + \cdots + d_p X_{t-p} = \varepsilon_t, \quad \text{pro } t \in \mathbb{Z}, \quad (11)$$

pro nějaké koeficienty  $d_0, \dots, d_p \in \mathbb{R}$ , takové, že  $d_0 \neq 0 \neq d_p$ , nazývame autoregresní posloupnost řádu  $p$ .

- Ekvivalentně lze model přepsát pomocí rovnice  
 $X_t = \tilde{d}_1 X_{t-1} + \cdots + \tilde{d}_p X_{t-p} + \tilde{\varepsilon}_t$ , kde  $\text{Var} \tilde{\varepsilon}_t = \frac{1}{d_0^2} \text{Var} \varepsilon_t$  a  $\tilde{d}_j = -d_j/d_0$ ;
- Obecně jsou pro týto modely **autokorelace nenulové** a jednotlivé složky se navzájem ovlivňují i když jsou libovolně daleko od sebe.
- Pokud je posloupnost stacionární, pak **závislost mezi složkami se vzrůstajícím rozdílem v čase nutně slabne**;

# Stacionarita autoregresní posloupnosti

## Věta: Stacionarita autoregresní posloupnosti

Nechť  $\{X_t; t \in \mathbb{Z}\}$  je autoregresní posloupnost  $p$ -tého řádu definovaný rovnicí (11) a nechť bez ujmy na obecnosti  $d_0 = 1$ . Nechť jsou všechny kořeny polynomu

$$d(z) = 1 + d_1 z + \dots + d_p z^p$$

vně jednotkového kruhu v komplexní rovině. Pak je proces  $\{X_t; t \in \mathbb{Z}\}$  slabě stacionární a náhodná veličina  $\varepsilon_t$  je nekorelovaná se všemi náhodnými veličinami  $X_{t-1}, X_{t-2}, \dots$

# Centrovanost a kauzálnost AR posloupnosti

- za platnosti podmínek předchozí věty je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  také **centrovaná**, protože ze slabé stacionarity také automaticky plyne, že

$$0 = E\varepsilon_t = d_0EX_t + \dots + d_pEX_{t-p} = \mu \left( \sum_{i=1}^p d_i \right),$$

a tudíž  $\mu = 0$ . Ak by  $\sum_{i=1}^p d_i = 0$ , pak by to znamenalo, že 1 je také kořenem polynomu  $d(z)$ , což je spor s předpokladem uvedené věty;

- za platnosti podmínek předchozí věty také platí, že posloupnost  $\{X_t; t \in \mathbb{Z}\}$  lze vyjádřit v **kauzálním tvare**, t.j. existuje vyjádření

$$X_t = \sum_{k=0}^{\infty} c_k \varepsilon_{t-k},$$

kde koeficienty  $c_k$  jsou určeny vztahem  $c(z) = \sum_{k=0}^{\infty} c_k z^k = \frac{1}{d(z)}$ , pro  $|z| \leq 1$ .

## Příklad: AR(1) proces

### Príklad

- nechť  $X_t = aX_{t-1} + \varepsilon_t$ , pro  $\{\varepsilon_t; t \in \mathbb{Z}\}$  bílý šum;
- polynom  $d(z) = 1 - az$  má kořen v bodě  $z = 1/a$ ;
- kořen je vně jednotkového kruhu  $\Leftrightarrow |a| < 1$ ;
- potom platí, že

$$X_t = aX_{t-1} + \varepsilon_t = a(aX_{t-2} + \varepsilon_{t-1}) + \varepsilon_t = \dots = a^k X_{t-k} + \sum_{\ell=0}^{k-1} a^\ell \varepsilon_{t-\ell};$$

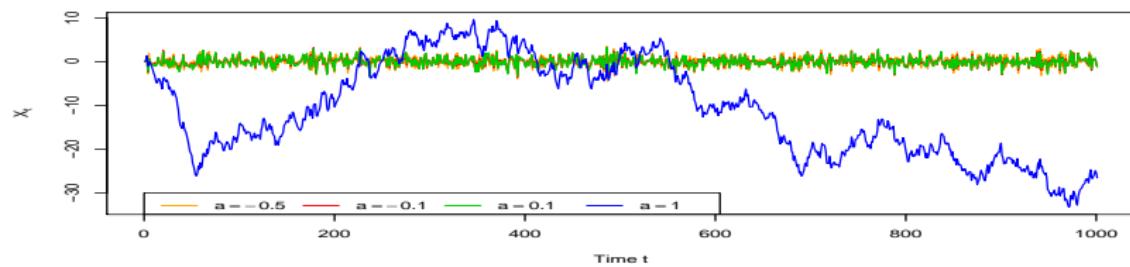
- a náhodnú veličinu  $X_t$  lze (limitním přechodem) vyjádřit kauzálně jako

$$X_t = \sum_{k=0}^{\infty} a^k \varepsilon_{t-k}$$

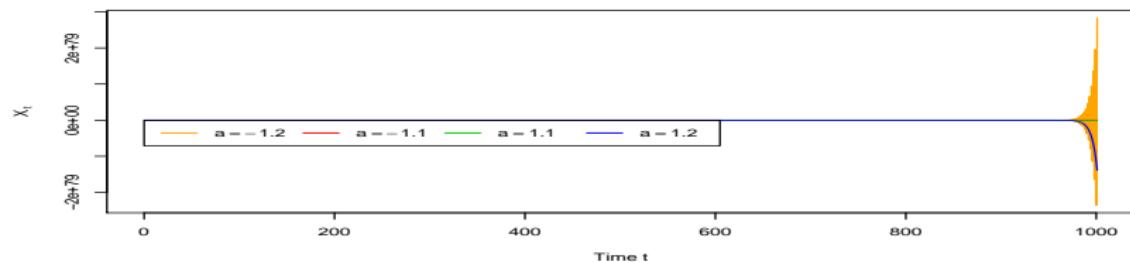
(t.j. lineární kombinaci minulosti posloupnosti  $\{\varepsilon_t; t \in \mathbb{Z}\}$ )

## Příklad: $AR(1)$ proces

- pro parametr  $|a| \leq 1$



- pro parametr  $|a| > 1$



## Příklad: AR(1) proces

- Rozptyl procesu lze spočítat i pomocí soustavy rovnic:

$$EX_t X_{t-1} = aEX_{t-1}^2 + E\varepsilon_t X_{t-1}$$

$$EX_t \varepsilon_t = aEX_{t-1} \varepsilon_t + E\varepsilon_t^2$$

- pak kůli nekorelovanosti  $\varepsilon_t$  a  $X_{t-1}$  máme  $EX_{t-1} \varepsilon_t = 0$  a tudíž

$$\begin{aligned}\sigma^2 &= E\varepsilon_t^2 = EX_t \varepsilon_t = EX_t(X_t - aX_{t-1}) = R(0) - aR(1) \\ &= R(0)[1 - ar(1)]\end{aligned}$$

- z první rovnice pak dostaneme

$$R(1) = aR(0) \Leftrightarrow a = R(1)/R(0) = r(1)$$

- pro rozptyl  $R(0)$  procesu  $\{X_t; t \in \mathbb{Z}\}$  dostaneme

$$R(0) = \frac{\sigma^2}{1 - a^2} = \frac{\sigma^2}{1 - (r(1))^2};$$

## Yule-Walkerovy rovnice

Za předpokladu, že  $\varepsilon_t$  je nekorelované s  $X_{t-1}, X_{t-2}, X_{t-3} \dots$

(vid' také předchozí věta o stacionaritě autoregresní posloupnosti), lze analogicky postup aplikovat i pro obecný autoregresní proces řádu  $p$ ;

- uvažujme obecný autoregresní proces

$$X_t = a_1 X_{t-1} + \dots + a_p X_{t-p} + \varepsilon_t \quad (12)$$

- rovnici autoregresného procesu vynásobíme postupně veličinami  $X_{t-1}, X_{t-2}, \dots, X_{t-p}$  a aplikujeme operátor stredné hodnoty:

$$E X_t X_{t-1} = a_1 E X_{t-1}^2 + \dots + a_p E X_{t-p} X_{t-1} + E \varepsilon_t X_{t-1}$$

$$E X_t X_{t-2} = a_1 E X_{t-1} X_{t-2} + \dots + a_p E X_{t-p} X_{t-2} + E \varepsilon_t X_{t-2}$$

.....

$$E X_t X_{t-p} = a_1 E X_{t-1} X_{t-p} + \dots + a_p E X_{t-p}^2 + E \varepsilon_t X_{t-p}$$

## Yule-Walkerovy rovnice

- soustavu rovníc lze ekvivalentně přepsát v maticovém tvaru

$$\begin{pmatrix} R(0) & \dots & R(p-1) \\ \dots & \dots & \dots \\ R(p-1) & \dots & R(0) \end{pmatrix} \begin{pmatrix} a_1 \\ \vdots \\ a_p \end{pmatrix} = \begin{pmatrix} R(1) \\ \vdots \\ R(p) \end{pmatrix}$$

- neboli také pomocí autokorelační funkce  $r(\cdot)$  jako

$$\begin{pmatrix} r(0) & \dots & r(p-1) \\ \dots & \dots & \dots \\ r(p-1) & \dots & r(0) \end{pmatrix} \begin{pmatrix} a_1 \\ \vdots \\ a_p \end{pmatrix} = \begin{pmatrix} r(1) \\ \vdots \\ r(p) \end{pmatrix}$$

- pomocí této soustavy lze spočítat hodnoty autokorelační funkce v časech  $1, 2, \dots, p$ . Pro hodnoty  $r(k)$ , kde  $k > p$  lze využít diferenční rovnici

$$r(k) - a_1 r(k-1) - \dots - a_p r(k-p) = 0,$$

kterú získame vynásobením rovnice (12) veličinou  $X_{t-k}$  a aplikovaním operátoru střední hodnoty;

## Výpočet rozptylu pro $AR(p)$

- pro výpočet rozptylu  $R(0)$  stačí vynásobit rovnici (12) veličinou  $\varepsilon_t$  a opět aplikovat operátor střední hodnoty;
- přímočaře dostaneme vyjádření

$$\begin{aligned}\sigma^2 &= E\varepsilon_t^2 = EX_t\varepsilon_t = EX_t(X_t - a_1X_{t-1} - \dots - a_pX_{t-p}) \\ &= R(0)[1 - a_1r(1) - \dots - a_pr(p)];\end{aligned}$$

- pro rozptyl  $AR(p)$  procesu teda platí, že

$$Var X_t = R(0) = \frac{\sigma^2}{1 - a_1r(1) - \dots - a_pr(p)};$$

# AR(2) Príklad

## Príklad

Nechť posloupnost  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum s jednotkovým rozptylem,  $\sigma^2 = 1$ . Definujme AR(2) proces jako

$$X_t - 0.5X_{t-1} + 0.06X_{t-2} = \varepsilon_t.$$

- Spočtěte střední hodnotu a rozptyl;
- Určete, zda je proces  $\{X_t; t \in \mathbb{Z}\}$  stacionární;
- Pomoci Yule-Walkerových rovnic spočítejte autokorelační funkci;

## Odhad neznámých parametrů

- Yule-Walkerove rovnice lze aplikovat i obráceným způsobem: použít data z procesu a **odhadnout neznáme parametry  $a_1, \dots, a_p$**  v  $AR(p)$  procesu;
- pomocí dat (konkrétní realizace procesu  $\{X_t; t \in \mathbb{Z}\}$ ) lze **odhadnout hodnoty autokovarianční funkce  $\widehat{R}(0), \dots, \widehat{R}(p)$** ;
- hodnoty odhadov autokovarianční funkce v daných bodech **dosadit do Yule-Walkerových rovníc** a řešit pro neznáme parametry  $a_1, \dots, a_p$ ;
- otázka pouze zůstava, jak správně nebo vhodně určit příslušný řád autokovariančního procesu, parametr  $p \in \mathbb{N}$ ;  
*(existují různa kritéria, tzv. "rules-of-thumb", nebo lze použít tzv. "expert judgement", nebo hlubší statistickou analýzu a formální statistické testy)*

# Konzistence odhadu parametrů

**Věta:** Konzistence odhadu parametrů v  $AR(p)$  procesu

Nechť  $\{X_t; t \in \mathbb{Z}\}$  je autoregresní posloupnost řádu  $p \in \mathbb{N}$  generovaná modelem

$$X_t = a_1 X_{t-1} + \cdots + a_p X_{t-p} + \varepsilon_t,$$

kde  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je posloupnost nezávislých, stejně rozdělených n.v. se střední hodnotou nula a konečným rozptylem  $\sigma^2 < \infty$ . Nechť všechny kořeny polynomu  $d(z) = 1 - a_1 z - \dots - a_p z^p$  leží vně jednotkového kruhu v komplexní rovině. Nechť  $\hat{\mathbf{a}}_n$  je odhad parametrů  $\mathbf{a} = (a_1, \dots, a_p)^\top$  pomocí Yule-Walkerových rovníc, založený na pozorováních  $X_1, \dots, X_n$  a odhadech  $\hat{R}(k)$  a  $\hat{r}(k)$ , pro  $k \geq 0$ . Pak platí, že

$$\sqrt{n}(\hat{\mathbf{a}}_n - \mathbf{a}) \xrightarrow{\mathcal{D}} N_p(\mathbf{0}, \sigma^2 \Gamma^{-1}),$$

kde  $\Gamma = (R(i-j))_{ij}$ .

# Asymptotické rozdelení odhadů parametrů

- ❑ konvergence  $\xrightarrow{\mathcal{D}}$  v předchozí větě značí konvergenci v distribuci;
- ❑ ekvivalentně je možné také napsat, že platí

$$\sup_{\mathbf{x} \in \mathbb{R}^p} |P(\sqrt{n}(\hat{a}_1 - a_1) \leq x_1, \dots, \sqrt{n}(\hat{a}_p - a_p) \leq x_p) - F(x_1, \dots, x_p)| \rightarrow 0,$$

pro  $n \rightarrow \infty$ , kde  $F : \mathbb{R}^p \rightarrow [0, 1]$  značí združenú distribuční funkci mnohorozměrného normálního rozdělení  $N_p(\mathbf{0}, \sigma^2 \Gamma^{-1})$ ;

- ❑ hustota mnohorozměrného normálního rozdělení  $N_p(\mu, \Sigma)$  je definováná:

$$f(x_1, \dots, x_p) = \frac{1}{(2\pi)^{\frac{p}{2}} |\Sigma|^{\frac{1}{2}}} \exp \left\{ -\frac{1}{2} (\mathbf{x} - \boldsymbol{\mu})^\top \boldsymbol{\Sigma}^{-1} (\mathbf{x} - \boldsymbol{\mu}) \right\},$$

pro  $\mathbf{x} = (x_1, \dots, x_p)^\top \in \mathbb{R}^p$ , kde  $\boldsymbol{\mu} = (\mu_1, \dots, \mu_p)^\top \in \mathbb{R}^p$  je vektor středních hodnot a  $\boldsymbol{\Sigma}$  pozitivně definitná, symetrická varianční matice;

# Odhad autokovarianční/autokorelační funkce

- máme k dispozici konkrétní realizaci časové řady  $\{X_t; t \in \mathbb{Z}\}$  až do nějakého času  $n \in \mathbb{N}$  (např. posloupnost  $\{x_i; i = 1, \dots, n\}$ );
- to znamená, že máme k dispozici pozorované hodnoty (realizace) náhodných veličin  $X_n, X_{n-1}, \dots, X_1$ ;
- dále také předpokládame, že proces  $\{X_t; t \in \mathbb{Z}\}$  je generovaný rovnicí

$$X_t = a_1 X_{t-1} + \dots + a_p X_{t-p} + \varepsilon_t;$$

(je nutné si uvědomit, že hodnota/dimenze  $p \in \mathbb{N}$  je (nějak) daná)

- parametre  $a_1, \dots, a_p \in \mathbb{R}$  (resp.  $\mathbf{a} \in \mathbb{R}^p$ ) jsou neznáme;
- **Jak pomocí empirických dat odhadnout parametry  $\mathbf{a} = (a_1, \dots, a_p)^\top$ ?**

# Odhad autokovarianční/autokorelační funkce

- v praktických prípadoch je k dispozici pouze konečná história (realizace) časové řady  $\{X_t; t \in \mathbb{Z}\}$ , t.j., pozorování  $X_1, \dots, X_n$  (nebo  $x_1, \dots, x_n$ );
- odhad autokovarianční funkce  $R(k)$  pro libovolné  $k \in \{0, n - 1\}$  získame pomocí vztahu

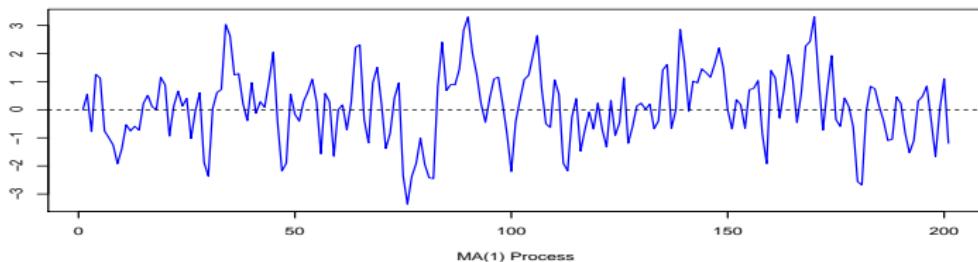
$$\widehat{R}(k) = \frac{1}{n-k} \sum_{i=1}^{n-k} \left( X_{i+k} - \frac{1}{n-k} \sum_{j=1}^{n-k} X_{j+k} \right) \left( X_i - \frac{1}{n-k} \sum_{j=1}^{n-k} X_j \right)$$

- odhad príslušné autokorelační funkce  $r(k)$  pro libovolné  $k \in \{0, n - 1\}$  pak získame jako

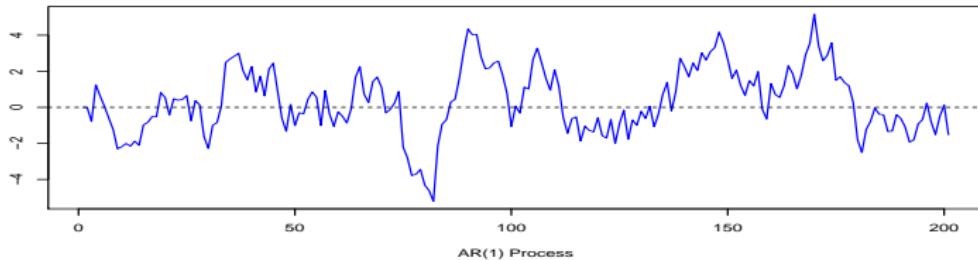
$$\widehat{r}(k) = \frac{\widehat{R}(k)}{\widehat{R}(0)}.$$

## Simulace: MA & AR proces prvého řádu

- **MA(1):**  $X_t = 0.8\epsilon_{t-1} + \epsilon_t \quad | \quad \epsilon_t \sim N(0, 1)$

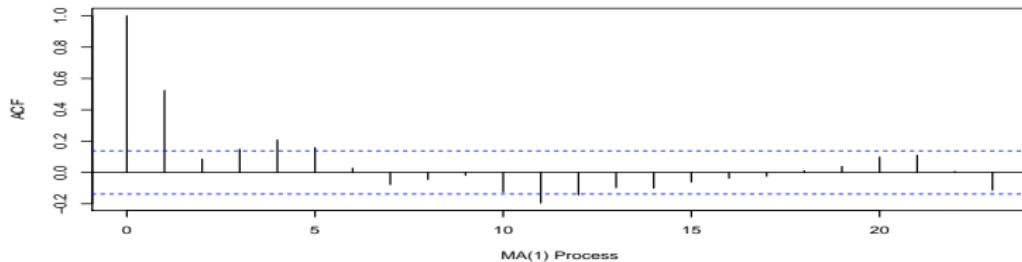


- **AR(1):**  $X_t = 0.8X_{t-1} + \epsilon_t \quad | \quad \epsilon_t \sim N(0, 1)$ :

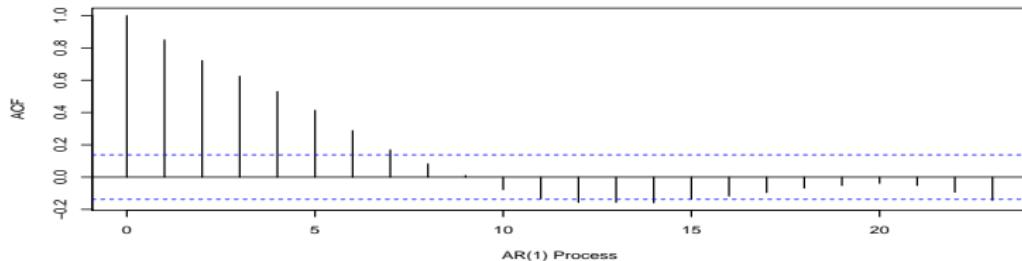


## Simulace: Autokorelačná funkce

- **MA(1):**  $X_t = 0.8\varepsilon_{t-1} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$

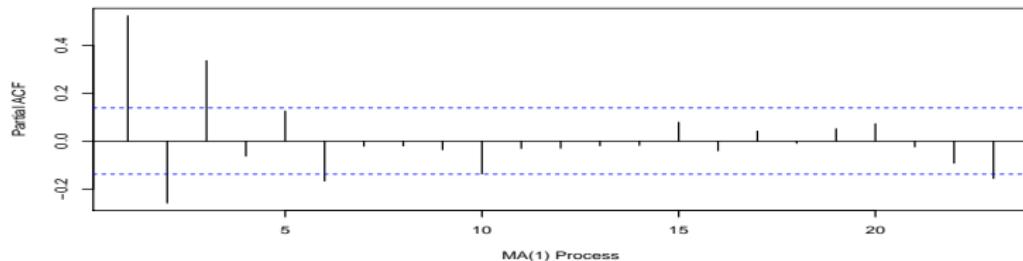


- **AR(1):**  $X_t = 0.8X_{t-1} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$ :

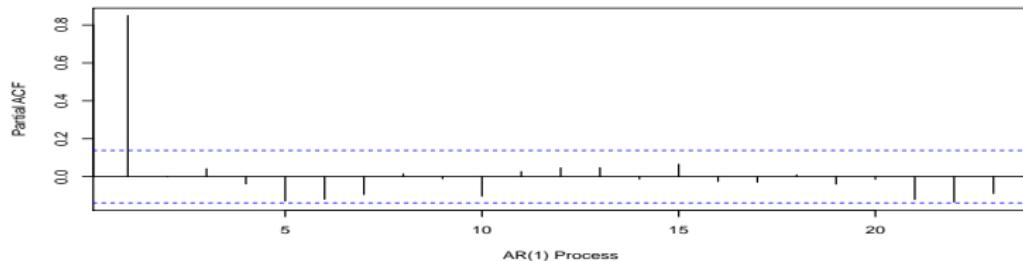


## Simulace: Parciální autokorelačná funkce

- **MA(1):**  $X_t = 0.8\varepsilon_{t-1} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$

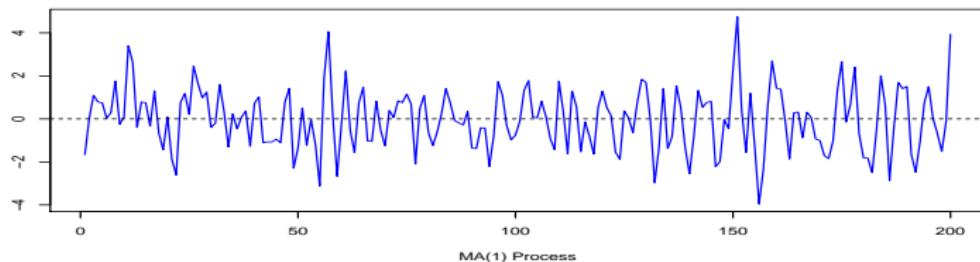


- **AR(1):**  $X_t = 0.8X_{t-1} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$ :

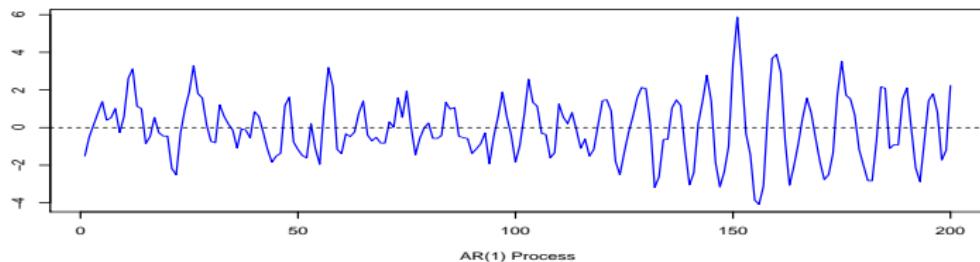


## Simulace: MA & AR proces třetího řádu

- **MA(3):**  $X_t = 0.8\epsilon_{t-1} - 0.4\epsilon_{t-2} - 0.2\epsilon_{t-3} + \epsilon_t \quad | \quad \epsilon_t \sim N(0, 1)$

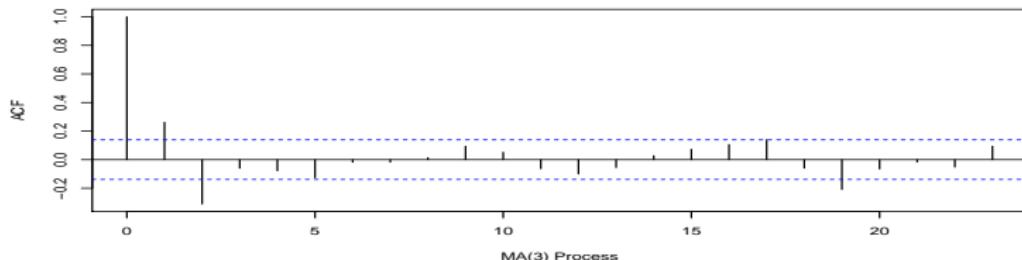


- **AR(3):**  $X_t = 0.8X_{t-1} - 0.4X_{t-2} - 0.2X_{t-3} + \epsilon_t \quad | \quad \epsilon_t \sim N(0, 1)$ :

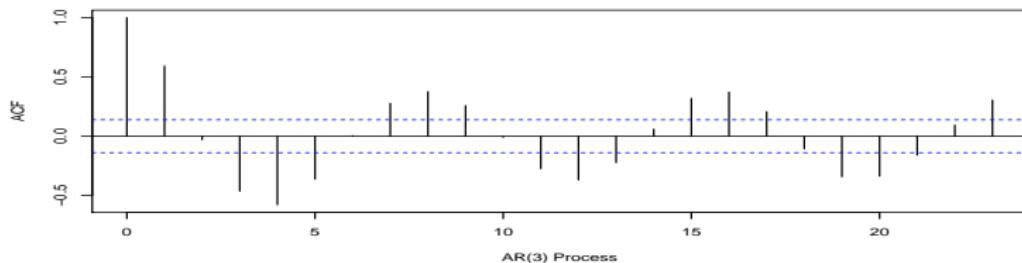


## Simulace: Autokorelačná funkce

- **MA(3):**  $X_t = 0.8\varepsilon_{t-1} - 0.4\varepsilon_{t-2} - 0.2\varepsilon_{t-3} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$

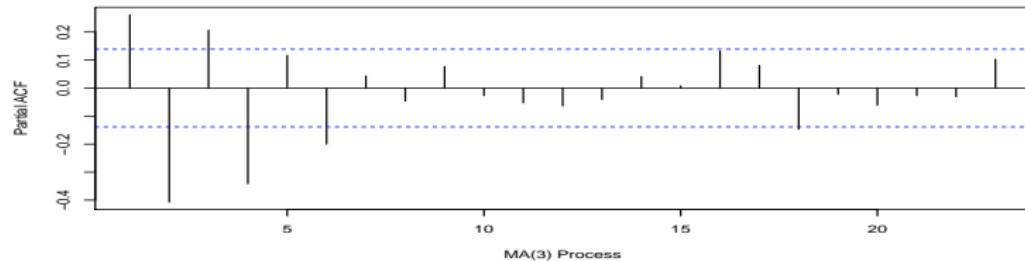


- **AR(3):**  $X_t = 0.8X_{t-1} - 0.4X_{t-2} - 0.2X_{t-3} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$ :

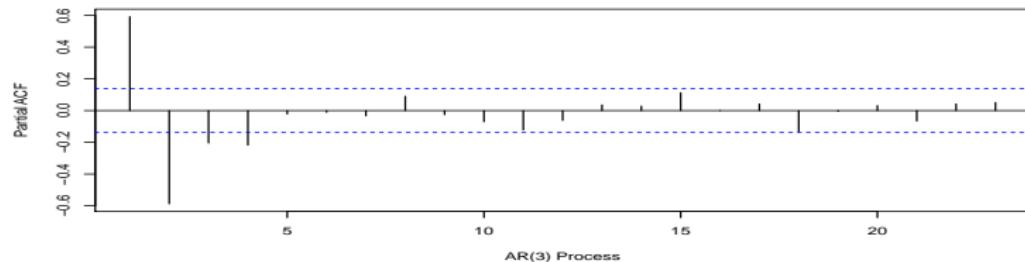


## Simulace: Parciální autokorelačná funkce

- MA(3):  $X_t = 0.8\varepsilon_{t-1} - 0.4\varepsilon_{t-2} - 0.2\varepsilon_{t-3} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$



- AR(3):  $X_t = 0.8X_{t-1} - 0.4X_{t-2} - 0.2X_{t-3} + \varepsilon_t \quad | \quad \varepsilon_t \sim N(0, 1)$ :



## Neúplnost odhadů $\widehat{R}(k)$ a $\widehat{r}(k)$

- odhad autokovarianční funkce  $R(k)$  nějaké posloupnosti se nazýva **výběrová autokovarianční funkce** – používame značení  $\widehat{R}(k)$ ;
- odhad autokorelační funkce  $r(k)$  nějaké posloupnosti se nazýva **výběrová autokorelační funkce** – používame značení  $\widehat{r}(k)$ ;
- pro necentrovanou posloupnost  $\{X_t; t \in \{1, \dots, n\}\}$  odhadujeme střední hodnotu  $\mu \in \mathbb{R}$  pomocí **výběrové střední hodnoty** definované

$$\widehat{\mu} = \frac{1}{n} \sum_{i=1}^n X_i;$$

- **výberová autokovariační/autokorelační funkce** spočetená na základě realizace  $X_1, \dots, X_n$  poskytuje **pouze omezenou informaci** o celkové kovarianční/korelační struktúře posloupnosti;
- na základě realizace  $X_1, \dots, X_n$  totíž logicky není možné spočítat hodnoty pro  $\widehat{R}(k)$  a  $\widehat{r}(k)$ , kde  $k \geq n$ ;

# Zhrnutí/opakování

- Stochastické procesy—časové řady—typu *MA* a *AR* ;
  - *MA*( $q$ ) – kĺzavé priemery, resp. tzv “moving averages” rádu  $q \in \mathbb{N}$ ;
  - *AR*( $p$ ) – postupnosť autoregresného typu s využitím histórie dĺžky  $p \in \mathbb{N}$ ;
- Obojsmerné využitie Yule-Walkerových rovníc;
  - Teoretické: charakterizácia modelu—autokovariancia/autokorelácia;
  - Empirické: odhad neznámych parametrov v predpokladanom modeli;
- Identifikácia správneho modelu na základe realizácie
  - autokovariančná/autokorelačná funkcia (resp. príslušné odhady);
  - parciálna autokovariančná/autokorelačná funkcia;
- Neúplnosť odhadnutej variančnej/kovariančnej štruktúry
  - nenulová autokovariančná štruktúra u MA procesov definovaná pouze pro  $k \leq q$ , kde  $q \in \mathbb{N}$  je zadaný rád MA postupnosti;
  - nenulová autokovariančná štruktúra u AR procesov obecně pre  $\forall k \in \mathbb{N}$ , ale odhadnuteľná je pouze pro zadaný rád  $p \in \mathbb{N}$ , t.j., pre  $k \leq p$ ;

# Modely typu $ARMA(p, q)$

- posloupnosti klouzavých průměrů a autoregresních posloupností lze vzájemně kombinovat do tzv.  $ARMA$  modelů;

**Definice:**  $ARMA(p, q)$  proces

Nechť posloupnost  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum s konečným rozptylem  $\sigma^2 < \infty$ . Pak náhodnou posloupnost  $\{X_t; t \in \mathbb{Z}\}$  splňujúcu

$$d_0 X_t + d_1 X_{t-1} + \cdots + d_p X_{t-p} = a_0 \varepsilon_t + \cdots + a_q \varepsilon_{t-q}, \quad (13)$$

pro  $t \in \mathbb{Z}$  a nějaké koeficienty  $d_0, \dots, d_p, a_0, \dots, a_q \in \mathbb{R}$ , takové, že  $d_0, d_p, a_0, a_q \neq 0$ , nazývame  $ARMA(p, q)$  model.

- podobně jako v předchozích případech nás zajíma, za akých předpokladů bude  $ARMA(p, q)$  posloupnost splňovat definici stacionarity (slabě);
- ekvivaletní zápis  $ARMA(p, q)$  modelu lze vyjádřit pomocí vztahu

$$X_t = \tilde{d}_1 X_{t-1} + \cdots + \tilde{d}_p X_{t-p} + \tilde{a}_0 \varepsilon_t + \cdots + \tilde{a}_q \varepsilon_{t-q};$$

## Stacionarita $ARMA(p, q)$ procesů

- předpokládejme, že v rovnici (13) je  $d_0 = a_0 = 1$  a definujeme polynomy

$$d(z) = 1 + d_1 z + \cdots + d_p z^p, \quad n(z) = 1 + a_1 z + \cdots + a_q z^q; \quad (14)$$

**Věta:** Stacionarita  $ARMA(p, q)$  modelů

Nechť všechny kořeny polynomu  $d(z)$  leží vně jednotkového kruhu v komplexní rovině a navíc, nechť jsou polynomy  $d(z)$  a  $n(z)$  ne-soudělné, t.j. nemají společné kořeny. Pak je posloupnost definovaná rovnici (13) slabě stacionární, s nulovou střední hodnotou, a navíc, lze proces  $\{X_t; t \in \mathbb{Z}\}$  vyjádřit v kauzálním tvaru, t.j.

$$X_t = \sum_{k=0}^{\infty} c_k \varepsilon_{t-k},$$

kde  $\{c_k\}_{k=0}^{\infty}$  jsou určený vztahem  $c(z) = \sum_{k=0}^{\infty} c_k z^k = \frac{n(z)}{d(z)}$ ,  
pro  $|z| \leq 1$ .

# Autokovariance/autokorelace ARMA procesů

- pokud by polynomy  $d(z)$  a  $n(z)$  měly společné kořeny, potom by polynom  $c(z) = n(z)/d(z)$  určoval ARMA( $m, n$ ) proces, pro  $m < p$  a  $n < q$ ;
- autokovarianční funkce stejně tak jako autokorelační funkce obecného ARMA( $p, q$ ) procesu se spočte analogicky, jako v případě AR( $p$ ) procesů, pomocí Yule-Walkerových rovníc.

## Samostatný úkol

Uvažujte obecný ARMA(1, 1) proces, definovaný předpisem

$$X_t + aX_{t-1} = \varepsilon_t + b\varepsilon_{t-1},$$

pro  $t \in \mathbb{Z}$ , kde  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum.

- definujte podmínky pro které je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  slabě stacionární;
- nájděte autokovarianční a autokorelační funkci posloupnosti  $\{X_t; t \in \mathbb{Z}\}$ ;
- pokud existuje, nájděte kauzální vyjádření procesu  $\{X_t; t \in \mathbb{Z}\}$ ;

# Lineární filtrace

**Definice:** Lineární filtrace/Linerní filtr

Nechť  $\{\varepsilon; t \in \mathbb{Z}\}$  je centrovaná, slabě stacionární posloupnost a  $\{\xi_k; k \in \mathbb{Z}\}$  je posloupnost koeficientů takových, že  $\sum_{k \in \mathbb{Z}} |\xi_k| < \infty$ . Pak řekneme, že posloupnost

$$X_t = \sum_{k=-\infty}^{\infty} \xi_k \varepsilon_{t-k}$$

vznikla **lineární filtraci** z posloupnosti  $\{\varepsilon; t \in \mathbb{Z}\}$ .

Posloupnost koeficientů  $\{\xi_k; k \in \mathbb{Z}\}$  se nazýva **lineární filtr**.

**Definice:** Kauzální filtr

Nechť  $\{\xi_k; k \in \mathbb{Z}\}$  je lineární filtr. Pokud platí, že  $\xi_k = 0$  pro  $k < 0$ , pak je filtr **kauzální**, t.j. fyzikálně uskutečnitelný.

# Lineární modely, procesy, systémy...

**Definice:** Lineární proces

Náhodnou posloupnost  $\{X_t; t \in \mathbb{Z}\}$  nazývame **lineárním procesem**, pokud existuje posloupnost nezávislých, stejně rozdělených náhodných veličín  $\varepsilon_t$ , pro  $t \in \mathbb{Z}$ , s nulovou střední hodnotou a konečným rozptylem a lineární filtr  $\{\xi_k; k \in \mathbb{Z}\}$  takový, že

$$X_t = \sum_{k=-\infty}^{\infty} \xi_k \varepsilon_{t-k}.$$

Lineární proces je navíc kauzální, pokud je příslušný filtr kauzální.

- **ARMA( $p, q$ ) model je ekvivalentní s obecnou rovnici lineárního systému** (vid' Kapitola 3). Rovnice ARMA modelu ale určuje vztah nikoli mezi nenáhodnými (deterministickými) posloupnostmi vstupů a výstupu, ale mezi náhodnými posloupnostmi bílého šumu a ARMA procesem  $\{X_t; t \in \mathbb{Z}\}$ .

# Invertibilita ARMA posloupnosti

**Definice:** Invertibilita ARMA posloupnosti

Stacionární ARMA( $p, q$ ) posloupnost  $\{X_t; t \in \mathbb{Z}\}$  vzniklá z bílého šumu  $\{\varepsilon_t; t \in \mathbb{Z}\}$ , se nazýva **invertibilní**, jestliže existuje posloupnost konstant  $\{\psi_k; k \in \mathbb{Z}\}$  taková, že  $\sum_{k=0}^{\infty} |\psi_k| < \infty$  a platí, že

$$\varepsilon_t = \sum_{k=0}^{\infty} \psi_k X_{t-k}.$$

- z pohledu posloupnosti  $\{\varepsilon_t; t \in \mathbb{Z}\}$  by se dalo říct, že se jedná o kauzální posloupnost vzhledem k posloupnosti  $\{X_t; t \in \mathbb{Z}\}$ ;

# Příklad: Striktná verzus slabá stacionarita

## Samostatný úkol

Nechť je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  definovaná předpisem

$$X_t = \rho X_{t-1} + \varepsilon_t,$$

pro  $|\rho| < 1$  a posloupnost  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je daná předpisem

$$\varepsilon_t = \begin{cases} Z_t & t = 2k, k \in \mathbb{Z}, \\ \frac{1}{\sqrt{2}}(Z_t^2 - 1) & t = 2k + 1, k \in \mathbb{Z}, \end{cases}$$

kde  $\{Z_t; t \in \mathbb{Z}\}$  je posloupnost nezávislých, stejně rozdělených náhodných veličín s normovaným normálním rozdělením  $N(0, 1)$ .

- Rozhodněte, zda je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  striktně stacionární.
- Rozhodněte, zda je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  slabě stacionární.
- Spočtěte autokovarianční funkci posloupnosti  $\{X_t; t \in \mathbb{Z}\}$ .

# Invertibilita ARMA posloupnosti

**Věta:** Invertibilita ARMA procesů

Nechť  $\{X_t; t \in \mathbb{Z}\}$  je stacionární ARMA( $p, q$ ) posloupnost, definovaná rovnici (13), pro  $d_0 = a_1 = 1$ . Nechť polynomy  $d(z)$  a  $n(z)$  definovány vztahy (14) nemají společné kořeny a navíc, nechť kořeny polynomu  $n(z)$  leží vně jednotkového komplexního kruhu. Pak je posloupnost  $\{X_t; t \in \mathbb{Z}\}$  **invertibilní** a lze psát

$$\varepsilon_t = \sum_{k=0}^{\infty} \psi_k X_{t-k},$$

pro  $k \in \mathbb{Z}$ , kde koeficienty  $\psi_k$  jsou určený vztahem

$$\Psi(z) = \sum_{k=0}^{\infty} \psi_k z^k = \frac{d(z)}{n(z)},$$

pro  $|z| \leq 1$ .

# Lineární predikce v časových řadách

- pomerně častý praktický problém v časových řadách je **predikce**;
- predikce/předpověď budoucích hodnot na základě pozorované realizace;
- z teoretického hlediska se jedná o pomerně náročnou úlohu, která vede na podmíněné střední hodnoty...
- **Jak to ale funguje v praxi?**

# Lineární predikce v časových řadách

- pomerně častý praktický problém v časových řadách je **predikce**;
  - predikce/předpověď budoucích hodnot na základě pozorované realizace;
  - z teoretického hlediska se jedná o pomerně náročnou úlohu, která vede na podmíněné střední hodnoty...
  - **Jak to ale funguje v praxi?**
- 
- **Jednoduchý příklad:** predikce pozorování  $X_{t+1}$  na základě realizace  $X_t$  (predpověď o jeden krok dopředu na základě jediného pozorování);
  - požadovaná predikce pro  $X_{t+1}$  je lineární, t.j.  $\hat{X}_{t+1} = a + bX_t$ ;
  - navíc předpokládame, že  $\{X_t; t \in \mathbb{Z}\}$  je slabě stacionární;
  - kvalita predikce pomoci **střední kvadratické chyby mezi  $X_{t+1}$  a  $\hat{X}_{t+1}$** ; (*chceme minimalizovat střední kvadratickou chybu  $E[X_{t+1} - \hat{X}_{t+1}]^2$* )

## Predikce $X_{t+1}$ formálně

- z formálneho/matematického hlediska teda řešíme minimalizační problém

$$\min_{a,b \in \mathbb{R}} E [X_{t+1} - (a + bX_t)]^2 = \min_{\tilde{a},b \in \mathbb{R}} E [X_{t+1} - \mu - \tilde{a} - b(X_t - \mu)]^2,$$

kde  $\tilde{a} = a + \mu(b - 1)$ ;

- derivováním podle  $\tilde{a}$  a  $b$  (a formálna záměna integrálu a derivace):

$$\frac{\partial}{\partial \tilde{a}} : -2E [X_{t+1} - \mu - \tilde{a} - b(X_t - \mu)] = 0$$

$$\frac{\partial}{\partial b} : -2E [X_{t+1} - \mu - \tilde{a} - b(X_t - \mu)] (X_t - \mu) = 0$$

- z první rovnice dostaneme okamžitě, že  $\tilde{a} = 0$ ;
- z druhé rovnice pak dostaneme, že

$$b = \frac{R(1)}{R(0)} = r(1);$$

- Predikce:  $\hat{X}_{t+1} = a + bX_t = \mu + b(X_t - \mu) = \mu + r(1)(X_t - \mu)$ ;

## Predikce $X_{t+1}$ formálně

- ❑ kvalita predikce sa obecně posuzuje pomocí střední kvadratické chyby/odchýlky, t.j.

$$\begin{aligned}MSE &= E(X_{t+1} - \hat{X}_{t+1})^2 = E [X_{t+1} - \mu - r(1)(X_t - \mu)]^2 \\&= R(0) [1 + r(1)^2 - 2r(1)^2] = R(0)(1 - r(1)^2);\end{aligned}$$

- ❑ čím silnější je lineární závislost mezi  $X_t$  a  $X_{t+1}$ , tím menší je chyba predikce (t.j., přesnější předpověď);
- ❑ obecně lze postup zobecnit na úlohu najít predikci pro  $X_{t+1}$ , na základě pozorování  $X_t, X_{t-1}, \dots, X_{t-p}$ ;
- ❑ následně je samozřejmě možné použít predikci  $\hat{X}_{t+1}$  a spočít další predikci pro nasledující krok  $X_{t+2}$ ;

# Příklad: predikce na základě $X_t$ a $X_{t-1}$

## Samostatný úkol

Předpokládejme, že posloupnost  $\{X_t; t \in \mathbb{Z}\}$  je slabě stacionární.

- spočtěte obecný vztah pro predikci pozorování  $X_{t+1}$  na základě hodnot  $X_t$  a  $X_{t-1}$ ;
- jako kritérium kvality predikce použijte střední kvadratickú chybu/odchýlku;

## Samostatný úkol

- Uvažujte model  $ARMA(2, 1)$  daný předpisem

$$X_t - 0.5X_{t-1} + 0.04X_{t-2} = \varepsilon_t + 0.25\varepsilon_{t-1},$$

pro  $\{\varepsilon_t; t \in \mathbb{Z}\}$  bílý šum. Nájděte autokovarianční a autokorelační funkci procesu a jeho kauzální vyjádření.

# Kauzalita a invertibilita ARMA procesů

## Samostatný úkol

Nechť  $\{X_t; t \in \mathbb{Z}\}$  je ARMA(2, 1) posloupnost definovaná rovnicí

$$X_t - (a + b)X_{t-1} + abX_{t-2} = \varepsilon_t - a\varepsilon_{t-1},$$

kde  $\{\varepsilon_t; t \in \mathbb{Z}\}$  je bílý šum. Diskutujte podmínky kauzality a invertibility vzhledem k neznámym parametrům  $a, b \in \mathbb{R}$ .

Spočtěte autokovarianční a autokorelační funkci posloupnosti  $\{X_t; t \in \mathbb{Z}\}$ .

# Zhrnutí/opakování

- ❑ Lineárni (stochastické) modely časových řad: *MA, AR a ARMA procesy; (náhodné procesy vytvořené z bílého šumu, indexovaný nejvýše spočetnou množinou indexů  $T$  - napr. množinou celých čísel  $\mathbb{Z}$ )*
- ❑ Základná charakterizace procesů:
  - ❑ střední hodnota procesu  $\{X_t; t \in \mathbb{Z}\}$ :  $\mu_t = EX_t$ ;
  - ❑ rozptyl procesu  $\{X_t; t \in \mathbb{Z}\}$ :  $\sigma^2(t) \equiv R(0, t)$ ;
  - ❑ autokovarianční a autokorelační funkce  $R(k, t)$  a  $r(k, t)$ ;
- ❑ Další vlastnosti modelů časových řad:
  - ❑ silná (striktní) a slabá stacionarita ( $\mu, \sigma^2, R(k), r(k)$ );
  - ❑ kauzálnost a invertibilita procesu;
  - ❑ lineární filtrace;
- ❑ Využití v praktických (reálných úlohach):
  - ❑ modelování procesů a odhadování koeficientu pomocí Yule-Walkerových rovníc (konzistentní odhad);
  - ❑ lineární predikce v časových řadách (předpověď nasledujících pozorování na základě tých předchozích);
- ❑ V praxi sa často používajú komplexnejšie modely...
  - ❑ napr. VARMA, NARMA, ARIMA, VARIMA, ARCH, GARCH, etc.;

Kapitola 6

# Poissonův proces

# Náhodné procesy se spojitým časem

## □ Stochastický (náhodný) proces

↪ posloupnost (systém) reálných náhodných veličin  $\{X_t; t \in T\}$  definovaných na stejném pravděpodobnostním prostoru  $(\Omega, \mathcal{A}, P)$ ;

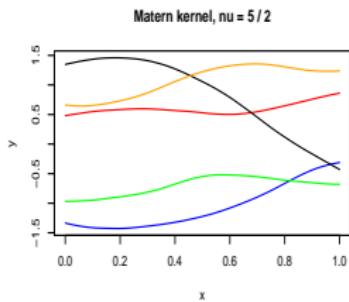
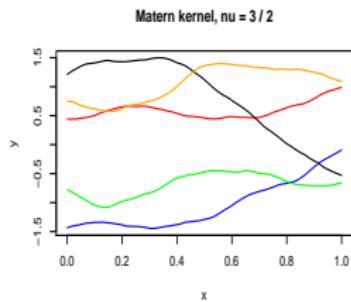
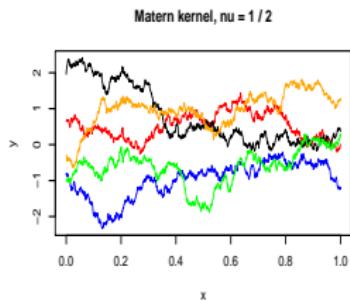
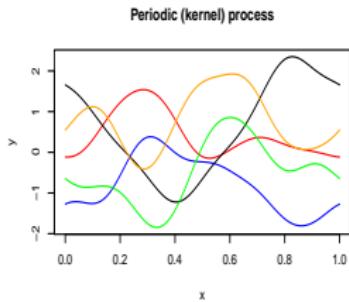
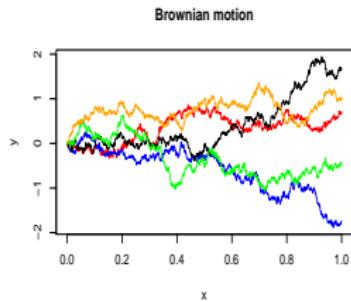
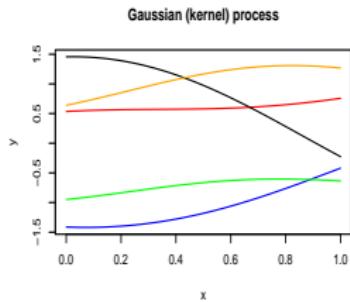
## □ Proces so spojitým časem

↪ v případě, že  $T \subseteq \mathbb{R}$ , pak říkame, že se jedná o proces se spojitým časem, t.j., hodnota procesu  $\{X_t; t \in T\}$  je definována v každém časovém okamžiku;

## □ Trajektórie procesu

↪ pro konkrétní  $\omega \in \Omega$  (elementární jev) je  $X_t(\omega) \equiv X(\omega)(t)$  funkce definována na  $T \subset \mathbb{R}$  (t.j., trajektórie procesu – jedna konkrétní realizace);

# Trajektórie rôznych procesov



# Čítací proces

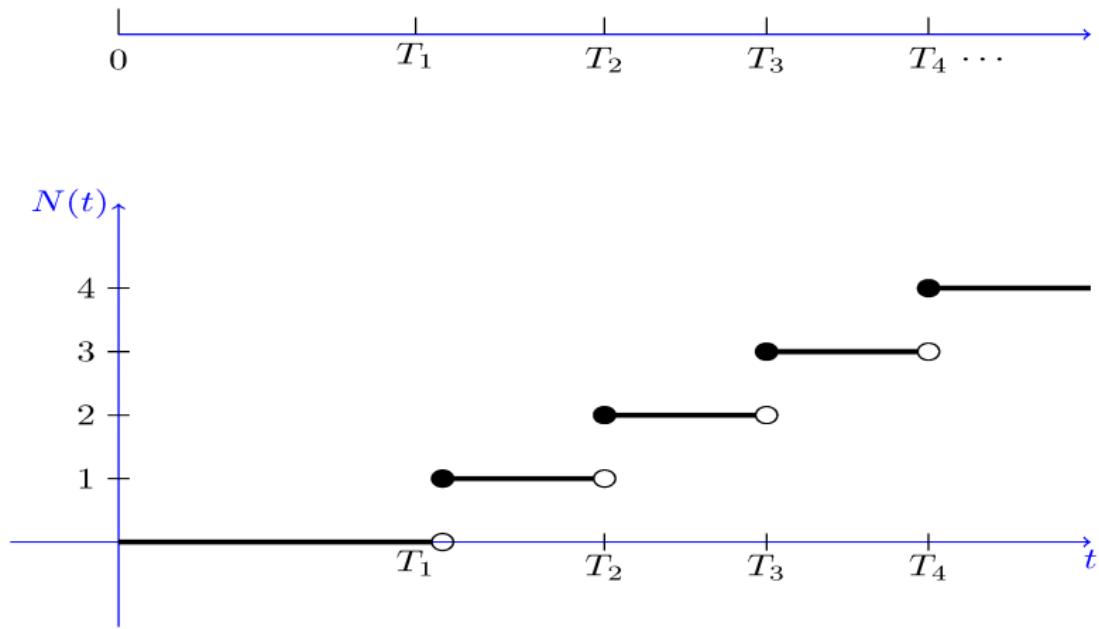
**Definice:** Čítací proces

Řekneme, že náhodný proces  $\{N_t; t \geq 0\}$  (proces se spojitím časem) je **čítací proces**, pokud nabýva celočíselných nezáporných hodnot a zároveň platí, že

$$\text{pokud } s \leq t \implies N(s) \leq N(t).$$

- Hodnotu  $N(t)$  interpretujeme jako **počet událostí**, které nastaly do času  $t$ .
- Ekvivalentně lze proces  $\{N_t; t \geq 0\}$  definovat jako proces, který má zprava spojité a neklesající trajektorie, **nabýva pouze celočíselných hodnot**, a začina z **nezáporne hodnoty**, t.j.  $N(0) \geq 0$ ;

# Trajektórie čítacieho procesu



# Prírastky procesu a nezávislé přírůstky

- Pro náhodný (čítací) process  $\{N_t; t \geq 0\}$  a pre libovolné dva časové okamžiky  $t_1, t_2 \geq 0$  takové, že  $t_1 < t_2$ , představuje náhodná veličina

$$N(t_2) - N(t_1) \geq 0$$

tzv. prírastok náhodného procesu medzi časom  $t_1$  a časom  $t_2$ .

## Definice: Nezávislé přírůstky

Řekneme, že proces  $\{N(t); t \geq 0\}$  má **nezávislé přírůstky**, pokud pro každé  $0 \leq t_0 \leq t_1 \leq \dots \leq t_n, n \in \mathbb{N}$  a  $t_i \in T$  pro  $i = 1, \dots, n$  platí, že  $N(t_n) - N(t_{n-1}), \dots, N(t_1) - N(t_0)$  jsou **nezávislé náhodné veličiny**.

# Poissonův (čítací) proces

## Definice: Poissonův proces

Náhodný čítací proces  $\{N(t); t \geq 0\}$  se nazýva homogénní Poissonův proces s intenzitou  $\lambda > 0$ , pokud platí:

- $N(0) = 0$ ;
- proces má nezávislé přírůstky;
- přírůstky  $N(t + h) - N(t)$  mají Poissonovo rozdělení s parametrem  $\lambda h$ ;

- nezávislé přírůstky Poissonovho procesu mají Poissonovo rozdělení s parametrem, který je přímo úměrný délce časového intervalu;
- parameter intenzity,  $\lambda > 0$ , je střední počet události za jednotku času;
- souvislost Poissonovho rozdělení s limitním binomickým rozdělením;

# Poissonov proces v aplikáciach

- ❑ Poissonův proces je často interpretován jako nahodný **bodový proces na reální přímce** (půlpřímce);
- ❑ Na reální přímce je Poissonův proces speciálním případem Markovského procesu se spojitým časem (**Markovská vlastnost**);
- ❑ V praxi často používaný náhodný proces pro modelování náhodných (a na sobě nezávislých) událostí v čase;
  - ❑ počty pojistných události, systémy obsluhy, atd' .;
  - ❑ chování zákazníků, modelování chyb a poruch, atd' .;
- ❑ Existuje mnoho různých a užitečných zobecnění Poissonova procesu:
  - ❑ nehomogenný Poissonův proces s variabilní intenzitou  $\lambda(t)$ ;
  - ❑ prostorový Poissonův proces (mnohorozměrná zobecnění);
  - ❑ procesy obnovy/zrodu a zániku (tzv. "renewal" a "birth-death" procesy);
  - ❑ značkované Poissonové procesy – napr. Cox proces;
  - ❑ procesy pro zavislé události v čase – tzv. Hawkesové procesy;
  - ❑ mnoho další...

# Příklad: Poissonův proces

## Príklad

### Telefonní ústředna a počet hovorů

Jednotlivé přichozí volání jsou na sobě nezávislé. Potenciálne je ale velký počet lidí, kteří mohou zavolat, ale u každého jednotlivce se jedná pouze o hodně malou pravděpodobnost, že skutečně zavolá na ústřednu. Z historických dat např. víme, že na telefonní ústřednu přijde v průměru 5 hovorů za minutu.

- Jaká je pravděpodobnost, že za půl minuty nepříde žádne volání?
  - Jaká je pravděpodobnost, že během pět sekund přijde alespoň 2 volání?
- 
- pro Poissonův proces obecně platí, že  $N(0) = 0$ , proto také platí, že

$$N(t) = N(t) - N(0) \sim Po(\lambda t)$$

a proto také platí, že

$$P[N(t) = k] = \frac{(\lambda t)^k}{k!} e^{-\lambda t}, \quad \text{pro } k = 0, 1, \dots$$

# Doby mezi událostmi v Poissonovém procesu

**Věta:** Doby mezi událostmi v Poissonovém procesu

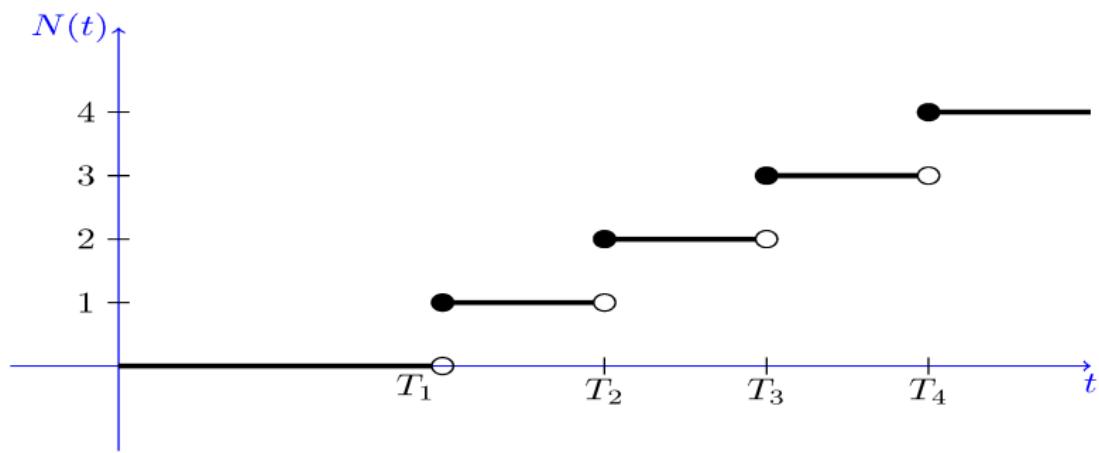
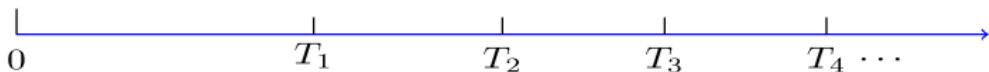
Nechť  $\{N(t); t \geq 0\}$  je Poissonův proces s intenzitou  $\lambda > 0$  a nechť  $\{\xi_n; n \in \mathbb{N}\}$  je posloupnost náhodných veličín definovaná předpisem

$$\xi_n = \inf\{t > 0; N(t) = n\}, \quad n = 1, 2, \dots$$

Pak náhodné veličiny  $T_n = \xi_n - \xi_{n-1}$ , pro  $n = 1, 2, \dots$ , pro  $\xi_0 = 0$ , jsou nezávislé náhodné veličiny s exponenciálním rozdělením s parametrem  $\lambda > 0$  a nazývají se doby mezi událostmi v Poissonovém procesu  $\{N(t); t \geq 0\}$ .

- **Idea:** platí  $P[\xi_k > t] = P[N(t) < k]$  a dokonce i  $\{\omega; \xi_k(\omega) > t\} \equiv \{\omega; N(\omega)(t) < k\}$

# Doby mezi událostmi



# Exponenciální a Erlangovo rozdělení

- náhodná veličina  $\xi_n$  pro  $n \in \mathbb{N}$  se nazýva doba do  $n$ -té události;
- náhodná veličina  $\xi_n$  pro  $n \in \mathbb{N}$  má Erlangovo rozdělení s hustotou

$$f_n(x) = \frac{\lambda^n}{(n-1)!} x^{n-1} e^{-\lambda x}, \quad \text{pro } x \geq 0.$$

- Erlangovo rozdělení s parametry  $\lambda > 0$  a  $n \in \mathbb{N}$  je rozdělení součtu  $n$  nezávislých náhodných veličin s exponenciálním rozdělením s parametrem  $\lambda > 0$  a jedná se o speciální případ Gamma rozdělení;
- Exponenciální rozdělení s parametrem  $\lambda > 0$  je rozdělení bez paměti, t.j., pro  $X \sim Exp(\lambda)$  platí, že

$$P[X > s + h | X > s] = P[X > h].$$

# Poissonův proces a exponenciální rozdělení

**Věta:** Exponenciální rozdělení a Poissonův proces

Nechť  $T_1, T_2, \dots$ , je posloupnost nezávislých, stejně rozdělených náhodných veličin s exponenciálním rozdělením s parametrem  $\lambda > 0$ . Nechť  $\xi_n = \sum_{k=1}^n T_k$ . Pak

$$N(t) = \sum_{k=1}^{\infty} \mathbb{I}_{\{\xi_k \leq t\}}$$

definuje Poissonův proces s intenzitou  $\lambda > 0$ .

- pokud teda známe počet události do nějakého času  $T > 0$ , pak je výskyt těchto události v intervalu  $[0, T]$  tzv. "binomický", t.j., časy událostí jsou nezávislé náhodné veličiny s rovnoměrným rozdělením na intervalu  $[0, T]$ ;

## Příklad: Binomická vlastnost

### Príklad

Nechť  $\{N(t); t \geq 0\}$  je Poissonův proces s intenzitou  $\lambda > 0$  a nechť  $N(T) = n$  a  $s \in (0, T)$ . Pak jednoduchým výpočtem dostaneme

$$\begin{aligned} P[N(s) = k | N(T) = n] &= \frac{P[N(s) = k, N(T) = n]}{P[N(T) = n]} \\ &= \frac{P[N(s) = k, N(T) - N(s) = n - k]}{P[N(T) = n]} \\ &= \frac{P[N(s) = k] \cdot P[N(T) - N(s) = n - k]}{P[N(T) = n]} \\ &= \binom{n}{k} \left(\frac{s}{T}\right)^k \left(1 - \frac{s}{T}\right)^{n-k} \end{aligned}$$

- Žádna část intervalu  $[0, T]$  není preferována a každý podinterval má rovnakú šancu (**úměrnou své délce**), že do něj padne událost. Body jsou do intervalu  $[0, T]$  umístňovány nezávisle na sobě.

## Poissonův proces s konstantní intenzitou

- Pro obecný Poissonův proces  $\{N(t); t \geq 0\}$  s konstantní intenzitou  $\lambda > 0$  také platí nasledující:
  - $P[N(t+h) = n+1 | N(t) = n] = \lambda h + o(h)$
  - $P[N(t+h) = n | N(t) = n] = 1 - \lambda h + o(h)$
  - $P[N(t+h) > n+1 | N(t) = n] = o(h)$

pro funkci  $o(h)$  takovou, že

$$\lim_{h \rightarrow 0_+} \frac{o(h)}{h} \rightarrow 0.$$

### Samostatný úkol

Ověřte, že uvedené vlastnosti skutečně platí pro obecný (homogenný) Poissonův proces s konstantní intenzitou  $\lambda > 0$ .

# Příklad: Škody v neživotném pojištění

## Príklad

Předpokládáme, že okamžiky pojistných událostí v čase tvoří Poissonův proces  $\{N(t); t \geq 0\}$  s konstantní intenzitou  $\lambda > 0$  a výše škod  $Y_k$  pro  $k \in \mathbb{N}$  jsou nezávislé, stejně rozdělené náhodné veličiny se střední hodnotou  $EY_k = \mu$ .

- $S(t) = \sum_{k=0}^{N(t)} Y_k$ , pro  $t \geq 0$  a  $Y_0 = 0$  je tzv. **složený Poissonův proces**;
- veličina  $S(t)$  udáva **celkovou výši škod** do času  $t \geq 0$  a platí

$$\begin{aligned} ES(t) &= E \left[ E[S(t)|N(t)] \right] = E \left[ E \left[ \sum_{k=0}^{N(t)} Y_k | N(t) \right] \right] \\ &= E \left[ N(t) \cdot EY_k \right] = EY_k \cdot \left( \sum_{n=0}^{\infty} n e^{-\lambda t} \frac{(\lambda t)^n}{n!} \right) = \lambda t \mu; \end{aligned}$$

K úhradě škodních nákladů by pojišťovna měla dostávat od pojištěných klientů pojistné ve výši  $\lambda \mu$  za jednotku času.

## Příklad: Systém obslužní linky

### Príklad

Uvažujme obslužní linku, která poskytuje určitou službu (např., pokladna v obchodě, telefonní linka, ...). Chceme modelovat chování takového systému.

- předpokládame, že události (t.j., např. příchody zákazníků) v systému tvoří Poissonův proces s konstantní intenzitou  $\lambda > 0$ ;
- když je linka obsazená, tvoří se fronta;
- doby obsluhy jednotlivých zákazníků jsou navzájem nezávislé náhodné veličiny s exponenciálním rozdělením s parametrem  $\mu > 0$ ;
- veličina  $X(t)$  značí počet zákazníků v systému (ve frontě a při obsluze);
- označme  $p_k(t) = P[X(t) = k]$ , pro  $k = 0, 1, \dots$ ;
- předpokládame, že také platí nasledující:

$$P(X(t+h) = k+1 | X(t) = k) = \lambda h + o(h)$$

$$P(X(t+h) = k | X(t) = k) = 1 - \lambda h + o(h)$$

$$P(X(t+k) > k+1 | X(t) = k) = o(h)$$

# Příklad: Systém obslužní linky

## Príklad

- ◻ pro doby obsluhy pak platí:  $T \sim Exp(\mu)$  a proto také platí:

$P(\text{obsluha skončí v čase } (t, t+h] | \text{zákazník je obsluhován v čase } t) = \mu h + o(h)$

$P(\text{obsluha neskončí v čase } (t, t+h] | \text{zákazník je obsluhován v čase } t) = 1 - \mu h + o(h)$

$P(\text{více zákazníku obsluženo v } (t, t+h] | \text{zákazník je obsluhován v čase } t) = o(h)$

$P(\text{přijde a odejde stejný počet v } (t, t+h] | \text{zákazník je obsluhován v čase } t) = o(h)$

## Samostatný úkol

Použijte vlastnosti exponenciálního rozdělení s parametrem  $\mu > 0$ , aplikujte Taylorův rozvoj a odvodte vztahy uvedené v příkladu nahoře.

## Příklad: Systém obslužní linky

### Príklad

- obecně můžeme psát, že v systému obslužní linky (model pro příchod a obsluhu zákazníku) nastane v intervalu  $(t, t + h)$  jedna změna (t.j. přijede jeden zákazník nebo odejde jeden zákazník) s pravděpodobností

$$\mu h + \lambda h + o(h);$$

- pravděpodobnost, že v takomto systému nenastane v časovém intervalu  $(t, t + h)$  žádna změna (nový zákazník nepříde a žádný nebude obslužen) je

$$1 - (\mu h + \lambda h) + o(h);$$

- pravděpodobnost, že v systému dojde v časovém intervalu  $(t, t + h)$  k nějaké jiné změně (např. přijede více zákazníku, nebo více zákazníku bude obsluženo, nebo zaroveň alespoň jeden přijede a alespoň jeden bude obslužen) je zanedbatelná, t.j. řádu  $o(h)$ ;

## Příklad: Systém obslužní linky

### Príklad

- ❑ zajíma nás limitní chování pravděpodobnosti

$$p_k(t) = P[X(t) = k],$$

pro  $t \rightarrow \infty$ ;

- ❑ Jaké je limitní rozdělení zákazníků v systému?  
*(hromadí se zákazníci ve frontě, nebo je systém prázdný?)*

- ❑ Příklad lze řešit pomocí soustavy diferenciálních rovnic...
- ❑ ... budeme uvažovat samostatně případ pro  $k = 0$  a  $k = 1, 2, \dots$ ;

# Řešení pomocí diferenciálních rovníc

- pro  $k = 0$  dostaneme:

$$p_0(t+h) = p_0(t)(1 - \lambda h + o(h)) + p_1(t)(\mu h + o(h)) + \sum_{j=2}^{\infty} p_j(t)o(h)$$

## Řešení pomocí diferenciálních rovníc

- pro  $k = 0$  dostaneme:

$$p_0(t+h) = p_0(t)(1 - \lambda h + o(h)) + p_1(t)(\mu h + o(h)) + \sum_{j=2}^{\infty} p_j(t)o(h)$$

- pro  $k = 1, 2, \dots$  dostaneme:

$$\begin{aligned} p_k(t+h) &= \sum_{j=0}^{k-2} p_j(t)o(h) + p_{k-1}(t)(\lambda h + o(h)) \\ &\quad + p_k(t)(1 - \lambda h - \mu h + o(h)) \\ &\quad + p_{k+1}(t)(\mu h + o(h)) + \sum_{j=k+2}^{\infty} p_j(t)o(h) \end{aligned}$$

## Řešení pomocí diferenciálních rovníc

- algebraickou úpravou a limitním přechodem pro  $h \rightarrow 0_+$  dostaneme diferenciální rovnici pro  $k = 0$ :

$$\frac{\partial}{\partial t} p_0(t) = -\lambda p_0(t) + \mu p_1(t)$$

# Řešení pomocí diferenciálních rovníc

- algebraickou úpravou a limitním přechodem pro  $h \rightarrow 0_+$  dostaneme diferenciální rovnici pro  $k = 0$ :

$$\frac{\partial}{\partial t} p_0(t) = -\lambda p_0(t) + \mu p_1(t)$$

- algebraickou úpravou a limitním přechodem pro  $h \rightarrow 0_+$  dostaneme diferenciální rovnice pro  $k = 1, 2, \dots$ :

$$\frac{\partial}{\partial t} p_k(t) = \lambda p_{k-1}(t) - (\lambda + \mu) p_k(t) + \mu p_{k+1}(t)$$

# Řešení pomocí diferenciálních rovníc

- Pokud existuje limita  $\lim_{t \rightarrow \infty} p_k(t)$ , pak musí platit

$$0 = -\lambda p_0(\infty) + \mu p_1(\infty)$$

$$0 = \lambda p_{k-1}(\infty) - (\lambda + \mu)p_k(\infty) + \mu p_{k+1}(\infty)$$

- Soustava rovnic, jejíž řešením je

$$p_k(\infty) = \rho^k p_0(\infty),$$

kde  $\rho = \lambda/\mu$ ;

- Zároveň musí platit, že

$$\sum_{k=0}^{\infty} p_k(\infty) = 1,$$

jelikož se jedná o pravděpodobnostní rozdělení na množině  $\{0, 1, 2, \dots\}$ ;  
(limitné rozdělení teda existuje pro  $\rho < 1$  a ide o geometrické rozdělení s  
parametrem  $\rho = \frac{\lambda}{\mu}$ )

# Sjednocení nezávislých Poissonových procesů

- Generická vlastnost Poissonového rozdelení:

$$N_1 \sim \text{Poiss}(\lambda_1) \wedge N_2 \sim \text{Poiss}(\lambda_2) \quad \Longrightarrow \quad N_1 + N_2 \sim \text{Poiss}(\lambda_1 + \lambda_2)$$

- Analogický aj pro Poissonov proces

Pro  $\{N_1(t); t \geq 0\}$  a  $\{N_2(t); t \geq 0\}$  dva nezávislé homogénní Poissonové procesy s intenzitou  $\lambda_1 > 0$  a  $\lambda_2 > 0$ , pak aj

$$\{N_1(t) + N_2(t); t \geq 0\}$$

je homogénní Poissonov proces s príslušnou intenzitou  $\lambda_1 + \lambda_2$ ;

## Samostatný úkol

Ukážte, že Poissonov proces  $\{N_1(t) + N_2(t); t \geq 0\}$  definovaný jako součet dvou vzájemně nezávislých homogénních Poissonových procesů s intenzitami  $\lambda_1 > 0$  a  $\lambda_2 > 0$  splňuje vlastnosti Poissonového procesu.

## Zobecnění pro více procesů

- Zjednocení dvou nezávislých Poissonových procesů lze samozrejme zobecnit na více než dva procesy;
- Obecně, pro  $m \in \mathbb{N}$  vzájemně nezávislých homogénních Poissonových procesů  $\{N_1(t); t \geq 0\}, \dots, \{N_m(t); t \geq 0\}$  s intenzitami  $\lambda_j > 0$  pro  $j = 1, \dots, m$  platí, že

$$N(t) = N_1(t) + \dots + N_m(t)$$

je opět Poissonov proces s příslušnou intenzitou

$$\lambda = \lambda_1 + \dots + \lambda_m.$$

### Samostatný úkol

Ukážte, že Poissonov proces  $\{N_1(t) + \dots + N_m(t); t \geq 0\}$  definovaný jako součet  $m$  vzájemně nezávislých homogénních Poissonových procesů s intenzitami  $\lambda_j > 0$  pro  $j = 1, \dots, m$ , splňuje vlastnosti Poissonového procesu.

# Nezávislost a podmíněná závislost

- Nechť  $\{N(t); t \geq 0\}$  je Poissonův proces s intenzitou  $\lambda > 0$ ;
- Události v procesu náhodne označíme dvěma různymi nálepkami...
- S pravděpodobností  $p \in (0, 1)$  označíme událost nálepkou  $A$ ;  
*(výskyt události typu A tvoří čítací proces  $\{N_1(t); t \geq 0\}$ )*
- S pravděpodobností  $(1 - p)$  označíme událost nálepkou  $B$ ;  
*(výskyt události typu B tvoří čítací proces  $\{N_2(t); t \geq 0\}$ )*

**Věta:** Nezávislost rozděleného Poissonového procesu

Čítací procesy  $\{N_1(t); t \geq 0\}$  a  $\{N_2(t); t \geq 0\}$  jsou vzájemně nezávislé homogénní Poissonové procesy s příslušnými intenzitami  $\lambda_1 = \lambda p$  a  $\lambda_2 = \lambda(1 - p)$ .

# Nezávislost a podmíněná závislost

- Poissonové procesy  $\{N_1(t); t \geq 0\}$  a  $\{N_2(t); t \geq 0\}$  jsou dle předchozí věty **združeně nezávislé**;
- **Podmíněně**, při daném stavu procesu  $\{N(t); t \geq 0\}$ , jsou ale procesy  $\{N_1(t); t \geq 0\}$  a  $\{N_2(t); t \geq 0\}$  **vzájemně závislé**;

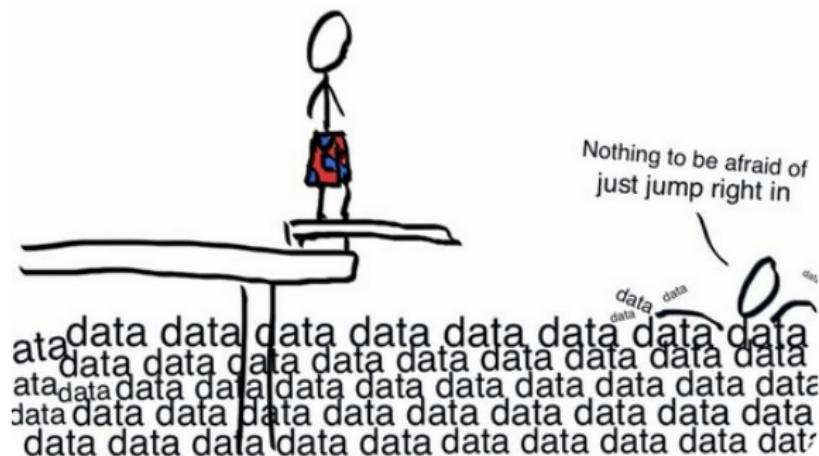
## Samostatný úkol

Ukážte, proč jsou procesy  $\{N_1(t); t \geq 0\}$  a  $\{N_2(t); t \geq 0\}$  při daném  $N \in \mathbb{N}$  podmíněně závislé. Dokonca jeden proces zcela určuje ten druhý.

# Různá zobecnění Poissonového procesu

- zobecnění Poissonového procesu v neeuklidovských prostorech;  
*(fundamentalní nástroj v pravděpodobnosti, teórii míry a topologii)*
- dvojitě stochastický Poissonův proces (Coxův proces);  
*(Poissonův proces s náhodnou intenzitou - funkci  $\Lambda(t)$ )*
- složený Poissonův proces (tzv. marked process);  
*(událost v čase má vlastní náhodnou hodnotu)*
- Poissonův proces se závislými přírastkami (Hawkesův proces);  
*(homogenný nebo nehomogenný, tzv. "self-exciting stochastický process")*
- tzv. compound Poissonův proces;  
*(Poissonův process jako součet několika složených Poissonových procesů)*
- mnohé další zobecnění a speciální případy;  
*(užitečný nástroj pro pravděpodobnostní teórii a stochastické modelování)*

# K čomu je to všetko dobré?



To conclude...

# Závěrečné zkoušky

# Zkouškové termíny

Momentálne sú v SISe vypísané **4 skúškové termíny**. Prihlásenie na konkrétny termín je nutné prostredníctvom systému SIS. Minimálne jeden další termín bude vypísaný v září 2023.

Závěrečná zkouška pozostáva z dvou časti:

**První část zkoušky**

→ početná časť skúšky na 90 minút (nutné minimum: 50 %);

**Druhá část zkoušky**

→ teoretická časť skúšky na 90 minút (nutné minimum: 50 %);

## Zkouškové termíny

- 1. Termín:** Středa | 15.05.2023 (10/10)  
(Posluchárna 12) | 9:00)
- 2. Termín:** Pondělí | 29.05.2023 (1/20)  
(Posluchárna K11) | 9:00)
- 3. Termín:** Pondělí | 12.06.2023 (0/20)  
(Posluchárna K11) | 9:00)
- 4. Termín:** Středa | 28.06.2023 (0/20)  
(Posluchárna K11) | 9:00)
  
- 5. Termín:** Září 2023  
(dodatečne bude upřesněno)

Na konkrétný zkouškový termín je nutný zápis prostredníctvom elektronického systému SIS (nejpozději jeden den před zkouškou!)