

Časové řady II

Ondřej Vencálek
Univerzita Palackého v Olomouci
ondrej.vencalek@upol.cz

seminář pro VŠB-TUO
2015-03-20, Ostrava



EVROPSKÁ UNIE



MINISTERSTVO ŠKOLSTVÍ,
MLÁDEŽE A TĚLOVÝCHOVY



INVESTICE DO ROZVOJE VZDĚLÁVÁNÍ

Nové kreativní týmy v prioritách vědeckého bádání

CZ.1.07/2.3.00/30.0055




Tento projekt je spolufinancován z ESF a státního rozpočtu ČR.




Písmenkové zmatky

Upozornění týkající se používání velkých a malých písmen v odborné literatuře:




- ▶ statistici občas až pedantsky rozlišují symboly Y (náhodná veličina) a y (realizace náhodné veličiny; reálné číslo),
- ▶ „časovkáři“ (zvláštní druh statistiků) dosti často používají symbolu y pro náhodnou veličinu

Omluva: v této prezentaci občas použiji pro náhodnou veličinu velké a občas malé písmeno.





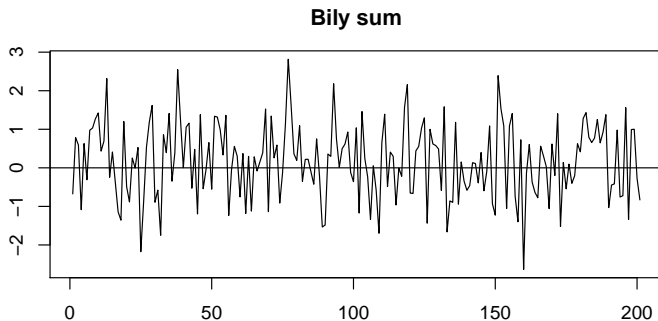
Korelace po sobě jdoucích hodnot



Bílý šum (white noise)

$$\epsilon_t, \quad t = \dots, -1, 0, 1, \dots \text{i.i.d. } \epsilon_t \sim N(0, \sigma^2),$$

tj. **nezávislé**, stejně rozdělené s nulovou stř. hodnotou.



http://en.wikipedia.org/wiki/White_noise


Procesy MA(1)

Posloupností klouzavých součtů řádu 1 (Moving Average – MA)
rozumíme posloupnost náhodných veličin danou předpisem


$$y_t = \epsilon_t + \theta \epsilon_{t-1},$$

kde $\{\epsilon_t\}$ je bílý šum ($\epsilon_t \sim N(0, \sigma^2)$),
 $\theta \in \mathbb{R}$ je parametr procesu.


MA(1), theta= 0.9



MA(1), theta= 0



MA(1), theta= -0.9



Procesy MA(1): střední hodnota a rozptyl

$$\begin{aligned} E(Y_t) &= E(\epsilon_t + \theta\epsilon_{t-1}) = E(\epsilon_t) + \theta E(\epsilon_{t-1}) = 0 + \theta \cdot 0 = 0 \\ \text{var}(Y_t) &= \text{var}(\epsilon_t + \theta\epsilon_{t-1}) = \text{var}(\epsilon_t) + \text{var}(\theta\epsilon_{t-1}) + 2\text{cov}(\epsilon_t, \theta\epsilon_{t-1}) = \\ &= \text{var}(\epsilon_t) + \theta^2 \text{var}(\epsilon_{t-1}) = \sigma^2 + \theta^2 \sigma^2 = \sigma^2(1 + \theta^2) \end{aligned}$$

Všimněte si: střední hodnota a rozptyl jsou v čase konstantní.

Procesy MA(1): korelace

$$\begin{aligned} \text{cov}(Y_t, Y_{t-1}) &= \text{cov}(\epsilon_t + \theta\epsilon_{t-1}, \epsilon_{t-1} + \theta\epsilon_{t-2}) = \\ &= \text{cov}(\epsilon_t, \epsilon_{t-1}) + \theta\text{cov}(\epsilon_t, \epsilon_{t-2}) + \\ &\quad + \theta\text{cov}(\epsilon_{t-1}, \epsilon_{t-1}) + \theta^2\text{cov}(\epsilon_{t-1}, \epsilon_{t-2}) = \\ &= 0 + 0 + \theta\text{var}(\epsilon_{t-1}) + 0 = \theta\sigma^2 \end{aligned}$$


$$\begin{aligned} \text{cov}(Y_t, Y_{t-k}) &= \text{cov}(\epsilon_t + \theta\epsilon_{t-1}, \epsilon_{t-k} + \theta\epsilon_{t-1-k}) = \\ &= \text{cov}(\epsilon_t, \epsilon_{t-k}) + \theta\text{cov}(\epsilon_t, \epsilon_{t-1-k}) + \\ &\quad + \theta\text{cov}(\epsilon_{t-1}, \epsilon_{t-k}) + \theta^2\text{cov}(\epsilon_{t-1}, \epsilon_{t-1-k}) = \\ &= 0 + 0 + 0 + 0 = 0 \text{ pro } k > 1 \end{aligned}$$

Připomeňme, že $\text{var}(Y_t) = \text{var}(Y_{t-1}) = \sigma^2(1 + \theta^2)$, tudíž

$$\begin{aligned} \text{cor}(Y_t, Y_{t-1}) &= \frac{\theta}{1 + \theta^2} \\ \text{cor}(Y_t, Y_{t-k}) &= 0 \text{ pro } k > 1 \end{aligned}$$

Všimněte si: korelace dvou po sobě jdoucích (náhodných) hodnot procesu je v čase konstantní.

Procesy MA(1): korelace



$$|\text{cor}(Y_t, Y_{t-1})| \leq 1/2$$

STACIONARITA

U procesů MA(1) jsme ukázali, že mají následující vlastnosti:

- ▶ střední hodnota je konstantní v čase, tj.

$$E(Y_t) = \mu \text{ pro všechna } t = \dots, -1, 0, 1, \dots$$

- ▶ rozptyl je konstantní v čase, tj.

$$\text{var}(Y_t) = \sigma^2 \text{ pro všechna } t = \dots, -1, 0, 1, \dots$$

- ▶ korelace dvou hodnot náhodného procesu závisí jen na jejich vzdálenosti, nikoliv na čase, tj.

$$\text{cor}(Y_t, Y_{t+h}) = \text{cor}(Y_s, Y_{s+h}) \text{ pro libovolné } t, s \text{ a časovou vzdálenost } h.$$

Procesy, které tyto vlastnosti mají, se nazývají **slabě stacionární**.

Důležitost stacionarity popisuje *Cipra* slovy: „V Box-Jenkinsově metodologii lze modelovat pouze stacionární časové řady, přičemž ovšem pomocí různých transformací (nejčastěji pomocí diferencování) je možné mnoho nestacionárních časových řad z praxe převést na stacionární.“

AUTOKORELAČNÍ FUNKCE

Autokorelační funkcí stacionární časové řady $\{Y_t, t \in \mathbb{Z}\}$ rozumíme funkci

$$\begin{aligned}\rho : \mathbb{Z} &\rightarrow [-1, 1] \\ k &\mapsto \text{cor}(Y_t, Y_{t+k})\end{aligned}$$


Poznámky:

- ▶ rozmyslete si, že bez předpokladu stacionarity procesu nemá autokorelační funkce smysl
- ▶ jde o sudou funkci, tj. $\rho(k) = \rho(-k)$,
neboť $\text{cor}(Y_t, Y_{t+k}) = \text{cor}(Y_t, Y_{t-k})$ (podmínka stacionarity)
proto stačí zkoumat autokorel. funkci jen pro $k \geq 0$
- ▶ $\rho(0) = 1$, neboť $\rho(0) = \text{cor}(Y_t, Y_t) = 1$

Autokorelační funkce procesů MA(1)

Ukázali jsme, že

- ▶ $\rho(1) = \text{cor}(Y_t, Y_{t-1}) = \frac{\theta}{1+\theta^2}$
- ▶ $\rho(k) = \text{cor}(Y_t, Y_{t-k}) = 0$ pro $k > 1$



Graf: autokorelační funkce procesu MA(1) s parametrem $\theta = 0,9$.

Procesy MA(q)

Posloupností klouzavých součtů řádu q (Moving Average – MA)
rozumíme posloupnost náhodných veličin danou předpisem

$$y_t = \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q},$$

kde $\{\epsilon_t\}$ je bílý šum ($\epsilon_t \sim N(0, \sigma^2)$),
 $\theta_1 \in \mathbb{R}, \dots, \theta_q \in \mathbb{R}$ jsou parametry procesu.

Procesy MA(q): stř. hodnota, rozptyl, autokorelační funkce

$$\begin{aligned}E(Y_t) &= 0 \\ \text{var}(Y_t) &= (1 + \theta_1^2 + \dots + \theta_q^2) \cdot \sigma^2\end{aligned}$$

Autokorelační funkce:


$$\begin{aligned}\rho_k = \text{cor}(Y_t, Y_{t+k}) &= \frac{\theta_k + \theta_1\theta_{k+1} + \dots + \theta_{q-k}\theta_q}{1 + \theta_1^2 + \dots + \theta_q^2} && \text{pro } k \leq q \\ \rho_k = \text{cor}(Y_t, Y_{t+k}) &= 0 && \text{pro } k > q\end{aligned}$$

Opět vidíme, že procesy MA(q) jsou stacionární.


Odvození je jednoduché cvičeníčko – zkuste si.

Procesy MA(q): příklady autokorelačních funkcí


MA(2): $\theta_1 = 1,0$, $\theta_2 = 0,7$




MA(2): $\theta_1 = -1,0$, $\theta_2 = 0,7$



MA(2): $\theta_1 = 0,0$, $\theta_2 = -0,5$



MA(3): $\theta_1 = 1,0$, $\theta_2 = 0,1$, $\theta_3 = -0,9$



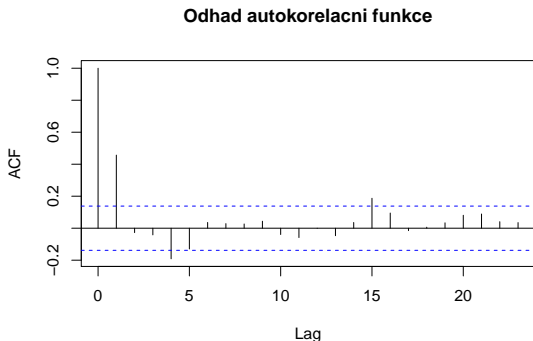
Proč je pro nás autokorel. funkce důležitá?

- ▶ Korelační koeficient umíme z dat odhadnout,
- ▶ Tedy umíme odhadnout, jak vypadá autokorelační funkce,
- ▶ Podle tvaru odhadnuté autokorel. funkce se můžeme rozhodnout, jaký model bude vhodný pro naše data.
- ▶ Hodnotu odhadu (auto)korelace můžeme využít k odhadu parametrů (θ) daného procesu.

Příklad interpretace odhadu autokorel. funkce

- ▶ Na začátku jsme viděli simulovaných 200 hodnot procesu MA(1) s parametrem $\theta = 0,9$.
- ▶ Jeho autokorelační funkce má hodnotu $90/181 \doteq 0,497$ pro $k = 1$ a je nulová pro $k > 1$.
- ▶ Představme si, že nevíme, že jde o proces typu MA(1) a neznáme hodnotu θ .

Odhadnutá autokorelační funkce:



Odhad autokorel. funkce

- ▶ Odhad autokovarianční funkce:

$$c_k = \frac{1}{n} \sum_{t=1}^{n-k} (Y_t - \bar{Y})(Y_{t+k} - \bar{Y})$$

- ▶ Odhad autokorelační funkce:

$$r_k = \frac{c_k}{c_0}$$

Odhad autokorel. funkce – Bartlettova aproximace

Je-li $\rho_k = 0$ pro $k > k_0$, pak

$$\text{var}(r_k) \approx \frac{1}{n} \left(1 + 2 \sum_{j=1}^{k_0} r_j^2 \right) \quad \text{pro } k > k_0$$

Využití odhadu autokorel. funkce pro odhad parametru θ

Víme

$$\rho(1) = \frac{\theta}{1 + \theta^2}$$


a umíme hodnotu autokorelace odhadnout.

$$\hat{\rho}(1) \cdot \hat{\theta}^2 - \hat{\theta} + \hat{\rho}(1) = 0$$

$$\hat{\theta} = \frac{1 - \sqrt{1 - 4\hat{\rho}(1)^2}}{2\hat{\rho}(1)}$$


Druhý kořen odpovídá procesu, který není *invertibilní* (vysvětlíme později).

Jiný typ modelu



Autokorelační funkce předešlého procesu

(odhad)



Procesy AR(1)

Autoregresním procesem řádu 1 rozumíme posloupnost náhodných veličin $\{y_t\}$ danou předpisem



$$y_t = \phi y_{t-1} + \epsilon_t,$$

kde $\{\epsilon_t\}$ je bílý šum ($\epsilon_t \sim N(0, \sigma^2)$),
 $\phi \in \mathbb{R}$ je parametr procesu.

Sacionarita procesů AR(1)

$$y_t = \phi y_{t-1} + \epsilon_t,$$

Proces AR(1) nemusí být stacionární – záleží na hodnotě parametru ϕ .



Sacionarita procesů AR(1) – neformální odvození

$$y_t = \phi y_{t-1} + \epsilon_t$$

$$y_t = \phi(\phi y_{t-2} + \epsilon_{t-1}) + \epsilon_t$$

$$y_t = \phi^2 y_{t-2} + \phi \epsilon_{t-1} + \epsilon_t$$

$$y_t = \phi^3 y_{t-3} + \phi^2 \epsilon_{t-2} + \phi \epsilon_{t-1} + \epsilon_t$$

⋮

$$y_t = \phi^k y_{t-k} + \sum_{j=0}^{k-1} \phi^j \epsilon_{t-j}, \quad k \in \mathbb{N}$$

Pro $|\phi| < 1$ je „modrý“ člen zanedbatelný, zbytek je proces MA, o němž víme, že je stacionární.

Procesy AR(1) jsou stacionární, pokud $|\phi| < 1$.

Stacionární procesy AR(1): střední hodnota

$$\begin{aligned} E(y_t) &= E(\phi y_{t-1} + \epsilon_t) = \\ &= \phi E(y_{t-1}) + E(\epsilon_t) = \\ &= \phi E(y_t) + 0 \\ E(y_t)(1 - \phi) &= 0 \\ E(y_t) &= 0 \end{aligned}$$

Využili jsme předpoklad stacionarity, nejprve v rovnosti $E(y_{t-1}) = E(y_t)$, poté v posledním kroku, kde $|\phi| < 1$.

Stacionární procesy AR(1): rozptyl

$$\begin{aligned}\text{var}(y_t) &= \text{var}(\phi y_{t-1} + \epsilon_t) = \\ &= \phi^2 \text{var}(y_{t-1}) + \text{var}(\epsilon_t) + 2\phi \text{cov}(y_{t-1}, \epsilon_t) = \\ &= \phi^2 \text{var}(y_t) + \text{var}(\epsilon_t) + 0 = \\ &= \phi^2 \text{var}(y_t) + \sigma^2 \\ \text{var}(y_t)(1 - \phi^2) &= \sigma^2 \\ \text{var}(y_t) &= \frac{\sigma^2}{1 - \phi^2}\end{aligned}$$

Pozornost si zaslouží rovnost $\text{cov}(y_{t-1}, \epsilon_t) = 0$, uvědomme si, že y_t je definováno pomocí *minulých* hodnot procesu $\{y_t\}$ a *současné* hodnoty bílého šumu ϵ_t . Hodnota v čase $t - 1$ (y_{t-1}), tedy musí být nezávislá s hodnotou bílého šumu v čase t , který je z pohledu času $t - 1$ *budoucností*.

Stacionární procesy AR(1): korelace


Pro výpočet použijeme vztah, který jsme odvodili o 3 slajdy dříve:

$$y_t = \phi^k y_{t-k} + \sum_{j=0}^{k-1} \phi^j \epsilon_{t-j}, \quad k \in \mathbb{N}$$


$$\begin{aligned} \text{cov}(y_t, y_{t-k}) &= \text{cov}\left(\phi^k y_{t-k} + \sum_{j=0}^{k-1} \phi^j \epsilon_{t-j}, y_{t-k}\right) = \\ &= \phi^k \text{cov}(y_{t-k}, y_{t-k}) + \sum_{j=0}^{k-1} \phi^j \text{cov}(\epsilon_{t-j}, y_{t-k}) = \\ &= \phi^k \text{cov}(y_{t-k}, y_{t-k}) + 0 = \\ &= \phi^k \sigma^2 \\ \rho(k) = \text{cor}(y_t, y_{t-k}) &= \phi^k \end{aligned}$$

Stacionární procesy AR(1): autokorelační funkce

AR(1): $\phi = 0,9$




AR(1): $\phi = -0,9$



Potřeba „přímé“ korelace

$$y_t = \phi y_{t-1} + \epsilon_t$$

$$y_{t-1} = \phi y_{t-2} + \epsilon_{t-1}$$




- ▶ Korelace mezi y_t a y_{t-2} je „přes y_{t-1} “.
- ▶ Existuje však mezi nimi „přímá“ korelace?
- ▶ KONCEPT PARCIÁLNÍ KORELACE

Připomenutí jednoho příkladu z minula

- ▶ X : počet právníků ve státě Kansas
- ▶ Y : počet úmrtí v důsledku pádu ze schodů v USA


máme k dispozici údaje za období 1999 až 2008 (10 let)

$$\text{cor}(X, Y) = 0,98$$



Připomenutí jednoho příkladu z minula

- ▶ X : počet právníků ve státě Kansas
- ▶ Y : počet úmrtí v důsledku pádu ze schodů v USA
- ▶ Z : počet obyvatel USA



Je mezi X a Y nějaký jiný vztah, než že obě přímo úměrně rostou s rostoucím Z ?

Odpověď na předešlou otázku

- ▶ Odhadněme (lineární) závislost X na Z

$$X = \beta_0 + \beta_1 Z + \epsilon_X$$

$$\widehat{X} = \widehat{\beta}_0 + \widehat{\beta}_1 Z$$

- ▶ Odhadněme (lineární) závislost Y na Z

$$Y = \beta_0^* + \beta_1^* Z + \epsilon_Y$$

$$\widehat{Y} = \widehat{\beta}_0^* + \widehat{\beta}_1^* Z$$

Studujme korelaci veličin $X - \widehat{X}$ a $Y - \widehat{Y}$, tj. zabývejme se tou částí vztahu X a Y , kterou nelze vysvětlit pomocí Z .

$$\text{cor}(X - \widehat{X}, Y - \widehat{Y}) =: \rho_{X,Y,Z}$$

Parciální korelační koeficient X a Y při daném Z .

Otázka pro Vás!

Jaký byste očekávali paricální korelační koeficient X a Y při daném Z ?

- ▶ X : počet právníků ve státě Kansas
- ▶ Y : počet úmrtí v důsledku pádu ze schodů v USA
- ▶ Z : počet obyvatel USA

Jde o korelační koeficient

- ▶ rozdílu skutečného počtu právníků v Kansasu a očekávaného (dle velikosti Americké populace)
- ▶ rozdílu skutečného počtu úmrtí ... a očekávaného (dle velikosti Americké populace)

Já bych očekával hodnotu blízkou nule.

Otázka pro Vás!

Jaký byste očekávali paricální korelační koeficient X a Y při daném Z ?

- ▶ X : počet právníků ve státě Kansas
- ▶ Y : počet úmrtí v důsledku pádu ze schodů v USA
- ▶ Z : počet obyvatel USA

Jde o korelační koeficient

- ▶ rozdílu skutečného počtu právníků v Kansasu a očekávaného (dle velikosti Americké populace)
- ▶ rozdílu skutečného počtu úmrtí ... a očekávaného (dle velikosti Americké populace)

Já bych očekával hodnotu blízkou nule.

Překvapení

$$\rho_{X,Y.Z} = 0,68$$

Tak že by přece jen ti právníci ...

Možné vysvětlení

- ▶ Kansas nebyl v příkladu zvolen úplně náhodně, byl to stát (z 51) s druhou nejsilnější korelací mezi X a Y .
- ▶ Korelační koeficient se pohyboval kolem hodnoty 0,91 (medián).
- ▶ Parciální korelační koeficient se pohyboval kolem hodnoty 0,19 (medián).

(Ale pořád je tu možnost, že „přece jen ti právníci ...“ – že existuje kauzální vztah mezi počtem právníků v Kansasu a počtem úmrtí při pádu ze schodů v USA)

PARCIÁLNÍ AUTOKORELAČNÍ FUNKCE

Parciální autokorelační funkcí stacionární časové řady $\{Y_t, t \in \mathbb{Z}\}$ rozumíme funkci

$$\begin{aligned}\rho : \mathbb{Z} &\rightarrow [-1, 1] \\ k &\mapsto \text{pcor}(Y_t, Y_{t+k}),\end{aligned}$$

kde $\text{pcor}(Y_t, Y_{t+k})$ označuje parciální korelační koeficient veličin Y_t a Y_{t+k} při daných $Y_{t+1}, \dots, Y_{t+k-1}$.

Parciální autokorelační funkce v procesech AR(1)


SpočtĚme např. $pcor(Y_t, Y_{t-2})$

$$\begin{aligned}y_t &= \phi y_{t-1} + \epsilon_t \\ \hat{y}_t &= \phi y_{t-1} \\ y_t - \hat{y}_t &= \epsilon_t\end{aligned}$$

$$\begin{aligned}y_{t-1} &= \phi y_{t-2} + \epsilon_{t-1} \\ \hat{y}_{t-2} &= \frac{1}{\phi} y_{t-1} \\ y_{t-2} - \hat{y}_{t-2} &= -\frac{1}{\phi} \epsilon_{t-1}\end{aligned}$$


$$pcor(Y_t, Y_{t-2}) = cor(y_t - \hat{y}_t, y_{t-2} - \hat{y}_{t-2}) = cor(\epsilon_t, -\frac{1}{\phi} \epsilon_{t-1}) = 0$$

Parciální autokorelační funkce v procesech AR(1)




Parciální autokorelační funkce v procesech AR(1) a MA(1)

AR(1)



MA(1)



Parciální autokorelační funkce v procesech MA(1)


$$pcor(y_t, t_{t-k}) = \frac{(-1)^{k-1} \theta^k (1 - \theta^2)}{1 - \theta^{2(k+1)}} \quad k = 2, 3, \dots$$

Je omezena geometricky klesající posloupností


$$|pcor(y_t, t_{t-k})| < |\theta|^k$$

Parciální autokorelační funkce v procesech MA(1)


PACF pro proces MA(1) s parametrem $\theta = 0,9$




PACF pro proces MA(1) s parametrem $\theta = 0,5$



PACF pro proces MA(1) s parametrem $\theta = -0,5$



PACF pro proces MA(1) s parametrem $\theta = -0,9$



Procesy AR(p)

Autoregresním procesem řádu p rozumíme posloupnost náhodných veličin $\{y_t\}$ danou předpisem

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t,$$

kde $\{\epsilon_t\}$ je bílý šum ($\epsilon_t \sim N(0, \sigma^2)$),

$\phi_1 \in \mathbb{R}, \dots, \phi_p \in \mathbb{R}$ jsou parametry procesu.

Procesy AR(p): podmínka stacionarity, stř. hodnota, rozptyl

$$E(Y_t) = 0$$
$$\text{var}(Y_t) = \frac{\sigma^2}{1 - \phi_1\rho_1 - \dots - \phi_p\rho_p}$$

Podmínka stacionarity: všechna řešení rovnice

$$1 - \sum_{j=1}^p \phi_j x^j = 0$$

musí ležet vně jednotkového kruhu.

(pro $p = 1$ má rovnice tvar $1 - \phi_1 x = 0$, kořen je $1/\phi_1$, podmínka je tedy $|1/\phi_1| > 1$, tj/ $|\phi_1| < 1$, viz dříve)

Procesy AR(p): autokorelační funkce

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t$$

$$y_t y_{t-k} = \phi_1 y_{t-1} y_{t-k} + \phi_2 y_{t-2} y_{t-k} + \dots + \phi_p y_{t-p} y_{t-k} + \epsilon_t y_{t-k}$$

$$E y_t y_{t-k} = \phi_1 E y_{t-1} y_{t-k} + \phi_2 E y_{t-2} y_{t-k} + \dots + \phi_p E y_{t-p} y_{t-k} + E \epsilon_t y_{t-k}$$

$$\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p}$$


pro $k \in \mathbb{N}$

Soustava prvních p těchto rovnic ($k = 1, \dots, p$) se nazývá *Yuleova-Walkerova soustava rovnic*, jejím řešením získáme hodnoty parametrů ϕ_1, \dots, ϕ_p vyjádřené pomocí hodnot autokorelační funkce ρ_1, \dots, ρ_p , které umíme odhadnout.

Procesy AR(p): parciální autokorelační funkce

$$\rho_{kk} = 0 \quad \text{pro } k > p$$

Odhad PACF pro data simulovaná z procesu AR(1) s parametrem $\phi = 0,9$:



Procesy ARMA(p, q)


Smíšeným procesem řádu p a q rozumíme posloupnost náhodných veličin $\{y_t\}$ danou předpisem

$$y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \theta_2 \epsilon_{t-2} + \dots + \theta_q \epsilon_{t-q},$$

kde $\{\epsilon_t\}$ je bílý šum ($\epsilon_t \sim N(0, \sigma^2)$),

$\phi_1 \in \mathbb{R}, \dots, \phi_p \in \mathbb{R}$ a $\theta_1 \in \mathbb{R}, \dots, \theta_q \in \mathbb{R}$ jsou parametry procesu.

Box, Jenkins a nestacionarita




Procesy ARIMA(p, d, q)

diferencování procesu:



$$\begin{aligned}\Delta y_t &= y_t - y_{t-1} \\ \Delta^2 y_t &= \Delta(\Delta y_t) = \Delta y_t - \Delta y_{t-1} = \\ &= (y_t - y_{t-1}) - (y_{t-1} - y_{t-2}) = y_t - 2y_{t-1} + y_{t-2} \\ &\dots\end{aligned}$$

Proces $\{y_t\}$, jehož d -tá diference je smíšeným procesem ARMA(p, q) se označuje jako proces ARIMA(p, d, q).


Po 1. diferencování



ACF a PACF diferencované řady



Tajenka



Řada byla generována pomocí generátoru náhodných čísel jako proces $ARIMA(1,1,0)$, kde parametr $\phi = 0,7$.

Box, Jenkins a sezónnost

$$\begin{array}{cccc} y_1 & y_{L+1} & y_{2L+1} & \dots \\ y_2 & y_{L+2} & y_{2L+2} & \dots \\ \vdots & \vdots & \vdots & \\ y_L & y_{2L} & y_{3L} & \dots \end{array}$$

- ▶ Dlouhodobý aspekt

$$y_t = \phi_1 y_{t-L} + \phi_2 y_{t-2L} + \dots + \phi_P y_{t-PL} + \eta_t + \Theta_1 \eta_{t-L} + \dots + \Theta_Q \eta_{t-QL}$$

- ▶ Krátkodobý aspekt

$$\eta_t = \varphi_1 \eta_{t-1} + \varphi_2 \eta_{t-2} + \dots + \varphi_p \eta_{t-p} + \epsilon_t + \theta_1 \epsilon_{t-1} + \dots + \theta_q \epsilon_{t-q}$$

$\{\epsilon_t\}$ je bílý šum

SARIMA $(p, 0, q) \times (P, 0, Q)_L$

obecněji SARIMA $(p, d, q) \times (P, D, Q)_L$