



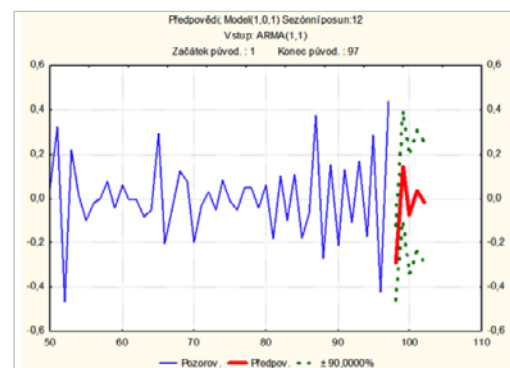
Pokročilá práce s časovou řadou – odhad řádu ARMA

V této části nahlédneme do statistického zpracování časových řad, ukážeme si jak odhadnout řád autokorelace $AR(p)$ a řád klouzavých součtů $MA(q)$ u stacionární časové řady. V jednom z dalších příspěvků si nastíníme, jak by se taková časová řada modelovala pomocí neuronové sítě, v následujícím příspěvku Vás však seznámíme s ověřováním předpokladů v regresních modelech pomocí vizualizace.


Nyní zpět k AR a MA procesům, neboť vysvětlovat dnešní hodnotu (návštěvnost, cenu, zaměstnanost atd.) hodnotou včera, před týdnem, před měsícem je v praxi velmi obvyklé a ve spoustě jevů, ať už ekonomických nebo přírodních, lze tyto vazby vysledovat.

Odhad řádu ARMA

Před samotným odhadem koeficientů $ARMA$ modelu musíme nejprve určit počet a typ $ARMA$ parametrů. Jako hlavní nástroj pro identifikaci parametrů modelu (p, q) nám poslouží autokorelační funkce (ACF) a parciálně autokorelační funkce (PACF). V určitém počtu případů není identifikace zcela jednoznačná a vyžaduje také experimentování s alternativními modely. Většinu průběhů empirických časových řad můžeme dostatečně dobře identifikovat pomocí pravidel odvozených z vlastností ACF a PACF uvedených v následujícím odstavci:

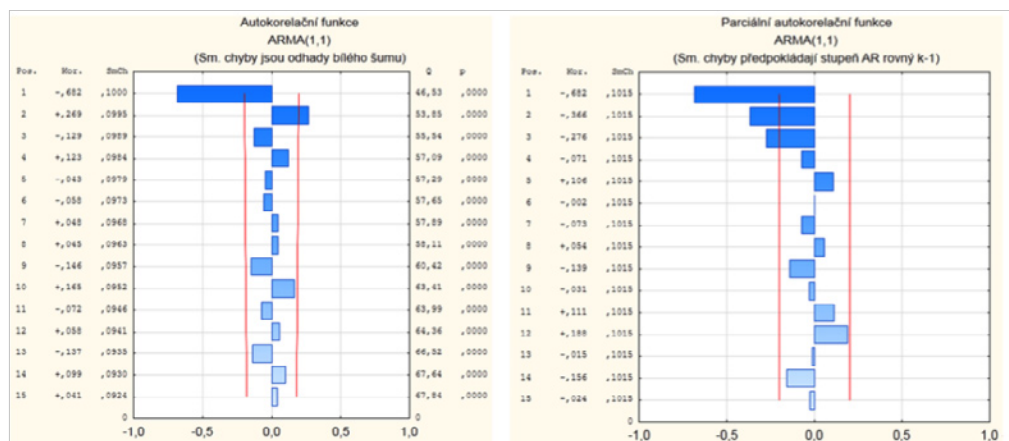


1. $AR(1)$: ACF exponenciálně klesá k nule, PACF má pouze jeden vrchol na pozici 1.
2. $AR(2)$: ACF má sinusový průběh nebo několik exponenciálních poklesů, PACF má vrcholy na pozicích 1 a 2. Na dalších pozicích nejsou již korelace.
3. $MA(1)$: ACF má pouze jeden vrchol na pozici 1, PACF jde exponenciálně k nule.
4. $MA(2)$: ACF má dva vrcholy na pozici 1 a 2, bez dalších korelací, PACF má sinusový průběh, nebo exponenciálně tlumený průběh.
5. $ARMA(1, 1)$: ACF má exponenciální pokles začínající na pozici 1, PACF má oscilující pokles začínající na pozici 1.
6. $ARMA(1, 1)$: ACF má oscilující pokles začínající na pozici 1, PACF má exponenciální pokles začínající na pozici 1.
7. $ARMA(p, q)$: ACF přímý nebo oscilující pokles k nule začínající na pozici q . PACF přímý nebo oscilující pokles k nule začínající na pozici p .

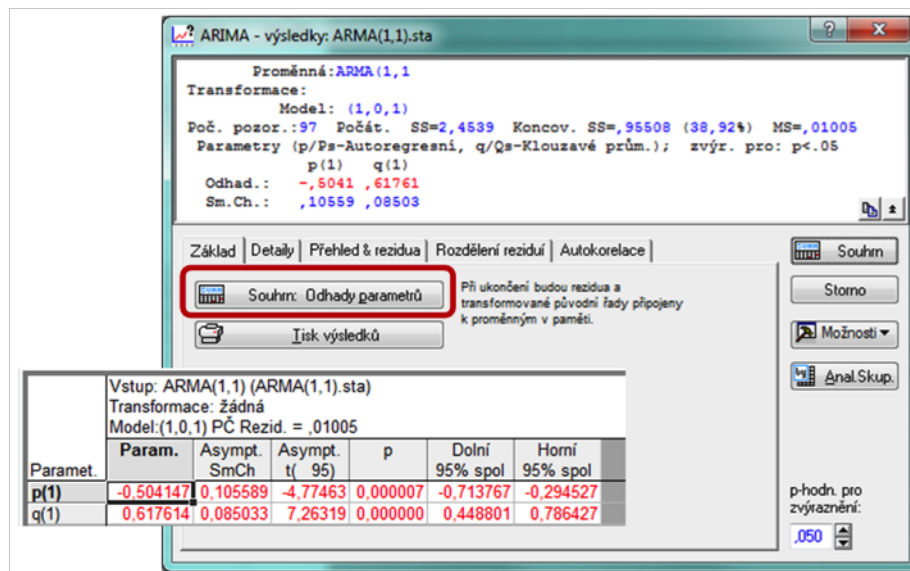


V softwaru *STATISTICA*: **Statistiky → Pokročilé lineární/nelineární modely → Časové řady/Predikce → ARIMA & autokorelační funkce (po výběru proměnné) → Záložka autokorelace**

Ukažme si příklad stacionární časové řady. Pro odhad řádu procesu použijeme výše uvedená pravidla pro identifikaci pomocí ACF a PACF. Modelovanou časovou řadu zobrazuje obrázek výše s naznačenou předpovědí budoucích hodnot pomocí modelu ARMA (1, 1). Podle ACF a PACF na obrázku určíme, že zkoumaná časová řada je ARMA (1, 1) proces.



Pomocí modulu časových řad v softwaru *STATISTICA* odhadneme koeficienty ARMA (1, 1) modelu pro zkoumanou časovou řadu:

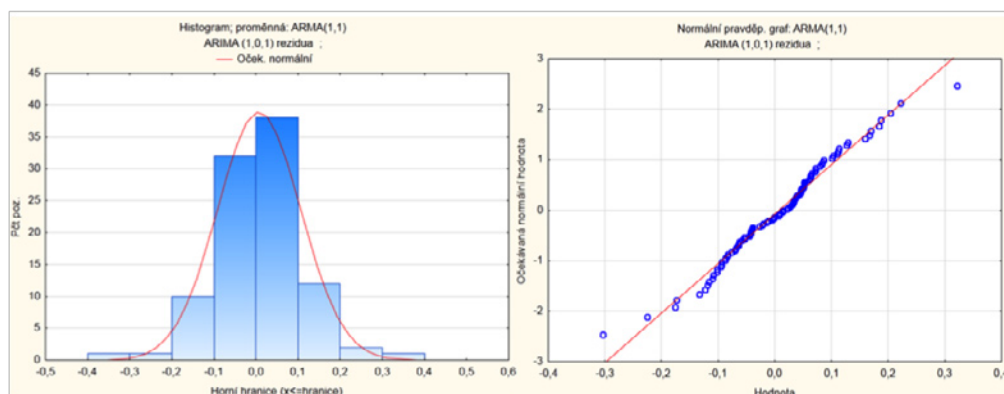


Parametry ARMA (1, 1) jsou signifikantní na 95% hladině významnosti, odhadnutý model má tvar:

$$X_t = -0,504 X_{t-1} + Z_t + 0,617 Z_{t-1},$$

(0,105) (0,085)

příčemž hodnoty v závorkách pod odhady koeficientů jsou jejich odhadnuté směrodatné chyby. Po odhadu parametrů musíme ověřit, jestli jsou splněny požadavky normality a nekorelovanosti reziduí. Normalitu ověříme na záložce **Rozdělení reziduí**, pomocí histogramu s proložením běžného rozdělení a běžným pravděpodobnostním grafem (obr. vpravo).



Na záložce **Autokorelace** ověříme oba korelogramy. Z ACF a PACF reziduí je zřejmá jejich vzájemná nekorelovanost. Rozdělení reziduí se blíží normálnímu rozdělení. Z analýzy reziduí je vidět, že odhadnutý model zahrnuje všechny podstatné parametry zkoumané časové řady. Odhadnutý ARMA (1, 1) model dobře popisuje zkoumanou časovou řadu.