



SLEZSKÁ
UNIVERZITA
OBCHODNĚ PODNIKATELSKÁ
FAKULTA V KARVÍNÉ

Modely jednorozměrných stacionárních a nestacionárních časových řad

Modely vícerozměrných časových řad

Kauzalita ve finančních časových řadách

2. tutoriál

Finanční ekonometrie

Modely jednorozměrných stacionárních časových řad



Boxova-Jenkinsova metodologie

- Autory této teorie jsou matematici G.E.P. Box a G.Jenkins = Boxova-Jenkinsova metodologie.
- Metodologie především vychází z modelů, které popisují tzv. stochastické procesy, tj. určité fenomény, které se vyvíjejí v čase plně podle zákonů pravděpodobnosti.
- Tyto modely pracují s náhodnými proměnnými a (většinou) nepředpokládají přítomnost nějaké deterministické složky ve funkčním vztahu.
- Pro stochastický proces je typické, že nelze s jistotou předpovědět jeho budoucí vývoj. Maximálně se může odhadnout pravděpodobnosti jeho budoucího chování.



Boxova-Jenkinsova metodologie

- Metodologie Boxe a Jenkinse je pojata velmi obecně a modely v ní vytvořené jsou schopny popisovat řadu reálných situací.
- Modely, s nimiž se pracuje, jsou schopny popisovat stochastické trendy a dokonce i sezónnost.
- Metodologie lépe totiž popisuje ty časové řady, jejichž vývoj je mnohem dynamičtější, tj. dochází v nich častěji k prudším nebo náhlým změnám.
- Metodologie tedy poskytuje v určitém slova smyslu „pružnější“ modely, jež se lépe adaptují na vývoj sledovaného procesu.



Boxova-Jenkinsova metodologie

- Kromě toho, klasická teorie vychází z regresní analýzy, která dává optimální model v případě, kdy jsou splněny klasické podmínky formulované pro náhodnou složku modelu.
- Tyto podmínky zahrnují předpoklad, že náhodné složky modelu jsou vzájemně nekorelované, tj. že závislé proměnné y_t jsou vzájemně nekorelované.
- Pokud tento předpoklad splněn není, zhoršují se vlastnosti odhadnutých parametrů regresní funkce a modelování se celkově komplikuje.
- V případě Boxovy-Jenkinsovy metodologie se naopak vychází právě ze zkorelovanosti y_t , která je základem pro budování konkrétního modelu.

Výhody a nevýhody Boxovy-Jenkinsovy metodologie

- **Výhody :**
 - stochastické modely typu ARMA jsou značně flexibilní, takže jsou použitelní i pro časové řady velmi obecných průběhů,
 - lze doložit nepřeberné množství úspěšných aplikací,
 - dostupný software,
 - zatím neexistuje lepší rutinní nástroj pro analýzu časově závislých pozorování.
- **Nevýhody:**
 - Boxova-Jenkinsova metodologie vyžaduje delší časové řady (minimálně 50 pozorování),
 - bez software je nerealizovatelná,
 - obtížná praktická interpretace zkonstruovaných modelů.



Autokorelační funkce

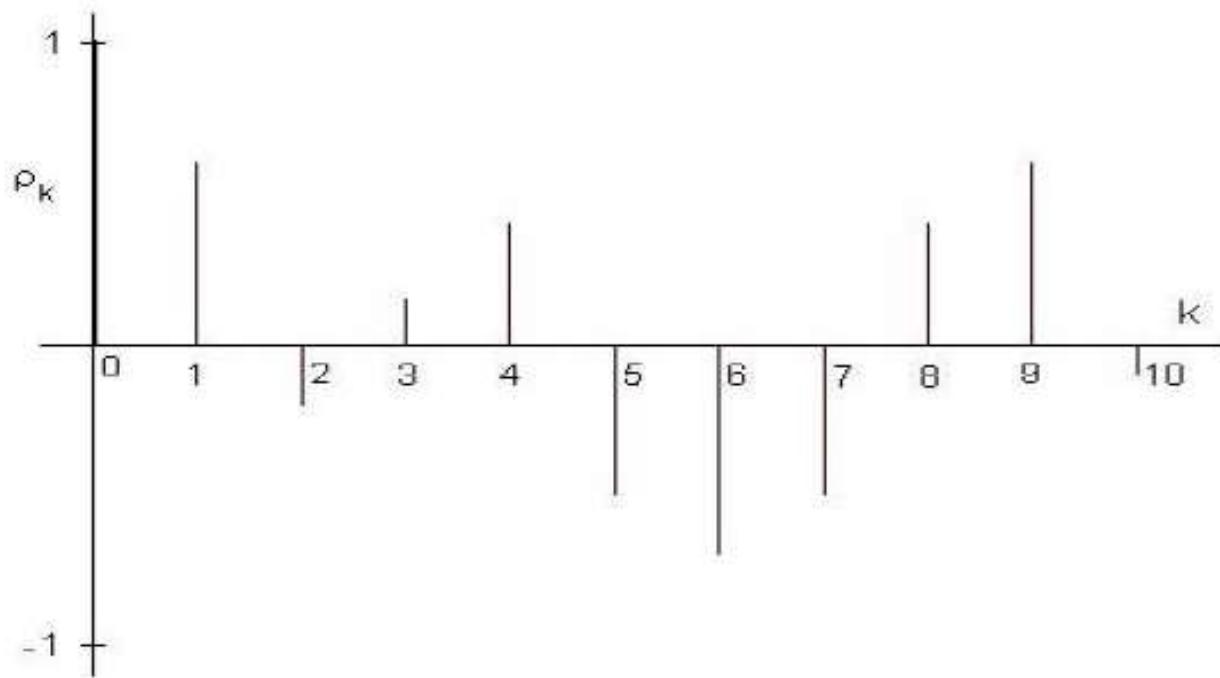
- Autokorelační funkce (ACF) podává informaci o síle lineární závislosti mezi veličinami y_t a y_{t-k} .
- Autokorelační funkce pro zpoždění k (autokorelace pro zpoždění k) se definuje jako

$$\rho_k = \frac{\gamma_k}{\gamma_0} = \frac{\gamma_k}{\sigma_y^2} \quad k = \dots, -1, 0, 1, \dots$$

- Autokorelační funkce je symetrická kolem $k = 0$, proto je vyjadřovaná pouze pro $k > 0$. Nabývá hodnoty v intervalu $<-1; 1>$.
- Graf autokorelační funkce se nazývá koreogram. Koreogram popisuje pomocí několika hodnot krátkodobou dynamiku dané stacionární řady (dlouhodobou dynamiku naproti tomu zachycuje většinou trend).



Korelogram





Parciální autokorelační funkce

- Korelace mezi dvěma náhodnými veličinami je často způsobena tím, že obě veličiny jsou korelovány s veličinou třetí.
- Značná část korelace mezi veličinami X_t a X_{t-k} může být tedy způsobena jejich korelací s veličinami $X_{t-1}, X_{t-2}, \dots, X_{t-k+1}$.
- Parciální autokorelace (PACF) podávají informaci o korelacích veličin X_t a X_{t-k} očištěnou o vliv veličin ležících mezi nimi.



Proces bílého šumu (White Noise)

- Jestliže je stochastický proces $\{a_t\}$ řadou nekorelovaných náhodných veličin jednoho pravděpodobnostního rozdělení s konstantní střední hodnotou (obvykle nulovou), konstantním rozptylem, pro všechna $k \neq 0$, potom se označuje jako *proces bílého šumu*.



Proces bílého šumu

- Základním rysem procesu bílého šumu tedy je, že ACF a PACF jsou identicky nulové.
- I když se tento proces prakticky nevyskytuje, hraje důležitou roli jako základní stavební prvek při výstavbě modelů časových řad.
- Proces bílého šumu se označuje jako gaussovský, je-li jeho sdružené pravděpodobnostní rozdělení normální.



Autoregresce, řády autoregresních procesů (AR)

- Proces typu AR (řádu p): $p = 1, 2, \dots, p$
 - příklad: AR(1), AR(3) atd.
- základní forma procesu AR:

$$y_t = \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} + \varepsilon_t$$

- Charakteristické kořeny leží vně jednotkového kruhu.
- Při zjištění, že tyto podmínky nejsou splněny, proces AR není invertibilní a nemůže být taktéž stacionární!
- Součet hodnot parametru alfa musí být menší než jedna. Pokud jsou jedna nebo se blíží 1, jsou nestacionární.
- Kořeny polynomu musí být v absolutní hodnotě větší jedna.
- Podmínka stacionarity: kořeny polynomu leží v rovině vně jednotkového kruhu.
- AR(p) je tedy automaticky invertibilním procesem.

Klouzavé (pohyblivé) průměry (MA), řády procesů MA

- MA(1): $y_t = e_t - \gamma_1 e_{t-1}$
- nebo pomocí operátoru zpětného posunutí: $y_t = (1 - \gamma_1 L) e_t$
- Modely MA(i) mají vždy konečný řád, to znamená, že jsou vždy stacionární.
- Proces klouzavých průměrů je automaticky stacionární.
- Naproti tomu není automaticky invertibilní.
- Podmínka invertibility: když kořeny polynomu leží vně jednotkového kruhu.



Smíšený model ARMA

- Proces ARMA lze identifikovat podle toho, že jeho autokorelační funkce vypadá jako autokorelační funkce procesu AR a jeho parciální autokorelační funkce vypadá jako parciální autokorelační funkce procesu MA.
- Obojí však platí s výjimkou prvních několika hodnot těchto funkcí.
- Tento návod platí v populaci a tvar výběrových korelací se může lišit, takže nevždy je možné se těmito doporučeními řídit.
- Výběrové korelace poskytují při výběru konkrétního modelu pouze hrubou orientaci.
- Smíšený proces řádu p a q značený jako ARMA (p,q) je definován jako:

$$y_t = \phi_1 y_{t-1} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}.$$



Smíšený model ARMA

- Proces ARMA (p,q) má vlastnosti:
 - Podmínka stationarity modelu ARMA (1,1) je totožná s podmínkou stacionarity modelu AR(1), podmínka invertibility je totožná s podmínkou invertibility modelu MA(1).
 - Střední hodnota procesu je nulová.
- Při praktických aplikacích Box-Jenkinsovy metodologie se obvykle vystačí s procesy, pro něž $p+q \leq 2$, tj. s autoregresními procesy maximálně druhého řádu a procesy klouzavých součtů také do maximálně druhého řádu.



Smíšený model ARMA

- Výstavbu modelu lze rozdělit do tří základních kroků:
 - Identifikace modelu – jaký typ modelu vybrat (AR, MA, ARMA) a explicitně určit řád modelu
 - Odhad parametrů modelu
 - Ověřování modelu – má potvrdit nebo zamítnout adekvátnost modelu

Modely jednorozměrných nestacionárních časových řad



Nestacionární časové řady

- V ekonomii a financích se často setkáváme s časovými řadami tvořeny nestacionárními stochastickými procesy.
- Nestacionarita procesu může být způsobena buď v čase se měnící střední hodnotou, nebo v čase se měnícím rozptylem procesu.

Náhodná procházka (Random Walk Process)

- Proces náhodné procházky je tvořen kumulováním náhodných veličin tvořících proces bílého šumu.
- Proces náhodné procházky se také nazývá *integrovaný proces*. Protože jeho první diference je proces bílého šumu, nazývá se integrovaný proces řádu jedna a označuje se $I(1)$.
- Náhodná procházka je nestacionární proces. Zdrojem nestacionarity je stochastický trend $\sum_{j=1}^t a_j$.



Model ARIMA

- Modely *ARIMA* se hodí pro popis celé řady nestacionárních procesů.
- Model *ARIMA*(p,d,q) má tři parametry
 - první udává stupeň autoregresního operátoru,
 - druhý počet diferencí aplikovaných na původní časovou řadu
 - a třetí udává stupeň *MA* operátoru.
- Pracovat s modely *ARIMA* tedy znamená d -krát differencovat původní časovou řadu a pak s ní pracovat pomocí modelu *ARMA*.
- Odhad parametrů i verifikace modelu se tak vlastně aplikuje na výsledný *ARMA* model.



Model ARIMA

- Pokud jde o identifikaci modelu *ARIMA*, používají se opět autokorelační a parciální autokorelační funkce, které se však konstruuují pro různé úrovně d , tj. konstruuují se pro původní časovou řadu, pro jedenkrát zdiferencovanou časovou řadu, dvakrát zdiferencovanou časovou řadu, atd.
- Pro nestacionární procesy je typické, že jejich korelogram vykazuje jen velmi pozvolný pokles korelace s rostoucím k .
- Pokud taková situace nenastává, nemá smysl řadu diferencovat, pokud nastává, je třeba konstruovat více korelogramů pro různé úrovně d , dokud korelogram nebude mít pro konkrétní $d = d^*$ již známý tvar typický pro *modely ARMA(p,q)*.
- Následně je pak třeba vyzkoušet k analýze procesu model *ARIMA(p, d*, q)*.

Modely sezónních časových řad (SAR, SMA, SARMA, resp. SARIMA)

- Důležitou vlastností mnoha krátkodobých časových řad je sezonnost.
- Sezonní složkou časových řad se rozumí periodické kolísání, které má systematický charakter.
- Toto kolísání se u makroekonomických časových řad odehrává během jednoho kalendářního roku a každý rok se ve stejné nebo modifikované podobě opakuje.
- U denních finančních časových řad se však také může projevovat pravidelné periodické kolísání, např. ve dnech během týdne.

Modely sezónních časových řad (SAR, SMA, SARMA, resp. SARIMA)

- Tradičním předpokladem je, že sezonní složka časové řady má pravidelný deterministický charakter.
- Tento typ systematičnosti lze dále klasifikovat na stacionární a integrovaný (jedná se o analogii nesezonních stacionárních a integrovaných řad).

Frakcionálně integrované procesy (tzw. dlouhá paměť), frakcionální diference, model ARFIMA

- Při analýze stacionárních procesů ARMA se došlo k závěru, že hodnoty ACF těchto modelů vykazují s rostoucím zpožděním exponenciální pokles.
- To znamená, že náhodné veličiny, které jsou od sebe časově vzdálené, můžeme pokládat za téměř nekorelované.
- Avšak v praxi se také můžeme setkat s časovými řadami, tvořenými stacionárními procesy, jejichž i velmi časově vzdálené náhodné veličiny jsou poměrně silně korelované.

Frakcionálně integrované procesy (tzw. dlouhá paměť), frakcionální diference, model ARFIMA

- Na tento jev u časových řad v hydrologii poprvé upozornil Hurst (1951, 1957).
- Podobné vlastnosti byly později nalezeny také u ekonomických, zejména pak u finančních časových řad.
- Časové řady s touto vlastností se označují jako *řady s dlouhou pamětí* a jejich generující stochastické procesy jako procesy s dlouhou pamětí.
- Modely časových řad s dlouhou pamětí se v ekonometrii pravidelně objevují od 80. let minulého století.
- Jejich charakteristikou vlastností je, že hodnoty ACF neklesají s rostoucím zpožděním exponenciální, ale hyperbolicky.

Frakcionálně integrované procesy (tzw. dlouhá paměť), frakcionální diference, model ARFIMA

- Toto chování je možné modelovat pomocí procesů ARFIMA(p,d,q), které jsou zobecněním modelů ARIMA(p,d,q).
- V procesech ARFIMA není kladeno žádné omezení na řád differencování a d může být libovolné reálné číslo, které se označuje jako frakcionální parametr.



Diagnostika modelu

- Diagnostika v rámci Boxovy-Jenkinsovy metodologie spočívá v tom, že pomocí různých diagnostických nástrojů ověřujeme (verifikujeme) adekvátnost zkonstruovaného modelu, tj. kontrolujeme, zda je skutečně kompatibilní s analyzovanými daty.
- Přitom se zaměřujeme zejména na:
 - Kontrola stationarity
 - Kontrola struktury ARMA
 - Grafická prohlídka vypočteného bílého šumu
 - Testování nekorelovanosti pro vypočtený bílý šum



Kritéria pro volbu modelu

- Při analýze časové řady můžeme dojít k závěru, že existuje několik akceptovatelných modelů. Někdy je poměrně jednoduché z této množiny vybrat ten nejlepší. Jsou však situace, kdy tuto jistotu nemáme a výběr nejlepšího modelu je velice obtížný.
- Pro řešení bylo navrženo několik dodatečných kritérií. Tato kritéria jsou založena na porovnání reziduů jednotlivých modelů prostřednictvím souhrnných statistik. Předpokládají přitom, že řád diferencování byl zvolen správně.
- **Jako nevhodnější se vybírá model minimalizující hodnoty těchto kritérií.**
 - Akaikeho kritéria AIC a BIC
 - Schwartzovo bayesovské kritérium SBC
 - Hannanovo-Quinnovo kritérium HQ

Modely vícerozměrných časových řad

Modely vektorové autoregresie (VAR, VMA, VARMA, VARIMA)

- Model vektorové autoregresie VAR (vector autoregression) je přirozeným zobecněním jednorozměrného autoregresního procesu.



Vektorova autoregresce (VAR)

- Při zkoumání dynamických vztahů několika časových řad ekonomických veličin je nutné přihlížet k jejich případné závislosti.
- Strukturní dynamické modely simultánních rovnic obsahující různě zpožděné hodnoty zahrnutých proměnných – předpokladem je apriorní klasifikace proměnných na endogenní a exogenní a dodržení podmínek identifikace jednotlivých rovnic.
- Alternativní přístup vycházející z vektorové autoregresce (VAR).



Vektorova autoregresce (VAR)

- Podstatou VAR je, že proměnné ve všech zkoumaných časových řadách jsou náhodné a simultánně závislé, tedy mají endogenní charakter, přičemž jejich známá maximální délka zpoždění je stejná.
- Modely VAR jsou vhodné k předpovědím, při analýze hospodářské politiky apod.
- Jsou zobecněním AR modelů na časové řady více proměnných a jejich předností je relativně jednoduchý odhad parametrů OLS.



Konstrukce VAR modelu

- 1. Transformace dat na stacionární časové řady
- 2. Volba proměnných modelů a maximální délky zpoždění.
- 3. Zjednodušení modelu redukcí maximálního zpoždění, popř. restrikcí parametrů.
- 4. Ortogonalizace náhodných složek, resp. reziduí.

Modelování VAR(1) modelu

- Nejjednodušší časové řady více proměnných je autoregresní model s dvěma závislými proměnnými $y_{1,t}$ a $y_{2,t}$, kde $t = 1, \dots, T$.
- Vývoj řady lze vysvětlit společnou minulostí těchto proměnných.
- Tedy vysvětlující proměnné v nejjednodušším modelu jsou $y_{1,t-1}$ a $y_{2,t-1}$.
- VAR(1) se zpožděnými hodnotami pro každou proměnnou je určen následovně:

$$y_{1,t} = \alpha_{11}y_{1,t-1} + \alpha_{12}y_{2,t-1} + \varepsilon_{1,t}$$

$$y_{2,t} = \alpha_{21}y_{1,t-1} + \alpha_{22}y_{2,t-1} + \varepsilon_{2,t}$$

- Maticové značení:

$$\mathbf{y}_t = \mathbf{A}_1 \mathbf{y}_{t-1} + \boldsymbol{\varepsilon}_t$$

$$\mathbf{A}_1 = \begin{pmatrix} \alpha_{11} & \alpha_{12} \\ \alpha_{21} & \alpha_{22} \end{pmatrix}$$



Diagnostika modelu VAR

- Zda odhadnutý model skutečně splňuje podmínu stacionarity, tj. zda hodnoty kořenů odhadnutého autoregresního polynomu leží vně jednotkového kruhu v komplexní rovině.
- Zda je časová nekorelovanost v odhadnuté reziduální složce (tj. ve vypočteném bílém šumu).



Výhody VAR modelu

- není třeba specifikovat, které proměnné jsou endogenní a exogenní, protože v klasickém modelu VAR jsou všechny proměnné endogenní,
- má bohatší strukturu než jednorozměrné AR modely, protože proměnná zde závisí na dalších hodnotách než jen na svých vlastních zpožděných hodnotách a bílém šumu (soubor jednorozměrných AR modelů postupně pro všechny uvažované proměnné je jen speciálním případem VAR za platnosti jistých omezení),
- pokud se používá jen redukovaný tvar VAR, na jehož pravé straně figurují pouze zpožděné hodnoty a jsou tedy v daném čase predeterminované, lze pro odhad použít klasický OLS-přístup.

Problémy spojeny s používáním VAR modelů

- aplikace VAR je někdy příliš technická bez nalezení hlubšího opodstatnění (zvlášť když se používá ve smyslu data mining),
- v praxi většinou vznikne problém, jaký řád p modelu použít (tj. do jakých zpoždění jít),
- i při nižších řádech p může být počet parametrů modelu $\text{VAR}(p)$ značný,
- konstrukce modelu VAR předpokládá, že všechny jeho složky (tj. jednorozměrné AR procesy) jsou stacionární; transformace používané pro dosažení stationarity (např. diferencování) však mohou znamenat ztrátu informace o dlouhodobých rovnovážných vztazích mezi jednotlivými řadami.

Problémy spojeny s používáním VAR modelů

- Výhodné vlastnosti VAR modelu platí pouze za předpokladu, že všechny časové řady v něm obsažené jsou stacionární. To znamená, že uvažované řady nesmí obsahovat trendy, pravidelné sezónní výkyvy a jejich variance se nesmí v čase měnit.
- Výstupem z VAR modelu jsou hodnoty vlastních koeficientů, dále pak F-testy nulových hypotéz o neexistenci Grangerovy kauzality mezi proměnnými a dekompozice rozptylu.
- VAR model umožňuje také studium dynamických vlastností časových řad.
- Dekompozice rozptylu přisuzuje napozorovanou varianci dané veličiny její vlastní minulé dynamice a dynamice ostatních proměnných.

Grangerova kauzalita ve VAR modelu

- Postup:
 - Sestavení modelu
 - Určení optimální délky zpoždění
 - Diagnostika modelu
 - Grangerova kauzalita
- Grangerova kauzalita
 - Nulová hypotéza: proměnná A nepřispívá k vysvětlení vývoje proměnné B

Kauzalita ve finančních časových řadách

Kauzalita ve finančních časových řadách

- Jedním z problémů, kterým se zabývá ekonometrie, je zkoumání kauzálních vztahů mezi ekonomickými časovými řadami.
- Granger (1969) definoval pojetí kauzality, při jehož praktickém ověření lze použít VAR modely.
- Základní myšlenka spočívá v této tezi:
 - Působí-li řada Z na řadu Y , pak by řada Z měla pomoci zlepšit předpovědi řady Y .



Korelační analýza

- Korelace znamená vzájemný lineární vztah mezi znaky či veličinami.
- Míru korelace vyjadřuje korelační koeficient, který může nabývat hodnot v intervalu $<-1;1>$.
- Korelace znamená vzájemný vztah mezi dvěma procesy nebo veličinami. Pokud se jedna z nich mění, mění se korelativně i druhá a naopak.
- Pokud se mezi dvěma procesy ukáže pozitivní či negativní korelace, je pravděpodobné, že na sobě závisejí, nelze z toho však ještě usoudit, že by jeden z nich musel být příčinou a druhý následkem. To samotná korelace nedovoluje rozhodnout.



Korelační koeficient

- Vztah mezi znaky či veličinami x a y může být kladný, pokud (přibližně) platí $y = kx$, nebo záporný ($y = -kx$).
- Hodnota korelačního koeficientu **-1** značí zcela nepřímou závislost.
- Hodnota korelačního koeficientu **+1** značí zcela přímou závislost.
- Pokud je korelační koeficient roven **0** (nekorelovanost), pak mezi znaky není žádná statisticky zjistitelná lineární závislost. Je dobré si uvědomit, že i při nulovém korelačním koeficientu na sobě veličiny mohou záviset, pouze tento vztah nelze vyjádřit lineární funkcí, a to ani přibližně.

Rozdíl mezi korelační závislostí a kauzální závislostí

- Pokud jsou dvě náhodné veličiny korelačně závislé, pak to znamená, že mezi těmito náhodnými veličinami může existovat kauzální závislost.
- Nelze ale rozlišit, zda jde o kauzální závislost bezprostřední, kdy změny jedné veličiny podmiňují změny druhé, nebo o kauzální závislost zprostředkovanou.
- Existence korelační závislosti dvou náhodných veličin nemůže být důkazem toho, že mezi nimi existuje kauzální závislost.

Rozdíl mezi korelační závislostí a kauzální závislostí

- Hindls (2007) upozorňuje na problem *zdanlive korelace*, kdy pozorujeme silnou závislost mezi proměnnými i v případě, že závislost ve skutečnosti buď téměř, nebo vůbec neexistuje. K tomuto jevu může docházet tehdy, když obě proměnné vykazují stejný vývojový trend v čase nebo jsou latentně ovlivňovány jinou třetí proměnou, s niž jednotlivě nebo současně souvisí zkoumané proměnné.
- Korelace může vznikat z několika důvodů. Je-li však mezi dvěma proměnnými vzajemna zavislost, neznamena to, že mezi nimi také existuje kauzální (tedy příčinný) vztah. Důležité je také vědět, jak dosažené výsledky empirického zkoumaní správně interpretovat. Správná interpretace vyžaduje nejen dobré intuitivní znalosti o tom, co vlastně korelace je, ale také dobrou znalost zkoumaného ekonomického problému (Koop, 2006; Němec, 2009).



Grangerova kauzalita

- Grangerova kauzalita – ukazuje, jak zpožděné hodnoty proměnné x zlepšují schopnost predikovat dnešní hodnoty y .
- V testech je za kauzální působení X na Y považována situace, kdy vysvětlení Y pomocí historie (minulých hodnot) Y a současně historie X je „dostatečně“ lepší než pouhé vysvětlení Y podle své vlastní historie.
- Za slovem „dostatečně“ se skrývá teorie pravděpodobnosti.
- Grangerovu kauzalitu nelze zaměňovat či ztotožňovat s běžně chápaným pojmem příčinné závislosti, neboť podstatou testování kauzality v Grangerově pojetí není nic jiného, než ověření, **zda změny určité proměnné předcházejí změně jiné proměnné, nikoliv která veličina je příčinnou a která následkem.**



Test Grangerovy kauzality

- Používá se velice často v případě, když testujeme, která z množiny faktorů, kterou analyzujeme je veličinou exogenní.
- Nejedná se o pravou kauzalitu (o pravou akci, reakci). Ale jedná se o to, zda jedna veličina přispívá k vysvětlení vývoje té druhé veličiny. Nikoliv že by ji determinovala, pouze jestli přispívá k jejímu vývoji.
- Protože využívá pouze dvě proměnné, jsou to dvě rovnice.
- Vyžaduje stacionární časové řady.



Test Grangerovy kauzality

- Při statistickém ověření výskytu Grangerovy kauzality jde o zjištění, zda zahrnutí dodatečné proměnné (jejích různě zpožděných hodnot) do regresního modelu, statisticky významně zvýší vypovídací schopnost regresní závislosti.
- H0 (nulová hypotéza):
 - Proměnná X neovlivňuje proměnnou Y v Grangerově smyslu
- H1(alternativní hypotéza) :
 - Proměnná X ovlivňuje proměnnou Y v Grangerově smyslu



Praktický příklad

- Určete kauzalitu mezi MB a M2 (data „MB_M3.xls“)
- Určete kauzalitu mezi úrokovými sazbami a výnosy státních dluhopisů (data: „Kauzalita.xls“)
- Určete kauzalitu mezi dvěma akciovými indexy
 - Stáhněte z Finance Yahoo libovolné dva akciové indexy či akciový index a akcie v něm obsaženou a určete kauzalitu mezi nimi
- Kauzalitu měřte pomocí:
 - Korelační koeficient
 - Grangerova kauzalita

Děkuji za pozornost a
přeji pěkný den ☺