

FINANČNÍ ČASOVÉ ŘADY

Až dosud popisované modely časových řad byly svou podstatou převážně lineární, popř. je bylo možno linearizovat jednoduchou (obvykle logaritmickou) transformací. Mnoho vztahů ve financích je však vnitřně nelineárních (příkladem buď závislost opční prémie na příslušných vstupech, vybalancování velikosti výnosu a rizika apod.). Podstatu finančních časových řad proto v řadě situací lépe vystihnou **nelineární modely**.

Lineární modely časových řad totiž nejsou zpravidla schopny zohlednit některé typické vlastnosti finančních časových řad, jimiž jsou zejména:

- **Leptokurtické rozdělení**: míry zisku finančních aktiv mívají rozdělení, která jsou více špičatá kolem střední hodnoty/modu, přičemž na koncích je jejich hustota větší a v ramenech menší než u normálního rozdělení se stejnou střední hodnotou a rozptylem (lze u nich rozpoznat „užší pas a těžší konce) s větší špičatostí než u normálního rozdělení. Význačnou charakteristikou bývá zde kladný koeficient špičatosti. Jako příklad typické podoby leptokurtického rozdělení by mohlo sloužit t-rozdělení o malém počtu stupňů volnosti.
- **Shlukování volatility** [*volatility clustering, v. bunching, v. pooling, v. busting*]; Jedná se o tendenci volatility finančních trhů objevovat se ve shlucích vysokých a nízkých volatilit, tj. velké resp. malé výkyvy v míře zisku lze očekávat spíše po větších resp. menších předchozích výkyvech (někdy se zde mluví o “výbuších” [bursts])
- **Pákový efekt** [*leverage effect*]: tento jev rovněž souvisí jako v předchozím případě s kolísáním volatility v čase, s kterým se lineární modely nejsou schopny uspokojivě vypořádat. Konkrétně se jedná o tendenci volatility zvětšit se více po cenovém poklesu, než po cenovém nárůstu souměřitelné velikosti.

KLASIFIKACE NELINEÁRNÍCH MODELU časových řad

Pokud se omezíme na **ryze stochastické** [purely stochastic] modely časových řad (tj. bez deterministických trendů a periodicit), pak za obecný zápis nelineárního modelu časové řady lze považovat

$$(6.1) \quad y_t = f(e_t, e_{t-1}, e_{t-2}, e_{t-3}, \dots) ,$$

kde f je nelineární funkce nekorelovaných, stejně rozdělených náhodných veličin e_t s nulovou střední hodnotou označovaných podle kontextu jako **předpovědní chyby** nebo **odchyly od podmíněné střední hodnoty** nebo **šoky** či **inovace** apod.

Speciálním případem může být již zmíněný lineární proces

$$(6.2) \quad y_t = e_t + \sum_{i=1}^{\infty} \psi_i e_{t-i} ,$$

k jehož existenci a stacionaritě např. stačí předpokládat $\psi_1^2 + \psi_2^2 + \dots < +\infty$. (jinou možností je dosažení téhož předpokladem $|\psi_1| + |\psi_2| + \dots + |\psi_3| < +\infty$)).

V obecném případě zápisu (6.1) však není nelineární proces přímo aplikovatelný, protože může obsahovat nekonečný počet parametrů. Proto se v literatuře dává přednost specifičtějšímu tvaru zapsanému pomocí podmíněných momentů prvních dvou řádů. Např. už stacionární AR(1)-proces s **nepodmíněnou nulovou střední hodnotou** $y_t = \phi_1 y_{t-1} + \varepsilon_t$ lze zapsat pomocí **podmíněné střední hodnoty** jako

$$(6.3) \quad E(y_t | y_{t-1}) = \phi_1 y_{t-1}$$

Obecně lze v čase t podmiňovat veškerou informací Ω_{t-1} známou do času $t-1$ včetně. Pro názornost si můžeme představit, že tuto minulou informaci generují všechny minulé hodnoty $\{y_{t-1}, y_{t-2}, y_{t-3}, \dots\}$ a $\{e_{t-1}, e_{t-2}, e_{t-3}, \dots\}$ a vhodné funkce těchto hodnot (obecně se takový prostor označuje v topologické symbolice jako σ -algebra generovaná uvedenou množinou hodnot.) Vzhledem k obvyklému omezení se na první dva momenty se pracuje s podmíněnou střední hodnotou μ_t a podmíněných rozptylem σ_t^2 ve tvaru (nelineárních) funkcí informace Ω_{t-1} ,

$$(6.4A) \quad \mu_t = E(y_t | \Omega_{t-1}) = g(\Omega_{t-1})$$

$$(6.4B) \quad \sigma_t^2 = h_t = \text{var}(y_t | \Omega_{t-1}) = h(\Omega_{t-1})$$

kde g_t a h_t jsou vhodné funkce, přičemž $h_t(*) > 0$. I když má časový index odlišovat např. podmíněnou střední hodnotu μ_t od nepodmíněné, korektnější než použité zjednodušené značení by bylo např. $\mu_{t|t-1}$ a $\sigma_{t|t-1}^2$ (Jedná se vlastně o jednorázové předpovědi střední hodnoty a rozptylu daného procesu). Protože platí

$$(6.5) \quad y_t = \mu_t + e_t$$

(což mj. odůvodňuje pojmenování e_t předpovědní chybou), platí navíc pro rozptyl

$$(6.6) \quad \sigma_t^2 = \text{var}(y_t | \Omega_{t-1}) = \text{var}(e_t | \Omega_{t-1})$$

a mluví se obecně o **volatilitě** uvažované řady v čase t . Náhodné veličiny e_t se pak vedle názvů uvedených výše označují jako **odchyly míry zisku** od (podmíněné) střední hodnoty [mean-corrected returns]. Odpovídající obecný zápis nelineárního procesu, který je ve financích využíván nejčastěji, je pak

$$(6.7) \quad y_t = \mu_t + \sigma_t \cdot \varepsilon_t = \mu_t + \sqrt{h_t} \cdot \varepsilon_t = g(\Omega_{t-1}) + \sqrt{h(\Omega_{t-1})} \cdot \varepsilon_t,$$

kde ε_t jsou *i.i.d.* náhodné veličiny s nulovou střední hodnotou a jednotkovým rozptylem. Zřejmě přitom je

$$(6.8) \quad e_t = \sigma_t \cdot \varepsilon_t,$$

přičemž náhodné veličiny e_t jsou sice nekorelované, ale (na rozdíl od ε_t) již nejsou obecně vzájemně nezávislé.

Uvažovaný nelineární model je tedy určen dvěma rovnicemi (6.4A,B). První je tzv. *rovnice střední hodnoty* [mean equation] a druhá je rovnice volatility [volatility equation]. Podle typu těchto rovnic se nelineární procesy klasifikují takto:

- *Procesy nelineární ve střední hodnotě* [nonlinear in mean] (mají nelineární funkci g_t)
- *Procesy nelineární v rozptylu* [nonlinear in variance]: mají časově invariantní (proměnlivou a většinou nelineární) funkci h_t (tj. h_t není v čase konstantní) a velmi často se označují jako *procesy s podmíněnou heteroskedasticitou* [conditional heteroskedasticity].

Obě kategorie se vzájemně kombinují a dále člení na velké množství specifických procesů (viz dále). Lineární modely Boxovy-Jenkinsovy metodologie zavedené dříve jsou speciálním případem (6.7) pro případ, kdy je g_t je lineární funkce a kdy h_t je konstantní funkce.

MODELOVÁNÍ VOLATILITY

Modelování a předpovídání volatility je v centru zájmu mnoha finančních analýz zaměřených jak teoreticky, tak prakticky. To není nijak překvapivé, protože *volatilita* uvažovaná jako *směrodatná odchylka různých ukazatelů výnosnosti či ztrátovosti* je dnes základní mírou rizikovosti finančních aktiv. Důkazem je budiž. bankovní metodika kapitálové přiměřenosti založená na hodnotě v riziku VaR včetně komerčních softwarových produktů typu *Riskmetrics*.

Zde uvedeme ty metody, pomocí nichž se dnes volatilita nejčastěji odhaduje a předpovídá. Přestože volatilita není přímo pozorovatelná, má určité charakteristiky, které jsou obvyklé, když se právě sleduje výnosnost nejrozličnějších finančních aktiv. (Některé z nich byly již zmíněny):

- *Shlukování volatility*: volatilita může být v některých obdobích s vysoká a v jiných nízká.
- *Pákový efekt*: volatilita reaguje odlišně na cenový vzestup a na cenový pokles..
- *Kontinuita*: Volatilita se vyvíjí spíše spojitě bez nějakých výrazných skoků.
- *Omezenost*: Volatilita nesměřuje k extrémně vysokým (neomezeným) hodnotám, ale její průběh bývá spíše stacionární v určitém rozmezí.

HISTORICKÁ VOLATILITA a MODEL EWMA

Jde o historicky nejstarší přístup k volatilitě, která se odhadovala většinou jako výběrový rozptyl nebo výběrová směrodatná odchylka přes určité historické období (proto *historická volatilita*), tj. v nejjednodušším případě jako

$$(6.11A,B) \quad \hat{\sigma}_t^2 = \frac{\sum_{\tau=t-k+1}^t (y_\tau - \hat{\mu}_t)^2}{k-1}, \quad \text{kde definujeme} \quad \hat{\mu}_t = \frac{\sum_{\tau=t-k+1}^t y_\tau}{k} \quad \text{pro}$$

vhodně zvolenou délku odhadního období k .

Zároveň se hodnoty definované jako (6.11A,B) běžně používaly jako předpovědní v čase t pro krátké předpovědní horizonty. I když se přístup pomocí historické volatility v počátcích používal např. pro předpověď volatility podkladového aktiva při výpočtu opční prémie podle *Blackovy-Scholesovy formule*, jeho dnešní význam se omezuje na stanovení srovnávacích hodnot [benchmarks] pro posouzení efektivnosti komplexnějších modelů volatility.

Pragmatickým rozšířením předchozího přístupu jsou modely EWMA. Nejpoužívanější EWMA-model volatility [exponentially weighted moving averages] představuje analogii jednoduchého exponenciálního vyrovnávání pro volatilitu. Na rozdíl od výpočtu historické volatility se zde při průměrování váží tím způsobem, že váhy klesají geometricky do minulosti. To má ve srovnání s historickou volatilitou řadu praktických předností:

- V praxi bývá volatilita skutečně více ovlivněna aktuálními pozorováními, které jsou v EWMA-modelu zvýrazněny většími vahami, než pozorováními vzatými z hlubší minulosti, které mají v EWMA-modelu nižší váhy.
- V EWMA-modelu se samovolně redukuje problém odlehlého pozorování s abnormálními velikostmi. (Naproti tomu v takovém případě při výpočtu historické volatility s krátkým odhadním obdobím může dojít ve skoku ve vypočtené volatilitě, jakmile odlehlé pozorování vypadne z odhadního období, zatímco při dlouhém odhadním období může vliv odlehlého pozorování přetrvávat v nezměněné intenzitě delší dobu, i když se finanční trh již dávno uklidnil).

V přímé analogii s modelem jednoduchého exponenciálního vyrovnání, kde jsme definovali

$$\hat{y}_t = (1 - \beta) \sum_{j=0}^{\infty} \beta^j y_{t-j} \quad \text{a} \quad \hat{y}_t = \alpha y_t + (1 - \alpha) \hat{y}_{t-1}$$

se volatilita při přístupu EWMA odhaduje jako

$$(6.12) \quad \hat{\sigma}_t^2 = (1 - \lambda) \sum_{j=0}^{\infty} \lambda^j (y_{t-j} - \bar{y})^2 = (1 - \lambda)(y_t - \bar{y})^2 + \lambda \hat{\sigma}_{t-1}^2, \text{ kde}$$

odhadnutá volatilita $\hat{\sigma}_t^2$ je zároveň předpovědí (nepříliš vzdálené) budoucí volatility z času t . \bar{y} je průměrná úroveň dané řady a λ , ($0 < \lambda < 1$) je předem zvolená diskontní konstanta. V případě, že se počítá volatilita pro časovou řadu finančních výnosů (logaritmických měř zisku, log returns) r_t , pracuje se často s nulovým průměrným výnosem (zvláště, když se jedná o vyšší frekvenci měřených hodnot, jako jsou např. denní výnosy), takže (6.12) přechází do tvaru:

$$(6.13) \quad \hat{\sigma}_t^2 = (1 - \lambda) \sum_{j=0}^{\infty} \lambda^j r_{t-j}^2 = (1 - \lambda)r_t^2 + \lambda \hat{\sigma}_{t-1}^2$$

Ve finanční praxi (viz např. text **RiskMetrics [1996]**) se na základě rozsáhlé zkušenosti s odhadem volatility doporučuje rutinně konstanta λ ve výši 0,94. Konstanta λ je tedy blíže k 1, než konstanta β jednoduchého exponenciálního vyrovnávání.

Typickými rysy, které vykazují finanční časové řady, jsou mj.:

- **Shlukování volatility** (viz volatilní shluky v časové řadě denních logaritmovaných měr zisku r_t přibližně na rozhraní první a druhé třetiny a v poslední čtvrtině řady).
- **Leptokurtické rozdělení** (rozpoznáme z histogramu: v časové řadě r_t byl koeficient standardizované špičatosti $5,22 - 3 = 2,22$) a hodnota Jarque-Berova testu normality 53,787 (p-hodnota zanedbatelná).

Pomocí rekurentního vzorce EWMA-modelu (6.13) s nulovou počáteční hodnotou byla odhadnuta odpovídající volatilita a její průběh zakreslen na obr.11.2.3. str.383 . EWMA-odhad volatility potvrzuje předchozí z náhledu vyvozený závěr: výskyt zvýšené volatility přibližně na rozhraní první a druhé třetiny a v poslední čtvrtině řady.

IMPLIKOVANÁ VOLATILITA

Ve finanční ekonometrii se využívají některé vztahy, nichž mezi vysvětlujícími faktory figuruje právě volatilita. Nejznámější z nich je **Black-Scholesova formule**, která vyjadřuje analyticky cenu opce (tj. opční prémii) jako funkci celkem pěti faktorů

- S_t - spotová cena podkladového aktiva
- X - realizační cena opce
- $T-t$ - doba do splatnosti opce
- σ - volatilita ceny podkladového aktiva
- i - bezriziková úroková míra

Např. pro cenu C_t evropské opce *call* je definován vztah

$$(6.14) \quad C_t = S_t \cdot \Phi(d_1) - X \cdot e^{-i(T-t)} \cdot \Phi(d_2),$$

kde hodnoty d_1 , d_2 jsou definovány jako

$$(6.15A) \quad d_1 = \frac{\ln\left(\frac{S_t}{X}\right) + \left(i + \frac{\sigma^2}{2}\right)(T-t)}{\sigma\sqrt{T-t}} \quad (6.15B) \quad d_2 = d_1 - \sigma\sqrt{T-t} ,$$

přičemž $\Phi(*)$ je distribuční funkce rozdělení $N(0,1)$.

Jestliže pozorujeme cenu obchodované (kótované) opce při daných hodnotách vysvětlujících faktorů (kromě volatility), pak jsme schopni pomocí vhodné numerické procedury právě tuto volatilitu vypočítat jako tzv. **implikovanou volatilitu**; přesněji řečeno, jedná se pak o předpověď volatility ceny podkladového aktiva v čase t s předpovědním horizontem rovným době do splatnosti opce $T - t$.

Implikovaná volatilita je však odvozena za předpokladu, které nemusí být v praxi splněny (např. logaritmicko-normální rozdělení ceny podkladové aktiva) a proto se může značně lišit od skutečné volatility. Praxe ukazuje, že **implikovaná volatilita** měr zisku různých finančních aktiv bývá vyšší než volatilita odvozená např. pomocí **modelů typu GARCH**.

AUTOREGRESNÍ MODELY VOLATILITY

Autoregresní modely volatility byly původně zavedeny jako přímá aplikace **Boxovy-Jenkinsovy metodologie** pro vyšetřování **volatility** – fluktuace, kolísavosti - časových řad. V rámci nelineárních modelů finančních modelů je ale lze zařadit mezi tzv. stochastické modely volatility (viz dále).

Ve finančnictví se často používají pro:

- **časové řady denních logaritmických měr zisku** r_t . Vzhledem k průměrně nulové úrovni takových řad se za vstup do autoregresního modelu volatility (6.23) obvykle bere přímo řada čtvercových logaritmických měr zisku (**squared log returns**) r_t^2 .

$$(6.21) \quad \sigma_t^2 = r_t^2$$

- **časové řady denních cen finančních aktiv** P_t . Zde se často jako vstup do autoregresního modelu volatility (6.23) používá řada zlogaritmovaných poměrů nejvyšší a nejnižší ceny uvažovaného aktiva během každého obchodního dne (tj. volatilita je měřena pomocí denního cenového rozpětí)

$$(6.22) \quad \sigma_t^2 = \ln\left(\frac{\max P_t}{\min P_t}\right) \approx \frac{\max P_t - \min P_t}{\min P_t}$$

Pro volatility v obou případech (6.21) a (6.22) se nakonec odhadne autoregresní model AR(s) tvaru

$$(6.23) \quad \sigma_t^2 = \beta_0 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 + \varepsilon_t,$$

pomocí něhož se pak případně volatilita též předpovídá. ε_t je klasický bílý šum s obvyklými vlastnostmi.

Základní reprezentace modelů volatility

Základními charakteristikami náhodných veličin stochastického procesu jsou *nepodmíněná a podmíněná střední hodnota* a *nepodmíněný a podmíněný rozptyl*. Vezměme AR(1) proces ve tvaru

$$(6.81) \quad y_t = \varphi_1 y_{t-1} + \varepsilon_t, \text{ kde}$$

$|\varphi_1| < 1$ a $\{\varepsilon_t\}$ je proces bílého šumu s nulovou střední hodnotou a rozptylem σ_ε^2 . Proces (6.81) lze vyjádřit jako nekonečnou posloupnost

$$(6.82) \quad y_t = \varepsilon_t + \varphi_1 \varepsilon_{t-1} + \varphi_1^2 \varepsilon_{t-2} + \varphi_1^3 \varepsilon_{t-3} + \dots$$

Je patrné, že *nepodmíněná střední hodnota veličiny* y_t je nulová, tj. $E(y_t) = 0$.

Podmíněnou střední hodnotou je střední hodnota veličiny y_t za předpokladu, že náhodné veličiny v časech $t-1, t-2, \dots, t-j$ nabyly konkrétních hodnot. Podmíněná střední hodnota závisí na volbě podmínky, a je tedy její funkcí. Tato funkce se označuje jako *funkce regresní*. V případě procesu AR(1) je podmínkou určitá hodnota náhodné veličiny v čase $t-1$. $E(y_t | y_{t-1}) = \varphi_1 y_{t-1}$, tj. *podmíněná střední hodnota veličiny* y_t je proměnlivá v čase.

Ze vztahu (6.81) vyplývá, že *nepodmíněný rozptyl veličiny* y_t je

$$(6.83) \quad \text{var}(y_t) = \frac{\sigma_\varepsilon^2}{1 - \varphi_1^2}, \text{ což je veličina v čase neměnná.}$$

Podmíněný rozptyl se někdy označuje jako *funkce skedastická*. Její průběh charakterizuje proměnlivost rozptylu veličiny y_t v závislosti na hodnotách veličin $y_{t-1}, y_{t-2}, y_{t-3}, \dots$. Z definičního vztahu AR(1)-procesu (6.81) lze vyvodit, že

$$(6.84) \quad \text{var}(y_t | y_{t-1}) = E(y_t - E(y_t | y_{t-1}))^2 = E(y_t - \varphi_1 y_{t-1})^2 = E(\varepsilon_t)^2 = \sigma_\varepsilon^2, \text{ tzn.,}$$

že *podmíněný rozptyl procesu* je také v čase neměnný.

V tomto případě se podmíněný rozptyl označuje jako *funkce homoskedastická*, při měnlivém podmíněném rozptylu by šlo o *funkci heteroskedastickou*.

Uvedené vlastnosti jsou charakteristické pro všechny stacionární a invertibilní modely, tj. pro modely typu AR, MA a ARMA.

Proces náhodné procházky

$$(6.86) \quad y_t = y_{t-1} + \varepsilon_t, \text{ kde}$$

$\{\varepsilon_t\}$ je proces bílého šumu s nulovou střední hodnotou a rozptylem σ_ε^2 , lze také

vyjádřit ve tvaru $y_t = y_0 + \sum_{j=1}^t \varepsilon_j$, takže

Nepodmíněná střední hodnota $E(y_t) = y_0$, kde y_0 je počáteční deterministická podmínka, tzn., že je *konstantní v čase*. Podmíněná střední hodnota

$E(y_t | y_{t-1}) = y_{t-1}$ je zřejmě naopak závislá na čase.

Nepodmíněný rozptyl $\text{var}(y_t) = t \cdot \sigma_\varepsilon^2$ je lineární funkcí časové proměnné.

Podmíněný rozptyl $\text{var}(y_t | y_{t-1}) = \sigma_\varepsilon^2$ je stejně jako v případě stacionárních procesů funkcí homoskedastickou.

Z uvedeného je názorně patrný problém lineárních modelů při modelování finančních a některých ekonomických časových řad, podmíněné rozptyly obou uvedených modelů jsou v čase neměnné. V realitě je však situace často jiná, podmíněné rozptyly jsou v čase proměnlivé.

Modely volatility vycházejí z představy, že např. model

(6.87) $y_t = \varphi_1 y_{t-1} + e_t$, kde $|\varphi_1| < 1$ a $\{e_t\}$ je podmíněně heteroskedastický proces s podmíněnou střední hodnotou $E(\varepsilon_t | \Omega_{t-1}) = 0$ a podmíněným rozptylem $\text{var}(e_t | \Omega_{t-1}) = h_t$, kde Ω_{t-1} je relevantní minulá informace až do času $t-1$. Tyto požadavky splňuje např. model procesu $\{e_t\}$ ve tvaru

(6.88) $e_t = \sqrt{h_t} \cdot \varepsilon_t$, kde

$\{\varepsilon_t\}$ jsou nezávislé náhodné veličiny s nulovou střední hodnotou a s jednotkovým rozptylem. Je-li rozdělení náhodné veličiny ε_t za podmínky informace, která je k dispozici v čase $t-1$ normované normální, tj. $\varepsilon_t \approx N_{t-1}(0, 1)$, potom je rozdělení náhodné veličiny y_t za podmínky informace, která je k dispozici v čase $t-1$ rovněž normální, avšak s podmíněným rozptylem, který se mění v závislosti na plynutí času, tj. $y_t \approx N_{t-1}(0, h_t)$.

Pokud jde o špičatost rozdělení veličiny e_t , vyplývá z vyjádření (6.88) na základě Jensenovy nerovnosti¹ vztah:

$$(6.89) \quad E(e_t^4) = E(h_t^2 \cdot \varepsilon_t^4) = E(h_t^2) E(\varepsilon_t^4) \geq E(\varepsilon_t^4) E(h_t)^2 = E(\varepsilon_t^4) E(e_t^2)^2,$$

takže platí (6.90)
$$\frac{E(e_t^4)}{E(e_t^2)^2} \geq E(\varepsilon_t^4),$$

tj. špičatost nepodmíněného rozdělení veličiny e_t je větší nebo rovna špičatosti normovaného normálního rozdělení. Rovnost platí právě tehdy, jsou-li podmíněné rozptyly konstantní.

Jednotlivé modely volatility se mj. liší vzájemně v tom, tak je u nich formulován vývoj podmíněného rozptylu h_t v čase.

¹ Podle ní platí pro konvexní funkci $\varphi(\cdot)$ a náhodnou veličinu Z nerovnost $\varphi(E(Z)) \leq E(\varphi(Z))$. Tuto nerovnost poprvé formuloval a dokázal dánský statistik Johan Jensen [1906]. V našem případě tedy platí: $E(h_t)^2 \leq E(h_t^2)$, protože kvadratická funkce $\varphi(\cdot)$ proměnné h_t je zde konvexní.

ARCH – modely

Průlomem směřujícím k systematickému modelování volatility byl model ARCH (*autoregressive conditional heteroskedasticity* – autoregresní podmíněná heteroskedasticita), aplikovaný poprvé Robertem Englem [1982] na modelování inflace ve Velké Británii. Modely tohoto typu a především jejich zobecnění na modely typu GARCH (bude o nich pojednáno dále) v současnosti představují patrně nejvýkonnější nástroj pro modelování finančních časových řad, které nebyly dosud ničím významnějším překonány. Vychází se zde ze dvou predikátů/tezí:

- Modely časových řad jsou *heteroskedastické*, tj. obsahující volatilitu proměnné v čase.
- *Volatilita je jednoduchou kvadratickou funkcí minulých předpovědních chyb* (tzn. odchylek od podmíněné střední hodnoty e_t),.

První predikát je plně v souladu s pozorovanou empirickou skutečností v oblasti finančních časových řad, takže se omezíme na vysvětlení pouze druhé teze:

Vzhledem k fenoménu volatility vytvářet jisté shluky, kdy větší (či resp. menší) výkyvy v dané finanční řadě lze očekávat spíše po větších (resp. menších) finančních výkyvech, lze považovat volatility za pozitivně autokorelované a jako jejich nejjednodušší pro jejich modelování zvolit autoregresní model. Navíc je $E(e_t) = 0$, takže podle (6.6) platí

$$(6.24) \quad \sigma_t^2 = \text{var}(e_t | \Omega_{t-1}) = E(e_t^2 | \Omega_{t-1}) = e_t^2$$

V důsledku toho se pro finanční časové řady stává realistickým pro vhodně zvolené (nevelké) m vztah

$$(6.25) \quad \sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \dots + \alpha_m e_{t-m}^2,$$

který zřejmě prezentuje volatilitu jako jednoduchou kvadratickou funkci zpožděných hodnot e_t . Za povšimnutí stojí, že závislost (6.25) je nestochastická, tj. je vyjádřena bez náhodné reziduální složky.

Na základě formulace obecného zápisu nelineárního modelu (6.7) lze přistoupit k formulaci modelu ARCH (m) m-tého řádu ve tvaru

$$(6.26) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t,$$
$$\sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2, \quad \text{kde}$$

ε_t jsou *i.i.d.* náhodné veličiny s nulovou střední hodnotou a jednotkovým rozptylem. Často se navíc předpokládá, že mají normální rozdělení, tj. $\varepsilon_t \approx N(0,1)$, případně stejným způsobem (tj. jedničkovým rozptylem) standardizované *t-rozdělení*. Podmíněná střední hodnota μ_t je modelována pomocí vhodné rovnice střední hodnoty – viz (6.4A) - která je většinou lineární. Dost často se jedná o podmíněnou střední hodnotu odpovídající lineárnímu regresnímu modelu (někdy zredukovanému jen na jeho úrovnovou konstantu *intercept*) nebo ARMA procesu.

Jako tři vybrané konkretizace tohoto vyjádření můžeme zde uvést:

$$(6.27) \text{ (M1)} \quad y_t = e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2,$$

tedy s nulovou podmíněnou střední hodnotou

$$(6.28) \text{ (M2)} \quad y_t = \gamma_0 + \gamma_1 x_{t1} + \gamma_2 x_{t2} + \dots + \gamma_m x_{tm}, \quad e_t = \sigma_t \cdot \varepsilon_t$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2,$$

tedy s vazbou na exogenní regresory

$$(6.29) \text{ (M3)} \quad y_t = \varphi_1 y_{t-1} + \varphi_2 y_{t-2} + \dots + \varphi_p y_{t-p} + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2,$$

tj. s podmíněnou střední hodnotou odpovídající autoregresnímu procesu AR(p).

Charakteristikou uvedených tří modelů je domněnka, že velké minulé hodnoty předpovědních chyb, které v minulosti vyvolaly zvýšenou volatilitu, implikují také zvýšenou volatilitu v přítomnosti.

První z těchto modelů se také nezřídka zapisuje v podobě

$$(6.27^*) \quad y_t = e_t, \quad e_t = \sqrt{h_t} \cdot \varepsilon_t, \quad h_t = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2,$$

Poznámka 1: Je užitečné ještě jednou zdůraznit, že zatímco náhodné veličiny e_t obecně (pouze) nekorelované, musí být veličiny ε_t stochasticky nezávislé. Logické jsou také průběhy korelogramů a parciálních korelogramů ARCH-modelů. Např. v modelu (6.27) by měl odhadnutý korelogram řady y_t vykazovat všechny hodnoty nevýznamné, zatímco odhadnutý parciální korelogram čtvercové řady y_t^2 by měl mít zřetelný bod useknutí v místě m .

Koeficienty α_j v definicích rozptylu musí splňovat určité podmínky regularity, aby náhodné veličiny e_t měly konečné aspoň druhé (nepodmíněné) momenty (tj. nepodmíněný rozptyl). V každém případě se však jako postačující (ale nikoliv nutné) podmínky kladných hodnot σ_t^2 požadují kladnosti/nezápornosti

$$(6.30) \quad \alpha_0 > 0, \alpha_1 \geq 0, \alpha_2 \geq 0, \dots, \alpha_m \geq 0.$$

Poznámka 2. Maticovým rozšířením základního modelu by bylo schéma

$$(6.31) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + (e_{t-1}, \dots, e_{t-m}) \cdot A(e_{t-1}, \dots, e_{t-m})',$$

ve kterém se vedle podmínky $\alpha_0 > 0$ požaduje, aby byla matice A pozitivně semidefinitní, tj. měla nezáporná všechna vlastní čísla. Rozptyl je zde definován kvadratickou formou odchylek. Výchozí model (6.26) je rovněž touto definicí „úsporně pokrytý“. Matice A je zde diagonální a obsahuje nezáporné diagonální prvky: některá α_j ale mohou být nulová.

Některé vlastnosti ARCH-modelu lze ukázat na nejjednodušším procesu ARCH(1):

$$(6.32) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2, \quad \alpha_0 > 0, \alpha_1 > 0 :$$

1) Nepodmíněná střední hodnota odchylek je skutečně nulová:

$$(6.33) \quad E(e_t) = E(Ee_t | \Omega_{t-1}) = E(\sigma_t \cdot E(\varepsilon_t)) = 0.$$

2) Pro (nepodmíněný) rozptyl odchylek e_t platí: (6.34)

$$\text{var}(e_t) = E(e_t^2) = E(E(e_t^2 | \Omega_{t-1})) = E(\sigma_t^2) = E(\alpha_0 + \alpha_1 e_{t-1}^2) = \alpha_0 + \alpha_1 \text{var}(e_{t-1})$$

Protože ale odchylky e_t mají stejné rozdělení (a tedy shodné rozptyly), dostaneme odtud

$$(6.35) \quad \text{var}(e_t) = \frac{\alpha_0}{1 - \alpha_1},$$

přirozeně pokud platí $0 \leq \alpha_1 < 1$, tj. postačující podmínka nejen pro existenci rozptylu $\text{var} e_t$, ale také pro slabou stacionaritu řady e_t

3) Často je potřebné analyzovat také špičatost odchylek e_t . Pokud platí, že $e_t \approx N(0,1)$, pak následně též platí

$$(6.36) \quad E(e_t^4) = E(Ee_t^4 | \Omega_{t-1}) = 3 \cdot E((\alpha_0 + \alpha_1 e_{t-1}^2)^2) = 3 \left((\alpha_0^2 + 2\alpha_0\alpha_1 \cdot \text{var}(e_{t-1})) + \alpha_1^2 \cdot E(e_{t-1}^4) \right).$$

Ze stejného důvodu jako pro rozptyl a s využitím vztahu (6.35) odtud dostaneme:

$$(6.37) \quad E(e_t^4) = \frac{3\alpha_0^2(1 + \alpha_1)}{(1 - \alpha_1)(1 - 3\alpha_1^2)}, \text{ pokud přitom platí}$$

postačující podmínka existence 4.obecného momentu e_t : $0 \leq \alpha_1 < \sqrt{1/3}$.

ověření (6.37):

$$E(e_t^4) = 3 \left((\alpha_0^2 + 2\alpha_0\alpha_1 \cdot \text{var}(e_{t-1})) + \alpha_1^2 \cdot E(e_{t-1}^4) \right) = 3 \left((\alpha_0^2 + 2\alpha_0\alpha_1 \cdot \frac{\alpha_0}{1 - \alpha_1} + \alpha_1^2 \cdot E(e_{t-1}^4)) \right), \text{ tedy následně}$$

$$E(e_t^4) - 3\alpha_1^2 E(e_{t-1}^4) = (1 - 3\alpha_1^2) E(e_t^4) = 3 \left(\alpha_0^2 + 2\alpha_0\alpha_1 \cdot \frac{\alpha_0}{1 - \alpha_1} \right), \text{ a protože rozptyl i}$$

4.obecný moment jsou nezávislé na t , takže platí $\text{var}(e_t) = \text{var}(e_{t-1})$, $E(e_t^4) = E(e_{t-1}^4)$

$$(1 - 3\alpha_1^2) E(e_t^4) = 3 \left(\frac{(1 - \alpha_1)\alpha_0^2}{1 - \alpha_1} + \frac{2\alpha_0^2\alpha_1}{1 - \alpha_1} \right) = 3 \left(\frac{\alpha_0^2 - \alpha_1\alpha_0^2 + 2\alpha_0^2\alpha_1}{1 - \alpha_1} \right) = 3 \left(\frac{\alpha_0^2(1 + \alpha_1)}{1 - \alpha_1} \right)$$

(Nepodmíněný) koeficient špičatosti odchylek e_t je následně

$$(6.38) \quad \gamma_2 = \frac{E(e_t^4)}{(\text{var}(e_t))^2} - 3 = 3 \cdot \frac{1 - \alpha_1^2}{1 - 3\alpha_1^2} - 3 = \frac{6\alpha_1^2}{1 - 3\alpha_1^2} \geq 0, \quad ,$$

To je ve shodě s požadavkem modelovat *leptokurtické rozdělení* (odchylky e_t podmíněného normálního modelu ARCH(1) generují odlehlá pozorování s větší pravděpodobností než jak je tomu u *normálního bílého šumu*).

Poznámka 3. Přechozí výsledky lze rozšířit taktéž na **model ARCH(m)**. Postačující podmínka pro slabou stacionaritu jeho odchylek e_t požaduje, aby všechny kořeny autoregresního polynomu $P_A(z) = 1 - \alpha_1 \cdot z - \alpha_2 \cdot z^2 - \dots - \alpha_m \cdot z^m$ ležely vně jednotkového kruhu v komplexní rovině; speciálně: z nezápornosti parametrů odtud plyne podmínka $\alpha_1 + \alpha_2 + \dots + \alpha_m < 1$, přičemž pro rozptyl odchylek e_t pak platí

$$(6.39) \quad \text{var}(e_t) = \frac{\alpha_0}{1 - \alpha_1 - \alpha_2 - \dots - \alpha_m}.$$

Z poměrně obsáhlého počtu výpočetních procedur pro modely ARCH vybereme jen některé (pro obecnější modely typu GARCH mají tyto procedury analogický tvar). Pro přiblížení budeme pracovat s modelem ARCH(m) ve tvaru (6.26), tj. s nulovou podmíněnou střední hodnotou μ_t a s přímo pozorovatelnými odchylkami e_t . (Již bylo zmíněno, že v praxi je toto obvykle splněno pro finanční řady logaritmovaných měr zisku r_t). V opačném případě je nutné vzít v úvahu podmíněnou střední hodnotu: např. v modelu (6.26) bychom pracovali s vyjádřením odchylek ve tvaru

$$(6.40) \quad e_t = y_t - \Phi_1 y_{t-1} - \Phi_2 y_{t-2} - \dots - \Phi_p y_{t-p}$$

Postupy identifikace ARCH-modelu

Řád modelu lze identifikovat jako bod useknutí odhadnutého parciálního korelogramu v modelu tvaru

$$(6.41) \quad e_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2 + u_t, \text{ kde}$$

u_t je klasický bílý šum, (tzn. stejným způsobem, jako pro klasický AR model v rámci Boxovy-Jenkinsovy metodologie). Při příliš velkém řádu m modelu hrozí nebezpečí, že odhadnuté parametry nebudou splňovat podmínky nezápornosti (6.30). Aby nebylo nutné odhadovat velký počet parametrů při velkých řádech m , navrhl Engle [1982] používat místo třetího vztahu v (6.26) úsporný model s $m=4$, ale obsahující jen dva parametry:

$$(6.42) \quad \sigma_t^2 = \delta_0 + \delta_1 \cdot (0,4 \cdot e_{t-1}^2 + 0,3 \cdot e_{t-2}^2 + 0,2 \cdot e_{t-3}^2 + 0,1 \cdot e_{t-4}^2)$$

(*model rozloženého zpoždění s lineárně klesajícími vahami.*)

Odhad parametrů ARCH-modelu

Protože kvantifikační techniky založené na *principu nejmenšího součtu čtverců* nejsou pro odhady *modelů s podmíněnou heteroskedasticitou* z více důvodů vhodné, odhadují se tyto modely obvykle *metodou maximální věrohodnosti*. V tomto případě platí pro příslušnou hustotu pravděpodobnosti vztah

$$(6.43) \quad f(e_1, e_2, \dots, e_n) = f(e_n | \Omega_{n-1}) \dots f(e_{m+1} | \Omega_m) \cdot f(e_1, e_2, \dots, e_n). \quad \text{Proto,}$$

pokud $e_t \approx N(0,1)$, bude mít (podmíněná) logaritmovaná věrohodnostní funkce tvar

$$(6.44) \quad L^*(\alpha_0, \alpha_1, \dots, \alpha_m) = \sum_{t=m+1}^n \left(-\frac{1}{2} \ln(2\pi) - \frac{1}{2} \ln(\sigma_t^2) - \frac{1}{2} \left(\frac{e_t^2}{\sigma_t^2} \right) \right).$$

Poslední činitel byl vynechán, protože podmiňujeme počátečními hodnotami e_1, e_2, \dots, e_m .

Volatility pro log-věrohodnostní funkci (6.44) vyjadřujeme pomocí parametrů α_j rekurentně ze vztahů

$$(6.45) \quad \sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \alpha_2 \cdot e_{t-2}^2 + \dots + \alpha_m \cdot e_{t-m}^2 \quad t = m+1, m+2, \dots, n.$$

Pokud normální rozdělení $e_t \approx N(0,1)$ není adekvátní příliš těžkým koncům modelovaných finančních dat, lze užít eventuálně i jiná rozdělení. Např. má-li $e_t \approx t_\nu(0,1)$, pak se analogicky vůči (6.44) použije logaritmovaná věrohodnostní funkce ve tvaru

$$(6.46) \quad L^*(\alpha_0, \alpha_1, \dots, \alpha_m) = - \sum_{t=m+1}^n \left(\frac{\nu+1}{2} \ln \left(1 + \frac{e_t^2}{(\nu-2) \cdot \sigma_t^2} \right) + \frac{1}{2} \ln(\sigma_t^2) \right).$$

Pomocí stupňů volnosti ν_t můžeme řídit pravděpodobnostní chování chvostů rozdělení tím, že pro $\nu_t \rightarrow \infty$ přechází (centrální) *t-rozdělení* na normální. Pokud ani *t-rozdělení* není pro daná data dostatečně *leptokurtické*, lze aplikovat např. *QED-rozdělená (generalized error distribution)*.

Maximalizace logaritmických věrohodnostních funkcí pro získání konečných ML-odhadů je výlučně softwarovou záležitostí (nejčastěji se k tomuto účelu užívá *BHHH-algoritmus*²). Přitom se většinou dohaduje simultánně celý model včetně rovnice střední hodnoty (tj. např. parametrů $\varphi_1, \varphi_2, \dots, \varphi_p$ ve vyjádření (6.40)), zpravidla včetně rozptylové matice odhadnutých parametrů.

Poznámka3. Použijeme-li pro model ARCH nekorektně podmíněné normální rozdělení $e_t \approx N(0,1)$, budou odpovídající ML-odhady dotčeného parametrů modelu stále konzistentní (pokud byl model jinak korektně identifikován), ale většinou to již nebude platit o odhadu jejich kovarianční matice. Konzistentní odhad této matice je ale možné pořídit jako *QML-odhad (quasi-maximum likelihood)*. Tento postup (označovaný někdy jako robustní vůči nenormalitě či heteroskedasticity consistent covariances), obsahuje např. software EViews 5.1, ale také třeba *gretl*.

² viz Berndt, E.R., Hall, B.H., Hall, R.E., Hausman, J.A. [1974] Estimation and Inference in Nonlinear Statistical Models. *Annals of Economic and Social Measurement* 3, p.653-665.

GARCH – modely

ARCH(m) model vykazuje kromě předností také některé **nedostatky**:

- Vyžaduje často příliš vysoký řád m , aby adekvátně popsal vývoj volatility dané časové řady.
- Ve vztahu k předchozímu je často nutno odhadovat značný počet parametrů, přičemž navíc může u některých dojít k porušení podmínky nezápornosti.
- Je sice zohledněno shlukování volatility, ale nikoliv již pákový efekt či asymetrie, kdy kladné a záporné odchylky mohou mít odlišný vliv na volatilitu.

Předchozí nedostatky odstraňuje **GARCH (generalized ARCH)** – model. V tomto modelu, jehož základní formalizaci navrhl Bollerslev³ a v jehož z mnoha různých modifikací může volatilita či podmíněný rozptyl procesu záviset také na svých předchozích (zpožděných) hodnotách. Zvláště jde o model **GARCH(1,1)**, který je nejjednodušším představitelem této třídy modelů, je dnes jedním z nejvíce používaných u finančních časových řad, protože je schopen pomocí tří parametrů zvládnout velmi obecné volatilní struktury (modely GARCH vyšších řádů se proto v praxi využívají jen sporadicky).

Model GARCH(m,s) má tento tvar

$$(6.51) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i e_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2, \quad \text{což ho činí dobř}$$

srovnatelným s vyjádřením ARCH-modelu (rozdílnost je pouze ve třetí podmínce).

I zde jsou ε_t *i.i.d.* náhodné veličiny s nulovou střední hodnotou a jednotkovým rozptylem a obvykle se předpokládá, že mají normální rozdělení, tj. $\varepsilon_t \approx N(0,1)$ nebo t-rozdělení o větším počtu stupňů volnosti. Pro přítomné parametry se předpokládá splnění těchto podmínek:

$$(6.52) \quad \alpha_0 > 0, \alpha_i \geq 0, \beta_j \geq 0; \quad \sum_{i=1}^{\max\{m,s\}} (\alpha_i + \beta_i) < 1 \quad \text{., kde klademe}$$

$\alpha_i = 0$ pro $i > m$ a $\beta_j = 0$ pro $j > s$. Pokud $s=0$, dostáváme zřejmě model **ARCH(m)**.

Poslední nerovnost v(6.52) je postačující pro existenci rozptylu

$$(6.52A) \quad \text{var}(e_t) = \frac{\alpha_0}{1 - \sum_{i=1}^{\max\{m,s\}} (\alpha_i + \beta_i)}.$$

³ Bollerslev, T. [1986]: Generalized Autoregressive Conditional Heteroskedasticity. *Journal of Econometrics*. 31 p.307-327

Bollerslev, T. [1987]: A Conditionally Heteroskedastic Time Series Model for Speculative Pirice and rates of Return. *Review of Economics and Statistics* 69, p.542-547.

Bollerslev, T. [1988]: On the Correlation Structure for the Generalized Autoregressive Conditional Heteroskedastic Process. *Journal of Time Series Analysis* 9. p.121-131.

Speciálně model **GARCH(1,1)** má jednoduchý tříparametrický tvar

$$(6.53) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \beta_1 \sigma_{t-1}^2,$$

$$(6.53A) \quad \alpha_0 > 0, \alpha_1 \geq 0, \beta_1 \geq 0; \alpha_1 + \beta_1 < 1.$$

Nepodmíněný rozptyl procesu **GARCH(1,1)** $\{e_t\}$ má podobu

$$\text{var } e_t^2 = \frac{\alpha_0}{1 - \alpha_1 - \beta_1}$$

Pro jeho koeficient špičatosti máme – **Bolerslev [1986]** - vyjádření

$$(6.54) \quad \gamma_2 = \frac{E(e_t^4)}{\text{var}(e_t^2)^2} = \frac{3 \cdot (1 - (\alpha_1 + \beta_1)^2)}{1 - 2\alpha_1^2 - (\alpha_1 + \beta_1)^2} - 3 = \frac{6\alpha_1^2}{1 - 2\alpha_1^2 - (\alpha_1 + \beta_1)^2} \geq 0, \text{ a to za}$$

platnosti postačující existenční podmínky

$$(6.54A) \quad 1 - 2\alpha_1^2 - (\alpha_1 + \beta_1)^2 > 0 \text{ neboli také } 3\alpha_1^2 + 2\alpha_1\beta_1 + \beta_1^2 < 1,$$

jinak je špičatost nekonečně velká $+\infty$.

Srovnáme-li podmínku (6.54A) s analogickou pro **ARCH(1) model**, kde postačující podmínka existence 4.obecného momentu e_t vyžadovala, aby $0 \leq \alpha_1 < \sqrt{1/3}$ a (nepodmíněný) koeficient špičatosti odchylek e_t byl roven

$$(6.38) \quad \gamma_2 = \frac{E(e_t^4)}{(\text{var}(e_t))^2} - 3 = \frac{6\alpha_1^2}{1 - 3\alpha_1^2},$$

Ize konstatovat, že při samotné dodržení podmínky pro α_1 u **ARCH(1) modelu**

$$3\sqrt{1/3}^2 + 2\sqrt{1/3}\beta_1 + \beta_1^2 = 1 + 2\sqrt{1/3}\beta_1 + \beta_1^2 < 1$$

tzn. $2\sqrt{1/3}\beta_1 + \beta_1^2 < 0$ tj. $\beta_1(2\sqrt{1/3} + \beta_1) < 0$ nepostačuje ke splnění (6.54A).

Konformita podmínek pro koeficient špičatosti nastává zřejmě jen pro $\beta_1 = 0$.

Hodnoty autokorelační funkce GARCH(1,1) modelu klesají s rostoucím zpožděním k geometricky. Rychlost tohoto klesání závisí na hodnotě součtu $\alpha_1 + \beta_1$: blíží-li se tento součet hodnotě 1, je pokles autokorelační funkce velmi pozvolný. **Hodnoty parciální autokorelační funkce rovněž s rostoucím zpožděním geometricky klesají.** Obecně lze konstatovat, že tvary ACF a PACF procesu e_t^2 odpovídají tvarům těchto funkcí u modelu ARMA(p,q).

Pokud jde o výpočetní procedury uplatnitelné pro GARCH-modelové specifikace, v podstatě jde o tytéž, na kterých je založena kvantitativní analýza ARCH-modelů.

Předpovědi volatility v modelu GARCH(1,1):

Podle (6.53) zřejmě platí:

$$(6.55) \quad \sigma_t^2(t-1) = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \beta_1 \sigma_{t-1}^2.$$

Protože platí

$\sigma_{t+1}^2 = \alpha_0 + (\alpha_1 + \beta_1)\sigma_t^2 + \alpha_1 \cdot \sigma_t^2 (e_t^2 - 1)$ a také $E(e_t^2 - 1 | \Omega_{t-1}) = 0$, je rovněž

$$(6.56) \quad \bar{\sigma}_{t+1}^2(t-1) = \alpha_0 + (\alpha_1 + \beta_1) \cdot \bar{\sigma}_t^2(t-1) \text{ a obecně}$$

$$(6.57) \quad \bar{\sigma}_{t+\tau}^2(t) = \alpha_0 + (\alpha_1 + \beta_1) \cdot \bar{\sigma}_{t+\tau-1}^2(t) \text{ pro libovolné (nevelké) } \tau > 1.$$

Postupnými substitucemi dostáváme konečný výraz

$$(6.58) \quad \bar{\sigma}_{t+\tau}^2(t) = \frac{\alpha_0 (1 - (\alpha_1 + \beta_1)^{\tau-1})}{1 - \alpha_1 - \beta_1} + (\alpha_1 + \beta_1)^{\tau-1} \cdot \bar{\sigma}_{t+1}^2(t), \text{ který zřejmě}$$

konverguje za podmínky (6.53A) $\alpha_1 + \beta_1 < 1$ k limitní hodnotě

$$(6.59) \quad \bar{\sigma}_{t+\tau}^2(t) = \frac{\alpha_0}{1 - \alpha_1 - \beta_1} \text{ při } \tau \rightarrow \infty.$$

Předpověď volatility tedy konverguje s rostoucím předpovědním horizontem k nepodmíněnému rozptylu předpovědních chyb e_t .

Modifikované GARCH – modely

Analýza nelineárních časových řad je rychle se rozvíjející oblastí, kde nové modely přibývají každým rokem (čímž se celkem už ztrácí přehled v jejich velmi rozmanitých zkratkách). Typickým příkladem jsou právě rozmanité modifikace modelů GARCH. Některé z nich budou dále stručně popsány jinak o nich existuje obsažná monografická i časopisecká literatura.

IGARCH – modely

Integrovaný GARCH model [integrated GARCH] značený jako IGARCH(m,s), je GARCH(m,s)- model s jednotkovým kořenem autoregresního polynomu v rovnici volatility. Jedná se o analogii ARIMA-modelu, ale pro volatilitu místo pro vlastní časovou řadu. Vyznačuje se tzv. *perzistencí v rozptylu*; zatímco v modelu GARCH, který je *stacionární ve volatilitě*, konvergují předpovědi volatility pro rostoucí předpovědní horizont k nepodmíněnému rozptylu procesu – viz (6.59), v modelu IGARCH přetrvává současná informace jako významná pro předpovědi volatility ve všech (tedy i velmi dlouhých) horizontech.

Při aplikaci GARCH –modelů na vysokofrekvenční časové řady se často stává, že součet odhadů parametrů α_1 a β_1 je číslo velmi blízké 1: Engle Bolerslev [1986] uvedli proto třídu modelů, které se označují jako IGARCH.

Model IGARCH(m,s) je definován jako model GARCH(m,s) podle (6.51), kde ale navíc platí

$$\sum_{i=1}^{\max\{m,s\}} (\alpha_i + \beta_i) = 1, \text{ takže mj.}$$

jeho nepodmíněný rozptyl (6.52A) existovat nemůže.

Speciálně nejjednodušší modelu IGARCH(1,1) má tvar

$$(6.61) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + (1 - \beta_1) \cdot e_{t-1}^2 + \beta_1 \sigma_{t-1}^2,$$

$$(6.61A) \quad \alpha_0 > 0, 0 \leq \beta_1 \leq 1.$$

Konkrétně model IGARCH(1,1) je tedy modelem GARCH(1,1) s restrikcí $\alpha_1 + \beta_1 = 1$,

Přitom je zajímavé, že při $\mu_t = 0$ a $\alpha_0 = 0$ zřejmě tento model přechází na schéma EWMA definované v (6.13)

Rekurentní předpovědní vztah (6.57) se v něm nyní zjednodušuje do tvaru

$$(6.62) \quad \hat{\sigma}_{t+\tau}^2(t) = \alpha_0 + \hat{\sigma}_{t+\tau-1}^2(t) \text{ pro libovolné (nevelké) } \tau > 1,$$

takže pro opakovaných substitucích nakonec dostáváme

$$(6.63) \quad \hat{\sigma}_{t+\tau}^2(t) = (\tau - 1) \cdot \alpha_0 + \hat{\sigma}_{t+1}^2(t) = (\tau - 1) \cdot \alpha_0 + \hat{\sigma}_{t+1}^2 \text{ pro (nevelké) } \tau > 1.$$

Zjištěný výsledek znamená, že vliv současných volatilit na předpovědi budoucích volatilit tedy opravdu přetrvává (je persistentní) a volatilní předpovědi se navíc vyvíjejí podle přímky se směrnici α_0 .

Formálně odlišná specifikace modelu IGARCH(1,1) může být zapsána také tvarem

$$(6.64) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad e_t^2 = \alpha_0 + \varepsilon_{t-1}^2 + v_t - \beta_1 v_{t-1}, \quad v_t = \varepsilon_t^2 - h_t \text{ tj.}$$

v podobě analogické specifikaci ARIMA(0,1,1).

GJR GARCH – model

Zřetelným handicapem původního modelu GARCH byla neschopnost modelovat asymetrické chování, kdy kladné a záporné odchylky e_t mohou mít odlišný vliv na volatilitu (ve vztahu k uvedenému pákovému efektu), tj. tendenci volatility zvětšit se více po cenovém poklesu než po cenovém nárůstu stejné velikosti. Úspěšnou modifikací GARCH-modelu v tomto směru navrhli **Glosten, Jagannathan a Runkle⁴ [1993]** (a nezávisle na nich **Zakoian [1994]⁵**), podle nichž byl příslušný model zkratkově pojmenován jako **GJR GARCH**, i když někdy se používá také označení **prahový GARCH model [threshold GARCH či TACHR]** v případě této modifikace uplatněné na ARCH-model.

$$(6.65) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t,$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i e_{t-i}^2 + \sum_{j=1}^m \beta_j \sigma_{t-j}^2 + \sum_{k=1}^n \gamma_k e_{t-k}^2 \cdot I_{t-k}^-, \text{ kde } I_t^- = 1 \text{ pro } e_t < 0$$

$$I_t^- = 0 \text{ pro } e_t \geq 0.$$

Tento model má zajímavou interpretaci v tom, že dopad „dobrých zpráv“ ($e_{t-i} \geq 0$) modelovaný pomocí α_i je odlišný od dopadu „špatných zpráv“ $e_{t-i} < 0$ modelovaných pomocí $\alpha_i + \gamma_i$. Je-li $\gamma_i > 0$ znamená to, že špatné zprávy vyvolávají růst volatility, takže se opravdu jedná o pákový efekt se zpožděním i .

V každém případě pro $\gamma_i \neq 0$ se model chová asymetricky.

Nejpoužívanější GJR GARCH model v praxi je zjednodušený model (6.51) na

$$(6.66) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 e_{t-1}^2 + \beta_1 \sigma_{t-1}^2 + \gamma_1 e_{t-1}^2 \cdot I_{t-1}^-,$$

$$\text{kde } I_t^- = 1 \text{ pro } e_t < 0, \text{ resp. } I_t^- = 0 \text{ v opačném případě.}$$

⁴ Glosten, L.R., Jagannathan, R., Runkle, D.E.: On the relation between the expected value and the volatility of the nominal excess return on stocks. *The Journal of Finance* 48/1993 p.1779-1801

⁵ Zakoian, J.M.: Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*. 18/1994 p.931/934.

EGARCH – model

Jiný přístup k řešení problému asymetrického chování odchylek e_t navrhl D.B.Nelson[1991]⁶. Po určitých zjednodušeníh jeho návrhu (neboť Nelson původně systematicky pracoval s rozdělením GED veličin ε_t) má jím prezentovaný **exponenciální GARCH-model** (značený zkratkou **EGARCH**) tvaru

$$(6.65) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t,$$

$$\ln \sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i \left| \frac{e_{t-i}}{\sigma_{t-i}} \right| + \sum_{j=1}^s \beta_j \ln \sigma_{t-j}^2 + \sum_{k=1}^n \gamma_k \frac{e_{t-k}}{\sigma_{t-k}},$$

Zápis modelu pomocí logaritmických volatilit má tu výhodu, že podmínky nezápornosti parametrů (např. α_0) nyní pozbývají význam a pákový efekt je nyní exponenciální (nikoliv jako dříve kvadratický). Asymetrie zřejmě nastává, když $\gamma_r \neq 0$ pro nějaké konkrétní zpoždění r . Speciálně pro $\gamma_r < 0$ nastává pákový efekt.

Nejjednodušší a nejpoužívanější tvar **EGARCH-modelu** je čtyřparametrický

$$(6.66) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t,$$

$$\ln \sigma_t^2 = \alpha_0 + \alpha_1 \left| \frac{e_{t-1}}{\sigma_{t-1}} \right| + \beta_1 \ln \sigma_{t-1}^2 + \gamma_1 \frac{e_{t-1}}{\sigma_{t-1}}, \text{ jako speciální případ}$$

zápisu (6.65) vždy jen s jediným členem k každé ze tří sumací.

Před vlastní konstrukcí asymetrických modelů typu **GJR GARCH** a **EGARCH** se doporučuje statisticky otestovat symetrii (viz např Engle a Ng [1993]⁷). Pracuje se většinou s reziduy \hat{e}_t vypočtenými z odhadnutého symetrického **GARCH-modelu** – $\hat{e}_t = y_t - \hat{\varphi}_1 y_{t-1} - \hat{\varphi}_2 y_{t-2} - \dots - \hat{\varphi}_p y_{t-p}$ a pomocí některého z klasických t -, F -, nebo LM -testu se testuje významnost parametrů v klasických lineárních modelech typu

$$(6.67) \quad \hat{e}_t^2 = \delta_0 + \delta_1 S_{t-1}^- + u_t \quad \begin{matrix} S_{t-1}^- = 1 & \text{pro } \hat{e}_{t-1} < 0 \\ S_{t-1}^- = 0 & \text{pro } \hat{e}_{t-1} \geq 0 \end{matrix}.$$

$$(6.68) \quad \hat{e}_t^2 = \delta_0 + \delta_1 S_{t-1}^- \hat{e}_{t-1} + u_t$$

$$(6.69) \quad \hat{e}_t^2 = \delta_0 + \delta_1 S_{t-1}^- + \delta_2 S_{t-1}^- \hat{e}_{t-1} + \delta_3 S_{t-1}^+ \hat{e}_{t-1} + u_t, \text{ kde } S_{t-1}^+ = 1 - S_{t-1}^-.$$

u_t je zde klasický bílý šum. Přitom zaznamenaná významnost parametrů:

δ_1 v modelu (6.67) svědčí o asymetrii volatilit v dané časové řadě.

δ_0, δ_1 v modelu (6.68) svědčí o asymetrii volatilit a vlivu velikosti záporných odchylek e_t na ni.

$\delta_0, \delta_1, \delta_2, \delta_3$ v modelu (6.69) svědčí o asymetrii volatilit a vlivu velikosti kladných a záporných odchylek e_t na volatilitu v analyzované časové řadě.

⁶ Nelson, D.B.: Conditional heteroskedasticity in asset returns: A new approach. *Econometrica* 59/1991 p.347-370

⁷ Engle, R.F., Ng, V.K.: Measuring and testing the impact of news on volatility. *Journal of Finance* 48/1993 p.1749-1778.

Poznámka: Ve finančních aplikacích se asymetrické modely pro volatilitu často kombinují s klasickými AR-modely pro střední hodnotu. Např. R.S.Tsay [2002]⁸ zkonstruoval pro denní logaritmické míry zisku r_t akcií IBM od 07/1962 do 12/1999 (9 442 hodnot) model AR(2)-GJR-GARCH(1,2) ve tvaru

GARCH-M – model GARCH in mean

Ve financích závisí často výnos aktiva na jeho volatilitě (např. investor je kompenzován za vyšší riziko vyšším výnosem). Proto Engle, Lilien a Robins [1987] navrhli další modifikaci nejprve ARCH-modelu, kde volatilita či její odmocnina vstupuje do rovnice střední hodnoty (tzv. **ARCH-M model**).

Pro GARCH modely má např. **GARCH(1,1)-M model (GARCH-in-mean)**

$$(6.71) \quad y_t = \mu_t + \gamma_I \sigma_t^2 + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \beta_I \sigma_{t-1}^2 \quad \text{nebo}$$

$$(6.72) \quad y_t = \mu_t + \gamma_I \sigma_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \sigma_t^2 = \alpha_0 + \alpha_1 \cdot e_{t-1}^2 + \beta_I \sigma_{t-1}^2,$$

Jestliže je parametr γ_I signifikantně kladný, pak zvýšené riziko projevující se zvýšenou volatilitou vede ke zvýšené úrovni řady (tj. ke zvýšené podmíněné střední hodnotě).

Modely SV – stochastické volatility

Rovnice volatility základního **GARCH-modelu** je zřejmě deterministická ve smyslu podmiňování minulou informací. O stochastické volatilitě [**stochastic volatility**] se v kontextu GARCH modelů mluví v případě, kdy do rovnice volatility je dodán další chybový člen, který i při podmiňování minulou informací zůstává náhodný. Jakkoliv jsou jednoduchým příkladem klasické AR modely volatility, obecně se model SV – viz např. Taylor [1994]⁹ - prezentuje následovně

$$(6.73) \quad y_t = \mu_t + e_t, \quad e_t = \sigma_t \cdot \varepsilon_t, \quad \ln \sigma_t^2 = \alpha_0 + \sum_{j=1}^s \beta_j \ln \sigma_{t-j}^2 + u_t, \quad \text{kde}$$

$\{u_t\}$ je další bílý šum (zpravidla *i.i.d.* s normálním rozdělením), nezávislá na $\{\varepsilon_t\}$; užití logaritmické volatility umožňuje ignorovat podmínku nezápornosti jako v EGARCH-modelu. Modely SV-typu se osvědčily v kontextu oceňování opčních premií, kdy volatilita podkladového aktiva, která je jedním ze vstupů do **Black-Scholesovy rovnice**, nemusí být fixována po celou dobu do splatnosti opce. Nevýhodou těchto modelů je ale jejich poměrně složitý odhad nejčastěji **Kalmanovým filtrem**.

⁸ Tsay, R.S.: Analysis of Financial time Series. Wiley, New York 2002.

⁹ Taylor, S., J.: Modelling Stochastic Volatility. *Mathematical Finance* 4/1994, p.183-204

FIGARCH (fractionally IGARCH) – modely

Pokles hodnot autokorelační funkce je při součtu hodnot parametrů $\alpha_1 + \beta_1$ blízkém 1 geometrický. Realita však může být odlišná a autokorelační funkce se může vyvíjet hyperbolicky (koeficienty klesají v reciprokových hodnotách). Takováto autokorelační struktura může být zachycena *frakcionálně integrovanými modely*, resp. tzv. modely s dlouhou pamětí. Baillie, Bollerslev a Mikkelsen [1992] navrhli třídu modelů, které označili FIGARCH. Proces e_t^2 modelu FIGARCH(1,d,0) lze zapsat ve tvaru

$$(4.74) \quad (1-B)^d e_t^2 = \alpha_0 + \varepsilon_t - \beta_1 \varepsilon_{t-1}, \text{ kde } 0 < d < 1.$$

Po dosazení vztahu $\varepsilon_t = e_t^2 - h_t$ do (4.74) je možné model podmíněného rozptylu vyjádřit ve tvaru ARCH(∞):

$$(4.75) \quad h_t = \frac{\alpha_0}{1 - \beta_1} + \lambda(B) \cdot e_t^2, \text{ v němž}$$

$\lambda(B) = \frac{1 - (1-B)^d}{1 - \beta_1 \cdot B}$, přičemž lze ukázat, že pro vysoké hodnoty λ aproximativně:

$$(4.76) \quad \lambda_k \approx \left[\frac{1 - \beta_1}{\Gamma(d)} \right] k^{d-1}, \text{ kde}$$

$\Gamma(\cdot)$ je *gama funkce* (zobecnění faktoriálu pro neceločíselný argument) tvaru

$$\Gamma(z) = \int_0^{\infty} t^{z-1} e^{-t} dt \text{ s rekurentní vlastností } \Gamma(z) = z \cdot \Gamma(z-1)$$

Ze zápisu (4.76) vyplývá, že – na rozdíl od kovariančně-stacionárního modelu GARCH(1,1) nebo modelu IGARCH(1,1), kde se šoky po podmíněného rozptylu zmenšují geometricky - se v modelu FIGARCH(1,d,0) šoky do podmíněného rozptylu zmenšují pomaleji, a to hyperbolicky (v reciprokových hodnotách).

Obecný model FIGARCH (p,d,q) má vyjádření:

$$(4.77) \quad \varphi(B)(e_t^2 - de_t^2) = \alpha_0 + [1 - \beta(B)]\varepsilon_t, \text{ kde } 0 < d < 1, \text{ přičemž}$$

kořeny polynomiálních rovnic $\varphi(B) = 0$ a $[1 - \beta(B)] = 0$ leží vně jednotkového kruhu.

Užité značení: Polynom $\beta(B)$: má tvar $\beta(B) = \beta_1 B + \beta_2 B^2 + \dots + \beta_q B^q$.

Polynom $\varphi(B)$: má tvar $\varphi(B) = \varphi_1 B + \varphi_2 B^2 + \dots + \varphi_p B^p$.