

## 2

### Modelos de Volatilidade Condicional

#### 2.1

##### Introdução

A teoria de análise de séries temporais, em particular os modelos ARIMA Box-Jenkins, permite a modelagem de variáveis de interesse, a partir da formulação explícita da dependência linear apresentada pelas mesmas.

Dentre os modelos empregados, podemos destacar os autoregressivos. Um processo autoregressivo de ordem  $p$  (AR( $p$ )), para uma determinada variável  $y_t$ , tem a seguinte forma:

$$y_t = c + \phi_1 \cdot y_{t-1} + \phi_2 \cdot y_{t-2} + \dots + \phi_p \cdot y_{t-p} + u_t \quad (2.1.1)$$

Onde,  $u_t$  assume a forma de um ruído branco.

$$E(w_t) = 0$$

$$E(w_t w_\tau) = \begin{cases} \lambda^2 & \rightarrow t = \tau \\ 0 & \rightarrow t \neq \tau \end{cases}$$

Dessa forma, pode-se afirmar que:

- O processo será estacionário de segunda ordem, caso as raízes do polinômio em “z” estejam localizadas fora do círculo unitário;

$$1 - \phi_1 \cdot z - \phi_2 \cdot z^2 - \dots - \phi_p \cdot z^p = 0 \quad (2.1.2)$$

- A previsão um passo à frente, condicional a toda informação disponível no instante de tempo “t-1”, corresponde à projeção linear da variável de interesse sobre uma constante e seus próprios defasamentos (média condicional);
- Enquanto o valor da média condicional do processo é expresso como função daqueles observados para os respectivos defasamentos, a média incondicional, considerando o processo como sendo estacionário de segunda ordem, se mostra constante.

Para determinadas séries temporais, em particular aquelas observadas no mercado financeiro, pode ser interessante a realização de previsões, não somente relacionadas ao nível da variável, como também à variância da mesma.

A variância de séries financeiras representa um dos assuntos de maior importância na atualidade, uma vez que investidores racionais exigirão um prêmio maior, à medida que a volatilidade (incerteza) dos retornos de seus investimentos aumenta.

Aos pontos enumerados acima, soma-se o fato de que mudanças no regime da volatilidade afetam a própria eficiência das inferências estatísticas com relação aos parâmetros do modelo ( $c, \phi_1, \phi_2, \dots, \phi_p$ ).

## 2.2

### ***Autoregressive Conditional Heteroskedasticity (ARCH)***

Introduzidos por Engle (1982), o modelo ARCH propõe uma formulação autoregressiva para capturar a estrutura de dependência linear existente na variância do ruído de uma determinada série de interesse.

Dessa forma, sendo o processo estocástico definido pela equação 2.1.1, diz-se que  $u_t^2$  segue um processo ARCH (m), desde que este assuma a seguinte forma funcional:

$$u_t^2 = \zeta + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2 + w_t \quad (2.2.1)$$

Onde,  $w_t$  corresponde a um ruído branco.

- Esperança condicional:

$$E[u_t^2 | I_{t-1}] = \zeta + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2 \quad (2.2.2)$$

- Como  $u_t^2 \geq 0$ , então, tem-se:
  - Equação 2.2.1 – deve ser não-negativa;
  - Equação 2.2.2 – deve ser positiva.
- Pode-se garantir que as condições acima sejam atendidas, se:
  - $-\zeta < w_t$ ;
  - $0 < \zeta$ ;
  - $\alpha_j \geq 0 \rightarrow j = 1, 2, \dots, m$ .
- Estacionaridade de segunda ordem (covariância):
  - Raízes do polinômio em  $Z$  devem corresponder a valores fora do círculo unitário.

$$1 - \alpha_1 \cdot z - \alpha_2 \cdot z^2 - \dots - \alpha_m \cdot z^m = 0 \quad (2.2.3)$$

Como  $\alpha_j \geq 0 \rightarrow j = 1, 2, \dots, m$ , então:  $\alpha_1 + \alpha_2 + \dots + \alpha_m < 1$

Uma vez satisfeitas as condições de estacionaridade de segunda ordem e aquelas referentes à própria característica dos dados de interesse, tem-se:

- Variância incondicional de  $u_t$ :

$$\sigma^2 = E[u_t^2] = \zeta / (1 - \alpha_1 - \alpha_2 - \dots - \alpha_m) \quad (2.2.4)$$

- Previsão “s” passos-à-frente:

$$\hat{u}_{t+s|t}^2 = E(u_{t+s}^2 | u_t^2, u_{t-1}^2, \dots) \quad (2.2.5)$$

$$(\hat{u}_{t+j|t}^2 - \sigma^2) = \alpha_1 (\hat{u}_{t+j-1|t}^2 - \sigma^2) + \alpha_2 (\hat{u}_{t+j-2|t}^2 - \sigma^2) + \dots + \alpha_m (\hat{u}_{t+j-m|t}^2 - \sigma^2) \quad (2.2.6)$$

$$j = 1, 2, \dots, s$$

Dessa forma,  $\hat{u}_{t+s|t}^2 \xrightarrow{p} \sigma^2$  (considerando os pressupostos assumidos).

### 2.2.1

#### Representação alternativa

Corresponde a um pressuposto mais forte sobre a dependência de  $u_t$ .

Seja:

$$u_t = \sqrt{h_t} \cdot v_t \rightarrow v_t \sim iid(0, 1) \quad (2.2.7)$$

$$E(v_t) = 0$$

$$E(v_t^2) = 1$$

$$\text{Se } h_t = \zeta + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2 \quad (2.2.8)$$

Então:

$$\text{ARCH}(m): E(u_{t+s}^2 | u_t^2, u_{t-1}^2, \dots) = \zeta + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2 \quad (2.2.9)$$

Substituindo (2.2.7) e (2.2.8) em (2.2.1), segue:

$$h_t \cdot v_t = h_t + w_t \quad \therefore w_t = h_t(v_t^2 - 1) \quad (2.2.10)$$

Assim, a variância (condicional) de  $w_t$  será:  $E(w_t^2) = \lambda^2$ .

Cabe ressaltar que a variância incondicional de  $w_t$  (quarto momento – curtose) não existe para todos os modelos ARCH estacionários.

### 2.2.2

#### Estimação dos parâmetros (máxima verossimilhança)

- $v_t$  é *Gaussiano*:

Seja a equação de regressão

$$y_t = X_t^T \cdot \beta + u_t \quad (2.2.11)$$

Onde,

$X_t$  – variáveis explicativas (incluindo defasamentos de  $y_t$ )

$$u_t = \sqrt{h_t} \cdot v_t \quad v_t \sim N(0, 1) \quad (2.2.12)$$

$$h_t = \xi + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2$$

Condicionando a estimação nas  $m$  primeiras observações ( $t = -m+1, -m+2, \dots, 0$ ).  $t = 1, 2, \dots, T$ .

Seja  $Y_t = (y_t, y_{t-1}, \dots, y_1, y_0, \dots, y_{-m+1}, X'_t, X'_{t-1}, \dots, X'_1, X'_0, \dots, X'_{-m+1})$ . Então, sendo  $v_t \sim$  i.i.d.  $N(0, 1)$  e  $v_t$  independente de  $X_t$  e  $Y_t$ , tem-se que a distribuição condicional de  $y_t$  é gaussiana com média  $X'_t \beta$  e variância  $h_t$ .

$$f(y_t | X_t; Y_{t-1}) = \frac{1}{\sqrt{2 \cdot \pi \cdot h_t}} \cdot \exp\left(-\frac{1}{2} \cdot \frac{(y_t - X_t^T \cdot \beta)^2}{h_t}\right) \quad (2.2.13)$$

Onde,

$$h_t = \xi + \alpha_1 \cdot (y_{t-1} - X_{t-1}^T \cdot \beta)^2 + \alpha_2 \cdot (y_{t-2} - X_{t-2}^T \cdot \beta)^2 + \dots + \alpha_m \cdot (y_{t-m} - X_{t-m}^T \cdot \beta)^2$$

$$h_t = [Z(\beta)]^T \cdot \delta \quad (2.2.14)$$

$$\delta = (\xi, \alpha_1, \alpha_2, \dots, \alpha_m) \quad (2.2.15)$$

$$[Z(\beta)]^T = \left[ 1, (y_{t-1} - X_{t-1}^T \cdot \beta)^2, (y_{t-2} - X_{t-2}^T \cdot \beta)^2, \dots, (y_{t-m} - X_{t-m}^T \cdot \beta)^2 \right] \quad (2.2.16)$$

Sendo  $\theta$  o vetor de hiperparâmetros.

$$\theta_{(ax1)} \equiv (\beta', \delta')$$

Log-verossimilhança:

$$L(\theta) = \sum_{t=1}^T \log[f(y_t | X_t; Y_{t-1}; \theta)]$$

$$L(\theta) = -\left(\frac{T}{2}\right) \cdot \log(2 \cdot \pi) - \left(\frac{1}{2}\right) \cdot \sum_{t=1}^T \log(h_t) - \left(\frac{1}{2}\right) \cdot \sum_{t=1}^T \left[ \frac{(y_t - X_t^T \cdot \beta)^2}{h_t} \right] \quad (2.2.17)$$

Trata-se, portanto, de um problema de otimização não-linear com restrições (estacionaridade).

$$\text{Max } L(\theta) = -\left(\frac{T}{2}\right) \cdot \log(2 \cdot \pi) - \left(\frac{1}{2}\right) \cdot \sum_{t=1}^T \log(h_t) - \left(\frac{1}{2}\right) \cdot \sum_{t=1}^T \left[ \frac{(y_t - X_t^T \cdot \beta)^2}{h_t} \right]$$

s.a.

$$\alpha_j \geq 0 \rightarrow \text{para todo } j$$

$$\sum_{j=1}^m \alpha_j < 1$$

## 2.3

### Outras formulações propostas

#### 2.3.1

#### GARCH

Seja:

$$u_t = \sqrt{h_t} \cdot v_t \rightarrow v_t \sim iid(0, 1)$$

$$h_t = \zeta + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2$$

ARCH(m)

Pode-se imaginar um processo no qual a variância condicional dependa de um número infinito de defasamentos da variável de interesse.

$$h_t = \zeta + \pi(L) \cdot u_t^2 \quad (2.3.1)$$

$$\pi(L) = \sum_{j=1}^{\infty} \pi_j \cdot L^j \quad (2.3.2)$$

Dessa forma, poder-se-ia definir  $\pi(L)$  como sendo a razão de dois polinômios de ordem finita, onde as raízes daquele contido no denominador fossem maiores que 1 (um) em módulo.

$$\pi(L) = \frac{\alpha(L)}{1 - \delta(L)} = \frac{\alpha_1 \cdot L^1 + \alpha_2 \cdot L^2 + \dots + \alpha_m \cdot L^m}{1 - \delta_1 \cdot L^1 - \delta_2 \cdot L^2 - \dots - \delta_r \cdot L^r}$$

Aplicando  $\pi(L)$  ter-se-ia:

$$h_t = \zeta + \frac{\alpha(L)}{1 - \delta(L)} \cdot u_t^2$$

$$[1 - \delta(L)] \cdot h_t = [1 - \delta(L)] \cdot \zeta + \alpha(L) \cdot u_t^2$$

$$\text{Assim, GARCH}(r, m): h_t - \delta(L) \cdot h_t = K + \alpha(L) \cdot u_t^2 \quad (2.3.3)$$

Adicionando  $u_t$ , tem-se:

$$h_t + u_t^2 - u_t^2 = K + \alpha(L) \cdot u_t^2 + \delta(L) \cdot h_t + \delta(L) \cdot u_t^2 - \delta(L) \cdot u_t^2$$

Fazendo  $(u_t^2 - h_t) = w_t$ , tem-se:

$$u_t^2 = K + [(\alpha_1 + \delta_1) \cdot u_{t-1}^2 + \dots + (\alpha_p + \delta_p) \cdot u_{t-p}^2] + w_t - \delta_1 \cdot w_{t-1} - \dots - \delta_r \cdot w_{t-r} \quad (2.3.4)$$

Onde,

$w_t$  – erro de previsão da variância (ruído branco) – seqüência de diferenças Martingale.

Assim, pode-se propor uma analogia entre o modelo GARCH (r, m) e os modelos ARMA (p, q), onde  $p = \text{Max}(r, m)$ .

Pontos importantes:

- O requerimento de não-negatividade é satisfeito se:

$$K > 0; \alpha_j \geq 0; \delta_j \geq 0 \rightarrow \text{para } j = 1, \dots, p$$

- De modo análogo aos processos ARMA, o modelo GARCH se mostrará estacionário de segunda ordem (covariância) se as raízes do polinômio em Z (conforme definido a seguir) apresentarem valores maiores do que 1 (um) em módulo.

$$1 - (\delta_1 + \alpha_1) \cdot Z - (\delta_2 + \alpha_2) \cdot Z^2 - \dots - (\delta_p + \alpha_p) \cdot Z^p = 0$$

Considerando as restrições de não-negatividade, o processo será estacionário se:

$$(\delta_1 + \alpha_1) + (\delta_2 + \alpha_2) + \dots + (\delta_p + \alpha_p) < 1$$

Tomando por base o que fora apresentado até o presente momento, tem-se que:

- a média incondicional de  $u_t^2$  será:

$$E(u_t^2) = \sigma^2 = \frac{K}{[1 - (\delta_1 + \alpha_1) - (\delta_2 + \alpha_2) - \dots - (\delta_p + \alpha_p)]} \quad (2.3.5)$$



- a previsão  $\hat{u}_{t+s}^2$ , considerando  $u_t^2, u_{t-1}^2, \dots, u_0^2$ , será:

$$\hat{u}_{t+s}^2 - \sigma^2 = \begin{cases} (\delta_1 + \alpha_1)(\hat{u}_{t+s-1}^2 - \sigma^2) + \dots + (\delta_1 + \alpha_1)(\hat{u}_{t+1}^2 - \sigma^2) \\ - \delta_s \hat{w}_t - \dots - \delta_r \hat{w}_{t-r} & p/s = 1, \dots, r \\ (\delta_1 + \alpha_1)(\hat{u}_{t+s-1}^2 - \sigma^2) + \dots + (\delta_1 + \alpha_1)(\hat{u}_{t+1}^2 - \sigma^2) & p/s > r \end{cases} \quad (2.3.6)$$

OBS.

O cálculo da seqüência de variâncias condicionais  $\{h_t\}_{t=1}^T$  requer uma “amostra pré-existente” ( $h_{-p+1}, \dots, h_0$  e  $u_{-p+1}^2, \dots, u_0^2$ ). Para contornar tal problema, Bollerslev propôs o seguinte procedimento:

- 1) Fazer  $h_j = u_j^2 = \hat{\sigma}^2 \rightarrow p/j = (-p+1), \dots, 0$ ;
- 2) Definir  $\hat{\sigma}^2 = T^{-1} \cdot \sum_{t=1}^T (y - X_t^T \cdot \beta)^2$ ;
- 3) Estimar a seqüência  $\{h_t\}_{t=1}^T$  pelo método da máxima verossimilhança (otimização não-linear com restrições).

### 2.3.2

#### IGARCH

Dizemos que  $u_t^2$  segue um processo IGARCH, caso este apresente raiz unitária (integrável). De forma análoga, tem-se:

$$\sum_{j=1}^r \delta_j + \sum_{l=1}^m \alpha_l = 1$$

Da mesma forma que nos processos ARIMA, se  $u_t^2$  possui raiz unitária, então a variância incondicional tende para infinito (comportamento explosivo).

### 2.3.3

#### ARCH-M (ARCH “na média”)

O modelo ARCH-M toma por base a teoria de finanças, a qual sugere que investidores racionais exigem um retorno maior (prêmio de risco) para negociarem ativos financeiros com maior grau de risco (risco associado à dispersão – volatilidade). Dessa forma, sendo:

$$r_t = \mu_t + u_t \quad (2.3.7)$$

Onde,

$r_t$  – retorno de um determinado ativo financeiro;

$\mu_t$  – parcela do retorno antecipada pelos investidores em t-1;

$u_t$  – parcela do retorno não antecipada.

Então, a teoria propõe que  $\mu_t$  estaria associado com a própria variância do retorno - $h_t$  (parâmetro de risco).

Tomando por base o que foi disposto anteriormente, em 1987 Engle propôs a seguinte formulação:

$$y_t = X_t^T \cdot \beta + \delta \cdot h_t + u_t \quad (2.3.8)$$

$$u_t = \sqrt{h_t} \cdot v_t \quad v_t \sim N(0, 1) \quad (2.3.9)$$

$$h_t = \xi + \alpha_1 \cdot u_{t-1}^2 + \alpha_2 \cdot u_{t-2}^2 + \dots + \alpha_m \cdot u_{t-m}^2 \quad (2.3.10)$$

onde o efeito da volatilidade sobre o prêmio de risco (consolidado no retorno) é medido pelo hiperparâmetro  $\delta$ .

### 2.3.4

#### E-GARCH (*Exponential GARCH*)

Seja:

$$u_t = \sqrt{h_t} \cdot v_t \quad (2.3.11)$$

$$\log(h_t) = \xi + \sum_{j=1}^{\infty} \pi_j \cdot \left\{ |v_{t-j}| - E|v_{t-j}| + \chi \cdot v_{t-j} \right\} \quad (2.3.12)$$

então, se  $\pi_j > 0$ , um desvio  $|v_{t-j}|$  ocasiona um aumento da variância condicional de  $u_t$ .

Já o termo  $\chi$ , é responsável por modelar adequadamente o efeito resultante da assimetria presente na distribuição de retornos de ativos financeiros. Assim, tem-se:

- $\chi = 0$  – choques positivos e negativos geram o mesmo efeito na variância;
- $-1 < \chi < 0$  – choques positivos aumentam menos a variância do que os negativos;
- $\chi < -1$  – choques positivos reduzem a volatilidade e choques negativos produzem o efeito contrário.

Uma das vantagens da formulação do E-GARCH é o fato de o processo de estimação dos parâmetros não apresentar quaisquer tipos de restrições com relação aos valores que os mesmos poderão assumir, uma vez que estar-se-á trabalhando com  $\log(h_t)$  e que  $\pi_j > 0$ .

Uma parametrização natural é modelar  $\pi(L)$  como a razão de dois polinômios de ordem finita – procedimento análogo ao GARCH(r, m). Deste modo, ter-se-ia:

$$\begin{aligned} \log(h_t) = & k + \delta_1 \cdot \log(h_{t-1}) + \dots + \delta_r \cdot \log(h_{t-r}) + \alpha_1 \cdot \{ |v_{t-1}| - E|v_{t-1}| + \chi \cdot v_{t-1} \} \\ & + \dots + \alpha_m \cdot \{ |v_{t-m}| - E|v_{t-m}| + \chi \cdot v_{t-m} \} \end{aligned} \quad (2.3.13)$$

### 2.3.4.1

#### Estimação dos parâmetros: máxima verossimilhança

Para o processo de estimação dos parâmetros, torna-se necessário especificar a função de distribuição de probabilidades de  $v_t$ .

Uma alternativa seria a utilização da distribuição padronizada generalizada do erro (Nelson).

$$f(v_t) = \frac{v \cdot \exp\left(-\frac{1}{2} \cdot \left|\frac{v_t}{\lambda}\right|^\nu\right)}{\lambda \cdot 2^{\lceil(\nu+1)/\nu\rceil} \cdot \Gamma\left(\frac{1}{\nu}\right)} \quad (2.3.14)$$

Onde,

$\Gamma(\cdot)$  – função gama;

$$\lambda = \left\{ \frac{2^{-2/\nu} \cdot \Gamma\left(\frac{1}{\nu}\right)}{\Gamma\left(\frac{3}{\nu}\right)} \right\}^{1/2}$$

$\nu$  – parâmetro positivo que governa a largura das caudas.

- $\nu < 2$  – caudas largas;
- $\nu > 2$  – caudas estreitas.

OBS. Para  $\nu = 2$ , então,  $\lambda = 1$  e, por conseguinte,  $f(v_t) \sim Normal$ .