

3

Modelos de Volatilidade Estocástica

3.1

O Modelo Univariado

O modelo de volatilidade estocástica (VE) é composto por duas equações básicas: uma que descreve o processo dos retornos (R_t), variável observável, e outra que descreve o processo de uma variável não observável (h_t), chave para a descrição da volatilidade dos retornos. Segue abaixo um modelo particular de VE em que h_t segue um processo autoregressivo de ordem 1 com intercepto:

$$R_t = \mu_t + \varepsilon_t e^{\frac{h_t}{2}} \quad \varepsilon_t \sim NID(0,1) \quad (1)$$

$$h_t = \gamma + \phi h_{t-1} + \eta_t \quad \text{para } |\phi| < 1, \quad \eta_t \sim NID(0, \sigma_\eta^2)$$

$$\text{com } E(\varepsilon_t, \eta_s) = 0 \quad \forall t, s$$

Ressalta-se que μ_t representa a média dos retornos. Um fato estilizado⁶ comum a séries financeiras é a presença de média nula dos retornos. Por esta razão, μ_t é comumente omitido em diversos trabalhos para efeito de simplificação da notação.

A média e variância incondicionais dos retornos podem ser calculadas da seguinte forma:

$$\begin{aligned} E(R_t) &= E(\varepsilon_t e^{\frac{h_t}{2}}) \\ &= E(\varepsilon_t) E(e^{\frac{h_t}{2}}) \\ &= 0 \end{aligned} \quad (2)$$

⁶ Fatos estilizados são regularidades estatísticas observadas em um grande número de séries financeiras de retornos

$$\begin{aligned}
V(R_t) &= E(R_t^2) - [E(R_t)]^2 \\
&= E(R_t^2) \\
&= E(\varepsilon_t^2 e^{h_t}) \\
&= E(\varepsilon_t^2) E(e^{h_t}) \\
&= E(e^{h_t})
\end{aligned} \tag{3}$$

Pela teoria da Distribuição Normal:

Se

$$h_t \sim N(\mu_h, \sigma_h^2) \text{ então } e^{h_t} \sim \text{Lognormal} \left(e^{\mu_h + \frac{\sigma_h^2}{2}}, [(e^{2\mu_h + \sigma_h^2})(e^{\sigma_h^2} - 1)] \right) \tag{4}$$

Logo

$$V(R_t) = e^{\mu_h + \frac{\sigma_h^2}{2}} \tag{5}$$

Onde:

$$\begin{aligned}
\mu_h &= E(h_t) \\
&= E(\gamma + \phi h_{t-1} + \eta_t) \\
&= E(\gamma + \phi(\gamma + \phi h_{t-2} + \eta_{t-1}) + \eta_t) \\
&= E(\gamma + \phi\gamma + \phi^2\gamma + \dots + \eta_t + \phi\eta_{t-1} + \phi^2\eta_{t-2} + \dots) \\
&= E(\gamma + \phi\gamma + \phi^2\gamma + \dots) + E(\eta_t + \phi\eta_{t-1} + \phi^2\eta_{t-2} + \dots) \\
&= \frac{\gamma}{1-\phi}
\end{aligned} \tag{6}$$

e

$$\begin{aligned}
\sigma_h^2 &= V(h_t) \\
&= V(\gamma + \phi\gamma + \phi^2\gamma + \dots + \eta_t + \phi\eta_{t-1} + \phi^2\eta_{t-2} + \dots) \\
&= V(\gamma + \phi\gamma + \phi^2\gamma + \dots) + V(\eta_t + \phi\eta_{t-1} + \phi^2\eta_{t-2} + \dots) \\
&= \frac{\sigma_\eta^2}{1-\phi^2}
\end{aligned} \tag{7}$$

Sob a hipótese de $\varepsilon_t \sim NID(0,1)$, temos $E(\varepsilon_t^3) = 0$ e $E(\varepsilon_t^4) = 3$, o que implica em retornos simétricos e leptocúrticos, como demonstrado a seguir:

$$\begin{aligned}
\text{Assimetria}(R_t) &= \frac{E[(R_t - E(R_t))^3]}{V(R_t)^{3/2}} \\
&= \frac{E[R_t^3]}{V(R_t)^{3/2}} \\
&= \frac{E\left[\left(\varepsilon_t e^{\frac{h_t}{2}}\right)^3\right]}{V(R_t)^{3/2}} \\
&= \frac{E\left[\varepsilon_t^3 \left(e^{\frac{3h_t}{2}}\right)\right]}{V(R_t)^{3/2}} \\
&= \frac{E(\varepsilon_t^3) E\left(e^{\frac{3h_t}{2}}\right)}{V(R_t)^{3/2}} \\
&= 0
\end{aligned} \tag{8}$$

$$\begin{aligned}
\text{Curtose}(R_t) &= \frac{E[(R_t - E(R_t))^4]}{V(R_t)^{4/2}} \\
&= \frac{E[R_t^4]}{\left(e^{\mu_h + \frac{\sigma_h^2}{2}}\right)^2} \\
&= \frac{E\left[\left(\varepsilon_t e^{\frac{h_t}{2}}\right)^4\right]}{\left(e^{\mu_h + \frac{\sigma_h^2}{2}}\right)^2} \\
&= \frac{E(\varepsilon_t^4) E(e^{2h_t})}{\left(e^{\mu_h + \frac{\sigma_h^2}{2}}\right)^2} \\
&= \frac{3E(e^{2h_t})}{\left(e^{2\mu_h + \sigma_h^2}\right)}
\end{aligned} \tag{9}$$

Novamente, pela teoria da Distribuição Normal:

$$\text{Se } h_t \sim N(\mu_h, \sigma_h^2) \text{ então } 2h_t \sim N(2\mu_h, 4\sigma_h^2) \tag{10.a}$$

o que implica em:

$$e^{2h_t} \sim \text{Lognormal} \left(e^{2\mu_h + \frac{4\sigma_h^2}{2}}, [(e^{4\mu_h + 4\sigma_h^2})(e^{4\sigma_h^2} - 1)] \right) \quad (10.b)$$

Aplicando (10.b) em (9) temos:

$$\begin{aligned} \text{Curtose}(R_t) &= \frac{3e^{2\mu_h + \frac{4\sigma_h^2}{2}}}{(e^{2\mu_h + \sigma_h^2})^2} \\ &= \frac{3e^{2\mu_h} \cdot e^{2\sigma_h^2}}{e^{2\mu_h} \cdot e^{\sigma_h^2}} \\ &= 3e^{\sigma_h^2} > 3 \end{aligned} \quad (11)$$

Provando, portanto, que os retornos são leptocúrticos.

A média e variância condicionais dos retornos podem ser obtidas de maneira similar:

$$\begin{aligned} E(R_t / \mathfrak{I}_{t-1}) &= E(\varepsilon_t e^{\frac{h_t}{2}} / \mathfrak{I}_{t-1}) \\ &= E(\varepsilon_t / \mathfrak{I}_{t-1}) E(e^{\frac{h_t}{2}} / \mathfrak{I}_{t-1}) \\ &= 0 \end{aligned} \quad (12)$$

$$\begin{aligned} V(R_t / \mathfrak{I}_{t-1}) &= E(R_t^2 / \mathfrak{I}_{t-1}) - [E(R_t) / \mathfrak{I}_{t-1}]^2 \\ &= E(R_t^2 / \mathfrak{I}_{t-1}) \\ &= E(\varepsilon_t^2 e^{h_t} / \mathfrak{I}_{t-1}) \\ &= E(\varepsilon_t^2 / \mathfrak{I}_{t-1}) E(e^{h_t} / \mathfrak{I}_{t-1}) \\ &= E(e^{h_t} / \mathfrak{I}_{t-1}) \end{aligned} \quad (13)$$

Pela teoria da Distribuição Normal: (14)

$$\text{Se } h_t / \mathfrak{I}_{t-1} \sim N(\mu_{ch}, \sigma_{ch}^2) \text{ então } e^{h_t} / \mathfrak{I}_{t-1} \sim \text{Lognormal} \left(e^{\mu_{ch} + \frac{\sigma_{ch}^2}{2}}, [(e^{2\mu_{ch} + \sigma_{ch}^2})(e^{\sigma_{ch}^2} - 1)] \right)$$

Desta forma, temos que

$$V(R_t / \mathfrak{I}_{t-1}) = e^{\mu_{ch} + \frac{\sigma_{ch}^2}{2}} \quad (15)$$

Conclui-se, portanto, que a estimação da variância condicional dos retornos passa pela estimação da média e variância condicionais de h_t ,

representadas acima por μ_{ch} e σ_{ch}^2 . Denominemos os estimadores de μ_{ch} e σ_{ch}^2 , respectivamente, de a_t e P_t de forma que:

$$\text{volatilidade estimada} = \hat{V}(R_t / \mathfrak{I}_{t-1}) = e^{\hat{\mu}_h + \frac{\hat{\sigma}_h^2}{2}} = e^{at + \frac{P_t}{2}} \quad (16)$$

A estimação por *Quasi* Máxima Verossimilhança (QMV) é feita concomitantemente com a aplicação do filtro de Kalman, ferramenta que será descrita com maiores detalhes no capítulo 4 deste Trabalho. Por esta razão é preciso colocar o modelo (1) na forma de Espaço de Estado (EE), o que exige a linearização da equação dos retornos. Isto é feito através da elevação ao quadrado da primeira equação, seguida de sua logaritmização:

$$R_t^2 = \{\exp(h_t)\} * \varepsilon_t^2 \quad (17)$$

$$\log(R_t^2) = h_t + \log(\varepsilon_t^2)$$

Em Abramovitz e Stugan (1970) mostra-se que a média e variância de $\log(\varepsilon_t^2)$ são, respectivamente, -1,27 e $\frac{\pi^2}{2}$. É conveniente, portanto, reescrever a equação (17) como:

$$\log(R_t^2) + 1,27 = h_t + \log(\varepsilon_t^2) + 1,27 \quad (18)$$

Denotemos $y_t = \log(R_t^2) + 1,27$ e $\xi_t = \log(\varepsilon_t^2) + 1,27$, de forma que $E(\xi_t) = 0$. Com isso podemos escrever um modelo em que o erro da equação das medidas tem média nula, como exige a forma em Espaço de Estado:

$$y_t = h_t + \xi_t \quad \xi_t \sim (0, \frac{\pi^2}{2}) \quad (19)$$

$$h_t = \gamma + \phi h_{t-1} + \eta_t \quad \eta_t \sim NID(0, \sigma_\eta^2)$$

$$\text{com } E(\xi_t, \eta_s) = 0 \quad \forall t, s^7$$

É importante ressaltar que com base em análises empíricas os retornos das séries financeiras, em geral, não apresentam distribuição Normal. Desta forma, a

⁷ Caso não fosse imposta a restrição de não correlação entre ε_t e η_s no modelo original (1), pode-se demonstrar que ξ_t e η_s , $\forall t, s$, são descorrelatados [cf. Harvey, Ruiz e Shephard (1994)].

solução via QMV por filtro de Kalman, quando se supõe normalidade dos dados, é sub-ótima.

3.2

O Modelo Multivariado

A extensão do modelo univariado para o multivariado é imediata. Supondo p séries com n observações cada, pode-se reescrever o modelo (19) da seguinte forma:

$$\begin{aligned}
 \begin{bmatrix} y_{1,t} \\ y_{2,t} \\ \dots \\ y_{p,t} \end{bmatrix}_{px1} &= \begin{bmatrix} h_{1,t} \\ h_{2,t} \\ \dots \\ h_{p,t} \end{bmatrix}_{px1} + \begin{bmatrix} \xi_{1,t} \\ \xi_{2,t} \\ \dots \\ \xi_{p,t} \end{bmatrix}_{px1} \quad \begin{bmatrix} \xi_{1,t} \\ \xi_{2,t} \\ \dots \\ \xi_{p,t} \end{bmatrix}_{pxn} \sim \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}_{px1}, H_{t_{pxp}} \right) \\
 \begin{bmatrix} h_{1,t+1} \\ h_{2,t+1} \\ \dots \\ h_{p,t+1} \end{bmatrix}_{px1} &= \begin{bmatrix} \gamma_{1,t} \\ \gamma_{2,t} \\ \dots \\ \gamma_{p,t} \end{bmatrix}_{px1} + \begin{bmatrix} \phi_{11} & \phi_{12} & \dots & \phi_{1p} \\ \phi_{21} & \phi_{22} & \dots & \phi_{2p} \\ \dots & \dots & \dots & \dots \\ \phi_{p1} & \phi_{p2} & \dots & \phi_{pp} \end{bmatrix} \begin{bmatrix} h_{1,t} \\ h_{2,t} \\ \dots \\ h_{p,t} \end{bmatrix}_{px1} + \begin{bmatrix} \eta_{1,t} \\ \eta_{2,t} \\ \dots \\ \eta_{p,t} \end{bmatrix}_{px1} \quad (20) \\
 \text{sendo } H_t &= \frac{\pi^2}{2} \begin{bmatrix} 1 & \rho_{1,2}^* & \dots & \rho_{1,p}^* \\ \rho_{2,1}^* & 1 & \dots & \rho_{2,p}^* \\ \vdots & \vdots & \vdots & \vdots \\ \rho_{p,1}^* & \rho_{p,2}^* & \dots & 1 \end{bmatrix}_{pxp} \quad \text{e} \quad \begin{bmatrix} \eta_{1,t} \\ \eta_{2,t} \\ \dots \\ \eta_{p,t} \end{bmatrix}_{px1} \sim \left(\begin{bmatrix} 0 \\ 0 \\ 0 \\ 0 \end{bmatrix}_{px1}, Q_{t_{pxp}} \right)
 \end{aligned}$$

Após a elevação ao quadrado da equação dos retornos seguida da logaritmização dos termos, surge uma dificuldade em recuperar os sinais originais dos erros da equação das medidas (ε_t) a partir dos elementos de H_t . Isto é percebido, quando se escrevem os coeficientes de correlação de ξ_t ($\rho_{i,j}^*$) em função dos elementos da matriz de correlação dos erros originais dos retornos (ε_t), representada aqui por ρ_ε :

$$\rho_\varepsilon = \begin{bmatrix} 1 & \rho_{1,2} & \cdots & \rho_{1,p} \\ \rho_{2,1} & 1 & \cdots & \rho_{2,p} \\ \vdots & \vdots & \vdots & \vdots \\ \rho_{p,1} & \rho_{p,2} & \cdots & 1 \end{bmatrix}_{p \times p} \quad (21)$$

Em Harvey, Ruiz e Shephard (1994) demonstra-se que os elementos $\rho_{i,j}^*$ podem ser escritos como:

$$\rho_{i,j}^* = \frac{2}{\pi^2} \sum_{n=1}^{\infty} \frac{(n-1)!}{(0,5)_n n} \rho_{i,j}^{2n} \quad (22)$$

$$\text{Onde } (0,5)_n = (0,5) * (0,5 + 1) * (0,5 + 2) * \dots * (0,5 + n - 1)$$

Para recuperar os sinais dos coeficientes de correlação $\rho_{i,j}$ sugere-se retomar as séries originais dos retornos e obter para cada instante de tempo o produto cruzado das séries duas a duas. Se mais da metade dos elementos da série “produto” for composta de termos positivos, então o coeficiente de correlação entre os erros das séries multiplicadas é positivo. Para efeito de ilustração, suponha $p=3$. Com base nas séries originais dos retornos R_{1t}, R_{2t} e R_{3t} (que dão origem respectivamente a y_{1t}, y_{2t} e y_{3t} após a linearização) devem-se obter para cada instante de tempo, as seguintes séries “produto”:

$$\begin{aligned} R_{1,2} &= R_{1t} * R_{2t} \\ R_{1,3} &= R_{1t} * R_{3t} \\ R_{2,3} &= R_{2t} * R_{3t} \end{aligned} \quad (23)$$

para $t=1, \dots, n$

Se o número de termos positivos na série $R_{i,j}$, para $i < j$, $i, j = 1, \dots, 3$ for maior que a metade do número de termos da série $R_{i,j}$ então fixa-se o sinal de $\rho_{i,j}$ como positivo, caso contrário, negativo.

3.3

Modelos de Fatores Comuns para Tendência

Como o nome antecipa, os modelos de fatores comuns para tendência são aplicados a bases multivariadas na tentativa de extrair fatores não observáveis, porém comuns às tendências das séries. Utilizando a notação de Harvey (1989, p.450), onde é feita uma abordagem completa sobre o tema, temos um modelo particular com p séries e k fatores comuns, os quais seguem um passeio aleatório:

$$Y_{t \text{ px1}} = \Theta_{\text{pxk}} \mu_{t \text{ kx1}} + \mu^0_{\text{px1}} + \varepsilon_{t \text{ px1}}, \quad \text{Var}(\varepsilon_t) = \Sigma_{\varepsilon \text{ pxp}} \quad (24)$$

$$\mu_{t+1 \text{ kx1}} = \mu_{t \text{ kx1}} + \beta_{0 \text{ kx1}} + \eta_{t \text{ kx1}}, \quad \text{Var}(\eta_t) = \Sigma_{\eta \text{ kxk}}$$

para $k \leq p$,

sendo μ^0 vetor com as primeiras k coordenadas nulas.

O vetor μ_t contempla os fatores comuns que regem o processo das diferentes tendências das séries temporais em Y_t .

Entretanto, o modelo como apresentado em (24) não é identificável. A comprovação pode ser feita tomando uma matriz qualquer H_{kxk} ortogonal e fazendo $\Theta^x = \Theta H^{-1}$, $\mu^x = H \mu$, $\beta_0^x = H \beta_0$, $\eta^x = H \eta$, $\text{Var}(\eta^x) = H \Sigma_{\eta} H'$.

Com isso temos:

$$Y_t = \Theta^x \mu_t^x + \mu^0 + \varepsilon_t, \quad \text{Var}(\varepsilon_t) = \Sigma_{\varepsilon} \quad (25)$$

$$\mu_{t+1}^x = \mu_t^x + \beta_0^x + \eta_t^x, \quad \text{Var}(\eta_t) = H \Sigma_{\eta} H'$$

para $k \leq p$,

de forma que o modelo (25) é indistinguível de (24). Isto significa que há infinitos parâmetros que geram a mesma função densidade para as observações em Y_t .

Para tornar o modelo identificável, devem-se impor algumas restrições sobre Σ_{η} e

Θ . Harvey (1989) sugere as seguintes restrições em conjunto:

$$(i) \Sigma_{\eta} \text{ diagonal} \quad (26)$$

$$(ii) \begin{cases} \Theta[i][i] = 1, \text{ para } i = 1, 2, \dots, k \\ \Theta[i][j] = 0, \text{ para } j > i, \text{ tal que } j = 1, 2, \dots, p \text{ e } i = 1, 2, \dots, k \end{cases}$$

A primeira restrição implica que os fatores comuns são não correlacionados entre si, o que é desejável para efeitos de simplificação da interpretação dos resultados. A segunda restrição tem menos apelo intuitivo e implica que a primeira série depende do primeiro fator comum, mas independe dos outros, a segunda série depende do primeiro e segundo fatores, mas não depende dos outros e assim sucessivamente.

As principais vantagens do modelo estão na sua parcimônia, uma vez que tenta-se encontrar apenas k ($k \leq p$) fatores para explicar o comportamento das p tendências das variáveis abarcadas em Y_t e na facilidade de interpretação do modelo. Esta advém da possibilidade do modelo ser multiplicado por uma matriz ortogonal R construída convenientemente e dita matriz de rotação dos fatores.

3.4

Modelos de Fatores Comuns para Volatilidade

Trata-se de uma simples adaptação do modelo anterior para modelos de volatilidade estocástica. Em Harvey, Ruiz e Shephard (1994) modelou-se a extração de fatores comuns entre as volatilidades das seguintes taxas de câmbio: marco/dólar, yen/dólar, libra/dólar e franco/dólar. Para tanto, supôs-se que a fator latente associado à volatilidade (h_t) seguia um processo de passeio aleatório, como mostrado a seguir:

$$\omega_{t \text{ px1}} = -1,27_{\text{px1}} + \Theta_{\text{pxk}} h_{t \text{ kx1}} + \bar{h}_{\text{kx1}} + \xi_{t \text{ kx1}} \quad \xi_{t \text{ pxp}} \sim (0_{\text{px1}}, \Sigma_{\xi_{\text{pxp}}}) \quad (27)$$

$$h_{t \text{ kxk}} = h_{t-1 \text{ kx1}} + \eta_{t \text{ kx1}}, \quad \eta_{t \text{ kxk}} \sim (0_{\text{kx1}}, \Sigma_{\eta_{\text{kxk}}})$$

Onde:

(i) R_t são os retornos das taxas de câmbio e seguem o seguinte processo

$$R_t = \left\{ \left[\exp(h_t) \right]^{1/2} \right\} * \varepsilon_t, \quad \varepsilon_t \sim (0,1)$$

$$(ii) \omega_t = \log(R_t^2),$$

$$(iii) \xi_t = \log(\varepsilon_t^2) + 1,27,$$

(iv) \bar{h} tem as primeiras k coordenadas nulas ,

(v) os elementos da diagonal da matriz Σ_ξ são $\frac{\pi^2}{2}$,

Assim como o modelo (25), o modelo (27) é não identificável, sendo necessária a imposição de restrições para estimá-lo. Em Harvey, Ruiz e Shephard (1994) as restrições sugeridas são:

$$(r.i) \Theta[i][j] = 0 \text{ se } j > i, \text{ para } j = 1, 2, \dots, p \quad i = 1, 2, \dots, k \quad (29)$$

$$(r.ii) \Sigma_\eta = I_{k \times k}$$

A grande questão, no entanto, ainda não foi abordada e trata-se de como obter o número correto de fatores comuns entre as volatilidades. A sugestão de Harvey, Ruiz e Shephard (1994) consiste em primeiramente estimar o modelo clássico de volatilidade estocástica multivariado (20), supondo que tanto a equação das medidas quanto a do estado seguem passeios aleatórios sem intercepto. Isto equivale a estimar o modelo (24) com o máximo de fatores comuns possíveis, isto é, $k=p$, e supondo $\Theta = I$. Observe que sob esta restrição o modelo é identificável.

Após a estimação da matriz de covariância do erro η_t , denotada por Σ_η , é feita a Análise de Componentes Principais (ACP) sobre $\hat{\Sigma}_\eta$, um método cuja finalidade é a redução da dimensionalidade do espaço dos componentes com o intuito de facilitar a interpretação do modelo. Os fatores são, em resumo, os autovetores da matriz de covariância estimada, multiplicados pelas respectivas raízes quadradas de seus autovalores. Ranqueia-se os fatores de forma decrescente com os autovalores a que estão associados. Fica a critério do analista, o número de fatores a serem escolhidos. No artigo citado, escolheu-se o menor número de fatores capaz de explicar pelo menos 95% da variação do sistema. Tal critério

resultou na escolha de dois fatores comuns. Uma vez determinado o número de fatores comuns (k), estima-se novamente o modelo (24), com as matrizes de coeficiente, impondo-se as devidas restrições para tornar o modelo identificável.