

**Problema 1.** Seja  $r_t$  os retornos (ou log-retornos) diários de um ativo financeiros (por exemplo, S&P500 ou Petrobrás ON) tal que  $r_t = \sigma_t \varepsilon_t$ , onde  $\varepsilon_t$  e  $\sigma_t$  são independentes e  $\varepsilon_t \sim NID(0,1)$ . Portanto  $r_t$  também é normal com  $E(r_t) = 0$  e  $V(r_t) = E(r_t^2) = E(\sigma_t^2)$ . Ou seja, apesar da média condicional de  $r_t$  ser zero, sua variância condicional é  $\sigma_t$  e pode variar no tempo, um fato comumente observado em séries temporais financeiras. A curtose de  $r_t$ , denotada aqui por  $K_{r_t}$ , mede o peso das caudas da distribuição de  $r_t$  e é dada por  $K_{r_t} = E(r_t^4)/\{E(r_t^2)\}^2$ . Obtenha  $K_{r_t}$  para os modelos: a) ARCH(1):  $\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2$ ; b) GARCH(1,1):  $\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \sigma_{t-1}^2$ ; e c) SV-AR(1):  $\log \sigma_t^2 = \mu + \phi(\log \sigma_{t-1}^2 - \mu) + u_t$ , onde  $u_t \sim N(0, \tau^2)$ .

Antes de resolvermos a)-c), vamos relembrar a diferença entre esperança (variância) condicional e esperança (variância) incondicional. É fácil ver que

$$E(r_t | \sigma_t) = E(\sigma_t \varepsilon_t | \sigma_t) \stackrel{\sigma_t \perp \varepsilon_t}{=} E(\sigma_t | \sigma_t) E(\varepsilon_t | \sigma_t) = \sigma_t \times 0 = 0,$$

onde  $\sigma_t \perp \varepsilon_t$  denota que  $\sigma_t$  é independente de  $\varepsilon_t$ . Segue, de um resultado básico de probabilidade<sup>1</sup>, que  $V(r_t | \sigma_t^2) = E(r_t^2 | \sigma_t^2)$ . Portanto

$$V(r_t | \sigma_t) = E(r_t^2 | \sigma_t) = E(\sigma_t^2 \varepsilon_t^2 | \sigma_t) \stackrel{\sigma_t \perp \varepsilon_t}{=} E(\sigma_t^2 | \sigma_t) E(\varepsilon_t^2 | \sigma_t) = \sigma_t^2 \times 1 = \sigma_t^2,$$

pois  $E(\varepsilon_t^2 | \sigma_t) = E(\varepsilon_t^2) = 1$ . Perceba que a suposição de normalidade para  $\varepsilon_t$  não foi usada em nenhum momento até aqui.

Usando dois resultados básicos de probabilidade<sup>2</sup>, segue imediatamente que

$$\begin{aligned} E(r_t) &= E\{E(r_t | \sigma_t)\} = E\{0\} = 0 \\ V(r_t) &= E\{V(r_t | \sigma_t)\} + V\{E(r_t | \sigma_t)\} = E\{\sigma_t^2\} + V\{0\} = E(\sigma_t^2). \end{aligned}$$

Somente nesse momento é necessário se utilizar as estruturas ARCH, GARCH e SV.

**ARCH(1):**  $V(r_t) = E(r_t^2) = E(\sigma_t^2) = E(\alpha_0 + \alpha_1 r_{t-1}^2) = \alpha_0 + \alpha_1 E(r_{t-1}^2)$ . Como  $E(r_t^2) = E(r_{t-1}^2)$  (esperanças incondicionais), segue que

$$V(r_t) = \frac{\alpha_0}{1 - \alpha_1}.$$

**GARCH(1,1):**  $V(r_t) = E(r_t^2) = E(\sigma_t^2) = E(\alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \sigma_{t-1}^2) = \alpha_0 + \alpha_1 E(r_{t-1}^2) + \beta_1 E(\sigma_{t-1}^2)$ . Como  $E(r_t^2) = E(r_{t-1}^2) = E(\sigma_t^2) = E(\sigma_{t-1}^2)$ , segue que

$$V(r_t) = \frac{\alpha_0}{1 - \alpha_1 - \beta_1}.$$

<sup>1</sup>  $V(X) = E(X^2) - \{E(X)\}^2$ . Portanto, quando  $E(X) = 0$ , segue que  $V(X) = E(X^2)$ .

<sup>2</sup>  $E(X) = E\{E(X|Y)\}$  e  $V(X) = E\{V(X|Y)\} + V\{E(X|Y)\}$ .

Só nos resta obter  $E(r_t^4)$ :

$$E(r_t^4) = E\{E(r_t^4|\sigma_t)\} = E\{E(\sigma_t^4\varepsilon_t^4|\sigma_t)\} = E\{\sigma_t^4E(\varepsilon_t^4)\} = 3E(\sigma_t^4),$$

pois a curtose da distribuição normal padrão é igual a 3.

**ARCH(1):**

$$\begin{aligned} \frac{1}{3}E(r_t^4) &= E(\sigma_t^4) = E\{(\alpha_0 + \alpha_1 r_{t-1}^2)^2\} = \alpha_0^2 + 2\alpha_0\alpha_1 E(r_{t-1}^2) + \alpha_1^2 E(r_{t-1}^4) \\ &= \alpha_0^2 + 2\alpha_1 \frac{\alpha_0^2}{1 - \alpha_1} + \alpha_1^2 E(r_{t-1}^4) = \alpha_0^2 \left( \frac{1 + \alpha_1}{1 - \alpha_1} \right) + \alpha_1^2 E(r_{t-1}^4) \end{aligned}$$

logo

$$E(r_t^4) = 3 \frac{\alpha_0^2(1 + \alpha_1)/(1 - \alpha_1)}{1 - 3\alpha_1^2}$$

e

$$K_{r_t} = \frac{E(r_t^4)}{\{E(r_t^2)\}^2} = \frac{3 \frac{\alpha_0^2(1 + \alpha_1)/(1 - \alpha_1)}{1 - 3\alpha_1^2}}{\alpha_0^2/(1 - \alpha_1)^2} = \frac{3(1 + \alpha_1)(1 - \alpha_1)}{1 - 3\alpha_1^2} = \frac{3(1 - \alpha_1^2)}{1 - 3\alpha_1^2}.$$

**GARCH(1,1):** O que você tem que mostrar aqui é que

$$K_{r_t} = 3 \left( \frac{1 - (\alpha_1 + \beta_1)^2}{1 - (\alpha_1 + \beta_1)^2 - 2\alpha_1^2} \right)$$

Finalmente, duas complicações adicionais surgem quando se trata do modelo SV-AR(1):

$$\log \sigma_t^2 = \mu + \phi(\log \sigma_{t-1}^2 - \mu) + u_t \quad u_t \sim N(0, \tau^2).$$

Em primeiro lugar, existe agora o termo de erro  $u_t$  que tem que ser levado em consideração. Mas esse é um problema relativamente simples, uma vez que assumimos que  $\varepsilon_t$  e  $u_t$  são independentes entre si. Em segundo lugar, para se obter esperança, variância e curtose de  $r_t$  é necessário se obter  $E(\sigma_t^2)$  e  $E(\sigma_t^4)$ , que são momentos de uma distribuição log-normal (dado que  $\log \sigma_t$  é normalmente distribuído).

**Problema 2.** Mostre que se  $r_t \sim \text{ARCH}(2)$  normal, então  $r_t^2 \sim \text{AR}(2)$  com inovações não-normais. Mostre também que  $\{r_t\}$  é uma sequência de ruídos brancos.

Como  $r_t \sim \text{ARCH}(2)$  normal, podemos escrever (como no problema 1 acima)

$$\begin{aligned}r_t &= \sigma_t \varepsilon_t & \varepsilon_t &\sim NID(0, 1) \\ \sigma_t^2 &= \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_2 r_{t-2}^2\end{aligned}$$

de forma que, se definirmos  $\nu_t = r_t^2 - \sigma_t^2$ , temos que

$$r_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_2 r_{t-2}^2 + \nu_t,$$

ou seja,  $r_t^2 \sim \text{AR}(2)$ .

O que ainda resta fazer é entender o comportamento de  $\nu_t$ :

$$\nu_t = r_t^2 - \sigma_t^2 = \sigma_t^2 \varepsilon_t^2 - \sigma_t^2 = \sigma_t^2 (1 - \varepsilon_t^2).$$

Segue que

$$E(\nu_t) = E(\sigma_t^2)E(1 - \varepsilon_t^2) = 0,$$

e

$$E(\nu_t \nu_{t+h}) = E\{\sigma_t^2 \sigma_{t+h}^2\}E\{(1 - \varepsilon_t^2)\}E\{(1 - \varepsilon_{t+h}^2)\} = 0.$$

Portanto o processo  $\{\nu_t\}$  é um ruído branco.

**Problema 3.** Suponha que  $r_1, r_2, \dots, r_n$  sejam observações de uma série de log-retornos seguindo um modelo AR(1)-GARCH(1,1) normal, isto é,

$$\begin{aligned} r_t &= \mu + \phi r_{t-1} + u_t, \\ u_t &= \sigma_t \varepsilon_t \\ \sigma_t^2 &= \alpha_0 + \alpha_1 u_{t-1}^2 + \beta_1 \sigma_{t-1}^2, \end{aligned}$$

para  $\varepsilon_t \sim NID(0, 1)$ . Perceba que o modelo acima pode ser mais compactamente escrito como

$$\begin{aligned} r_t | r_{t-1}, \sigma_t &\sim N(\mu + \phi r_{t-1}, \sigma_t^2) \\ \sigma_t^2 &= \alpha_0 + \alpha_1 (r_{t-1} - \mu - \phi r_{t-2})^2 + \beta_1 \sigma_{t-1}^2, \end{aligned}$$

o que evidencia a normalidade dos log-retornos  $r_t$  e também que  $\sigma_t^2$  depende de  $r_{t-1}^2$ ,  $r_{t-2}^2$  e  $\sigma_{t-1}^2$ . Obtenha a função de log-verossimilhança condicional de  $(\mu, \phi, \alpha_0, \alpha_1, \beta_1)$ . Sem perda de generalidade, assumamos que  $\sigma_0^2 = r_0 = r_{-1} = 0$ .

Para se obter a função de log-verossimilhança condicional de  $\theta = (\mu, \phi, \alpha_0, \alpha_1, \beta_1)$ , é necessário que escrevamos a densidade conjunta dos dados condicional em  $\theta$ ,  $p(r_1, \dots, r_n | \theta)$ . Uma vez que  $\sigma_1^2, \dots, \sigma_n^2$  são deterministicamente derivados de  $\sigma_0^2, r_0, r_{-1}, \theta$  e  $r_1, \dots, r_n$ , segue que

$$p(r_1, \dots, r_n | \theta) = \prod_{t=1}^n p(r_t | r_{t-1}, \theta) = \prod_{t=1}^n (2\pi\sigma_t^2)^{-1/2} \exp \left\{ -\frac{1}{2} \frac{(r_t - \mu - \phi r_{t-1})^2}{\sigma_t^2} \right\}.$$

Portanto, a função log-verossimilhança condicional de  $\theta$  é

$$l(\theta) = \log p(r_1, \dots, r_n | \theta) = K - \frac{1}{2} \left[ \log(2\pi) + \sum_{t=1}^n \log \sigma_t^2 \right] + \sum_{t=1}^n \sigma_t^{-2} (r_t - \mu - \phi r_{t-1})^2.$$

O estimador de máxima verossimilhança,  $\hat{\theta}$ , é obtido maximizando  $l(\theta)$  sujeito às seguintes restrições:  $|\phi| < 1$ ,  $\alpha_0, \alpha_1, \beta_1 > 0$  e  $\alpha_1 + \beta_1 < 1$ .

**Problema 4.** O arquivo `sp500.csv` contém preços diários do S&P500 para o período de 03/01/1950 a 23/04/2015 (16432 observações). Veja a figura 1 com os dados.

a) Ajuste modelos ARCH(1), GARCH(1,1) e SV-AR(1) para essa série temporal financeira. Mais precisamente, para  $r_t = \sigma_t \varepsilon_t$ , onde  $\varepsilon_t$  e  $\sigma_t$  são independentes e  $\varepsilon_t \sim NID(0,1)$ , ajuste os modelos

a1) ARCH(1):  $\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2$ .

a2) GARCH(1,1):  $\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \sigma_{t-1}^2$ .

a3) SV-AR(1):  $\log \sigma_t^2 = \mu + \phi(\log \sigma_{t-1}^2 - \mu) + u_t$ , onde  $u_t \sim N(0, \tau^2)$ .

Veja os resultados na próxima página e nas figuras 2 a 3.

ARCH(1)

Parameter	Estimate	Std. Error
alpha0	6.518712e-05	9.616782e-07
alpha1	3.118930e-01	1.465707e-02

GARCH(1,1)

Parameter	Estimate	Std. Error
alpha0	8.116538e-07	9.956670e-08
alpha1	8.055070e-02	4.198828e-03
beta1	9.127400e-01	4.483739e-03

SV-AR(1)

	mu	phi	sigma
1st Qu.	-9.806	0.9844	0.1404
Median	-9.752	0.9857	0.1449
Mean	-9.752	0.9856	0.1453
3rd Qu.	-9.700	0.9869	0.1497

VARIANCE, STANDARD DEVIATION AND KURTOSIS

	Sample	ARCH(1)	GARCH(1,1)	SV-AR(1)
Variance	0.0000944	0.0000947	0.0001210	0.0000583
St.Dev.	0.0097164	0.0097331	0.0109988	0.0076381
Kurtosis	24.6164182	3.8241874	101.1132664	6.3648994

b) Divida a série em grupos de 5 anos (13 grupos, portanto) e repita as análises de a). Como se comportam os parâmetros dos modelos ao longo do tempo? Comente seus resultados.




Figure 1: S&P500: preços, log-preços e log-retornos.




Figure 2: S&P500: Estimativas dos desvios-padrões pelos modelos ARCH(1) e GARCH(1,1).




Figure 3: S&P500: Análise residual dos modelos ARCH(1) e GARCH(1,1).