

# Modelos ARCH e GARCH

## Aula 8

Morettin e Tolo, 2006, Capítulo 1 e 14

Morettin, 2011, Capítulo 1 e 5

Bueno, 2011, Capítulo 8

# Motivação

Pesquisadores que se dedicam a prever séries temporais, tais como preços de ações, taxas de inflação, taxas de câmbio, etc., costumam observar que a capacidade dos modelos em prever tais variáveis oscila consideravelmente de um período para outro: para alguns períodos, os erros de previsão são relativamente pequenos, já para outros, tais erros são relativamente grandes, e então são outra vez pequenos para um outro período.

## Motivação

Observando as expressões de cálculo dos erros de previsão:

$$e_T(1) = y_{T+1} - \hat{y}_T(1) = \varepsilon_{T+1}$$

$$e_T(2) = y_{T+2} - \hat{y}_T(2) = \varepsilon_{T+2} + \psi_1 \varepsilon_{T+1}$$

$$e_T(3) = y_{T+3} - \hat{y}_T(3) = \varepsilon_{T+3} + \psi_1 \varepsilon_{T+2} + \psi_2 \varepsilon_{T+1}$$

$\vdots$

$$e_T(h) = y_{T+h} - \hat{y}_T(h) = \varepsilon_{T+h} + \psi_1 \varepsilon_{T+h-1} + \cdots + \psi_{h-1} \varepsilon_{T+1}$$

não é difícil notar que tais quantidades realmente podem guardar algum tipo de relação.

# Motivação

Não é difícil notar que o comportamento dos erros de previsão dependem do comportamento das perturbações  $\varepsilon_t$ .

Dessa forma, temos uma justificativa plausível para a existência de auto-correlação na variância de  $\varepsilon_t$ .

Assim, podemos observar que as variâncias dos erros de previsão não são constantes. Ou seja, há uma espécie de auto-correlação nas variâncias dos erros de previsão.

## Modelos ARCH e GARCH

Para capturar a estrutura de correlação na variância condicional da inflação do Reino Unido, Engle (1982) propôs um modelo denominado como ARCH (Modelo Autorregressivo para a Heteroscedasticidade Condicional), que é um exemplo de modelo não-linear.

Uma generalização do modelo ARCH foi sugerida por Bollerslev (1986, 1987, 1988), o chamado modelo GARCH (generalized ARCH), que pode ser usado para descrever a volatilidade com menos parâmetros do que um modelo ARCH.

# Objetivos


Assim, nesta parte da disciplina o objetivo será modelar o que se chama de volatilidade, que é a variância condicional de uma variável, comumente de um retorno.

Embora não seja medida diretamente, a volatilidade manifesta-se de várias maneiras numa série financeira e nós a trataremos a partir de uma abordagem estatística, que modela diretamente a volatilidade da série de retornos usando alguma classe de modelos como, por exemplo, o GARCH.

## Fatos estilizados sobre os retornos


- (a) Retornos são, em geral, não auto-correlacionados;
- (b) Séries de retornos apresentam agrupamentos de volatilidades ao longo do tempo;
- (c) Os quadrados dos retornos são auto-correlacionados, apresentando uma correlação de lag 1 pequena e depois uma queda lenta das demais;
- (d) A distribuição (incondicional) dos retornos apresenta caudas mais pesadas do que as caudas de uma distribuição normal; além disso, a distribuição, embora aproximadamente simétrica, é, em geral, leptocúrtica;
- (e) Algumas séries de retornos são não-lineares.

# Petrobras (PBR/NYSE) - 11/08/00 - 27/03/15 (3678 obs)







# Função de autocorrelação



# Função de autocorrelação parcial




# Normalidade ou não?



# Normalidade ou não?

Normal Q-Q Plot




## Estatísticas básicas

---


Média	0.00008045
Mediana	0.00065148
Mínimo	-0.2625885
Máximo	0.2641932
Desvio Padrão	0.0305223
Assimetria	-0.1103535
Excesso de curtose	7.379875

---


# Quadrados dos log-retornos



## Quadrados dos log-retornos - FAC



## Quadrados dos log-retornos - FACP





## Modelos não-lineares

Na análise de modelos não-lineares as inovações (choques aleatórios)  $\varepsilon_t$  são, em geral, supostas i.i.d e o modelo tem a seguinte forma

$$r_t = \mu(\varepsilon_{t-1}, \varepsilon_{t-2}, \dots) + \sigma(\varepsilon_{t-1}, \varepsilon_{t-2}, \dots)\varepsilon_t,$$

de modo que

- ▶  $\mu(\cdot)$  representa a função média condicional; e
- ▶  $\sigma^2(\cdot)$  representa a função variância condicional.

Se  $\mu(\cdot)$  for não-linear  $\Rightarrow$  modelo não-linear na média.

Se  $\sigma^2(\cdot)$  for não-linear  $\Rightarrow$  modelo não-linear na variância.

## Média e variância condicionais de $r_t$

- Considere  $r_t$  uma série de log-retornos.
- $\mathfrak{J}_{t-1} = \{r_1, r_2, \dots, r_{t-1}\}$  denota toda a informação até  $t - 1$ .
- A média condicional de  $r_t$  é dada por

$$\mu_t = E(r_t | \mathfrak{J}_{t-1}) = E_{t-1}(r_t).$$

- A variância condicional de  $r_t$  é dada por

$$\sigma_t^2 = E[(r_t - \mu_t)^2 | \mathfrak{J}_{t-1}] = E_{t-1}[(r_t - \mu_t)^2].$$

- Se  $\mu_t = 0$ , então  $\sigma_t^2 = E[r_t^2 | \mathfrak{J}_{t-1}] = E_{t-1}[r_t^2]$

## Notação

Um modelo típico para a volatilidade é da forma

$$r_t = \mu_t + \sigma_t \varepsilon_t$$

em que

$$E_{t-1}(\varepsilon_t) = 0$$

e

$$Var_{t-1}(\varepsilon_t) = 1$$

e tipicamente  $\varepsilon_t$  é uma sequência i.i.d. com certa distribuição.

**Obs:** A média e a variância incondicionais de  $r_t$  serão denotadas por

$$\mu = E(r_t) \quad \text{e} \quad \sigma^2 = Var(r_t),$$

respectivamente.

# ARCH(m)

Um modelo ARCH(m) é definido por

$$r_t = \sigma_t \varepsilon_t$$

onde  $\varepsilon_t \sim IID(0, 1)$  e com variância condicional

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_2 r_{t-2}^2 + \cdots + \alpha_m r_{t-m}^2$$

em que  $\alpha_0 > 0$ ,  $\alpha_i \geq 0$ ,  $i = 1, \dots, m-1$  e  $\alpha_m > 0$ .

## $r_t^2$ é AR(m)

Definindo  $v_t = r_t^2 - \sigma_t^2$  e substituindo em

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_2 r_{t-2}^2 + \cdots + \alpha_m r_{t-m}^2,$$

obtemos

$$r_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \alpha_2 r_{t-2}^2 + \cdots + \alpha_m r_{t-m}^2 + v_t.$$

Portanto:

- ▶  $r_t^2$  segue um processo AR(m).
- ▶  $v_t = r_t^2 - \sigma_t^2 = \sigma_t^2(\varepsilon_t^2 - 1)$  é não Gaussiano, mesmo quando  $\varepsilon_t \sim NID(0, 1)$ .

## Observações

Na prática, usualmente é suposto que os erros  $\varepsilon_t$  sigam uma distribuição,  $N(0,1)$ .

Ou ainda  $t$ -Student,  $t_\nu$ , com baixo graus de liberdade  $\nu$ , ou alguma distribuição que descreva melhor as caudas pesadas de séries financeiras.

Os coeficientes  $\alpha_i$  devem satisfazer certas condições, dependendo do tipo de imposição que colocamos sobre o processo  $r_t$ .

Pela própria definição, valores grandes de  $r_t$  são seguidos por outros valores grandes da série.

## GARCH(m,n)

A variância condicional de modelo GARCH(m,n) é definida por

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i r_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2$$

em que  $\alpha_0 > 0$ ,

- ▶  $\alpha_i \geq 0$ ,  $i = 1, \dots, m-1$  e  $\alpha_m > 0$ ,
- ▶  $\beta_i \geq 0$ ,  $i = 1, \dots, n-1$  e  $\beta_n > 0$ ,
- ▶ Para  $q = \max(m, n)$

$$\sum_{i=1}^q (\alpha_i + \beta_i) < 1.$$

Coeficientes positivos dão uma condição suficiente, mas não necessária, para que  $\sigma_t^2 > 0$  (Nelson & Cao, 1992).

Como no caso de modelos ARCH, usualmente trabalhamos com a suposição de que os  $\varepsilon_t$  sejam normais ou t-Student, ou ainda, uma distribuição de erro generalizada.

$r_t^2$  é AR(q,n)

Definindo  $v_t = r_t^2 - \sigma_t^2$  e substituindo em

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i r_{t-i}^2 + \sum_{j=1}^n \beta_j \sigma_{t-j}^2$$

obtemos

$$r_t^2 = \alpha_0 + \sum_{i=1}^q (\alpha_i + \beta_i) r_{t-i}^2 - \sum_{j=1}^n \beta_j v_{t-j} + v_t$$

Portanto:

- ▶  $r_t^2$  segue um processo AR(q,n).
- ▶  $v_t$  não é, em geral, um processo i.i.d.



## Modelo ARCH(1)

Para investigarmos algumas propriedades dos modelos ARCH( $m$ ), vamos considerar o caso especial onde  $m = 1$ . Ou seja,

$$r_t = \sigma_t \varepsilon_t$$

com erro  $\varepsilon_t \sim iid(0, 1)$  e variância condicional

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2$$

e parâmetros  $\alpha_0 > 0$  e  $\alpha_1 > 0$ .

## Média e variância incondicionais

Não é difícil verificar que

$$E(r_t) = E[E(r_t|\mathcal{J}_{t-1})] = E[E(\sigma_t \varepsilon_t|\mathcal{J}_{t-1})] = E[\sigma_t \underbrace{E(\varepsilon_t|\mathcal{J}_{t-1})}_{=0}] = 0,$$

e que  $Var(r_t) = E(r_t^2)$ . Portanto,

$$\begin{aligned} E(r_t^2) &= E[E(r_t^2|\mathcal{J}_{t-1})] = E[E(\sigma_t^2 \varepsilon_t^2|\mathcal{J}_{t-1})] \\ &= E[\sigma_t^2 \underbrace{E(\varepsilon_t^2|\mathcal{J}_{t-1})}_{=1}] = E(\sigma_t^2) \\ &= E(\alpha_0 + \alpha_1 r_{t-1}^2) = \alpha_0 + \alpha_1 E(r_{t-1}^2). \end{aligned}$$

## Restrição adicional: $0 < \alpha_1 < 1$

Se o processo  $r_t$  for estacionário de segunda ordem, então, para todo  $t$  e  $k$ , segue que  $E(r_t^2) = E(r_{t-k}^2)$ .

Se  $\mu$  e  $\sigma^2$  são média e variância incondicionais do processo  $r_t$ , então

$$\sigma^2 = E(r_t^2) = \alpha_0 + \alpha_1 E(r_{t-1}^2) = \alpha_0 + \alpha_1 \sigma^2$$

e, conseqüentemente a variância incondicional de  $r_t$  é

$$\text{Var}(r_t) = \sigma^2 = \frac{\alpha_0}{1 - \alpha_1},$$

implicando que  $\alpha_0 > 0$  e  $0 < \alpha_1 < 1$ .

## Covariâncias incondicionais

$$\begin{aligned} \text{Cov}(r_t, r_{t+k}) &= E(r_t r_{t+k}) = E[E(r_t r_{t+k} | \mathcal{J}_{t+k-1})] \\ &= E[r_t E(r_{t+k} | \mathcal{J}_{t+k-1})] = E[r_t E(\sigma_{t+k} \varepsilon_{t+k} | \mathcal{J}_{t+k-1})] \\ &= E[r_t \sigma_{t+k} \underbrace{E(\varepsilon_{t+k} | \mathcal{J}_{t+k-1})}_{=0}] = 0 \end{aligned}$$

para todo  $k \geq 1$ .

Poranto,  $r_t$  é uma sequncia de variáveis não correlacionadas (ruído branco), com média zero e variância dada por  $\alpha_0/(1 - \alpha_1)$ .

## Curtose maior que 3

Um dos fatos estilizados é que os retornos apresentam geralmente caudas mais longas, de modo que a curtose é maior do que 3.

A curtose, supondo que  $r_t \sim \text{ARCH}(1)$  com  $\varepsilon_t \sim \text{NID}(0, 1)$ , é dada por

$$K = \frac{E(r_t^4)}{[\text{Var}(r_t)]^2} = 3 \left( \frac{1 - \alpha_1^2}{1 - 3\alpha_1^2} \right) > 3$$

Vemos, pois, que se admitirmos que  $r_t$  siga um modelo ARCH, as caudas serão mais pesadas do que as da normal, o que é uma propriedade vantajosa do modelo.

## GARCH(1,1)

Um modelo bastante usado na prática é o GARCH(1,1), para o qual a volatilidade condicional é expressa como

$$\sigma_t^2 = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta_1 \sigma_{t-1}^2$$

com  $\alpha_0 > 0$  e  $\alpha_1, \beta_1 \in (0, 1)$ .

Para os modelos GARCH temos as mesmas vantagens e desvantagens dos modelos ARCH:

- ▶ Volatilidades altas são precedidas de retornos ou volatilidades grandes, observando-se os grupos de volatilidades presentes em séries financeiras;
- ▶ Retornos positivos e negativos são tratados de forma similar, já que quadrados dos retornos entram na fórmula da volatilidade.

## Curtose maior que 3

A curtose, supondo que  $r_t \sim \text{GARCH}(1,1)$  com  $\varepsilon_t \sim \text{NID}(0,1)$ , é dada por

$$K = \frac{E(r_t^4)}{[E(r_t^2)]^2} = 3 \left( \frac{1 - (\alpha_1 + \beta_1)^2}{1 - (\alpha_1 + \beta_1)^2 - 2\alpha_1^2} \right) > 3$$

Vemos, pois, que se admitirmos que  $r_t$  siga um modelo GARCH, as caudas serão mais pesadas do que as da normal, o que é uma propriedade vantajosa do modelo.

## Variância incondicional

É fácil provar que, supondo que  $r_t \sim \text{GARCH}(1,1)$  com  $\varepsilon_t \sim (0, 1)$ , a variância incondicional de  $r_t$  é

$$\text{Var}(r_t) = \frac{\alpha_0}{1 - (\alpha_1 + \beta_1)},$$

portanto  $\alpha_1 + \beta_1 < 1$  é uma restrição adicional.

No longo prazo, a volatilidade convergirá para tal resultado incondicional.



## ARCH/GARCH no R

```
install.packages("fGarch")  
  
library(fGarch)  
  
data = read.csv("petrobras.csv",header=TRUE)  
  
y = diff(log(as.numeric(data[,2])))  
  
fit.arch = garchFit(~garch(1,0),data=y,trace=F,include.mean=FALSE)  
  
fit.garch = garchFit(~garch(1,1),data=y,trace=F,include.mean=FALSE)
```

# fit.arch

Title: GARCH Modelling

Conditional Distribution: norm

	Estimate	Std. Error	t value	Pr(> t )	
omega	6.440e-04	2.043e-05	31.52	<2e-16	***
alpha1	3.388e-01	3.142e-02	10.78	<2e-16	***

---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:

7793.993      normalized: 2.119085

# fit.arch

Title: GARCH Modelling

Conditional Distribution: norm

	Estimate	Std. Error	t value	Pr(> t )	
omega	1.473e-05	3.152e-06	4.673	2.96e-06	***
alpha1	7.197e-02	8.042e-03	8.949	< 2e-16	***
beta1	9.100e-01	1.010e-02	90.127	< 2e-16	***



---

Signif. codes: 0 '\*\*\*' 0.001 '\*\*' 0.01 '\*' 0.05 '.' 0.1 ' ' 1

Log Likelihood:


8179.795      normalized: 2.223979

# Fitted standard deviations




# Residual analysis


**ARCH(1)**




**ACF residuals squared**




**PACF residuals squared**




**Normal Q-Q Plot**




**GARCH(1,1)**




**ACF residuals squared**



**PACF residuals squared**



**Normal Q-Q Plot**



## Ljung-Box statistic

```
Box.test(res.arch^2,lag=10,type='Ljung')  
  
# Box-Ljung test  
# data:  res.arch^2  
# X-squared = 742.0735, df = 10, p-value < 2.2e-16  
  
Box.test(res.garch^2,lag=10,type='Ljung')  
  
# Box-Ljung test  
# data:  res.garch^2  
# X-squared = 8.7553, df = 10, p-value = 0.5555
```

## Unconditional variances and kurtosis

#	Sample	ARCH(1)	GARCH(1,1)
#Variance	0.0009316083	0.0009740429	0.0008170309
#St.Dev.	0.0305222590	0.0312096596	0.0285837524
#Kurtosis	4.3625780142	4.0506396090	4.2243098902