

CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ
ISSN impresso 1413-9022 / ISSN on-line 2317-4536 - v.41, p.01 - 14, 2016
DOI: 10.12957/cadest.2016.27738

ANÁLISE DO COMPORTAMENTO DA VOLATILIDADE DA TAXA DE CâMBIO EURO-DÓLAR

Winicius Botelho Faquierei
Universidade do Estado do Rio de Janeiro
wfaquierei@gmail.com

Fernando Antonio Lucena Aiube
Universidade do Estado do Rio de Janeiro
faiube@gmail.com

Resumo

O presente trabalho analisa a série de retornos da taxa de câmbio euro-dólar, com frequência diária. A estacionariedade é comprovada através dos testes ADF e Phillips-Perron. Foi constatada a não-normalidade da série de retornos. A dependência temporal dos retornos foi testada através das autocorrelações dos mesmos e posteriormente modelada. Ajustou-se a dependência não-linear através de alguns modelos da família GARCH lineares e não lineares. Posteriormente, avaliou-se a capacidade de previsão de cada modelo. Os resultados empíricos indicam um alto grau de persistência da volatilidade da taxa de câmbio. O modelo EGARCH foi aquele que apresentou melhor capacidade preditiva, embora os três modelos de volatilidade condicional analisados tenham fornecido previsões de volatilidade muito próximas.

Palavras-chave: Taxa de Câmbio, GARCH, Volatilidade, Previsibilidade da volatilidade.

1. Introdução

O arranjo monetário internacional definido no decorrer da II Guerra Mundial, no ano de 1944, em Bretton Woods, estabeleceu que a liquidez da economia mundial dependeria, fundamentalmente, da condução da política monetária norte americana sob o regime de câmbio fixo ajustável e o compromisso de manter constante a relação dólar-ouro. Tal arranjo prevaleceu até 1971, quando Nixon “fechou a janela por onde fugia o ouro” e decretou o fim do último vínculo existente entre o ouro e o sistema monetário internacional (SENNA, 2010). Desde então, muitos países passaram a substituir o regime de câmbio fixo ajustável pelas taxas flutuantes de câmbio.

Tal mudança estimulou um extenso debate sobre a capacidade da volatilidade da taxa de câmbio de influenciar bem-estar, crescimento econômico, comércio internacional, bem como sua relação com variáveis macroeconômicas, tais como: inflação, PIB, taxa de juros, etc. Além disso, a volatilidade da taxa de câmbio passou a assumir importância fundamental no estabelecimento de políticas de hedge, gerenciamento de risco e no planejamento de curto e longo prazo das empresas que realizam transações de compra e venda de moedas estrangeiras ou de papéis que as representem.

O colapso de Bretton Woods fez com que a modelagem da volatilidade da taxa de câmbio ganhasse considerável importância (ABDALLA, 2011) e diferentes modelos foram desenvolvidos na literatura de finanças para investigar certas regularidades empíricas no comportamento da volatilidade, tais como: (i) evidência de aglomerados de volatilidade na série de retornos; (ii) efeitos assimétricos na volatilidade da taxa de câmbio; e (iii) períodos de alta volatilidade com acentuada persistência, conforme observado por Engel e Bollerslev (1986).

Alguns modelos bem conhecidos e frequentemente utilizados para estimar a volatilidade da taxa de câmbio são o modelo heterocedástico condicional ARCH (Autoregressive Conditional Heterocedasticity), proposto por Engel (1982) e modificado, posteriormente, por Bollerslev (1986), através da inclusão da variância passada ao modelo, na qual denominou-se GARCH (Generalized Autoregressive Conditional Heterocedasticity). O objetivo foi o de obter um modelo mais parcimonioso e sem os problemas de estimação do modelo ARCH. Contudo, algumas propriedades do comportamento da volatilidade não são capturadas pelos modelos GARCH clássicos, tais como o seu comportamento assimétrico e o efeito alavanca.

Tal assimetria refere-se ao comportamento da volatilidade frente aos diferentes efeitos de choques positivos ou negativos. Os choques negativos trazem maior impacto à volatilidade do que choques positivos de mesma magnitude. Os modelos da família GARCH não lineares foram desenvolvidos com a finalidade de capturar tal efeito. Neste sentido, podem-se destacar os trabalhos de Nelson (1991), Ding, Granger e Engle (1993), Glosten, Jagannathan e Runkle (1993) e Zakoian (1994).

O presente trabalho analisa o comportamento da volatilidade da série de retornos da taxa de câmbio euro-dólar e especifica um modelo para o comportamento dos retornos da série a partir de testes realizados com os dados empíricos. Posteriormente, avalia a capacidade de previsão de cada modelo.

O restante do artigo é organizado como segue. Seção (2) descreve brevemente a escolha e a natureza dos dados utilizados. Seção (3) discute os modelos lineares e não lineares da família GARCH usados no presente trabalho. Seção (4) apresenta a metodologia utilizada na previsão. Seção (5) mostra os resultados empíricos e, por fim, a seção (6) provê algumas conclusões.

2. Dados empíricos

Foram coletados dados históricos da taxa de câmbio, de 04 de janeiro de 1999 a 30 de dezembro de 2016, a partir da plataforma QUANDL (www.quandl.com). Os dados dos últimos seis meses, i.e., 01 de julho de 2016 a 30 de dezembro de 2016, são usados para avaliar a previsão da volatilidade fora da amostra. A amostra é composta pelas cotações diárias de fechamento da taxa de câmbio euro/dólar.

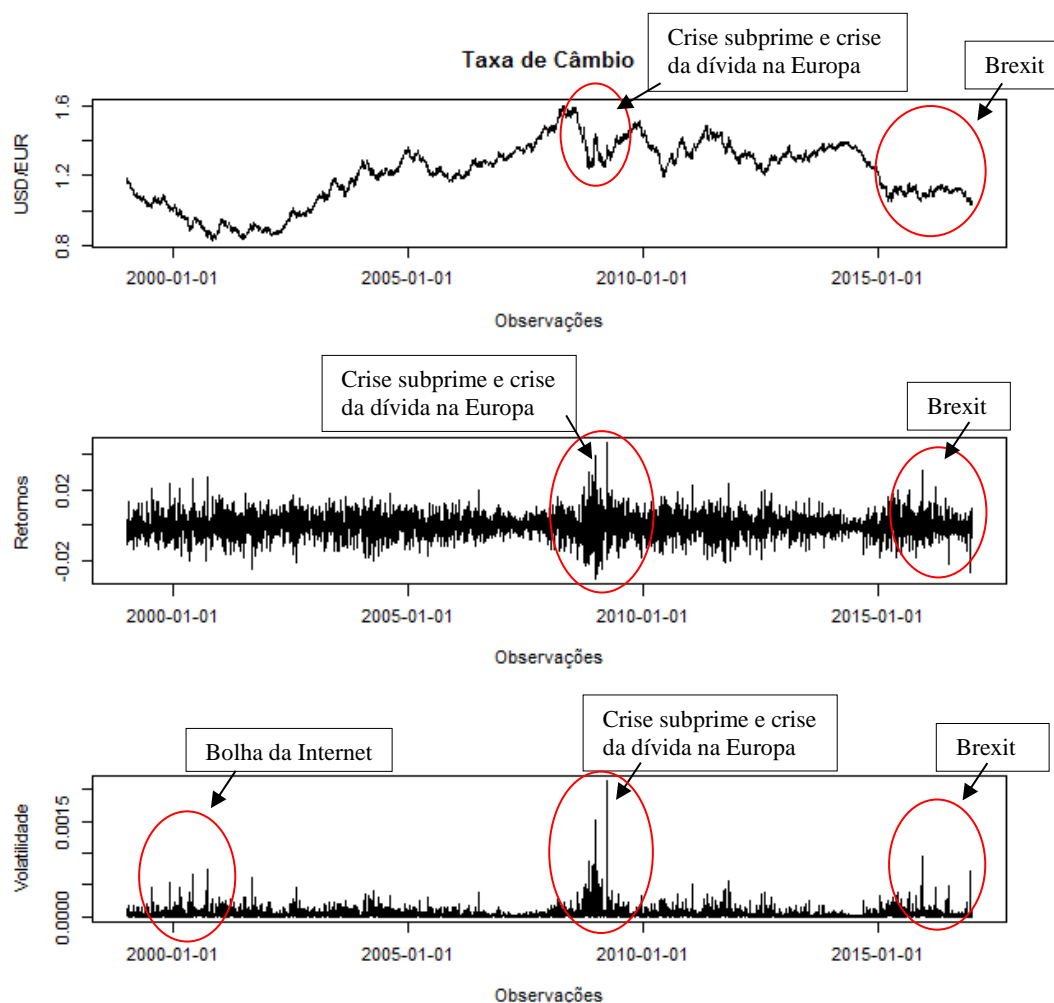
No presente trabalho ajustamos os modelos da família GARCH lineares e não lineares a uma série de retornos da taxa de câmbio euro-dólar (EUR/USD) com frequência diária.

Para trabalhar com os modelos da família GARCH, primeiramente é necessário transformar a série de preços em uma série de retornos. Os testes *Dickey-Fuller* aumentado (ADF) e de *Phillips-Perron* (P-P) evidenciam que a série de retorno da taxa de câmbio é estacionária.

Segundo Sadorsky (2006) e Kang *et al.* (2009), a volatilidade real diária é avaliada usando os retornos quadrados diários (r_t^2). A representação gráfica da taxa de câmbio euro-dólar com frequência diária, dos retornos e da volatilidade são dados na

figura 1. Para melhor compreensão do comportamento da série foi feita a identificação dos eventos associados a períodos de alta volatilidade. Observa-se o efeito, sobre o comportamento da taxa de câmbio, de crises financeiras e de acontecimentos relevantes no cenário internacional.

Figura 1 – Taxa de câmbio euro-dólar, retornos diários e volatilidade no período de 4 de janeiro de 1999 a 30 de dezembro de 2016



Fonte: O autor, 2017

A tabela 1 provê as estatísticas descritivas da série de retornos. A média amostral da série é muito pequena em relação ao seu desvio padrão. A estatística Jarque-Bera (JB) mostra que a hipótese nula de normalidade é rejeitada ao nível de significância de 1%, assim como é evidenciado pelo excesso de curtose e assimetria positiva. Em tal caso, a função de distribuição é mais "achatada" do que a distribuição normal. A estatística Ljung-Box (Q) para correlação serial revela que a hipótese nula de não autocorrelação é

rejeitada para 10 lags e, portanto, confirma autocorrelação serial na série de retornos. Os testes ADF e de P-P rejeitam a hipótese nula de raiz unitária. Ambos os testes implicam que a série de retorno é estacionária ao nível de significância de 1% e, portanto, pode ser modelada diretamente sem qualquer transformação.

Tabela 1. Estatísticas descritivas da série de retornos

| | |
|------------------------------|------------|
| Número de observações | 4524 |
| Média (%) | -2.494e-05 |
| Desvio Padrão (%) | 0.634 |
| Min. | -3.003e-02 |
| Max. | 4.621e-02 |
| Assimetria | 0.115 |
| Curtose | 2.155 |
| Jarque-Bera | 887.09*** |
| Q (10) | 16.174* |
| ADF | -16.121** |
| P-P | -4518.3** |

Fonte: O autor, 2017

Nota: Q(10) é o teste Ljung-Box para correlação serial da série de retornos até a defasagem de ordem 10.

*, ** e *** denotam o nível de significância de 10%, 5% e 1%, respectivamente.

3. Modelos de volatilidade condicional

Segundo Campbell, Lo e McKinlay (1997), a maior parte dos estudos financeiros concentra-se na análise da série de retornos ao invés do uso da série de preços devido a dois fatores principais: (i) o retorno de um ativo financeiro contém as informações de interesse dos investidores; (ii) as propriedades estatísticas da série de retornos são mais atrativas do que a série de preços.

A série de retornos (ou melhor, a de log-retornos a partir da frequência diária) foi construída como é usual na literatura por:

$$r_t = \ln(1 + R_t) = \left(\frac{P_t}{P_{t-1}} \right) = \ln(P_t) - \ln(P_{t-1}) \approx R_t \quad (1)$$

O ajuste do modelo heterocedástico à série de retornos foi definido através da minimização do critério BIC (Schwarz, 1978), resultando em modelos mais parcimoniosos. Tal critério compara o ajuste dentro da amostra, que é medido pela variância dos resíduos contra o número de parâmetros estimados. Também foi verificado se, após o ajuste, os resíduos e o quadrado dos resíduos não estavam correlacionados e não apresentavam nenhum tipo de dependência. Estes fatos foram verificados a partir do teste Ljung-Box (1978) para análise da autocorrelação. Além deste, foi realizado o teste

ARCH-LM de Engle (1982) nos resíduos de cada série para verificar a eliminação do efeito heterocedástico.

Foi testada a adequação da série aos modelos da família GARCH pelas distribuições normal, t-Student, GED (*generalized error distribution*) e skew t. Todos os modelos selecionados apresentaram melhores resultados ao serem ajustados pela distribuição GED.

Modelos lineares de volatilidade condicional como o modelo GARCH de Bollerslev (1986) foram testados, bem como os modelos não lineares EGARCH (*exponential GARCH*; Nelson, 1991) e GJR-GARCH (Glosten *et. al*, 1993).

3.1 Modelos da família GARCH lineares

Baseado no trabalho de Engle (1982), Bollerslev (1986) propôs uma extensão ao modelo ARCH através da inclusão da volatilidade condicional em função não somente dos quadrados dos erros passados ε_{t-i}^2 , bem como de seus próprios valores passados σ_{t-j}^2 . Tal modelo ficou conhecido como modelo GARCH (GeneralizedAutoregressive Conditional Heteroskedastic). Assim, um modelo GARCH (p,q) é dado por:

$$\varepsilon_t = \sigma_t \varepsilon_t, \quad (2)$$

$$\sigma_t^2 = \left(\omega + \sum_{i=1}^m \tau_i \varphi_{it} \right) + \sum_{j=1}^q \alpha_j \varepsilon_{t-j}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2, \quad (3)$$

Onde σ_t^2 é a variância condicional, ω é o intercepto e ε_{t-j}^2 é o erro observado no tempo “t-j” em que “j” denota a defasagem. σ_{t-j}^2 é a variância condicionada observada em “t-j”. Para garantir que a variância condicional seja positiva são impostas restrições quanto aos sinais dos coeficientes: $\omega > 0$, $\alpha > 0$ e $\beta > 0$. O termo ε_t é um ruído branco $[N \sim (0, \sigma_t^2)]$.

A persistência da volatilidade dos choques é dada por $(\alpha + \beta)$, se esta for superior a unidade a persistência dos choques será caracterizada pela existência de uma raiz unitária. Para garantir que a variância condicional seja finita e que os choques terão efeitos transitórios, então $\alpha + \beta < 1$. Conforme visto na tabela 1, a média amostral é muito pequena em relação ao desvio padrão. Então, fizemos a média condicional μ_t igual a zero, seguindo Koopman *et al.*(2005), entre outros.

3.2 Modelos da família GARCH não lineares

Alguns fatos estilizados do comportamento da volatilidade não são capturados pelos modelos GARCH clássicos tais como o seu comportamento assimétrico e o efeito alavanca. O comportamento da volatilidade frente aos diferentes efeitos de choques positivos ou negativos não é simétrico. Os choques negativos trazem maior impacto à volatilidade do que choques positivos de mesma magnitude. Entretanto, os modelos de volatilidade condicional lineares consideram o choque em $t-1$ elevado ao quadrado e, portanto, são indiferentes ao sinal do choque. Assim, o efeito constatado empiricamente não é capturado por tais modelos. Este efeito foi identificado pioneiramente por Black (1976) e ficou conhecido como efeito alavanca. Os modelos GARCH não lineares foram desenvolvidos posteriormente com a finalidade de capturar tal efeito.

O modelo GJR-GARCH, desenvolvido por Glosten *et al.* (1993) e ora tratado como TARCH (*threshold ARCH*) devido a Zakoian (1994), considera as diferenças na volatilidade condicional causadas por choques positivos ou negativos. A variância condicional do modelo GJR(p,q) é dada por:

$$\sigma_t^2 = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 + \sum_{k=1}^s \gamma_k \varepsilon_{t-k}^2 I_{t-k}^- \quad (4)$$

Onde os três primeiros termos da equação acima têm o mesmo significado do modelo GARCH clássico e o último termo modela a assimetria através da variável dummy I_t^- , sendo s o número de defasagens. Se ocorrem más notícias, $\varepsilon_t < 0$, então $I_t^- = 1$. Em tal caso o impacto do choque negativo na variância é dado por $\alpha + \gamma$. O efeito assimétrico ocorre quando $\gamma \neq 0$ e o efeito alavanca é observado quando $\gamma > 0$. Por outro lado, se o choque for positivo, isto é, $\varepsilon_t > 0$ e $I_t^- = 0$, então o impacto na variância é dado por α .

Outro modelo da família GARCH não linear é o modelo EGARCH (Exponential GARCH) proposto por Nelson (1991). Nelson argumentou que as restrições de não negatividade do modelo GARCH linear são muito restritivas. O modelo GARCH impõe restrições de não negatividade sob os parâmetros α e β , enquanto que no modelo EGARCH tais restrições são flexibilizadas através do uso do logaritmo da variância. O modelo EGARCH (p,q) é dado por:

$$\log(\sigma_t^2) = \omega + \sum_{i=1}^p \beta_i \log(\sigma_{t-i}^2) + \sum_{i=1}^q \gamma_i \frac{\varepsilon_{t-i}}{\sigma_{t-i}} + \alpha_i \left[\frac{\varepsilon_{t-i}}{\sigma_{t-i}} - \sqrt{\frac{2}{\pi}} \right] + v_t \quad (5)$$

Onde σ_t^2 denota a variância condicional em t, ω é o termo constante, ε_{t-1} é o erro observado no tempo t-1 e v_t é um ruído branco [$N(0,1)$].

4. Metodologia da previsão

Nesta seção, avaliou-se a metodologia de previsão dos modelos apresentados na seção 3. O processo de previsão é tratado como segue.

As observações compostas pelas cotações diárias de fechamento da taxa de câmbio euro-dólar, de 04 de janeiro de 1999 a 30 de dezembro de 2016, são classificadas em dois subgrupos: (i) dados dentro da amostra para a modelagem da volatilidade abrangendo um período de 17 anos, de 04 de janeiro de 1999 a 30 de junho de 2016 e (ii) dados fora da amostra para previsão do modelo no período de 01 de julho de 2016 a 30 de dezembro de 2016, i.e., os últimos 6 meses.

Segundo Sadorsky (2006) e Kang *et al.* (2009), a volatilidade real diária é avaliada usando os retornos quadrados diários e denotados como r_t^2 . A previsão da volatilidade obtida usando um modelo da família GARCH é denotada por $\hat{\sigma}_t^2$. Vários critérios de previsão podem ser considerados para avaliar a precisão preditiva de um modelo de volatilidade. No entanto, como discutido por Lopez (2001), não é óbvio qual critério é o mais apropriado para a avaliação de modelos de volatilidade. Portanto, ao invés de fazer uma única escolha, utilizou-se três diferentes estatísticas ou funções de perda como critérios de previsão:

$$EQM = n^{-1} \sum_{t=1}^n (r_t^2 - \hat{\sigma}_t^2)^2 \dots (6)$$

$$EAM = n^{-1} \sum_{t=1}^n |r_t^2 - \hat{\sigma}_t^2| \quad (7)$$

$$EAMP = \left(n^{-1} \sum_{t=1}^n \left| \frac{r_t^2 - \hat{\sigma}_t^2}{\hat{\sigma}_t^2} \right| \right) \times 100 \quad (8)$$

Onde n é o número de dados fora da amostra para previsão do modelo; EQM e EAM são o erro quadrático médio e o erro absoluto médio, respectivamente; EAMP é o EAM percentual.

As abordagens tradicionais para análises comparativas do melhor modelo de previsão baseiam-se, em geral, em medidas associadas aos erros de previsão. Entretanto, quando uma função de perda particular é menor para o modelo A do que para o modelo B isto não significa, ainda, que o modelo A é superior ao modelo B. Segundo Marzo e

Zagaglia (2010), não é possível concluir qual o melhor modelo de previsão com base em apenas um critério de previsão ou função de perda.

5. Resultados empíricos

5.1 Resultados da estimação para diferentes modelos de volatilidade

Os resultados reportados na tabela 2 mostram que para todos os modelos ajustados a variável β está próxima de 1 e é significativa ao nível de 1%. A soma do termo ARCH (α) e do termo GARCH (β) é menor do que 1 em todos os modelos. Isto indica um alto grau da persistência da volatilidade da taxa de cambio. Além disso, o parâmetro que reflete a assimetria γ é significativo ao nível de 5% no modelo GJR e ao nível de 1% no modelo EGARCH. Ambos os modelos apresentam $\gamma > 0$, mostrando que a série analisada exibe o efeito alavanca.

Os resultados da estimação do modelo GARCH (1,1) mostram que os coeficientes α e β são estatisticamente significantes ao nível de 1% e apresentam sinal de acordo com o esperado. A significância estatística do coeficiente α mostra a presença de aglomerados de volatilidade no modelo GARCH (1,1). A soma do termo ARCH (α) e do termo GARCH (β) é menor do que 1; isto significa que o processo de volatilidade condicional é do tipo reversão à média e os choques são do tipo transitórios.

Os resultados dos testes diagnósticos estão reportados na parte inferior da tabela 2. Em geral, todos os modelos apresentam Log(L) e BIC próximos para os diferentes tipos de modelos da família GARCH.

O teste Ljung-Box dos resíduos e dos resíduos ao quadrado não rejeitam a hipótese nula de não autocorrelação serial ao nível de 5%. A Figura 2 apresenta o QQ -plot dos resíduos para verificação da aderência da série de resíduos à distribuição GED. O teste ARCH-LM mostra que não há presença remanescente do efeito ARCH.

Tabela 2. Resultados da estimação de diferentes modelos de volatilidade para a série de retorno


| | GARCH | GJR | EGARCH |
|---------------------|------------------|------------------|-------------------|
| ω | 0.000(0.000) | 0.000(0.000) | -0.045*** (0.001) |
| α | 0.029***(0.018) | 0,021***(0.003) | -0,012** (0,005) |
| β | 0.969***(0.001) | 0,970***(0.002) | 0,995*** (0,000) |
| γ | | 0,014** (0,006) | 0.069*** (0,002) |
| <i>shape</i> | 1.456*** (0.062) | 1.469*** (0.066) | 1.469*** (0.045) |
| $\alpha + \beta$ | 0,998 | 0,991 | 0,983 |
| DIAGNÓSTICOS | | | |
| LOG(L) | 16300.38 | 16302.87 | 16304.22 |
| BIC | -7.4050 | -7.4042 | -7.4048 |
| Q(9) | 2.7487 [0.455] | 2,580 [0.489] | 2.7848 [0.448] |
| Q ² (9) | 12.836 [0.076] | 12.448 [0.0867] | 12.264 [0.092] |
| Q ² (15) | 16.54 [0.221] | 16.112 [0.243] | 16.016 [0.248] |
| ARCH-LM(7) | 1.9338 [0.9634] | 2.2031 [0.948] | 1.7251 [0.973] |

Fonte: O autor, 2017

Notas: Os números entre parênteses são os erros-padrão das estimações. Log(L) é o logaritmo do valor da função de máxima verossimilhança. BIC é o critério de informação Schwartz. Q(9) e Q²(9) são as estatísticas Ljung-Box de ordem 9 dos resíduos e do quadrado dos resíduos, respectivamente. P-valor das estatísticas são reportados em colchetes.

*, ** e *** denotam o nível de significância de 10%, 5% e 1%, respectivamente.

Fig. 2. QQ -plot dos resíduos



Fonte: O autor, 2017

Em face da incerteza acerca de qual é o melhor modelo, Clive W.J. Granger promoveu a ideia de que o melhor modelo deveria ser selecionado de acordo com sua capacidade de previsão (Swanson *et al.*, 2006).

5.2 Alguns resultados da previsão


Tabela 3. Resultados da previsão

| modelo | Função de perda | | | | | |
|---------------|-----------------|------|----------|------|----------|------|
| | EQM | Rank | EAM | Rank | EAMP (%) | Rank |
| <i>GARCH</i> | 5,13E-09 | 2 | 3,94E-05 | 2 | 87,68 | 2 |
| <i>GJR</i> | 5,20E-09 | 3 | 4,07E-05 | 3 | 87,24 | 1 |
| <i>EGARCH</i> | 5,03E-09 | 1 | 3,71E-05 | 1 | 89,72 | 3 |

Fonte: O autor, 2017

A partir dos resultados da previsão reportados na tabela 3 é possível concluir que o modelo EGARCH apresentou o melhor desempenho preditivo, uma vez que o seu erro quadrático médio e erro absoluto médio são relativamente menores. Embora, os três tipos de modelos da família GARCH forneçam previsões de volatilidade muito semelhantes. A figura 3 mostra a previsão fora da amostra da volatilidade obtida pelo modelo EGARCH. O horizonte temporal da previsão é de 125 dias, ou 6 meses. A volatilidade real diária observada é plotada como referência.

Fig. 3. Previsão fora da amostra da volatilidade do modelo EGARCH



Fonte: O autor, 2017

6. Conclusões

Este trabalho examinou os retornos diários da série da taxa de câmbio euro-dólar. Os dados vão de 04 de janeiro de 1999 a 30 de dezembro de 2016. Ajustou-se a dependência não linear através de modelos da família GARCH, incluindo modelos simétricos e assimétricos que capturam fatos estilizados mais comuns sobre os retornos

da taxa de câmbio, tais como aglomerados de volatilidade e o efeito alavancagem. Os resultados empíricos indicam um alto grau de persistência da volatilidade da taxa de câmbio. Isto significa que o processo de volatilidade condicional é do tipo reversão à média e os choques são transitórios. Além disso, o parâmetro que reflete a assimetria γ é significativo ao nível de 5% no modelo GJR e ao nível de 1% no modelo EGARCH, mostrando que a série analisada exibe o efeito alavanca.

O modelo com a melhor capacidade preditiva foi definido em medidas associadas aos erros de previsão. Utilizou-se três diferentes estatísticas ou funções de perda como critérios de previsão. O modelo EGARCH foi aquele que apresentou melhor capacidade preditiva, uma vez que seu erro quadrático médio e erro absoluto médio foram relativamente menores, embora os três modelos de volatilidade condicional tenham fornecido previsões de volatilidade muito próximas.

Os resultados têm implicações para os gestores de carteira no cômputo do VaR (*Value at Risk*) e para os analistas que fazem o uso da volatilidade no apreçamento de derivativos. Trabalhos subsequentes podem testar a superioridade de previsão de tais modelos através de outros testes, tais como o teste de Diebold e Mariano (1995) ou, ainda, o teste *SPA* (*Superior Predictive Ability*), proposto por Hansen (2005). Podem, ainda, fazer uso dos modelos de volatilidade de memória longa, bem como incluir na comparação dos modelos de volatilidade condicional o índice de volatilidade empregado no mercado como o VIX.

Referências

- ABDALLA, Suliman Zakaria Suliman. **Modelling Exchange Rate Volatility using GARCH Models: Empirical Evidence from Arab Countries**. International Journal Of Economics And Finance, [s.l.], v. 4, n. 3, p.216-229, 23 fev. 2012.
- BLACK, F. **The price of commodity contracts**. Journal of Financial Economics.3:167-79, 1976.
- BOLLERSLEV, T. **Generalized Autorregressive Conditional Heteroskedasticity**, Journal of Econometrics, v.31, p.307-327, 1986.
- CAMPBELL, J.; LO, A.; MCKINLAY, C. **The econometrics of financial markets**. Princeton: Princeton University; 1997.
- DIEBOLD, F.X., MARIANO, R. (1995). **Comparing Predictive Accuracy**. Journal of Business and Economic Statistics 13, 253-265.
- DING, Zhuanxin; GRANGER, Clive W.j.; ENGLE, Robert F.. **A long memory property of stock market returns and a new model**. Journal Of Empirical Finance, [s.l.], v. 1, n. 1, p.83-106, jun. 1993.

- ENGLE, R. F. **Autorregressive Conditional Heteroskedasticity with Estimates of the Variance of United Kingdom Inflation**, *Econometrica*, v.50, n.4, p.987-1007, 1982.
- ENGEL, R.F, BOLLERSLEV, T. 1986. **Modelling the persistence of conditional variances**. *Econometric Reviews* 5, 1-50.
- GLOSTEN, L.R., JAGANNATHAN, R., RUNKLE, D.E., 1993. **On the relation between the expected value and the volatility of the nominal excess return on stocks**. *Journal of Finance* 48, 1779-1801.
- HANSEN, P.R., 2005. **A test for superior predictive ability**. *Journal of Business & Economic Statistics* 23, 365-380.
- KANG, S.H., KANG, S.M, YOON, S.M., 2009. **Forecasting volatility of crude oil markets**. *Energy Economics* 31, 119-125.
- LOPEZ, J.A., 2001. **Evaluating the predictive accuracy of volatility models**. *Journal of Forecasting* 20, 87-109.
- LJUNG GM, Box GEP. **On a measure of lack of fit in time series models**. *Biometrika*.65: 297-303. 1978
- MARZO, Massimiliano; ZAGAGLIA, Paolo. **Volatility forecasting for crude oil futures**. *Applied Economics Letters*, [s.l.], v. 17, n. 16, p.1587-1599, 28 out. 2010.
- NELSON, D.B. 1991. **Conditional heteroskedasticity in asset returns: a new approach**. *Econometrica* 59, 347-370.
- SCHWARZ, Gideon. **Estimating the Dimension of a Model**. *The Annals of Statistics*, v.6, n. 2, 461-464, 1978.
- SENNA, José Júlio. **Política monetária: ideias, experiências e evolução**. Rio de Janeiro: Editora FGV, 2010.
- SADORSKY, P., 2006. **Modeling and forecasting petroleum futures volatility**. *Energy Economics* 28, 467-488.
- SWANSON, N.R., ELLIOTT, G., Ghysels, E., GONZALO, J., 2006. **Predictive methodology and application in economics and finance**: volume in honor of the accomplishments of Clive W.J. Granger. *Journal of Econometrics* 135, 1-9.
- ZAKOIAN, J-M. 1994. **Threshold heteroskedastic models**. *Journal of Economic Dynamics and Control* 18, 931-955. BRAYNER, A.R.A.; MEDEIROS, C.B. Incorporação do tempo em SGBD orientado a objetos. In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS, 9.; 1994, São Paulo. **Anais...** São Paulo: USP, 1994. p. 16-29.

ANALYSIS OF THE BEHAVIOR OF VOLATILITY IN THE EURO-DOLLAR EXCHANGE RATE

Abstract

The present paper analyzes the series of returns of the euro-dollar exchange rate, with daily frequency. The stationarity is proven through the ADF and Phillips-Perron tests. The non-normality of the series of returns was verified. The temporal dependence of the returns was tested through the autocorrelations of the same and later modeled. We use some linear and nonlinear generalized autoregressive conditional heteroskedasticity (GARCH) class models to capture the volatility features of the euro-dollar exchange rate. Subsequently, the predictive capacity of each model was evaluated. The empirical results indicate a high degree of persistence of exchange rate volatility. The EGARCH model was the one with the best predictive capacity, although the three conditional volatility models analyzed provided predictions of volatility very close.

Key-words: Exchange Rate, GARCH, Volatility, Predictability of volatility.