

APLICAÇÃO DA MÉTRICA *VALUE AT RISK* A ÍNDICES DE BOLSAS DE VALORES DE PAÍSES LATINO-AMERICANOS: UM ESTUDO UTILIZANDO OS MODELOS DE PREVISÃO DE VOLATILIDADE EWMA, EQMA E GARCH

Application of metric *Value at Risk* the index stock exchanges of
Latin American countries: a study using the models forecast
EWMA volatility, and GARCH EQMA

SILVA, W. V.
TARDELLI, M.
ROCHA, D. T. DA
MAIA, M.

Recebimento: 24/11/2009 – Aceite: 09/07/2010

RESUMO: Atualmente, o mercado financeiro vem passando por um momento de grande volatilidade, tornando técnicas de gerenciamento de riscos uma importante ferramenta na tomada de decisões. Deste modo, este artigo tem como objetivo o estudo da métrica *Value at Risk*, sendo sua volatilidade estimada por três modelos estatísticos: EWMA, EQMA e GARCH. Para avaliação destes modelos foi criada uma carteira teórica com os índices de preços de ações da Argentina, Brasil e México. Os resultados mostraram que o modelo de suavização exponencial foi o mais apropriado para a modelagem da volatilidade, considerando o nível de confiança de 99%, além de possuir grande capacidade dinâmica de se ajustar aos picos de volatilidade e de realizar previsões mais acuradas das perdas.

Palavras-chave: *Value at Risk*. Volatilidade condicional – GARCH. Suavização exponencial – EWMA. Médias móveis igualmente ponderadas - EQMA.

ABSTRACT: Currently, the financial market is undergoing a period of great volatility, making techniques of risk management an important tool in decision making. Thus, this article aims to study the metric *Value at Risk*, being its

volatility estimated by three statistical models: EWMA, EQMA and GARCH. To evaluate these models a theoretical portfolio with the indexes of stock prices in Argentina, Brazil and Mexico was created. The results showed that the exponential smoothing model was more appropriate for modeling volatility, considering a confidence level of 99%, besides having great dynamic ability to adjust to peaks of volatility and make more accurate predictions of losses

Key words: Value at Risk. Conditional volatility - GARCH. Exponential smoothing - EWMA. Equally weighted moving averages - EQMA.

Introdução

A avaliação de riscos de uma carteira de ativos financeiros, ou mesmo de índices do mercado, é o principal objetivo da teoria financeira moderna, na qual estes riscos são frequentemente medidos em termos de variação de preço de ativos. As séries financeiras apresentam alta volatilidade além de, geralmente, não serem estacionárias na média, fazendo-se necessário o uso do chamado retorno.

A característica de interesse nessas séries de retornos é a sua volatilidade, a qual está diretamente associada à variabilidade dos preços de um determinado ativo, ou mesmo da oscilação do índice de diversas Bolsas de Valores. Então, se os preços ou índices variam muito, diz-se que o ativo é muito volátil.

Usualmente utiliza-se a variância ou o desvio padrão como uma medida da volatilidade, no qual sua estimação e previsão são fundamentais tanto para quantificar o risco de um determinado ativo, quanto para a precificação de produtos financeiros.

Outra característica interessante é que os retornos financeiros raramente apresentam tendências e sazonalidade, além de, em geral, serem não correlacionados, apresentando agrupamentos de volatilidades ao longo do tempo, bem como, geralmente, não possuindo uma distribuição incondicional normal.

Diversas classes de modelos podem ser utilizadas para modelar esta volatilidade. Em particular, os modelos não-lineares ARCH e GARCH, além do método de suavização exponencial e de médias móveis, serão utilizados para estimar a volatilidade de uma carteira teórica dos índices de ações das bolsas do Brasil, México e Argentina (principais economias da América Latina) e posteriormente calcular seu valor de risco (*Value at Risk*).

Esta pesquisa encontra-se estruturada em cinco seções que podem ser descritas da seguinte forma: a primeira diz respeito à parte introdutória; a segunda trata do referencial teórico; a terceira trata da metodologia usada na pesquisa; a quarta refere-se à apresentação e análise dos dados, e a quinta trata das considerações finais e recomendações para elaboração de trabalhos futuros.

Referencial teórico

O cálculo do risco tem como objetivo essencial a mensuração do grau de incerteza na obtenção do retorno esperado em uma determinada aplicação financeira, em um investimento realizado ou na oscilação do índice de ações. Desta forma, estes retornos esperados podem ser classificados como de baixo, médio e alto risco, nos quais, geralmente, os de baixo risco apresentam maior nível de segurança ao investidor, mas em contrapartida costuma ter menor retorno. Já

os de alto risco, por outro lado, podem trazer maior retorno, porém com elevado grau incerteza, podendo até mesmo trazer prejuízos aos investidores.

Destarte, torna-se de extrema importância a disseminação de técnicas de gerenciamento de risco que permitam aos investidores a tomada de decisão de maneira que o retorno auferido seja proporcional ao risco que se esteja disposto a assumir, no qual neste contexto, o *Value at Risk* é uma boa alternativa, assunto o qual será abordado nas próximas seções.

A Métrica *Value at Risk*

O *Value-at-Risk (VaR)*, ou Valor no Risco, é uma métrica para gerenciamento de risco amplamente utilizada por instituições financeiras e por corporações não financeiras em função de suas características e benefícios. Segundo Jorion (2003), “[...] o atributo mais importante do *VaR* é a transparência: um único número de *VaR* transmite o risco de perda potencial em termos que podem ser compreendidos por qualquer pessoa”.

Um marco histórico para a gestão de risco foi a divulgação pública na *internet* do documento denominado *Risk Metrics* pela Instituição Financeira J. P. Morgan que continha uma versão simplificada do modelo de gerenciamento de riscos adotado na Instituição com ênfase no cálculo da estimativa de *VaR*.

Em consequência disso, houve grande disseminação da métrica, que acabou se tornando o principal parâmetro de risco adotado pelo mercado financeiro, sendo utilizado por várias instituições estrangeiras e, posteriormente, pelas brasileiras. Por força do Órgão Regulador, Banco Central, estabeleceu-se regras de alocação de capital mínimo requerido, com base na busca de harmonização regulatória para gerenciamento de risco de mercado incorporada posteriormente ao Acordo da Basileia I de 1988. Outras Cor-

porações não financeiras acabaram posteriormente adotando o *VaR*, porém, em um prazo um pouco mais longo (KIMURA *et al.*, 2009, p. 99-100).

Segundo Crouhy (2004), a métrica *VaR* (Valor em Risco) é uma medida de risco que estima o valor financeiro da perda máxima de uma carteira para um dado nível de confiança e um período de tempo no qual não haja mudança na carteira. Isto permite aos gerentes dizerem: “Nós estamos *X* por cento certos que não iremos perder mais do que *Y* dólares nos próximos *N* dias” (HULL, 2002). Sendo, conforme Filho (2006), *X* uma variável aleatória que representa um valor; $F_X(x) = P[X \leq x]$ a função de distribuição associada a ela; e $F_X^{-1}(\alpha)$ a função inversa de $F_X(x)$, o *VaR* para o nível de confiança de $(1 - \alpha)$ é definido conforme encontra-se a expressão (1).

$$VaR_{(1-\alpha)} = -F_X^{-1}(\alpha) = -\inf\{x \mid F_X(x) \geq \alpha\} \quad (1)$$

A figura 1 mostra a função de densidade de probabilidade dos retornos de uma carteira para um dado período (ex. 1 dia), com o intervalo de confiança de 95%. O *VaR* não informa quanto uma carteira perde em um período, mas mostra estatisticamente que no intervalo de 20 dias, em 1 dia (5% dos dias) as perdas serão maiores que o *VaR* indicado na mesma figura.




Figura 1 - *VaR* de uma distribuição normal com 95% de nível de confiança

Fonte: Elaboração própria.

Na figura 1, a distribuição é considerada normal, mas, na prática, em séries temporais financeiras, geralmente verifica-se a presença

de *fat tails* (caudas gordas). Essa simplificação pressupondo distribuição normal é utilizada como aproximação de forma que os cálculos do valor em risco sejam simplificados. Um problema nessa abordagem é a possibilidade de se subestimar o *VaR*, conforme evidencia Filho (2006).

Considerando uma distribuição normal com o nível de confiança de 95%, o *VaR* é calculado como 1,65 vez o desvio padrão abaixo da média e pode ser interpretado como a probabilidade em 5% de acontecer uma perda maior ou igual ao *VaR*.

Esta métrica é atualmente essencial para a mensuração de riscos nos bancos, os quais usam níveis de confiança de 99%, conforme determinação do *Bank for International Settlements* (BIS), em português, Banco para Compensações Internacionais.

Geralmente, os bancos utilizam o período de um dia como horizonte de tempo padrão, considerando a permanência com a carteira inalterada. Entretanto, o BIS requer o cálculo para 10 dias, o qual pode ser obtido pela multiplicação do valor do Valor em Risco, para 1 dia, por raiz quadrada de 10, conforme mostra Crouhy (2004).

Quanto mais elevado for o nível de confiança, menor será a frequência com que se observam valores maiores que o *VaR* na distribuição de probabilidades dos dados históricos de eventos passados e presentes, e mais difícil será a identificação apropriada de eventos extremos (FILHO, 2006).

Segundo Alarcon (2005), uma característica importante desta métrica é a sua ampla aceitação entre as instituições financeiras pela sua capacidade de aplicação em carteiras compostas por uma grande variedade de ativos, o que permite a avaliação relativa de cada fator de risco de mercado e sua agregação em uma base de análise comum. Como conceito padrão de mensuração de risco de mercado, o *Value at Risk* permite quantificar

e comparar riscos de ativos financeiros de naturezas distintas.

Levar em consideração as correlações dos ativos é outra característica que deve ser ressaltada em relação ao *VaR*, uma vez que esta permite que a adição de dois ativos expostos a riscos de fontes distintas e inversamente relacionadas possam se autocompensar e fornecer menores estimativas do *VaR*. O inverso, ativos positivamente relacionados, irá elevar a estimativa do Valor em Risco de forma a refletir o aumento do risco da carteira.

Segundo Alarcon (2005), existem três limitações a serem consideradas quando da utilização dos modelos *VaR*: a primeira é a suposição de que existe uma relação entre valores do passado e presente com valores futuros, o que pode não ser verificado uma vez que o mercado pode apresentar comportamento inesperado. A segunda é baseada nas simplificações, por exemplo, em termos de assumir distribuição normal dos retornos de uma carteira, o que pode distorcer os resultados. A última limitação mostra que qualquer sistema de *software* é passível de falhar e, por esse motivo, deve ser utilizado de forma cautelosa, considerando outras informações que não somente os números.

Por ser baseado em diferentes parâmetros, com pequenos erros decorrentes de aproximações, o cálculo do *VaR* é impreciso e não faz muito sentido empregar esforço com cálculos muito precisos, uma vez que os dados de entrada possuem ruídos (WIENER, 1997).

Segundo Kimura *et al.* (2008), “convém destacar que não existem evidências que demonstrem a superioridade de uma metodologia sobre a outra. Dependendo dos ativos da carteira e das condições de mercado, uma metodologia pode ser superior à outra”. A seguir são brevemente introduzidas as metodologias para cálculo do *VaR*.

Método Não-Paramétrico para o Cálculo do Value at Risk

Segundo Souza (2004), basicamente existem dois tipos de métodos para o cálculo do VaR: o paramétrico e o não paramétrico. O método não paramétrico compreende a abordagem da simulação histórica e simulação de Monte Carlo. O método paramétrico, geralmente, utiliza a abordagem variância-covariância e alguns métodos analíticos.

Por meio do modelo não paramétrico de simulação histórica, a avaliação do Valor em Risco é feita sem nenhuma assunção especial sobre o modelo que rege o comportamento dos retornos, sendo utilizado o percentil experimental da série observada. O método é facilmente implementável, exigindo pouco esforço computacional, porém possui algumas deficiências. Uma delas é que, quanto maior o nível de confiança, mais observações são necessárias para se obter uma previsão segura. Além disso, como essa métrica atribui pesos iguais a todas as observações anteriores, ela assume que os retornos são identicamente distribuídos. Desta forma, variações na volatilidade não são captadas por esta metodologia.

Enquanto no outro modelo não paramétrico, a metodologia de Monte Carlo é usada para gerar séries de retornos aleatórios, a partir de um modelo determinado. O VaR é, então, calculado a partir do percentil da série simulada.

Métodos Paramétricos EQMA e EWMA Para o Cálculo do Value at Risk

Os modelos paramétricos buscam modelar a série de retornos dos ativos observados, ajustando-os a uma função de probabilidade, na qual o VaR é calculado de acordo com o percentil desta distribuição. Destarte, a qualidade da medida depende do realismo

com que o modelo representa os retornos dos ativos observados.

O método *Equally Weighted Moving Average* (EQMA), ou Médias Móveis Iguamente Ponderadas, considera valores passados e presente da série de dados como tendo a mesma importância, é sabido que os valores mais recentes da série influenciam mais significativamente os valores futuros do que os passados, em função disso, para que esse método forneça resultados mais significativos é importante considerar uma faixa de valores extensa no cálculo da média. Na prática podem ser utilizados 252 valores, o que representa, em média, um ano de negociações diárias. A variância e a autocorrelação são calculadas estimadas com base nas expressões (2) e (3), respectivamente:

$$\hat{\sigma}_t^2 = \sum_{i=1}^n r_{t-i}^2 / n \quad (2)$$

$$\hat{\rho}_t = \frac{\sum_{i=1}^n r_{1,t-i} r_{2,t-i}}{\sqrt{\sum_{i=1}^n r_{1,t-i}^2 \sum_{i=1}^n r_{2,t-i}^2}} \quad (3)$$

No modelo Exponentially Weighted Moving Average (EWMA), ou Médias Móveis Exponencialmente Ponderadas, vem ao encontro da necessidade de se considerarem valores mais recentes da série de dados como mais significativos para a definição do futuro, em detrimento aos valores mais antigos da série. Vale destacar que as equações (4) e (5), respectivamente, são utilizadas para o cálculo da variância e covariância:

$$\hat{\sigma}_t^2 = (1 - \lambda)r_{t-i}^2 + \lambda\hat{\sigma}_{t-1}^2 \quad (4)$$

$$\hat{\sigma}_{2,t} = (1 - \lambda)r_{1,t-1}r_{2,t-1} + \lambda\hat{\sigma}_{2,t-1} \quad (5)$$

O EWMA, também denominado alisamento exponencial, em português, foi bastante disseminado, principalmente, pelo fato ser a metodologia utilizada para estimar volatilidades e correlações constante no documento *Risk Metrics* do J. P. Morgan, tornando-o padrão no mercado financeiro e sendo bastante utilizado pelas instituições financeiras.

Uma importante característica deste modelo é a propriedade de modelar a memória de curto prazo da volatilidade, pois o fator de decaimento λ constante nas expressões (4) e (5), respectivamente, representa um fator de associado à memória de curto prazo, sendo que a ideia do modelo é justamente identificar o λ que melhor modele a memória de curto prazo do ativo ou mercado como um todo (KIMURA *et al.*, 2008, p. 192-194).

Modelos ARCH e GARCH Para Estimação da Volatilidade dos Retornos

Os modelos *Autoregressive Conditional Heteroskedastic* (ARCH), ou em português, Heteroscedasticidade Condicional Autoregressiva, são ferramentas usadas para modelar a volatilidade do retorno de um ativo e são exemplos de modelos de heteroscedasticidade condicional.

A volatilidade tem sua utilidade em várias aplicações financeiras (precificação de opções, alocação de recursos em estruturas de variância mínima) e, neste artigo, será utilizada como parâmetro no cálculo do valor em risco de uma carteira de títulos.

O modelo ARCH, em português (Heteroscedasticidade Condicional Autoregressiva), de Engle (1982), modela a volatilidade e apoia-se na ideia de que o resíduo α_t do re-

torno de um ativo não é serialmente correlacionado, mas é dependente, e a dependência de α_t pode ser representada por uma função quadrática de seus valores defasados. Um modelo ARCH (m) pode ser representado pela expressão algébrica (6).

$$a_t = \sigma_t \varepsilon_t,$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 a_{t-1}^2 + \dots + \alpha_m a_{t-m}^2 \quad (6)$$

Onde ε_t é uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média zero e variância 1, $\alpha_0 > 0$, e $\alpha_i > 0$ para todo $i > 0$. Na prática pressupõe-se que ε_t assuma distribuição normal, *t-Student* ou distribuição generalizada de erro. Observando-se a estrutura do modelo, percebe-se que grandes choques do passado implicam grande variância. Isto significa que grandes choques tendem a ser seguidos por outros grandes choques.

Segundo Tsay (2005), a volatilidade não pode ser observada diretamente dos dados de retorno, uma vez que existe somente uma observação em um dia de pregão. Se forem considerados dados intradiários (retorno de 15 minutos ou frequências maiores) é possível o cálculo da volatilidade diária, mas será necessária uma análise cuidadosa dos dados uma vez que dados de alta frequência possuem pouca informação sobre a volatilidade diária.

Embora não seja diretamente observável, a volatilidade apresenta os seguintes comportamentos comuns em séries de retornos de ativos:

- o agrupamento de volatilidade pode ser alto para alguns períodos e baixo para outros períodos;
- evolui de maneira contínua ao longo do tempo, sendo raras as ocorrências de saltos;

- não diverge para o infinito – as variações ficam restritas a uma faixa de valores (o que significa que a volatilidade é estatisticamente estacionária);
- tem comportamento diferenciado na reação a um retorno significativamente positivo e um retorno significativamente negativo (comportamento este conhecido como efeito de alavancagem).

Estas características têm sido o foco dos modelos de previsão de volatilidade e a diferença de um modelo está na capacidade de capturar um ou outro comportamento (ex: modelo EGARCH para capturar o efeito de alavancagem).

As alterações no comportamento da variância dos erros de uma série de dados é característica frequentemente encontrada em séries temporais financeiras e é denominada heterocedasticidade.

Nesse tipo de série temporal, a heterocedasticidade apresenta-se a partir de grandes (pequenos) retornos absolutos seguidos por outros grandes (pequenos) retornos. Isto significa que existem períodos que mostram agrupamentos de alta (baixa) volatilidade e estes podem ser observados em séries diárias e semanais, de ações, *commodities* e câmbio.

Alguns coeficientes de correlação e o conjunto dos quatro primeiros momentos (média, variância, assimetria e curtose) da estatística, podem ajudar a identificar o modelo GARCH que melhor captura o comportamento da série temporal.

Segundo Alexander (2005), por consequência do agrupamento observa-se uma forte autocorrelação dos retornos ao quadrado, o que pode ser verificado, calculando-se o coeficiente de correlação de primeira ordem dos retornos ao quadrado como mostrado na equação (7).

$$\frac{\sum_{t=2}^T r_t^2 r_{t-1}^2}{\sum_{t=2}^T r_t^4} \quad (7)$$

A significância estatística do coeficiente de correlação de primeira ordem pode ser medida a partir do teste de hipóteses de Box-Pierce (LM). O teste de Box-Pierce é uma forma de teste do Multiplicador de Lagrange (LM), e assintoticamente, é uma variável do tipo qui-quadrado com 1 grau de liberdade, para o caso de correlação de primeira ordem e, por consequência, seu valor crítico a 1% é igual a 6,635. A equação (8) expressa o teste de hipóteses de Box-Pierce para ordem p , em que T é o tamanho da amostra e $\varphi(n)^2$ a autocorrelação de ordem n .

$$Q = T \sum_{n=1}^p \varphi(n)^2 \quad (8)$$

O teste de hipóteses de Box-Pierce é simples em relação à programação computacional, mas não tão robusto em termos de resultado. Devem-se considerar outras medidas estatísticas no sentido de confirmar o resultado desse teste. Em uma situação hipotética na qual se verifica assimetria negativa e extremo excesso de curtose, é provável que o resultado do teste esteja sendo influenciado por *outliers* extremamente negativos que induzem uma baixa autocorrelação.

Outro aspecto a ser considerado na identificação do modelo está relacionado com a assimetria presente nas séries, e essa característica pode ser verificada pelo coeficiente de autocorrelação de primeira ordem entre os retornos defasados e os retornos correntes ao quadrado tal como pode ser visto na equação (9).

$$\frac{\sum_{t=2}^T r_t^2 r_{t-1}}{\sqrt{\sum_{t=2}^T r_t^4 \sum_{t=2}^T r_{t-1}^2}} \quad (9)$$

Caso se obtenha um resultado negativo para o coeficiente supracitado e o teste de hipóteses de Box-Pierce for estatisticamente diferente de zero, conclui-se que existe assimetria no agrupamento, a qual não será capturada por modelos GARCH simétricos. Como desvantagens dos modelos ARCH pode-se destacar:

- Assume que choques positivos e negativos têm o mesmo efeito sobre a volatilidade, pois ele depende do quadrado do choque anterior; mas na prática é sabido que as séries financeiras respondem de formas diferentes ante choques negativos e positivos, pois o agrupamento de volatilidade pode ser alto para alguns períodos e baixo para outros períodos;
- É restritivo uma vez que o beta da equação deve assumir valores no intervalo $[0, 1/3]$, se a série tem curtose finita. Na prática, essa restrição dificulta a modelagem com muitos parâmetros e limita a habilidade dos modelos ARCH em capturar excesso de curtose;
- Não fornece informações sobre o que gerou as variações nas séries financeiras. É simplesmente uma forma de descrever o comportamento da variância condicional;
- É possível que o modelo superestime a volatilidade, porque responde lentamente a grandes choques da série de retornos.

Com a intenção de resolver o problema de excesso de parâmetros do modelo ARCH, Bollerslev (1986) propôs uma extensão conhecida como modelo ARCH generalizado,

generalized auto regressive conditional heteroskedastic (GARCH). Ao modelo foi adicionada uma variável para capturar o comportamento da variância condicional em separado. Para uma série de logaritmos de retornos r_t , onde $a_t = r_t - \mu t$ seja o resíduo no tempo t , o modelo GARCH (m, s) pode ser expresso a partir da equação (10).

$$a_t = \sigma_t \varepsilon_t,$$

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^m \alpha_i a_{t-i}^2 + \sum_{j=1}^s \beta_j \sigma_{t-j}^2 \quad (10)$$

onde (ε_t) é uma sequência de variáveis aleatórias independentes e identicamente distribuídas com média zero e variância igual a 1, $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$ e $\sum_{i=1}^m \alpha_i + \sum_{j=1}^s \beta_j < 1$. É importante explicitar que $\alpha_i = 0$ para $i > m$, $\beta_j = 0$ para $j > s$ e $\alpha_i + \beta_i$ implica que a variância incondicional de a_t é finita, e a variância incondicional evolui ao longo do tempo.

De acordo com Jorion (2003), “o modelo GARCH pressupõe que a variância dos retornos siga um processo previsível. A variância condicional depende da inovação mais recente e, também da variância condicional anterior”.

Em questões de desvantagens, os modelos GARCH sofrem da mesma deficiência que os modelos ARCH, uma vez que não diferencia um choque negativo de um positivo e, como foi observado por Tsay (2005), o mercado reage de forma diferenciada a esses eventos.

Metodologia

Caracterização da Pesquisa

Este trabalho pode ser caracterizado como uma pesquisa aplicada que objetiva gerar conhecimentos para aplicação prática e dirigidos à solução de problemas específicos.

O tipo de amostragem utilizada é o não probabilístico por conveniência e intencional que, segundo Hair Jr. *et al.* (2005), este tipo de amostragem não permite ao pesquisador, contudo, extrapolar os dados, visto que não se conta com um número de casos suficiente ou suporte estatístico para tal, deve ficar circunscrito ao evento analisado.

O estudo apresentado é de natureza descritiva, pois tem o objetivo de analisar os dados coletados a partir do estudo das características das variáveis coletadas. Segundo Gil (2002), a pesquisa descritiva estabelece relações entre variáveis a partir da descrição das características de determinado fenômeno ou população.

Quanto aos procedimentos técnicos utilizados, o delineamento desta pesquisa é não experimental ou *ex-post facto*. Não sendo possível manipular os dados e não havendo controle sobre as variáveis estudadas, pois trata de fenômenos já ocorridos, esse delineamento considera constatações exclusivamente correlacionais entre as variáveis estudadas (GIL, 2002).

Coleta dos Dados

Na análise, foram consideradas as séries históricas de retornos dos índices de preços de ações dos países com maior representatividade do mercado de capitais da América Latina, isto é: México (Índice de Preços e Cotações - IPC); Brasil (Índice da Bolsa de Valores de São Paulo - IBOVESPA); e Argentina (Mercado de Valores de Buenos Aires - Merval), os quais abrangem o período de 23/03/2001 até 14/07/2009, sendo considerados somente os dias em que houve pregão. As séries temporais foram obtidas a partir do site da *Internet Yahoo Finance*, e formam a carteira teórica de índices de preços de ações a ser analisado.

Para o período em estudo foram geradas previsões de volatilidade diárias para a car-

teira hipotética, calculada posteriormente a estimativa máxima de perda com o nível de confiança de 99% no horizonte de tempo de um dia, conforme requerido no acordo de Basileia II para risco de mercado, e verificando o percentual de exceções em relação ou realizado, ou seja, no qual a perda da carteira foi maior que a perda prevista pelos métodos.

Apresentação e análise dos resultados

Os modelos de volatilidade para cálculo do *VaR* foram aplicados aos índices das Bolsas de Valores Merval (Argentina), IPC (México) e IBOVESPA (Brasil) em função da grande representatividade desses países em termos de Produto Interno Bruto da América Latina.

Foram obtidos os dados diários (levando-se em conta os dias em que houve pregão nos três países) do período de 23/03/2001 a 14/7/2009. Para a realização do *backtesting* foi utilizada uma janela de observação equivalente as 450 últimas observações, que equivalem ao período de 10/8/2007 a 14/07/2009.

A figura 2 demonstra o comportamento da série histórica dos retornos obtidos, com destaque para o evento do agravamento da crise financeiro nos EUA, principal agrupamento de alta volatilidade da série:




Figura 2 - Retorno da Carteira Teórica de Índices de Ações
Fonte: Dados da Pesquisa.

Backtesting do Modelo Estimado

Denomina-se *backtesting* o termo genérico atribuído a um procedimento, por meio do qual é efetuada uma avaliação, considerando os dados reais obtidos posteriormente aos fatos ocorridos, com o objetivo de checar se o modelo está adequado.

No caso específico do *VaR*, este procedimento é utilizado para avaliar se as estimativas de perda máxima geradas a partir do *VaR* estão adequadas à carteira e às condições do mercado. O *backtesting* mais simples envolve a mera comparação entre os valores de perda máxima estimados pelo *VaR*, antes da ocorrência do fato para o horizonte de tempo em questão (1 dia no caso de nosso estudo) e a perda real ocorrida na carteira.

O procedimento consiste na comparação do resultado real L_t na data t_t com a estimativa de perda máxima VaR_t que foi realizada na data t_0 . (como em qualquer procedimento estatístico é importante realizar esta comparação por período de tempo razoável, como por exemplo: 100 ou 1.000 dias). Nos casos em que as perdas reais L_t superarem as perdas máximas estimadas VaR_t considera-se que ocorreu uma violação do modelo. As violações são esperadas, porém, desde que a quantidade contabilizada não supere a quantidade máxima que é esperada de acordo com o intervalo de confiança cujas estimativas foram feitas (KIMURA *et al.*, 2009, p. 153-155).

Fundamentado no que foi explanado anteriormente, com a finalidade de comparar os resultados reais com as estimativas de *VaR* geradas pelo modelo, o teste realizado neste estudo consistiu em comparar o retorno real (L_t) da carteira (marcada a mercado) na data anterior (t_0) com as estimativas de *VaR* (L_t) da data t_0 calculadas através de cada um dos métodos.

Para obter a quantidade de vezes em que ocorreram violações do modelo, foi contabilizado o número de vezes em que o retorno negativo superou a estimativa de perda máxima calculada pelo *VaR* dentro do alcance da janela, composta por 450 observações para cada um dos métodos.

Nas figuras 3, 4 e 5, respectivamente, são apresentados os resultados do *VaR* calculados a partir das métricas EQMA, EWMA e GARCH, respectivamente, *versus* os retornos reais efetivamente ocorridos na carteira (marcada a mercado) no período do estudo.

Por meio destes gráficos é possível constatar as violações dos limites ocorridos, observando os momentos em que os retornos negativos da linha “carteira” extrapolam as percentagens de perdas máximas estimada por cada uma das metodologias.




Figura 3 - Value at Risk Estimado a Partir do EQMA

Fonte: Dados da Pesquisa.

Na figura 3, pode-se observar a partir do cálculo realizado por meio da metodologia EQMA, que as estimativas de perdas tenderam a permanecer constantes (sem oscilações bruscas), a despeito das altas oscilações (choques) ocorridas nos momentos de maior volatilidade.

Percebe-se que, desde o início da série histórica, o método não demonstrou ter boa capacidade de prever as perdas ocorridas. Posteriormente ao período de maior volatilidade (outubro de 2008), as estimativas apresentadas se tornaram demasiadamente pessimistas, não demonstrando boa capacidade de ajuste à dinâmica das condições posteriores e, por consequência, superestimando

as perdas potenciais. Os resultados dos testes de violação dos limites demonstraram que em 4% (17 ocorrências) das observações os retornos da carteira excederam os limites das estimativas de *VaR* calculadas pelo EQMA.




Figura 4 - Value at Risk Estimado a Partir do EWMA
Fonte: Dados da Pesquisa.

A partir da figura 4, percebe-se que o cálculo realizado por meio da metodologia EWMA (utilizando o fator de decaimento $\lambda = 0,94$) apresentou estimativas de perdas mais apuradas do que os cálculos feitos pela metodologia EQMA.

Pode-se observar que, nos momentos de maiores volatilidades (set/out 2008), as estimativas se ajustaram dinamicamente aos retornos reais (perdas), retornando a calcular estimativas mais próximas das perdas reais, em um espaço de tempo relativamente curto.

Os resultados dos testes de violação dos limites demonstraram que em 1% (5 ocorrências) das observações os retornos da carteira excederam os limites das estimativas de *VaR* calculadas pelo EWMA, sendo que este foi o método de cálculo de estimativa que teve a melhor *performance*.

Pautando-se na figura 5, percebe-se que o cálculo realizado por meio da metodologia GARCH parece ter uma boa dinâmica de ajustamento às perdas reais, não superestimando tais perdas, porém apresentando uma capacidade limitada para prever os maiores percentuais de perdas ocorridos nos picos de volatilidade.

Os resultados dos testes de violação dos limites demonstraram que em 4% (20 ocor-

rências) das observações os retornos da carteira excederam os limites das estimativas de *VaR* calculadas a partir do GARCH, sendo o método de cálculo de estimativas com a pior *performance* dentre todos.




Figura 5 - Value at Risk Estimado a Partir do GARCH
Fonte: Dados da Pesquisa.

Nos resultados apresentados no exercício de *backtesting*, dentre os 3 modelos testados, o EWMA (ou RiskMetrics), também chamado em português de alisamento exponencial foi o único cujas violações permaneceram dentro do nível de confiança esperado de 1%.

Para a amostra utilizada neste estudo, os resultados da comparação entre os três modelos permitem inferir que as estimativas de perda máxima calculada a partir do método EWMA sofreram menos violações de limites do que as estimativas de *VaR* calculadas pelos outros modelos. Estas duas constatações nos permitem inferir que, para nesta situação específica, este modelo se mostrou mais eficiente do que os demais.

É importante salientar que as interpretações acima foram feitas baseando-se nos indicativos obtidos, utilizando esta amostra a qual espelha um cenário de um período conturbado em função da alta volatilidade causada pela crise financeira internacional. Portanto, não se pode dizer categoricamente que um modelo seja mais eficiente que o outro, pois a dinâmica do mercado e outras variáveis, tais como o tamanho da amostra, o perfil de risco da carteira, etc., caso fossem diferentes, poderiam ter-nos levado a outras conclusões.

Conclusão

Foram apresentados neste artigo três modelos distintos para cálculo de estimativas de risco (volatilidade) ou *VaR* (*Value at risk*), que é uma métrica bastante difundida para avaliação de riscos em carteiras de ativos, desde que se tornou pública graças à Instituição Financeira J. P. Morgan que a utilizava em sua estrutura de gerenciamento de risco e resolveu compartilhar com o mercado. Sem dúvida, o diferencial do *VaR* perante outras métricas de gerenciamento de risco é a sua característica simples, pois um único número estimado pelo *VaR* reflete uma estimativa de perda de maneira compreensível para qualquer público. Basicamente o *VaR* informa qual o máximo que se pode perder em valor (no nosso caso em Reais) em um horizonte de tempo determinado (normalmente curtíssimo prazo, 1 dia por exemplo) com um nível de confiança estabelecido (o mais comum é 95%).

A partir do teste de violação dos limites (*backtesting*) realizado neste artigo, foi possível constatar que o único modelo que se mostrou apropriado para a modelagem da volatilidade foi o modelo de alisamento exponencial EWMA, considerando que o número de violações se manteve dentro do nível de confiança de 99%. Na comparação feita no *backtesting* foi possível observar que o modelo EWMA se mostrou superior aos demais, apresentando uma grande capacidade dinâmica de se ajustar aos picos de volatilidade e de realizar previsões mais acuradas das perdas ou, em outras palavras, ajustando-se rapidamente à memória de curto prazo da volatilidade.

A utilização de várias metodologias para cálculo do *VaR* nos permitem obter um panorama mais abrangente do nível de risco assumido. Os modelos estatísticos buscam o máximo possível à representação das condições reais do mercado, porém nem sempre é possível ter acesso a todos os dados que representam o processo em si, tendo sempre em mente que modelos são apenas abstrações da realidade. Existem determinados riscos, aos quais os mercados emergentes estão sujeitos e que normalmente não estão refletidos em bases de dados históricas, podemos citar como exemplo destes riscos: moratórias nos países latino-americanos, a crise da Rússia e o atual cenário vivido em função da crise financeira internacional deflagrado pela nação considerada o símbolo do capitalismo.

A atividade de gerenciamento de risco, portanto, exige que sejam levados em conta todos os riscos envolvidos no processo, fazendo o possível para não cair na armadilha de negligenciarmos outros riscos relevantes, apenas pela falsa sensação de conforto causada pela precisão na mensuração do cálculo do *VaR*, ou de qualquer outro modelo estatístico. Devemos ter sempre em mente que os modelos estatísticos são uma das ferramentas a serem utilizadas no processo de gerenciamento de risco e não as únicas ferramentas, pois, conforme Richard Felix *Chief Credit Officer*, do Morgan Stanley, disse: “A gestão de risco consiste em perguntar o que pode ocorrer no 1% restante das vezes”.

A título de sugestão para trabalhos futuros, a recomendação seria a inclusão de outros índices de bolsa na carteira, talvez utilizando dados das bolsas de valores da Ásia e Pacífico, e que fossem acrescentados outros modelos de estimativa de cálculo de *VaR*.

AUTORES

Wesley Vieira da Silva – Professor da Pontifícia Universidade Católica do Paraná - (PUCPR)/ FESP-PR . Doutor em Engenharia de Produção pela Universidade Federal de Santa Catarina (2002). Pontifícia Universidade Católica do Paraná - (PUCPR). E-mail: wesley.vieira@pucpr.br

Marcelo Tardelli – Mestrando pela Pontifícia Universidade Católica do Paraná - (PUCPR). Pontifícia Universidade Católica do Paraná - (PUCPR).

Daniela Torres da Rocha – Doutoranda pela Pontifícia Universidade Católica do Paraná - (PUCPR). Pontifícia Universidade Católica do Paraná - (PUCPR) E-mail: danitorres.rocha@gmail.com

Marcos Maia – Aluno MBA Mercado Financeiro – FESP-PR.

REFERÊNCIAS

ALARCON, C. M. **Avaliação de Modelos de Value at Risk para Ações** – Universidade Estadual de Campinas. Instituto de Economia – Dissertação Mestrado, 2005.

ALEXANDER, C. **Modelos de Mercado: Um Guia para a Análise de Informações Financeiras** – Bolsa de Mercadorias & Futuro, 2005.

ASSAF NETO, A. **Mercado Financeiro**. São Paulo: Atlas, 2009.

BARRETOS, G. A.; OLIVEIRA, S. C.; ANDRADE, M. G. **Estimação Bayesiana de parâmetros de modelos ARCH(p) via simulação de Monte Carlo em Cadeias de Markov**, Anais do XV Congresso Brasileiro de Automática, 2004.

BOLLERSLEV, T. Generalised autoregressive conditional heteroscedasticity. *Journal of Econometrics*, vol. 31, p. 307-327, 1986.

BOLLERSLEV, T.; CHOU, R. Y.; KRONER, K. F. **ARCH modeling in finance - a review of the theory and empirical evidence**, *Journal of Econometrics*, vol. 52, p. 5-59, 1992.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**., Englewood Cliffs NJ: Prentice-Hall, New York, 1994.

CROUHY, M.; GALAI, D.; MARK, R. **Gerenciamento de Risco: abordagem conceitual e prática: uma visão integrada dos riscos crédito operacional e de Mercado**. Rio de Janeiro: Qualitymark, 2004.

ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation, *Econometrica*, vol. 50, pp. 987-1007, 1982.

FILHO, V. A. D. **Portfolio Management Using Value at Risk: A Comparison Between Genetic Algorithms and Particle Swarm Optimization** – Master Thesis Informatics & Economics, 2006.

FRANSES, P. H.; VAN DIJK, D. **Non-linear time series models in empirical finance**, Cambridge University Press: Cambridge, 2000.

- GALDI, F. C.; PEREIRA, L. M. **Valor em risco (VaR) utilizando modelos de previsão de volatilidade: EWMA, GARCH e volatilidade estocástica.** Brazilian Business Review, Vitória, v. 4, n.1, p. 74-95, jan./abr. 2007.
- GIL, A. C. **Métodos e técnicas de pesquisa social.** 4. ed. São Paulo: Atlas, 1994.
- HAIR JR., J. F. et al. **Análise multivariada de dados.** 5. ed. Porto Alegre: Bookman, 2005.
- JORION, P. **Value-at-risk: a nova fonte de referência para a gestão do risco financeiro.** São Paulo – Bolsa de Mercadorias & Futuros, 2003.
- KIMURA, H. et al. **Value-at-risk - como entender e calcular o risco pelo var: uma contribuição para a gestão no Brasil.** Ribeirão Preto: Inside Books, 2008.
- MILONE, M. C. M.; FAMÁ, R. **Avaliação de Risco: Modelos Simplificados de VaR ao alcance de Investidores Não-Institucionais – V SEMEAD – USP,** 2001.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais.** Gold Blücher 2. ed. São Paulo, 2006.
- SANT’ANNA, A. S.; ROSSI L. E. M. **Análise de Metodologias de VaR – Value at Risk – Para Estimar o Risco de Mercado de Ativos Brasileiros – VII SEMEAD – USP.**
- SOUSA, M. N. C. **Redução da Persistência de Volatilidade nos Modelos GARCH para o Cálculo do Valor em Risco no Mercado Brasileiro.** UFRJ/COPPEAD, 2004.
- TSAY, R. S. **Analysis of Financial Time Series, Wiley Series In Probability and Statistics – 2. ed.** New Jersey, 2005.
- VERHOEVEN, P.; MCALEER, M. **Fat tails and Asymmetry in financial volatility models,** Faculty of Economics, University of Tokyo, CIRJE-F-211, 2003.
- WIENER, Z. **Introduction to VaR (Value-at-Risk)** Business School, The Hebrew University of Jerusalem – May 1997.