



ANÁLISE DO COMPORTAMENTO DO ÍNDICE DOW JONES

Pedro Luiz Costa Carvalho

Bacharel e mestre em Administração - UFLA
Prof.: Instituto Federal Goiano, campus Urutaí - Goiás – Brasil.
(pcostacarvalho@yahoo.com.br).

Recebido em: 04/05/2012 – Aprovado em: 15/06/2012 – Publicado em: 30/06/2012

RESUMO

O presente trabalho tem como objetivo analisar o comportamento da série do índice Dow Jones em quantidades de pontos mensais no fechamento do pregão, utilizando as técnicas de modelagem ARIMA (modelos auto-regressivos integrados de médias móveis). A base de dados foi adquirida no Instituto de Pesquisa Econômica Aplicada (IPEA) e compreende dados mensais da quantidade de pontos na hora do fechamento do Índice Dow Jones da bolsa de Valores de Nova York. Os dados mensais compreendem o período de janeiro de 1980 a dezembro de 2006. Os resultados mostraram que a série apresenta uma dependência da sazonalidade em relação à tendência. Além disso, o tipo de tendência encontrado na série é do tipo crescente e evolui no decorrer do tempo. Outra característica interessante é que apenas com uma diferença a série já se torna estacionária e não correlacionada. Dessa forma ajustaram-se dois modelos à série. O primeiro modelo considerou apenas o efeito da tendência como componente principal, descartando a existência de outros fatores, como, por exemplo, possíveis intervenções externas. Já, o segundo modelo procurou identificar possíveis intervenções de forma a melhorar o ajustamento.

PALAVRAS-CHAVE: economia, modelagem, séries temporais.

ANALYSIS OF THE BEHAVIOR OF THE DOW JONES INDEX

ABSTRACT

The present work aims to analyze the behavior of the series of the Dow Jones in monthly amounts of points at close, using ARIMA modeling techniques. The database was obtained through the site www.ipea.com.br and understands the amount of monthly data points in the closing hours of the Dow Jones Stock Exchange in New York. The monthly data cover the period from January 1980 to December 2006. The results showed that the series presents a dependence of seasonality for the trend and has an increasing trend. Another interesting feature is that only with a difference since the series becomes stationary and uncorrelated. Thus set up two models to the series. The first model considered only the effect of the trend and magnitude so that did not take into account other factors such as potential interventions. The second model attempts to identify possible interventions to improve the adjustment.

KEYWORDS: economic, modeling, time series.

1. INTRODUÇÃO

As séries temporais referem-se a conjuntos de dados ordenados no tempo, sendo que estes podem ser relacionados à economia, em geral, por essa série. Dessa forma, modelos de análise de séries temporais são eventualmente utilizados para o estudo de dados dessa natureza. A característica mais importante deste tipo de dados é que as observações vizinhas são dependentes. Dessa forma, analisar e ajustar um modelo matemático que explique essa relação de dependência é o principal objetivo do estudo das séries temporais. Enquanto em modelos de regressão, por exemplo, a ordem das observações é irrelevante para a análise em séries temporais a ordem dos dados é crucial.

Dentre os objetivos das análises de séries temporais destacam-se: a investigação do mecanismo gerador da série; a realização de previsões de valores futuros de curto e longo prazos; e a descrição do comportamento da série, com verificação gráfica de existências de tendências, ciclo e variações sazonais, busca de periodicidade nos dados (MORETTIN & TOLOI, 1987).

Uma das áreas que mais se utilizam das técnicas de séries temporais é a área de mercado de capitais. Entender o comportamento das séries de ações e dos índices que compõem o mercado é uma importante ferramenta a ser utilizada como forma de escolher melhores investimentos. Dentre os índices existentes, o Dow Jones se destaca devido a sua capacidade de influenciar economias de todo o mundo.

O índice é um dos indicadores de maior confiabilidade mundial e tornou-se, desde sua criação, uma referência importante para investidores e administradores de recursos estrangeiros, que se baseiam em sua performance para tomar decisões de investimentos. Dessa forma, as técnicas de séries temporais são um importante caminho para tentar entender e prever o comportamento da série (ADRIÃO, 2009).

Há diferentes métodos paramétricos para estimar a variância dos retornos com o objetivo de se substituir a hipótese de que esta seja constante ao longo do tempo. Têm-se, por exemplo, os modelos de volatilidade determinística que utilizam da informação de preços passados para atualizar seu valor para o ativo corrente, pode-se citar os modelos da família ARCH (*Autoregressive Conditional Heteroscedasticity*).

Conforme mostram Poon e Granger (2003), em pesquisa realizada em 93 artigos e “*working papers*” publicados no período de 1976 a 2002, a diversidade de resultados ainda não permite que se firme um consenso sobre a capacidade preditiva dos diversos modelos de predição de volatilidade, configurando-se um amplo campo para pesquisas e debates.

Dessa forma, este estudo busca elucidar a seguinte questão e pesquisa: como se dá o comportamento da série de preços do Índice Dow Jones e quais as vantagens podem ser adquiridas através do estudo desse comportamento?

Neste contexto, o presente trabalho tem como objetivo analisar o comportamento da série do índice Dow Jones em quantidades de pontos mensais no fechamento do pregão, utilizando as técnicas de modelagem ARIMA.

2. REFERENCIAL TEÓRICO

Com o advento da informática e das técnicas de programação houve um crescente interesse e maior facilidade para desenvolver novos modelos que

pudessem explicar de forma mais confiável o comportamento das séries financeiras, principalmente no que se refere a volatilidade ou variância condicional.

Dessa forma vários trabalhos empíricos foram feitos utilizando séries financeiras brasileiras com o objetivo de verificar o comportamento dos retornos e comprovar a existência de fatos estilizados como assimetria e curtose, dentre outros.

Duarte et al. (1996) analisam a volatilidade das ações da Light ON, Telebrás PN e Vale do Rio Doce PN; Ziegelmann e Pereira (1997) utilizam modelos de volatilidade estocástica com e sem deformação temporal para estimarem a volatilidade dos retornos do Índice Bovespa (IBOVESPA); Herencia (1997) utiliza a série de retornos da Telebrás PN para comparar a volatilidade estocástica e a volatilidade dos modelos ARCH; Galvão et al. (2000) estudam a evidência da volatilidade e da causalidade do mercado à vista e futuro do índice de ações no Brasil; Silva et al. (2005) realizam uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH para os casos do café e da soja; Goulart et al. (2005) prevêm a volatilidade no mercado interbancário de câmbio; Morais e Portugal (1999) fazem a modelagem e a previsão da volatilidade determinística e estocástica para a série do Ibovespa.

2.1 Índice Dow Jones

O índice Dow Jones foi introduzido em 1884 pelos norte-americanos Charles Henry Dow, precursor da análise de ações, juntamente com seu sócio Eduard Jones — primeiros editores do *The Wall Street Journal*. A idéia era formar uma empresa que divulgasse cotações de ações e notícias econômicas do mercado de Nova York. Nascia a *Dow Jones & Company*. De início, eles acompanharam onze companhias, sendo nove delas construtoras de estrada de ferro (VIANA, 2009 e LOPES, 2006).

Hoje, o índice é utilizado para acompanhar a evolução dos negócios na New York Stock Exchange (NYSE), a Bolsa de Valores de Nova Iorque. O Cálculo feito a partir de uma média das cotações entre as 30 empresas de maior importância na bolsa de valores, as 20 companhias ferroviárias mais destacadas e as 15 maiores empresas concessionárias de serviços públicos. A maior e mais importante bolsa de valores do mundo, também conhecida como Big Board, é composta por um conselho de 20 membros que acompanham e regulam as atividades comerciais de mais de 3000 empresas norte-americanas e estrangeiras (VIANA, 2009 e LOPES, 2006).

2.2 Modelos ARIMA

Os modelos auto-regressivos foram desenvolvidos por Yule em 1926, enquanto que os modelos de médias móveis foram desenvolvidos por volta de 1937. Em 1970 Box & Jenkins desenvolveram uma metodologia para modelos de previsão que é largamente utilizada. Essa metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA, a um conjunto de dados.

2.2.1 Modelo auto-regressivo (AR)

Sejam $\bar{Z}_t = Z_t - \mu$ os desvios em relação a μ . Então,

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + \phi_2 \bar{Z}_{t-2} + \dots + \phi_p \bar{Z}_{t-p} + a_t$$

É um processo auto-regressivo de ordem p, denotado por AR(p) (MORETTIN & TOLOI, 2004). Em outras palavras, a série é representada por uma soma ponderada de p observações anteriores da série mais um termo aleatório. Definindo-se o operador auto-regressivo de ordem p por:

$$\phi(B) = 1 - \phi_1 B - \dots - \phi_p B^p$$

em que $B^p Z_t = Z_{t-p}$ é o operador de retardo.

pode-se escrever,

$$\phi(B)\bar{Z}_t = a_t;$$

em que:

a_t é resíduo (ou ruído);

\bar{Z}_t é a série de dados

$\phi(B)$ é o operador auto-regressivo

2.2.2 Modelo de médias móveis

Um processo,

$$\bar{Z} = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}$$

em que a série é vista como uma soma ponderada de q observações anteriores do ruído é chamado processo de médias móveis de ordem q, denotado por MA(q). Definindo-se o operador de médias móveis e ordem q por:

$$\theta(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q$$

pode-se escrever

$$\bar{Z}_t = \theta(B)a_t$$

em que:

a_t é resíduo (ou ruído);

\bar{Z}_t é a série de dados

$\theta(B)$ é o operador de médias móveis

2.2.3 Modelo misto auto-regressivo e de médias móveis (ARMA)

É o modelo que inclui tanto termos auto-regressivos como termos de médias móveis, sendo denotado por ARMA (p,q):

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + \dots + \phi_p \bar{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q}$$

Ou

$$\phi(B)\bar{Z}_t = \theta(B)a_t.$$

em que:

a_t é resíduo (ou ruído);

\bar{Z}_t é a série de dados

$\theta(B)$ é o operador de médias móveis
 $\phi(B)$ é o operador auto-regressivo

2.2.4 Modelos auto-regressivos integrados de médias móveis (ARIMA)

Se $W_t = \Delta^d Z_t$ for estacionária, podemos representar W_t por um modelo ARMA (p,q), ou seja,

$$\phi(B)\bar{Z}_t = \theta(B)a_t$$

Se W_t for uma diferença de Z_t , então Z_t é uma integral de W_t , daí dizermos que Z_t segue um modelo auto-regressivo, integrado, de médias móveis, ou modelo ARIMA,

$$\phi(B)\Delta^d \bar{Z}_t = \theta(B)a_t$$

de ordem (p,d,q).

2.2.5 Modelos com intervenção

Por uma intervenção entendemos a ocorrência de algum tipo de evento em dado instante de tempo T, conhecido a priori. Tal ocorrência pode manifestar-se por um intervalo de tempo subsequente e que afeta temporariamente, ou permanentemente, a série em estudo (Morettin e Toloi, 2004). A análise de intervenção tem por objetivo avaliar o impacto de tal evento no comportamento da série. Uma classe geral de modelos, que leva em conta a ocorrência de múltiplas intervenções, é dada por:

$$Z_t = \sum_{j=1}^k v_j(B)X_{j,t} + N_t$$

em que:

\bar{Z}_t é a série de dados

$v_j(B)$ é a função de intervenção de para X valores da série

N_t é a variável temporal.

Em que, $v_i(B)$ é da função de transferência da forma:

$$v_i(B) = \begin{cases} \frac{\omega(i)}{1 - \delta_i B} & (1) \\ \text{ou} & \\ \omega(i) & (2) \end{cases}, \quad \text{em que } |\delta_i| < 1;$$

δ_i é o efeito de intervenção até atingir um novo nível na série temporal. $\omega(i)$ é a localização da intervenção na série de dados. A função de transferência, $v_i(B)$, do

tipo (1) é considerada uma intervenção gradual permanente e a do tipo (2) igual a uma intervenção abrupta permanente.

3. METODOLOGIA

O presente trabalho adotou o estudo de caso como metodologia básica. De acordo com Patton (1990), Sampieri et al. (1991) e Santos (1991), o estudo de caso pode proporcionar um retrato válido sobre o programa, boa base para as pessoas entenderem o que está acontecendo, bem como bases sólidas para entender o desenrolar das ações programadas.

Quanto à concepção metodológica utilizou-se um estudo quantitativo visto que o mesmo permite analisar, por meio de um conjunto limitado de questões, as relações de um grupo relativamente grande de informações, facilitando a comparação e o tratamento estatístico dos dados. Hair Jr (2005) ressalta que esses estudos supõem que as medidas sejam, além de precisas e confiáveis, construídas a partir de modelos que permitam demonstrar relações de causalidade, sendo por isso mesmo construídos com base na lógica das explicações científicas, isto é, através de requerimentos de verificação lógica como, por exemplo, a consistência entre as proposições que integram o modelo explicativo e de verificação empírica como a correspondência das proposições do modelo com a realidade empírica.

3.1 Coleta e análise dos dados

A base de dados foi adquirida através do site www.ipea.gov.br e compreende dados mensais da quantidade de pontos na hora do fechamento do índice Dow Jones da bolsa de Valores de Nova York. Os dados mensais compreendem o período de janeiro de 1980 a dezembro de 2006.

A primeira parte do processo de análise consiste em estudar o gráfico da série original e verificar possíveis componentes. Também se utiliza do gráfico da função de autocorrelação e função de autocorrelação parcial.

A segunda etapa inicia o processo de identificação das componentes. É nesta etapa que:

- Verifica-se a existência da necessidade de transformação logarítmica através do gráfico da média versus o do desvio padrão.
- Verifica-se a existência de tendência na série. Um teste simples e prático que comprova esta existência é o teste do sinal de Cox-Stuart. Para maiores informações sobre o teste ver Morretin & Tolo (2004).
- Observa-se a existência de sazonalidade significativa. Neste caso, uma importante ferramenta de análise é a decomposição espectral das séries em série de Fourier. Nesta análise, é como se colocasse a série em um prisma com a finalidade de identificar o tamanho das ondas e a importância dos componentes cíclicos. Dessa forma, flutuações sazonais de diferentes comprimentos podem ser identificadas e testadas (JENKINS & WATTS, 1968; PRIESTLEY, 1981; SHURNWAY, 1988 e, WEI, 1989). Um teste bastante utilizado é o teste G de Fisher. De acordo com o teste se o valor de G que é calculado através do periodograma for maior do que o valor de Z então a série apresenta periodicidade. A estatística do teste pode ser descrita da forma:

$$g = \frac{\max I_j^{(N)}}{\sum_{j=1}^{\lfloor \frac{N}{2} \rfloor} I_j^{(N)}} \quad z = 1 - n^{-1} \sqrt{\frac{\alpha}{n}}$$

em que,

I = maior valor do periodograma,

N = tamanho da série dividido por 2,

α = nível de significância de 95%.

Após a identificação e a eliminação destes efeitos inicia-se a identificação e estimação dos parâmetros ARMA. Isto é feito utilizando-se do gráfico da função de autocorrelação – FAC – e do gráfico da função de autocorrelação parcial – FACP –. Enquanto que o primeiro mostra a ordem do MA o segundo mostra a ordem do AR.

Em seguida, verifica-se se o modelo escolhido deixou os resíduos da série estacionários e não correlacionados, ou seja, com um ruído branco. Isso é feito ao se observar o gráfico da função de autocorrelação dos resíduos e confirmado pelo teste de Box & Pierce. O teste consiste em comparar o valor da estatística χ^2 com o valor de Q . Se o valor de Q for menor do que o valor de χ^2 então a hipótese de ruído branco para os resíduos é aceita. A estatística de Q pode ser definida da seguinte forma:

$$Q(K) = n(n+2) \sum_{j=1}^k \frac{\hat{r}_j^2}{(n-j)}$$

Por fim, para verificar qual modelo é o melhor utiliza-se do Critério de Informação de Akaike – AIC – e do Critério de Informação Bayesiano – BIC –. O AIC e o BIC são dados pelas estatísticas:

$$AIC(k, l) = \ln(\sigma_{k,l}^2) + 2(k+l)/n$$

$$BIC(k, l) = \ln(\sigma_{k,l}^2) + (k+l) \ln(n)/n$$

em que,

K e L = parâmetros do modelo,

$\ln(\sigma_{k,l}^2)$ = logarítmico da variância

4. RESULTADOS e DISCUSSÃO

A série corresponde à quantidade de pontos mensais no horário de fechamento da bolsa americana Dow Jones abrangendo o período de janeiro de 1980 a dezembro de 2006. Conforme pode ser observado pela Figura 1, a série apresenta um crescimento exponencial até por volta da observação 240. A partir daí, inicia uma queda que perdura por um longo período de cinco anos. Somente depois da observação 270 a série começa novamente sua tendência de alta.




FIGURA1 – Série Histórica de pontos de fechamento da Dow Jones no período de 1980 a 2006.

Fonte: Resultado da pesquisa.

A partir da descrição da série começou a identificação das variáveis que podem estar presentes na série como, tendência e sazonalidade e também a necessidade de transformação logarítmica.

De acordo com a Figura 2 – média versus o desvio padrão – nota-se que a reta possui inclinação diferente de zero em relação ao eixo das abscissas, indicando uma dependência da sazonalidade sobre a tendência e confirmando a adequabilidade de um modelo multiplicativo. Por isso, a série sofreu transformação logarítmica.

Já a Figura 3 mostra a função de autocorrelação da série original. Através dela é possível supor que a série possui tendência visto que os valores dos lags decaem à zero lentamente. Além disso, a presença de tendência está quando se observa a Figura 1. Contudo, para comprová-la foi feito o teste do sinal introduzido por Cox-Stuart. O resultado do teste veio confirmar o que era evidente, a série possui tendência crescente. Então, fez-se a primeira diferença da série a fim de eliminar este efeito, conforme demonstrado pelo Figura 4.

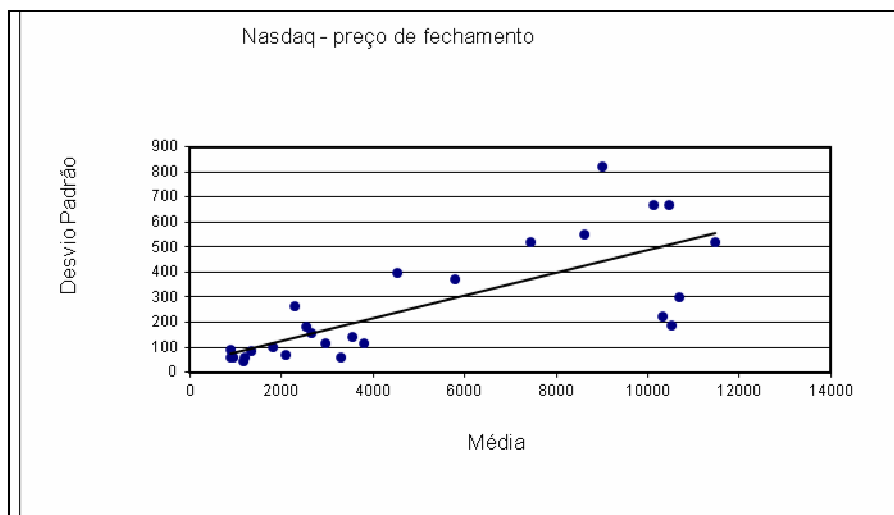


FIGURA 2 – Desvio Padrão vs Média anual

Fonte: Resultado da pesquisa.

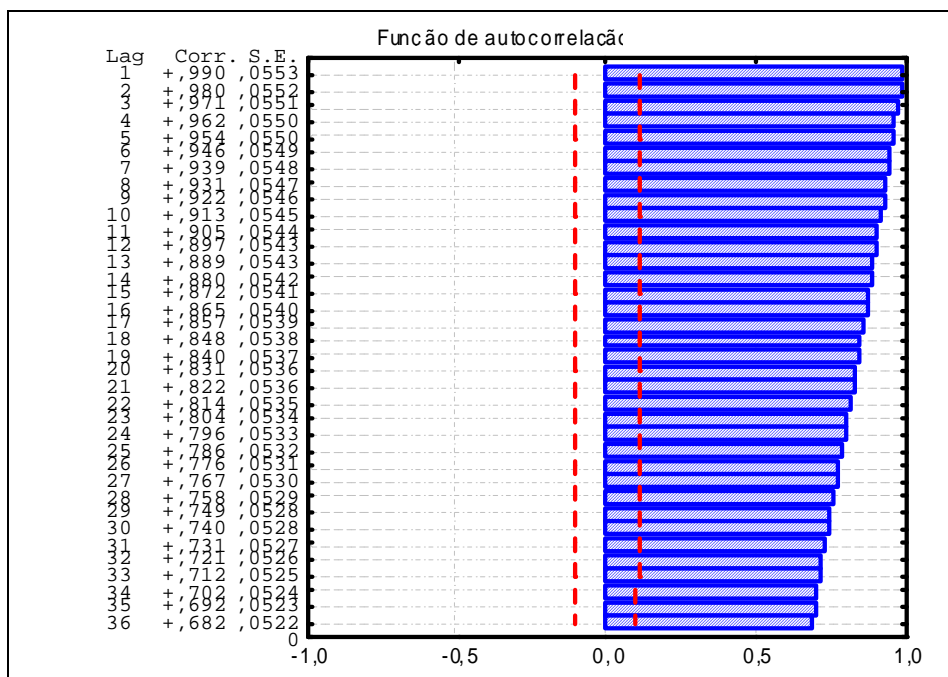


FIGURA 3 – Função de autocorrelação da série original.

Fonte: Resultado da pesquisa.




FIGURA 4 – 1º Diferença da série logaritmizada

Fonte: Resultado da pesquisa.

O gráfico da primeira diferença da série logaritmizada está demonstrado pela Figura 5. Ao observá-lo, nota-se que após a diferença a série tornou-se estacionária, ou seja, está se desenvolvendo no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável. Por este gráfico ainda é possível notar alguns fundos que podem representar alguma forma de intervenção externa. Mais adiante sua significância será estudada.

A última componente a ser identificada foi a presença de sazonalidade na série. De acordo com o teste de Fischer o valor de G calculado foi menor do que o valor de Z e, dessa forma aceita-se H_0 , ou seja, a série não apresenta sazonalidade.

Em seguida, buscou-se identificar a necessidade de um modelo ARMA para ajustar à série. As ordens do modelo AR e do MA são verificadas, respectivamente, pelo gráfico da função de autocorrelação parcial – FACP – e pelo gráfico da função de autocorrelação – FAC –. O gráfico da FAC e da FACP estão representados, respectivamente, pela Figura 5 e 6 abaixo.

Ao observar o gráfico da FAC, Figura 5, nota-se que não há nenhum lag com valor fora do intervalo de confiança. O mesmo comportamento é observado no gráfico da FACP, Figura 6. Sendo assim, os dois gráficos não sugerem nenhuma ordem para AR e para MA, ou seja, apenas a diferença foi suficiente para que a série se tornasse não correlacionada, comumente chamada de ruído branco. Para confirmar esta hipótese fez-se o teste de Box & Pierce. O resultado do teste confirmou a característica de ruído branco ao apresentar um valor de 51,00 para o χ^2 , ou seja, maior do que o valor de Q_{36} (28,60), observado no gráfico da FAC.

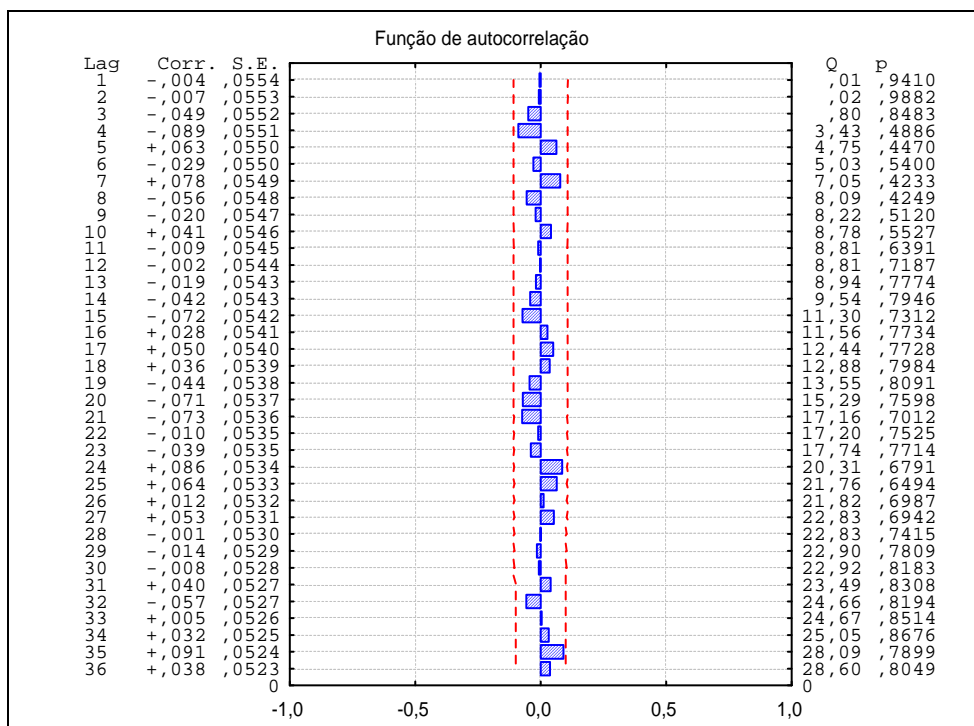


FIGURA 5 – Função de autocorrelação da série diferenciada e logaritimizada.

Fonte: Resultado da pesquisa.

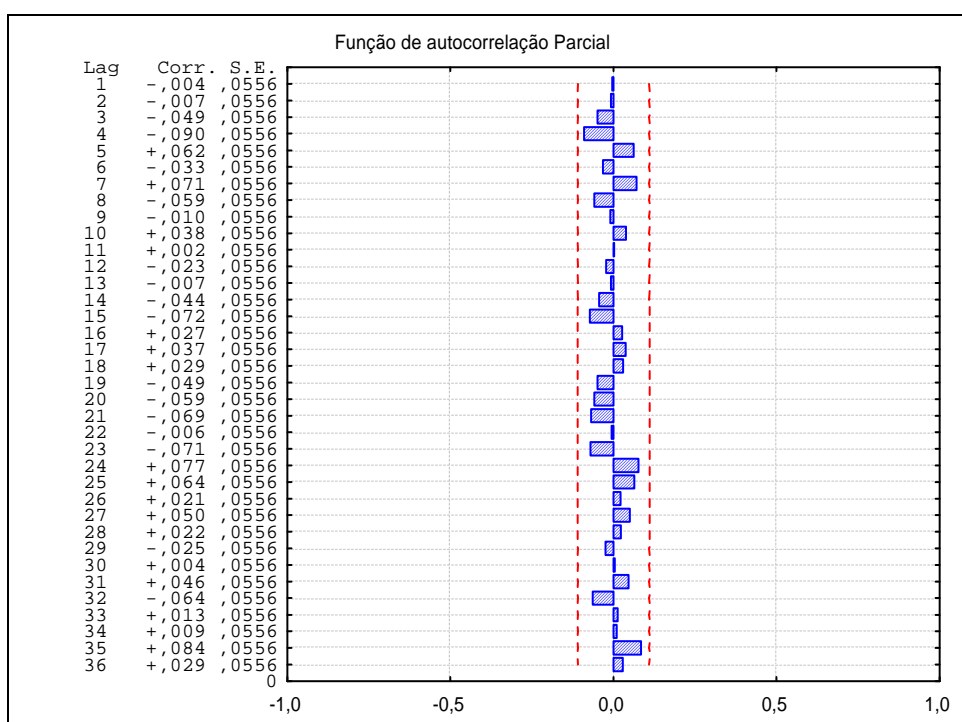


FIGURA 6 – Função de autocorrelação Parcial da série diferenciada e logaritimizada.

Fonte: Resultado da pesquisa.

Apesar de ter apresentado um ruído branco apenas com uma diferença optou-se por ajustar um segundo modelo à série, mas agora levando-se em conta as possíveis presenças de intervenções, conforme observado pela Figura 4.

Dessa forma, testou-se na série logaritmizada e diferenciada se os 5 maiores fundos visualizados pela Figura 4 eram significativos ou não. Contudo, para testá-los no *software* utilizado neste trabalho é necessário colocar no mínimo uma ordem para um AR ou para um MA, caso contrário a análise da presença de intervenções não se conclui. Sendo assim, adicionou um AR(1) ao modelo mesmo não sendo necessário. Retomando a análise, dos 5 cinco fundos verificados, 2 foram significativos. O primeiro representa a observação 92, data de novembro de 1987, data em que a bolsa sofreu uma queda acentuada devido a uma crise interna que assustou os americanos. Nesta época a bolsa chegou a cair impressionantes 22% em apenas um dia. O segundo representa a observação 272, data de novembro de 2002 em que a bolsa começou a reverter a tendência de queda na qual estava e iniciou um período de grandes altas, provavelmente causado pelo fim do impacto negativo da crise de 2001 em que a “bolha” da informática estourou e influenciou negativamente todas as economias do planeta.

O modelo escolhido foi então um ARIMA(1,1,0) com 2 intervenções. Um resumo das características desse modelo bem como a significância dos parâmetros podem ser conferidas pelo Quadro 1. Nota-se que o parâmetro referente ao AR(1) é não significativo, contudo a inclusão deste parâmetro no modelo é necessária visto a impossibilidade de se ajustar um modelo com intervenção sem ele.

Quadro 1 – Resumo das informações do modelo.

```
Variable: NASDAQ
Transformations: ln(x),D(1)
Model: (1,1,0) Interventions: 2
No. of obs.: 323 Initial SS= ,63743 Final SS= ,61259(96,10%) MS= ,00193
Parameters (p/Ps-Autoregressive, q/Qs-Moving aver.); highlight: p<.05
p(1) Om(1) Del(1) Om(2) Del(2)
Estimate: ,02152 ,08627 ,52623 ,06402 -,4149
Std.Err.: ,05899 ,04006 ,18234 ,02568 ,18826
```

Em seguida, fez-se o gráfico da função de autocorrelação dos resíduos para o segundo modelo, conforme pode ser observado pela Figura 7. De acordo com o gráfico todos os valores dos lags estão dentro do intervalo de confiança e, além disso, o teste de Box & Pierce comprova a não correlação entre os lags ao apresentar o valor de 47,40 para o χ^2 contra o valor de Q_{36} a 26,92.




FIGURA 7 – Função de autocorrelação dos resíduos.

Fonte: Resultado da pesquisa.

Por fim, comparou-se os dois modelos para determinar qual deles apresentou melhor ajustamento. Para isto utilizou-se do Critério de Informação de Akaike (AIC) e do critério de Informação Bayesiano (BIC). De acordo com os critérios aquele que apresentar menor valor é o melhor modelo. Sendo assim, o melhor modelo foi o modelo 1 sem intervenção e apenas com a 1^o diferença, conforme pode ser observado por asteriscos na Tabela 1. Isso pode ser explicado porque para calcular o modelo 2 foi necessário colocar um parâmetro que não era significativo.

TABELA 1 – Comparativo entre os modelos

	AIC	BIC
Modelo 1 s/ intervenção	-6,2471*	-6,2471*
Modelo 2 c/ intervenção	-6,2317	-6,1967

Nota: * representa o melhor modelo

Diante dos resultados expostos acima se recomenda que o modelo 1, sem intervenção, seja utilizado para possíveis investimentos que sejam indexados pelo índice Dow Jones. Isso é relevante porque além de estimar o ajuste de um modelo matemático à série do Índice Dow Jones, mostra seu comportamento ao longo dos anos, evidenciando fundos e topos profundos que podem influenciar positivamente ou negativamente o mercado. Além disso, o modelo matemático proveniente deste ajustamento pode ser utilizado para realização de previsões futuras do comportamento da série.

Mais importante do que uma previsão totalmente certa do comportamento da série do índice Dow Jones, já que todo modelo matemático apresenta erros percentuais em suas previsões, é o fato deste modelo mostrar uma tendência futura que pode ser de alta ou baixa, contribuindo assim, para diminuir o risco do investidor nesse mercado.

5. CONCLUSÃO

Com o presente trabalho pode-se entender melhor o comportamento da série histórica mensal de pontos da bolsa de valores de Nova York, a Dow Jones. Além disso, foi uma oportunidade para aplicar as técnicas de séries temporais.

De acordo com os resultados constatou-se que a série apresenta uma dependência da sazonalidade em relação à tendência, sendo que a tendência observada pode ser classificada como crescente. Outra característica interessante é que apenas com uma diferença a série já se torna estacionária e não correlacionada.

Dessa forma ajustou-se dois modelos à série. O primeiro modelo considerou apenas o efeito da tendência e não levou em conta outros fatores como, por exemplo, possíveis intervenções. O segundo modelo procurou identificar possíveis intervenções de forma a melhorar o ajustamento. Para o segundo modelo, duas intervenções foram significativas: uma na data de novembro de 1987 e a outra na data de novembro de 2002. Essas duas intervenções causaram impactos distintos na série. Enquanto que a primeira fez com que o Índice Dow Jones caísse, a segunda fez com que o Índice se recuperasse e começasse a subir. Conforme já descrito no trabalho, para o segundo modelo o melhor ajustamento foi um ARIMA (1,1,0) com duas intervenções, mesmo o parâmetro AR(1) não sendo significativo.

Em seguida, comparou-se a qualidade de ajustamento dos dois modelos a fim de detectar o que melhor explicasse as características da série em estudo. Através do Critério de Informação de Akaike e do Critério de Informação Bayesiano concluiu-se que o melhor modelo é o modelo 1 sem intervenções. Isso pode ser explicado, pois para o modelo 2 foi necessário incluir um parâmetro AR(1) que não era significativo para que o *software* pudesse “rodar” a informação com intervenções.

Para possíveis trabalhos futuros fica a ideia de se ajustar modelos não lineares da classe ARCH à volatilidade da série, já que séries financeiras são mais complexas.

REFERENCIAS

ADRIÃO, M. C. **Um estudo de caso de previsão de tendência em uma série temporal financeira utilizando análise técnica**. 2009. 59 f. Dissertação (Mestre em Ciências e engenharia Civil) Instituto Alberto Luiz Coimbra de Pós-Graduação e Pesquisa em Engenharia (COPPE) da Universidade Federal do Rio de Janeiro (UFRJ).

BOX, G. E. P., JENKINS, G. M. **Time series analysis**. San Francisco: Holden Day. 1970.

DUARTE J. A. M.; PINHEIRO M. A.; HEIL, T. B. B. Estimação da Volatilidade de Ativos e Índices Brasileiros. **Resenha BM&F**, n. 111, p. 16-28, 1996.

GALVÃO, A. B. C.; PORTUGAL, M. S.; RIBEIRO, E. P. Volatilidade e Causalidade: evidências para o mercado à vista e futuro de índice de ações no Brasil. **Revista Brasileira de Econometria**, v. 54, n. 1, p. 37-56, 2000.

GOULART, P. C.; AMARAL, F. H.; BERTUCCI, A. L.; BRESSAN, A. A. Previsão da Volatilidade no Mercado Interbancário de Câmbio. **Revista de Administração e Economia**. Edição Especial Minas Gerais. v. 45, p. 86-101, 2005.

HAIR JR.; J. F.; BABIN, B.; MONEY, A. H.; SAMOUEL, P. **Fundamentos de métodos de pesquisa em administração**. Porto Alegre: Bookman, 2005.

HERENCIA, M. E. Z. **Volatilidade nos Modelos ARCH e Variância Estocástica: um estudo comparativo**. 244 f. Dissertação. (Mestrado em Estatística) – Universidade Estadual de Campinas, Unicamp, 1997.

IPEA – Instituição de Pesquisa Econômica Aplicada. Disponível em: <www.ipea.gov.br>. Acessado em: out. 2009.

JENKINS, G. M.; WATTS, D. G. **Spectral analysis and its applications**. San Francisco: Holden-Day, 1968.

LOPES, D. C. **Análise quantitativa da volatilidade entre os índices Dow Jones, Ibovespa e S&P500**. 2006. 135 f. Dissertação (Mestre em Economia) Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da Universidade Federal do Rio Grande do Sul.

MORAIS, I. A. C. de; PORTUGAL, M. S. Modelagem e Previsão de Volatilidade Determinística e Estocástica para a Série do Ibovespa. **Estudos Econômicos**, v. 29, n. 3, p. 303-341, 1999.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher. 2004. 535p.

MORETTIN, P. A.; TOLOI, C. M. C. **Modelos para previsão de séries temporais**, v.1 e 2, Rio de Janeiro, IMPA/CNPq, 1987.

PATTON, M. Q. **Qualitative evaluation and research methods**. Londres: Sage, 1990. 338p.

POON, S.; GRANGER, C. W. J. Forecasting Volatility in Financial Markets: a review. **Journal of Economic Literature**, v. 41, n. 2, p. 478-539, 2003.

PRIESTLEY, M. B. **Spectral analysis and time series**. Academic Press Inc, London, England, 1981. 890p

SAMPIERI, R. H.; COLLADO, C. F.; LUCIO, P. B. **Metodología de la investigación**. México: McGraw-Hill, 1991. 896 p.

SANTOS, J. V. T. A construção da viagem inversa. Ensaio sobre a investigação nas ciências sociais. **Cadernos de Sociologia**. Porto Alegre: v. 3, n. 3, p. 55-88, janeiro/julho 1991.

SHUMWAY, R. H. **Applied statistical time series analysis**. Englewood Cliffs, NJ: Prentice Hall, 1988.

SILVA, W. S. **Modelagem da Volatilidade dos Índices Financeiros IBOVESPA, Dow Jones e Standard & Poors Utilizando Modelos da Classe ARCH**. 91 f.

Dissertação (Mestrado em Estatística) – Universidade Federal de Lavras, UFLA, 2003.

ZIEGELMANN, F. A.; PEREIRA, P. L. V. Modelos de Volatilidade Estocástica com Deformação Temporal: um estudo empírico para o índice Ibovespa. **Política e Planejamento Econômico**, v. 27, n. 2, p. 353-376, 1997.

VIANA, O. **História da Análise Técnica**. Think Finance, 2008. Disponível em <http://www.monitorinvestimentos.com.br/aprendizado.php?id_aprendizado=67>. Acesso em: nov. 2009.

WEI, W.W. **Time series analysis: Univariate and multivariate methods**. New York: Addison-Wesley, 1989.