

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO
MESTRADO ACADÊMICO
DISSERTAÇÃO DE MESTRADO

**Modelagem Paramétrica e não Paramétrica no Mercado
Acionário Brasileiro: Uma Investigação do Desempenho de
Modelos ARIMA&GARCH e do Algoritmo NN em
Estratégias de Negociação.**

Marcelo Scherer Perlin

Orientador: Prof. Dr. Gilberto de Oliveira Kloeckner.

Porto Alegre, Fevereiro de 2007

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
PROGRAMA DE PÓS-GRADUAÇÃO EM ADMINISTRAÇÃO
MESTRADO ACADÊMICO
DISSERTAÇÃO DE MESTRADO

**Modelagem Paramétrica e não Paramétrica no Mercado
Acionário Brasileiro: Uma Investigação do Desempenho de
Modelos ARIMA&GARCH e do Algoritmo NN em
Estratégias de Negociação.**

Dissertação de Mestrado,
apresentada ao Programa de
Pós-Graduação em
Administração da
Universidade Federal do Rio
Grande do Sul como requisito
parcial para a obtenção do
título de Mestre em
Administração.

Marcelo Scherer Perlin

Orientador: Prof. Dr. Gilberto de Oliveira Kloeckner.

Porto Alegre, Fevereiro de 2007

Agradecimentos

Primeiramente agradeço ao suporte financeiro do CNPQ (Conselho Nacional de Desenvolvimento Científico e Tecnológico), o qual foi de profunda importância para a conclusão do curso de mestrado.

Gostaria de agradecer ao orientador do trabalho, Prof. Dr. Gilberto de Oliveira Kloeckner, por sempre se mostrar disponível quando solicitado e, juntamente com o Prof. Dr. Newton Carneiro Affonso da Costa Junior, pelo suporte no meu ingresso no programa de doutorado da ICMA/UK. Também estou fortemente agradecido pela liberdade oferecida na orientação do mestrado, onde foi possível que eu perseguisse meus próprios interesses acadêmicos. Possivelmente, sem tal liberdade, o estudo preliminar que motivou o desenvolvimento da respectiva pesquisa jamais teria existido.

Agradeço também ao orientador de minhas primeiras pesquisas, Prof. Dr. Paulo Sérgio Ceretta, com o qual escrevi diversos trabalhos ao longo dos anos e foi o tutor nos meus primeiros passos em pesquisa acadêmica.

Agradeço aos bons momentos passados junto aos colegas de curso: Pietro, Rafael, Daniel, Odécio, Christian, Paola, entre outros.

Em relação a minha família, agradeço ao meu pai, Tarcisio Antonio Perlin, e minha mãe, Helga Heliani Scherer Perlin, pelo suporte emocional ao longo do curso e pelo suporte financeiro aos congressos que participei. Agradeço também ao meu irmão, Ricardo Scherer Perlin, pelo compartilhado entretenimento nos ganhos e perdas obtidos junto ao mercado de capitais brasileiro. Ao meu outro irmão, Tarcizio Scherer Perlin, também agradeço a companhia presente nesses surpreendentemente agradáveis 12 meses que moramos juntos.

Todos os citados acima contribuíram de uma forma ou outra para a conclusão desse trabalho, o qual certamente constitui uma fase importante da minha vida.

SUMÁRIO

INTRODUÇÃO	9
1 REFERENCIAL TEÓRICO	11
1.1 A HIPÓTESE DE CAMINHO ALEATÓRIO	11
1.1.1 TESTANDO A HIPÓTESE DE CAMINHO ALEATÓRIO	14
1.2 MODELOS MATEMÁTICOS UTILIZADOS NA PESQUISA	18
1.2.1 MODELOS ARIMA (AUTOREGRESSIVE INTEGRATED MOVING AVERAGE)	18
1.2.2 EQUACIONANDO AS VARIÂNCIAS NO TEMPO T – MODELOS DA FAMÍLIA ARCH	19
1.2.3 O ALGORITMO DE PREVISÃO NEAREST NEIGHBOR	24
2. MÉTODO DA PESQUISA	28
2.1 BASE DE DADOS	28
2.2 ESTRATÉGIAS DE NEGOCIAÇÃO	30
2.2.1 ESTRATÉGIA 1 (TIMING STRATEGY)	30
2.2.2 ESTRATÉGIA 2 (ARBITRAGE STRATEGY)	31
2.3 CÁLCULO E AVALIAÇÃO DOS RETORNOS DAS ESTRATÉGIAS	35
2.3.1 CÁLCULO DOS RETORNOS EXCESSIVOS	36
2.3.2 COMPARAÇÃO DO DESEMPENHO EM RELAÇÃO A INVESTIDORES ALEATÓRIOS	38
2.3.3 AVALIAÇÃO DOS RETORNOS CONSIDERANDO RISCO SISTEMÁTICO (ALPHA DE JENSEN)	41
3. RESULTADOS OBTIDOS	42
3.1 ESTRATÉGIA 1 (TIMING STRATEGY)	42
3.1.1 RESULTADOS PARA O ALGORITMO NN	42
3.1.2 RESULTADOS PARA OS MODELOS ARIMA & GARCH	44
3.2 ESTRATÉGIA 2 (ARBITRAGE STRATEGY)	47
3.2.1 RESULTADOS PARA O ALGORITMO NN	47
3.2.2 RESULTADOS PARA OS MODELOS ARIMA & GARCH	48
4. NOVOS CAMINHOS PARA A PESQUISA	53
COMENTÁRIOS FINAIS	54
BIBLIOGRAFIA	56

LISTA DE FIGURAS

<i>Figura 1 – Probabilidade X Escore Z de uma Distribuição Normal</i>	<i>34</i>
<i>Figura 2 – Histograma dos Retornos Obtidos em 5.000 Simulações com C=0.15%.....</i>	<i>40</i>
<i>Figura 3 – Retornos Acumulados para Estratégia 2.....</i>	<i>50</i>
<i>Figura 4 - Histograma dos Retornos obtidos com Estratégia 2/ARIMA&GARCH.....</i>	<i>52</i>

LISTA DE QUADROS

<i>Tabela 1 – Ativos Utilizados na Pesquisa</i>	<i>29</i>
<i>Tabela 2 – Resultados para Estratégia 1 com Algoritmo NN.....</i>	<i>43</i>
<i>Tabela 3 – Resultados para Estratégia 1 com Modelos ARIMA&GARCH</i>	<i>45</i>
<i>Tabela 4 – Resultados para Estratégia 2 com o Algoritmo NN.....</i>	<i>47</i>
<i>Tabela 5 – Resultados para Estratégia 2 com Modelos ARIMA&GARCH</i>	<i>49</i>

RESUMO

Para um administrador de carteira, a possibilidade de prever o comportamento dos ativos é algo desejável. A previsibilidade do mercado financeiro é objeto de pesquisa há inúmeras décadas. Tal hipótese de previsibilidade ou falta dela pode ser testada de diferentes maneiras, incluindo o uso direto de modelagem matemática para realizar as previsões. O principal objetivo do presente estudo é verificar a performance de dois diferentes métodos de previsão em estratégias de negociação para o mercado acionário brasileiro. A base de dados é constituída por retornos diários dos 40 ativos mais líquidos entre 2003 e 2005. O primeiro método pesquisado foi o uso do algoritmo de previsão NN (*Nearest Neighbor*) e o segundo corresponde aos populares modelos ARIMA&GARCH. A principal conclusão da pesquisa foi que os modelos ARIMA&GARCH, dentro da metodologia sugerida, obtiveram resultados superiores ao algoritmo NN e em relação a uma estratégia ingênua, resultado um respeitável desempenho nas estratégias de negociação, mais particularmente na estratégia de arbitragem. Tal resultado motiva o uso do método sugerido em aplicações reais no mercado financeiro Brasileiro, porém é importante salientar que a pesquisa foi baseada em algumas necessárias pressuposições, as quais podem afetar tal resultado em aplicações reais.

ABSTRACT

For a portfolio manager, the predictability of stock market behavior is a desirable characteristic for obvious reasons. The predictability of financial markets has been a research topic for a long time. Such type of study can be tested in different ways, including the use of mathematical formulations for time series forecasting. The main objective of the present study is to verify the performance of two different forecasting methods in trading strategies for the Brazilian financial market. The database for the research is based on the 40 most liquid assets with daily observations from 2003 to 2005. The first investigated method is the non parametric approach of NN (*Nearest Neighbor*) and the second one is the use of the popular ARIMA&GARCH models. The main conclusion of this study is that the use of ARIMA&GARCH models in the proposed methodology was able to beat the NN algorithm and the naïve approach, obtaining a respectable performance in the trading strategies, more specifically in the arbitrage strategy. Such result motivates the application of the proposed method to real trading environments in the Brazilian equity market, but it's important to say that this study was based in some key assumptions which may affect the result for real trading applications.

Introdução

O trabalho do gestor ativo de carteira, aquele que muda a composição do portfólio administrado em curtos períodos de tempo, se encontra na alocação de recursos. Dentre inúmeras alternativas de investimentos, o administrador deve investir seus recursos nos ativos os quais ele espera que proporcionarão o maior retorno, isto é, o gestor projeta os futuros rendimentos de uma determinada ação e, considerando a magnitude do possível erro de previsão (risco), o mesmo efetua a decisão de investimento. A afirmativa anterior corrobora a moderna teoria financeira, a qual foi fundada, principalmente, pelos trabalhos seminais de Markowitz (1952) e Sharpe (1964).

Dentre as bases citadas anteriormente, incluindo a derivação do modelo de precificação CAPM, um conceito intrinsecamente utilizado é o de eficiência fraca de mercado, Fama (1970). Tal conceito postula, de uma forma simplificada, que os preços do mercado são sempre justos, ou seja, não é possível uma estratégia de negociação baseada em dados históricos obter retornos excessivos positivos e persistentes ao longo do tempo.

Um diferente modo de analisar a afirmação anterior seria que as informações chegam ao mercado e são precificadas instantaneamente. Devido a pressuposição de que todas as informações passadas a respeito de um ativo estão disponíveis ao público, então, devido às forças de mercado, o preço hoje é o preço justo. Tal afirmativa implica a existência de expectativas homogêneas por parte dos investidores. Se todos possuem as mesmas informações e entendem-nas da mesma forma, então nunca será possível obter lucro excessivo positivo significativo e persistente com base em informações passadas dos ativos, isto é, o futuro fluxo de caixa da empresa em questão está corretamente avaliado pelo mercado.

Conforme foi visto, existe uma forte relação entre a forma de atuação dos gestores financeiros e a teoria de eficiência de mercado. Se a última é verdadeira, então nenhum gestor financeiro consegue obter lucros significativamente acima do lucro médio do mercado. Porém se for possível comprovar que existe a possibilidade de obter lucros positivos e excessivos com base no uso de informações passadas e públicas, tal como séries de preços históricos, então se verifica uma ineficiência no mercado de capitais. O problema de pesquisa vigente neste estudo é a presença de previsibilidade nos retornos dos ativos, ou seja, verificar se é possível atingir retornos excessivos e positivos com base em regras de negociação, as quais são criadas com base, apenas, nos preços históricos.

O objetivo dessa pesquisa é averiguar o desempenho de dois modelos matemáticos de previsão, mais especificamente ARIMA&GARCH e algoritmo NN, em duas diferentes estratégias de negociação para o mercado acionário brasileiro. Claramente, tal pesquisa pode ser vista como um teste de eficiência de mercado.

O trabalho está estruturado da seguinte forma: inicialmente é apresentada uma breve revisão da hipótese de caminho aleatório, as maneiras de testá-la e os principais estudos anteriores; em seguida é explanado o método utilizado, contemplando a base de dados, os detalhes dos modelos matemáticos, a descrição das estratégias testadas e as formas utilizadas para averiguar o desempenho das mesmas. Por fim, conclui-se o trabalho com a exposição de novos caminhos a serem perseguidos na pesquisa e também os comentários finais.

1 Referencial Teórico

Nos próximos tópicos serão apresentados os principais conceitos teóricos envolvidos na pesquisa em questão, incluindo, também, trabalhos anteriores que sejam relevantes para o tema.

1.1 A Hipótese de Caminho Aleatório

A hipótese de caminho aleatório é uma maneira de formalizar matematicamente o comportamento de uma série de preços, a qual resulta em importantes conseqüências para a teoria financeira em geral. Conforme será mostrado, tal formalização possui forte relação com a hipótese de eficiência de mercado, Fama (1964) e Fama (1970). A seguir apresenta-se uma definição mais formal.

Para desenvolver a parte quantitativa da hipótese de caminho aleatório, será feita uma generalização e, logo após, será realizada uma análise mais completa de uma das versões do caminho aleatório, *Random Walk I*, conforme definido em Campbell et al (1997).

Uma forma geral de formalizar a hipótese de caminho aleatório, agora referenciada como HCA, é definir que $Cov[f(R_t); g(R_{t+k})] = 0$, onde $f(\cdot)$ e $g(\cdot)$ representam funções genéricas para R_t e R_{t+k} , as quais demonstram que o retorno no tempo t não possui relação alguma com o retorno no futuro (R_{t+k}). O que a formalização anterior expressa, em termos leigos, é que o comportamento presente dos retornos é independente dos retornos passados, ou seja, pela teoria, tentar prever o retorno em $t+1$ com base em t , é um exercício sujeito ao fracasso, pois não importa a forma das funções $f(\cdot)$ e $g(\cdot)$, o presente não possui relação com o passado. Devido a isso, caso a HCA seja verdadeira, uma estratégia de negociação baseada em dados passados obteria apenas um retorno excessivo positivo dado pelo acaso.

Uma das versões mais simples e populares de modelo de caminho aleatório, agora referenciados como RW (*Random Walk*), é o RW1, apresentada na Equação [1.1].

$$\begin{aligned} P_t &= u + P_{t-1} + \varepsilon_t \\ \varepsilon_t &\sim IID(0, \sigma^2) \end{aligned} \quad [1.1]$$

Para a Equação [1.1], P_t é o preço do ativo no tempo t , u é o coeficiente chamado *drift* (tendência), isto é, o valor constante que o preço irá mudar após cada tempo t , o termo ε_t é o resíduo do modelo, tendo esperança matemática igual a zero ($E(\varepsilon_t) = 0$), variância constante igual a σ^2 e autocorrelação serial nula, $Cov(\varepsilon_t; \varepsilon_{t-j}) = 0$.

Com o fim de analisar as conseqüências no uso do modelo RW1, Equação [1.1], como modelo de comportamento de preços, serão verificados os momentos matemáticos do mesmo. Para a Equação [1.1], se for substituído P_{t-1} por $u + P_{t-2} + \varepsilon_{t-1}$ tem-se:

$$P_t = u + u + P_{t-2} + \varepsilon_{t-1} + \varepsilon_t \quad [1.2]$$

Para a equação anterior, substituindo P_{t-2} por $u + P_{t-3} + \varepsilon_{t-2}$ resulta em:

$$P_t = u + u + u + P_{t-3} + \varepsilon_{t-2} + \varepsilon_{t-1} + \varepsilon_t \quad [1.3]$$

Tal exercício já mostra que a cada “abertura” dos termos defasados de P_{t-j} , gera um u , um ε_{t-1} e um P_{t-j-1} , portanto, caso tal operação fosse realizada até chegar à primeira observação da série de preços (P_0) teria-se o resultado a seguir:

$$P_t = Tu + P_0 + \sum_{i=1}^T \varepsilon_i \quad [1.4]$$

Em [1.4], o símbolo T sinaliza o total de observações da série. Tirando-se a esperança matemática de [1.4] e lembrando que $E(\varepsilon_t) = 0$, tem-se como resultado a Equação [1.5], a qual representa o primeiro momento do modelo, isto é, sua expectativa matemática.

$$E(P_t) = Tu + P_0 \quad [1.5]$$

A Equação [1.5] mostra que a melhor previsão (esperança) do valor de P_t é dada por $Tu + P_0$, isto é, o número de observações até o valor previsto multiplicado pelo *drift* (u) e somado ao primeiro preço da série. Claramente, se os preços dos ativos seguirem [1.1], a informação passada em [1.5] não serve de nada para a construção de estratégias de negociação. Sabendo que T e P_0 são sempre positivos, então o único fator da equação [1.5] que pode dizer qual a direção do movimento futuro da ação é o termo u . Se u for maior (menor) que zero, então a expectativa matemática é que os preços das ações subam (desçam) na medida em que evoluem no tempo. O problema dessa análise é que o valor de u é estimado da amostra e indica a inclinação temporal histórica da ação, portanto uma estratégia de negociação utilizando o valor de u somente funcionaria caso o preço da ação subisse ou descasse indefinidamente, porém supõe-se que tal episódio seja pouco provável.

Outra análise a ser perseguida é a respeito do segundo momento da distribuição, a variância. Partindo-se de $E[P_t - E(P_t)]^2$ e utilizando o resultado de [1.4] e [1.5], tem-se [1.6].

$$\begin{aligned} Var(P_t) &= E\left[Tu + P_0 + \sum_{t=1}^T \varepsilon_t - Tu - P_0\right]^2 \\ Var(P_t) &= E\left[\sum_{t=1}^T \varepsilon_t\right]^2 \\ Var(P_t) &= E[\varepsilon_t + \varepsilon_{t-1} + \varepsilon_{t-2} \dots \varepsilon_{t-T+1}]^2 \end{aligned} \quad [1.6]$$

Observando-se o último resultado de [1.6], caso fosse elevado ao quadrado $[\varepsilon_t + \varepsilon_{t-1} + \varepsilon_{t-2} \dots \varepsilon_{t-T+1}]$ e logo após utilizado o operador de esperança, todos elementos $E(\varepsilon_t \varepsilon_{t-j})$ seriam iguais a zero pois os resíduos do modelo não são autocorrelacionados. Por exemplo, caso $T=2$, tem-se para [1.6]: $Var(P_t) = E[\varepsilon_t + \varepsilon_{t-1}]^2 = E[\varepsilon_t^2 + 2\varepsilon_t \varepsilon_{t-1} + 2\varepsilon_{t-1}^2]$. Utilizando o operador de esperança, a última fórmula resulta em $Var(P_t) = E(\varepsilon_t^2) + E(\varepsilon_{t-1}^2)$ pois, conforme definido anteriormente, $E(\varepsilon_t \varepsilon_{t-j}) = 0$. Para esse exemplo, of valor de $Var(P_t)$

será igual a $2\sigma^2$, uma vez que a variância é constante e igual para todo tempo t , isto é, $E(\varepsilon_{t-j}^2) = \sigma^2$.

O exemplo anterior mostra que, independentemente do valor de T , o qual está relacionado com o número de termos a serem levados ao quadrado em [1.6], o que sobraria no cálculo dessa expressão sempre será um número T de termos $E(\varepsilon_t^2)$, os quais são iguais à variância do resíduo (σ^2), portanto, tal substituição leva ao resultado final, Equação [1.7].

$$\text{Var}(P_t) = T\sigma^2 \quad [1.7]$$

Observando-se [1.7], fica claro que tal modelo não é estacionário, uma vez que a variância cresce com o número de observações, portanto, caso o processo gerador dos preços obedecer [1.1], quanto maior o número de observações analisadas, menor a confiança nas previsões realizadas.

De um ponto de vista geral, o que o modelo RW1 está informando é que, caso os preços sigam a fórmula destacada em [1.1], então o comportamento dos preços é imprevisível e qualquer tentativa de construção de estratégias de negociação baseando-se em informações históricas é fadada ao fracasso.

1.1.1 Testando a Hipótese de Caminho Aleatório

Apesar da formulação matemática anterior para o PGP (processo gerador de preços) ser interessante academicamente do ponto de vista da teoria de eficiência fraca de mercado, sabe-se que a mesma é pouco realista e a possibilidade de previsão dos preços das ações sempre motivou a academia a buscar formulações quantitativas que possam ser úteis do ponto de vista de administração de investimentos, ou seja, que são contrárias, em idéia, à teoria de eficiência de mercado.

Existem diversas maneiras de testar a hipótese de eficiência de mercado¹. A linha de pesquisa dentre tal universo que mais se assemelha aos objetivos da presente pesquisa é a verificação empírica se informações passadas podem explicar os retornos das respectivas ações. Dentre tais estudos, diversos evidenciaram sinais de que as informações passadas são, em alguma extensão, critérios aceitáveis para os futuros rendimentos dos ativos. Entre os trabalhos mais destacados encontram-se Fama e French (1992) e Lo e Mackinley (1988, 1997a, 1997b) entre outros.

Particularmente, o foco da presente pesquisa é testar a HEM com base em modelagem de séries temporais, ou seja, utilizar apenas as observações passadas da própria série modelada para gerar previsões em $t+1$. Dentro de tal linha, é imprescindível discorrer sobre uma popular ferramenta utilizada por praticantes do mercado, a análise técnica. A análise técnica é uma ferramenta utilizada para realizar previsões de curto prazo no comportamento dos ativos. Tal método é composto por duas abordagens, a análise de indicadores quantitativos e a análise gráfica, conforme descrito em Murphy (1999).

Diversas pesquisas já foram empregadas para averiguar se as regras da análise técnica geram lucros excessivos no mercado. Uma parcela desses estudos utiliza-se dos índices quantitativos para gerar as estratégias, tais como médias móveis, índices de força relativa, estocásticos, etc. Um dos trabalhos pioneiros nesta linha é Dooley e Shafer (1983), os quais chegam à conclusão de que regras quantitativas da análise técnica podem gerar lucros médios acima da estratégia ingênua *buy&hold*. Dentre tal linha de pesquisa, foram encontrados poucos trabalhos com foco no mercado financeiro brasileiro. Um desses é Saffi (2002), o qual testou diversas estratégias baseadas em tais índices. A principal conclusão do autor é que tais índices, dentro da metodologia utilizada, não devem ser usados como parâmetros para formular a decisão de compra ou venda de ativos.

Sabe-se que a análise técnica não é composta somente por índices quantitativos, sendo formada, também, por análises gráficas (*charting*) cujas regras são demasiadamente não lineares e complexas para serem formuladas em uma equação. Um trabalho que buscou modelar tais padrões gráficos foi Lo (2000) através de regressões *Kernel*, onde foi concluído que tais padrões gráficos possuem poder preditivo a respeito do movimento das ações. Para

¹ Para a revisão mais completo sobre a teoria de eficiência de mercado, sugere-se o trabalho de Dimson e Mussain (1998), onde é realizada uma extensa pesquisa bibliográfica sobre os trabalhos acadêmicos realizados neste tópico. Para o caso brasileiro pode-se destacar os trabalhos de Amado e Carmona (2003), Bruni e Famá (2003), Perobelli e Ness (2000), Bueno et al (2000) e Ceretta (2003) entre diversos outros.

uma revisão mais completa dos trabalhos anteriores a respeito da análise técnica, sugere-se o trabalho de Park e Irwin (2004), onde é realizada uma extensa pesquisa bibliográfica.

Em Clyde e Osler (1997) foi mostrado que o método não paramétrico de previsão chamado *nearest neighbor* pode ser visto como uma generalização da parcela visual da análise técnica. A idéia por trás do algoritmo é selecionar pedaços da série modelada que possuam a maior simetria possível com o pedaço o qual se está buscando a previsão em $t+1$, o que é, de certa forma, similar ao que os analistas gráficos realizam, isto é, buscar padrões visuais no comportamento histórico das ações².

Outro ponto a ser destacado sobre o algoritmo de previsão *nearest neighbor*, agora referenciados como NN, é que o mesmo pode ser entendido como uma ligação entre teoria do caos e análise técnica (Bajo-Rubio et al, 2002), o que o torna atrativo do ponto de vista de investigação acadêmica. O principal conceito dentro da teoria do caos é que se uma série histórica é governada por propriedades caóticas, então o comportamento da mesma é previsível apenas no curto prazo com oscilações aparentemente randômicas, as quais se assemelham ao comportamento dos ativos negociados no mercado (Hsieh, 1991). Maiores detalhes sobre a congruência entre teoria do caos e o mercado de capitais pode ser encontrado em Perlin e Ceretta (2006).

Exemplos da aplicação do algoritmo NN em estratégias de negociação pode ser visto em Fernandez-Rodrigues et al (2001), Fernandez-Rodriguez et al (1997) e Perlin (2006). Uma das principais conclusões dos trabalhos citados anteriormente é o encontro de capacidade preditiva para o algoritmo NN em séries financeiras, porém é importante ressaltar que a evidência não foi forte para todos os estudos citados.

Outro tipo de modelagem matemática aplicada aos mercados financeiros é o uso de redes neurais. Resultados positivos a respeito do método pode ser encontrado em Chen et al (2003) para o mercado de Taiwan. Para os mercados latino americanos, existe o trabalho de Carvalhal da Silva e Ribeiro (2002), onde tal método foi aplicado para os respectivos índices de mercado de diferentes países. A conclusão de tal trabalho também é positiva a respeito da performance da modelagem na previsão das séries.

² Maiores detalhes sobre os tipos de padrões gráficos que os analistas procuram (*head and shoulders*, *triple top*, etc) podem ser encontrados em Murphy (1999).

Uma das regras quantitativas de negociação mais populares e também uma das mais fáceis de implementar é a estratégia de pares (pairs trading). Tal metodologia foi arquitetada no começo dos anos 80 por uma equipe de cientistas de diferentes áreas (matemática, ciências da computação, física, etc). O principal objetivo de tal time era criar regras de negociação baseadas em métodos estatísticos, onde a subjetividade humana não teve qualquer influência no processo de administração da carteira. Outras informações a respeito de tal método podem ser visualizadas em Vidyamuthy (2004). Resultados positivos a respeito da estratégia de pares pode ser encontrado em Gatev et al (1999) para o mercado americano e Perlin (2007) para o mercado brasileiro.

Para o caso de modelos paramétricos, um estudo que possui forte simetria com a presente pesquisa é Efetkhari (1997), o qual buscou construir estratégias de *timing* com base em modelos de mudança de regime (*markov switching model*). A principal conclusão do trabalho é que tais modelos obtiveram retornos excessivos em relação ao respectivo índice de mercado. Para o caso Brasileiro, tal conclusão é corroborada pelo trabalho de Almeida e Pereira (2000).

Outros exemplos no uso de formulações quantitativas em decisões de investimento são estratégias de timing, Brooks, Katsaris e Persaud (2005) e estratégias de replicação de índices, Alexander e Dimitriu (2003), entre diversos outros trabalhos.

Conforme foi visto, existem diversas abordagens que buscam verificar a hipótese de eficiência de mercado com base em previsões dada por algum modelo matemático. Apesar da popularidade no uso de modelos ARIMA e GARCH em finanças, não foi encontrado nenhum trabalho que verificasse o potencial de tais formulações matemáticas em estratégias de negociação para o mercado de ações³. Esta informação é uma das motivações do presente estudo. No tópico seguinte será destacada a teoria por trás dos modelos matemáticos utilizados.

³ Apesar de não se encontrado para o mercado de ações, para o mercado derivativo pode ser indicado o trabalho de Chan, et al (2006).

1.2 Modelos Matemáticos Utilizados na Pesquisa

Neste tópico será destacada a teoria por trás dos modelos de previsão utilizados na pesquisa.

1.2.1 Modelos ARIMA (Autoregressive Integrated Moving Average)

Em meados da década de 70, conforme descrito em Madalla (2001), os modelos ARIMA tornaram-se bastante populares pela metodologia Box-Jenkins (Box e Jenkins, 1976), a qual é estruturação de um número de passos na modelagem de séries temporais. Tais modelos conseguem tratar de forma suficiente os fatos estilizados encontrados na maioria das séries temporais, tais como tendência e sazonalidade.

A base do modelo ARIMA é composta por três partes, uma AR (*autoregressive*), uma MA (*moving average*) e uma diferenciação, a qual tem como objetivo tornar a série modelada estacionária. A seguir, na Equação [2.1], apresenta-se a formulação geral de um modelo ARIMA.

$$\Delta^d y_t = \alpha_0 + \sum_{i=1}^j \theta_i y_{t-i} + \sum_{i=1}^m \phi_i \varepsilon_{t-i} + \varepsilon_t \quad [2.1]$$

Conforme pode ser visto na Equação [2.1], o modelo ARIMA é uma combinação entre modelos AR e MA, isto é, tanto as observações passadas como os erros passados são inseridos no modelo para prever os futuros valores da série temporal y_t . O termo $\sum_{i=1}^j \theta_i y_{t-i}$ indica a parte AR do modelo ARIMA, isto é, serão utilizadas j observações passadas no modelo, enquanto o termo $\sum_{i=1}^m \phi_i \varepsilon_{t-i}$ indica a parte MA da Equação [2.1], onde a letra m indica o grau de defasagem dos erros do modelo ARIMA.

Para Equação [2.1], o termo $\Delta^d y_t$ indica a diferenciação da série original y_t , isto é, o número d de vezes em que a série será diferenciada. Por exemplo, caso $d=1$ então Δy_t será igual a $y_t - y_{t-1}$. É fácil de ver que se $d=0$ então a série modelada será a original, sem diferenciação alguma. Um modo estruturado de chamar o modelo ARIMA da Equação [2.1] é ARIMA (j,d,m) , onde, conforme foi dito anteriormente, j é a defasagem do termo AR, d indica o nível de diferenciação da série a ser modelada e m denota o *lag* do termo MA. Tais classes de modelos são estimados através da maximização da função de máxima verossimilhança. Maiores detalhes sobre essa questão e sobre a teoria ARIMA em geral podem ser encontrados em Moretin e Tolo (2004) ou Tsay (2002).

Para modelar séries de retornos financeiros, as quais possuem fatos estilizados tais como *fat tails* e aglomeração de volatilidade, é natural a extensão dos modelos ARIMA para a inserção de variâncias condicionais na modelagem. Tal classe de modelos é destacada a seguir.

1.2.2 Equacionando as Variâncias no Tempo t – Modelos da Família Arch

Um dos modelos mais simples em econometria é a regressão linear simples, mais especificadamente o método de mínimos quadrados. Tal classe de modelo possui certas premissas e, uma delas, é a presença de variâncias constantes para o erro (homocedasticidade). Quando esta e outras qualidades são verdadeiras, é possível provar que os estimadores dos mínimos quadrados são eficientes (menor variância dentre a classe de estimadores lineares) e não-viesados (valor estimado igual a expectativa matemática do valor real). Tal propriedade também é chamada de teorema de Gauss/Markov (Maddala, 2001).

Para a modelagem de séries de retornos financeiros com relativa alta frequência (diária e semanal), é comum serem encontradas variâncias não constantes nos erros, ou seja, a presença de heterocedasticidade no modelo. No trabalho seminal de Engle (1982), foi sugerida uma classe nova de modelos, a qual possui como base uma abordagem diferente a respeito da variância dos erros. A inovação por trás desse tipo de modelagem é tratar a heterocedasticidade de modo condicional, ou seja, condicionar as variâncias no tempo t em relação a outras variáveis, incluindo as próprias volatilidades passadas.

A idéia básica dessa família de modelos é que os retornos do ativo i não são correlacionados serialmente, ou seja, os resíduos não possuem correlação no lag genérico k , porém, quando os erros são elevados ao quadrado, verifica-se uma correlação significativa nos *lags* próximos (geralmente 1 e 2), indicando que um erro brusco em qualquer direção é seguido por outro erro também brusco em qualquer direção (tratamento quadrático).

Particularmente em séries financeiras, partindo-se da análise sobre o impacto das informações nos rendimentos dos ativos, pode-se definir que a média de R_{it} (retorno do ativo i no tempo t) e a variância irão comportar-se de acordo com tal vetor não observável, a qual toma o símbolo de F_{it-1} (informação disponível no tempo $t-1$). A formalização matemática das afirmativas anteriores é apresentada a seguir, Equações [2.2] e [2.3].

$$u_t = E(R_{it} | F_{it-1}) \quad [2.2]$$

$$h_t = \text{Var}(R_{it} | F_{it-1}) \quad [2.3]$$

Para as Equações [2.2] e [2.3], os termos u_t e h_t representam, respectivamente, a média e a variância condicional do rendimento do ativo i no tempo t . Ambos os momentos estão condicionados em relação às informações disponíveis em $t-1$, as quais estão representadas por F_{t-1} . Simplificando, o grande ponto das Equações [2.2] e [2.3] é que a média, ou seja, o que se espera de rendimento para o ativo i no tempo t assim como a volatilidade em torno dessa média (incerteza) são condicionadas às informações observadas em um período anterior.

A seguir, Equações [2.4] e [2.5], apresenta-se matematicamente o uso de variâncias condicionais em termos de funções genéricas $f(\cdot)$ e $g(\cdot)$.

$$R_{it} = f(X) + \varepsilon_t \quad \varepsilon_t \sim N(0; \sqrt{h_t}) \quad [2.4]$$

$$h_t = g(Y) + v_t \quad [2.5]$$

Os termos X e Y nas Equações [2.4] e [2.5] são apenas de caráter ilustrativo, representando matrizes explicativas genéricas, incorporando tudo aquilo que pode explicar, respectivamente, R_{it} e h_t , incluindo, também, as informações disponíveis em $t-1$ (F_{t-1}). A

Equação [2.4] é denominada equação da média, sendo, portanto, similar à Equação [2.2]. A mesma análise é coerente para a Equação [2.5] em paralelo com a Equação [2.3]. Os erros da equação da média são normais, possuindo média zero e variância h_t , sendo essa última condicional. No exemplo anterior foi utilizada uma distribuição normal para os erros, porém é possível modificar tal premissa auferindo, por exemplo, uma distribuição t para os erros da variância condicional. Tal abordagem não será utilizada no presente trabalho, porém sua descrição pode ser encontrada na bibliografia básica do trabalho (Moretin e Tolo, 2004).

Para o presente trabalho, o modelo ARCH utilizado será o GARCH (*generalized autoregressive conditional heteroscedasticity*) proposto por Bollerslev (1986), o qual é uma representação parcimoniosa de modelos ARCH com grande número de defasagens, isto é, faz o mesmo trabalho, porém de forma mais simples. O modelo GARCH utilizado na pesquisa é explicitado algebricamente a seguir, nas Equações [2.6] e [2.7]. É importante notar que a média condicional já está explicitada como um modelo ARIMA (j,d,m), definido nos tópicos anteriores.

$$\Delta^d y_t = \alpha_0 + \sum_{i=1}^j \theta_i y_{t-i} + \sum_{i=1}^m \phi_i \varepsilon_{t-i} + \varepsilon_t \quad [2.6]$$

$$\varepsilon_t \sim N(0, h_t)$$

$$h_t = \gamma_0 + \sum_{i=1}^l \omega_i y_{t-i}^2 + \sum_{i=1}^k \tau_i h_{t-i} + v_t \quad [2.7]$$

Para Equação [2.7], o termo $\sum_{i=1}^l \omega_i y_{t-i}^2$ é a parcela ARCH do modelo, enquanto o termo $\sum_{i=1}^k \tau_i h_{t-i}$ representa a parcela GARCH. A seguir será definida de forma mais detalhada a abordagem utilizada para selecionar as defasagens dos termos AR, MA, ARCH e GARCH, assim como também o grau de diferenciação para a série original.

1.2.2.1 Detalhes na Estimação dos Modelos ARIMA&GARCH

Para os modelos ARIMA&GARCH, é preciso definir duas coisas: primeiro o número de parâmetros no modelo (AR, MA, ARCH, GARCH) e, por segundo, o tamanho da série utilizada na estimação dos modelos. Um grande problema em qualquer pesquisa que busca simular uma estratégia de negociação historicamente é a possibilidade de *data snooping*, isto é, basear os resultados da pesquisa com base em padrões específicos de uma determinada amostra. Para o caso de estratégias de negociação, por exemplo, é possível que modelos ARIMA (2,0,1) com efeitos GARCH (2,2) estimados em janelas móveis de 50 observações passadas possam obter um retorno excessivo significativo dentro do período total analisado na pesquisa, porém nada garante que o uso da mesma configuração possa funcionar no futuro ou em amostras diferentes.

Em simulações preliminares ao estudo, foi possível verificar que os resultados da pesquisa eram bastante sensíveis à escolha dos parâmetros dos modelos estimados. Com o objetivo de evitar *data snooping*, foi necessário buscar um método cientificamente mais interessante na seleção do número de defasagens para cada termo dos modelos ARIMA&GARCH.

O método para solucionar tal entrave foi a construção e execução de um algoritmo que seleciona, para cada tempo t , a melhor combinação entre os termos AR, MA, ARCH e GARCH com base em alguma função penalizadora. Neste caso foi escolhido o uso do critério de Akaike⁴ (Akaike, 1974). O critério de Akaike (Akaike Info Criterion – AIC) é nada mais que uma função que possibilita a seleção de modelos com base no número de coeficientes, valor da log verossimilhança e no tamanho da janela de estimação. A seguir, Equação [2.10], apresenta-se a fórmula.

$$AIC = -2\left(\frac{l}{T}\right) + 2\left(\frac{k}{T}\right) \quad [2.10]$$

Na Equação [2.10], o termo l é o *log* do valor de *verossimilhança* (*log likelihood*) do modelo estimado, T é o número de observações utilizadas e k é o número de termos da

⁴ O critério para a escolha do AIC foi pela facilidade de implementação, porém também foi testada outra função penalizadora, a *Schwarz Information Criteria*. Os resultados da pesquisa para ambos métodos foram bastante similares.

respectiva modelagem. Dentro da seleção de modelos, o melhor modelo será aquele que apresentar o menor valor de AIC. Portanto, reordenando AIC para $AIC = \frac{2(-l + k)}{T}$ e tendo o valor de T como uma constante, minimizar AIC é equivalente a maximizar l e minimizar k . O entendimento do componente l de tal função penalizadora (AIC) é intuitivo, isto é, está-se maximizando o logaritmo⁵ da função de máxima verossimilhança, a qual possui direta relação com a minimização do erro quadrático do modelo, o que é algo desejável. A minimização do termo k também é intuitiva, ou seja, está-se buscando parcimônia na modelagem (poucos parâmetros nos modelos).

Os passos do algoritmo para seleção dos modelos são destacados abaixo.

- 1) Estimar todas as possíveis combinações entre os termos ARMA e GARCH para uma janela histórica de tamanho T, salvando o valor do critério de Akaike para cada modelo estimado.
- 2) Selecionar a combinação entre ARIMA e GARCH que tenha produzido o menor valor de critério de Akaike.
- 3) Com base no modelo escolhido no passo 2, criar previsões de média e volatilidade condicional para $t+1$.
- 4) Repetir passos 1-3 para cada tempo t , até que todas as previsões sejam feitas⁶.

Para o passo 1, é importante observar que as combinações testadas para os termos ARIMA foi ARIMA (1,0,1), ARIMA (2,0,2), ARIMA (3,0,3) e assim sucessivamente até o valor de *maxarma* (valor máximo para os termos ARMA). A simplificação feita, testar apenas as combinações entre ARMA, ao contrário de testar as combinações entre AR e MA, foi uma maneira de diminuir o tempo necessário nos cálculos das previsões. Caso fossem testadas as possíveis combinações entre os termos AR e MA, o número de modelos a serem estimados aumentaria exponencialmente, o que, conseqüentemente, aumentaria demasiadamente o tempo necessário de processamento. Para o estudo, o valor de *maxarma* utilizado foi 5 e

⁵ O logaritmo e a função original chegam ao máximo no mesmo ponto.

⁶ Para executar tais passos foi criada uma rotina no pacote estatístico Eviews. O critério para a escolha do Eviews, ao contrário do MatLab, foi pela rapidez nas estimações dos modelos.

maxgarch foi igual a 2, isto é, foram testadas todas possíveis combinações entre defasagens 1, 2, 3, 4 e 5 para os termos ARMA com defasagens 1 e 2 para os termos GARCH.

É importante observar que o tamanho da janela móvel utilizada nas estimações dos modelos foi definido arbitrariamente, neste caso $T=150$, isto é, para cada tempo t as 150 observações anteriores foram utilizadas na estimação do modelo⁷ e conseqüente construção das previsões de média e volatilidade em $t+1$.

Outro ponto importante a ser destacado é a abordagem escolhida para o termo d (grau de diferenciação). Como os retornos dos ativos são geralmente estacionários, optou-se por utilizar $d=0$, ou seja, foram utilizados apenas os retornos originais para a construção dos modelos.

1.2.3 O Algoritmo de Previsão Nearest Neighbor

O método NN está situado dentro da classe de regressões não paramétricas, ou seja, são mais flexíveis quanto às hipóteses do modelo. Sua idéia principal é que a série copia seus próprios pedaços no desenrolar de seu comportamento, isto é, pedaços passados possuem simetria com os pedaços anteriores ao que se quer prever, o que justifica a semelhança, a qual foi exposta anteriormente, entre análise técnica e o algoritmo NN. Tal abordagem, conforme será detalhada a seguir, é filosoficamente diferente dos modelos de previsão ARIMA, o qual busca relações matemáticas entre o instante t e o *lag* genérico $t-j$, seja com a série original (AR) ou os erros (MA). Para o algoritmo NN, ao contrário dos populares modelos ARIMA, a localidade no tempo não é importante, uma vez que se está buscando simetria entre pedaços da série, e não do *lag* t com a defasagem genérica $t-j$.

Conforme foi descrito anteriormente, o ponto principal do algoritmo é que o comportamento da série modelada se repete ao longo do tempo. Tal autosimilaridade pode ser entendida como uma propriedade de sistemas caóticos (Perlin e Ceretta, 2006; Ceretta, 2003; Fernandez-Rodriguez *et al*, 2001) o que, de certo modo, justifica o uso de tal abordagem na

⁷ No desenvolvimento da pesquisa também foi testado um algoritmo que selecionava, juntamente com as defasagens dos termos, a janela com base no AIC, porém o tempo necessário para o processamento dos dados nessa abordagem é demasiadamente elevado (4 horas para cada diferente janela testada) e resultados preliminares se apresentaram bastante inferiores em relação ao uso de uma janela fixa, o que levou a desmotivação para esse tipo de abordagem na estimação dos modelos.

pesquisa, uma vez que séries financeiras tendem a apresentar algumas propriedades de sistemas caóticos (Hsieh, 1991; Mandelbrot, 2004).

A seguir será descrito de forma simplificada o modo como o método de previsão *Nearest Neighbor* opera. Para maiores detalhes sobre a questão, sugere-se o trabalho de Farmer e Sidorowich (1987) e Fernández-Rodríguez *et al* (1997).

1) O primeiro passo do NN é definir um período de treinamento e dividir tal período em vetores de tamanho m , $i = m...T$, onde T é o número total de observações no intervalo de treinamento. O termo m também é definido como o valor de *embedding dimension* da série temporal. Para fins de notação, o pedaço anterior à observação a ser prevista será chamado de y_T^m , e os demais pedaços passados serão denotados por y_i^m .

2) O segundo passo é selecionar k pedaços, os quais possuam, dentre todos os pedaços y_i^m , maior simetria com y_T^m . Em uma notação mais formal, procura-se os k pedaços com maior valor de $|\rho|$, o qual representa a correlação entre y_i^m e y_T^m dentro da norma euclidiana (valor absoluto).

3) De posse dos k pedaços, cada um com m observações, é necessário entender de que forma os pedaços podem servir de base para a construção da previsão em $t+1$. Neste passo existem diferentes maneiras de fazer tal construção. O método escolhido para a pesquisa é o destacado em Fernández-Rodríguez *et al* (2001), o qual consiste em calcular a seguinte expressão, Equação [2.8].

$$\hat{y}_{T+1} = \hat{\alpha}_0 + \hat{\alpha}_1 y_{T-1}^m + \hat{\alpha}_2 y_{T-2}^m + \dots + \hat{\alpha}_m y_{T-m}^m \quad [2.8]$$

Os coeficientes $\hat{\alpha}_0, \hat{\alpha}_1 \dots \hat{\alpha}_m$ são obtidos pela estimação de um modelo linear com a variável dependente sendo y_{i+1} e as demais variáveis explicativas como sendo

$y_i^m = (y_i, y_{i-1}, \dots, y_{i-m+1})$, onde r vai de 1 até k . Para facilitar a compreensão de tal regressão, apresenta-se a mesma em forma matricial, Equação [2.9]

$$\begin{bmatrix} y_{i_1+1} \\ y_{i_2+1} \\ y_{i_3+1} \\ \mathbf{M} \\ y_{i_k+1} \end{bmatrix} = \hat{\alpha}_0 + \hat{\alpha}_1 \begin{bmatrix} y_{i_1} \\ y_{i_2} \\ y_{i_3} \\ \mathbf{M} \\ y_{i_k} \end{bmatrix} + \hat{\alpha}_2 \begin{bmatrix} y_{i_1-1} \\ y_{i_2-1} \\ y_{i_3-1} \\ \mathbf{M} \\ y_{i_k-1} \end{bmatrix} + \dots + \hat{\alpha}_{m-1} \begin{bmatrix} y_{i_1-m+1} \\ y_{i_2-m+1} \\ y_{i_3-m+1} \\ \mathbf{M} \\ y_{i_k-m+1} \end{bmatrix} + \begin{bmatrix} \varepsilon_1 \\ \varepsilon_2 \\ \varepsilon_3 \\ \mathbf{M} \\ \varepsilon_k \end{bmatrix} \quad [2.9]$$

Para a Equação [2.9], é preciso entender que o algoritmo NN é, de certo modo, atemporal. Os valores de y_{i_k+1} são as observações que estão um período a frente dos pedaços escolhidos pelo critério de máxima correlação em valor absoluto. Analisando os vetores de cima para baixo, o termo y_{i_k-m+1} indica os primeiros valores dos pedaços escolhidos, os quais são de número k , enquanto o termo y_{i_k} representa os últimos termos de cada pedaço escolhido. A Equação [9] será estimada pela minimização do somatório do erro quadrático ($\sum_{i=1}^k \varepsilon_k^2$). É fácil de ver que todas as séries explicativas em [2.9] terão tamanho k , e que o número de séries explicativas é m .

Por trás de toda a formalidade matemática, a idéia básica do método é captar quais os pedaços que são mais parecidos com o pedaço anterior à observação a qual se está querendo prever. Com base em tais pedaços escolhidos, verifica-se de que modo a próxima observação da série pode ser construída tendo como variáveis explicativas as m observações passadas (regressão do passo 3) dos k pedaços similares. Com os coeficientes estimados, calcula-se a previsão para $t+1$ com os valores de y_t^m (pedaço de tamanho m anterior à observação a ser prevista). Os passos 1-3 são realizados sucessivamente até calcular todas as previsões em $t+1$ da série modelada ⁸.

⁸ Para efetivar todos os cálculos do NN, foi criada uma função no MatLab, a qual está disponibilizada ao público em <http://www.mathworks.com/matlabcentral/fileexchange/>, keyword: nearest neighbor.

É importante observar que dois parâmetros devem ser definidos para se efetivar o uso do algoritmo, primeiro o tamanho dos pedaços (valor de m) e o número de pedaços a ser utilizado nas previsões (valor de k). Nos próximos tópicos será destacada a abordagem utilizada na seleção de tais parâmetros.

1.2.3.1 Detalhes na Utilização do Algoritmo NN

Para o algoritmo NN, o que resta definir são os valores de k (número de pedaços a serem utilizados na regressão da Equação [2.8]) e m (tamanho dos pedaços).

É importante observar que o algoritmo NN é computacionalmente intensivo. Uma simplificação nos parâmetros, neste caso, é algo necessário. A simplificação neste ponto será utilizar para todos os ativos o valor de m e k que apresente o menor valor de erro quadrático de previsão em relação à série do Ibovespa, ou seja, executa-se o algoritmo nas ações com bases nos parâmetros que apresentarem melhores resultados para o Ibovespa. Tal método constitui uma fraqueza da pesquisa, uma vez que as diferentes séries podem apresentar diferentes parâmetros ótimos. Essa fragilidade do trabalho deve ser levada em conta nas conclusões da pesquisa em relação ao desempenho do algoritmo NN nas estratégias.

A modelagem do Ibovespa foi realizada utilizando dados diários de 2000 até 2003, isto é, não sendo utilizado as observações dentro do período das estratégias. O parâmetro com menor erro de previsão foi $m=5$ e $k=140$.

2. Método da Pesquisa

Neste tópico serão explanados, de forma mais completa, os conceitos envolvidos no método utilizado para atingir os objetivos destacados anteriormente.

2.1 Base de Dados

A base de dados da pesquisa é originária do software Economática®, composta pelos 40 ativos com maior liquidez entre 2002 e 2005, contemplando dados diários de janeiro de 2002 até janeiro de 2005, totalizando 748 observações para cada ativo. A razão na escolha do período da pesquisa foi de que tal intervalo compreende um momento em que a economia brasileira encontra-se relativamente mais estável em relação a períodos anteriores a 2000. Outro ponto importante a ser destacado é que os modelos são utilizados em diferentes tipos de séries. O algoritmo NN será executado em séries de preços, enquanto os modelos ARIMA&GARCH são utilizados nas séries de retornos. O ano de 2002 será utilizado como período de treinamento dos primeiros modelos estimados, enquanto os anos de 2003 e 2004 serão utilizados como período de teste das estratégias contempladas no trabalho. O total de observações para cada ativo no período de teste de estratégia é 499. A seguir, Tabela 1, apresenta-se os ativos utilizados na pesquisa.

Tabela 1 – Ativos Utilizados na Pesquisa

Código na Bolsa	Setor	Liquidez 2002-2005
TNLP4	Telecomunicações	9.980.453
PETR4	Extração de petróleo e gás	7.187.362
EBTP4	Telecomunicações	3.662.876
BBDC4	Bancos	3.431.823
TSPC6	Telecomunicações	3.308.909
VALE5	Mineração de metais	3.178.575
ELET6	Geração, transmissão e distribuição de energia elétrica	2.797.066
USIM5	Transformação de aço em produtos de aço	2.751.213
ITAU4	Bancos	2.683.752
CMIG4	Geração, transmissão e distribuição de energia elétrica	2.503.326
CSNA3	Transformação de aço em produtos de aço	2.434.194
BRTO4	Telecomunicações	2.025.353
GGBR4	Transformação de aço em produtos de aço	2.003.365
AMBV4	Indústria de bebidas	1.939.389
BRTP4	Indústria de equipamentos aeroespaciais	1.730.089
TMAR5	Telecomunicações	1.619.789
NETC4	TV a cabo	1.616.256
TMCP4	Telecomunicações	1.481.894
TMAR3	Telecomunicações	1.417.467
CPLE6	Geração, transmissão e distribuição de energia elétrica	1.392.659
ITSA4	Administração de empresas e empreendimentos	1.089.999
CMET3	Mineração de metais	1.072.032
SBSP3	Água, esgoto e outros sistemas	1.012.685
ACES4	Transformação de aço em produtos de aço	975.071
TMCP4	Telecomunicações	961.985
CSTB4	Transformação de aço em produtos de aço	931.081
BRKM5	Indústria química	887.637
TCSL4	Telecomunicações	877.813
VCPA4	Indústria de papel, celulose e papelão.	872.624
ARCZ6	Indústria de papel, celulose e papelão.	762.489
BBAS3	Bancos	752.727
ELPL4	Geração, transmissão e distribuição de energia elétrica	706.289
CRTP5	Telecomunicações	658.010
TLPP4	Telecomunicações	651.292
CLSC6	Geração, transmissão e distribuição de energia elétrica.	637.417
CRUZ3	Indústria de fumo	562.873
BRAP4	Administração de empresas e empreendimentos	546.265
SDIA4	Abatedouros	516.525
GOAU4	Transformação de aço em produtos de aço	488.672
CESP5	Geração, transmissão e distribuição de energia elétrica	444.817

Conforme pode ser visto na Tabela 1, tomou-se o cuidado para não utilizar duas ações da mesma empresa, uma vez que tal operação iria enviesar os resultados da pesquisa, pois estar-se-ia aplicando regras de negociação para duas séries com comportamentos em princípio

similares, o que iria apenas replicar os resultados⁹. Também pode ser visualizada na Tabela 1 a diversificação de setores referentes aos papéis utilizados no trabalho, a qual também constitui um cuidado a ser tomado nesse tipo de pesquisa.

2.2 Estratégias de Negociação

Após a especificação do modelo, o próximo passo é explicitar as estratégias baseadas nas previsões criadas. Para fins de formalidade matemática, as previsões de retornos criadas para o tempo t , seja pelo modelo ARIMA ou NN, serão indicadas como \hat{R}_{it} , isto é, o retorno previsto para o ativo i no tempo t . Para o caso do algoritmo NN, o termo \hat{R}_{it} será dado por $\hat{R}_{it} = \ln\left(\frac{\hat{P}_{it}}{P_{it-1}}\right)$, onde \hat{P}_{it} é o preço previsto no tempo t . O termo C é o custo de transação, denotado em percentagem, envolvido em uma operação de compra ou venda.

Duas diferentes estratégias serão utilizadas. Em termos gerais, a estratégia 1 indica, apenas, quando investir, enquanto a estratégia 2, a qual pode ser considerada mais completa, indica aonde e quando investir.

2.2.1 Estratégia 1 (Timing Strategy)

A idéia por trás da estratégia 1 é intuitiva. Se o modelo prever que, considerando todos custos de transação envolvidos, investir na ação i hoje, o lucro de amanhã será positivo, então gera-se um sinal de compra. Formalmente:

⁹ Apesar de aparecer Gerdau e Gerdau Metalúrgica na lista dos ativos utilizados, o que aparentemente parece contraditório com a afirmação no texto, tal escolha foi realizada pelo filtro do próprio software, neste caso o economática, o qual entende que Gerdau e Gerdau Metalúrgica são empresas diferentes. Deste modo, optou-se por manter a configuração oferecida pelo banco de dados.

- Se $\hat{R}_t + \ln\left(\frac{1-C}{1+C}\right) > 0$ então se gera um sinal de compra (entrar no mercado). Se em $t-1$ foi gerado um sinal de compra, então se continua no mercado.
- Se $\hat{R}_t + \ln\left(\frac{1-C}{1+C}\right) \leq 0$, então se gera um sinal de venda (sair do mercado).¹⁰

A estratégia 1 será testada em cada um dos ativos, tendo como base as previsões em $t+1$ criadas pelas duas abordagens matemáticas.

É importante observar que, apesar da estratégia 1 ser menos completa que a estratégia 2, uma vez que fica restrita a apenas um ativo, as regras da estratégia 1 geram um número menor de custos de transação. Por exemplo, se uma ação for comprada em $t-1$ e em t é gerado outro sinal de compra para a mesma ação, então não se computa o custo da segunda transação, uma vez que a determinada ação já estava na carteira. Quando a estratégia 1 é aplicada em um grande número de observações, verifica-se que os sinais de compra tendem a se aglomerar, o que diminui consideravelmente o total de custos de transação. Portanto, apesar da estratégia 2 ser mais completa, ela acarreta um número maior de custos em relação à estratégia 1.

2.2.2 Estratégia 2 (Arbitrage Strategy)

A estratégia 2 é relativamente mais complexa que a estratégia 1. A idéia principal deste método é comparar todas as previsões criadas. Por exemplo, para o tempo t , serão criadas 40 previsões: uma para cada ativo. É natural que algumas previsões irão ser quantitativamente diferentes, isto é, com valores diferentes e erros padrões diferentes. A pergunta que define a estratégia 2 é: dentro de uma estratégia de negociação, o que pode ser entendido como uma boa previsão? Uma previsão boa é aquela que apresenta alto valor

¹⁰ É importante observar que, na grande parte dos estudos verificando *timing strategies* foi utilizado o ativo livre de risco para os casos onde é criado um sinal de venda, ou seja, sair do mercado e colocar os recursos em algum papel livre de risco. Para a presente pesquisa, realizar tal operação é inviável, uma vez que se está trabalhando com relativa alta frequência (dados diários) e colocar e retirar o investimento no ativo livre de risco, para cada dia, torna-se impraticável ou muito oneroso. Devido a isso, optou-se por retirar o ativo livre de risco na análise das estratégias.

positivo de retorno esperado e baixo valor de erro padrão, isto é, o retorno previsto na operação é alto, e a confiança prevista em tal previsão também é alta (baixa volatilidade prevista). Com base na análise anterior, utiliza-se um índice de modo a comparar as previsões. Tal índice, o qual é nada mais que uma versão mais sofisticada do popular índice Sharpe, será denominado de S_{it} . A seguir, Equação [2.11], apresenta-se a fórmula do mesmo.

$$S_{it} = \frac{\hat{R}_{it} + \ln\left(\frac{1-C}{1+C}\right)}{\hat{\sigma}_{it}} \quad [2.11]$$

Conforme pode ser observado na Equação [2.11], o índice S_{it} é nada mais que a divisão entre o retorno previsto (descontados dos custos de transação), o qual também pode ser entendido como retorno esperado, e o desvio padrão previsto dos modelos, o qual também pode ser entendido como risco. Ao contrário de utilizar a média incondicional como retorno esperado e desvio padrão dos rendimentos como risco, a qual é a base da teoria de carteiras, a presente pesquisa constrói tais índices de forma mais complexa, através de modelos ARIMA&GARCH e do algoritmo NN.

O próximo passo nessa estratégia é comparar os índices provenientes dos diferentes ativos e procurar aquele que apresente o maior retorno previsto pela menor volatilidade. Portanto, procura-se, dentre as previsões para n ativos, o seguinte termo chamado S_{Mt}^{\max} , conforme Equação [2.12].

$$S_{Mt}^{\max} = \max[S_{1t}, S_{2t}, S_{3t}, S_{4t}, S_{5t}, \dots, S_{nt}] \quad [2.12]$$

O termo S_{Mt}^{\max} , com i variando de 1 até n , é o índice S_{it} para o ativo M (o que apresentou maior relação entre retorno esperado e volatilidade para $t+1$). Em outras palavras, a função desse índice Sharpe modificado é escolher, para cada tempo t , aquele ativo que apresentar a melhor previsão para $t+1$. A seguir apresenta-se a regra formal de negociação.

- Escolher no tempo t , dentre todas as previsões disponíveis para $t+1$, aquela que apresenta maior retorno previsto por uma menor volatilidade prevista, isto é, calcular o valor de S_{Mt}^{\max} . A partir disso, caso o retorno previsto deste ativo, levando em conta os custos envolvidos, seja positivo, gera-se um sinal de compra na ação M para o tempo $t+1$. Em caso contrário, fica-se fora do mercado.

Conforme pode ser visto, foi utilizada uma segunda condição - o retorno previsto tem que ser positivo - de modo a evitar que a estratégia leve a investir em ações onde é previsto um retorno negativo. É fácil de enxergar que a estratégia 2 é mais completa que a estratégia 1, uma vez que esta última apenas aponta quando investir, enquanto a 2 indica aonde e quando investir.

Outro modo de enxergar a estratégia 2 é analisando do ponto de vista de probabilidades. Tendo como base uma distribuição normal, quando se está dividindo

$\hat{R}_{it} + \ln\left(\frac{1-C}{1+C}\right)$ por $\hat{\sigma}_{it}$, o resultado é um simples escore Z , portanto, caso fosse colocado tal

valor em uma distribuição normal, o resultado seria a probabilidade do retorno previsto, \hat{R}_{it} , ser maior que o custo de transação. Visto isso, quando se procura, para cada tempo t , o ativo

que possui maior $\frac{\hat{R}_{it} + \ln\left(\frac{1-C}{1+C}\right)}{\hat{\sigma}_{it}}$, é equivalente a procurar o ativo que possui maior

probabilidade de que o retorno de amanhã seja positivo, levando em conta, também, os custos envolvidos.

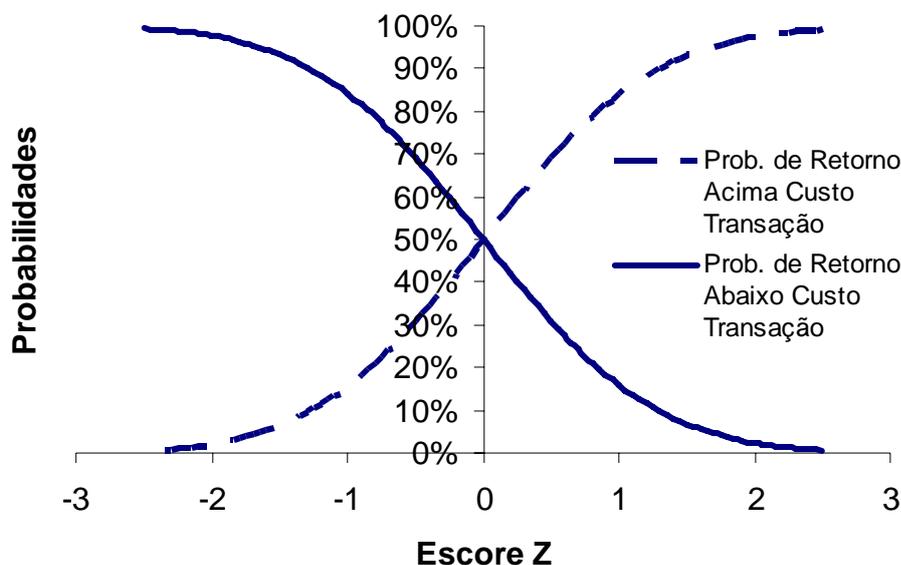
Outro ponto a ser destacado é a utilização do filtro nas regras da estratégia 2, o qual não permite que se entre no mercado quando o valor de S_{Mt}^{\max} seja negativo

$(\hat{R}_{Mt} < \ln\left(\frac{1-C}{1+C}\right))$. Partindo-se do uso de distribuições simétricas e analisando-se as

conseqüências no uso de tal regra, verifica-se que quando $S_{Mt}^{\max} = 0$, isto é, $\hat{R}_{Mt} = \ln\left(\frac{1-C}{1+C}\right)$, a

probabilidade de retornos positivos é igual à probabilidade de retornos negativos, ou seja, ambas são 50%. Tal propriedade é ilustrada, a seguir, na Figura 1.

Figura 1 – Probabilidade X Escore Z de uma Distribuição Normal



Conforme pode ser visualizado na Figura 1, quando $S_{Mt}^{\max} < 0$, a probabilidade de retornos negativos é maior que a probabilidade de retornos positivos. Conforme pode ser visto, o uso do filtro na estratégia 2 e a análise das probabilidades envolvidas em tal operação corroboram, isto é, quando a probabilidade de retorno negativo for maior que a probabilidade de retornos maiores que zero, fica-se fora do mercado e vende-se qualquer ativo comprado anteriormente. De forma intuitiva, as análises anteriores confirmam e também justificam o uso do índice S_{it} na estratégia de arbitragem.

Na estratégia 2, as abordagens escolhidas para calcular a volatilidade das previsões das séries são fundamentalmente diferentes. Tal termo, para os modelos ARIMA&GARCH, é facilmente computado através da previsão da volatilidade pelos termos GARCH, $\hat{\sigma}_{it+1}^2$. Para o algoritmo NN, tal critério de erro não é tão claro. Com o intuito de obter uma *proxy* de volatilidade, optou-se, no caso do NN, pelo uso do erro padrão da regressão em [2.9], o qual é dividido por P_{it} para que todos os erros padrões fiquem na mesma unidade, permitindo a

comparação realizada pela Equação [2.12]¹¹. Portanto, para o caso do NN, a volatilidade

prevista em $t+1$ será dada por $\hat{\sigma}_{it+1}^{NN} = \frac{\sqrt{\sum_{r=1}^k \mathcal{E}_r^2}}{P_{it}}$.

2.3 Cálculo e Avaliação dos Retornos das Estratégias

Ao se obter o retorno de uma estratégia, é necessário compará-lo com um *benchmark* e levar em consideração, também, os custos de transação envolvidos. Por exemplo, uma estratégia apresenta um retorno de 50%, o qual pode parecer relativamente satisfatório em uma primeira análise, porém se o ativo objeto ou o mercado rendeu em média 70%, então a performance de tal estratégia foi fraca, uma vez que uma alternativa ingênua de *buy&hold* obteve melhor retorno.

Existem diferentes abordagens para comparar uma determinada estratégia com uma alternativa ingênua. A mais simples de todas é simplesmente construir uma carteira *benchmark* e verificar seu total retorno no período do estudo, comparando com o retorno obtido na estratégia. Outra forma, certamente mais complexa que a primeira, é gerar sinais aleatórios de entradas no mercado um número n de vezes e verificar quanto do retorno proveniente dos dados pode ser devido ao simples acaso. Tal método é denominado simulação *bootstrap*.

Outro ponto no sentido de avaliação dos retornos é a verificação do potencial das estratégias em relação ao risco sistemático que as mesmas estão submetidas, ou seja, verificar se, filtrando os movimentos sistemáticos do mercado da análise, a gestão da carteira consegue produzir, em média, retornos positivos constantes. Tal informação é obtida pelo teste de significância do alpha de Jensen. Os diferentes métodos de avaliação dos retornos das estratégias serão detalhados a seguir.

¹¹ Para o caso do algoritmo NN, a modelagem é realizada na série de preços dos ativos, portanto, os erros estão em unidades diferentes. Por exemplo, a unidade do erro de modelagem de uma ação que tenha preço histórico perto de 100 R\$ é diferente do que em relação a um preço histórico perto de 10 R\$. Devido a isso, é necessária a padronização dos dados.

2.3.1 Cálculo dos Retornos Excessivos

Para o caso da construção da estratégia *benchmark*, devido ao fato de que as estratégias 1 e 2 são fundamentalmente diferentes, então é necessário adaptar as fórmulas de cálculo dos retornos excessivos apresentadas em Fernández -Rodriguez et al (2001).

Para o cálculo do retorno da estratégia 1 para a ação i , utiliza-se a Equação [2.13], mostrada a seguir.

$$R_{E1i} = \sum_{t=1}^T R_{it} I_{bit} + n_i \ln\left(\frac{1-C}{1+C}\right) \quad [2.13]$$

Onde:

I_{bit} - Variável *dummy* que toma valor 1 (um) quando for gerado um sinal de compra para a ação i no tempo t e 0 (zero) caso contrário.

R_{it} - Rendimento real do ativo i no tempo t , calculado pela fórmula $\ln\left(\frac{P_t}{P_{t-1}}\right)$.

n_i - Número de transações.

C - Custo de transação (*one way transaction cost*) definido em porcentagem. Para a presente pesquisa o valor será de 0.15% por operação¹².

O entendimento da Equação [2.13] é intuitivo, toda vez que a estratégia 1 gerar um sinal de entrada no mercado, $I_{bt} = 1$, computa-se o lucro/prejuízo como sendo o rendimento efetivo do ativo objeto no tempo t . O termo $\ln\left(\frac{1-C}{1+C}\right)$ indica o custo de transação envolvido em uma operação. Por exemplo, se um investidor comprar uma ação no mercado por VC

¹² Tal valor de custo por operação é facilmente atingido para o mercado acionário brasileiro. Uma breve pesquisa mostra que diversas corretoras trabalham com custos fixos de 10-15 R\$ por compra e venda, portanto, com um montante relativamente pequeno de 10.000 R\$ já é possível atingir os custos de transação simulados na presente pesquisa.

(valor de compra) e vender por VV (valor de venda), ele pagará o valor real de $VC(1+C)$ e venderá a mesma por $VV(1-C)$. Portanto, o retorno logarítmico dessa ilustrativa operação será $\ln\left(\frac{VV(1-C)}{VC(1+C)}\right)$. Utilizando as propriedades do operador de logaritmo na equação anterior, temos que o lucro total dessa fictícia operação é dado por $\ln\left(\frac{VV}{VC}\right) + \ln\left(\frac{1-C}{1+C}\right)$.

Deste modo, sabendo que C é uma constante, o termo $n_i \ln\left(\frac{1-C}{1+C}\right)$ da Equação [2.13] indicará o custo total envolvido em n transações com a ação i . Devido ao fato que $\frac{1-C}{1+C}$ é sempre menor que 1 (um), então o termo $n_i \ln\left(\frac{1-C}{1+C}\right)$ será sempre negativo, isto é, os custos envolvidos em n transações serão diminuídos dos retornos das estratégias, o que é um resultado intuitivo.

Para a estratégia 2, tomando-se como base a Equação [2.13], modifica-se o cálculo do retorno, de modo que o mesmo seja coerente com a dinâmica da estratégia. A seguir, Equação [2.14], apresenta-se a fórmula.

$$R_{E2} = \sum_{i=1}^n \left[\sum_{t=1}^T (R_{it} I_{bit}) \right] + n_T \ln\left(\frac{1-C}{1+C}\right) \quad [2.14]$$

Devido ao fato que a estratégia 2 gera sinais de compra para diferentes ativos, então a Equação [2.13] não é coerente para calcular o retorno de tal estratégia. A modificação se deu no termo $\sum_{i=1}^n \sum_{t=1}^T R_{it} I_{bit}$. O último calculará o retorno “puro” da estratégia, isto é, somará os somatórios da multiplicação entre os retornos efetivos dos ativos e as variáveis *dummy* que geram ou não os sinais de compra para cada ação em cada tempo t . Para a Equação [2.14], o termo n_T indica o número total de transações realizadas pela estratégia.

Para comparar os retornos das estratégias, será utilizado um retorno *benchmark* dado pelas Equações [2.15] e [2.16], mostradas a seguir.

$$R_{B1i} = P_i \sum_{t=1}^T R_{it} + \ln\left(\frac{1-C}{1+C}\right) \quad [2.15]$$

A Equação [2.15] possui como objetivo calcular os retornos *benchmark* para a estratégia 1, onde o símbolo P_i é proporção dos dias em que a estratégias gerou sinais de compra (entrada no mercado).

Para estratégia 2, também teve que ser feita uma modificação em relação ao retorno *benchmark*. A seguir, Equação [2.16], apresenta-se a fórmula.

$$R_{B2} = \sum_{i=1}^n \left[P_i \sum_{t=1}^T R_{it} \right] + \ln\left(\frac{1-C}{1+C}\right) \quad [2.16]$$

A principal diferença entre [2.15] e [2.16] é que, para a estratégia 2, o retorno *benchmark* será dado pela soma da multiplicação entre P_i e $\sum_{t=1}^T R_{it}$, ou seja, o retorno *benchmark* levará em consideração o tempo que a estratégia passou em cada ativo. Claramente tal abordagem é mais completa do que a simples análise comparativa com um índice qualquer de mercado, uma vez que se está utilizando as características dos próprios ativos envolvidos na estratégia para calcular os retornos da estratégia ingênua.

Os retornos excessivos da estratégia 1, para cada ativo, serão dados pela diferença entre Equação [2.13] e [2.15]. Para a estratégia 2, tal cálculo será realizado pela diferença entre [2.14] e [2.16].

2.3.2 Comparação do Desempenho em Relação a Investidores Aleatórios

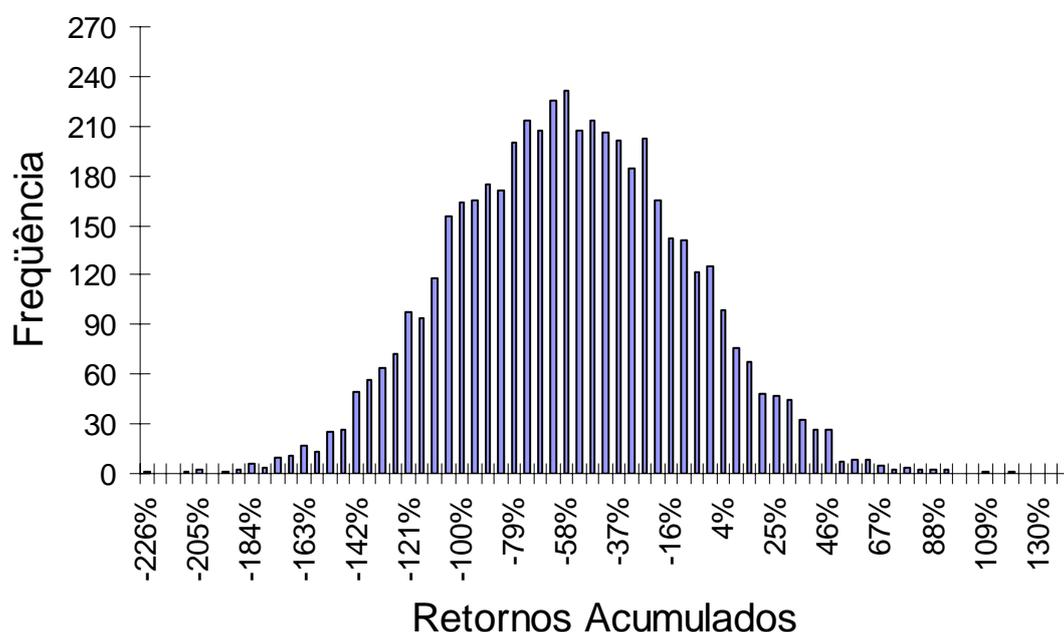
Uma das análises a ser perseguida para complementar o uso de retornos *benchmarks* é a verificação do desempenho das estratégias em relação a investidores sem técnica alguma, isto é, a simulação de caminhos aleatórios de investimentos (Burns, 2006). É importante observar que o algoritmo destacado em Burns (2006) é diferente do algoritmo utilizado na

presente pesquisa. No trabalho de tal autor, foram utilizadas carteiras randômicas para verificar o potencial das estratégias, porém nas estratégias testadas aqui, não são utilizadas carteiras com diferentes pesos para os ativos, mas sim o investimento total em apenas um ativo, para cada tempo t . Tal procedimento aproxima-se da realidade das estratégias testadas na presente pesquisa, o que justifica a respectiva abordagem utilizada. Devido a isso, foi necessário adaptar a rotina desenvolvida pelo respectivo autor. Os passos são os seguintes:

1. Formar um caminho aleatório de investimento para um número m de transações, onde o valor de m deve igualar ao número de dias em que a respectiva estratégia testada produziu um sinal de compra. Para a estratégia 1, a simulação somente ocorre dentro do ativo em questão, porém para a estratégia 2, tal construção utiliza, naturalmente, todos os papéis pesquisados.
2. Somar todos os retornos obtidos com o caminho realizado no passo 1, diminuir os custos de transação e salvar tal resultado.
3. Repetir passos 1 e 2 n vezes.

O resultado dos passos destacados anteriormente será um vetor com n valores referentes à riqueza total de n caminhos aleatórios simulados. A seguir, Figura 2, apresenta-se o histograma de ganhos em um total de 5.000 caminhos aleatórios simulados para todos os ativos utilizados na pesquisa com $C=0.15\%$.

Figura 2 – Histograma dos Retornos Obtidos em 5.000 Simulações com $C=0.15\%$



Conforme pode ser visto na Figura 2, o ganho médio dos caminhos aleatórios gerados seria de, aproximadamente, -58%, isto é, apesar do bom desempenho do mercado financeiro no período estudado, um investidor sem técnica alguma iria ganhar, em média, um retorno negativo.

O próximo passo no uso das simulações aleatórias para analisar o desempenho de uma estratégia é verificar o percentual de caminhos aleatórios que ficaram abaixo da estratégia testada. Por exemplo, caso uma estratégia apresente retorno acumulado, após custos de transação, de -10%, então tal estratégia possui, utilizando os dados da Figura 2, um total de 93.32 % de caminhos com retorno total inferior, isto é, o desempenho da respectiva estratégia, apesar de ser negativo, não pode ser devido ao simples acaso.

2.3.3 Avaliação dos Retornos considerando Risco Sistemático (alpha de Jensen)

O uso do alpha de Jensen é comumente utilizado para verificar a performance de um gestor de carteira em relação ao risco sistemático que o mesmo está sujeito, porém o mesmo pode, naturalmente, ser estendido para a avaliação de uma estratégia de negociação.

O método tem como base o modelo de precificação CAPM, Sharpe (1964), e consiste em estimar uma regressão linear entre os retornos da estratégia com os retornos do mercado, conforme Equação [2.17].

$$R_{Et} + \ln\left(\frac{1-C}{1+C}\right) = \alpha_E + \beta_E R_{Mt} + \varepsilon_t \quad [2.17]$$

Na Equação [2.17], o termo R_{Et} é o retorno da estratégia (seja ela a 1 ou 2) no tempo t , a constante $\ln\left(\frac{1-C}{1+C}\right)$ denota o custo de transação no tempo t , conforme destacado anteriormente, a variável R_{Mt} é o retorno da carteira de mercado, nesse caso o Ibovespa, no tempo t e os termos α_E e β_E são, respectivamente, o alpha de Jensen e o beta (coeficiente de risco sistemático) da estratégia.

Analisando [2.17], se α_E mostrar-se positivo e significativo, então a respectiva estratégia analisada conseguiu produzir um retorno constante e positivo após o filtro dos movimentos sistemáticos do mercado. Tal encontro indica evidências positivas a respeito do desempenho da estratégia. Portanto, essa investigação estatística será realizada através da observação do sinal e do teste t do coeficiente α_E da Equação [2.17].

3. Resultados Obtidos

A apresentação dos resultados da pesquisa é dividida em duas partes; a primeira parte retém, para cada tipo de modelagem, os resultados a respeito da estratégia 1 (*timing strategy*) enquanto a segunda explora os resultados obtidos com a estratégia 2 (*arbitrage strategy*).

3.1 Estratégia 1 (*Timing Strategy*)

Neste tópico serão apresentados os resultados obtidos na execução das regras de negociação da estratégia 1, tanto para os modelos NN quanto para os modelos ARIMA&GARCH.

3.1.1 Resultados para o Algoritmo NN

A seguir, na Tabela 2, apresenta-se os resultados da pesquisa referentes ao uso do algoritmo NN na estratégia 1. É importante lembrar que todas as estratégias foram testadas com $C=0.15\%$.

Tabela 2 – Resultados para Estratégia 1 com Algoritmo NN

Código na Bolsa	Retornos Excessivos					Alpha Jensen		Simulação***
	2003		2004		2003-2004	Valor	Prob.	% Ret. Inf.
	1º Sem.	2º Sem.	1º Sem.	2º Sem.				
TNLP4	-34.78%	1.90%	-19.79%	-7.55%	-60.22%	-0.005	0.00%	15.50%
PETR4	-14.83%	-2.17%	2.42%	-13.22%	-27.80%	-0.002	1.93%	58.40%
EBTP4	-16.67%	-34.23%	13.33%	7.23%	-30.33%	-0.003	25.69%	68.30%
BBDC4	-34.33%	10.24%	-9.58%	12.71%	-20.96%	-0.002	3.04%	63.30%
TSPC6	17.63%	-13.35%	-26.10%	-7.62%	-29.43%	-0.004	0.64%	60.70%
VALE5	3.19%	-11.40%	-23.54%	-17.03%	-48.79%	-0.003	1.34%	16.80%
ELET6	17.13%	-3.42%	-41.24%	-3.75%	-31.28%	-0.004	1.40%	55.50%
USIM5	-13.18%	-14.99%	-13.44%	-11.58%	-53.19%	0.001	55.07%	17.00%
ITAU4	-14.14%	-6.72%	-3.05%	-0.92%	-24.83%	-0.003	0.36%	54.20%
CMIG4	-23.27%	-6.98%	-1.24%	-4.93%	-36.41%	-0.003	1.75%	46.50%
CSNA3	-13.87%	5.57%	-24.71%	-1.81%	-34.82%	-0.001	26.91%	30.30%
BRT04	-18.42%	4.72%	-2.82%	14.93%	-1.59%	-0.004	0.29%	89.20%
GGBR4	-10.42%	8.22%	-6.44%	-5.95%	-14.60%	-0.001	35.29%	72.40%
AMBV4	-16.97%	-16.60%	7.64%	-15.61%	-41.53%	-0.003	1.50%	29.90%
BRTP4	-11.41%	-5.49%	-13.82%	-1.16%	-31.88%	-0.003	11.68%	51.00%
TMAR5	7.12%	-20.77%	-9.31%	-12.06%	-35.03%	-0.005	0.00%	50.20%
NETC4	-24.07%	-15.24%	-0.93%	3.96%	-36.29%	-0.004	36.71%	52.20%
TMCP4	-17.25%	2.93%	-23.84%	-19.73%	-57.89%	-0.005	0.48%	16.50%
TMAR3	-24.28%	-12.64%	3.66%	7.12%	-26.13%	-0.003	0.38%	56.60%
CPLE6	-16.34%	-22.60%	0.03%	-8.59%	-47.50%	-0.005	0.90%	35.10%
ITSA4	-15.74%	-15.71%	-19.37%	-17.03%	-67.85%	-0.003	0.05%	1.10%
CMET3	-8.12%	-4.90%	-11.33%	1.53%	-22.82%	-0.003	1.64%	4.40%
SBSP3	-5.35%	-13.64%	7.67%	-3.41%	-14.72%	-0.003	1.97%	74.80%
ACES4	4.96%	-15.78%	14.27%	3.69%	7.13%	-0.002	14.08%	88.60%
TMCP4	5.87%	-16.55%	-21.19%	-19.23%	-51.10%	-0.004	1.47%	29.60%
CSTB4	-2.34%	5.25%	-9.94%	20.44%	13.41%	-0.001	53.97%	6.30%
BRKM5	-15.71%	1.12%	3.61%	2.00%	-8.97%	0.000	84.84%	69.10%
TCSL4	9.88%	-13.21%	1.70%	1.36%	-0.27%	-0.002	14.67%	86.00%
VCPA4	-0.71%	-11.85%	-29.07%	-9.34%	-50.96%	-0.003	1.16%	16.90%
ARCZ6	-23.45%	-36.76%	-4.40%	-26.06%	-90.67%	-0.005	0.04%	0.30%
BBAS3	22.87%	-19.42%	-16.38%	-9.03%	-21.96%	-0.002	8.35%	46.60%
ELPL4	-5.33%	-15.98%	-11.85%	-5.23%	-38.40%	0.000	84.37%	53.10%
CRTP5	11.64%	-9.33%	-2.73%	-8.03%	-8.45%	-0.003	4.27%	81.90%
TLPP4	-6.31%	-14.47%	-8.94%	-9.63%	-39.35%	-0.003	4.69%	30.90%
CLSC6	9.34%	3.32%	5.07%	-18.33%	-0.59%	-0.003	5.58%	79.10%
CRUZ3	-21.94%	-5.59%	-25.10%	1.57%	-51.07%	-0.003	1.49%	16.40%
BRAP4	27.78%	0.30%	-20.82%	-13.69%	-6.43%	-0.001	43.83%	66.40%
SDIA4	-11.32%	-22.39%	-12.14%	-32.64%	-78.48%	-0.001	26.90%	44.10%
GOAU4	1.65%	-7.02%	-9.45%	-8.36%	-23.18%	-0.001	38.93%	47.30%
CESP5	-41.52%	-3.30%	-26.33%	2.06%	-69.10%	-0.004	9.58%	26.60%
Média	-8.08%	-9.22%	-9.74%	-5.82%	-32.86%	-0.003	15.18%	45.23%
Desvio Padrão	15.91%	10.74%	12.70%	10.86%	23.40%	0.001	22.64%	25.73%
Máximo	27.78%	10.24%	14.27%	20.44%	13.41%	0.001	84.84%	89.20%
Mínimo	-41.52%	-36.76%	-41.24%	-32.64%	-90.67%	-0.005	0.00%	0.30%

* Valor positivo e estatisticamente significativo a 5%.

** Valor positivo e estatisticamente significativo a 1%.

*** Na simulação *bootstrap* foram gerados 5.000 caminhos aleatórios para o mesmo ativo com $C=0.15\%$ e sempre igualando o número de sinais de compra na simulação com o real de cada ativo.

Analisando-se os valores de retornos da Tabela 2, pode-se observar que os resultados para os modelos NN indicam baixa performance deste, com um total de 72.5% dos valores para o primeiro e segundo semestre de 2003 e 2004 como retornos excessivos negativos. Para o caso dos alphas de Jensen, é possível ver que grande maioria são negativos. Os poucos alphas positivos não apresentaram significância estatística. Para o caso das simulações, os resultados foram mistos, onde 20 dos 40 ativos apresentaram percentagens menores que 50%. Ou seja, para esses casos, gerar entradas aleatórias no mercado é mais lucrativo que utilizar o algoritmo NN, dentro do método proposto. O melhor caso da Tabela 2 é para a Ação ACES4, apresentando um retorno excessivo positivo de 7.13% e situando-se acima de 88.6% dos caminhos aleatórios gerados.

A conclusão retirada da análise da Tabela 2 é de que, para a estratégia 1, o algoritmo NN atingiu um desempenho relativamente baixo, conforme pode ser visto nos retornos excessivos negativos e alphas também negativos. Este resultado não corrobora os resultados apresentados em Perlin (2006), porém é importante observar que, no trabalho do autor, foram testadas diferentes combinações dos parâmetros do algoritmo e o período de treinamento disponível era maior. Tal abordagem não foi realizada na pesquisa, uma vez que o número de ativos utilizados é 8 vezes maior e o número de observações é 4 vezes maior, ou seja, a presente pesquisa possui 32 vezes mais observações que o estudo de Perlin (2006), o que, conseqüentemente, devido ao tempo necessário para calcular as previsões, forçou a simplificação nos parâmetros do modelo NN.

3.1.2 Resultados para os modelos ARIMA&GARCH

A seguir, na Tabela 3, apresenta-se os resultados obtidos com a estratégia 1 com base nos modelos ARIMA&GARCH.

Tabela 3 – Resultados para Estratégia 1 com Modelos ARIMA&GARCH

Ativos	Retornos Excessivos					Alpha Jensen		Simulação
	2003		2004		2003-2004	Valor	Prob.	% Ret. Inf.
	1º Sem.	2º Sem.	1º Sem.	2º Sem.				
TNLP4	-4.26%	-10.01%	13.45%	12.67%	11.84%	-0.001	26.99%	99.66%
PETR4	14.14%	9.76%	10.88%	6.40%	41.18%	0.001	11.57%	100.00%
EBTP4	24.01%	19.72%	29.95%	40.53%	114.21%	0.001	47.93%	100.00%
BBDC4	-14.64%	18.51%	7.20%	20.68%	31.74%	0.002	4.20%*	100.00%
TSPC6	19.71%	11.37%	5.56%	18.51%	55.16%	0.002	19.06%	99.94%
VALE5	16.53%	-6.19%	21.66%	-1.48%	30.52%	0.003	1.38%*	99.98%
ELET6	11.96%	35.08%	31.31%	53.05%	131.40%	0.002	27.66%	100.00%
USIM5	31.82%	58.07%	43.36%	9.48%	142.72%	0.006	0.00%**	100.00%
ITAU4	8.23%	14.17%	-10.43%	6.48%	18.45%	0.002	0.97%**	99.92%
CMIG4	12.79%	30.09%	19.60%	29.19%	91.67%	0.002	3.36%*	100.00%
CSNA3	17.89%	11.56%	-4.89%	28.68%	53.24%	0.003	0.38%**	100.00%
BRT04	-7.76%	33.95%	37.92%	5.69%	69.80%	0.001	45.44%	100.00%
GGBR4	13.65%	24.05%	-5.82%	-8.59%	23.29%	0.002	3.63%*	99.72%
AMBV4	1.46%	11.46%	13.52%	7.37%	33.81%	0.003	1.64%*	99.98%
BRTP4	9.06%	29.23%	1.51%	15.23%	55.03%	0.004	2.47%*	99.98%
TMAR5	17.98%	18.88%	-13.85%	16.10%	39.11%	0.000	65.89%	99.98%
NETC4	41.07%	112.61%	5.03%	44.49%	203.21%	0.009	2.30%*	100.00%
TMCP4	21.78%	31.56%	-6.37%	19.21%	66.19%	0.002	18.84%	99.98%
TMAR3	-13.99%	27.39%	1.94%	4.42%	19.76%	0.000	83.79%	99.56%
CPLE6	-3.28%	10.51%	-25.77%	11.82%	-6.72%	-0.001	51.51%	15.34%
ITSA4	9.39%	15.19%	-14.40%	6.11%	16.29%	0.003	0.14%**	99.94%
CMET3	-4.80%	13.95%	25.88%	12.39%	47.41%	0.005	0.01%**	100.00%
SBSP3	5.73%	2.89%	11.16%	-10.23%	9.55%	0.001	29.85%	99.26%
ACES4	36.07%	11.22%	-12.92%	33.40%	67.77%	0.004	0.17%**	99.98%
TMCP4	12.33%	5.85%	21.02%	24.42%	63.62%	0.002	21.10%	100.00%
CSTB4	3.41%	12.80%	20.74%	15.84%	52.79%	0.004	0.06%**	100.00%
BRKM5	-25.45%	22.35%	-1.83%	-4.08%	-9.02%	0.003	1.85%*	95.98%
TCSL4	34.33%	19.61%	40.08%	11.03%	105.05%	0.002	13.76%	100.00%
VCPA4	-3.42%	10.68%	-4.71%	8.21%	10.76%	0.002	13.18%	99.98%
ARCZ6	19.28%	10.97%	10.32%	10.85%	51.42%	0.004	0.12%**	100.00%
BBAS3	29.29%	34.68%	-20.01%	15.34%	59.30%	0.004	0.14%**	100.00%
ELPL4	-25.29%	8.23%	1.06%	37.25%	21.25%	0.001	48.34%	98.04%
CRTP5	27.18%	-2.92%	45.66%	5.83%	75.75%	0.002	5.13%	100.00%
TLPP4	-2.33%	24.52%	13.81%	19.97%	55.96%	0.003	0.79%**	99.98%
CLSC6	-7.56%	-0.07%	33.73%	23.69%	49.79%	0.004	4.79%*	99.92%
CRUZ3	-0.82%	15.37%	16.31%	6.61%	37.48%	0.004	0.06%**	100.00%
BRAP4	38.24%	2.39%	-2.96%	29.12%	66.79%	0.005	0.12%*	100.00%
SDIA4	9.82%	15.88%	11.08%	10.87%	47.66%	0.005	0.00%**	100.00%
GOAU4	-21.13%	18.83%	13.34%	-15.46%	-4.41%	0.003	0.02%**	98.70%
CESP5	10.60%	11.97%	13.37%	17.68%	53.61%	-0.001	74.91%	99.78%
Média	9.08%	18.65%	9.91%	14.97%	52.61%	0.003	15.84%	97.64%
Desvio Padrão	17.05%	19.86%	17.63%	14.50%	42.32%	0.002	22.90%	13.37%
Máximo	41.07%	112.61%	45.66%	53.05%	203.21%	0.009	83.79%	100.00%
Mínimo	-25.45%	-10.01%	-25.77%	-15.46%	-9.02%	-0.001	0.00%	15.34%

* Valor positivo e estatisticamente significativo a 5%.

** Valor positivo e estatisticamente significativo a 1%.

*** Na simulação *bootstrap* foram gerados 10.000 caminhos aleatórios para o mesmo ativo com $C=0.15\%$ e sempre igualando o número de sinais de compra na simulação com o real de cada ativo.

Analisando-se os valores na Tabela 3, pode-se observar que os retornos excessivos são, em maior parte, positivos. Aproximadamente 79% dos retornos semestrais são positivos, indicando que, para a maioria dos casos, a estratégia de *timing* conseguiu obter retorno superior à estratégia ingênua (*buy&hold*) nos subperíodos analisados.

Continuando a análise da Tabela 3, pode-se verificar que os resultados também mantiveram certa consistência, onde 37.5% dos ativos apresentaram retornos excessivos positivos nos 4 semestres pesquisados, 42.5% das ações apresentaram retornos positivos em 3 semestres, 17.5 % com retornos excessivos positivos em 2 semestres e apenas 2.5% dos papéis apresentou retorno excessivo positivo somente em um semestre. Tal informação sugere que, dentro de um custo de transação a 0.15% por operação, uma estratégia baseada na construção de modelos ARIMA&GARCH dentro da metodologia utilizada, pode gerar lucros excessivos positivos no futuro.

Para o caso da análise do alpha de Jensen, Tabela 3, pode-se verificar que, do total de ativos analisados, 57.5 % apresentou coeficiente positivo e estatisticamente significativo, ou seja, a estratégia de *timing* conseguiu obter, em média, um retorno constante e positivo após o filtro dos movimentos sistemáticos do mercado, o que, também, indica bom desempenho da estratégia.

Do ponto de vista de simulações de investimentos, também se verifica resultados positivos em relação ao desempenho das estratégias com base em modelos ARIMA&GARCH, isto é, a grande maioria dos retornos obtidos foram superiores a 95% dos caminhos aleatórios gerados. O único caso em que o retorno obtido pela estratégia ficou abaixo dos 95% foi para a ação CPLE6, cuja fraca performance também é confirmada no respectivo baixo retorno excessivo e alphas negativos. Este, porém, é um caso isolado perto da totalidade dos resultados.

3.2 Estratégia 2 (Arbitrage Strategy)

Nos próximos tópicos serão apresentados os resultados da pesquisa na execução da estratégia 2, tanto para o algoritmo NN quanto para a modelagem ARIMA&GARCH.

3.2.1 Resultados para o Algoritmo NN

A seguir, Tabela 4, apresentam-se os resultados da estratégia 2 utilizando-se como base as previsões de média e volatilidade realizadas pelo algoritmo NN.

Tabela 4 – Resultados para Estratégia 2 com o Algoritmo NN

Resultados	2003		2004		2003-2004
	1º Semestre	2º Semestre	1º Semestre	2º Semestre	
Retorno Puro	41.28%	59.63%	-27.85%	67.35%	140.41%
Custos de Transação	-36.60%	-38.40%	-37.20%	-37.50%	-149.70%
Retorno Estratégia Ingênua	20.69%	77.14%	5.66%	48.84%	152.32%
<u>Retorno Excessivo Total</u>	-16.01%	-55.90%	-70.71%	-18.99%	-161.62%
<u>Alpha de Jensen</u>					
Valor	-0.04%	-0.08%	-0.49%	0.11%	-0.14%
Prob.	84.36%	67.58%	1.87%**	46.06%	11.33%
<u>Beta (Risco Sistemático)</u>					
Valor	0.66	0.57	0.80	0.78	0.73
Prob.	0.00%***	0.00%***	0.00%***	0.00%***	0.00%***
<u>Simulação Bootstrap*</u>					
% de inferiores	89.54%	49.04%	16.98%	98.72%	85.80%

* Na simulação Bootstrap foram criados 5.000 caminhos aleatórios de investimentos com $C=0.15$ %

** Significativo a 5%

*** Significativo a 1%

Na Tabela 4, analisando-se os valores de retornos excessivos nos subperíodos e no período total, é evidente a fraca performance da respectiva estratégia em relação a uma alternativa ingênua de *buy&hold*, uma vez que todos os valores de retornos excessivos são negativos. Para o caso dos alphas, também pode-se observar valores negativos, os quais também inferem o fraco desempenho da modelagem NN nas estratégias de arbitragem.

Do ponto de vista de comparação com carteiras randômicas, os resultados obtidos são mais positivos. Por exemplo, para o segundo semestre de 2004, a percentagem de caminhos aleatórios com retorno inferior ao da estratégia é de 98.72 %, indicando que o caminho desenhado pela modelagem NN foi muito superior ao desempenho médio de um investidor sem técnica alguma. Tal informação também é confirmada para o período total, com uma percentagem de 85.80%. O pior caso foi para o primeiro semestre de 2004, onde é visualizado uma percentagem de 16.98 %, indicando que 83.02 % dos caminhos randômicos obtiveram retorno acumulado maior que o da estratégia para o respectivo período.

Apesar do resultado positivo para as simulações realizadas, os demais testes indicam fraca performance da estratégia 2 baseada no algoritmo NN. Podem ser levantadas duas possíveis causas para o fracasso de tal abordagem. Uma possível razão foi o uso de uma *proxy* para volatilidade em modelos NN, a qual pode não representar o índice que se está procurando. Outro fator foi na simplificação necessária realizada nos parâmetros do modelo, onde foi utilizado o Ibovespa para selecionar os valores de m e k dos outros ativos. Ambas as possibilidades devem ser levadas em conta nos resultados da pesquisa para o algoritmo NN.

3.2.2 Resultados para os modelos ARIMA&GARCH

A seguir, na Tabela 5, são apresentados os resultados obtidos com a execução da estratégia 2 baseada nos modelos ARIMA&GARCH.

Tabela 5 – Resultados para Estratégia 2 com Modelos ARIMA&GARCH

Resultados	2003		2004		2003-2004
	1º Semestre	2º Semestre	1º Semestre	2º Semestre	
Retorno Puro	131.79%	207.60%	108.68%	129.83%	577.90%
Custos de Transação	-36.60%	-38.48%	-37.20%	-37.50%	-149.78%
Retorno Estratégia Ingênua	16.23%	69.20%	-3.26%	31.36%	113.53%
<u>Retorno Excessivo Total</u>	79.0%	99.9%	74.7%	61.0%	314.59%
<u>Alpha de Jensen</u>					
Valor	0.672%	0.935%	0.623%	0.523%	0.6762%
Prob.	0.073%***	0.040%***	0.047%***	0.219%***	0.000%***
<u>Beta (Risco Sistemático)</u>					
Valor	0.94	0.92	1.14	1.26	1.08
Prob.	0.00%***	0.00%***	0.00%***	0.00%***	0.00%***
<u>Simulação BootStrap*</u>					
% de inferiores	100.00%	100.00%	100.00%	100.00%	100.00%

* Na simulação Bootstrap foram criados 5.000 caminhos aleatórios de investimentos com $C=0.15$ %

** Significativo a 5%

*** Significativo a 1%

Analisando-se os valores da Tabela 5, é possível visualizar que a estratégia de arbitragem utilizando os modelos ARIMA&GARCH obteve retornos excessivos positivos em todos os casos. Outro ponto importante a ser observado é a magnitude dos retornos excessivos obtidos, os quais também indicam a relativa superioridade da estratégia em relação à uma estratégia ingênua. Dentre os semestres analisados, o máximo atingido foi no segundo semestre de 2003, onde a estratégia atingiu o valor de 99.9 % de retorno excessivo. Nesse mesmo período, a estratégia ingênua resultou em 69.20%, enquanto o retorno semi-puro (tirando apenas os custos de transação) foi de 169.12 %.

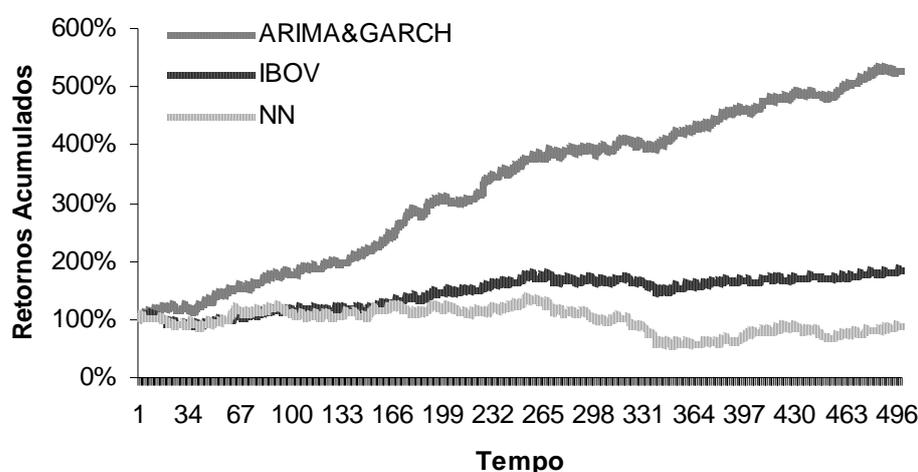
Para o caso dos alphas de Jensen, Tabela 5, pode-se observar que todos são positivos e significantes estatisticamente a 1%, indicando que, filtrando os movimentos do mercado, a respectiva estratégia conseguiu obter, em média, um retorno constante e positivo para cada tempo t . Tal desempenho positivo é suportado, também, pelas simulações realizadas, onde todos os subperíodos apresentaram percentagens maiores que 100 %, ou seja, nenhum dos 5.000 caminhos simulados obteve retorno total maior que o da respectiva estratégia.

Os resultados apresentados na Tabela 5 indicam a presença de evidências contrárias à hipótese de eficiência de mercado para o caso brasileiro, uma vez que foi possível gerar retornos excessivos e significantes baseando-se, apenas, em informações passadas, mais especificamente retornos históricos dos ativos.

É importante lembrar que o período analisado na pesquisa foi extremamente positivo para o desempenho do mercado brasileiro. Portanto, o retorno obtido pela estratégia simplesmente potencializou o desempenho geral da economia através da escolha inteligente dos investimentos. Conforme pode ser visto na Tabela 5, os betas são todos significantes a 1% e ligeiramente menores que 1 para os semestres de 2003, porém são significativamente maiores para o período de 2004, atingindo o valor de 1.13 para o primeiro semestre e 1.26 para o segundo semestre. Tal informação indica que, apesar da estratégia 2 com modelos ARIMA&GARCH ser bastante lucrativa para o período analisado, ela possui, também, um risco sistemático maior que o do mercado (beta igual a 1), conforme pode ser visto no beta de 1.08 no período total analisado.

Para apreciação gráfica do desempenho da estratégia é mostrada a seguir a Figura 2, a qual ilustra os ganhos acumulados oriundos da estratégia ao longo dos 2 anos pesquisados.

Figura 3 – Retornos Acumulados para Estratégia 2



Para a Figura 3, é importante lembrar que os retornos visualizados são puros retirando apenas os custos de transação, isto é, não foram levados em consideração os retornos de uma estratégia ingênua de *buy&hold*. Fica claro de ver que a estratégia 2, quando aplicada com modelos ARIMA&GARCH, apresenta maiores lucros que a usual carteira de mercado (índice Bovespa), porém também fica saliente o comportamento compartilhado das séries, por exemplo, para meados da observação 311, onde ambas as séries apresentam um leve declínio simultâneo. Também fica claro o fraco desempenho dos modelos NN nessa mesma estratégia,

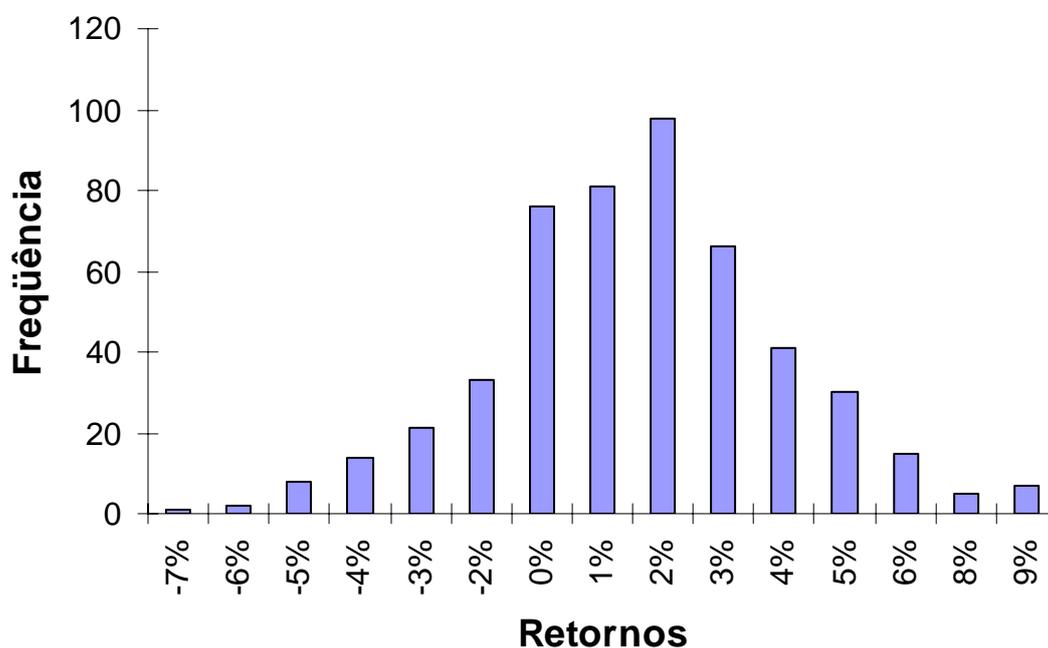
onde o respectivo retorno acumulado ficou abaixo da carteira de mercado em grande parte do período analisado.

Outro ponto a ser salientado na Figura 3 é que a distância entre as linhas ARIMA&GARCH e IBOV aumenta ao longo do tempo, ou seja, o desempenho superior da estratégia 2 na respectiva modelagem é consistente ao longo dos meses. Traduzindo para uma formulação quantitativa, uma regressão da linha IBOV no tempo indica um coeficiente angular de 0.0018 ou seja, dentro do período analisado, cada variação do tempo aumenta, em média, 0.18% no retorno acumulado do índice. Para a linha ARIMA&GARCH o coeficiente angular é de 0.9%, o que indica que sua variação ao longo do tempo é maior que da linha azul, em outras palavras, a distância entre as respectivas linhas analisadas tende a aumentar ao longo dos anos. Isto indica que, se ingenuamente extrapolarmos para o futuro as linhas mostradas na Figura 3, o retorno acumulado da estratégia será cada vez maior que o do Ibovespa.

Do ponto de vista de investimentos, analisando-se os valores da Figura 3, um montante de R\$ 10.000 R\$ investidos no início de 2003 se transformaria em R\$ 52.819,97 no final de 2004, ou seja, um lucro de R\$ 42.819,97. Portanto, a estratégia construída apresenta-se significativamente lucrativa para o período analisado.

No caso da análise dos retornos das ações, uma das preocupações é a abundante existência de valores outliers, os quais podem ofuscar uma análise objetiva dos lucros. Para fim de verificar tal possibilidade, a seguir, Figura 4, é mostrado o histograma dos respectivos retornos analisados.

Figura 4 - Histograma dos Retornos obtidos com Estratégia 2/ARIMA&GARCH



Verificando-se os valores da Figura 4, é possível afirmar que não existiu um preocupante número de retornos *outliers* na distribuição dos retornos provenientes da respectiva estratégia analisada. Tal informação sugere que os resultados positivos da pesquisa não podem ser devido a apenas observações anormais da amostra, o que ajuda na validação dos valores apresentados na Tabela 5. O cálculo da significância da média para os dados mostrados na Figura 4 indica um teste *t* igual a 6,743, isto é, uma probabilidade associada menor que 1%, o que também corrobora com os resultados da Tabela 5.

De um ponto de vista geral, é possível afirmar que a estratégia 2 produziu melhores resultados em relação à estratégia 1. Tal superioridade é intuitivamente respondida pelo fato de que a estratégia 2 é mais completa, uma vez que a mesma indica quando e aonde investir, enquanto a estratégia 1 apenas indica se vale a pena investir no tempo t , para um determinado ativo fixo. Dentre as classes de modelos testados, também é bastante claro que os modelos ARIMA&GARCH apresentaram melhor performance que o algoritmo de previsão *Nearest Neighbor*.

Devido ao fato que um custo de transação de 0.15% por operação é facilmente atingível para o mercado brasileiro, as evidências salientadas nesse trabalho motivam o uso de estratégia 2 baseada em modelos ARIMA&GARCH, dentro da metodologia sugerida, para operações reais no mercado acionário brasileiro.

4. Novos Caminhos para a Pesquisa

Para a pesquisa efetuada, procurou-se utilizar uma abordagem dinâmica a respeito dos modelos matemáticos executados. Porém inúmeras questões ainda podem ser levantadas na tentativa de otimizar e/ou estender a pesquisa. Para o caso dos modelos ARIMA&GARCH, os quais apresentaram os melhores resultados, segue abaixo algumas possibilidades.

- Foram utilizados termos GARCH para modelar a variância condicional dos retornos e um ARIMA para a média condicional. Existem modelos quantitativamente mais interessantes, por exemplo modelos de mudanças de regime, modelos de decomposição (Rydberg e Shephard, 1998), e modelagem de probabilidades (Hauseman, Lo e Mackinlay, 1992). É possível que tais modelos possam apresentar melhores resultados em estratégias de negociação.
- Dentro da pesquisa não foi verificado o potencial na construção de metodologias que possam ser integradas ao uso das ferramentas de transação disponíveis para qualquer *trader*, tal como *stop loss*. A utilização de tais ferramentas com base em alguma formulação quantitativa também parece um caminho interessante a ser verificado futuramente.
- Uma das premissas da pesquisa foi de que era possível comprar ou vender as ações pelos respectivos preços de fechamento dos pregões. Sabe-se que tal operação nem sempre é possível uma vez que existe um *spread* entre ofertas de compra e venda (*Bid and Ask prices*). Um possível exercício de simulação poderia mostrar a sensibilidade dos resultados da pesquisa em relação a este problema. Tal estudo não foi realizado no trabalho devido à falta de dados sobre as ofertas de compra e venda no final dos pregões no banco de dados utilizado, nesse caso o Economática.
- Os dados utilizados na pesquisa foram diários e limitados ao mercado brasileiro. Seria interessante, também, realizar a pesquisa proposta para dados de frequência maior (*intraday*) e/ou em outros mercados.

Comentários Finais

O objetivo da presente pesquisa foi verificar o potencial lucrativo de dois modelos matemáticos em estratégias de negociação. O primeiro deles foi o algoritmo *Nearest Neighbor*, o qual pode ser visto como uma *proxy* da parcela visual da análise técnica. O segundo modelo testado foi o difundido ARIMA&GARCH, dentro de uma abordagem dinâmica na seleção dos parâmetros. Para o caso das estratégias, foram utilizadas duas abordagens, a primeira foi uma estratégia de entrada e saída do mercado (*market timing*) e a segunda foi uma estratégia de arbitragem, a qual busca escolher qual ativo, dentre todos os disponíveis, investir a cada tempo t .

Para a avaliação dos retornos das estratégias, foi utilizada uma análise comparativa com os retornos de uma estratégia ingênua e também a verificação da significância do alpha de Jensen, o qual mostra a performance da estratégia após o filtro dos movimentos sistemáticos do mercado. Claramente o respectivo estudo efetuado pode ser considerado um teste de eficiência de mercado, uma vez que se buscou simular operações no mercado acionário brasileiro com base, apenas, nos retornos históricos de mercado.

Para o caso do algoritmo NN, os resultados obtidos foram pouco satisfatórios, onde a maioria dos testes, em ambas as estratégias, indicaram relativo baixo desempenho do método. Tal informação indica que uma abordagem ingênua de *buy&hold* pode obter melhor desempenho que o respectivo modelo testado. Tanto para a estratégia 1 quanto a 2, é importante lembrar as simplificações realizadas no método utilizado. É possível que a *proxy* de volatilidade para o NN não seja a mais realística e a simplificação na determinação dos parâmetros também pode ter sido uma das causas do fraco desempenho do método. Tais questões devem ser levadas em consideração nas conclusões obtidas com tal modelagem.

Para o caso dos modelos ARIMA&GARCH, foi verificado um forte retorno excessivo positivo em todos subperíodos analisados assim como também o encontro de alphas de Jensen positivos e estatisticamente significativos. Tais resultados obtidos com os testes indicam que o método é relevante para ser usado em estratégias de negociação, tanto a 1 quanto a 2.

Os resultados obtidos com estratégia 2 baseada em modelos ARIMA&GARCH indicam sinais de ineficiência para o mercado acionário brasileiro, uma vez que foi possível obter retornos excessivos positivos e significantes com base, apenas, na série histórica dos preços dos ativos.

Apesar dos resultados promissores das estratégias, ainda é importante salientar que a pesquisa teve uma forte premissa. Tal suposição foi a de que era possível, sempre, comprar e vender as ações pelo preço de fechamento. Sabe-se que isso nem sempre é possível devido ao *spread* entre as ofertas de compra e venda. A sensibilidade dos resultados da pesquisa em relação a tal questão não foi pesquisada devido à falta de dados sobre as ofertas de compra e venda no final do dia. Tal questão deve ser levada em conta nas conclusões retiradas sobre os resultados apresentados no presente trabalho.

Bibliografia

AKAIKE, H. A new look at the statistical model identification. *IEEE Transactions on Automatic Control*, v. 19, p. 716–723, 1974.

ALEXANDER, C., DIMITRIU, A. Regimes of Index Out-Performance: A Markov Switching Model of Index Dispersion. *ISMA Centre Discussion Papers in Finance 2003*, n. 02, 2003.

ALMEIDA, N., M., PEREIRA, P., V. Mudança de regime para séries financeiras: Um estudo empírico destes modelos para a realização de regras de mercado. Finance Lab Working Paper, n. 03, 2000.

AMADO, C. F. P., CARMONA, C. U. M. Eficiência dos Mercados Futuros: um Estudo Utilizando Testes de Cointegração para Commodities Agrícolas. Anais ENANPAD, 2003.

BAJO-RUBIO, O., SOSVILLA-RIVERO, S., FERNÁNDEZ-RODRÍGUEZ, F. Non-linear Forecasting Methods: Some applications to the analysis of Financial Series. *Working paper*, n. 1, FEDEA, 2002.

BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, ed. 31, p. 307-327, 1986.

BOX, G. E. P.; JENKINS, G. M. *Time Series Analysis: Forecasting and Control*. Holden-Day, 1976.

BROOKS, C., KATSARIS, A., PERSAND, G. Timing is Everything: A Comparison and Evaluation of Market Timing Strategies. *Working Paper*, Disponível em: <http://ssrn.com/abstract=834485>, 2005.

BRUNI, A. L., FAMÁ, R. Uma Análise da Eficiência Informacional do Mercado de ADRs Brasileiros com Base em Testes de Auto-Correlação, Raiz Unitária e Cointegração. Anais ENANPAD, 2003.

BUENO, A. F., BRAGA, R. F., ALMEIDA, R. J. Pesquisa sobre a Eficiência Informacional do Mercado Brasileiro nos Casos de Fusões e Aquisições. Anais ENANPAD, 2000.

BURNS, P. J., Random Portfolios for Evaluating Trading Strategies. Available at SSRN: <http://ssrn.com/abstract=881735>, 2006.

CAMPBELL, J. Y, LO, A. W., MACKINLAY, A. C. *The Econometrics of Financial Markets*. Princeton University Press, 1997.

CARVALHAL DA SILVA, A. L., RIBEIRO, T. L. Estimating and Forecasting Latin American Indexes Using Artificial Neural Networks. Proceedings of BALAS, 2002.

CERETTA, P. S. Eficiência no Mercado de Ações Latino-Americano: Contribuição da Teoria do Caos. Anais ENANPAD, 2003.

CHAN, W. H., KALIMIPALLI, M., SIVAKUMAR, R. The Economic Value of using Realized Volatility in the Index Options Market. *Working Paper*, Centre for Advanced Studies in Finance, University of Waterloo, 2006.

CHEN, A., LEUNG, M. T., DAOUK, H. Application of Neural Networks to an Emerging Financial Market: Forecasting and Trading the Taiwan Stock Index. *Computers & Operations Research*, v. 30, p. 901–923, 2003.

CLYDE, W. C., OSLER, C. L. Charting: Chaos Theory in Disguise? *Journal of Futures Markets*, agosto, v. 17, n. 5, p. 489-514, 1997.

DIMSON, E., MUSSAVIAN, M. A brief history of market efficiency. *European Financial Management*, v. 4, p. 91-193, 1998.

DOOLEY, M. P., SHAFER, J. Analysis of short-run exchange rate behavior: March 1973 to November 1981. *Exchange rates and trade instability: Causes, consequences and remedies*, Ballinger, Cambridge, 1983.

EFETKHARI, B. The Markov Regime Switching model as Trading Tool. *Working Paper*, University of Cambridge, 1997.

ENGLE, R. F. Autoregressive Conditional Heteroskedasticity with Estimates of the Variance of U.K. inflation. *Econometrica*, ed. 50, p. 987-1008, 1982.

FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, v. 25, n. 2, p. 383-417, Maio 1970.

FAMA, E., F. The behavior of Stock Market Prices. *The Journal of Business*. Janeiro, p. 34-105, 1964.

FAMA, E., FRENCH, K. The cross-section of expected stock returns. *Journal of Finance*, v. 47 (2), p. 427-465, 1992.

FARMER, D., SIDOROWICH, J. Predicting chaotic time series. *Physical Review Letters*, v. 59, p. 845-848, 1987.

FERNÁNDEZ-RODRÍGUEZ, F., SOSVILLA-RIVERO, S., GARCÍA-ARTILES, M. Using nearest neighbor predictors to forecast the Spanish Stock Market. *Investigaciones Económicas*, v. 21, p. 75-91, 1997.

FERNÁNDEZ-RODRÍGUEZ, F., SOSVILLA-RIVERO, S., GARCÍA-ARTILES, M. An empirical evaluation of non-linear trading rules. *Working paper*, n. 16, FEDEA, 2001.

GATEV, E., GOETZMANN, W. N., ROUWENHORST, K. G. Pairs Trading: Performance of a Relative Value Arbitrage Rule. *Working Paper*, Yale School of Management. Disponível em: <http://ssrn.com/abstract=141615>, 1999.

HAUSEMAN, J., LO, A., MACKINLAY, C. An Ordered Probit Analysis of Transaction Stock Prices. *Journal of Financial Economics*, 1992.

HSIEH, David A. Chaos and nonlinear dynamics: applications to financial markets. *The Journal of Finance*, v. 46, n.5, 1839-1877, dezembro 1991.

LO, A. W., MACKINLEY, A. C. A non random walk down Wall Street. *Princeton University Press*, Princeton, 1997a.

LO, A. W., MACKINLEY, A. C. Maximizing predictability in stock and bonds markets. *Macroeconomic Dynamics*, v. 1, p. 102-134, 1997b.

LO, A. W., MACKINLEY, A. C. Stock Market Prices do not follow random walks: Evidence from a simple specification test. *Review of Financial Studies*, v. 1, p. 41-66, 1988

LO, A. Foundations of Technical Analysis: Computational Algorithms Statistical Inference, and Empirical Implementation. *Journal of Finance*, n. 55, p. 1705-1765, 2000.

- MADDALA, G. S. Introduction to Econometrics. John Wiley & Sons, 2001.
- MANDELBROT, B. B. The (mis) Behavior of Financial Markets: A Fractal View of Risk, Ruin, and Reward. New York: Basic Books, 2004.
- MARKOWITZ, Harry M. Portfolio selection. *Journal of finance*, v. 7 p. 77-91, 1952.
- MORETIN, P. A., TOLOI, C. M. C. Análise de séries temporais. São Paulo: Edgard Blusher, 2004.
- MURPHY, J. Technical Analysis of the Financial Markets. New York Institute of Finance, 1999.
- PARK, C., IRWIN. The Profitability of Technical Analysis: A Review. AgMAS Project Research Report, n 04, 2004.
- PERLIN, M. S. ; CERETTA, P. S. . Teoria do Caos aplicada aos Contratos de Café no Mercado de Derivativos. READ - Revista Eletrônica da Administração, <http://read.adm.ufrgs.br/>, v. 11, n. 4, 2006.
- PERLIN, M. S. Non Parametric Modelling in Major Latin America Market Indexes: An Analysis of the Performance from the Nearest Neighbor Algorithm in Trading Strategies. BALAS Conference, Lima, Peru, 2006.
- PERLIN, M., S. Evaluation of Pairs Trading Strategy at the Brazilian Financial Market. Trabalho não publicado. Disponível em <http://ssrn.com/abstract=952242>, 2007.
- PEROBELLI, F. F. C, NESS, W. L. Reações do Mercado Acionário a Variações Inesperadas nos Lucros das Empresas: um Estudo sobre a Eficiência Informacional no Mercado Brasileiro. Anais ENANPAD, 2000.
- RYDBERG, T. H., SHEPHARD, N. Dynamics of trade-by-trade price movements: decomposition and models. Working Paper, Nuffield College, Oxford University, 1998.
- SAFFI, P. A. C. Análise Técnica - Sorte ou Realidade? Segundo Encontro Brasileiro de Finanças, 2002.
- SCHWARZ, G. Estimating the dimension of a model. *Annals of Statistics*, v. 6, p. 461-464, 1978.
- SHARPE, W. Capital Asset prices: A Theory of Market Equilibrium under conditions of Risk. *Journal of finance*, v. 19, p. 425-42, 1964.
- TSAY, R. S. Analysis of Financial Time Series. Wiley, 2002.
- VIDYAMURTHY, G. Pairs Trading: Quantitative Methods and Analysis. John Wiley & Sons, 2004.