

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS NATURAIS E EXATAS
CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA E
MODELAGEM QUANTITATIVA

**ANÁLISE DAS AÇÕES PREFERENCIAIS DA METALÚRGICA GERDAU
POR MEIO DE MODELOS ESTOCÁSTICOS**

Rudimar Engel

Santa Maria, RS

2018

Rudimar Engel

**ANÁLISE DAS AÇÕES PREFERENCIAIS DA METALÚRGICA GERDAU POR MEIO
DE MODELOS ESTOCÁSTICOS**

Monografia apresentada ao Curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Especialista em Estatística e Modelagem Quantitativa.**

Orientador: Prof. Dr. Adriano Mendonça Souza

Santa Maria, RS


2018

Rudimar Engel

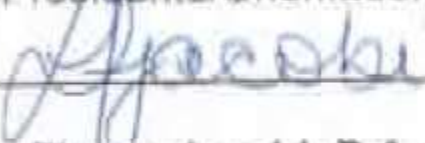
**ANÁLISE DAS AÇÕES PREFERÊNCIAIS DA METALÚRGICA GERDAU POR MEIO
DE MODELOS ESTOCÁSTICOS**

Monografia apresentada ao Curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para a obtenção do título de **Especialista em Estatística, e Modelagem Quantitativa.**

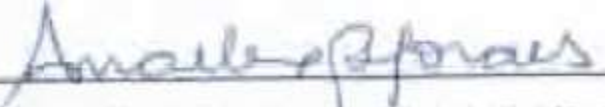
Aprovado em 16 de Março de 2018.



Adriano Mendonça Souza, Dr. (UFSM)
(Presidente/Orientador)



Luciane Flores Jacobi, Drª. (UFSM)



Anaelena Bragança de Moraes, Drª. (UFSM)

Santa Maria, RS
2018

AGRADECIMENTOS

Ao meu orientador Professor Dr. Adriano Mendonça Souza pelo apoio e incentivo, pelas sugestões de leituras, conselhos e orientações no processo de elaboração desta monografia. Especialmente pelo fato de análise de séries temporais ser um tópico de estudos do meu interesse.

A Coordenação de Especialização em Estatística e Modelagem Quantitativa, pelas condições proporcionadas para o desenvolvimento deste trabalho, pelo conhecimento adquirido e pela possibilidade de aprofundar os meus conhecimentos em estatística.

Aos professores do curso pelo seu empenho durante as aulas e sua dedicação em transmitir conhecimento.

RESUMO

ANÁLISE DAS AÇÕES PREFERENCIAIS DA METALÚRGICA GERDAU POR MEIO DE MODELOS ESTOCÁSTICOS

AUTOR: Rudimar Engel

ORIENTADOR: Dr. Adriano Mendonça Souza

Este estudo apresenta uma análise estocástica das ações preferenciais da Metalúrgica Gerdau, uma vez que o valor momentâneo de negociação de uma ação raramente reflete o verdadeiro valor da empresa que o papel representa, será utilizado da análise de séries temporais como uma ferramenta de auxílio para a segurança de investimentos no mercado de capitais. Assim, Esta pesquisa objetiva a modelagem da série de preços de fim de dia das ações preferenciais da Metalúrgica Gerdau, referentes à média e a volatilidade, e para cumprir estes objetivos foram trabalhados os modelos ARIMA e ARCH, tratando da média e das incertezas sobre os futuros valores de negociações no mercado de capitais. Os dados analisados foram obtidos através do portal eletrônico Yahoo Finanças, com a análise destes sendo realizada a partir das ferramentas de análise de séries temporais oferecidas pela linguagem de programação R. Com os resultados alcançados demonstrando a habilidade dos modelos em descrever a série em estudo, bem como a complexidade destes, visto os vários pontos a serem considerados.

Palavras-chave: Modelagem ARIMA, Modelagem ARCH, Mercado de Capitais, Metalúrgica Gerdau.

ABSTRACT

ANALYSIS OF PREFERENTIAL SHARES OF GERDAU METALLURGY BY STOCHASTIC MODELS

AUTHORS: Rudimar Engel
ADVISOR: Dr. Adriano Mendonça Souza

This study presents a stochastic analysis of the preferred shares of Gerdau Metallurgy, since the momentary trading value of trading stock rarely reflects the true value of the company that the paper represents, will be used from the analysis of time series as an aid tool for the investment in the capital market. Thus, this research aims at modeling the end-of-day price series of the preferred shares of Metalúrgica Gerdau, referring to the average and the volatility. To fulfill these objectives, the models ARIMA and ARCH were worked on, dealing with the average and the uncertainties about the future values of negotiations in the capital market. The analyzed data were obtained through the electronic portal Yahoo Finances, with the analysis of these being carried out from the tools of analysis of time series offered by the programming language R. With the obtained results demonstrating the ability of the models in describing the series under study, as well as the complexity of these, given the various points to be considered.

Keywords: ARIMA models, ARCH models, stock market, Gerdau Metallurgy.

LISTA DE FIGURAS

Figura 1 - Valores de fim de dia do preço das ações preferenciais da Metalúrgica Gerdau, durante o ano de 2016.	27
Figura 2 - Gráfico da primeira diferença da série original, para transformá-la em estacionária.	28
Figura 3 - À esquerda o gráfico da ACF, e à direita o da PACF da série original.	29
Figura 4 - À esquerda o gráfico da ACF, e à direita da PACF da primeira diferença da série original.	30
Figura 5 - ACF e PACF gerados a partir dos resíduos do modelo ARIMA(2,0,2) sem o intercepto.	33
Figura 6 - Gráfico com os valores previstos (linha espessa) e com os valores reais (linha fina).	34
Figura 7 - Série do quadrado dos resíduos do modelo ARIMA(2,0,2) sem intercepto da primeira diferença dos dados originais.	35
Figura 8 - ACF dos quadrados dos resíduos (a) e PACF dos quadrados dos resíduos (b).	36
Figura 9 - ACF e PACF dos resíduos do modelo de volatilidade.	38
Figura 10 - Desvio Padrão Condicional encontrado a partir do modelo de volatilidade criado para a série.	39

LISTA DE TABELAS

Tabela 1 - Valores AIC, AIC _C e BIC para os modelos concorrentes da primeira diferença da série original.	31
Tabela 2 - Valores do modelo ARIMA(2,0,2) com o intercepto, selecionado.	32
Tabela 3 - Valores do modelo selecionado para as previsões, com o intercepto removido.	32
Tabela 4 - Valores previstos e os observados para o modelo ARIMA(2,0,2) sem intercepto para a série da primeira diferença.	34
Tabela 5 - Modelos de volatilidades GARCH para a comparação e análise.	37
Tabela 6 - Modelo de volatilidade GARCH(1,0) escolhido.	40

LISTA DE ABREVIATURA E SÍMBOLOS

ACF	Função de Auto Correlação, do inglês <i>Autocorrelation Function</i> .
ADF	Dickey-Fuller Aumentado, do inglês <i>Aumented Dickey-Fuller</i> .
AIC	Critério de Informação Akaike, do inglês <i>Akaike Information Criterion</i> .
AIC _C	Critério de Informação Akaike Corrigido, do inglês <i>Corrected Akaike Information Criterion</i> .
AICF	Critério de Informação Akaike Amostra Finita, do inglês <i>Akaike Information Criterion Finite Sample</i> .
AKIC _C	Critério de Informação de Kullback corrigido aproximado, do inglês <i>Approximated Corrected Kullback Information Criterion</i> .
APARCH	Poder Assimétrico de Heteroscedasticidade Condicional Autorregressiva, do inglês <i>Asymetric Power Autoregressive Conditional Heteroscedasticity</i> .
AR	Modelo Autoregressivo, do inglês <i>Autoregressive Model</i> .
ARCH	Heteroscedasticidade Condicional Autorregressiva, do inglês <i>Autoregressive Conditional Heteroscedasticity</i> .
ARFIMA	Autorregressivos Fracionários Integrados de Médias Móveis, do inglês <i>Autoregressive Fractionally Integrated Moving Average</i> .
ARIMA	Autorregressivos Integrados de Médias Móveis, do inglês <i>Auto Regressive Integrated Moving Averages</i> .
ARMA	Autorregressivos de Médias Móveis, do inglês <i>Auto Regressive Moving Averages</i> .
BIC	Critério de Informação Bayesiano, do inglês <i>Bayesian Information Criterion</i> .

EGARCH	Autoregressivo Heteroscedastico Generalizado Exponencial, do inglês <i>Exponential Generalized Autoregressive Heteroskedasticity</i> .
FIGARCH	Autoregressivo Condicional Heteroscedastico de Fracionamento Integrado, do inglês <i>Fractionally Integrated Generalized Autoregressive Conditional Heteroscedastic</i> .
GARCH	Heterosqueticidade Autoregressiva Generalizada, do inglês <i>Generalized Autoregressive Heteroskedasticity</i> .
IGARCH	Heterosqueticidade Autoregressiva Generalizada Integrada, do inglês <i>Integrated Generalized Autoregressive Heteroskedasticity</i> .
KIC	Critério de Informação de Kullback, do inglês <i>Kullback Information Criterion</i> .
KIC _C	Critério de Informação de Kullback corrigido, do inglês <i>Corrected Kullback Information Criterion</i> .
KPSS	Kwiatkowski-Phillips-Schmidt-Shin.
MA	Médias Móveis, do inglês <i>Moving Average</i> .
MAE	Erro Absoluto Médio, do inglês <i>Mean Absolute Error</i> .
MAPE	Erro Médio Absoluto Percentual, do inglês <i>Mean Absolute Percentage Error</i> .
ME	Erro Médio, do inglês <i>Medium error</i> .
PACF	Função de Auto Correlação Parcial, do inglês <i>Partial Autocorrelation Function</i> .
PP	Philips-Perron.

SUMÁRIO

1. INTRODUÇÃO	1
2. REVISÃO BIBLIOGRÁFICA	4
2.1 O MERCADO DE AÇÕES.....	4
2.1.1 Metalúrgica Gerdau	5
2.2 SÉRIES TEMPORAIS	6
2.2.1 Modelos Autoregressivos, Integrados e de Médias Móveis	8
2.2.2 Modelos Auto Regressivos de Heteroscedasticidade Condicional ...	19
3. MATERIAIS E MÉTODOS	24
3.1 COLETA DE DADOS	24
3.2 PROGRAMAÇÃO R.....	24
3.2.1 Processo de modelagem da média	25
3.2.2 Processo de modelagem da variância	26
4. DESENVOLVIMENTO	27
4.1 MODELAGEM ARIMA.....	28
4.1.1 Identificação do modelo	29
4.1.2 Estimação e validação do modelo	31
4.1.3 Análise dos resíduos	33
4.1.4 Previsão dos valores médios futuros	34
4.2 MODELAGEM GARCH	35
4.2.1 Identificação do modelo	36
4.2.2 Estimação e validação do modelo	37
4.2.3 Análise de resíduos	38
4.2.4 Análise do modelo de volatilidade	39
5. CONCLUSÕES	41
REFERÊNCIAS	43

1. INTRODUÇÃO

Dentro do mercado de capitais, o preço momentâneo de uma ação raramente reflete o seu verdadeiro valor perante a empresa que representa, variando de acordo com a percepção dos investidores do cenário econômico sobre a empresa, ou do cenário econômico geral. Conforme Piazza (2011), as flutuações das cotações podem estar relacionadas a diversas variáveis ligadas aos fundamentos da empresa, à economia global ou à visão dos investidores sobre o mercado financeiro como um todo, sobre um país ou sobre um setor econômico.

Cerbasi (2013) afirma que cada ação representa uma parcela mínima do capital de uma empresa, de modo que cada acionista é detentor de uma parte da empresa e tem direito a uma parcela dos lucros, por meio de dividendos. Além destas, outras formas de rendimento também podem ser proporcionadas aos acionistas, como juros sobre capital próprio, bonificações com ações ou dinheiro e direitos de subscrição, ou então, o acionista também pode exercer o direito ao voto em assembleia, proporcionado pelas ações ordinárias. Demonstrando que o preço justo de uma ação pode ser visto como o valor real de uma empresa, que pode ser estimado em termos da esperança dos ganhos futuros que as atividades da companhia devem proporcionar aos seus investidores.

Pring (1993) afirma que a percepção do mercado quanto ao valor de uma ação dificilmente reflete os resultados da empresa. Essa avaliação nunca é precisa, podendo resultar em preços justos significativamente diferentes conforme o analista que a elabora e as premissas tomadas para estimar os fluxos esperados. Consequentemente, as flutuações no preço de uma ação podem ser relacionadas a diversas variáveis, algumas qualitativas e a maioria quantitativa, ligadas aos fundamentos da empresa, à economia global e à visão dos investidores sobre o mercado acionário como um todo, sobre um país ou sobre um setor da economia.

No que se refere às oscilações da economia, os valores de preços históricos de negociação da Metalúrgica Gerdau, fornecidos pelo Yahho Finanças, refletem o cenário econômico, mundial e nacional, dos últimos dez anos. Este era um papel que chegou a

ser negociado por valores superiores a R\$ 50,00 em 2008, antes da crise do *subprime*, sofrendo uma queda, e conseguindo uma breve recuperação até o ano de 2010, e o recomeço de seu declínio até janeiro de 2016, quando seus papéis chegaram a ser negociados por valores inferiores a R\$ 1,00.

Porém, com o processo de *Impeachment* da presidente da República do Brasil iniciando em dezembro de 2015, conforme relatado por Passarinho (2015), e o país em uma crise econômica que o mercado financeiro relacionava com a situação política do país, o mercado de ações foi marcado por uma virada de grandes altas durante o ano de 2016. Com os papéis da Metalúrgica Gerdau obtendo uma grande valorização, iniciando o ano em R\$ 1,00 e chegando ao patamar de R\$ 6,28 em novembro de 2016.

Com todas as incertezas sobre os futuros valores de negociação no mercado de capitais, bem como o risco de prejuízo ao investir em ações, frente às crises ou outros fatos que podem levar a uma maior variação dos preços dos ativos, este estudo visa a aplicação de ferramentas de análise de séries temporais nos valores de fim de dia das ações da Metalúrgica Gerdau durante o ano de 2016. Com a utilização de modelos de previsão de valores futuros auxiliando como uma ferramenta de grande importância para a segurança de investimentos contra possíveis perdas, permitindo ao investidor o correto gerenciamento de risco de uma carteira de investimentos a partir da previsão das oscilações dos preços no mercado.

Conforme Bueno (2008), na análise de dados que se desenrolam ao longo do tempo, tem-se a análise de séries temporais, que são uma sequência de observações equidistantes, seguindo uma ordem de observações sucessivas, geralmente em intervalos de tempo uniformes, sendo as observações vizinhas dependentes e o interesse é analisar e modelar esta dependência. Permitindo, assim, o desenvolvimento de uma abordagem para a construção de um modelo que use da inferência estatística para a construção de equações que caracterizem as relações entre as observações.

Desta forma, objetivando-se a caracterização dos processos de modelagem de series temporais, bem como a modelagem da série de preços de fim de dia das ações preferências da Metalúrgica Gerdau, este estudo está dividido em cinco capítulos: Introdução, Revisão Bibliográfica, Materiais e Métodos, Desenvolvimento e Conclusões.

O Capítulo de *Introdução* busca trazer uma perspectiva geral do conteúdo abordado pelo trabalho, isto dentro de uma contextualização referente aos processos de valorização e desvalorização das ações no mercado de capitais, bem como uma breve definição de séries temporais.

O Capítulo 2, a *Revisão Bibliográfica* tem por finalidade apresentar os princípios básicos sobre os quais o trabalho foi guiado e desenvolvido.

O Capítulo 3, *Materiais e Métodos* é apresentada uma descrição da coleta de materiais bem como dos métodos utilizados.

O Capítulo 4, *Desenvolvimento* é apresentada a análise e os resultados alcançados a partir das descrições apresentadas no Capítulo 2.

O Capítulo 5, *Conclusões* é reservado para a discussão dos resultados e trabalhos futuros.

2. REVISÃO BIBLIOGRÁFICA

O Capítulo de Revisão Bibliográfica está dividido em duas seções. Na primeira será feita uma breve descrição do mercado de ações, onde serão colocados os pontos básicos sobre este mercado, e a exposição de alguns pontos a respeito da Metalúrgica Gerdau. Na segunda seção será realizada a descrição dos modelos matemáticos para a descrição e previsão de valores em Séries Temporais.

2.1 O MERCADO DE AÇÕES

Quando uma empresa está interessada em captar novos recursos para investir em seu crescimento e modernização em médio e longo prazo, ela pode recorrer a um empréstimo em um banco, para depois devolver o dinheiro com o acréscimo de juros. Porém, conforme Piazza (2011), em virtude destes juros cobrados, esta acaba por ser uma opção de custo elevado. Assim, para evitar o empréstimo dos bancos, as empresas possuem a opção de captar dinheiro de novos sócios, através do lançamento de ações na Bolsa de Valores, permitindo arrecadar capital livre de juros.

Uma ação é um título negociável que representa uma fração mínima do capital social da empresa. Cada comprador dos papéis de uma empresa, por menor que seja o investimento, coloca capital próprio na estruturação da empresa. Desta forma, quando um investidor decide comprar uma ação, significa que ele está comprando uma parte mínima dessa empresa, tornando-se um sócio, e tendo direito a receber a parte correspondente dos lucros da empresa, sob a forma de dividendos. (Piazza, 2011).

Cerbasi (2013) define que comprar ações é o mesmo que adquirir o direito de participar do sucesso ou fracasso de uma empresa que optou por abrir o seu capital a investidores, onde, quanto melhor for o desempenho da empresa mais as ações se valorizam e maior é o lucro do acionista. Porém, são vários os mecanismos que podem valorizar ou desvalorizar uma ação. Sendo a imprensa um dos principais influenciadores, com notícias referentes à política ou economia, ataques militares,

acidentes aéreos, índices econômicos, e inúmeros outros fatores que podem subir ou baixar os valores de compra e venda de uma ação.

Para Pring (1993) todos os mercados refletem a atitude e expectativa de seus participantes em resposta ao potencial financeiro e ao ambiente econômico, sendo os preços do mercado mais determinados por emoções do que por julgamento racional, levando os indivíduos a serem gananciosos quando pensam que os preços sobem, e pessimistas quando os preços baixam.

Neste sentido, o sucesso no mercado de ações é alcançado pelo indivíduo que consegue controlar as suas emoções, seguindo um plano de investimentos cuidadosamente elaborado. Pring (1993) afirma que a metodologia adotada para as negociações será o veículo para o investidor alcançar suas metas e objetivos. Cerbasi (2013) corrobora, afirmando que o mercado de ações é suficientemente variado, com a capacidade de atender aos mais diversos perfis de investidores, sendo que a escolha de uma boa estratégia, e a fidelidade a esta geram bons resultados.

2.1.1 Metalúrgica Gerdau

Uma empresa que reflete a expectativa dos investidores em relação à economia é a Metalúrgica Gerdau, uma das maiores empresas brasileiras e mundiais na produção e exploração comercial de metais como ferro e aço, atuando na manufatura de produtos metalúrgicos em geral sendo, conforme Alves (2017), uma empresa brasileira detentora de participação do Grupo Gerdau.

Segundo Graciani (2016), esta empresa apresentou quedas de demanda ao longo de 2015, bem como uma contínua pressão de produtos importados em seus diferentes segmentos e regiões de atuação. Em suas unidades na América do Norte, houve uma redução de 4% de sua comercialização, em relação a 2014, resultado da entrada de produtos importados na região; na América do Sul, uma redução de 2% em suas vendas; e nas operações com aços especiais com Brasil, Estados Unidos e Índia, houve uma diminuição de 9% em relação ao ano anterior, em razão da forte queda de demanda do setor automotivo no Brasil e do setor de óleo e gás nos Estados Unidos.

Conforme documentado no endereço eletrônico da Gerdau, listado nas Referências Bibliográficas, a Companhia Gerdau é um negócio de família que iniciou quando João Gerdau adquiriu a Fábrica de Pregos Pontas de Paris no ano de 1901, em Porto Alegre, Rio Grande do Sul. Esta é uma empresa gaúcha que se caracteriza por uma liderança moldada em base familiar, atuando de forma ativa em várias partes do mundo, e desde o final da década de quarenta possui operações no mercado de capitais.

2.2 SÉRIES TEMPORAIS

Conforme Morettin e Tolo (2004), uma série temporal é uma trajetória de observações sequenciais ao longo do tempo, onde a característica mais importante é que as observações vizinhas sejam dependentes, e o interesse está em modelar esta dependência, sendo a ordem dos dados fundamental.

Segundo Ribeiro e Werner (2003), as propriedades observadas em uma série temporal podem ser descritas assumindo-se uma decomposição em componentes de tendência, que descreve o sentido de deslocamento da série, de ciclo e sazonalidade, que descrevem os momentos ondulatórios de período fixo, e de ruído aleatório que compreende a variabilidade que não pode ser modelada.

Estes autores também afirmam que uma das técnicas de análise de séries temporais mais difundidas é a metodologia de Box-Jenkins (Box-Jenkins, 1970), descrita por estes autores em 1970. Estes modelos partem da ideia de que cada valor da série pode ser explicado por valores prévios, a partir do uso da estrutura de correlação temporal que, geralmente, há entre os valores da série.

Segundo Gruginski (2010), os modelos de Box-Jenkins são conhecidos por modelos ARIMA (*Auto Regressive Integrated Moving Averages*). Sendo definidos como modelos matemáticos que utilizam a correlação seriada entre os valores de uma série temporal para captar o comportamento, e com base neste comportamento, realizar previsões futuras.

Quando se fala no estudo de séries temporais, dois conceitos básicos devem ser levados em consideração, o da homocedasticidade e o da heterocedasticidade. O

primeiro conceito trata da característica de uma série temporal com média e variância constante, característica de séries estacionárias, e que pode ser estudada a partir dos modelos ARIMA. Porém, uma vez que as séries do mercado de capitais apresentam uma variabilidade forte, realiza-se uma caracterização da heterocedasticidade da série, onde a média e a variância não são dependentes do tempo. Assim, conforme apresentado por Engle (1982), ocorre a necessidade de se utilizar modelos de análise de volatilidade, os chamados modelos ARCH (*Autoregressive Conditional Heteroscedasticity*).

A importância do estudo de séries temporais para a aplicação no mercado de ações é fundamentada com Baidya e Costa (2001). Estes autores afirmam que a caracterização das propriedades estatísticas das séries de retornos das ações é importante para permitir a correta aplicação de modelos de dados, sobretudo no que diz respeito à média e a variância, que vão determinar o retorno esperado e a previsão de volatilidade para os próximos períodos.

O estudo das propriedades estatísticas das séries financeiras iniciou-se com Bachelier (1964), em um estudo que implicava que os retornos tivessem distribuição normal independente e idêntica, e buscava estabelecer uma lei de probabilidades para as flutuações dos preços que o mercado aceitaria em um determinado momento. Conforme Baidya e Costa (2001), foi a partir de Fama (1965) que se iniciou um grande número de publicações sobre a estatística das séries financeiras, onde as primeiras constatações de passeio aleatório no mercado de ações são feitas, bem como a de séries de retorno com distribuições de caudas pesadas.

Fama (1965) afirma que o modelo de passeio aleatório impossibilita a utilização de preços históricos para a previsão de preços futuros. Esta impossibilidade de previsão no mercado de ações a partir de valores históricos também é colocada por Morais e Portugal (1999), no que se refere à variância. Segundo estes autores, o valor histórico da variância nem mesmo é importante, mas sim o que prevalecerá no futuro, que pode ou não estar condicionado às informações passadas.

Morais e Portugal (1999) acrescentam que a volatilidade assume que as variações no retorno dos ativos são conhecidas pelos participantes do mercado, tal como seu nível de preços. E para um melhor entendimento dos preços futuros dos

ativos, são citados os modelos de estudo da volatilidade de séries temporais que utilizam a informação de valores passados para a caracterização da série.

Desta forma, esta seção é referente a uma breve descrição da modelagem de séries temporais e é dividida em duas subseções. A primeira fala dos modelos da família ARIMA, que visam a modelagem da média da série, enquanto que a segunda trata da discussão dos modelos da família ARCH, voltados à análise de séries heterocedásticas, que visam a modelagem da variância, e é por vezes dependente do erro dos resultados encontrados na modelagem ARIMA.

2.2.1 Modelos Autoregressivos, Integrados e de Médias Móveis

Ribeiro e Werner (2003), com o intuito de prever a demanda de assistência técnica de computadores pessoais, realizaram uma detalhada caracterização dos modelos ARIMA. Segundo estes autores, esta família de modelos trata da integração dos modelos de médias móveis (MA) com os modelos autoregressivos (AR), onde a base para uma boa previsão de valores futuros está na estacionariedade da série.

Conforme Bueno (2008), um modelo de médias móveis estará sempre associado aos erros do período atual com aqueles ocorridos em períodos anteriores. Sendo o modelo de médias móveis de ordem q , ou MA(q) definido pela equação (1), sempre dependente do erro de q defasagens.

$$y_t = \mu + \sum_{j=0}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (1)$$

Sendo μ o representante do intercepto, θ_j o parâmetro que descreve como y_t se relaciona com ε_{t-j} , os ruídos ocorridos em períodos passados, e ε_t o representante do ruído branco atual.

E para o modelo autoregressivo, define-se o processo de ordem p , ou AR(p), conforme a equação (2). Descrita por seus valores passados regredidos e pelo ruído aleatório ε_t .

$$y_t = \mu + \sum_{j=1}^p \phi_j y_{t-j} + \varepsilon_t \quad (2)$$

Sendo ϕ_j o parâmetro que descreve como y_t se relaciona com y_{t-j} .

Ainda, segundo Bueno (2008), combinando-se os modelos de médias móveis com os autoregressivos é possível se obter uma representação adequada com um número menor de parâmetros, os chamados processos ARMA (Auto Regressivos de Médias Móveis), que acabam por formar uma classe de modelos muito úteis e parcimoniosos para descrever séries temporais. Apresentando a equação (3) para um modelo ARMA(p,q).

$$y_t = \mu + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=0}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (3)$$

Para Morettin e Tolo (2004), os modelos MA(q), AR(p) e ARMA(p,q) são modelos muito úteis para séries temporais estacionárias, mas nem tanto quando o processo da série não é estacionária. Assim, para a utilização destes modelos, é interessante a remoção das fontes de variação não estacionárias, onde a transformação mais comum consiste em tomar diferenças sucessivas da série original até se obter uma série estacionária. E em situações normais, sendo uma ou duas diferenças suficientes para se alcançar a estacionariedade.

Conforme Ribeiro e Werner (2003), o número de diferenças necessárias para tornar a série estacionária é considerado a ordem de integração entre os modelos. A inclusão do termo de ordem de integração permitindo a criação dos modelos ARIMA (*Auto Regressive Integrated Moving Averages*), representado por ARIMA(p,d,q), onde p se refere à ordem de regressão, q de médias móveis e d de diferenciações necessárias para se obter a estacionariedade.

2.2.1.1 Testes de Estacionariedade

A constatação da estacionariedade de uma série temporal é um dos primeiros passos para os processos de modelagem ARIMA. Conforme Bueno (2008), esta

constatação permitirá a procedência das inferências estatísticas. Uma série temporal é definida como estacionária quando a média é igual para todo o período, mesmo com a distribuição da variável se alterando no tempo, e também a variância deve ser igual para todo o período, e a autocovariância não dependente do tempo, mas apenas da distância entre as observações.

Morettin e Tolo (2004) afirmam que uma série estacionária se desenvolve aleatoriamente em torno de uma média constante, refletindo um equilíbrio estável. E esclarece que as séries econômicas e financeiras apresentam, em geral, tendências, onde na situação mais simples, os valores flutuam em torno de uma reta de inclinação positiva ou negativa, com média dependente do instante de tempo. E como a maioria dos procedimentos de análise de séries temporais supõe que estas sejam estacionárias, é necessária a constatação desta estacionariedade.

Porém, a inspeção visual de uma série nem sempre permite distingui-la como estacionária ou não estacionária, o que pode incorrer em erros de análise. Neste sentido, foram desenvolvidos testes para esta verificação, mais conhecidos como testes de raízes unitárias.

Na sua aplicação, em séries temporais, um destes testes é o chamado Dickey-Fuller Aumentado (ADF). Bueno (2008) expõe que a ideia deste teste é a estimação de um modelo com variáveis autoregressivas, onde se buscam encontrar desvios de y_t em relação a sua média. Sendo o erro também considerado, e é preciso introduzir tantas variáveis autoregressivas quantas forem necessárias. Apesar de ser aplicado com componentes autoregressivas, também pode ser aplicado para processos com componentes de médias móveis, uma vez que se pode transformar um $MA(q)$ em um $AR(\infty)$. É um teste de hipóteses para a constatação da presença de raízes unitárias na série, onde a hipótese nula é a presença de raiz unitária no processo $AR(p)$, e a rejeição desta hipótese leva a constatação da estacionariedade da série.

Apesar de o teste ADF permitir a realização do teste de raízes unitárias usando modelos autoregressivos, Bueno (2008) recomenda um teste que independe das ordens p e q do modelo, também muito utilizado, o teste Philips-Perron (PP), caracterizado como uma generalização para os casos em que os erros são correlacionados e heterocedásticos. Permitindo, assim, que o teste seja consistente

mesmo que existam variáveis defasadas dependentes, e erros com correlação serial, tornando desnecessária a especificação de um modelo autoregressivo com ordem suficiente para eliminar esta correlação serial dos resíduos.

Tanto o teste ADF quanto o PP possuem como hipótese nula a existência de raiz unitária. Diferente destes dois testes e também muito utilizado, existe o teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS), apresentado por Kwiatkowski et al. (1992), possui como hipótese nula a inexistência de raiz unitária. Os testes de raiz unitária desenvolvidos por Dickey e Fuller são considerados de baixo poder, e conforme os autores, dificultam a rejeição da hipótese nula para a maioria das séries econômicas.

Conforme Kwiatkowski et al. (1992), uma explicação para a comum falha na rejeição da hipótese nula é o fato de a maioria das séries temporais econômicas não serem muito informativas sobre ter ou não ter uma raiz unitária. Neste sentido, a hipótese nula do teste KPSS é a não presença de raiz unitária, com o teste sendo realizado de tal forma que a hipótese nula é aceita, a não ser que exista uma forte evidência contra. E conforme colocado por Bueno (2008), a ideia do teste é a análise da variância de passeio aleatório.

2.2.1.2 Autocorrelações e Autocorrelações Parciais

Conforme Tsay (2005), o coeficiente de correlação entre duas variáveis x e y mede a força de dependência linear entre elas, podendo variar de -1 a $+1$, e se for igual a zero diz-se que as duas variáveis são não correlacionadas. Já no estudo de séries temporais, este autor expõe o estudo da dependência linear de y_t e os seus valores passados, chegando-se à generalização do conceito de correlação para o de autocorrelação.

Assim, de acordo com Tsay (2005), o coeficiente de correlação entre y_t e y_{t-k} é chamado de defasagem k de y_k , normalmente denominado de ρ_k , onde a estatística $\rho_1, \rho_2, \dots, \rho_k$ é chamada de Função de Autocorrelação (ACF) de y_t , com o modelo linear sendo caracterizado a partir da sua ACF, capturando a dinâmica dos dados.

Segundo Gruginiskie (2010), a utilização dos coeficientes da ACF é uma poderosa ferramenta para identificar características da série temporal. Ele afirma que a

autocorrelação é utilizada para descrever a correlação entre dois valores da mesma série temporal em diferentes períodos de tempo. Com a adequada interpretação sendo necessária, devendo-se associar certos padrões de comportamento do correlograma com determinadas características da série temporal, como a aleatoriedade das séries demonstrada na não correlação quando nenhum valor significativo é encontrado. E acrescenta, afirmando que a ACF só tem significado para séries estacionárias, quando as tendências da série não dominam as outras características.

Tsay (2005) também fala sobre o funcionamento das Funções de Autocorrelação Parciais (PACF), e as ressalta como uma ferramenta muito útil para determinar a ordem p de um modelo AR. Estas medem a ordem de correlação k entre y_t e y_{t-k} sem a influência de $y_{t-1}, y_{t-2}, \dots, y_{t-k-1}$, sobre y_t . Por definição, a segunda defasagem da PACF mostra a contribuição adicionada por y_{t-2} para y_t no modelo AR(1), a terceira defasagem mostra a contribuição de y_{t-3} para y_t em um modelo AR(2), e assim por diante.

Conforme Ribeiro e Werner (2003), a análise do comportamento da ACF e da PACF indica qual modelo ARIMA deve ser utilizado, bem como auxilia na constatação ou não da estacionariedade da série temporal.

Para a análise da ACF, Morettin e Tolo (2004) afirmam que, em um processo AR(p), esta é infinita e decai conforme exponenciais ou senóides amortecidas, enquanto que para um comportamento de MA(q) a ACF é finita, com um corte na defasagem q . Com um processo ARMA(p,q) possuindo ACF infinita que decai conforme exponenciais ou senóides amortecidas a partir das defasagens p e q .

Enquanto para a análise da PACF, conforme estes autores, um processo AR(p) apresenta valores diferentes de zero para as defasagens menores ou iguais a p , com os processos MA(q) apresentando PACFs que se comportam como senóides ou exponenciais amortecidas, similar a ACF de um processo AR(p). E um processo ARMA(p,q) apresentando PACF que se comporta como uma PACF de um processo MA(q) puro.

Bueno (2008) é mais objetivo, afirmando que a ACF define a ordem de defasagem do modelo MA, enquanto que a PACF define a ordem de defasagem do modelo AR. Segundo o autor, para um modelo MA, a ACF decai exponencialmente com o aumento de defasagens, enquanto que a PACF é truncada a partir da

defasagem q . Para um modelo AR, a ACF será truncada na defasagem p , e a PACF decairá exponencialmente. E no caso de um modelo ARMA(p,q), ambas as funções decairão exponencialmente a partir da defasagem de truncagem.

Shumway (2011) também deixa claro o destaque da PACF para a determinação da ordem do modelo AR e da ACF para o modelo MA, afirmando que valores significativos que se apresentam em períodos fixos, tanto na ACF quanto na PACF, são indicativos de sazonalidade.

2.2.1.3 Estimação e Critérios de Informação

Uma vez que tenha sido identificado um modelo para a análise da série temporal, realiza-se a estimação dos parâmetros deste modelo, utilizando um procedimento iterativo de estimação não linear de mínimos quadrados, sendo as estimativas preliminares encontradas na fase de identificação usadas como valores iniciais neste procedimento. (Morettin e Tolo, 2004).

Para a estimação dos parâmetros, Bueno (2008) afirma que é importante ter estacionariedade estrita, o que garante certas condições necessárias para a inferência, sendo um dos métodos de estimação mais empregados o de máxima verossimilhança, iniciando com o método de máxima verossimilhança condicional, que é assintoticamente equivalente ao de máxima verossimilhança exata, e tem por vantagem a facilidade de especificar e estimar a função de máxima verossimilhança.

Na análise de séries temporais, a análise da ACF e da PACF para a identificação de um modelo ARIMA, conforme Morettin e Tolo (2004), é um dos maiores obstáculos, visto que existe a possibilidade de vários pesquisadores, analisando a mesma série temporal, identificarem diferentes modelos. Neste sentido, outras propostas de identificação e análise de modelos têm sido apresentadas na literatura.

Também, conforme Sobral e Barreto (2011), quando se busca construir um modelo matemático de uma série temporal, o que se procura é a menor ordem possível que consiga se adequar satisfatoriamente aos dados da série. Estes podem ter muitos distúrbios, sendo muitas vezes difícil se construir um modelo que consiga captar todas

as características a serem modeladas, com grande chance de os dados nunca se adequarem perfeitamente a algum modelo. A solução seria aumentar a ordem do modelo, o que permitiria captar características mais complexas da série, mas a grande dúvida fica em até onde se torna razoável aumentar a ordem do modelo.

Pensando nisto, vários métodos de critérios de seleção foram desenvolvidos para se escolher o melhor modelo. Sobral e Barreto (2011) afirmam que o principal objetivo destes critérios é buscar o modelo mais parcimonioso, sem parâmetros em excesso.

Segundo Ribeiro e Werner (2003), a verificação dos critérios é realizada com base no erro-padrão dos coeficientes. Se o valor do coeficiente estimado for pequeno em relação a seu erro-padrão, ele não é significativo, não havendo evidência estatística para a inclusão do coeficiente no modelo. Também, conforme estes autores, a análise do desvio padrão dos resíduos é outro indicador para se verificar se a ordem do modelo está correta, quanto menor, melhores serão as previsões.

Sobral e Barreto (2011) realizaram uma análise empírica dos métodos de informação para a seleção de ordem em modelos auto-regressivos. Estes falam a respeito do critério AIC (*Akaike's Information Criterion*), um dos modelos mais utilizados, que cria um critério de pontuação para cada modelo e tem sua fórmula apresentada na equação (4).

$$\text{AIC} = -2 \ln f(x | \hat{\theta}) + 2k \quad (4)$$

Onde o primeiro termo é uma bonificação por uma melhor adequação dos dados, em que $f(x | \hat{\theta})$ é a função de verossimilhança do modelo, e o segundo termo funciona como uma penalização, que é maior à medida que se aumentam as ordens do modelo, visando os modelos de menores ordens. Dando uma pontuação para o modelo, baseada em sua maior adequação aos dados e a menor ordem.

Sobral e Barreto (2011) também informam que outros critérios podem ser encontrados na literatura científica, principalmente desenvolvidos após a apresentação do AIC, como o AIC_C (AIC corrigido), KIC (*Kullback Information Criterion*), KIC_C (KIC

corrigido), $AKIC_C$ (*Approximated KIC_C*) e AICF (*AIC Finite Sample*), onde a diferença entre estes métodos se dá em um critério de penalização para cada modelo.

Uma consideração interessante feita por Sobral e Barreto (2011) é que nenhum destes métodos é garantido de funcionar bem em todas as situações, pois o seu desempenho depende muito do número de parâmetros, do tamanho da amostra ou da complexidade dos dados. Estes critérios simplesmente geram uma nota para o modelo, mas não dão informações a respeito da qualidade do modelo, assim, se todos forem ruins, apenas informarão qual é o melhor dentre estes. Sendo que estes critérios devem ser utilizados mais como uma ferramenta para auxiliar na modelagem dos dados.

2.2.1.4 Análise de Resíduos

Segundo Morettin e Tolo (2004), após o modelo ser estimado, é necessário verificar se existe ou não a representação adequada da variável, e qualquer insuficiência pode sugerir a necessidade de um modelo alternativo, sendo a análise dos chamados resíduos estimados, ou apenas resíduos, a base geral para os testes de adequação, diferenças entre os valores estimados e os reais, onde os valores estimados devem ser próximos aos reais e não correlacionados.

Para Ribeiro e Werner (2003), a análise dos resíduos consiste em verificar se o modelo fornece uma descrição adequada da variável. Segundo estes autores, para um modelo ser adequadamente especificado e ter um bom ajuste, espera-se que os resíduos se distribuam aleatoriamente, com média em torno de zero, e variância, aproximadamente, constante.

Bueno (2008) corrobora ao expor que na formulação inicial do modelo se assume que os erros sejam aleatórios e que o mesmo deve acontecer com os resíduos. Significando que verificar a ACF e a PACF dos resíduos estimados é mostrar que estes não possuem nenhuma dependência, e que se a hipótese nula é rejeitada, então ainda existem informações não captadas pelo modelo, o que pode gerar previsões pobres.

Ribeiro e Werner (2003) também enfatizam a importância de os resíduos de um modelo estimado serem serialmente não correlacionados, e a análise da ACF dos resíduos se encaixaria como a melhor ferramenta para a verificação desta não autocorrelação. Desta forma o correlograma permitiria uma análise mais detalhada da estrutura da autocorrelação e indicaria possíveis termos faltantes no modelo. A ideia é que a investigação venha a identificar características que não foram adequadamente modeladas.

Outra questão interessante a ser levada em consideração é a aplicação de testes para a identificação de heterocedasticidade condicional. Conforme Bueno (2008), é utilizado o resíduo defasado ao quadrado como variável dependente, verificando a presença, ou não, de variância não constante, definida como volatilidade.

2.2.1.5 Previsões com os Modelos ARIMA

Conforme Morettin e Tolo (2004), uma vez seguido o ciclo de identificação, estimação e verificação, deve-se utilizar o modelo para as previsões de um ou mais valores futuros, para prever valores a partir do último instante de tempo t observado, chamado de origem da previsão, e os valores observados sendo conhecidos por horizonte h .

Segundo Bueno (2008), no que se refere à metodologia de previsão aplicada, pode ser com ou sem a utilização de informação adicional. Com a utilização de informação adicional, a previsão feita para um instante de tempo pode ser atualizada com o novo valor observado da série, sendo este utilizado para se realizar a próxima previsão, denominada previsão estática. E quando se utiliza de valores previstos para se realizar a previsão seguinte, denomina-se previsão dinâmica, a qual apresenta uma maior variância. Por fim, o autor afirma que, na prática, a cada nova observação os coeficientes são reestimados e as previsões são refeitas.

Morettin e Tolo (2004) também comentam a respeito da determinação de intervalos de confiança, calculada a partir da variância do erro de previsão. Com suposições iniciais a respeito da distribuição dos erros, considerada normal e de média zero, fixando-se um valor de confiança que atuará como a probabilidade, com o cálculo

da variância sendo realizado em função do horizonte h . O que, conforme estes autores faz a variância aumentar conforme h aumenta, o que ocasiona em um aumento das amplitudes destes intervalos de confiança à medida que as previsões se distanciam da origem t , caracterizando o aumento da incerteza para h passos à frente.

Bueno (2008) corrobora afirmando que a variância aumenta com o horizonte de previsão. Segundo o autor, na prática não se sabem os verdadeiros valores dos coeficientes, uma vez que são estimados, logo, é necessário considerar a variância das estimativas dos coeficientes, dificultando a fórmula da variância. Assim, no que se refere aos coeficientes, o autor afirma que o fato de os modelos mais parcimoniosos terem menos parâmetros estimados implica em uma diminuição da incerteza na estimação.

Conforme Bueno (2008) e Morettin e Tolo (2004), o processo de previsão trata da aplicação do modelo encontrado em conjunto com os devidos cálculos dos erros, onde a complexidade deste processo cresce conforme o número de parâmetros do modelo aplicado.

2.2.1.6 Metodologia Box-Jenkins e Extensões do Modelo ARIMA

Dentro da comunidade científica, em seus trabalhos acadêmicos, vários são os autores que citam a metodologia de Box e Jenkins (1970) para a criação dos modelos matemáticos de séries temporais. Gruginskie (2010) cita os comentários dos autores desta metodologia, afirmando que a partir da iteração entre teoria e prática uma classe de modelos pode ser considerada.

Conforme Ribeiro e Werner (2003), a metodologia Box-Jenkins para a construção do modelo é dividida em três etapas: Identificação, Estimação e Verificação. Segundo Gruginskie (2010), a forma usual para a identificação dos modelos ocorre por meio das ACFs e PACFs, mais precisamente, pela análise do comportamento destas funções. Os autores também afirmam que a estimação consiste em obter os parâmetros dos comportamentos autoregressivos e de médias móveis dos modelos. Enquanto que a verificação consiste em avaliar se o modelo é adequado para descrever o comportamento dos dados.

Ribeiro e Werner (2003) também ressaltam que, se caso o modelo se mostre não adequado na etapa de verificação, o ciclo deve ser repetido, e acrescentam que um procedimento muito utilizado é identificar mais de um modelo para serem estimados e verificados. Desta forma, quando se obtém um modelo satisfatório, passa-se para a etapa de previsão.

Uma relativa quantidade de variações dos modelos ARIMA podem ser encontradas na literatura, onde se observa uma intenção de se modelar as séries a partir de características mais específicas. Neste sentido, este trabalho apresentará uma breve abordagem sobre duas extensões que são aplicadas em séries econômicas, as de sazonalidade e as de longa memória.

Conforme Morettin e Tolo (2004), um modelo de decomposição de uma série temporal consiste em descrever a série como uma soma das componentes de tendência, sazonalidade e aleatoriedade. As componentes de tendência e sazonalidade estão bastante relacionadas entre si e a influência da tendência sobre o componente sazonal pode ser muito forte. O que justificaria não isolar as componentes, mas realizar a sua modelagem conjunta.

Os modelos ARIMA, conforme Ribeiro e Werner (2003), exploram a autocorrelação entre valores em instantes sucessivos, mas com os dados observados em um determinado período de tempo, estes podem apresentar autocorrelação de sazonalidade.

Os modelos sazonais são chamados de modelos SARIMA(p,d,q)(P,D,Q), onde p e q se referem, respectivamente, às ordens autoregressivas e de médias móveis, enquanto que P e Q se referem, respectivamente, à ordem regressiva sazonal e a de média móvel sazonal (Gruginski, 2010).

A sazonalidade das séries pode ser verificada a partir da análise das funções ACF e PACF. Conforme Shumway (2011), o procedimento de análise destas funções ocorre da mesma forma que para o modelo ARIMA padrão, porém, é observável a presença de valores significativos em defasagens de períodos fixos, quando o correlograma consegue apresentar o período que caracteriza a sazonalidade da série.

Conforme Morettin e Tolo (2004), um processo ARIMA é referenciado como um processo de memória curta, com a ACF decrescendo rapidamente para zero. Neste

sentido, os modelos ARFIMA foram criados para a modelagem de séries que apresentam persistência nas autocorrelações amostrais, com dependência significativa entre observações separadas por um longo período de tempo, os chamados processos de memória longa, onde a função de autocorrelação decresce suavemente para zero. Os autores afirmam que os economistas notaram que há evidências de os modelos de memória longa descreverem de modo satisfatório dados econômicos e financeiros, como juros e inflação. Com trabalhos como o de Figueiredo e Marques (2009) incorporando os modelos ARFIMA nas modelagens de volatilidade.

2.2.2 Modelos Auto Regressivos de Heteroscedasticidade Condicional

Nesta seção serão abordados os modelos ARCH para a aplicação em séries heterocedásticas, característica das séries do mercado de ações, onde a busca se caracteriza pela descrição da volatilidade da série.

Campos (2007) afirma que os procedimentos de previsão indicam que as séries financeiras apresentam valores que oscilam, consideravelmente, de um período para outro, criando erros de previsão pequenos em alguns períodos e grandes em outros. Esta variabilidade pode ser explicada pela volatilidade (variância condicional) do mercado financeiro, com a variância dos erros de previsão apresentando autocorrelação.

Supondo que o comportamento dos erros de previsão dependa das perturbações da série, pode-se buscar uma explicação para a autocorrelação na variância das perturbações. Assim, para captar esta correlação, Engle (1982) introduziu os modelos ARCH com o objetivo inicial de estimar a variância da série de dados da inflação do Reino Unido.

Engle (1982) assume como modelo para a variância as equações (5) e (6).

$$y_t = \varepsilon_t h_t^{1/2} \quad (5)$$

$$h_t = \alpha_0 + \alpha_1 y_{t-1}^2 \quad (6)$$

Com y_t , na equação (5), representando a série temporal de dados, α_0 e α_1 da função (6) representando os coeficientes da regressão que descreve a função de variância condicional h_t , que pode ser generalizada conforme a equação (7).

$$h_t = h(y_{t-1}, y_{t-2}, \dots, y_{t-p}, \alpha) \quad (7)$$

Onde p é a ordem do processo ARCH e α um vetor de parâmetros desconhecidos.

Uma generalização do modelo ARCH foi apresentada por Bollerslev (1986), vindo a ficar conhecida por GARCH (*Generalized Autoregressive Heteroskedasticity*). Ampliando o número de informações apresentada pela série temporal e obtendo uma fórmula mais parcimoniosa.

Morais e Portugal (1999) afirmam que os modelos GARCH estendem a formulação ARCH no sentido de permitir uma memória mais longa e uma estrutura de defasagens mais flexível para a variância. Enquanto que Morettin e Tolo (2004) afirmam que esta generalização consiste em assumir que a variância condicional se comporte como um processo ARMA, que pode ser mais parcimonioso do que os modelos AR ou MA, um modelo GARCH pode descrever a volatilidade com menos parâmetros que um modelo ARCH. Para Bueno (2008), a identificação do modelo GARCH pode seguir a mesma metodologia proposta por Box-Jenkins, desde que se trate de fato de um modelo GARCH, conforme o modelo apresentado na equação (8).

$$h_t = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_t^2 + \sum_{j=1}^q \beta_j h_{t-j} \quad (8)$$

Onde q é a ordem do processo GARCH, com β um vetor de parâmetros desconhecidos acrescentados ao modelo, e α_0 e α_i os parâmetros de ARCH.

Morettin e Tolo (2004) também afirmam que na modelagem de volatilidade deve-se considerar que esta se manifesta de várias maneiras em uma série financeira, podendo aparecer em grupos, de maior ou menor volatilidade evoluindo no tempo, podendo ser considerada estacionária ou reagindo de modo diferente a valores

positivos ou negativos da série. Com os modelos ARCH e GARCH tratando simetricamente os retornos, visto que a volatilidade é uma função quadrática destes.

Porém, conforme Morais e Portugal (1999), a correlação entre os retornos das ações e as mudanças na sua volatilidade pode ser negativa, pois é observado que as más notícias aumentam a volatilidade, enquanto que as boas notícias as diminuem. Caracterizando uma assimetria na volatilidade, tendendo a ser maior para os retornos negativos.

Neste sentido, Nelson (1991) propôs um modelo alternativo, o EGARCH (*Exponential GARCH*), também conhecido por GARCH Exponencial, que permite uma maior flexibilidade à equação da variância, possibilitando a captura de alguma assimetria na relação entre retornos de mercado e volatilidade condicional, com grandes erros provocando maiores impactos na volatilidade do que nos modelos GARCH, sejam eles valores positivos ou negativos. Esta assimetria, Conforme Morettin e Tolo (2004), permite que a volatilidade responda mais rapidamente a retornos negativos do que a positivos, fato este conhecido como efeito alavanca.

Outra questão dos modelos GARCH(1,1), exposta por Morais e Portugal (1999), se refere ao caso em que a soma dos coeficientes esteja próximo de um ($\alpha_1 + \beta_1 = 1$), o que caracterizaria a persistência a choques na volatilidade, de maneira que se possa ter um modelo GARCH Integrado, o IGARCH. Conforme estes autores, esta persistência pode ser interpretada de duas maneiras em séries financeiras, como resultado de uma tendência na variância, ou ainda como uma mudança estrutural nesta tendência.

Baidya e Costa (2001) afirmam que um processo com a soma destes coeficientes menor que um ($\alpha_1 + \beta_1 < 1$) caracteriza a série como sendo estacionária. E quando a soma está muito próximo de um, indica um alto grau de persistência, ainda podendo ser modeladas com GARCH(1,1), apesar de o modelo mais adequado ser um IGARCH.

Também, na análise da variabilidade das séries, há a aplicação dos modelos fracionários para a detecção de memórias longas, os chamados ARFIMA-FIGARCH. Conforme Figueiredo e Marques (2009), o modelo é criado a partir de um modelo ARFIMA, para a média, que apresenta ruídos GARCH, com a equação da variância

condicional exibindo um comportamento fracionário. Buscando assim, a captura de uma dupla memória longa, ou seja, da média e da variância. Conforme o autor, em face de sua estrutura complexa, é interessante selecionar uma baixa defasagem em seu processo de estimação.

2.2.2.1 Modelagem e Análise da Volatilidade

Engle (1982) propôs os modelos ARCH para modelar a variância da série, assumindo que esta seja dependente dos quadrados dos erros passados, obtendo-se primeiro os quadrados dos erros estimados pelo modelo ARIMA estabelecido.

Conforme Bueno (2008), para o teste de detecção de modelos GARCH, levando-se em consideração que a utilização destes modelos se assemelha aos modelos ARMA, calcula-se a ACF e a PACF para os quadrados dos erros, da mesma maneira que auxiliam para a caracterização das ordens p e q . Ainda, inversamente aos modelos ARMA, a ACF informa a ordem máxima da autorregressão de GARCH, enquanto que a PACF a ordem das médias móveis. Assim, algum modelo ARCH estará presente se os valores forem autocorrelacionados, sugerindo que a série temporal é heterocedástica.

No que se referem à identificação dos melhores modelos, Morais e Portugal (1999), comentam sobre as estatísticas de erro, como o erro médio (ME), erro quadrático (RMSE), erro absoluto médio (MAE) e o erro médio absoluto percentual (MAPE). Também do log da verossimilhança, do valor da função de verossimilhança, do critério de Schwartz e outros mais. Enquanto que Bueno (2008) afirma que a alternativa usual para a escolha do modelo é o critério de AIC, que apesar de ter propriedades estatísticas desconhecidas na presença de modelos GARCH, é fácil de ser usado e é recomendado.

Para a estimação dos parâmetros dos modelos, geralmente, utiliza-se o método de máxima verossimilhança sobre a verdadeira distribuição. Conforme Engle (1992), a estimação de α e β pode ser considerada separadamente, sem perda assintótica de eficiência. Segundo este autor, cada um pode ser estimado com total eficiência baseado apenas em uma consistente estimativa do outro, se recomendando

inicialmente estimar β por mínimos quadrados, e obter os resíduos. A partir destes valores, realizar uma estimativa de α , e posteriormente uma mais eficiente de β .

No que se refere aos modelos de volatilidade, Bueno (2008) afirma que o processo de previsão dos valores futuros segue os mesmos passos do modelo ARIMA, onde se realiza a previsão um passo a frente e com o resultado obtido calcula-se o passo seguinte, e assim sucessivamente. Com a variância não condicional tornando a incerteza do erro de predição crescente com o horizonte de predição, e a distribuição leptocúrtica dos erros afeta sensivelmente a maneira de se construir o intervalo de confiança.

Por fim, no que se refere à utilização dos modelos de volatilidade, pode-se afirmar que estes servem como ferramentas para a caracterização da volatilidade, indicando o quanto os valores de uma série poderão se alterar. No mercado de ações, por exemplo, em períodos de incerteza, a modelagem da volatilidade permite definir o quanto uma ação poderá se valorizar ou desvalorizar, permitindo, ao investidor, definir um momento mais propício para comprar ou vender uma ação.

3. MATERIAIS E MÉTODOS

Para a discussão sobre os materiais e métodos utilizados neste estudo, será apresentado o Yahoo Finanças, portal eletrônico de onde foram retirados os dados que formam a série temporal analisada, bem como se falará a respeito da linguagem de programação R e as funções utilizadas para o processamento dos dados.

A pesquisa realizada busca a previsão de valores futuros e caracterização dos dados coletados a partir da aplicação da linguagem de programação R. Onde os conceitos de séries temporais discutidos na Revisão Bibliográfica serão aplicados, com um nível de significância de até 10%.

3.1 COLETA DE DADOS

Os dados analisados foram obtidos no *site* Yahoo Finanças. Este é um endereço eletrônico que disponibiliza várias informações a respeito do mercado financeiro, e dentre estas se consegue os valores históricos, em arquivo, dos papéis negociados no mercado de ações a partir do ano 2000. Desta forma, selecionou-se o período que vai de primeiro de janeiro de 2016 até primeiro de janeiro de 2017, obtendo-se um arquivo com os valores de negociação de fim de dia das ações preferenciais da Metalúrgica Gerdau.

Os dados encontrados no arquivo estão divididos em sete colunas, referentes à data de negociação, valor de abertura, maior valor de negociação, menor valor, valor de fim de dia, valor de fim de dia ajustado e número de ações negociadas. Sendo neste estudo utilizada a série de dados que representa os valores de fim de dia.

3.2 PROGRAMAÇÃO R

Conformem Lhak e Gentleman (1996), R é uma linguagem e um ambiente de desenvolvimento integrado para cálculos estatísticos e gráficos. Começou como um

experimento para a construção de testes que poderiam ser usados para julgar algumas ideias de construção de um ambiente de desenvolvimento estatístico. No início desenvolveu-se uma sintaxe semelhante a da linguagem S, aprimorada. Hoje o R superou seu processo inicial de desenvolvimento e é exposto como um trabalho colaborativo que usa da internet para a troca de ideias e distribuição de resultados.

3.2.1 Processo de modelagem da média

Tendo em vista a necessidade de uma série temporal ser estacionária para a aplicação dos modelos ARIMA, a linguagem de programação R fornece várias funções que aplicam os testes de estacionariedade discutidos na Revisão Bibliográfica. Porém, devido a fácil constatação da tendência de crescimento da série em estudo, optou-se pela constatação visual com o auxílio da função *plot()*, que gera o gráfico da série de dados.

No que se refere à análise das autocorrelações da série, utilizou-se das funções *acf()* e *pacf()*. Estas são duas funções genéricas do R, onde a primeira processa e exibe o gráfico dos valores de autocorrelação, enquanto que a segunda processa e exibe os valores da função de autocorrelação parcial.

Conforme Hydman e Khandakar (2008), o *software* R possui várias funções para a modelagem ARIMA, e uma destas é a função *Arima()* da biblioteca *forecast*. Esta é uma função que viabiliza a possibilidade de se testar várias ordens para o modelo, obtendo como retorno os devidos valores dos coeficientes e os seus respectivos valores de desvio padrão, e assim gerando um modelo para a série. Possibilitando também, com a utilização da função genérica *summary()*, a obtenção dos valores de AIC, AIC_C e BIC.

Na análise dos resíduos utilizou-se da função genérica *residuals()*, que extrai os resíduos do modelo, e a partir desta série de resíduos aplicou-se as funções *acf()* e *pacf()*.

Outra ferramenta utilizada e muito importante é a função genérica *forecast()*. Conforme Hydman e Khandakar (2008), esta função retorna pontos e intervalos de confiança de 80% e 95% para os valores futuros de uma série temporal modelada.

Podendo ser aplicada em modelos ARIMA criados a partir da função *Arima()*, bem como viabilizando a criação do gráfico dos valores futuros com os seus devidos intervalos de confiança a partir da utilização da função genérica *plot()*.

3.2.2 Processo de modelagem da variância

Para a construção do modelo de volatilidade da série utilizou-se muitas funções que também foram utilizadas na modelagem da volatilidade. Tais como as funções *acf()* e *pacf()* para a análise das ACF e PACF dos resíduos ao quadrado do modelo ARIMA e dos resíduos do modelo de volatilidade, bem como a função *summary()* e *plot()* para a análise dos resultados encontrados.

Porém, para a modelagem da volatilidade, duas funções foram utilizadas, a *garchFit()* da biblioteca *fGarch* e a *garch()* da biblioteca *tseries*. A primeira função foi desenvolvida para retornar os parâmetros de modelos ARMA-GARCH/APARCH, permitindo o teste de várias ordens para uma função GARCH, desde que a ordem p seja diferente de zero. Retornando um modelo com os valores dos coeficientes, bem como os seus erros padrões e os seus devidos valores de significância. E com a utilização da função *summary()* se obtém os valores AIC e BIC do modelo.

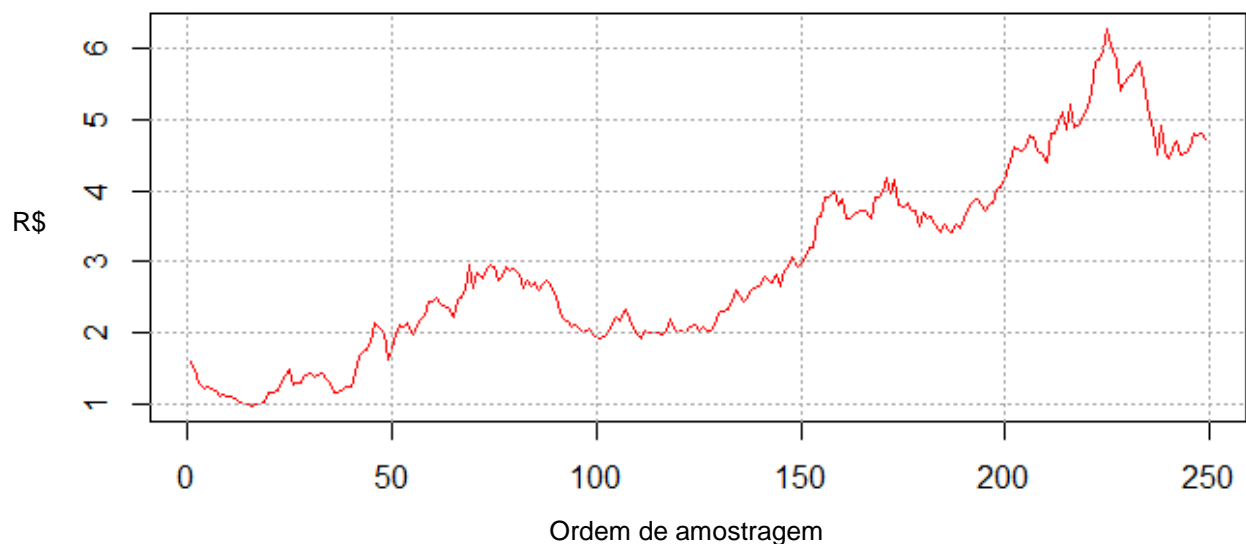
Enquanto que a função *garch()* retornou os coeficientes de um modelo GARCH(p,q) para uma série temporal, também permitindo o teste de vários modelos, porém, desde que a ordem q seja diferente de zero, onde a função *summary()* fornece os valores de significância de cada coeficiente.

Para a análise de resíduos gerados pelo modelo também se utilizou da função *residuals()* e a sua devida análise com as funções *acf()* e *pacf()*. Enquanto que o gráfico dos resíduos do modelo encontrado pode ser criado com a função *plot()*.

4. DESENVOLVIMENTO

A série estudada refere-se aos valores de fim de dia das ações preferenciais da Gerdau Metalurgia, negociados na Bolsa de Valores de São Paulo, durante o ano de 2016, a partir do dia 1º de janeiro de 2016 até 1º de janeiro de 2017, representados na Figura 1.

Figura 1 - Valores de fim de dia do preço das ações preferenciais da Metalúrgica Gerdau, durante o ano de 2016.



Fonte: *Software R*.

A série é composta por 249 observações diárias, onde o menor valor é 0,97 e encontra-se na posição 16 referente ao dia 17 de janeiro de 2016, e o maior valor é 6,28 e encontra-se na posição 225, do dia 28 de novembro de 2016. Sendo o primeiro valor da série 1,60, enquanto que o último é 4,74.

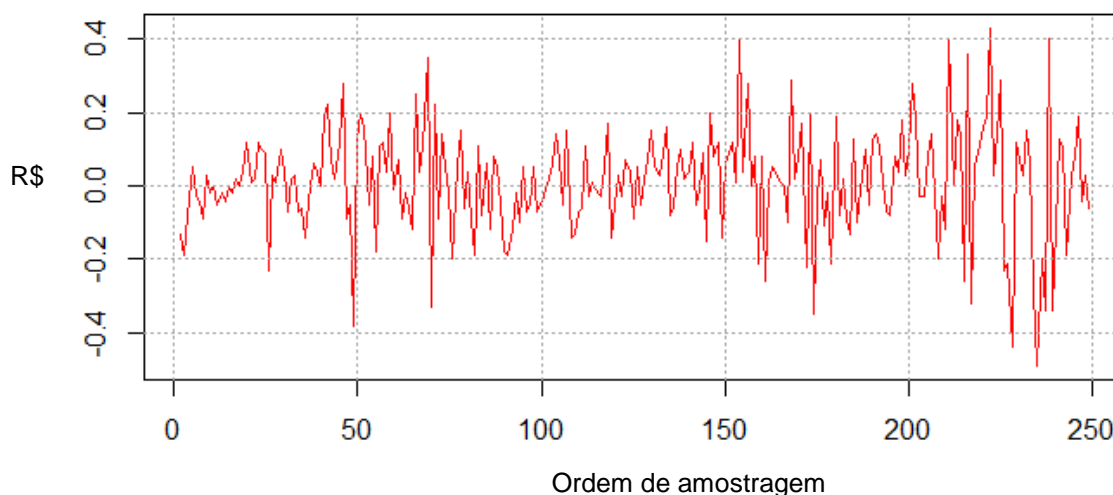
A série apresentou média de 2,96, variância de 1,75, enquanto que a mediana ficou em 2,68, e o coeficiente de variação 44,7%. O teste de assimetria aplicado apresentou o valor de 0,47, valor positivo, o que indica assimetria à direita. Enquanto que o teste de curtose apresentou valor referente a 0,73, indicando distribuição platicúrtica, mais achatada que a normal.

4.1 MODELAGEM ARIMA

Estes valores citados, em comparação com a observação visual da série original, apresentam a fácil conclusão de que a série não é estacionária visto que apresenta uma tendência de crescimento. O que gera a necessidade de se transformar a série.

Foi utilizada a primeira diferença como um dos meios para transformar a série em estacionária, apresentada na Figura 2.

Figura 2 - Gráfico da primeira diferença da série original, para transformá-la em estacionária.



Fonte: *Software R*.


A análise visual do gráfico da Figura 2 pode levar à conclusão de que a tendência de crescimento da série foi anulada, com os valores se situando em torno de uma média zero. A alta variabilidade da série as diferentes amplitudes de variação indicam a presença de volatilidade, com variância dependente do tempo, o que justificaria a utilização de modelos de volatilidade para a modelagem da série.

4.1.1 Identificação do modelo

As análises da ACF e da PACF são realizadas para a série original e para a primeira diferença da série.

Na Figura 3 são apresentados os gráficos de ACF e PACF da série original.

Figura 3 - À esquerda o gráfico da ACF, e à direita o da PACF da série original.



Fonte: *Software R*.


A presença de não estacionariedade da série pode ser constatada a partir do decaimento lento da ACF, apresentado no gráfico (a) da Figura 3, bem como da presença de apenas um valor significativo na PACF. O comportamento autoregressivo pode ser constatado na PACF, no gráfico (b) da Figura 3, onde a primeira defasagem apresenta valor significativo, sendo indicativo de uma AR(1).

Este decaimento lento da ACF também pode ser um indicativo da necessidade de se realizar uma diferença fracionária, o que implica na utilização de modelos de memória longa, ARFIMA-FIGARCH. Uma estratégia interessante, nesta situação, seria a aplicação dos testes de raízes unitárias ADF e KPSS. Caso os testes de estacionariedade apresentem resultados distintos, com um indicando uma série estacionária e o outro não estacionária, seria um indício de modelo fracionário. Porém,

esta verificação não será realizada nesta pesquisa, visto que o objetivo atual é a modelagem ARIMA e GARCH, ficando para os trabalhos futuros.

A ACF e a PACF da primeira diferença são apresentadas na Figura 4.

Figura 4 - À esquerda o gráfico da ACF, e à direita da PACF da primeira diferença da série original.



Fonte: *Software R*.

No gráfico (a) da Figura 4, observa-se o decaimento rápido da ACF, o que pode servir de indicativo para a estacionariedade da série transformada. Em ambos os gráficos é possível observar certa dificuldade em se obter uma conclusão a respeito dos dados, visto que estes não apresentaram valores significativos na primeira defasagem, porém significativo na segunda defasagem. Estes resultados não permitem a constatação precisa a respeito de um modelo ARIMA para a série, mas apenas a da presença de autocorrelação nos dados da série, bem como a presença de componentes autoregressivos e de médias móveis.

4.1.2 Estimação e validação do modelo

Os valores de AIC, AIC_C e BIC de cada modelo, obtidos com a análise da primeira diferença da série para a comparação entre os modelos concorrentes encontram-se na Tabela 1.

Tabela 1 - Valores AIC, AIC_C e BIC para os modelos concorrentes da primeira diferença da série original.

Modelo	AIC	AIC _C	BIC
ARIMA(0,0,1)	-252,7	-252,61	-242,16
ARIMA(0,0,2)	-258,34	-258,18	-244,29
ARIMA(0,0,3)	-259,01	-258,77	-241,45
ARIMA(1,0,0)	-252,82	-252,72	-242,28
ARIMA(1,0,1)	-253,19	-253,03	-239,14
ARIMA(1,0,2)	-257,69	-257,44	-240,12
ARIMA(1,0,3)	-257,23	-256,89	-236,15
ARIMA(2,0,0)	-257,6	-257,43	-243,54
ARIMA(2,0,1)	-255,88	-255,64	-238,32
ARIMA(2,0,2)	-264,79	-264,44	-243,71
ARIMA(2,0,3)	-263,12	-262,66	-238,53
ARIMA(3,0,0)	-256,26	-256,01	-238,69
ARIMA(3,0,1)	-255,05	-254,7	-233,97
ARIMA(3,0,2)	-263,21	-262,74	-238,61
ARIMA(3,0,3)	-260,79	-260,19	-232,68

Fonte: O autor.

Na análise dos valores apresentados na Tabela 1 observa-se que os menores valores de AIC e AIC_C encontram-se no modelo ARIMA(2,0,2), enquanto que o menor valor BIC encontra-se no modelo ARIMA(0,0,2). Optando-se pelo primeiro modelo para a continuação dos estudos, visto que apresentou os menores valores de AIC e AIC_C.

Tabela 2 - Valores do modelo ARIMA(2,0,2) com o intercepto, selecionado.

Modelo	Coeficientes	Erro Padrão	S ²
ARIMA(2,0,2)	$\phi_1 = -0,4425$	0,0602	0,01947
	$\phi_2 = -0,7851$	0,1041	
	$\theta_1 = 0,4491$	0,0355	
	$\theta_2 = 0,9563$	0,0663	
	$\mu = 0,0127$	0,0095	
AIC = -264,79		AIC _C = -264,44	BIC = -243,71

Fonte: O autor.

Na Tabela 2, realizando-se a divisão dos coeficientes pelos seus respectivos valores de erro padrão, apenas o intercepto apresenta valor não significativo. O que leva a remoção deste para a construção do modelo, apresentado na Tabela 3.

Tabela 3 - Valores do modelo selecionado para as previsões, com o intercepto removido.

Modelo	Coeficientes	Erro Padrão	S ²
ARIMA(2,0,2)	$\phi_1 = -0,4400$	0,0638	0.01922
	$\phi_2 = -0,7818$	0,1141	
	$\theta_1 = 0,4483$	0,0390	
	$\theta_2 = 0,9552$	0,0733	
AIC = -264.99		AIC _C = -264.74	BIC = -247.42

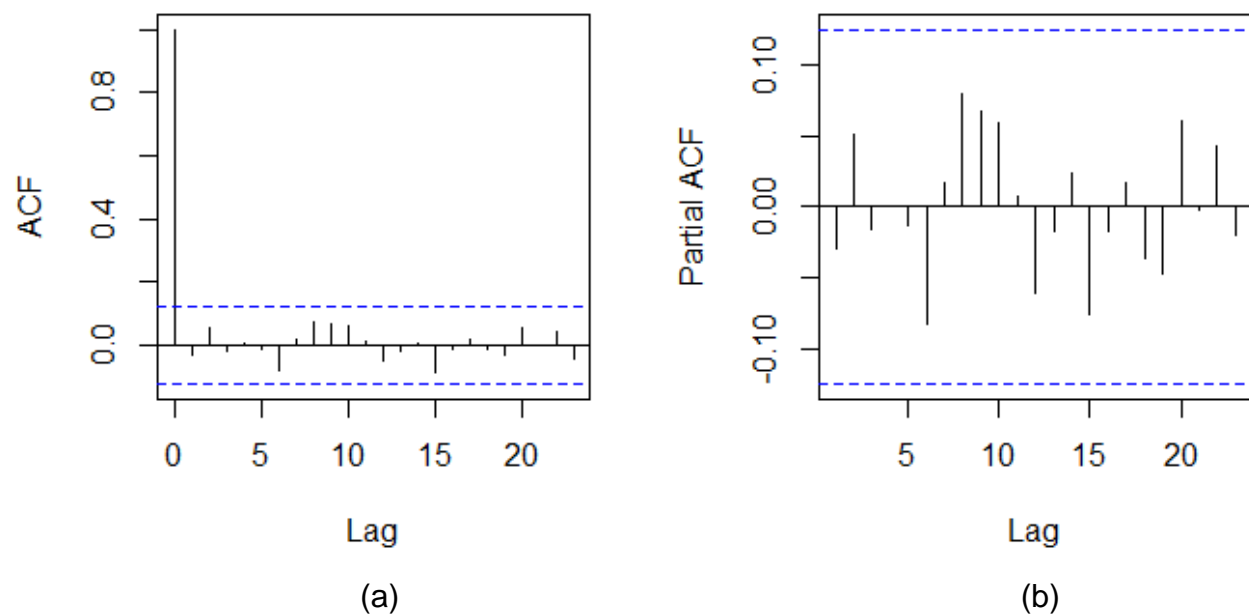
Fonte: O autor.

Na Tabela 3 é apresentado o modelo selecionado, com o intercepto removido e os coeficientes apresentando valores significativos inferiores a 5%.

4.1.3 Análise dos resíduos

Para a avaliação da capacidade do modelo em captar todas as componentes da série, inicia-se com a verificação da ACF e da PACF dos resíduos, apresentadas na Figura 5.

Figura 5 - ACF e PACF gerados a partir dos resíduos do modelo ARIMA(2,0,2) sem o intercepto.




Fonte: *Software R*.

Tanto a ACF, gráfico (a) da Figura 5, quanto a PACF, gráfico (b) da Figura 5, não apresentam valores significativos, nem nas primeiras defasagens, nem em defasagens maiores. O que pode ser interpretado como a capacidade que o modelo selecionado tem para captar todos os movimentos da série, bem como de indicar distribuição aleatória da série de resíduos, conforme o esperado para um modelo representativo da série em estudo.

4.1.4 Previsão dos valores médios futuros

Os resultados de previsão encontram-se na Figura 6.

Figura 6 - Gráfico com os valores previstos (linha espessa) e com os valores reais (linha fina).



Fonte: *Software R*.

Na Figura 6 são apresentados os valores previstos e os reais, referentes ao mês de janeiro de 2017, com a previsão entre as amostras 250 e 254. Sendo a linha mais espessa representante dos pontos calculados pelo modelo, a área cinza mais escura o intervalo de 80% de previsão, enquanto que a mais clara 95% de previsão. Na Tabela 4 são apresentados os valores da Figura 6, com os respectivos erros de previsão.

Tabela 4 - Valores previstos e os observados para o modelo ARIMA(2,0,2) sem intercepto para a série da primeira diferença.

Ordem	Valor Previsto	Valor Observado	Erro
250	0,0259	0,16	0,1341
251	0,0123	0,05	0,0377
252	-0,0257	0,24	0,2657
253	0,0017	0	-0,0017
254	0,0194	0,04	0,0206

Fonte: O autor.

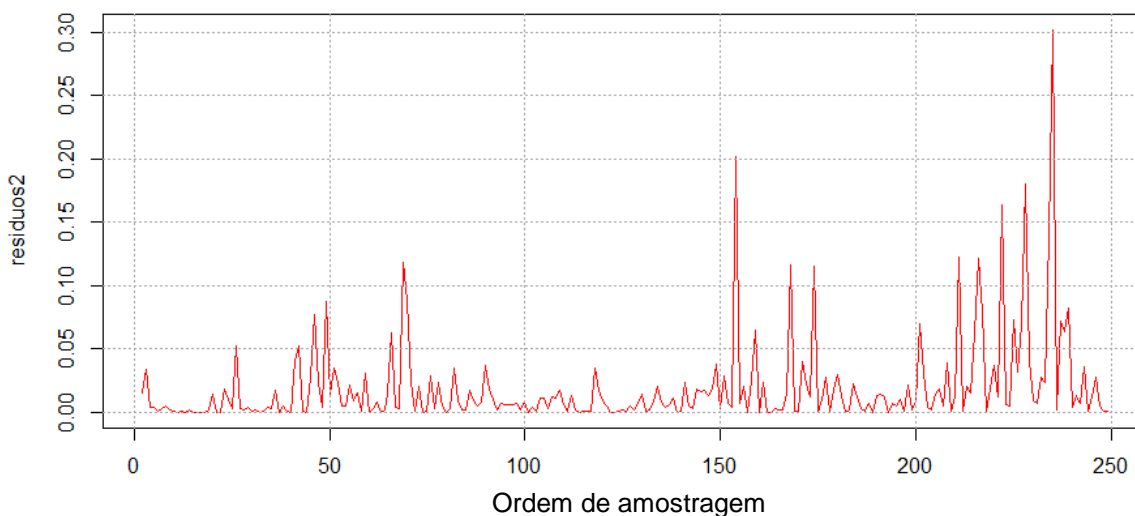
Em uma rápida análise dos valores obtidos, é válido levar em consideração que nas primeiras cinco observações, a quarta observação conseguiu prever um valor nulo, a primeira, a segunda e a quinta previram altas, e apenas a terceira previsão não obteve sucesso, prevendo um valor negativo em dia de alta. O que pode levar as indicações de altas ou baixas nos próximos dias.

Uma vez que o modelo apresenta a capacidade de prever quando a série original será valorizada ou desvalorizada, permite a construção de uma boa estratégia de compra e venda. Não se saberá ao certo o valor futuro do papel, mas se terá alguma informação referente à valorização ou desvalorização deste.

4.2 MODELAGEM GARCH

Sendo o modelo GARCH uma generalização de ARCH, para assim se obter um modelo de volatilidade que possuísse informações mais parcimoniosas. A modelagem da variância da série em estudo se dará pelo modelo apresentado por Bollerslev (1986). Com a Figura 7 se encontra a série dos quadrados dos resíduos.

Figura 7 - Série do quadrado dos resíduos do modelo ARIMA(2,0,2) sem intercepto da primeira diferença dos dados originais.



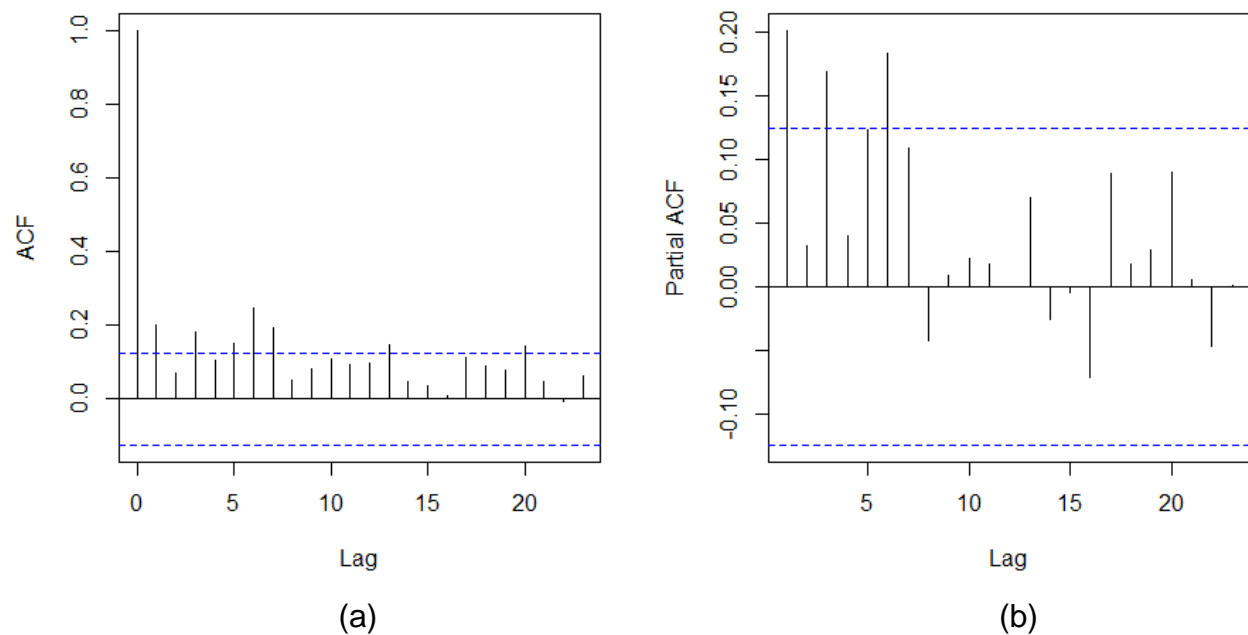
Fonte: *Software R.*

Na Figura 7 é apresentada a série a qual será aplicada a análise de volatilidade, sendo esta o resultado do quadrado dos resíduos do modelo ARIMA encontrado na modelagem da média.

4.2.1 Identificação do modelo

Na Figura 8 são apresentadas as funções ACF, no gráfico (a), e PACF, gráfico (b), do quadrado dos resíduos.

Figura 8 - ACF dos quadrados dos resíduos (a) e PACF dos quadrados dos resíduos (b).



Fonte: *Software R*.

As funções ACF e PACF apresentadas na Figura 8 possuem, valores significativos na primeira defasagem, e não significativo na segunda, o que indica um modelo GARCH(1,1). Além destes, também se observam alguns valores significativos em defasagens maiores, que não seguem uma ordem lógica.

4.2.2 Estimação e validação do modelo

Para a estimação do modelo de volatilidade utilizou-se de duas funções, a *garch()* da biblioteca *tseries* e a *garchFit()* da biblioteca *fGarch()*. Esta abordagem foi escolhida visto que a primeira função acusa erro quando a ordem q for igual à zero, enquanto que a função *garchFit()* acusa erro com p igual à zero. Os valores encontrados estão apresentados na Tabela 5.

Tabela 5 - Modelos de volatilidades GARCH para a comparação e análise.

Modelo	Coeficientes	Significância dos Coeficientes	Função Utilizada
GARCH(0,1)	$\alpha_0 = 0,12908$ $\alpha_1 = 0,362508$	0,1% 1%	<i>garch()</i>
GARCH (0,2)	$\alpha_0 = 0,011878$ $\alpha_1 = 0.369045$ $\alpha_2 = 0.048569$	0,1% 1% >10%	<i>garch()</i>
GARCH (1,0)	$\alpha_0 = 0.014775$ $\alpha_1 = 0.383835$	10% 1%	<i>garchFit()</i>
GARCH (1,1)	$\alpha_0 = 0.0010849$ $\alpha_1 = 0.1847337$ $\beta_1 = 0.7702073$	>10% 5% 0,1%	<i>garch()</i>
GARCH (1,2)	$\alpha_0 = 0.0010387$ $\alpha_1 = 0.1771990$ $\alpha_2 = 0.0002017$ $\beta_1 = 0.7791427$	>10% 10% >10% 0,1%	<i>garch()</i>
GARCH (2,0)	$\alpha_0 = 0.014661$ $\alpha_1 = 0.391649$ $\alpha_2 = 0.048449$	10% 1% >10%	<i>garchFit()</i>
GARCH (2,1)	$\alpha_0 = 0.001485$ $\alpha_1 = 0.371332$ $\beta_1 = 0.021199$ $\beta_2 = 0.567411$	>10% 1% >10% 0,1%	<i>garch()</i>
GARCH (2,2)	$\alpha_0 = 2.659e-03$ $\alpha_1 = 2.448e-01$ $\alpha_2 = 6.383e-06$ $\beta_1 = 8.858e-02$ $\beta_2 = 4.982e-01$	>10% 5% >10% >10% 5%	<i>garch()</i>

Fonte: O autor.


Observação importante a ser feita a partir da Tabela 5 é que quase todos os modelos apresentarem coeficientes não significativos, com exceção apenas de GARCH(0,1) e GARCH(1,0). Porém, o primeiro modelo apresentou resíduo com ACF autocorrelacionada, enquanto que os resíduos do segundo mostram ACF e PACF não autocorrelacionadas, conforme será mostrado na próxima sessão, optando-se, portanto, pelo modelo GARCH(1,0) para a continuação dos trabalhos.

Também vale ressaltar o fato de não se ter optado pela análise dos valores AIC para a escolha do melhor modelo, que é a abordagem adotada pela literatura. Isto se deu devido ao fato de as funções utilizadas retornarem valores diferentes quando o mesmo modelo é analisado. Como, por exemplo, na análise do modelo GARCH(1,1), onde a função `garchFit()` retorna -1,237225 para o critério AIC, ao passo que a função `garch()` retorna o valor -305,5858. O que inviabiliza a comparação a partir destes critérios.

4.2.3 Análise de resíduos

Para a análise dos resíduos do modelo GARCH(1,0) do modelo de volatilidade, são apresentados os valores ACF e PACF na Figura 9.

Figura 9 - ACF e PACF dos resíduos do modelo de volatilidade.




Fonte: *Software R.*

Uma análise dos valores apresentados na Figura 9 mostram que o modelo conseguiu captar as características da série, o que leva a escolha do modelo GARCH(1,0) para a continuação dos trabalhos.

4.2.4 Análise do modelo de volatilidade

O modelo encontrado apresentou o desvio padrão condicional da Figura 10.

Figura 10 - Desvio Padrão Condicional encontrado a partir do modelo de volatilidade criado para a série.



Fonte: *Software R*.

Comparando-se os resultados apresentados na Figura 10 com a série dos resíduos ao quadrado apresentado na Figura 8, é notável a capacidade do modelo em representar os momentos de alta e baixa volatilidade da série. Onde se observa a captação de valores de pico de volatilidade nos índices 50, entre 50 e 100, bem como entre 150 e 200, também a baixa volatilidade entre os índices 100 e 150 e a representação do crescimento gradativo da volatilidade no período entre os índices 200 e 248.

Na Tabela 6 é apresentado o modelo selecionado, com os valores dos coeficientes e seus devidos erros padrões e significâncias.

Tabela 6 - Modelo de volatilidade GARCH(1,0) escolhido.

Coeficientes	Estimado	Erro Padrão	Significância
α_0	0,014775	0,007632	10%
α_1	0,383835	0,144201	1,0%

Fonte: *Software R*.

O modelo de volatilidade, apresentado na Tabela 6, foi comparado com vários outros modelos GARCH, sendo o único a apresentar coeficientes com significância de até 10% e resíduos não autocorrelacionados, onde os coeficientes se mostraram todos positivos, satisfazendo as exigências mínimas para um modelo que represente a variância de uma série temporal. Sendo perceptível que a soma dos coeficientes ficou muito abaixo 1,0, o que leva a afirmação de que o modelo não apresenta persistência, onde a variabilidade possui pouco efeito sobre o desenvolvimento da média.

5. CONCLUSÕES

Conclui-se que a análise de séries temporais é um sistema complexo, com vários pontos a serem considerados dentro de diferentes processos de análise. Porém, apesar da necessidade de estudos mais aprofundados, pode-se concluir que os métodos de análise de séries temporais são viáveis para a aplicação no mercado de capitais.

Na aplicação da análise de séries temporais desenvolvida nesta pesquisa, levando-se em consideração a dificuldade para se alcançar os valores futuros no mercado de ações, visto a grande variedade de variáveis que podem influenciar o preço de negociação de um papel, os valores previstos pelo modelo são de grande importância. Os dois primeiros dias de alta previstos pelo modelo ARIMA(2,0,2) devem ser vistos como resultados que confirmam a capacidade deste modelo para apresentar valores significativos a serem aplicados na construção de uma estratégia de investimentos.

Também, no que se refere à alta ordem do modelo ARIMA, levando a um modelo não parcimonioso, deve-se levar em consideração a aplicação das extensões destes modelos nos trabalhos futuros. Como um ARFIMA, por exemplo, visto que a análise da ACF e da PACF indica a sua aplicação, o que possibilitaria um modelo da média com memória mais longa.

E no que se refere ao modelo de volatilidade encontrado, os coeficientes significativos devem ser analisados.

No que se refere à utilização da linguagem R para a análise de séries temporais do mercado de ações, deve ser levado em consideração a dificuldade inerente à modelagem destas séries, visto que é um mercado extremamente competitivo. Porém, é possível afirmar que os resultados encontrados com o R podem ser considerados satisfatórios, onde um estudo mais aprofundado dos meios e condições para se realizar a previsão se mostra necessário.

Quanto à análise dos valores das ações preferenciais da Metalúrgica Gerdau, objeto de estudo desta pesquisa, observa-se a habilidade dos modelos ARIMA para

prever dias de alta e dias de baixa, visto que entre as cinco primeiras previsões, apenas a terceira falhou. Também vale ser ressaltado o modelo de volatilidade, que conseguiu caracterizar de forma satisfatória a variabilidade da série. Conquistas muito importantes, que podem ser de grande auxílio para o desenvolvimento de uma estratégia de investimentos eficaz.

Por fim, as pesquisas desenvolvidas neste trabalho podem ser aperfeiçoadas, este aperfeiçoamento pode ser alcançado a partir das seguintes ações:

- A realização de estudos e aplicação dos métodos ARFIMA-FIGARCH na série analisada, visto o decaimento lento da ACF da série original, o que poderia também gerar um modelo mais parcimonioso;
- A aplicação dos modelos ARIMA em outras séries de ações, visando a avaliação da habilidade do modelo em prever dias de alta e dias de baixa;
- A continuação da modelagem ARIMA e das previsões das ações da Metalúrgica Gerdau, visando a corroboração da capacidade da análise de séries temporais para a previsão de altas e baixas da série em estudo;
- Um maior estudo dos modelos ARCH aplicados no mercado de ações, visto que o trabalho atual foi inicial e visou bastante o entendimento dos modelos ARIMA;
- Aplicação de outros processos de transformação de séries não estacionárias, como logaritmos, por exemplo, visando a análise dos resultados a serem obtidos;
- Estudos mais aprofundados da linguagem R em séries temporais e no mercado de ações, visando um maior conhecimento do poder desta ferramenta.

REFERÊNCIAS

- ALVES, A. Metalúrgica gerdau adquire 80,35% das ações ON da Gerdau. **Exame**. São Paulo, 22 ago. 2017.
<https://exame.abril.com.br/mercados/metalurgica-gerdau-adquire-8035-das-acoes-on-da-gerdau/>, Acesso em: 25 out. 2017.
- BACHELIER, L. (1964). The Theory of Speculation. (1900), reimpresso em *The random character of stock market prices* [editado por Cootner, P.], MIT Press, Cambridge, USA, 17-78.
- BAIDYA, T.; COSTA, P. Propriedades Estatísticas das Séries de Retornos das Principais Ações Brasileiras. **Pesquisa Operacional**, v. 21, p. 61-87, 2001.
- BOLLERSLEV, T. Generalized Autoregressive Conditional Heteroscedasticity. **Journal of Econometrics**, v. 31, n. 3, p. 307-327, 1986.
- BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. San Francisco: Holden-Day, 1976. Edição revisada.
- BUENO, R. L. S. **Econometria de Séries Temporais**. São Paulo: Cengage Learning, 2008.
- CAMPOS, K. C. Análise da Volatilidade de Preços de Produtos Agropecuários no Brasil. **Revista de Economia e Agronegócio**, v. 5, n. 3, p. 303-328, 2007.
- CERBASI, G. **Investimentos Inteligentes: Estratégias para multiplicar seu patrimônio com segurança e eficiência**. 1. ed. Rio de Janeiro: GMT Editores, 2013, 251 p.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. **Econometrica**, v. 50, n. 4, p. 987-1007, 1982.
- FAMA, E. The Behavior of Stock-Market Prices. **Journal of Business**, v. 38, p.34 – 105, 1965.
- FIGUEIREDO, E. E.; MARQUES, A. M. Inflação Inercial como um Processo de Longa Memória: Análise a partir de um Modelo Arfima-Figarch, **Est. Econ.**, v. 39, p. 437-458, São Paulo, 2009.
- GRACIANI, M. Gerdau perde R\$ 4,5 bi com cenário econômico incerto. **Amanhã**, Porto Alegre, RS, 15 de mar de 2016. Disponível em: <http://www.amanha.com.br/posts/view/1972/com-cenario-economico-incerto-gerdau-perde-r-4-5-bilhoes> >. Acesso em: 18 dez. 2017

- GERDAU. In: Página Oficial da Companhia Gerdau. Porto Alegre, RS. Disponível em < <https://www.gerdau.com/br/pt>>. Acesso em: 25 out. 2017.
- GRUGINSKIE, L. A. S. Proposta de Função Executável em R para Ajuste de Modelos ARIMA(p,d,q). **XXX Encontro Nacional de Engenharia de Produção**, São Paulo, SP, 2010, p. 1-13.
- HYNDMAN, R. J.; KHANDAKAR, Y. Automatic Time Series Forecasting: the forecast Package for R. **Journal of Statistical Software**, v. 27, 2008.
- KWIATKOWSKI, D. et al. Testyng the null hypothesis of stationarity against the alterantive of a unit root. **Journal of Econometrics**, p. 159-178, 1992
- LHAK, R.; GENTLEMAN, R. R: A Language for Data Analysis and Graphics. **Journal of Computational and Graphics Statistics**, p. 299-314, 1996.
- MORAIS, I.; PORTUGAL, M. Modelagem e Previsão de Volatilidade Determinística e estocástica para a Série Ibovespa. **Estudos Econômicos.**, São Paulo, v. 29, n. 3, p. 303-341, 1999.
- MORETTIN, P. A. ; TOLOI, C. M. **Análise de Séries Temporais**. São Paulo: Editora Edgard Blucher, [2004].
- NELSON, D. B. Conditional Heteroskedasticity in Asset Returns: A New Approach. **Econometrica**, v. 59, n. 2, p. 347-370, 1991.
- PASSARINHO, N. Eduardo Cunha autoriza abrir processo de impeachment de Dilma. **G1**, Brasília, DF, 02 dez 2015. Disponível em < <http://g1.globo.com/politica/noticia/2015/12/eduardo-cunha-informa-que-autorizou-processo-de-impeachment-de-dilma.html> >. Acesso em: 18 dez 2017.
- PIAZZA, M. **Bem-vindo à Bolsa de Valores**: O guia passo a passo para você fazer seu primeiro investimento pela internet. São Paulo: Editora Saraiva, [2011].
- PRING, M. **Investment Psychology Explained**: Classic Strategies to Beat the Markets. New York: John Wiley & Sons, 1993, 266 p.
- RIBEIRO, J.; WERNER, L. Previsão de Demanda: Uma Aplicação dos Modelos Box-Jenkins na Área de Assistência Técnica de Computadores Pessoais. **Gestão e Produção**, v. 10, n. 1, p. 47-67, 2003.
- SHUMWAY, R. H.; **Time Series Ananlysis and Its Applications**. 3. ed. New York: Springer, 2011.
- SOBRAL, T. E. L.; BARRETO, G. Análise dos Critérios de Informação para a Seleção de Ordem em Modelos Autoregressivos. **10ª Conferência Brasileira de Dinâmica, Controle e Aplicações**. P. 379-382, 2011.
- TSAY, R. S. **Analysis of Financial Time Series**. 2nd ed. Chicago: Wiley-Interscience, 2005.