

UNIVERSIDADE FEDERAL DO PARANÁ

DAVID ALEXANDRE BURATTO

USO DE REDES NEURAIS E MODELOS AUTOREGRESSIVOS PARA PREVISÃO
DE VARIÁVEIS RELACIONADAS A PRODUÇÃO DE MADEIRA SERRADA DE
PINUS NO ESTADO DO PARANÁ

CURITIBA

2018

DAVID ALEXANDRE BURATTO

USO DE REDES NEURAIIS E MODELOS AUTOREGRESSIVOS PARA PREVISÃO
DE VARIÁVEIS RELACIONADAS A PRODUÇÃO DE MADEIRA SERRADA DE
PINUS NO ESTADO DO PARANÁ

Tese apresentada ao curso de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Engenharia Florestal, Área de Concentração: Economia, Política e Administração Florestal.

Orientador: Prof. Dr. Romano Timofeiczky Junior
Coorientador: Prof. Dr. João Carlos Garzel Leodoro da Silva
Coorientador: Prof. Dr. José Roberto Frega

CURITIBA
2018

Ficha catalográfica elaborada pela
Biblioteca de Ciências Florestais e da Madeira - UFPR

Buratto, David Alexandre

Uso de redes neurais e modelos autoregressivos para previsão de variáveis relacionadas a produção de madeira serrada de pinus no estado do Paraná / David Alexandre Buratto. – Curitiba, 2018.
108 f. : il.

Orientador: Prof. Dr. Romano Timofeiczky Junior

Corientadores: Prof. Dr. João Carlos Garzel Leodoro da Silva

Prof. Dr. José Roberto Frega

Tese (Doutorado) - Universidade Federal do Paraná, Setor de Ciências Agrárias, Programa de Pós-Graduação em Engenharia Florestal. Defesa: Curitiba, 28/09/2018. Área de concentração: Economia e Política Florestal.

1. Economia florestal - Paraná. 2. Madeira serrada - Aspectos econômicos - Paraná. 3. Econometria. 4. Redes neurais (Computação). 5. Madeira serrada - Comércio. 6. Teses. I. Timofeiczky Junior, Romano. II. Silva, João Carlos Garzel Leodoro da. III. Frega, José, Roberto. IV. Universidade Federal do Paraná, Setor de Ciências Agrárias. V. Título.

CDD – 634.9

CDU – 634.0.6(816.2)

Bibliotecária: Berenice Rodrigues Ferreira – CRB 9/1160



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DO PARANÁ
PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
Setor CIÊNCIAS AGRÁRIAS
Programa de Pós-Graduação em ENGENHARIA FLORESTAL
Código CAPES: 40001016015P0

TERMO DE APROVAÇÃO

Os membros da Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA FLORESTAL da Universidade Federal do Paraná foram convocados para realizar a arguição da Tese de Doutorado de **DAVID ALEXANDRE BURATTO**, intitulada: " **USO DE REDES NEURAIIS E MODELOS AUTOREGRESSIVOS PARA PREVISÃO DE VARIÁVEIS RELACIONADAS A PRODUÇÃO DE MADEIRA SERRADA DE PINUS NO ESTADO DO PARANÁ** ", após terem inquirido o aluno e realizado a avaliação do trabalho, são de parecer pela sua APROVAÇÃO.

Curitiba, 28 de setembro de 2018.

Prof. ROMANO TIMOFEICZYK JUNIOR (UFPR)
(Presidente da Banca Examinadora)

Prof. PHILIPPE RICARDO CASEMIRO SOARES (UDESC)

Prof. JOÃO BATISTA PADILHA JUNIOR (UFPR)

Prof. ALEXANDRE NASCIMENTO DE ALMEIDA (UNB)

Prof. JOÃO CARLOS GARZEL LEODORO DA SILVA (UFPR)

“Combati o bom combate, terminei a corrida, guardei a fé. ”

2 Timóteo, 4:7

A Deus Criador,
que nos dotou com conhecimento e sabedoria,
a todos os pesquisadores cuja fé pensa e a razão crê,
ao meu grande incentivador, Edson Buratto (*in memoriam*)
e a todos que acreditaram em mim e neste trabalho,
dedico esta Tese.

AGRADECIMENTOS

A Jesus Cristo, por me mostrar o caminho que eu deveria seguir. Por me dar força, segurança e confiança em todos os momentos. Por, mais uma vez, ter satisfeito os desejos do meu coração e ter permitido que esta etapa se realizasse em minha vida.

Ao meu orientador, Prof. Dr. Romano Timofeiczuk Junior. Pela orientação, compreensão e confiança em mim depositada quando foi necessário. Pela sua amizade.

Ao meu coorientador, Prof. Dr. Garzel, pela contribuição acadêmica e científica, pelas conversas que me levaram à reflexão deste trabalho e de outros assuntos.

Ao meu coorientador, Prof. Dr. Frega pelos ensinamentos econométricos e disposição em ajudar, por ser sempre muito prestativo.

Ao engenheiro florestal, Dr. Marcelo Wiecheteck, pelas reuniões estendidas e fora do horário, pelo seu interesse e dedicação neste trabalho.

Aos secretários da Pós-graduação, Reinaldo e David, pelo apoio e disposição ao programa e a mim quando precisei.

À Universidade Federal do Paraná, ao Laboratório de Economia Florestal, ao Programa de Pós-Graduação em Engenharia Florestal e à CAPES, pelo uso das instalações e equipamentos. Pela oportunidade concedida para realização deste doutorado e pela concessão da bolsa de estudo.

A todos os professores do Programa de Pós-Graduação em Engenharia Florestal, mormente aos da área de economia, administração, legislação e política florestal pelas aulas, ensinamentos e contribuição científica à minha formação.

Aos colegas de estudo da área de economia florestal e da pós-graduação, pelo auxílio e colaboração nas atividades desenvolvidas e momentos divididos, em especial aos amigos: Ailson Loper, Amarildo Hersen, Eduardo Rezende, Fernanda Costa, Jaqueline Valerius, Marco Bento, Rodrigo Medeiros, Roni Ansolin, Thiago Sozinho, pela amizade construída.

Ao meu estimado amigo, Prof. Dr. Nilton José Sousa, pela mentoria na minha vida profissional e pessoal. Pela amizade construída e exemplo de pessoa que é.

Ao Prof. Dr. Sílvio Luís Rafaeli, pela orientação profissional, pela amizade e auxílio na minha mudança para Curitiba.

À turma do GAC, professores Ricardo, Márcio, Nilton, Romano, Tetto, ao seu Ademir, Giba e ao Mauro, pelos cafezinhos rotineiros, regados a conversas e risadas que me animaram diariamente. Aos companheiros de almoço, à turma da farofa!

Ao meu pai Edson Buratto (*in memoriam*) sempre presente e à minha mãe Eliane Cristina Jung Buratto, por terem acreditado em mim, me incentivado a estudar e dado condições educacionais para eu ser quem eu sou e estar realizando esse doutorado.

Aos meus irmãos Kézia Cristina e Gabriel Vinícius Buratto, pelo amor, apoio e momentos descontraídos que sempre me proporcionaram.

A minha noiva Aline Surdi, pelo amor, carinho, companheirismo, suporte, incentivo, paciência, compreensão e ajuda para conclusão deste trabalho. Minha formação, inclusive pessoal, não teria sido a mesma sem você. Te amo!

Aos meus familiares, em especial aos meus avós Walmor Buratto (*in memoriam*) e Neusa Burigo Buratto, Milton Jung e Christa Engel Jung (*in memoriam*) pelo ânimo, refúgio, carinho e amor.

Aos meus amigos, em especial a Gabriel Maines Caon, Daniel Tutida (Sun), Francine Pagno, Arthur Nogueira, Andressa Surdi, Ricardo Iida, Salete Viecele e Vilmar Surdi, pela grande amizade e apoio.

O ser humano é ser social. Por isso, a todos cujos caminhos cruzaram com os meus e que de alguma forma somaram para a realização desse trabalho e à minha carreira.

Muito obrigado!

DAVID ALEXANDRE BURATTO, filho de Edson Buratto e Eliane Cristina Jung Buratto, nasceu em 16 de maio de 1986, na cidade de Fraiburgo - Santa Catarina. No ano de 2005, ingressou no Curso de Engenharia Florestal da Universidade do Estado de Santa Catarina. Em 2006, iniciou suas atividades científicas como voluntário no Laboratório de Microbiologia do Solo, tornou-se bolsista FAPESC, ProBIC e CNPq de iniciação científica, encerrando suas atividades nesse laboratório no ano de 2009, e em 2010, formou-se Engenheiro Florestal. Em agosto do mesmo ano, iniciou como aluno especial no Curso de Pós-graduação em Engenharia Florestal da Universidade Federal do Paraná, tornando-se aluno regular desta instituição em 2011 na área de concentração em Silvicultura. Em abril do mesmo ano, iniciou sua carreira profissional, atuando como professor substituto na Universidade do Estado de Santa Catarina, onde permaneceu por cinco anos. No ano seguinte, atuou também como professor substituto por um ano na Universidade Federal de Santa Catarina. No dia 26 de agosto de 2013, concluiu seu curso de Mestrado em Engenharia Florestal. No ano de 2014, iniciou seu doutorado, na Universidade Federal do Paraná, na área de concentração em Economia, Administração, Legislação e Política Florestal. Ainda em 2014, ingressou como professor na Universidade do Planalto Catarinense, local em que trabalhou por dois anos. Atualmente, leciona para o ensino superior na Faculdade de Tecnologia de Curitiba.

“É muito melhor prever, mesmo sem certeza, do que não prever nada”.

Henri Poincare

RESUMO

O presente estudo referiu-se à elaboração de um modelo explicativo e preditivo do preço da madeira serrada de pinus no estado do Paraná. O objetivo geral deste trabalho foi a avaliação de modelos auto regressivos e redes neurais para previsão dos preços de madeira serrada de pinus do estado do Paraná. Foram utilizados dados secundários coletados em fontes públicas, de periodicidade anual abrangendo o período de 1997 a 2017, totalizando 21 observações para cada variável, organizadas em séries temporais. O primeiro, por meio do método de Mínimo Quadrados Ordinários, com o intuito de explicar o preço e analisar a elasticidade das variáveis correlacionadas. Posteriormente, foram elaborados os modelos de previsão baseados na técnica de Redes Neurais Artificiais e Autorregressivo Integrado de Média Móvel. Foram comparados os modelos gerados pelas diferentes técnicas que geraram uma previsão para os anos de 2018 a 2019. Os principais resultados indicaram que o preço real da madeira serrada de pinus no estado do Paraná pode ser explicado pelo preço médio de madeira em tora de pinus e da madeira serrada de eucalipto. O preço médio da madeira serrada de eucalipto apresenta a elasticidade de 0,60% e 95% de significância ao modelo. No modelo preditivo, o modelo ARIMA (0,0,1), concebido a partir das variáveis defasadas que formaram o modelo explicativo foi o modelo melhor ajustado aos dados, apresentando leve superioridade em relação aos demais, destacando-se os baixos erros percentuais de previsão para 2016 e 2017 (respectivamente 0,91% e 3,99%), quando comparados com os valores reais coletados, sugerindo que pode ser utilizado para prever o preço no curto prazo de forma confiável. A previsão do preço real indicou uma leve tendência de aumento a partir do ano de 2017, com uma taxa de crescimento de 1,63% ao ano. O modelo preditivo, formado com as variáveis utilizadas no modelo explicativo, possui elevada capacidade preditiva, apresentando baixos erros de previsão para o preço real de madeira serrada de pinus no estado do Paraná, podendo ser utilizado para previsão a curto prazo de forma confiável.

Palavras-chave: Econometria florestal. Modelos explicativos. Modelos preditivos. Previsões florestais.

ABSTRACT

The present study refers to the elaboration of an explanatory and predictive model of the price of sawnwood of pine in the state of Paraná. The general objective of this work was the evaluation of self regressive models and neural networks for predicting the prices of sawnwood of pine in the state of Paraná. Secondary data were used and collected from public sources, with annual periodicity covering the period from 1997 to 2017, totaling 21 observations for each variable, organized into time series. The first one was using the Ordinary Minimum Square method to explain the price and analyze the elasticity of the correlated variables. Subsequently, forecast models based on the Artificial Neural Network technique and Autoregressive Integrated Moving Average were elaborated. The models generated by the different techniques that generated a forecast for the years 2018 to 2019 were compared. The main results indicated that the actual price of sawnwood of pine in the state of Paraná can be explained by the average price of roundwood and eucalyptus sawn timber. The average price of sawnwood of eucalyptus presents an elasticity of 0.60% and 95% significance to the model. In the predictive model, the ARIMA model (0,0,1), conceived from the variables that formed the explanatory model, was the model best adjusted to the data, showing slight superiority over the others, highlighting the low percentage forecast errors for 2016 and 2017 (respectively 0.91% and 3.99%), when compared to the actual values collected, suggesting that it can be used to reliably predict the price in the short term. The real price forecast indicated a slight upward trend from 2018 onwards, with a growth rate of 1.63% per year. The predictive model formed with the variables used in the explanatory model has high predictive capacity, presenting low forecast errors for the actual price of pine sawn timber in the state of Paraná, and can be used for short-term forecast reliably.

Keywords: Forest econometrics. Explanatory models. Predictive models. Forestry forecasts.

LISTA DE FIGURAS

| | | | |
|----------|---|--|----|
| FIGURA 1 | – | DIAGRAMA DO USO DA MADEIRA SERRADA..... | 27 |
| FIGURA 2 | – | RESUMO DO PROCEDIMENTO SISTEMÁTICO DESENVOLVIDO. | 46 |
| FIGURA 3 | – | MAPA DOS PRINCIPAIS POLOS FLORESTAIS NO ESTADO DO PARANÁ..... | 47 |
| FIGURA 4 | – | MODELO ESQUEMÁTICO DA REDE NEURAL UTILIZADA..... | 63 |
| FIGURA 5 | – | GRÁFICO GERADO PELO MODELO NA REDE NEURAL ARTIFICIAL..... | 79 |
| FIGURA 6 | – | EVOLUÇÃO E PREVISÃO GERADA PELO MODELO SELECIONADO..... | 84 |

LISTA DE TABELAS

| | | | |
|----------|---|---|----|
| TABELA 1 | – | COMPOSIÇÃO DA ÁREA DE FLORESTAS PLANTADAS NO BRASIL EM 2015..... | 24 |
| TABELA 2 | – | DISTRIBUIÇÃO DAS FLORESTAS PLANTADAS DE PINUS E EUCALIPTO NO BRASIL EM 2015..... | 25 |
| TABELA 3 | – | EXPECTATIVAS TEÓRICAS REFERENTES AOS PARÂMETROS..... | 58 |
| TABELA 4 | – | GRAU DE CORRELAÇÃO DAS VARIÁVEIS EXPLICATIVAS COM A DEPENDENTE..... | 73 |
| TABELA 5 | – | RESULTADO DOS PARÂMETROS DO MODELO..... | 76 |
| TABELA 6 | – | PREMISSAS DO MODELO DE REGRESSÃO..... | 77 |
| TABELA 7 | – | AJUSTES DOS MODELOS ARIMA..... | 81 |
| TABELA 8 | – | DESEMPENHO DOS MODELOS DE PREVISÃO PARA PREÇO REAL MÉDIO DE MADEIRA SERRADA DE PINUS..... | 82 |

LISTA DE QUADROS

| | | |
|------------|--|----|
| QUADRO 1 – | PRINCIPAIS PRODUTOS DE MADEIRA SERRADA..... | 27 |
| QUADRO 2 – | SÉRIES TEMPORAIS ANUAIS UTILIZADAS PARA GERAR OS MODELOS..... | 49 |
| QUADRO 3 – | <i>TRADE-OFF</i> ENTRE OS MODELOS ELABORADOS..... | 83 |

LISTA DE ABREVIATURAS E SIGLAS

| | |
|-----------------|---|
| ABIMCI | – Associação Brasileira da Indústria de Madeira Processada Mecanicamente |
| AIC | – <i>Akaike Information Criterion</i> |
| ALICE WEB | – Sistema de Análise das Informações de Comércio Exterior via Web |
| AR | – Autorregressivos |
| ARIMA | – <i>Autoregressive Integrated Moving Average</i> |
| Ce_t | – Taxa de câmbio efetiva |
| C_t^{ser} | – Consumo aparente de madeira serrada de pinus no Brasil |
| CPC_t^{ser} | – Consumo aparente <i>per capita</i> de madeira serrada de pinus no Brasil |
| CPI | – <i>Consumer Price Index</i> |
| Cr_t | – Taxa de câmbio real entre o real brasileiro e dólar americano |
| DATASUS | – Departamento de Informática do Sistema Único de Saúde |
| DERAL | – Departamento de Economia Rural |
| EMA | – Erro Médio Absoluto |
| EPP | – Erro Percentual de Previsão |
| EQM | – Erro Quadrático Médio |
| $Exeua_t^{ser}$ | – Exportações paranaenses de madeira serrada de pinus aos Estados Unidos |
| Exm_t^{ser} | – Exportações paranaenses de madeira serrada de pinus ao Mundo |
| ha | – Hectare |
| HP_t | – Novas unidades de habitações permitidas nos Estados Unidos (<i>House permits</i>) |
| I | – Integração |
| IBGE | – Instituto Brasileiro de Geografia e Estatística |
| IPCA | – Índice de Preço ao Consumidor Amplo |
| ITTO | – <i>International Tropical Timber Organization</i> |
| J_t | – Taxa básica de juros real do Brasil - SELIC |
| kg | – Quilo |

| | |
|-----------------|--|
| km ² | – Quilômetro quadrado |
| m | – Metro |
| m ³ | – Metro cúbico |
| MA | – Médias Móveis |
| MDF | – <i>Medium Density Fiberboard</i> |
| MAE | – <i>Mean Absolute Error</i> |
| MLP | – <i>Multilayer Perceptron</i> |
| NCM | – Nomenclatura Comum do Mercosul |
| Pbr_t^{ser} | – Produção de madeira serrada de pinus no Brasil |
| PIB | – Produto Interno Bruto |
| PIB_t^{civpr} | – PIB real do setor de construção civil do estado do Paraná |
| PIB_t^{civsp} | – PIB real do setor de construção civil do estado de São Paulo |
| Po_t^{br} | – População brasileira |
| Ppr_t^{ser} | – Produção de madeira serrada de pinus no Paraná |
| Ppr_t^{tor} | – Produção de tora de pinus para serraria no Paraná |
| PR | – Paraná |
| $PREuc_t^{ser}$ | – Preço médio real da madeira serrada de eucalipto no Paraná |
| $PRfer_t$ | – Preço médio real do ferro no Brasil |
| PR_t^{ser} | – Preço médio real de madeira serrada de pinus no Paraná |
| PR_t^{tor} | – Preço médio real de madeira em tora de pinus no Paraná |
| R\$ | – Real brasileiro (moeda) |
| R_t^{br} | – Renda domiciliar <i>per capita</i> real média do Brasil |
| RNA | – Rede Neural Artificial |
| SEAB | – Secretaria da Agricultura e do Abastecimento do estado do Paraná |
| SELIC | – Sistema Especial de Liquidação e de Custódia |
| SIDRA | – Sistema IBGE de Recuperação Automática |
| SINDUSCON PR | – Sindicato da Industria da Construção Civil no estado do Paraná |
| SM_t^{br} | – Salário mínimo real nacional |
| t | – Tonelada |
| US\$ | – Dólar Americano (moeda) |
| VBP | – Valor Bruto da Produção |
| VIF | – Fator de Inflacionamento da Variância |

SUMÁRIO

| | | |
|-----------|---|----|
| 1 | INTRODUÇÃO | 18 |
| 2 | OBJETIVO | 20 |
| 2.1 | OBJETIVO GERAL..... | 20 |
| 2.2 | OBJETIVOS ESPECÍFICOS..... | 20 |
| 3 | REVISÃO DE LITERATURA | 21 |
| 3.1 | SETOR FLORESTAL BRASILEIRO..... | 21 |
| 3.1.1 | Setor florestal paranaense..... | 23 |
| 3.2 | FLORESTAS PLANTADAS..... | 24 |
| 3.2.1 | Madeira serrada..... | 26 |
| 3.3 | VARIÁVEIS QUE AFETAM O PREÇO DE PRODUTOS MADEREIROS..... | 28 |
| 3.4 | SÉRIES TEMPORAIS..... | 32 |
| 3.5 | MODELOS ECONOMETRÍCOS..... | 34 |
| 3.5.1 | Modelo autorregressivo integrado de médias móveis..... | 39 |
| 3.5.2 | Rede neural artificial..... | 41 |
| 4 | MATERIAL E MÉTODOS | 46 |
| 4.1 | MATERIAL..... | 47 |
| 4.1.1 | Dados..... | 47 |
| 4.1.1.1 | Coleta de dados..... | 47 |
| 4.1.1.2 | Variáveis incluídas nos modelos..... | 48 |
| 4.1.1.3 | Considerações sobre a coleta de dados..... | 51 |
| 4.2 | MÉTODOS..... | 51 |
| 4.2.1 | Adequação dos dados..... | 51 |
| 4.2.2 | Modelo explicativo..... | 56 |
| 4.2.2.1 | Forma funcional do relacionamento das variáveis..... | 57 |
| 4.2.2.2 | Expectativa teórica referente aos parâmetros..... | 57 |
| 4.2.2.3 | Elaboração do modelo explicativo..... | 59 |
| 4.2.2.3.1 | Definição do relacionamento entre as variáveis..... | 60 |
| 4.2.2.4 | Elasticidade das variáveis..... | 61 |
| 4.2.3 | Modelo preditivo..... | 61 |
| 4.2.3.1 | Elaboração do modelo preditivo..... | 62 |

| | | |
|-----------|--|------------|
| 4.2.3.1.1 | Técnica de rede neural artificial..... | 63 |
| 4.2.3.1.2 | Técnica ARIMA..... | 64 |
| 4.2.3.2 | Critérios estatísticos para avaliação de desempenho..... | 65 |
| 4.2.3.2.1 | Erro quadrático médio..... | 65 |
| 4.2.3.2.2 | Erro médio absoluto..... | 66 |
| 4.2.3.2.3 | Erro percentual de previsão..... | 66 |
| 4.2.3.2.4 | Coeficiente U de Theil..... | 67 |
| 4.2.3.2.5 | Critério de informação Akaike..... | 68 |
| 4.2.3.3 | Geração da previsão de 2018 a 2021..... | 69 |
| 4.2.3.4 | Ferramentas para análise dos resultados preditivos..... | 69 |
| 4.2.3.4.1 | Variação percentual..... | 69 |
| 4.2.3.4.2 | Taxa de crescimento..... | 70 |
| 4.3 | LIMITAÇÕES DO TRABALHO..... | 71 |
| 5 | RESULTADOS E DISCUSSÃO | 73 |
| 5.1 | DESENVOLVIMENTO DO MODELO EXPLICATIVO..... | 73 |
| 5.1.1 | Definição das variáveis utilizadas..... | 73 |
| 5.1.2 | Modelo explicativo desenvolvido..... | 74 |
| 5.1.3 | Premissas do modelo de regressão..... | 77 |
| 5.2 | DESENVOLVIMENTO DO MODELO PREDITIVO..... | 78 |
| 5.2.1 | Identificação do melhor modelo preditivo..... | 78 |
| 5.2.2 | Análise comparativa das técnicas utilizadas..... | 82 |
| 5.2.3 | Previsão gerada de 2018 a 2021..... | 83 |
| 6 | CONCLUSÕES | 85 |
| 7 | CONSIDERAÇÕES FINAIS | 86 |
| | REFERÊNCIAS | 87 |
| | APÊNDICE 1 – MODELO EXPLICATIVO DETALHADO | 105 |
| | APÊNDICE 2 – MODELO PREDITIVO DETALHADO | 106 |
| | APÊNDICE 3 – VALORES OBSERVADOS | 108 |

1 INTRODUÇÃO

A madeira serrada de pinus produzida no estado do Paraná é um dos principais produtos madeireiros comercializados no mercado nacional e internacional. Segundo Araújo et al. (2017), este produto serve como matéria-prima para abastecer diversos setores industriais, especialmente da construção civil, caixotaria, molduras, portas, janelas e móveis.

Nos últimos anos, a ampliação fabril e o surgimento de novas empresas florestais causaram mudanças no mercado de madeira pinus, como crescimento da demanda pela matéria-prima e elevação do preço da madeira de pinus. Somado a isso, a recente recessão econômica brasileira provocou impactos em diversos setores industriais que utilizam a madeira serrada, afetando a sua produção, consumo e, conseqüentemente, seu valor.

As análises dos preços de mercado de produtos florestais são tópicos de pesquisas importantes, pois impulsionam a alocação de recursos e as decisões de produções (NING; SUN, 2014), sendo o preço o indicador mais importante no efeito de recursos e políticas sobre a demanda, oferta e comércio (BUONGIORNO; ZHU, 2014).

É evidente que o planejamento florestal necessita da explicação e previsão dos preços de produtos florestais, se não no nível exato, pelo menos a tendência geral e seus efeitos no setor. Com a finalidade de preencher estas lacunas e diminuir as incertezas relacionadas a gestão de recursos florestais, empresas e pesquisadores buscam informações baseadas em soluções matemáticas e estatísticas para obtenção de informações numéricas a respostas quantitativas.

Estas análises requerem ferramentas adequadas por meio de técnicas e modelos econométricos que representam simplificada a realidade, auxiliando no esclarecimento das relações entre determinadas variáveis. Estes procedimentos, baseiam-se na utilização de modelos explicativos e preditivos.

Há poucos estudos que explicam e preveem o preço de madeira serrada de pinus, sobretudo no estado do Paraná, e que utilizam métodos quantitativos não convencionais para previsão de variáveis econômicas florestais. Com base nestas premissas e diante da importância da análise do preço corrente e futuro, este estudo teve como objetivo prever o preço médio real da madeira serrada de pinus no estado do Paraná, baseando-se em modelos explicativos e preditivos.

Por or meio dos resultados desta tese, buscou-se informações a respeito das variáveis que possam explicar o preço de madeira serrada de pinus no estado do Paraná e uma previsão que indique sua tendência. Tais conhecimentos podem antecipar situações econômicas e mercadológicas e devem ser considerados e observados pelas empresas produtoras e pelos consumidores, podendo subsidiar suas respectivas tomadas de decisões e o planejamento estratégico de empresas.

2 OBJETIVOS

2.1 OBJETIVO GERAL

O objetivo geral deste trabalho foi a avaliação de modelos autorregressivos e redes neurais para previsão econométrica dos preços de madeira serrada de pinus do estado do Paraná.

2.2 OBJETIVOS ESPECÍFICOS

- a) Desenvolver modelo explicativo para o preço médio real da madeira serrada de pinus no estado do Paraná;
- b) Analisar a influência das principais variáveis do modelo explicativo
- c) Elaborar modelos preditivos baseados na técnica de redes neurais artificiais e na técnica ARIMA; e
- d) Analisar a consistência do melhor modelo para os anos de 2018 a 2019, para o preço médio real de madeira serrada de pinus no estado do Paraná.

3 REVISÃO DE LITERATURA

3.1 SETOR FLORESTAL BRASILEIRO

O setor florestal está inserido no agronegócio brasileiro, representado principalmente pelos segmentos da madeira sólida para processamento mecânico, painéis de madeira industrializada, papel e celulose, energia e móveis. Este setor contribui com a economia nacional gerando impostos, fornecendo produtos para o consumo direto, auxiliando na balança comercial, criando empregos e, ainda, atuando na conservação e preservação dos recursos naturais (RIBASKI, 2018).

A cadeia produtiva deste setor constitui uma atividade econômica complexa e diversificada de produtos, entre eles, o fornecimento de biocombustível e matéria prima, e sua origem está atrelada ao processo de apropriação dos recursos florestais naturais. No Brasil, as características das indústrias são singulares em razão do país estar entre os principais detentores de recursos florestais abundantes, sendo estes principalmente de florestas nativas. (SAMPAIO; MAZZOCHIN, 2010).

As indústrias florestais brasileiras podem ser verticalizadas ou não verticalizadas. As verticalizadas, ou integradas, produzem desde a matéria-prima de florestas próprias até a fabricação de um produto madeireiro que pode ser destinado ao consumidor final (produto acabado) ou a outra indústria que utilizará para a fabricação de outros produtos. As indústrias verticalizadas de forma sucessiva geralmente são constituídas das seguintes atividades: silvicultura, manejo, colheita florestal, primeira, segunda e terceira transformação dos produtos (beneficiamento) e destino final. Estas empresas normalmente investem em florestas próprias, para garantir o abastecimento da fábrica e reduzir sua dependência do mercado. As indústrias não verticalizadas, ou não integradas, são aquelas que atuam em parte da cadeia produtiva, geralmente abastecendo-se da matéria-prima florestal a partir do suprimento no mercado, ficando dependente da variação do preço da matéria-prima que abastece suas fábricas (PARANÁ, 2007).

No Brasil, existem dois modelos de organização industrial. De um lado, os setores de celulose, papel, lâmina de madeira, chapas de fibra e madeira aglomerada que são dominadas por poucas empresas de grande porte, integradas verticalmente da floresta até produtos acabados para o consumidor final ou para outras indústrias. De outro lado, a produção de madeira serrada, compensados e móveis, com grande

número de empresas de pequeno e médio porte, geralmente não verticalizadas (CONFEDERAÇÃO NACIONAL DA AGRICULTURA – CNA, 2016).

De acordo com a Associação Brasileira da Indústria de Madeira Processada Mecanicamente - ABIMCI (2016), no ano de 2015, o Brasil possuía aproximadamente 166,3 mil empresas ativas atuando no setor florestal. Destas, 53% relacionadas à indústria de móveis de madeira, 40% de produtos madeireiros, 4% ligadas a papel e celulose e 3% à produção florestal – floresta plantadas. Em relação às indústrias de produtos madeireiros, a maior parte estão localizada nas regiões Sul (34%) e Sudeste (31%) do país, seguidas das regiões Norte e Nordeste (12%) e Centro Oeste (11%).

No primeiro semestre de 2018, os produtos florestais alcançaram a segunda posição entre os principais produtos exportados pelo Brasil, atingindo o montante de US\$ 1,32 bilhão, 28,5% maior que no mesmo período de 2017. As exportações de madeira e suas obras corresponderam a 23,69% desse montante total, isto é, US\$ 312,68 milhões, 24,7% maior que o mesmo período em 2017 (MAPA, 2018).

Somado a isso, de acordo com os dados do Ministério do Trabalho e Emprego (MTE, 2017), a indústria da madeira e do mobiliário gerou aproximadamente 434 mil empregos diretos, deste modo, o setor florestal brasileiro possui significativa influência na geração de empregos. Moreira et al. (2017) constataram que as atividades desenvolvidas pelo setor florestal brasileiro destacam-se pelo seu elevado impacto social e econômico, apresentando um alto potencial de expansão, geração de renda e empregos diretos, principalmente ao longo da cadeia produtiva.

Ainda de acordo com Moreira et al. (2017), os quatro segmentos dentro do setor florestal que mais geraram empregos formais no Brasil no ano de 2015 foram o de produção moveleira (191,9 mil), seguido da produção de celulose e papel (177,3 mil), indústria de desdobramento de madeira (70,7 mil) e da produção de florestal – florestas plantadas (63,1 mil).

Ademais, de acordo com o Banco Nacional de Desenvolvimento Econômico e Social (BNDS, 2002), o setor florestal e a atividade de extração de madeira possuem uma dinâmica específica, definida pela oferta de madeira e pela produtividade das florestas. Ainda que cada produto gerado pelas indústrias de base florestal possuam um mercado próprio, as condições para o seu desenvolvimento estão associadas à base florestal, tornando-os dependentes um do outro.

Já em relação aos setores industriais, as florestas são as únicas fontes de matéria prima em sua cadeia de abastecimento de madeira. Ao mesmo tempo que na

construção civil, por exemplo, os principais materiais de construção (como aço, concreto, tijolo, cimento, areia e agregado) são oriundos de fontes bastante distintas (RAMAGE et al., 2017).

3.1.1 Setor florestal paranaense

Segundo Eisfeld e Nascimento (2015), o uso dos recursos florestais madeireiros no estado do Paraná iniciou no século XX, baseado no corte das espécies *Araucária angustifolia* (araucária) e *Ocotea porosa* (imbuia), representando na época uma das principais atividades econômicas do Estado. Além disso, os plantios florestais iniciaram na década de 1960, impulsionados pela Lei 5.106 /66 de incentivo fiscal, que passou a tornar dinâmica a atividade florestal (KENGEN¹ apud BREPOHL, 1976). Relacionado a estes fatos, a madeira representou uma das primeiras e mais importantes cadeias produtivas do estado do Paraná (FAJARDO, 2007).

Consoante ao disposto, o estado do Paraná, somou em 2015 uma área de 1.066.479 hectares de florestas de pinus e eucalipto, que representaram aproximadamente 5,4% da área total, sendo 653.566 hectares de pinus (65,8% da área total plantada), 340.315 hectares de eucalipto (34,2% da área total plantada) (EISFELD; NASCIMENTO, 2015).

O setor florestal paranaense fornece madeira para diversos usos, dentre eles o desdobro e beneficiamento nas serrarias. Segundo dados da Secretaria da Agricultura e do Abastecimento do Estado, no ano de 2016, 89,28% da madeira serrada produzida concentrou-se nas mesorregiões sudeste (29,03%), metropolitana de Curitiba (26,35%), centro oriental (21,43%) e centro sul (12,45%) (PARANÁ, 2017).

Neste contexto, o setor de base florestal do Estado no ano de 2019, registrou R\$ 3,1 bilhões de valor da produção da silvicultura. Com incremento de 6,2% na madeira em tora, alcançando 17,9 milhões de metros cúbicos, ou 34,2 do total nacional, sendo o maior produto do país. (INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE, 2020).

Em relação às indústrias e empresas de madeira processada mecanicamente, em 2015, o Estado possuía 16.328 empresas ligadas ao setor madeireiro, sendo que 48,7% destinada a indústria madeireira e 51,2% a indústria de móveis de madeira

¹ KENGEN, S. **Incentivos fiscais**. Brasília, IBDF, [S.a] (não publicado).

(ABIMCI, 2016). De acordo com os dados de Paraná (2015), o Valor Bruto da Produção – VBP deste segmento florestal nos anos de 2014 e 2015, representou 5% de participação dos segmentos rurais do Estado. Vale lembrar que nestes números não estão incluídas as indústrias ligadas ao setor de papel e celulose.

As empresas produtoras de madeira serrada possuem maior concentração nas microrregiões das cidades de Telêmaco Borba, Palmas, Jaguariaíva, Guarapuava, União da Vitória, Prudentópolis, Irati e Ponta Grossa e a mesorregião Região Metropolitana de Curitiba (PARANÁ, 2015). Segundo a distribuição espacial das regiões do Estado, em conformidade à Secretaria de Estado da Agricultura e do Abastecimento (SEAB), a região Centro-Sul é a que apresenta maior destaque no setor florestal, sendo responsável por 85% das toras de serraria e laminação e 49% da receita gerada pelas toras para papel e celulose. Já a região metropolitana de Curitiba, representa 24% dos produtos florestais, sendo basicamente destinados a produção de toras para serraria e laminação (PARANÁ, 2015).

3.2 FLORESTAS PLANTADAS

Em uma pesquisa realizada por Buongiorno e Zhu (2014), constataram que o consumo mundial estimado de toras para processamento industrial de florestas plantadas foi 14% maior do que o de florestas nativas. Segundo os dados da *Food and Agriculture Organization of the United Nations* (FAO, 2015), as florestas plantadas, são responsáveis por 91% de toda a madeira produzida para fins industriais no Brasil. Sobre isso, de acordo com FAO (2015), o Brasil tem a nona maior área de florestas plantadas no mundo (2,69% do total mundial). (TABELA 1).

TABELA 1 – COMPOSIÇÃO DA ÁREA DE FLORESTAS PLANTADAS NO BRASIL EM 2018.

| Cultura florestal | Área | |
|-------------------|-----------|-------|
| | ha | % |
| Eucalipto | 5.672.431 | 72,39 |
| Pinus | 1.569.305 | 20,03 |
| Acacia | 161.907 | 2,07 |
| Seringueira | 218.307 | 2,79 |
| Paricá | 90.811 | 1,16 |
| Teca | 93.957 | 1,20 |
| Araucária | 13.077 | 0,17 |
| Populus | 4.326 | 0,06 |
| Outras | 9.066 | 0,12 |
| Total | 7.833.187 | ≅100 |

FONTE: Adaptado de Indústria Brasileira de Árvores - IBÁ (2019).

Segundo Moreira et al. (2017), o Brasil tem ampliado a sua área de florestas plantadas a uma Taxa Geométrica Média (TGM) anual de 1,8%, inferior à taxa mundial que foi de 2,1%. O avanço da área de florestas plantadas no Brasil deve-se, sobretudo, ao aumento da fronteira florestal de silvicultura para produção de celulose, papel e biomassa lenhosa.

A substituição da produção obtida com árvores de florestas nativas por árvores de pinus e eucalipto como matéria-prima, ocorre devido ao grande potencial de crescimento em ambientes distintos do território nacional e produzem uma grande variedade de produtos com o uso de sua madeira (VITALE; MIRANDA, 2010).

Em 2018, 36% da área de florestas plantadas destinou-se às empresas do segmento de celulose e papel. Em segundo lugar, encontraram-se os proprietários independentes e fomentados (pequenos e médios produtores) com 29%. Na sequência, o segmento de siderurgia a carvão vegetal com 12% da área plantada, painéis de madeira e pisos laminados com 6%, produtos sólidos com 4% e outros com 3%. Além disso, as *TIMOs* (*Timber Investment Management Organizations*) detiveram 10% das florestas plantadas no Brasil (IBÁ, 2019).

Dentre as espécies florestais plantadas que fornecem matéria prima para fabricação de madeira, destaca-se as do gênero *Pinus* e *Eucalyptus* (BERGER et al., 2011). As distribuições destes dois gêneros estão presentes em aproximadamente 2/3 dos estados brasileiros (TABELA 2).

TABELA 2 – DISTRIBUIÇÃO DAS FLORESTAS PLANTADAS DE PINUS E EUCALIPTO NO BRASIL EM 2015.

| Estado | Área por gênero (ha) | | Área total | |
|--------|----------------------|-------------------|------------|-------|
| | <i>Pinus</i> | <i>Eucalyptus</i> | ha | % |
| MG | 37.636 | 1.364.538 | 1402174 | 19,35 |
| SP | 124.222 | 936.265 | 1060487 | 14,64 |
| PR | 663.982 | 295.970 | 959952 | 13,25 |
| MS | 6.292 | 901.778 | 908070 | 12,53 |
| SC | 540.621 | 113.073 | 653694 | 9,02 |
| BA | 3.371 | 619.514 | 622885 | 8,60 |
| RS | 184.595 | 308.657 | 493252 | 6,81 |
| ES | 2.518 | 228.488 | 231006 | 3,19 |
| MA | 0 | 225.052 | 225052 | 3,11 |
| MT | 0 | 181.435 | 181435 | 2,50 |
| GO | 8.500 | 127.201 | 135701 | 1,87 |
| PA | 0 | 137.866 | 137866 | 1,90 |
| TO | 430 | 119.871 | 120301 | 1,66 |
| AP | 0 | 67.826 | 67826 | 0,94 |
| PI | 0 | 25.675 | 25675 | 0,35 |
| Outros | 0 | 19.222 | 19222 | 0,27 |
| Total | 1572167 | 5672431 | 7244598 | 100 |

FONTE: Adaptado de IBÁ (2019).

Segundo Hoeflich (2006) as florestas plantadas no Brasil chegam a ser três vezes mais produtivas que os plantios dos Estados Unidos. De acordo com a Sociedade Florestal Brasileira (MMA, 2013), este fato deve-se aos fatores ambientais favoráveis e as novas tecnologias utilizadas para aumentar a produção, corroborando para que o Brasil seja destaque na produtividade florestal de coníferas e folhosas.

Sendo assim, no que diz respeito aos fatores que contrastam de forma positiva a rentabilidade do cultivo florestal, destacam-se: taxa de juros, custo de arrendamento da terra e distância do consumidor. Adicionalmente, a floresta pode ser manejada para diferentes finalidades, permitindo ao produtor alcançar diferentes mercados de produtos florestais (MOREIRA et al., 2017).

A partir da produção de árvores como matéria-prima, inicia-se a cadeia produtiva florestal, desde a sua extração até o seu processamento primário. Nestas etapas, aproximadamente 50% da árvore extraída da floresta não é aproveitada no processamento mecânico. O material lenhoso aproveitado é então destinado a múltiplos usos, como: obtenção de cavacos, laminadas, madeira serrada entre outros (RAMAGE, 2017).

3.2.1 Madeira serrada

Conforme citado anteriormente, a madeira serrada é um dos primeiros produtos gerados no processamento industrial mecânico da madeira em tora, resultando diretamente do processo de desdobro, reduzindo as toras inteiras em partes menores de secção retangular ou quadrada, por meio de serras circulares e fitas (FAGUNDES, 2003). Posteriormente, é secada, aplainada e classificada, para a obtenção de outros produtos (RAMAGE, 2017).

A produção de madeira, portanto, está baseada no aproveitamento da tora e está diretamente relacionada com as suas características, além da quantidade e qualidade dos equipamentos utilizados nas serrarias (ZENID, 2009). Entre os tipos de madeira serrada obtidos nas serrarias, destacam-se os descritos no Quadro 1, baseados na Norma Brasileira 7203: Madeira serrada e beneficiada que ainda está em vigor.

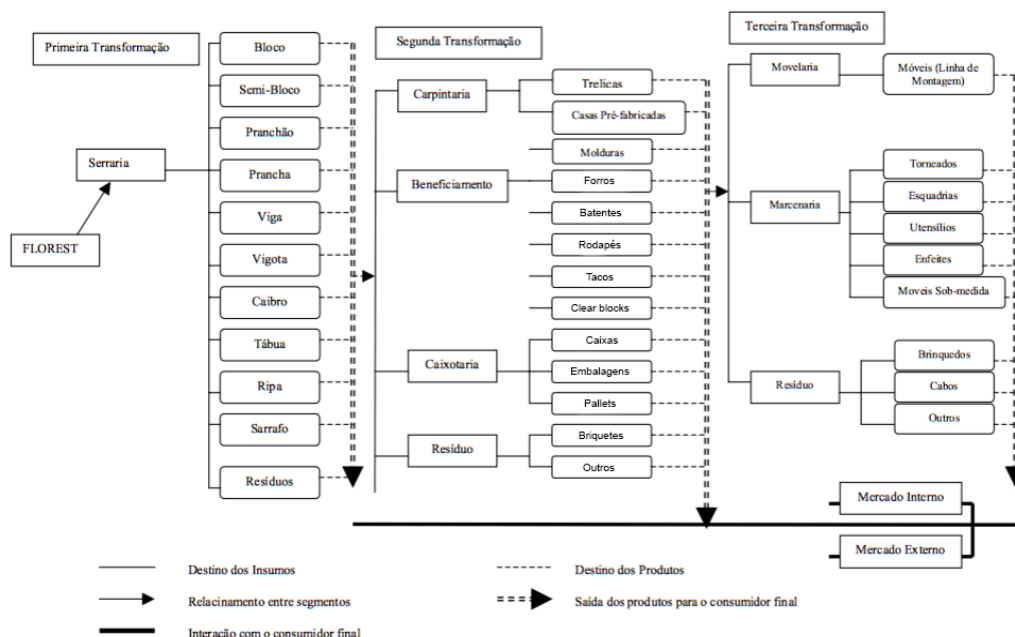
QUADRO 1 – PRINCIPAIS PRODUTOS DE MADEIRA SERRADA.

| Produto | Dimensões (mm) | | |
|-----------|----------------|-----------|--------------------------|
| | Espessura | Largura | Comprimento |
| Pranchão | > 70 | > 200 | Variável |
| Prancha | 40 – 70 | > 200 | Variável |
| Viga | > 40 | 110 – 200 | Variável |
| Vigota | 40 – 80 | 80 – 110 | Variável |
| Caibro | 40 – 80 | 50 – 80 | Variável |
| Tábua | 10 – 40 | > 100 | Variável |
| Sarrafo | 20 – 40 | 20 – 100 | Variável |
| Ripa | > 20 | > 100 | Variável |
| Dormente | 160 – 170 | 220 – 240 | 2,00 – 5,60/ 2,80 – 5,60 |
| Pontalete | 75 | 75 | Variável |
| Bloco | Variável | Variável | Variável |

FONTE: ZENID (2009).

A produção média de madeira serrada de pinus em uma madeireira de pequeno porte é de 1.300 m³ por mês (HEINRICH, 2010). Em madeireira de grande porte, pode chegar a mais de 20.000 m³ por mês (ROCHA, 2002). Os produtos obtidos a partir da madeira serrada estão representados na Figura 1.

FIGURA 1 – DIAGRAMA DO USO DA MADEIRA SERRADA.



FONTE: POLZL et al. (2003).

Segundo os dados da FAO (2018), no ano de 2017 a produção mundial de madeira serrada de coníferas foi de 342,14 milhões/m³. No mesmo ano, o Estados Unidos foi um dos principais países neste indicador, tendo produzido 16,83%, seguido do Canadá como outro grande produtor (14,07%), Rússia (11,05%) e China (10,04%). Em relação ao Brasil, a produção foi de 8 milhões/m³, representando 2,51% da produção mundial.

No Brasil, dentre os setores industriais que mais consomem madeira serrada de coníferas e folhosas, destaca-se o da construção civil (FAGUNDES, 2003; ABIMCI, 2016). Segundo Cantareli (2003) e Zenid (2009), a madeira é utilizada neste setor de diversas formas com uso temporário, como formas para concreto, andaimes e escoramentos e, de forma definitiva, é usada em vigas, estruturas de coberturas (caibros e terças), pilares, esquadrias (portas e janelas), forros e pisos.

Na construção civil brasileira, a madeira serrada desempenha funções de curto prazo, como moldes de concreto (28%) sendo, geralmente, de floresta plantada e de longo prazo como estruturas (56%), sendo usada, neste caso, madeira serrada de floresta nativa (PUNHAGUI et al., 2012). Cantareli (2003) ainda constatou, que uma unidade de 50 m² de alvenaria é constituída em média, de 3,8 m³ de madeira, dos quais 3,4 m³ são de madeira serrada para uso definitivo e 0,4 m³ em painéis para usos não definitivos.

Além disso, as estimativas das elasticidades de demanda próprias e cruzadas de preços para produtos à base de madeira e seus substitutos associados ao setor de construção civil da Alemanha, foi constatado que 36% da madeira é usada para novas construções e 64% para reformas e modernização (JOCHEM et al., 2016).

3.3 VARIÁVEIS QUE AFETAM O PREÇO DE PRODUTOS MADEIREIROS

O preço possui forte relação com a produção (oferta) e consumo (demanda) dos produtos, que refletem vários fatores que os impactam, tais como tecnologia, política macroeconômica, renda, etc. Sua relação com a demanda pode ser medida pelo cálculo da elasticidade-preço da demanda.

Pelo lado do produtor (ofertante), se inserido em mercados oligopolistas, de concorrência monopolística ou monopolístico, os custos de produção como salários, taxa de juros, custo das matérias-primas, entre outros, aumenta e permite que o produtor eleve os preços dos produtos gerados (PINDIYCK; RUBINFELD, 2010). Do

lado do consumidor (demandante), tem-se o monopólio e oligopólio, que compreendem uma forma de mercado em que há somente um comprador ou poucos compradores para muitos fornecedores (vendedores) de insumos (VASCONCELLOS; GARCIA, 2014). No entanto, vale lembrar que que o produtor inserido em uma estrutura de mercado de concorrência perfeita não consegue repassar ao produto a elevação dos custos de produção.

Alguns estudos já foram realizados no sentido de buscar compreender as diferentes variáveis que influenciam na formação de preço dos produtos madeireiros, quais sejam as de maior significância, dando ênfase aos custos da produção e dos insumos e bens substitutos e quais importâncias devem ser dadas a cada fator (SIMANGUNSONG; BUONGIORNO, 2001; MICHINAKA, et al., 2011; BUONGIORNO, 2015b; JOCHEM, et al., 2016).

Sobre isso, segundo Almeida et al. (2008) a silvicultura paranaense já vivenciou dois momentos marcantes de forte oscilação nos preços da madeira. O primeiro, registrado em meados da década de 1980, em que o preço da madeira despencou, devido à oferta excessiva de madeira no mercado, proveniente principalmente de florestas nativas. O segundo momento foi ao longo do ano de 2006, em que foi verificada um aumento expressivo do preço da madeira e seu estudo indicou que este aumento estava relacionado a demanda externa.

Hurmekoski et al. (2018), mencionaram que a demanda por produtos de madeira é dada pelo nível de alterações do preço e do crescimento do Produto Interno Bruto (PIB). A influência do PIB pode ser direta ou indireta no consumo de produtos florestais, refletindo a situação econômica do país ou de setores industriais, que inclui o valor dos bens produzidos e o valor dos serviços comercializados. Buongiorno (2015b) verificou a dependência de renda e tempo nas elasticidades da demanda por produtos florestais e implicações para previsão e constatou que o PIB foi estatisticamente significativo para o consumo de madeira serrada e aglomerado em vários países.

Em relação aos custos de produção de madeira serrada, 84,31% está relacionado ao custo variável total e 15,69% relacionado ao custo fixo total. (MANHIÇA et al., 2013). Os estudos de Almeida (2006) e Almeida et al. (2010) apontaram que os custos podem variar muito entre as fábricas, devido à tecnologia empregada na produção, necessidade de mão-de-obra, escassez de matéria-prima e do produto final. Além disso, quando o custo na produção de madeira aumenta por

conta dos custos fixos e variáveis, a tendência é que a produção deste produto diminua, bem como o consumo de madeira em tora.

Manhiça (2010), descreveu que algumas serrarias buscam utilizar novas tecnologias e otimizar o processo produtivo relacionado ao desdobro de madeira com o intuito de reduzir os custos de produção e agregar valor ao produto final. Os custos, por sua vez, dependem da natureza da função da produção – a relação entre os insumos utilizados e a quantidade de produto obtida – e dos preços desses insumos (PINDICK; RUBINFELD, 2010).

Em relação ao efeito do consumo no preço, Hurmekoski et al. (2015) citou que, para os produtos florestais, as variáveis construção, preço e renda *per capita* do consumidor influenciam o consumo de produtos madeireiros. Na maioria dos casos, a queda no preço de um bem aumenta o seu consumo enquanto um aumento no preço pode aumentar o consumo de outro bem considerado substituto (MANKIW, 2015). Quanto ao emprego, a madeira serrada pode ter vários produtos substitutos, como: ferro, concreto e plástico (JOCHEM et al., 2016, HURMEKOSKI, 2015).

Jochem et al. (2016), ao estimar as elasticidades de demandas próprias e cruzadas de preços para produtos a base de madeira e seus substitutos associados no setor de construção da Alemanha, constatou que as elasticidades preço da demanda diferem entre construções residenciais e não residências. Na construção residencial, o preço tem menos importância na escolha de um material de construção específico, sendo que a decisão depende mais de outros fatores (subjetivos). De acordo com Hurmekoski (2015), a utilidade técnica e o preço são os principais fatores que influenciam na decisão de substituir produtos de madeira por produtos de outros materiais.

O custo da madeira em tora é um dos determinantes sobre a formação de preços de madeira serrada de conífera, especialmente em países em desenvolvimento (MORLAND et al., 2018). No entanto, em mercados em que a empresa (produtor) tem poder sobre o preço, é mais fácil para o produtor repassar qualquer elevação de custos para o preço de seus produtos. De acordo com Mendes e Padilha (2007) há um intervalo de tempo entre a mudança no desejo de produzir um produto e a mudança na produção efetiva (real), ou seja, a produção de um determinado produto no ano corrente depende do preço do mesmo produto no ano anterior.

Ainda no que diz respeito à formação e dinâmica dos preços da madeira, estes

dependem, de um lado, dos reflorestamentos e da produtividade das florestas e, do outro lado, do consumo dos diversos produtos de origem madeireira (BANCO NACIONAL DE DESENVOLVIMENTO ECONÔMICO E SOCIAL, 2002). Sobre isso, Buongiorno e Zhu (2014), avaliando o impacto das florestas plantadas na economia global, verificaram que o preço da madeira em tora tem influência direta no consumo de madeira industrializada. Estes mesmos autores, ainda, constataram que a produção de florestas plantadas é impulsionada pela magnitude da alteração de oferta e pela mudança no preço.

Outra variável é a taxa de câmbio que, segundo Gomes (2014), possui relação direta e comportamento elástico com o consumo de produtos florestais e, conseqüentemente, podendo influenciar o preço dos produtos, demonstrando a importância do mercado externo. Quando a moeda estrangeira compra menos unidades de moeda local, os exportadores são incentivados a ofertarem o seu produto para o mercado interno (AGUIAR, 2014). De outro viés, com o câmbio desvalorizado, as empresas são estimuladas a exportar seus produtos. Para Lopez e Gama (2007) o preço praticado no mercado externo pode ser um fator decisivo no sucesso das exportações de um produto.

Em relação a preferência do consumidor, esta é a variável mais indicada para determinar o consumo de algum produto, porém não é quantificada numericamente. As pessoas consomem o que desejam para proporcionar o maior grau de satisfação ou utilidade. Este desejo pode dar início à demanda derivada por diversos outros produtos que são fabricados ou manufaturados por diferentes indústrias. Sobre os consumidores, o crescimento da população também tem relação direta com consumo, isso porque há um aumento na procura por bens e serviços. Contudo, juntamente com o crescimento da população, é necessário que haja um aumento na renda domiciliar média (MANKIW, 2015).

Em relação à renda *per capita*, Pindyck e Rubinfeld (2010) citaram que o aumento dela faz os consumidores gastarem mais em qualquer dos bens disponíveis a eles, contudo, com menores rendas o critério de escolha do consumidor pode mudar para os bens necessários, considerados inferiores (de menor preço) em detrimento dos bens superiores (bens de luxo). Tais fatores são considerados para a mensuração da elasticidade-renda da demanda.

3.4 SÉRIES TEMPORAIS

Série temporal ou histórica é a classe de fenômeno cujo processo observacional e consequente quantificação numérica geram uma sequência de dados obtidos em intervalos regulares de tempo durante um período específico. Elas podem ser estocásticas ou determinísticas (BUENO, 2015).

Uma vez definida como a observação de valores numéricos em ordem sucessiva e sequencial, que uma variável de interesse assume ao longo do tempo, a ordem dos dados é fundamental e geralmente ocorre em intervalos regulares, como: diariamente, semanalmente, mensalmente, trimestralmente, semestralmente, anualmente (GUJARATI; PORTER, 2011).

De acordo com Sharpe et al. (2011), dentre outras características que as séries temporais apresentam, destacam-se as componentes:

- a) tendência: a maioria das séries podem ser crescente ou decrescente com outras flutuações em torno dela;
- b) sazonalidade: é a parte da variação que flutua de uma forma aproximadamente estável ao longo do tempo com relação ao ritmo, direção e magnitude, apresentando entre os picos o período;
- c) cíclica: constitui ciclos regulares nos dados com períodos além de um ano e podem, algumas vezes, ser modeladas com comportamento regular, por estarem relacionadas a um fenômeno previsível ou com a introdução de uma variável que represente um dado fenômeno previsível; e
- d) aleatória: é a parte dos dados que não é ajustada por um modelo (resíduo), denominado de flutuações aleatórias dos dados.

Neste contexto, a característica mais importante das séries temporais é a dependência que as observações vizinhas possuem. Além disso, o objetivo da utilização do modelo de dados é analisar e modelar esta dependência. As observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas, presença de tendências e variação sazonal ou cíclica podem ser difíceis de estimar ou remover (EHLERS, 2007; MANCUSO, 2014).

Neste sentido, a obtenção de séries temporais (históricas) pode ser feita em bancos de dados de instituições públicas ou privadas que registram as observações.

Entretanto, em relação a qualidade de alguns dados disponíveis na internet, como dados relacionados a ciência social, podem estar abaixo do desejável, isto porque a maioria deles não são controlados pelo pesquisador e alguns apresentam erros de medição elevados em decorrência de aproximações e arredondamentos (HILL et al., 2010; GUJARATI; PORTER, 2011)

Outro fator relevante é a agregação dos dados, que representam grandes regiões geográficas, mostrando pouco sobre as microunidades individuais. Granger e Newbold (1986) citaram ainda que as séries econômicas são não-estacionárias.

Uma série temporal é estacionária quando se desenvolve no tempo, aleatoriamente, em torno de uma média constante, refletindo uma forma de equilíbrio estável. Além disso, para tornar a série temporal estacionária é necessário transformar os dados originais em logaritmos, e o procedimento mais comum consiste em tomar diferenças sucessivas da série original (VILLAMAGNA, 2013).

Pindyck e Rubenfield (2004), descreveram que a análise de séries temporais se aplica em casos em que há um padrão persistente ou sistemático no comportamento da variável, possível de captar por meio de uma representação paramétrica. De acordo com Ehlers (2007), a predição é um dos principais objetivos dos estudos de séries temporais, sendo os valores previstos com base em valores de períodos anteriores ($t - 1$).

De forma geral, de acordo com Ehlers (2007) os principais objetivos dos estudos de séries temporais consistem em:

- a) descrição: entender o mecanismo da série, compreender o seu comportamento, encontrar periodicidade, padrão de tendência, existência variação sazonal ou cíclica, observações discrepantes (*outliers*) e alterações estruturais;
- b) explicação: usar a variação em uma série para explicar a variação em outra;
- c) previsão: estimar valores futuros com base em valores passados. Para isso admitisse que o futuro envolve incerteza e que por isso, as previsões não são perfeitas. Por isso, deve-se buscar a redução dos erros de previsão; e
- d) controle: os valores da série temporal podem indicar um processo.

No setor florestal, os principais estudos com a utilização de séries temporais são voltados para elaborar modelos econométricos e elasticidades-preço e renda da demanda por produtos florestais em diversos países (BUONGIORNO, 1996; MICHINAKA et al., 2011; BUONGIORNO, 2014; BUONGIORNO, 2015b). Outros importantes estudos estão relacionados com a análise econométrica para determinar a demanda por produtos florestais pelos diversos setores industriais e os fatores que afetam o consumo por madeira serrada na Europa (HURMEKOSKI et al., 2011; HAIM et al., 2014, JOCHEM et al., 2016).

3.5 MODELOS ECONOMÉTRICOS

Os modelos econométricos são representações simplificadas da realidade, sendo que, para descrevê-la completamente, seria necessário desenvolver um modelo extremamente complexo que teria pouco uso prático (MUNIZ JR et al., 2012). Os modelos econométricos são ferramentas que auxiliam o esclarecimento das relações entre determinadas variáveis, ou seja, um modelo é uma forma de testar se existe, de fato, evidência empírica para uma determinada hipótese (VALERIUS, 2016).

Segundo Hill et al. (2010) a econometria trata do uso da teoria e dados econômicos, negócios e ciências sociais, juntamente com recursos da matemática e estatística, para responder questões quantitativas. Gujarati e Porter (2011), citam que a econometria é o resultado de determinada perspectiva sobre o papel da economia. Consiste na aplicação da estatística matemática e dados econômicos para dar suporte empírico aos modelos formulados pela economia matemática e obter resultados numéricos.

A econometria se divide em teórica e aplicada e, dentro de cada categoria, pode ser abordada o método Bayesiano e Clássico (GUJARATI; PORTER, 2011). Hsiao e Wan (2011), citam que o método Bayesiano é superior ao Clássico. Para Fernandes (1995), esta superioridade ocorre por causa da representação paramétrica, em que os modelos são analisados em sua forma estrutural, atribuindo-se a cada parâmetro uma interpretação específica. Além disso, propicia um tipo de estimação essencialmente recursivo, que a cada instante atualiza a estimativa dos parâmetros combinando a estimativa anterior com a informação daquele instante. Os parâmetros do modelo são interpretados como variáveis aleatórias e não simplesmente quantidades desconhecidas. Ainda, a natureza bayesiana do método permite

considerar que o modelo em funcionamento num dado instante de tempo pode não ser adequado no instante seguinte.

Ainda segundo Fernandes (1995), a formulação matemática do modelo bayesiano é feita por meio de um sistema de duas equações estocásticas, formando o Modelo Linear Dinâmico (MLD). Diante disso, descreveu o processo gerador das observações em termos de um vetor de parâmetros estocásticos (estados) acrescidos de um ruído branco.

Entretanto, a abordagem clássica recebe destaque pelo potencial apresentado e acurácia, por meio da combinação via variância mínima e ajustes por regressão. (WEATHERFORD; KIMES, 2003; GUJARATI; PORTER, 2011; CHEN, 2011; MANCUSO, 2013). Wooldridge (2002), explicou que os modelos fornecem uma relação contemporânea entre as variáveis explicativas e a variável dependente.

Para Gujarati e Porter (2011), os modelos econométricos tem por objetivo determinar aproximações e não relações exatas entre a teoria e a realidade, pois não incluem todas as variáveis que participam do comportamento do fenômeno que é analisado. Ainda, o valor da variável dependente pode ser estimado com base nos valores conhecidos de variáveis independentes ou explanatórias.

Matos (2000), afirmou que o modelo econométrico pode ser aplicado de forma empírica, sendo uma maneira simplificada de representar a realidade, estruturado de forma a relacionar a teoria sobre o funcionamento de um fenômeno com fatos observados. Dentre os modelos econométricos, o método de Mínimo Quadrados Ordinários (MQO) é um dos mais utilizados. Este modelo é a primeira etapa de grande parte das análises econométricas, por ser um dos mais eficientes e difundidos dentre os métodos de análise de regressão (GUJARATI; PORTER, 2011).

No princípio do MQO, os estimadores dos parâmetros (α e β) conduzem à menor soma dos quadrados das diferenças entre os valores observados e as estimativas, buscando encontrar o melhor ajuste para um conjunto de dados. Essas diferenças são chamadas de resíduos (WERNER, 2004).

Navarro e Myung (2004), salientaram que há vários fatores para considerar ao avaliar um modelo. De forma geral, métodos estatísticos podem ser usados para medir a suficiência descritiva de um modelo, ajustando os dados e testando esses ajustes, simplicidade e generalização, usando ferramentas de seleção de modelos. Ademais, a qualidade de um modelo também depende de sua interpretação, consistência com outros modelos, aceitação e probabilidade global. Para isso, é

preciso usar julgamentos propriamente subjetivos, porém não menos importantes.

Um objetivo realista visa encontrar um modelo que represente uma boa aproximação da previsão com a realidade sendo que, em um senso estatisticamente definido, é preciso reconhecer que todos os modelos estão errados e que não há como substituir as avaliações pessoais e o bom-senso. Razão pela qual as variáveis, por si só, explicam resultados aproximados, mas não exatos (NAVARRO; MYUNG, 2004).

Previsão é o processo de estimar um evento, tendência, valores ou observações futuras, baseado em dados históricos (passado). Tais dados são combinados sistematicamente de maneira predeterminada para se obter uma estimativa futura, fornecendo informações com o propósito de planejamento e tomada de decisão (MEDEIROS, 2006; MORETTIN; TOLOI, 2006).

Já para Martins e Laugeni (1999), previsão é um processo metodológico para determinação de dados futuros, baseados em modelos matemáticos, estatísticos, econométricos em modelos subjetivos. Em discordância, Godet (2000), afirmou que estes modelos se tornam ineficazes, pois são criados com referências passadas e não integram parâmetros qualitativos e comportamentais às previsões.

A previsão de dados pode ser definida como um processo qualitativo ou quantitativo, usadas para tentar prever o futuro (MANCUSO; WERNER, 2014). Neste último processo, um dos modelos básicos utilizados é de séries temporais e proporciona uma boa aproximação da realidade a curto prazo, não obstante as incertezas deverão existir (CORRÊA, 2000).

Entre os resultados reais que podem ser sazonais, aleatórios ou tendenciosos, e os valores previstos, podem existir oscilações, dependendo da variável. Entretanto, algumas delas ocorrem porque os métodos usados para gerar as previsões, são insuficientes, e isso aumenta quando as previsões são de médio e longo prazo (TUBINO, 2000).

Makridakis et al. (1982) afirmaram que, para obter previsões, existem métodos puramente subjetivos, como a opinião de especialistas, modelos causais ou explanatórios, como os econométricos e modelos extrapolativos como as séries temporais ou, ainda, a combinação de todos. Para Vere e Griffith (1990), apresentaram nas atividades relacionadas ao agronegócio, dada a defasagem existente entre as decisões de produção e seus efeitos, a necessidade de informações preditivas de variáveis de mercado são fundamentais.

Dentre os modelos de previsão, os de regressão dinâmica combinam a

dinâmica de séries temporais com o efeito de variáveis explicativas. Neste processo, o termo dinâmico significa um modelo de regressão no qual se inclui a estrutura de dependência de uma série temporal (HAMILTON, 1994).

Neste contexto, estes modelos são utilizados quando há uma estrutura de dependência entre a variável de interesse e possíveis variáveis exógenas e, ao mesmo tempo, uma estrutura de correlação da série dependente indicar que não se pode supor a independência dos erros. A aplicação destes modelos é aceitável quando os resíduos de cada equação são correlacionados no momento das estimativas das equações separadas (KLIDZIO, 2009).

A elaboração dos modelos de regressão dinâmica em muitos casos, torna-se um processo difícil, pois é necessário escolher as variáveis a serem incluídas no modelo e defasagens destas variáveis, tais fatores desencadeiam um procedimento iterativo com vários estágios (KLIDZIO, 2009). Nos modelos de regressão dinâmica, a variável dependente é explicada por seus valores defasados, valores atuais e passados de variáveis exógenas (ZANINI et al., 2000).

Segundo Hyndman e Khandakar (2008), diversos outros modelos são utilizados para previsão, dentre eles o alisamento exponencial, ou volatilidade exponencialmente ponderada, que busca valorizar as ocorrências mais recentes. Para Armstrong e Brodie (1999) esta técnica é mais popular e com melhor benefício/custo. A sua popularidade se deve a robustez e praticidade nas aplicações em que um grande número de séries deve ser modelado, características valorizadas por Taylor (2003).

Embora para Granger e Newbold (1986) o conjunto de informações relativos ao comportamento de uma variável econômica qualquer não se restrinja somente ao seu comportamento passado, os modelos de previsões podem ser elaborados rapidamente, com uma aplicação imediata com baixo custo. Para tal, as previsões obtidas podem ser utilizadas em combinações com outras de modo a otimizar outras previsões e ao produzir uma previsão univariada, tem-se a possibilidade de determinar em que medida a oscilação da variável pode ser explicada por seu comportamento passado.

Os modelos univariados, baseados somente na análise da variável em si, são um dos modelos de previsão de séries temporais mais simples, são constituídos a partir de processos estocásticos especiais, que buscam estimar o valor futuro da variável em questão com base somente em seus valores passados (BRESSAN,

2004). Sobre o uso deste tipo de modelo econométrico, Berti (2004), constatou que o modelo univariado apresentou desempenho inferior ao multivariado, para a previsão do preço da celulose no mercado internacional.

Dentre as técnicas disponíveis de alisamento ou suavização exponencial, destacam-se a exponencial simples, dupla, e modelo linear *Holt* (para as séries que apresentam o componente de tendência), usado por Moon e Shin (2018) e o modelo de *Holt-Winters* (quando a série apresentar tanto o componente de tendência quanto o componente sazonal) são as técnicas de suavização exponencial que mais se destacam na modelagem de séries temporais. A finalidade destas técnicas é identificar um padrão básico, assumindo que os valores extremos da série são flutuações aleatórias (MORETTIN; TOLOI, 2006). De acordo com Gujarati e Porter (2011), estas técnicas são muito utilizadas na área de negócios e economia.

Para buscar atenuar a subjetividade, as técnicas de previsão deixaram de ser usadas apenas de forma individual e diversos métodos de combinação de previsão vem sendo aplicados por seu desempenho, embora ainda não haja um consenso de que algum método seja superior aos demais (MOON; SHIN 2018).

Sendo assim, dentre os métodos de combinação de previsões, o mais conhecido é de média simples. Alguns autores adotam o método de combinação ponderada, dentre eles Figlewski e Urich (1983), Clemen (1989), Buongiorno (1996), Menezes et al. (2000) e Jeong e Kim (2009).

Para Martins e Werner (2014) a combinação de previsões pelo método da variância mínima é o mais acurado, superando o desempenho da média aritmética. Estudos com outros enfoques, como Hwang (2011), são trazidos pela literatura, saindo da linha de estudos sobre os métodos mais usuais. A utilização de técnicas de redução da dimensão, indicando a previsão de mínimos quadrados parciais, de regressão por componentes principais e de análise fatorial, por exemplo, são considerados superiores aos modelos usuais (PONCELA et al., 2011).

Em relação à regressão por componentes principais, destacam-se os modelos autorregressivos (AR), que são caracterizados como estacionários, pois assumem que o processo está em equilíbrio. Isso acontece quando as médias e as variâncias se mantêm constantes ao longo do tempo e a função de auto covariância depende apenas da defasagem entre os instantes de tempo (BERTI, 2004).

Uma extensão do modelo AR, é o Vetor Autorregressivo (VAR), é um modelo de série temporal usado por Xu e Moon (2013), para prever valores de duas ou mais

variáveis econômicas. Define-se VAR como um sistema de equações lineares dinâmicas, em que cada variável é escrita em função de um erro não-correlacionado e todas as variáveis que pertencem ao sistema possuem o mesmo número de defasagens (KLIDZIO, 2009).

A metodologia VAR assume que todas as variáveis são endógenas e utiliza somente regularidades e padrões passados de séries temporais como base para sua previsão, diferente do modelo de equações simultâneas (KLIDZIO, 2009). A metodologia de VAR possibilita uma estimação conjunta dos parâmetros, considerando as inter-relações e capturando o comportamento dinâmico dos dados, fornecendo uma estrutura entre as variáveis de entrada e de saída do sistema. Dessa maneira, torna-se possível aumentar a acurácia das estimativas do modelo, utilizando-se informações adicionais fornecidas pelas inter-relações (GUJARATI; PORTER, 2011).

3.5.1 Modelo autorregressivo integrado de médias móveis

Os modelos Autorregressivos integrados de médias móveis – ARIMA (ou no inglês, *Auto Regressive Integrated Moving Average*), propostos por Box e Jenkins no ano de 1970 são os mais populares para previsão de séries temporais (CHEN; WNAG, 2007; XU et al., 2010). Nesta técnica, considera-se a sucessão de dependência dos erros, bem como das observações. Desta maneira, elabora-se modelos de forma parcimoniosa que exploram a auto correlação em instantes sucessivos e descrevem com precisão o processo gerador da série temporal, gerando, assim, previsões acuradas de valores futuros (OLIVEIRA et al., 2010).

As vantagens desta técnica são sua flexibilidade, simplicidade e baixo custo (MAKRIDAKIS et al., 1998; MARTÍNEZ; ZAMPROGNO, 2003; MORETTIN; TOLOI, 2006). Os modelos ARIMA, são modelos não-estacionários que resultam da combinação de três componentes: AR (autorregressivo), I (integração) e MA (Médias Móveis). O algoritmo de Box e Jenkins auxilia na escolha do melhor modelo baseado nos gráficos das funções de autocorrelação e de autocorrelação parcial (TSAY, 2005).

Segundo Makridakis et al. (1998), esta metodologia se sobressai, quando comparada a outras técnicas de previsão, por causa da sua facilidade de uso, interpretação, análises profundas e detalhistas, acurácia dos modelos, além da fácil explanação e implementação. Em contrapartida, possuem a desvantagem de serem

lineares e assumir que o modelo por detrás dos dados seja linear podendo ser questionável, pois a relação entre as variáveis é não linear na maioria dos problemas reais (FELISONI et al., 2011). De acordo com Box e Jenkins² (1976) apud Werner e Ribeiro (2003), a construção de um modelo é constituída de três etapas:

- a) identificação: consiste em descobrir qual dentre as várias versões dos modelos de Box-Jenkins, sejam eles sazonais ou não, descreve o comportamento da série. A identificação do modelo a ser estimado ocorre pelo comportamento das funções de autocorrelações. Nesta etapa os componentes ARIMA são identificados respectivamente pelas letras p , d e q ;
- b) estimação: consiste em estimar os parâmetros φ do componente autorregressivo e θ do componente de médias móveis e a variância de ε_t ;
- c) verificação: consiste em fazer um diagnóstico para avaliar se o modelo estimado é adequado para descrever o comportamento dos dados. Para isso, é analisado os resíduos estimados para saber se eles são não correlacionados. Em relação a correlação dos resíduos, Hill et al. (2010), citaram que a autocorrelação é um fenômeno recorrente em séries temporais, em que os dados seguem uma ordenação ao longo do tempo, na qual os erros estão correlacionados entre si e seus efeitos podem permanecer por vários períodos influenciando no sistema.

Para realizar a previsão de séries temporais, Gujarati e Porter (2011) ainda incluem a previsão como quarta e última etapa. A construção do modelo ARIMA pode ser representada a partir de um modelo matemático, em que as séries temporais envolvidas na análise são geradas por um processo estocástico estacionário. Além disso, cabe destacar que, para elaboração de tais modelos, é fundamental a obtenção de uma série temporal estacionária ou uma série temporal que se torna estacionária depois de uma ou mais diferenciações (KLIDZIO, 2009)

Cordeiro et al. (2010) ao buscar elaborar um modelo de previsão de preço de exportação de madeira serrada de pinus no Brasil, constatou que a metodologia Box

² BOX, G. E. P.; JENKINS, G. M. **Time series analysis forecasting and control**. San Francisco: Holden- Day, 1976. Edição revisada.

e Jenkins mostrou-se de grande utilidade na área da engenharia florestal, por ter sido eficiente e ter apresentado uma projeção satisfatória para o período de setembro de 2007 a agosto de 2008. Já Almeida et al. (2009b), ao buscar estimar um modelo de previsão do preço internacional do compensado produzido no estado do Paraná, por meio da metodologia Box e Jenkins, detectou uma variação de 3% para um período a frente, apresentando valores estimados bem próximos ao valor real, entretanto, não apresentou boa eficácia para previsões em períodos mais distantes, evidenciando a eficiência do modelo de previsão apenas no curto prazo.

Hwang (2011), ao elaborar modelos de séries temporais para previsão de custos de construção, constatou que o modelo ARMA, foi superior ao VAR e ARIMA. Desta forma, pelo fato de uma mesma série de dados apresentar diferentes modelos, cabe ao analista identificar o melhor, baseado em sua experiência e subjetividade (LU; ABOURIZK, 2009).

3.5.2 Rede neural artificial

A Rede Neural Artificial (RNA) busca, por meio de técnicas inspiradas no neurônio biológico do cérebro humano, o desenvolvimento de sistemas inteligentes computacionais que visam reproduzir respostas semelhantes aos de seres humanos, tais como: percepção, raciocínio, aprendizado, evolução e adaptação; por meio do aprendizado com novas situações (SOUZA et al., 2014; HAIR et al., 2009).

O psicólogo Warren McCulloch e o matemático Walter Pitts foram os que conceberam o primeiro modelo na área de redes neurais. Em 1943, eles representaram os conceitos de combinação de neurônios, pesos e seu limiar de excitação, estes denominados *thresholds* (MACCULLOCH; PITTS, 1943). Em 1949, Donald Hebb, um psicólogo da McGill University, definiu a primeira lei de aprendizagem para as redes neurais. Sua premissa era de que se dois neurônios fossem ativados simultaneamente, então o resultado da conexão entre eles deveria ser reforçado (HEBB, 1949).

Em 1958, Frank Rosenblatt introduziu e desenvolveu uma classe de redes neurais, denominada *perceptron* ou discriminador linear. Este modelo consiste de uma rede de múltiplos neurônios artificiais dispostos em três camadas, denominada MLP (ou no inglês, *Multilayer Perceptron*), sendo o modelo de RNA mais utilizado na previsão de séries temporais (HAYKIN, 2001; PALMER et al., 2006). Segundo Hair et

al. (2009), este modelo de RNA é formado pelos nós (camadas) de entrada, de saída e intermediários, estes últimos são os ocultos. Além disso, toda a rede é alimentada por dados enviados pelos nós de entrada.

A camada de entrada fornece os dados ou informações (insumos), a camada oculta recebe as informações da camada de insumos, ou de outra camada oculta e fornece as informações para outra camada oculta ou para a camada de saída. Do ponto de vista estatístico, cada nó de entrada representa uma variável independente e seu efeito se propaga através da rede, camada por camada e cada nó de saída representa uma variável dependente, que está sendo prevista por meio da rede, sem alterar os pesos sinápticos (HAYKIN, 2001; PALMER et al., 2006).

A ativação da rede neural acontece por uma função não-linear, como a função sigmoide, por exemplo, da classe de curvas em forma de 'S' que inclui a função logística. (HAYKIN, 2001). Embora existam ligações e dependências básicas na maioria desses neurônios, muitos deles podem processar a informação, independentemente dos outros. (TURBAN, 1993).

Haykin (2001) cita que as fases necessárias para a implantação de uma rede neural são: (1) organizar uma base de dados com as informações relevantes e disponíveis; (2) separar estas informações em dois grupos: o primeiro para a fase de aprendizagem da rede e o segundo para a fase de teste; (3) realizar as transformações e codificações necessárias nas variáveis de modo a servir de entrada para a rede; (4) selecionar, treinar e tesar a rede, até que os resultados sejam considerados adequados; (5) aplicar o modelo desenvolvido ao problema de pesquisa. Corrar et al. (2007) afirmou que, para a montagem da estrutura da rede neural, é necessário determinar o número de camadas e neurônios e o método de aprendizado que será utilizado nos dados preparados.

Em conformidade aos dados, para utilização em RNA precisam antes ser examinados, devido às redes neurais não terem a capacidade de transformar dados de qualidade ruim ou mal coletados em um modelo bem-sucedido (SELAU, 2008). Ademais, é por meio das camadas ocultas que as relações não-lineares entre as variáveis são representadas.

Neste sentido, uma rede neural artificial busca fazer previsões, analisando um grande número de casos na fase de treinamento, em que a rede aprende e memoriza os pesos da rede e que não terão mais alterações significativas e o erro não é mais reduzido. Tal procedimento ocorrerá posteriormente a um número suficiente de

exemplos da amostra de análise terem passado pela rede, obtendo assim um ajuste dentro da amostra. Outra característica importante é a capacidade de generalização dos dados, gerando boas previsões fora da amostra e contribuindo para que uma rede neural artificial possa descobrir respostas corretas mesmo nos casos em que os dados estão incompletos ou danificados (HAYKIN, 2001).

Após a fase de treinamento, uma RNA está em condições para combinar determinado conjunto de valores que são apresentados em suas entradas a um resultado de saída. (HAYKIN, 2001). Corrar et al. (2007), citou que quando a rede neural artificial aprende a reconhecer as entradas significa que a rede está treinada. Dessa forma, a capacidade de aprendizagem ou autocorreção, é a característica mais importante de uma RNA e o fator que destaca a rede das demais técnicas de previsão (HAIR et al., 2009).

Dentre os algoritmos de treinamento mais utilizados, a retropropagação do erro ou *backpropagation* é um dos mais utilizados na rede, e o mais bem-sucedido, possuindo melhores resultados em diversos estudos (HAYKIN, 2001; GEVREY, et al., 2003; ANGELO et al., 2011; SIVARAM, 2014; BARDAK, 2016). Esta técnica foi desenvolvida a partir de estudos de Windrow e Hoof (1960), que desenvolveram o aprendizado da rede neural artificial pela regra delta, em que ajusta os pesos para reduzir a diferença entre a saída da rede e a saída desejada. (ZELL, 1995³ apud ZANETTI JUNIOR; ALMEIDA, 1998). Além disso, o algoritmo possibilita a formação de previsões consistentes com o comportamento da série em estudo, realizando as transformações necessárias à transmissão dos dados para a rede (FITZPATRICK, 1999).

Deste modo, a retropropagação consiste basicamente em dar um passo a frente e outro para trás. Para o aprendizado, a primeira faixa (faixa-treino), capta o padrão de comportamento da série, para a segunda faixa (faixa-teste), testando se o erro foi minimizado. A faixa-treino deve ser suficientemente grande para captar o padrão de comportamento da série, e a faixa-teste deve ser representativa das condições futuras que a rede vai tentar captar para realização da previsão (FITZPATRICK, 1999). Ao comparar os valores de saída da rede, com os esperado, calcula-se o erro. Com isso, os pesos sinápticos são ajustados de acordo com o valor do erro, buscando a redução e ajustando a rede para que a resposta seja mais

³ ZELL, A. et. al. **Stuttgart Neural Network Simulator User Manual**. v. 4.1, 1995.

próxima possível da resposta esperada (HAYKIN, 2001).

Um modelo paralelo entre RNA e os modelos econométricos tradicionais foi traçado por Portugal e Fernandes (1996). Assim, observaram que os modelos econométricos estimam parâmetros para explicar o comportamento de uma variável endógena a partir de variáveis dependentes (endógenas) e variáveis independentes (exógenas), enquanto que as RNA produzem um padrão de comportamento (variável dependente) a partir das informações obtidas nos dados (variáveis independentes) e das ponderações (BRESSAN, 2004).

Ademais, outra diferença entre esses modelos, está relacionada com a camada oculta, que introduz uma relação não-linear entre os dados de entrada e o produto de saída. (BRESSAN, 2004). Outros modelos, como por exemplo o método de Box-Jenkins, necessitam que a série de tempo analisada seja gerada a partir de processos lineares (FELISONI et al., 2011).

Os modelos de RNA não contam com uma base estatística predeterminada, apenas com entradas e saída de informações. No entanto, de acordo com Felisoni et al. (2011) a ausência de uma base estatística impede a construção de intervalos de confiança para previsões resultantes de modelos de RNA. Por isso, as previsões são sempre pontuais, porém passíveis de comparação com outros modelos por intermédio de medidas como o erro percentual médio de previsão.

As redes neurais agregam uma explicação mais eficaz diante das complexas correlações e interações entre as variáveis independentes que, muitas vezes, são realmente não-lineares (SELAU, 2008). Para Zhang (2003) as RNA podem ser uma alternativa promissora aos tradicionais métodos lineares por sua capacidade de modelação não-linear. Outra característica é o fato deste modelo de previsão ser um dos mais precisos (KHASHEI; BIJARI, 2010).

A dificuldade de interpretação e comparação com modelos clássicos, se torna uma desvantagem das redes neurais. Alguns autores denominam esta condição nas RNA de: “problema da caixa-preta” (FLORÊNCIO, 2016). No entanto, as redes neurais podem absorver características importantes da série como: sazonalidade e tendência (MANCUSO; WERNER, 2014).

A rede neural não identifica padrões de comportamento da série temporal e o desenvolvimento da rede incorpora dificuldades e limitações como à identificação da taxa de aprendizado, definição dos pesos iniciais e do número de camadas ocultas (SOUSA; MENEZES, 2003). As redes neurais capturam relações “escondidas” entre

as entradas e saídas com uma aproximação altamente precisa e a interpretação satisfatória de seu comportamento é uma tarefa muito difícil (BENÍTEZ et al., 1997).

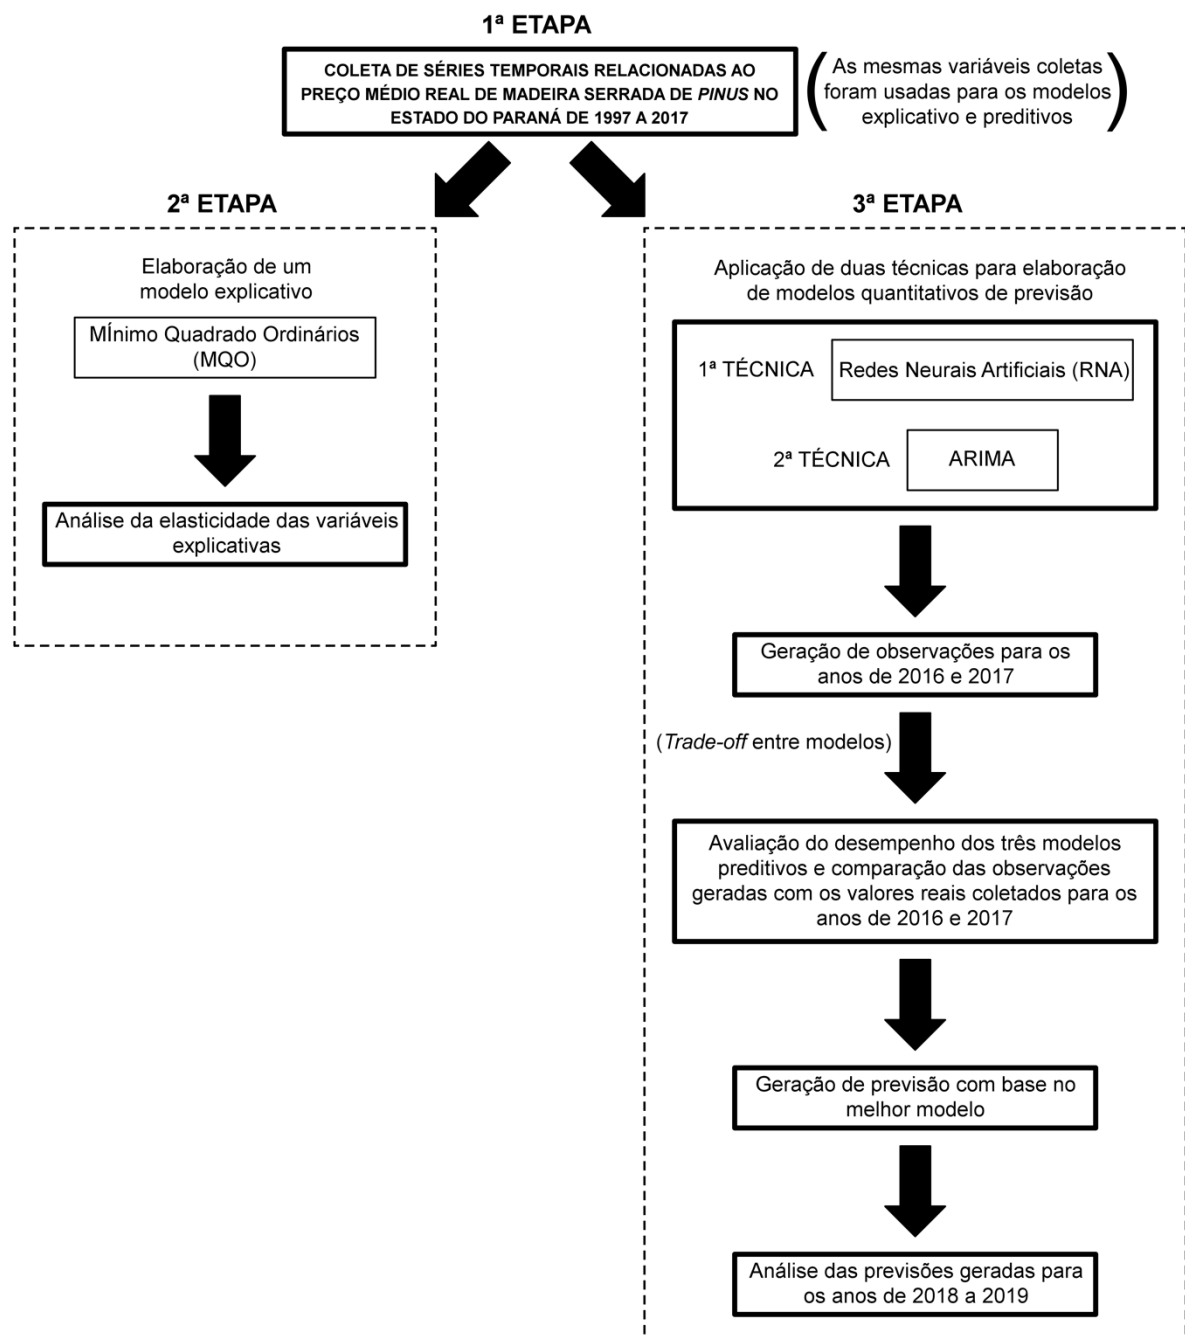
Rede Neural Artificial é uma das técnicas mais usadas para estudos de previsão e que tem despertado grande interesse de pesquisadores, sendo aplicada nas áreas de economia, indústria e ciências tecnológicas, e obtido muito sucesso (WIDROW, et al., 1994; CORRAR et al., 2007). Nas ciências econômicas, as redes neurais têm encontrado várias aplicações interessantes com resultados superiores aos métodos estatísticos convencionais com o uso de séries temporais (CORRAR et al., 2007).

Angelo et al. (2011), ao realizarem uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro, constataram que as redes neurais e modelos ARIMA se mostraram praticamente equivalentes. Bardak et al. (2016) concluíram que as redes neurais são uma ferramenta eficaz na previsão da força de adesão da madeira e bastante útil e confiável, o mesmo foi observado por Jovic et al. (2017) ao estimarem a força de colagem de madeira e consumo de energia no processo de usinagem. No entanto, Sivaram (2014) ao buscar modelar a tendência de preço da madeira de teca, concluiu que estas previsões para o próximo ano pelos modelos univariados do tipo ARIMA e redes neurais ficaram longe dos preços reais devido a fatores imprevistos.

4 MATERIAL E MÉTODOS

A sequência dos procedimentos metodológicos realizados neste trabalho estão demonstrados de forma sistemática e resumida na Figura 2. A primeira etapa corresponde ao material usado neste trabalho, a segunda refere-se ao desenvolvimento do modelo explicativo e a terceira etapa está relacionada com a elaboração dos modelos preditivos e geração da previsão pelo melhor modelo.

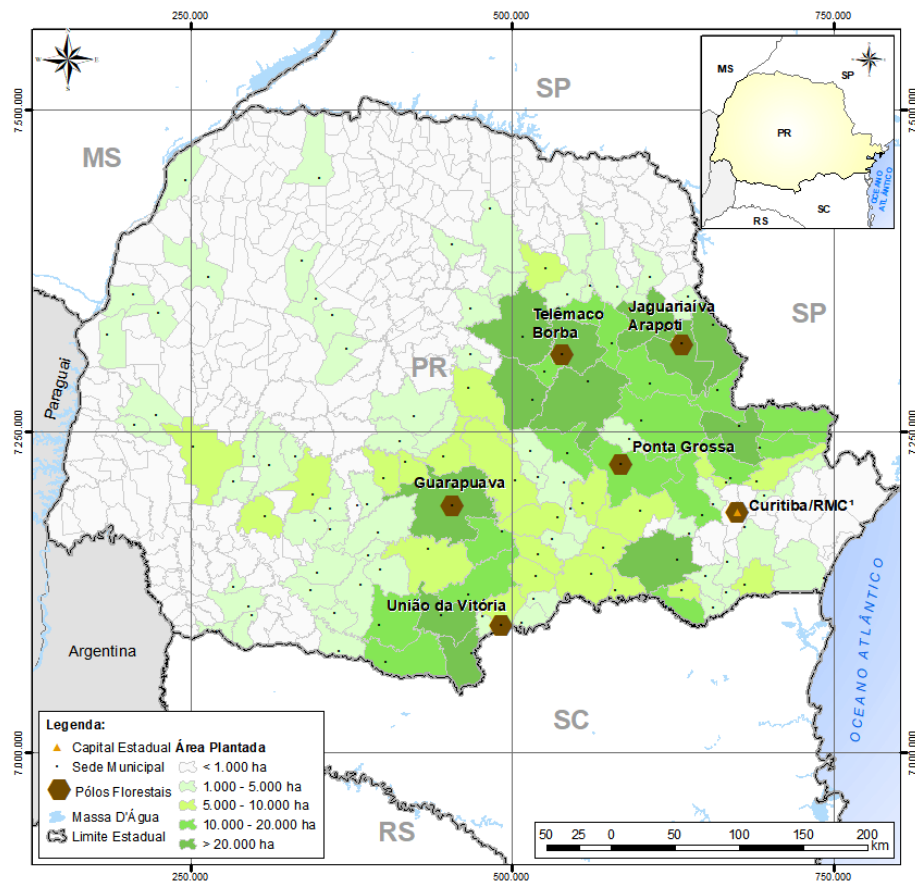
FIGURA 2 – RESUMO DO PROCEDIMENTO SISTEMÁTICO DESENVOLVIDO.



FONTE: O autor (2018)

Na Figura 3 está demonstrada a concentração de florestas plantadas e a localização dos principais polos de empresas e indústrias florestais no estado do Paraná, de onde foram coletados os dados referentes ao preço e produção de madeira paranaense.

FIGURA 3 – MAPA DOS PRINCIPAIS POLOS FLORESTAIS NO ESTADO DO PARANÁ.



FONTE: Associação Paranaense de Empresas de Base Florestal - APRE (2018).

4.1 MATERIAL

4.1.1 Dados

4.1.1.1 Coleta de dados

Esta parte corresponde à primeira etapa do trabalho, referente à coleta de variáveis. Para realização deste estudo, foram utilizados dados secundários que foram coletados em bancos de dados de fontes públicas, sendo elas: a) Secretaria da Agricultura e do Abastecimento do estado do Paraná, Departamento de Economia Rural; b) *International Tropical Timber Organization*; c) Instituto de Pesquisa

Econômica Aplicada; d) Sindicato da Indústria da Construção Civil no estado do Paraná; e) Instituto Brasileiro de Geografia e Estatística; f) Departamento de Informática do Sistema Único de Saúde; g) Banco Central do Brasil; h) Ministério de Desenvolvimento Indústria e Comércio exterior.

Estes dados foram de periodicidade anual abrangendo o período de 1997 a 2017, totalizando 21 observações para cada variável, organizadas em séries temporais. Este período de análise foi baseado na premissa de obter o maior conjunto de séries temporais com a mesma quantidade de observações, requisito necessário para os tipos de modelos elaborados.

A maioria dos dados foram coletados no intervalo de tempo requerido (anual), entretanto, pelo fato das séries de preços e exportações terem sido publicadas mensalmente, elas foram transformadas em anuais por meio da média aritmética de seus valores mensais, conforme também realizado por (HWANG, 2011; SUN; ZHOU, 2018).

Quanto ao corte temporal, tratou-se de um estudo seccional com avaliação longitudinal. Segundo Gil (2002) este trabalho é classificado como pesquisa *ex-post facto*, já que o pesquisador não dispõe de controle sobre a variável independente, que constitui o fator presumível do fenômeno, sendo que os dados foram coletados após as suas ocorrências.

4.1.1.2 Variáveis incluídas nos modelos

Neste estudo, utilizou-se a modelagem econométrica para analisar a influência de variáveis sobre a formação do preço de madeira serrada de pinus no estado do Paraná. Da mesma forma, buscou-se formar um modelo de previsão utilizando as mesmas variáveis. Segundo Gujarati e Porter (2011), neste caso deve ser considerado a experiência do analista e trabalhos empíricos anteriores.

Existem diversas variáveis explicativas associadas ao preço, no entanto, o intuito de se construir um modelo econométrico é analisar o efeito das variáveis mais representativas. Normalmente, elas são selecionadas segundo a opinião de especialistas ou até mesmo da disponibilidade de dados (SENRA, 2007).

Na elaboração destes modelos, há o método *forward*, que constitui em iniciar um modelo com adição de variáveis independentes que melhoram o modelo e o método *backward*, em que se inicia a elaboração do modelo com todas as variáveis

independentes, eliminando as variáveis que menos melhoram o modelo (GUJARATI; PORTER, 2011).

Ao todo foram coletadas séries temporais de 20 variáveis. Estas variáveis tiveram o intuito de captar o efeito do produtor (oferta), do consumidor (demanda nacional e internacional) e dos produtos substitutos, sobre o preço da madeira serrada de pinus no Paraná (QUADRO 2).

QUADRO 2 – SÉRIES TEMPORAIS ANUAIS UTILIZADAS PARA GERAR OS MODELOS.

| | Variáveis | Código | Unidade | Fonte de dados |
|--|---|--|---------------------|-----------------------------|
| Dep. | Preço médio real de madeira serrada de pinus no Paraná (ano base = 2017) | PR_t^{ser} | R\$/m ³ | SEAB/DERAL |
| Oferta | Preço médio real de madeira em tora de pinus no Paraná (ano base = 2017) | PR_t^{tor} | R\$/m ³ | SEAB/DERAL |
| | Produção de madeira serrada de pinus no Brasil | Pbr_t^{ser} | m ³ | ITTO |
| | Produção de madeira serrada de pinus no Paraná | Ppr_t^{ser} | m ³ | SEAB/DERAL |
| | Produção de tora de pinus para serraria no Paraná | Ppr_t^{tor} | m ³ | SEAB/DERAL |
| | Salário mínimo real nacional (ano base = 2017) | SM_t^{br} | R\$ | IPEADATA |
| | Taxa básica de juros real do Brasil - SELIC (ano base = 2017) | J_t | % | BACEN |
| | Demanda Nacional | Consumo aparente de madeira serrada de pinus no Brasil | Cbr_t^{ser} | m ³ |
| Consumo aparente <i>per capita</i> de madeira serrada de pinus no Brasil | | $CPCbr_t^{ser}$ | m ³ /uni | Equação (4) |
| PIB real do setor de construção civil do estado do Paraná (ano base = 2017) | | PIB_t^{civpr} | R\$ | SINDUSCON PR |
| PIB real do setor de construção civil do estado de São Paulo (ano base = 2017) | | PIB_t^{civsp} | R\$ | IBGE/SIDRA |
| População brasileira | | PO_t^{br} | Uni. | DATASUS |
| Renda domiciliar <i>per capita</i> real média do Brasil (ano base = 2017) | | R_t^{br} | R\$ | IBGE/SIDRA |
| Demanda internacional | Novas unidades de habitações permitidas nos Estados Unidos (<i>House permits</i>) | HP_t | Uni. | United States Census Bureau |
| | Taxa de câmbio efetiva | Ce_t | R\$/US\$ | BACEN |
| | Taxa de câmbio real entre o real brasileiro e dólar americano (ano base = 2017) | Cr_t | R\$/US\$ | IPEADATA |
| | Exportações paranaenses de madeira serrada de pinus ao Mundo | Exm_t^{ser} | m ³ | Alice Web/MDIC |
| | Exportações paranaenses de madeira serrada de pinus aos Estados Unidos | $Exeua_t^{ser}$ | m ³ | Alice Web/MDIC |
| Sub. | Preço médio real da madeira serrada de eucalipto no Paraná (ano base = 2017) | $PREuc_t^{ser}$ | R\$/m ³ | SEAB/DERAL |
| | Preço médio real do ferro no Brasil (ano base = 2017) | $PRfer_t$ | R\$/t | IBGE/SIDRA |

LEGENDA: Dep.: Variável dependente; SEAB: Secretaria da Agricultura e do Abastecimento do estado do Paraná; DERAL: Departamento de Economia Rural; ITTO: *International Tropical Timber Organization*; IPEA: Instituto de Pesquisa Econômica Aplicada; SINDUSCON PR: Sindicato da Indústria da Construção Civil no estado do Paraná; IBGE: Instituto Brasileiro de Geografia e Estatística; SIDRA: Sistema IBGE de Recuperação Automática; DATASUS: Departamento de Informática do Sistema Único de Saúde; BACEN: Banco Central do Brasil; Alice Web: Sistema de Análise das Informações de Comércio Exterior via Web; MDIC: Ministério de Desenvolvimento, Indústria e Comércio Exterior; SELIC: Sistema Especial de Liquidação e de Custódia; e PIB: Produto Interno Bruto.

FONTE: O autor (2018).

A formação do preço de um produto se dá pela interação de suas curvas de oferta e demanda. Assim, devem ser consideradas tanto as variáveis determinantes da oferta quanto da demanda na especificação de um modelo explicativo de preço (PINDYCK; RUBINFELD, 2011). É esperado que haja um equilíbrio de mercado entre oferta e demanda, que determinará o preço (VASCONCELLOS; GARCIA, 2014).

Foi considerada a produção e consumo aparente nacional de madeira serrada de pinus. A decisão de utilizar variáveis relacionadas ao consumo, produção e exportação para captar o efeito da demanda internacional e o preço de produtos substitutos na demanda para modelagem econométrica do setor florestal, corrobora com Buongiorno (1996) e Buongiorno (2014).

A madeira serrada produzida pela indústria paranaense é comercializada no mercado interno e externo e, como tal, a sua quantidade demandada é exógena ao estado do Paraná (ALMEIDA, 2006). Neste sentido, para captar o desempenho do consumidor, foram consideradas variáveis relacionadas à demanda nacional e internacional.

Foi também utilizado o consumo aparente *per capita*, pois este escalonamento normaliza os dados em relação ao tamanho do mercado. Além disso, os modelos que envolvem consumo de produtos florestais são frequentemente baseados no conceito de demanda derivada. A indústria moveleira e da construção civil, seguidas da indústria da embalagem são os setores que mais consomem madeira serrada de pinus (ABIMCI, 2016). Devido a esse predomínio, os deslocadores de demanda estão geralmente ligados a fatores de atividade econômica como renda, taxa de juros, confiança do consumidor e fatores demográficos, como taxa de natalidade (PUNHAGUI et al, 2012; HURMEKOSKI et al., 2015).

Dessa forma, a renda domiciliar foi utilizada com o intuito de captar os possíveis estímulos que ela pode gerar no consumidor, ocasionando variações no consumo e conseqüentemente no preço. O mesmo raciocínio foi adotado em relação ao PIB da construção civil, pois espera-se que a variação deste indicador seja consequência da variação no consumo dos diversos materiais usados na construção civil, incluindo a madeira serrada. Estas variáveis foram também usadas por Michinaka et al. (2011), Buongiorno (2015b) e Jochem et al. (2016).

O crescimento da população também tem relação direta com o consumo, e por isso foi considerado. O seu crescimento gera naturalmente um aumento na procura por bens e serviços

Para captar a influência dos bens substitutos ou complementares da madeira na demanda e compreender o efeito dessas possíveis relações foram considerados: o preço pago pela madeira serrada de eucalipto e do ferro. A mesma consideração foi feita por Buongiorno (1996) e Hurmekoski et al. (2015).

Devido à falta de uma série histórica referente ao custo de produção de madeira serrada, esta foi explicada pela inclusão de variável que captou a variação do salário mínimo real e custo da matéria prima (preço médio real de madeira em tora de pinus).

4.1.1.3 Considerações sobre a coleta de dados

Neste trabalho foram constatadas dificuldades na coleta de dados. Por isso, um dos grandes desafios do presente estudo foi ter cautela para obter dados coerentes e úteis para a análise econômica.

A natureza e a fonte de dados foram fatores preocupantes em relação à coleta das amostras. Isso porque, muitos dados foram variáveis socioeconômicas aleatórias observadas, com valores que não foram gerados por um experimento controlado. Esses dados podem, conseqüentemente, ter sido coletados para outros fins que não sejam de análise científica.

A qualidade de muitos dados disponíveis na internet para a pesquisa econômica são abaixo do desejável, por apresentarem erros de medição elevados em decorrência de aproximações e arredondamentos (HILL et al., 2010; GUJARATI; PORTER, 2011). No entanto, isso não impede que pesquisas sejam realizadas, mas exigem ponderação para se obter dados confiáveis e estruturá-los de maneira congruente para utilização nos modelos.

Os dados de volume exportado e importado de madeira serrada de pinus são disponibilizados no Alice Web em quilograma, que posteriormente precisaram ser transformados para volume medido em metro cúbico, pois comumente se analisa o preço de produtos madeireiros nestas unidades.

4.2 MÉTODOS

4.2.1 Adequação dos dados

Após a coleta dos dados, foi necessário examiná-los em relação às condições de identificação da função de interesse sobre os problemas de agregação envolvidos nas variáveis funcionais e quanto ao grau de correlação entre as variáveis explicativas (KOUTSOYIANNIS⁴, 1978 apud ALMEIDA, 2006).

No presente trabalho, não foi necessário realizar o exame das condições de identificação da função em que se estabelece quais coeficientes estimados pela aplicação de alguma técnica econométrica apropriada são os verdadeiros coeficientes da função de interesse (ALMEIDA, 2006). Isso porque, houve a adição de variáveis explicativas que representaram o efeito da oferta e demanda de madeira serrada. O mesmo ocorreu em relação à agregação de indivíduos, pelo fato do objeto de estudo ser unicamente a madeira serrada de pinus.

No que diz respeito à agregação de bens, volume produzido de madeira serrada e tora de pinus e preço e consumo aparente, não foram diferenciadas por bitola (tipos de madeira serrada ou diâmetro de tora), pois foi utilizado o preço médio da tora), ou por espécie. Entretanto, isto não foi um problema, já que não se buscou trabalhar com sortimentos, mas com o produto.

Em relação à agregação espacial dos dados para elaboração do modelo, eles foram reunidos em função do mercado da madeira serrada de pinus. Desta forma, considerou-se variáveis relacionadas à construção civil nos estados do Paraná, São Paulo e mercado internacional. Devido à inexistência da variável de consumo paranaense de madeira serrada, foi utilizado o consumo aparente nacional como *proxy*⁵, já que esta engloba todo o mercado interno.

Sabe-se que o mercado paranaense de madeira serrada de pinus é o primeiro com maior produção e consumo no Brasil e que a dinâmica de seu mercado pode ser diferente da dinâmica nacional. No entanto, o uso de uma *proxy* de consumo aparente de madeira serrada de pinus no Paraná poderia resultar em valores equivocados, devido à dificuldade de se determinar o volume consumido e produzido exclusivamente pelas indústrias deste Estado.

A produção de madeira serrada de pinus no estado do Paraná foi obtida por meio de uma *proxy* (equação 1), na qual utilizou-se um fator de conversão f com, base

⁴ KOUTSOYIANNIS, A. **Theory of econometrics**. 2. Ed. New Jersey: Barnes & Noble Books, 1978.

⁵ Segundo Salvato e Santos (2011), uma variável *proxy* é uma variável observada que é usada para substituir uma variável não observável, mas que tem um comportamento similar.

nos valores de produção de toras de pinus para serraria, coletados no banco de dados do Departamento de Economia Rural da Secretaria da Agricultura e do Abastecimento do estado do Paraná. Este cálculo foi fundamentado no método descrito por Murara Junior et al. (2013) e adaptado para este trabalho.

$$Vserrada_j = \frac{Vtoraserraria_j}{f} \quad (1)$$

em que:

$Vserrada_j$ = volume produzido de madeira serrada de pinus no ano j (m^3);
 $Vtoraserraria_j$ = volume produzido de toras de pinus para serraria no ano j (m^3); e
 f = fator de conversão de tora de pinus para serraria para madeira serrada de pinus, que neste caso foi 2,2. Com base nos trabalhos de Rocha, (1999), Polzl et al. (2003), Murara Junior et al. (2005), Paraná (2007), Manhiça et al. (2012) e Murara Junior et al. (2013).

Para obter o consumo de madeira serrada de pinus no Brasil, foi utilizado a *proxy* de consumo aparente (equação 2), calculada a partir da metodologia utilizada por Jochem et al. (2016)

$$CA_j = P_j + M_j - X_j \quad (2)$$

em que:

CA_j = consumo aparente da madeira serrada de pinus no Brasil no ano j (m^3);
 P_j = volume produzido da madeira serrada de pinus no Brasil no ano j (m^3);
 M_j = volume importado de madeira serrada de pinus no Brasil no ano j (m^3); e
 X_j = volume exportado de madeira serrada de pinus no Brasil ano j (m^3).

Os dados de exportação e importação coletados (Nomenclatura Comum do Mercosul - NCM 4407.10.00) foram convertidos para metros cúbicos por meio de um cálculo, que segundo Wiecheteck (2017) é usado por empresas e associações do setor florestal paranaense (informação verbal)⁶, conforme descrito na equação (3).

⁶ WIECHETECK, M. S. S. Informação verbal. Curitiba, 2017. Reunião.

$$R = \frac{m}{f} \quad (3)$$

em que:

R = volume de madeira serrada de pinus exportada (m³);
 m = quantidade de madeira serrada de pinus exportada (kg); e
 f = fator de conversão para madeira serrada de conífera (kg/m³).
 O valor do fator de conversão (f) usado para madeira serrada de pinus é 475 kg/m³.

O consumo aparente *per capita* de madeira serrada de pinus no Brasil foi calculado baseando-se na metodologia utilizada por Hurmekoski et al. (2015) descrita na equação (4).

$$CPC_j = \frac{CA_j}{\text{População}_j} \quad (4)$$

em que:

CPC = consumo aparente *per capita* de madeira serrada no ano *j* (m³/uni); e
 CA = consumo aparente da madeira serrada de pinus no Brasil no ano *j* (m³);

Para a escolha da base de um número índice, é preciso escolher um período relativamente estável, em que atividade econômica não foi afetada por variações estruturais ocasionais. A mudança de base é necessária quando pretende-se comparar séries de índices que tenham bases diferentes ou para atualizá-las tornando-as mais próximas da realidade atual, facilitando sua comparação no tempo (MENDES; PADILHA, 2007; REIS, 2017).

Para análise real dos preços utilizados e sua comparação no tempo, descontou-se a inflação acumulada durante o período analisado. Este cálculo foi feito por meio da equação (5), utilizada por Mendes e Padilha (2007).

$$\text{Preço real}_i = \left(\frac{\text{IPCA}_{\text{ano base}}}{\text{IPCA}_i} \right) \times \text{Preço nominal}_i \quad (5)$$

em que:

$IPCA_{ano\ base}$ = Índice Nacional de Preços ao Consumidor Amplo no ano 2017 (base = 100).

Foi escolhido o Índice Nacional de Preços ao Consumidor Amplo (IPCA) para deflacionar o preço da madeira serrada de pinus, o Produto Interno Bruto, renda domiciliar *per capita* média e salário mínimo nacional. Este é o índice que melhor representa a evolução geral dos preços, pois representa a inflação oficial brasileira (REIS, 2017). A taxa de câmbio real entre a moeda brasileira e americana, foi calculado conforme a equação (6) sugerida por Rocha (2012).

$$TCreal_j = \frac{e_j \times CPI_j}{IPCA_j} \quad (6)$$

em que:

$TCreal_j$ = taxa de câmbio real entre o real brasileiro e dólar americano no ano j (R\$ /US\$);
 e_j = taxa de câmbio nominal entre o real brasileiro e dólar americano no ano j (R\$ /US\$);
 CPI_j = *Consumer Price Index* no ano j ; e
 $IPCA_j$ = Índice Nacional de Preços ao Consumidor Amplo no ano j .

As séries temporais usadas foram transformadas em séries estacionárias por meio da diferença logarítmica das observações, conforme sugerido por Bressan (2004) e Gujarati e Porter (2011). Esta diferença foi obtida de acordo com a equação (7), sugerida por Lemgruber (1975).

$$\Delta = \log \left(\frac{Z_t}{Z_{t-1}} \right) \quad (7)$$

em que:

Δ = diferença logarítmica das observações;
 Z_t = valor da observação no ano t ; e
 Z_{t-1} = valor da observação no ano anterior.

Por ser utilizada a diferença logarítmica, foi possível obter a elasticidade das variáveis, sendo que, a partir dessa transformação, a forma funcional dos modelos

passa a ser log-linear (GUJARATI; PORTER, 2011).

Salienta-se que, na Rede neural artificial, os dados foram também normalizados. Silva et al. (2010) citaram que a normalização tem o propósito de minimizar os problemas oriundos do uso de unidades e dispersões entre as variáveis.

Tal normalização justifica-se em razão das séries temporais utilizadas apresentarem amplitudes diferentes umas das outras (heterogêneas). Assim sendo, os dados de entrada foram normalizados com o objetivo de adaptá-los à faixa dinâmica das funções de ativação da rede neural, conforme a equação (8), sugerida por Silva et al. (2010).

$$y = \left(\frac{y_t - \bar{y}}{\sigma_y} \right) \quad (8)$$

em que:

y = valor normalizado;
 y_t = valor real ou observado;
 \bar{y} = média amostral; e
 σ_y = desvio padrão da amostra.

4.2.2 Modelo explicativo

Após a coleta e adequação dos dados, iniciou-se a segunda etapa do trabalho, correspondendo ao desenvolvimento e elaboração do modelo explicativo e análise da elasticidade das variáveis explicativas. O modelo explicativo foi formulado seguindo os princípios propostos por Koutsoyiannis⁷ (1978) apud Almeida (2006). Em resumo, a criação do modelo explicativo envolveu as seguintes considerações:

- 1) Coleta das variáveis explicativas que foram incluídas no modelo;
- 2) Forma funcional do relacionamento das variáveis;
- 3) Expectativa teórica referente aos sinais e o tamanho dos parâmetros; e
- 4) Escolha da técnica econométrica apropriada para estimação da função.

⁷ KOUTSOYIANNIS, A. **Theory of econometrics**. 2. Ed. New Jersey: Barnes & Noble Books, 1978.

Para a desenvolvimento do modelo explicativo, utilizou-se a análise de regressão, que é a principal técnica econométrica de séries temporais. Trata-se de um método pelo qual são feitas análises para a verificação do nível de relacionamento entre uma variável dependente e duas ou mais variáveis explicativas (GUJARATI; PORTER, 2011).

4.2.2.1 Forma funcional do relacionamento das variáveis

A primeira entrada de dado foi o preço médio real da madeira serrada de pinus e a segunda foram as variáveis explicativas. A equação (9) representa um modelo geral de séries temporais log-linear (BUONGIORNO, 2015a).

$$\Delta \ln Y_t = \beta_0 + \beta_1 \Delta \ln X_1 + \beta_2 \Delta \ln X_2 + \beta_3 \Delta \ln X_3 + \mu_t \quad (9)$$

em que:

$\Delta \ln$ = diferença do logarítmico neperiano;
 Y_t = variável dependente ao longo do tempo t ;
 β_0 = constante;
 B_1, B_2, B_3 = vetor dos coeficientes correspondentes;
 X_1, X_2, X_3 = vetor das variáveis explicativas; e
 μ_t = termo de erro no tempo t ;

Neste modelo, a análise foi feita com base no estudo da dependência de uma variável (preço médio real) em relação à uma ou mais variáveis explicativas. Assim sendo, foi considerado o método de equação única com uma forma funcional logarítmica. Optou-se por esta forma, devido à simplicidade de obter as elasticidades diretamente dos coeficientes de inclinação utilizando séries temporais estacionárias.

4.2.2.2 Expectativa teórica referente aos parâmetros

A Tabela 3, representa as expectativas teóricas referentes aos sinais, elasticidade e níveis de significância dos parâmetros considerados no modelo explicativo que serviram de base para avaliar os resultados estimados.

TABELA 3 – EXPECTATIVAS TEÓRICAS REFERENTES AOS PARÂMETROS.

| Variáveis | Sinal esperado | Elasticidade esperada | Nível de significância considerado |
|-----------------|----------------|-----------------------|------------------------------------|
| PR_t^{tor} | + | Não determinado | 90% |
| Pbr_t^{ser} | - | Inelástico | 90% |
| Ppr_t^{ser} | - | Inelástico | 90% |
| Ppr_t^{tor} | - | Inelástico | 90% |
| SM_t^{br} | + | Não determinado | 90% |
| J_t | + | Não determinado | 90% |
| Cbr_t^{ser} | + | Elástico | 90% |
| $CPCbr_t^{ser}$ | + | Elástico | 90% |
| PIB_t^{civpr} | + | Inelástico | 90% |
| PIB_t^{civsp} | + | Inelástico | 90% |
| Po_t^{br} | + | Inelástico | 90% |
| R_t^{br} | + | Não determinado | 90% |
| Hp_t | + | Não determinado | 90% |
| Ce_t | + | Não determinado | 90% |
| Cr_t | + | Não determinado | 90% |
| Exm_t^{ser} | + | Não determinado | 90% |
| $Exeua_t^{ser}$ | + | Não determinado | 90% |
| $PREuc_t^{ser}$ | + | Não determinado | 90% |
| PR_t^{fer} | + | Não determinado | 90% |

LEGENDA: PR_t^{tor} : Preço médio real de madeira em tora de pinus no Paraná (ano base = 2017); Pbr_t^{ser} : Produção de madeira serrada de pinus no Brasil; Ppr_t^{ser} : Produção de madeira serrada de pinus no Paraná; Ppr_t^{tor} : Produção de tora de pinus para serraria no Paraná; SM_t^{br} : Salário mínimo real nacional (ano base = 2017); J_t : Taxa básica de juros real do Brasil - SELIC (ano base = 2017); Cbr_t^{ser} : Consumo aparente de madeira serrada de pinus no Brasil; $CPCbr_t^{ser}$: Consumo aparente *per capita* de madeira serrada de pinus no Brasil; PIB_t^{civpr} : PIB real do setor de construção civil do estado do Paraná (ano base = 2017); PIB_t^{civsp} : PIB real do setor de construção civil do estado de São Paulo (ano base = 2017); Po_t^{br} : População brasileira; R_t^{br} : Renda domiciliar *per capita* real média do Brasil (ano base = 2017); Hp_t : Novas unidades de habitações permitidas nos Estados Unidos (*House permits*); Ce_t : Taxa de câmbio efetiva; Cr_t : Taxa de câmbio real entre o real brasileiro e dólar americano (ano base = 2017); Exm_t^{ser} : Exportações paranaenses de madeira serrada de pinus ao Mundo; $Exeua_t^{ser}$: Exportações paranaenses de madeira serrada de pinus aos Estados Unidos; $PREuc_t^{ser}$: Preço médio real da madeira serrada de eucalipto no Paraná (ano base = 2017); PR_t^{fer} : Preço médio real do ferro no Brasil (ano base = 2017).

FONTE: O autor (2018), baseado em Almeida (2006).

Baseado nos trabalhos de Michinaka et al. (2011) e Buongiorno (2015b), foi considerado 10% de probabilidade em relação ao nível de significância. Considerando que o mercado de madeira serrada de pinus, pelo lado de demandante de insumos, seja oligopsônio, foi esperada uma relação positiva da variável dependente com o preço da tora de pinus para serraria, porém com elasticidade não determinada.

Para produção de tora e produção de madeira serrada de pinus, foi esperada uma relação contrária, pois o aumento da produção, e conseqüente aumento da oferta de madeira serrada de pinus no mercado, pode ocasionar uma diminuição no preço da madeira serrada. No entanto, o aumento na produção pode ser conseqüência do aumento na demanda. Neste caso, se a oferta e a demanda crescerem na mesma proporção, o preço, em princípio, continuaria o mesmo, mas se a oferta crescer a uma

taxa inferior à demanda, o preço aumentaria. Em virtude da dificuldade em responder ao preço a curto prazo, foi esperada uma reação inelástica destas variáveis.

Pelo lado do consumidor de madeira serrada de pinus, foi esperada uma relação concordante e elástica com o consumo aparente e consumo *per capita*, de forma que o aumento no consumo possa ocasionar elevação no preço. No entanto, o aumento da demanda por madeira serrada de pinus pode ser uma consequência da redução de seu preço. Dessa forma, a demanda pode ser dependente e impactada pelo preço.

No que diz respeito ao PIB da construção civil nos estados do Paraná e São Paulo, foi esperada uma relação positiva e inelástica, pois o setor da construção civil é um dos que mais consomem madeira serrada de pinus e, conseqüentemente, influencia a produção e o preço deste produto. (ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE - ABIMCI, 2016).

Sobre as variáveis que captaram o efeito da demanda internacional, foi esperada uma relação contrária da variável dependente e uma elasticidade não determinada. Uma variação positiva nestas variáveis ocasiona uma diminuição dos preços dos bens internos, sendo que a taxa de câmbio é um fator importante na tomada de decisão dos produtores de madeira serrada, pois uma desvalorização da moeda nacional (aumento na taxa de câmbio) incentiva as exportações por produto de madeira, conseqüentemente aumentando a produção de madeira serrada (ALMEIDA, 2006).

Em relação às variáveis que mediram o efeito dos produtos substitutos ou complementares da madeira serrada de pinus para o preço da madeira serrada de eucalipto e preço do ferro, o sinal esperado foi positivo, não expressando contrariedade e, sim, uma tendência relacional de substituição. A madeira tem diferentes relações com esses materiais nos diferentes usos (JOCHEM et al., 2016; ALMEIDA, 2006).

4.2.2.3 Elaboração do modelo explicativo

O modelo foi elaborado por meio do método dos Mínimos Quadrados Ordinários (MQO), utilizando-se o aplicativo computacional Gretl 2016d-git®. Este modelo está entre os métodos mais eficientes e difundidos (GUJARATI; PORTER, 2011).

A formulação do modelo partiu da generalização para, posteriormente, extrair-se os excessos (via análise estatística) e, finalmente, elaborar um modelo representativo da realidade. Buscou-se considerar a teoria econômica e, a partir dela, escolher o melhor modelo com base em critérios estatísticos (FILHO; BRAGA, 2000⁸ apud ALMEIDA, 2006).

Sobre isso, para Gujarati e Porter (2011), os modelos econométricos têm por objetivo determinar aproximações e não relações exatas entre a teoria e a realidade, pois não incluem todas as variáveis que participam do comportamento do fenômeno que é analisado. Os modelos econométricos são representações simplificadas da realidade, sendo que para descrevê-la completamente seria necessário desenvolver um modelo extremamente complexo que teria pouco uso prático (MUNIZ JR et al., 2012)

Assumindo-se que todas as variáveis explicativas escolhidas são consistentes com a teoria econômica, a seleção do modelo melhor ajustado, neste caso, a identificação dos regressores foi realizada por meio dos sinais esperados, critério R^2 ajustado, teste de Durbin-Watson, ausência de heterocedasticidade, ausência de multicolinearidade, especificação correta do modelo de regressão e distribuição normal do termo de erro (GUJARATI; PORTER, 2011).

4.2.2.3.1 Definição do relacionamento entre as variáveis

Com base no trabalho de Almeida (2006), considerou-se a correlação mútua entre termos, sendo uma a dependente e as outras explicativas, por meio de matriz de correlação. Nesta etapa, foi avaliada a força e direção (positiva ou negativa) da relação entre as variáveis, sendo que valores de correlação elevados e positivos indicaram que as variáveis mediam a mesma característica. Dessa forma, foi examinada a correlação entre as variáveis independentes (GUJARATI; PORTER, 2011).

Sabe-se que variáveis com valores de correlação maiores do que 0,8 são frequentemente consideradas altamente correlacionadas e que se deve tomar cuidado para não haver o problema de multicolinearidade entre elas. Este problema indica que

⁸ FILHO, M. B.; BRAGA, M. B. Metodologia da econometria. In: VASCONCELOS, M. A. S. et al. **Manual de econometria**. São Paulo: Atlas, 2000.

as variáveis independentes possuem relações lineares exatas, medindo aproximadamente o mesmo valor (GUJARATI; PORTER, 2011).

Para detectar a presença de colinearidade, fez-se o uso do teste do Fator de Inflacionamento da Variância (VIF), que mede o grau em que cada variável independente é explicada pelas demais variáveis explicativas. Quanto maior o fator de inflação de variância, mais severa é a multicolinearidade. Neste estudo, foi considerado que se o valor de VIF for maior que 10 indica a presença de multicolinearidade, causando efeitos nos coeficientes de regressão (HAIR et al., 2009).

4.2.2.4 Elasticidade das variáveis

Para mensurar a sensibilidade da variação de cada variável dependente analisada em relação as variáveis explicativas no modelos logarítmico, foi usado o coeficiente angular β_2 que mede a elasticidade de uma variável dependente Y em relação a outra variável independente X , isto é, a variação percentual de Y correspondente a uma dada variação percentual em X . Neste sentido, usa-se como uma orientação para a importância relativa das variáveis independentes incluídas na equação (GUJARATI; PORTER, 2011).

4.2.3 Modelo preditivo

Após a elaboração do modelo explicativo, iniciou-se a execução da terceira etapa do trabalho, correspondendo a elaboração dos modelos preditivos, avaliação de suas capacidades preditivas e análise da previsão gerada pelo melhor modelo.

O método de previsão utilizado neste estudo foi o quantitativo, o qual tem maior robustez matemática e estatística e com uma estruturação mais rígida (SANTOS, 2011). Buscou-se trabalhar com a análise passada da variável dependente, que pode ser repetida no futuro e também com a análise de outras variáveis que podem a ter influenciado, por meio dos métodos de séries temporais. A elaboração do modelo preditivo, seguiu as etapas sugeridas por Davis et al., (2001) e envolveu as seguintes considerações:

- 1) Objetivo do modelo;

- 2) Coleta e análise de dados;
- 3) Seleção da técnica de previsão;
- 4) Obtenção das previsões; e
- 5) Monitoração do modelo.

4.2.3.1 Elaboração do modelo preditivo

Nesta etapa, foram utilizadas 19 observações de cada variável, as mesmas descritas no item 4.1.3, porém compreendendo o período entre os anos de 1997 a 2015. Esse procedimento foi adotado para preservar dois períodos a frente, referentes aos anos de 2016 e 2017 da variável dependente, afim de conhecer o desempenho preditivo de cada modelo e comprovar sua eficácia. Esta comprovação foi feita por meio da comparação entre os valores estimados com os valores reais coletados para o mesmo período.

A abordagem deste estudo, buscou-se focar em modelos de previsão de curto prazo que possam ser motivados com base em razões econômicas, a exemplo do que fizeram Baumeister et al. (2014). Por isso, utilizou-se variáveis relacionadas ao setor florestal para elaborar o modelo deste estudo, representando o mercado da madeira serrada de pinus. No entanto, segundo Hanninen (2004), na modelagem de curto prazo, a teoria econômica pode não ser muito útil, e os modelos não baseados na teoria econômica podem ter um desempenho melhor do que os fundamentados.

Buscou-se elaborar dois modelos de previsão para cada técnica testada (Rede Neural Artificial e Autorregressivo Integrado de Média Móvel), um modelo exclusivamente preditivo e outro modelo de previsão utilizando as variáveis que formaram o modelo explicativo (MQO), porém defasadas.

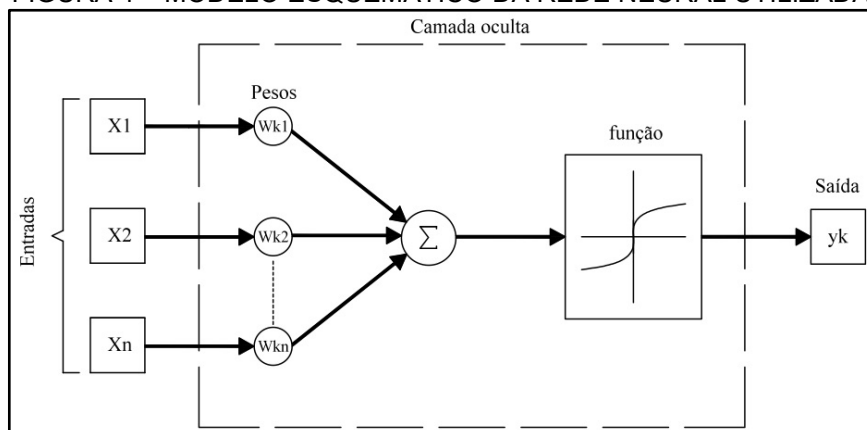
A elaboração do modelo exclusivamente preditivo iniciou-se pela técnica de Rede Neural Artificial, onde foi identificado a combinação de variáveis que resultaram no melhor desempenho preditivo, em seguida, as mesmas variáveis foram utilizadas no método Autorregressivo Integrado de Média Móvel. Na elaboração desses modelos, não foi considerada a matriz de correlação, pois, segundo Gujarati e Porter (2011), os modelos preditivos não são derivados de nenhuma teoria econômica. Dessa forma, sugerem-se que sejam incluídas variáveis que simplesmente resultem em satisfatório desempenho estatístico, considerando como parâmetros os resultados dos critérios estatísticos descritos no item 4.2.3.2.

Para as variáveis explicativas utilizadas em todos os modelos de previsão, foi considerado a defasagem de um ano ($t - 1$), pois a vinculação de uma variável dependente (Y) sobre outras explanatórias (X) raramente é imediata. Com frequência, Y responde a X com lapsos temporais (GUJARATI; PORTER, 2011).

4.2.3.1.1 Técnica de rede neural artificial

A primeira técnica testada foi a Rede Neural Artificial (RNA), de arquitetura *perceptron* de múltiplas camadas (*MLP – Multilayer Perceptron*) (BRESSAN, 2004; SOBREIRO, 2009; COSTA, 2012). De acordo com Braga et al. (2000), este método consiste em um aprendizado supervisionado em que os valores de entrada e saída foram fornecidos. A Figura 4 representa o modelo esquemático de uma rede neural artificial semelhante a que foi usada neste estudo.

FIGURA 4 – MODELO ESQUEMÁTICO DA REDE NEURAL UTILIZADA.



FONTE: O autor (2017) adaptado de HAYKIN (2001).

Os ajustes foram feitos a partir do método de tentativa-erro utilizando as variáveis descritas no item 4.1.1.2. Neste método, uma ou mais variáveis coletadas são incluídas manualmente na rede formando combinações, sendo todas testadas com o intuito de obter uma modelagem adequada e satisfatórios resultados de saída. Para isso, foram considerados os critérios estatísticos descritos no item 4.2.3.2 e o gráfico de saída. Este processo serviu para a elaboração do modelo de previsão (HAYKIN, 2001).

A construção da rede foi feita por meio do aplicativo computacional Matlab r2016b®, utilizando-se a função tangente hiperbólica em todas as camadas ocultas e empregado a função de treinamento *trainbr* (FLORÊNCIO, 2016). Por se tratar de

séries temporais curtas para redes neurais, foi retirado a fase de validação e os dados foram divididos em apenas dois grupos:

- a) Treinamento: a rede ajustou os pesos de suas conexões por meio do uso do algoritmo *backpropagation*. Nesta fase, a partir dos valores conhecidos dos sinais de entrada, são computados os correspondentes valores dos sinais de saída, que por sua vez são comparados com os valores conhecidos da variável dependente e o resíduo é usado para ajustar os pesos das conexões. Este é também o algoritmo mais popular aplicado as redes *MLP* (BRESSAN, 2004; SOBREIRO, 2009; COSTA, 2012); e
- b) Teste: um conjunto de dados de cada série temporal, que não foram utilizados na fase de treinamento, foram separados pela rede neural para determinar a sua performance. Esta etapa foi executada para avaliar a capacidade de previsão da rede e permitir comparações entre métodos (COSTA, 2012).

Segundo Souza e Menezes (2003) e Ceretta et al. (2010) o treinamento deve ser caracterizado por possuir uma boa representação de observações das variáveis analisadas. O treinamento deve ser suficientemente grande para captar o padrão de comportamento da série e o teste deve ser representativo das condições futuras que a rede vai tentar captar para realização da previsão (FITZPATRICK, 1999).

Haykin (2001) e Santos (2011), indicaram que no mínimo 20% da amostra deve ser utilizada para validar o modelo obtido na fase de treinamento. Com base nestes trabalhos, para elaboração do modelo de previsão os dados de entrada na rede neural foram ordenados e divididos em 70% para a fase de treinamento e 30% para teste. De forma parcimoniosa, foi testada uma arquitetura que iniciou com cinco neurônios até encontrar o número ideal de 150 neurônios em uma camada oculta, um trabalho manual que dependeu da experiência humana.

4.2.3.1.2 Técnica ARIMA

A segunda técnica testada foi o método Autoregressivo Integrado de Média Móvel (ARIMA), por meio do aplicativo computacional Gretl 2016d-git®. De acordo com Tsay (2005), um modelo ARIMA combina três parâmetros ou também chamados de

filtro, sendo eles os modelos autorregressivos (AR), identificado pela letra p (número de termos autorregressivos), o filtro de integração (I), distinguido pela letra d (número de diferenças necessárias para a série ser estacionária), e média móvel (MA), reconhecido pela letra q (número de termos de média móvel), sendo, portanto, identificado por ARIMA (p, d, q). Foi considerado nesta etapa a sugestão metodológica de Gujarati e Porter (2011):

- a) Identificação do modelo: escolha provisória de p, d, q ;
- b) Estimação dos parâmetros do modelo escolhido: método de máxima verossimilhança;
- c) Verificação do diagnóstico: análise dos resíduos e autocorrelação; e
- d) Previsão.

A identificação das ordens autorregressivas (p), do filtro de integração (d) e da média móvel (q) foram definidas com base na significância dos coeficientes e no valor do Critério de Informação Akaike. Este método une as fases de identificação e estimação do modelo (BAYER et al., 2012). Sabe-se que os modelos ARIMA são considerados ateóricos, por não serem derivados de nenhuma teoria econômica (GUJARATI; PORTER, 2011).

4.2.3.2 Critérios estatísticos para avaliação do desempenho preditivo dos modelos

Para avaliar o desempenho preditivo de cada modelo produzido por meio das técnicas de RNA e ARIMA, foram considerados critérios estatísticos que avaliaram a precisão obtida escolhendo-se o modelo que apresentasse o menor erro (WANKE; JULIANELLI, 2006). Sobreiro et al. (2009) citaram que as medidas de erro agregado podem auxiliar a escolha do modelo melhor ajustado às variáveis. Por conseguinte, o desempenho de cada modelo testado foi avaliado por meio da análise dos resíduos.

4.2.3.2.1 Erro Quadrático Médio

Foi calculado o Erro Quadrático Médio (EQM) que é definido pela média do quadrado da diferença entre o valor real e o valor previsto. Este é um dos critérios mais apropriados para avaliar o desempenho preditivo de modelos baseados em

séries temporais (ZANETTI JUNIOR; ALMEIDA, 1998; PELLEGRINI; FOGLIATTO, 2001; WERNER, 2004; SILVA et al., 2010; RIBEIRO, 2009; MARTINS; WERNER, 2014; SOUZA et al., 2014). O EQM foi obtido segundo o cálculo proposto por Martins e Werner (2014), descrito na equação (10).

$$EQM = \frac{\sum_{t=1}^n (Y_t - \bar{Y}_t)^2}{n} \quad (10)$$

em que:

EQM = Erro Quadrático Médio;
 Y_t = valor real;
 \bar{Y}_t = valor previsto; e
 n = quantidade total de observações.

4.2.3.2.2 Erro Médio Absoluto

Outra avaliação de desempenho foi feita por meio do cálculo do valor médio dos erros absolutos, conhecido como Erro Médio Absoluto (EMA). É, também, uma das formas mais utilizadas para medir a acurácia e performance de previsão de um modelo (FERNANDES et al., 1995; GOMES, 2005; MANCUSO; WERNER, 2014). O EMA foi obtido de acordo com a equação (11) sugerida por Mancuso e Werner (2014).

$$EMA = \frac{\sum_{t=1}^n |e_t|}{n} \quad (11)$$

em que:

EMA = Erro Médio Absoluto;
 e = erro de previsão no tempo t ; e
 n = quantidade total de observações.

4.2.3.2.3 Erro Percentual de Previsão

Neste parâmetro, o desempenho foi avaliado a partir do Erro Percentual de Previsão (EPP), considerando apenas os anos de 2016 e 2017. Este cálculo baseou-se na metodologia utilizada por Bressan e Lima (2002), conforme descrito na equação (12).

$$EPP = \left| \frac{(y_i - \hat{y}_i)}{y_i} \right| \times 100 \quad (12)$$

em que:

EPP = Erro Percentual de Previsão (%);
 y_i = valor real em 2015 ou 2016; e
 \hat{y}_i = valor previsto para 2015 ou 2016.

4.2.3.2.4 Coeficiente U de Theil

De acordo com Floriano et al. (2006), para comparar modelos, é necessário também utilizar ferramentas estatísticas de aproximação. Para isso, foi utilizado a métrica U de Theil, que avaliou o desempenho das estimativas em relação aos valores da previsão ingênua, quando a estimativa calculada no tempo t é igual a estimativa do valor observado no tempo anterior $t - 1$ (WERNER, 2004; WERNER; RIBEIRO, 2006; EHLERS, 2007; OLIVEIRA, 2007; CORDEIRO et al., 2010; MANCUSO; WERNER, 2014).

Segundo Gutiérrez e Romanel (2003), os modelos de previsão para séries temporais, lineares ou não-lineares, devem apresentar como requisito mínimo um desempenho superior ao da previsão ingênua e por meio do valor do coeficiente U de Theil é possível analisar a qualidade do modelo, observando os seguintes aspectos:

- a) Se $U > 1$, significa que o erro da estimativa é maior que da previsão ingênua; e
- b) Se $U < 1$, significa que o erro da estimativa é menor que da previsão ingênua.

Quanto mais próximo de zero for a métrica U de Theil, melhor será o resultado da previsão do modelo. O valor U de Theil foi obtido por meio da equação (13) sugerida por Gutiérrez e Romanel (2003).

$$U \text{ de Theil} = \frac{\sqrt{\sum_{j=1}^N (A_t - F_t)^2}}{\sqrt{\sum_{j=1}^N (A_t - A_{t-1})^2}} \quad (13)$$

em que:

A_t = valor real ou observado;
 F_t = valor previsto; e
 N = quantidade total de observações.

4.2.3.2.5 Critério de Informação Akaike

Em relação ao ajuste dos modelos ARIMA, ao comparar dois ou mais modelos ARIMA, utiliza-se o Critério de Informação de Akaike (*Akaike Information Criterion – AIC*) e aquele com menor valor é considerado o melhor ajustado. O *AIC* busca selecionar modelos parcimoniosos, equilibrando a explicabilidade e complexidade do modelo (GUJARATI; PORTER, 2011).

A lógica do teste pelo *AIC* é que não há hipótese sendo testada como no teste *F*, pelo contrário, o teste *AIC* permite que se determine qual modelo é o mais correto (FLORIANO et al., 2006). Esse teste pode ser utilizado para comparar qualquer tipo de modelo: lineares, não-lineares, aninhados e não-aninhados, sendo recomendando para séries temporais curtas.

O modelo com menor *AIC* é o mais próximo de ser o correto (SANTORO et al., 2005; FLORIANO et al., 2006). O critério *AIC* foi calculado de acordo com a equação (14) sugerida por Bayer et al. (2012):

$$AIC = -2 \ln [L(\hat{\xi})] + 2k \quad (14)$$

em que:

AIC = Akaike Information Criterion;
 $L(\cdot)$ = função de verossimilhança;
 $\hat{\xi}$ = estimativas de máxima verossimilhança do vetor paramétrico ξ ; e
 k = número de parâmetros do modelo.

As séries temporais normalmente têm distribuição não-linear e o método ordinário de mínimos quadrados estima equivocadamente o erro-padrão. Além disso, deve-se considerar que estatísticas como o *F* de Fischer e o *t* de *Student* em modelo de previsão podem apresentar tendenciosidade na análise de regressão de séries temporais. É preferível usar o critério *AIC* para seleção de modelos por causa da possibilidade de existência de correlação serial (SOUZA, 1998; COLLET, 2003).

Para seleção do melhor modelo gerado na rede neural artificial, foi também analisado o gráfico formado por cada modelo. Há vários fatores a serem considerados ao avaliar um modelo de previsão. Além dos critérios estatísticos, a qualidade de um modelo também depende de sua interpretabilidade, de sua consistência e de sua plausibilidade global. Isso implica em julgamentos inerentemente subjetivos, mas não menos importantes (NAVARRO; MYUNG, 2004). Por isso, foi crucial reconhecer que uma meta realística foi ajustar um modelo que representou uma “boa” aproximação da verdade em um senso estatisticamente definido.

4.2.3.3 Geração da previsão de 2018 e 2019

Após o ajuste, desenvolvimento e seleção do melhor modelo, utilizou-se 21 observações, compreendendo o período entre os anos de 1997 a 2017, com o objetivo de gerar previsões para o horizonte temporal de dois anos (2018 a 2019), de acordo com as modelagens de previsão deste trabalho.

Sobre isso, de acordo com Gujarati e Porter (2011), os erros de previsão aumentam rapidamente se avançar muito no futuro. Por isso as previsões obtidas são mais confiáveis quando feitas para o curto prazo, sendo esta uma característica de todo modelo de previsão.

4.2.3.4 Ferramentas para análise dos resultados preditivos

4.2.3.4.1 Variação percentual

Com a finalidade de verificar o crescimento ou decréscimo pela diferença entre dois valores, foi usada a variação percentual sugerida por Farias e Pesco (2004)⁹ apud Valerius (2016) e descrita na equação (15).

$$\Delta V = \frac{(V_f - V_i)}{V_i} \times 100 \quad (15)$$

⁹ FARIAS, A. M. L.; PESCO, D. U. **Taxas e índices**. Universidade Federal Fluminense. Conteúdos digitais de Matemática e Estatística, 2004. Disponível em: < <http://www.uff.br/cdme/taxa/taxa-html/taxaseindices.pdf>.>. Acesso em: 14 fev. 2017.

em que:

ΔV = variação percentual do valor;
 V_f = valor no período final (referência); e
 V_i = valor no período inicial (base).

4.2.3.4.2 Taxa de crescimento

Para realizar o cálculo da taxa de crescimento foi utilizado o modelo log-lin proposto por Gujarati e Porter (2011) e usado por Valerius (2016). Este modelo tem início no cálculo de juros compostos equação (16), conforme descrito a seguir:

$$Y_t = Y_0 (1 + r)^t \quad (16)$$

em que:

Y_t = valor no período t;
 Y_0 = valor no período inicial;
 r = taxa de crescimento composta ou geométrica (ao longo do período) de Y; e
 t = período;

Para isso, Gujarati e Porter (2011) recomendaram a transformação das variáveis da equação (15) em logaritmo natural, para descrever a equação (17) a seguir:

$$\ln Y_t = \ln Y_0 + t \ln (1 + r) \quad (17)$$

Após isso, considerou-se $\beta_1 = \ln Y_0$ e $\beta_2 = \ln (1 + r)$ para escrever a equação (18):

$$\ln Y_t = \beta_1 + \beta_2 t \quad (18)$$

Com a adição do termo de erro u_t a equação (19), obteve-se o modelo de regressão expresso por:

$$\ln V_t = \beta_1 + \beta_2 t + u_t \quad (19)$$

em que:

V_t = valor;
 β_1 = coeficiente linear (intercepto);
 β_2 = coeficientes angulares; e
 u_t = termo de erro no período.

Assim a equação (20) apresenta o intercepto β_1 que mede V_t independentemente do tempo e o coeficiente angular β_2 que mede a variação proporcional ou relativa constante em V_t para uma dada variação absoluta no valor da variável t . Este modelo é também denominado semilogarítmico, porque apenas o regressando está em forma logarítmica. Todavia, para realizar o cálculo da taxa de crescimento instantânea em um momento t , continuou-se seguindo a metodologia proposta por Gujarati e Porter (2011), tomando-se o anti-logaritmo do coeficiente angular β_2 estimado, subtraindo-o de um e multiplicado a diferença por 100, conforme descrito na equação (20) a seguir:

$$r = [(e^{\beta_2} - 1) \times 100] \quad (20)$$

em que:

r = taxa de crescimento no período t ; e
 β_2 = coeficiente angular.

4.3 LIMITAÇÕES DO TRABALHO

Este trabalho foi limitado pela dificuldade de se obter variáveis relacionadas ao setor florestal brasileiro que poderiam auxiliar na formulação dos modelos, pois sabe-se que algumas informações são de domínio privado ou não existem por não estarem quantificadas e organizadas em séries temporais. Como exemplo, cita-se os dados numéricos sobre os gostos e preferências do consumidor e a qualidade do produto. Outro exemplo diz respeito às séries históricas de base florestal plantada anualmente pelas empresas no estado do Paraná, de custos de produção de produtos florestais, do volume consumido de tora de pinus para serraria e madeira serrada de pinus pelas empresas e indústrias paranaenses, bem como comercializado com empresas de outros estados brasileiros.

Ressalta-se que os polos paranaenses de madeira serrada de pinus estão

localizados próximo à fronteira do estado de Santa Catarina (outro Estado que produz e consome elevado volume de madeira serrada de pinus) e de seu polo fabril madeireiro. Diariamente é transportado madeira em tora e serrada de um Estado para outro por meio de rodovias ou estradas, sendo que algumas indústrias, paranaenses e catarinenses, possuem florestas que abrangem áreas territoriais nos dois Estados. Kureski (2003), ao buscar estabelecer a importância da indústria de base florestal sobre a ocupação e renda do estado do Paraná, já havia constado a ausência de informações sobre as variáveis econômicas florestais.

5 RESULTADOS E DISCUSSÃO

5.1 DESENVOLVIMENTO DO MODELO EXPLICATIVO

Este conhecimento pode servir de base para produtores e consumidores de diversos tipos de produtos que utilizam a madeira serrada como matéria prima, subsidiando a elaboração de estratégias de mercados e a tomada de decisão, além de aperfeiçoar o setor de base florestal, promovendo o desenvolvimento de novas pesquisas.

A intensidade destes resultados deve ser interpretada com cautela, tendo em vista que são particulares da amostra avaliada. Deve-se considerar as variáveis usadas neste estudo, período analisado, comportamento das séries temporais e abrangência geográfica, sendo que a explicação do preço pode estar relacionada com características peculiares de seu mercado.

5.1.1 Definição das variáveis utilizadas

Conforme descrito no item 4.2.2.3.1, para elaboração do modelo explicativo, realizou-se um exame do grau de correlação, por meio de matriz de correlação entre as variáveis explicativas coletadas, para identificar quais destas foram utilizadas no modelo, definindo uma linha de corte para a entrada de variáveis no modelo. (TABELA 4).

TABELA 4 – GRAU DE CORRELAÇÃO DAS VARIÁVEIS EXPLICATIVAS COM A DEPENDENTE.

| Variáveis | Correlação | Variáveis | Correlação |
|--------------------------------|---------------|-----------------------------------|---------------|
| PR_t^{ser} | 1 | Po_t^{br} | 0,0439 |
| PR_t^{tor} | 0,6227 | R_t^{br} | - 0,5001 |
| Pbr_t^{ser} | 0,0820 | J_t | 0,2539 |
| Ppr_t^{ser} | 0,0893 | HP_t | 0,1662 |
| Ppr_t^{tor} | 0,0893 | Ce_t | 0,0828 |
| SM_t | 0,0319 | Cr_t | 0,0318 |
| Cbr_t^{ser} | - 0,0120 | Exm_t^{ser} | 0,1402 |
| $CPCbr_t^{ser}$ | - 0,0173 | $Exeud_t^{ser}$ | 0,2943 |
| PIB_t^{civpr} | - 0,0946 | $PREuc_t^{ser}$ | 0,6413 |
| PIB_t^{civsp} | - 0,2702 | PR_t^{fer} | 0,3787 |

LEGENDA: PR_t^{ser} : Preço médio real de madeira serrada de pinus no Paraná (ano base = 2017); PR_t^{tor} : Preço médio real de madeira em tora de pinus no Paraná (ano base = 2017); Pbr_t^{ser} : Produção de madeira serrada de pinus no Brasil; Ppr_t^{ser} : Produção de madeira serrada de pinus no Paraná; Ppr_t^{tor} : Produção de tora de pinus para serraria no Paraná; SM_t : Salário mínimo real nacional (ano base = 2017); Cbr_t^{ser} : Consumo aparente de madeira serrada de pinus no Brasil; $CPCbr_t^{ser}$: Consumo aparente per capita de madeira serrada de pinus no Brasil; PIB_t^{civpr} : PIB real do setor de construção civil do

estado do Paraná (ano base = 2017); PIB_t^{civsp} : PIB real do setor de construção civil do estado de São Paulo (ano base = 2017); Pop_t^{br} : População brasileira; R_t^{br} : Renda domiciliar *per capita* real média do Brasil (ano base = 2017); J_t : Taxa básica de juros real do Brasil - SELIC (ano base = 2017); HP_t : Novas unidades de habitações permitidas nos Estados Unidos (*House permits*); Ce_t : Taxa de câmbio efetiva; Cr_t : Taxa de câmbio real entre o real brasileiro e dólar americano (ano base = 2017); Exm_t^{ser} : Exportações paranaenses de madeira serrada de pinus ao Mundo; $Exeua_t^{ser}$: Exportações paranaenses de madeira serrada de pinus aos Estados Unidos; $PREuc_t^{ser}$: Preço médio real da madeira serrada de eucalipto no Paraná (ano base = 2017); PR_t^{fer} : Preço médio real do ferro no Brasil (ano base = 2017).

FONTE: O autor (2020).

Os resultados da Tabela 4 demonstram que apenas as séries referentes ao preço médio de madeira em tora de pinus e da madeira serrada de eucalipto apresentam correlação positiva forte. Segundo Gujarati e Porter (2011) as correlações positivas e fortes indicam que as variáveis medem a mesma característica e por isso podem ser usadas no modelo. Desse modo, este estudo sugere que estas foram as variáveis que o modelo explicativo foi capaz de captar o efeito, sendo elas da oferta e do preço de produtos substitutos.

As correlações negativas fracas encontradas nas variáveis que buscaram captar o efeito da demanda nacional atraíram atenção, pois com exceção da série referente à população, nenhuma outra apresenta correlação positiva. Não há, para isso, uma justificativa teórica consistente, podendo ser uma relação peculiar à amostra obtida ou a qualidade dos dados. No entanto, fomenta a dificuldade de encontrar boas *proxies* capazes de representar o efeito da demanda para este mercado, como por exemplo, uma série temporal referente ao consumo de madeira serrada de pinus por Estado, em especial do Paraná, Santa Catarina e São Paulo.

De acordo com, Wooldridge (2002)¹⁰ apud Buongiorno (2015b), a forma como os produtos madeireiros são consumidos muda dependendo das condições do país ou com o período observado. É possível, ainda, que parâmetros de demanda, como PIB, amplamente utilizado em estudos do setor florestal, possa variar constantemente ao longo do tempo. Ignorar esses efeitos, se existirem, leva a estimativas enviesadas dos parâmetros.

5.1.2 Modelo explicativo desenvolvido

¹⁰ Wooldridge J.M. (2002). **Econometric analysis of cross section and panel data**. The MIT Press, Cambridge. 752 p.

Com base nas variáveis correlacionadas apresentadas na Tabela 4, obteve-se a equação (21) como explicativa para este caso, do preço de madeira serrada de pinus no estado do Paraná.

$$PR_t^{ser} = PR_t^{tor} + PReuc_t^{ser} \quad (21)$$

em que:

PR_t^{ser} = preço médio real de madeira serrada de pinus no estado do Paraná (R\$/m³) (ano base = 2017) no ano t ;

PR_t^{tor} = Preço médio real de madeira em tora de pinus no Paraná (R\$/m³) (ano base = 2017) no ano t ;

$PReuc_t^{ser}$ = Preço médio real da madeira serrada de eucalipto no Paraná (R\$/m³) (ano base = 2017) no ano t ;

Sabe-se que os modelos de Mínimos Quadrado Ordinários (MQO) devem ser utilizadas variáveis explicativas, preferencialmente contemporâneas, com a variável dependente (GUJARATI; PORTER, 2011). No Apêndice 1 contém os resultados completos da regressão, porém entende-se que a representação simplificada da equação (21) e os valores dos parâmetros apresentados na Tabela 6, a seguir, facilitam a sua compreensão.

Ressalta-se que este modelo estatístico não representa de forma adequada a realidade econômica deste mercado, pois não há nele a presença de uma variável referente à demanda, reduzindo seu poder explicativo e de projeção. Conforme a discussão dos resultados apresentados na Tabela 4 no item 5.1.1, as variáveis que buscaram captar o efeito da demanda apresentaram correlações negativas fracas, gerando uma limitação estatística e metodológica que impossibilitaram suas inserções no modelo.

Salienta-se que, apesar da limitação, foi tentado forçadamente inserir variáveis da demanda no modelo, porém os resultados obtidos dos parâmetros foram ruins. De acordo com a metodologia sugerida e utilizada neste trabalho, o modelo ficou estatisticamente bom, mas a ausência de variáveis capazes de captar o efeito da demanda, como já citado, causam uma limitação quanto ao seu uso. Assim, devem, os usuários, entender que outros fatores influenciam o preço da madeira serrada de pinus e procurar modelos que as contemplem.

Os sinais das séries utilizadas estão de acordo com o esperado. Para as duas

variáveis explicativas, foi constatado uma relação inelástica. Apenas para a variável “preço da madeira serrada de eucalipto” encontrou-se a significância dentro do esperado.

TABELA 5 – RESULTADO DOS PARÂMETROS DO MODELO.

| Variável | Coeficiente β_2 | Sinal | | Elasticidade | | Significância | |
|-----------------|-----------------------|-------|------|-----------------|------------|---------------|-------|
| | | Esp. | Enc. | Esp. | Enc. | Esp. | Enc. |
| PR_t^{tor} | 0,2142 | + | + | Não determinado | Inelástica | 90% | < 90% |
| $PREuc_t^{ser}$ | 0,6060 | + | + | Não determinado | Inelástica | 90% | 95% |

LEGENDA: Esp.: esperado; Enc.: encontrado; PR_t^{tor} : Preço médio real de madeira em tora de pinus no Paraná (ano base = 2017); e $PREuc_t^{ser}$: Preço médio real da madeira serrada de eucalipto no Paraná (ano base = 2017).

FONTE: O autor (2020).

Ao analisar a Tabela 5, o coeficiente positivo e inelástico da variável “preço da madeira serrada de eucalipto” inferiu-se que um aumento de 1% em seu preço causa um crescimento de 0,60% no preço da madeira serrada de pinus produzida no estado do Paraná, considerando que as evoluções das séries temporais correlacionadas se mantenham constantes. Esta variável apresentou 95% de significância ao modelo, sendo a única dentro do esperado. No que se refere à variável “preço médio real da tora de pinus” esta, apesar de não ser pelo menos 90% significativa ao modelo, apresentou um valor de correlação com a variável dependente de 0,6227, considerado satisfatório (TABELA 4).

Em relação ao preço da madeira serrada de eucalipto, uma hipótese para esta relação é a aparente concorrência, pois espera-se que o aumento no preço da madeira serrada de eucalipto ocasione uma diminuição no seu consumo, ocasionado um aumento no consumo de outros produtos, como é o caso da madeira serrada de pinus. Consequentemente, o aumento no consumo de pinus, gera um aumento no seu preço de mercado.

Em relação ao preço médio real de madeira em tora de pinus, encontrou-se uma sensibilidade inelástica (baixo valor para o seu coeficiente β_2). Esta observação indica que o aumento de 1% no seu preço ocasiona um crescimento de 0,21% no preço da madeira serrada de pinus. No entanto, não foi possível captar o efeito desta variável sobre a elasticidade da demanda.

Salienta-se que o efeito do tamanho das amostras utilizadas é visto no poder estatístico do teste de significância, sendo que amostras pequenas, com menos de 20 observações, são apropriadas para análise por regressão simples com uma única variável independente. Nestas situações, apenas relações muito fortes podem ser

detectadas com elevado grau de certeza (HAIR et al., 2009).

5.1.3 Premissas do modelo de regressão

Conforme descrito no item 4.2.2.3, o modelo de regressão possui algumas premissas que devem ser atendidas para que a estimação seja considerada correta. Estes resultados estão descritos na Tabela 6.

TABELA 6 – PREMISSAS DO MODELO DE REGRESSÃO.

| Premissas | Variável | Valor |
|----------------|-----------------|-------|
| VIF | PR_t^{tor} | 1,527 |
| | $PREuc_t^{ser}$ | 1,527 |
| \bar{R}^2 | | 0,512 |
| Durbin Watson | | 1,993 |
| White | | 0,811 |
| Doornik-Hansen | | 0,656 |
| Reset | | 0,092 |

FONTE: O autor (2020).

Os resultados do teste de VIF (Fator de Inflacionamento da Variância) de cada variável não consideram elas altamente correlacionadas, uma vez que todos os valores são menores que 10. Assim, não há o problema de multicolinearidade.

Para o \bar{R}^2 ajustado, o resultado encontra-se satisfatório, sendo considerado um bom ajustamento para o modelo, indicando que o modelo explica 51% da variação do preço na resposta aos dados utilizados. Este valor está próximo ao de 50% encontrado por Turner et al. (2006) que desenvolveu um modelo MQO para suplemento e estoque de florestas.

O resultado do teste de Durbin Watson, indica a ausência de correlação serial, pois o valor encontrado está próximo de dois. Isso significa que o termo de erro de uma observação não é influenciado pelo termo de erro de qualquer outra. Este valor está próximo ao encontrado por Buongiorno (1996) e Sun e Zhou (2018).

O resultado do teste de White permite aceitar a hipótese nula de que a variância dos resíduos é homocedástica. Assim, o termo de erro é constante para todas as variáveis explicativas. Pelo resultado do teste de Doornik-Hansen também é possível aceitar a hipótese nula, relatando que o erro possui distribuição normal nos resíduos, ou seja, significa que os erros de cada variável presente no modelo não estão correlacionados. Pelo resultado do teste Reset, a hipótese nula também é aceita, indicando que as variáveis mais relevantes foram incluídas e a forma funcional

empregada é adequada.

Os modelos ajustados com amostras pequenas têm baixo poder de generalização, de modo que variáveis com séries temporais curtas podem resultar em fácil ajuste dos dados, conforme resultados observados na Tabela 5. Para isso, sugere-se uma razão mínima de cinco observações para cada variável explicativa (HAIR et al., 2009). O presente estudo contou com uma razão de 10, ou seja, foram testadas 20 variáveis explicativas e duas foram aproveitadas no modelo. Almeida (2006) utilizou uma razão de 5,7 observações e Wiecheteck (2001)¹¹ apud Almeida (2006), usou 14 observações.

5. 2 DESENVOLVIMENTO DO MODELO PREDITIVO

Buscou-se, por meio deste resultado, apresentar um modelo de previsão utilizando Rede Neural Artificial (RNA) e o método Autorregressivo Integrado de Média Móvel (ARIMA). Em seguida, com base no modelo que apresentou o melhor desempenho preditivo, foi gerado uma previsão com a provável tendência para o preço da madeira serrada de pinus no estado do Paraná para os anos de 2018 a 2019.

Conforme descrito no item 4.2.3.1, para elaboração dos modelos exclusivamente preditivos, não foi considerado a matriz de correlação, pois os mesmos foram elaborados com base no método de tentativa-erro, incluindo variáveis que simplesmente resultem em satisfatório desempenho estatístico (GUJARATI; PORTER, 2011).


5.2.1 Identificação do melhor modelo preditivo

A primeira técnica testada foi a RNA. Neste método, as variáveis coletadas foram incluídas manualmente na rede com o intuito de obter uma modelagem adequada, com bons resultados de saída, conforme sugerido por Haykin, (2001). A representação gráfica da RNA que foi capaz de produzir o melhor modelo com baixo erro entre os dados reais e modelados da rede está demonstrada na Figura 5 (os

¹¹ WIECHETECK, M. S. S. **Spatial equilibrium analysis of conifer timber markets in southern brazil and in the other mercosur countries**. 237 f. Tese (Ph.D.) – Michigan State University, Michigan, 2001.

valores dos erros da RNA estão descritos na Tabela 8, no item 5.2.2 a seguir).

FIGURA 5 – GRÁFICO GERADO PELO MODELO NA REDE NEURAL ARTIFICIAL.



FONTE: O autor (2018) através do aplicativo computacional Matlab r2016b.

O resultado gráfico apresentado na Figura 5 foi obtido com base nas variáveis de entrada: “consumo aparente de madeira serrada de pinus no Brasil (m^3) ($t-1$)” e “produção de madeira serrada de pinus no Brasil (m^3) ($t-1$)”. Assim, a equação (22) expressa o modelo exclusivamente preditivo utilizado tanto pela técnica de RNA como pela técnica ARIMA, com variáveis que resultaram em satisfatório desempenho estatístico. Por esse motivo, as variáveis explicativas presentes na equação (22) são diferentes das variáveis utilizadas no modelo explicativo da equação (21).

$$PR_t^{ser} = Cbr_t^{ser} + Pbr_t^{ser} \quad (22)$$

em que:

PR_t^{ser} = preço médio real de madeira serrada de pinus no estado do Paraná (ano base = 2017) (R\$/ m^3) no ano t ;

Cbr_t^{ser} = consumo aparente de madeira serrada de pinus no Brasil (m^3) com defasagem de um ano ($t-1$); e

Pbr_t^{ser} = produção de madeira serrada de pinus no Brasil (m^3) com defasagem de um ano ($t-1$).

Este foi o modelo que apresentou o melhor resultado, dentre

aproximadamente mais de 100 modelos, com diferentes combinações de variáveis que foram testados na RNA. Verificou-se, na série temporal estacionária apresentada na Figura 5, a evolução gráfica durante o período analisado, apresentando raros picos. A madeira serrada de pinus tem um mercado estável e consolidado no estado do Paraná e no Brasil e é um dos principais produtos oriundos das florestas plantadas (APRE, 2018).

Sabe-se que a defasagem de um ano em relação a variável dependente não se aplica à todas as variáveis explicativas, pois a resposta do preço à variação na produção e consumo nacional de madeira serrada pode ocorrer em intervalo de tempo menor que um ano. No entanto, não foi possível analisar períodos de defasagens menores, pois foi usado observações de séries anuais para todas as variáveis.

Além disso, conforme descrito no item 4.2.3.1 também foi elaborado um modelo de previsão utilizando as variáveis explicativas que formaram o modelo explicativo da equação (21). Este novo modelo está apresentado na equação (23).

$$PR_t^{ser} = PR_t^{tor}_{t-1} + PReuc_t^{ser}_{t-1} \quad (23)$$

em que:

PR_t^{ser} = preço médio real de madeira serrada de pinus no estado do Paraná (R\$/m³) (ano base = 2017) no ano t ;

PR_t^{tor} = Preço médio real de madeira em tora de pinus no Paraná (R\$/m³) (ano base = 2017) no ano t ;

$PReuc_t^{ser}$ = Preço médio real da madeira serrada de eucalipto no Paraná (R\$/m³) (ano base = 2017) no ano t ;

Não foi possível obter os resultados da RNA utilizando as variáveis do modelo da equação (23), pois constatou-se, graficamente, um problema de sobreajuste (*overfitting*) em que a rede se mostrou ineficaz para realizar estimativas. Apesar de ter sido utilizado no modelo de previsão da equação (23), as variáveis explicativas defasadas do modelo explicativo da equação (21) nos modelos de previsão, não se analisa a sensibilidade (elasticidade) das variáveis, apenas o seu desempenho preditivo (GUJARATI; PORTER, 2011). A análise do desempenho preditivo está descrita no item 5.2.2, a seguir.

Os valores de *AIC* para as diferentes combinações de parâmetros das equações (22) e (23) estão descritos na Tabela 7. Nestes modelos, o valor do

parâmetro d foi zero, pois as variáveis usadas foram transformadas em séries temporais estacionárias por meio da diferença logarítmica das observações.

TABELA 7 – AJUSTES DOS MODELOS ARIMA.

| <i>Akaike Information Criterion – AIC</i> | | |
|--|-------------------|-------------------|
| Função de Autocorrelação (p, d, q) | Equação (22) | Equação (23) |
| 0 0 1 | – 31,19631 | – 32,60100 |
| 0 0 2 | – 31,43757 | – 30,60122 |
| 0 0 3 | – 30,15946 | – 29,97385 |
| 1 0 0 | – 31,25780 | – 32,59970 |
| 1 0 1 | – 29,39202 | – 30,60105 |
| 1 0 2 | – 30,24183 | – 29,26107 |
| 1 0 3 | – 29,54716 | – 28,91081 |
| 2 0 0 | – 30,12111 | – 30,60590 |
| 2 0 1 | – 28,82736 | – 28,61135 |
| 2 0 2 | – 29,29467 | – 28,94207 |
| 2 0 3 | – 27,90968 | – 27,51425 |
| 3 0 0 | – 30,67313 | – 28,76264 |
| 3 0 1 | – 28,93697 | – 27,01741 |
| 3 0 2 | – 28,30046 | – 28,05254 |
| 3 0 3 | – 26,50614 | – 25,76949 |

LEGENDA: p : autorregressivo; d : filtro de integração; q : média móvel; e AIC : *Akaike Information Criterion*.

FONTE: O autor (2020).

Com as variáveis da equação (22), o modelo ARIMA (0,0,2) apresentou o menor valor para o AIC. Para as variáveis da equação (23), o modelo ARIMA (0,0,1) apresentou o menor valor de AIC. Ao comparar o valor de AIC resultante deste estudo com o de outros autores, percebeu-se que o valor encontrado é satisfatório, pois ao comparar dois ou mais modelos ARIMA, aquele com menor valor de AIC é considerado o melhor ajustado. Castro et al. (2012), encontraram um valor AIC de 15,6458, ao realizarem uma análise econométrica da produção de madeira serrada de coníferas no Brasil. Cerreta et al. (2010), encontraram um valor de 9,837 ao elaborar um modelo de previsão de preço da soja. Felisoni et al. (2011), encontraram um valor de – 5,830982 ao analisar técnicas de previsão de vendas do varejo brasileiro.

5.2.2 Análise comparativa das técnicas utilizadas

Entre as técnicas testadas (RNA e ARIMA), os dois modelos elaborados a partir da equação (22) e o modelo ARIMA elaborado a partir da equação (23), apresentaram pequenas diferenças de valores nos critérios estatísticos considerados, com uma leve superioridade para o modelo ARIMA (0,0,1) (TABELA 8).

TABELA 8 – DESEMPENHO DOS MODELOS DE PREVISÃO PARA PREÇO REAL MÉDIO DE MADEIRA SERRADA DE PINUS.

| Ano | Real (R\$/m ³) | Previsto (R\$/m ³) | | |
|------------------------|----------------------------|--------------------------------|---------------|------------------|
| | | Equação (22) | | Equação (23) |
| | | RNA | ARIMA (0,0,2) | ARIMA (0,0,1) |
| 2016 | 523,73 | 527,80 | 508,69 | 518,94 |
| 2017 | 494,46 | 517,84 | 470,06 | 514,18 |
| Critérios estatísticos | | | | |
| | EQM | 0,0056 | 0,0046 | 0,0045 |
| | EMA | 0,0572 | 0,0469 | 0,0408 |
| | EPP (2016) | 2,88% | 2,87% | 0,91% |
| | EPP (2017) | 4,73% | 4,93% | 3,99% |
| | U de Theil | 0,7612 | 0,8521 | 0,75587 |
| | AIC | - - - | - 31,4376 | - 32,6010 |

LEGENDA: RNA: Rede Neural Artificial; EQM: Erro Quadrático Médio; EMA: Erro Médio Absoluto; EPP: Erro Percentual de Previsão; e AIC: Akaike Information Criterion.

FONTE: O autor (2018).

O modelo da equação (23) gerou previsões de melhor qualidade, considerando os resultados obtidos. Dentre os critérios considerados, destacam-se o EPP (2016) de 0,91% e EPP (2017) de 3,99%. Sivaram (2014), ao validar o preço da madeira de teca para um ano a frente, encontrou um erro percentual de previsão de 11,1% utilizando modelo ARIMA.

A técnica de RNA obteve, neste estudo, um desempenho inferior em comparação a técnica ARIMA. Uma hipótese para esta constatação é o uso de séries temporais curtas, que impediu a realização da fase de validação da rede neural, sendo que as séries temporais foram divididas em apenas em dois grupos: treinamento (70%) e teste (30%).

Considerando os resultados de desempenho estatístico, estes diferem de Ceretta et al. (2010) que encontraram uma ligeira superioridade no uso de RNA em relação ao modelo ARIMA ao gerar modelos de previsão para o preço da soja. Corrêa et al. (2017), ao compararem modelos de previsões, constataram que as redes neurais foram eficientes, eliminaram a deficiência e melhoraram a performance do

desempenho dos modelos de médias móveis utilizados para previsão de preços.

A partir dos resultados da Tabela 8, foi possível analisar as vantagens e desvantagens dos modelos testados e realizar o *trade-off* entre eles (QUADRO 3).

QUADRO 3 – *TRADE-OFF* ENTRE OS MODELOS ELABORADOS.

| Critérios | Utilizando as variáveis da Equação (22) | | Utilizando as variáveis da Equação (23) |
|--|---|----------------------|---|
| | RNA | ARIMA (0,0,2) | ARIMA (0,0,1) |
| Forma funcional | Equação única | Equação única | Equação única |
| Estacionariedade | Presente | Presente | Presente |
| Capacidade interpretativa dos coeficientes β_2 | Inexistente | Inexistente | Inexistente |
| Capacidade preditiva | Presente | Presente | Presente |

LEGENDA: RNA: Rede Neural Artificial; ARIMA: Autorregressivo Integrado de Média Móvel.

FONTE: O autor (2020).

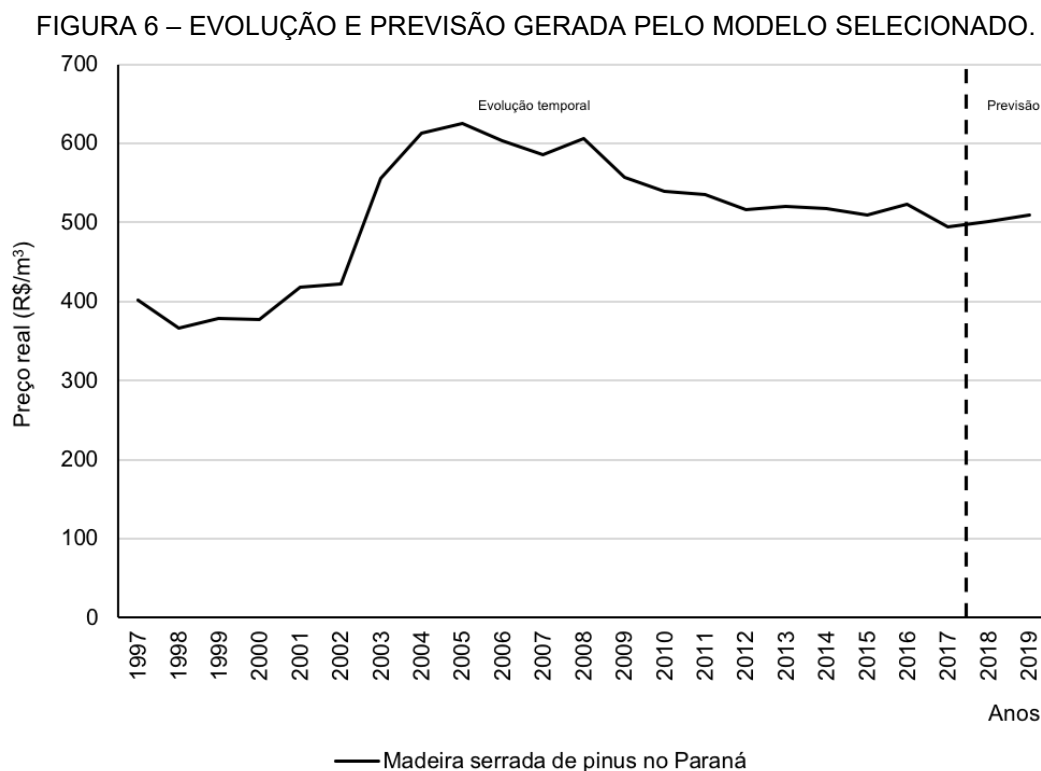
Percebe-se que é possível usar as variáveis de um modelo explicativo para gerar previsão. É um modelo que pode ser usado para explicar algumas variáveis que influenciam o preço e as causas de suas mudanças temporais e possuiu, ainda, elevada capacidade preditiva a partir da defasagem de um ano de suas variáveis explicativas, apresentando baixos erros de previsão. Assim, o modelo preditivo elaborado com base em um modelo explicativo MQO, foi mais eficaz para realizar previsões do que o modelo preditivo formado com base no método tentativa-erro.

Os modelos de previsões possuem bons critérios de desempenho preditivo, mas não são passíveis de interpretação por meio dos seus coeficientes. Dessa forma, os modelos preditivos são limitados a simplesmente gerarem previsões, sem uma análise acurada das relações entre os dados. Com estes modelos, busca-se os menores erros de previsão, independente das variáveis explicativas que são incluídas. Os resultados desse trabalho corroboram com Almeida (2006) e Oliveira (2007), que citaram que a modelagem ARIMA resulta em boas previsões, especialmente a curto prazo.

5.2.3 Previsão gerada de 2018 a 2019

O objetivo deste resultado por analisar as previsões produzidas pelo melhor modelo para os anos de 2018 a 2019, para o preço médio real de madeira serrada de pinus no estado do Paraná. A Figura 6 ilustra a previsão do preço médio real da madeira serrada de pinus no estado do Paraná, a partir do modelo ARIMA (0,0,1), o qual apresentou a melhor capacidade de previsão, segundo os resultados descritos

no item 5.2.2 e Tabela 8.



FONTE: O autor (2018).

A previsão indica, graficamente, uma tendência de leve elevação a partir do ano de 2017. Com base nos resultados encontrados, haverá um aumento de 1,63% entre os anos de 2018 e 2019. No último ano previsto, o valor estimado para o preço da madeira é de R\$ 509,10 por metro cúbico.

Apesar da propensão de crescimento para os últimos anos previstos, considerando todo o período estimado (dois anos), a tendência é de um aumento de 1,63% ao ano, logo, a tendência é que o preço pago ao produtor de madeira serrada aumente. A tendência gráfica de aumento no preço da madeira serrada de pinus no estado do Paraná foi em grande parte impulsionada, neste caso, pelas variáveis independentes (equação 23), a saber: o preço médio real de madeira em tora de pinus e da madeira serrada de eucalipto no estado do Paraná.

Apesar do modelo não ter captado o efeito de variáveis macroeconômicas, a evolução do mercado nas previsões deve ser considerada. Deve-se considerar que os indicadores macroeconômicos do Brasil podem apresentar crescimento nos próximos anos, ocasionando aumento no consumo e conseqüentemente também no preço da madeira serrada.

6 CONCLUSÕES

- O modelo explicativo gerado não foi capaz de captar o efeito da demanda, representando uma limitação em relação ao seu uso.
- As variáveis que formaram o modelo explicativo do preço real da madeira serrada de pinus no estado do Paraná foram: o preço médio de madeira em tora de pinus e o preço da madeira serrada de eucalipto no estado do Paraná.
- O preço médio da madeira serrada de eucalipto apresenta a maior significância ao modelo e o maior efeito de mudança na variação do preço da madeira serrada de pinus.
- O modelo preditivo, formado com as variáveis utilizadas no modelo explicativo, possui elevada capacidade preditiva, apresentando baixos erros de previsão para o preço real de madeira serrada de pinus no estado do Paraná.
- O modelo preditivo elaborado com base em um modelo explicativo MQO é mais eficaz para realizar previsões do que o modelo preditivo formado com base no método tentativa-erro.
- O modelo elaborado pelo método ARIMA (0,0,1) apresenta capacidade preditiva superior ao modelo de Rede Neural Artificiais (RNA).
- A maior limitação dos modelos preditivos elaborados é o seu pequeno conjunto de dados, no entanto, um modelo reducionista pode facilmente ser usado por analistas do setor gerando bons resultados.
- A previsão do preço real indica uma leve tendência de aumento de 1,63% ao ano entre 2018 a 2019.

7 CONSIDERAÇÕES FINAIS

As previsões econômicas sempre incluem incertezas e como elas são usadas para auxiliar na tomada de decisões, elas também são julgadas neste contexto. Embora os modelos econométricos de séries temporais sejam a principal ferramenta, o acerto exato de previsões é estaticamente impossível, por isso, o objetivo deste trabalho foi apresentar a estimativa de uma tendência. Um desafio para novas pesquisas é formular novos modelos e adaptar novas técnicas de previsão ao setor florestal.

Para a adequação dos modelos de previsão, existem limitações que devem ser observadas. Deve-se analisar a elaboração do modelo considerando o comprimento das séries temporais, a utilização de dados atualizados e limitar o período potencial de previsão.

Os modelos ARIMA são comumente usados e conhecidos por sua fácil aplicação e interpretação, mas o interesse nos modelos gerados por meio de Redes Neurais Artificiais tem crescido devido às baixas restrições que eles apresentam com possibilidade de analisar dados não lineares.

O problema de obter variáveis relacionadas ao setor florestal brasileiro poderia ser resolvido se os órgãos governamentais, instituições de dados e estatísticas, fornecessem mais informações ao setor florestal como, por exemplo, um relatório trienal de abrangência nacional e estadual do volume produzido, consumido, exportado, importado, valores de venda de diferentes tipos de produtos madeireiros e não madeireiros de florestas nativas e plantadas, a exemplo do que é feito em outros países. O acesso a mais informações poderia facilitar as pesquisas, estudos e análises do setor florestal, bem como a abertura de novos negócios e investimentos no estado do Paraná e no Brasil.

Diante dessas considerações, sugere-se a busca pelas soluções das mesmas como proposta para pesquisas futuras visando entender melhor as relações das variáveis concomitantes com o preço. Novos estudos podem ser realizados para buscar prever outras variáveis econômicas florestais, visando identificar os possíveis efeitos futuros que podem ser causados no mercado florestal e madeireiro, aliando-os aos fatores mais relevantes que influenciam a tomada de decisão.

REFERÊNCIAS

- AGUIAR, G. P. **Competitividade do setor exportador brasileiro de castanha-do-brasil**. 140 f. Dissertação (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2014.
- ALMEIDA, A. N. **Estudo econométrico da demanda e oferta de madeira em tora para o processamento mecânico no estado do Paraná**. 235 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2006.
- ALMEIDA, A. N.; SILVA, J. C. G. L.; ANGELO, H.; BITTENCOURT A. M.; NUNEZ A. E. C; Mercado Paranaense de madeira em tora procedente de silvicultura entre 1999 e 2005. **Revista Floresta**, v. 39, n. 4, p. 69-875, 2008.
- ALMEIDA, A. N.; ANGELO, H.; SILVA, J. C. G. L.; BITTENCOURT A. M.; NUNEZ A. E. C. Análise econométrica do mercado de madeira em tora para o processamento mecânico no estado do Paraná. **Scientia Forestalis**, v. 37, n. 84, p. 377 - 386, 2009a.
- ALMEIDA, A. N.; SILVA, J. C. G. L.; ANGELO, H.; NUÑEZ, B. E. C. Análise de fatores que influenciam o preço da madeira em tora para processamento mecânico no Paraná. **Cerne**, v. 16, n. 2, p. 243-250, 2010.
- ANGELO, C. F.; ZWICKER, R.; FOUTO, N. M. M. D.; LUPPE, M. R. Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro. **Brazilian Business Review**, v. 8, n. 2, p. 1-21, 2011.
- ARAUJO, V. A.; GARCIA, J. N.; BARBOSA-CORTEZ, J.; GAVA, M.; SAVI, A. F.; MORALES, E. A. M.; LAHR, F. A. R.; VASCONCELOS, J. S.; CHRISTOFORO, A. L. Importância da madeira de florestas plantadas para a indústria de manufaturados. **Pesquisa Florestal Brasileira**, v. 37, n. 90, p. 189-200, 2017.
- ASSOCIAÇÃO BRASILEIRA DA INDÚSTRIA DE MADEIRA PROCESSADA MECANICAMENTE (ABIMCI). **Estudo Setorial**: ano base 2015. Curitiba, 2016.
- ASSOCIAÇÃO PARANAENSE DE EMPRESAS DE BASE FLORESTAL (APRE). **Estudo setorial**. Curitiba, 2018.
- Banco Central do Brasil. **Séries Temporais**. Brasília, 2016. Disponível em: <<http://www.bcb.gov.br/?serietemp>> Acesso em: 6 fev. 2017.

BANCO NACIONAL DE DESENVOLVIMENTO ECONÔMICO E SOCIAL. **O setor florestal no brasil e a importância do reflorestamento**. Rio de Janeiro, n. 16, 2002.

BARDAK, S.; TIRYAKI, S.; BARDAK, T.; AYDIN, A. Predictive Performance of Artificial Neural Network and Multiple Linear Regression Models in Predicting Adhesive Bonding Strength of Wood. **Strength of Materials**, v. 48, n. 6, p. 811-824, 2016.

BAUMEISTER, C.; KILIAN, L.; LEE, T. K. Are there gains from pooling real-time oil price forecasts? **Energy Economics**, v. 46, n. S1, p. 33-43, 2014.

BAYER, D. M.; CASTRO, N. M. R.; BAYER F. M. Modelagem e Previsão de Vazões Médias Mensais do Rio Potiribu Utilizando Modelos de Séries Temporais. **Revista Brasileira de Recursos Hídricos**, v. 17, n. 2, p. 229 - 239, 2012.

BENÍTEZ, J. M.; CASTRO, J. L.; REQUENA, I. Are Artificial Neural Networks Black Boxes? **IEEE Transactions on Neural Networks**, v. 8, n. 5, 1997, p. 1156 - 1164.

BERGER, R.; TIMOFEICZYK JÚNIOR, R.; SANTOS, A. J.; BITTENCOURT, A. M.; SOUZA, V. S. S.; EISFELD, C. L.; POLZL, W. B. Rentabilidade econômica da produção de Pinus spp. por mesorregião homogênea no estado do Paraná. **Revista Floresta**, v. 41, n. 1, p. 161-168, 2011.

BERTI, L. C. **A utilização de modelos econométricos para a previsão do preço da celulose no mercado internacional: uma comparação entre modelos univariados e multivariados**. 123 f. Dissertação (Mestrado Profissionalizante em Modelagem Matemática e Finanças) – Universidade de São Paulo, São Paulo, 2004.

BRAGA, A.; CARVALHO, A.; LUDERMIR, T. **Redes neurais artificiais: teoria e aplicações**. Rio de Janeiro: Livros técnicos e científicos, 2000.

BREPOHL, D. **A continuidade da contribuição econômica do setor florestal**. 103 f. Dissertação (Mestrado em Ciências) – Universidade Federal do Paraná, Curitiba, 1976.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **RAE-eletrônica**, São Paulo, v. 3, n. 1, p. 1 - 20, 2004.

BRESSAN, A. A.; LIMA, J. E. Modelos de previsão de preços aplicados aos

contratos futuros de boi gordo na BM&F. **Revista Nova Economia**, Belo Horizonte, v. 12, n. 1, p. 117 - 140, 2002.

BUENO, R. L. S. **Econometria de séries temporais**. 2ª ed. São Paulo: Cengage, 2015

BUONGIORNO, J. Forest sector modeling: a synthesis of econometrics, mathematical programming, and system dynamics methods. **International Journal of Forecasting**, v. 12, n. 3, p. 329 - 343, 1996.

_____. Global modelling to predict timber production and prices: the GFPM approach. **Forestry**, v. 88, n. 3, p. 291 - 303, 2014.

_____. Monetary union and forest products trade – The case of the euro. **Journal of Forest Economics**, v. 21, n. 4, p. 238 - 249, 2015a.

_____. Income and time dependence of forest product demand elasticities and implications for forecasting. **Silva Fennica**, v. 49, n. 5, p. 1 - 17, 2015b.

BUONGIORNO, J.; ZHU, S. Assessing the impact of planted forests on the global forest economy. **New Zealand Journal of Forestry Science**, v. 44, suppl 1, p. 2 - 9, 2014.

BUREAU OF LABOR STATISTICS. UNITED STATES DEPARTMENT OF LABOR. Disponível em: <<https://www.bls.gov>> Acesso em: 07 ago. 2017.

CANTARELI, E. B. **Falta de madeira para a construção civil**. Jornal do CREA, Porto Alegre, n. 13, p. 1 - 8, 2003.

CASTRO, R. V. O.; MENDES, A. F. N.; ATAÍDE, G. M.; ARAÚJO JUNIOR, C. A.; MARCATTI, G. E.; SILVEIRA, D. P.; COSTA, C. B. Análise econométrica da produção de madeira serrada no Brasil. **Revista Floresta**, v. 42, n. 4, p. 661 – 670, 2012.

CERETTA, P. S.; RIGHI, M. B.; SCHLENDER, S. G. Previsão do preço da soja: uma comparação entre os modelos ARIMA e redes neurais artificiais. **Informações Econômicas**, v. 40, n. 9, p. 15 - 27, 2010.

CHEN, K. Y. Combining linear and nonlinear model in forecasting tourism demand.

Expert Systems with Applications, v. 38, p. 10368 - 10376, 2011.

CHEN, K. Y.; WANG, C. H. A hybrid SARIMA and support vector machines in forecasting the production values of the machinery industry in Taiwan. **Expert Systems with Applications**, v. 32, n. 1, p. 254 - 264, 2007.

CLEMEN, R. T. Combining forecasts: A review and annotated bibliography. **International Journal of Forecasting**, 1989, v. 5, p. 559 - 583.

COLLETT, D. **Modeling Binary Data**. 2 ed. London: Chapman & Hall/CRC, 2003.

CONFEDERAÇÃO NACIONAL DA AGRICULTURA (CNA). **Caracterização da produção florestal brasileira por atividade, região e porte das empresas**. Documento publicado em 2016. Disponível em: <https://www.cnabrazil.org.br/assets/arquivos/artigostecnicos/artigo-19_0.90465700%201514912076.pdf>. Acesso em: 11 dez. 2018.

CORDEIRO, S. A.; SOARES, N. S.; BRAGA, M. J.; SILVA, M. L. Previsões do preço de exportação da madeira serrada de Pinus no Brasil. **Scientia Forestalis**, v. 38, n. 86, p. 205 – 214, 2010.

CORRAR, L. J.; PAULO, E.; DIAS FILHO, J. M. **Análise Multivariada**: para cursos de Administração, Ciências Contábeis e Economia. São Paulo: Atlas, 2007.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, programação e controle da produção**: MRP II/ERP: conceitos, uso e implantação. 3. ed. São Paulo: Atlas, 2000.

CORRÊA, M. F.; LACHTERMACHER, G.; MACHADO, M. A. S. Introdução de redes neurais em modelos de médias móveis na previsão de preços. **Resenha BM&F**, 89–97. Disponível em: <http://www2.bmf.com.br/cimConteudo/W_ArtigosPeriodicos/redesneurais167.pdf>. Acesso em: 19 ago. 2017.

COSTA, A. F. **Previsão de séries temporais financeiras por meio de redes neurais dinâmicas e processos de transformação de dados: uma abordagem empírico-comparativa**. 97 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Estadual Paulista Julio de Mesquita Filho., Bauru, 2012.

DAVIS, M.M.; AQUILANO, N.J.; CHASE, R.B. **Fundamentos da administração da**

produção. 3ª ed., Porto Alegre, Bookman, 2001.

DEPARTAMENTO DE INFORMÁTICA DO SUS (DATASUS). **Ministério da saúde**. Disponível em:

<<http://www2.datasus.gov.br/DATASUS/index.php?area=0206&id=6942&VObj=http://tabnet.datasus.gov.br/cgi/defthtm.exe?ibge/cnv/pop>> Acesso em: 16 dez. 2016.

DORNELES, R. C. Análise da conjuntura agropecuária safra 2011/2012: produtos florestais. **Secretaria da Agricultura e do Abastecimento**. DERAL. Curitiba, 2011, 16 p.

EHLERS, R. S. **Análise de séries temporais**. In: Notas de aula. São Paulo: USP, 2007. Disponível em: <<http://www.icmc.usp.br/pessoas/ehlers/stemp/>>. Acesso em: 15 jul. 2017.

EISFELD, R. L.; NASCIMENTO, F. A. F. **Mapeamento dos plantios florestais do estado do Paraná: *Pinus* e *Eucalyptus***. Curitiba: Instituto de Florestas do Paraná, 2015.

FAGUNDES, H. A. V. **Produção de madeira serrada e geração de resíduos do processamento de madeira de florestas plantadas no Rio Grande do Sul**. 180 f. Dissertação (Mestrado em Engenharia Civil) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2003.

FAJARDO, S. Aspectos da ocupação, da formação da estrutura produtiva e das transformações na paisagem rural no território paranaense. **Caminhos de Geografia**, v. 7, n. 20, p. 89-101, fev. 2007.

FELISONI A. C.; ZWICKER, R.; DIAS FOUTO, N. M. M.; LUPPE, M. R. Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro. **Brazilian Business Review**, v. 8, n. 2, p. 1 - 21, 2011.

FERNANDES, L. G. L. **Utilização de redes neurais na análise e previsão de séries temporais**. 76 f. Dissertação (Mestrado em Ciência da Computação) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 1995.

FIGLEWSKI, S.; URICH, T. Optimal Aggregation of Money Supply Forecasts: Accuracy, Profitability and Market Efficiency. **The Journal of Finance**, 1983, v. 38, n. 3, p. 695 - 710.

FITZPATRICK, D. W. **Neural net primer: a brief introduction to the use of neural networks suitable for futures forecast**. 1999. Disponível em: <<http://www.jurikres.com/down/nnprimer.txt>>. Acesso em: mai. 2016.

FLORIANO, E. P.; MULLER, I.; FINGER, C. A. G.; SCHNEIDER, P. R. Ajuste e seleção de modelos tradicionais para série temporal de dados de altura de árvores. **Revista Ciência Florestal**, v. 16, n. 2, p. 177 - 199, 2006.

FLORÊNCIO, P. H. B. **Aplicação de redes neurais artificiais na previsão de demanda de peças der reposição de veículos automotores**. 86 f.. Dissertação (Mestrado em Engenharia de Produção e Sistemas) – Pontifícia Universidade Católica de Goiás, Goiânia, 2016.

FOOD AND AGRICULTURE ORGANIZATION OF THE UNITED NATIONS (FAO). **Global Forest Resources Assessment 2015**. Desk reference. Roma, 2015.

_____. 2018. Disponível em: < <http://www.fao.org/faostat/en/#home>>. Acesso em: 08 de out. 2018.

GIL, A. C. **Como elaborar projetos de pesquisa**. 4 ed. São Paulo: Atlas, 2002.

GEVREY, M.; DIMOPOULOS, I.; LEK, S. Review and comparison of methods to study the contribution of variables in artificial neural network models. **Ecological Modelling**, v. 160, p. 249-264, 2003.

GODET, M. **A “caixa de ferramentas” da prospectiva estratégica**. CEPES – Centro de Estudos de Prospectiva e Estratégica. Lisboa, 2000 (Cadernos do CEPES). Disponível em: <<http://www.institutobrasilrural.org.br/download/20080615095245.pdf>> Acesso em: 17. Dez. 2017.

GOMES, D. T. **Redes neurais recorrentes para previsão de séries temporais de memórias curta e longa**. 153 f. Dissertação (Mestrado em Estatística) – Universidade Estadual de Campinas. Campinas, 2005.

GOMES, F. P. **Crescimento da economia e demanda de recursos florestais no Brasil**. 135 f. Dissertação (Mestrado em Economia) – Universidade Federal de Santa Catarina. Florianópolis, 2014.

GRANGER, C. W. J.; NEWBOLD, P. **Forecasting Economic Time Series**. London:

Academic Press, 1986.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5 ed. Porto Alegre: AMGH, 2011.

GUTIÉRREZ, J. L. C.; ROMANEL, C. Aplicação de redes neurais na previsão de vazão através da fundação da obreira esquerda da barragem Corumbá-I. In: XXV Seminário Nacional de Grandes Barragens, Comitê Brasileiro de Barragens. **Anais...** Salvador: 2003. p. 1-18.

HAIM, D.; ADAMS, D. M.; WHITE, E. M. Determinants of demand for wood products in the US construction sector: an econometric analysis of a system of demand equations. **Canadian Journal of Forest Research**. v. 44, n. 10, p. 1217-1226, 2014.

HAIR, J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. **Análise multivariada de dados**. 6. ed. Porto Alegre: Bookman, 2009.

HAMILTON, J. **Time series analysis**. New Jersey: Princeton University Press, 1994.

HANNINEN, R. Econometric models in forest sector forecasting. **Journal of Forest Economics**, n. 10. p. 57 - 59, 2004.

HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.

HEBB, D. O. **The Organization of Behavior**. [S.l.]: John Wiley 1949.

HEINRICH, D. **Simulação da produção de madeira serrada**. 159 f. Dissertação (Mestrado em Administração) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

HILL, R. C.; JUDGE, G. G.; GRIFFITHS, W. E. **Econometria**. 3 ed. São Paulo: Saraiva, 2010.

HOEFLICH, V. A. **Desenvolvimento florestal sustentável: requerimentos de uma sociedade**. n. 138. Colombo: Embrapa Florestas, 2006. 38 p.

HSIAO, C.; WAND, S. K. Comparison of forecasting methods with an application to

predicting excess equity premium. **Mathematics and Computers in Simulation**, [S.I.], v. 81, p. 1235 - 1246, 2011.

HURMEKOSKI, E.; HETEMAKI, L.; LINDEN, M. Factors affecting sawwood consumption in Europe. **Forest Policy and Economics**, v. 50, p. 236 - 248, 2015.

HURMEKOSKI, E.; SJØLIE, H.; HANNE, K. Comparing forest sector modelling and qualitative foresight analysis: Cases on wood products industry. **Journal of Forest Economics**, v. 31, p. 11 - 16, 2018.

HYNDMAN, R.J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**. v. 27, n. 3, p.1 - 22, 2008.

HWANG, S. Time series models for forecasting construction costs using time series indexes. **Journal of Construction Engineering and Management**, v. 137, n. 9, p. 656-662, 2011.

INDÚSTRIA BRASILEIRA DE ÁRVORES (IBÁ). **Indústria Brasileira de Árvores**. Ano base 2018. Brasília, 2019.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). SIDRA. Sistema IBGE de recuperação automática: banco de dados agregados. **Sistema produção da extração vegetal e da silvicultura**. Várias edições. Rio de Janeiro, 2020.

INSTITUTO DE PESQUISA ECONÔMICA APLICADA (IPEA). **Dados Macroeconômicos e Regionais** (IPEADATA). Disponível em: <<http://www.ipeadata.gov.br/Default.aspx>> Acesso em: 12. nov. 2016.

INTERNATIONAL TROPICAL TIMBER ORGANIZATION (ITTO). Disponível em: <http://www.itto.int/annual_review_output/>. Acesso em: 14 mar. 2017.

JEONG, D.; KIM, Y. Combining single-value streamflow forecasts: A review and guidelines for selecting techniques. **Journal of Hydrology**, v. 377, p. 284-299, 2009.

JOCHEM, D.; NIELS, J.; WEIMAR, H. Estimation of own and cross price elasticities of demand for wood-based products and associated substitutes in the German construction sector. **Journal of Cleaner Production**, v. 137, p. 1216 - 1227, 2016.

JOVIC, S.; GOLUBOVIC, Z.; STOJANOVIC, J. Wood bonding strength sensitivity estimation and power consumption prediction in wood machining process by artificial intelligence methods. **Sensor Review**, v. 37, n. 4, p. 444-447, 2017.

KHASHEI, M.; BIJARI, M. A artificial neural network (p,d,q) model for time series forecasting. **Expert Systems with Applications**, v.37, p. 479 – 489, 2010.

KLIDZIO, R. **Modelos de previsão aplicados ao controle de qualidade com dados autocorrelacionados**. 155 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Santa Maria, Santa Maria, 2009.

KURESKI, R. **Avaliação de impactos da indústria de base florestal sobre a ocupação e renda do Paraná – 1998: Uma aplicação da Matriz de Contabilidade Social**. 181 f. Tese (Doutorado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2003.

LEMGRUBER, A. C. O modelo econométrico de St. Louis aplicado ao Brasil. **Revista de Administração de Empresas**. v. 15, n. 1, 1975.

LOPEZ, J.M.C.; GAMA, M. **Comércio exterior competitivo**. 3 ed., São Paulo: Aduaneiras, 2007.

LU, Y.; ABOURIZK, S. M. Automated Box-Jenkins forecasting modeling. **Automation in Construction**, v. 18, p. 547 - 558, 2009.

MACCULLOCH, W. S.; PITTS, W. H.; A logical calculus of the ideas emmanent in nervous activity. **Bulletin of Mathematical Biophysics**, v. 5, p. 115 - 133, 1943.

MADDALA, G. S. **Introduction to econometrics**. 2^a ed. Englewood Cliffs: Prentice Hall, 1992.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting – methods and applications**, 3 ed. [S.I.]: John Wiley, 1998.

MANCUSO, A. C. B. **Uma investigação do desempenho de métodos de combinações de previsões: simulada e aplicada**. 78 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2013.

MANCUSO, A. C. B; WERNER, L. Estudo dos métodos de previsão de demanda aplicado em uma empresa de auditorias médicas. **Revista Ingenieria Industrial**, v 13, n. 1, p. 99 - 111, 2014.

MANHIÇA, A. A. **Rendimento e eficiência no desdobro de Pinus sp. utilizando modelos de corte numa serraria de pequeno porte** 97 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2010.

MANHIÇA, A. A; ROCHA, M. P.; TIMOFEICZYK JUNIOR, R. Rendimento no desdobro de Pinus sp. utilizando modelos de corte numa serraria de pequeno porte. **Revista Floresta**, Curitiba, v. 42, n. 2, p. 409-420, 2012.

MANHIÇA, A. A; ROCHA, M. P.; TIMOFEICZYK JUNIOR, R. Custos no Desdobro de *Pinus* spp. com Utilização de Modelos de Corte numa Serraria. **Floresta e Ambiente**, v. 20, n. 3, p. 327-335, 2013.

MANKIW, N. G. **Macroeconomia**. 6 ed. Rio de Janeiro: LTC, 2008.

_____. **Introdução à economia**. São Paulo: Cengage Learning, 2015.

MARTINEZ, R. O.; ZAMPROGNO, B. Comparação de algumas técnicas de previsão em análise de séries temporais. **Revista Colombiana de Estadística**, v. 26, no. 2, p. 129 - 157, 2003.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. São Paulo: Saraiva, 1999.

MARTINS, V. L. M.; WERNER, L. Comparação de previsões individuais e suas combinações: Um estudo com séries industriais. **Production**, v. 24, n.3, p. 618 - 627, 2014.

MATOS, O. C. **Econometria básica: teoria e aplicações**. 3ed. São Paulo: Atlas, 2000.

MEDEIROS, A. L. **Regressão múltipla e o modelo arima na previsão do preço da arroba do boi gordo**. 124 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal de Itajubá, Itajubá, 2006.

MENDES, J. T. G.; PADILHA JUNIOR, J. B. **Agronegócio: uma abordagem**

econômica. São Paulo: Pearson Prentice hall, 2007.

MENEZES, L. M.; BUNN, D. W.; TAYLOR, J. W. Review of guidelines for the use of combined forecasts. **European Journal of Operational Research**, v. 120, p. 190 - 204, 2000.

MICHINAKA, T.; TACHIBANA, S.; TURNER, J. A. Estimating price and income elasticities of demand for forest products: Cluster analysis used as a tool in grouping. **Forest Policy and Economics**, v. 13, n. 6, p. 435 - 445, 2011.

MINISTÉRIO DA AGRICULTURA, PECUÁRIA E ABASTECIMENTO (MAPA). **Cadeia produtiva de madeira**. Série Agronegócios. v. 6. 84 p. 2007. Disponível em: <<http://repiica.iica.int/docs/B0589p/B0589p.pdf>>. Acesso em: 03/12/2018.

_____. **Boletim da balança comercial do agronegócio**. Brasília, 2018. Disponível em:

<<https://www.google.com/url?sa=t&rct=j&q=&esrc=s&source=web&cd=1&ved=2ahUKahUKEwi616fgAhVpG7kGHaz7BtQQFjAAegQIAxAC&url=http%3A%2F%2Fwww.agriagricul.gov.br%2Fnoticias%2Fexportacoes-do-agronegocio-atingem-us-9-27-bilhoes-segundo-melhor-resultado-historico-para-junho%2Fnota-junho-2017-balanca-comercial.docx&usq=AOvVaw0vPtcxOWL2pirT-iRv6C4s>>. Acesso em 12/12/2018

MINISTÉRIO DE DESENVOLVIMENTO E INDÚSTRIA E COMÉRCIO EXTERIOR (MDIC). SECRETARIA DE COMÉRCIO EXTERIOR (SECEX). **SISTEMA DE ANÁLISE DAS INFORMAÇÕES DE COMÉRCIO EXTERIOR** (Aliceweb) Rio de Janeiro, 2017. Disponível em: <<http://alicesweb.mdic.gov.br>>. Acesso em: 17 nov. 2018.

MINISTÉRIO DO MEIO AMBIENTE (MMA). **Florestas do Brasil em Resumo 2013**: dados de 2017-2012. Serviço Florestal Brasileiro. Brasília: SFB, 2013.

MINISTÉRIO DO TRABALHO E EMPREGO (MTE). **Anuário do sistema público de emprego, trabalho, e renda 2016**: Mercado de Trabalho, Departamento Intersindical de estatística e estudos socioeconômicos. São Paulo: DIEESE, 2017.

MOON, T.; SHIN, D. H. Forecasting model of construction cost index based on VECM with search query. **KSCE Journal of Civil Engineering**, v. 22, n. 8, p. 2726-2734, 2018.

MORLAND, C.; SCHIER, F.; JANZEN, N.; WEIMAR, H. Supply and demand

functions for global wood markets: Specification and plausibility testing of econometric models within the global forest sector. **Forest Policy and Economics**, v. 92, p. 92 – 105, 2018.

MOREIRA, J. M. M. A. P.; SIMIONI, F. J.; OLIVEIRA, E. B. Importância e desempenho das florestas plantadas no context do agronegócio brasileiro. **Revista Floresta**, v. 47, n. 1, p. 85 - 94, 2017.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de Séries Temporais**. 2 ed. São Paulo: Edgard Blucher, 2006.

MUNIZ, J. Jr.; FERREIRA, U. R.; DELAMARO, M. C.; CAMPOS, A. E. M.; MARINS, F. A. S.; SALOMON, V. A. P.; COSTA, A. F. B.; BATISTA Jr., E. D.; SILVA, M.B.; ROCHA, H.M. **Administração de produção**. Curitiba: IESDE Brasil, 2.ed., 2012.

MURARA JUNIOR, M. I.; ROCHA, M. P.; TIMOFEICZYK JUNIOR, R. Rendimento em madeira serrada de Pinus taeda para duas metodologias de desdobro. **Revista Floresta**, Curitiba, v. 35, n. 3, p. 473 - 483. 2005.

MURARA JUNIOR, M. I.; ROCHA, M. P.; TRUGILHO P. F. Estimativa do rendimento em madeira serrada de pinus para duas metodologias de desdobro. **Revista Floresta e Ambiente**, Rio de Janeiro, v. 20, n. 4, p. 556 - 563, 2013.

NAVARRO, D.J.; MYUNG, I. J. **Model evaluation and selection**. Ohio State University, Department of Psychology: Columbus, 2004.

NING, Z.; SUN, C. Vertical price transmission in timber and lumber markets. **Journal of Forest Economics**, v. 20, n. 1, p. 17 - 32, 2014.

OLIVEIRA, A. C. S.; SOUZA, A. A.; LACERDA, W. S.; GONÇALVES, L. R. Aplicação de redes neurais artificiais na previsão da produção de álcool. **Ciência e Agrotecnologia**, Lavras, v. 34, n. 2, p. 279 - 284, 2010.

OLIVEIRA, M. A. **Aplicação de redes neurais artificiais na análise de séries temporais econômico-financeiras**. 316 f. Tese (Doutorado em Administração) – Universidade de São Paulo, São Paulo, 2007.

PALMER, A.; MONTAÑO, J. J.; SESÉ, A. Designing an artificial neural network for forecasting tourism time series. **Tourism Management**, v.27, p.781 - 790, 2006.

PARANÁ. SETI - Secretaria de Estado da Ciência, Tecnologia e Ensino Superior. **Oferta e demanda de madeira para fins industriais no estado do Paraná.** Curitiba, 2007.

_____. SEAB - Secretaria da Agricultura e do Abastecimento. DERAL - Departamento de Economia Rural. **Valor bruto da produção rural paranaense.** Curitiba, 2015.

_____. SEAB - Secretaria da Agricultura e do Abastecimento. DERAL - Departamento de Economia Rural. **Valor Bruto da Produção: Ano Base 2016.** Curitiba, 2017.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda – técnicas e estudo de caso. **Revista Produção**, Rio de Janeiro, v. 11, n. 1, p. 43 - 64, 2001.

PEREZ, P. L.; BACHA, C. J. C. Mercado de madeira serrada. **Agroanalysis**, v. 26, n. 8, p. 21 - 23, 2006.

PINDYCK, R. S.; RUBENFIELD, D. L. **Econometria: modelos e previsões.** 4 ed. Rio de Janeiro: Elsevier, 2004.

_____. **Microeconomia.** 7 ed. São Paulo: Pearson Education do Brasil, 2010.

POLZL, W. B.; SANTOS, A. J.; TIMOFEICZYK JÚNIOR. R.; POLZL, P. K. Cadeia produtiva do processamento mecânico da madeira: segmento da madeira serrada no estado do Paraná. **Revista Floresta**, v. 33, n. 2, p. 127 - 134, 2003.

PONCELA, P.; RODRÍGUEZ, J.; MANGAS, R. S.; SENRA, E. Forecast combination through dimension reduction techniques. **International Journal of Forecasting**, [S.l.], v. 27, p. 224-237, 2011.

PORTUGAL, M. S.; FERNANDES, L. G. L. Redes neurais artificiais e previsão de séries econômicas: uma introdução. **Nova Economia**, v.6, n.1, p.51 - 73, 1996.

PUNHAGUI, K. R. G.; CAMPOS, E. F.; GONZÁLEZ, J. M. B; JOHN, V. M. Prospects for the Use of Wood in Residential Construction in Brazil - First Results, Suíça. **Key Engineering Materials**, v. 517, p. 247 - 260, 2012.

RAMAGE, M. H.; BURRIDGE, H.; BUSSE-WICHER, M.; FEREDAY, G.; REYNOLDS, T.; SHAH, D. U.; WU, G.; YU, LI.; FLEMING, P.; DENSLEY-TINGLEY, D.; ALLWOOD, J.; DUPREE P.; LINDEN, P. F.; SCHERMAN, O. The wood from the trees: the use of timber in construction. **Renewable and Sustainable Energy Reviews**, v. 68, p. 333 - 359, 2017.

REIS, M. M. **Estatística para Administradores I. INE7001** - Notas de Aula, Capítulo 5, Departamento de Informática e Estatística, UFSC, 2017.

RIBASKI, N. G. Conhecendo o setor florestal e perspectivas para o futuro. **Brazilian Journal of Animal and Environmental Research**, v. 1, n. 1, p. 44 - 58, 2018.

RIBEIRO, A. R. **Previsão de demanda: estudo de caso na cadeia de suprimentos**. 145 f. Dissertação (Mestrado em Engenharia Industrial) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2009.

ROCHA, M. A. A. **Ensaio sobre o papel da taxa de câmbio no desenvolvimento**. 147 f. Tese (Doutorado em Economia de Empresas) – Escola de Economia de São Paulo da Fundação Getúlio Vargas, São Paulo, 2012.

ROCHA, M. P. **Desdobro Primário da Madeira**. – Série Didática FUPEF, Curitiba, n. 02/99. Curitiba, 1999.

_____. **Técnicas de planejamento em serrarias**. Série Didática FUPEF, Curitiba, n. 02/01, 2002.

SAMPAIO, F. S.; MAZZOCHIN, M. S. Espacialidade da economia: inovação e estratégias espaciais no setor de base florestal brasileiro. **Revista RAEGA**, n. 20, p. 53 – 65, 2010.

SANTORO, K. R.; BARBOSA, S. B. P.; SANTOS, E. S.; BRASIL, L. H. A. Uso de funções de covariância na descrição do crescimento de bovinos Nelore criados no estado do Pernambuco. **Revista Brasileira de Zootecnia**, Viçosa, v. 34, n. 6, p. 2290 - 2297, 2005.

SANTOS, C. C. **Previsão de demanda de água na região metropolitana de são paulo com redes neurais artificiais e condições socioambientais e meteorológicas**. 138 f. Tese (Doutorado em Engenharia Civil) – Escola Politécnica da Universidade de São Paulo, São Paulo, 2011.

SCHIER, F.; MORLAND, C.; JANZEN, N.; WEIMAR, H. Impacts of changing coniferous and non-coniferous wood supply on forest product markets: a German scenario case study. **European Journal of Forest Research**, v. 137Sch, n. 3, p. 279 - 300, 2018.

SELAU, L. P. R. **Construção de modelos de previsão de risco de crédito**. 130 f. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2008.

SENRA, L. F. A. D. C.; NANJI, L. C.; MEZA, L. A. Estudo sobre métodos de seleção de variáveis em DEA. **Pesquisa Operacional**, v.27, n.2, p.191-207, 2007.

SHARPE, N.; VEAUX, R. D.; VELLEMAN, P. F. **Estatística aplicada**: administração, economia e negócios. Porto Alegre: Bookman, 2011.

SIMANGUNSONG, B. C. H.; BUONGIORNO, J. International Demand Equations for Forest Products: A Comparison of Methods. **Scandinavian Journal of Forest Research**. v. 16Si, v. 2, p. 155 - 172, 2001

SIVARAM, M.; Modeling the price trends of teak wood using statistical and artificial neural network techniques. **Electronic Journal of Applied Statistical Analysis**, v. 7, n. 2, p. 180-198, 2014.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais Para Engenharia e Ciências Aplicadas**. 1 ed. São Paulo: Artliber, 2010.

SIMONDS INTERNATIONAL. Aplicação de Ferramentas de corte para a madeira. **Anais do II Congresso de Iniciação Científica da UNESP**, Itapeva, 2005.

SINDICATO DA INDUSTRIA DA CONSTRUÇÃO CIVIL NO ESTADO DO PARANÁ (SINDUSCON PR). Disponível em: <<https://sindusconpr.com.br/igp-di-fgv-308-p>>. Acesso em: 22 jan. de 2017.

SOBREIRO, V. A.; ARAÚJO, P. H. S. L.; NAGANO, M. S. Precificação do etanol utilizando técnicas de redes neurais artificiais. **Revista de Administração**, São Paulo, v. 44, n. 1, p. 46-58, 2009.

SOUSA, A. P.; MENEZES, J. E. Box-Jenkins e rede neural artificial para previsão de séries temporais: estudo comparativo entre modelos. In *Conjuntura Econômica*

Goiana, **IMB - Instituto Mauro Borges de Estatística e Estudos Socioeconômicos**, n. 24, p. 89 - 102, 2003.

SOUZA, C. C.; REIS NETO, J. F.; ARAUJO, L. O.; NUNES, H. S.; CONCEIÇÃO, L. R. Utilização de redes neurais artificiais para previsão de preços de frutas e hortaliças. **FACEF Pesquisa: Desenvolvimento e Gestão**, v. 17, n. 3, p. 259 - 272, 2014.

SOUZA, G. S. **Introdução aos modelos de regressão linear e não linear**. Brasília: EMBRAPA, 1998.

SUN, C.; ZHOU, X. Imperfect competition in China's import market of roundwood and lumber products. **Journal of Agricultural and Applied Economics**, v. 50, n. 2, p. 149-168, 2018.

TAYLOR, J. W. Exponential smoothing with a damped multiplicative trend. **International Journal of Forecasting**, v. 19, p. 715 - 725, 2003.

TUBINO, Dalvio Ferrari. **Manual de Planejamento e Controle da Produção**. 2 ed. São Paulo: Atlas, 2000.

TURBAN, E. **Decision Support and Expert Systems: Management Support Systems**. New York: MacMillan, 1993.

TURNER, J.; BUONGIORNO, J.; ZHU, S. An economic model of international wood supply, forest stock and forest area change. **Scandinavian Journal of Forest Research**, v. 21, n. 1, p. 73 - 86, 2006.

TSAY, R. S. **Analysis of financial time series**. 2 ed. New Jersey: John Wiley & Sons, 2005.

VALERIUS, J. **Dinâmica do Mercado mundial de molduras de madeira de coníferas e a competitividade brasileira nas importações dos Estados Unidos**. 159 f. Dissertação (Mestrado em Engenharia Florestal) – Universidade Federal do Paraná, Curitiba, 2016.

VASCONCELLOS, M. A. S.; GARCIA, M. E. **Fundamentos de economia**. 5 ed. São Paulo: Saraiva, 2014.

VERE, D.T.; GRIFFITH, G. R. Comparative Forecast Accuracy in the New South Wales Prime Lamb Market. **Australian Journal of Agricultural Economics**, v. 34, n. 2, p.103 - 117, 1990.

VILLAMAGNA, M. R. **Seleção de modelos de séries temporais e redes neurais artificiais na previsão de consumo e demanda de energia elétrica**. 118 f. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) – Univeridade Federal de Lavras, Lavras, 2013.

VITALE, V.; MIRANDA, G. de M. Análise comparativa da viabilidade econômica de plantios de Pinus taeda e Eucalyptus dunni na região centro-sul do Paraná. **Revista Floresta**, v. 40, n. 3, p. 469 - 476, 2010.

WANKE, P.; JULIANELLI, L. **Previsão de vendas: processos organizacionais & métodos quantitativos e qualitativos**. 1 ed. São Paulo: Atlas, 2006.

WEATHERFORD, L. R.; KIMES, S. A comparison of forecasting methods for hotel revenue management. **International Journal of Forecasting**, v. 19, p. 401 - 415, 2003.

WERNER, L. **Um modelo composto para realizar previsão de demanda através da integração da combinação e de previsões e ajustes baseado na opinião**. 166 f. Tese (Doutorado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 2004.

WERNER, L.; RIBEIRO, J. L. D. 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.

_____. Modelo composto para prever demanda através da integração de previsões. **Produção**, v. 16, n. 3, p. 493 - 509, 2006.

WIDROW, B.; RUMELHART, D. E.; LEHR, M. A. Neural networks: applications in industry, business and science. **Communications of the ACM**, v. 37, n. 3, p.93-105, 1994.

WIDROW, B.; HOFF JR, M. E. Adaptive switching circuits. **Ire Wescon Convention Record**, New York, p. 96 - 104, 1960.

WOOLDRIDGE, J. M. **Econometric analysis of cross section and panel data**.

Londres: The MIT Press, 2011.

XU, J.; MOON, S. Stochastic Forecast of Construction Cost Index Using a Cointegrated Vector Autoregression Model. **Journal of Management in Engineering**, v. 29, n. 1, p. 10-18, 2013.

XU, X.; QI, Y.; HUA, Z. Forecasting demand of commodities after natural disasters. **Expert Systems with Applications**, v. 37, p. 4313 - 4317, 2010.

ZANETTI JUNIOR, L. A.; ALMEIDA, F. C. Exploração do uso de redes neurais na previsão do comportamento de ativos financeiros. **Terceiro SEMEAD**, Faculdade de Economia Administração e Contabilidade – USP, 11 p. 1998.

ZANINI, A.; SOUZA, R. C.; PEDREIRA, C. E. Redes neurais e regressão dinâmica: um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no Brasil. In: XXXII SIMPÓSIO BRASILEIRO DE PESQUISA OPERACIONAL, 2000, Viçosa. **Anais...** Viçosa: Sociedade Brasileira de Pesquisa Operacional, 2000. p. 1928-1946

ZENID, J. G. **Madeira**: uso sustentável na construção civil. 2 ed. São Paulo: Instituto de Pesquisa Tecnológica, SVMA, 2009.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA and neural network model. **Neurocomputing**, 2003, v. 50, p. 159 - 175.

APÊNDICE 1 – MODELO EXPLICATIVO DETALHADO

RESULTADO DO AJUSTE DO MODELO DE MÍNIMO QUADRADOS ORDINÁRIOS (MQO).

MQO: MQO, usando as observações 1998-2017 (T = 20)
Variável dependente: ld_preco_ser

| | <i>Coefficiente</i> | <i>Erro Padrão</i> | <i>razão-t</i> | <i>p-valor</i> | |
|------------------------|---------------------|-----------------------|----------------|----------------|----|
| const | -0,00201856 | 0,0128456 | -0,1571 | 0,8770 | |
| ld_preco_ser_euc | 0,606073 | 0,231798 | 2,6147 | 0,0181 | ** |
| ld_preco_tora | 0,214259 | 0,133191 | 1,6087 | 0,1261 | |
| Média var. dependente | 0,010296 | D.P. var. dependente | | 0,080050 | |
| Soma resíd. quadrados | 0,053158 | E.P. da regressão | | 0,055919 | |
| R-quadrado | 0,563391 | R-quadrado ajustado | | 0,512025 | |
| F(2, 17) | 10,96820 | P-valor(F) | | 0,000873 | |
| Log da verossimilhança | 30,92336 | Critério de Akaike | | -55,84671 | |
| Critério de Schwarz | -52,85952 | Critério Hannan-Quinn | | -55,26358 | |
| rô | -0,129513 | Durbin-Watson | | 1,993568 | |

FONTE: O autor (2018) através do aplicativo computacional Gretl 2016d-git®.

APÊNDICE 2 – MODELO PREDITIVO DETALHADO

- a) RESULTADO DO AJUSTE DO MODELO ARIMA ELABORADO A PARTIR DA EQUAÇÃO 23 PARA O PREÇO MÉDIO REAL DE MADEIRA SERRADA DE PINUS NO ESTADO DO PARANÁ.

Com base na Eq23: ARMAX, usando as observações 1999-2015 (T = 17)
Variável dependente: *ld_Preco_ser*
Erros padrão baseados na Hessiana

| | <i>Coefficiente</i> | <i>Erro Padrão</i> | <i>z</i> | <i>p-valor</i> | |
|------------------------|---------------------|--------------------|-----------------------|----------------|---|
| const | 0,00676834 | 0,0272292 | 0,2486 | 0,8037 | |
| theta_1 | 0,249291 | 0,22917 | 1,0878 | 0,2767 | |
| theta_2 | 0,43549 | 0,24138 | 1,8042 | 0,0712 | * |
| ld_Con_br_ser | -0,941818 | 0,639897 | -1,4718 | 0,1411 | |
| ld_Pro_mad_ser_br | 1,271 | 0,741676 | 1,7137 | 0,0866 | * |
| Média var. dependente | 0,019534 | | D.P. var. dependente | 0,080749 | |
| Média de inovações | 0,000565 | | D.P. das inovações | 0,066551 | |
| Log da verossimilhança | 21,71878 | | Critério de Akaike | -31,43757 | |
| Critério de Schwarz | -26,43829 | | Critério Hannan-Quinn | -30,94063 | |

| | <i>Real</i> | <i>Imaginária</i> | <i>Módulo</i> | <i>Frequência</i> |
|--------|-------------|-------------------|---------------|-------------------|
| MA | | | | |
| Raiz 1 | -0,2862 | -1,4881 | 1,5153 | -0,2802 |
| Raiz 2 | -0,2862 | 1,4881 | 1,5153 | 0,2802 |

FONTE: O autor (2018) através do aplicativo computacional Gretl 2016d-git.

- b) RESULTADO DO AJUSTE DO MODELO ARIMA ELABORADO A PARTIR DA EQUAÇÃO 22 PARA O PREÇO MÉDIO REAL DE MADEIRA SERRADA DE PINUS NO ESTADO DO PARANÁ.

Com base na Eq22: ARMAX, usando as observações 1999-2015 (T = 17)
Variável dependente: *ld_Preco_ser*
Erros padrão baseados na Hessiana

| | <i>Coefficiente</i> | <i>Erro Padrão</i> | <i>z</i> | <i>p-valor</i> | |
|------------------------|---------------------|--------------------|-----------------------|----------------|---|
| const | 0,0215393 | 0,0188415 | 1,1432 | 0,2530 | |
| theta_1 | 0,063882 | 0,341459 | 0,1871 | 0,8516 | |
| ld_Pre_tor | 0,34191 | 0,193064 | 1,7710 | 0,0766 | * |
| ld_Pre_euca | 0,420274 | 0,310208 | 1,3548 | 0,1755 | |
| Média var. dependente | 0,019534 | | D.P. var. dependente | 0,080749 | |
| Média de inovações | 0,000065 | | D.P. das inovações | 0,069112 | |
| Log da verossimilhança | 21,30050 | | Critério de Akaike | -32,60100 | |
| Critério de Schwarz | -28,43494 | | Critério Hannan-Quinn | -32,18689 | |

| | <i>Real</i> | <i>Imaginária</i> | <i>Módulo</i> | <i>Frequência</i> |
|--------|-------------|-------------------|---------------|-------------------|
| MA | | | | |
| Raiz 1 | -15,6539 | 0,0000 | 15,6539 | 0,5000 |

FONTE: O autor (2018) através do aplicativo computacional Gretl 2016d-git.

- c) RESULTADO DO AJUSTE DO MODELO ARIMA ELABORADO A PARTIR DA EQUAÇÃO 22 PARA PREVISÃO DOS ANOS DE 2018 A 2021 DO PREÇO MÉDIO REAL DE MADEIRA SERRADA DE PINUS NO ESTADO DO PARANÁ, CONSIDERANDO OS DADOS OBSERVADOS NOS ANOS DE 2016 E 2017.

Modelo: ARMAX, usando as observações 1999-2017 (T = 19)
 Variável dependente: ld_Preco_ser
 Erros padrão baseados na Hessiana

| | <i>Coefficiente</i> | <i>Erro Padrão</i> | <i>z</i> | <i>p-valor</i> | |
|------------------------|---------------------|--------------------|-----------------------|----------------|---|
| const | 0,0171775 | 0,0161288 | 1,0650 | 0,2869 | |
| theta_1 | 0,00461943 | 0,337597 | 0,0137 | 0,9891 | |
| ld_Pre_tor | 0,365664 | 0,187513 | 1,9501 | 0,0512 | * |
| ld_Pre_euca | 0,386088 | 0,300214 | -1,2860 | 0,1984 | |
| Média var. dependente | 0,015845 | | D.P. var. dependente | 0,078192 | |
| Média de inovações | 4,48e-06 | | D.P. das inovações | 0,067404 | |
| Log da verossimilhança | 24,28408 | | Critério de Akaike | -38,56816 | |
| Critério de Schwarz | -33,84596 | | Critério Hannan-Quinn | -37,76898 | |

| | <i>Real</i> | <i>Imaginária</i> | <i>Módulo</i> | <i>Frequência</i> |
|--------|-------------|-------------------|---------------|-------------------|
| MA | | | | |
| Raiz 1 | -216,4767 | 0,0000 | 216,4767 | 0,5000 |

FONTE: O autor (2018) através do aplicativo computacional Gretl 2016d-git.

APÊNDICE 3 – VALORES OBSERVADOS

VALORES OBSERVADOS NAS SÉRIES TEMPORAIS UTILIZADAS.

| Ano | PR_t^{ser} (R\$/m ³) | PR_t^{tor} (R\$/m ³) | Pbr_t^{ser} (m ³) | Ppr_t^{ser} (m ³) | Ppr_t^{tor} (m ³) | SM_t^{br} (R\$) | Cbr_t^{ser} (m ³) | $CPCbr_t^{ser}$ (m ³ /uni.) | PIB_t^{civpr} (R\$) | PIB_t^{civsp} (R\$) |
|------|---------------------------------------|---------------------------------------|------------------------------------|------------------------------------|------------------------------------|----------------------|------------------------------------|---|--------------------------|--------------------------|
| 1997 | 402,44 | 98,09 | 5.610.000 | 4.189.281,12 | 9.216.418,47 | 402,10 | 4.983.831,15 | 0,0312 | 25.598.360,95 | 157.400.027.316,21 |
| 1998 | 365,92 | 107,36 | 6.020.000 | 2.333.131,82 | 5.132.890,00 | 427,04 | 5.243.131,97 | 0,0324 | 27.451.523,27 | 164.910.013.863,02 |
| 1999 | 378,41 | 103,57 | 6.730.000 | 3.395.975,91 | 7.471.147,00 | 414,69 | 5.555.750,92 | 0,0339 | 24.481.871,35 | 152.133.802.030,78 |
| 2000 | 376,69 | 106,53 | 7.800.000 | 4.223.308,18 | 9.291.278,00 | 430,02 | 6.525.008,44 | 0,0384 | 22.732.256,94 | 149.305.609.240,36 |
| 2001 | 417,76 | 120,89 | 7.950.000 | 5.096.676,82 | 11.212.689,00 | 468,55 | 6.627.835,01 | 0,0384 | 20.849.964,23 | 141.581.709.886,14 |
| 2002 | 422,47 | 130,08 | 8.320.000 | 6.143.619,55 | 13.515.963,00 | 470,01 | 6.850.479,90 | 0,0392 | 19.561.384,04 | 131.604.433.076,43 |
| 2003 | 556,44 | 172,64 | 8.660.000 | 4.560.247,70 | 10.032.544,95 | 507,20 | 7.038.642,71 | 0,0398 | 19.624.167,37 | 122.857.281.225,06 |
| 2004 | 613,11 | 199,01 | 7.400.000 | 5.214.959,57 | 11.472.911,06 | 519,19 | 5.824.837,28 | 0,0325 | 20.048.657,73 | 120.624.142.849,14 |
| 2005 | 625,49 | 233,86 | 8.935.000 | 4.723.875,41 | 10.392.525,90 | 555,88 | 7.431.656,68 | 0,0403 | 18.840.881,49 | 132.104.165.473,27 |
| 2006 | 603,57 | 182,08 | 9.078.000 | 4.534.673,81 | 9.976.282,38 | 634,53 | 7.787.664,32 | 0,0417 | 18.142.775,50 | 122.823.327.138,50 |
| 2007 | 586,26 | 158,08 | 9.577.000 | 4.954.282,91 | 10.899.422,41 | 670,43 | 8.304.968,04 | 0,0439 | 18.966.026,08 | 139.354.537.081,08 |
| 2008 | 606,54 | 146,31 | 9.531.900 | 4.844.620,36 | 10.658.164,79 | 695,39 | 8.582.446,44 | 0,0453 | 18.786.932,35 | 154.802.154.019,57 |
| 2009 | 557,49 | 134,59 | 8.470.000 | 4.663.425,45 | 10.259.536,00 | 750,84 | 7.770.116,91 | 0,0406 | 19.271.419,44 | 162.907.253.365,08 |
| 2010 | 539,49 | 134,47 | 8.970.000 | 4.800.626,82 | 10.561.379,00 | 784,58 | 8.303.352,49 | 0,0435 | 20.579.714,27 | 199.602.984.541,17 |
| 2011 | 535,98 | 122,01 | 9.060.000 | 4.580.327,73 | 10.076.721,00 | 786,05 | 8.330.360,59 | 0,0433 | 20.908.216,75 | 207.695.267.499,50 |
| 2012 | 516,53 | 129,06 | 9.170.000 | 5.043.122,73 | 11.094.870,00 | 848,90 | 8.456.354,51 | 0,0436 | 20.386.696,60 | 213.156.263.747,38 |
| 2013 | 520,49 | 136,44 | 9.370.000 | 5.431.415,45 | 11.949.114,00 | 873,70 | 8.627.434,56 | 0,0429 | 20.115.284,63 | 222.351.580.684,40 |
| 2014 | 517,05 | 139,74 | 9.230.000 | 4.978.662,15 | 10.953.056,74 | 876,77 | 8.243.830,54 | 0,0407 | 18.506.591,16 | 213.601.424.882,18 |
| 2015 | 510,04 | 134,41 | 9.230.000 | 3.396.426,70 | 7.472.138,73 | 862,27 | 7.932.057,31 | 0,0388 | 15.217.310,88 | 187.087.064.322,41 |
| 2016 | 523,73 | 129,65 | 10.083.886 | 3.732.947,41 | 8.212.484,31 | 905,96 | 8.225.701,73 | 0,0399 | 13.515.045,13 | 197.321.176.500,00 |
| 2017 | 494,46 | 128,22 | 8.600.000 | 3.477.146,82 | 7.649.723,00 | 937,00 | 7.527.535,16 | 0,0359 | 12.471.386,96 | 182.083.650.000,00 |

FONTE: O autor (2018).

VALORES OBSERVADOS NAS SÉRIES TEMPORAIS UTILIZADAS.

| Ano | Po_t^{br} (uni.) | R_t^{br} (R\$) | J_t (%) | HP_t (uni.) | Ce_t (R\$/U) | Cr_t R\$/US\$ | Exm_t^{ser} (m ³) | $Exeua_t^{ser}$ (m ³) | $Preuc_t^{ser}$ (R\$/m ³) | PR_t^{fer} (R\$/t) |
|------|-----------------------|---------------------|--------------|------------------|-------------------|--------------------|------------------------------------|--------------------------------------|--|-------------------------|
| 1997 | 159.636.297 | 2.541,55 | 264,97 | 1.441.100,00 | 98,51 | 2,37 | 239.689,34 | 138.422,99 | 417,02 | 1.034,95 |
| 1998 | 161.790.182 | 2.526,35 | 289,93 | 1.612.260,00 | 102,24 | 2,55 | 313.758,40 | 185.325,48 | 414,84 | 1.314,39 |
| 1999 | 163.947.436 | 2.189,58 | 254,41 | 1.663.532,00 | 150,97 | 3,75 | 517.449,46 | 309.900,47 | 394,83 | 1.913,70 |
| 2000 | 169.799.170 | 2.082,07 | 175,31 | 1.592.267,00 | 139,23 | 3,69 | 524.134,41 | 346.357,91 | 386,60 | 2.057,31 |
| 2001 | 172.385.776 | 1.948,46 | 177,18 | 1.636.676,00 | 164,79 | 4,47 | 523.447,10 | 362.399,39 | 412,01 | 1.897,45 |
| 2002 | 174.632.932 | 1.731,41 | 194,44 | 1.747.678,00 | 189,14 | 5,06 | 695.124,93 | 498.160,83 | 391,73 | 2.359,79 |
| 2003 | 176.876.251 | 1.491,85 | 229,85 | 1.889.214,00 | 183,87 | 4,97 | 813.041,30 | 541.077,48 | 486,73 | 3.003,09 |
| 2004 | 179.108.134 | 1.417,30 | 163,69 | 2.070.077,00 | 175,76 | 4,53 | 869.813,58 | 613.089,22 | 539,71 | 3.638,37 |
| 2005 | 184.184.074 | 1.421,53 | 192,11 | 2.155.316,00 | 144,14 | 3,69 | 891.743,65 | 701.269,66 | 575,41 | 3.459,37 |
| 2006 | 186.770.613 | 1.506,45 | 151,02 | 1.838.903,00 | 129,22 | 3,28 | 722.969,60 | 492.339,89 | 584,92 | 2.833,18 |
| 2007 | 189.335.191 | 1.480,29 | 119,12 | 1.398.415,00 | 119,12 | 2,92 | 614.724,69 | 349.331,36 | 578,71 | 2.281,88 |
| 2008 | 189.612.814 | 1.466,07 | 125,53 | 9.05.359,00 | 113,41 | 2,60 | 462.980,04 | 261.951,67 | 574,41 | 3.032,22 |
| 2009 | 191.481.045 | 1.443,29 | 97,54 | 5.82.963,00 | 114,93 | 2,79 | 313.304,15 | 202.868,28 | 590,99 | 2.593,37 |
| 2010 | 190.755.799 | 1.405,65 | 99,75 | 6.04.610,00 | 100,00 | 2,36 | 282.515,93 | 115.403,98 | 618,41 | 2.205,13 |
| 2011 | 192.379.287 | 1.360,14 | 117,38 | 6.24.061,00 | 96,12 | 2,17 | 312.412,49 | 125.488,51 | 589,90 | 2.154,66 |
| 2012 | 193.976.530 | 1.387,07 | 83,94 | 8.29.658,00 | 106,88 | 2,43 | 289.749,64 | 94.634,12 | 546,60 | 2.287,35 |
| 2013 | 201.062.789 | 1.350,43 | 83,04 | 9.90.822,00 | 113,56 | 2,57 | 350.488,15 | 154.465,75 | 601,76 | 2.499,96 |
| 2014 | 202.799.518 | 1.395,38 | 109,72 | 1.052.124,00 | 117,47 | 2,66 | 439.615,71 | 195.968,46 | 608,38 | 2.451,09 |
| 2015 | 204.482.459 | 1.144,74 | 136,51 | 1.182.582,00 | 141,58 | 3,43 | 517.450,54 | 194.786,08 | 589,88 | 2.305,60 |
| 2016 | 206.114.067 | 1.100,70 | 140,92 | 1.206.642,00 | 134,93 | 3,45 | 693.324,76 | 243.376,70 | 580,52 | 2.255,63 |
| 2017 | 209.607.642 | 1.268,00 | 100 | 1.281.977,00 | 122,00 | 3,19 | 1.077.930,11 | 100.201,45 | 569,54 | 2.304,51 |

FONTE: O autor (2018).