**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Uma comparação entre modelos de previsão de preços do boi
gordo paulista**

Vitor Bianchi Lanzetta

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração:
Economia Aplicada

**Piracicaba
2018**

Vitor Bianchi Lanzetta
Bacharel em Ciências Econômicas

Uma comparação entre modelos de previsão de preços do boi gordo paulista
versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **PEDRO VALENTIM MARQUES**

Dissertação apresentada para obtenção do título de
Mestre em Ciências. Área de concentração:
Economia Aplicada

Piracicaba
2018

Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP

Lanzetta, Vitor Bianchi

Uma comparação entre modelos de previsão de preços do boi gordo paulista / Vitor Bianchi Lanzetta. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. - - Piracicaba, 2018.

107 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura "Luiz de Queiroz".

1. Boi gordo 2. Previsão 3. Redes neurais 4. Suavização exponencial I.
Título

SUMÁRIO

RESUMO.....	4
ABSTRACT.....	5
1. INTRODUÇÃO	7
2. RISCO, INCERTEZA E PREVISÕES	11
2.1. PREVISÃO, UMA VISÃO GERAL	13
2.2. PREVISÃO DO BOI GORDO.....	18
3. METODOLOGIAS E DADOS.....	27
3.1. SUAVIZAÇÃO EXPONENCIAL.....	28
3.2. MERCADO FUTURO.....	35
3.3. REDES NEURAIS ARTIFICIAIS (ANN)	41
3.4. COMBINAÇÃO DE PREVISÕES.....	49
3.5. AVALIAÇÃO E CLASSIFICAÇÃO.....	50
3.5.1. <i>Três medidas</i>	50
3.5.2. <i>Pós-partida</i>	53
3.6. DADOS	54
4. RESULTADOS.....	67
4.1. SUAVIZAÇÃO EXPONENCIAL.....	67
4.2. MERCADOS FUTUROS	75
4.3. REDES NEURAIS	81
4.4. COMPARAÇÃO CONJUNTA.....	88
4.5. MODELOS COMBINADOS	93
5. CONCLUSÕES	95
REFERÊNCIAS.....	97
APÊNDICES	101

RESUMO

Uma comparação entre modelos de previsão de preços do boi gordo paulista

O estudo comparou o desempenho preditivo dos modelos de previsão de redes neurais e de suavização exponencial, empregando dados diários do preço da arroba do boi gordo futuro (BM&FBOVESPA) entre janeiro de 2010 até dezembro de 2015. Os resultados mostram que modelos relativamente mais complexos como redes neurais não necessariamente apresentam melhor desempenho se comparados a modelos mais simples, e também mostram que a classificação relativa muda conforme variam as medidas de ajuste e/ou horizonte de previsão além de vantagens associadas a combinação de diversos modelos.

Palavras-chave: Boi-gordo; Previsão; Redes neurais; Suavização exponencial

ABSTRACT

A comparison between São Paulo's live cattle prices forecasting models

This study compared the predictive performance between neural network models and exponential smoothing, using daily data of live cattle future price (BM&FBOVESPA) from January 2010 to December 2015. The results show that relatively more complex models like neural networks do not necessarily display better performance compared to simpler ones. Results also shows that relative classification changes with respect to adjust measures and/or forecast horizons changes besides advantages achieved by model combinaion.

Keywords: Live cattle; Forecasting; Neural network; Exponential smoothing

1. INTRODUÇÃO

Dos vários problemas que compelem aos agentes econômicos inseridos no contexto da economia de mercado, a confecção¹, classificação e uso de previsões² tem relação direta com o problema essencial da economia, isto é, a alocação de bens escassos às necessidades ilimitadas. Em relação as atividades produtivas, boas previsões são responsáveis por melhor adequar a produção, estoques e insumos. Dentre as atividades que podem se beneficiar do uso de previsões, a pecuária de corte brasileira é uma delas.

Da Silva et al. (2012) relatam a história do povoamento bovino no Brasil central e explicam que a espécie bovina foi trazida para a América do Sul no ciclo das Grandes Navegações. Os primeiros exemplares chegaram no Brasil em 1533 na expedição de Martin Alfonso de Souza, responsável pela fundação da primeira Capitania Portuguesa na Ilha de São Vicente. Desde então a atividade tem ganho considerável importância, com um rebanho nacional somando 215.199.488 cabeças³ no ano de 2015, de acordo com a Pesquisa Pecuária Municipal (PPM) conduzida pelo Instituto Brasileiro de Geografia e Estatística (IBGE).

Somente no estado de São Paulo, o Instituto de Economia Agrícola (IEA) estimou em cerca de R\$ 8,9 bilhões o valor da produção de carne bovina durante o ano de 2015. Para o mesmo ano esse valor representou 14,69% do Valor da Produção de um total de 50 itens que compõe a lista dos Principais Produtos Agropecuários do Estado de São Paulo, elaborada pelo IEA. Ainda em 2015, o relatório de *Live Stock and Poultry: World Market and Trade*, elaborado pelo United

---

1 É razoável assumir que agentes econômicos delegam tempo a construção de cenários, projeção de resultados além do estabelecimento de expectativas. Estes são em seu amago, previsões, que se distinguem entre si pela probabilidade inculcida a sua realização, propósito e natureza. Além da natureza estatística, computacional e matemática elas ainda podem descrever caráter intuitivo, provavelmente a natureza mais comum entre as previsões cunhadas por agentes cotidianamente.

2 Embora a previsão não se restrinja ao contexto de economia de mercado, em comparação com outros sistemas mais arbitrários, a economia de mercado apresenta um cenário no qual um número maior de variáveis estão sujeitas aos mais diversos tipos de oscilações, o que corresponde a um número maior de candidatos à previsão. Dessa forma o autor entende que quanto mais próxima uma economia se encontre do livre mercado mais propício é o ambiente em relação a previsões, uma vez que quanto mais livremente aos preços sejam permitidas oscilações, mais relevante e necessária se faz a previsão. Em um contexto extremo de economia de planejamento central os preços sequer oscilam consistentemente.

3 A título de comparação, o sítio <http://www.ibge.gov.br/apps/populacao/projecao/> projetava uma população de pouco mais de 207 milhões de pessoas no Brasil as 10:30:00 do dia 6 de fevereiro de 2017.

States Department of Agriculture (USDA), referente ao mês de outubro destaca a posição do Brasil como maior exportador de carne bovina, depois de superar Austrália e Índia.

Ainda que a atividade de pecuária de corte brasileira ostente desempenho satisfatório, sua natureza intrínseca, caracterizada por um lapso temporal prolongado entre a decisão de produção – isto é, compra dos insumos – e a realização efetiva da produção, aliado a dependência climática, remetem a uma série de riscos e incertezas. O conjunto de fatores de riscos, aliados a importância econômica que a atividade exerce – tanto em nível estadual quanto global – sugerem potencial ganho associado ao apropriado uso de previsões⁴ de variáveis como o preço da arroba (@) do boi gordo.

Contínuos avanços nas metodologias de previsão trazem à tona a necessidade de novas experiências associadas a essas mesmas metodologias. As redes neurais artificiais (ANN) não tinham sido adotadas de forma prática antes dos anos 80⁵, ainda pouco aplicada ao contexto de previsão de preços do boi gordo. Em contrapartida uma série de estudos, como é o caso de Makridakis et al. (1982, 1993, 2000) evidenciam que não necessariamente modelos mais complexos se saem melhor quando comparados os resultados fora da amostra. Outras evidências importantes trazidas à tona por esses mesmos trabalhos dizem respeito à combinação linear de modelos concorrentes – que de acordo com os autores, tende a se sair melhor em relação as suas contrapartes individuais – sobre horizonte de previsão – o desempenho dos modelos depende do tamanho do horizonte de previsão e sobre classificação dos modelos, que dificilmente se mantém quando medidas alternativas de desempenho são adotadas. Estas evidências impactam de maneira significativa o campo da previsão, ainda assim, a literatura carece de trabalhos que constata sua ocorrência no âmbito da previsão de preços da arroba do boi gordo no Brasil, sobretudo quando modelos ANN são levados em consideração.

---

4 Nate Silver (2012) mostra vários casos em que o uso inadequado das previsões teve consequências desastrosas.

5 A inspiração para os modelos ANN pode surgir em 1943 com o artigo de McCulloch e Pitts (*A logical calculus of the ideas immanent in nervous activity*), todavia, foi só em Paul Werbos (1974) que surge a primeira menção a utilização de um método tangível para treinar as redes neurais. A primeira aplicação prática aparece em Paul Werbos (1982).

Nesse contexto, o objetivo geral deste trabalho é verificar se para o caso específico da @ do boi gordo no estado de São Paulo, modelos de previsão de constituição mais complexa superam os modelos mais simples em horizontes diversos. Além disso, o trabalho tenta responder a uma série de perguntas como parte de seus objetivos específicos:

- Definir os escopos de risco e incerteza salientando o papel da previsão como instrumento de mitigação;
- Calibrar diferentes modelos de previsão de preços do preço da @ do boi gordo paulista (ANN, suavização exponencial, estatísticas históricas e contratos futuros) e combinação para diferentes horizontes de previsão (cinco, vinte e sessenta dias úteis a frente) usando dados diários de 2010 a 2013;
- Aplicar, apontar e contrastar medidas de ajuste dos modelos dentro (entre os anos de 2010 a 2013) e fora da amostra (2014 e 2015);
- Classificar e comparar os modelos com base nas diferentes medidas de ajuste, delimitações amostrais (dentro e fora da amostra) e horizontes de previsão;

Deste modo pretende-se avaliar se modelos de constituição mais complexa são capazes de imprimir desempenhos superiores em relação a outros mais simples ou até mesmo de indicadores já estabelecidos, como é o caso dos mercados futuros, para os ajustes fora da amostra, e até mesmo em relação à média simples das previsões. Além disso, pretende-se avaliar como se comportam os ajustes desses modelos para diferentes horizontes de previsão. As hipóteses iniciais são de que:

- (i) modelos de redes neurais exibem erros quadráticos e absolutos médios mais elevados em relação as mesmas medidas exibidas pelos modelos de suavização exponencial e mercados futuros calculada fora da amostra;
- (ii) os erros quadráticos e absolutos médios se ampliam na medida que se ampliam os horizontes de previsão para todos os modelos;
- (iii) previsões angariadas por meio da média simples de todos os modelos individuais apresentarão erros quadráticos e absolutos médios calculados fora da amostra menores do que qualquer modelo avaliado individualmente.

Evidências encontradas neste trabalho podem auxiliar produtores, pesquisadores e profissionais da previsão ligados ao agronegócio. Em muitas pesquisas, como no estudo de Peck (1976), a previsão de preços executa papel fundamental na determinação da razão de *hedge*. Em casos em que a previsão de preços da arroba constitui papel importante na pesquisa, este trabalho pode funcionar como um guia, auxiliando o pesquisador na escolha entre métodos de previsão simples, complexos ou mesmo combinações. Para os produtores, a escolha da previsão mais adequada para os preços da arroba pode mitigar riscos da atividade e de acordo com Makridakis et al. (2000), até mesmo reduzir custos. Caso o trabalho sinalize um ganho potencial dado pela combinação de previsões, incentivos são criados para que previsores individuais, sejam eles pesquisadores, produtores ou até mesmo especialistas, reúnam esforços em um ato de cooperação a fim de compartilhar e combinar suas previsões, obtendo maior acurácia.

No capítulo seguinte da revisão de literatura, inicialmente faz-se uma breve discussão a respeito das definições de risco e incerteza e suas implicações para a previsão. Ainda no mesmo capítulo serão alocadas revisões bibliográficas sobre previsão de modo geral, com destaque para o seu desenrolar ao longo dos anos, ressaltando diferentes características e usos de modelos diversos, para em seguida revisar trabalhos relacionados à previsão ligada ao preço da @ do boi gordo.

O capítulo de número três, intitulado Metodologia e Dados, explicita as metodologias adotadas, abrangendo desde a adoção dos preços dos mercados futuros, suavização exponencial e redes neurais. Além disso, o capítulo também é responsável por cobrir as medidas de ajuste utilizadas bem como apresentar os dados utilizados protagonizando também uma breve análise descritiva destes. Em seguida os capítulos cinco e seis apresentarão respectivamente os resultados e as conclusões.

2. RISCO, INCERTEZA E PREVISÕES

Knight (1921) define risco como a parcela mensurável do desconhecido, enquanto a incerteza fica relegada a parcela não mensurável⁶. Partindo de sua definição, pode-se inferir que a previsão tem como objetivo mitigar ambas⁷. A pecuária de corte, assim como diversas atividades ligadas ao agronegócio, está sujeita a uma série destes riscos. Nesse contexto a previsão é uma ferramenta capaz de auxiliar no processo decisório. Segundo Burgo (2005) a atividade agrícola tem como uma das características mais marcantes a magnitude e natureza dos riscos aos quais está sujeita. Carrer et al. (2013) arrola dois principais riscos: o risco de produtividade e o risco de preços, este último é o objeto de estudo do presente trabalho. Uma vez acolhido como objeto de estudo, o risco de preços deve ser então definido e delimitado.

Na literatura predominam dois entendimentos com respeito ao risco de preços. Um deles associa o risco apenas a oscilações inesperadas que tragam prejuízos, alternativamente, a definição restante abrange qualquer tipo de oscilação não esperada nos preços, independente do resultado trazido pela surpresa (prejuízos ou lucros não antecipados). Rossi (2008) é adepto da primeira corrente, para ele, o risco de preços consiste no “risco de queda dos preços dos produtos finais, ou do aumento dos preços dos insumos utilizados, depois da decisão de produção ter sido tomada”. Seguindo a risca sua definição, previsões pessimistas⁸ apresentariam maior capacidade de redimir os riscos de preços, uma vez que lucros inesperados não compõe o risco. Em contrapartida, Burgo (2005) identifica o risco de preços como sendo o risco associado a variações não antecipadas nos preços, sem associar tais variações seja com prejuízos nem mesmos lucros.

Carrer et al (2013) não deixa claro a qual grupo pertence, uma vez que faz menção ao risco de preços como oscilações desfavoráveis nos preços, deixando de

---

6 Knight (1921) diferencia risco de incerteza com base em seu caráter mensurável. Risco corresponderia então a parcela mensurável enquanto incerteza teria caráter não mensurável, ou então, não quantitativo, sendo referido pelo autor como “verdadeira” incerteza.

7 A inclusão das incertezas nesse computo depende em grande medida de como é interpretada a cláusula mensurável empregada por Knight (1921) para diferenciar risco de incerteza. Se o caráter não mensurável for atribuído à falta de ferramenta adequada para fazê-lo, logo, avanços nas previsões podem dirimir incertezas. Por outro lado, se por não mensurável se entende uma característica intrínseca da variável prevista, a previsão nada pode fazer nesse sentido.

8 Por previsões pessimistas entenda previsões com vieses baixistas para os preços dos produtos finais e altistas para os insumos a serem adquiridos.

esclarecer todavia qual a abrangência do termo desfavorável. Uma reflexão típica daquilo que os pesquisadores Philip E. Tetlock e Dan Gardner (2015) referenciam como *tip-of-your-nose perspective*⁹ poderia conduzir ao entendimento segundo o qual apenas as oscilações responsáveis por prejuízos inesperados seriam desfavoráveis, contudo, uma reflexão mais cautelosa, levando em conta os custos de oportunidade, indica que lucros inesperados também podem adquirir feições de prejuízos¹⁰. Assim, ambos os entendimentos acerca de risco de preços compreendem noções que abrangem o desfavorável.

Tendo isto em vista, o risco de preços defendido por Burgo (2005) pode ainda ser decomposto em duas categorias: risco de lucros – variações nos preços dos insumos e produtos que acarretem em lucros inesperados – e risco de prejuízos – variações nos preços dos insumos e produtos que culminem em prejuízos não antecipados. O presente trabalho adota o risco de preços como o risco de quaisquer oscilações não antecipadas de preços, em conformidade com a definição impressa por Burgo (2005). Deste modo, a previsão de preços da @ do boi gordo serve como ferramenta para mitigar os riscos de preços oriundos de operações que dele dependem, tanto no sentido de antecipar prováveis lucros quanto prejuízos, sendo o boi gordo um insumo ou produto.

Em decorrência do estabelecimento de novos modelos preditivos, origina-se a necessidade de testar sua viabilidade, isto é, contrapor sua complexidade e custo ante o desempenho angariado (resultado), sem deixar de considerar demais métodos já empregados. Por esse motivo o presente capítulo está dividido em duas subseções. A primeira cuida da evolução dos métodos de previsão de maneira geral. Em seguida, a segunda trata dos trabalhos específicos que destinaram seus esforços a tratar da previsão de preços voltada ao preço do boi gordo, examinando o modo como a evolução dos métodos se deu no estudo da *commodity* e a maneira como a pesquisa é usualmente conduzida, levantando aspecto como metodologias empregadas, amostra, tratamento dos dados e medidas de ajuste.

---

9 Em suma, o pensamento do tipo *tip-of-your-nose*, ou sistema 1, funcionaria quase como um reflexo, de maneira inconsciente, rápida e demandando pouco esforço. Em contrapartida, o sistema 2 operaria de modo consciente, lento e demandando muito esforço.

10 Colocando em termos da teoria da produção, subestimar receitas e superestimar custos, em qualquer que fosse a natureza do mercado, levaria a uma decisão de produção além de menor em termos de quantidade, pior em termos de lucro. Fácil perceber que tanto do ponto de vista do produtor que optou pela previsão viesada, quanto do ponto de vista do consumidor (que não teve papel nessa escolha) existam perspectivas de prejuízo na decisão tomada.

2.1. Previsão, uma visão geral

Gooijer e Hyndman (2006) revisaram 25 anos de pesquisas sobre previsões de séries temporais. Os autores ordenaram os artigos estudados de acordo com os modelos utilizados, estes foram: suavização exponencial, modelos ARIMA, modelos não lineares, modelos de longa memória, modelos ARCH/GARCH. Para os artigos que não tratavam de um modelo em específico, outros critérios foram adotados para agrupá-los, como por exemplo acurácia. Os autores ainda trataram de previsões de intervalo e densidade.

Gooijer e Hyndman (2006) explicam que em meados de 1980 os métodos de suavização exponencial eram frequentemente considerados como uma coleção de técnicas *ad hoc* para extrapolar os vários tipos de séries temporais. Os autores também esclarecem que apesar de amplamente utilizados pela indústria dos negócios, essa metodologia recebeu pouca atenção dos estatísticos, não apresentando uma fundamentação estatística desenvolvida.

Eles afirmam que previsões consideravelmente boas empregando o método da suavização exponencial foram reportados por diversos autores. Entre os trabalhos citados nesse sentido estão Satchell e Timmermann (1995) e Chatfield et al. (2001).

Realizando uma simulação Monte Carlo, Hyndman (2001) mostrou que se tratando de previsão, a suavização exponencial pode apresentar desempenho superior a modelos ARIMA de primeira ordem. O autor atribuiu a baixa performance da metodologia Box-Jenkins a erros de especificação do modelo, sobretudo quando o processo gerador dos dados não assume uma distribuição Gaussiana.

Outra evidência a favor da suavização exponencial vem de Makridakis et al. (1979). Em seu estudo utilizaram 111 séries temporais para examinar a acurácia de vários métodos de previsão, particularmente métodos de séries temporais. Uma das principais conclusões era de que os métodos simples, como o de suavização exponencial, apresentavam desempenho superior quando comparados a outros métodos tidos como mais sofisticados.

Ao analisar a metodologia, ARIMA, Gooijer e Hyndman (2006) apontam a publicação de *Time Series Analysis: Forecasting and Control*, de Box e Jenkins (1970) como responsável por integrar o conhecimento existente e estabelecer um procedimento de três etapas iterativas para identificação, estimação e verificação de

séries temporais. Eles afirmam que o livro teve grande impacto na teoria e prática da análise moderna de séries temporais e previsão.

Comparativamente ao estudo linear das séries temporais, o desenvolvimento dos estudos não lineares de séries temporais e previsão estariam ainda em sua infância. Em meados de 2006, previsões não lineares são obtidas tanto por simulação Monte Carlo quanto por *bootstrapping*, sendo a última abordagem preferida, uma vez que não depende de pressuposições a respeito da distribuição dos processos de erro (Gooijer e Hyndman, 2006, p. 453).

Entre os métodos não lineares apontados por Gooijer e Hyndman (2006) está o método das redes neurais. Os autores explicam que vários estudos têm reportado bons desempenhos na previsão de dados financeiros, muito embora alguns tenham se mostrado céticos a esse assunto questionando o seu desempenho¹¹.

Outra classe de modelos contemplados pelo estudo de Gooijer e Hyndman (2006) são aqueles caracterizados como família ARCH/GARCH. Eles descrevem os modelos de classe autorregressivos de heterocedasticidade condicional (ARCH) como responsáveis por descrever as mudanças dinâmicas na volatilidade por meio de uma função determinística dos retornos passados. Dessa maneira a previsão do período seguinte estaria prontamente disponível a múltiplos períodos à frente pode ser obtida recursivamente. Os autores ainda tratam sobre o modelo ARCH generalizado, ou então GARCH. Gooijer e Hyndman (2006, p. 455) caracterizam o modelo GARCH como um modelo mais parcimonioso em relação ao ARCH.

Uma série de trabalhos buscou comparar acurácia de previsão fora da amostra entre diferentes métodos de séries temporais. Alguns deles são Newbold e Granger (1974), Makridakis et al. (1979, 1982, 1993, 2000). Os últimos classificam Makridakis et al. (1979) como o primeiro esforço para comparar um grande número de métodos de séries temporais ao longo de múltiplos grupos de dados diferentes.

Makridakis et al. (1982, 1993, 2000) se destacam por avaliar os resultados da série de competições que ficou conhecida como *M-Competitions*. Makridakis et al. (2000) classificam essas competições como estudos empíricos no campo da

---

11 Gooijer e Hyndman (2006, p. 453 e 454) aponta Chatfield (1993) como um dos autores que questionam o aparente sucesso dos métodos de ANN. Chatfield (1993) compara o sucesso inicial das redes neurais artificiais com o sucesso inicial da metodologia Box e Jenkins e vê com cautela os resultados obtidos de estudos preliminares.

previsão que comparam a acurácia de vários métodos de previsão de modo que sua performance é mensurada de maneira objetiva.

Makridakis et al. (1982) foram responsáveis por analisar os resultados da primeira *M-Competition*. Os dados reportados pelo seu estudo correspondem a 24 diferentes métodos de previsões realizadas por 7 especialistas voltadas para até 1001 séries com horizontes de previsão variando de 6 a 18 períodos à frente.

Resultados obtidos Makridakis et al. (1982) estão de acordo com aqueles anunciados por Makridakis et al. (1979). Entre eles se destacam: (1) métodos estatisticamente complexos não necessariamente provêm previsões mais acuradas se comparadas com métodos mais simples; (2) o ranking relativo de performance de vários métodos varia de acordo com a medida de acurácia adotada; (3) a acurácia obtida pela combinação de diferentes métodos supera na média os diferentes métodos individuais sendo combinados e se sai muito bem em comparação com outros métodos; (4) a acurácia de vários métodos depende do horizonte de previsão.

Onze anos depois, o estudo de Makridakis et al. (1993) debruçou-se sobre a *M2-Competition*. A segunda edição da competição contou com 29 séries, sendo 23 vindas de quatro empresas e 6 de natureza macroeconômica. Cinco especialistas realizaram as previsões

Diferente da competição que antecedeu, foi possível para os competidores incorporar informações do estado da economia e obter informações adicionais junto das empresas colaboradoras enquanto formulavam e aprimoravam as previsões. Mesmo com essa inovação em relação a competição anterior, e se tratando de resultados fora da amostra, Makridakis et al. (1993) reportaram pouca ou nenhuma diferença em relação aos resultados demonstrados por Makridakis et al. (1979, 1982).

Em um breve artigo intitulado *A commentary on the M2-Competition*, Chatfield (1993) classifica a *M-Competition* como um marco nas pesquisas relacionadas à previsão. Ele manifesta sua opinião segunda a qual é provável que pouco progresso usando grandes bancos de dados e procedimentos automáticos procedam aqueles alcançados pela *M2-Competition*, sugerindo novos estudos utilizando bancos de dados menores.

Makridakis et al. (2000) sintetizam os resultados obtidos da *M3-Competition*. A terceira edição da competição contou com 3003 séries temporais estritamente positivas de diferentes tipos como micro, indústria, macro entre outros. A

periodicidade dos dados também varia, de anual, semestral, mensal. Os autores destacam que para viabilizar as previsões um número mínimo de observações para cada periodicidade foi considerado um número mínimo de observações.

Makridakis et al. (2000) reiteram os 4 pontos encontrados por Makridakis et al. (1979, 1982, 1993). Eles reportam que os mesmos resultados teriam sido sancionados por outros estudos, de forma a confirmar acima de qualquer dúvida, segundo os autores, que métodos estatisticamente mais sofisticados não necessariamente resultariam em maior acurácia da previsão fora da amostra em comparação com métodos mais simples, muito embora modelos estatísticos possam se encaixar melhor a dados disponíveis.

Muito embora Makridakis et al. (2000) indiquem um esgotamento dos estudos a respeito da acurácia de diferentes métodos de previsão eles apontam novas direções para as quais o tema pode caminhar. Nesse sentido, o destaque vai para melhorias na acurácia da previsão fora da amostra.

Em síntese eles destacam possíveis benefícios, economia de recursos, alocações mais eficientes, menores estoques, melhores serviços, todos advindo de melhorias na acurácia da previsão fora da amostra. Os autores ainda ressaltam a importância do trabalho conjunto entre estatísticos e previsores em prol de avanços no campo das previsões.

Apesar da sua abrangência, a *M3-Competition* contou com um único competidor utilizando o método das redes neurais artificiais¹². Alternativamente foi elaborada a *NN3-Competition*. Crone et al. (2011) classificam a competição como uma replicação da *M3-Competition* com a extensão de competidores das áreas de ANN e inteligência computacional (*computational intelligence* – CI).

Os resultados da *NN3-Competition* são expressos por Crone et al. (2011) e trazem novidades em relação aqueles obtidos pelas *M-Competitions*, o que acaba por chamar atenção a necessidade de mais estudos a medida que os métodos de previsão se aprimoram. Ao menos em parte, dois pontos não se verificam exatamente como em estudos anteriores.

---

¹² A variedade de possibilidades a ser explorada dentro do campo da ANN faz com o *desing* da rede neural constitua um mundo à parte. O método pode realizar aproximações lineares e não lineares.

O primeiro ponto diz respeito a relação entre acurácia e horizonte de previsão. Segundo Crone et al. (2011), os melhores métodos de CI apresentaram acurácia quase constante para crescentes horizontes de previsão.

Outra divergência parcial corresponde a performance de métodos simples em comparação com métodos complexos. De acordo com Makridakis et al. (1979, 1982, 1993) e Makridakis et al. (2000) métodos mais complexos não necessariamente superam métodos mais simples no desempenho fora da amostra.

Um singular método estatístico complexo foi capaz de superar todos os demais. Crone et al. (2011) classificam a metodologia utilizada pelo competidor Marc Wildi como sendo de natureza estatística e nada mais se não complexo.

Na descrição de seu método, disponibilizada no sítio do *NN3-Competition*¹³, Marc Wildi relata que os métodos tradicionais de previsão estão, em maior ou menor grau, sujeitos a problemas de especificação, responsáveis por afetar a sua performance fora da amostra. A não estacionariedade e distribuições não Gaussianas seriam os principais problemas.

Vale ressaltar que o estudo de Crone et al (2011) não coloca em cheque a validade e credibilidade dos estudos conduzidos anteriormente, ainda que seus resultados não converjam. Limitando o seu estudo aos métodos adotados em estudos anteriores seus resultados são essencialmente os mesmos. As novidades apontadas em seu estudo vêm da adoção de diferentes métodos de previsão, sobretudo em relação aos métodos de CI e ao método de Marc Wildi.

Esta subseção cuidou de um breve histórico a respeito da previsão. Ela tratou dos modelos utilizados para realizar previsões, algumas de suas aplicações bem como diversos estudos avaliando seu desempenho fora da amostra.

A subseção seguinte trata mais especificamente das previsões relacionadas ao preço do boi gordo. Ela objetiva levantar os dados e métodos utilizados para previsão da commodity bem como seus fins e resultados obtidos.

---

13 <http://www.neural-forecasting-competition.com/NN3>

2.2. Previsão do Boi Gordo

Considerando as limitações, todos os métodos mencionados na subseção anterior podem ser utilizados para fins de previsão do preço da @ boi gordo¹⁴. Tantos quantos os métodos de previsão são as razões para fazê-lo, estas podem variar desde de pesquisa, planejamento e *hedge*. Essa subseção vai abordar os estudos acadêmicos relacionados aos preços da arroba do boi gordo, segmentados em trabalhos voltados a previsão e trabalhos voltados à formação de preços. Destaques são confiados aos objetivos, dados, métodos de previsão e conclusões de cada trabalho.

Kassouf (1988) foi pioneira na previsão de preços da pecuária de corte paulista, tendo como objetivo estudar as variações nos preços mensais do bezerro, boi magro e boi gordo paulistas. Os dados vão de janeiro de 1970 a agosto de 1987, sendo para os valores compreendidos entre março e dezembro de 1986 utilizadas as observações levantadas pelo CEPEA/FEALQ (Fundação de Estudos Agrários “Luiz de Queiroz”), devido ao congelamento de preços, para os demais períodos os preços adotados foram os do IEA. Para os modelos de previsão foram utilizados os preços reais, deflacionados pelo Índice Geral de Preços – Disponibilidade Interna (IGP-DI) fornecido pela Fundação Getúlio Vargas (FGV), transformados usando logaritmos. Além de empregar os modelos do tipo ARIMA, SARIMA, harmônicos e mistos, os preços dados pela Bolsa de Mercadorias de São Paulo também foram comparados com os valores observados. Adotando o erro quadrático médio (EQM) como medida de ajuste da previsão do preço da @ do boi gordo, o estudo indicou o modelo misto AR (2) como o de melhor desempenho preditivo. Para as previsões realizadas entre 1981 e 1987, calibradas com dados de 1970 em diante, apenas nos anos 1982 e 1983 essas previsões superaram aquelas fornecidas pelo mercado a termo. Outros resultados importantes dizem respeito a estacionariedade, a série de preços reais logaritmizados foi considerada estacionária na sua primeira diferença bem como na primeira diferença sazonal. Kassouf ainda sugere a possibilidade de se obter ganhos associando técnicas econométricas conjuntamente a julgamentos pessoais e outros conhecimentos. Essa sugestão é reforçada por Nate Silver (2012),

---

14 Nada impede que os modelos da família GARCH sejam utilizados para previsões pontuais, muito embora sejam mais indicados para previsões envolvendo volatilidade, uma vez que o modelo subjacente escolhido para sua aplicação é o responsável por definir os resultados pontuais.

que salienta os bons resultados obtidos em projeções meteorológicas, onde o resultado final é comumente dado pelo conjunto de modelos formais estabelecidos ajustados pelo julgamento pessoal vindo de profissionais experientes.

Bacchi (1994) teve como objetivo modelar e prever as séries de preços do bovino, suíno e frango utilizando a metodologia Box & Jenkins, além de testar os modelos de função transferência. Semelhante ao procedimento realizado por Kassouf (1988), também utilizou os preços mensais obtidos junto ao IEA, deflacionados pelo IGP-DI e depois logaritmizados. As séries empregadas no estudo tiveram início em janeiro de 1971 indo até junho de 1992. Para denotar ajuste, a autora adotou o Índice de Theil (IT) como medida de desempenho dos modelos de previsão. As evidências encontradas sugerem que a série de preços reais logaritmizadas do boi gordo futuro são estacionárias na primeira diferença. Os testes de causalidade sugeriram uma relação causal no sentido preço do frango no preço do bovino, bem como do preço do bovino para os preços do frango e suíno. Com respeito as previsões dadas pelos modelos univariados, ainda que os testes tenham indicado não ser necessária a inclusão de termos sazonais (tanto pela diferença de 12 períodos como pela inclusão de binárias), esses procedimentos aprimoraram o desempenho preditivo do modelo. A inclusão das variáveis preço do frango e preço do suíno no modelo de previsão da arroba do boi gordo também aprimorou seu desempenho. Para a autora, os resultados das previsões indicam, segundo o critério de Theil, que os modelos empregados geraram boas previsões.

Bressan e Lima (2002) estudam a aplicabilidade de modelos de séries temporais como ferramentas de decisão de compra e venda de contratos futuros do boi gordo na BM&F. Os autores avaliam o desempenho preditivo de diferentes modelos de series temporais univariados, comparando os métodos ARIMA, redes neurais e dois modelos lineares dinâmicos (clássico e bayesiano). Eles utilizam duas medidas para avaliar e comparar os modelos, uma delas tem caráter estatístico, o Erro Percentual de Previsão (EPP), a outra apresenta caráter operacional e corresponde ao Índice de Sharpe.

Dados semanais dos preços físicos e futuros de cotação do boi gordo foram empregados no estudo. Para os preços físicos foi utilizada a cotação CEPEA e as cotações BM&F para o preço futuro, compreendidos entre 1996 e 1999. De acordo com Bressan e Lima (2002, p. 139), o modelo que apresentou o melhor desempenho de acordo com os dois indicadores foi o linear dinâmico com abordagem clássica.

Eles ressaltam que os demais modelos também apresentaram bons resultados para ambos indicadores. Um aspecto importante do trabalho de Bressan e Lima (2002) merece destaque. Os autores optaram por empregar como nós de entrada aqueles recomendados pela metodologia Box-Jenkins, contudo, Zhang et al (1998, p. 45) arrolam as razões para não fazê-lo. Sobretudo, modelos Box-Jenkins correspondem a modelos lineares, e o número de termos do tipo AR (auto correlacionados) apenas indica o número de observações linearmente correlacionados, os modelos de redes neurais por sua vez têm a capacidade de representar relações não lineares. Aspectos relacionados a definição de uma RNA serão abordados com mais profundidade em seção específica do capítulo seguinte.

Ferreira et al. (2011) utilizam modelos de redes neurais para precificar as commodities soja, boi gordo, milho e trigo empregando dados mensais obtidos juntos da Emater/RS, de 1992 até 2006. Seu objetivo é analisar o uso dessa metodologia para fins de previsão. O modelo de rede neural empregado tem duas entradas correspondendo aos preços defasados, cinco nós na sua camada escondida e mais um na camada de saída. A avaliação dos modelos ficou a cargo da raiz do erro quadrático médio (REQM). Para o treinamento dos modelos 140 observações foram utilizadas, mais 20 observações foram empregadas na fase de validação, isto é, averiguação do desempenho dos modelos fora da amostra. Com respeito a previsão de preços do boi gordo, o REQM da fase de treinamento foi de aproximadamente 0,005, já para a fase de validação a mesma medida atingiu patamares próximos de 0,007. Os autores concluem atestando pela alta capacidade preditiva dos modelos de redes neurais, bem como pela sua aplicabilidade no processo decisório.

Kohzadi et al. (1996) tem como objetivo comparar o desempenho dos modelos de redes neurais e séries temporais para fins de previsão do preço de commodities, entre elas o boi gordo. Os dados do boi gordo utilizados corresponderam aos preços mensais em dólares por cada 100 libras do boi gordo norte americano negociado em Omaha, obtidos junto do USDA. A série teve início em janeiro de 1950 e final em dezembro de 1990. Foram adotadas três medidas de ajuste, o erro quadrático médio (EQM), o erro médio absoluto (EMA) e o erro absoluto médio percentual (ABMP). Resultados fora da amostra foram coletados 7 vezes, por um período de 3 anos cada vez. Em média o modelo de redes neurais superou o tradicional modelo ARIMA para todas as medidas. Para o autor isso se deve a existência de comportamento caótico ou não linear dos dados. Um teste t

ainda sugere que a diferença entre os erros é estatisticamente diferente de zero. Outro aspecto de destaque do trabalho diz respeito a arquitetura das RNA treinadas, apenas uma camada escondida foi empregada.

Usando os dados do IEA, Sachs e Pinatti (2015) objetivam analisar a relação entre os preços do boi gordo e magro entre os anos de 1995 e 2006. Diferentemente dos estudos conduzidos por Kassouf (1988) e Bacchi (1994), os preços foram analisados na sua forma nominal, mas ainda logaritmizados. Além de realizar o teste de raiz unitária de Dickey-Fuller (ADF), causalidade de Granger e co-integração de Johansen, os autores ainda empregaram a metodologia de auto-regressão vetorial (VAR). O teste ADF sugere que a série de preços do boi gordo não é estacionária em nível, contudo, se torna estacionária na diferença. Esse mesmo resultado é observado em diversos outros trabalhos. Adotando o Critério de Informação de Akaike (AIC), os autores optaram pelo modelo auto-regressivo com uma defasagem para aplicar o teste de Granger. Os resultados deste sugerem que o preço do boi gordo causa (no sentido de Granger) o preço do boi magro, mas não o contrário. Constatadas evidências a favor da integração de ordem um para ambas variáveis estudadas, o AIC sugeriu o ajuste de modelos auto-regressivos com duas defasagens para a realização do teste de co-integração. Seu resultado sugere que as variáveis não são co-integradas, não apresentando uma relação de equilíbrio no longo prazo. A partir destas evidências os autores indicam o VAR nas diferenças como mais adequado. A análise de decomposição dos erros praticada a partir do modelo VAR indica uma relação de curto prazo entre as variáveis, na qual o preço do boi gordo descreve considerável influência sobre o preço do boi magro.

Margarido et al (1996) têm como objetivo estabelecer os graus de influência da cotação do dólar em mercado paralelo e dos índices pluviométricos das principais regiões produtoras de boi gordo do estado de São Paulo sobre o preço da @. Foram usadas três séries distintas do preço médio nominal do preço recebido pelo produtor do estado de São Paulo, entre janeiro de 1984 a maio de 1994, transformados usando uma função logarítmica. Os demais dados correspondem a cotação do dólar no mercado paralelo, também logaritmizado e a média aritmética simples do índice pluviométrico (em decâmetros) das regiões de Araçatuba, São José do Rio Preto e Presidente Prudente, principais regiões produtoras. O autor ainda procedeu de forma a realizar uma conversão entre moedas para a unidade do cruzeiro (Cr\$), sem, no entanto, contabilizar a inflação de modo intencional. Ainda fora introduzida

uma variável binária do tipo salto, representando os pacotes econômicos estabelecidos entre 1986 e 1990. O autor destaca a tendência explosiva impressa pelas variáveis dólar paralelo e preço da @ (já logaritimizadas), optando por trabalhar com as séries em suas primeiras diferenças. Com respeito a variável construída pelos índices pluviométricos, esta foi trabalhada em sua diferença sazonal.

Os modelos empregados corresponderam à metodologia ARIMA bem como funções de transferência. Entre os resultados o autor sugere estacionariedade na primeira diferença para a série de preços logaritimizada. Em relação a função de transferência no curto prazo, ele sugere que 39,31% da variação da informação do dólar são transmitidos ao preço do da arroba do boi gordo em um intervalo de um mês, já para o índice pluviométrico, 41,13% das informações são transferidas dentro de um intervalo de 5 meses. Para os resultados de longo prazo, o autor estima uma velocidade de ajuste de 106,06% entre o preço do boi gordo e o dólar paralelo, sugerindo uma elasticidade superior a unidade. Demais evidências dadas pela decomposição dos erros, indicam até mesmo para um horizonte de doze meses, em função de um choque não antecipado nos preços do boi gordo, a maior parte da decomposição de seu erro (99,55%) se deve a ela mesma.

Abitante (2008) também não realiza uma previsão do preço do boi gordo em si, no entanto ele busca uma cointegração entre mercados futuros e *spot* para o mercado brasileiro. As suas implicações são relevantes para a previsão do preço do boi gordo. Uma vez verificada a relação entre preço *spot* e futuro é fortalecida a hipótese segundo a qual os preços futuros predizem em certo grau o preço *spot*. Seu objetivo é verificar se existe uma ligação estatística de longo prazo entre o mercado físico e o mercado futuro dos mercados de boi gordo e soja brasileiros. Desse modo, evidências encontradas podem indicar a capacidade do mercado futuro fornecer informações capazes de auxiliar produtores no processo de descoberta de preço. Foram utilizados dados diários de contratos futuros com vencimento entre janeiro e novembro de 2005 disponibilizados pela BM&FBOVESPA. Para os preços futuros Abitante (2008) empregou a cotação do último negócio de contratos que venceriam em oito ou menos meses, excluídos os dias em que não houve negociação. O preço *spot* foi representado pelos dados do Centro de Pesquisas em Economia Aplicada (CEPEA – ESALQ/USP). Entre as suas conclusões o autor aponta para evidências a favor da ligação entre os mercados

futuros e *spot* do boi gordo para os contratos com vencimento em março, setembro, outubro e novembro de 2005. Para o autor, indícios de cointegração para os meses de setembro e outubro sugerem que os contratos futuros nesses vencimentos podem auxiliar os produtores de modo eficiente na descoberta de preços.

Tabela 2.2.1. Trabalhos de previsão revisados – dados, amostra, metodologia, tratamento dos dados e medidas de ajuste.

Autoria	Dados	Período analisado	Metodologias	Tratamento	Medidas de Ajuste
Kassouf (1988)	obs. mensais do preço @ boi gordo (IEA e CEPEA), IGP-DI (FGV) e @ do gordo a termo (BOLSA)	Jan/1970 a ago/1987	• ARIMA • SARIMA • Harmônicos • Mistos	Preços deflacionados e logaritimizados	• EQM
Bacchi (1994)	obs. mensais do preço @ boi gordo (IEA), IGP-DI (FGV) além de outros	jan/1971 a junho/1992	• ARIMA • SARIMA • funções de transferência • teste de causalidade	Preços deflacionados e logaritimizados	• IT
Bressan e Lima (2002)	obs. semanais do preço da @ do boi gordo físico (CEPEA) e futuro (BM&F)	jan/1996 a dez/1999	• ARIMA • MDL • RNA	Preços nominais	• EPP • Índice de Sharp e
Ferreira et al. (2011)	obs. mensais do preço da @ do boi gordo dados pelo Emater/RS	jan/1992 a dez/2006	• RNA	Preços Nominais	• REQM
Kohzadi et al. (1996)	obs. mensais dos preços em dólares por cada 100 libras de boi gordo negociados em Omaha (EUA)	jan/1950 a dez/1990	• ARIMA • RNA	Preços Nominais	• EQM • EMA • ABMP

Elaboração própria.

A Tabela 2.2.1 sintetiza alguns dos aspectos observados em trabalhos de previsão do preço do boi gordo revisados nessa seção. Entre os estudos a respeito da previsão de preços do boi gordo revisados nesta seção, uma parcela considerável deles – 4 de 5 (80%) – empregaram modelos do tipo ARIMA e derivados, 60% dos fizeram uso de modelos de RNA, muito embora nenhum destes indicou a utilização de algoritmos genéticos para a sua definição¹⁵.

¹⁵ Zhang et al. (1998) ressalta o caráter não trivial a tarefa de atribuir uma arquitetura para os modelos de RNA. Autores como Jones (1993) e Guo e Uhrig (1992) sugerem o emprego de algoritmos genéticos em sua designação.

Outro aspecto de destaque diz respeito a periodicidade, apenas um dos estudos empregou dados semanas, para os demais, dados mensais foram empregados. No que tange o tratamento dos dados, a maior parte dos estudos optou pela forma logarítmica, enquanto os modelos foram na maior parte dos estudos ajustados para a primeira diferença, fato este associado a necessidade linear dos modelos Box e Jenkins (1970)¹⁶. De modo semelhante aos períodos estudados e número de observações, as medidas de ajuste adotadas variam nitidamente de estudo para estudo, apenas o EQM se repetiu entre dois trabalhos distintos. Esse fato ganha relevância quando examinado a luz das sugestões exibidas pelos extensos estudos empíricos descritos por Makridakis et al. (1982, 1993) e Makridakis et al. (2000) cujos resultados apontaram evidências a favor da hipótese segunda a qual, o emprego de diferentes medidas de ajuste mais provavelmente conduza a diferentes conclusões no que diz respeito ao problema de comparação entre previsões. Deste modo, o emprego de um maior número de medidas conduz a maior solidez nos resultados, no sentido que indica se a divergência de desempenho entre modelos está associada as características a eles inerentes ou então as respectivas medidas de ajuste escolhidas¹⁷. Ademais, resultados de Kassouf (1988) reforçam a propriedade preditiva do mercado a termo do boi gordo, em conformidade com a hipótese de mercado eficiente (EMH, *efficient market hypothesis*), a medida que as previsões fornecidas por este mercado superaram as demais (ARIMA, SARIMA, harmônicos e mistos)¹⁸ em um número maior de anos.

Além dos estudos dedicados a previsão, esta subseção revisou artigos voltados para a formação de preços do boi gordo. Esses trabalhos contribuem com a confecção dos modelos de previsão de redes neurais à medida que sugerem variáveis relevantes para a formação de preços. Entre as variáveis apontadas como relevantes na formação de preços estão: cotação do dólar, índices pluviométricos e

---

16 Todos os estudos que empregaram modelos do tipo ARIMA sugeriram que a série é estacionária na sua primeira diferença.

17 Diferentes medidas de ajuste valoram de maneira distinta aspectos relacionados aos erros dos modelos. Um exemplo disso é como o EQM penaliza em maior grau erros extremos se comparado ao EMA.

18 Segundo a EMH, atribuída originalmente a Fama (1970), um mercado é eficiente quando os preços “refletem completamente” as informações disponíveis. Nesse contexto, um mercado futuro eficiente forneceria previsões relativamente boas dos preços no futuro.

cotações futuro da arroba do boi gordo. O próximo capítulo trata das metodologias e dados utilizados no estudo.

3. METODOLOGIAS E DADOS

Este capítulo se dedica a delinear as metodologias associadas a cada conjunto de modelos de previsão empregados – suavização exponencial, redes neurais, mercados futuros e combinação simples – explicitando suas formulações, maneira como são empregadas e pressupostos associados. O capítulo traz também as medidas de ajustes, além de apresentar e descrever uma breve análise descritiva dos dados empregados, dedicando especial atenção àqueles que correspondem a variável prevista.

Enquanto o emprego de uma variedade de medidas de ajuste tem por finalidade averiguar se a classificação dos diferentes métodos de previsão se deve às competências das metodologias utilizadas ou a diferentes ponderações das medidas de ajuste, o emprego de uma variedade de metodologias de previsão tem finalidades múltiplas. A comparação entre os métodos de suavização exponencial, mercados futuros e redes neurais pretende verificar se métodos mais complexos como os de redes neurais necessariamente superam métodos mais simples como é o caso da suavização exponencial e mercados futuros¹⁹. A comparação entre a combinação dada pela média simples e demais previsões tem como objetivo primário avaliar, ainda que de modo preliminar, os resultados da combinação de previsões no contexto do boi gordo. Mesmo que uma série de estudos apontem vantagens associadas à combinação de previsões em diversos campos, a literatura carece de estudos aplicados à previsão no contexto dessa *commodity* agrícola em específico. Ademais, resultados positivos obtidos por meio de combinações sugerem que metodologias de previsões de preços da @ do boi gordo, ainda que consideradas piores no sentido da acurácia, podem fornecer informações relevantes.

Partindo do método menos elaborado, a primeira seção explora o método da suavização exponencial. Em seguida são explorados os métodos de previsão via mercados futuros, aqui chamado de previsão *spread* em decorrência da metodologia desenvolvida para sua confecção, redes neurais e combinação simples de previsões. A combinação simples segue a seção de redes neurais, decorrente da

---

19 A metodologia que será apresentada no presente capítulo utilizando os dados do mercado futuro apresenta racionalidade estatística comportada dentro de relativa simplicidade, nesse aspecto a metodologia pode ser avaliada como simples. Por outro lado, pressupõe a existência de um mercado futuro para a variável prevista, o que por sua vez depende de sua viabilidade, portanto de um conjunto mais complexo de características oferecidas pelo produto e seu respectivo mercado.

necessidade de precedência das redes neurais – uma vez que o capítulo seguinte deve explorar os conteúdos deste capítulo em sequência similar – antes de combinar as diferentes previsões é necessário confeccioná-las. Na sequência virão as seções que tratam respectivamente das medidas de ajuste adotadas e apresentação e análise descritiva dos dados.

3.1. Suavização Exponencial

Adotado neste estudo como representante de modelos estatisticamente mais simples, Goojier e Hyndman (2006) atestam pela simplicidade dos modelos conhecidos por suavização exponencial. Eles chamam a atenção para sua ampla aplicação na indústria. Sua simplicidade leva pesquisadores a questionarem seu emprego. De acordo com Gardner (2006, p. 637), muitos acreditam que o método deveria ser desconsiderado por corresponder a um caso especial da modelagem ARIMA ou então se tratar de um processo *ad hoc* ausente de racionalidade estatística²⁰.

Chatfield et al. (2001), Hyndman (2001) e Makridakis et al. (1979) trazem indícios de um desempenho superior dos métodos de suavização em relação a metodologias tidas como estatisticamente mais complexas. A possibilidade de obter resultados mais satisfatórios a custos menores torna a metodologia não negligenciável.

Gardner (1985) afirma que evidências substanciais existem para concluir que os modelos de suavização exponencial são robustos não só do ponto de vista dos dados, mas também dos erros de especificação e, portanto, não deveriam ser desconsiderados. Ele atribui a popularidade dos métodos de suavização exponencial a acurácia surpreendente obtida com um esforço mínimo de identificação. Segundo Gardner (2006, p. 637), a metodologia de suavização exponencial é ótima para uma classe geral de modelos de estado espaço, mais amplo até mesmo que os modelos ARIMA.

Muito embora os métodos de suavização exponencial estejam mais comumente associados à ideia de simplicidade e seu desenvolvimento careça de

---

²⁰ Por racionalidade estatística não se deve entender a racionalidade debatida pela microeconomia, mas sim uma elaboração de cunho estatístico na sua origem, uma razão estatística.

racionalidade estatística, a metodologia evoluiu de forma a apresentar ampla variedade de estruturas a disposição. Elas têm como objetivo comportar diversos tipos de tendências, bem como capturar sazonalidades.

Essas diferentes estruturas apresentam divergências em termos de complexidade. O trabalho seminal de Gardner (1985), intitulado *Exponential Smoothing: The State of the Art*, descreve uma série especificações que se encontram sob o guarda-chuva que delimita os modelos conhecidos pela designação comum de suavização exponencial. A Figura 3, retirada de Gardner (1985, p. 2), exhibe o formato geral que cada modelo tende a apresentar. A escolha entre as diferentes estruturas disponíveis leva em conta o formato desenhado pela série, experiência e intuição do previsor. Esses mesmos fatores responsáveis por imbuir de personalidade o processo, são os mesmos que garantem simplicidade e agilidade à metodologia.

Figura 3.1.1 Formas das diferentes especificações dos modelos de suavização exponencial para diferentes tendências e tipos de sazonalidade.

Fonte: Gardner (1985, p. 2).

Na Figura 3.1.1, Gardner (1985) usa um sistema de dois algarismos para nomear cada estrutura. O primeiro algarismo representa o tipo de tendência adotado, enquanto o segundo faz alusão ao modo que a sazonalidade é tratada. Taxinomias alternativas usam caracteres alfabéticos seguindo a mesma ordem (tendência-sazonalidade) para descrever o modelo adotado. Essas taxinomias podem ser encontradas nos trabalhos de Hyndman et al. (2002) e Taylor (2003).

Gardner (1985) descreve a formulação e propriedades de um modelo simples de suavização. Esse modelo representaria a série temporal dada por $X_t = b + e_t$, onde e_t é corresponde a um componente aleatório, b é tido como uma constante em qualquer segmento local da série, mas pode mudar lentamente com o

passar do tempo. De acordo com Gardner (1985), ele pode ser expresso pelas eq. (3.1.1) e eq. (3.1.2):

$$S_t = \delta y_{t-1} + (1 - \delta)S_{t-1} \quad (3.1.1)$$

$$S_t = S_{t-1} + \delta \epsilon_{t-1} \quad (3.1.2)$$

Onde,

S_t : previsão para o período t ;

δ : parâmetro de suavização, com valor entre 0 e 1;

y_t : variável prevista no período t ;

ϵ_{t-1} : componente de erro referente à previsão no período $t-1$.

Em Gardner (1985, p. 3), os modelos descritos pelas eq. (3.1.1) e (3.1.2) são denominados de forma recorrente e formato de correção de erros, respectivamente. A eq. (3.1.2) pode ser obtida reorganizando a eq. (3.1.1).

Gardner (2006) descreve um método adaptativo para a suavização simples. Segundo o autor, esse método tem demonstrado uma melhoria crível na acurácia em comparação com métodos de parâmetros fixos. Ele esclarece, ainda, que o termo adaptativo significa tão somente que aos parâmetros são permitidas mudanças automáticas de maneira controlada à medida que as características das séries temporais se alteram.

Apesar do autor reportar uma série de propostas de metodologias adaptativas, apenas aquela apresentada por Taylor (2004a, 2004b) é associada a demonstrada melhoria na acurácia, em comparação com modelos de parâmetro fixo. Taylor (2004b) descreve a metodologia apresentada em seu estudo como um novo método adaptativo de suavização, que permite o parâmetro de suavização ser modelado como uma função logística de uma variável especificada pelo usuário. De acordo com o autor, um estudo empírico realizado com uma série de dados mensais obtidas da M3-Competition forneceu resultados animadores.

Depois de apresentar uma série modelos de transição suave de suavização exponencial (*smooth transition exponential smoothing* – STES), Taylor (2004b) descreve um modelo alternativo. Ele pode ser expresso nas eq. (3.1.3) e (3.1.4):

$$S_t = \delta_{t-1} y_{t-1} + (1 - \delta_{t-1}) S_{t-1} \quad (3.1.3)$$

Com

$$\delta_t = \frac{1}{1+e^{(\beta+\gamma V_t)}} \quad (3.1.4)$$

Onde,

δ_t : parâmetro transitório de suavização;

β, γ : parâmetros constantes;

V_t : parâmetro de transição escolhido pelo usuário.

Em comparação com a eq. (3.1.3), na eq. (3.1.4), o parâmetro de suavização ganha um sufixo indicando variação no tempo. Essa é a distinção fundamental que se faz entre modelos simples de suavização sem e com transição. A distinção fundamental que se faz entre outros modelos de transição suave reside, sobretudo, na maneira como é definida a transição. Taylor (2004b) define um parâmetro de transição com base em uma função logística.

Ele chama atenção para que, se $\gamma < 0$, δ_t é uma função monotonicamente crescente em V_t . O autor também esclarece que a função está restrita a valores entre 0 e 1, ressaltando que essa restrição tem um forte apelo intuitivo além de se tratar de uma convenção na maior parte dos *packages* de previsão mais populares.

Dois outros pontos destacados pelo autor dizem respeito a estimação dos parâmetros β , γ e a escolha do parâmetro de transição (V_t). A estimação dos parâmetros β e γ é realizada empregando dados históricos por meio de métodos de otimização não lineares. Taylor (2004b, p. 389) descreve como crucial para o sucesso do método a escolha do parâmetro de transição. As possibilidades arroladas pelo autor levam em consideração o último erro de previsão disponível ou então um conjunto de erros recentes.

Entre as opções que empregam o último erro disponível ele aponta o quadrado ou valor absoluto do último erro disponível. Considerando um conjunto de erros mais recentes as opções vão de média dos erros quadrados, média dos erros absolutos e erro percentual. Uma outra possibilidade inscrita pelo autor diz respeito ao uso do parâmetro adaptativo de outro STES. Neste trabalho optou-se por utilizar o método de GRC não linear para a soma do quadrado dos erros. Além do modelo STE, o modelo de suavização simples (SS) cuja constituição é ainda mais elementar será estimado conjuntamente.

Os modelos de redes neurais serão calibrados separadamente para cada horizonte de previsão. Esse procedimento evita uma série de complicações,

simplificando em grande medida o processo, em adição tende gerar melhores resultados, uma vez que a alternativa oposto se baseia em alimentar o modelo de previsões com previsões de diversas outras variáveis, que fogem ao escopo do trabalho. Desse modo, para colocar os modelos de suavização exponencial em pé de igualdade em termos de procedimento de ajuste, eles também serão calibrados especificamente para cada horizonte.

Para os modelos de suavização exponencial, o ajuste original seria feito por meio da série na primeira diferença, e a partir desta previsões extrapoladas aquelas para horizontes alargados. Em contrapartida, se tratando dos modelos ajustados para horizontes específicos, dois modos de fazê-lo serão testados (tanto para a suavização simples quanto para adaptativa) e adicionados ao conjunto de comparações. Ambos se alicerçam na premissa de que os erros que balizam o ajuste são representantes dos erros para o horizonte de previsão em questão.

Um deles se mantém mais alinhado em relação aos modelos mais tradicionais de suavização exponencial. Ele pode ser representado reescrevendo as eq. (3.1.1) e (3.1.3):

$$S_t = \delta y_{t-h} + (1 - \delta)S_{t-h} \quad (3.1.5)$$

$$S_t = \delta_{t-h} y_{t-h} + (1 - \delta_{t-h})S_{t-h} \quad (3.1.6)$$

As eq. (3.1.5) e (3.1.6) representam respectivamente as adaptações derivadas para os modelos de SS e STES. A mudança fica a cargo do subscrito h , agora os modelos passam a ser calibrados com base em informações defasadas na ordem do horizonte de previsão (h). O modelo alternativo a este responsável por carregar o mesmo propósito adiante se origina de um detalhe se fundamentando em um princípio: usar as informações mais atualizadas o possível.

Uma vez que as previsões são cultivadas de forma consistente com o horizonte definido $h > 1$, ao passo $t-h$ ao se definir uma previsão destinada ao período t , muito embora a realização y_{t-1} ainda não se encontre disponível, a previsão S_{t-1} certamente está. Em outras palavras, para horizontes de previsão superiores a um período a realização imediatamente anterior é desconhecida, mas a previsão imediatamente anterior não. A formalização desses modelos fica então a cargo das eq. (3.1.7) e (3.1.8):

$$S_t = \delta y_{t-h} + (1 - \delta)S_{t-1} \quad (3.1.7)$$

$$S_t = \delta_{t-h} y_{t-h} + (1 - \delta_{t-h})S_{t-1} \quad (3.1.8)$$

Note que a variável S (previsão exponencial) do lado direito das expressões (3.1.7) e (3.1.8) perdem o subscrito h que cede espaço para o subscrito 1. Novamente o primeiro modelo denota a adaptação destinada ao formalização SS seguido daquele destinado ao STES. Note que o parâmetro de suavização adaptativo mantém o subscrito h . Isto porque este é construído com base nos erros, e como os erros dependem do valor realizado o mais atual é aquele disponibilizado em $t-h$.

Para fins de referência, os modelos descritos pelas eq. (3.1.5), (3.1.6), (3.1.7) e (3.1.8) serão agrupados como modelos de suavização defasada. Por sua vez os modelos das eq. (3.1.5) e (3.1.6) serão chamados de defasagem geral enquanto os demais receberam o rótulo de defasagens atualizadas. Está explicação encerra os detalhes de como os modelos de suavização exponencial serão calibrados, mas carece de uma síntese dos pontos fortes e fracos e expectativas em relação a cada abordagem.

Talvez a maior desvantagem das abordagens defasadas em relação a tradicional seja a perda de observações proporcional ao horizonte de previsão. Conforme se expande o horizonte de previsão essa condição se agrava e atenuada por amostras consideravelmente grandes. Outra desvantagem aparente é a necessidade de se calibrar tantos modelos quanto horizontes diferentes se deseja investigar, para a abordagem tradicional basta calibrar um horizonte e expandi-lo para quantos se desejar. Essa, todavia é amainada por uma economia de escala. Ao se calibrar dois horizontes, calibrar um terceiro não parecerá tão difícil e assim por diante.

Essas desvantagens são contrabalanceadas pela expectativa de melhores desempenhos. É natural que se tratando de uma amostra relativamente grande resultados mais satisfatórios do ponto de vista de EQM e EMA sejam esperados dos modelos defasados em relação ao modelo tradicional. Essas questões levantadas serão avaliadas durante a fase de resultados e discussão. A seção a seguir aborda modelos desenhados usando somente dados obtidos junto aos mercados futuros.

3.2. Mercado Futuro

Alguns mercados de commodities agrícolas possuem correspondentes nos mercados financeiros, isto é, mercados futuros, como é o caso da arroba do boi gordo, que dispõe de contrato futuro negociado na BM&FBovespa. Usualmente seu correspondente é tido por muitos agentes como alternativa direta e instantânea para estabelecer suas previsões. Todavia, a mera tradução das informações dadas por contratos mensais para o contexto diário pede alguma adaptação – ou então uma sinalização caso opte por nenhuma. Além disso, a compreensão das teorias que buscam explicar a formação de preços futuros pode auxiliar na confecção dos modelos a serem estabelecidos para fins de previsão. Essa subsecção cuida de arrolar e examinar as principais teorias a respeito da formação de preços nos mercados futuros de commodities agrícolas. Também cuida de estabelecer o modelo de previsão derivado dos dados do mercado futuro usando tão somente estatísticas básicas.

São duas as principais interpretações dos preços das commodities futuros, a teoria dos estoques e a teoria do prêmio de risco, esta que divide o preço futuro em um prêmio de risco somada uma previsão do preço físico no futuro (Fama e French, 1987, p. 55). Em síntese, a teoria dos estoques preconiza que a diferença entre o preço físico e o preço futuro é dado pela taxa de juros, custo de carregamento e o *convenience yield*. Kaldor (1939) é um de seus precursores, definindo conceitos nucleares associados a ela. Telser (1958) avança nessa corrente, estudando a relação entre preços futuros e esperados, encontra evidências que corroboram a hipótese de que os preços futuros fornecem estimativas não viesadas dos preços físicos. Em contraparte, Cootner (1960) defende a segunda interpretação, também descrita como hipótese de Keynes-Hicks. Para o autor os preços futuros fornecem estimativas viesadas dos preços físicos. O viés fica por conta do prêmio de risco, enquanto seu componente restante seria dado pela previsão do preço físico no futuro. Fama e French (1987) ressaltam que para a segunda corrente não existe consenso em termos de poder de previsão ou até mesmo da existência do viés. Eles também chamam atenção que ambas correntes fornecem interpretações alternativas, e não contraditórias a respeito dos preços futuros.

Poder de previsão e viés são aspectos importantes quando se trata de previsão. O primeiro será testado dentro e fora da amostra contra uma série de

outros métodos de previsões, garantindo contexto ao poder de previsão. O segundo pode ser estimado de diferentes maneiras, tendo impacto direto sobre o primeiro. Assumindo uma característica sazonal da atividade pecuária de corte paulista, o viés será estimado na forma mensal. Esse modelo é expresso pela eq. (3.2.1):

$$p_{t,t-h}^* = f_{t,t-h} + v_i \quad (3.2.1)$$

Onde $p_{t,t-h}^*$ é a previsão de preços para o período t , realizada em $t-h$, e $f_{t,t-h}$ é representa a cotação média da respectiva commodity no período $t-h$ com maturidade para o período t . O parâmetro v_i cuida do viés mensal, que pode ser traduzido pela diferença média entre o preço futuro h períodos antes e o preço físico para o mês i . Adotando o paradigma de variação esperada no lugar do preço esperado, a eq. (3.2.1) pode ser adaptada, se apresentando da seguinte maneira:

$$(p_{t,t-h}^* - p_{t-h}) = (f_{t,t-h} - p_{t-h}) + v_i \quad (3.2.2)$$

Onde p_{t-h} é corresponde ao preço físico no período $t-h$. Assim a eq. (3.2.2) sustenta que a variação esperada no preço entre o período t e $t-h$ é dada pela diferença entre a cotação futuro em t com maturidade em $t-h$ e o preço no mercado físico em $t-h$, somado a um viés mensal.

As observações são diárias, entretanto os contratos futuros apresentam maturidade mensal, o que significa dizer que a diferença entre a maturidade de um contrato futuro e o seguinte conta um mês. Portanto, no contexto do trabalho, fixado o horizonte de previsão, para cada mês específico é esperado não mais do que uma única observação satisfazendo a condição de horizonte de previsão, isto é, para o mês i do ano j , no máximo uma observação difere entre o período atual e a maturidade do contrato em h períodos. Para determinado mês a inexistência de observações que satisfaçam a condição de horizonte pode ocorrer por dois motivos: feriado local na cidade onde se situa a bolsa, falta de liquidez em determinado contrato. Como as séries de futuro foram construídas pela cotação média, dias em que nenhum contrato fora negociado não fazem parte da amostra total, dessa forma, uma série de cotações médias fixado o primeiro vencimento entre janeiro de 2010 e dezembro de 2015 teria um total de 1.233 observações, já as series de segundo,

terceiro e quarto vencimentos fixados teriam respectivamente 1.213, 1.040 e 894 observações²¹.

Para endereçar o descompasso entre a frequência de previsões fornecidas pelo modelo da eq. (3.2.2) e a frequência dos dados optou-se por desenhar um modelo que busca extrapolar os horizontes de previsão dados por um determinado contrato em determinado dia. Uma solução satisfatória nesse sentido iria garantir mais flexibilidade no uso de contrato futuros com fins de previsão, uma vez que expande os horizontes de previsão fornecidos. No intento de buscar uma maneira de proceder com a extrapolação, uma análise preliminar do tipo exploratória dos dados será praticada. Os dados utilizados correspondem a cotação média do boi gordo futuro BM&FBovespa com primeiro vencimento e o preço físico é dado pelo indicador CEPEA/ESALQ, a frequência dos dados é diário, partindo de janeiro de 2010 até dezembro de 2015, esses dados são apresentados mais detalhadamente na subseção dados, que também descreve uma análise descritiva destes. A análise parte de uma pressuposição simples. Presuma que um indivíduo deseja sucessivamente prever o quinto próximo preço da arroba do boi gordo anunciado pelo indicador CEPEA/ESALQ, isto na maioria das vezes daria o preço referência daqui uma semana, o que equivale prever o preço anunciado em cerca cinco dias úteis. Assuma agora que esse mesmo agente opte por usar a cotação média do contrato futuro de vencimento mais recente (primeiro vencimento) como previsão. Nenhuma adaptação feita, o erro seria computado pela simples diferença entre a série de preços físicos e futuros cinco dias úteis antes. A expressão que descreve essa previsão pode ser obtida por:

$$p_{t-d,t-d-h}^* = f_{t,t-d-h} \quad (3.2.3)$$

Onde o subscrito d indica a diferença em termos de dias corridos que separa o alvo da previsão e a maturidade do contrato usado. Para o contexto descrito h assumiria o valor cinco com d variando de zero a trinta. Se praticada do início de 2010 até o final de 2015, os erros obtidos contrastados com o intervalo de dias entre

---

21 Seja por feriados locais ocorridos na cidade onde se situa a bolsa de futuros ou pela falta de liquidez exibida por um determinado vencimento existe uma disparidade entre o número de observações entre séries físicas e futuro. Para a série de preços físicos dentro do mesmo período são 1.245 observações. O tratamento aos dados “faltantes” é explicado na subseção dados.

a maturidade do contrato e o alvo da previsão exibiriam a mesma dispersão apresentado pela Figura 3.2.1.

Figura 3.2.1. Diferença entre os preços físicos (correntes) e futuros (defasados em cinco períodos) diários da arroba do boi gordo paulista entre janeiro de 2010 e dezembro de 2015.

Fonte: Elaboração própria com dados do CEPEA/ESALQ e BM&FBovespa.

Na Figura 3.2.1, o eixo horizontal exibe a diferença em termos de número de dias corridos entre o alvo da previsão²² e a maturidade do contrato. Tendo em vista que a previsão ajustada tinha como horizonte cinco dias úteis, d assume zero quando no dia em questão, o contrato responsável pela previsão do preço físico

²² Previsão de cinco períodos (dias úteis) a frente, dada pela série de contratos futuros de boi gordo BM&FBovespa com primeiro vencimento fixado.

estava a cinco dias de maturar. Com d valendo trinta existem trinta dias corridos entre a maturidade do contrato utilizado para previsão e o dia alvo da previsão. A medida que d se amplia, é natural esperar que o viés da previsão, que se espelha cada vez mais em um horizonte distante do alvo, se espace. Todavia, a linha vermelha, responsável por indicar a regressão linear de Y por X ($Y = a + bX$)²³, mostra que esse erro médio (viés) tende a diminuir a passos lentos conforme se ampliam os dias entre vencimento do contrato e dia alvo da previsão. Sem discriminar mês a mês, o viés (fornecido pelo intercepto), se mostra positivo em um primeiro momento caindo vagorosamente a medida em que ampliam os dias entre o vencimento do um contrato e o dia alvo da previsão. Vale salientar que o intervalo em que d está entre dez e quinze descreve uma variância menor em relação ao intervalo em que d assume valores entre zero e cinco. Para o primeiro intervalo a média é de aproximadamente 0,2547 com desvio padrão de 1,3497, já para o segundo a média foi de 0,1914 com desvio padrão de 0,9067.

---

²³ O intercepto (a) foi de 0,9071 e o coeficiente de variação (b) foi $-5,22 \cdot 10^{-5}$. Os p-valores para ambas estimativas foram respectivamente de 39,6% e 43,8%. Estatisticamente é difícil sustentar a existência de um viés que varia de acordo com descompasso entre horizonte de previsão e maturidade do contrato utilizado. Ainda assim vale checar empiricamente o desempenho dispositivo em uma situação simulada de previsão.

Figura 3.2.2. Diferença entre os preços físicos e futuros diários da arroba do boi gordo paulista entre janeiro de 2010 e dezembro de 2015, segmentados por mês.

Fonte: CEPEA/ESALQ e BM&FBovespa.

A Figura 3.2.2 mostra que o viés da previsão apresenta tendências em relação a variável d que se alternam entre os diferentes meses. Levando o componente sazonal em consideração ao descrever a análise, as dispersões apresentadas pela Figura 3.2.2 segmentam os erros da previsão dispostos na Figura 3.2.1 por mês. As linhas vermelhas mostram as tendências descritas pelos erros em cada um dos meses em relação a variável d . A sugestão dada pela Figurara 3.2.2 pode ser expressa pelas seguintes equações:

$$(p_{t+d,t-h}^* - p_{t-h}) = (f_{t,t-h} - p_{t-h}) + v_i(d) \quad (3.2.4)$$

$$v_i(d) = b + a \cdot d \quad (3.2.5)$$

Nela o viés mensal passa a ser uma função em relação a variável d . Não há claramente um caminho certo a ser tomado, mas duas possibilidades a serem testadas. O viés dos erros pode realmente exibir pouca ou até nenhuma relação com a variável d e o padrão exibido pelos erros mensais pode ser fruto apenas do menor número de observações obtidas quando se segmenta a amostra. Todavia o padrão observado quando a amostra é segmentada por mês pode ser de fato consistente e contribuir para a previsão fora da amostra. Com intuito de contrastar as duas abordagens tanto um modelo com viés único será estimado quanto outro modelo com viés mensal, variando em relação a d e seus resultados serão comparados tanto em relação seu desempenho fora como dentro da amostra, assim como todos os demais modelos, usando os contratos de primeiro e segundo vencimento, o que culmina com a criação de um total de quatro modelos de previsão. A comparação entre eles deve sugerir, para cada horizonte de previsão designado como o modelo de viés variável mensal se sai fora da amostra em relação ao modelo de viés constante e como o primeiro vencimento se sai em relação ao segundo vencimento. Enquanto para os modelos de viés constante a simples média dos erros obtidos usando a eq. (3.2.3), para o modelo de viés mensal os erros e a variável d será levantada para cada mês separadamente, em seguida o erro será regredido contra a variável d , ainda separados por mês, como resultado, os valores a e b farão parte da função responsável por devolver o viés esperado para cada mês baseado na distância entre a data que busca prever e o vencimento do contrato utilizado.

3.3. Redes Neurais Artificiais (ANN)

Kaastra e Boyd (1996) descrevem as ANN como sendo aproximações altamente flexíveis e universais de funções. Eles também relatam que apesar de seus primeiros usos se restringirem aos campos das ciências cognitivas e engenharia, nos anos recentes sua aplicação nas finanças tem ganho considerável espaço²⁴.

De acordo com Atkinson e Tatnall (1997) os procedimentos neurais têm mostrado um desempenho geralmente mais acurado. Zhang et al. (1998) descrevem

---

24 Entre as tarefas desempenhadas pelas ANN no campo das finanças, Kaastra e Boyd (1996) descrevem a previsão de séries temporais, reconhecimento de padrões e classificação.

uma série de características responsáveis por tornar os modelos de previsão baseados nas ANN atrativos em relação a modelos tradicionais. Entre as características arroladas pelos autores estão as capacidade de autoadaptação²⁵, generalização bem como menor necessidade pressuposições a priori, se comparados a modelos tradicionais.

Zhang et al. (1998, p. 35) chamam atenção para a inspiração biológica do modelo, oriunda em grande parte de estudos sobre o cérebro humano²⁶. Segundo os autores, o modelo foi originalmente designado para imitar o sistema neural básico, que é composto por unidades de processamento interconectadas.

Essas unidades recebem os nomes de neurônios ou nódulos. Cada nódulo recebe um sinal de entrada (“informação total”) que pode ter origem de outro nódulo ou então de um estímulo externo. A informação é processada localmente pelo nódulo por meio de funções de ativação ou transformação, e então transformada em um sinal de saída para outros nódulos ou então um resultado. A Figura 4 traz uma representação do funcionamento de dois nódulos. Um deles apresenta uma única entrada (a) em contraposição a outra que apresenta três entradas (b).

Figura 3.3.1. Representação Gráfica de nódulos de um sistema de redes neurais artificiais.

Fonte: elaboração própria.

²⁵ A capacidade de auto adaptação também é verificada nos modelos STES.

²⁶ Embora a inspiração tenha partido do cérebro humano, ela não representa a complexidade do cérebro humano em sua totalidade. Sarle (1994, p. 1) chama atenção que redes comparáveis ao cérebro humano em complexidade estão muito aquém da capacidade mesmo para mais rápidos computadores paralelos.

Na Figura 3.3.1, as incógnitas X_t representam dados de entrada do modelo. Muito embora o sufixo t faça alusão a um processo temporal, não necessariamente os dados devem corresponder a um processo desse tipo.

Designados com a letra W estão representados os pesos dados para cada informação. Nos quadriláteros, a função $S(X_i, W_i)$ corresponde a uma função de soma, onde os dados de entrada são somados considerando seus respectivos pesos. Ela pode ser expressa pela eq. (3.2.1):

$$S(X_i, W_i) = \sum_{i=0}^n W_i \cdot X_i \quad (3.2.1)$$

Em seguida, o octógono exibe a função $F(S)$, que é responsável por transformar o conjunto de dados de entrada ($X_i, \dots, X_t$) em dados de saída (Y_t). Essa função é também conhecida como função de transformação, ou então ativação.

Esse procedimento é descrito por Hinton (1992) como uma conversão em dois estágios. No primeiro estágio a função $S(X_i, W_i)$ daria origem a um computo conhecido como informação total. A etapa seguinte está associada a aplicação desse valor na função de transformação $F(S)$.

Como explica Hinton (1992), o comportamento das redes neurais depende tanto dos pesos atribuídos as entradas quanto da função de transformação que é especificada. Ele ainda explica que essas funções se encaixam em uma de três categorias: (i) linear; (ii) limite, (iii) sigmoide.

- (i) linear: saída é proporcional a informação total;
- (ii) limite: saída é designada como uma entre duas possibilidades dependendo do valor da informação total em comparação com outros valores;
- (iii) sigmoide: varia continuamente mas não linearmente conforme variações na entrada. É a forma que guarda maiores semelhanças com neurônios reais (Hinton, 1992, p. 145).

Tanto as entradas de informação, os pesos adotados e função de ativação caracterizam o funcionamento individual do nódulo. As redes neurais são formadas por nódulos interconectados, podendo assumir uma infinidade de configurações.

Na Figura 3.3.2, retirada de Zhang et al. (1998, p. 38) é possível verificar um exemplo de configuração de rede neural artificial. Nela os círculos representam nódulos. As setas ligadas aos círculos representam estímulos externos enquanto a

seta restante significa a saída do resultado da rede e as retas simulam ligações entre os nódulos.

Figura 3.3.2. Exemplo de configuração de rede neural artificial.

Fonte: Zhang et al. (1998, p. 38).

As primeiras camadas são chamadas de camada de entrada (*input layer*) e recebem os estímulos externos, ou dados de entrada. A última camada recebe o nome de camada de saída (*output layer*) e fornece o resultado do processamento. Ademais, as camadas intermediárias recebem o nome de camadas escondidas (*hidden layer*). Kaastra e Boyd (1996, p. 216) relacionam uma série de parâmetros comuns ao *desing* de uma rede neural de retro propagação. Eles envolvem: processamento de dados; treinamento e topologia.

A etapa de processamento de dados é comum entre diversos métodos de análise, tomando conta de questões como a frequência dos dados e método de amostragem. As etapas de treinamento e topologia são próprias dos métodos de redes neurais artificiais.

Entre os parâmetros de treinamento é possível destacar a taxa de aprendizado, tamanho da época, conjuntos de treinamento, teste e validação bem como algoritmo de treinamento²⁷. A topologia também pode ser chamada de arquitetura da rede, e é responsável por definir parâmetros como: número de

---

²⁷ Kaastra e Boyd (1996, p. 216) não mencionam o algoritmo de aprendizado, pois já partem do pressuposto que o algoritmo utilizado é o de retro propagação.

nódulos de entrada, número de nódulos de saída, número de camadas escondidas e funções de transferência para cada nódulo.

Sarle (1994, p.2) traz uma comparação entre a terminologia empregada nos modelos de redes neurais em comparação com os termos utilizados por modelos estatísticos. Analogias entre termos ligados a modelos estatísticos e redes neurais podem ser vistos na Tabela 3.3.1. Ainda que não haja correspondência perfeita entre os termos, a associação terminológica proposta por Sarle (1994) pode contribuir para o melhor entendimento das redes neurais artificiais por aqueles que possuem alguma familiaridade com modelos estatísticos.

Tabela 3.3.1. Analogia terminológica entre modelos estatísticos e modelos de redes neurais.

Modelo Estatístico	Redes Neurais
Variáveis	<i>Features</i>
Variáveis Independentes	Entradas
Valores previstos	Saídas
Variáveis dependentes	Alvos/valores de treino
Resíduos	Erros
Estimativas	Treinamento/aprendizado/adaptação/ auto-organização
Observações	Padrões/pares de treinamento
Parâmetros estimados	Pesos sinápticos
Interações	Neurônios de alta ordem
Transformações	Links funcionais
Regressão	Aprendizado supervisionado
Interpolação	Generalização

Fonte: elaboração própria com base em Sarle (1994, p. 2).

Zhang et al. (1998) trazem algumas considerações sobre as principais questões relativas a modelagem das ANN. Eles abrangem desde o estabelecimento do número de camadas escondidas até mesmo número de nódulos de entrada e saída. De acordo com os autores, o *design* da rede neural é usualmente não trivial e dependente do problema específico em questão. Os autores ainda ressaltam que apesar de existirem um série de algoritmos destinados a estabelecer o *design* da rede neural, estes são de difícil implementação sem garantias de um resultado ótimo.

Eles sugerem uma série de procedimentos para o estabelecimentos dos principais parâmetros que funcionariam como atalhos para o *design* da rede. Com respeito ao número de camadas escondidas, os autores citam uma série de trabalhos que atestam pela suficiência de apenas uma camada escondida para aproximar qualquer função complexa não linear.

Contudo eles chamam atenção para ocasiões onde o emprego de apenas uma camada escondida traga problemas. Caso sejam necessários muitos nódulos nas camadas escondidas, tanto o tempo de treinamento quanto capacidade de generalização do modelo podem ser prejudicadas.

Eles ainda citam diversos autores que atestam pela prevalência e maior acurácia promovida pelo emprego de duas camadas escondidas em contraposição

ao emprego de uma ou três camadas. Determinada em duas o número de camadas escondidas resta estabelecer o número de nódulos usados nas camadas escondidas.

Para eles a determinação do número ótimo de nódulos escondidos é um problema crucial e complicado. O uso de um número menor de nódulos escondidos é preferível, pois usualmente apresentam maior capacidade de generalização bem como menores chances de incorrer em *overfitting*. Por outro lado, redes com escassez de nódulos escondidos apresentam reduzido poder de modelar e aprender por meio dos dados.

Entre as maneiras de determinar o número de nódulos escondidos os autores apontam a tentativa e erro como mais comumente usados. Eles apontam também uma série de estudos que indicam para o melhor desempenho de previsão observado em modelos que empregaram o mesmo número de nódulos de entrada.

Para Zhang et al. (1987), o número de nódulos de entrada em um problema de previsão de séries temporais corresponde ao número de variáveis defasadas usadas para descobrir o padrão subjacente da série, embora não exista até então nenhuma sugestão de método sistemático para sua determinação. Dois pontos merecem revisões.

Se tratando de series temporais, as únicas entradas possíveis não correspondem apenas a valores defasados da série. Binárias, diferenças podem ser empregadas ou até mesmo dados de séries que não a prevista²⁸. Além disso vale ressaltar que nem sempre existe um padrão subjacente a ser descoberto. No caso dos mercados futuros, a hipótese de eficiência de mercado prevê desvios aleatórios dos preços.

Quando a finalidade é prever preços de mercado, o pesquisador deve considerar tanto entradas técnicas como fundamentais de um ou mais mercados. As entradas técnicas correspondem a valores defasados ou indicadores calculados por meio da variável prevista. Como entradas fundamentais são consideradas variáveis econômicas que se acredite que possam influenciar a variável prevista (Kaastra e Boyd, 1996, p. 219).

---

28 Para Kaastra e Boyd (1996, p. 219), o bom entendimento das variáveis importantes para o mercado previsto é fator crítico para o sucesso no desenho da rede neural. Eles destacam que a razão para confiar nas redes neurais vem da sua capacidade de detectar relações complexas e não-lineares entre diversas variáveis.

Jones (1993) sugere o uso de algoritmos genéticos para o *design* de redes neurais. Guo e Uhrig (1992) indicam o emprego de algoritmos genéticos para a escolha do número de nódulos na camada de entrada. Para determinar o número de nódulos de entrada, bem como os tipos de dados utilizados, foi adotado um algoritmo genético, partindo de uma população dividida em três grupos de modelos, cada grupo com 2, 4 e 8 nódulos de entrada.

Os grupos são divididos por tipos de dados de entrada. Um dos grupos apresenta como dados de entrada apenas preços defasados. Outro grupo apresenta como dados de entrada apenas diferenças enquanto o terceiro grupo exibe tanto diferenças quanto valores defasados como valores de entrada²⁹.

Entre as operações recorrentes a um algoritmo genético estão o *crossover* e a mutação (Leung et al., 2003). Para definição do algoritmo é necessário determinar alguns parâmetros, tais como: critérios de seleção; critério e medidas de avaliação; limite de iterações e critério de parada

Como critério de seleção dos modelos foi utilizado o menor erro quadrático médio. Para o critério de seleção dos nódulos, tanto para o procedimento de *crossover* quanto de mutação, a medida adotada foi o peso absoluto médio de suas ligações com a camada seguinte, a primeira camada escondida. Por meio do processo de *crossover*, os quatro modelos com melhor desempenho preditivo são pareados entre si dando origem até dois modelos pela junção da metade dos nódulos³⁰ de cada modelo pareado. A mutação segue um processo não seletivo, para cada modelo, o nódulo com menor peso médio absoluto é substituído por uma variável binária indicando o vencimento de um contrato. Todo esse processo se repete até que uma dessas três condições sejam verificadas:

- (i) nenhum modelo novo é sugerido pelo processo;
- (ii) um mesmo modelo apresenta o melhor desempenho por três iterações seguidas;
- (iii) vinte iterações realizadas.

---

29 Para todos os modelos são definidas como duas o número de camadas escondidas. O número de nódulos escondidos é igual ao número de nódulos de entrada. A configuração das camadas foi pré-definida de maneira arbitrária de acordo com número de nódulos de entrada. Elas podem ser representadas pelos pares ordenados (1,1), (2,2) e (6,2), onde o primeiro número corresponde ao número de nódulos na primeira camada escondida e o segundo representa o número de nódulos na camada escondida seguinte.

30 São escolhidos os nódulos com as maiores médias absolutas de pesos em suas ligações.

A definição do número de nódulos de saída corresponde a um problema relativamente fácil e diretamente ligado ao problema em questão. Eles esclarecem que o número de nódulos de saída é usualmente definido de acordo com o horizonte de previsão. (Zhang et al., 1987, p. 45). Alternativamente pode-se empregar uma única saída e por ter iterações chega-se a previsão desejada. Para esse último caso pode ser necessária a previsão de outra variável.

Para o treinamento dos sistemas de redes neurais foi utilizado o algoritmo da retro propagação resiliente. Ele é descrito no trabalho de Riedmiller (1994). Entre as vantagens em relação ao algoritmo de retro propagação tradicional está um ajuste superior em termos de erros dentro da amostra utilizada. Vale ressaltar que sua execução tende a requerer mais etapas em relação ao algoritmo tradicional, o que acaba por se refletir em maior demanda de esforço computacional e tempo.

3.4. Combinação de Previsões

Uma alternativa ao uso de previsões individuais corresponde a combinação de duas ou mais previsões. Vários trabalhos indicam que previsões combinadas tendem a apresentar um desempenho superior quando comparadas a previsões utilizadas individualmente. Clemen (1989) afirma que os resultados sobre combinação de previsões têm sido virtualmente unânimes. Segundo o autor, os resultados unânimes sugerem que combinar múltiplas previsões culmina em maior acurácia de previsão. Para muitos estatísticos e homens de negócios a atitude típica ao se depararem com um conjunto de previsões é a de aceitar o melhor previsor, descartando todos os demais, todavia as previsões descartadas quase sempre trazem informações úteis e independentes (Bates e Granger, 1969).

Evidências a favor da combinação de previsões também são fornecidas pelos estudos de Makridakis et al. (1979, 1982, 1993, 2000), que apontam que até mesmo as combinações simples, isto é, a média simples fornecidas pelas previsões de modo geral se saem bem se comparadas as demais previsões. Deste modo, uma previsão obtida pela médias de todas as demais previsões será computada, e avaliada com as demais previsões individuais.

3.5. Avaliação e Classificação

Uma vez que o estudo tem como objetivo verificar se métodos mais complexos, como é o caso das redes neurais, superam métodos mais simples, como a suavização exponencial, usando como critério o desempenho fora da amostra para a previsão de preços do boi gordo, os critérios de avaliação cumprem função central no estudo. Resultados apresentados por Makridakis et al. (1982, 1993, 2000) sugerem que diferentes medidas conduzam a diferentes classificações. Entre as prováveis razões está a inexistência de uma característica única nos erros a ser ponderada e sim um conjunto delas, como persistência de *outliers* ou até mesmo direção dos erros. Sen (2001) argumenta que “cada abordagem avaliatória pode ser caracterizada segundo sua base informacional”, o que compreende não só as informações que determinada abordagem leva em consideração para traçar seus juízos, mas também aquelas que desconsidera no processo. Essa subseção apresenta as medidas de ajuste adotadas no trabalho, não deixando de comparar a base informacional de cada uma delas, elucidando características importantes levantadas e excluídas por cada uma delas.

3.5.1. Três medidas

Para esse estudo, três medidas de desempenho foram empregadas: (i) o Erro Quadrático Médio (EQM), (ii) o Erro Médio Absoluto (EMA) e (iii) a Taxa de Acerto. O leitor deve entender erro individual de previsão no período t , com horizonte h , como sendo:

$$e_{t,h} = p_t - p_{t,t-h}^* \quad (3.5.1)$$

Onde p_t indica preço observado no período t e $p_{t,t-h}^*$ a previsão do modelo para o período t , realizada h períodos antes. A partir da definição do erro individual é possível definir as medidas de desempenho que serão empregadas. Dentre as três enumeradas no parágrafo anterior, a primeira é provavelmente a mais difundida, podendo ser expressa por:

$$EQM = \frac{1}{n} \sum_{t=0}^n e_{t,h}^2 \quad (3.5.2)$$

Em que n representa o número de observações. Alternativamente, o Erro Médio Absoluto (EMA) é dado pela form. (3.5.3):

$$EBM = \frac{1}{n} \sum_{t=0}^n |e_{t,h}| \quad (3.5.3)$$

Ambas as medidas (EQM e EMA) levam em consideração a distância entre a previsão dada pelo modelo e resultado observado, cada uma delas ponderando de modo simétrico desvios para cima e para baixo, isto é, para ambas as medidas erros opostos acrescentam montantes equivalentes ao computo total da medida de desempenho. Neste tocante, ambas medidas apresentam bases informacionais semelhantes, a distinção entre as duas todavia se dá no modo como ponderam os erros na medida em que estes se ampliam. Enquanto para o EMA a ponderação do erro se dá de forma linear à medida que o erro se distancia da origem, para o EQM essa ponderação cresce de maneira exponencial. A Figura 3.5.1 compara um erro individual ponderado pelo EMA e EQM.

Figura 3.5.1. Ponderação do erro individual pelo Erro Quadrático Médio e Erro Médio Absoluto.

Elaboração própria.

Um erro individual situado no intervalo entre menos um e um será mais duramente ponderado pelo EMA, com exceção do erro zero, que é igualmente ponderado. São igualmente ponderados também os erros equivalentes as menos um e um, para os demais erros o EQM pondera com maior rigor. A partir da mesma figura também é possível notar a equivalência entre os erros opostos. Enquanto essas medidas levam em consideração primordialmente a distância entre a estimativa e o observado, sem, no entanto, distinguir quanto ao sentido, a TA leva em consideração somente o sentido da estimativa frente ao observado, computando a porcentagem de realizações em que a variação estimada percorreu o mesmo sentido que a de fato observada, podendo ser expressa por:

$$TA = \frac{NA}{n} \quad (3.5.4.1)$$

$$NA = \sum_{t=0}^n A_t \quad (3.5.4.2)$$

$$A_t = \begin{cases} 1 & \text{se } \begin{cases} \Delta p_t = \Delta p_{t,t-h}^* = 0 \\ \Delta p_t > 0 \text{ e } \Delta p_{t,t-h}^* > 0 \\ \Delta p_t < 0 \text{ e } \Delta p_{t,t-h}^* < 0 \end{cases} \\ 0 & \text{caso contrário} \end{cases} \quad (3.5.4.3)$$

Na eq. (3.5.4.1) NA representa o número de estimativas que variaram no mesmo sentido em relação a variável prevista. Diferente do que ocorre com o EQM e EMA, a TA não leva em consideração o tamanho do erro, apenas os respectivos sentidos da variação indicados pela variável prevista e estimativa. Para sintetizar é possível descrever tanto a EQM e EMA como medidas de distância em relação à origem, e a TA como uma medida de direção. Como medidas de distância ambas tratam os erros de maneira simétrica, isto é, erros opostos em relação à origem somam montantes equivalentes no computo final – equivalência dos erros opostos. A diferença é que, enquanto para o EMA, os erros acrescentam somas lineares à medida que se distanciam da origem, para o EQM essas somas crescem de maneira exponencial, de modo que ambas ponderam de forma distinta erros cada vez menores.

3.5.2. Pós-partida

Jornalistas e comentaristas esportivos usualmente tecem uma série de previsões e convicções a respeito do time A ou B³¹ no início da temporada, para no decorrer da mesma, entre outras coisas, assinalar seus acertos ou então manifestar indignação e até mesmo surpresa vindas dessas equipes. Neste estudo que busca comparar as previsões de preços da arroba do boi gordo, o equivalente as convicções e previsões estabelecidas no pré-temporada são fornecidas pelas medidas dentro da amostra, os resultados das partidas no decorrer da temporada servem de metáfora para os resultados fora da amostra. Dito isso, é relevante então para cada método adotado comparar seu desempenho dentro da amostra contra seu desempenho fora. Esta comparação tem como objetivo sugerir padrões e relações entre os desempenhos dos modelos preditivos para dados já incluídos no ajuste e dados desconhecidos pelo processo.

Essa comparação se dará visualmente, com gráficos distintos para cada medida de desempenho, reunindo todos os modelos de previsão estudados em uma dispersão de pontos em que o eixo vertical dispõe os erros fora da amostra, enquanto o eixo horizontal representa os erros para as medidas dentro da amostra. Uma linha que acompanha reta cruzando a origem do gráfico e com inclinação igual a um – linha de consistência – servirá de referência. Ela recebe esse nome pois ela iguala os desempenhos dentro e fora da amostra, portanto, os modelos que dela se mais se aproximarem apresentaram um desempenho dentro e fora da amostra similares. A intuição sugere que a maioria dos modelos deve se apresentar acima da linha, isto é, o desempenho se mostre mais acurado para os dados utilizados em seu ajuste em comparação ao desempenho em relação a dados não empregados. Para os modelos abaixo dessa linha fica implícito um ajuste melhor para os dados não utilizados em seu ajuste. Isso pode acontecer por dois motivos distintos, ou uma combinação deles: (i) o padrão captado pelo modelo se reforçou no período designado como fora da amostra; (ii) coincidência.

Essa comparação não tem como objetivo apontar razões, tão pouco traçar conclusões a serem tratadas como definitivas, ambiciona tão somente complementar

---

³¹ Tetlock e Gardner (2016) lembra que nem sempre a finalidade de uma previsão é ser precisa. Muitas vezes a finalidade de uma previsão é convencer ou até mesmo agradar um determinado público alvo.

a análise, adicionando sugestões e questionamentos. Vale ressaltar ainda que cada modelo será ajustado empregando alguma medida de erro, por exemplo, enquanto a suavização exponencial leva em conta os erros quadráticos, as redes neurais são calibradas levando em consideração uma medida conhecida como entropia cruzada. Essa seção apresentou as medidas de ajuste utilizadas para a classificação e comparação do desempenho dos modelos de previsão, salientando aspectos relevantes atribuídas a cada uma delas sobretudo em relação a sua base informacional, sem atribuir a nenhuma delas a alcunha de melhor em relação as demais. A próxima seção apresenta os dados, tecendo uma breve análise descritiva e apresentando o tratamento dado aos dados faltantes.

3.6. Dados

Para o estudo foram selecionados dados diários, uma vez que a literatura carece de estudos adotando essa periodicidade. Ademais, essa abordagem também confere duas vantagens, uma do ponto de vista operacional, uma vez que será possível obter previsões para um determinado dia de operação no mês no lugar de apenas uma como ocorreria nas tradicionais abordagens mensais, outra vantagem está relacionada ao maior número de observações que conferem as estimativas maior credibilidade, sobretudo no que diz respeito às estimativas de desempenho fora da amostra além de viabilizar o uso de defasagens e diferenças mais longas.

Os dados do preço da @ do boi gordo corresponderam aqueles levantados pelo CEPEA-ESALQ. A série completa tem início no dia 3 de janeiro de 2011, indo até 30 de dezembro de 2015, contando um total de 1245 observações antes de qualquer defasagem e diferença. Além do preço da @ do boi gordo no mercado físico, a cotação média da @ do boi gordo no mercado futuro BM&FBovespa também foi utilizada, para este, foram empregadas series com a primeira e segunda ordem de vencimento fixadas. Ainda em relação ao mercado futuro BM&FBovespa, a cotação do câmbio futuro foi utilizada.

Muito embora a amostra total conte com um total de 1493 observações, apenas algumas foram utilizadas para ajuste. Para amostra total foi utilizado um esquema do tipo A-B-C, isto é, a amostra foi dividida em 3 partes, as partes A e B correspondem as parcelas de ajuste dos modelos de previsão, já a parcela C corresponde a parte de teste por meio da qual o desempenho dos modelos de

previsão fora da amostra serão auferidos. A única distinção que se faz entre a parte A e B, se dá durante a fase de arquitetura e seleção prévia dos modelos RNA, unicamente nessa fase, os modelos RNA são ajustados usando a amostra A e previamente classificados usando a amostra B, em acordo com o algoritmo genético especificado na seção anterior. Os modelos selecionados são então ajustados novamente de modo que a classificação definitiva fica a cargo da amostra C. A amostra A se estende entre os anos 2011 e 2012, contando com um total de 498 observações, a amostra B contém os dados de 2013, somando 250 observações, enquanto o restante da amostra compreende os anos de 2014 e 2015, com um total de 497 observações.

A evolução dos preços da @ do boi gordo em nível está disposta na Figura 3.6.1. A mesma figura sinaliza o esquema de amostras empregado, a área anterior à linha azul vertical pontilhada representa a amostra A, a área compreendida entre a linha pontilhada azul e a linha cheia verde indica a amostra B, e a área posterior à linha verde representa a amostra C. A evolução do preço dá uma ideia do desafio inerente a previsão de preços do boi gordo. A parcela A da amostra exibe uma tendência de queda, enquanto as parcelas B e C mostram uma tendência alista de preços.

Figura 3.6.1. Evolução diária do preço da @ do boi gordo CEPEA/ESALQ de 2011 a 2015.

Fonte: CEPEA/ESALQ.

Outra forma ainda de conceber o desafio proposto pela previsão pode ser obtida da série nas diferenças, adotando as defasagens respectivas a cada horizonte de previsão proposto, isto é, as oscilações de preços exibidas respectivamente durante 5, 20 e 60 dias de negócios. A Figura 3.6.2 Exibe conjuntamente essas oscilações.

Figura 3.6.2. Oscilações nos preços da @ do boi gordo CEPEA/ESALQ para 5, 20 e 60 dias de negócios.

Fonte: CEPEA/ESALQ.

Também sinalizando as divisões amostrais de modo semelhante à figura anterior, a Figura 3.6.2 mostra a oscilação dos preços de acordo com os horizontes de previsão adotados. A linha preta compreende as oscilações exibidas no decorrer de 5 dias de negócios, já as linha laranja e vermelha apresentam respectivamente as oscilações observadas ao longo de 20 e 60 dias de negócios. Uma vez que a variável prevista só apresenta valores em dias úteis, isto é, dias de semana excluídos feriados, esses horizontes podem ser aproximados respectivamente para uma semana, quatro semanas (ou um mês) ou então doze semanas (ou três meses). Todas essas variáveis parecem seguir uma mesma tendência, a única diferença fica a cargo da variância, uma vez que as diferenças de defasagem mais longa tendem a exibir oscilações mais abruptas em torno da tendência. A Tabela 3.6.1 traz as estatísticas descritivas segmentadas por amostras para os preços em nível e nas três diferenças.

Tabela 3.6.1. Estatísticas descritivas da série prevista.

	Preço da arroba do boi gordo (R\$/@)				
	Forma	Nível	Diferença	Diferença	Diferença
Amostra (anos)	Defasagem	-	5	20	60
A (2011 e 2012)	Mínimo	R\$ 88,71	-R\$ 4,30	-R\$ 9,49	-R\$ 13,14
	Máximo	R\$ 109,60	R\$ 4,73	R\$ 10,19	R\$ 9,39
	Média*	98,2838	-0,0698	-0,2823	-1,0653
	Variância*	20,0193	1,5142	9,7712	20,8929
B (2013)	Mínimo	R\$ 97,02	-R\$ 2,11	-R\$ 3,27	-R\$ 1,14
	Máximo	R\$ 114,79	R\$ 2,69	R\$ 7,11	R\$ 8,36
	Média*	102,6388	0,3599	1,3062	3,2422
	Variância*	25,9463	0,8056	6,1380	6,4872
C (2014 e 2015)	Mínimo	R\$ 112,64	-R\$ 3,50	-R\$ 6,47	-R\$ 9,48
	Máximo	R\$ 150,65	R\$ 4,31	R\$ 11,37	R\$ 19,23
	Média*	135,7944	0,3399	1,3769	4,5497
	Variância*	136,4267	1,8387	12,7503	45,9623
TOTAL (2011 a 2015)	Mínimo	R\$ 88,71	-R\$ 4,30	-R\$ 9,49	-R\$ 13,14
	Máximo	R\$ 150,65	R\$ 4,73	R\$ 11,37	R\$ 19,23
	Média*	114,3240	0,1811	0,7151	2,1984
	Variância*	382,5680	1,5408	10,8611	34,8213

Elaboração própria.

* Valores aproximados para quatro casas decimais.

Analisando as estatísticas descritivas dispostas na Tabela 3.6.1, fica evidente a tendência baixista de preços alocados na amostra A, que apresenta variação média negativa, em oposição a tendência altista das demais amostras, que apresentam oscilações médias positivas. Outro aspecto importante diz respeito à variância, que apresenta uma tendência de crescimento conforme crescem as defasagens das diferenças. Muito embora a variância cresça em razão mais do que proporcional aos horizontes de oscilação, no tocado do desvio padrão ela evolui em razão menos do que proporcional. A crescente variância dá uma sugestão do desafio imposto pelo crescente horizonte de previsão. Vale ressaltar que o número de observações varia entre as diferentes séries para as amostra completa e A, devido o emprego de diferentes formas e defasagens.

Outro aspecto importante da atividade pecuária paulista do tipo extensiva, com reflexos no preço, diz respeito as variações estacionais que ocorrem dentro de

um mesmo ano, em decorrência da sazonalidade da produção de forrageira, associadas à entrada do período das águas (setembro-outubro) e entrada do período seco (abril-maio). No primeiro caso os produtores retêm o gado, na expectativa de engorda, reduzindo a oferta, enquanto no segundo os produtores se desfazem do gado para evitar perdas de peso, ampliando a oferta (Kassouf 1988, p.3).

Figura 3.6.3. Diagrama de caixa para as oscilações de cinco dias úteis nos preços da arroba do boi gordo CEPEA/ESALQ de janeiro de 2011 a dezembro de 2015.

Elaboração própria.

É de se esperar que esses movimentos impactem de alguma forma a série de preços. A Figura 3.6.3 traz os diagramas de caixa para as oscilações de cinco dias úteis de preços, agrupadas por mês. Os meses de abril e maio, associados ao período de secas, recebe destaque na cor vermelha, enquanto os meses de águas, associados ao período de águas, recebe destaque na coloração azulada. A linha pontilhada horizontal que percorre o diagrama indica oscilação nula. Vale destacar o mês de maio unicamente exibiu seu terceiro quartil abaixo dessa mesma linha, o que equivale afirmar que para todo o período analisado, ao menos 75% das oscilações compreendidas nesse mês foram negativas, evidência favorável a variação

estacional anual. As caixas correspondentes aos meses de setembro e outubro também aparentam estar dispostas em patamares superiores aqueles apresentados por demais meses.

Outras séries utilizadas no estudo, que podem contribuir na análise das variações estacionais, correspondem às cotações médias diárias de vencimento fixado (primeiro e segundo) da BM&FBovespa entre os dias 3 de janeiro de 2011 e 30 de dezembro de 2015. A evolução dessas duas séries está disposta na Figura 3.6.4, sendo a série com o primeiro vencimento fixada na cor preta e a série de segundo vencimento fixada na cor vermelha. A título de comparação, o preço no mercado físico também foi disposto no gráfico representado pela coloração amarela.

Figura 3.6.4. Evolução diária da cotação da arroba do boi gordo futuro (BM&FBovespa) e físico (CEPEA/ESALQ), 2011-2015.

Fonte: BM&FBovespa e CEPEA/ESALQ.

Vale ressaltar que a mesma sinalização, indicando as separações amostrais estão indicadas na Figura 3.6.4 e que apenas dias com um ou mais negócios realizados foram contabilizados na série. Ambos os contratos seguem uma trajetória semelhante, ora liderada pelo primeiro vencimento, ora liderada pelo segundo

vencimento. Também disposto na Figura 3.6.4 o preço físico aparenta se manter próximo as cotações futuro. A redução do contrato com segundo vencimento pelo primeiro vencimento pode ser interpretado como oscilação de preço esperada para o mês seguinte, isto é, a expectativa de variação de preços para o próximo mês. A Figura 3.6.5 traz essa variável na forma de diagrama de caixa, agrupada por mês. É importante lembrar que cada mês representa a expectativa de oscilação de preços para o mês seguinte, derivada por meio do mercado futuro, logo, a expectativa de variações para o mês das águas (setembro-outubro) é formada pelas caixas de agosto e setembro, enquanto a expectativa para os meses de seca é dada pelos diagramas dispostos março-abril, no lugar de abril-maio.

Figura 3.6.5. Diagrama de caixa da diferença entre as cotações médias diárias da @ do boi gordo futuro BM&FBovespa de primeiro e segundo vencimento entre 2011 e 2015.

Elaboração própria.

* Segundo vencimento diminuído o primeiro vencimento.

** Expectativa para os meses de entrada da seca e águas.

Diferente do observado na Figura 3.6.3, neste diagrama um número maior de caixas está sob ou sobre a linha pontilhada, ou seja, para um número maior de meses ao menos 75% das observações apontaram uma “expectativa” só de

aumento ou queda dos preços no mês seguinte. Todavia vale lembrar que a Figura 3.6.3 usou dados do mercado físico, representando oscilações ocorridas em um intervalo de cinco dias úteis, enquanto a Figura 3.6.5 usa dados do mercado futuro, podendo ser interpretado como uma expectativa de variação nos preços para o total de um mês. Sem deixar de lado as características salientadas, a Figura 3.6.5 exhibe mais claramente uma expectativa de queda nos preços para os meses de entrada da seca e alta para os meses de entrada das águas, com destaque para a expectativa referente ao mês de setembro (formada em agosto), que apresenta aproximadamente 99% das observações indicando uma expectativa de alta nos preços do mês seguinte.

Ainda obtidas dos mercados futuros, outra variável considerada no estudo corresponde à cotação média diária do dólar futuro BM&FBovespa, medida em mil dólares por real (US\$D 1.000,00 / R\$). A série tem início no dia 3 de janeiro de 2011, com final no dia 30 de dezembro de 2015. Somente dias em que de fato ocorreram negócios foram considerados e a série construída correspondeu à série fixada o vencimento mais recente. A Figura 3.6.6 exhibe a evolução da cotação durante o período analisado.

Figura 3.6.6. Evolução da cotação média diária do dólar futuro (US\$D 1.000,00/R\$) BM&FBovespa da série com primeiro vencimento entre os dias 3 de janeiro de 2011 e 30 de dezembro de 2015.

Fonte: BM&FBovespa.

Ao longo da Figura 3.6.6 a cotação do dólar exibe uma tendência de alta, com movimentos mais explosivos a partir do ano de 2015. Outra forma de visualizar a evolução da cotação do dólar é empregar a série nas diferenças. A Figura 3.6.7 traz a evolução da cotação média do dólar futuro BM&FBovespa em sua primeira diferença, fixado o primeiro vencimento. As observações têm início no dia 3 de janeiro de 2011, indo até o dia 30 de dezembro de 2015.

Figura 3.6.7. Evolução da cotação média diária do dólar futuro (US\$D 1.000,00 / R\$) BM&FBovespa na diferença, série fixada o primeiro vencimento entre os dias 3 de janeiro de 2011 e 30 de dezembro de 2015.

Fonte: BM&FBovespa.

Os movimentos da série na diferença sugerem uma variância oscilante ao longo da série. A variância da série parece ampliar a partir do final de 2014. Já seus menores valores parecem se situar nos períodos próximos ao início de 2013. Diferente dos demais dados apresentados até agora, a cotação do dólar futuro BM&FBovespa é exclusivamente adotada pelos modelos de redes neurais. A partir desses dados outros dados foram derivados para o *desígn* e ajuste dos modelos de redes neurais. Estes são: binárias indicando meses de águas e secas, binárias indicando primeiro e segundo semestre, variável inteira indicando o número de aumentos sucessivos nos preços físicos, variável inteira indicando o número de quedas sucessivas nos preços físicos.

Outro aspecto importante dos dados diz respeito a disparidade de observações entre a série de preços CEPEA e os demais dados, em outras palavras, dados faltantes. Os dados podem ser segmentados pela característica do mercado do qual faz parte, isto é, físico ou futuro. Os dados do mercado físico são representados pelo indicador CEPEA, enquanto as séries de preços futuros são dados pelos preços do boi gordo (primeiro e segundo vencimento fixados) e dólar

futuro BM&FBovespa. Para o mesmo período, a série dada pelo indicador CEPEA compreende um número maior de observações. Isto acontece pois a bolsa de mercadoria futuros obedece feriados que não necessariamente afetam os dados disponibilizados pelo CEPEA e também por que a série futuro considera apenas dias em que ao menos um contrato tenha sido negociado. Ambos os motivos são fontes de disparidade entre o número de observações. Uma alternativa foi adotada para conciliar o número de dados. Tendo em vista o paradigma de previsão os dados faltantes foram substituídos pela última observação disponível. São duas as justificativas para a reposição dos dados faltantes. Em primeiro lugar a adoção do último valor conhecido mantém fora da análise observações “vindas do futuro” diferente do que ocorreria caso a solução envolvesse a média das observações compreendidas entre os dados faltantes. Em um contexto real de previsão, caso um modelo se baseie em dados do mercado futuro, é impossível para o previsor antecipar um valor inexistente e desconhecido pela média de um valor já conhecido e outro que se deseja prever (ainda desconhecido e objetivo de sua atividade). A outra justificativa é da manutenção do número de observações. Deste modo, o desempenho fora da amostra, principal medida analisada no estudo, dos diferentes modelos de previsão serão considerados usando o mesmo número de observações.

Para o período que compreende o estudo, nenhuma observação falta quando se trata do indicador CEPEA. Já por motivos já anteriormente expostos, 12 observações faltam para o contrato futuro com primeiro vencimento, 32 para o contrato com segundo vencimento e 9 observações para o dólar futuro com primeiro vencimento. Para mais informações sobre dados faltantes e substituições consulte o Apêndice A. Essa seção encerra o capítulo responsável por tratar das metodologias e dados utilizados no trabalho. O próximo capítulo cuida da análise e desenvolvimento das previsões.

4. RESULTADOS

Essa seção traz os resultados obtidos por meio dos modelos de previsão. Antes de auferir a comparação entre os diferentes modelos das diversas classes, as estimativas e resultados definidos são discriminados por cada classe abrangente de modelos (suavização exponencial, futuros e redes neurais) e discutidos entre si (comparação intra classes). Deste modo pretende-se investigar os padrões com que se desenham os resultados dentro e fora da amostra para cada classe individual e até mesmo verificar se determinada especificação descreve desempenhos extraordinários em relação as demais considerando os diversos horizontes de previsão (5, 20 e 60 dias úteis) e as variadas medias de ajuste (EQM, EMA e TA).

4.1. Suavização Exponencial

Dentre os modelos individuais previamente definidos, os de suavização exponencial são aqueles cuja constituição esboça menor complexidade. Ainda que o termo suavização exponencial descreva uma classe ampla de modelos, existem variações e algumas delas foram contempladas. A comparação intra classes visa salientar as diferentes características descritas por cada especificação dentre a classe bem como divergências em termo de desempenho.

Em se tratando dos modelos suavização exponencial, uma primeira distinção se dá em relação ao tipo de estimador: adaptativo ou estático. Partindo dessa distinção três abordagens similares foram empregadas para estimar cada uma delas, o que acabaria por totalizar seis modelos. Essas abordagens foram classificadas como tradicional, defasagens simétricas e defasagem mais atual, dizendo respeito sobretudo a forma como as previsões para diferentes horizontes foram obtidas.

Modelos obtidos pela abordagem tradicional foram ajustados para o horizonte de previsão do dia seguinte, a partir deste horizonte os demais foram obtidos de modo recursivo, isto é, previsões obtidas de previsões. Já as abordagens defasadas foram ajustadas especificamente para cada horizonte de previsão. O ajuste de defasagem simétrica leva em consideração apenas informações com defasagens equiparadas ao horizonte de previsão enquanto a defasagem mais atual considera as informações mais atuais disponíveis dado o horizonte de previsão específico (h). A defasagem simétrica considera o erro h períodos antes e a previsão

h períodos antes para formar sua previsão, já a defasagem mais atual considera o erro h períodos antes e a previsão apenas 1 período antes, para este último, considerando um contexto da previsão realista, ainda que seu erro fosse desconhecido o valor da previsão já fora revelada.

Como consequência direta da forma com que os modelos tradicionais foram estimados, apenas um horizonte de previsão foi ajustado. Isto se traduz em um único parâmetro (*delta*) estimado para o caso do modelo estático e dois parâmetros (*beta* e *gama*) para o caso dinâmico, responsáveis pelas previsões para quaisquer horizontes. A Tabela 4.1.1 sintetiza os resultados dos parâmetros para cada modelo obtidos usando apenas a amostra de ajuste.

Tabela 4.1.1. Estimativas dos parâmetros para os modelos de suavização exponencial usando a abordagem tradicional e dados diários de janeiro de 2011 à dezembro de 2013.

	delta (δ)*	beta (β)*	gama (γ)*
Modelo estático	0,129843	..	..
Modelo adaptativo	..	1,40171	0,646935

Fonte: resultados da pesquisa.

* Valores arredondados para seis casas decimais.

Em contraparte, os modelos de defasagens são calibrados especificamente para os horizontes de previsão previamente designados. Isto quer dizer que cada abordagem (simétrica ou atual) conta com três parâmetros estimados para o caso estático, um para cada horizonte investigado, ou então seis para o caso dinâmico, dois para cada horizonte. A Tabela 4.1.2 sumariza esses resultados.

Tabela 4.1.2. Estimativas dos parâmetros para os modelos de suavização exponencial usando a abordagem defasada e dados diários de janeiro de 2011 à dezembro de 2013.

Tipo de defasagem		delta (δ)*	beta (β)*	gama (γ)*
Horizonte = 5 (dias úteis)				
simétrica	modelo estático	0,046143	..	..
	modelo adaptativo	..	2,262762	0,503292
atual	modelo estático	0,007533	..	..
	modelo adaptativo	..	0,414939	5,3885
Horizonte = 20 (dias úteis)				
simétrica	modelo estático	0,091007	..	..
	modelo adaptativo	..	2,301407	0
atual	modelo estático	0,007972	..	..
	modelo adaptativo	..	0	2,23897
Horizonte = 60 (dias úteis)				
simétrica	modelo estático	0,38148	..	..
	modelo adaptativo	..	0	0,063785
atual	modelo estático	0,006617	..	..
	modelo adaptativo	..	1,42791	0,647627

Fonte: resultados da pesquisa.

*Valores arredondados para seis casas decimais.

Com a finalidade de facilitar a identificação e distinção dos modelos um sistema de nomenclatura alfabético foi adotado. As letras são dispostas de forma a sinalizar respectivamente a classe pertencente, a abordagem de estimação, o tipo de estimador calculado e por fim o tipo de defasagem empregada de cada especificação. A última sigla está presente somente nas previsões que seguem a abordagem aqui denominada como defasada. Assim os modelos de abordagem tradicional são representado por uma sequência de três letras, já os modelos cuja abordagem é a defasada são representados por uma sequência de quatro letras.

A primeira letra diz respeito a classe dos modelos e equivale ao S (suavização exponencial) para todos eles. A letra seguinte se refere ao tipo de abordagem empregada para obtenção das previsões, variando entre T (tradicional) e D (defasada). Para a terceira posição a letra designa o tipo de estimador construído, E (estático) ou A (adaptativo). Por último, apenas para os modelos de abordagem defasada, a quarta letra representa o tipo de defasagem adotada. Para essa posição, a letra S (simétrica) sinaliza que apenas defasagem equivalentes ao horizonte de previsão foram empregadas, já a letra A (atualizada) indica que a defasagem mais atual disponível dado o horizonte pertinente do problema de

previsão foi usado. A Figura 4.1.1 usa um diagrama de árvore para demonstrar os diferentes dispositivos presentes nas diferentes especificações e suas respectivas nomenclaturas, as bifurcações indicam escolhas entre dispositivos alternativos e as folhas apresentam o nome dado a cada especificação junto de um escala arbitrária de complexidade.

Figura 4.1.1. Diagrama de Árvore: nomenclatura adotada pelos modelos de suavização exponencial.

Fonte: elaboração própria.

A Figura 4.1.1 demonstra como são nomeados os modelos à medida que são atribuídas as características pertinentes à abordagem, estimador e para alguns casos o defazor. A totalidade das seis variações de especificações são contempladas. Ao final de cada folha do diagrama de árvore estão dispostos as

nomenclaturas recebidas por cada especificação mais uma pontuação arbitrária designando complexidade relativa as demais especificações entre parênteses, o modelo que emprega abordagem defasada, com estimador adaptativo e defasagem atualizada recebe a sigla de SDAA (6). O sistema arbitrário de pontuações é capaz de criar um ordenamento em termos de complexidade entre as especificações. As abordagens defasadas somam três pontos, parâmetros adaptativos somam mais dois e defasagens atualizadas adicionam mais um, as demais especificações não somam pontos. A pontuação mínima corresponde a zero e a máxima a seis, maiores as pontuações, maior a complexidade atribuída. Vale ressaltar que está é uma escala arbitrária.

Por meio da Figura 4.1.2 é possível averiguar como os modelos se comportaram dentro e fora da amostra para as diferentes especificações e ao longo dos diferentes horizontes de previsão de acordo com o EQM. Para cada modelo foi atribuído uma combinação única de cor e formato. Além disso, a escala arbitrária de complexidade anteriormente apresentada também é contemplada pelo número dentro de cada símbolo. Uma vez que cada modelo recebeu uma pontuação distinta também é possível referenciá-los se baseando nessa escala apenas. Para cada horizonte de previsão os símbolos foram empilhados do pior classificado (mais abaixo e com maior EQM) até o melhor classificado (mais acima e com menor EQM), abaixo de cada símbolo está a medida do EQM auferido para determinado horizonte e delimitação amostral arredondados até a quarta casa decimal. As colunas ímpares indicam o desempenho medido dentro da amostra para determinado horizonte de previsão enquanto as colunas imediatamente seguintes indicam o desempenho fora da amostra para o mesmo horizonte de previsão (em relação a coluna anterior). Desta forma é possível acompanhar como os modelos se saem dentro e fora da amostra e também como se saem para diferentes horizontes de previsão. O quanto uma coluna ímpar se parece com a seguinte sugere quão preciso é a classificação dada dentro da amostra para prever a classificação e desempenho fora dela.

Figura 4.1.2. Erro quadrático médio das diferentes especificações de suavização exponencial dentro e fora da amostra para os diferentes horizontes.

Fonte: resultados da pesquisa.

Adotando o EQM como medida de referência, o melhor desempenho fora da amostra é desenhado pela especificação SDAA para os horizontes de 20 e 60 dias úteis. A especificação SDAS consistentemente ocupa o segundo lugar dentro e fora da amostra, com exceção com o desempenho dentro da amostra para o horizonte de 5 dias. Ademais, a classificação dentro da amostra não anuncia com exatidão a classificação fora dela, muito embora a classificação de alguns modelos se repita dentro e fora da amostra. Mas o que acontece quando adotamos uma nova medida de desempenho? A Figura 4.1.3 reproduz os resultados da Figure 4.1.2 usando como medida de referência o EMA.

Figura 4.1.3. Erro médio absoluto das diferentes especificações de suavização exponencial dentro e fora da amostra para os diferentes horizontes.

Fonte: resultados da pesquisa.

Também de acordo com a Figura 4.1.3, a tendência das especificações elencados previamente como duas mais complexos (SDAA e SDAS) dominarem os ajustes para horizontes mais alongados enquanto o mais simples (STE) lidera o ajuste com horizonte de cinco dias úteis persiste ao menos no que tange os desempenhos fora da amostra. A classificação fora da amostra também não representou com exatidão a mesma dentro dela. Outra medida adotada foi a TA, seus resultados são relatados pela Figura 4.1.4.

Figura 4.1.4. Taxa de acerto das diferentes especificações de suavização exponencial dentro e fora da amostra para os diferentes horizontes.

Fonte: resultados da pesquisa.

Com respeito a TA, a tendência antes mantida tanto pelo EQM quanto pelo EMA se altera. O modelo ostentando seis pontos na escala de complexidade arbitrariamente definida só figura como primeiro colocado dentro da amostra para o horizonte de sessenta dias úteis. Ademais, contrariando em alguma medida a intuição a medida de desempenho fora da amostra para o horizonte mais largo (60 dias úteis) foi o que apresentou melhor ajuste. Uma série de classificações dentro da amostra se repetem também fora dela, garantindo relativa consistência ao seu desempenho.

Nenhuma especificação se mostrou absolutamente superior em relação as demais levando em conta a diversidade de medidas de desempenho e horizontes de previsão. De maneira geral a classificação fora da amostra não sugeriu de maneira

precisa a classificação fora dela para um mesmo horizonte preditivo. Outra constatação, essa restrita a as medidas de EQM e EMA é a de degradação dos valores ajustados, essa degradação se dá de duas formas, quando se analisa os crescentes horizontes de previsão as medidas de ajuste pioram e também dentro de um mesmo horizonte essa medida se degrada do ajuste dentro para o ajuste fora da amostra. A próxima seção traz análise semelhante voltada para os modelos derivados dos mercados futuros.

4.2. Mercados Futuros

Contando também com seis especificações distintas, as questões levantadas quando se trata da utilização dos modelos baseados nos mercados futuros diferem um tanto daquelas levantadas na seção anterior. Não se trata somente de elencar complexidades arbitrárias ao confrontar os desempenhos, mas também de discernir quais vencimentos fixados representam previsores mais acurados para os respectivos horizontes.

Dito isso, as dimensões capazes de distinguir as especificações adotadas entre modelos de mercados futuros podem perfeitamente serem descritas como duas: a dimensão dos estimadores, posteriormente traduzida em uma escala arbitrária de complexidades; e a dimensão das ordens de vencimento, aqui acolhidas como primeira e segunda pela liquidez desenvolva.

A dimensão das estimativas recepciona três variações. Começando pelo estimador “inocente”, que considera simplesmente a última observação disponível da série para o horizonte estabelecido como a previsão em si. Essa abordagem exige a necessidade de ajuste, conferindo distinta simplicidade a especificação.

Alternativamente, a estimativa seguinte equivale à anterior subtraídos os vieses mensais dos erros. O viés mensal dos erros é obtido da média condicional dos erros em relação aos meses em que essas previsões do estimador anterior foram cunhadas. Em alguma medida essa abordagem busca capturar uma possível sazonalidade no viés. As médias junto das estimativas de p-valor se encontram-se no apêndice B.

Outra estimativa analisada usa aquelas descritas no parágrafo anterior para calcular o viés. Essas estimativas são obtidas por meio da regressão dos erros desses modelos contra o horizonte real de previsão medido em dias úteis, dado pela

diferença em entre o dia em que a observação fora obtida e o vencimento do respectivo contrato adotado. Esse estimador encerra o rol relativo a dimensão dos estimadores. A essa dimensão é possível atribuir uma escala arbitrária de complexidade. Atribuindo números inteiros a cada estimativa o primeiro dos estimadores é representado pelo número um, o seguinte por dois e este último por três, essa numeração é diretamente proporcional a escala de complexidade arbitrariamente atribuída a essas distinções entre estimadores.

Ademais, tem se a dimensão das ordens de vencimento. Duas séries de preços futuros foram adotadas e separadamente aplicadas no ajuste das diferentes estimativas. Essas correspondem as séries com o primeiro e segundo vencimento fixados. Dessa forma a segunda dimensão procura investiga se algum desses contratos trazem informações mais relevantes quando se trata de prever os preços do mercado físico para determinados horizontes. Diferente do que ocorre com a dimensão das estimativas, não é razoável estabelecer uma escala arbitrária de complexidade, contudo ainda é possível referenciá-los com base na ordem de vencimento do contrato utilizado, o que conduz a taxonomia adotada.

Para referenciar os modelos foi adotado um sistema de dois algarismos inteiros separados por um traço, onde o primeiro algarismo alude o tipo de estimativa adotada para formular a previsão e o segundo indica a ordem de vencimento do contrato empregado para calibrar o modelo. A Tabela 4.2.1 descreve a taxonomia recebida por cada modelo junto de seus dispositivos.

Tabela 4.2.1. Taxonomia, estimadores e ordem de vencimento das especificações derivadas a partir dos dados do mercado futuro.

Nomenclatura “(A-B)”	Estimador	Ordem de vencimento
	A = 1,2 ou 3	B = 1 ou 2
1-1	Inocente	Primeiro
1-2	Inocente	Segundo
2-1	Ajustado pelo viés mensal	Primeiro
2-2	Ajustado pelo viés mensal	Segundo
3-1	Ajustado pelo viés mensal e horizonte real de previsão	Primeiro
3-2	Ajustado pelo viés mensal e horizonte real de previsão	Segundo

Elaboração própria.

A taxonomia adotada facilita o exame de duas questões relacionadas aos modelos baseados em preços futuros: (i) existe relação entre os estimadores e o desempenho dentro e fora da amostra?; (ii) algum dos vencimentos representa um previsor mais adequado levando em conta os horizontes específicos? Essas questões serão verificadas para as diferentes medidas de ajuste e os resultados individuais de cada medida de ajuste serão então comparados entre si.

A Figura 4.2.1 compara o desempenho dos diversos modelos, para os horizontes de previsão de 5, 20 e 60 dias úteis para os ajustes dentro e fora da amostra. Cada cor representa uma ordem de vencimento e cada formato um tipo de estimativa. A cor verde é atribuída aos modelos ajustados pelos dados do primeiro vencimento e rosa ao segundo. Com respeito aos formatos, círculos representam estimadores “inocentes”, quadrados indicam estimativas ajustadas pelo viés mensal e triângulos indicam os estimadores ajustados para o viés mensal e regredidos contra o horizonte real de previsão dado pelo contrato usando. Cada especificação é então representada por uma combinação única de formato e cor, está por sua vez recepcionada pela taxonomia presente na Tabela 4.2.1 também representada dentro de cada ponto da Figura 4.2.1, dessa forma também é possível se orientar por meio destas. A medida de desempenho arredondada para a quarta casa decimal fica disposto logo abaixo de cada ponto e os pontos são empilhados de acordo com a classificação, pontos mais acima representam modelos melhores classificados de acordo com a medida utilizada.

Figura 4.2.1. Erro quadrático médio das diferentes especificações de modelos de mercados futuros dentro e fora da amostra para os diferentes horizontes.
Fonte: resultados da pesquisa.

Se tratando de EQM, exceto para horizonte mais curto, as medidas dentro da amostra não apontam com destreza o exato modelo mais bem colocado fora dela, ainda assim, ela aponta que os modelos ajustados pelas séries com primeiro vencimento se saem melhor em relação aqueles ajustados para o segundo vencimento, a não ser pelos modelos inocentes que para os horizontes de 20 e 60 dias úteis brigam pelas últimas colocações, independente da delimitação amostral (dentro ou fora) adotada. Se tratando do tipo de estimador, no geral os modelos de viés mensal e viés mensal regredido pelo horizonte real ajustados pela série de primeiro vencimento são os que figuram entre os primeiros colocados para cada uma das comparações realizadas.

Figura 4.2.2. Erro médio absoluto das diferentes especificações de modelos de mercados futuros dentro e fora da amostra para os diferentes horizontes.
Fonte: resultados da pesquisa.

Para a medida do EMA o cenário muda em algum montante, como é ilustrado pela Figura 4.2.2. Em média as séries de primeiro vencimento ajustam as melhores previsões, contudo para as previsões com horizontes de 60 dias úteis, a medida fora da amostra aponta as previsões ajustadas pela série de segundo vencimento fixado como melhores – exceção feita a especificação inocente que figura na última colocação. Ainda permanece a tendência dos estimadores 2 e 3 (viés mensal e viés mensal regredido contra horizonte real de previsão) em alternar entre a primeira colocação para as diferentes comparações.

De modo geral a diferença de desempenho entre os diferentes modelos para cada uma das medidas de ajuste tende a ser relativamente menor em relação aquela exibida pelos modelos de suavização exponencial. Enquanto a diferença em

termos de EQM entre o melhor e pior modelo fora da amostra para o horizonte de 60 dias úteis está em torno das centenas, para os modelos de mercados futuros não chega a atingir a cada das dezenas. Para essa mesma comparação o EMA difere em algumas unidades entre o pior e melhor modelo de suavização exponencial, já para os modelos de mercados futuros essa diferença é comportada pela casa decimal. Vale salientar que para as medidas analisadas até então a degeneração das mediadas de ajuste se verifica tanto no âmbito da comparação dentro e fora da amostra bem como no âmbito dos crescentes horizontes temporais. Uma única exceção se confirma para o modelo 1-2 no horizonte de previsão de 5 dias úteis levando em consideração o EMA seu ajuste é aprimorado na variação dentro-fora da amostra.

Figura 4.2.3. Taxa de acerto das diferentes especificações de modelos de mercados futuros dentro e fora da amostra para os diferentes horizontes.

Fonte: resultados da pesquisa.

A Figura 4.2.3 exibe um resultado análogo levando em consideração a taxa de acerto como medida de ajuste. A disposição dos pontos sugere certa dificuldade em se inferir a classificação ou desempenho fora da amostra exatos das especificações por meio de seu desempenho e classificação dentro dela. Um resultado que desafia a intuição é o desempenho superior obtido por alguns modelos para a medida fora da amostra em comparação com a mesma medida dentro da amostra, de outro modo, a degeneração dos resultados dentro-fora da amostra não se confirma para a maior parte das especificações. A especificação 1-2, ou seja, inocente baseada nos contratos com segundo vencimento, se saiu melhor ao prever o sentido da variação dos preços segundo a medida fora da amostra para o horizonte de 5 dias úteis, outro resultado contra intuitivo uma vez que os dados do primeiro vencimento são mais compatíveis³² com o horizonte de previsão. Esses resultados encerram aqueles obtidos por meio de modelos exclusivamente baseados em dados dos mercados futuros.

4.3. Redes neurais

As redes neurais correspondem a abordagem de maior complexidade quando comparada as demais exploradas neste estudo. A própria especificação dos modelos corresponde a um problema não trivial. Um algoritmo genético, com acesso limitado aos dados de ajuste, foi empregado para elaborar variadas especificações e eleger seis delas para o horizonte de previsão de cinco dias úteis. Posteriormente essas especificações foram estendidas e novamente calibradas para os demais horizontes. O algoritmo genético tem como finalidade sugerir quais variáveis são relevantes para a análise. As especificações de redes neurais para um mesmo horizonte de previsão distinguem entre si somente em relação ao número e tipos de variáveis de entrada. Foram adotadas duas camadas intermediárias com dois nódulos cada. A função de transformação correspondeu a tangente hiperbólica, com exceção do último nódulo (nódulo de saída), contemplado por uma função de

---

32 Quando implico maior compatibilidade refiro ao “horizonte verdadeiro” de previsão de determinado contrato. A diferença entre o dia de vencimento do contrato e o dia alvo da previsão são em média mais próximos de cinco para a série com primeiro vencimento em detrimento da série com segundo vencimento.

transformação linear. Para cada horizonte de previsão a variável de saída, portanto variável prevista, era a variação de preços nos últimos h períodos, h correspondendo ao horizonte de previsão.

Para a aplicação do algoritmo genético a amostra total utilizada não excedeu a amostra de ajuste empregada pelos demais modelos. Essa amostra foi então dividida em duas partes. A primeira, depois de realizadas as transformações (diferenças e defasagens) contou com 432 observações, com início no dia 7 de abril de 2011 indo até o dia 28 de dezembro de 2012. Esses dados foram empregados para ajustar os modelos ainda durante o emprego do algoritmo genético. Depois de ajustados os modelos foram testados na parte seguinte dessa amostra, que contou com 250 observações, começando partindo do dia 2 de janeiro de 2013 indo até o dia 30 de dezembro do mesmo ano. O algoritmo contou com uma população inicial de 13 modelos e foi terminado com 31 deles. A tabela 4.3.1 aponta as seis especificações selecionadas pelo processo.

Tabela 4.3.1. Modelos selecionados pelo algoritmo genético.

Modelo	Geração	Nódulos de entrada	Desempenho*	Variáveis**
0.2a	0	2	0,5221408	Última variação de preços futuros (primeiro contrato) em h períodos disponível e última variação de preços físicos em h períodos disponível
0.2b	0	2	0,5394172	Última variação de preços futuros (segundo contrato) em h períodos disponível e última variação de preços físicos em h períodos disponível
1.2.a	1	2	0,5849392	Última variação de preços futuros (primeiro contrato) em h períodos disponível e última variação de preços futuros (segundo contrato) em h períodos disponível
1.3a	1	3	0,6209352	Últimas variações de preços para h períodos dos preços futuros (primeiro e segundo contrato) e físico
1.3b	2	3	0,6093448	Últimas variações de preços para h períodos dos preços futuro (primeiro contrato) e físico e binária indicando meses de secas e águas
5.4a	5	4	0,6081732	Últimas variações de preços para h períodos dos preços futuro (primeiro contrato) e físico, última variação do preço físico para 1 período e binária indicando meses de secas e águas

Elaboração própria.

* EQM medido usando a segunda parte da amostra designada para o algoritmo genético.

** h representa o horizonte da previsão.

Na tabela 4.3.1 a coluna Modelo apresenta o nome dado a cada modelo. Da esquerda para a direita, o primeiro algarismo numérico indica a geração em que foi concebido, o segundo o número de nódulos de entrada enquanto o algarismo alfabético indica a ordem de concepção. A segunda coluna indica a geração em que o modelo foi concebido, seguida da coluna que representa o número de nódulos de entrada. A coluna desempenho exibe o EQM de cada modelo medido usando a segunda parte da amostra separada para o empenho do algoritmo genético, ela descreve uma espécie de estimativa do EQM fora da amostra para os modelos de previsão para o horizonte $h = 5$. Por último, a coluna variáveis descreve as variáveis empregadas por cada modelo. Variáveis indicando o número de períodos seguidos

em que teria havido queda dos preços, outra indicando períodos seriados de alta de preços não foram selecionadas pelo algoritmo, a taxa de câmbio futuro também ficou de fora dos modelos selecionados. Vale ressaltar que as especificações testadas apresentavam de 2 até 6 nós de entrada, ainda assim o algoritmo genético findou selecionando apenas uma especificação contendo 4 nós e as demais com dois ou três nós, posto de outra forma, o procedimento apresentou uma inclinação favorável a especificações mais enxutas em detrimento de outras com um número maior de nós de entrada.

Depois de selecionadas, essas especificações foram novamente estimadas usando as observações para o ano de 2013, totalizando 250 observações entre os dias dois de janeiro e trinta de dezembro. Elas foram então testadas para as 497 observações obtidas entre os dias dois de janeiro de 2014 até o dia trinta de dezembro de 2015. Esse procedimento foi repetido para os três horizontes de previsão estudados (5, 20 e 60 dias úteis). Seguindo a mesma lógica das seções anteriores o desempenho dos modelos para as três medidas (EQM, EMA e TA) está representada pelo diagrama de pontos empilhados. Cada ponto representa uma especificação do modelo de redes neurais, os pontos mais acima são aqueles melhor colocados (tomando por base a medida de ajuste adotada) em relação aos modelos mais abaixo. A Figura 4.3.1 exibe o desempenho das diferentes especificações medidos em termos de EQM. O nome de cada especificação está inscrito nos pontos e correspondem aqueles arrolados na Tabela 4.3.1.

Figura 4.3.1. Erro quadrático médio das diferentes especificações de modelos de previsão de redes neurais dentro e fora da amostra para os diferentes horizontes. Fonte: resultados da pesquisa.

A Figura 4.3.1 exemplifica o quão difícil é estabelecer um padrão de comportamento e desempenho para os modelos de redes neurais. Em termos de classificação a única pista que a figura indica é a classificação do modelo 1.2a fora da amostra se repetindo em relação a mesma classificação para horizontes distintos. Ademais, a classificação dentro da amostra se repete fora da amostra para um mesmo horizonte uma única vez, também para o modelo 1.2a no horizonte de previsão $h = 60$. Também o desempenho dentro da amostra medido em EQM não se aproxima em valor do mesmo fora da amostra. A degradação da medida de ajuste se constata tanto na transição dentro-fora da amostra como também a medida que se amplia o horizonte de previsão. Vale ressaltar que em comparação com os modelos ajustados até agora, os modelos de redes neurais obtiveram melhor

desempenho dentro da amostra, com uma ressalva, a delimitação para esse desígnio não foi a mesma uma vez que as redes neurais foram ajustadas usando dados de 2013 com a finalidade de evitar o *overtraining*. Em seguida, a Figura 4.3.2 descreve análise semelhante tendo como medida de referência o EMA.

Figura 4.3.2. Erro médio absoluto das diferentes especificações de modelos de previsão de redes neurais dentro e fora da amostra para os diferentes horizontes.
Fonte: resultados da pesquisa.

Se tratando do EMA, também é difícil identificar linhas e colunas dispondo modelos em ordem semelhante. Em média, a medida de ajuste dentro da amostra não sugere com precisão a classificação fora dela tão pouco serve de indicador para o desempenho em si. A degradação da medida de ajuste se constata tanto no âmbito dentro-fora da amostra como quando se ampliam os horizontes de previsão. O modelo selecionado da quinta geração continua figurando entre os melhores

desempenhos dentro da amostra, mas isso se reverte se tratando da medida fora da amostra. Muitas das colunas da figura antecedente se repetem nesta, o que significa dizer que nesse caso EQM é uma boa aproximação para EMA e vice-versa. A Figura 4.3.3 traz as informações relacionadas a taxa de acerto.

Figura 4.3.3. Taxa de acerto das diferentes especificações de modelos de previsão de redes neurais dentro e fora da amostra para os diferentes horizontes.

Fonte: resultados da pesquisa.

Tendo como medida de referência a taxa de acerto, a consistência apontada pela classificação dos modelos é em média maior em relação aos duas outras medidas de desempenho. Também empregando essa medida, analisando o ranking e desempenho dentro da amostra é difícil inferir o ranking e desempenho fora dela, muito embora se tratando de ranking um modelo para o horizonte de cinco períodos se manteve, 1.3b, e para demais alguns modelos como o 0.2a e 0.2b estiveram

muito próximos de sua classificação dentro da amostra por diversas vezes. Tendo a TA como referência a degeneração da medida de ajuste acontece no âmbito dentro-fora da amostra, mas não a medida que se ampliam os horizontes de previsão. Essa análise encerra por hora a discussão sobre como cada classe se comportou quando somente a mesma estava sob exame.

4.4. Comparação conjunta

Evidências reunidas nas subseções anteriores sugerem a dificuldade em se apontar de acordo com um mesmo parâmetro de ajuste uma única especificação dentro de uma grande classe que supere as demais para todos os horizontes de previsão. Mas o que dizer das grandes classes quando comparadas conjuntamente? Será que alguma das grandes classes de modelos foi capaz de consistentemente superar as demais para a delimitação fora da amostra segundo alguma das medidas adotadas? Essa seção explora essa questão, buscando evidências acerca do comportamento da classe relativamente mais complexa, redes neurais, perante as demais antes mesmo de testar o modelo oriundo da média simples de todas as 18 especificações arroladas até agora³³.

Com a finalidade de promover a análise, tabelas foram construídas dispondo a nomenclatura dada a cada especificação, discriminadas grandes classes de origem. O erro fora da amostra para cada horizonte fora disposto junto de sua classificação levando em conta a totalidade das 18 especificações. Os nomes dos modelos em ordem, primeiro aparecem as 6 especificações da suavização exponencial, logo em seguida vêm as 6 especificações dos modelos de mercados futuros e as demais especificações correspondem àquelas oriundas das redes neurais. A construção e nomenclatura de cada uma das especificações é descrita subseção correspondente a grande classe que pertence. É importante salientar que os erros da delimitação chamada de dentro da amostra não foram dispostos na tabela uma vez que cada grande classe de modelos usa uma delimitação diferente, tendo em vista os diferentes pressupostos e necessidades de cada uma, por vezes

---

33 Uma vez que os modelos adotavam pressupostos diferentes, números de dados diferentes para calibrar os modelos, a medida chamada de dentro da amostra não fora comparada, apenas aquela chamada de fora da amostra teve seu desempenho contraposto.

diferindo entre especificações diversas dentro de uma grande classe. Essa delimitação foi apenas empregada nas três últimas secções com a finalidade de investigar possíveis padrões sobressalientes entre os erros dentro e fora da amostra. A tabela 4.4.1 mostra os resultados referentes ao EQM.

Tabela 4.4.1. Desempenho medido em erro quadrático médio fora da amostra para os diversos modelos, resultado das previsões diárias entre os dias 2 de janeiro de 2014 e 30 de dezembro de 2015.

	horizonte	h = 5		h = 20		h = 60	
	Nomenclatura	EQM	Rank	EQM	Rank	EQM	Rank
suavização exponencial	STE(0)	1,87927	13	20,17294083	18	161,3975555	18
	STA(2)	1,855905	9	19,21903592	17	153,489109	17
	SDES(3)	1,863465	11	13,65898206	9	64,24629267	16
	SDEA(4)	1,875413	12	14,86064128	11	63,97151299	15
	SDAS(5)	1,857247	10	13,65898181	8	60,65944345	13
	SDAA(6)	1,937359	14	13,01214857	7	46,03138713	2
modelos futuros	1-1	1,580235	7	11,61727364	6	61,99284668	14
	1-2	6,05073	18	11,58179598	5	57,4677839	11
	2-1	1,59193	8	10,01620535	1	54,15282658	7
	2-2	4,411217	16	10,54336643	3	55,67496685	9
	3-1	1,574183	6	10,02980423	2	54,21386104	8
	3-2	4,451466	17	10,63070114	4	55,72084636	10
redes neurais	0.2a	1,495653	2	13,94545412	10	51,02396398	5
	0.2b	2,006662	15	15,52963883	14	44,37127344	1
	1.2a	1,510982	3	14,96338853	13	50,74021429	4
	1.3a	1,493223	1	14,92687384	12	48,58198652	3
	1.3b	1,568294	5	16,24758672	15	59,62826177	12
	5.4a	1,542516	4	16,7329008	16	51,62396097	6

Fonte: resultados da pesquisa.

Resultados dispostos na Tabela 4.4.1 sugerem que se tratando da EQM, nenhuma especificação ou classe deles é capaz de consistentemente, isto é, para todos os horizontes analisados superar os demais. Os resultados sugerem um desempenho mais adequado por parte dos modelos de redes neurais para os horizontes de 5 e 60 dias úteis, para o horizonte intermediário de 20 dias úteis os melhores desempenhos foram desenhados pelos modelos de mercados futuros. A

classificação fica condicionada aos horizontes de previsão utilizados. Outra constatação importante é a da degradação das medidas de ajuste conforme se ampliam os horizontes de previsão, reforçando a intuição. Os *benchmarks* obtidos são de 1,493223 para a rede neural 1.3a no horizonte de cinco dias, 10,01620535 para o modelo futuro 2-1 para o horizonte de vinte dias e 44,37127344 para o modelo futuro 0.2b no horizonte de sessenta dias. A Tabela 4.4.2 examina os mesmos quesitos utilizando o EMA como medida de ajuste.

Tabela 4.4.2. Desempenho medido em erro médio absoluto fora da amostra para os diversos modelos, resultado das previsões diárias entre os dias 2 de janeiro de 2014 e 30 de dezembro de 2015.

horizonte		h = 5		h = 20		h = 60	
Nomenclatura		erro	rank	erro	rank	erro	rank
suavização exponencial	STE(0)	1,074369	11	3,590386	18	9,975001	18
	STA(2)	1,066897	10	3,458084	17	9,631741	17
	SDES(3)	1,087006	13	3,091607	9	6,756333	16
	SDEA(4)	1,092058	14	3,291882	15	6,719484	15
	SDAS(5)	1,084037	12	3,091607	8	6,516048	14
	SDAA(6)	1,125552	15	2,977161	7	5,634317	2
modelos futuros	1-1	1,00006	7	2,674286	5	6,471187	13
	1-2	1,902455	18	2,794889	6	6,104145	11
	2-1	1,000097	8	2,476063	1	6,046335	9
	2-2	1,747378	16	2,560061	3	5,960637	6
	3-1	0,994306	6	2,476177	2	6,057504	10
	3-2	1,7584	17	2,564363	4	5,961349	7
redes neurais	0.2a	0,95	2	3,111328	10	5,952294	5
	0.2b	1,048109	9	3,296479	16	5,507022	1
	1.2a	0,958008	4	3,14163	11	5,901791	4
	1.3a	0,93837	1	3,155272	12	5,801348	3
	1.3b	0,956398	3	3,211791	14	6,155835	12
	5.4a	0,966459	5	3,187666	13	6,013159	8

Fonte: resultados da pesquisa.

Exceto para algumas especificações de suavização exponencial que mantiveram suas colocações entre os horizontes de 20 e 60 dias úteis de previsão, a Tabela 4.4.2 mostra que de acordo com o erro médio absoluto, a classificação

também varia quando variam os horizontes de previsão. Não foi possível identificar uma classe de modelos que claramente superasse as demais nos diversos horizontes. No entanto, comparando as Tabelas 4.4.1 e 4.4.2 é possível notar que muitas classificações se repetem, ainda que não sua totalidade. A degradação das medidas de ajuste conforme se ampliam os horizontes de previsão também é constatada quando adotada o erro médio absoluto como medida de ajuste. Os *benchmarks* obtidos são de 0,93837 para a rede neural 1.3a no horizonte de cinco dias, 2,476063 para o modelo futuro 2-1 no horizonte de vinte dias e de 5,507022 para a rede neural 0.2b para o horizonte de sessenta dias. Vale ressaltar que os mesmos modelos para os mesmos horizontes alcançaram marcas consideradas *benchmarks* também de acordo com o EQM. A tabela 4.4.3 traz resultados semelhantes usando a taxa de acerto para classificar os modelos.

Tabela 4.4.3. Desempenho medido em taxa de acerto fora da amostra para os diversos modelos, resultado das previsões diárias entre os dias 2 de janeiro de 2014 e 30 de dezembro de 2015.

horizonte		h = 5		h = 20		h = 60	
	Nomenclatura	TA	Rank	TA	Rank	TA	Rank
suavização exponencial	STE(0)	62,37%	11	61,77%	7	59,56%	13
	STA(2)	60,56%	12	61,37%	8	59,56%	13
	SDES(3)	55,73%	15	60,76%	10	73,24%	3
	SDEA(4)	57,95%	13	58,15%	13	73,24%	3
	SDAS(5)	57,75%	14	60,76%	10	73,24%	3
	SDAA(6)	57,95%	13	51,31%	17	71,63%	4
modelos futuros	1-1	69,31%	3	63,52%	6	62,24%	12
	1-2	70,93%	1	67,51%	5	67,51%	9
	2-1	69,11%	4	69,18%	3	67,51%	9
	2-2	67,89%	5	70,86%	2	71,40%	5
	3-1	69,51%	2	68,97%	4	67,73%	8
	3-2	69,51%	2	71,49%	1	67,73%	8
redes neurais	0.2a	65,39%	9	58,35%	12	68,61%	7
	0.2b	66,00%	8	55,73%	14	73,44%	1
	1.2a	66,00%	8	60,76%	9	73,24%	2
	1.3a	66,20%	7	59,96%	11	70,62%	6
	1.3b	66,60%	6	55,53%	15	65,79%	11
	5.4a	65,19%	10	53,12%	16	66,80%	10

Fonte: resultados da pesquisa.

Adotando a taxa de acerto como medida de referência os resultados permanecem condicionados ao horizonte de previsão, isto é, a classificação varia conforme variam os horizontes de previsão. Ademais, nenhuma grande classe demonstra superioridade perante as demais para os diferentes horizontes de previsão. Alguns resultados, consequentemente classificações, se repetem entre modelos da mesma grande classe para um mesmo horizonte. A degradação da medida de conforme se ampliam os horizontes de previsão foi constatada para alguns modelos, mas não para todos. Poucas classificações se repetem em relação as medidas anteriores. Os benchmarks estabelecidos foram de 70,93% pelo modelo futuro 1-2 para o horizonte de cinco dias úteis de previsão, 71,49% pelo modelo

futuro 3-2 para o horizonte de vinte dias e de 73,44%, superando todos os demais benchmarks, pelo modelo de rede neural 0.2b para o horizonte de sessenta dias.

Considerando os diversos modelos individuais pertencentes as diferentes grandes classes, não foi possível constatar um modelo ou classe claramente superior aos demais para uma mesma medida de ajuste nos diversos horizontes de previsão. Esses resultados reforçam aqueles encontrados por Makridakis et al. (1982, 1993) e Makridakis et al. (2000), segundo os quais métodos estatisticamente mais complexos não necessariamente superam outros mais simples e que a classificação dos modelos depende da medida de erro empregada. Exceto para o horizonte de sessenta dias, nenhum modelo se mostrou claramente superior aos demais considerando as diferentes medidas de ajuste. Para o horizonte de previsão de sessenta dias a especificação de redes neurais 0.2b³⁴ apresentou os melhores resultados seja de acordo com a taxa de acerto, EQM e erro médio absoluto. Esses resultados exprimem a comparação entre modelos individuais das diferentes grandes classes definidas. A subseção seguinte traz a comparação desses resultados contra os resultados da combinação de todos os modelos individuais por meio da média simples.

4.5. Modelos Combinados

O resultado do modelo combinado é dado pela média simples dos resultados dos 18 especificações individuais comportadas em 3 classes de modelos. A Tabela 4.5.1 sintetiza os resultados da combinação de modelos de acordo com a medida de ajuste adotada. Ela também traz os valores de referência listados como *benchmarks*, estes correspondem aos desempenhos dos modelos melhor classificados de acordo com as diferentes medidas. Para o EQM e EMA valores inferiores ao benchmark refletem a superioridade constatada pela medida no determinado horizonte de previsão. Em outras palavras, para cada horizonte de previsão, medidas inferiores ao *benchmark* sugerem que a combinação excederia as demais especificações tendo em vista a medida específica. Para o TA valores maiores sugerem superioridade da combinação em detrimento das especificações individuais.

---

³⁴ Os valores ajustados para este modelo podem ser vistos no Apêndice C.

Tabela 4.5.1. Resultados da combinação de modelos.

	horizonte (h)		
	h = 5	h = 20	h = 60
EQM	1,180876	9,806843	45,02401
benchmark	1,493223	10,01621	44,37127
EMA	0,846719	2,48315	5,691888
benchmark	0,93837	2,476063	5,507022
TA	69,22%	67,40%	73,44%
benchmark	70,93%	71,49%	73,44%

Fonte: resultados da pesquisa.

A combinação é capaz de superar o melhor modelo individual de acordo com o EQM para os horizontes de previsão de cinco e vinte dias úteis. Para o EMA, somente para o horizonte de cinco dias úteis a combinação é capaz de superar todos os demais modelos e para a TA ela é capaz de parear o melhor resultado somente para o horizonte de sessenta dias úteis. Ainda que não fosse capaz de superar em 5 dos nove casos, o modelo oferecido pela média ainda é capaz de oferecer um resultado capaz de superar a maioria dos modelos considerados individualmente. Para o EQM no horizonte de 60 dias úteis a combinação ocuparia o segundo lugar quando comparada contra todas as demais especificações. O terceiro lugar seria ocupado pela mesma se considerado o EMA nos contextos da previsão para 20 e 60 dias úteis. A quarta colocação seria ocupada considerando a TA para o horizonte de 5 dias úteis e a sexta colocação no horizonte de 20 dias úteis.

Vale ressaltar que a análise desenhada por meio da combinação simples não esgota sobremaneira a investigação a respeito da combinação. Pelo contrário, corresponde uma investigação preliminar em que apenas a heurística da combinação simples fora adotada em detrimento a infinidade de heurísticas disponíveis. A heurística da combinação simples tem como característica a não seletividade, todos os modelos estimados estão incluídos, até mesmo aqueles que não se esperava bons resultados. Outra característica é a da não predileção, nenhum dos modelos exerce mais peso em relação aos demais, todos são ponderados a mesma maneira. É possível que outras heurísticas com características distintas ofereçam resultados melhores. Ainda assim, essa investigação preliminar é favorável ao emprego da combinação, tendo em vista que quando essa abordagem não ocupou a primeira colocação ela superou mais do que a maioria das especificações individuais.

5. CONCLUSÕES

Os resultados encontrados para o problema de previsão do indicador de preços da @ do boi gordo paulista CEPEA-ESALQ reforçam aqueles encontrados por Makridakis et al. (1982, 1993, 2000). Modelos considerados mais complexos não necessariamente superam outros cujas configurações são tidas como mais simples. Dessa forma, os resultados sugerem que ao optar por um modelo de previsão em detrimento de outro no contexto do índice boi gordo CEPEA-ESALQ, a relativa complexidade dos modelos não deve ser considerada como um bom indicador da classificação desses modelos fora da amostra. Uma ressalva deve ser feita com relação ao horizonte mais longo estudado, o de 60 dias úteis. Antes de mais nada vale destacar o aspecto da multiplicidade de medidas de erro.

Assim como na macroeconomia indicadores diversos podem analisar uma questão por diferentes perspectivas, analogamente para o problema de previsão os erros também podem ser avaliados de distintas maneiras. A predileção de um indicador em detrimento de outro deve ser feita com base na capacidade dele em refletir mais precisamente custos e receitas associadas ao emprego de determinada previsão, também sendo possível o desenho de uma função específica para designar o custo ou preferência pelos erros. No entanto, se a classificação das previsões é insensível a medida de erro utilizada, em outras palavras, não muda para as diferentes medidas de erro, então qualquer medida poderia ser empregada para classificar as previsões. Por esse motivo é importante analisar como se classificam as previsões em resposta as diferentes medidas de erro. Assim como os trabalhos de Makridakis et al. (1982, 1993) e Makridakis et al. (2000) sugerem, a classificação das diversas especificações é sensível a medida de erro utilizada. A ressalva é dirigida ao modelo específico de redes neurais (0.2b), que superou todos os demais para o horizonte de previsão de 60 dias úteis, não importando a medida de erro utilizada. Esse resultado sugere uma possível tendência dos modelos mais complexo em descrever previsões mais precisas quando se expande o horizonte de previsão.

Além da análise da multiplicidade dos erros, outra importante investigação, ainda que preliminar, se dirige a combinação dos diversos modelos. Os resultados indicam vantagens aliadas a combinação dos modelos de previsão. Novas investigações poderão verificar se diferentes abordagens de combinações podem

aprimorar esses resultados. O estudo empregou apenas uma abordagem linear e não seletiva. É possível que abordagens não lineares e abordagens seletivas tragam resultados ainda mais vantajosos, mas essa é conclusão que por hora pede mais investigação. Ainda assim, resultados da combinação dos modelos pela média simples sugere que a cooperação entre produtores para formular previsões conjuntas é capaz de gerar benefícios a todos. Pesquisas posteriores podem apontar qual método de combinação é mais adequado e vantajoso para diferentes contextos.

Aliadas as discussões a respeito da combinação e multiplicidade dos erros, mostram que diferentes modelos em situações específicas apresentam virtudes diferentes, por exemplo, para o horizonte de 20 dias úteis os modelos combinados apresentaram o menor EQM, no entanto, o modelo futuro 3-2 melhor comportou o sentido da variação dos preços (TA). Uma tradução da divisão do trabalho para o problema de previsão poderia resultar em uma espécie de sociedade de modelos. Deste modo, enquanto para o horizonte de 20 dias poderíamos usar a combinação de modelos para indicar a variação esperada de preços em termos absolutos, o sentido dessa mudança de preços poderia ser dado então pelo modelo futuro 3-2, por isso o nome sociedade de modelos. Outros modelos ainda poderiam ser designados para por exemplo alertar para *outliers* ou então descrever limites para a variação dada pelos modelos. Estudos subsequentes podem investigar desta natureza.

Os resultados indicados pelo trabalho podem ser sintetizados em quatro pontos relacionados a previsão de preços do indicador do boi gordo CEPEA: (i) a complexidade não necessariamente se traduz em melhores desempenhos; (ii) a classificação dos modelos varia de acordo com o horizonte de previsão e medida de erro adotada; (iii) a combinação, ainda que simples, é capaz de trazer melhorias na acurácia; (iv) um único modelo de redes neurais foi capaz de superar os demais para o horizonte mais longo. Esses resultados podem contribuir para pesquisadores e produtores ligados a cadeia de produção do boi gordo, balizando a elaboração e uso de previsões para a *commodity* em questão.

REFERÊNCIAS

- ABITANTE, K. G. Co-integração entre os mercados spot e futuro: evidências dos mercados de boi gordo e soja. **Revista de Economia e Sociologia Rural**, v. 46, n. 1, p. 75-96, 2008.
- ATKINSON, Peter M.; TATNALL, A. R. L. Introduction neural networks in remote sensing. **International Journal of remote sensing**, v. 18, n. 4, p. 699-709, 1997.
- BACCHI, MRP. **Previsão de preços de bovino, suíno e frango com modelos de séries temporais**. Piracicaba, 1994. 172p. Tese de Doutorado. Tese (Doutorado)–Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo.
- BATES, John M.; GRANGER, Clive WJ. The combination of forecasts. **Or**, p. 451-468, 1969.
- BOX, George EP; JENKINS, Gwilym M.; REINSEL, G. Forecasting and control. **Time Series Analysis**, v. 3, p. 75, 1970.
- BRESSAN, A. A.; LIMA, J. E. de. 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, jan./jun. 2002.
- BURGO, M N.. **Caracterização Espacial de riscos na agricultura e implicações para o desenvolvimento de instrumentos para seu gerenciamento**. 2005. Tese de Doutorado. Universidade de São Paulo.
- CARRER, Marcelo José et al. Fatores determinantes do uso de instrumentos de gestão de risco de preço por pecuaristas de corte do Estado de São Paulo. **Ciência Rural**, v. 43, n. 2, 2013.
- CHATFIELD, C. Neural network: Forecasting breakthrough or passing fad? **International Journal of Forecasting**, 9, 1–3, 1993.
- CHATFIELD, Chris et al. A new look at models for exponential smoothing. **Journal of the Royal Statistical Society: Series D (The Statistician)**, v. 50, n. 2, p. 147-159, 2001.
- CLEMEN, Robert T. Combining forecasts: A review and annotated bibliography. **International journal of forecasting**, v. 5, n. 4, p. 559-583, 1989.
- COOTNER, Paul H. Returns to speculators: Telser versus Keynes. **Journal of political Economy**, v. 68, n. 4, p. 396-404, 1960.
- CRONE, S. F.; HIBON, M.; NIKOLOPOULOS, K. Advances in forecasting with neural networks? Empirical evidence from the NN3 competition on time series prediction. **International Journal of Forecasting**, v. 27, n. 3, p. 635-660, 2011.

DA SILVA, Marcelo Corrêa; BOAVENTURA, Vanda Maria; FIORAVANTI, Maria Clorinda Soares. História do povoamento bovino no Brasil Central. 2012.

DE FÁTIMA MONTEIRO, Waleska et al. A não efetividade do hedge para o boi gordo. **Revista de Economia**, v. 39, n. 1. 2013.

DE GOOIJER, Jan G.; HYNDMAN, Rob J. 25 years of time series forecasting. **International journal of forecasting**, v. 22, n. 3, p. 443-473, 2006.

FAMA, Eugene F.; FRENCH, Kenneth R. Commodity futures prices: Some evidence on forecast power, premiums, and the theory of storage. **Journal of Business**, p. 55-73, 1987.

FERREIRA, Luciano et al. Utilização de redes neurais artificiais como estratégia de previsão de preços no contexto de agronegócio. **RAI Revista de Administração e Inovação**, v. 8, n. 4, p. 6-26, 2011.

GARDNER, Everette S. Exponential smoothing: The state of the art—Part II. **International journal of forecasting**, v. 22, n. 4, p. 637-666, 2006.

GARDNER, Everette S. Exponential smoothing: The state of the art. **Journal of forecasting**, v. 4, n. 1, p. 1-28, 1985.

GUO, Zhichao; UHRIG, Robert E. Using genetic algorithms to select inputs for neural networks. In: **Combinations of Genetic Algorithms and Neural Networks, 1992., COGANN-92. International Workshop on.** IEEE, 1992. p. 223-234.

HINTON, Geoffrey E. How neural networks learn from experience. **Scientific American**, v. 267, n. 3, p. 145-151, 1992.

HYNDMAN, R. J. It's time to move from what to why'. **International Journal of Forecasting**, v. 17, n. 1, p. 567-570, 2001.

HYNDMAN, Rob J. et al. A state space framework for automatic forecasting using exponential smoothing methods. **International Journal of Forecasting**, v. 18, n. 3, p. 439-454, 2002.

JONES, Antonia J. Genetic algorithms and their applications to the design of neural networks. **Neural Computing & Applications**, v. 1, n. 1, p. 32-45, 1993.

KAASTRA, Ieabeling; BOYD, Milton. Designing a neural network for forecasting financial and economic time series. **Neurocomputing**, v. 10, n. 3, p. 215-236, 1996.

KALDOR, Nicholas. Speculation and economic stability. **The Review of Economic Studies**, v. 7, n. 1, p. 1-27, 1939.

KASSOUF, Ana L. Previsão de preços na pecuária de corte do Estado de São Paulo. **Piracicaba: USP/ESALQ**, 1988.

KNIGHT, Frank H. Risk, uncertainty and profit. New York: Hart, **Schaffner and Marx**, 1921.

KOHZADI, Nowrouz et al. A comparison of artificial neural network and time series models for forecasting commodity prices. **Neurocomputing**, v. 10, n. 2, p. 169-181, 1996.

LEUNG, Frank HF et al. Tuning of the structure and parameters of a neural network using an improved genetic algorithm. **Neural Networks, IEEE Transactions on**, v. 14, n. 1, p. 79-88, 2003.

MAKRIDAKIS, S.; HIBON, M.; MOSER, C. Accuracy of forecasting: An empirical investigation. **Journal of the Royal Statistical Society. Series A (General)**, p. 97-145, 1979.

MAKRIDAKIS, Spyros et al. The accuracy of extrapolation (time series) methods: Results of a forecasting competition. **Journal of forecasting**, v. 1, n. 2, p. 111-153, 1982.

MAKRIDAKIS, Spyros et al. The M2-competition: A real-time judgmentally based forecasting study. **International Journal of Forecasting**, v. 9, n. 1, p. 5-22, 1993.

MAKRIDAKIS, Spyros; HIBON, Michele. The M3-Competition: results, conclusions and implications. **International journal of forecasting**, v. 16, n. 4, p. 451-476, 2000.

MALKIEL, Burton G.; FAMA, Eugene F. Efficient capital markets: A review of theory and empirical work. **The journal of Finance**, v. 25, n. 2, p. 383-417, 1970.

MARGARIDO, Mario Antonio et al. Análise dos impactos das cotações do dólar paralelo e do índice pluviométrico sobre os preços do boi gordo no estado de S. Paulo. **Revista Brasileira de Economia**, v. 50, n. 2, p. 255-278, 1996.

MCCULLOCH, Warren S.; PITTS, Walter. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, v. 5, n. 4, p. 115-133, 1943.

NEWBOLD, P.; GRANGER, C. WJ. Experience with forecasting univariate time series and the combination of forecasts. **Journal of the Royal Statistical Society. Series A (General)**, p. 131-165, 1974.

PECK, Anne E. Futures markets, supply response, and price stability. **The Quarterly Journal of Economics**, p. 407-423, 1976.

RIEDMILLER, Martin; RPROP, I. Rprop-description and implementation details. 1994.

ROSSI, Cláudio Antonio. **Análise de estratégias de hedging estáticas aplicadas a commodities agrícolas**. 2008. Tese de Doutorado. Universidade de São Paulo.

SACHS, Raquel Castellucci Caruso; PINATTI, Eder. ANÁLISE DO COMPORTAMENTO DOS PREÇOS DO BOI GORDO E DO BOI MAGRO NA PECUÁRIA DE CORTE PAULISTA, NO PERÍODO DE 1995 A 2006. **Revista de Economia e Agronegócio-REA**, v. 5, n. 3, 2015.

SARLE, Warren S. Neural networks and statistical models. 1994.

SATCHELL, Steve; TIMMERMAN, Allan. An assessment of the economic value of non-linear foreign exchange rate forecasts. **Journal of Forecasting**, v. 14, n. 6, p. 477-497, 1995.

SEN, Amartya. **Development as freedom**. Oxford Paperbacks, 2001.

SILVER, Nate. **The signal and the noise: why so many predictions fail--but some don't**. Penguin, 2012.

TAYLOR, James W. Exponential smoothing with a damped multiplicative trend. **International journal of Forecasting**, v. 19, n. 4, p. 715-725, 2003.

TAYLOR, James W. Smooth transition exponential smoothing. **Journal of Forecasting**, v. 23, n. 6, p. 385-404, 2004b.

TAYLOR, James W. Volatility forecasting with smooth transition exponential smoothing. **International Journal of Forecasting**, v. 20, n. 2, p. 273-286, 2004a.

TELSER, Lester G. Futures trading and the storage of cotton and wheat. **Journal of Political Economy**, v. 66, n. 3, p. 233-255, 1958.

TETLOCK, Philip E.; GARDNER, Dan. **Superforecasting: The art and science of prediction**. Random House, 2016.

WERBOS, Paul J. Applications of advances in nonlinear sensitivity analysis. In: **System modeling and optimization**. Springer, Berlin, Heidelberg, 1982. p. 762-770.

WERBOS, Paul. Beyond regression: New tools for prediction and analysis in the behavior science. **Unpublished Doctoral Dissertation, Harvard University**, 1974.

ZHANG, Guoqiang; PATUWO, B. Eddy; HU, Michael Y. Forecasting with artificial neural networks: The state of the art. **International journal of forecasting**, v. 14, n. 1, p. 35-62, 1998.

APÊNDICES

Apêndice A – dados futuros faltantes

Para algumas observações do índice CEPEA boi gordo, não se tem correspondente nas séries de boi gordo futuro (primeiro e segundo vencimento) e dólar futuro (primeiro vencimento). Para essas séries, os dados estão indisponíveis seja por feriado local na cidade onde se situa a bolsa onde os futuros são negociados ou então por nenhum contrato de determinado vencimento ter se concretizado naquele dia. Os dados faltantes foram então substituídos pelo dado anterior mais próximo disponível. As datas para os dados utilizados estão descritos abaixo:

- Boi gordo futuro (primeiro vencimento) – 25/01/2011, 30/08/2011, 25/01/2012, 20/11/2012, 25/01/2013, 31/07/2013, 20/11/2013, 12/06/2014, 31/07/2014, 29/09/2014, 20/11/2014, 20/11/2015.
- Boi gordo futuro (segundo vencimento) – 03/01/2011, 25/01/2011, 03/02/2011, 04/02/2011, 07/02/2011, 01/03/2011, 06/01/2012, 25/01/2012, 03/02/2012, 06/02/2012, 20/11/2012, 03/01/2013, 04/01/2013, 25/01/2013, 05/03/2013, 12/03/2013, 18/03/2013, 31/07/2013, 20/11/2013, 12/06/2014, 01/08/2014, 20/11/2014, 02/01/2015, 05/01/2015, 02/03/2015, 03/03/2015, 04/03/2015, 05/03/2015, 06/03/2015, 09/03/2015, 10/03/2015, 20/11/2015.
- Dólar futuro (primeiro vencimento): 25/01/2011, 25/01/2012, 20/11/2012, 25/01/2013, 31/07/2013, 20/11/2013, 12/06/2014, 20/11/2014, 20/11/2015.

Apêndice B – estimativa de viés mensal para os modelos de mercados futuros

Tabela A.1. Vieses mensais e *p-valor* estimado para os modelos de mercados futuros para o horizonte de previsão de 5 dias úteis

modelo	2-1		2-2	
Mês	viés	p-valor	viés	p-valor
Janeiro	0,890333	9,42E-06	2,152542	2,15E-23
Fevereiro	0,447719	2,95E-05	1,854386	9,88E-40
Março	0,258889	0,04142	1,455397	8,07E-15
Abril	0,516557	1,47E-05	1,743443	1,49E-16
Maio	-0,05769	0,689153	-0,10969	0,5401
Junho	-0,29115	0,001382	-1,6841	1,91E-48
Julho	-0,06672	0,53464	-1,35438	3,23E-19
Agosto	-0,4675	0,000333	-2,20015	2,47E-25
Setembro	0,012459	0,957521	-2,51213	2,22E-16
Outubro	-0,19277	0,142227	-1,43262	9,85E-09
Novembro	0,158833	0,341099	0,125	0,598647
Dezembro	0,138966	0,4324	1,972759	1,78E-29

Fonte: elaboração própria.

Tabela A.2. Vieses mensais e *p-valor* estimado para os modelos de mercados futuros para o horizonte de previsão de 20 dias úteis

modelo	2-1		2-2	
Mês	viés	p-valor	viés	p-valor
Janeiro	-0,08067	0,830249	1,780682	1,06E-18
Fevereiro	0,954912	0,000147	2,361579	2,36E-14
Março	-0,13984	0,562645	1,16746	3,48E-05
Abril	1,123443	1,07E-10	2,238197	7,27E-32
Maio	-2,24892	1,93E-34	-0,95554	0,000123
Junho	-0,07885	0,696739	-0,76852	0,001385
Julho	0,907188	0,007498	-0,66656	0,042129
Agosto	-0,42765	0,070178	-1,67676	2,55E-13
Setembro	2,26541	2,39E-06	0,183607	0,685955
Outubro	0,201385	0,513146	-1,93508	7,87E-07
Novembro	2,325333	4,21E-10	0,942333	0,007245
Dezembro	-0,98017	0,087368	-0,1581	0,765101

Fonte: elaboração própria.

Tabela A.3. Vieses mensais e *p-valor* estimado para os modelos de mercados futuros para o horizonte de previsão de 60 dias úteis

modelo	2-1		2-2	
Mês	viés	p-valor	viés	p-valor
Janeiro	-0,66341	0,046667	-3,08705	5,34E-27
Fevereiro	-5,16946	6,88E-10	-4,1027	2,69E-09
Março	-1,89591	0,012723	-0,09349	0,877796
Abril	1,002787	0,006314	2,332131	5,8E-09
Maio	-2,054	3,23E-12	-0,73277	0,01882
Junho	-2,70623	6,12E-09	-1,56721	7,71E-05
Julho	-1,47547	0,002551	-0,32984	0,567858
Agosto	1,204118	0,001641	0,337941	0,450273
Setembro	3,626885	1,09E-22	2,092787	1,05E-07
Outubro	3,557692	4,23E-15	2,321077	1,94E-05
Novembro	5,536167	3,12E-82	3,269167	1,78E-20
Dezembro	2,233621	8,74E-11	0,092241	0,854042

Fonte: elaboração própria.

Apêndice C – ajuste do modelo de rede neural 0.2b para os diferentes horizontes de previsão.

As figuras C.1, C.2 e C.3 exibem os valores ajustados para o modelo de rede neural denominado 0.2b para os horizontes de 5, 20 e 60 dias úteis adiante. Esses valores foram obtidos usando dados diários disponíveis para o ano de 2013. Na figura é possível visualizar o número de passos até o algoritmo de retro propagação resiliente ajustar o modelo (*Steps*) e o erro (*Error*) medido em termos de entropia cruzada. Cada círculo representa um nóculo. As variáveis *d5_bgi2*, *d20_bgi2* e *d60_bgi2* indicam respectivamente a diferença de preço médio do contrato de boi gordo futuro BM&FBovespa com segundo vencimento fixado para os últimos 5, 20 e 60 dias úteis. As variáveis *p_d5*, *p_d20* e *p_d60* indicam a variação do indicador da @ do boi gordo CEPEA para os últimos 5, 20 e 60 dias úteis respectivamente; *t5*, *t20* e *t60* indicam as previsões para 5, 20 e 60 dias úteis adiante.

Figura C.1. Modelo de rede neural 02.b ajustado para o horizonte de previsão de 5 dias úteis.

Fonte: elaboração própria.

Figura C.2. Modelo de rede neural 02.b ajustado para o horizonte de previsão de 20 dias úteis.

Fonte: elaboração própria.

Figura C.3. Modelo de rede neural 02.b ajustado para o horizonte de previsão de 60 dias úteis.
Fonte: elaboração própria.