

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ
COORDENAÇÃO DE ENGENHARIA DE PRODUÇÃO
CURSO DE GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

MARINA MOREIRA CUNHA

**PREVISÃO DE SÉRIES TEMPORAIS POR MEIO DE MÉTODOS
ESTATÍSTICOS E NEURAIS: APLICAÇÃO EM UMA INDÚSTRIA DE
BEBIDAS**

TRABALHO DE CONCLUSÃO DE CURSO

Medianeira

2019

MARINA MOREIRA CUNHA

**PREVISÃO DE SÉRIES TEMPORAIS POR MEIO DE MÉTODOS
ESTATÍSTICOS E NEURAIS: APLICAÇÃO EM UMA INDÚSTRIA DE
BEBIDAS**

Trabalho de Conclusão de Curso apresentado como requisito parcial à obtenção do título de Bacharel em Engenharia de Produção, do Curso de Graduação em Engenharia de Produção, da Universidade Tecnológica Federal do Paraná.

Orientador: Prof. Dr. Jairo Marlon Corrêa
Coorientadores: Prof^a Dr^a Carla Adriana Pizarro Schmidt
Prof. Ms. Matheus de Lima Goedert

Medianeira

2019

TERMO DE APROVAÇÃO

PREVISÃO DE SÉRIES TEMPORAIS POR MEIO DE MÉTODOS ESTATÍSTICOS E NEURAIIS: APLICAÇÃO EM UMA INDÚSTRIA DE BEBIDAS

Por

MARINA MOREIRA CUNHA

Este trabalho de conclusão de curso foi apresentado às 15h50 do dia 08 de novembro de 2019, como requisito parcial para a aprovação na disciplina de TCC2, da Universidade Tecnológica Federal do Paraná, Campus Medianeira. O candidato foi arguido pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o projeto para realização de trabalho de diplomação aprovado.

Prof. Dr. Jairo Marlon Corrêa
Universidade Tecnológica Federal do Paraná

Prof. Dr. Diego Venâncio Thomaz
Universidade Tecnológica Federal do Paraná

Profª Ms. Edson Hermenegildo Pereira Junior
Universidade Tecnológica Federal do Paraná

Profª Dr. Sérgio Adelar Brun
Universidade Tecnológica Federal do Paraná

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso -

AGRADECIMENTOS

Primeiramente, à minha família, pelo voto de confiança e pelo suporte emocional e financeiro proporcionado durante os anos de graduação. Em especial aos meus pais, por serem meu porto seguro e sempre me incentivarem a lutar pelos meus sonhos, e às minhas irmãs, pela motivação e pelo apoio incondicional.

Ao meu orientador, Prof. Jairo Marlon Corrêa, por não medir esforços para me ajudar e possibilitar a concretização deste trabalho. Também aos meus coorientadores, Prof^a Carla Adriana Pizarro Schmidt e Prof. Matheus de Lima Goedert, pelas contribuições e sugestões.

Aos meus amigos, que me acompanharam durante a jornada acadêmica e compartilharam comigo alguns dos melhores (e piores) momentos da minha vida. Também àqueles que, mesmo à distância, fizeram-se presentes.

À Universidade Tecnológica Federal do Paraná campus Medianeira, por todas as oportunidades e por disponibilizar uma estrutura de qualidade que possibilitou a realização do sonho de me formar em Engenharia.

Por fim, a todos aqueles que contribuíram de alguma maneira para a realização deste trabalho.

"No que diz respeito ao empenho, ao compromisso, ao esforço, à dedicação, não existe meio termo. Ou você faz uma coisa bem feita ou não faz."

Ayrton Senna

RESUMO

CUNHA, Marina Moreira. **Previsão de séries temporais por meio de métodos estatísticos e neurais: aplicação em uma indústria de bebidas.** 2019. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

Diante da importância da indústria de bebidas (em especial o segmento cervejeiro) para a economia brasileira, a utilização de técnicas de previsão se mostra vantajosa para embasar o planejamento da produção e a tomada de decisões nas empresas deste setor. Através da previsão de produção, é possível estimar os recursos necessários para a transformação de matérias-primas em produtos acabados e otimizar a utilização destes, bem como viabilizar o atendimento ao mercado consumidor de maneira mais ágil e assertiva, o aumento da lucratividade e a redução de perdas financeiras e desperdícios em geral. Desta forma, o presente trabalho visa obter a previsão para três meses da produção semanal de uma indústria de bebidas, por meio da utilização de métodos estatísticos e do treinamento de uma Rede Neural Artificial. A aplicação dos métodos estatísticos permitiu verificar que o modelo de Médias Móveis não se ajustou à série temporal e, conseqüentemente, não forneceu previsões confiáveis, motivo pelo qual estas não foram apresentadas neste trabalho. Além disso, verificou-se que o modelo de Suavização Exponencial Simples e o modelo ARIMA apresentaram ajustes satisfatórios aos dados, no entanto, resultaram na previsão de valores constantes e próximos a um valor médio, respectivamente. Por fim, as previsões fornecidas pela Rede Neural Artificial acompanharam melhor os dados reais (utilizados para fins comparativos), logo, mostraram-se mais assertivas e confiáveis. A comparação entre os modelos testados foi feita com base no cálculo do RMSE para os valores previstos, sendo que a rede neural apresentou menor erro, seguida do modelo de Box-Jenkins e do modelo de Suavização Exponencial, fato que confirma a maior eficiência do primeiro método para a previsão utilizando a série temporal em estudo e viabiliza sua utilização como uma ferramenta para embasar a tomada de decisões relativas ao planejamento da produção na indústria em estudo.

Palavras-chave: Inteligência Artificial. Redes Neurais. Modelos Matemáticos. Planejamento da Produção. Cervejarias.

ABSTRACT

CUNHA, Marina Moreira. **Time series forecasting through statistical and neural methods: application in a beverage industry**. 2019. Monografia (Bacharel em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná.

Given the importance of beverage industry (especially breweries) for the Brazilian economy, forecasting techniques are useful to support production planning and decision making in these companies. Through production forecasting, it is possible to estimate the resources required for raw materials transformation into finished products and to optimize their use, as well as to get more assertiveness about the consumer's preferences, increasing profitability and reducing financial losses. Therefore, the present work aims to obtain a three-month-ahead forecast of a beverage industry's weekly production, through the use of statistical methods and the training of an Artificial Neural Network. For this, the company's historical production data was used. The methodology consists of an applied nature study, with a quantitative approach, modeling procedures and descriptive goals. With the application of the statistical methods, it was possible to verify that the Moving Average model has not fitted correctly the time series and, consequently, did not provide a trustworthy forecast, which is the reason it was not presented in this study. Also, it was found that the Simple Exponential Smoothing model (with $\alpha = 0,2277$) and the ARIMA (2,1,6) model presented satisfactory data adjustments, however predicted, respectively, constant values and near to an average value. Finally, the Artificial Neural Network forecasts were better adjusted to real data (used for comparison), which demonstrates its forecasting process is more assertive and reliable. The comparison between all the tested models was based in the RMSE value, calculated for the predicted values, being that the Artificial Neural Network had the lowest error, followed by the Box-Jenkins and the Exponential Smoothing models, which confirms the first method's better efficiency in forecasting the analyzed time series and enables its use as a support for decision making processes related to the production planning.

Key-words: Artificial Intelligence. Neural Networks. Mathematical Models. Production Planning. Breweries.

LISTA DE ILUSTRAÇÕES

Figura 1 – Representação do princípio de um modelo ARMA	24
Figura 2 – Representação do princípio de um modelo ARIMA.....	26
Figura 3 – Procedimento para aplicação da metodologia de Box-Jenkins	28
Figura 4 – Modelo de Neurônio Artificial	31
Figura 5 – Ilustração de uma RNA do tipo MLP de duas camadas ocultas.....	33
Figura 6 – Mecanismo de convergência do algoritmo resilient propagation.....	34
Figura 7 – Classificação da Pesquisa Científica.....	37
Figura 8 – Inicialização do treinamento da RNA utilizando o toolbox.....	41
Figura 9 – Definição dos parâmetros da RNA no Matlab	42
Figura 10 – Correlograma da FAC dos resíduos para o método de Médias Móveis .	44
Figura 11 – Correlograma da FACP dos resíduos para o método de Médias Móveis	44
Figura 12 – Periodograma integrado dos resíduos para o método de Médias Móveis	45
Figura 13 – Correlograma da FAC dos resíduos para o método de Suavização Exponencial Simples	46
Figura 14 – Correlograma da FACP dos resíduos para o método de Suavização Exponencial Simples	46
Figura 15 – Periodograma integrado dos resíduos para o método de Suavização Exponencial Simples	47
Figura 16 – Correlograma da FAC dos resíduos para o modelo ARIMA (2,1,6)	49
Figura 17 – Correlograma da FACP dos resíduos para o modelo ARIMA (2,1,6).....	50
Figura 18 – Periodograma integrado dos resíduos para o modelo ARIMA (2,1,6)	50
Figura 19 – Arquitetura da RNA utilizada	53

LISTA DE GRÁFICOS

Gráfico 1 - Série temporal utilizada no processo preditivo	39
Gráfico 2 – Comparação entre os dados históricos de produção e as previsões obtidas pelo método de Suavização Exponencial	47
Gráfico 3 – Comparação entre a produção real e prevista pelo método de Suavização Exponencial	48
Gráfico 4 – Comparação entre os dados históricos de produção e as previsões obtidas utilizando a metodologia de Box-Jenkins.....	51
Gráfico 5 – Comparação entre a produção real e prevista pelo modelo ARIMA (2,1,6)	52
Gráfico 6 – Comparação entre a produção real e prevista pela RNA.....	54
Gráfico 7 – Comparação entre os dados reais e as previsões fornecidas pelos modelos testados	56

LISTA DE TABELAS

Tabela 1 – Resultados obtidos pelo método de Suavização Exponencial Simples...	48
Tabela 2 – Resultados obtidos pelo modelo ARIMA (2,1,6).....	51
Tabela 3 – Resultados obtidos pela Rede Neural Artificial.....	54
Tabela 4 – Comparação da previsão obtida pelos diferentes modelos	55

SUMÁRIO

1 INTRODUÇÃO	12
1.1 OBJETIVO GERAL.....	13
1.2 OBJETIVOS ESPECÍFICOS	13
2 REVISÃO DE LITERATURA	15
2.1 A IMPORTÂNCIA DAS PREVISÕES PARA O PLANEJAMENTO DA PRODUÇÃO.....	15
2.2 MÉTODOS DE PREVISÃO	16
2.3 SÉRIES TEMPORAIS	17
2.4 MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS.....	18
2.4.1 Médias Móveis	19
2.4.2 Suavização Exponencial	20
2.4.2.1 Suavização Exponencial Simples (SES)	21
2.4.2.2 Suavização Exponencial Linear de Holt (SEH)	22
2.4.3 Modelo de Box-Jenkins (BJ).....	23
2.4.3.1 Modelos Autorregressivos (AR) e de Médias Móveis (MA)	24
2.4.3.2 Modelo ARIMA	25
2.4.3.3 A metodologia de Box-Jenkins para previsão.....	28
2.4.4 Redes Neurais Artificiais.....	30
2.4.4.1 RNA's para previsão de séries temporais	32
2.5 MEDIDAS DE ACURÁCIA	34
3 MATERIAL E MÉTODOS	36
3.1 CARACTERIZAÇÃO DA EMPRESA	36
3.2 CLASSIFICAÇÃO DA PESQUISA	36
3.3 ETAPAS DA PESQUISA	38
3.3.1 Aplicação dos métodos estatísticos	40
3.3.2 Treinamento da Rede Neural Artificial.....	40
3.3.3 Comparação entre os modelos estatísticos e a RNA	43
4 RESULTADOS E DISCUSSÃO	44
4.1 MÉTODO DE MÉDIAS MÓVEIS	44
4.2 MÉTODO DA SUAVIZAÇÃO EXPONENCIAL	45
4.3 MODELO DE BOX-JENKINS	49
4.4 REDE NEURAL ARTIFICIAL.....	52
4.5 COMPARAÇÃO ENTRE OS MÉTODOS ESTATÍSTICOS E A RNA	55
5 CONCLUSÃO	57
REFERÊNCIAS	59
APÊNDICE A – Modelos Matemáticos Testados	59
APÊNDICE B – Redes Neurais Treinadas	59

1 INTRODUÇÃO

Dentre os diversos segmentos industriais atuantes no Brasil, a indústria de bebidas recebe considerável destaque. O clima predominantemente tropical, o grande contingente populacional e a cultura do país criam um ambiente favorável para o consumo de bebidas geladas, fato que explica, por exemplo, o Brasil ser o terceiro maior produtor e consumidor de cervejas e refrigerantes do mundo, atrás apenas de Estados Unidos e China (CERVIERI JÚNIOR et al., 2014).

A indústria cervejeira, considerada uma das mais tradicionais do Brasil, comercializa seus produtos em todo o país e constitui uma cadeia produtiva que envolve o agronegócio, pequenos e grandes varejos, indústrias de embalagens e maquinários, além de mobilizar grande parte da frota logística brasileira. Atualmente, é responsável por 1,6% do PIB (Produto Interno Bruto) nacional, por gerar aproximadamente 2,7 milhões de empregos e por atender cerca de 99% dos lares brasileiros (CERVBRASIL, 2019).

As mudanças econômicas e tecnológicas ocorridas nos últimos anos exigiram das organizações o desenvolvimento de planejamentos consistentes das atividades, de forma a otimizar o fluxo e a alocação de pessoas, materiais e informações, bem como atender a demanda do mercado de maneira eficiente (CAVALHEIRO, 2003).

Neste sentido, as previsões são consideradas ferramentas importantes para auxiliar as decisões estratégicas de uma empresa, visto que contribuem para garantir a assertividade nos níveis de produção, a qualidade das operações, e para reduzir perdas logísticas, de compras e estoques (WERNER; LEMOS; DAUDT, 2006; BONOTTO, 2015).

A proposta do presente trabalho, fundamentada na utilização de métodos quantitativos para prever a programação semanal de produção de uma cervejaria, contribuirá para o adequado planejamento das atividades da indústria, tanto aquelas relacionadas ao processo cervejeiro em si, como às outras áreas, a exemplo de paradas para setup, compra de insumos, níveis de estoques, consumo de água, energia elétrica e vapor, escala de trabalho da operação, programação de movimentações logísticas, entre outros.

A realização do presente trabalho também é motivada pela aplicação de

conceitos e técnicas de outras áreas do conhecimento para a resolução de problemas relacionados à Engenharia de Produção, uma vez que serão abordados não somente aspectos particulares desta área, mas também de Estatística e de Inteligência Artificial.

A utilização dos métodos estatísticos de Médias Móveis e Suavização Exponencial se justifica pelo baixo custo e pela facilidade de modelagem que apresentam, enquanto o modelo ARIMA (Autoregressive Integrated Moving Average) se mostra vantajoso devido a sua flexibilidade e ampla utilização em processos preditivos. Já as Redes Neurais Artificiais (RNA's) merecem destaque pelo fato de que possibilitam a modelagem de séries temporais que apresentam estruturas de dependência não-lineares (o que não é possível pelos métodos preditivos convencionais). Além do mais, a atualidade desta ferramenta, sua importância para a Indústria 4.0, a relativamente baixa exploração desta no cenário acadêmico e seu potencial de pesquisa incentivam e valorizam a aplicação das RNA's para o presente estudo.

Por fim, destaca-se a possibilidade de realizar um estudo comparativo entre os métodos matemáticos convencionais e a RNA, de maneira a verificar quais modelos apresentaram melhor adequação aos dados e, portanto, proverão um prognóstico mais preciso sobre a situação futura.

1.1 OBJETIVO GERAL

Obter a previsão de produção semanal de uma cervejaria por meio da aplicação de métodos estatísticos e neurais sobre a série temporal de dados.

1.2 OBJETIVOS ESPECÍFICOS

- a) Realizar um levantamento bibliográfico sobre os métodos de Inteligência Artificial e estatísticos aplicáveis à previsão de séries temporais;
- b) Analisar os dados históricos de produção e modelar as séries temporais;

- c) Definir os métodos a serem utilizados para as análises preditivas e aplica-los;
- d) Identificar os modelos que melhor se ajustam aos dados e compará-los quanto à assertividade das previsões fornecidas;
- e) Definir um modelo que possa ser utilizado como base para as decisões referentes à programação da produção na empresa em estudo.

2 REVISÃO DE LITERATURA

A gestão de qualquer tipo de negócio requer a necessidade de cálculo de estimativas para que, assim, as adequações de recursos e estratégias operacionais sejam feitas de maneira satisfatória. Antecipar certos comportamentos permite aos gestores: dimensionar capacidades, calcular a necessidade de capital de giro, adequar os estoques para suprir compromissos de demanda, determinar o volume de mão-de-obra, adequar frotas de veículos, dentre outras decisões (GONÇALVES, 2013).

Segundo Gonçalves (2013), a modelagem matemática tem sido amplamente utilizada na Ciência da Gerência/Decisão, embasando de forma racional os processos decisórios. Além disso, novas linhas de raciocínio, como a Computação Natural, e conseqüentemente, a IA, buscam simular a forma de pensar, agir e aprender de sistemas naturais, como o cérebro humano. Estes tipos de algoritmos são capazes de resolver problemas complexos, muitos dos quais, até então não solucionados (DE CASTRO; VON ZUBEN, 2005; CORNE et al., 2012).

2.1 A IMPORTÂNCIA DAS PREVISÕES PARA O PLANEJAMENTO DA PRODUÇÃO

O PCP (Planejamento e Controle da Produção) é uma área que tem como função administrar as informações vindas dos diversos setores da empresa e coordenar os recursos produtivos para desenvolver, da melhor maneira possível, a programação da produção (TUBINO, 2017).

Hyndman e Athanasopoulos (2018) afirmam que as previsões se tratam de tentativas de antever o futuro com a maior precisão possível, considerando todas as informações disponíveis, como dados históricos e eventos que possam afetar o cenário futuro. Neste sentido, as previsões são fundamentais para os processos de planejamento da produção, uma vez que possibilitam aos gestores estimar o futuro, planejar adequadamente suas ações e desenvolver adequados planos de capacidade, vendas, produção, mão de obra, compras, estoques e outros (TUBINO, 2017).

O PCP se utiliza de previsões para planejar tanto o sistema produtivo como

o seu uso. No primeiro caso, elas são usadas para auxiliar no dimensionamento dos produtos a serem fabricados, do nível de serviço a ser oferecido e das instalações e equipamentos necessários, enquanto que, no segundo caso, servem como base para programar a produção a curto prazo e a utilização dos recursos disponíveis, como mão de obra, níveis de estoques e planos de compra (TUBINO, 2017).

Outro exemplo de utilização das previsões no processo de gestão é o Planejamento Agregado, o qual consiste no balanceamento da produção com a demanda e objetiva a combinação ótima dos recursos de forma a atender o mercado ao menor custo possível (MOREIRA, 2012).

Por fim, também os erros de previsão podem contribuir com os processos de programação da produção no que diz respeito ao planejamento e ao dimensionamento dos estoques de segurança (TUBINO, 2017).

2.2 MÉTODOS DE PREVISÃO

Um sistema de previsão é viabilizado pela coleta, análise e tratamento de dados e informações, e objetiva gerar estimativas futuras com uma precisão aceitável (ARAÚJO et al., 2018).

As incertezas e os erros advindos das previsões possuem duas fontes principais: o mercado, que pode ser instável e de baixa previsibilidade, e o método de previsão, o qual se baseia em variáveis de mercado e dados históricos para gerar a demanda futura. Considerando que a primeira é inevitável e inerente a qualquer tipo de negócio, a incerteza referente à segunda fonte deve ser minimizada por meio de um sistema de previsão de qualidade (CORRÊA; GIANESI; CAON, 2007).

Os métodos de previsão podem ser classificados em quantitativos ou qualitativos. Os métodos qualitativos, como o Método Delphi, envolvem o conhecimento empírico e a experiência dos especialistas, bem como a opinião de consumidores, e são utilizados quando da introdução de produtos novos no mercado e nos casos em que não há registro histórico dos dados ou estes são insuficientes para a modelagem matemática (MOREIRA, 2012; TUBINO, 2017).

Por outro lado, nos métodos quantitativos, assume-se que as causas que caracterizaram a série histórica continuarão em uma situação futura. Estes métodos

podem ser classificados em causais ou de análise de séries temporais. No primeiro caso, são utilizados dados históricos para variáveis dependentes e independentes e busca-se encontrar relações causais que influenciam no cenário futuro, enquanto, no segundo, os dados são organizados em forma de séries temporais para que seja possível reconhecer tendências e padrões sazonais, além de analisar o comportamento destes ao longo do tempo (PELLEGRINI, 2000; LEMOS, 2006; MOREIRA, 2012).

2.3 SÉRIES TEMPORAIS

Conforme definido por Spiegel (1993), o conjunto de amostras coletadas ao longo de um período de tempo, geralmente em intervalos iguais, é conhecido como séries temporais.

A escolha de um método apropriado de previsão depende em grande parte do padrão dos dados históricos disponíveis e de qual técnica melhor se adequa a este padrão (DORNELAS, 2017).

Pellegrini (2000) afirma que, das séries de dados, é possível extrair informações que permitem modelar matematicamente o comportamento destas, supondo a continuidade do comportamento apresentado historicamente sem influência de variáveis externas. A qualidade das previsões resultantes destes métodos tem se mostrado superior à de previsões baseadas na intuição dos gestores, além de que estes modelos são atualizáveis a partir da entrada de novos dados.

A análise das séries temporais envolve o entendimento dos seguintes comportamentos (SPIEGEL, 1993; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998):

- a) Tendência: refere-se à direção geral na qual os dados se comportam ao longo de um intervalo de tempo, podendo assumir, por exemplo, uma tendência de crescimento ou decréscimo ao longo do tempo.
- b) Sazonalidade: é observada quando uma série temporal apresenta um padrão de repetição conforme um fator sazonal (mensal, trimestral, semestral, anual ou até mesmo relativo a horários específicos do dia).

Os motivos que levam a ocorrência desse fenômeno são diversos, tais como datas festivas, clima, estratégias da empresa e características do mercado.

- c) Padrão cíclico: trata-se de oscilações ou desvios ocorridos, em longos intervalos de tempo (superiores a um ano), em torno do padrão de tendência. São difíceis de prever, pois não apresentam comportamento análogo em intervalos conhecidos e não possuem duração uniforme.
- d) Variações aleatórias (ou ruídos aleatórios): referem-se ao deslocamento esporádico da série temporal, provocado por eventos casuais (como catástrofes ambientais e eventos políticos), e correspondem à parcela de incerteza da demanda.

Por fim, dentre os objetivos envolvidos na análise de séries temporais, apresentados por Morettin e Tolo (2006), destacam-se os seguintes: a) Descrever o comportamento da série, de forma a verificar a existência de tendências, ciclos e variações sazonais; b) Prever os valores futuros da série a curto, médio ou longo prazo.

2.4 MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS

A utilização de um modelo de séries temporais para a previsão é uma técnica estatística conhecida como extrapolação, em que é identificado um padrão existente ao longo do tempo e assume-se que os dados futuros seguirão este padrão (LEMOS, 2006; FERNANDES; GODINHO FILHO, 2010).

De acordo com Makridakis, Wheelwright e Hyndman (1998), os métodos quantitativos de previsão de séries temporais podem ser utilizados se as seguintes condições forem satisfeitas: a) houver a disponibilidade de informações históricas; b) essas informações puderem ser quantificadas como dados numéricos; c) for possível assumir que alguns aspectos do passado se repetirão no futuro.

Os métodos de extrapolação podem ser classificados de três maneiras (MENTZER; MOON, 2005; LEMOS, 2006; DORNELAS, 2017):

- a) Modelos Fixos de Séries Temporais (FMTS): pressupõem que ao menos um dos componentes da série temporal é fixo e projetam este componente no futuro para gerar uma equação para a previsão. São utilizados em casos de necessidade de previsões frequentes. Exemplos: Médias Móveis e Suavização Exponencial.
- b) Modelos Abertos de Séries Temporais (OMTS): consideram apenas os dados da série temporal, sem influência de variáveis externas, e buscam identificar inter-relações entre seus componentes para determinar a equação de previsão. Indicados para a previsão de poucos itens e quando não há muita informação contextual. Exemplo: Método de Box-Jenkins.
- c) Análises de Correlação e Regressão: identificam o grau de correlação entre os dados em análise e as variáveis externas que os influenciam e, se provada a forte relação, os dados podem ser usados para o processo preditivo. Exemplos: Regressões Simples e Múltiplas, RNA's e ARIMAX.

2.4.1 Médias Móveis

Os modelos de Médias Móveis são apropriados para previsões a curto prazo e para dados históricos irregulares, ou seja, que contêm componentes randômicos, e que não apresentam tendência ou sazonalidade (LEMOS, 2006; CASULA, 2012). Consistem, ainda, no cálculo da média aritmética das n observações mais recentes da amostra, desprezando a observação mais antiga e incluindo a mais recente, conforme demonstrado na Equação 1 (MORETTIN; TOLOI, 2006).

$$M_t = \frac{D_t + D_{t-1} + \dots + D_{t-n+1}}{n} \quad (1)$$

Em que:

M_t : média no período atual;

D_t : demanda real no período t ;

n : número total de períodos considerados.

Neste método, o número de observações se mantém constante em cada média e os padrões de sazonalidade ou aleatoriedade (ou ambos) são eliminados. As médias se movem ao longo da série temporal até que sejam computadas para todos os períodos analisados. Então, as previsões para os períodos posteriores se baseiam na última média obtida, conforme a Equação 2, em que P_{t+1} é a previsão para o próximo período considerado (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MORETTIN; TOLOI, 2006).

$$P_{t+1} = M_t \quad (2)$$

A atualização da previsão, ou seja, o cálculo da previsão para os passos à frente, pode ser efetuado por meio da Equação (2.1), prevista por Morettin e Tolo (2006).

$$P_{(t)} = P_{t-1}(t + 1) + \frac{P_t - P_{t-n}}{n} \quad (2.1)$$

Os modelos de Média Móvel são muito utilizados por apresentarem simplicidade operacional e facilidade de entendimento. No entanto, envolvem o armazenamento de grande volume de dados, principalmente se o número de períodos for elevado (LE MOS, 2006; TUBINO, 2017).

2.4.2 Suavização Exponencial

Os métodos de suavização exponencial se diferenciam dos de Média Móvel por utilizarem todos os dados da série e aplicarem pesos desiguais aos dados de modo que as observações mais recentes recebem maior peso do que as mais antigas. Isso é resultante da consideração de que os dados mais recentes representam melhor a realidade atual e, assim, conferem maior confiabilidade à previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

2.4.2.1 Suavização Exponencial Simples (SES)

De acordo com Lemos (2006), a suavização exponencial simples permite obter a previsão para um período futuro por meio da previsão atual somada ao erro inerente ao ato de prever. Trata-se do método mais básico de suavização exponencial e pode ser utilizado quando a série temporal não apresenta tendência ou sazonalidade, somente nível e ruído (variações aleatórias) (LEMOS, 2006; DORNELAS, 2017). A Equação 3, proposta por Makridakis, Wheelwright e Hyndman (1998), representa a forma geral deste método.

$$F_{t+1} = \alpha Y_t + (1 - \alpha)F_t \quad (3)$$

Em que:

F_{t+1} : previsão para o período (t+1);

α : constante de suavização ($0 \leq \alpha \leq 1$);

Y_t : demanda relativa ao período t;

F_t : previsão referente ao período t.

Para expressar a previsão em função de todos os dados da série temporal, Winters (1960) propõe a Equação 4, na qual n representa o tamanho da série temporal.

$$F_{t+1} = \alpha \sum_{i=0}^n (1 - \alpha)^i Y_{t-i} + (1 - \alpha)^i F_1 \quad (4)$$

A constante de suavização α varia entre zero e um. Quanto mais próxima de um, maior peso é atribuído às observações mais recentes, ao passo que as observações mais antigas recebem os maiores pesos à medida que essa constante se aproxima de zero (HYNDMAN; ATHANASOPOULOS, 2018).

Assim, para pequenos valores de α , as flutuações aleatórias ocorridas no presente não influenciam consideravelmente nas previsões, tornando-as mais estáveis, ao passo que, para valores mais elevados de α , as previsões são mais

responsivas às observações recentes (MORETTIN; TOLOI, 2006; CASULA, 2012).

Este método apresenta grande flexibilidade por permitir a modificação da constante de suavização à medida que o padrão dos dados muda. Além disso, mostra-se vantajoso para processos preditivos que envolvem grande quantidade de itens (LEMOS, 2006).

A principal desvantagem apontada por Morettin e Tolo (2006) para a utilização deste método consiste na determinação de uma constante de suavização ótima. Makridakis, Wheelwright e Hyndman (1998) propõem aplicar o método com diferentes valores de α e escolher aquele que apresentar menor erro nas previsões.

2.4.2.2 Suavização Exponencial Linear de Holt (SEH)

Também conhecido como Suavização Exponencial Dupla, este método possibilita o processo preditivo para séries temporais que apresentam tendência linear, mas sem sazonalidade. São utilizadas duas constantes de suavização não relacionadas e que variam entre zero e um, sendo elas: α , para o nível, e β , para a tendência (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; LEMOS, 2006; CASULA, 2012).

Makridakis, Wheelwright e Hyndman (1998) também propuseram as Equações 5, 6 e 7 para a determinação, respectivamente, da previsão, do nível e da tendência da série.

$$F_{t+m} = L_t + b_t m \quad (5)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (7)$$

Sendo:

F_{t+m} : previsão para o período $t + m$;

L_t : estimativa do nível da série no período t ;

b_t : estimativa da tendência da série temporal no período t ;

m : horizonte de previsão.

A previsão, neste caso, é obtida adicionando-se ao nível atual (L_t) a tendência (b_t) multiplicada pelo horizonte de previsão (m) (MORETTIN; TOLOI, 2006). Além do mais, o procedimento de ajuste da tendência do período anterior ao último valor suavizado de nível, proposto na Equação 6, possibilita incorporar mudanças no padrão dos dados e, assim, aproximar o nível L_t do valor atual da série temporal (LEMOS, 2006).

A inicialização do método depende de dois valores iniciais: o primeiro nível (L_1), que pode ser considerado igual ao valor do primeiro período, e a primeira tendência (b_1), que pode ser nula ou assumir o valor da diferença entre os dois primeiros dados da série ($Y_2 - Y_1$) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Morettin e Tolo (2006), bem como Lemos (2006), apontam que a principal dificuldade na utilização deste método consiste em determinar valores ótimos para α e β , o que deve ser feito de maneira similar ao método da Suavização Exponencial Simples.

2.4.3 Modelo de Box-Jenkins (BJ)

Dentre os métodos mais robustos para previsão de séries temporais, destacam-se os modelos Autorregressivos de Médias Móveis (ARMA) e os modelos Autorregressivo Integrado de Médias Móveis (ARIMA), os quais obtêm a previsão dos valores de uma série temporal por meio da combinação de seus valores reais prévios e/ou dos erros ocorridos (MUELLER, 1996).

Tecnicamente denominada ARIMA, a metodologia de Box-Jenkins pressupõe que os valores de uma série temporal podem ser explicados por seus valores passados, por meio de uma correlação temporal geralmente existente entre os dados (GUJARATI; PORTER, 2011).

Enquanto os modelos de suavização exponencial se baseiam no tratamento da tendência e sazonalidade da série temporal, os modelos ARIMA objetivam descrever as autocorrelações entre os dados destas séries (HYNDMAN; ATHANASOPOULOS, 2018).

2.4.3.1 Modelos Autorregressivos (AR) e de Médias Móveis (MA)

Os modelos lineares de previsão de séries temporais estacionárias (que não possuem tendência) podem ser autorregressivos (AR), de médias móveis (MA) ou uma combinação dos dois (ARMA). Neste último, a série temporal a ser prevista é descrita como uma combinação de seus valores prévios (termos autorregressivos) e dos erros decorrentes de previsões anteriores (termos de média móvel) (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Estes modelos partem do princípio de que a série temporal é gerada por meio de um filtro linear (ou sistema linear) composto por uma entrada (ruído branco ou termo de erro, a_t), uma função de transformação ($\psi(B)$ para o processo AR(p) e $\theta(B)$ para MA(q)), e uma saída (Z_t), conforme demonstrado na Figura 1 (MORETTIN; TOLOI, 2006).




Figura 1 – Representação do princípio de um modelo ARMA
Fonte: Morettin e Toloí (2006).

Para determinar se um ruído é branco, faz-se necessário analisar os resíduos do modelo por meio de alguns testes. Os testes de Ljung-Box e de Box-Pierce verificam a existência de autocorrelação residual, enquanto o teste de Shapiro-Wilk analisa-os quanto à normalidade. Portanto, se os resíduos forem independentes e identicamente distribuídos (i.i.d), ou seja, normais e não autocorrelacionados, o resíduo é considerado um ruído branco, o qual apresenta distribuição de probabilidade com média nula e variância σ_a^2 , ou seja, $a_t \sim N(0, \sigma_a^2)$ (MORETTIN; TOLOI, 2006).

O processo autorregressivo de ordem p, AR(p), pode ser representado pela Equação 8, proposta por Box, Jenkins e Reinsel (2008).

$$\bar{Z}_t = \phi_1 \bar{Z}_{t-1} + \phi_2 \bar{Z}_{t-2} + \dots + \phi_p \bar{Z}_{t-p} + \alpha_t \quad (8)$$

A análise da equação acima permite verificar que o valor da série temporal (\bar{Z}) no período t depende de seus valores nos períodos anteriores ($\bar{Z}_{t-1}, \bar{Z}_{t-2}, \dots, \bar{Z}_{t-p}$), do valor do erro (a_t) e dos parâmetros ponderados ($\theta_1, \theta_2, \dots, \theta_p$) (BOX; JENKINS; REINSEL, 2008).

O modelo de Médias Móveis de ordem q , MA(q), é representado pela Equação 9, também proposta por Box, Jenkins e Reinsel (2008).

$$\bar{Z}_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (9)$$

A equação de representação do modelo de Médias Móveis (MA) é similar à Equação 8, exceto pelo fato de que o valor de \bar{Z} previsto para o período t não depende das observações anteriores, mas dos valores de erro observados em cada um dos períodos passados (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Por fim, considerando que o Modelo Autorregressivo e de Médias Móveis se trata de uma junção dos modelos AR(p) e MA(q), pode ser representado por ARMA(p, q) e sua fórmula consiste na soma das Equações 8 e 9, resultando na Equação 10, também proposta por Box, Jenkins e Reinsel (2008).

$$\bar{Z}_t = \theta_1 \bar{Z}_{t-1} + \dots + \theta_p \bar{Z}_{t-p} + a_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (10)$$

É possível verificar, assim, que este modelo relaciona os valores futuros da série temporal com as observações prévias, bem como com os erros advindos de previsões passadas (MUELLER, 1996).

2.4.3.2 Modelo ARIMA

De acordo com Box, Jenkins e Reinsel (2008), muitas das séries temporais, principalmente aquelas compostas por dados econômicos e industriais, não apresentam médias fixas ou apresentam comportamento não estacionário. Para que seja possível realizar previsões para o cenário futuro com base em dados passados, os parâmetros devem ser fixos e, portanto, a série temporal deve, obrigatoriamente, apresentar comportamento estacionário (MORETTIN; TOLOI,

2006).

Segundo Makridakis, Wheelwright e Hyndman (1998), a presença de padrões de não-estacionariedade (como a tendência) em séries temporais resulta em autocorrelações positivas dominantes. Por este motivo, é necessário remover a não-estacionariedade dos dados utilizando técnicas de diferenciação, de forma a tornar possível a visualização de outras estruturas de correlação importantes para a escolha do modelo de previsão.

Assim, quando a aplicação do modelo ARMA(p , q) depende da diferenciação de uma série temporal d vezes para torná-la estacionária, considera-se que a série original é do tipo ARIMA(p , d , q), em que p se refere aos termos autorregressivos; d , ao número de diferenciações necessárias para tornar a série estacionária; e q , à quantidade de termos de média móvel (GUJARATI; PORTER, 2011). A Equação 11 demonstra um modelo ARIMA(p , d , q) diferenciado d vezes, em que Δ é o operador de diferenciação, e p e q são as ordens de $\phi_{(B)}$ e $\theta_{(B)}$, respectivamente (MORETTIN; TOLOI, 2006; BOX; JENKINS; REINSEL, 2008).

$$\phi_{(B)}\Delta^d Z_t = \theta_{(B)}a_t \quad (11)$$

Figueredo (2008) apresenta o esquema de funcionamento de um modelo ARIMA, conforme apresentado na Figura 2. A entrada (ruído branco, a_t) e a saída (Z_t) são semelhantes ao modelo ARMA. A diferença entre os dois modelos está no fato de que o ARIMA contém duas funções de transformação: $\psi(B)$, para a parcela estacionária da série temporal, e S , responsável por eliminar a não-estacionariedade dos dados.




Figura 2 – Representação do princípio de um modelo ARIMA
 Fonte: Figueredo (2008).

De acordo com Morettin e Toloi (2006), os testes para verificar se o ruído é do tipo branco, neste caso, são os mesmos utilizados para o modelo ARMA, os quais foram apresentados na seção 2.4.3.1.

Morettin e Toloi (2006) apresentam, ainda, uma fórmula usual do modelo

ARIMA, representada pela Equação 12, considerada adequada para o cálculo de previsões.

$$Z_t = \varphi_1 Z_{t-1} + \dots + \varphi_{p+d} Z_{t-p-d} + \alpha_t - \theta_1 a_{t-1} - \dots - \theta_q a_{t-q} \quad (12)$$

Mueller (1996) afirma que o método ARIMA consegue modelar séries temporais de qualquer natureza, desde que apresentem comportamento linear. Além disso, para Morettin e Tolo (2006), estes modelos são úteis para eliminar as limitações apresentadas por outros modelos de previsão que não correlacionam os erros advindos de previsões anteriores.

De acordo com Makridakis, Wheelwright e Hyndman (1998), a determinação dos modelos de Box-Jenkins envolve duas funções fundamentais, a FAC (Função de Autocorrelação) e a FACP (Função de Autocorrelação Parcial), as quais são utilizadas em conjunto para auxiliar na escolha do modelo apropriado para a modelagem e a previsão de uma série temporal.

A FAC mede a correlação entre dois valores de determinada variável em períodos de tempo distintos, enquanto a FACP identifica a correlação entre valores atuais de uma variável da série temporal e seus valores no período $t - k$, descontando a influência das observações nos demais períodos (PELLEGRINI, 2000).

Makridakis, Wheelwright e Hyndman (1998) afirmam que plotar as FACs em um correlograma é útil para explorar as séries temporais antes de realizar processos preditivos, uma vez que possibilita a identificação de padrões cíclicos, de sazonalidade, entre outros.

Além do mais, a validação do modelo escolhido pode ser reforçada por meio da análise do periodograma integrado dos resíduos. Para que um modelo seja considerado ajustado aos dados, não devem existir desvios sistemáticos da reta e espera-se que os resíduos se comportem como ruídos brancos (MORETTIN; TOLOI, 2006).

Além disso, Morettin e Tolo (2006) afirmam que, mesmo que seja eliminada a componente sazonal da série temporal, ainda podem restar autocorrelações significativas, as quais devem ser ajustas por meio de um modelo ARIMA sazonal, ou SARIMA.

Este modelo pode ser utilizado também nos casos em que os dados são

classificados por períodos específicos de tempo (por ano, por exemplo) e possui a notação ARIMA $(p, d, q)(P, D, Q)_s$, em que (p, d, q) se refere à parcela não-sazonal do modelo, (P, D, Q) , à parte sazonal e s , ao número de períodos considerados (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

2.4.3.3 A metodologia de Box-Jenkins para previsão

A metodologia de Box-Jenkins se trata de um ciclo iterativo que, segundo Morettin e Toloí (2006, p. 106), “consiste em ajustar modelos autorregressivos integrados de médias móveis, ARIMA(p, d, q), a um conjunto de dados”.

Makridakis, Wheelwright e Hyndman (1998), Marchezan (2007) e Gujarati e Porter (2011) propõem que a operacionalização da metodologia de Box-Jenkins segue quatro passos básicos, demonstrados na Figura 3, sendo eles: identificação do modelo a ser utilizado, estimação dos parâmetros, validação do modelo e aplicação deste para a previsão. Morettin e Toloí (2006) apresentam os mesmos procedimentos, acrescentando a etapa de especificação, a qual precede a identificação e consiste em considerar uma classe geral de modelos para a análise.

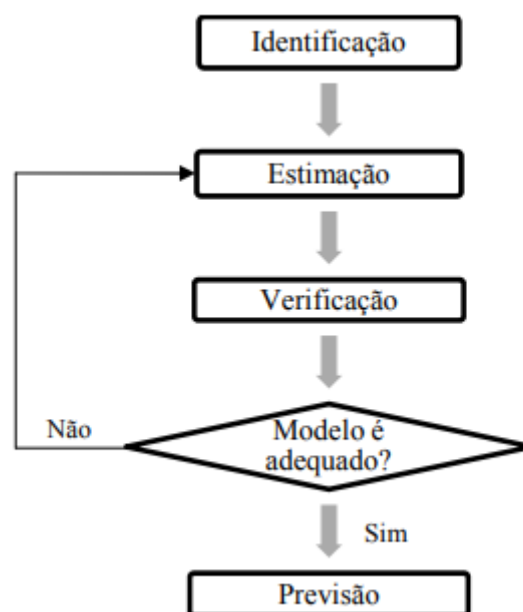


Figura 3 – Procedimento para aplicação da metodologia de Box-Jenkins
 Fonte: Marchezan (2007).

Morettin e Tolo (2006) e Figueredo (2008) são unânimes em afirmar que a identificação se trata da fase mais crítica do ciclo iterativo. Nesta etapa, são analisados os padrões de tendência, sazonalidade e ciclo da série temporal (MARCHEZAN, 2007). Além disso, verifica-se a estacionariedade da série com base nos correlogramas de FAC e FACP (SILVA, 2017) e, caso seja não estacionária, deve-se proceder à estabilização por meio de diferenciação (PELLEGRINI, 2000). O objetivo, nesta etapa, é determinar os valores de p , d e q do modelo ARIMA(p , d , q), além de fornecer uma estimativa dos parâmetros a serem utilizados na etapa de estimação (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MORETTIN; TOLOI, 2006).

Depois de definido o modelo ARIMA a ser utilizado, faz-se necessário estimar os parâmetros dos termos autorregressivos e de médias móveis inclusos no modelo (GUJARATI; PORTER, 2011). Quando houver termos do tipo MA, deve ser aplicado o método dos mínimos quadrados não-linear para otimizar os parâmetros. Caso contrário, faz-se o uso do método dos mínimos quadrados ou do método da máxima verossimilhança (MORETTIN; TOLOI, 2006; FIGUEREDO, 2008).

A etapa de verificação consiste em analisar se o modelo escolhido representa os dados adequadamente, o que é feito por meio da verificação dos resíduos gerados pelos ajustes. Se estes resíduos forem aleatórios e se comportarem como ruídos brancos, o modelo pode ser utilizado. Caso contrário, deve-se escolher outro modelo (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998; MORETTIN; TOLOI, 2006).

Além do mais, a escolha do melhor modelo, nesta etapa, considera os menores valores para os critérios AIC (Akaike Information Criterion) e BIC (Bayesian Information Criterion), os quais permitem identificar o modelo mais parcimonioso, ou seja, com a menor quantidade de parâmetros possível (MADDALA, 2003). Tal escolha também pode se basear no RMSE (Root Mean Square Error ou Raiz do Erro Quadrático Médio) ou no MAPE (Mean Absolute Percentage Error ou Média dos Erros Percentuais Absolutos), dependendo da escala dos dados.

Após determinado o modelo adequado para os dados da série temporal em estudo, este pode ser utilizado para gerar previsões para um cenário futuro (PELLEGRINI, 2000). De acordo com Gujarati e Porter (2011), a popularidade do modelo ARIMA para previsões se dá devido à confiabilidade de seus resultados, muitas vezes superior aos métodos tradicionais de modelagem matemática, o que

pode ser confirmado, por exemplo, pela pesquisa realizada por Jacobs (2011), em que os modelos ARIMA superaram os modelos de Suavização Exponencial (SE) tanto na modelagem como na previsão das séries temporais de dois produtos de determinada empresa, uma vez que os modelos de SE não capturaram adequadamente o processo gerador das séries e não se ajustaram de maneira satisfatória aos dados, apresentando elevados valores de erro e, portanto, mostrando-se pouco confiáveis para as previsões.

2.4.4 Redes Neurais Artificiais

Diante do interesse de cientistas e pesquisadores por replicar a maneira de processar informações do cérebro humano, foram desenvolvidas as RNAs sendo que o primeiro modelo de neurônio artificial foi proposto por McCulloch e Pitts em 1943 (SILVA; SPATTI; FLAUZINO, 2010).

As RNA's consistem na interligação maciça de células computacionais análogas aos neurônios biológicos, denominadas unidades de processamento. Além disso, são classificadas como máquinas adaptativas comparáveis ao cérebro humano no que diz respeito à capacidade de adquirir conhecimento por meio da experiência e utilizá-lo posteriormente. As informações são armazenadas em uma RNA pelas forças sinápticas (forças de conexão entre os neurônios artificiais) e o processo de aprendizagem ocorre mediante a alteração ordenada dos pesos sinápticos até que o objetivo seja atingido (HAYKIN, 2007).

Conforme demonstrado na Figura 4, proposta por Haykin (2007), o neurônio artificial recebe sinais de entrada (x_1, x_2, \dots, x_m) , provenientes do meio externo, e emite um sinal de saída (y_k) , que pode ser usado para alimentar outros neurônios ou como resultado da RNA.

Cada entrada possui um respectivo peso sináptico $(w_{k1}, w_{k2}, \dots, w_{km})$, responsável por quantificar a sua relevância em relação à saída. A combinação de todas as entradas com suas respectivas ponderações é feita por meio do combinador linear (Σ). O valor obtido por este último, subtraído do limiar de ativação (ou bias, b_k), resulta no potencial de ativação (v_k) do neurônio, o qual consiste na entrada da função de ativação (φ) e tem potencial excitatório ou inibitório sobre ela. Por fim, a

função de ativação objetiva limitar a saída do neurônio a valores que correspondam à imagem da função (HAYKIN, 2007; SILVA; SPATTI; FLAUZINO, 2010).




Figura 4 – Modelo de Neurônio Artificial
Fonte: Haykin (2007).

As funções de ativação podem ser classificadas em parcialmente diferenciáveis, utilizadas em redes Perceptron e Adaline, ou diferenciáveis, aplicadas nas Perceptron de Múltiplas Camadas e nas Redes de Base Radial, por exemplo (HAYKIN, 2009; SILVA; SPATTI; FLAUZINO, 2010).

As RNA's são constituídas, basicamente, por camadas de entrada, que recebem as informações (dados) do meio externo, camadas ocultas (também chamadas de intermediárias, invisíveis ou escondidas), responsáveis por extrair as características dos dados e realizar maior parte do processamento da rede, e camadas de saída, cujos neurônios produzem e apresentam o resultado final da rede (SILVA; SPATTI; FLAUZINO, 2010).

O processo de treinamento e aprendizagem da rede neural consiste no ajuste dos parâmetros da rede e dos pesos sinápticos, de forma a gerar um conjunto de saídas consistentes. Este processo pode ser do tipo supervisionado, quando o usuário apresenta à RNA as entradas e suas respectivas saídas, ou não-supervisionado, no qual somente os dados de entrada estão disponíveis para a rede, sendo ela a responsável por identificar padrões e codificar características de entrada e saída (BRAGA; LUDEMIR; CARVALHO, 2000).

Para o processo de treinamento, o conjunto de dados é dividido em dois

subconjuntos: o de treinamento, que compreende de 60 a 90% das amostras totais e serve para ajustar os pesos sinápticos e os potenciais de ação; e o de teste ou validação, que utiliza o restante das amostras para analisar o desempenho da rede no que diz respeito à capacidade de generalização (SILVA; SPATTI; FLAUZINO, 2010).

2.4.4.1 RNA's para previsão de séries temporais

Uma das características mais relevantes das RNA's para a previsão de séries temporais é a capacidade de aprender por meio de padrões (amostras) que representam o comportamento do sistema e generalizar as soluções após compreender a relação entre as entradas e as saídas (ZHANG; PATHUO; HU, 1998).

As RNA's são úteis para a previsão de séries temporais não lineares em que modelos lineares não conseguem captar o padrão de comportamento dos dados (JACOBS, 2011). Consideradas métodos avançados de previsão de séries temporais, geralmente apresentam erros inferiores aos demais métodos mesmo em sistemas mais complexos (FLORES; WERNER, 2007; FERNANDES; GODINHO FILHO, 2010).

Para processos preditivos, são utilizadas redes neurais que aproximam funções, como as MLP (Multilayer Perceptron), também chamadas de PMC (Perceptron de Múltiplas Camadas), as quais se caracterizam por apresentarem pelo menos uma camada oculta entre a camada de entrada e a de saída (SILVA; SPATTI; FLAUZINO, 2010; JACOBS, 2011).

Haykin (2007) e Silva, Spatti e Flauzino (2010) propõem a representação do modelo de rede MLP demonstrada na Figura 5, no qual os estímulos externos são apresentados à rede em suas camadas de entrada, então as camadas intermediárias ocultas extraem os padrões de comportamento dos dados e, por meio dos pesos sinápticos e dos limiares de ativação, criam uma representação dos mesmos. Por fim, as camadas de saída recebem os estímulos provenientes dos neurônios da última camada oculta e geram o padrão de respostas a ser disponibilizado pela rede.




Figura 5 – Ilustração de uma RNA do tipo MLP de duas camadas ocultas
Fonte: Haykin (2007).

As redes MLP apresentam topologia do tipo feedforward, na qual a informação é passada através da rede em um único sentido: das camadas de entrada para as de saída (BRAGA; LUDEMIR; CARVALHO, 2000; HAYKIN, 2009; SILVA; SPATTI; FLAUZINO, 2010).

O treinamento das redes MLP é do tipo supervisionado e ocorre por meio do algoritmo de aprendizagem denominado backpropagation, que utiliza pares de dados (entradas e saídas) para, por meio de um mecanismo de correção de erros, ajustar os pesos da rede. Este processo ocorre em duas fases que caminham em direções contrárias na rede: a fase forward é responsável por definir a saída relativa a uma entrada e a fase backward compara o valor de saída encontrado com o valor esperado e determina o erro existente entre eles para atualizar os pesos sinápticos das conexões, de forma a minimizar o erro e obter melhor relação entre as informações de entrada e saída (BRAGA; LUDEMIR; CARVALHO, 2000; SILVA; SPATTI; FLAUZINO, 2010).

Uma versão aperfeiçoada do backpropagation é o resilient propagation (Figura 6), algoritmo de treinamento que possui o mesmo princípio de funcionamento do primeiro, mas que, ao contrário deste, considera apenas a variação do sinal do gradiente da função erro. Assim, quando os sinais dos gradientes forem iguais em duas iterações sucessivas, a taxa de aprendizado pode ser aumentada, visto que ainda se está distante do ponto de mínimo da função. No entanto, se os sinais das iterações forem diferentes, entende-se que a taxa de aprendizado deve ser reduzida para convergir a este ponto (SILVA; SPATTI; FLAUZINO, 2010).

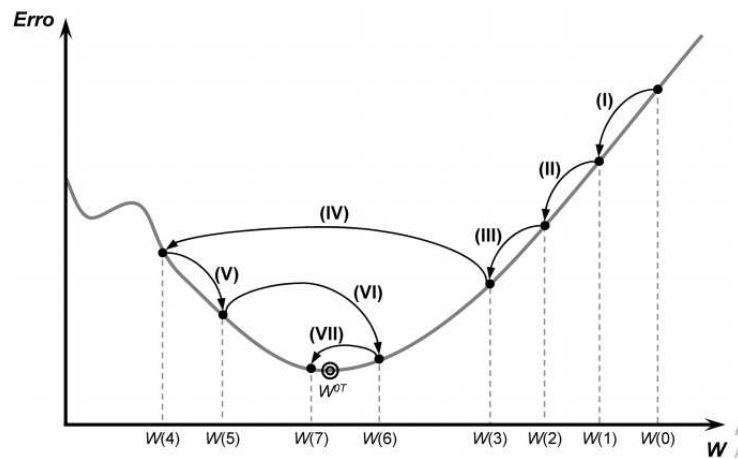


Figura 6 – Mecanismo de convergência do algoritmo resilient propagation
Fonte: Silva, Spatti e Flauzino (2010).

Por fim, conforme ressaltado pelos autores citados anteriormente, a configuração de uma rede MLP, bem como a quantidade de camadas intermediárias, depende de alguns fatores, como o problema em estudo, os valores iniciais atribuídos aos parâmetros e a disposição dos dados amostrais.

2.5 MEDIDAS DE ACURÁCIA

Diferentes métodos de previsão podem ser aplicados a uma mesma série temporal, sendo necessário avaliar qual deles melhor se ajusta à curva característica dos dados e, portanto, é mais indicado para o processo preditivo. Para isso, calcula-se o erro em cada intervalo de tempo por meio da Equação 13 (PELLEGRINI, 2000).

$$e_t = z_t - \hat{z}_t \quad (13)$$

Em que e_t equivale ao erro no período t , z_t ao valor observado no período t e \hat{z}_t ao valor previsto para este mesmo período.

Armstrong e Collopy (1992) apontam algumas medidas de acurácia, dentre as quais se destacam a raiz do erro quadrático médio (RMSE – Root Mean Square Error), o erro absoluto médio (MAE – Mean Absolute Error) e a média dos erros percentuais absolutos (MAPE – Mean Absolute Percentage Error), definidos pelas Equações 14, 15 e 16, respectivamente.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (Y_i - \hat{Y}_i)^2} \quad e_t = z_t - \hat{z}_t \quad (14)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |Y_i - \hat{Y}_i| \quad (15)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| \quad (16)$$

Em que n se refere à quantidade de períodos utilizados na previsão; Y_i , ao valor observado da demanda no período em questão; e \hat{Y}_i , ao valor previsto para a demanda neste mesmo período.

Pellegrini (2000) destaca que o modelo adequado será aquele que apresentar menor erro, independentemente da medida utilizada para os cálculos. Além disso, deve-se considerar que a acuracidade dos métodos diminui à medida que o horizonte de previsão aumenta, devido à influência de fatores aleatórios que não conseguem ser captados pelas previsões (FERNANDES; GODINHO FILHO, 2010; TUBINO, 2017).

Após escolhido e aplicado o modelo de previsão, deve-se acompanhar, por meio das medidas de acurácia e de indicadores de desempenho, a assertividade das previsões obtidas por ele e confirmar sua validade para o cenário atual, de forma a mantê-lo atualizado e garantir que as previsões sejam confiáveis (MOREIRA, 2012; TUBINO, 2017).

Diante da importância da previsão para as organizações, o nível de acurácia é um dos indicadores mais importantes para avaliar os métodos preditivos disponíveis e garantir que a exatidão dos resultados seja maximizada (LEMOS, 2006).

3 MATERIAL E MÉTODOS

3.1 CARACTERIZAÇÃO DA EMPRESA

A companhia em estudo no presente trabalho se trata de uma empresa que possui atuação em todo o território brasileiro e também em outros países das Américas. Caracterizada como uma indústria de bebidas, é responsável pela produção e comercialização de cervejas, refrigerantes, sucos, chás e água. Por questões de sigilo empresarial, optou-se por não divulgar o nome real da empresa em questão, a qual será tratada como Empresa A.

Para a realização do presente trabalho, escolheu-se, dentre as fábricas da referida companhia, uma cervejaria localizada no Paraná. Esta se caracteriza pela produção empurrada, opera sete dias por semana, e emprega aproximadamente 400 funcionários diretos e 250 indiretos, os quais se dividem entre diferentes áreas. Atualmente, envasa cerveja em garrafas de 550, 600 e 1000mL, e em latas de 269, 350 e 473mL. Além disso, produz chope, o qual é envasado em barris de 10, 30 e 50L.

Considerada uma das unidades fabris mais tecnológicas da companhia, possui capacidade nominal de produção de 500.000 hectolitros (hl) por mês distribuídos entre as diferentes marcas fabricadas. No entanto, a produção real, atualmente, é de cerca de metade da capacidade nominal. Por fim, ressalta-se que o volume de produção é maior entre os meses de outubro a janeiro, o que se deve ao fato do consumo de cerveja se intensificar no verão.

3.2 CLASSIFICAÇÃO DA PESQUISA

Segundo Gil (2008), a pesquisa trata do procedimento formal de desenvolvimento do método científico e possui o objetivo de apresentar respostas para os problemas propostos por meio de técnicas científicas. Prodanov e Freitas (2013) afirmam que, para conhecer cientificamente o problema, a pesquisa deve ser

sistemática, crítica e metódica e seus resultados devem agregar conhecimento.

A caracterização do presente estudo é apresentada em negrito na Figura 2 e foi elaborada com base nas classificações da pesquisa científica propostas por Gil (2008) e Morabito e Pureza (2010).

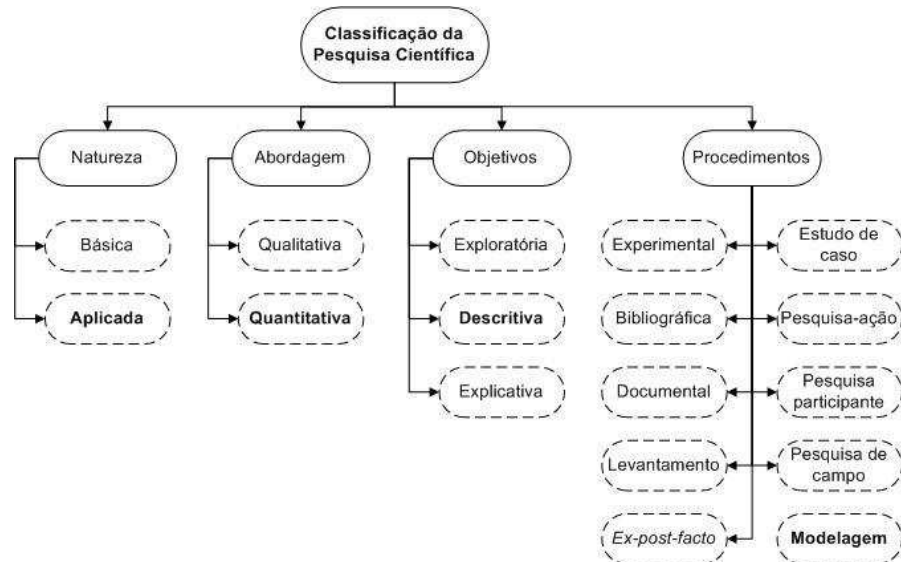


Figura 7 – Classificação da Pesquisa Científica
Fonte: Adaptado de Gil (2008) e Morabito e Pureza (2010).

A presente pesquisa apresenta natureza aplicada pelo fato que busca gerar conhecimento para a aplicação prática em uma problemática específica (a necessidade de se obter previsões) (GERHARDT; SILVEIRA, 2009; PRODANOV; FREITAS, 2013).

Considerada uma pesquisa quantitativa em relação à abordagem do problema, tem como princípio a objetividade na coleta e análise de dados numéricos, bem como a utilização de procedimentos estatísticos e computacionais para descrever o fenômeno em estudo, e diferencia-se da pesquisa qualitativa por gerar resultados quantificáveis (GERHARDT; SILVEIRA, 2009).

Por considerar que o comportamento dos dados passados se repetirá no futuro, a previsão de séries temporais se caracteriza como uma pesquisa descritiva, a qual, de acordo com Gil (2008), objetiva descrever as características de um fenômeno, de forma a identificar, sem a interferência do pesquisador, relações entre variáveis.

Com relação aos procedimentos metodológicos, esta pesquisa se classifica como modelagem, visto que utiliza modelos quantitativos abstratos (ou seja,

aqueles baseados em linguagem matemática e técnicas computacionais) para representar a realidade e auxiliar no tratamento do problema de forma sistemática (MORABITO; PUREZA, 2010).

Dentre as áreas do conhecimento relacionadas à Engenharia de Produção apresentadas pela Associação Brasileira de Engenharia de Produção (ABEPRO, 2019), o presente trabalho se enquadra na área de Pesquisa Operacional, uma vez que objetiva resolver um problema real por meio da aplicação de modelos matemáticos processados computacionalmente e de uma ferramenta de Inteligência Artificial, a RNA (TURRIONI; MELLO, 2012).

3.3 ETAPAS DA PESQUISA

A primeira etapa do presente trabalho consistiu em um levantamento bibliográfico em livros didáticos, teses, dissertações e artigos científicos, a fim de conhecer com maior detalhamento o estado da arte acerca do tema em questão, tanto no que diz respeito à previsão de demanda em si, quanto aos métodos matemáticos e de IA aplicáveis a processos preditivos e os resultados obtidos nestes.

Posteriormente, foi realizada uma visita técnica à unidade fabril para conhecer em detalhes o processo produtivo e, juntamente com os gestores, identificar as necessidades e prioridades da empresa, de forma a definir quais dados seriam utilizados para a previsão. Ficou estabelecido, então, que seriam utilizados os dados históricos referentes à produção diária da cervejaria, os quais são medidos com base na quantidade (em hectolitros) de cerveja e chope envasada no dia.

A escolha por tais dados se justifica pelo fato de que muitos dos indicadores da Empresa A são medidos com base na produção diária, a exemplo da produtividade da cervejaria, do consumo de água, energia elétrica e vapor, da eficiência das linhas, das perdas, entre outros. Além do mais, a produção diária é o fator que direciona as atividades da fábrica como um todo, como compra de materiais, gestão de estoques, nível de serviço, programação de manutenções, planejamento financeiro, consumo de água e tratamento de efluentes industriais.

Feito isso, procedeu-se à coleta dos dados relativos ao período de junho de 2015 a outubro de 2019. Faz-se importante ressaltar que nem todas as marcas de

cerveja/chope são produzidas todos os dias, podendo haver longos intervalos entre as diferentes produções de uma mesma marca. Por este motivo, não foram escolhidas marcas específicas de cerveja, mas a produção diária total.

De posse dos dados e por meio da utilização do software Microsoft Office Excel®, foi realizada uma análise inicial dos dados, de forma a identificar o comportamento da série temporal e analisar suas características quanto à tendência, sazonalidade, aleatoriedade e existência de ruídos.

Com base na análise preliminar dos dados e no que foi alinhado com os gestores, decidiu-se por utilizar os dados agrupados em semanas, visto que resultaria em uma quantidade satisfatória de dados (232 semanas), facilitaria a análise por parte dos softwares e teria como saídas (ou resultados) as previsões semanais, o que se mostra importante do ponto de vista estratégico.

O pré-processamento dos dados e a organização dos mesmos forneceu, então, um banco de dados que serviu como recurso tanto para a aplicação dos métodos estatísticos de previsão, como para o treinamento da RNA. Nota-se, pela análise do Gráfico 1, que os dados não apresentam tendência linear, tampouco sazonalidade, e são consideravelmente variáveis de uma semana para a outra. Apesar de grande parte oscilar entre 20.000 e 40.000 hectolitros por semana, existem alguns dados discrepantes com picos de oscilação positivos ou negativos.




Gráfico 1 - Série temporal utilizada no processo preditivo
Fonte: Autoria própria (2019).

Por questões de sigilo empresarial, os dados em estudo foram

transformados, de forma a evitar a divulgação dos dados reais de produção da Empresa A.

3.3.1 Aplicação dos métodos estatísticos

Os modelos de Médias Móveis, Suavização Exponencial e ARIMA foram testados e ajustados para os dados da série temporal por meio da utilização do software Statgraphics®, sendo que a opção por sua utilização se deve ao fato de que este possui versão de avaliação gratuita.

Para todos os modelos testados (Apêndice A), foram utilizados os dados de 220 semanas para treinamento do modelo e os últimos 12 dados para comparação com a previsão fornecida pelo método. A escolha pela previsão de 12 períodos (3 meses) à frente se justifica pelo fato de que a empresa realiza P3M (Planejamento Trimestral) para a grande maioria das suas atividades (como manutenção, orçamentos, compra de matérias primas, programação da produção, disponibilidade de mão-de-obra, custos fixos e variáveis, entre outras).

No caso dos modelos ARIMA, foram testadas diversas configurações, com diferentes parâmetros, utilizando o MSE como critério de seleção. Para a definição do melhor modelo obtido, entre todas as classes de métodos testados, foi realizada a análise do RMSE obtido da comparação entre os dados reais e previstos dentro da amostra.

Além do mais, para a validação do modelo ajustado, procedeu-se à análise dos resíduos por meio dos correlogramas de FAC e FACP, bem como pelo periodograma integrado dos resíduos. Para cada um dos modelos testados, verificou-se a existência de autocorrelação entre os resíduos, sendo que os modelos mais adequados foram aqueles cujos resíduos não apresentaram autocorrelações e oscilaram menos em torno da linha média do periodograma.

3.3.2 Treinamento da Rede Neural Artificial

O treinamento da Rede Neural Artificial foi feito utilizando-se o software Matlab® (versão 2015a), por meio do toolbox. Primeiramente, os dados da série temporal foram separados entre vetor de treinamento e vetor teste. De modo a treinar a RNA, com o objetivo que ela fosse capaz de realizar a previsão desejada e entendesse o comportamento dos dados, estes foram separados em dois vetores: o vetor de entrada, que, em cada uma das linhas, era formado pelos dados de produção de duas semanas consecutivas (semanas 1 e 2, semanas 2 e 3,...), e o vetor de saída, que carregava o dado de produção referente à semana seguinte (semana 3, semana 4,...). Esse procedimento se repetiu até a semana 219, sendo que, assim, o conjunto treinamento foi formado por 217 amostras.

Seguindo a mesma metodologia, constituiu-se o vetor teste, o qual foi formado pelas semanas 219 e 220, 220 e 221 e assim sucessivamente, até a semana 232, de forma a se obter a previsão para os próximos 12 períodos. Faz-se importante salientar que o vetor teste é composto apenas pelas entradas, sendo que as saídas são as próprias previsões fornecidas pela rede neural. Desta forma, este vetor é responsável por não somente fornecer as previsões, mas também indicar a qualidade do treinamento da RNA.

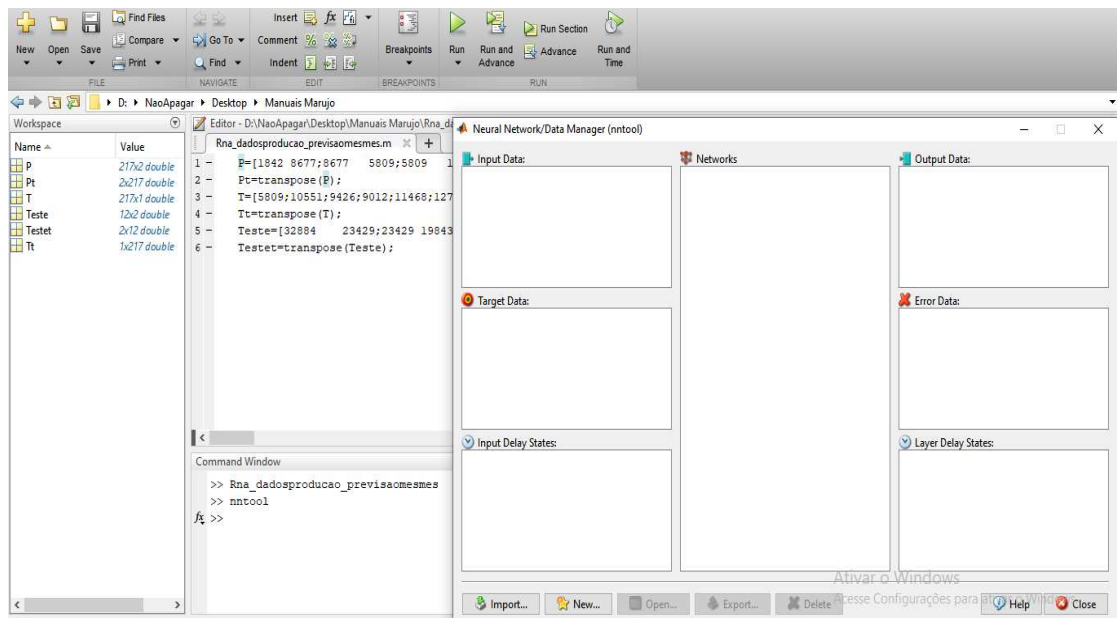


Figura 8 – Inicialização do treinamento da RNA utilizando o toolbox
Fonte: Autoria própria (2019).

Então, procedeu-se à ativação do toolbox para efetuar o treinamento da RNA do tipo MLP. Conforme demonstrado na Figura 8, digitando o comando “nntool”

na janela de comando, foi possível exportar os vetores de treinamento, “Pt” (entradas) e “Tt” (saídas), do workspace para o toolbox.

A criação das RNA's, bem como a escolha de suas topologias e ajuste de parâmetros, foi feita por meio do comando “new”, o qual permitiu configurar as RNA's que foram testadas durante a realização deste trabalho.

Foram testadas diversas funções de ativação nas camadas intermediária (tangente sigmoide e logística) e de saída (função rampa e logística), bem como diferentes algoritmos de treinamento (backpropagation, resilient propagation e Levenberg-Maquardt) e quantidades de neurônios (de dois até 24). Todos os testes propostos foram realizados criando-se novas RNA's através do comando “new” e ajustando-se os parâmetros conforme o vetor teste era exposto a cada um dos modelos projetados. Na Figura 9, ilustra-se a janela de criação de novas arquiteturas de RNA's.

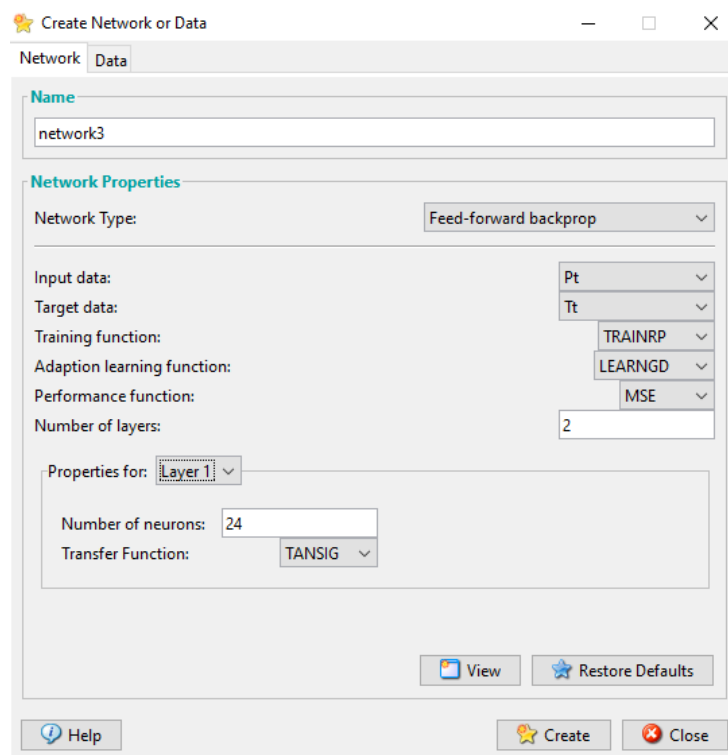


Figura 9 – Definição dos parâmetros da RNA no Matlab
Fonte: Autoria própria (2019).

Em “Network type”, escolhe-se o tipo de rede; nas opções “Input data” e “Target data”, é possível selecionar os vetores de entrada e saída da RNA, respectivamente. No campo “Training function”, seleciona-se o tipo de treinamento desejado (modo como a RNA ajustará os pesos e o bias); em “Adaption learning

function”, escolhe-se o algoritmo de aprendizagem (que define como o erro será tratado no treinamento); já em “Performance function”, determina-se o critério para cálculo do erro durante o treinamento.

O número de camadas da RNA pode ser estipulado no campo “Number of layers” e depende da aplicação para a qual ela se destina. Em “Properties for”, escolhe-se em qual camada da RNA se deseja fazer alterações na quantidade de neurônios (“Number of neurons”) e na função de ativação (“Transfer Function”). Após definidos estes parâmetros, basta clicar em “Create” para que a RNA seja criada.

Após criada a RNA, efetuou-se o seu treinamento, definindo como entrada o vetor teste. Então, as saídas (ou previsões) fornecidas pelo modelo apareceram no campo “*Output Data*” (Figura 8) e foram posteriormente utilizadas para comparar com os valores reais de produção semanal. Os resultados obtidos das diferentes configurações de RNA’s treinadas estão apresentados no Apêndice B.

3.3.3 Comparação entre os modelos estatísticos e a RNA

Com a finalidade de comparar os modelos estatísticos e a RNA, calculou-se o RMSE fora da amostra, ou seja, entre os dados reais de produção e as previsões fornecidas pelos modelos, ambos referentes às semanas 221 a 232.

Definiu-se, portanto, que o modelo que apresentasse menor RMSE seria considerado o mais ajustado à série temporal dos dados e, conseqüentemente, mais indicado para o processo preditivo, uma vez que apresenta maior assertividade em seus resultados.

4 RESULTADOS E DISCUSSÃO

4.1 MÉTODO DE MÉDIAS MÓVEIS

O melhor modelo de Médias Móveis obtido por meio do Statgraphics® foi o de dois termos. Assim, de forma a verificar o ajuste deste aos dados, primeiramente foram analisados os resíduos, por meio dos correlogramas de FAC e FACP, apresentados nas Figuras 10 e 11.




Figura 10 – Correlograma da FAC dos resíduos para o método de Médias Móveis
Fonte: Autoria própria (2019).




Figura 11 – Correlograma da FACP dos resíduos para o método de Médias Móveis
Fonte: Autoria própria (2019).

Nota-se que, neste caso, existem coeficientes de autocorrelação fora do intervalo de confiança, o que indica que possíveis parâmetros da série temporal não foram capturados pelo modelo.

Além disso, analisou-se o periodograma integrado dos resíduos (Figura 12), o qual demonstra que estes não se comportam como ruídos brancos, ou seja, podem apresentar autocorrelação.

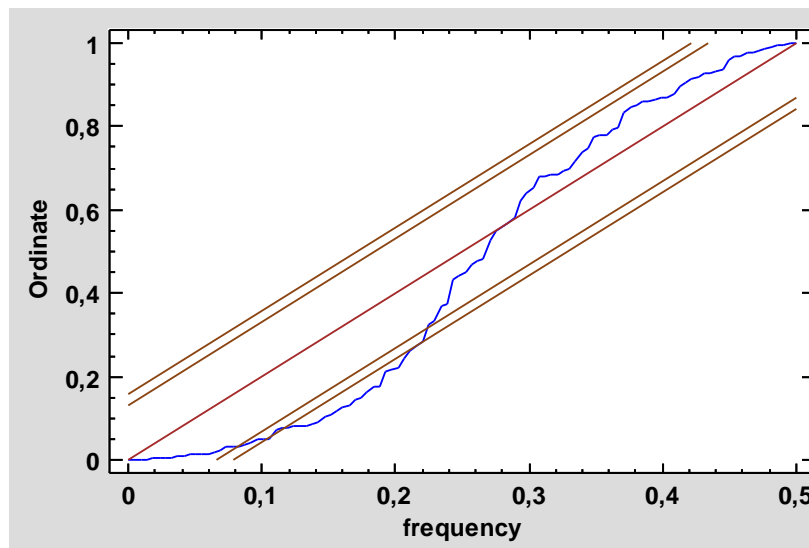


Figura 12 – Periodograma integrado dos resíduos para o método de Médias Móveis

Fonte: Autoria própria (2019).

A análise dos correlogramas de FAC e FACP, bem como do periodograma integrado dos resíduos, permite inferir que o modelo de Médias Móveis não apresenta um bom ajuste aos dados, não sendo, portanto, confiável para a realização das previsões desejadas.

4.2 MÉTODO DA SUAUIZACÃO EXPONENCIAL

Utilizando-se o MSE como critério de seleção, obteve-se o modelo de Suavização Exponencial Simples (SES) com $\alpha = 0,2277$ como o melhor modelo deste método para a série temporal em estudo, uma vez que apresentou menor RMSE nas previsões dentro da amostra.

A análise dos correlogramas de FAC e FACP (Figuras 13 e 14) permitem

verificar que não existem coeficientes de autocorrelação fora dos intervalos de aceitabilidade. Logo, assume-se que todos os parâmetros da série temporal foram capturados pelo modelo e que este apresenta um bom ajuste aos dados.




Figura 13 – Correlograma da FAC dos resíduos para o método de Suavização Exponencial Simples
Fonte: Aatoria própria (2019).




Figura 14 – Correlograma da FACP dos resíduos para o método de Suavização Exponencial Simples
Fonte: Aatoria própria (2019).

O periodograma integrado dos resíduos (Figura 15) demonstra que não existem desvios sistemáticos da reta e que esta permanece dentro dos limites de aceitabilidade. Assim sendo, pode-se confirmar que os resíduos se comportam como ruídos brancos e não possuem autocorrelação, ou seja, possuem distribuição normal e são independentes e identicamente distribuídos (i.i.d.).




Figura 15 – Periodograma integrado dos resíduos para o método de Suavização Exponencial Simples
Fonte: Autoria própria (2019).

O Gráfico 2 apresenta os pontos (em azul) referentes aos dados reais da série temporal e a curva característica (em vermelho) das previsões realizadas pelo modelo de Suavização Exponencial testado, para valores de dentro da amostra. Além disso, demonstra a curva das previsões realizadas para os doze períodos à frente, com um intervalo de confiança de 95%.




Gráfico 2 – Comparação entre os dados históricos de produção e as previsões obtidas pelo método de Suavização Exponencial
Fonte: Autoria própria (2019).

A Tabela 1 apresenta os valores reais e previstos referentes às semanas 221 a 232, bem como o limite inferior (LI) e o limite superior (LS) de controle, e os erros percentuais absolutos.

Tabela 1 – Resultados obtidos pelo método de Suavização Exponencial Simples

Semana	Valores reais	Valores previstos	LI	LS	Erro Percentual Absoluto
221	19843	26735,6	13615,9	39855,2	35%
222	32114	26735,6	13280,1	40191	17%
223	21904	26735,6	12952,5	40518,6	22%
224	19111	26735,6	12632,5	40838,6	40%
225	29961	26735,6	12319,6	41151,6	11%
226	32318	26735,6	12013,3	41457,8	17%
227	20941	26735,6	11713,3	41757,8	28%
228	33441	26735,6	11419,1	42052	20%
229	39827	26735,6	11130,5	42340,6	33%
230	34379	26735,6	10847,1	42624	22%
231	30603	26735,6	10568,7	42902,4	13%
232	42100	26735,6	10295,1	43176,1	36%

Fonte: Autoria própria (2019).

O Gráfico 3 apresenta a curva real (em azul) dos dados históricos de produção entre as semanas 221 e 232, bem como a curva (em laranja) da previsão fornecida pelo modelo de Suavização Exponencial para o mesmo período.




Gráfico 3 – Comparação entre a produção real e prevista pelo método de Suavização Exponencial

Fonte: Autoria própria (2019).

Considerando que o método da Suavização Exponencial Simples apresentou elevados erros percentuais absolutos e forneceu como previsão de

produção um valor constante, pode-se inferir que, provavelmente, este método não conseguiu compreender o comportamento dos dados históricos e, assim, não apresentou um bom ajuste a estes, o que resultou em uma previsão insatisfatória.

4.3 MODELO DE BOX-JENKINS

Dentre os diversos modelos de Box-Jenkins testados, o que apresentou menor RMSE para os valores internos à amostra foi o ARIMA (2,1,6), o qual é composto por dois parâmetros autorregressivos, uma diferenciação e seis parâmetros de médias móveis. Para a validação deste, primeiramente foram analisados os resíduos, por meio dos correlogramas de FAC e FACP, apresentados nas Figuras 16 e 17, de forma a verificar o ajuste do modelo aos dados.




Figura 16 – Correlograma da FAC dos resíduos para o modelo ARIMA (2,1,6)
Fonte: Autoria própria (2019).




Figura 17 – Correlograma da FACP dos resíduos para o modelo ARIMA (2,1,6)
Fonte: Autoria própria (2019).

Os correlogramas de FAC e FACP permitem verificar que não há coeficientes de autocorrelação fora do intervalo, o que indica que não existem parâmetros da série temporal que deixaram de ser capturados pelo modelo, demonstrando, portanto, um bom ajuste deste aos dados.

Além disso, analisou-se o periodograma integrado dos resíduos (Figura 18), o qual demonstra que estes se comportam como ruídos brancos (possuem distribuição normal, são independentes e identicamente distribuídos (i.i.d.) e não apresentam autocorrelações), indicando também um bom ajuste do modelo.




Figura 18 – Periodograma integrado dos resíduos para o modelo ARIMA (2,1,6)
Fonte: Autoria própria (2019).

O Gráfico 4 apresenta um comparativo entre os valores históricos de

produção, representados pelos pontos em azul, e aqueles obtidos na previsão pela metodologia de Box-Jenkins (linha vermelha), em toda a amostra. Ainda, demonstra a curva das previsões realizadas para os doze períodos à frente, com um intervalo de confiança de 95%.




Gráfico 4 – Comparação entre os dados históricos de produção e as previsões obtidas utilizando a metodologia de Box-Jenkins
 Fonte: A autoria própria (2019).

A Tabela 2 apresenta os valores reais e previstos referente às semanas 221 a 232, bem como os limites de controle e os erros percentuais absolutos.

Tabela 2 – Resultados obtidos pelo modelo ARIMA (2,1,6)

Semana	Valores reais	Valores previstos	LI	LS	Erro Percentual Absoluto
221	19843	26416,8	13079,2	39754,4	33%
222	32114	29303,5	15587	43020,1	9%
223	21904	27628	13769,6	41486,4	26%
224	19111	27934,9	13609,4	42260,5	46%
225	29961	27142,8	12298	41987,6	9%
226	32318	28242,1	12858	43626,2	13%
227	20941	28195,9	12643	43748,9	35%
228	33441	28079,2	12267,4	43890,9	16%
229	39827	28266,3	12156,5	44376,1	29%
230	34379	28366,8	12004,1	44729,6	17%
231	30603	28422,7	11807,9	45037,6	7%
232	42100	28515	11643,7	45386,4	32%

Fonte: A autoria própria (2019).

O Gráfico 5, por sua vez, apresenta a curva real (em azul) dos dados históricos de produção entre as semanas 221 e 232, bem como a curva (em vermelho) da previsão fornecida pelo modelo de Box-Jenkins para o mesmo período.

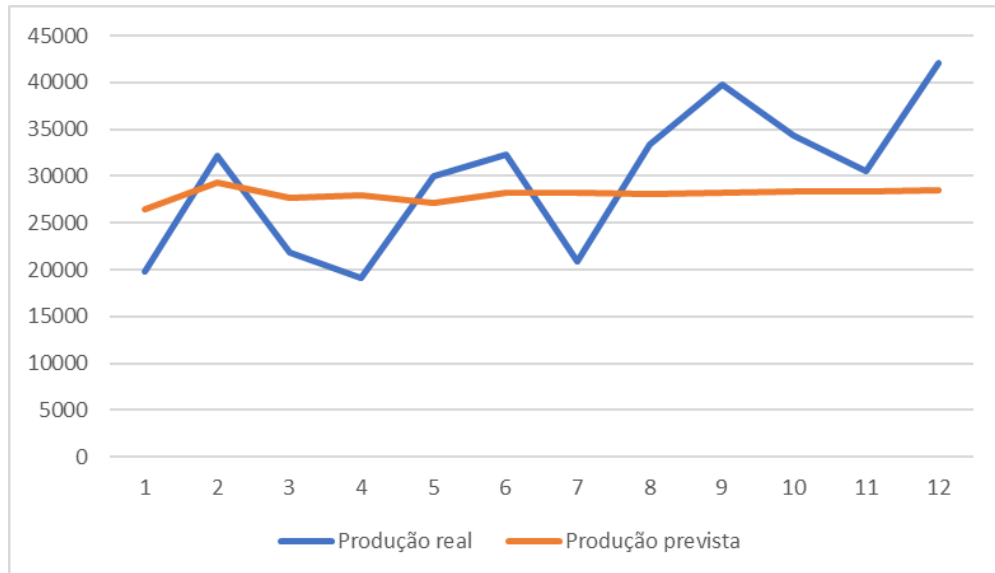


Gráfico 5 – Comparação entre a produção real e prevista pelo modelo ARIMA (2,1,6)
Fonte: Autoria própria (2019).

A análise dos gráficos e tabelas anteriores permite perceber que o modelo de previsão obtido pela metodologia de Box-Jenkins apresentou, em geral, menores erros percentuais absolutos do que o modelo de SES. Além disso, o modelo ARIMA (2,1,6) não forneceu um valor constante de previsão, no entanto, apresentou pequenas variações nos valores de saída, os quais permaneceram próximos a um valor médio.

Desta forma, nota-se que, ainda que o modelo ARIMA (2,1,6) tenha se mostrado ajustado aos dados e que não possua autocorrelações residuais, as previsões de produção semanal fornecidas por ele não representam com satisfatória acuracidade a realidade dos dados.

4.4 REDE NEURAL ARTIFICIAL

Após testar diferentes configurações de RNA's, definiu-se que seria utilizada a seguinte arquitetura: uma RNA do tipo MLP com uma camada de entrada

com duas entradas, uma camada oculta com 24 neurônios e uma camada de saída com uma saída, conforme demonstrado na Figura 19.




Figura 19 – Arquitetura da RNA utilizada
Fonte: Autoria própria (2019).

Além disso, optou-se pela utilização do algoritmo de treinamento Resilient Propagation e da função de aprendizagem LearnGD (Gradiente Decrescente). Na camada oculta, utilizou-se a função TANSIG (Tangente Sigmoide), uma vez que esta se ajustou melhor aos dados do que a função Logística, que também é do tipo diferenciável. Na camada de saída, optou-se pela função linear, pois, além de ser habitualmente utilizada nesta camada, foi a que melhor representou o comportamento dos dados. Também na RNA, o MSE foi utilizado como critério de avaliação do erro durante o treinamento.

Por fim, foram definidos dois critérios de parada: o mínimo gradiente ($1e^{-0,5}$) e o número de épocas (4000 épocas). Estes valores foram escolhidos devido a otimizarem a resolução do problema. Dessa forma, caso o algoritmo atingisse o valor do mínimo gradiente ou ultrapassasse 4000 épocas, o processo seria parado e o treinamento finalizado.

A Tabela 3 apresenta os valores de produção semanal previstos (saídas) pela RNA para os 12 períodos estipulados no vetor teste (semanas 221 a 232), bem como uma comparação destes com os valores reais por meio do erro percentual absoluto. Ressalta-se que, para facilitar a operacionalização da RNA no Matlab®, os valores foram arredondados.

Já o Gráfico 6 apresenta uma comparação entre os valores reais de produção (em azul) e as previsões (em laranja) fornecidas pela RNA para as semanas 221 a 232.

Tabela 3 – Resultados obtidos pela Rede Neural Artificial

Semana	Valores reais	Valores previstos	Erro Percentual Absoluto
221	19843	24872	25%
222	32114	28902	10%
223	21904	33129	51%
224	19111	24168	26%
225	29961	28993	3%
226	32318	32115	1%
227	20941	32079	53%
228	33441	24724	26%
229	39827	33172	17%
230	34379	36016	5%
231	30603	31293	2%
232	42100	33528	20%

Fonte: Autoria própria (2019).




Gráfico 6 – Comparação entre a produção real e prevista pela RNA

Fonte: Autoria própria (2019).

Faz-se possível perceber que as previsões de produção fornecidas pela rede neural foram variáveis e se assemelharam mais aos valores reais do que os demais métodos, o que pode ser verificado pelo fato de que a curva das previsões se aproxima da curva original dos dados. Verificado o ajuste da RNA à série temporal dos dados, pode-se concluir que esta forneceu uma previsão mais assertiva que os demais métodos.

4.5 COMPARAÇÃO ENTRE OS MÉTODOS ESTATÍSTICOS E A RNA

Para comparar os modelos apresentados anteriormente no que diz respeito à qualidade das previsões e ao ajuste aos dados históricos, elaborou-se a Tabela 4, na qual são apresentadas as previsões fornecidas por cada um dos métodos e o RMSE calculado entre os dados reais e previstos nos 12 períodos em análise (fora da amostra de treinamento).

Tabela 4 – Comparação da previsão obtida pelos diferentes modelos

Semana	Valores reais	SES	ARIMA (2,1,6)	RNA
221	19843	26735,6	26416,8	24872
222	32114	26735,6	29303,5	28902
223	21904	26735,6	27628	33129
224	19111	26735,6	27934,9	24168
225	29961	26735,6	27142,8	28993
226	32318	26735,6	28242,1	32115
227	20941	26735,6	28195,9	32079
228	33441	26735,6	28079,2	24724
229	39827	26735,6	28266,3	33172
230	34379	26735,6	28366,8	36016
231	30603	26735,6	28422,7	31293
232	42100	26735,6	28515	33528
RMSE		7952,2	7227,1	6513,5

Fonte: Autoria própria (2019).

O Gráfico 7 apresenta as curvas características das previsões fornecidas pelos modelos testados (SES em laranja, ARIMA em cinza e RNA em amarelo), bem como a curva dos dados reais da série temporal no período previsto (os quais foram utilizados para fins comparativos).

Nota-se que, ainda que tenham sido considerados ajustados à série temporal dos dados, os modelos estatísticos (SES e ARIMA) não conseguiram prever com acuracidade a produção semanal referente às semanas 221 a 232, uma vez que forneceram valores constantes ou próximos a um valor médio e apresentaram elevados erros percentuais absolutos. Em contrapartida, estes erros foram menores nas previsões fornecidas pela RNA, podendo-se verificar melhor ajuste desse modelo aos dados, o que resultou em uma previsão mais assertiva.

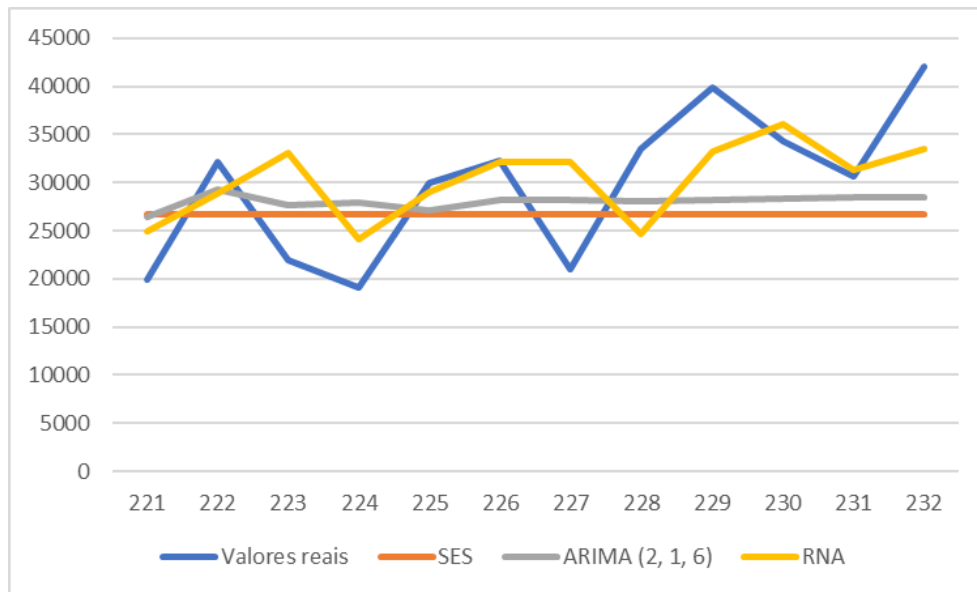


Gráfico 7 – Comparação entre os dados reais e as previsões fornecidas pelos modelos testados

Fonte: Autoria própria (2019).

O Gráfico 7 demonstra que a curva de resposta da RNA tentou acompanhar o comportamento da curva dos dados reais, ao passo que os métodos matemáticos forneceram previsões conservadoras. Por fim, o RMSE calculado para cada um dos modelos (Tabela 4) também contribuiu para confirmar o melhor desempenho da RNA no processo preditivo, motivo pelo qual esta é recomendada para embasar os processos de planejamento da produção na empresa em estudo.

5 CONCLUSÃO

Desde os tempos remotos, o ser humano busca antever certos fenômenos com o intuito de se precaver e planejar antecipadamente suas decisões. Atualmente, isso se mostra fortemente presente no segmento industrial, uma vez que, diante do dinamismo econômico e da acirrada concorrência a nível mundial, as organizações precisam programar suas atividades de maneira a manter a competitividade e sustentar seus lucros por meio de uma performance satisfatória. Neste sentido, os procedimentos formais de previsão utilizando dados históricos, como os modelos matemáticos e de Inteligência Artificial, têm se mostrado importantes ferramentas de suporte gerencial na tomada de decisões.

De maneira geral, pode-se afirmar que este trabalho conseguiu realizar todos os objetivos propostos. Primeiramente, foi apresentada uma base teórica acerca da importância das previsões para o planejamento e controle da produção, bem como os métodos de previsão de séries temporais e como as Redes Neurais Artificiais podem ser utilizadas em processos preditivos deste gênero.

Em seguida, apresentou-se o modo como a pesquisa foi realizada, desde a empresa colaboradora, até os procedimentos de análise e tratamento dos dados, e a aplicação dos métodos propostos. Por fim, foi possível obter a previsão de produção para três meses à frente a partir dos dados históricos de produção da Empresa A, por meio da aplicação de métodos estatísticos e do treinamento de uma Rede Neural Artificial.

A aplicação do método de Médias Móveis para a série temporal utilizada evidenciou que este não se ajustou bem aos dados, não sendo possível, portanto, obter previsões utilizando este método. Além disso, pode-se verificar que, ainda que alguns métodos apresentaram bom ajuste à série temporal, não forneceram previsões assertivas, como foi o caso da Suavização Exponencial Simples e do ARIMA (2,1,6).

Com relação à RNA, é possível confirmar que esta apresentou superioridade na capacidade de previsão para a série temporal em estudo, se comparada aos métodos estatísticos convencionais apresentados, uma vez que apresentou menor RMSE calculado sobre os valores previstos. Esta constatação também foi obtida por Jacobs (2011) ao utilizar modelos de Suavização Exponencial, Box-Jenkins e RNA para prever a demanda de dois produtos de uma empresa,

concluindo que o último método apresentou melhor capacidade preditiva em relação aos outros dois; e por Figueredo (2008), que também verificou superioridade da RNA em relação ao modelo de Box-Jenkins ao utilizá-los na previsão de uma série temporal para a inicialização de planejamento e controle da produção de uma empresa.

Ainda que a RNA tenha se mostrado mais eficiente que os demais métodos, esperava-se que o RMSE das previsões fornecidas por ela fosse ainda menor (o mais próximo de zero possível). O RMSE relativamente alto pode ser justificado pelas características da série temporal e pela quantidade de dados utilizados no treinamento. Sabe-se que, quanto maior a quantidade de dados, a MLP tende a apresentar um treinamento mais completo, o que resulta em uma maior taxa de acerto nas previsões.

Neste sentido, propõe-se, para trabalhos futuros, outros critérios de avaliação do erro e o treinamento de outras topologias e arquiteturas de RNA's e uma organização diferente dos dados da série temporal no vetor de treinamento. Além do mais, sugere-se considerar sazonalidade, bem como alguns fatores externos à produção que possam exercer influência sobre ela.

Em síntese, a realização deste estudo permitiu evidenciar a oportunidade de se demonstrar aos gestores a existência de métodos matemáticos capazes de auxiliar na gestão da produção. Além disso, considerando que a previsão de produção pode se estender para outros segmentos industriais que não o de bebidas, este trabalho contribui para difundir o conhecimento relacionado à literatura de previsões, tanto na esfera acadêmica como empresarial, bem como à aplicabilidade de métodos estatísticos e RNA's na previsão de séries temporais.

REFERÊNCIAS

- ARAÚJO, G. C.; SILVA, J. P. Z. da; SOUZA, L. R.; LOUREIRO, M. B.; FERONI, R. de C. Previsão de demanda e análise simplificada da gestão de estoque aplicada a uma empresa do setor alimentício. **Brazilian Journal Of Production Engineering: Revista Brasileira de Engenharia de Produção**, São Mateus, v. 4, n. 2, p.48-64, ago. 2018. Disponível em: < http://periodicos.ufes.br/BJPE/article/view/v4n2_4/pdf>. Acesso em: 17 mai. 2019.
- ARMSTRONG, J. S.; COLLOPY, F. Error Measures for Generalizing about Forecasting Methods: Empirical Comparisons. **International Journal of Forecasting**. v. 8, n. 1, p. 69-8, 1992.
- ABEPRO - Associação Brasileira de Engenharia de Produção. **A profissão: Saiba mais sobre a Engenharia de Produção**. 2019. Disponível em: <<http://portal.abepro.org.br/a-profissao/#1521896886728-954b63bc-a756>>. Acesso em: 13 maio 2019.
- BONOTTO, G. **Previsão de demanda a partir de métodos quantitativos aplicada ao setor varejista**. 2015. 23 f. TCC (Graduação) - Curso de Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015. Disponível em: <<https://lume.ufrgs.br/bitstream/handle/10183/147496/000999425.pdf?sequence=1&isAllowed=y>>. Acesso em: 17 mar. 2019.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and control**. 4. ed. Hoboken, New Jersey: John Wiley & Sons, Inc., 2008.
- BRAGA, A. de P.; LUDEMIR, T. B.; CARVALHO, A. P. de L. F. de. **Redes Neurais Artificiais: teoria e aplicações**. Rio de Janeiro: LTC, 2000.
- CASULA, H. C. **Aplicação de Técnicas de Previsão de Demanda em Manufatura: estudo de caso em uma indústria de laminados**. Dissertação (Mestrado em Engenharia Mecânica) – Programa de Pós-graduação em Engenharia Mecânica, Faculdade de Engenharia Mecânica, Universidade Estadual de Campinas, Campinas, 2012.
- CAVALHEIRO, D. **Método de previsão de demanda aplicada ao planejamento da produção de indústrias de alimentos**. 2003. 137 f. Dissertação (Mestrado) - Curso de Mestrado em Engenharia Mecânica, Universidade Federal de Santa Catarina, Florianópolis, 2003. Disponível em:

<<https://repositorio.ufsc.br/bitstream/handle/123456789/85516/203135.pdf?sequence=1&isAllowed=y>>. Acesso em: 18 mar. 2019.

CERVIERI JÚNIOR, O. et al. O setor de bebidas no Brasil. **BNDES Setorial**, Rio de Janeiro, v. 40, p.93-130, set. 2014. Disponível em:
<https://web.bndes.gov.br/bib/jspui/bitstream/1408/3462/1/BS%2040%20O%20setor%20de%20bebidas%20no%20Brasil_P.pdf>. Acesso em: 23 out. 2019.

CORNE, D.; DEB, K.; KNOWLES, J.; YAO, X. Selected Applications of Natural Computing. In: ROZENBERG, G.; BACK, T.; KOK, J. N. **Handbook of Natural Computing**. Berlin: Springer-Verlag, 2012.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, Programação e Controle da Produção**. 5. ed. São Paulo: Atlas, 2007.

DE CASTRO, L. N.; VON ZUBEN, F. J. From Biologically Inspired Computing to Natural Computing. In: CASTRO, L. N. de; VON ZUBEN, F. J. **Recent Developments in Biologically Inspired Computing**. Hershey: Idea Group Publishing, 2005.

DORNELAS, R. C. **Previsão de vendas e gestão da demanda de máquinas agrícolas**: proposta de uma abordagem baseada em redes neurais artificiais. 2017. 95 f. Dissertação (Mestrado) – Mestrado em Pesquisa Operacional, Faculdade de Ciências Aplicadas, Universidade Estadual de Campinas, Limeira, 2017.

FERNANDES, F. C. F.; GODINHO FILHO, M. **Planejamento e controle da produção**: dos fundamentos ao essencial. São Paulo: Atlas, 2010.

FIGUEREDO, C. J. **Previsão de Séries Temporais Utilizando a Metodologia Box & Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção**. Dissertação (Mestrado) - Curso de Pós-graduação em Métodos Numéricos em Engenharia, Departamento de Matemática, Universidade Federal do Paraná, Curitiba, 2008.

FLORES, J. H. F.; WERNER, L. Aplicação de Redes Neurais Artificiais à previsão de vendas de máquinas agrícolas. In: XXVII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 2007, Foz do Iguaçu. **Anais eletrônicos do Encontro Nacional de Engenharia de Produção**. Foz do Iguaçu: ABEPRO, 2007. p. 1 - 9. Disponível em:
<http://www.abepro.org.br/biblioteca/ENEGEP2007_TR620466_9360.pdf>. Acesso em: 16 abr. 2019.

GERHARDT, T. E.; SILVEIRA, D. T. **Métodos de Pesquisa**. Porto Alegre: Editora da UFRGS, 2009. 120 p.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 6. ed. São Paulo: Atlas, 2008.

GONÇALVES, P. S. **Logística e cadeia de suprimentos: o essencial**. São Paulo: Manoele, 2013.

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

HAYKIN, S. **Redes Neurais Artificiais: Princípios e prática**. 2. ed. Porto Alegre: Bookman, 2007.

HAYKIN, S. **Neural Networks and Learning Machines**. 3. ed. New Jersey: Pearson Prentice Hall, 2009.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and practices**. 2. ed. Melbourne: Otexts, 2018. Disponível em: <<https://otexts.com/fpp2/>>. Acesso em: 26 mar. 2019.

JACOBS, W. **Modelos de suavização exponencial, ARIMA e redes neurais artificiais: um estudo comparativo para a previsão de demanda de produtos**. 2011. 110 f. TCC (Graduação) - Curso de Engenharia de Produção, Universidade do Vale do Taquari, Lajeado, 2011.

LEMOS, F. O. **Metodologia para Seleção de Métodos de Previsão de Demanda**. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-graduação em Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

MADDALA, G. S. **Introdução à Econometria**. 3. Ed. Rio de Janeiro: LTC, 2003.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: methods and applications**. 3. Ed. New York: John Wiley & Sons, 1998.

MARCHEZAN, A. **Previsão do preço dos principais grãos do Rio Grande do Sul**. Monografia (Especialização em Estatística e Modelagem Quantitativa) – Programa

de Pós-graduação em Estatística e Modelagem Quantitativa, Centro de Ciências Naturais e Exatas, Universidade Federal de Santa Maria, Santa Maria, 2007.

MENTZER, J. T.; MOON, M. A. **Sales Forecasting Management: A Demand Management Approach**. 2. ed. Thousand Oaks: Sage Publications, 2005.

MORABITO, R.; PUREZA, V. Modelagem e simulação. In: MIGUEL, P. A. C. **Metodologia da pesquisa em engenharia de produção e gestão de operações**. 2. ed. Rio de Janeiro: Elsevier, 2012.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Cengage Learning, 2012.

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

MUELLER, A. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. Dissertação (Mestrado em Engenharia de Produção) – Programa de Pós-graduação em Engenharia de Produção, Universidade Federal de Santa Catarina, Florianópolis, 1996.

PELLEGRINI, F. R. **Metodologia para Implementação de Sistemas de Previsão de Demanda**. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-graduação em Engenharia de Produção, Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2. ed. Novo Hamburgo: Feevale, 2013.

SILVA, L. da. **Análise da aplicação do modelo ARIMA: Estudo em uma instituição federal de ensino superior**. 2017. 31 f. TCC (Graduação) - Curso de Engenharia de Produção, Centro de Tecnologia, Universidade Federal de Santa Maria, Santa Maria, 2017.

SILVA, I. N. da; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas: Fundamentos teóricos e aspectos práticos**. 2. ed. São Paulo: Artliber, 2010.

SPIEGEL, M. R. **Estatística**. 3. ed. São Paulo: Pearson Makron Books, 1993.

TURRIONI, J. B.; MELLO, C. H. P. **Metodologia de pesquisa em Engenharia de Produção**: Estratégias, métodos e técnicas para a condução de pesquisas quantitativas e qualitativas. Itajubá: Unifei, 2012.

TUBINO, D. F. **Planejamento e controle da produção**: teoria e prática. São Paulo: Atlas, 2017.

WERNER, L.; LEMOS, F. de O.; DAUDT, T. Previsão de demanda e níveis de estoque: Uma abordagem conjunta aplicada no setor siderúrgico. XIII SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO, 2006, Bauru. **Anais eletrônicos do Simpósio de Engenharia de Produção**. Disponível em: <http://www.simpep.feb.unesp.br/anais/anais_13/artigos/1205.pdf>. Acesso em: 17 mar. 2019.

ZHANG, G.; PATHUO, B. E.; HU, M. y. Forecasting with artificial neural networks: the state of the art. **International Journal of Forecasting**, Ohio, v. 14, n. 1, p.35-62, mar. 1998. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/download?doi=10.1.1.138.4828&rep=rep1&type=pdf>>. Acesso em: 25 abr. 2019.

APÊNDICE A – Modelos Matemáticos Testados

Semana	Valores reais	SES	ARIMA (2, 1, 1)	ARIMA (2, 1, 4)	ARIMA (2, 1, 6)
221	19843	26735,6	25767,6	26417,9	26416,8
222	32114	26735,6	27031,7	27321,1	29303,5
223	21904	26735,6	26594,1	27240,3	27628
224	19111	26735,6	26433,6	27006,4	27934,9
225	29961	26735,6	26510,3	27258,6	27142,8
226	32318	26735,6	26529,2	27371,1	28242,1
227	20941	26735,6	26516,4	27410,8	28195,9
228	33441	26735,6	26514,4	27513	28079,2
229	39827	26735,6	26516,5	27610,8	28266,3
230	34379	26735,6	26516,7	27694,3	28366,8
231	30603	26735,6	26516,3	27784,1	28422,7
232	42100	26735,6	26516,3	27875,3	28515
RMSE		7952,2	7466,8	7390,1	7227,1

APÊNDICE B – Redes Neurais Artificiais Treinadas

Semana	Valores reais	RNA (18 neurônios)	RNA (20 neurônios)	RNA (26 neurônios)	RNA (24 neurônios)
221	19843	28117,2	28694,8	27180,0	24872
222	32114	28834,5	34422,4	32631,1	28902
223	21904	31888,9	29284,0	30792,9	33129
224	19111	26775,1	28792,4	26495,4	24168
225	29961	30585,7	34234,6	33423,0	28993
226	32318	29933,7	27681,3	28752,9	32115
227	20941	30668,0	29814,6	29011,5	32079
228	33441	26262,7	29363,1	25987,3	24724
229	39827	32663,9	29651,5	31004,2	33172
230	34379	36220,5	37408,4	35636,9	36016
231	30603	32373,5	31119,8	31598,4	31293
232	42100	31334,6	33420,6	29083,9	33528
RMSE		6853,2	6802,6	6969,3	6513,5