

DISSERTAÇÃO DE MESTRADO

**REDE NEURAL COM CONHECIMENTO
ESPECIALIZADO PARA PREVISÃO DE
DEMANDA INTERMITENTE**

Por

Alexandre Crepory Abbott de Oliveira

Brasília, 01 de dezembro de 2020.



UNIVERSIDADE DE BRASÍLIA

Faculdade de Tecnologia

DISSERTAÇÃO DE MESTRADO

**REDE NEURAL COM CONHECIMENTO
ESPECIALIZADO PARA PREVISÃO DE
DEMANDA INTERMITENTE**

Alexandre Crepory Abbott de Oliveira

Dissertação submetida ao Departamento de Engenharia Mecânica da Faculdade de Tecnologia da Universidade de Brasília, como requisito parcial para obtenção do grau de Mestre Engenheiro em Sistemas Mecatrônicos.

Banca Examinadora

Profa. Dra. Andrea Cristina dos Santos, EPR/UnB (Orientadora)

Prof. Dr. Geraldo Pereira Rocha Filho, CIC/UnB (Co-Orientador)

Prof. Dr. Li Weigang, CIC/UnB

Prof. Dr. Reinaldo Crispiniano Garcia, EPR/UnB

Brasília, 01 de dezembro de 2020

FICHA CATALOGRÁFICA

OLIVEIRA, ALEXANDRE CREPORY ABBOTT DE OLIVEIRA

Rede Neural com Conhecimento Especializado para Previsão de Demanda Intermitente,

[Distrito Federal] 2020.

xi, 93p., 297 mm (FT/UnB, Mestre Engenheiro, Sistemas Mecatrônicos, 2020).

Dissertação de Mestrado – Universidade de Brasília. Faculdade de Tecnologia.

1.Previsão de Demanda
3.Redes Neurais Artificiais

2.Demanda Intermitente
4. Conhecimento Especializado

I. Sistemas Mecatrônicos/FT/UnB

REFERÊNCIA BIBLIOGRÁFICA

OLIVEIRA, A.C.A., (2020). Rede Neural com Conhecimento Especializado para Previsão de Demanda Intermitente. Dissertação de Mestrado em Sistemas Mecatrônicos, Publicação FT. Faculdade de Tecnologia, Universidade de Brasília, Brasília, DF, 93p.

CESSÃO DE DIREITOS

AUTOR: Alexandre Crepory Abbott de Oliveira.

TÍTULO DA DISSERTAÇÃO DE MESTRADO: Rede Neural com Conhecimento Especializado para Previsão de Demanda Intermitente.

GRAU: Mestre Engenheiro

ANO: 2020

É concedida à Universidade de Brasília permissão para reproduzir cópias deste Trabalho de Graduação e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor reserva outros direitos de publicação e nenhuma parte deste Trabalho de Graduação pode ser reproduzida sem autorização por escrito do autor.

Alexandre Crepory Abbott de Oliveira

AGRADECIMENTOS

Primeiramente, agradeço a minha orientadora, Prof.^a Andrea Santos, pela oportunidade de desenvolver esse trabalho e por ser um exemplo na docência para mim. Sou muito grato pela nossa amizade, cultivada nesses últimos três anos.

Agradeço, também, ao Prof. Geraldo Pereira que se dispôs a me coorientar, mesmo acabando de chegar na UnB. A sua ajuda na área de aprendizado de máquina foi essencial para este trabalho.

Agradeço à Coordenação de Aperfeiçoamento de Pessoas de Nível Superior (CAPES) pelo apoio financeiro para realizar esta pesquisa.

Agradeço ao Jonatan, Cristiane, Liliane, Antônio e Arthur pelo auxílio no estudo de caso e por me inspirarem com o seu comprometimento e profissionalismo.

Agradeço à equipe do Laboratório Aberto de Brasília e do Projeto Vida 2020 que me apoiaram na reta final do mestrado e me mostraram que mesmo nos momentos mais adversos, somos capazes de se juntar e ajudar o próximo.

Agradeço aos meus amigos e ex-sócios Giordano, Rodrigo, Buzz e Arthur que, através da nossa experiência com a LUA, me deram a maturidade para lidar com esse projeto e com a vida profissional.

Agradeço às minhas amigas Bela, Gabi e Mel que me acompanham há mais de 13 anos e que sempre acreditaram no meu potencial.

Agradeço à minha família por me mostrar a importância da educação e por me permitir seguir esse caminho. Agradeço ao meu irmão, Bruno, meu companheiro de todas as horas. Agradeço ao meu pai, Carlos, pelo incentivo constante. Agradeço a minha mãe, Nora, por fazer o que poucas fazem, como ela mesmo diz.

Por fim, agradeço à minha “partner” nesse mestrado, Jéssica. Sem o seu apoio e incentivo nos momentos difíceis durante projeto, eu não estaria aqui.

Alexandre Crepory Abbott de Oliveira.

RESUMO

A exatidão da previsão de demanda é essencial para um controle de estoque eficaz, visto que erros na previsão podem resultar em estoques excessivos ou na falta de material. Dentro dos tipos de previsão de demanda, destaca-se a intermitente, em que ocorre diversas demandas nulas. Os métodos de previsão mais utilizados para esse tipo de demanda se baseiam apenas no histórico da demanda, ignorando a sua causa. Dessa forma, este trabalho documenta a implementação de uma rede neural artificial com conhecimento especialista para demanda intermitente em uma empresa de manutenção, reparo e revisão. A pesquisa seguiu as cinco primeiras etapas da metodologia do CRISP-DM: Entendimento do Negócio, Entendimento dos Dados, Preparação dos Dados, Modelagem e Avaliação. As informações consideradas importantes para o comportamento da demanda foram convertidas em variáveis para a rede neural. Para avaliar o desempenho da rede neural proposta, esta foi comparada a onze métodos de previsão em relação a três medidas de exatidão. E para avaliar o impacto da rede no controle de estoque, foi desenvolvido um simulador de estoque a partir das informações da empresa. Os resultados mostraram que as redes neurais apresentam os menores erros absolutos na previsão de demanda e que tendem a subdimensionar a previsão. Essa tendência de subdimensionamento resulta em níveis de serviços e estoque médios menores e em custos de estoque maiores.

Palavras-Chave: Previsão de demanda; Demanda intermitente; Rede neural artificial; Conhecimento especializado.

ABSTRACT

The accuracy of demand forecasting is essential for an effective inventory control, as errors in forecasting can result in excessive stocks or a lack of material. Within the types of demand forecast, the intermittent one stands out, in which there are several null demands. The most used forecasting methods for this type of demand are based only on the history of the demand, ignoring its cause. Thus, this work documents the implementation of an artificial neural network with specialist knowledge for intermittent demand in a maintenance, repair, and overhaul company. The research followed the first five steps of the CRISP-DM methodology: Business Understanding, Data Understanding, Data Preparation, Modeling and Evaluation. The information considered important for the demand behavior was converted into variables for the neural network. To evaluate the performance of the proposed neural network, it was compared to eleven forecasting methods in relation to three measures of accuracy. And to assess the network's impact on inventory control, a stock simulator was developed based on company information. The results showed that neural networks have the smallest absolute errors in the demand forecast and that they tend to underestimate the forecast. This downsizing trend results in lower average service and inventory levels, and higher inventory costs.

Keywords: Demand forecasting; Intermittent demand; Artificial neural network; Specialized knowledge.

SUMÁRIO

1	INTRODUÇÃO	1
1.1	OBJETIVO	2
1.1.1	Objetivo Geral.....	2
1.1.2	Objetivos Específicos.....	2
1.2	ESTRUTURA DO DOCUMENTO.....	2
2	FUNDAMENTAÇÃO TEÓRICA.....	3
2.1	CONTROLE DE ESTOQUE.....	3
2.1.1	Terminologia.....	3
2.1.2	Políticas de Controle de Estoque	4
2.1.3	Custos de Estoque	5
2.1.3.1	Custos de Pedido.....	7
2.1.3.2	Custos de Armazenagem.....	7
2.1.3.3	Custos de Falta	8
2.1.4	Medidas de Serviço.....	8
2.2	COMPORTAMENTOS DA DEMANDA.....	9
2.3	MÉTODOS DE PREVISÃO	11
2.4	MEDIDAS DE EXATIDÃO	16
2.5	REDES NEURAIS ARTIFICIAIS	20
2.5.1	Neurônio Artificial.....	20
2.5.2	Arquitetura da Rede Neural Artificial	22
2.5.3	Aprendizagem da Arquitetura.....	23
3	METODOLOGIA.....	25
3.1	ENTENDIMENTO DO NEGÓCIO	27
3.2	ENTENDIMENTO DOS DADOS	29
3.3	PREPARAÇÃO DOS DADOS	29
3.4	MODELAGEM	32
3.5	AVALIAÇÃO	32

4	DESENVOLVIMENTO.....	35
4.1	ENTENDIMENTO DO NEGÓCIO	35
4.1.1	Sistema Atual	36
4.1.2	Objetivos Técnicos.....	36
4.2	ENTENDIMENTO DOS DADOS	36
4.3	PREPARAÇÃO DOS DADOS	39
4.3.1	Limpar Dados	39
4.3.2	Construir Dados	40
4.3.3	Integrar Dados.....	41
4.3.4	Formatar Dados.....	41
4.4	MODELAGEM	41
4.4.1	Selecionar Técnica de Modelagem	41
4.4.2	Gerar Desenho de Testes.....	42
4.4.3	Construir e Avaliar o Modelo	43
4.5	AVALIAÇÃO	45
4.5.1	Capacidade de Previsão	45
4.5.1.1	Desenho de Testes.....	45
4.5.1.2	Avaliação dos Resultados	48
4.5.2	Simulação de Controle de Estoque	58
4.5.2.1	Desenho de Testes.....	62
4.5.2.2	Avaliação dos Resultados	63
5	CONSIDERAÇÕES FINAIS.....	72
5.1	CONCLUSÕES	72
5.2	TRABALHOS FUTUROS	73
	REFERÊNCIAS BIBLIOGRÁFICAS	75

LISTA DE FIGURAS

Figura 1. Exemplificação das políticas de controle de estoque - (a) Política (s, Q), (b) Política (s, S), (c) Política (R, S), (d) Política (R, s, S).....	6
Figura 2. Classificação do comportamento da demanda (SYNTETOS; BOYLAN; CROSTON, 2005).	11
Figura 3 - Estrutura de um neurônio artificial (SILVA; SCHIMIDT, 2016).....	21
Figura 4. Rede neural progressiva	22
Figura 5. Rede neural recorrente	23
Figura 6. Algoritmo de <i>backpropagation</i>	24
Figura 7. Metodologia CRISP-DM. Adaptado de (CHAPMAN et al., 2000).	26
Figura 8. Gráfico da distribuição ADI e CV ² da amostra	38
Figura 9. Categorização do comportamento da demanda da amostra.....	39
Figura 10. Configuração dos parâmetros da MLP adotada.....	44
Figura 11. Esquemático da rede neural proposta	45
Figura 12. <i>Box plot</i> dos resultados MAPE para o conjunto amostral	50
Figura 13. <i>Box plot</i> dos resultados MAPE para o conjunto amostral reduzido	50
Figura 14. <i>Box plot</i> dos resultados do ME A para o conjunto amostral reduzido	54
Figura 15. <i>Box plot</i> dos resultados PBt para o conjunto amostral reduzido.....	57
Figura 16. Fluxograma do funcionamento do simulador.....	60
Figura 17. <i>Box plot</i> dos resultados de RR.....	64
Figura 18. Alterações do RR comparada com o método padrão MM12_6.....	66
Figura 19. Alterações do custo de estoque comparada com o método padrão MM12_6.....	69
Figura 20. Alterações do estoque médio comparado com o método padrão MM12_6.....	71

LISTA DE TABELAS

Tabela 1. Resultados de MAPE.....	49
Tabela 2. Média e desvio padrão do MAPE da amostra reduzida	51
Tabela 3. Teste Shapiro-Wilk dos resultados do MAPE	51
Tabela 4. rANOVA do MAPE.....	51
Tabela 5. Correção de Greenhouse e Geisser para MAPE	51
Tabela 6. Resultados do ME A	53
Tabela 7. Teste Shapiro-Wilk dos resultados ME A.....	54
Tabela 8. rANOVA do ME A.....	54
Tabela 9. Correção de Greenhouse e Geisser para ME A.....	55
Tabela 10. Resultados do PBt.....	56
Tabela 11. Teste Shapiro-Wilk dos resultados do PBt	57
Tabela 12. rANOVA do PBt.....	58
Tabela 13. Correção de Greenhouse e Geisser para o PBt.....	58
Tabela 14. Custos de armazenagem em função do volume ocupado pela unidade de compra	61
Tabela 15. Custo de falta em função da criticidade do item	62
Tabela 16. Resultados do RR do simulador.....	63
Tabela 17. Teste Shapiro-Wilk dos resultados ME A.....	64
Tabela 18. rANOVA do RR	64
Tabela 19. Correção de Greenhouse e Geisser para RR	65
Tabela 20. Alteração do RR em relação ao método padrão MM12_6.....	66
Tabela 21. Resultados do custo de estoque do simulador.....	67
Tabela 22. Resultados do custo de estoque do simulador normalizados pelo método MM12_6.....	68
Tabela 23. Custo de estoque total por método e variação percentual em relação ao método de previsão padrão MM12_6.....	69
Tabela 24. Estoque médio por item	70
Tabela 25. Estoque médio dos itens normalizado pelo método padrão MM12_6.....	70

LISTA DE QUADROS

Quadro 1. Medidas de exatidão	17
Quadro 2. Funções de ativação e suas fórmulas	21
Quadro 3. Descrição, importância e implementação das saídas das tarefas do Entendimento do Negócio	28
Quadro 4. Descrição, importância e implementação das saídas das tarefas do Entendimento dos Dados	30
Quadro 5. Descrição, importância e implementação das saídas das tarefas do Preparação dos Dados	31
Quadro 6. Descrição, importância e implementação das saídas das tarefas da Modelagem.....	33
Quadro 7. Descrição, importância e implementação das saídas das tarefas da Avaliação.....	34
Quadro 8. Referência para classificação dos itens segundo criticidade e volume ocupado.....	37
Quadro 9. Classificação dos itens segundo a criticidade e volume ocupado	37
Quadro 10. Resumo do <i>dataset</i> final	42
Quadro 11. Métodos de previsão e seus parâmetros adotados no trabalho.....	47
Quadro 12. Pares de métodos significativamente diferentes de acordo com os resultados MAPE	52
Quadro 13. Pares de métodos significativamente diferentes de acordo com os resultados do ME A ..	55
Quadro 14 Pares de métodos significativamente diferentes de acordo com os resultados PBT	59
Quadro 15. Métodos de previsão selecionados.....	59
Quadro 16. Pares de métodos significativamente diferentes de acordo com os resultados de RR	65

LISTA DE SÍMBOLOS

Símbolos

\hat{y}_t	Previsão de demanda média para o tempo t
CV^2	Coefficiente de variação do tamanho da demanda
\bar{E}	Estoque médio
\bar{I}	Intervalo médio entre demandas
y_t	Demanda real no tempo t
A	Custo fixo de pedido
Q	Quantidade pedida fixa
R	Período de revisão
S	Estoque máximo
s	Ponto de pedido
q	Intervalo real de tempo entre as últimas demandas não-nulas
r	Taxa para manter uma unidade monetária do item por 1 ano
v	Custo do produto
w	Intervalo entre demandas não-nulas
z	Tamanho estimado da demanda
α	Parâmetro de suavização
β	Parâmetro de suavização

Siglas

ANOVA	Análise de Variância
CR	Método de Croston
CREP	Rede Neural proposta nesta pesquisa
CRSIP-DM	<i>Cross-Industry Standard Process for Data Mining</i>

CSL	<i>Cycle Service Level</i>
ED	Entre Demandas
ERP	<i>Enterprise Resources Planning</i> - Planejamento de Recursos Empresariais
FNN	<i>Feedforward Neural Network</i> - Rede Neural Progressiva
FR	<i>Fill Rate</i>
GG	Greenhouse e Geisser
GUT	Rede Neural proposta por Gutierrez; Solis; Mukhopadhyay (2008)
LOL	Rede Neural proposta por Lolli et al. (2017)
MAD	<i>Mean Absolute Deviation</i> - Desvio Absoluto Médio
MAPE	<i>Mean Absolute Percentage Error</i> - Erro Percentual Absoluto Médio
MC	<i>Maintenance Centre</i> - Centro de Manutenção
MdAPE	<i>Median Absolute Percentage Error</i> - Erro Percentual Absoluto Mediano
MdRAE	<i>Median Relative Absolute Error</i> - Erro Absoluto Relativo Mediano
ME	<i>Mean Error</i> - Erro Médio
ME A	<i>Mean Error divided by Average Value</i> - Erro Médio dividido pelo Valor Médio
MLP	<i>Multilayer Perceptron</i>
MRO	<i>Maintenance, Repair and Overhaul</i> - Manutenção, Reparo e Revisão
MSE	<i>Mean Squared Error</i> - Erro Quadrático Médio
MUK	Rede Neural proposta por Mukhopadhyay; Solis; Gutierrez (2012)
OS	<i>Off Site</i> - Em Campo
PB	<i>Percentage Better</i>
PBt	<i>Percentage Best</i>
PCP	Planejamento e Controle da Produção
RAE	<i>Relative Absolute Error</i> - Erro Absoluto Relativo
rANOVA	Análise de Variância com Medidas Repetidas

RC	<i>Repair Centre</i> - Centro de Reparo
RGRMSE	<i>Relative Geometric Root-Mean-Square Error</i> - Raiz Geométrica do Erro Quadrático Médio Relativa
RMSE	<i>Root Mean Squared Error</i> - Raiz do Erro Quadrático Médio
RNA	Rede Neural Artificial
RNN	<i>Recurrent Neural Network</i> - Rede Neural Recorrente
RR	<i>Ready Rate</i>
SBA	<i>Syntetos-Boylan Approximation</i> - Aproximação de Syntetos-Boylan
SES	<i>Single Exponential Smoothing</i> - Amortecimento Exponencial Simples
TSB	Método Teunter-Syntetos-Babai
UD	Última Demanda
UnB	Universidade de Brasília
WEKA	<i>Waikato Environment for Knowledge Analysis</i>
ZS	Zero Seguidos

1 INTRODUÇÃO

A 4ª Revolução Industrial ou Indústria 4.0 é caracterizada pelo processo de transformação digital, viabilizado pelo emprego de tecnologias habilitadoras, tais como *Big Data*, Computação nas Nuvens, Inteligência Artificial, Internet Industrial das Coisas, Segurança Cibernética (LEE; BAGHERI; KAO, 2015; SALKIN et al., 2018).

Um dos principais benefícios da transformação digital é a automatização dos processos de tomada de decisão da empresa (KUMAR et al., 2018). Para obter os melhores resultados da automatização é necessário a sua implementação e integração nos diferentes departamentos da empresa (KUMAR et al., 2018). Essa tarefa é complexa, pois envolve um novo fluxo de coleta e análise dos dados para o processamento de tomada de decisão.

Entre as atividades críticas da indústria, o controle de estoque tem grande destaque, pois garante a entrega de insumos para a produção. Um controle eficiente é essencial para a competitividade da empresa no mercado (SILVER; PYKE; THOMAS, 2017). Uma das atividades associadas ao controle de estoque é a previsão de demanda de insumos, os erros na previsão de demanda podem levar a estoques sobressalentes ou, pior, paradas na linha de produção devido à falta de itens. Devido a sua relevância, diversos métodos de previsão foram propostos ao longo dos anos (SYNTETOS et al., 2010). Entre eles destaca-se a previsão de demanda intermitentes, caracterizada por períodos em que não há demanda (BABAI; SYNTETOS; TEUNTER, 2014). Exemplos de itens com esse comportamento incluem: peças de manutenção de aeronaves, equipamentos elétricos, produtos veterinários, peças de reposição na indústria automotiva (MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012).

Nos últimos anos, redes neurais artificiais (RNA) começaram a ser utilizadas para a previsão de demandas intermitentes, devido a sua flexibilidade de aplicação e a sua capacidade de resolver problemas não-lineares sem a necessidade de ter conhecimento da distribuição estatística dos dados (LOLLI et al., 2017; WIELAND; LEIGHTON, 1987).

Os métodos propostos na literatura se baseiam exclusivamente no comportamento passado da demanda do item para fazer a sua previsão. Consequentemente, não exploram a causa da demanda. A evolução das redes neurais artificiais e a maior disponibilidade de dados, oriunda da digitalização da indústria, nos últimos anos, fornecem um cenário propício para desenvolvimentos nessa área.

1.1 OBJETIVO

1.1.1 Objetivo Geral

Implementar uma rede neural com conhecimento especialista para prever a demanda de itens com comportamento intermitente.

1.1.2 Objetivos Específicos

Neste trabalho, pretende-se atingir os seguintes objetivos específicos:

- Identificar dados que possam ser utilizados como conhecimento especialista pela rede neural;
- Avaliar o impacto do conhecimento especialista na previsão da demanda;
- Avaliar o impacto dos métodos de previsão nos custos de estoque e no desempenho do sistema de controle de estoque.

1.2 ESTRUTURA DO DOCUMENTO

O restante do trabalho é estruturado da seguinte forma:

Capítulo 2 – Fundamentação Teórica: descreve os principais assuntos pertinentes ao trabalho, incluindo políticas de controle de estoque, comportamentos da demanda, métodos de previsão e redes neurais artificiais.

Capítulo 3 – Metodologia: apresenta os procedimentos adotados para o desenvolvimento do trabalho. Neste capítulo, a pesquisa é caracterizada quanto à natureza, aos procedimentos, à abordagem e aos objetivos.

Capítulo 4 – Desenvolvimento: apresenta os resultados do desenvolvimento seguindo a metodologia definida no capítulo anterior. Os resultados obtidos são analisados utilizando ferramentas estatísticas.

Capítulo 5 – Conclusões: expõe as conclusões dos resultados e aponta os trabalhos futuros sobre o tema do projeto.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os conceitos básicos deste trabalho, incluindo, controle de estoque, métodos de previsão de demanda e redes neurais.

2.1 CONTROLE DE ESTOQUE

O controle de estoque tem como objetivo responder as três perguntas a seguir: (SILVER; PYKE; THOMAS, 2017)

- Qual a frequência que se deve avaliar o estado do estoque?
- Quando um pedido de compra deve ser solicitado?
- Qual deve ser o tamanho do pedido?

Para obter as respostas para essas perguntas, deve-se entender o funcionamento da empresa e a sua produção. Para condições determinísticas, as respostas são triviais. No entanto, quando não são, as respostas são mais difíceis de se obterem (SILVER; PYKE; THOMAS, 2017).

A determinação do estado do estoque em diferentes pontos temporais tem um custo maior, incluindo pessoal e computacional. Contudo, como não há certeza sobre as variações do estoque, a frequência de atualização não pode ser muito baixa. Sobre a dúvida de quando fazer o pedido, existe a chance de se pedir cedo demais e ter maiores custos de estoque; e a chance de fazer tarde demais e perder clientes por falta de produto. Para a terceira pergunta, o lote econômico de compra é uma boa estimativa, no entanto, a resposta de quando fazer o pedido pode alterar essa quantidade (SILVER; PYKE; THOMAS, 2017).

2.1.1 Terminologia

Antes de discorrer sobre os diferentes tipos de controle de estoque, é importante definir a nomenclatura referente ao estoque utilizada neste trabalho.

- Estoque disponível – é a quantidade de estoque físico na empresa. É este estoque que atende as demandas dos clientes.

- Estoque líquido – é a quantidade de estoque considerando a quantidade que está faltando para outros pedidos (backorder). Este estoque pode ser negativo.
- Nível de estoque – é a quantidade de estoque considerando as backorders, a quantidade já pedida e que ainda não chegou na empresa. O nível de estoque é o indicador utilizado para ver a necessidade de se fazer um pedido de material.

2.1.2 Políticas de Controle de Estoque

Existem diversas políticas para a gestão do estoque (PORRAS; DEKKER, 2008; SILVER; PYKE; THOMAS, 2017). Elas podem ser classificadas na forma de monitorar o estoque, pela forma em um pedido é gerado e como calcular a quantidade a ser pedida.

Existem duas formas de se monitorar o estoque, continuamente ou periodicamente. Na primeira, o estado do estoque é sempre conhecido pelo sistema. Hoje em dia, essa forma de monitoramento é facilitada pela integração dos bancos de dados e softwares de ERP (*Enterprise Resources Planning* – Planejamento de Recursos Empresariais). No controle periódico, o sistema é avaliado a cada R unidades de tempo.

Com primeira forma de controle é possível obter níveis de estoque menores, uma vez que o estoque de segurança pode ser menor, pois o pedido de compra é feito quando o nível de estoque passa do limite. No entanto, o custo de atualização do estoque para a empresa, em geral, é menor para o controle periódico (SILVER; PYKE; THOMAS, 2017).

Silver, Pyke, Thomas (2017) apresentam quatro políticas mais comuns de controle de estoque e que são adotadas como referência neste trabalho. A primeira política (s, Q) é um sistema de revisão contínua. Uma quantidade fixa (Q) é pedida, quando o nível de estoque é menor ou igual ao ponto de pedido (s) . É considerado o nível de estoque, pois ele considera os pedidos já feitos e que ainda não chegaram. Este sistema é simples de ser implementado no estoque (SILVER; PYKE; THOMAS, 2017). No entanto, se houver uma demanda grande de uma vez, a quantidade fixa pode não ser suficiente para elevar o nível de estoque acima do ponto de pedido (SILVER; PYKE; THOMAS, 2017).

A política (s, S) também possui monitoramento contínuo e ponto de pedido (s) , como a (s, Q) , mas a quantidade a ser pedida não é fixa. A quantidade pedida é a necessária para

e elevar o nível de estoque para o nível máximo (S). Dessa forma, o problema anterior de uma demanda grande é resolvido (SCHNEIDER, 1981). No entanto, achar o ponto ótimo dos parâmetros (s, S) é mais complexo e muitas vezes eles são definidos de forma arbitrária pela empresa (SILVER; PYKE; THOMAS, 2017).

Na política (R, S) , a cada R unidades de tempo é feito um pedido da quantidade necessária para elevar o nível de estoque ao seu nível máximo (S). Este sistema é recomendado para empresas que precisam fazer pedidos de itens relacionados, ou seja, eles serão pedidos em conjunto (SILVER; PYKE; THOMAS, 2017). A desvantagem dessa política é que a quantidade de pedidos tende a ser maior e, conseqüentemente, o custo de pedido também (SILVER; PYKE; THOMAS, 2017).

A quarta política (R, s, S) é a versão periódica da (s, S) . A cada R unidades de tempo, o estado do estoque é atualizado e, caso o nível de estoque esteja abaixo do nível s , é feito um pedido de quantidade suficiente para chegar no nível S . Se $R = 0$, ela é igual a política (s, S) , e, caso $s = S - 1$, ela é idêntica a política (R, S) . Das quatro políticas apresentadas, esta é a que tem maior complexidade no cálculo dos seus valores ótimos (SILVER; PYKE; THOMAS, 2017).

A Figura 1 apresenta um resumo do comportamento das quatro políticas de estoque apresentadas para a mesma demanda. O *lead-time* para a chegada dos pedidos é de 4 unidades de tempo, $R = 4$, $s = 5$, $S = 20$, $Q = S - s = 15$. Dessa forma, é possível observar as particularidades de cada política comentadas anteriormente.

A determinação dos parâmetros ótimos para cada política de controle de estoque depende da métrica utilizada. As principais são relacionadas a minimizar custos de estoque e atingir níveis mínimos de medidas de serviço (SILVER; PYKE; THOMAS, 2017).

2.1.3 Custos de Estoque

Como o estoque afeta diretamente a rentabilidade da empresa, os seus custos devem ser considerados na definição das políticas de controle de estoque e em seus parâmetros (HILLIER; LIEBERMAN, 1995). Existem três principais custos de estoque: custo de pedido, custo de armazenagem e custo de falta.

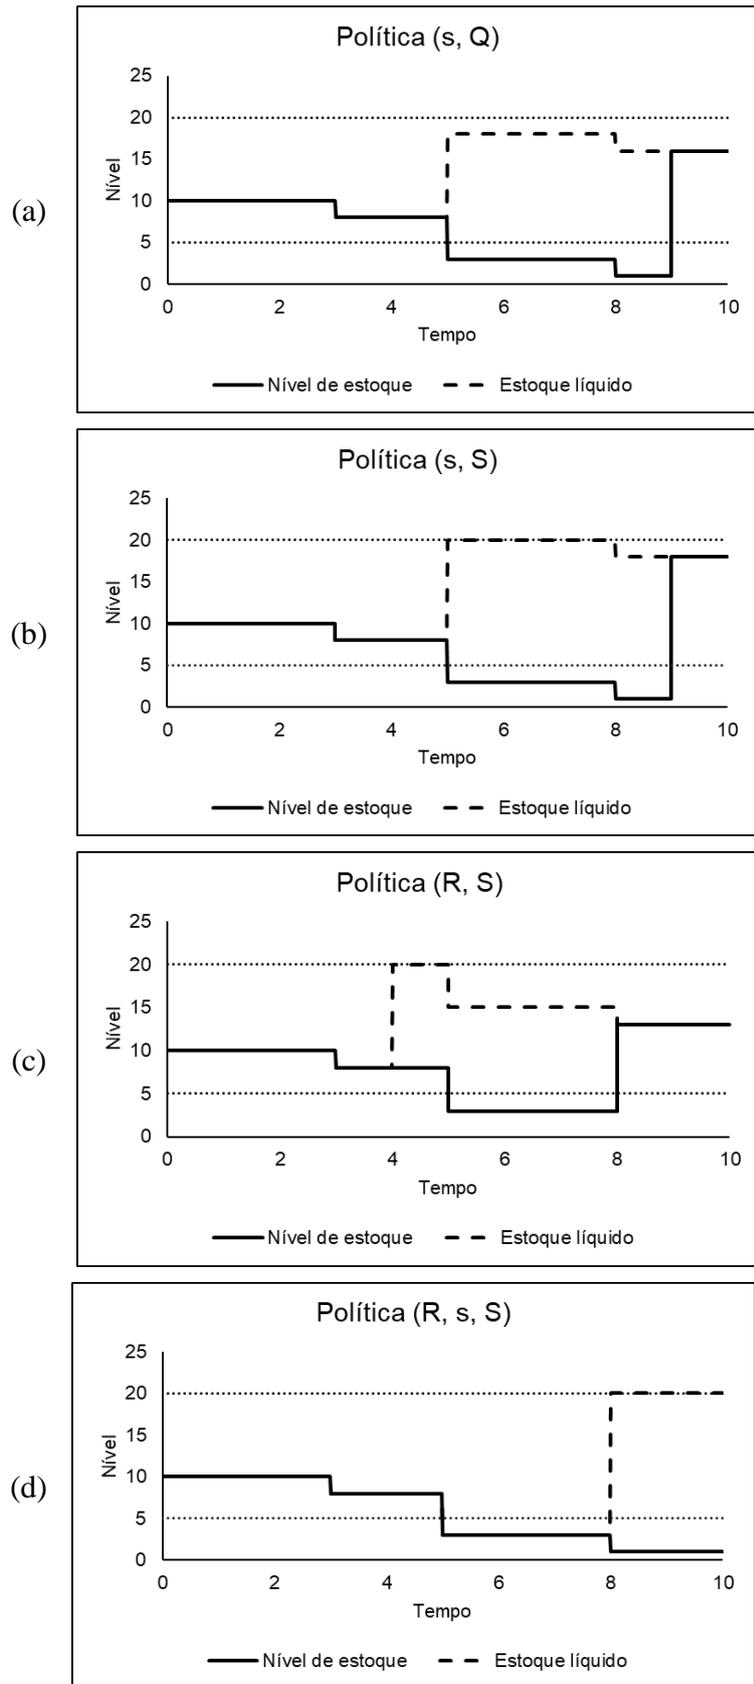


Figura 1. Exemplicação das políticas de controle de estoque - (a) Política (s, Q), (b) Política (s, S), (c) Política (R, S), (d) Política (R, s, S)

2.1.3.1 Custos de Pedido

O custo de pedido compreende os custos de todas as atividades para realizar e acompanhar o pedido de compra, e receber e inspecionar o material (SILVER; PYKE; THOMAS, 2017). Em algumas referências (HILLIER; LIEBERMAN, 1995), o custo de aquisição do item também é considerado.

O cálculo do custo de pedido (Equação 1) é dado pelo custo fixo de pedido (A) multiplicado pela quantidade de pedidos.

$$\text{Custo de Pedido} = A * n^{\circ} \text{ de Pedidos (1)}$$

2.1.3.2 Custos de Armazenagem

O custo de armazenagem é composto por todos os custos associados em manter o item em estoque até que ele seja consumido ou vendido (HILLIER; LIEBERMAN, 1995). Dias (2000) agrupou esses custos em quatro modalidades:

- Custos de capital parado: juros e depreciação;
- Custos com pessoal: salários, encargos sociais e impostos;
- Custos com edificação: aluguel, luz, água, impostos e manutenção;
- Custoso de manutenção: deterioração, obsolescência, equipamento e seguro.

Segundo Silver, Pyke, Thomas (2017), os dois maiores componentes do custo de armazenagem são o custo de oportunidade do capital parado que poderia ser utilizado em outro lugar e o custo de espaço ocupado no estoque.

O custo de armazenagem é proporcional a quantidade do material no estoque e o tempo que ele permanece no estoque (DIAS, 2000). A fórmula utilizada por Silver, Pyke, Thomas (2017) para caracterizar o custo de armazenagem é dada por:

$$\text{Custo de Armazenagem} = \bar{E} * v * r \quad (2)$$

Onde, \bar{E} é o estoque médio em unidades, v é o custo do produto e r é a taxa para manter uma unidade monetária do item por 1 ano.

2.1.3.3 Custos de Falta

O custo da falta ou de demanda não atendida ocorre quando a demanda é superior a quantidade de estoque em mãos. Existem duas possibilidades para esse caso, a perda da venda e o *backorder* (SILVER; PYKE; THOMAS, 2017). Na primeira situação, qualquer demanda que não possa ser atendida será perdida, ou seja, o nível de estoque nunca será negativo. Na segunda situação, o cliente pode esperar até a sua demanda ser atendida e ele não vai desistir dela. Nessa situação, o nível de estoque pode ser negativo. Segundo Silver, Pyke, Thomas (2017), na prática, existe uma combinação das duas situações, uma parte da demanda vai ser perdida e outra vai ser mantida em espera até ser completada.

O custo de falta pode ser calculado a partir da ocorrência de falta no período, a partir da quantidade faltando ou a partir da quantidade de unidades de tempo da falta. A escolha da forma de cálculo depende do contexto da empresa e deve ser analisada caso a caso (SILVER; PYKE; THOMAS, 2017).

2.1.4 Medidas de Serviço

Medidas de serviço são utilizadas para caracterizar o desempenho do sistema de controle de estoque, devido à dificuldade de se calcular com exatidão os custos de estoque (INDERFURTH; MINNER, 1998). Eles são indicadores da ocorrência de falta de material, quantidade faltante e duração da falta de material (SCHNEIDER, 1981).

Segundo Schneider (1981), existem duas medidas de serviço para analisar a ocorrência de falta de material em controles de estoque contínuos. A primeira, denominada nível de serviço α , é a probabilidade de não ocorrer esgotamento de estoque em um período arbitrário. A segunda medida é o nível de serviço α_λ que considera a probabilidade de não ocorrer esgotamento durante o ciclo de recompletamento. Ciclo de recompletamento é o período entre a chegada de dois pedidos de compra. Silver, Pyke, Thomas (2017) denominam essa medida de *Cycle Service Level* (CSL). Schneider (1981) critica o uso do CSL, pois para períodos longos de compra, ele pode ser próximo de zero e não representar o comportamento do estoque.

No contexto de controles de estoque periódicos, para Schneider (1981) não existe diferença entre as duas medidas, pois ambas considerariam o período de revisão como o período de análise. Silver, Pyke, Thomas (2017) não fazem essa distinção e mantêm o seu conceito de CSL considerando o ciclo de recompletamento.

As medidas de serviço nível de serviço β (SCHNEIDER, 1981) e *Fill Rate* (FR) (SILVER; PYKE; THOMAS, 2017) indicam a proporção da demanda atendida imediatamente pelo estoque por unidade de tempo. Essa medida de serviço foi apresentada por Brown (1962) e está relacionada ao custo de falta de material proporcional a quantidade de demanda perdida ou atrasada.

Há casos em que a frequência do esgotamento de estoque ou a quantidade de demanda não atendida não são adequadas para caracterizar o desempenho do controle de estoque. Há casos em que o fator principal é a quantidade de dias em que o item ficou em falta. Schneider (1981) o denomina nível de serviço γ e Silver, Pyke, Thomas (2017), de *Ready Rate* (RR).

2.2 COMPORTAMENTOS DA DEMANDA

A previsão de demanda é um elemento essencial no controle de estoque (HAX; CANDEA, 1984). No entanto, nem todos os itens possuem o mesmo comportamento de demanda e, dessa forma, o método de previsão recomendado também não é o mesmo para todos. Dependendo do tamanho do estoque, não é possível identificar o método ótimo para cada item. Uma opção é categorizar o comportamento da demanda e relacionar o método de estimação mais adequado para cada categoria (SYNTETOS; BOYLAN; CROSTON, 2005).

Poucos métodos de categorização que consideram o comportamento da demanda foram propostos na literatura (SYNTETOS; BOYLAN; CROSTON, 2005). Williams (WILLIAMS, 1984) apresentou uma categorização baseada na decomposição da variância da demanda durante o *lead-time* em três componentes: variabilidade no tamanho da demanda, variabilidade das ocorrências de demanda no tempo e variabilidade do *lead-time*. Essas variáveis são utilizadas para caracterizar o comportamento da demanda em: suave (*smooth*), baixo giro (*slow-moving*), esporádico (*sporadic*) e esporádico com *lead-time* altamente variável (*sporadic, with highly variable lead time*).

Eaves & Kingman (2004) avaliaram a classificação de Williams (1984) em dados de demanda da Royal Air Force, o braço aéreo das forças armadas do Reino Unido, e observaram que não caracterizava adequadamente o comportamento dos dados. A diferenciação do comportamento suave, apenas utilizando a variabilidade da ocorrência da demanda no tempo não era precisa o suficiente. Desta forma, eles propuseram cinco categorias de comportamento: suave (*smooth*), irregular (*irregular*), baixo giro (*slow moving*), intermitente (*mildly intermittent*) e altamente intermitente (*highly intermittent*).

Os dois métodos de classificação adotaram valores arbitrários como limites entre as categorias para se adequar aos dados disponíveis. Desta forma, a generalização desses resultados para outros dados é comprometida (SYNTETOS; BOYLAN; CROSTON, 2005).

Syntetos, Boylan, Croston (2005) apresentaram um método de classificação baseado no intervalo médio entre demandas (\bar{I}) e no quadrado do coeficiente de variação do tamanho da demanda (CV^2). Os autores definiram quatro categorias de comportamento da demanda: suave (*smooth*), errática (*erradic*), intermitente (*intermittent*) e esporádico (*lumpy*). Um comportamento de demanda suave tem baixa variabilidade do tamanho da demanda e poucas demandas nulas. O comportamento errático também possui poucas demandas nulas, mas tem alta variabilidade do tamanho da demanda. Uma demanda com comportamento intermitente tem baixa variabilidade das quantidades das demandas e uma grande quantidade de demandas nulas. O comportamento esporádico tem alta variabilidade no tamanho da demanda e grande quantidade de demandas nulas. Syntetos, Boylan, Croston (2005) validaram os valores limites entre as categorias usando estimadores adequados para cada comportamento. Cada categoria foi associada a um método de previsão adequado ao seu comportamento. A classificação proposta por Syntetos, Boylan, Croston (2005) é mostrada na Figura 2.

Um dos fatores que modificam o comportamento intermitente da demanda é a agregação delas em função do tempo (EAVES; KINGSMAN, 2004). Um item que apresenta comportamento classificado como suave, quando analisado mensalmente, pode ter um comportamento intermitente, quando analisado semanalmente ou diariamente.

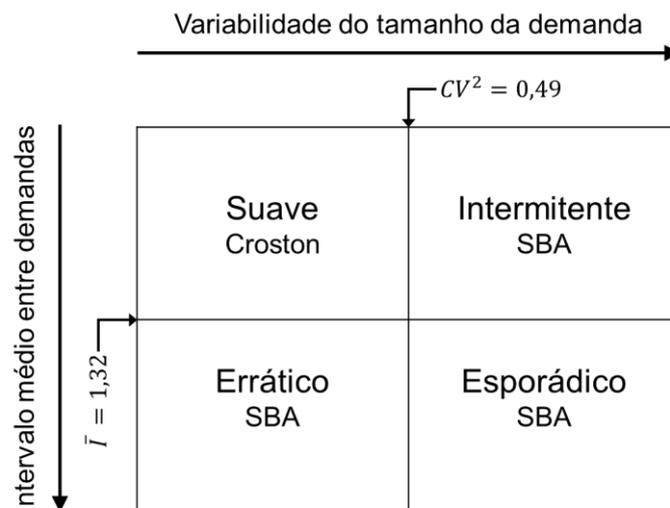


Figura 2. Classificação do comportamento da demanda (SYNTETOS; BOYLAN; CROSTON, 2005).

2.3 MÉTODOS DE PREVISÃO

A previsão da demanda apresenta grandes desafios quando o comportamento é intermitente ou esporádico, seguindo a classificação de Syntetos, Boylan, Croston (2005), porque existe a incerteza da ocorrência da demanda e, ainda, o seu tamanho pode não ser constante (WATSON, 1987). Erros na previsão podem ocasionar grandes perdas por estoque obsoleto ou por demanda não atendida (SYNTETOS; BOYLAN, 2005).

Um dos métodos mais simples de previsão é a média móvel, frequentemente utilizado mesmo para demandas intermitentes (SYNTETOS; BOYLAN, 2005). Existem dois parâmetros para a sua caracterização: quantidade de períodos considerados e sua taxa de atualização.

Outro método comumente utilizado para prever demandas intermitentes é o amortecimento exponencial simples (*single exponential smoothing* - SES) (BROWN, 1962; SYNTETOS; BOYLAN, 2005; WILLEMAIN; SMART; SCHWARZ, 2004). Este método é considerado como o padrão para demanda intermitente segundo Ghobbar & Friend (2003). A Equação 3 apresenta a fórmula para a estimação por SES.

$$\hat{y}_{t+1} = \hat{y}_t + \alpha(y_t - \hat{y}_t) \quad (3)$$

Onde, \hat{y}_{t+1} é a previsão da demanda média para o período $t + 1$, \hat{y}_t é a previsão de demanda média para o tempo t , y_t é a demanda real no tempo t e α é o parâmetro de suavização.

Diversos estudos foram conduzidos sobre o SES e a recomendação para o parâmetro de suavização α é de que ele seja pequeno, próximo de 0,1 a 0,2 (BROWN, 1962).

Devido ao parâmetro de suavização, o SES é robusto contra mudanças no comportamento da demanda. No entanto, Croston (1972) argumenta que, com a intermitência da demanda, os erros aumentam. Isso ocorre porque o SES considera mais a última demanda. Dessa forma, após uma demanda positiva a previsão será maior e depois de uma demanda nula, será menor.

Croston (1972) propôs uma solução para esse viés separando a estimação da ocorrência da demanda, da estimação do tamanho da demanda no período. Para isso, são utilizadas duas SES atualizadas somente quando ocorre uma demanda. O algoritmo de método de Croston (CR) é apresentado a seguir:

Se $y_t = 0$, então

$$z_{t+1} = z_t$$

$$w_{t+1} = w_t$$

$$q = q + 1$$

Se $y_t \neq 0$, então

$$z_{t+1} = z_t + \alpha(y_t - z_t)$$

$$w_{t+1} = w_t + \beta(q - w_t)$$

$$q = 1$$

$$\hat{y}_{t+1} = \frac{z_{t+1}}{w_{t+1}}$$

Onde, z é a tamanho estimado da demanda, w é o intervalo entre demandas não-nulas, y é a demanda real, q é o intervalo real de tempo entre as últimas demandas não-nulas, α e β são parâmetros de suavização e \hat{y} é o valor estimado da demanda.

Para avaliar o seu método, Croston (1972) o implementou em um sistema de controle de estoque e o comparou ao SES em uma simulação com demanda intermitente. O CR obteve

uma confiança de 95% contra escassez e, com o SES, ocorreram faltas em 20% das demandas. Outros estudos corroboram a superioridade do CR sobre o SES (ver (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012)). No entanto, Willemain, Smart, Schwarz, (2004) não conseguiram resultados significativamente diferentes entre os dois métodos para a previsão da demanda durante o *lead time*.

Apesar do CR ser amplamente utilizado em pacotes de softwares de previsão estatística (SYNTETOS; BOYLAN, 2005) e estar implementado em softwares de ERP, como o SAP ERP (TEUNTER; SYNTETOS; BABAI, 2011), seus estimadores são enviesados (SYNTETOS; BOYLAN, 2001). Foi encontrado um erro na derivação matemática da demanda estimada esperada. Considerando que os estimadores do tamanho da demanda e do intervalo da demanda são independentes, então:

$$E\left(\frac{z_t}{w_t}\right) = E(z_t) * E\left(\frac{1}{w_t}\right) \quad (4)$$

No entanto,

$$E\left(\frac{1}{w_t}\right) \neq \frac{1}{E(w_t)} \quad (5)$$

Dessa forma, o estimador é enviesado. Para resolver esse problema, Syntetos & Boylan (2005) quantificaram o viés no método CR e propuseram um estimador de demanda aproximadamente não enviesado, conhecido como Aproximação de Syntetos-Boylan (*Syntetos-Boylan Approximation* - SBA). Ele usa os mesmos SES que o CR, mas modifica a forma de calcular o valor estimado da demanda, como mostra a Equação 6.

$$\hat{y}_{t+1} = \left(1 - \frac{\beta}{2}\right) \frac{z_{t+1}}{w_{t+1}} \quad (6)$$

Estudos comprovaram a superioridade do SBA em relação ao CR e SES em simulações (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008).

Os métodos CR e SBA apenas atualizam o estimador de intervalo entre demandas não-nulas quando ocorre uma demanda diferente de zero. Dessa forma, a previsão pode ter a sua exatidão reduzida após vários períodos com demanda nula. Isso significa que os métodos tem um viés positivo para itens em risco de obsolescência (TEUNTER; SYNTETOS; BABAI, 2011). Para reduzir esse viés, Teunter, Syntetos, Babai (2011) propuseram o método TSB que utiliza a probabilidade da ocorrência da demanda (p) e não

o intervalo entre demandas. A probabilidade da ocorrência da demanda é atualizada a cada período. A forma de estimar o tamanho da demanda é o mesmo de CR e SBA. O seguinte algoritmo descreve o método TSB:

Se $y_t = 0$, então

$$z_{t+1} = z_t$$

$$p_{t+1} = p_t + \beta(0 - p_t)$$

Se $y_t \neq 0$, então

$$z_{t+1} = z_t + \alpha(y_t - z_t)$$

$$p_{t+1} = p_t + \beta(1 - p_t)$$

$$\hat{y}_{t+1} = z_{t+1} * p_{t+1}$$

Recentemente, redes neurais artificiais estão sendo estudadas como uma alternativa para a previsão de demanda intermitente ou esporádica, devido as suas habilidades de identificar relações não lineares entre variáveis sem informação sobre a sua distribuição probabilística (CARMO; RODRIGUES, 2004).

Carmo, Rodrigues (2004) foi o primeiro trabalho com RNAs encontrado com foco em demandas com comportamentos esporádicos. Eles implementaram três redes diferentes para fazer a previsão: rede de função de base radial gaussiana, rede de função de base gaussiana normalizada e rede de função de base elíptica gaussiana. Além disso, dois tipos de saída foram testados: tipo 1 – previsão da demanda futura total para o período; tipo 2 – previsão do tamanho da demanda e do período da próxima demanda. Para a previsão de tipo 1, foi utilizada a rede de função de base radial gaussiana que obteve os melhores resultados quando comparado a outras redes. Para avaliar os resultados do tipo 2 de previsão, foram comparados o método CR e a rede de função de base radial gaussiana. As análises indicaram que a rede neural obteve melhores resultados que o método tradicional, especialmente com seus parâmetros otimizados.

Gutierrez, Solis, Mukhopadhyay (2008) adotaram a *multilayer perceptron* (MLP) treinada por algoritmo de *back-propagation* para fazer a previsão de demanda. A RNA deles possuía 3 camadas: uma camada de entradas, uma camada escondida e uma camada de saída. As variáveis de entrada eram:

- Demanda no final do último período;
- Número de períodos separando as duas últimas demandas não-nulas.

A camada escondida possui três unidades escondidas, segundo Gutierrez, Solis, Mukhopadhyay (2008), suficiente para aproximar a maioria das funções complexas. A camada de saída possui uma unidade que retorna o valor estimado da demanda para o próximo período.

Gutierrez, Solis, Mukhopadhyay (2008) compararam a sua RNA com três métodos tradicionais (SES, CR, SBA), utilizando três medidas de erro diferentes. Os resultados mostraram que a MLP proposta era, geralmente, superior aos métodos tradicionais de previsão. No entanto, se há diferenças significantes entre os dados utilizados para o treinamento e os para teste, os métodos tradicionais têm uma melhora relativa a RNA, pois ao contrário das redes neurais, eles são atualizados a cada novo dado.

Mukhopadhyay, Solis, Gutierrez (2012) propuseram uma nova MLP para previsão de demanda intermitente e esporádica. A sua configuração é similar à de Gutierrez, Solis, Mukhopadhyay (2008). A única diferença é que eles usaram outra entrada. Mukhopadhyay, Solis, Gutierrez (2012) utilizaram o número de demandas nulas em sequência e não o número de períodos, separando as duas últimas demandas não-nulas. Para validar a sua RNA, Mukhopadhyay, Solis, Gutierrez (2012) a compararam com os métodos SES, CR, SBA e média móvel ponderada com pesos otimizados. A rede proposta apresentou os melhores resultados gerais, seguido pela média móvel ponderada.

Lolli *et al* (2017) combinou os trabalhos de Mukhopadhyay, Solis, Gutierrez (2012) e de Gutierrez, Solis, Mukhopadhyay (2008) e propôs uma MLP para prever a demanda intermitente e esporádica. A sua rede neural possui três entradas: a demanda no final do último período, número de demandas nulas em sequência e número de períodos separando as duas últimas demandas não-nulas. Neste trabalho, Lolli *et al* (2017) testaram diferentes configurações de redes neurais, cujos parâmetros testados foram:

- Arquitetura da rede neural: progressiva, com atraso temporal e recorrente;
- Abordagem de aprendizado: back-propagation e *extreme learning machines* (HUANG; ZHU; SIEW, 2006);
- Modo de aprendizado: batelada (*batch*) e online;
- Horizonte de previsão: um, três e cinco períodos.

Lolli *et al* (2017) compararam as diferentes combinações de redes neurais com os métodos CR e SBA e com as redes de Mukhopadhyay, Solis, Gutierrez (2012) e de Gutierrez, Solis, Mukhopadhyay (2008). As RNAs obtiveram melhores resultados que os métodos tradicionais, em especial a de Mukhopadhyay, Solis, Gutierrez (2012), que apresentou o menor viés em todos os horizontes de previsão. Avaliando os resultados em relação à abordagem de aprendizado, o *back-propagation* se mostrou uma abordagem melhor em relação ao erro absoluto e o *extreme learning machines*, que é mais fácil de implementar. Outra conclusão interessante é que o aumento do horizonte de previsão resultou em uma diminuição do erro absoluto das previsões.

2.4 MEDIDAS DE EXATIDÃO

É necessário definir a forma de comparação dos resultados dos métodos de previsão. Para isso são utilizadas as medidas de exatidão que fornecem informações relevantes sobre o comportamento do sistema de previsão. Cada medida produz intuições diferentes e, dessa forma, é de interesse da pesquisa o estudo de diferentes medidas.

O Quadro 1 apresenta as medidas de exatidão utilizadas em diferentes trabalhos, identificadas durante as pesquisas. Além da sua identificação, notação e fórmula, é avaliado se a medida é dependente da escala ou não. A vantagem das medidas não dependentes da escala é que elas podem ser comparadas estatisticamente, pois não são relacionadas a magnitude dos valores observados. No entanto, existem informações apenas disponíveis em medidas com escala. Também são apresentadas observações sobre as medidas.

Quadro 1. Medidas de exatidão

Medida de Exatidão	Notação	Fórmula	Dependente da escala?	Trabalhos que a utilizam	Observação
Erro Médio (Mean Error)	ME	$\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)$	Sim	(SYNTETOS; BOYLAN, 2005; TEUNTER; SYNTETOS; BABAI, 2011)	
Erro Quadrático Médio (Mean Squared Error)	MSE	$\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2$	Sim	(TEUNTER; SYNTETOS; BABAI, 2011; WALLSTRÖM; SEGERSTEDT, 2010; WILLEMAIN et al., 1994)	
Desvio Absoluto Médio (Mean Absolute Deviation)	MAD	$\frac{1}{T} \sum_{t=1}^T \hat{y}_t - y_t $	Sim	(EAVES; KINGSMAN, 2004; WALLSTRÖM; SEGERSTEDT, 2010; WILLEMAIN et al., 1994)	
Erro Percentual Absoluto Médio (Mean Absolute Percentage Error)	MAPE	$\frac{1}{T} \sum_{t=1}^T \frac{ \hat{y}_t - y_t }{y_t}$	Não	(EAVES; KINGSMAN, 2004; GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; LOLLI et al., 2017; MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012; WILLEMAIN et al., 1994)	A segunda fórmula é capaz de lidar com demandas nulas e foi apresentada por Gilliland (2002).
		$\frac{\sum_{t=1}^T \hat{y}_t - y_t }{\sum_{t=1}^T y_t}$			

Continuação

Medida de Exatidão	Notação	Fórmula	Dependente da escala?	Trabalhos que a utilizam	Observação
Erro Percentual Absoluto Mediano (Median Absolute Percentage Error)	MdAPE	Mediana do conjunto $APE = \left\{ \frac{ \hat{y}_t - y_t }{y_t} \mid t \in \mathbf{R}, t \leq T \right\}$	Não	(WILLEMAIN et al., 1994)	Não pode ser utilizado para demandas intermitentes pois não aceita demandas nulas.
Erro Absoluto Relativo (Relative Absolute Error)	RAE	$\frac{ \hat{y}_{A,t} - y_t }{ \hat{y}_{B,t} - y_t }$	Não		
Erro Absoluto Relativo Mediano (Median Relative Absolute Error)	MdRAE	Mediana do conjunto $APE = \left\{ \frac{ \hat{y}_{A,t} - y_t }{ \hat{y}_{B,t} - y_t } \mid t \in \mathbf{R}, t \leq T \right\}$	Não	(MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012)	
Erro Médio dividido pelo Valor Médio (Mean Error divided by Average Value)	ME A	$\frac{\sum_{t=1}^T (\hat{y}_t - y_t)}{\sum_{t=1}^T y_t}$	Não	(LOLLI et al., 2017)	Possibilita analisar o erro médio sem escala.

Continuação

Medida de Exatidão	Notação	Fórmula	Dependente da escala?	Trabalhos que a utilizam	Observação
Percentage Better	PB	Número de vezes que o estimador foi melhor que pelo menos um outro em relação a um critério específico	Não	(SYNTETOS; BOYLAN, 2005)	
Percentage Best	PBt	Número de vezes que o estimador foi o melhor em relação a um critério específico	Não	(GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012; SYNTETOS; BOYLAN, 2005)	
Raiz Geométrica do Erro Quadrático Médio Relativa (Relative Geometric Root-Mean-Square Error)	RGRMSE	$\frac{\sqrt[2T]{\prod_{t=1}^T (\hat{y}_{A,t} - y_{A,t})^2}}{\sqrt[2T]{\prod_{t=1}^T (\hat{y}_{B,t} - y_{B,t})^2}}$	Não	(GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012; SYNTETOS; BOYLAN, 2005)	
Raiz do Erro Quadrático Médio (Root Mean Squared Error)	RMSE	$\sqrt{\frac{1}{T} \sum_{t=1}^T (\hat{y}_t - y_t)^2}$	Sim	(EAVES; KINGSMAN, 2004)	

2.5 REDES NEURAIIS ARTIFICIAIS

As redes neurais artificiais foram projetadas para mimetizar o cérebro humano com o objetivo de emular o desempenho humano em atividades que computadores têm maiores dificuldades (PAL; MITRA, 1992).

Os desenvolvimentos de redes neurais artificiais começaram na década de 1940, com o trabalho de McCulloch e Pitts (1943), em que é apresentado o primeiro modelo algébrico de um neurônio artificial. Rosenblatt (1962) introduziu o procedimento de convergência para um neurônio artificial (*perceptron*), resultando em uma rede de camada única. O *perceptron* tem por objetivo identificar padrões por meio de dados que são utilizados em sua entrada.

É válido frisar, no entanto, que o *perceptron* não é capaz de resolver problemas não linearmente separados (MINSKY; PAPERT, 2017). A adição de uma camada, denominada escondida, entre a camada de entrada e de saída, corrige esta limitação (GROSSBERG, 2012). E dessa forma, criou-se a *multilayer perceptron*, uma das redes neurais mais populares (LOLLI et al., 2017).

2.5.1 Neurônio Artificial

O neurônio artificial, apresentado na Figura 3, é unidade de processamento de informação fundamental para o funcionamento da rede neural, sendo composto por:

- Conjunto de sinapses – são as conexões entre a camada de entrada e neurônios e entre neurônios. Cada sinapse é relacionada a um peso sináptico (w_{kj});
- Somatório – responsável por somar os sinais de entrada ponderados pelos pesos sinápticos no neurônio;
- Função de ativação ($\varphi(\cdot)$) – limita a amplitude do sinal de saída no neurônio;
- Viés (b_k) – é um valor externo que modifica o somatório das entradas ponderadas.
- Saída (y_k) – resultado da função de ativação, sua fórmula é apresentada na Equação 7

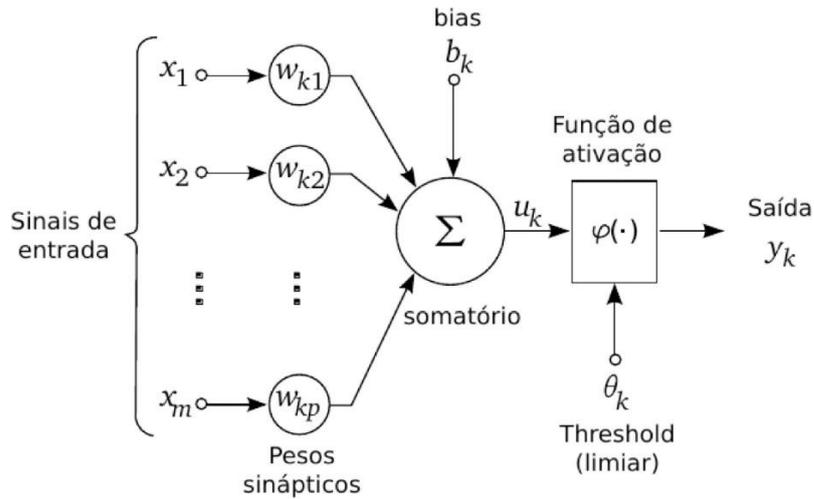


Figura 3 - Estrutura de um neurônio artificial (SILVA; SCHIMIDT, 2016)

$$y_k = \varphi\left(\sum_{j=0}^m w_{kj} \times x_j\right) \quad (7)$$

Considerando $w_{k0} = b_k$ e $x_0 = 1$.

Uma rede neural pode ser modelada usando diferentes funções de ativação, sendo as mais comuns: função de limiar, função sigmoide, função tangente hiperbólica, função de ativação linear retificada e função *softmax*, como apresentado no Quadro 2.

Quadro 2. Funções de ativação e suas fórmulas

Função de ativação	Fórmula
Função de limiar	$\varphi(u_k) = \begin{cases} 1, & \text{se } u_k \geq 0 \\ 0, & \text{se } u_k < 0 \end{cases}$
Função sigmoide	$\varphi(u_k) = \frac{1}{1 + \exp(-au_k)}$
Função de tangente hiperbólica	$\varphi(u_k) = \frac{\sinh(u_k)}{\cosh(u_k)}$
Função de ativação linear retificada	$\varphi(u_k) = \begin{cases} u_k, & \text{se } u_k \geq 0 \\ 0, & \text{se } u_k < 0 \end{cases}$
Função <i>softmax</i>	$\varphi(u_k) = \frac{e^{u_k}}{\sum_j e^{u_j}}$

2.5.2 Arquitetura da Rede Neural Artificial

A arquitetura da rede neural é a forma como os neurônios da rede são conectados. As redes podem ser classificadas segundo a sua arquitetura em redes neurais progressivas (*Feedforward Neural Network* – FNN) e em redes neurais recorrentes (*Recurrent Neural Network* – RNN) (MITCHELL, 1997).

Nas FNNs, os sinais se propagam em apenas uma direção. A Figura 4 exemplifica uma rede neural progressiva, no caso, uma MLP. A MLP é composta por três camadas: de entrada, oculta e de saída. A camada de entrada, a primeira, fornece os sinais de entrada para a rede. Camadas intermediárias ou ocultas são as principais responsáveis pelo processamento das informações a partir dos pesos sinápticos. A camada de saída fornece o resultado da rede neural.

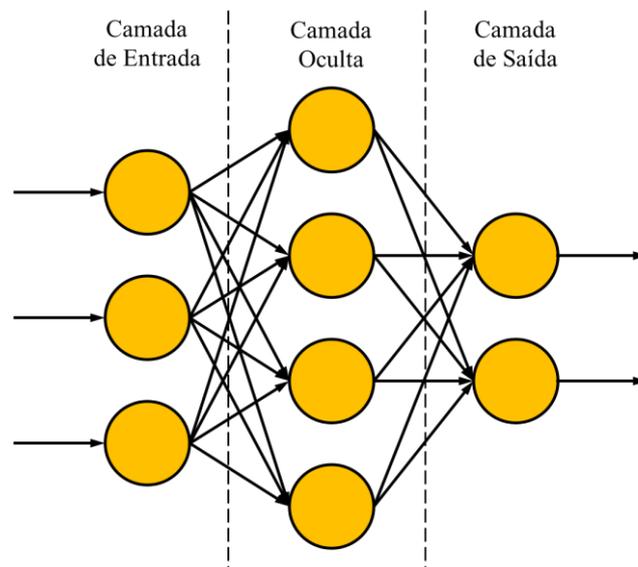


Figura 4. Rede neural progressiva

Diferente da MLP que não possui uma retroalimentação em relação as camadas extremas, as redes neurais recorrentes apresentam uma ligação de realimentação entre as camadas. Desta forma, é possível fornecer habilidades de memória a RNA, ou seja, armazenar resultados anteriores para auxiliar no seu aprendizado. Por essa característica, RNNs são aplicadas em reconhecimento automático de fala, tradução de máquina e identificação ótica de caracteres (MIKOLOV et al., 2011). A Figura 5 apresenta a estrutura de uma rede neural recorrente.

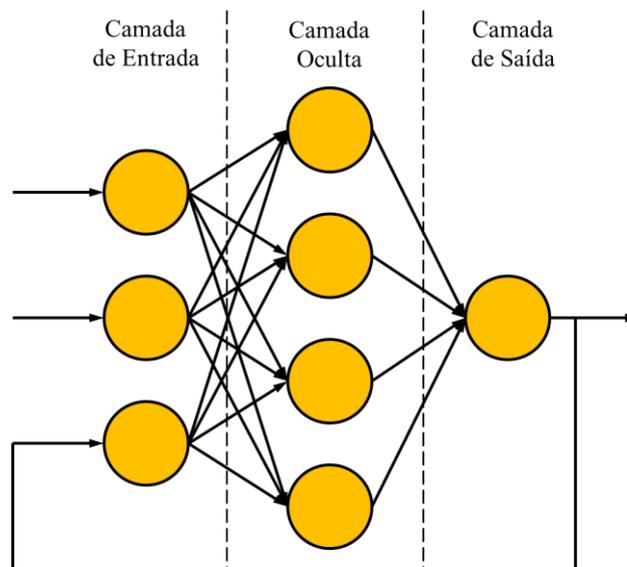


Figura 5. Rede neural recorrente

2.5.3 Aprendizagem da Arquitetura

Uma das características fundamentais de uma rede neural é a sua capacidade de aprender (PAL; MITRA, 1992). É necessário, então, definir o método utilizado por RNAs para entender e aprender com os dados fornecidos, e assim, definir os seus pesos sinápticos. O algoritmo mais comumente utilizado, para aprendizado supervisionado, é o *backpropagation*, apresentado por Rumelhart, Hinton, Williams (1986). Este algoritmo é da família dos algoritmos de gradiente descendente. O *backpropagation* foi desenvolvido para FNN, mas Werbos (1990) apresenta um extensão do algoritmo adaptado para RNN.

O funcionamento do algoritmo de *backpropagation* (Figura 6) é baseado na análise da variação da margem erro gerada pela alteração nos pesos sinápticos. A análise começa com o erro gradiente da saída e o propaga até a camada de entrada utilizando a regra da cadeia. A superfície de erro é percorrida até encontrar um mínimo global. O algoritmo treina a rede com cada instância dos dados de treinamento ajustando os pesos sinápticos. Uma passagem do *dataset* de treinamento pelo gradiente descendente é chamada de época, e são necessárias várias épocas para o treinamento completo de uma rede neural (SILVA; SPATTI; FLAUZINO, 2016).

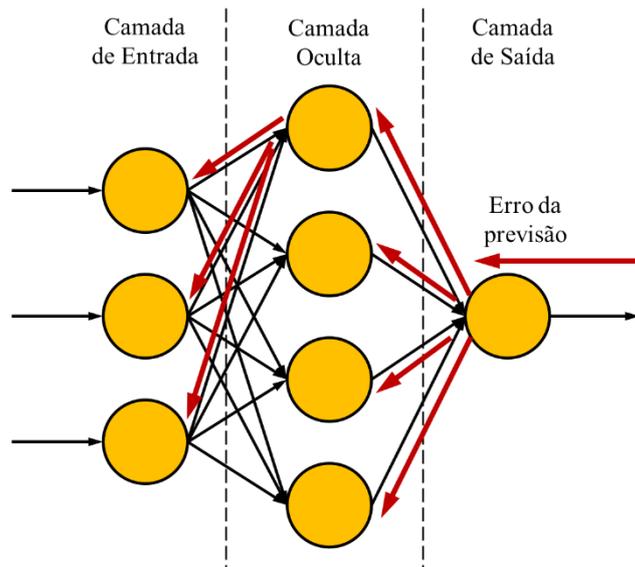


Figura 6. Algoritmo de *backpropagation*

A taxa de aprendizado é um parâmetro que controla o quanto o peso vai ser alterado a partir do erro obtido. Taxas de aprendizado muito pequenas podem levar a longos treinamentos e a obter mínimos locais. Por outro lado, se forem muito grandes podem gerar pesos sub-ótimos ou um treinamento instável (MITCHELL, 1997).

A taxa de aprendizado é um dos possíveis fatores para a ocorrência de *overfitting* (taxa de aprendizado baixa) ou *underfitting* (taxa de aprendizado alta) da rede neural. No primeiro caso, a RNA decora as respostas do *dataset* de treinamento o que previne a generalização para outros dados. O *underfitting* ocorre quando a RNA não é capaz de aprender com o conjunto de dados fornecido e seu erro quadrático é significativo (SILVA; SPATTI; FLAUZINO, 2016).

Para auxiliar o processo de convergência para um ponto ótimo, o termo de momento pode ser adicionado *backpropagation*. Esse termo é uma variável entre 0 e 1 que suaviza o algoritmo de treinamento, direcionando o próximo passo do gradiente descendente. Ele pode ajudar o algoritmo a sair de mínimos locais e chegar a mínimos globais (SILVA; SPATTI; FLAUZINO, 2016).

3 METODOLOGIA

A proposta deste trabalho é a implementação de uma rede neural com conhecimento especialista para previsão de demanda. Desta forma, é imprescindível que o trabalho seja feito em coordenação com uma empresa para obter o conhecimento especialista e testar a usabilidade desta rede. No entanto, não existe um modelo definido de como deve ser essa rede. Desta forma, segundo as definições de Gil (2008), essa pesquisa é classificada quanto aos procedimentos como uma pesquisa experimental combinada com um estudo de caso.

Quanto a sua abordagem, essa pesquisa é quantitativa, visto que todas as informações trabalhadas são quantificáveis. Analisando a natureza, é uma pesquisa aplicada, pois não é desenvolvida uma nova tecnologia, e sim uma aplicação de tecnologias já estabelecidas na literatura para um problema real. A pesquisa também pode ser classificada como pesquisa exploratória quanto aos objetivos, visto que é o primeiro trabalho nessa área, deve-se explorar diferentes possibilidades.

A metodologia do projeto, representada pela Figura 7, é baseada na metodologia CRISP-DM (*Cross-Industry Standard Process for Data Mining*) (CHAPMAN et al., 2000). Essa metodologia foi criada com o intuito de ser uma ferramenta voltada para indústria e independente de aplicação (CHAPMAN et al., 2000). A metodologia foi desenvolvida para dar suporte a aplicações de mineração de dados, no entanto, diversos trabalhos o utilizam como metodologia para aplicações de aprendizagem de máquina (BOHANEC; ROBNIK-ŠIKONJA; BORŠTNAR, 2017; BUNKER; THABTAH, 2019; DA ROCHA; DE SOUSA JUNIOR, 2010).

Esta metodologia é dividida em 6 etapas: Entendimento do Negócio, Entendimento dos Dados, Preparação dos Dados, Modelagem, Avaliação e Implementação. Cada etapa é desdobrada em tarefas genéricas. Cada tarefa possui saídas esperadas. Para obter essas saídas são sugeridas atividades a serem realizadas. Como a metodologia tem o objetivo ser aplicada em diferentes contextos, é responsabilidade do projetista adaptar o modelo para o caso estudado.

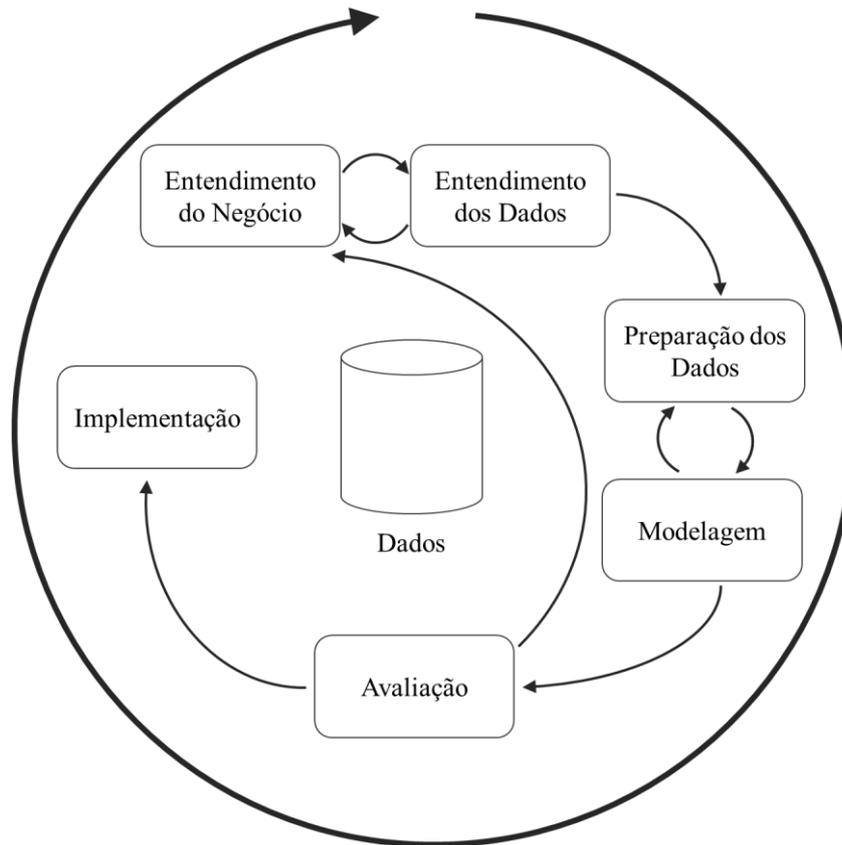


Figura 7. Metodologia CRISP-DM. Adaptado de (CHAPMAN et al., 2000).

A Etapa 1 é de Entendimento do Negócio, focada em compreender o funcionamento da empresa e caracterizar o problema a ser resolvido. A partir dessas informações são criados os objetivos da empresa para o projeto e o plano de projeto preliminar. A segunda etapa, Entendimento dos Dados, compreende a coleta inicial dos dados e análises preliminares sobre eles. Estas duas etapas estão interligadas, pois as informações de uma impactam a outra. Uma nova informação sobre o negócio precisa ser validada pelos dados e novas descobertas sobre os dados alteram o entendimento sobre o negócio da empresa.

A Etapa 3, Preparação dos Dados, foca na transformação dos dados iniciais no *dataset* final que será utilizado pelo sistema. A Etapa 4 de Modelagem inclui a seleção e implementação das técnicas de modelagem do projeto. São feitas as calibrações dos parâmetros para cada modelo testado. Como cada modelo tem seus requisitos para os dados, as etapas são interligadas.

A Etapa 5 é a de Avaliação, onde se avalia o modelo de maior potencial dentro do sistema. Nessa etapa é verificado se o modelo atende todas os requisitos definidos no Entendimento do Negócio.

A última etapa, Implementação, inclui as atividades necessárias para implementar a solução dentro do sistema da empresa de forma que o usuário seja capaz de utilizar. Em geral, essa etapa é feita pela empresa devido a sua complexidade e integração entre os sistemas.

A Etapa 6 está fora do escopo deste trabalho. E devido a restrições de informações sigilosas e a sua relevância acadêmica, as Etapas 1, 2 e 3, serão apresentadas de forma generalistas.

3.1 ENTEDIMENTO DO NEGÓCIO

A primeira etapa da metodologia CRISP-DM tem como objetivo levantar informações sobre a empresa e o problema a ser resolvido. Ela é dividida em quatro tarefas: Determinar os Objetivos do Negócio, Avaliar Situação, Determinar Objetivos Técnicos e Produzir Plano de Projeto.

A primeira tarefa identifica os objetivos da empresa em relação ao negócio. Para isso, é necessário primeiro entender as informações básicas da empresa, como: a área que ela atua, como ela se organiza, quais setores da empresa serão afetados pelo projeto, qual a solução atual para o problema, caso exista. As expectativas da empresa para o projeto são transformadas em objetivos claros e são definidos os critérios de sucesso para esses objetivos.

Durante a tarefa de Avaliar Situação são identificadas as informações detalhadas para a execução do projeto. São definidos os requisitos, restrições e premissas para o projeto.

A tradução dos objetivos de negócio em objetivos técnicos e a determinação de como avaliá-los são realizadas na tarefa de Determinar Objetivos Técnicos.

A última tarefa é a criação do plano de projeto com as ações necessárias para alcançar os objetivos definidos. O plano é dinâmico e deve ser reavaliado no decorrer do projeto.

O Quadro 3 apresenta as atividades da Etapa 1, as saídas esperadas, a definição e a importância de cada uma. Além disso são apresentadas as técnicas utilizadas para obter as informações necessárias para a saída.

Quadro 3. Descrição, importância e implementação das saídas das tarefas do Entendimento do Negócio

Tarefa	Saída	Definição	Importância	Implementação
1.1 Determinar Objetivos do Negócio	Informações Básicas	Documentar as informações sobre os negócios da empresa.	Conhecer a empresa ajuda na identificação dos objetivos do negócio.	Levantamento de documentos internos; Entrevistas com diferentes áreas da empresa; Observação do processo; Organograma da empresa.
	Objetivos do Negócio	Afirmção clara sobre os objetivos da empresa com o projeto.	Serve como direcionamento para todo o projeto.	Metas da empresa; Entrevistas com áreas relacionadas com o projeto.
	Critérios de Sucesso dos Objetivos do Negócio	Critérios de sucesso objetivos ou subjetivos para a empresa e os seus valores alvo.	Ajuda a verificar se o projeto alcançou os objetivos do negócio.	Discussões com pessoal responsável relacionado com o processo.
1.2. Avaliar Situação	Inventário de Recursos	Lista dos recursos tecnológicos e de pessoal disponíveis.	Verifica se a empresa possui o conhecimento necessário para o desenvolvimento do projeto.	Organograma da empresa; Entrevistas com áreas relacionadas com o projeto; Levantamento de documentos internos.
	Requisitos e Restrições da Empresa	Lista dos requisitos de negócio e verificação de restrições por parte da empresa sobre o projeto.	Ajuda a formalizar as expectativas da empresa em relação ao projeto e as restrições que o projeto tem que obedecer.	Levantamento de documentos internos; Entrevistas com pessoal responsável relacionado com o processo.
	Requisitos e Restrições do Projeto	Lista dos requisitos e das restrições analisadas do ponto de vista do projeto.	Formaliza as necessidades do projeto para a sua execução e as suas restrições.	Identificação pela equipe de projeto.
	Premissas	Lista de premissas feitas sobre o projeto.	Formaliza as premissas feitas e que precisam ser validas nas próximas etapas.	Identificação pela equipe de projeto; Análise de outras tarefas.
	Glossário	Terminologia relevante e acrónimos usados.	Auxilia na comunicação entre o projeto e a empresa.	Levantamento de documentos internos; Entrevistas com áreas relacionadas com o projeto.
1.3. Determinar Objetivos Técnicos	Objetivos Técnicos	Tradução dos objetivos do negócio para o contexto técnico.	Serve como guia para as atividades técnicas das próximas etapas.	Entrevistas com especialistas da área técnica; Entrevistas com áreas relacionadas com o projeto.
	Critérios de Sucesso dos Objetivos Técnicos	Critérios de sucesso para os objetivos técnicos com valores alvo.	Ajuda na avaliação dos resultados técnicos projeto.	Entrevistas com especialistas da área técnica.

Tarefa	Saída	Definição	Importância	Implementação
1.4. Produzir Plano de Projeto	Plano de Projeto	Documentação das tarefas a serem realizadas no projeto.	Auxilia na implementação e no monitoramento do projeto.	Entrevistas com áreas relacionadas com o projeto.

3.2 ENTENDIMENTO DOS DADOS

A Etapa 2 da metodologia CRISP-DM é a responsável pela coleta e análise dos dados disponíveis para o projeto. Ela é subdividida em quatro atividades: Coletar Dados Iniciais, Descrever Dados, Explorar Dados e Verificar a Qualidade dos Dados. A saída de cada atividade é um relatório documentando o seu desenvolvimento.

A primeira atividade, Coletar Dados Iniciais, inclui a aquisição dos dados, descrição da sua localização no banco de dados e como extraí-los. O levantamento das características superficiais dos dados, como quantidade de dados disponíveis, formato, é realizado na tarefa seguinte de Descrever Dados. O passo seguinte é de exploração, onde se analisa as informações obtidas dos dados, quais inferências podem ser realizadas e como os dados se relacionam. A última tarefa Verificar a Qualidade dos Dados é feita para garantir que não há erros ou dados faltando. O Quadro 4 apresenta de forma resumida as atividades e saídas desta etapa e as técnicas utilizadas.

3.3 PREPARAÇÃO DOS DADOS

Na etapa de Preparação dos Dados são selecionados quais dados são relevantes para o projeto e são preparados para gerar o *dataset* final. As seguintes tarefas compõem a etapa: Selecionar Dados, Limpar Dados, Construir Dados, Integrar Dados e Formatar Dados.

Quadro 4. Descrição, importância e implementação das saídas das tarefas do Entendimento dos Dados

Tarefa	Saída	Definição	Importância	Implementação
2.1 Coletar Dados Iniciais	Relatório da Coleta dos Dados Iniciais	Lista dos conjuntos de dados adquiridos, com sua localização e método de aquisição.	Adquire os dados iniciais para serem analisados nas próximas tarefas da fase e identifica como eles podem ser encontrados para a integração futura.	Entrevistas com especialistas; Pesquisa nos bancos de dados.
2.2 Descrever Dados	Relatório da Descrição dos Dados	Descrição dos dados obtidos, incluindo formato, quantidades e identificação dos campos.	Auxilia na compreensão dos dados e serve como referência sobre os dados para tarefas futuras.	Entrevistas com especialistas; Pesquisa nos bancos de dados.
2.3 Explorar Dados	Relatório da Exploração dos Dados	Descrição das informações obtidos a partir das análises dos dados.	Permite a validação de premissas iniciais sobre os dados e auxilia na compreensão dos dados.	Técnicas de visualização de dados, como histogramas e gráficos de dispersão; Análises estatísticas.
2.4 Verificar a Qualidade dos Dados	Relatório da Verificação da Qualidade dos Dados	Lista dos dados analisados e dos erros e falhas encontrados.	Verifica se os dados adquiridos estão corretos e se existem dados faltando, para poder criar ações corretivas.	Técnicas de visualização de dados, como histogramas e gráficos de dispersão; Pesquisas nos dados.

A primeira tarefa de Selecionar Dados tem como objetivo identificar os dados que serão utilizados na modelagem. Todas as informações básicas dos dados foram documentadas na etapa anterior. Em seguida os dados devem ser limpos, eliminando ou corrigindo os erros e valores faltando. Na tarefa seguinte, Construir Dados, novos dados são criados a partir de outros, como: somatório de colunas e conversão de unidades. A tarefa de Integrar Dados é a junção de dados de diferentes fontes em um lugar só. A última tarefa é responsável por garantir que os dados estejam formatos da forma correta para a próxima etapa de Modelagem. O Quadro 5 apresenta as tarefas, as saídas, suas descrições e importância, e como foram implementadas.

Quadro 5. Descrição, importância e implementação das saídas das tarefas do Preparação dos Dados

Tarefa	Saída	Definição	Importância	Implementação
3.1 Selecionar Dados	Justificativa para Inclusão e Exclusão	Lista dos dados que serão utilizados ou excluídos e o motivo para essa decisão.	Define quais dados serão analisados com uma justificativa sólida.	Pesquisa nos bancos de dados; Análises dos dados adquiridos.
3.2 Limpar Dados	Relatório de Limpeza dos Dados	Descrição das decisões e ações tomadas para garantir a qualidade dos dados selecionados.	Aumentar a qualidade dos dados selecionados e evitar erros na modelagem.	Varredura dos dados; Correção de registros com erros ou incompletos; Estimacão de dados incompletos.
3.3 Construir Dados	Atributos Derivados	Atributos gerados a partir de atributos já existentes.	Obter novos dados a partir da combinação de dados existentes.	Entrevistas com especialistas; Pesquisa nos bancos de dados; Estudo sobre os algoritmos de modelagem; Técnicas de combinação e transformação de colunas (atributos) e/ou de linhas (registros).
	Registros Gerados	Criação de novos dados.	Obter informações diferentes sobre segmentos dos dados disponíveis.	Entrevistas com especialistas; Pesquisa nos bancos de dados; Divisão de bancos de dados; Análise estatísticas.
3.4 Integrar Dados	Dados Fundidos	Fundir informações de diferentes tabelas de dados relacionadas aos mesmos objetos.	Ter todas as informações do objeto em uma só tabela para ser alimentada no modelo.	Estudo sobre os algoritmos de modelagem; Técnicas de combinação e transformação de colunas (atributos) e/ou de linhas (registros).
3.5 Formatar Dados	Dados Reformatados	Ajustar a formatação dos dados para se adequarem aos algoritmos de modelagem.	Os algoritmos de modelagem têm as suas especificações de formatação que os dados devem seguir.	Estudo sobre os algoritmos de modelagem; Mudança sintática das colunas; Organização das colunas.

3.4 MODELAGEM

O desenvolvimento dos modelos é realizado na etapa de Modelagem. Para definir o modelo final do projeto, a metodologia CRISP-DM define quatro tarefas: Selecionar Técnicas de Modelagem, Gerar Desenho de Testes, Construir Modelo e Avaliar Modelo.

A tarefa de Selecionar Técnicas de Modelagem é a responsável por definir a técnica de modelagem utilizada no projeto a partir das características do problema. Em seguida, é definido como os testes serão conduzidos e como os modelos serão avaliados. A terceira tarefa, Construir Modelo, é a execução dos modelos propostos e a documentação dos resultados obtidos. A última tarefa é a de avaliar os resultados obtidos e fazer as devidas alterações, caso necessário. O Quadro 6 apresenta como foi desenvolvida essa etapa.

3.5 AVALIAÇÃO

Os modelos criados e identificados como possíveis soluções devem ser avaliados cuidadosamente antes de serem implementados. As tarefas dessa etapa são: Gerar Desenho de Testes, Avaliar Resultados, Rever Processo e Determinar Próximos Passos.

Neste trabalho, etapa de Avaliação se diferencia do proposto por Chapman *et al.* (2000) ao adicionar a tarefa “Gerar Desenho de Testes” no início. Essa tarefa tem como objetivo definir

A tarefa de Avaliar Resultados é responsável por testar diferentes modelos e selecionar o que deve ser utilizado na aplicação.

Na tarefa Rever Processo, é verificado se alguma informação relevante para o projeto não foi desconsiderada erroneamente durante o desenvolvimento.

Na última tarefa, Determinar Próximos Passos, são levantadas as possíveis ações para o projeto, se o projeto pode seguir para a próxima etapa ou se deve ter nova iteração. E, após a análise, são documentadas as ações que vão ser tomadas.

Quadro 6. Descrição, importância e implementação das saídas das tarefas da Modelagem

Tarefa	Saída	Definição	Importância	Implementação
4.1 Selecionar Técnicas de Modelagem	Técnica de Modelagem	Documentar a técnica de modelagem escolhida	Avalia as diferentes técnicas de modelagem e, baseado nas análises, escolhe a(s) técnica(s) mais adequada(s)	Pesquisa na literatura acadêmica Entrevistas com especialistas
	Requisitos do Modelo	Documentar os requisitos da técnica para os dados	Cada técnica tem seus requisitos, dessa forma, é necessário deixar claro as informações para avaliar os dados disponíveis	Pesquisa na literatura acadêmica Técnicas de visualização de dados, como histogramas e gráficos de dispersão Revisão do Relatório da Descrição dos Dados
4.2 Gerar Desenho de Testes	Desenho de Teste	Definição de como o modelo vai ser avaliado	Definir o procedimento para determinar a qualidade e validade do modelo obtido	Pesquisa na literatura acadêmica Revisão do <i>dataset</i>
4.3 Construir Modelo	Configuração de Parâmetros	Lista dos parâmetros utilizados pelo modelo	Apresenta os parâmetros utilizados para futuras comparações	Pesquisa na literatura acadêmica Processo de iteração
	Modelos	Execução do modelo no <i>dataset</i> preparado	Execução do modelo para a sua avaliação	Software <i>Waikato Environment for Knowledge Analysis</i> (WEKA)
	Descrição dos Modelos	Descrição dos resultados do modelo	Os resultados obtidos serão utilizados para a comparação entre os modelos	Software WEKA
4.4 Avaliar Modelo	Avaliação do Modelo	Resumo dos resultados obtidos	Avaliação se o modelo atende aos critérios de sucesso definidos	Análises estatísticas Entrevistas com especialistas
	Revisão da Configuração de Parâmetros	Revisar os parâmetros a partir dos resultados	Ajustar os parâmetros para os próximos modelos	Pesquisa na literatura acadêmica

Quadro 7. Descrição, importância e implementação das saídas das tarefas da Avaliação

Tarefa	Saída	Definição	Importância	Implementação
5.1 Gerar Desenho de Testes	Desenho de teste	Definição dos testes de validação.	Definir o procedimento para determinar a qualidade e validade.	Pesquisa na literatura acadêmica; Revisão do <i>dataset</i> .
5.2 Avaliar Resultados	Avaliação dos Resultados	Avaliar se o modelo atingiu os objetivos de negócio definidos.	Verifica se o modelo atende ou não o que foi proposto. Evita a implementação de um modelo incompleto.	Comparação com outros modelos; Simulação de estoque; Análises estatísticas – rANOVA e teste t de Student.
	Modelos Aprovados	Seleção e aprovação dos modelos que atendem aos critérios definidos.	Índica os modelos aprovados e a justificativa da sua aprovação.	Critérios de sucesso; Entrevistas com especialistas.
5.3 Rever Processo	Revisão do Processo	Revisão criteriosa do processo de desenvolvimento do projeto.	Verifica se alguma informação relevante foi desconsiderada. Evita a implementação de um modelo incompleto.	Entrevistas com especialistas; Revisão das etapas anteriores.
5.4 Determinar Próximos Passos	Lista de Ações Possíveis	Lista das ações e suas vantagens e desvantagens.	Auxilia a tomada de decisão sobre o futuro de projeto.	Entrevistas com especialistas; Análise dos resultados.
	Decisão	Descreve as decisões tomadas e sua justificativa.	Decisões sobre o futuro do projeto.	Entrevistas com especialistas.

4 DESENVOLVIMENTO

Este capítulo apresenta as etapas de desenvolvimento baseadas na metodologia do CRISP-DM, ilustrado na Figura 7, começando pela etapa de Entendimento do Negócio até a de Avaliação. Dessa forma é possível caracterizar o problema, analisar e prepara os dados disponíveis, modelar a solução e avaliá-la.

4.1 ENTENDIMENTO DO NEGÓCIO

O objetivo dessa etapa é adquirir informações sobre a empresa e o problema a ser resolvido. O desenvolvimento dessa etapa seguiu a metodologia proposta no Capítulo 2.5. No entanto, será apresentada de forma resumida, pois a sua versão completa apresenta informações sigilosas sobre a empresa e que fogem do escopo deste trabalho.

O estudo de caso foi realizado em parceria com uma empresa de manutenção, reparo e revisão (*Maintenance, Repair and Overhaul – MRO*) de motores de helicópteros localizada no Rio de Janeiro, Brasil. A empresa possui dois centros, um de reparo (*Repair Centre – RC*) e um de manutenção (*Maintenance Centre – MC*), além deles, a empresa presta serviços em campo (*Off Site – OS*).

Como a empresa trabalha com serviços sobre demanda, ou seja, não são realizadas as mesmas atividades todos os dias, realizar previsões sobre o uso de materiais é uma tarefa complexa. E a falta de um material significa que o serviço ficará aguardando a chegada dele, consequentemente, a empresa tem prejuízos financeiros e pode perder a confiança do cliente. Uma das propostas deste trabalho é identificar variáveis que possivelmente afetem o comportamento da demanda.

Dessa forma, empresa tem como objetivo melhorar a sua exatidão na previsão da demanda dos itens classificados como consumíveis, itens que são utilizados nos reparos, mas que não são peças de motores. Exemplos destes itens incluem: graxa, álcool isopropílico e saco plástico. A previsão da demanda é informação essencial para o processo de reabastecimento desses materiais.

4.1.1 Sistema Atual

A política de controle de estoque do reabastecimento dos consumíveis é a (R, s, S), com um ponto de pedido igual a 2 meses de produção e nível máximo de estoque de 3 ou 4 meses dependendo do item. Esses valores foram definidos empiricamente pela empresa.

O método atual de previsão de demanda é a média móvel dos 12 meses anteriores atualizada a cada 6 meses.

O sistema é avaliado a cada duas semanas pela equipe de Planejamento e Controle da Produção (PCP) e quantidade a ser pedida é definida. A quantidade é arredondada baseada na unidade de compra (*packing*) do item.

4.1.2 Objetivos Técnicos

- Reduzir as paradas na linha devido à falta de materiais;
- Previsão da demanda mais próxima da real.

4.2 ENTENDIMENTO DOS DADOS

Durante o Entendimento dos Dados são realizados os estudos exploratórios iniciais sobre os dados, o que eles representam, onde são encontrados e como podem ser extraídos. Os dados não são modificados, apenas analisados. Similar a anterior, esta etapa será comentada brevemente.

Inicialmente, foram selecionados 20 consumíveis para compor a amostra de teste. Esses itens foram selecionados por possuírem características diferentes, representando a diversidade dos dados totais. Esses itens foram identificados por uma letra por motivos de sigilo. Esta amostra constitui aproximadamente 5,35% da quantidade total de itens e representa 17,8% do capital parado do estoque de consumíveis.

Os itens foram classificados em relação ao seu volume ocupado no estoque e a sua criticidade para a operação, seguindo o Quadro 8. Essa classificação facilita a agregação de

informações sobre custos do estoque, explorados mais à frente. Os itens e suas classificações são apresentados no Quadro 9.

Quadro 8. Referência para classificação dos itens segundo criticidade e volume ocupado

Valor	Criticidade	Volume ocupado
1	Afeta uma atividade	Muito pequeno
2	Afeta uma Área	Pequeno
3	Afeta uma Linha	Médio
4	-	Grande
5	-	Muito grande

Quadro 9. Classificação dos itens segundo a criticidade e volume ocupado

Item	Criticidade	Volume Ocupado
A	3	2
B	1	3
C	3	2
D	3	3
E	1	2
F	3	3
G	3	4
H	3	4
I	3	4
J	3	4
K	3	3
L	3	3
M	3	3
N	3	3
O	3	4
P	3	2
Q	2	3
R	3	2
S	2	3
T	3	1

Os dados sobre a demanda dos itens foram obtidos a partir das saídas do estoque. Como essas informações estão em um banco de dados, foi necessário o desenvolvimento de *queries* para gerar uma planilha com as informações de interesse. As movimentações do estoque são caracterizadas pelo dia, tipo de movimentação, item, tipo do item e quantidade movimentada. Os dados obtidos compreendem as movimentações de estoque realizadas entre 1/2013 e 7/2019.

Para caracterizar o funcionamento da empresa, foram obtidas as informações sobre as ordens de serviço motores de helicópteros reparados durante o mesmo período, de 1/2013 a 7/2019. A ideia de usar essas informações foi levantada em entrevistas com especialistas durante a etapa anterior. Nessa planilha consta a informação de quando o motor entrou e saiu de cada centro e o coeficiente que indica quanto do motor foi reparado.

Além da informação sobre os motores, também foi identificado pela equipe de especialista diferenças na quantidade de serviços realizados dependendo do período do ano. Dessa forma, as informações de ano, trimestre e mês foram marcadas como potenciais variáveis para os modelos.

A análise do comportamento da demanda semanal dos itens da amostra considera duas medidas: intervalo médio entre demandas (\bar{I}) e quadrado do coeficiente de variação do tamanho da demanda (CV^2). A partir deles é possível classificar a demanda em: suave (*smooth*), errática (*erradic*), intermitente (*intermittent*) e esporádica (*lumpy*), seguindo a classificação de Syntetos, Boyla, Croston (2005). A distribuição dos resultados é apresentada na Figura 8. Agrupando os itens nas classificações de comportamento obteve-se a Figura 9. Dos 20 itens selecionados: 9 tem comportamento intermitente, 9 tem comportamento esporádico, 1 tem comportamento errático e 1 tem comportamento suave. A maioria dos itens apresenta grande presença de demandas nulas na agregação temporal semanal. Essa informação é relevante para a seleção dos métodos de previsão mais adequados para o estudo de caso.

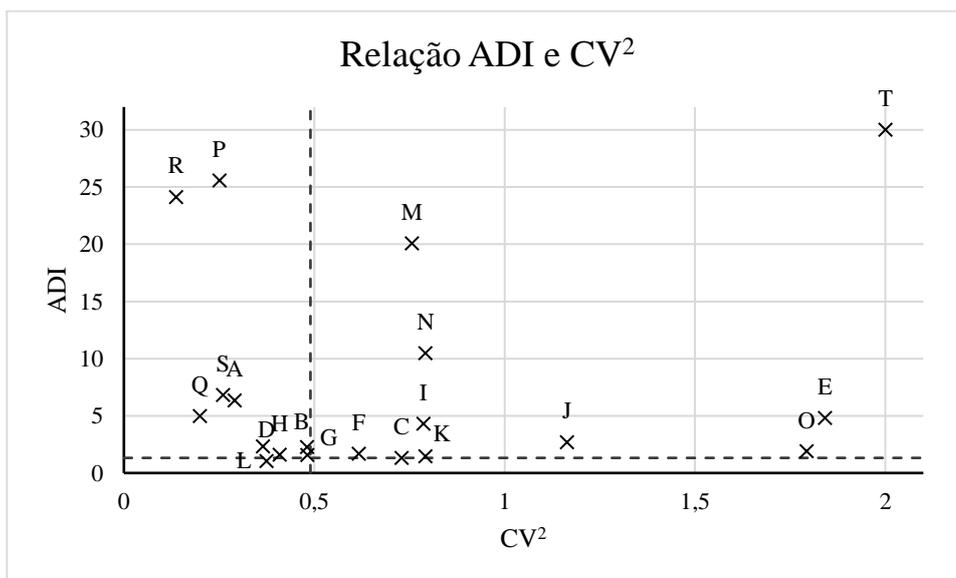


Figura 8. Gráfico da distribuição ADI e CV² da amostra

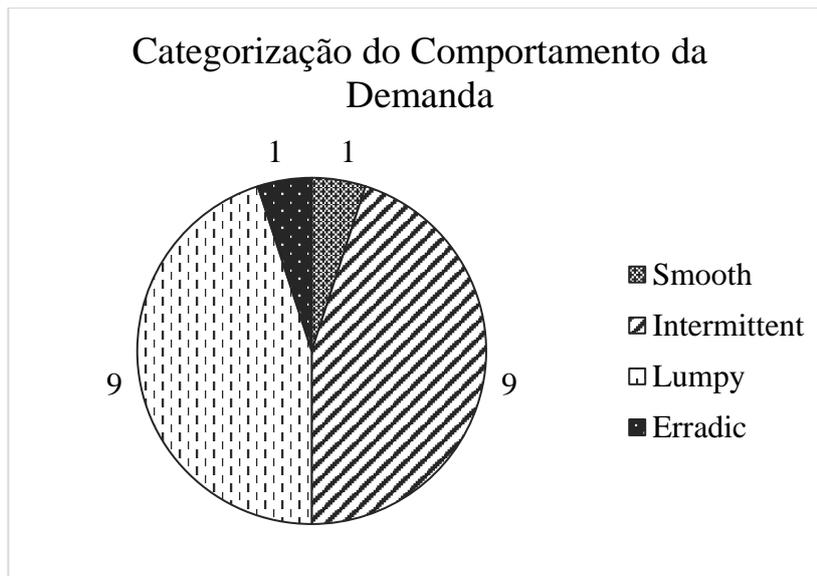


Figura 9. Categorização do comportamento da demanda da amostra

4.3 PREPARAÇÃO DOS DADOS

Nessa etapa, os dados identificados são preparados para serem alimentados aos modelos. Essa preparação inclui limpeza, construção, integração e formatação dos dados. A tarefa de seleção de dados foi suprimida, pois os dados selecionados foram apresentados.

4.3.1 Limpar Dados

A limpeza dos dados é importante para retirar inconsistências e erros do *dataset*. Os principais erros encontrados são relacionados às informações fornecidas pelos usuários no sistema. Os erros encontrados foram:

- Espaços e tabulações nos códigos dos itens;
- Quantidade de consumo negativos;
- Informações faltando.

Para não influenciar os resultados, as entradas com dados ausentes foram excluídas, assim como os que apresentaram erros.

O item T foi retirado da amostra, pois não apresentou nenhuma ocorrência de demanda durante o período de análise. Seu comportamento foi classificado como esporádico.

A planilha com as informações sobre a movimentação do estoque foi tratada para apresentar apenas saídas de estoque caracterizadas como consumo. Para isso foram utilizadas as informações do tipo de movimentação e o conhecimento dos especialistas da empresa no processo.

4.3.2 Construir Dados

A construção dos dados compreende a criação de novos dados a partir dos existentes. O software utilizado para realizar esta tarefa foi o Microsoft Excel. Sobre os dados da demanda, eles foram agregados em semanas, a janela temporal escolhida para a previsão, utilizando uma tabela dinâmica. Além disso, foram adicionadas as informações explícitas do ano, trimestre e mês da demanda. Dessa forma, se houver sazonalidade em algum período temporal nos dados, a rede neural terá acesso a essa informação.

Baseado nos trabalhos de Gutierrez; Solis; Mukhopadhyay (2008), Mukhopadhyay; Solis; Gutierrez (2012), Lolli *et al* (2017), foram adicionadas mais três informações aos dados: número de ocorrências de demandas nulas em sequência (ZS); número de períodos entre as duas últimas demandas não-nulas (ED) e última demanda (UD).

Foram adicionadas as informações de semana, mês, trimestre e ano das datas de entrada e de saída dos motores dos centros de manutenção. Aplicou-se duas tabelas dinâmicas nos dados para obter a informação de entrada e saída de motores agrupada semanalmente, como a informação da demanda. Dessa forma, gerou-se 6 novas variáveis:

- IMC – Entrada de motores no MC;
- IOS – Entrada de motores no Off Site;
- IRC – Entrada de motores no RC;
- OMC – Saída de motores do MC;
- OOS – Saída de motores do Off Site;
- ORC – Saída de motores do RC.

4.3.3 Integrar Dados

A integração dos dados foi um processo simples, pois ambas as tabelas de dados apresentam a mesma organização (semana, mês, trimestre e ano). A informação da semana não foi incluída no *dataset* final. Com o intuito de dar informação sobre os estados anteriores, os 4 últimos estados das variáveis também foram adicionados, não sendo aplicado as variáveis de ano, mês e trimestre.

4.3.4 Formatar Dados

A formatação dos dados tem como objetivo garantir a compatibilidade com o modelo a ser desenvolvido. Neste projeto será utilizado o software de aprendizagem de máquina WEKA (*Waikato Environment for Knowledge Analysis*) (FRANK; HALL; WITTEN, 2016; HALL et al., 2009). Este software utiliza arquivos do tipo .arff, mas o próprio software oferece uma ferramenta para converter arquivos .csv (exportável pelo Microsoft Excel) para o formato suportado. Além de conter os dados, ele fornece as informações sobre os tipos das variáveis utilizadas. O *dataset* final é caracterizado pelo Quadro 10 que apresenta as variáveis, sua descrição, importância e o seu formato.

4.4 MODELAGEM

Nesta etapa são implementadas e testadas diferentes técnicas de modelagem e seus parâmetros calibrados a partir dos dados disponíveis.

4.4.1 Selecionar Técnica de Modelagem

A *multilayer perceptron* foi a rede neural escolhida como técnica de modelagem para este trabalho. Além de ser uma rede amplamente utilizada para diversos casos, foi a rede mais adotada para previsão de demanda intermitente na literatura pesquisada. A MLP é uma rede versátil, capaz de trabalhar com problemas de classificação e de regressão. Sobre o treinamento, optou-se pelo algoritmo de *backpropagation*, usado nos trabalhos de referência.

Quadro 10. Resumo do *dataset* final

Variável	Nome	Importância	Formato
Ano	Ano	Informação sobre a tendência anual da demanda do item.	Numérico
Tri	Trimestre	Informação sobre a sazonalidade trimestral da demanda do item.	Numérico
Mês	Mês	Informação sobre a sazonalidade mensal da demanda do item.	Numérico
IMC [5]	Entrada de motores no MC	Informação referente ao trabalho a ser executado durante a semana em um dos centros.	Numérico
IOS [5]	Entrada de motores no Off Site	Informação referente ao trabalho a ser executado durante a semana em um dos centros.	Numérico
IRC [5]	Entrada de motores no RC	Informação referente ao trabalho a ser executado durante a semana em um dos centros.	Numérico
OMC [5]	Saída de motores do MC	Informação referente ao trabalho que foi executado durante a semana em um dos centros.	Numérico
OOS [5]	Saída de motores do Off Site	Informação referente ao trabalho que foi executado durante a semana em um dos centros.	Numérico
ORC [5]	Saída de motores do RC	Informação referente ao trabalho que foi executado durante a semana em um dos centros.	Numérico
ZS [5]	Número de ocorrências de demandas nulas em sequência	Informação de quanto tempo não há uma demanda não nula.	Numérico
ED [5]	Número de períodos entre as duas últimas demandas não-nulas	Informação de qual foi o último período entre demandas não nulas.	Numérico
UD [5]	Última demanda	Informação sobre a última demanda.	Numérico
Demanda	Demanda real	Valor real da demanda, usada para treino e avaliação dos resultados.	Numérico

4.4.2 Gerar Desenho de Testes

Para construir o modelo é necessário definir as configurações da MLP. Incluindo os parâmetros: número de camadas ocultas, número de neurônios ocultos, taxa de aprendizado,

momento e épocas. A proposta é testar diferentes combinações dos parâmetros e avaliá-las segundo as seguintes métricas: coeficiente de correlação, erro absoluto médio, erro absoluto relativo, raiz do erro quadrático médio e raiz do erro quadrático relativo.

O *dataset* da amostra foi dividido em dois, um *dataset* para treinar a MLP e um *dataset* para testá-la. O primeiro conjunto de dados compreende o período de 1/2013 a 12/2017 e o segundo, o período de 1/2018 a 7/2019.

O computador utilizado para o desenvolvimento deste trabalho possui as seguintes especificações:

- Sistema operacional: Microsoft Windows 10
- Processador: Intel Core i7-9750H CPU 2.60 GHz 6 núcleos, 12 processadores lógicos
- Memória RAM: 8 GB
- Armazenamento de dados: SSD
- Placa de vídeo: NVIDIA GeForce GTX 1660 Ti 6 GB

4.4.3 Construir e Avaliar o Modelo

O software utilizado para a construção e treinamento das redes neurais foi o WEKA versão 3.8.4 (HALL et al., 2009). Ele é um ambiente de desenvolvimento composto por diversos algoritmos de aprendizagem de máquina e de técnicas de processamento de dados (FRANK; HALL; WITTEN, 2016). A sua interface gráfica permite testes rápidos de diferentes algoritmos e configurações. Este software já foi validado pela academia e para o setor privado (HALL et al., 2009).

Diversas configurações de redes foram testadas, incluindo as utilizadas nos trabalhos de Gutierrez; Solis; Mukhopadhyay (2008), Mukhopadhyay; Solis; Gutierrez (2012), Lolli *et al* (2017). A configuração que obteve os melhores resultados é mostrada na Figura 10 através da janela de configuração do software.

A MLP possui uma camada oculta com três neurônios ocultos que são suficientes para aproximar a maioria das funções complexas (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008). A escolha de três camadas para MLP está de acordo com diretrizes sobre escolha de arquitetura apresentadas por (XIANG; DING; LEE, 2005). A taxa de aprendizado e o

momento foram definidas como 0,01, valores inferiores aos adotados em outros trabalhos sobre redes neurais e demandas intermitentes. É importante ressaltar que nesses trabalhos não houve otimização proposital dos parâmetros, para avaliar a generalização das redes. Este trabalho é um estudo de caso, por isso, houve a otimização dos parâmetros. Utilizando essas configurações, o treinamento das redes para cada item da amostra teve duração média de 15 segundos.

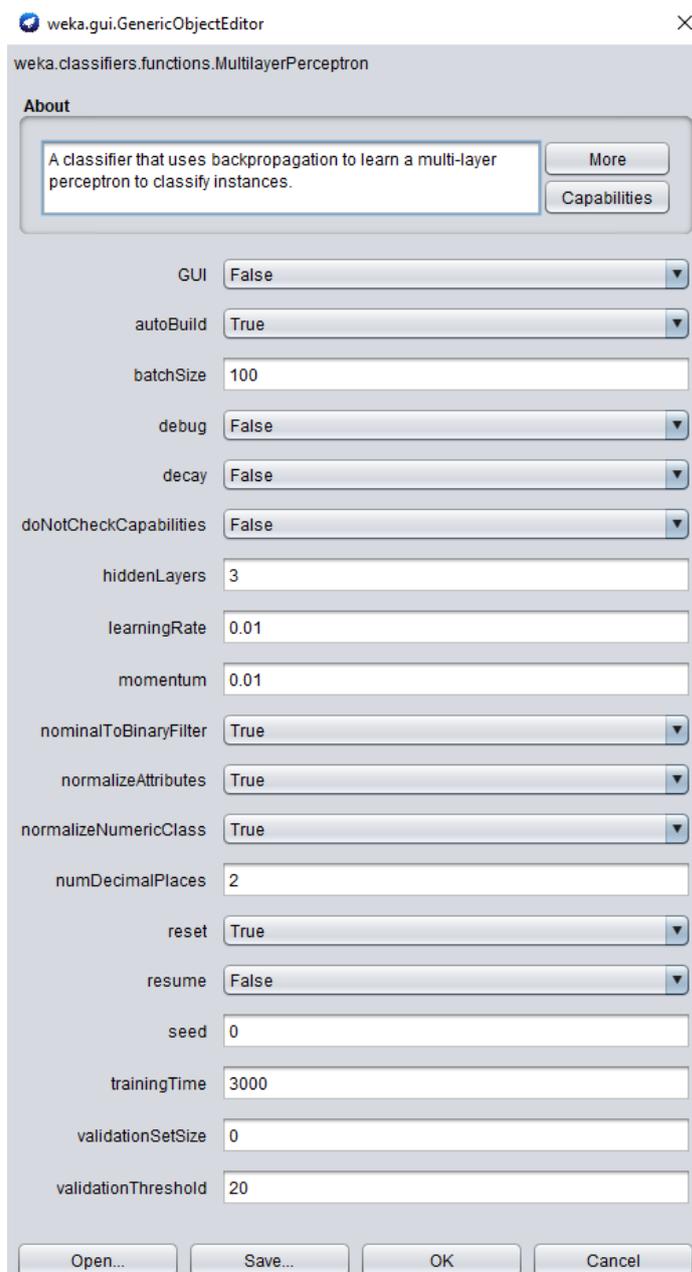


Figura 10. Configuração dos parâmetros da MLP adotada

A Figura 11 apresenta de forma visual a arquitetura da MLP proposta, suas entradas e sua saída.

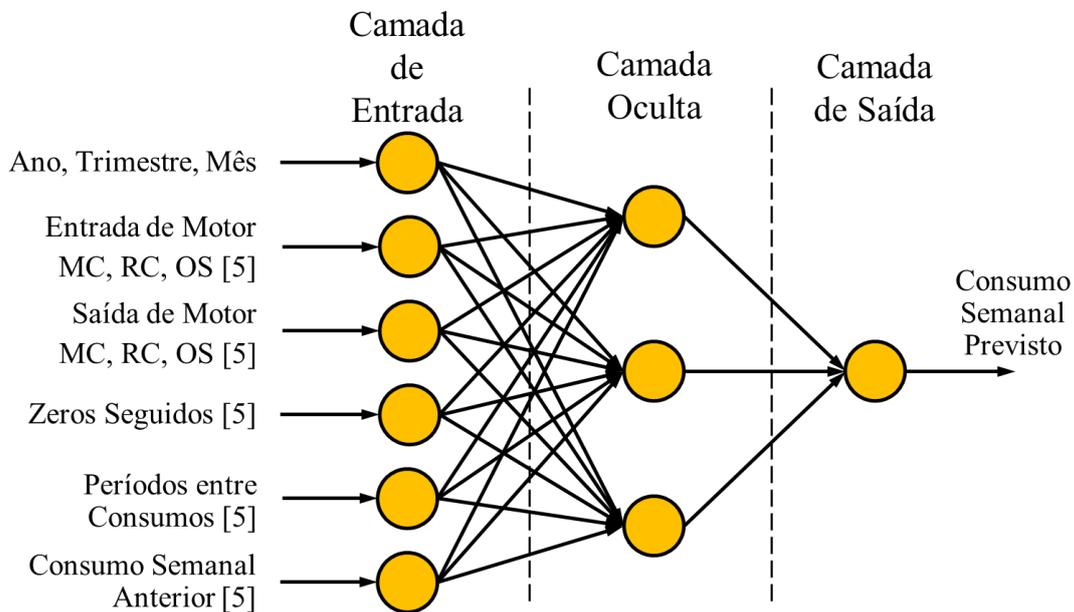


Figura 11. Esquemático da rede neural proposta

4.5 AVALIAÇÃO

A avaliação da rede neural proposta é composta por dois testes principais. O primeiro teste compara a ANN com outros onze métodos de previsão, para verificar a capacidade de prever a demanda utilizando medidas de exatidão. O segundo teste avalia o comportamento de cinco métodos selecionados no controle de estoque utilizando um simulador desenvolvido no projeto. Com o intuito de facilitar o entendimento, o desenvolvimento desta etapa é dividido em duas partes, uma para cada teste.

4.5.1 Capacidade de Previsão

4.5.1.1 Desenho de Testes

A avaliação da capacidade de previsão compara três tipos de métodos de previsão (médias móveis, métodos tradicionais e redes neurais) da literatura, a partir dos resultados

em três medidas de exatidão (MAPE, ME|A e PBt). Todos os métodos selecionados já foram utilizados ou foram desenvolvidos para prever demandas com comportamento intermitente/esporádico, como é o caso da maioria dos dados disponíveis.

As médias móveis são amplamente utilizadas em empresas, devido a sua simplicidade e facilidade de implementação. A solução atual da empresa estudada utiliza uma média móvel para fazer as previsões. Foram adotados dois parâmetros de configuração para as médias móveis: a quantidade de unidades de tempo considerada e a frequência de atualização da estimação. Neste trabalho, foram adotadas quatro configurações de médias móveis.

A partir da característica intermitente dos dados foram selecionados quatro métodos tradicionais: SES, CR, SBA e TSB. Estes métodos possuem uma ou duas constantes de suavização para controlar o quanto o erro da previsão anterior vai impactar a próxima previsão. A literatura indica que os valores das constantes devem ser entre 0,05 e 0,2 e, para os métodos com duas constantes, $\alpha = \beta$ (BABAI; SYNTETOS; TEUNTER, 2014). Desta forma, foi utilizado o valor 0,1 para todas as constantes.

As RNAs adotadas no projeto são as propostas por Gutierrez, Solis, Mukhopadhyay (2008), por Mukhopadhyay, Solis, Gutierrez (2012) e por Lolli *et al.* (2017), além da proposta no trabalho. Todas as redes neurais são MLP e possuem diversos parâmetros que devem ser definidos, incluindo: número de camadas ocultas, número de neurônios ocultos, taxa de aprendizado, momento e épocas. Optou-se por utilizar os parâmetros que geraram os melhores resultados da RNA proposta para todas as RNAs.

O Quadro 11 apresenta os doze métodos de previsão adotados neste trabalho, sua notação e a configuração dos seus parâmetros.

Os métodos são comparados utilizando-se as medidas de exatidão: MAPE, ME|A e PBt. A primeira medida é a relação entre o erro absoluto e a demanda média. Desta forma, ela fornece informação sobre a proximidade do valor previsto do valor real, ignorando o sinal do erro. Como a demanda apresenta ocorrências nulas, utilizou-se a fórmula derivada de Gilliland (2002).

A segunda medida, ME|A, indica o viés da previsão. Se o valor é negativo, significa que a previsão tende a ser subdimensionada, se o valor for positivo, significa que ela tende a ser superdimensionada.

Quadro 11. Métodos de previsão e seus parâmetros adotados no trabalho

Método de Previsão	Notação	Parâmetros
Média móvel de 12 meses atualizada a cada 6 meses	MM12_6	Quantidade de unidades de tempo considerados pela média = 12 meses; Frequência de atualização em unidades de tempo = 6 meses.
Média móvel de 12 meses atualizada a cada 12 meses	MM12_12	Quantidade de unidades de tempo considerados pela média = 12 meses; Frequência de atualização em unidades de tempo = 12 meses.
Média móvel de 12 meses atualizada a cada 3 meses	MM12_3	Quantidade de unidades de tempo considerados pela média = 12 meses; Frequência de atualização em unidades de tempo = 3 meses.
Média móvel de 6 meses atualizada a cada 6 meses	MM6_6	Quantidade de unidades de tempo considerados pela média = 6 meses; Frequência de atualização em unidades de tempo = 6 meses.
Amortecimento exponencial simples	SES	$\alpha = 0,1$.
Método de Croston	CR	$\alpha = 0,1$; $\beta = 0,1$.
Aproximação de Syntetos-Boylan	SBA	
Método de Teunter- Syntetos-Babai	TSB	
Rede neural proposta por (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008)	GUT	Número de camadas ocultas = 1; Número de neurônios ocultos = 3; Taxa de aprendizado = 0,01; Momento = 0,01; Épocas = 30000.
Rede neural proposta por (MUKHOPADHYAY; SOLIS; GUTIERREZ, 2012)	MUK	
Rede neural proposta por (LOLLI et al., 2017)	LOL	
Rede neural proposta neste trabalho	CREP	

O PBt é a porcentagem de vezes em que o método obteve o melhor resultado de acordo com uma métrica definida. Neste trabalho, foi adotado o erro absoluto como métrica, seguindo o direcionamento de Gutierrez, Solis, Mukhopadhyay (2008).

As três medidas de exatidão são independentes da escala, o que permite o uso de análises estatísticas para corroborar as comparações. Como a comparação envolve mais de duas entidades, é interessante o uso da análise de variância (ANOVA). A ANOVA é um

procedimento para isolar a fonte de variabilidade das medidas, desta forma é possível identificar o impacto das variáveis independentes nos resultados (BOX; HUNTER; HUNTER, 1978). A hipótese nula testada nesse teste é a de que as médias dos tratamentos são iguais, ou seja, o tratamento não tem impacto no resultado.

As previsões dos métodos são feitas sobre os mesmos dados, desta forma, é necessário utilizar uma variação deste método, a ANOVA com medidas repetidas (rANOVA) (GIRDEN, 1992). A rANOVA permite retirar a influência dos objetos de testes (no casos, os itens) do resultado da previsão. Deste modo, os tratamentos (métodos de previsão) podem ser analisados separadamente.

A rANOVA se baseia na premissa da esfericidade dos dados, ou seja, as diferenças entre pares de tratamentos são iguais. No entanto, segundo Keselman *et al.* (1980), a premissa de esfericidade, testada pelo método de Mauchly, é frequentemente violada e é recomendado a adoção do ϵ de Greenhouse e Geisser (GG), fator de correção de graus de liberdade.

Caso a hipótese nula da rANOVA seja rejeitada com confiança de 95%, é realizado o teste t de Student para cada método. Como os tratamentos são realizados nos mesmos itens, é conduzido o teste t de Student pareado com confiança de 95%.

Os dados de demanda semanal dos 19 itens da amostra, durante período de 1/2013 a 7/2019, foram divididos entre treino (1/2013 a 12/2017) e teste (1/2018 a 7/2019), uma divisão próxima de 75:25. Essa divisão foi feita para facilitar a implementação do simulador, comentado a frente, e avaliar os resultados na mudança do ano. A separação dos dados é necessária pois (1) as redes neurais precisam de um *dataset* de treino para aprender e definir os pesos sinápticos adequados, (2) os métodos tradicionais necessitam de dados iniciais para ajustar os seus estimadores e (3) as médias precisam de uma quantidade mínima de dados históricos para fazerem a primeira estimativa.

Os testes estatísticos foram realizados no software Microsoft Excel 2016 em conjunto com a extensão Real Statistics Resource Pack Versão 7.2 (ZAIONTZ, 2013).

4.5.1.2 Avaliação dos Resultados

Os resultados da medida de exatidão MAPE são apresentados na Tabela 1, acompanhados pela média e desvio padrão de cada método. É possível identificar que as

quatro RNAs tendem a ter valores de MAPE menores que os outros métodos, ou seja, tendem a ter erros absolutos menores. Os resultados das médias e métodos tradicionais não indicaram diferenças perceptíveis.

Tabela 1. Resultados de MAPE

Item	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
A	1,516	1,511	1,534	1,535	1,621	1,477	1,453	1,582	1,250	1,248	1,248	1,307
B	1,079	1,088	1,079	1,080	1,058	1,059	1,048	1,068	1,049	1,047	1,049	1,055
C	0,673	0,672	0,671	0,674	0,699	0,686	0,681	0,689	0,670	0,670	0,669	0,669
D	0,363	0,361	0,364	0,376	0,367	0,367	0,367	0,367	0,375	0,375	0,375	0,367
E	1,609	1,541	1,546	1,712	1,454	1,452	1,429	1,457	1,345	1,345	1,345	1,360
F	0,903	0,897	0,910	0,916	0,935	0,917	0,905	0,937	0,929	0,931	0,929	0,919
G	0,870	0,869	0,868	0,874	0,917	0,907	0,901	0,907	0,948	0,948	0,948	0,929
H	0,788	0,783	0,786	0,796	0,821	0,818	0,811	0,816	0,805	0,806	0,805	0,799
I	1,369	1,350	1,392	1,428	1,589	1,441	1,419	1,635	1,657	1,655	1,658	1,574
J	0,935	0,931	0,956	0,967	1,024	0,946	0,928	1,000	0,885	0,885	0,884	0,881
K	0,769	0,768	0,774	0,797	0,812	0,807	0,796	0,799	0,751	0,751	0,751	0,748
L	0,819	0,819	0,825	0,849	0,857	0,839	0,838	0,855	0,824	0,824	0,822	0,809
M	1,173	1,115	1,190	1,308	1,691	1,842	1,799	1,642	1,878	1,857	1,893	1,939
N	1,596	1,467	1,619	1,634	1,696	1,409	1,388	1,611	1,250	1,267	1,248	1,182
O	1,296	1,273	1,323	1,297	1,361	1,323	1,290	1,331	1,159	1,160	1,159	1,176
P	2,404	2,510	2,404	2,404	2,053	2,115	2,059	2,238	1,487	1,506	1,486	1,644
Q	1,426	1,406	1,434	1,441	1,490	1,410	1,390	1,449	1,245	1,243	1,243	1,270
R	3,154	3,423	3,279	2,885	2,357	3,429	3,308	2,367	2,227	2,215	2,232	2,601
S	1,314	1,279	1,344	1,359	1,466	1,289	1,275	1,421	1,137	1,139	1,135	1,143
Média	1,266	1,266	1,279	1,281	1,277	1,291	1,268	1,272	1,151	1,151	1,152	1,177
σ .	0,644	0,696	0,664	0,603	0,504	0,667	0,641	0,518	0,442	0,439	0,444	0,508

O *box plot* ou diagrama de caixa é uma ferramenta gráfica que permite verificar as variações dos dados, em função dos quartis e extremos. A Figura 12 apresenta o *box plot* dos resultados do MAPE. Analisando o gráfico, percebe-se que as áreas do segundo e terceiro quartis dos métodos são similares, se concentrando entre 0,75 e 1,5. No entanto, o quarto quartil apresenta uma grande variação.

Para verificar a presença de *outliers* no conjunto amostral, os dados da Tabela 1 foram analisados e o item R apresentou os maiores valores. Ao analisar a demanda deste item, foi observado que, no *dataset* de teste, ele apresentou apenas duas ocorrências de demanda, ambas com demanda unitária. Ao retirar este item do conjunto, obteve-se o *box plot* mostrado na Figura 13. A distribuição dos quartis entre os métodos de previsão é mais

uniforme com a remoção do item R. As novas médias e desvios padrões eliminando este item são apresentados na

Tabela 2. Considerando estes resultados, optou-se por retirar esse item para as próximas etapas.

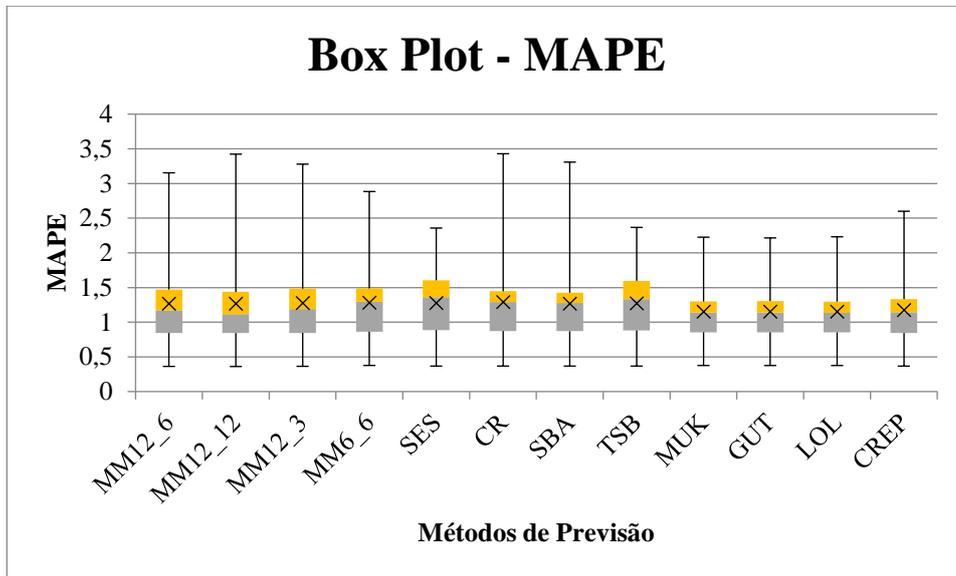


Figura 12. *Box plot* dos resultados MAPE para o conjunto amostral

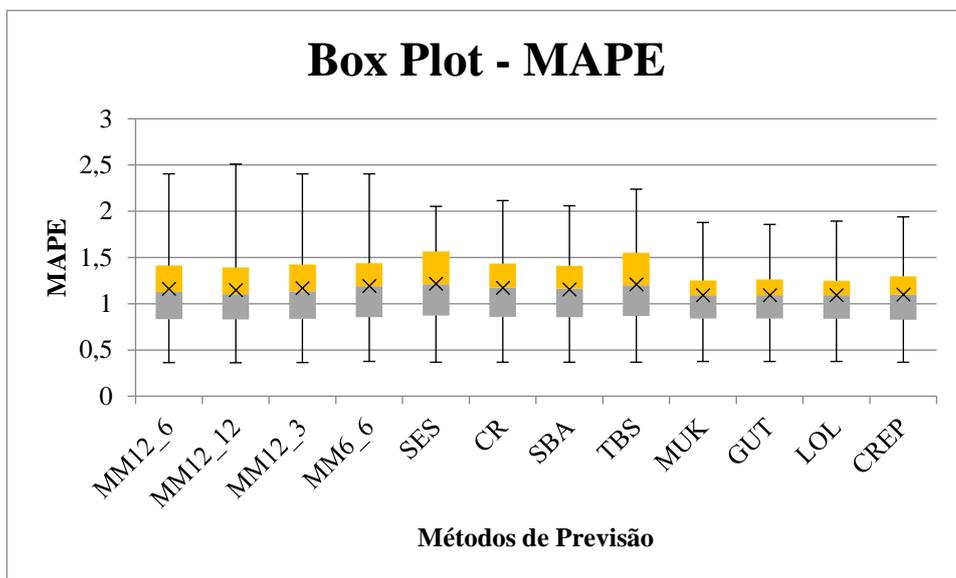


Figura 13. *Box plot* dos resultados MAPE para o conjunto amostral reduzido

Tabela 2. Média e desvio padrão do MAPE da amostra reduzida

	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
Média	1,161	1,147	1,168	1,192	1,217	1,172	1,154	1,211	1,092	1,092	1,092	1,098
σ .	0,467	0,473	0,467	0,474	0,443	0,433	0,419	0,458	0,367	0,366	0,369	0,385

Para verificar a normalidade dos dados, foi aplicado o teste de Shapiro-Wilk, mostrado na Tabela 3. Com uma confiança (α) de 95%, é possível afirmar que a distribuição dos resultados MAPE seguem uma distribuição normal.

Tabela 3. Teste Shapiro-Wilk dos resultados do MAPE

	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
Estat. W	0,943	0,910	0,943	0,953	0,959	0,961	0,962	0,958	0,985	0,987	0,984	0,982
p-valor	0,322	0,085	0,327	0,472	0,583	0,621	0,643	0,569	0,987	0,992	0,983	0,971
$1 - \alpha$	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05
Normal	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim	Sim

Para verificar se a diferença identificada entre os métodos de previsão é significativa, a rANOVA foi conduzida (Tabela 4). A rANOVA indica que tanto os itens quanto os métodos têm impacto significativo nos resultados do MAPE, ambos com p-valor menor que 0,05.

Tabela 4. rANOVA do MAPE

Fonte	SS	g.l.	MS	F	p-valor
Itens	33,869	17	1,992	101,930	7,59E-85
Métodos	0,430	11	0,039	1,998	0,031
Erro	3,655	187	0,020	-	-
Total	37,953	215	-	-	-

Como recomendado por Keselman (1980), foi aplicada a correção nos graus de liberdade de Greenhouse e Geisser (Tabela 5). Nessa análise mais conservadora, os métodos não são significativos para o resultado, considerando uma confiança de 95%.

Tabela 5. Correção de Greenhouse e Geisser para MAPE

Fonte	SS	g.l.	MS	F	p-valor
-------	----	------	----	---	---------

Métodos	0,430	1,249	0,344	1,998	0,171
Erro	3,655	21,233	0,172	-	-

Mesmo com o resultado negativo da correção GG, optou-se por fazer o teste t pareado entre os métodos de previsão. Com o nível de confiança de 95%, os pares significativamente diferentes são apresentados no Quadro 12, em que na primeira coluna está o método com menor MAPE do par.

Quadro 12. Pares de métodos significativamente diferentes de acordo com os resultados MAPE

Método com menor MAPE	Método com maior MAPE
CREP	SES
	CR
	TSB
GUT	SES
	TSB
LOL	SES
	TSB
MM12_12	MM6_6
MM12_3	MM6_6
MM12_6	MM6_6
MUK	SES
	TSB
SBA	SES
	CR
	TSB

As RNAs obtiveram resultados melhores que o SES e o TSB em relação ao erro absoluto, e a rede proposta no trabalho foi a única superior ao método CR. Como em outros trabalhos, o SBA foi significativamente melhor que o método de Croston (GUTIERREZ; SOLIS; MUKHOPADHYAY, 2008; SYNTETOS; BOYLAN, 2005). Há diferença significativa entre as médias, a MM6_6 apresentou pior MAPE que as três médias móveis.

A próxima medida de exatidão avaliada é a ME|A, que fornece informações sobre o viés dos métodos. Ao calcular este erro a partir das previsões de demanda, obteve-se a Tabela 6. Em uma análise preliminar, as RNAs apresentaram os maiores valores absolutos de ME|A,

indicando que mais se distanciam do valor real quando considerado o sinal dos erros. Além disso, para a maioria dos itens, apresentaram ME|A negativos, indicando um subdimensionamento da demanda.

Os métodos tradicionais também apresentaram médias de ME|A negativas, no entanto, com um valor absoluto menor. As médias móveis apresentaram valores absolutos baixos, mas com um desvio padrão superior aos métodos tradicionais.

Tabela 6. Resultados do ME|A

Item	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
A	0,019	-0,001	-0,045	-0,047	0,049	-0,078	-0,124	-0,004	-0,513	-0,517	-0,515	-0,393
B	-0,013	-0,009	0,008	0,016	-0,024	-0,004	-0,054	-0,010	-0,038	-0,047	-0,037	-0,018
C	-0,163	0,188	0,162	0,152	-0,159	-0,161	-0,203	-0,170	-0,197	-0,197	-0,198	-0,193
D	0,011	-0,034	-0,005	-0,014	-0,021	-0,021	-0,070	-0,022	-0,155	-0,155	-0,156	-0,126
E	0,334	-0,222	-0,251	-0,487	0,068	0,040	-0,012	0,061	-0,219	-0,220	-0,219	-0,163
F	-0,070	0,116	0,068	0,027	-0,064	-0,046	-0,094	-0,067	0,021	0,022	0,021	-0,018
G	-0,092	0,110	0,100	0,058	-0,078	-0,051	-0,099	-0,069	0,246	0,246	0,248	0,164
H	-0,076	0,106	0,077	0,055	-0,050	-0,044	-0,092	-0,035	-0,005	-0,004	-0,006	-0,032
I	-0,305	0,341	0,267	0,191	-0,083	-0,215	-0,255	0,025	0,159	0,156	0,160	0,007
J	-0,027	0,133	-0,006	-0,033	0,009	-0,064	-0,110	0,016	-0,350	-0,352	-0,352	-0,326
K	-0,043	0,051	0,066	-0,019	-0,018	-0,010	-0,060	-0,020	-0,309	-0,309	-0,311	-0,300
L	0,029	-0,043	-0,027	-0,039	-0,042	-0,025	-0,074	-0,005	-0,210	-0,204	-0,213	-0,195
M	-0,798	0,856	0,773	0,635	-0,175	-0,067	-0,114	-0,211	-0,003	-0,026	0,010	0,077
N	-0,159	0,339	0,120	0,089	-0,039	-0,411	-0,440	-0,179	-0,631	-0,611	-0,634	-0,735
O	0,007	0,028	-0,046	-0,006	0,006	0,023	-0,028	0,004	-0,223	-0,223	-0,223	-0,188
P	0,558	-0,683	-0,558	-0,538	0,129	0,235	0,173	0,327	-0,461	-0,440	-0,462	-0,281
Q	-0,037	0,075	0,020	0,009	-0,021	-0,070	-0,116	-0,067	-0,443	-0,447	-0,445	-0,379
S	-0,207	0,270	0,152	0,124	-0,049	-0,296	-0,331	-0,089	-0,671	-0,669	-0,674	-0,647
Média	-0,057	0,090	0,049	0,010	-0,031	-0,070	-0,117	-0,029	-0,222	-0,222	-0,223	-0,208
$\sigma..$	0,267	0,298	0,254	0,245	0,072	0,138	0,131	0,115	0,259	0,255	0,261	0,235

O *box plot* dos resultados de ME|A é apresentado na Figura 14. Como o ME|A pode ser negativo, é necessário fazer um *shift* no eixo vertical de pelo menos o valor mínimo dos dados. Para permitir a comparação com os valores reais, foi feito um *shift* de 1, ou seja, valores próximos a 1 no gráfico são, na verdade, valores próximos a 0. A análise deste gráfico reforça os comentários anteriores.

A análise da normalidade por Shapiro-Wilk (Tabela 7) indica que 58,3% dos métodos violam essa premissa. A violação da normalidade pode levar ao aumento de erros do tipo I, ou seja, rejeitar uma hipótese nula verdadeira.

O resultado da rANOVA por ser observado na Tabela 8 e a correção GG, na Tabela 9. Nesta avaliação, as duas análises rejeitam a hipótese nula para os métodos de previsão, indicando que estes têm impacto significativo no erro médio.

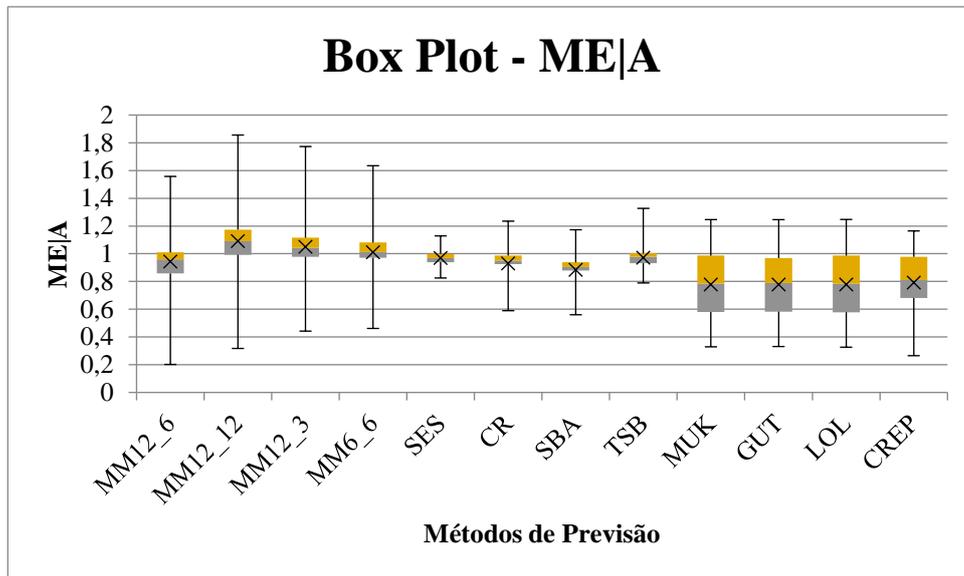


Figura 14. *Box plot* dos resultados do ME|A para o conjunto amostral reduzido

Tabela 7. Teste Shapiro-Wilk dos resultados ME|A

	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
Estat. W	0,848	0,880	0,839	0,815	0,958	0,894	0,894	0,846	0,976	0,981	0,976	0,951
p-valor	0,008	0,026	0,006	0,003	0,564	0,045	0,045	0,007	0,905	0,957	0,899	0,446
$1 - \alpha$	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05
Normal	Não	Não	Não	Não	Sim	Não	Não	Não	Sim	Sim	Sim	Sim

Tabela 8. rANOVA do ME|A

Fonte	SS	g.l.	MS	F	p-valor
Itens	2,051	17	0,121	2,798	0,00034
Métodos	2,470	11	0,225	5,208	3,9E-07
Erro	8,063	187	0,043	-	-
Total	12,584	215	-	-	-

Tabela 9. Correção de Greenhouse e Geisser para ME|A

Fonte	SS	g.l.	MS	F	p-valor
Métodos	2,470	1,940	1,273	5,208	0,011
Erro	8,063	32,981	0,244	-	-

A comparação par a par do teste t de Student confirmou os indícios que as redes neurais resultaram em ME|A inferiores aos métodos: CR, MM12_12, MM12_3, MM6_6, SES e TSB. Um resultado inesperado foi a superioridade do CR sobre o SBA para erro médio, considerando que o SBA foi desenvolvido para eliminar o viés do CR. Em geral, o SBA obteve resultados de ME|A inferiores aos outros métodos tradicionais. Houve diferenças entre as médias também, em especial a MM6_6. Todos os pares significativamente diferentes podem ser observados no Quadro 13.

Quadro 13. Pares de métodos significativamente diferentes de acordo com os resultados do ME|A

Método com menor ME A	Método com maior ME A
CR	RNAs
	SBA
MM12_12	RNAs
MM12_3	RNAs
	MM12_12
MM6_6	RNAs
	MM12_12
	MM12_3
SBA	MM12_12
SES	RNAs
	SBA
TSB	RNAs
	SBA

A terceira medida de exatidão testada é a PBt que indica a proporção de vezes em que o módulo da previsão do método mais se aproximou do valor real. Os resultados são dispostos na Tabela 10. A partir de uma análise superficial, os métodos MM12_12, MM6_6, GUT,

LOL e CREP obtiveram os melhores resultados. No entanto, as RNAs GUT e CREP apresentaram os maiores desvios padrões, indicando que seus resultados variam dependendo do item analisado.

Tabela 10. Resultados do PBt

Item	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
A	0,035	0,000	0,094	0,094	0,012	0,012	0,000	0,024	0,000	0,529	0,200	0,000
B	0,077	0,198	0,022	0,209	0,242	0,011	0,033	0,011	0,000	0,077	0,022	0,099
C	0,151	0,217	0,123	0,094	0,009	0,028	0,170	0,104	0,000	0,000	0,019	0,085
D	0,120	0,230	0,090	0,100	0,060	0,010	0,060	0,020	0,060	0,010	0,220	0,020
E	0,063	0,021	0,063	0,083	0,198	0,000	0,000	0,052	0,031	0,250	0,135	0,104
F	0,023	0,186	0,081	0,163	0,163	0,070	0,128	0,023	0,000	0,070	0,058	0,035
G	0,178	0,159	0,121	0,093	0,075	0,019	0,047	0,056	0,075	0,019	0,150	0,009
H	0,066	0,176	0,044	0,132	0,121	0,033	0,110	0,132	0,000	0,077	0,077	0,033
I	0,000	0,244	0,000	0,280	0,122	0,000	0,171	0,024	0,012	0,073	0,049	0,024
J	0,074	0,084	0,074	0,137	0,053	0,000	0,105	0,021	0,032	0,179	0,126	0,116
K	0,122	0,044	0,089	0,178	0,067	0,033	0,011	0,022	0,033	0,122	0,089	0,189
L	0,037	0,146	0,000	0,232	0,049	0,012	0,012	0,049	0,134	0,012	0,146	0,171
M	0,250	0,254	0,234	0,195	0,004	0,000	0,000	0,008	0,000	0,000	0,000	0,055
N	0,023	0,093	0,035	0,058	0,047	0,000	0,023	0,012	0,000	0,000	0,035	0,674
O	0,056	0,056	0,067	0,033	0,089	0,044	0,000	0,044	0,100	0,233	0,144	0,133
P	0,000	0,009	0,000	0,017	0,122	0,000	0,000	0,096	0,278	0,000	0,296	0,183
Q	0,035	0,012	0,081	0,070	0,023	0,023	0,000	0,070	0,000	0,488	0,163	0,035
S	0,000	0,012	0,061	0,085	0,073	0,000	0,000	0,061	0,329	0,000	0,183	0,195
Média	0,073	0,119	0,071	0,125	0,085	0,016	0,048	0,046	0,060	0,119	0,117	0,120
$\sigma..$	0,068	0,092	0,056	0,071	0,066	0,019	0,061	0,035	0,097	0,163	0,080	0,153

O *box plot* (Figura 15) fornece mais informações sobre o comportamento do PBt para cada método. O quarto quartil do CREP é o maior entre os métodos e é desproporcional aos outros quartis, o que pode indicar a presença de um *outlier*. Ao analisar os dados da Tabela 10, identificou-se o PBt do item N que possui um valor 3,5 vezes maior que o segundo maior resultado deste método. Um possível motivo para isso é que como as redes têm a tendência de subdimensionar a previsão, a demanda prevista por CREP foi a menor entre os métodos para as demandas nulas, sendo considerado a melhor previsão nesses casos. O método LOL obteve um valor alto de média do PBt e possui a menor variância entre as RNAs, similar às das médias.

A Tabela 11 apresenta os resultados do teste Shapiro-Wilk para verificar a premissa de normalidade dos métodos. Apenas quatro métodos não violaram a premissa de normalidade: MM12_12, MM6_6, SES, LOL.

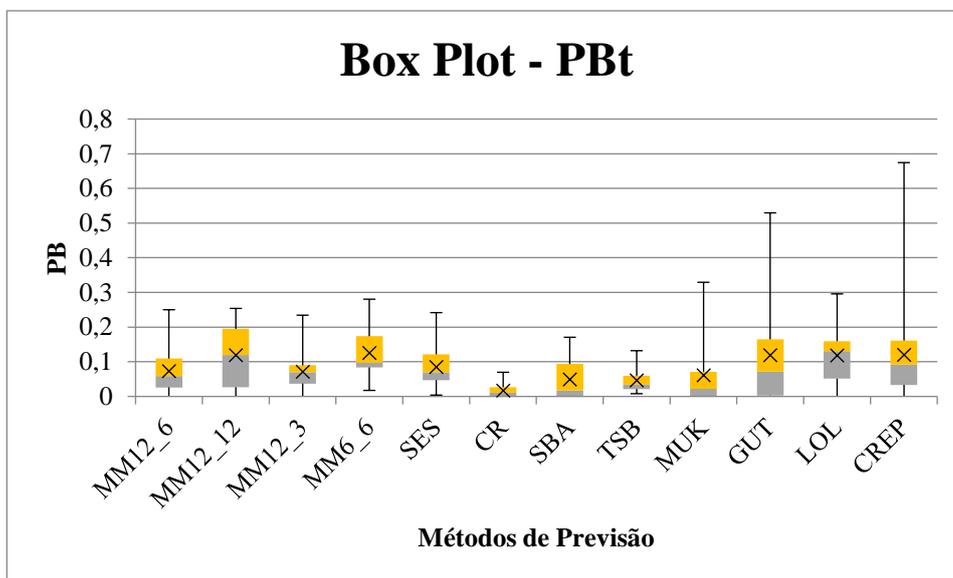


Figura 15. *Box plot* dos resultados PBt para o conjunto amostral reduzido

Tabela 11. Teste Shapiro-Wilk dos resultados do PBt

	MM12_6	MM12_12	MM12_3	MM6_6	SES	CR	SBA	TSB	MUK	GUT	LOL	CREP
Estat. W	0,885	0,898	0,886	0,954	0,918	0,828	0,785	0,876	0,676	0,743	0,961	0,648
p-valor	0,031	0,052	0,033	0,488	0,121	0,004	0,001	0,022	0,000	0,000	0,629	0,000
$1 - \alpha$	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05	0,05
Normal	Não	Sim	Não	Sim	Sim	Não	Não	Não	Não	Não	Sim	Não

Os resultados da análise estatística pela rANOVA para o PBt são mostrados na Tabela 12 e a correção de Greenhouse e Geisser, na Tabela 13. Para essa medida de exatidão, os itens não têm impacto significativo. Isso acontece porque o somatório de cada item é 1, uma vez que o PBt é uma porcentagem. A soma dos quadrados não é exatamente zero devido a arredondamentos. Não foi avaliada a interação entre itens e métodos de previsão. Outra conclusão destas análises é que os métodos de previsão são significativos, tanto na rANOVA quanto na correção GG.

Tabela 12. rANOVA do PBt

Fonte	SS	g.l.	MS	F	p-valor
Itens	3,93E-32	17	2,31E-33	2,63E-31	1
Métodos	0,264	11,000	0,024	2,733	0,003
Erro	1,644	187,000	0,009	-	-
Total	1,908	215,000	-	-	-

Tabela 13. Correção de Greenhouse e Geisser para o PBt

Fonte	SS	g.l.	MS	F	p-valor
Métodos	0,264	4,011	0,066	2,733	0,036
Erro	1,644	68,187	0,024	-	-

O resultado da comparação par a par pelo teste t é apresentado no Quadro 14. O método de Croston obteve os piores resultados nessa medida, apenas não foi significativamente diferente da rede MUK. Em geral, os métodos tradicionais tiveram um desempenho inferior, comparados aos outros tipos de métodos. Devido as suas grandes variâncias, as redes CREP e GUT só foram significativamente diferentes de CR. Já LOL foi melhor que outros quatro métodos. As médias móveis MM12_12 e MM6_6 foram os métodos que mais se destacaram, ambos com cinco métodos significativamente diferentes. Não foi possível diferenciar as médias dos cinco métodos identificados inicialmente com resultados superiores.

A partir dos resultados das três medidas de exatidão, foram escolhidos cinco métodos de previsão para serem implementadas no simulador. O Quadro 15 apresenta os motivos para escolha de cada método.

4.5.2 Simulação de Controle de Estoque

O simulador desenvolvido tem como objetivo emular o funcionamento do estoque e do sistema de controle dele. O sistema de controle adotado é o mesmo utilizado na empresa. Dessa forma, a política de controle no simulador é a (R, s, S), com R = 14, s = 60 dias de demanda, S = 90 ou 120 dias de demanda. O funcionamento do simulador é mostrado na Figura 16 por meio de um fluxograma de dados.

Quadro 14 Pares de métodos significativamente diferentes de acordo com os resultados PBt

Método com maior PBt	Método com menor PBt
CREP	CR
GUT	CR
LOL	CR
	SBA
	TSB
	MUK
MM12_12	MM12_6
	MM12_3
	CR
	SBA
	TSB
MM12_3	CR
MM12_6	CR
MM6_6	MM12_6
	MM12_3
	CR
	SBA
	TSB
SBA	CR
SES	CR
	TSB
TSB	CR

Quadro 15. Métodos de previsão selecionados

Método de previsão	Motivo para seleção
CREP	Bons resultados de MAPE; Significativamente superior a 3 outros métodos considerando MAPE.
LOL	Menor MAPE médio; Significativamente superior a 5 outros métodos considerando PBt.
MM12_6	Método de previsão atual da empresa.
MM6_6	Menor ME A médio; Maior PBt médio com σ pequeno.
TSB	2º menor ME A médio, com σ menor que o 1º.

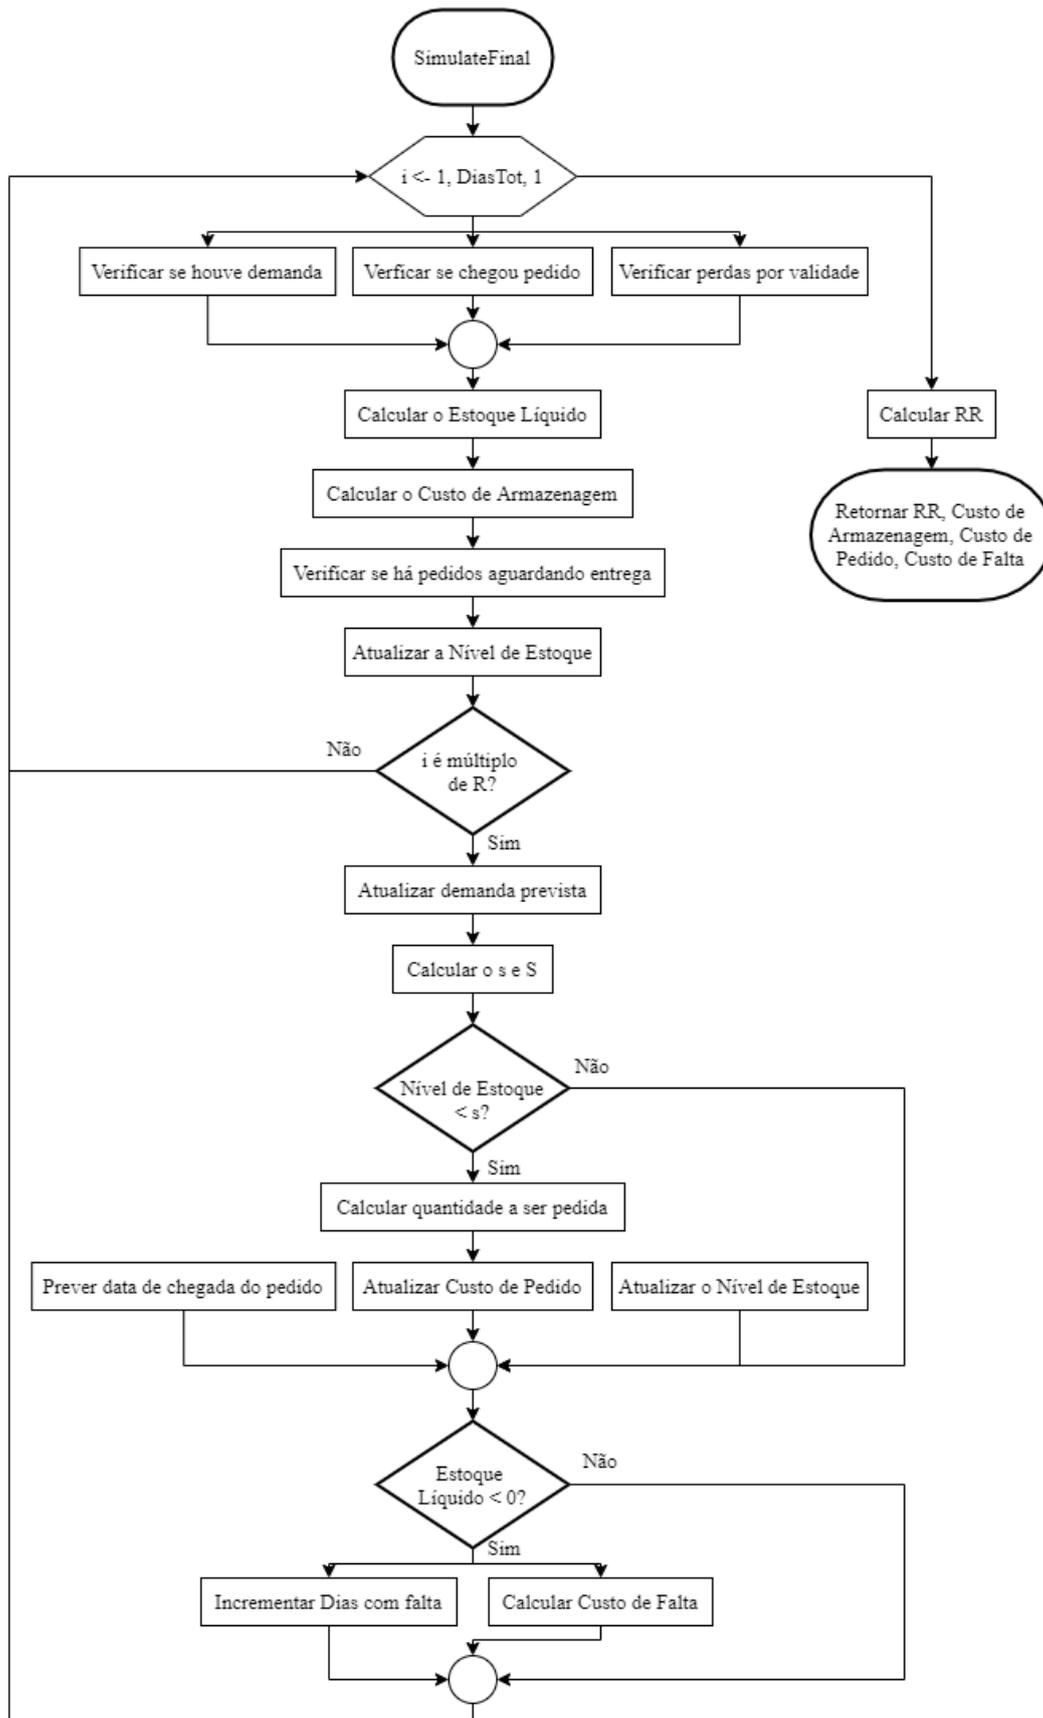


Figura 16. Fluxograma do funcionamento do simulador

O simulador de controle de estoque foi desenvolvido em Python 3.0, no ambiente de desenvolvimento Jupyter Notebook 6.0.3, com o auxílio das seguintes bibliotecas:

- Numpy;
- Pandas;
- Math;
- Matplotlib;
- Scipy;
- Datetime.

Durante a etapa Entendimento do Negócio, foram levantados os custos de estoque da empresa em função das características definidas no Quadro 9. Os custos de armazenagem em função do volume ocupado são apresentados na Tabela 14. É importante salientar a diferença entre unidade de compra e unidade de consumo, a primeira é definida pelo fornecedor e a quantidade comprada deve ser múltiplo desse valor, e a segunda é a unidade consumida internamente pela empresa.

Tabela 14. Custos de armazenagem em função do volume ocupado pela unidade de compra

Volume Ocupado	Característica	Custo/Unid. de compra/Mês	Custo/Unid. de compra/Ano
1	Muito Pequeno	R\$ 0,0178	R\$ 0,213
2	Pequeno	R\$ 0,278	R\$3,34
3	Médio	R\$ 1,00	R\$ 12,00
4	Grande	R\$ 11,25	R\$135,00
5	Muito Grande	R\$ 109,09	R\$1.309,08

Uma particularidade de alguns itens da amostra é que eles têm validade e caso não sejam utilizados até certa data, devem ser descartados. Caso ocorra, o custo dos itens perdidos é adicionado ao custo de armazenagem.

Os custos de falta em função da criticidade foram relacionados a quantidade de média de colaboradores que seriam impactados pela falta por dia. A partir dessa informação e do custo do dia de trabalho, obteve-se o custo por dia de falta do item, apresentados na Tabela 15. Como a empresa funciona como uma fábrica, são considerados dias corridos e não dias úteis para os cálculos.

Tabela 15. Custo de falta em função da criticidade do item

Criticidade	Impacto	Custo/Dia de falta
1	Atividade	R\$ 184,00
2	Área	R\$ 920,00
3	Linha	R\$ 2.760,00

O custo de pedido é fixo e igual a R\$53,85. A empresa definiu que o custo do item não faz parte do custo de pedido.

O tempo de entrega do material é obtido através de uma distribuição estatística determinada para cada item. Os parâmetros das distribuições foram definidos a partir do histórico de entregas dos itens na empresa.

4.5.2.1 Desenho de Testes

O simulador é executado 100 vezes por item para cada método de previsão e é utilizada a média dos resultados. A intenção é reduzir as chances de ter um *outliers* como resultado.

Os métodos de previsão utilizados são os apresentados no Quadro 15. As configurações dos métodos são as mesmas dos últimos testes, apresentadas no Quadro 11.

Os dados utilizados no simulador são os mesmos utilizados para o teste dos métodos na seção anterior. Para esses testes, o item R não foi retirado do conjunto amostral.

Para analisar o impacto de cada método no controle de estoque, foram escolhidas três métricas: RR, custo de estoque e estoque médio. A partir do contexto da empresa e de como a falta de material a afeta, optou-se por utilizar o *ready rate* como medida de serviço. Ele monitora a quantidade de unidades de tempo que o item ficou em falta, neste caso, a unidade é dia.

Do ponto de vista da empresa, o custo é um dos principais fatores para a tomada de decisão, dessa forma os três custos de estoque foram somados para obter essa métrica.

O espaço físico disponível para o armazenamento de itens é limitado. Deste modo, é importante monitorar a variação do tamanho do estoque em função do método de previsão utilizado.

Das três métricas, apenas o RR é independente de escala. Dessa forma, ela é única que pode ser feita a análise estatística com rANOVA e teste t de Student, como nos testes anteriores. O número grande de repetições, 100 vezes, foi adotado para dar maior confiança nas inferências em relação as outras duas métricas: custo de estoque e estoque diário médio.

4.5.2.2 Avaliação dos Resultados

A primeira métrica avaliada é o *ready rate*, que indica a proporção de dias sem falta de material. Os resultados do RR para os 19 itens da amostra são apresentados na Tabela 16. O método que apresentou o maior RR médio foi o TSB, além do menor desvio padrão. Entre as médias, a MM6_6 aparenta ter um RR médio superior a MM12_6. E entre as RNAs, o CREP obteve um RR médio superior ao de LOL. É necessário verificar se as diferenças observadas são significativas.

Tabela 16. Resultados do RR do simulador

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	0,952	0,962	0,962	0,978	0,980
B	0,853	0,824	0,893	0,977	0,984
C	0,944	0,943	0,946	0,829	0,900
D	0,994	0,995	1,000	0,999	0,999
E	1,000	1,000	1,000	0,967	0,967
F	0,783	0,827	0,781	0,515	0,509
G	0,999	0,999	0,996	0,990	0,995
H	0,763	0,815	0,950	0,876	0,925
I	0,994	0,994	0,982	0,959	0,962
J	1,000	1,000	1,000	1,000	1,000
K	0,999	1,000	1,000	0,967	0,976
L	0,958	0,958	0,951	0,967	0,957
M	0,959	0,994	1,000	0,952	0,958
N	0,943	0,953	0,922	0,842	0,869
O	0,964	1,000	1,000	0,963	0,965
P	0,878	0,997	0,984	0,764	0,773
Q	0,959	0,960	0,953	0,935	0,949
R	0,967	0,981	0,980	0,975	0,965
S	0,993	0,991	0,987	0,988	0,993
Média	0,942	0,957	0,962	0,918	0,928
$\sigma_{..}$	0,072	0,063	0,053	0,117	0,115

Para visualizar melhor a distribuição dos RR para cada método foi gerada o *box plot* apresentado na Figura 17. O *range* do primeiro quartil das duas RNAs é superior ao dobro dos outros métodos. E ao analisar o CREP, percebe-se que a média foi deslocada para o

primeiro quartil. Considerando essas observações, deve existir um *outlier* nesses dois métodos, no caso, o item F. Não é possível perceber nenhuma diferença clara entre os métodos pela Figura 17

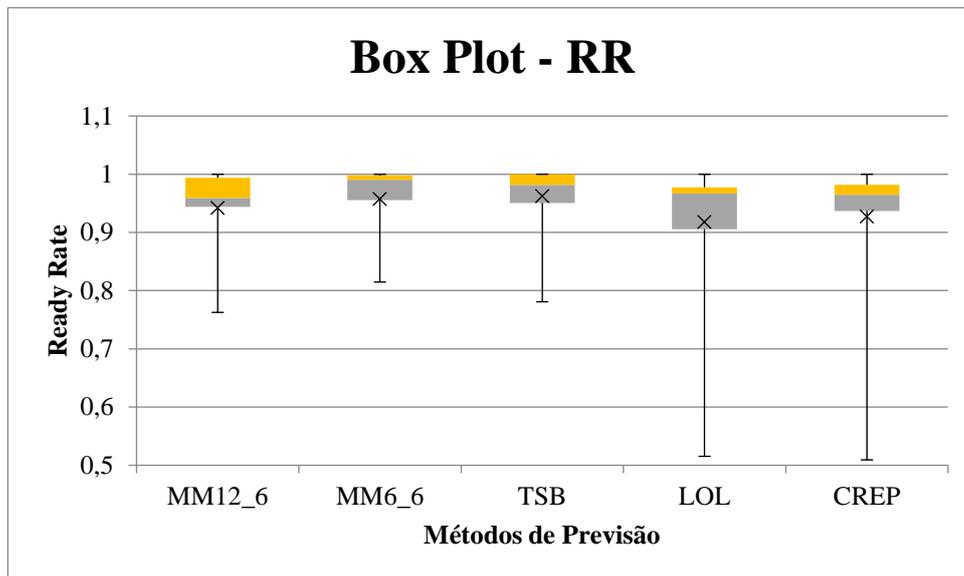


Figura 17. Box plot dos resultados de RR

O teste Shapiro-Wilk para os resultados de RR, mostrado na Tabela 17, indicou que todos os resultados violam a premissa de normalidade dos dados.

Tabela 17. Teste Shapiro-Wilk dos resultados ME|A

	MM12_6	MM6_6	TSB	LOL	CREP
Estat. W	0,759939	0,676035	0,71128	0,663199	0,594055
p-valor	0,000316	2,92E-05	7,6E-05	2,09E-05	3,87E-06
$1 - \alpha$	0,05	0,05	0,05	0,05	0,05
Normal	no	no	no	no	no

A rANOVA foi conduzida e seus resultados podem ser observado na Tabela 18 e a correção GG, na Tabela 19. A rANOVA indica que os métodos são significativos para o RR. No entanto, com a correção GG, o p-valor é 0,117, maior que o α determinado de 0,05.

Tabela 18. rANOVA do RR

Fonte	SS	g.l.	MS	F	p-valor
Itens	0,508168	18	0,028232	10,51655	1,03E-13
Métodos	0,027197	4	0,006799	2,532819	0,047569
Erro	0,193283	72	0,002684	-	-
Total	0,728648	94	-	-	-

Tabela 19. Correção de Greenhouse e Geisser para RR

Fonte	SS	g.l.	MS	F	p-valor
Métodos	0.027197	1.328935	0.020465	2.532819	0.116777
Erro	0.193283	23.92082	0.00808	-	-

Para comparar par a par os métodos, foi realizado o teste t de Student com confiança de 95%. O Quadro 16 apresenta os pares de métodos que rejeitaram a hipótese nula de médias iguais. Apenas dois pares podem ser considerados significativamente diferentes, CREP-LOL e LOL-TSB. Além deles, o par MM12_6-MM6_6, ficou próximo de ter a sua hipótese nula rejeitada, com um p-valor de 0,0518.

Quadro 16. Pares de métodos significativamente diferentes de acordo com os resultados de RR

Método com maior RR	Método com menor RR
CREP	LOL
TSB	LOL

O média móvel MM12_6 é o método de previsão utilizado atualmente pela empresa, dessa forma, é interessante comparar a diferença entre ele e os outros métodos. A Tabela 20 auxilia nessa comparação. Os métodos MM6_6 e TSB apresentam a variação média do RR positiva, enquanto LOL e CREP apresentaram valores negativos dessa média e as maiores variâncias dela.

Além da média geral, é interessante analisar o comportamento para cada item, se o método melhorou ou não a previsão em relação ao padrão atual. Para facilitar essa análise, foi gerada a Figura 18, que apresenta a quantidade de itens que apresentaram melhora na previsão, piora na previsão ou nenhuma alteração. A adoção da média MM6_6 levou a melhora no RR em 68,4% dos itens e a piora em 21% dos itens, enquanto, com o TSB, houve melhora em 52,6% dos casos e piora em 36,8%. As duas RNAs, LOL e CREP, apresentaram piora no RR em 63,1% e 68,4% dos itens, respectivamente.

Tabela 20. Alteração do RR em relação ao método padrão MM12_6

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	0,000	0,010	0,010	0,026	0,028
B	0,000	-0,029	0,040	0,124	0,131
C	0,000	-0,002	0,001	-0,116	-0,044
D	0,000	0,001	0,006	0,005	0,005
E	0,000	0,000	0,000	-0,033	-0,033
F	0,000	0,045	-0,002	-0,267	-0,273
G	0,000	0,000	-0,003	-0,009	-0,004
H	0,000	0,052	0,187	0,113	0,162
I	0,000	0,000	-0,012	-0,035	-0,032
J	0,000	0,000	0,000	0,000	0,000
K	0,000	0,001	0,001	-0,031	-0,023
L	0,000	0,000	-0,007	0,009	-0,001
M	0,000	0,034	0,041	-0,007	-0,001
N	0,000	0,010	-0,021	-0,101	-0,075
O	0,000	0,036	0,036	-0,002	0,001
P	0,000	0,119	0,105	-0,114	-0,105
Q	0,000	0,000	-0,007	-0,025	-0,010
R	0,000	0,014	0,013	0,008	-0,001
S	0,000	-0,002	-0,006	-0,005	0,000
Média	0,000	0,015	0,020	-0,024	-0,015
σ .	0,000	0,032	0,049	0,085	0,087

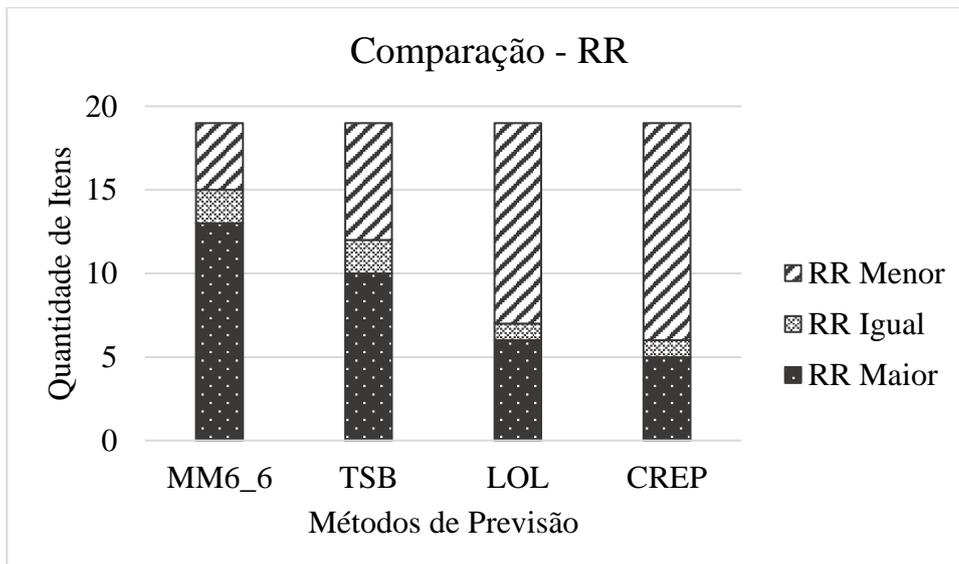


Figura 18. Alterações do RR comparada com o método padrão MM12_6

Os custos de estoque para os cinco métodos de previsão, durante o período de análise, são apresentados na Tabela 21. Em relação às médias gerais, os métodos MM6_6 e TSB apresentaram os menores custos de estoque médio, e as RNAs, os maiores custos. No entanto,

devido a magnitude dos valores e dos desvios padrões, inferências sobre os resultados são limitadas. Como o custo total tem uma variação grande entre os itens, chegando a diferença de mais de 30.000%, as análises da rANOVA e teste t de Student não foram realizadas.

Tabela 21. Resultados do custo de estoque do simulador

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	R\$ 76.927	R\$ 61.184	R\$ 61.000	R\$ 36.455	R\$ 32.572
B	R\$ 234.147	R\$ 281.171	R\$ 172.563	R\$ 37.857	R\$ 27.758
C	R\$ 29.740	R\$ 30.716	R\$ 29.135	R\$ 90.775	R\$ 53.048
D	R\$ 999	R\$ 912	R\$ 340	R\$ 525	R\$ 530
E	R\$ 1.360	R\$ 1.365	R\$ 602	R\$ 54.321	R\$ 54.984
F	R\$ 346.458	R\$ 275.625	R\$ 349.845	R\$ 769.093	R\$ 778.431
G	R\$ 2.229	R\$ 1.503	R\$ 8.655	R\$ 17.014	R\$ 9.136
H	R\$ 378.092	R\$ 295.635	R\$ 81.431	R\$ 196.848	R\$ 121.715
I	R\$ 10.176	R\$ 9.708	R\$ 29.376	R\$ 65.992	R\$ 60.620
J	R\$ 2.212	R\$ 2.104	R\$ 223	R\$ 2.212	R\$ 1.405
K	R\$ 2.348	R\$ 113	R\$ 114	R\$ 51.669	R\$ 38.614
L	R\$ 67.344	R\$ 68.089	R\$ 77.941	R\$ 52.892	R\$ 68.431
M	R\$ 64.829	R\$ 10.552	R\$ 466	R\$ 75.939	R\$ 66.846
N	R\$ 91.144	R\$ 75.652	R\$ 125.216	R\$ 251.666	R\$ 209.484
O	R\$ 3.880	R\$ 115	R\$ 114	R\$ 4.077	R\$ 3.827
P	R\$ 64.879	R\$ 2.231	R\$ 9.171	R\$ 125.038	R\$ 120.209
Q	R\$ 66.923	R\$ 66.774	R\$ 81.600	R\$ 105.536	R\$ 83.106
R	R\$ 53.333	R\$ 30.621	R\$ 32.575	R\$ 39.862	R\$ 55.285
S	R\$ 11.622	R\$ 15.376	R\$ 21.808	R\$ 20.315	R\$ 12.019
Média	R\$ 79.402	R\$ 64.708	R\$ 56.957	R\$ 105.163	R\$ 94.633
$\sigma..$	R\$ 113.938	R\$ 101.042	R\$ 85.863	R\$ 173.540	R\$ 173.389

Para facilitar as análises, o custo de estoque do item pelo método MM12_6 foi adotado como referência, assim, os custos dos outros itens são apresentados como uma porcentagem dele (Tabela 22). Dessa forma, é possível observar a proporção do impacto para cada item. Como são medidas diferentes, a média e desvio padrão gerais não fornecem informações relevantes e não são calculados.

É possível perceber alguns resultados fora do padrão, como um aumento de mais 4000% no custo de estoque do item E pelo método CREP e a redução de quase 99,3% do custo de estoque do item M pelo método TSB. Esses comportamentos podem ser explicados pela diferença de magnitude entre os custos de falta e de armazenagem.

Tabela 22. Resultados do custo de estoque do simulador normalizados pelo método MM12_6

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	1,000	0,795	0,793	0,474	0,423
B	1,000	1,201	0,737	0,162	0,119
C	1,000	1,033	0,980	3,052	1,784
D	1,000	0,913	0,341	0,526	0,530
E	1,000	1,004	0,442	39,941	40,428
F	1,000	0,796	1,010	2,220	2,247
G	1,000	0,674	3,884	7,635	4,100
H	1,000	0,782	0,215	0,521	0,322
I	1,000	0,954	2,887	6,485	5,957
J	1,000	0,951	0,101	1,000	0,635
K	1,000	0,048	0,048	22,009	16,448
L	1,000	1,011	1,157	0,785	1,016
M	1,000	0,163	0,007	1,171	1,031
N	1,000	0,830	1,374	2,761	2,298
O	1,000	0,030	0,029	1,051	0,986
P	1,000	0,034	0,141	1,927	1,853
Q	1,000	0,998	1,219	1,577	1,242
R	1,000	0,574	0,611	0,747	1,037
S	1,000	1,323	1,876	1,748	1,034

Os maiores valores de custo de estoque apresentados pelas RNAs podem ser explicados pela sua tendência de subdimensionar a previsão de demanda, identificada pelo ME|A. Isso ocorre porque os custos de falta são significativamente maiores os custos de armazenagem, neste estudo de caso.

A Figura 19 apresenta a quantidade de itens que tiveram seus custos de estoque aumentados e reduzidos com a mudança de métodos de previsão em relação ao padrão (MM12_6). É possível perceber que os métodos MM6_6 e TSB reduziram os custos de estoque para mais itens do que aumentaram. Enquanto, para LOL e CREP foi o contrário. Essa análise não compreende o tamanho da alteração no custo, apenas se foi positiva ou negativa.

Por fim, é interessante analisar o custo total de estoque para cada método, apresentado na Tabela 23. Para auxiliar na comparação, é calculada a diferença em porcentagem para o método de previsão padrão MM12_6. Estes resultados, reforçam as conclusões anteriores de que os métodos MM6_6 e TSB reduziram custos e LOL e CREP os aumentaram. O melhor resultado foi o do TSB com uma redução de custo de mais de um quarto.

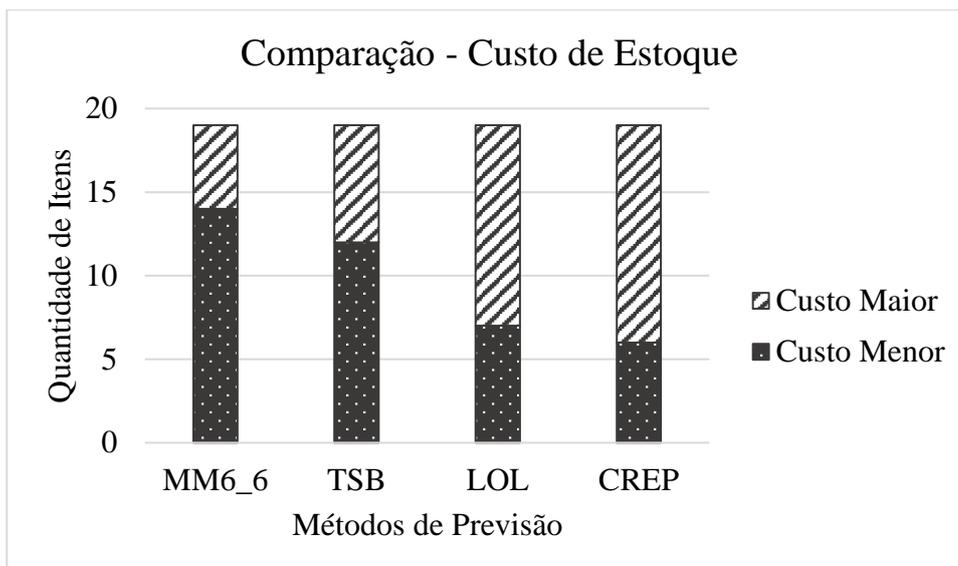


Figura 19. Alterações do custo de estoque comparada com o método padrão MM12_6

Tabela 23. Custo de estoque total por método e variação percentual em relação ao método de previsão padrão MM12_6

	MM12_6	MM6_6	TSB	LOL	CREP
Custo Total de Estoque	R\$ 1.508.640	R\$ 1.229.445	R\$ 1.082.176	R\$ 1.998.088	R\$ 1.798.021
Diferença em %	0%	-18,5%	-28,3%	32,4%	19,2%

No entanto, basear as decisões apenas na redução de custo de estoque e no RR pode gerar problemas com o espaço físico disponível. Dessa forma, foram levantados os valores de estoque médio para cada item em cada configuração do simulador. Os resultados são apresentados na Tabela 24. Observa-se que as quantidades de estoque para diferentes itens variam consideravelmente. E como os itens possuem diferentes tamanhos, não é possível agrupar os itens em uma média, é necessário, antes, analisá-los individualmente.

Na Tabela 25, os estoques médios são normalizados em função do estoque médio do método padrão. Dessa forma, é possível visualizar o impacto dos métodos em cada item mais facilmente. Para complementar a análise, foi compilado a quantidade de vezes que cada método obteve um estoque médio menor e maior que o padrão, apresentado na Figura 20.

Tabela 24. Estoque médio por item

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	13178	13190	12972	13961	13907
B	37,9	42,0	71,3	62,7	56,4
C	24,1	22,8	23,7	13,7	17,0
D	17,5	17,7	20,2	16,6	16,7
E	1,2	1,2	1,7	0,7	0,7
F	41,7	55,2	62,1	14,2	13,4
G	67,7	70,7	68,5	50,1	51,3
H	4,0	6,2	21,7	29,8	37,5
I	26,9	27,6	25,8	26,8	26,7
J	0,7	0,7	1,5	0,7	0,9
K	57,2	59,9	62,2	47,0	46,1
L	1329,3	1523,2	1555,2	1630,0	1567,9
M	28,8	32,1	30,8	20,0	21,0
N	84,1	84,1	91,2	56,3	59,2
O	16,7	22,3	19,6	13,4	14,5
P	14,6	17,5	17,7	5,0	6,6
Q	80,2	84,6	96,2	46,5	49,6
R	953,6	1032,2	1098,6	1104,9	1065,1
S	187,1	185,3	177,1	138,2	151,1

Tabela 25. Estoque médio dos itens normalizado pelo método padrão MM12_6

Item	MM12_6	MM6_6	TSB	LOL	CREP
A	1	1,001	0,984	1,059	1,055
B	1	1,108	1,881	1,653	1,488
C	1	0,949	0,986	0,568	0,707
D	1	1,012	1,156	0,948	0,952
E	1	0,997	1,440	0,616	0,613
F	1	1,323	1,489	0,340	0,320
G	1	1,044	1,011	0,740	0,757
H	1	1,546	5,399	7,424	9,348
I	1	1,027	0,956	0,995	0,993
J	1	0,998	2,206	0,989	1,372
K	1	1,046	1,087	0,822	0,806
L	1	1,146	1,170	1,226	1,180
M	1	1,112	1,069	0,693	0,728
N	1	1,001	1,084	0,670	0,704
O	1	1,336	1,174	0,807	0,868
P	1	1,199	1,210	0,344	0,454
Q	1	1,055	1,200	0,580	0,619
R	1	1,082	1,152	1,159	1,117
S	1	0,990	0,946	0,738	0,807

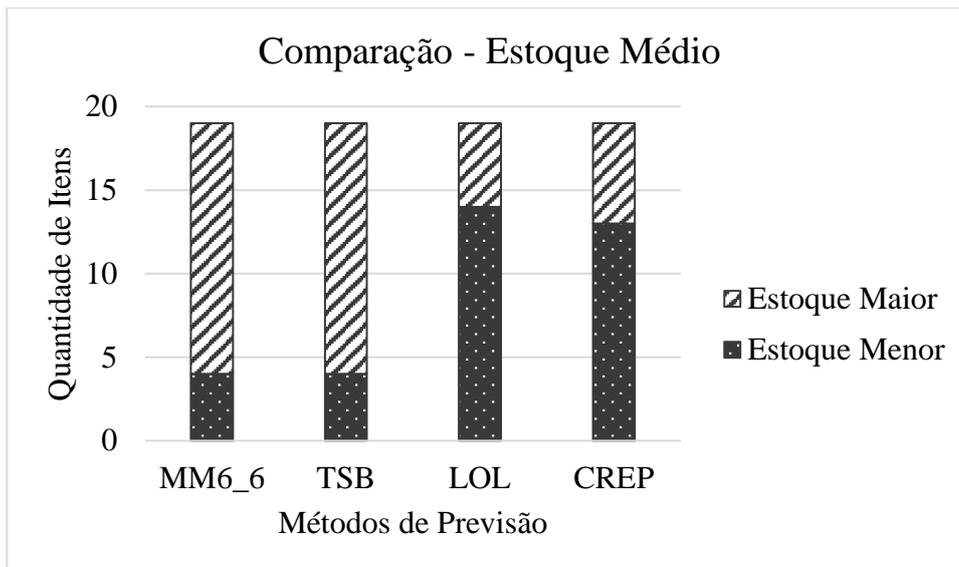


Figura 20. Alterações do estoque médio comparado com o método padrão MM12_6

Como esperado, os métodos MM6_6 e TSB, que reduziram os custos de estoque, aumentaram o estoque médio. E as RNAs, com a sua tendência de subdimensionar a previsão, resultaram em estoques menores. Entre as redes, CREP resultou em um estoque menor para 13 itens e LOL, para 14.

5 CONSIDERAÇÕES FINAIS

5.1 CONCLUSÕES

A evolução das tecnologias habilitadoras da 4ª Revolução Industrial permitiu avanços significativos em diferentes áreas da indústria. Entre essas tecnologias, as redes neurais artificiais apresentam grande potencial, pois tem flexibilidade de aplicação e conseguem resolver problemas não lineares. Entre as diferentes arquiteturas de RNAs, destaca-se a *multilayer perceptron*, uma das mais utilizadas.

Nesta pesquisa, foi implementada uma MLP para a previsão de demanda intermitente com conhecimento especialista em uma empresa de MRO de motores de helicópteros.

O desenvolvimento seguiu uma versão parcial da metodologia CRISP-DM, compreendendo cinco das seis etapas. A adoção de uma metodologia criada com foco na aplicação na área de dados foi essencial para a identificação do conhecimento especializado. Em especial, as etapas de Entendimento do Negócio e de Entendimento dos Dados foram fundamentais para o levantamento das variáveis que poderiam conter informações relevantes para o comportamento da demanda dos consumíveis e que seriam utilizadas pela RNA. Foram selecionadas as informações: entradas e saídas de motores em três áreas diferentes da empresa, ano, trimestre e mês da previsão.

O conjunto de dados de demandas históricas de 20 consumíveis possibilitou a modelagem da rede neural artificial e o seu teste. Os testes foram divididos em duas etapas. A primeira, verificou a capacidade de previsão da rede CREP ao compará-la com 11 outros métodos de previsão em três medidas de exatidão (MAPE, ME|A, PBt). A segunda, avaliou o impacto de cinco métodos de previsão selecionados no sistema de controle de estoque da empresa através de um simulador. Os métodos foram avaliados por três métricas: *ready rate*, custo de estoque e estoque médio.

A rede neural CREP obteve bons resultados de MAPE, o que indica que possui um erro absoluto médio baixo. Foi a única RNA que pôde ser considerada significativamente superior a três outros métodos de previsão nessa métrica. Em relação ao erro médio, as RNAs tiveram resultados inferiores aos outros métodos de previsão. De forma geral, as redes neurais tendem a subdimensionar a demanda. Analisando apenas as redes neurais, CREP apresentou

os menores resultados de ME|A, mas não foi possível verificar essa afirmação estatisticamente. Avaliando a medida de exatidão PBT, a rede proposta apresentou a maior média geral. No entanto, estatisticamente só foi superior ao método CR.

É importante ressaltar uma diferença entre a atualização dos métodos de previsão adotados. As médias atualizam a sua previsão periodicamente (a cada 3, 6 ou 12 meses), os métodos tradicionais são atualizados a cada período. Já as redes neurais são treinadas com um *dataset* e depois todas as previsões são feitas sem retreinamento da rede. Dessa forma, elas não aprendem com as novas entradas, como nos outros métodos.

Ao analisar os resultados do simulador, foi observado que as duas RNAs analisadas, CREP e LOL, apresentaram resultados inferiores aos outros métodos, inclusive comparado ao método padrão da empresa, MM12_6. Houve redução no RR em 13 dos 19 itens analisados com a adoção do CREP como método de previsão do simulador. O custo de estoque subiu 19,2% com as previsões do CREP e 32,4% com LOL. Observando a variação do estoque em relação ao método padrão, CREP reduziu o estoque médio em 14 dos 19 itens. Esses resultados do simulador são explicados pela tendência a subdimensionar a demanda identificada pelo ME|A.

Uma consideração interessante sobre os resultados do simulador é que eles não correspondem exatamente a realidade. Isso porque existe interferência humana no processo. Se um item crítico teve uma demanda grande fora do esperado, a equipe de PCP é avisada e faz um pedido de urgência para o fornecedor. A equipe de PCP pode ter a informação que certo item vai ter uma demanda maior nos próximos períodos e fazer um pedido maior deste item. Esse conhecimento especialista não pode ser implementado no simulador.

5.2 TRABALHOS FUTUROS

A facilidade de implementar novos atributos nas redes neurais é um incentivo a continuar a pesquisa sobre variáveis relevantes para o processo. Dessa forma, as redes podem fazer novas conexões e, possivelmente, melhorar a sua previsão. Outra possibilidade é verificar os resultados de outras redes neurais além do MLP.

Uma linha de pesquisa interessante é a de criação de modelos híbridos de previsão, compostos por redes neurais e métodos tradicionais. Dessa forma, seria possível combinar os pontos fortes de cada método e compensar os pontos fracos.

É interessante, também, verificar o comportamento dos métodos de previsão para outras agregações temporais, como dia, mês e trimestre.

A extensão do banco de dados amostral é outra possibilidade para trabalhos futuros. Com isso, mais comportamentos de demanda seriam analisados e seria possível identificar o impacto desses comportamentos na previsão. Além disso, poderiam ser definidas áreas de atuação específicas para os diferentes métodos, melhorando a previsão total do banco.

Considerando que este trabalho é um estudo de caso e as conclusões obtidas têm limitações relacionadas a sua generalização, sugere-se a implementação de redes neurais com conhecimento especialista em empresas e áreas diferentes. Desta forma, seria possível analisar melhor o potencial deste método de previsão.

REFERÊNCIAS BIBLIOGRÁFICAS

BABAI, M. Z.; SYNTETOS, A.; TEUNTER, R. Intermittent demand forecasting: An empirical study on accuracy and the risk of obsolescence. **International Journal of Production Economics**, v. 157, n. 1, p. 212–219, 2014.

BOHANEK, M.; ROBNIK-ŠIKONJA, M.; BORŠTNAR, M. K. Decision-making framework with double-loop learning through interpretable black-box machine learning models. **Industrial Management & Data Systems**, 2017.

BOX, G. E. P.; HUNTER, W. H.; HUNTER, S. **Statistics for experimenters**. [s.l.] John Wiley and sons New York, 1978. v. 664

BROWN, R. G. **Smoothing, forecasting and prediction of discrete time series**. [s.l.] Englewood Cliffs, N.J., Prentice-Hall, 1962.

BUNKER, R. P.; THABTAH, F. A machine learning framework for sport result prediction. **Applied computing and informatics**, v. 15, n. 1, p. 27–33, 2019.

CARMO, J. L.; RODRIGUES, A. J. Adaptive forecasting of irregular demand processes. **Engineering Applications of Artificial Intelligence**, v. 17, n. 2, p. 137–143, 2004.

CHAPMAN, P. et al. CRISP-DM 1.0: Step-by-step data mining guide. **SPSS inc**, v. 9, p. 13, 2000.

CROSTON, J. D. Forecasting and Stock Control for Intermittent Demands. **Operational Research Quarterly**, v. 23, n. 2, 1972.

DA ROCHA, B. C.; DE SOUSA JUNIOR, R. T. Identifying bank frauds using CRISP-DM and decision trees. **International Journal of Computer Science and Information Technology**, v. 2, n. 5, p. 162–169, 2010.

DIAS, M. A. P. **Administração de materiais: uma abordagem logística** . [s.l.] Editora Atlas SA, 2000.

EAVES, A. H. C.; KINGSMAN, B. G. Forecasting for the ordering and stock-holding of spare parts. **Journal of the Operational Research Society**, v. 55, n. 4, p. 431–437, 21 abr. 2004.

FRANK, E.; HALL, M. A.; WITTEN, I. H. The WEKA Workbench. In: **Data**

Mining: Practical Machine Learning Tools and Techniques. 4. ed. [s.l.] Morgan Kaufmann, 2016.

GHOBBAR, A. A.; FRIEND, C. H. Evaluation of forecasting methods for intermittent parts demand in the field of aviation: a predictive model. **Computers & Operations Research**, v. 30, n. 14, p. 2097–2114, 2003.

GIL, A. C. **Métodos e técnicas de pesquisa social.** [s.l.] 6. ed. Editora Atlas SA, 2008.

GILLILAND, M. Is forecasting a waste of time? **SUPPLY CHAIN MANAGEMENT REVIEW**, V. 6, NO. 4 (JULY/AUG. 2002), P. 16-23: ILL, 2002.

GIRDEN, E. R. **ANOVA: Repeated measures.** [s.l.] Sage Publications, Inc., 1992.

GROSSBERG, S. T. **Studies of mind and brain: Neural principles of learning, perception, development, cognition, and motor control.** [s.l.] Springer Science & Business Media, 2012. v. 70

GUTIERREZ, R. S.; SOLIS, A. O.; MUKHOPADHYAY, S. Lumpy demand forecasting using neural networks. **International Journal of Production Economics**, v. 111, n. 2, p. 409–420, 2008.

HALL, M. et al. The WEKA Data Mining Software: An Update. **SIGKDD Explorations**, v. 11, n. 1, p. 10–18, 2009.

HAX, A. C.; CANDEA, D. **Production and inventory management.** [s.l.] Prentice-Hall Englewood Cliffs, NJ, 1984. v. 1

HILLIER, F. S.; LIEBERMAN, G. J. **Introduction to operations research.** [s.l.] McGraw-Hill Science, Engineering & Mathematics, 1995.

HUANG, G.-B.; ZHU, Q.-Y.; SIEW, C.-K. Extreme learning machine: theory and applications. **Neurocomputing**, v. 70, n. 1–3, p. 489–501, 2006.

INDERFURTH, K.; MINNER, S. Safety stocks in multi-stage inventory systems under different service measures. **European Journal of Operational Research**, v. 106, n. 1, p. 57–73, 1998.

KESELMAN, H. J. et al. Testing the validity conditions of repeated measures F tests. **Psychological Bulletin**, v. 87, n. 3, p. 479, 1980.

KUMAR, S. et al. Investigating the value of integrated operations planning: A case-based approach from automotive industry. **International Journal of Production Research**, v. 56, n. 22, p. 6971–6992, 2018.

LEE, J.; BAGHERI, B.; KAO, H. A. A Cyber-Physical Systems architecture for Industry 4.0-based manufacturing systems. **Manufacturing Letters**, v. 3, p. 18–23, 2015.

LOLLI, F. et al. Single-hidden layer neural networks for forecasting intermittent demand. **International Journal of Production Economics**, v. 183, n. July 2016, p. 116–128, 2017.

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

MIKOLOV, T. et al. Extensions of recurrent neural network language model. **ICASSP, IEEE International Conference on Acoustics, Speech and Signal Processing - Proceedings**, p. 5528–5531, 2011.

MINSKY, M.; PAPERT, S. A. **Perceptrons: An introduction to computational geometry**. [s.l.] MIT press, 2017.

MITCHELL, T. M. **Machine Learning**. [s.l.] McGraw-Hill Science, Engineering & Mathematics, 1997.

MUKHOPADHYAY, S.; SOLIS, A. O.; GUTIERREZ, R. S. The accuracy of non-traditional versus traditional methods of forecasting lumpy demand. **Journal of Forecasting**, v. 31, n. 8, p. 721–735, 2012.

PAL, S. K.; MITRA, S. Multilayer perceptron, fuzzy sets, and classification. **IEEE Transactions on Neural Networks**, v. 3, n. 5, p. 683–697, 1992.

PORRAS, E.; DEKKER, R. An inventory control system for spare parts at a refinery: An empirical comparison of different re-order point methods. **European Journal of Operational Research**, v. 184, n. 1, p. 101–132, 2008.

ROSENBLATT, F. **Principles of neurodynamics: Perceptions and the theory of brain mechanisms**. [s.l.] Spartan, 1962.

RUMELHART, D. .; HINTON, G. .; WILLIAMS, R. . **Learning Internal Representations By Error Propagation (original) Explorations in the Micro-Structure of Cognition Vol. 1 : Foundations**, 1986.

SALKIN, C. et al. A conceptual framework for Industry 4.0. In: **Industry 4.0: Managing the Digital Transformation**. [s.l.] Springer, 2018. p. 3–23.

SCHNEIDER, H. Effect of service-levels on order-points or order-levels in inventory models. **International Journal of Production Research**, v. 19, n. 6, p. 615–631, 1981.

SILVA, I. N. DA; SPATTI, D. H.; FLAUZINO, R. A. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. 2. ed. [s.l.] Artliber Editora, 2016.

SILVA, S. R.; SCHIMIDT, F. Redução de variáveis de entrada de redes neurais artificiais a partir de dados de análise de componentes principais na modelagem de oxigênio dissolvido. **Química Nova**, v. 39, n. 3, p. 273–278, 2016.

SILVER, E. A.; PYKE, D. F.; THOMAS, D. J. **Inventory and Production Management in Supply Chains**. 4th. ed. [s.l.] CRC Press, 2017.

SYNTETOS, A. A. et al. Forecasting and stock control: A study in a wholesaling context. **International Journal of Production Economics**, v. 127, n. 1, p. 103–111, 2010.

SYNTETOS, A. A.; BOYLAN, J. E. On the bias of intermittent demand estimates. **International Journal of Production Economics**, v. 71, n. 1–3, p. 457–466, 2001.

SYNTETOS, A. A.; BOYLAN, J. E. The accuracy of intermittent demand estimates. **International Journal of Forecasting**, v. 21, n. 2, p. 303–314, 2005.

SYNTETOS, A. A.; BOYLAN, J. E.; CROSTON, J. D. On the categorization of demand patterns. **Journal of the Operational Research Society**, v. 56, n. 5, p. 495–503, 21 maio 2005.

TEUNTER, R. H.; SYNTETOS, A. A.; BABAI, M. Z. Intermittent demand: Linking forecasting to inventory obsolescence. **European Journal of Operational Research**, v. 214, n. 3, p. 606–615, nov. 2011.

WALLSTRÖM, P.; SEGERSTEDT, A. Evaluation of forecasting error measurements and techniques for intermittent demand. **International Journal of Production Economics**, v. 128, n. 2, p. 625–636, dez. 2010.

WATSON, R. B. The effects of demand-forecast fluctuations on customer service and inventory cost when demand is lumpy. **Journal of the Operational Research Society**, v. 38, n. 1, p. 75–82, 1987.

WERBOS, P. J. Backpropagation through time: what it does and how to do it. **Proceedings of the IEEE**, v. 78, n. 10, p. 1550–1560, 1990.

WIELAND, A.; LEIGHTON, R. **Geometric analysis of neural network capabilities**. 1st IEEE Int. Conf. on Neural Networks. **Anais...**1987

WILLEMAIN, T. R. et al. Forecasting intermittent demand in manufacturing: a comparative evaluation of Croston's method. **International Journal of Forecasting**, v. 10, n. 4, p. 529–538, dez. 1994.

WILLEMAIN, T. R.; SMART, C. N.; SCHWARZ, H. F. A new approach to forecasting intermittent demand for service parts inventories. **International Journal of Forecasting**, v. 20, n. 3, p. 375–387, 2004.

WILLIAMS, T. M. Stock Control with Sporadic and Slow-Moving Demand. **Journal of the Operational Research Society**, v. 35, n. 10, p. 939–948, 20 out. 1984.

XIANG, C.; DING, S. Q.; LEE, T. H. Geometrical Interpretation and Architecture Selection of MLP. **IEEE Transactions on Neural Networks**, v. 16, n. 1, p. 84–96, jan. 2005.

ZAIONTZ, C. **Real Statistics Resource Pack**, 2013. Disponível em: <www.real-statistics.com>