

**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
**ESCOLA DE ENGENHARIA**  
**DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE**  
**PRODUÇÃO**

Leandro Reis Muniz

**PREVISÃO DE DEMANDA, CLASSIFICAÇÃO**  
**MULTICRITÉRIO E OTIMIZAÇÃO NO**  
**PLANEJAMENTO DE PEÇAS SOBRESSALENTES NA**  
**INDÚSTRIA MINERAL**

Belo Horizonte – MG

2020

Leandro Reis Muniz

**PREVISÃO DE DEMANDA, CLASSIFICAÇÃO  
MULTICRITÉRIO E OTIMIZAÇÃO NO  
PLANEJAMENTO DE PEÇAS SOBRESSALENTES NA  
INDÚSTRIA MINERAL**

Tese apresentada ao Curso de Pós-Graduação em Engenharia de Produção da Universidade Federal de Minas Gerais como requisito parcial para obtenção do grau de Doutor em Engenharia de Produção.

Orientador: PhD. Dr. Samuel Vieira Conceição

Coorientador: Dr. João Flávio de Freitas Almeida

Coorientadora: Dra. Lásara Fabrícia Rodrigues

Belo Horizonte – MG

2020

M966p

Muniz, Leandro Reis.

Previsão de demanda, classificação multicritério e otimização no planejamento de peças sobressalentes na indústria mineral [recurso eletrônico] / Leandro Reis Muniz. - 2020.

1 recurso online (127 f. : il., color.) : pdf.

Orientador: Samuel Vieira Conceição.

Coorientador: João Flávio de Freitas Almeida.

Coorientadora: Lásara Fabrícia Rodrigues.

Tese (doutorado) - Universidade Federal de Minas Gerais, Escola de Engenharia.

Apêndices: f. 100-127.

Bibliografia: f. 90-99.

Exigências do sistema: Adobe Acrobat Reader.

1. Engenharia de produção - Teses. 2. Otimização - Teses. 3. Processo decisório - Teses. 4. Programação linear - Teses. I. Conceição, Samuel Vieira. II. Universidade Federal de Minas Gerais. Escola de Engenharia. III. Título.

CDU: 658.5(043)



**UNIVERSIDADE FEDERAL DE MINAS GERAIS**  
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO




## FOLHA DE APROVAÇÃO


**PREVISÃO DE DEMANDA, CLASSIFICAÇÃO MULTICRITÉRIO E OTIMIZAÇÃO  
NO PLANEJAMENTO DE PEÇAS SOBRESSALENTES NA INDÚSTRIA MINERAL**

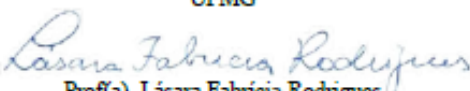
### **LEANDRO REIS MUNIZ**


Tese submetida à Banca Examinadora designada pelo Colegiado do Programa de Pós-Graduação em ENGENHARIA DE PRODUÇÃO, como requisito para obtenção do grau de Doutor em ENGENHARIA DE PRODUÇÃO, área de concentração PESQUISA OPERACIONAL E INTERVENÇÃO EM SISTEMAS SOCIOTÉCNICOS, linha de pesquisa Otimização e Simulação de Sistemas Logísticos e de Grande Porte.


Aprovada em 26 de março de 2020, pela banca constituída pelos membros:

  
Prof(a). Samuel Vieira Conceição - Orientador  
Universidade Federal de Minas Gerais

  
Prof(a). João Flavio de Freitas Almeida  
UFMG

  
Prof(a). Lásara Fabricia Rodrigues  
UFMG

  
Prof(a). Helton Cristiano Gomes  
Universidade Federal de Ouro Preto

  
Prof(a). Magno Silvério Campos  
UFOP

Belo Horizonte, 26 de março de 2020.

## AGRADECIMENTOS

Repito aqui a oração que me fortaleceu nesta caminhada como forma de agradecimento:

*Senhor, ao iniciar esta nova jornada, peço tua proteção.*

*Volta teus olhos para o caminho que ora vou trilhar, estendendo a tua luz sobre todos os meus passos.*

*Ilumina a minha estrada, pois sempre estou contigo, sou forte e capaz de suportar as lições que me destinas.*

*Orienta as decisões que deverei tomar.*

*Acompanha-me e certifica-me que estarei indo ao encontro das minhas melhores opções.*

*Faz com que minha jornada tenha sucesso, Senhor.*

*Livra-me dos perigos, dos acidentes e de qualquer situação que possa me impedir de construir minha felicidade.*

*Governa as minhas ações e o comportamento daqueles que podem influenciar o meu destino.*

*Dirige a tua luz divina para este filho teu, que ora com fervor e é motivado pelo teu amor.*

*Amém.*

Agradeço a minha esposa, Tarcila, pelo apoio incondicional e paciência em todos os momentos em que me ausentei para me dedicar ao doutorado. Agradeço também ao meu filho, Murilo, que por diversas vezes me acalentou. A minha mãe Maria Antônia sou grato por se preocupar e me fortalecer. À Lucília agradeço pelas orações e aos familiares pelo incentivo.

Aos amigos, em especial ao Allexandre Fortes e Lucas Félix, obrigado pelos auxílios computacionais. À amiga Lásara Fabrícia eu agradeço pelos conselhos e auxílio nas revisões textuais.

Aos professores e colegas de trabalho da Coenp, Demec e à UFSJ, pelo suporte em diversas situações.

Agradeço à UFSJ pela possibilidade de afastamento para qualificação e programa Pqualis.

Aos profissionais da UFMG, obrigado pela disponibilidade nas demandas educacionais, e à UFMG pelo ensino de qualidade, público e gratuito.

Ao meu orientador e amigo, Prof. PhD. Dr. Samuel Vieira Conceição, agradeço pela orientação, paciência, compreensão e por direcionar com mestria as ações do trabalho da tese.

*Faça o bem sem olhar a quem.*

## RESUMO

Este trabalho apresenta uma metodologia para gerenciamento de peças sobressalentes no ciclo normal de operação. Apresenta uma revisão de literatura, estuda os modelos de previsão e propõe modelos conjugados. Posteriormente, apresenta uma metodologia combinada por métodos qualitativos e quantitativos de quatro fases para auxílio na tomada de decisão nos ciclos mensais de planejamento de peças sobressalentes. Responde à questão fundamental de quais peças sobressalentes estocar e em quais quantidades. A primeira fase consiste na seleção de critérios utilizando o Método Ponto de Corte, subcritérios e delimitação das categorias pelo Método Vital, Essencial e Desejável (VED). A segunda utiliza Análise Hierárquica de Processos (AHP) e o Método *Botton-up* para calcular a criticidade total de cada item. A terceira representa o modelo de previsão que gera os valores da variável do modelo de otimização. Por fim, a quarta fase consiste em um modelo de otimização biobjetivo, baseado em preço e criticidade que pode realizar uma única iteração ou diversas pelo Método  $\epsilon$ -ésilon e construção da Curva Pareto Ótima com base em previsões e revisões mensais de saldos disponíveis para estocagem dos itens. O modelo é suportado por heurísticas para impedir inviabilidades e reduzir rupturas de estoque. A abordagem desenvolvida avalia peças de reposição com dados reais de 9.263 itens de uma mineradora. Como resultados, tem-se melhor suporte para a decisão durante os ciclos de planejamento e controle adequado dos valores imobilizados em estoque. A contribuição científica consiste no modelo qualitativo e quantitativo multicritério na gestão de previsão de peças sobressalentes com e sem *lead time*, de modelos de otimização biobjetivo e métodos heurísticos aplicados em dados reais da indústria mineral.

**Palavras-chave:** Tomada de decisão. Peças sobressalentes. AHP. Programação linear. Programação biobjetivo.



## ABSTRACT

This work presents a methodology for managing spare parts in the normal cycle of operation. It presents a literature review, studies forecasting models and proposes combined models. Subsequently, it presents a methodology combined by qualitative and quantitative methods of four phases to assist in decision making in the monthly spare parts planning cycles. It answers the fundamental question of which spare parts to stock and in what quantities. The first phase consists of the selection of criteria using the Cutoff Method, subcriteria and delimitation of categories by the Vital, Essential and Desirable Method (VED). The second uses Hierarchical Process Analysis (AHP) and the Bottom-up Method to calculate the total criticality of each item. The third represents the forecast model that generates the values of the optimization model variable. Finally, the fourth phase consists of a biobjective optimization model, based on price and criticality that can perform a single iteration or several by the p-epsilon method and construction of the Pareto Optimal Curve based on forecasts and monthly reviews of balances available for storage of the items. The model is supported by heuristics to prevent unavailability and reduce stockouts. The developed approach evaluates spare parts with real data from 9,263 items from a mining company. As a result, there is better support for the decision during the planning cycles and adequate control of the fixed assets in stock. The scientific contribution consists of the qualitative and quantitative multicriteria model in the management of spare parts prediction with and without lead time, of biobjective optimization models and heuristic methods applied to real data from the mineral industry.

**Keywords:** Decision making. Spare parts. AHP. Linear programming. Biobjective programming.

## LISTA DE FIGURAS

FIGURA 1 – PESQUISA OPERACIONAL E GESTÃO DE PEÇAS SOBRESSALENTES .....	20
FIGURA 2 – MAPE COMPARATIVO NO HORIZONTE DE DEMANDA .....	21
FIGURA 3 – AVALIAÇÃO MODELOS DE PREVISÃO (A).....	25
FIGURA 4 – AVALIAÇÃO MODELOS DE PREVISÃO (B).....	25
FIGURA 5 – AVALIAÇÃO MODELOS DE PREVISÃO (C).....	26
FIGURA 6 – CLASSIFICAÇÃO DE DEMANDA ADAPTADO .....	30
FIGURA 7 – CLASSIFICAÇÃO DE DEMANDA .....	31
FIGURA 8 – CLASSIFICAÇÃO DE DEMANDA .....	43
FIGURA 9 – EXEMPLO DE PADRÃO DE DEMANDA OBSERVADO .....	44
FIGURA 10 – TEMPO COMPUTACIONAL PARA EXECUÇÃO DO BOOTSTRAP.....	46
FIGURA 11 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> .....	64
FIGURA 12 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> .....	65
FIGURA 13 – EXEMPLO DE QUANTIDADE DE PREVISÕES POR PERÍODO .....	68
FIGURA 14 – FLUXOGRAMA DA ABORDAGEM PROPOSTA.....	69
FIGURA 15 – SELEÇÃO DE CRITÉRIOS DE CRITICIDADE RELEVANTES.....	71
FIGURA 16 – HIERARQUIA E PESOS (A).....	73
FIGURA 17 – HIERARQUIA E PESOS (B).....	74
FIGURA 18 – HIERARQUIA E PESOS (C).....	74
FIGURA 19 – HIERARQUIA E PESOS (D).....	75
FIGURA 20 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> SEM <i>OUTLIERS</i> .....	87
FIGURA 21 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> SEM <i>OUTLIERS</i> .....	88
FIGURA 22 – CURVA PARETO ÓTIMA.....	89
FIGURA 23 – CURVA PARETO ÓTIMA.....	90
FIGURA 24 – EXPERIMENTO MAE E MASE DIVERGENTES .....	106
FIGURA 25 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> CATEGORIA ERRÁTICO .....	123
FIGURA 26 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> CATEGORIA IRREGULAR.....	123
FIGURA 27 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> CATEGORIA REGULAR .....	124
FIGURA 28 – EVOLUÇÃO DO VALOR DE ESTOQUE SEM <i>LEAD TIME</i> CATEGORIA INTERMITENTE.....	124
FIGURA 29 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> CATEGORIA ERRÁTICO .....	125
FIGURA 30 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> CATEGORIA IRREGULAR .....	125
FIGURA 31 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> CATEGORIA REGULAR .....	126
FIGURA 32 – EVOLUÇÃO DO VALOR DE ESTOQUE COM <i>LEAD TIME</i> CATEGORIA INTERMITENTE .....	126

## **LISTA DE QUADROS**

QUADRO 1 - CLASSIFICAÇÃO DE DEMANDA ADAPTADO .....	31
QUADRO 2 – LISTA DE CRITÉRIOS DE CRITICIDADE .....	72

## LISTA DE TABELAS

TABELA 1 – PREVISÕES (EXEMPLO 1) .....	21
TABELA 2 – RESULTADO DO EXPERIMENTO COMPARATIVO ENTRE MAE E MASE .....	47
TABELA 3 – ANÁLISE DE PREVISÃO SEM RETIRADA DE <i>OUTLIERS</i> E COMBINADA.....	48
TABELA 4 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> E COMBINADA.....	49
TABELA 5 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> POR CATEGORIA E COMBINADA .....	50
TABELA 6 – ANÁLISE DE PREVISÃO SEM RETIRADA DE <i>OUTLIERS</i> COM <i>LEAD TIME</i> E COMBINADA .....	51
TABELA 7 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> E COMBINADA .....	52
TABELA 8 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> POR CATEGORIA E COMBINADA .....	53
TABELA 9 – MODELOS PROPOSTOS .....	56
TABELA 10 – GANHOS NA CATEGORIA ERRÁTICO MAE.....	57
TABELA 11 – GANHOS NA CATEGORIA ERRÁTICO MAE.....	58
TABELA 12 – GANHOS NA CATEGORIA ERRÁTICO MAE.....	59
TABELA 13 – GANHOS NA CATEGORIA ERRÁTICO MAE.....	59
TABELA 14 – ANÁLISE DE PREVISÃO SEM RETIRADA DE <i>OUTLIERS</i> E COMBINADA POR ITEM.....	60
TABELA 15 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> E COMBINADA POR ITEM .....	61
TABELA 16 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> POR CATEGORIA E COMBINADA POR ITEM.....	61
TABELA 17 – ANÁLISE DE PREVISÃO SEM RETIRADA DE <i>OUTLIERS</i> COM <i>LEAD TIME</i> E COMBINADA .....	62
TABELA 18 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> E COMBINADA .....	63
TABELA 19 – ANÁLISE DE PREVISÃO SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> POR CATEGORIA E COMBINADA .....	63
TABELA 20 – ANÁLISE MENOR ERRO MAE DE PREVISÃO POR ITEM.....	66
TABELA 21 – ANÁLISE DO MENOR ERRO MAE DE PREVISÃO COM <i>LEAD TIME</i> POR ITEM .....	67
TABELA 22 – ÍNDICE DE CONSISTÊNCIA.....	75
TABELA 23 – LIMITES SUPERIORES E INFERIORES DE CRITICIDADE.....	76
TABELA 24 – ANÁLISE DAS OTIMIZAÇÕES .....	83
TABELA 25 – ANÁLISE DAS OTIMIZAÇÕES PELA TAXA DE COBERTURA .....	83
TABELA 26 – ANÁLISE DAS OTIMIZAÇÕES PELO NÍVEL MÉDIO DE ESTOQUE.....	84
TABELA 27 – ANÁLISE DAS OTIMIZAÇÕES PELA TAXA DE RUPTURA .....	84
TABELA 28 – ANÁLISE DAS OTIMIZAÇÕES COM <i>LEAD TIME</i> .....	85
TABELA 29 – ANÁLISE DAS OTIMIZAÇÕES COM <i>LEAD TIME</i> PELA TAXA DE COBERTURA.....	85
TABELA 30 – ANÁLISE DAS OTIMIZAÇÕES COM <i>LEAD TIME</i> PELO NÍVEL MÉDIO DE ESTOQUE .....	86
TABELA 31 – ANÁLISE DAS OTIMIZAÇÕES COM <i>LEAD TIME</i> PELA TAXA DE RUPTURA .....	86
TABELA 32 – DADOS DA CURVA PARETO ÓTIMA.....	89
TABELA 33 – TAXA DE COBERTURA BASE COMPLETA .....	107

TABELA 34 – NÍVEL MÉDIO DE ESTOQUE BASE COMPLETA .....	107
TABELA 35 – TAXA DE RUPTURA BASE COMPLETA.....	107
TABELA 36 – TAXA DE COBERTURA BASE SEM <i>OUTLIERS</i> .....	108
TABELA 37 – NÍVEL MÉDIO DE ESTOQUE BASE SEM <i>OUTLIERS</i> .....	108
TABELA 38 – TAXA DE RUPTURA BASE SEM <i>OUTLIERS</i> .....	108
TABELA 39 – TAXA DE COBERTURA POR CATEGORIA SEM <i>OUTLIERS</i> .....	109
TABELA 40 – NÍVEL MÉDIO DE ESTOQUE POR CATEGORIA SEM <i>OUTLIERS</i> .....	109
TABELA 41 – TAXA DE RUPTURA POR CATEGORIA SEM <i>OUTLIERS</i> .....	109
TABELA 42 – TAXA DE COBERTURA BASE COMPLETA COM <i>LEAD TIME</i> .....	110
TABELA 43 – NÍVEL MÉDIO DE ESTOQUE BASE COMPLETA COM <i>LEAD TIME</i> .....	110
TABELA 44 – TAXA DE RUPTURA BASE COMPLETA COM <i>LEAD TIME</i> .....	110
TABELA 45 – TAXA DE COBERTURA BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	111
TABELA 46 – NÍVEL MÉDIO DE ESTOQUE BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	111
TABELA 47 – TAXA DE RUPTURA BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	111
TABELA 48 – TAXA DE COBERTURA POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	112
TABELA 49 – NÍVEL MÉDIO DE ESTOQUE POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	112
TABELA 50 – TAXA DE RUPTURA POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	112
TABELA 51 – COMPARATIVO TAXA DE COBERTURA .....	113
TABELA 52 – COMPARATIVO NÍVEL MÉDIO DE ESTOQUE.....	113
TABELA 53 – COMPARATIVO TAXA DE RUPTURA .....	113
TABELA 54 – COMPARATIVO TAXA DE COBERTURA .....	114
TABELA 55 – COMPARATIVO NÍVEL MÉDIO DE ESTOQUE.....	114
TABELA 56 – COMPARATIVO TAXA DE RUPTURA .....	114
TABELA 57 – COMPARATIVO TAXA DE COBERTURA COM <i>LEAD TIME</i> .....	115
TABELA 58 – COMPARATIVO NÍVEL MÉDIO DE ESTOQUE COM <i>LEAD TIME</i> .....	115
TABELA 59 – COMPARATIVO TAXA DE RUPTURA COM <i>LEAD TIME</i> .....	115
TABELA 60 – COMPARATIVO TAXA DE COBERTURA COM <i>LEAD TIME</i> .....	116
TABELA 61 – COMPARATIVO NÍVEL MÉDIO DE ESTOQUE COM <i>LEAD TIME</i> .....	116
TABELA 62 – COMPARATIVO TAXA DE RUPTURA COM <i>LEAD TIME</i> .....	116
TABELA 63 – TAXA DE COBERTURA BASE COMPLETA .....	117
TABELA 64 – NÍVEL MÉDIO DE ESTOQUE BASE COMPLETA .....	117
TABELA 65 – TAXA DE RUPTURA BASE COMPLETA.....	117
TABELA 66 – TAXA DE COBERTURA BASE SEM <i>OUTLIERS</i> .....	118
TABELA 67 – NÍVEL MÉDIO DE ESTOQUE BASE SEM <i>OUTLIERS</i> .....	118
TABELA 68 – TAXA DE RUPTURA BASE SEM <i>OUTLIERS</i> .....	118
TABELA 69 – TAXA DE COBERTURA POR CATEGORIA SEM <i>OUTLIERS</i> .....	119
TABELA 70 – NÍVEL MÉDIO DE ESTOQUE POR CATEGORIA SEM <i>OUTLIERS</i> .....	119

TABELA 71 – TAXA DE RUPTURA POR CATEGORIA SEM <i>OUTLIERS</i> .....	119
TABELA 72 – TAXA DE COBERTURA BASE COMPLETA COM <i>LEAD TIME</i> .....	120
TABELA 73 – NÍVEL MÉDIO DE ESTOQUE BASE COMPLETA COM <i>LEAD TIME</i> .....	120
TABELA 74 – TAXA DE RUPTURA BASE COMPLETA COM <i>LEAD TIME</i> .....	120
TABELA 75 – TAXA DE COBERTURA BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	121
TABELA 76 – NÍVEL MÉDIO DE ESTOQUE BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	121
TABELA 77 – TAXA DE RUPTURA BASE SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	121
TABELA 78 – TAXA DE COBERTURA POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	122
TABELA 79 – NÍVEL MÉDIO DE ESTOQUE POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	122
TABELA 80 – TAXA DE RUPTURA POR CATEGORIA SEM <i>OUTLIERS</i> COM <i>LEAD TIME</i> .....	122
TABELA 81 – COMPARAÇÃO PAR A PAR (A) .....	130
TABELA 82 – COMPARAÇÃO PAR A PAR (B) .....	130
TABELA 83 – COMPARAÇÃO PAR A PAR (C) .....	130
TABELA 84 – COMPARAÇÃO PAR A PAR (D) .....	130
TABELA 85 – CURVA PARETO ÓTIMA.....	131

## LISTA DE HEURÍSTICAS

HEURÍSTICA 1 – ITENS CRÍTICOS .....	80
HEURÍSTICA 2 – TRATAMENTO DE RUPTURAS .....	81

## LISTA DE SIGLAS

ABC	Classificação ABC
ADI	Average inter-Demand Interval
AHP	Analytic Hierarchy Process
ANP	Analytic Network Process
CV <sup>2</sup>	Coefficient of Variation
ERP	Enterprise Resource Planning
MAE	Mean Absolute Deviation
MAPE	Mean Absolute Percentage Error
MASE	Mean Absolute Scaled Error
MCDM	Multi-Criteria Decision Making
ME	Mean Error
MOPs	Multiobjective Problems
MSE	Mean Square Error
RMSE	Root Mean Square Error
SBA	Syntetos-Boylan Aproximation
TSB	Teunter-Syntetos-Babai method
VED	Vital, Essential, Desirable
XYZ	Classificação XYZ



## SUMÁRIO

<b>CAPÍTULO 1</b> .....	<b>19</b>
<b>INTRODUÇÃO</b> .....	<b>19</b>
1.1 Contextualização .....	19
1.2 Motivação e relevância da pesquisa .....	20
1.3 Objetivos.....	22
1.3.1 Geral .....	22
1.3.2 Específicos.....	22
1.4 Metodologia.....	23
1.5 Limitações .....	26
1.6 Delineamento do trabalho.....	27
<b>CAPÍTULO 2</b> .....	<b>28</b>
<b>EXAME DE LITERATURA</b> .....	<b>28</b>
2.1 Peças sobressalentes .....	28
2.2 Classificação da demanda.....	29
2.3 Previsão de peças sobressalentes .....	32
2.3.1 Métodos de previsão .....	32
2.3.2 Medidas de erros de previsão .....	35
2.4 Classificação e políticas de controle de peças sobressalentes .....	37
2.5 Decisão multicritério e AHP .....	38
2.6 Otimização e AHP .....	41
<b>CAPÍTULO 3</b> .....	<b>43</b>
<b>CLASSIFICAÇÃO E MODELOS DE PREVISÃO</b> .....	<b>43</b>
3.1 Classificação da demanda.....	43
3.2 Análise dos modelos de previsão .....	44
3.3 Proposição de modelos de previsão e análises .....	55

<b>CAPÍTULO 4</b> .....	<b>69</b>
<b>MODELO DE DECISÃO</b> .....	<b>69</b>
4.1 Desenvolvimento do modelo de decisão .....	69
4.2 Seleção dos critérios e subcritérios.....	70
4.3 Hierarquia e criticidade .....	73
4.4 Método de previsão .....	76
4.4 Método de otimização .....	77
4.5 Método Heurístico .....	79
4.6 Análise dos modelos de otimização .....	82
<b>CAPÍTULO 5</b> .....	<b>91</b>
<b>CONSIDERAÇÕES FINAIS</b> .....	<b>91</b>
5.1 Resultados e conclusões .....	91
5.2 Implicações gerenciais.....	93
5.3 Contribuição científica e trabalhos futuros.....	94
REFERÊNCIAS .....	96
APÊNDICE 2 – Tabelas de indicadores consolidadas .....	107
APÊNDICE 3 – Tabelas de indicadores para ganhos modelos propostos .....	113
APÊNDICE 4 – Gráficos de evolução de valor de estoque por categoria .....	123
APÊNDICE 5 – Pesquisa de sub-critérios do Método <i>Cut off Point</i> .....	127
APÊNDICE 6 – Tabelas de comparação par a par da AHP .....	130
APÊNDICE 7 – Dados Curva Pareto Ótima .....	131

# CAPÍTULO 1

## INTRODUÇÃO

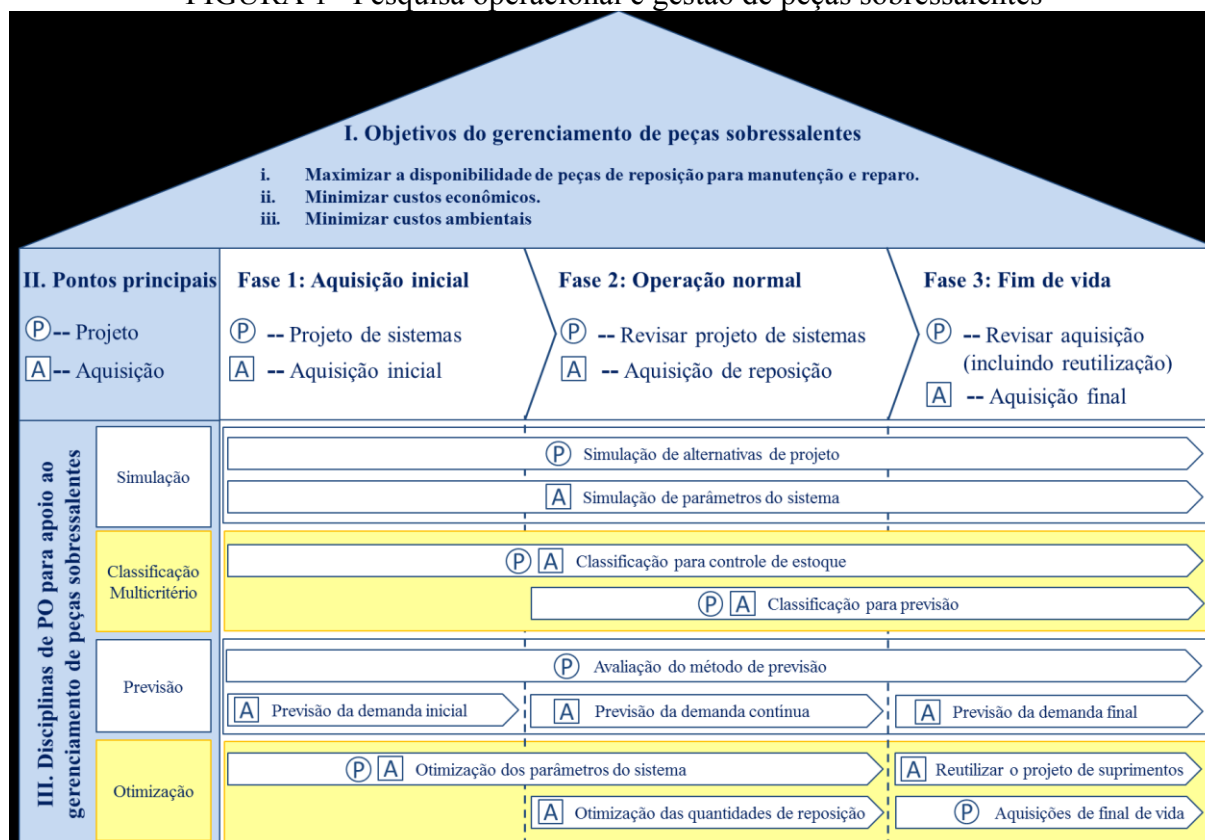
### 1.1 Contextualização

O gerenciamento de estoques faz parte da rotina organizacional que compreende diversos processos decisórios, como a definição das estratégias de transporte, técnicas de movimentação e armazenagem, programação de compras, gerenciamento de materiais, seleção de fornecedores, decisões de estocagem e previsão. A estocagem de peças sobressalentes tem por finalidade atender aos processos produtivos e equipamentos. A gestão de peças sobressalentes é complexa e envolve grande quantidade de materiais, o que torna seu gerenciamento especialmente difícil (EAVES, 2002; EAVES; KINGSMAN, 2004; REGO; MESQUITA, 2015; HU *et al.*, 2018).

Diversos itens são estratégicos para a operação e uma ruptura de estoque pode afetar diretamente o processo de produção (CONCEIÇÃO *et al.*, 2015; ZHANG; ZENG, 2017). Em muitas grandes empresas, é comum manter dezenas de milhares de peças sobressalentes (CAVALIERI *et al.*, 2008; BABAI; LADHARI; LAJILI, 2015). Dessa forma é importante o desenvolvimento de pesquisas relacionadas a peças sobressalentes para melhor embasar os processos decisórios. Nesse sentido, este estudo apresenta alternativas que auxiliem a tomada de decisão no gerenciamento de peças sobressalentes. A FIG. 1 apresenta um resumo das diversas perspectivas de estudo e os objetivos principais do gerenciamento de peças sobressalentes.

Destaca-se que um eficiente sistema de estocagem e armazenagem é fundamental para a adequada operação dos sistemas produtivos organizacionais (STOLL *et al.*, 2015), sendo a imprecisão de previsão de demanda uma grande dificuldade na gestão de peças sobressalentes (BACCHETTI; SACCANI, 2012). Nesta tese, utilizam-se as técnicas de classificação multicritério, previsão, otimização e simulação de parâmetros em métodos analíticos, para minimizar os custos com inventário e maximizar a disponibilidade de peças sobressalentes na fase normal de operação.

FIGURA 1– Pesquisa operacional e gestão de peças sobressalentes



Fonte: HU *et al.*, 2018, p. 9.


## 1.2 Motivação e relevância da pesquisa

No planejamento de peças sobressalentes, existem objetivos conflitantes entre o aumento da disponibilidade e a redução dos recursos financeiros imobilizados. O excesso de peças sobressalentes leva a um alto custo de retenção de capital que pode impedir o fluxo de caixa (GU; ZHANG; LI, 2014). As indisponibilidades de peças sobressalentes têm custos de oportunidade elevados, podem gerar perda de receita, aumento do custo de reparação e incremento no tempo de inatividade da produção (DRIESSEN *et al.*, 2010; SHARIF *et al.*, 2016). Assim, estudos relacionados a modelos de previsão e abordagem multiobjetivo que suportem a tomada de decisão na gestão de peças sobressalentes se fazem necessários.

Os modelos de previsão de peças sobressalentes baseados no histórico de demanda para realizar as previsões nas quais são observadas medidas de erros. Eaves (2002), utilizando dados da *Royal Air Force* com mais de 700 mil peças sobressalentes, mostrou a variação do erro percentual absoluto médio (Mape), nas classificações Regular, Irregular, Intermitente, Errático e Altamente Errático, com erros elevados que não permitem uma adequada gestão

dos inventários, conforme demonstrado na FIG. 2. Entender e mitigar os erros de previsão é relevante e justifica o estudo dos modelos de previsão de peças sobressalentes.

FIGURA 2 – Mape comparativo no horizonte de demanda



Fonte: EAVES, 2002, p. 178.

A TAB. 1 apresenta os dados de um caso hipotético. Os materiais têm previsão de demanda para o período de um mês, com as respectivas quantidades previstas e preço. Entende-se criticidade como um valor em uma escala de 0 (menor criticidade) a 1 (maior criticidade). Considerando a disponibilidade de R\$ 3.000,00 para aquisição de materiais para estoque, o tomador de decisão pode escolher a combinação dos itens e a quantidade a comprar.

TABELA 1 – Previsões (exemplo 1)

Item	Previsão (item)	R\$/item	Total R\$/item	Criticidade
1	5	125,00	625,00	0,334
2	12	37,00	444,00	0,573
3	8	233,00	1.864,00	0,177
4	25	89,00	2.225,00	0,140
5	11	64,00	704,00	0,082
<b>Soma</b>			<b>5.862,00</b>	<b>1,306</b>

Fonte: Elaborada pelo autor.

Nesse exemplo, é possível combinar as quantidades previstas por item, multiplicando a previsão por item da TAB. 1, totalizando 132.000 combinações. Assim, as decisões de compra assumem riscos recorrentes sem um embasamento adequado.

Os modelos que conciliam previsão de demanda, classificação multicritério, otimização e suas relações na gestão de peças permitem uma decisão mais consistente ainda não encontrado na literatura revisada. Alguns estudos levantaram lacunas no gerenciamento de peças de reposição: quais e quantas peças de reposição devem ser estocadas? (HU *et al.*, 2018; BOTTER; FORTUIN, 2000); quantas devem ser solicitadas? (BOSNJAKOVIC, 2010; BOTTER; FORTUIN, 2000); quais manter em estoque? (REGO; MESQUITA, 2011); a falta de abordagens combinando métodos quantitativos e qualitativos para otimização de um problema biobjetivo (HU *et al.*, 2017); como desenvolver e validar as categorias de classificações (LOLLI; ISHIZAKA; GAMBERINI, 2014; HU *et al.*, 2018; RODA *et al.*, 2014); ausência de uma perspectiva integrada de classificação, gerenciamento da demanda e inventário (BACCHETTI; SACCANI, 2012); estudos empíricos que vinculem a previsão de demanda e controle de estoques e modelos de pesquisa operacional no gerenciamento de peças sobressalentes com base de dados reais (HU *et al.*, 2018).

Assim, esta pesquisa propõe métodos de otimização no processo de reposição baseados em modelos de previsão e classificação multicritério na fase normal de operação. A base de dados utilizada correspondem a fase normal, o que impedi sua utilização na fase de aquisição inicial ou na fase final de vida. A otimização biobjetivo é utilizada no *trade-off* minimização dos custos e maximização da disponibilidade das peças sobressalentes. Os resultados são analisados com e sem *lead time* nas previsões de demanda. Os modelos de previsão são analisados por medidas de erro e indicadores de gestão de inventários. Não foram encontrados trabalhos que atendam a essas perspectivas simultaneamente, em nosso conhecimento inédito na literatura.

## **1.3 Objetivos**

### **1.3.1 Geral**

Desenvolver abordagem qualitativa e quantitativa que combine classificação multicritério, previsão de demanda e otimização no gerenciamento das peças sobressalentes durante os ciclos mensais de previsão.

### **1.3.2 Específicos**

1. Detalhar os modelos clássicos de previsão de peças sobressalentes, amortecimento exponencial, Croston, Syntetos-Boylan Approximation (SBA), Teunter-Syntetos-Babai (TSB) e Bootstrap.
2. Elaborar novos modelos de previsão baseados nos modelos clássicos.
3. Aplicar modelo de classificação multicritério para quantificação da criticidade total de cada peça sobressalente, individualmente.
4. Desenvolver um modelo matemático para resolver o problema biobjetivo dos materiais com previsão no período.
5. Desenvolver heurísticas para suporte ao modelo matemático.
6. Aplicar e avaliar os modelos e métodos em um caso real.

#### **1.4 Metodologia**

As classificações deste estudo foram baseadas na abordagem apresentada por Gil, (2017) quanto à natureza, abordagem, objetivos e procedimentos técnicos.

A pesquisa é classificada como de natureza aplicada, já que busca solucionar um problema específico. A abordagem classifica-se como quantitativa, uma vez que as variáveis envolvidas foram quantificadas em uma escala e as análises feitas de forma indutiva. Do ponto de vista do seu objetivo, pode-se classificar o trabalho como explicativo, pois buscou-se aprofundar na razão de causa e efeito, identificar os principais fatores, descobrir os motivos e propor soluções. Por fim, quanto aos procedimentos técnicos, o presente estudo é uma pesquisa experimental, na medida em que o objetivo está relacionado às variáveis que podem influenciar os resultados. Durante o estudo foram manipuladas variáveis para analisar situações de interesse e avaliar os métodos desenvolvidos.

Os procedimentos técnicos do estudo foram baseados no estado da arte em pesquisa bibliográfica sobre o tema consistiu em:

1. Revisar da literatura sobre modelos de previsão, métodos multicritério de classificação, programação linear inteira e programação biobjetivo.
2. Implementar métodos de previsão de peças sobressalentes, calcular erros e indicadores.
3. Desenvolver modelos de previsão conjugados e comparar aos modelos clássicos
4. Desenvolver modelo com métodos qualitativos e quantitativos para suporte à decisão na gestão de peças sobressalentes.

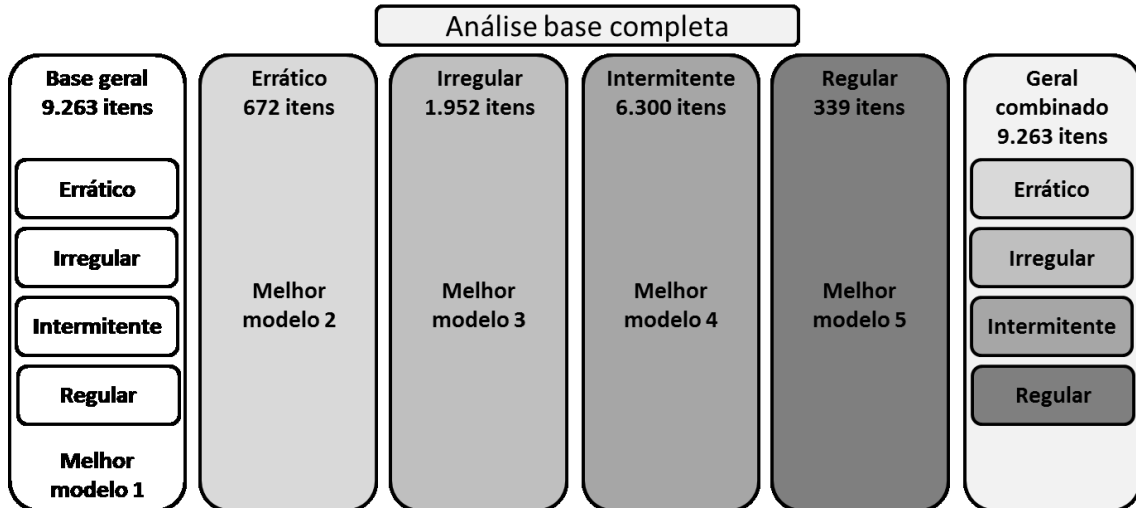
5. Aplicar classificação multicritério na base de dados de peças sobressalentes.
6. Desenvolver modelos de otimização biobjetivo para aperfeiçoamento das previsões nos ciclos mensais de previsão.
7. Comparar o desempenho do modelo de otimização com os modelos de previsão.

Foram utilizados os indicadores taxa de cobertura com variação de 0 a 1, mais adequado para valores maiores, taxa de ruptura com variação de 0 a 1, mais apropriado para valores menores e nível médio de estoque, com valores positivos e positivos e adequado quando se aproxima de 0. Os indicadores se baseiam no saldo de estoque no período, que é calculado pela soma do saldo em estoque no período anterior, mais a previsão e menos a demanda no período. A taxa de cobertura mensura quantas vezes a demanda do período foi completamente atendida pelo saldo disponível em estoque. A taxa de ruptura avalia em quantos períodos o saldo de estoque foi menor ou igual a zero. O nível médio de estoque representa o saldo médio de estoque. As métricas de erro MAE (*Mean Absolute Deviation*) e Mase (*Mean Absolute Scaled Error*) foram utilizadas para as análises dos resultados dos modelos. Os modelos de previsão conjugados foram elaborados com a junção dos métodos de previsão dos modelos clássicos e variação na forma de atualização dos parâmetros.

Os modelos de previsão e otimização foram avaliados nas aberturas: Geral, por categoria e Geral Combinado com e sem *outliers e lead time*. A Abertura Geral representa o resultado da base de 9.263 itens com um único modelo de previsão. As categorias de análise se referem ao modelo de previsão mais aderente em cada classificação: Errático, com 672 itens; Irregular, com 1.952; Intermitente, com 6.300; e Regular, com 339. A Abertura Geral Combinado consolida os melhores resultados dos modelos de previsão por Categoria Errático, Irregular, Intermitente e Regular, conforme FIG. 3.



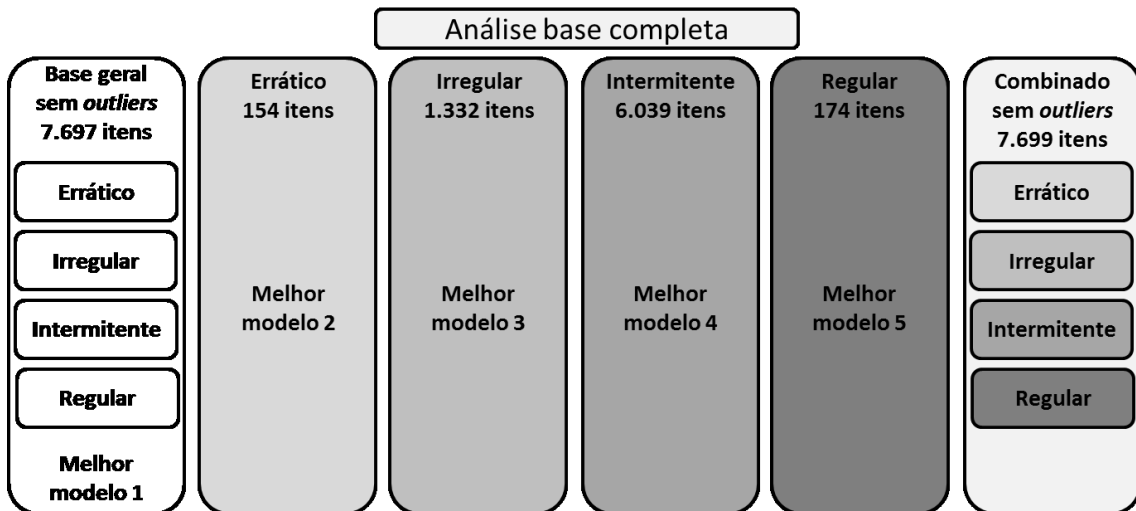
FIGURA 3 – Avaliação modelos de previsão (a)



Fonte: Elaborada pelo autor.

As análises sem *outliers* foram realizadas de duas formas: na primeira, a retirada de *outliers* foi realizada na base Geral e, posteriormente, a abertura por categoria e a consolidação na Abertura Geral Combinado, conforme FIG. 4.

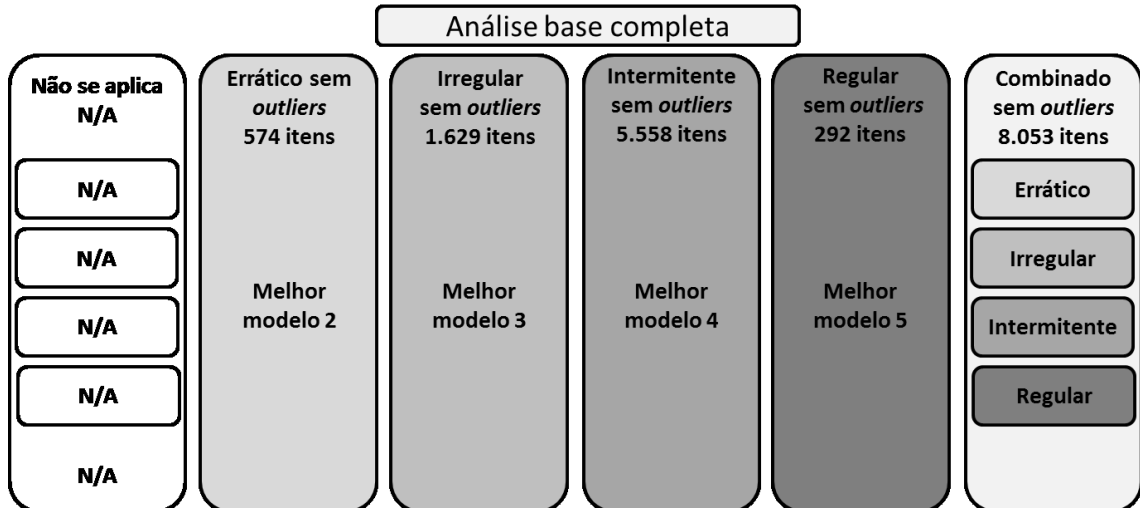
FIGURA 4 – Avaliação modelos de previsão (b)



Fonte: Elaborada pelo autor.

Na segunda forma de análise, a retirada dos *outliers* foi realizada por Categoria Errático, Irregular, Intermitente e Regular e, em seguida, a consolidação na base Geral Combinado, conforme FIG. 5.

FIGURA 5 – Avaliação modelos de previsão (c)



Fonte: Elaborada pelo autor.

Nas duas formas, ocorre redução na quantidade total de itens avaliados e diferentes quantidades nas aberturas: Geral, por categoria e Geral Combinado. Por fim, todas as análises foram realizadas com e sem utilização do *lead time* médio.

As implementações dos algoritmos de previsão foram realizadas em Python 2.7 – destaca-se que o foco da pesquisa não é obter redução de tempos computacionais. Os modelos de classificação multicritério avaliados usando o *software* SuperDecisions.Ink 2013. As análises estatísticas dos modelos de previsão foram realizadas no *software* XLSTAT® 2018. O *software* AMPL foi utilizado para implementação dos modelos de otimização com *software* de otimização CPLEX 12.5.

### 1.5 Limitações

O estudo é delimitado à fase normal de operação, fase 2 da FIG. 1, que ocorre após as aquisições iniciais e finalização de projeto e antecede o fim da vida útil dos equipamentos.

A minimização do tempo de falha e dos custos ambientais não são avaliados neste trabalho por impossibilidade de obtenção de dados confiáveis e quantificação matemática consistente desses parâmetros.

A base de dados foi obtida no setor de mineração de ferro com estocagem em local único.

## **1.6 Delineamento do trabalho**

Este trabalho é dividido em 5 capítulos. Este capítulo apresenta a contextualização e motivação, contribuição científica, objetivos, metodologia e limitações. O Capítulo 2 revisa o estado da arte sobre peças sobressalentes, suas especificidades de demanda e classificação. O capítulo aborda, também, os métodos de previsão e medidas de erro, classificação multicritério e a revisão sobre programação biobjetivo.

Os Capítulos 3 e 4 abordam o desenvolvimento do trabalho. No Capítulo 3, são realizados os experimentos relacionados aos modelos de previsão. No Capítulo 4, apresenta-se o modelo de decisão, que relaciona classificação multicritério, modelo de previsão e otimização biobjetivo. Finalmente, no Capítulo 5, apresentam-se as conclusões finais da pesquisa, a síntese dos resultados, adequação aos objetivos propostos e as recomendações para trabalhos futuros.

## CAPÍTULO 2

### EXAME DE LITERATURA

#### 2.1 Peças sobressalentes

Para Hu *et al.* (2018), a gestão de peças sobressalentes é um caso especial na gestão de inventários. Esses materiais são componentes relevantes, necessários para manter ou restaurar sistemas industriais defeituosos (KAREEM; LAWAL, 2015), exercendo função importante nas atividades de manutenção regulares e periódicas, pois a falta desses materiais pode provocar graves perdas de produção (MOHARANA; SARMAH, 2016). Alguns aspectos são únicos nas peças de reposição, como as falhas das peças geralmente dependentes; a demanda de uma peça pode causar o aumento no consumo de outras peças e a obsolescência (KENNEDY; PATTERSON; FREDENDALL, 2002; RODA *et al.*, 2014); demanda intermitente, grande variedade e consumo relacionado às demandas de manutenção (HU *et al.*, 2018).

Em função disso, a gestão de peças sobressalentes tem recebido especial atenção, o que pode ser comprovado nos trabalhos de Botter e Fortuin (2000), Kennedy, Patterson, e Fredendall (2002), Suryadi (2003), Braglia, Grassi, e Montanari (2004), Bosnjakovic (2010), Rego e Mesquita (2011), Bacchetti e Saccani (2012), Molenaers *et al.* (2012), De Felice *et al.* (2014), Stoll *et al.* (2015), Moharana e Sarmah (2016), Zhü *et al.* (2016), Hu *et al.* (2017), Zhang e Zeng (2017) e Hu *et al.* (2018).

A estocagem é a atividade mais importante na logística de peças de reposição (Hu *et al.*, 2017; Stoll *et al.*, 2015), uma vez que a estocagem desses materiais é exigida em decorrência do longo *lead time* e da necessidade de reposição imediata para atendimento aos clientes, segundo Tracht *et al.* (2013), o que permite a redução do tempo de paradas, e elevação da qualidade no controle dos estoques (DEWALT, 2014).

Aplicações de gerenciamento de peças de reposição são relatadas principalmente na área da saúde e manufatura, conforme Hu *et al.* (2017). Outros estudos foram realizados em setores, como na indústria de dispositivos eletrônicos (BOTTER; FORTUIN, 2000), indústria de celulose e papel (BRAGLIA *et al.*, 2004), usina hidrelétrica (ZENG *et al.*, 2012), indústria automobilística (FALCONE; PETRILLO, 2014; REGO; MESQUITA, 2015; STOLL *et al.*, 2015), companhia siderúrgica (CONCEIÇÃO *et al.*, 2015), indústria petroquímica (MOLENAERS *et al.*, 2012), na mineração (MOHARANA; SARMAH, 2016; RODA *et al.*, 2014), usina eólica (ZHANG; ZENG, 2017), companhia de manufatura (HU *et al.*, 2017).

Sendo que a maioria desses trabalhos focam na classificação das peças sobressalentes e em métodos de gestão. Ainda referente às aplicações, Hu *et al.* (2017) relatam que poucos estudos de caso nesse campo foram realizados com aplicações ou bases de dados do mundo real.

Referente à indústria mineral, Roda *et al.* (2014) apresenta uma extensa pesquisa no setor de mineração de cobre do Chile em gerenciamento de peças de reposição. Os autores apresentaram que 70% das empresas utilizam abordagens de classificações e 31% dessas companhias adotam apenas a classificação ABC, baseada em um critério quantitativo, o consumo anual, 17% usam dois ou mais critérios quantitativos, e 52% usam métodos qualitativos, isso em 12 empresas do estudo. As peças sobressalentes apresentam características particulares quanto ao intervalo entre demandas e o tamanho da demanda, o que pode influenciar diretamente a classificação ABC quanto ao consumo anual.

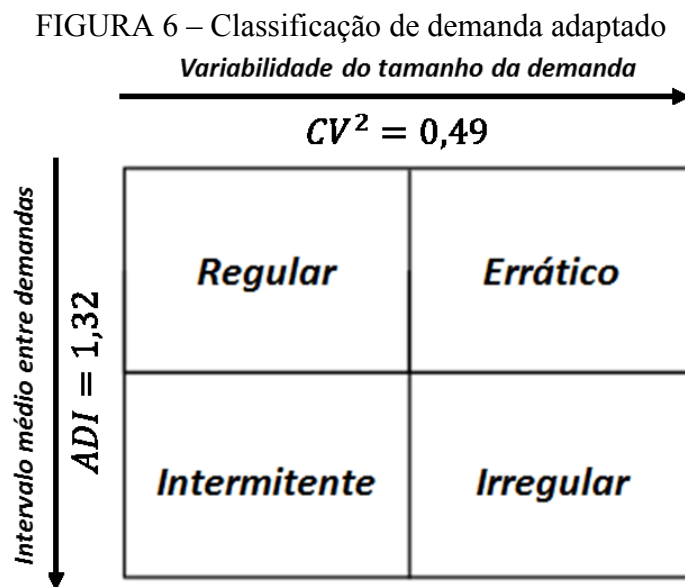
## 2.2 Classificação da demanda

Os modelos de classificação de demanda de Williams (1984) e Syntetos e Boylan (2001) são intensamente discutidos na literatura, sendo os dois modelos principais. A metodologia proposta por Williams (1984) classifica a demanda por SKUs em categorias “suaves”, “lentas” e “esporádicas”, com base na partição de variância, cuja finalidade era a identificação dos métodos de previsão e controle de inventário mais adequado para as categorias resultantes. Syntetos e Boylan (2001) modificaram o método de classificação para quatro categorias (Errático, Irregular, Intermitente, Regular), usando como base o intervalo médio entre demandas ADI (*Average inter-Demand Interval*) e o coeficiente quadrado de variação dos tamanhos da demanda  $CV^2$  (*Coefficient of Variation*), sendo o desvio padrão da demanda do item dividido pela demanda média (COSTANTINO *et al.*, 2017), conforme equações 2.1 e 2.2 e a FIG. 6.

$$ADI = \frac{\sum_{n=1}^{N_{pi}} t_i^n}{N_{pi}} \quad (2.1)$$

$$CV_i = \frac{\sqrt{\sum_{n=1}^{N_{pi}} (d_i^n - d_i)^2}}{N_{pi}} \bigg/ \frac{\sum_{n=1}^{N_{pi}} d_i^n}{N_{pi}} \quad (2.2)$$

Considera-se  $t_i^n$  intervalo de período sem demanda do item  $i$ ,  $N_{pi}$  número de demandas não nulas no intervalo de tempo,  $d_i^n$  valor da demanda do item  $i$  no período  $n$  e  $d_i$  média das demandas não nulas do item  $i$ . Com o intuito de definir mais claramente os pontos de corte Syntetos, Boylan e Croston (2005) apresentam valores de corte para esta classificação ( $ADI = 1,32$  e  $CV^2 = 0,49$ ), utilizados neste trabalho, que foram avaliados em teste com dados do setor automobilístico com mais de 3.000 séries de dados.



Fonte: SYNTETOS; BOYLAN; CROSTON, 2005, p. 500.

Essa classificação apresenta quatro regiões, nas quais os itens Regulares têm alto giro e baixa variação, a classificação Intermitente apresenta diversos períodos sem demanda, baixo giro e baixa aleatoriedade no tamanho da demanda, a região de peças Errático apresenta um alto giro com elevada variação no tamanho da demanda, já os materiais Irregulares são de baixo giro com elevada variação no tamanho da demanda.

Os valores de corte entre as categorias podem ser alterados, conforme base de dados analisada. Eaves (2002) afirma que a escolha de limites entre cada uma das categorias é essencialmente uma decisão gerencial, sendo que um item mudará de categoria à medida que

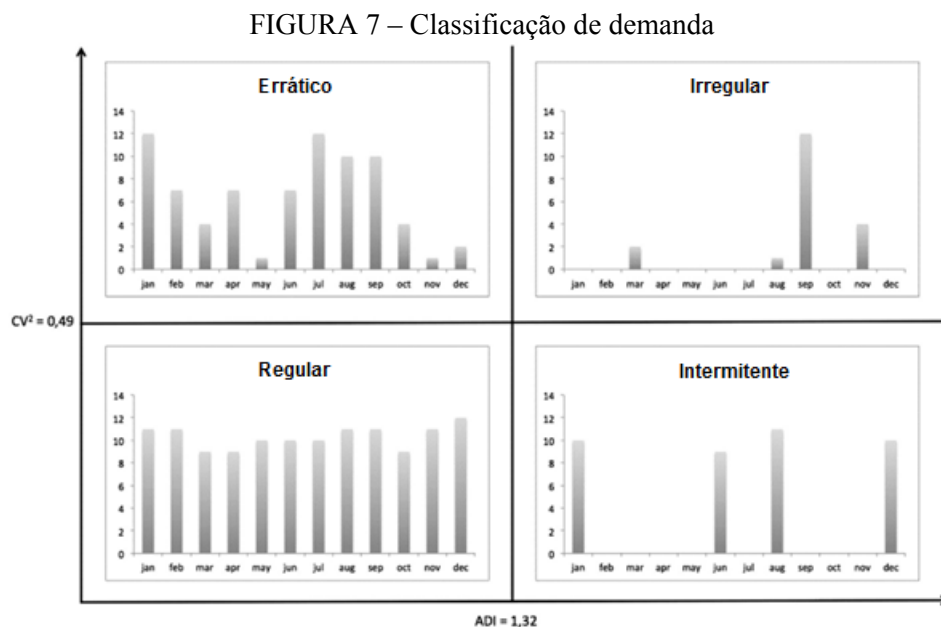
os valores de parâmetro se movem de uma região para outra, portanto, os itens podem mudar continuamente se os parâmetros estiverem no limite. Finalmente, Eaves (2002) e Eaves e Kingsman (2004), em análise de dados da *Royal Air Force*, realizaram a abertura dos itens Erráticos ou Intermitentes com base na variabilidade do *lead time*, como mostra o QUADRO 1.

QUADRO 1 - Classificação de demanda adaptado

Componentes de demanda durante o <i>lead time</i>			Tipo de padrão de demanda
Variabilidade de transações	Variabilidade do tamanho de demanda	Variabilidade do <i>lead time</i>	
Baixa	Baixa	-	Regular
Baixa	Alta	-	Errático
Alta	Baixa	-	Intermitente
Alta	Alta	Baixa	Levemente Irregular
Alta	Alta	Alta	Altamente Irregular

Fonte: EAVES; KINGSMAN, 2004, p. 432.

Com base nas classificações da demanda, os estudos buscam desenvolver técnicas de previsão e definir os melhores modelos e parâmetros para cada grupo de peças sobressalentes. A FIG. 7 apresenta de forma gráfica o comportamento dos itens.



Fonte: COSTANTINO *et al.*, 2017, p. 3.

Outro fator relevante no gerenciamento de peças sobressalentes é a previsão de demanda destas, já que esses materiais apresentam regiões com comportamento distinto de demanda, o que torna a assertividade dos modelos de previsão mais complexa.

### 2.3 Previsão de peças sobressalentes

A gestão de estoques é auxiliada por métodos de previsão de demanda baseados em séries temporais. Conforme Hu *et al.* (2018), os modelos tradicionais de previsão foram desenvolvidos para itens de alto giro e, nesses casos, podem ser aderentes. O autor destaca que a maioria das peças sobressalentes são itens de baixo giro, muitas vezes com períodos sem demanda, o que torna necessário o desenvolvimento de modelos específicos, como o Método de Amortecimento Exponencial, Método de Croston, Método de Croston Ajustado (SBA), Método Teunter, Syntetos e Babai (TSB) e Bootstrap de Willemain. Esses modelos têm sido estudados para melhorar as previsões realizadas com o intuito de reduzir os erros dos modelos, permitindo uma decisão mais assertiva. Diversos estudos abordam o tema como os de Croston (1972), Willemain *et al.* (1994), Syntetos e Boylan (2001), Eaves (2002), Eaves e Kingsman (2004), Willemain, Smart e Schwarz (2004), Syntetos, Boylan e Croston (2005), Dekker *et al.* (2013), Kot (2013), Hu *et al.* (2015), Rego e Mesquita (2015) e Zhu *et al.* (2017).

#### 2.3.1 Métodos de previsão

O Método de Amortecimento Exponencial pondera os dados recentes e a última previsão. As previsões podem ser altamente tendenciosas após a ocorrência de uma demanda e pouco tendenciosa imediatamente antes de uma demanda. É provável que a quantidade de reabastecimento seja determinada por previsões feitas logo após uma demanda, resultando em níveis de estoque desnecessariamente altos. O modelo é dado pela equação 2.3.

$$Y_{t+1} = \alpha X_t + (1 - \alpha)Y_t \quad (2.3)$$

Sendo que  $Y_{t+1}$  é o valor previsto para o próximo período,  $Y_t$  é o valor previsto no período atual,  $X_t$  é o valor observado de demanda no período e  $\alpha$  sendo a constante de amortecimento variando entre 0 e 1. A quantidade de valores nulos podem tornar



praticamente impossível prever bem, usando qualquer método estatístico, enquanto poucos valores zero tornam desnecessário abandonar a suavização exponencial (WILLEMAIN *et al.*, 1994).

Atento à tendência apresentada no Método de Amortecimento Exponencial e à possibilidade de elevação dos níveis de estoques, Croston (1972) considera dois componentes da série temporal de forma separada: valor observado da demanda diferente de zero ( $D_t$ ) e o tempo de chegadas ( $Q_t$ ). As estimativas de suavização são denotadas por  $Z_t$  e  $P_t$  – conforme apresentado em Syntetos *et al.* (2015).

$$Z_{t+1} = \alpha D_{t+1} + (1 - \alpha)Z_t \quad (2.4)$$

$$P_{t+1} = \alpha Q_{t+1} + (1 - \alpha)P_t \quad (2.5)$$

No Método de Croston, os valores de  $\alpha$  são os mesmos em ambas as equações, e a previsão de demanda é dado por:

$$Y_{t+1} = Z_{t+1}/P_{t+1} \quad (2.6)$$

Nos períodos sem demanda, os parâmetros  $Z_{t+1}$  e  $P_{t+1}$  permanecem inalterados, ou seja,  $Z_{t+1} = Z_t$  e  $P_{t+1} = P_t$ . Syntetos *et al.* (2015) destacam que, quando a demanda ocorre a cada período, o Método Croston fornece as mesmas previsões que o Amortecimento Exponencial Convencional, o que permite sua utilização para demandas intermitentes e não intermitentes. Syntetos e Boylan (2001) mostraram que o Método de Croston tende a superestimar, sendo enviesado. Posteriormente, Syntetos *et al.* (2005) propuseram uma adaptação para a equação 2.6, desenvolvendo, assim, o Método de Croston modificado (SBA):

$$Y_{t+1} = (1 - \alpha/2) Z_{t+1}/P_{t+1} \quad (2.7)$$

Teunter *et al.* (2011) afirmam que o Método de Croston é padrão para a previsão de demanda intermitente, mas aponta duas desvantagens: reforça que o método é enviesado e que não há atualização na ocorrência de longos períodos sem demanda, tornando o método inadequado para itens em obsolescência. Para superar essas deficiências, o Método TSB

atualiza a probabilidade de demanda ( $P'_t$ ) em todos os períodos e não o intervalo entre demandas em todos os períodos, sendo  $\beta$  a constante de amortecimento variando entre 0 e 1.

A atualização ocorre conforme a equação 2.8 nos períodos com demanda, conforme Teunter *et al.* (2011):

$$P'_{t+1} = P'_t + \beta(1 - P'_t) \quad (2.8)$$

Para períodos sem demanda, o valor 1 é substituído por 0 na equação 2.8. As estimativas de  $Z_t$  não são alteradas e as previsões dadas por:

$$Y_{t+1} = P'_{t+1} * Z_{t+1} \quad (2.9)$$

Outro método de previsão é o Bootstrap (EFRON, 1979), que cria pseudodados por amostragem com reposição das observações individuais. Aplicado ao problema de previsão, essa abordagem simples ignoraria a autocorrelação na sequência da demanda e produziria como valores previstos apenas os mesmos números que já haviam aparecido no histórico de demanda (WILLEMAIN; SMART; SCHWARZ, 2004). Os mesmos autores desenvolveram um Bootstrap modificado que responde a três características difíceis de demanda intermitente: autocorrelação, valores repetidos frequentes e séries relativamente curtas, modelando a autocorrelação usando a Cadeia de Markov. O modelo realiza a atualização dos dados pelo processo de *Jittering*, em que  $Z$  é o desvio padrão normalizado, sendo:

$$JITTERED(S) = 1 + INT(X_t + Z * \sqrt{X_t}) \quad (2.10)$$

Nos casos em que o  $JITTERED \leq 0$ , faça  $JITTERED = X_t$ , onde:

$X_t$  – Valor histórico da demanda selecionado aleatoriamente.

$Z$  – Desvio aleatório normal padrão das demandas históricas.

$S$  – Valor não nulo ajustado, ou seja, previsão realizada a partir de  $X_t$ .

O método consiste de oito passos:

1. Obter demanda com histórico.
2. Estimar a probabilidade de transição entre valores nulos e não nulos.

3. Baseado na última demanda, use Cadeia de Markov para estimar a sequência de zeros e não zeros no horizonte de previsão.
4. Substitua os valores não nulos por um valor histórico da série de dados.
5. Aplique Jitter nas demandas não nulas.
6. Some os valores de previsão no horizonte de previsão.
7. Repita os passos de 3 a 6 até obter 1.000 previsões.
8. Sorteie e utilize o resultado da previsão com base no percentil desejado.

Os autores não detalham a quantidade de vezes necessárias de repetições no passo 7, neste trabalho foram realizadas 1.000 repetições. Os modelos Amortecimento Exponencial, Croston, SBA, TSB e Bootstrap de Willemain serão utilizados neste trabalho para identificar o mais aderente à base de dados, que servirá de parâmetro de controle e propor modelos conjugados.

### 2.3.2 Medidas de erros de previsão

As medidas de erro de previsão é a forma usual para seleção de um modelo de previsão adequado. Assim, são apresentadas algumas das medidas de erro utilizadas na literatura em previsão de demanda, sendo: erro médio (*Mean Error* – ME), erro absoluto médio (*Mean Absolute Deviation* – MAE), erro quadrático médio (*Mean Square Error* – MSE), erro percentual absoluto médio (*Mean Absolute Percentage Error* – Mape) e o erro de escala absoluto médio (*Mean Absolute Scaled Error* – Mase).

Para uma série temporal com  $n$  observações, denota-se  $Z_t$  como o valor observado no tempo  $t$ , e  $\bar{Z}_t$  a previsão no período. Assim, o erro de previsão no período  $t$  pode ser definido como  $e_t = (Z_t - \bar{Z}_t)$ , neste caso com variações positivas e negativas (CHEN; TWYLCROSS; GARIBALDI, 2017). Os erros apresentados utilizam como base o erro de previsão por período e são apresentados nas equações de 2.11 a 2.16,

$$ME = \frac{1}{N} \sum_{t=1}^N e_t \quad (2.11)$$

$$MAE = \frac{1}{N} \sum_{t=1}^N |e_t| \quad (2.12)$$

$$MSE = \frac{1}{N} \sum_{t=1}^N (e_t)^2 \quad (2.13)$$

$$MAPE = \frac{\sum_{t=1}^n \frac{|e_t|}{y_t} \times 100}{n} \quad (2.14)$$

Sendo o Mase definido como:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (2.15)$$

$$MASE = \text{média}(|q_t|) \quad (2.16)$$

A escolha de uma medida de erro para avaliar a precisão das previsões é um tópico importante e ainda controverso na literatura (DAVYDENKO; FILDES, 2013). Entre os tipos de medidas apresentados, o MAE tem como objetivo avaliar a precisão em uma única série e é fácil de calcular e entender. Segundo Hyndman (2006), o ME tem as mesmas premissas e permite visualizar variações positivas e negativas. As medidas baseadas em erros absolutos ou ao quadrado, MAE, MSE e Raiz do Erro Quadrado Médio (RMSE) também são conhecidas como medidas dependentes da escala, sendo úteis na comparação de métodos de previsão no mesmo conjunto de dados (CHEN *et al.*, 2017).

As medidas dependentes da escala mais comumente usadas são Erro Absoluto Médio (MAE), Erro Quadrático Médio (MSE) e Raiz do Erro Quadrado Médio (RMSE). O MAE é amplamente utilizado como uma medida da dispersão dos erros de previsão no controle de estoques (GARDNER; DIAZ-SAIZ, 2002). Para Willmott e Matsuura (2005), o MAE é considerado uma medida natural do erro médio e é inequívoco, já Eaves (2002) afirma que o MAE é menos afetado por discrepâncias. O Mape, por sua vez, apresenta inconsistência quando existem valores nulos na série (HYNDMAN, 2006), mas na ocorrência de pequena quantidade de valores nulos pode ser utilizado (WILLEMAIN *et al.*, 1994).

O Mape e o Mase, baseados no MAE, apresentam vulnerabilidade a *outliers* (DAVYDENKO; FILDES, 2013). A única circunstância sob a qual o Mase seria infinito ou indefinido é no caso irrelevante, quando todas as observações históricas são iguais (CHEN; TWYLCROSS; GARIBALDI, 2017). Hyndman e Koehler (2006) destacam o Mase como a melhor medida de erro, sendo que, em algumas situações, o MAE pode ser preterido pela facilidade de entendimento, ou até mesmo o Mape, se todos os dados forem positivos. Chen *et al.* (2017) afirmam que não existe na literatura uma definição da medida de erro mais adequada.

Os erros dos modelos de previsão deste trabalho foram realizados conforme Eaves (2002), considerando que a norma de comparação da previsão é baseada um período à frente com a demanda real. Diante do exposto, realizamos um estudo comparativo de desempenho entre os erros MAE e Mase, pois, segundo Davydenko e Fildes (2013), as análises baseadas em medidas diferentes podem levar a conclusões diferentes. A análise de indicadores serviu

de suporte para definir a métrica de erro a ser utilizada. Conforme Chen *et al.* (2017), mesmo um único grande erro pode, às vezes, dominar o resultado do MAE, assim, as análises serão feitas com a base completa e com retirada de *outliers*. Na análise de pontos discrepantes contidos nos erros de previsão, utilizamos o Método de Box Plot, sendo que os cortes são encontrados pelas equações  $Q_3 + 1,5 * (Q_3 - Q_1)$  para o corte superior, e  $Q_1 - 1,5 * (Q_3 - Q_1)$  para o corte inferior. A análise por meio de Box Plot e variações é utilizada frequentemente para diversas análises, como em Chen *et al.* (2017), Davydenko e Fildes (2013), Fildes (1992), Petropoulos *et al.* (2018) e Tayman e Swanson (1999).

## 2.4 Classificação e políticas de controle de peças sobressalentes

A classificação de peças sobressalentes em categorias é uma tarefa essencial para o gerenciamento desses materiais (MOLENAERS *et al.*, 2012; RODA *et al.*, 2014). O agrupamento dos materiais em categorias permite estabelecer políticas específicas de gestão para cada grupo (HU *et al.*, 2017). A literatura tem apresentado metodologias para a classificação de estoques como em Botter e Fortuin (2000), Suryadi (2003), Braglia, Grassi e Montanari (2004), Bosnjakovic (2010), Babai, Ladhari e Lajili (2015), Moharana e Sarmah (2015), Stoll *et al.* (2015), Sharif *et al.* (2016) e Hu *et al.* (2017). Apesar de diversos estudos, normalmente utiliza-se o Método ABC tradicional para a classificação de peças sobressalentes, conforme Bacchetti e Saccani (2012) e Stoll *et al.* (2015).

De acordo com Hu *et al.* (2018), os critérios de classificação mais utilizados são, nesta ordem: *lead time* e criticidade, critério financeiro, custo anual de uso e preço unitário. Molenaers *et al.* (2012) afirmam que a criticidade do equipamento é o mais importante critério na classificação, contudo, a criticidade assume diferentes significados e pode ser avaliada de maneiras diferentes, com base em cada área ou ponto de vista da atividade (RODA *et al.*, 2014; BOSNJAKOVIC, 2010).

Roda *et al.* (2014) apontaram que a literatura sugere classificação com perspectiva de decisão multicritério (MCDM – *Multi-Criteria Decision Making*) e baseada em critérios quantitativos e qualitativos. Ojha e Ota (2014) destacam que os problemas do mundo real são essencialmente multicritérios e multiescolhas, com certas restrições. Além disso, Hu *et al.* (2018) sugerem que nos processos de tomada de decisões a maior parte da literatura é dominada por dois objetivos, quais sejam, maximizar a disponibilidade de peças sobressalentes e minimizar os custos econômicos.

Entre as diversas formas de classificação de peças sobressalentes, a classificação ABC é a mais utilizada (BRAGLIA; GRASSI; MONTANARI, 2004). Essa classificação conhecida como regra 80/20 proposta por Vilfredo Pareto, segmenta os materiais em faixas de valores, sendo que os itens da faixa A devem ser gerenciados de forma diferenciada. Já o Método VED e a classificação XYZ buscam segmentar os materiais estocados para facilitar a análise e tomada de decisão (REGO; MESQUITA, 2011). A classificação XYZ foi desenvolvida para classificar itens em três classes, baseando-se em critérios relacionados às características da demanda (BABAI; LADHARI; LAJILI, 2015). A classificação VED, mais usual que a XYZ, segmenta os itens em Vitais (V), sem os quais o processo não funciona, essenciais (E), no qual o processo funciona com perda de qualidade e desejáveis (D), que não interferem no desempenho organizacional (SINGH *et al.*, 2015). O Método VED foi utilizado em diversos estudos como os de Botter e Fortuin (2000), Bosnjakovic (2010), Molenaers *et al.* (2012), Singh *et al.* (2015), Stoll *et al.* (2015) e Kavilal e Kumar (2017).

As políticas de estoque definem basicamente quando e qual quantidade pedir dos materiais estocados. As duas políticas básicas de estoque são (Q,r), com ponto de pedido (r) e quantidade do pedido (Q) fixos (BOYLAN; SYNTETOS; KARAKOSTAS, 2008; SYNTETOS; KEYES; BABAI, 2009); e a mais usual a revisão contínua (s,S), com ponto de reabastecimento fixo (s) e pedido até o nível (S), conforme Duchessi, Tayi e Levy (1988) e Nagarur, Hu e Baid (1994). Outras políticas de controle são desenvolvidas e adaptadas à realidade organizacional.

Na literatura, diversas distribuições estatísticas podem fornecer bom ajuste aos dados, como a utilização da distribuição Normal, Poisson, Geométrica ou compostas (SYNTETOS; KEYES; BABAI, 2009). Bacchetti e Saccani (2012) e Cavalieri *et al.* (2008) afirmam que poucas empresas aplicam modelos de inventário complexos, devido à dificuldade matemática caracterizada na resolução. Assim, as políticas de estoques não serão aprofundadas neste trabalho. As diversas possibilidades de classificação e gestão reforçam a característica multicritério que devem ser tratadas no gerenciamento das peças sobressalentes.

## **2.5 Decisão multicritério e AHP**

A Análise Hierárquica de Processos (AHP – *Analytical Hierarchy Process*) é baseada em julgamentos de especialistas em comparações par a par com estrutura hierárquica, comumente usada para a tomada de decisões multicritério (MOLENAERS *et al.*, 2012). A

AHP tem como vantagens sua praticidade, habilidade de prover um quadro para decisões em grupo e abordar claramente o processo (AKBARI *et al.*, 2017), bem como avaliar critérios e alternativas quantitativas e qualitativas na mesma escala de preferências (ISHIZAKA; LABIB, 2011). Zeng *et al.* (2012) também afirmam que a AHP é amplamente utilizada pela facilidade de implementação.

A AHP usa o método de comparação par a par de duas maneiras. No Modelo Relativo, os elementos são comparados entre si. Quando há um grande número de elementos, o tomador de decisão deve organizá-los em *clusters* e realizar as comparações nesses *cluster*, no chamado modelo de classificação. Saaty (2008) afirma que os resultados desses modelos estão adequadamente próximos, mesmo que não atinjam exatamente as mesmas prioridades.

Na AHP, os julgamentos são convertidos em uma escala numérica de 1 a 9, que indica quantas vezes um elemento é mais importante que o outro na análise de um critério específico. Os especialistas comparam os critérios em cada nível correspondente. Pode-se calcular o número de comparações par a par necessárias ( $I$ ) em função do número de elementos ( $n$ ), por meio de  $I = n * (n - 1)/2$  (SAATY, 1990). Em quantidade elevada de dados, o processo computacional se torna custoso devido ao tamanho das matrizes, grande necessidade de espaço de armazenamento e a impossibilidade de julgamentos consistentes pelos especialistas. A verificação da consistência dos julgamentos no Método AHP é realizada com base nos autovalores e autovetores das matrizes de comparação par a par, o CR (*consistency ratio* – relação de consistência) com valores inferiores a 10% são aceitáveis (SAATY, 1990).

A AHP foi aplicada na classificação de inventário multicritério em diversos trabalhos de pesquisa. Flores *et al.* (1992) avaliaram vários objetivos de gerenciamento usando a AHP. Gajpal *et al.* (1994) usaram a AHP para obter medidas absolutas de criticidade e classificar peças sobressalentes como vital, essencial ou desejável. Partovi e Hopton (1994) aplicaram a AHP em setores industriais em dois problemas relacionados a estoques. Suryadi (2003) combinou a AHP e o Ponto de Corte para avaliar a criticidade em uma arquitetura de *software*. Braglia, Grassi, and Montanari (2004) desenvolveram uma matriz de política de estoques para traçar estratégias para estoques de peças sobressalentes em uma indústria de papel com altos níveis de estoque, combinando a AHP e a manutenção centrada na confiabilidade. Bosnjakovic (2010) utiliza um modelo multicritério que trata da política de estoques e previsão de demanda para controle de estoque de peças de reposição. Hadi-Vencheh e Mohamadghasemi (2011) integram o Fuzzy AHP com análise envoltória de dados

para classificação de inventário ABC multicritério no armazém de matéria-prima de uma linha de produção de refrigerantes. Kabir (2012) e Kabir e Hasin (2012) usam Fuzzy AHP para controlar itens de inventário e determinar as políticas de pedidos de itens em uma grande empresa de engenharia do setor de energia em Bangladesh. Molenaers *et al.* (2012) propuseram um modelo para converter critérios relevantes que afetam a criticidade do item em um único score de criticidade para cada nível com o uso da AHP. Wu e Tsai (2012) aplicaram a AHP pesquisando fornecedores de autopeças em Taiwan para identificar a importância de sete critérios principais e 30 subcritérios. Lolli *et al.* (2014) introduziram o novo método híbrido baseado na AHP e no algoritmo *K-means*. Stoll *et al.* (2015) apresentam uma abordagem de classificação tridimensional para peças de reposição com base na metodologia AHP e levando em conta tanto as perspectivas de produção quanto as de manutenção. Ladhari *et al.* (2016) propuseram um modelo híbrido para o problema de classificação de inventário multicritério utilizando AHP, R-model, H-model e Ng-model. Ishizaka *et al.* (2018) desenvolveram um método combinando análise envoltória de dados com AHP e *Analytic Network Process* (ANP) para minimizar as classificações ABC apenas baseada em valores percentuais.

A AHP também foi aplicada para apoiar decisões relacionadas ao setor de mineração. Sivakumar *et al.* (2015) sugeriram uma estrutura baseada em uma abordagem combinada de funções de perda com a AHP. Shen *et al.* (2015) utilizaram a AHP para analisar a eficiência da implementação da cadeia de fornecimento verde na indústria de mineração. Shang *et al.* (2015) combinaram o Método Delphi, AHP e Fuzzy para uma avaliação mais abrangente da dificuldade de se escolher as políticas de Mineração Verde do governo chinês. Li e Nie (2017) construíram um sistema de avaliação para identificar problemas existentes no processo de produção de carvão usando a AHP. Sobczyk *et al.* (2017) aplicaram o Método AHP para apoiar decisões relativas à escolha do investimento na aquisição de uma mina de minério de zinco e chumbo juntamente com a planta de processamento e seus depósitos. Mesmo com trabalhos que relacionam a AHP com o setor mineral, é notório o baixo volume de trabalhos no setor de mineração específicos no gerenciamento de peças sobressalentes.

As tomadas de decisões multicritério baseadas na AHP têm sido aplicadas em apoio a diferentes decisões e também no contexto da indústria de mineração. Outro fato marcante é a combinação da AHP com outras metodologias como técnicas de otimização.



## 2.6 Otimização e AHP

A tomada de decisão envolve a análise de diferentes aspectos, tendo como objetivo encontrar a resposta mais adequada para determinado problema. A otimização pode auxiliar a tomada de decisão quando existem muitas variáveis, ou em caso de impossibilidade de análise sistemática pelo tomador de decisão. A combinação de métodos multicritérios de decisão como a AHP, com modelos de otimização são relevantes no suporte a decisão.

Os modelos de otimização devem explicitar aspectos múltiplos de avaliação referentes aos objetivos distintos (ALVES *et al.*, 2015). No entanto, o problema de otimização multiobjetivo (MOPs – *Multiobjective Problems*) não tem uma solução única que possa otimizar todos os objetivos simultaneamente (OJHA; BISWAL, 2014). As diversas soluções encontradas durante o processo iterativo formam a Curva Pareto Ótima e podem ser encontradas por métodos de geração ou pelo  $\varepsilon$ -*constraint method* (OJHA; OTA, 2014; BABAZADEH *et al.*, 2017). As soluções eficientes são exploradas em vez de soluções ótimas (BABAZADEH *et al.*, 2017), sendo o método da restrição  $\varepsilon$  é um dos métodos mais populares para geração da Curva Pareto Ótima (SAHEBJAMNIA; TORABI; MANSOURI, 2015). No método da restrição  $\varepsilon$ , uma das funções-objetivo é selecionada para ser otimizada e os outros objetivos são abordados como restrições (OJHA; BISWAL, 2014; LUZ; MOURA; ALMEIDA, 2017), especificando níveis inferiores ou superiores.

Alguns estudos utilizam o método da restrição  $\varepsilon$ , como You e Wang (2011), Ojha e Biswal (2014), Saffar, Shakouri, e Razmi (2015), Mazidi, Monsef e Siano (2016) e Tsao *et al.* (2018). Recentemente, estudos que utilizam a AHP em conjunto com a restrição  $\varepsilon$  foram realizados por Allaoui *et al.* (2018), Jing *et al.* (2018) e Mohammed *et al.* (2018). Existem também aplicações que combinam a AHP com a programação linear, por exemplo, Ho, Lee e Ho (2010), Quezada e López-Ospina (2014), Ozgen e Gulsun (2014), Fallahi e Gholinezhad (2016), com outros métodos de otimização, como Ho, Lee e Ho (2010), Quezada e López-Ospina (2014), Ozgen e Gulsun (2014), Liu, Zhang e Beijing (2015), Fallahi e Gholinezhad (2016), Goyal, Kaushal e Sangaiah (2016), Goyal e Kaushal (2017) e Allaoui *et al.* (2018). Esses estudos não abordaram a combinação da AHP com modelos multiobjetivos e métodos de previsão nos ciclos de gestão de peças sobressalentes na fase normal de operação propostos neste trabalho.

A combinação da AHP com otimização pode ser utilizada para solucionar problemas multiobjetivos, por exemplo, em um conjunto de itens cujos valores e pesos são deterministas,

o objetivo é encontrar um subconjunto de itens a serem selecionados a fim de maximizar os valores totais, respeitando o limite das restrições (CHEN; ROSS, 2014).

O problema pode ser modelado considerando um limite financeiro  $r$ . O item  $j$  ( $j = 1, 2, 3, \dots, n$ ) tem custo  $r_j$  e criticidade  $c_j$  para cada material. O problema consiste na decisão de quais itens  $j$  estocar, respeitando a disponibilidade financeira  $r$  e obter a maior criticidade possível. Seja então a variável  $x_j$  pertencente ao conjunto dos números naturais inteiros, com essas considerações, o modelo se torna:

$$\text{Max } Z = \sum_{j=1}^n c_j * x_j \quad (2.17)$$

$$\text{Sujeito a: } \sum_{j=1}^n r_j * x_j \leq r \quad (2.18)$$

$$x_j \in \mathbb{Z}^+, \forall j = 1, 2, 3, \dots, n \quad (2.19)$$

A função objetivo (2.17) maximiza a criticidade total dos itens estocados, enquanto (2.18) define o limite financeiro disponível no período de previsão e (2.19) define o conjunto das variáveis inteiras.

Assim, o modelo desenvolvido baseia-se na criticidade dos itens calculadas no Método AHP, quantidades previstas nos modelos de previsão e são limitados valores financeiros disponíveis, o que gera um problema biobjetivo.


## CAPÍTULO 3

### CLASSIFICAÇÃO E MODELOS DE PREVISÃO

#### 3.1 Classificação da demanda

Os dados utilizados no trabalho são de uma mineradora brasileira com mais de 42.000 peças sobressalentes cadastradas no sistema *Enterprise Resource Planning* (ERP) do *software* SAP R/3 módulo de gestão de materiais MM. Destes, 12.723 foram analisados no trabalho por terem 10 anos (132 meses) de histórico de demanda mensal.

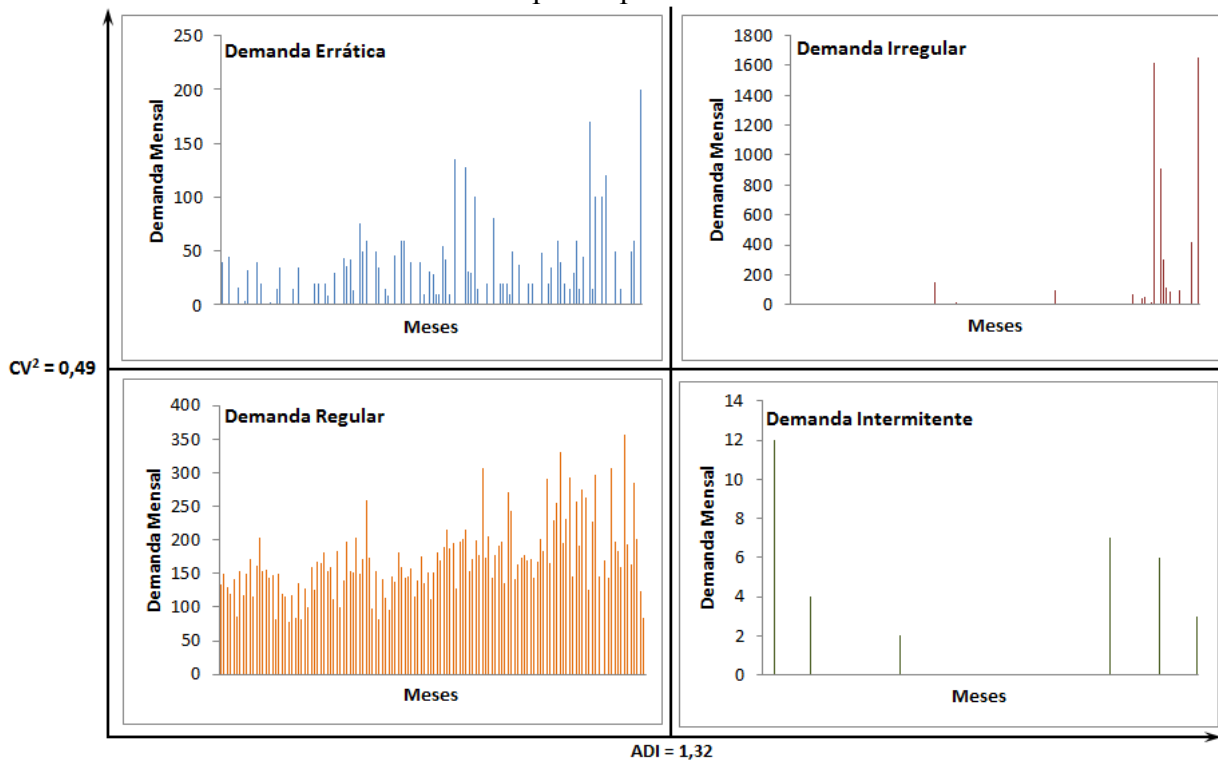
A classificação da demanda examina o consumo dos itens ao longo de um *lead time* e classifica a base de dados pela variação do padrão de demanda. A base de dados tem o *lead time* médio sem variabilidade, impossibilitando a utilização da classificação proposta por Eaves e Kingsman (2004), assim, foi utilizada a categorização proposta por Syntetos, Boylan e Croston (2005). A proporção final dos itens em cada padrão de demanda é ilustrada na FIG. 8, sendo retirados da base os itens com apenas uma demanda no período de 132 meses, o que resultou em uma quantidade final de 9.263 itens que serão utilizados ao longo do trabalho.



Fonte: Elaborada pelo autor.

Destaca-se a baixa ocorrência de itens da classe Regular e o maior número de itens do tipo Intermitente. A FIG. 9 ilustra o padrão da demanda de itens da série histórica de dados.

FIGURA 9 – Exemplo de padrão de demanda observado



Fonte: Elaborada pelo autor.

Percebem-se diferentes comportamentos entre os tipos de demanda, sendo assim, um estudo mais detalhado dos modelos de previsão é pertinente, no intuito de identificar modelos de previsão mais aderentes à base de dados com o objetivo de reduzir os erros de previsão, ruptura de estoque e altos custos de manutenção.

### 3.2 Análise dos modelos de previsão

Foram realizadas análises para definir a métrica de erro mais adequada entre MAE e Mase, em que os menores valores indicam melhor desempenho do modelo de previsão, levando-se em consideração que a previsão de demanda corresponde ao período de um mês. Os Modelos Amortecimento Exponencial, Croston, SBA, TSB e Bootstrap foram implementados em Python 2.7, os modelos que utilizam o parâmetro  $\alpha$  e o Bootstrap foram executados 10 vezes, o TSB foi executado 100 vezes por utilizar os parâmetros  $\alpha$  e  $\beta$ , totalizando 140 execuções com 17 análises estatísticas por execução dos modelos de previsão. A validação dos modelos de previsão, período de inicialização, aquecimento e erros foi realizada pelos exemplos disponíveis em Eaves (2002), com cálculos manuais, planilhas


eletrônicas e em Python 2.7, exceto o Bootstrap. O Bootstrap, proposto por Willemain, Smart e Schwarz (2004), foi validado por conferências manuais e em Python 2.7, com 1.000 sorteios com reposição. Para atendimentos de confiança nas estimações e poder amostral conforme Montgomery, Runger e Calado (2016), considerando distribuição normal, desvio padrão 200, nível de confiança 95% e intervalo de confiança bilateral, o tamanho amostral para estimação é de 849 sorteios com reposição para o Bootstrap. Desta forma tem-se 95% de confiança na estimação das estatísticas de precisão dos modelos de previsão, respeitando um erro máximo de 10 unidades para cima ou para baixo, a partir de seus valores médios. Por utilizar 1.000 sorteios com reposição para realização de cada previsão Bootstrap, apresenta-se resultados acima de 95% na estimação das estatísticas.

Os períodos de inicialização e aquecimento são anteriores à utilização das medidas de erro. Eaves (2002) utilizou um período de 12 meses para inicializar as previsões; Syntetos *et al.* (2015) utilizou um período 12 meses para inicialização e 24 meses para selecionar o melhor parâmetro de suavização, variando de 0,05 a 0,30 com incremento de 0,01; Boylan *et al.* (2008) utilizou 20 períodos para inicialização em uma base de 26 meses de histórico e 48 meses em uma base com 60 períodos. Percebe-se que não existe consenso na literatura sobre o período de inicialização e aquecimento, dessa forma, neste trabalho, foram utilizados períodos de 12 meses de inicialização e 24 de aquecimento.

Um objetivo comum na previsão de demanda é encontrar a variância mínima, estimador imparcial, no entanto, isso só pode ser alcançado se o processo de demanda subjacente for conhecido conforme Teunter, Syntetos e Babai (2011). Os autores reforçam que para demanda altamente não estacionária, é preferível um método de previsão que se adapte rapidamente pelas constantes de suavização com valores elevados. Como a demanda subjacente não é conhecida para peças sobressalentes é inviável encontrar a variância mínima.

O Método Bootstrap apresentou tempo de execução de 2.105 minutos para 1.000 amostragens, conforme mostra a FIG. 10; os demais modelos apresentaram tempo inferior a 60 minutos. Os cálculos dos erros e indicadores após cada execução consumiam 240 minutos. Nesta etapa não se considerou *lead time*. Para realização dos testes, foram utilizados cinco computadores com processador Intel® Core I3 com memória ram de 8Gb.

FIGURA 10 – Tempo computacional para execução do Bootstrap



Fonte: Elaborada pelo autor.

A mediana é a estatística de análise principal. Caso a comparação entre modelos apresentem os mesmos valores para mediana, é analisado o desvio padrão dos modelos. Nos modelos em que os erros MAE e Mase divergiram sobre o melhor valor dos parâmetros  $\alpha$  e  $\beta$ , foram analisados os indicadores taxa de cobertura e taxa de ruptura, ambos variando entre 0 e 1. A taxa de cobertura analisa o número de vezes que a demanda do período é completamente atendida pela quantidade disponível em estoque no período, assim, quanto maior seu valor, melhor. A taxa de ruptura indica em quais períodos o saldo de estoque é nulo ou negativo.

O experimento foi executado para os 9.263 itens nos Modelos Amortecimento Exponencial, Croston, SBA, TSB e Bootstrap. Os parâmetros  $\alpha$  e  $\beta$  foram variam de 0,1 a 1,0, com incremento de 0,1 a cada execução, e o percentil do Método Bootstrap com variação de 10% a 100%, com incremento de 10% a cada execução.

Para exemplificar, na análise do modelo de previsão Amortecimento Exponencial, o MAE sugere a utilização do parâmetro  $\alpha = 0,3$ , e o MASE sugere  $\alpha = 0,2$ , conforme a TAB. 2. No APÊNDICE 1, tem-se a taxa de cobertura de 0,562 e taxa de ruptura 0,021, utilizando  $\alpha = 0,3$  com a métrica de erro MAE. Com a métrica Mase, tem-se taxa de cobertura de 0,500 e taxa de ruptura 0,042. Assim, os indicadores taxa de cobertura e taxa de ruptura apresentaram melhor desempenho com a utilização do parâmetro  $\alpha = 0,3$  sugerido pela métrica de erro MAE, o que acarreta melhor desempenho do inventário.

A TAB. 2 apresenta os resultados do experimento dos modelos com divergência de melhor parâmetro  $\alpha$  entre as análises pela mediana dos erros MAE e Mase e o melhor desempenho na análise dos indicadores taxa de cobertura e taxa de ruptura.

TABELA 2 – Resultado do experimento comparativo entre MAE e Mase

Modelos de previsão	Erro MAE	Erro Mase
Amortecimento exponencial	$\alpha = 0,3$	$\alpha = 0,2$
Croston	$\alpha = 0,3$	$\alpha = 0,4$
SBA	$\alpha = 0,6$	$\alpha = 0,7$
TSB com $\beta = 0,7$	$\alpha = 0,3$	$\alpha = 0,2$
TSB com $\beta = 1,0$	$\alpha = 0,4$	$\alpha = 0,2$
Análise dos indicadores		
Melhor taxa de cobertura	2	3
Melhor taxa de ruptura	4	1
<b>Total</b>	<b>6</b>	<b>4</b>

Fonte: Elaborada pelo autor.

Apenas no Modelo TSB para  $\beta = 1,0$  os erros indicaram melhor modelo com divergência maior que 0,1 na variação de  $\alpha$ . Nesse caso, o erro MAE indica  $\alpha = 0,4$  como melhor parâmetro, e o Mase indica  $\alpha = 0,2$ . Os resultados do experimento dos melhores valores das constantes de amortecimento  $\alpha$  e  $\beta$  para diferentes modelos de previsão, considerando as métricas MAE e Mase, indicam o erro MAE como mais adequado à análise de dados por apresentar melhor desempenho na análise dos indicadores por seis vezes contra quatro vezes pela métrica Mase. Dessa forma, o erro MAE foi adotado como padrão desta pesquisa.

Foram realizadas mais 140 execuções dos modelos de previsão considerando o *lead time*. As 280 execuções foram analisadas pela retirada de *outlier* e de forma combinada por categoria de itens, das quais foram retirados os valores-base de comparação para os modelos propostos. Os percentuais de *outliers* das TAB. 3 a TAB. 8, com retirada pela base geral representa de 16,9% sem *lead time* e 16,8% com *lead time*, com retirada na categoria Errático tem-se 14,6% sem *lead time* e 14,4% com *lead time*, a categoria Irregular apresenta 16,5% de *outliers* sem *lead time* e 16,2% com *lead time*, na categoria Intermitente tem-se 11,8% de *outliers* sem *lead time* e 12,0% com *lead time* por fim a categoria regular apresenta 13,9% de *outliers* sem *lead time* e 13,0% de *outliers* com *lead time*.

A primeira forma de análise considera os valores dos erros na base completa sem retirada de *outliers* em cada modelo de previsão. Posteriormente, a análise nas categorias de classificação Regular, Errático, Intermitente e Irregular consolida-se à base, dessa vez utilizando em cada categoria o modelo e os parâmetros de melhor desempenho, conforme demonstrado na TAB. 3. Os resultados dos indicadores taxa de cobertura, taxa de ruptura e nível médio de estoque se encontram no APÊNDICE 2, TAB. 33 a 35.

TABELA 3 – Análise de previsão sem retirada de *outliers* e combinada

		Análise consolidada					
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,8$	$\beta = 0,5$	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,845	-	-	0,548	-
	Máximo	68.662,54	10.850,44	1.795,91	11.566,42	69.905,60	69.905,60
	1º quartil	0,092	4,134	0,556	0,062	1,278	0,090
	Mediana	0,314	10,018	1,578	0,157	3,529	0,318
	3º quartil	1,609	29,132	5,898	0,408	15,978	1,605
	Média	30,944	145,624	26,083	5,061	309,261	30,821
	Variância (n-1)	581.343,38	476.856,80	10.971,77	29.333,50	14.575.447,60	594.527,25
	Desvio Padrão (n-1)	762,46	690,55	104,75	171,27	3817,78	771,06

Fonte: Elaborada pelo autor.

A comparação entre a base de dados Geral e Geral Combinado apresentou elevação do valor da mediana do erro MAE de 0,314 para 0,318. Os indicadores, ver TAB. 33 a 35, APÊNDICE 2, taxa de cobertura manteve a mediana em 0,333; o nível médio de estoque com variação de 0,934 para 0,974; e a taxa de ruptura teve redução mais significativa de 0,135 para 0,104. Percebe-se que os valores máximos do erro MAE, TAB. 3, são elevados e que a forma de análise Geral Combinado apresenta melhora mais relevante com a redução da taxa de ruptura.

A segunda forma de análise considera os valores dos erros na base com retirada de *outliers* em cada modelo de previsão. Na sequência, os dados sem *outliers* são analisados nas categorias de classificação Regular, Errático, Intermitente e Irregular e, por fim, consolida-se a base na Abertura Geral Combinado. As categorias utilizam o modelo e os parâmetros de melhor desempenho sem *outliers*, o que pode gerar valores diferentes em quantidade de itens entre a coluna Geral e Geral Combinado, conforme a TAB. 4. Os resultados dos indicadores estão disponíveis no APÊNDICE 2, TAB. 36 a 38.



TABELA 4 – Análise de previsão sem *outliers* e combinada

Análise consolidada – sem <i>outliers</i>							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Combinado
Quantidade de itens		7.697	154	1332	6.039	174	7.699
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		$\beta = 0,5$	$\beta = 0,3$	$\beta = 0,7$	$\beta = 0,9$	$\beta = 0,2$	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,845	-	-	0,529	-
	Máximo	3,86	3,85	3,91	3,97	3,92	3,97
	1º quartil	0,073	1,762	0,364	0,062	0,945	0,074
	Mediana	0,206	2,516	0,822	0,145	1,278	0,206
	3º quartil	0,618	3,161	1,674	0,358	2,058	0,628
	Média	0,532	2,483	1,128	0,326	1,560	0,536
	Desvio Padrão (n-1)	0,58	0,67	0,94	0,26	0,66	0,59
Desvio Padrão (n-1)	0,76	0,82	0,97	0,51	0,81	0,77	

Fonte: Elaborada pelo autor.

A retirada dos *outliers* gerou a redução de itens na comparação entre as TAB. 3 e 4, na Abertura Geral, a redução foi de 9.236 para 7.697, correspondendo a 16,9%. Nas demais categorias, redução de 77,1% itens Erráticos, 31,8% itens Irregulares, 0,04% itens Intermitentes e 48,7% itens Regulares e na Abertura Geral Combinado a redução foi de 16,8%. Isso demonstra que a Categoria Errático apresenta maior dificuldade de previsibilidade e os itens Intermitentes são mais aderentes aos modelos de previsão. A comparação dos valores das medianas dos erros MAE entre as TAB. 3 e 4 apresentou redução em todas as bases de dados com a retirada de *outliers*. A melhora dos indicadores na análise comparativa entre as TAB. 33 a 35 e 36 a 38, do APÊNDICE 2, ficou estável nos itens Intermitentes e apresentou melhoras significativas nas demais aberturas.

A comparação entre a base de dados Geral e Geral Combinado, TAB. 4, manteve o valor da mediana do erro MAE em 0,206. Os indicadores, ver TAB. 36 a 38, APÊNDICE 2, taxa de cobertura melhorou de 0,400 para 0,417, nível médio de estoque com pequena redução de 1,0 para 0,989 e a taxa de ruptura com redução de 0,042 para 0,031 – o que reforça que a combinação de diferentes modelos de previsão melhora os resultados das previsões. Percebe-se também que os valores máximos do erro MAE reduziram significativamente e geraram redução nos valores de desvio padrão.

O terceiro método de análise retira os *outliers* por categorias, Regular, Errático, Intermitente e Irregular e, posteriormente, consolida na Abertura Geral Combinado, conforme TAB. 5. Os dados dos indicadores estão disponíveis no APÊNDICE 2, TAB. 39 a 41.

TABELA 5 – Análise de previsão sem *outliers* por categoria e combinada

		Análise consolidada por categoria					
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Combinado
Quantidade de itens		N/A	574	1.629	5.558	292	8.053
Erro	Estatísticas	N/A	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		N/A	$\beta = 0,2$	$\beta = 0,4$	$\beta = 0,5$	$\beta = 0,1$	Combinado
Erro Médio Absoluto – MAE	Mínimo	N/A	0,843	-	-	0,545	-
	Máximo	N/A	65,43	13,50	0,92	36,01	65,43
	1º quartil	N/A	3,720	0,455	0,057	1,124	0,077
	Mediana	N/A	7,820	1,141	0,125	2,426	0,228
	3º quartil	N/A	17,036	2,743	0,281	9,668	0,741
	Média	N/A	13,228	2,199	0,200	6,653	1,767
	Variância (n-1)	N/A	192,03	7,19	0,04	67,56	29,58
Desvio Padrão (n-1)	N/A	13,86	2,68	0,20	8,22	5,44	

Fonte: Elaborada pelo autor.

A retirada dos *outliers* reduziu a quantidade de itens entre as TAB. 3 e 5, sendo que, na Abertura Errático, a redução foi de 672 para 574, correspondendo a 14,6%. Na Abertura Irregular, houve redução de 16,5% na quantidade de itens; na Intermitente, redução de 11,8%; na Regular, redução de 13,8%; na Abertura Geral Combinado, a redução foi de 13,1%. A retirada de *outliers* por categoria tem variação percentual menor entre as categorias. A comparação dos valores das medianas dos erros MAE entre as TAB. 3 e 5 apresentou redução em todas as bases de dados com a retirada de *outliers*. As melhoras dos indicadores na análise comparativa entre as TAB. 33 a 35 e 39 a 41, APÊNDICE 2, ficou estável nos itens Intermitentes e apresentou melhoras significativas nas demais aberturas. A comparação das diferentes formas de retirada de *outliers* pode ser verificada na comparação entre as TAB. 4 e 5 e os indicadores das TAB. 36 a 38 e 39 a 41, APÊNDICE 2. A redução do erro ocorre apenas nos itens Intermitentes de 0,145 para 0,125, a taxa de cobertura e taxa de Ruptura se mantém constante na classe Intermitente, na classe Regular, a taxa de ruptura reduz de 0,406 para 0,365, sendo que o indicador nível médio de estoque apresenta redução significativa.

De forma geral, a redução nos valores dos erros ocorre em todas as categorias, comparação entre a TAB. 3 e a TAB. 5, mas a melhora é inferior à obtida pela retirada de *outliers* da base completa, comparação entre a TAB. 4 e a TAB. 5. Percebe-se que os erros reduzem com a retirada de *outliers*, o que mostra que as previsões se aproximam das demandas reais. Diante das análises, o Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,5$  sem *outliers* e o Geral Combinado sem *outliers* apresentam melhor desempenho referente ao erro MAE com mediada de 0,206, TAB. 4. Na sequência, o Modelo Geral Combinado sem *outliers* por categoria com mediana 0,228, TAB. 5, seguido pelo Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,3$  no Modelo

Geral com mediana de 0,314 e, por fim, o Modelo Geral Combinado com mediana 0,318, TAB. 3.

De forma geral, o modelo mais aderente em todas as categorias é o TSB com  $\alpha = 0,1$  e diferentes valores de  $\beta$ . Destaca-se que outros modelos, como Bootstrap, por vezes, apresentaram valores próximos aos resultados obtidos com o TSB. Foram realizadas 17 análises estatísticas por previsão nas 140 execuções dos modelos de previsão, o que totaliza 2.380 análises estatísticas. O mesmo método foi utilizado nos modelos de previsão com *lead time* nas previsões de demanda, perfazendo 4.760 avaliações estatísticas.

A primeira análise da base completa sem retirada de *outliers* com *lead time* é apresentada na TAB. 6, e os indicadores no APÊNDICE 2, TAB. 42 a 44.

TABELA 6 – Análise de previsão sem retirada de *outliers* com *lead time* e combinada

		Análise consolidada com <i>lead time</i>					
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Combinado
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		$\beta = 0,5$	$\beta = 0,6$	$\beta = 0,4$	$\beta = 0,7$	$\beta = 0,2$	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,889	-	-	0,540	-
	Máximo	69.905,60	11.196,32	1.791,77	13.712,26	68.608,27	68.608,27
	1º quartil	0,090	4,382	0,556	0,062	1,274	0,090
	Mediana	0,310	10,289	1,603	0,154	3,638	0,312
	3º quartil	1,638	29,760	5,967	0,402	17,015	1,626
	Média	31,239	148,440	26,200	5,431	303,891	31,105
	Variância (n-1)	602.087,10	497.305,28	110.45,46	386.61,97	14.033.905,38	582.477,76
Desvio Padrão (n-1)	775,94	705,20	105,10	196,63	3746,19	763,20	

Fonte: Elaborada pelo autor.

A mediana do erro MAE apresentou elevação do valor da mediana de 0,310 na base Geral para 0,312 na base Geral Combinado. Os indicadores, ver TAB. 42 a 44, APÊNDICE 2, taxa de cobertura manteve a mediana em 0,333, o nível médio de estoque com variação de 0,896 para 0,908 e a taxa de ruptura teve redução relevante de 0,167 para 0,156. Percebem-se elevados valores máximos do erro MAE e que a forma de análise Geral Combinado apresenta melhora com a redução da taxa de ruptura.

O modelo de previsão TSB predomina com variação do parâmetro  $\beta$  em todas as aberturas com e sem *lead time*, conforme TAB 3 e 6. Assim, desconsiderar o *lead time* induz à utilização de parâmetros errados nos modelos de previsão. A comparação dos indicadores, TAB. 33 a 35 e 42 a 44, APÊNDICE 2, mostra pequenas variações com e sem *lead time*; nas bases Geral e Geral Combinado, a taxa de cobertura se manteve em 0,333, o nível médio de estoque com pequena redução, considerando *lead time* e elevação na taxa de ruptura na base

Geral sem *lead time* de 0,135 para 0,167 com *lead time* e de 0,104 para 0,156 na Abertura Geral Combinado.

A segunda avaliação dos dados com retirada de *outliers* da base completa e consolidação final dos menores erros são apresentados na TAB. 7, e os indicadores estão disponíveis no APÊNDICE 2, TAB. 45 a 47.

TABELA 7 – Análise de previsão sem *outliers* com *lead time* e combinada

Análise consolidada com <i>lead time</i> – sem <i>outliers</i>							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Combinado
Quantidade de itens		7.708	150	1.336	6.041	173	7.700
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		$\beta = 0,8$	$\beta = 0,2$	$\beta = 0,5$	$\beta = 1,0$	$\beta = 0,2$	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,843	-	-	0,540	-
	Máximo	4,07	3,96	3,94	4,11	3,92	4,11
	1º quartil	0,073	1,770	0,374	0,062	0,951	0,074
	Mediana	0,203	2,492	0,845	0,143	1,299	0,204
	3º quartil	0,629	3,146	1,719	0,358	2,070	0,634
	Média	0,549	2,494	1,146	0,329	1,567	0,541
	Variância (n-1)	0,64	0,68	0,96	0,27	0,66	0,61
	Desvio Padrão (n-1)	0,800	0,827	0,980	0,523	0,814	0,778

Fonte: Elaborada pelo autor.

A retirada dos *outliers* gerou a redução de itens na comparação entre as TAB. 6 e 7; na Abertura Geral, a redução foi de 9.236 para 7.708, correspondendo a 16,8%. Nas demais classes, redução de 77,7%, itens Erráticos, 31,6%, itens Irregulares, 0,04%, itens Intermitentes e 48,9%, itens Regulares, já na Abertura Geral Combinado, a redução foi de 16,9% – valores próximos aos apresentados na mesma análise sem considerar *lead time*. A comparação dos valores das medianas dos erros MAE, entre as TAB. 6 e 7, apresentou redução em todas as bases de dados com a retirada de *outliers*. As melhoras dos indicadores na análise comparativa entre as TAB. 42 a 44 e 45 a 47, APÊNDICE 2, ficaram estáveis nos itens Intermitentes no indicador nível médio de estoque. Na comparação das TAB. 4 e 7, a Abertura Geral teve redução na mediana do erro MAE de 0,206 sem *lead time* para 0,203 com *lead time*; na Abertura Geral Combinado, a redução foi de 0,206 sem *lead time* para 0,204 com *lead time*. A taxa de cobertura comparada, com e sem *lead time*, apresenta redução na base Geral 0,400, TAB. 36, APÊNDICE 2, e 0,375, TAB. 45, APÊNDICE 2; na base Geral Combinado, ocorre uma elevação significativa de 0,417, TAB. 36, APÊNDICE 2, para 0,500, TAB. 45, APÊNDICE 2. O nível médio de estoque apresenta pequenas variações e a taxa de ruptura pequena piora na base Geral de 0,042, TAB. 38, APÊNDICE 2, para 0,073, TAB. 50, APÊNDICE 2; na base Geral Combinado, de 0,031, TAB. 38, APÊNDICE 2, para 0,042, TAB. 47, APÊNDICE 2.

A comparação entre a base de dados Geral e Geral Combinado, TAB. 7, apresentou pequena melhora na mediana do erro MAE de 0,203 para 0,204. Os indicadores, ver TAB. 45 a 47, APÊNDICE 2, tiveram melhora na taxa de cobertura da base Geral de 0,375 para base Geral Combinado de 0,500, TAB. 45. O nível médio de estoque com pequena elevação de 0,974 na base Geral para 0,979 na base Geral Combinado, TAB. 46. A taxa de ruptura com relevante redução de 0,073 na base Geral para 0,042 na base Geral Combinado, TAB. 47. Na comparação dos indicadores com e sem *lead time* nas bases Geral e Geral Combinado, TAB. 36 a 38 e 45 a 47, APÊNDICE 2. A taxa de ruptura na base Geral reduziu de 0,400 sem *lead time*, TAB. 36, para 0,375 com *lead time*, TAB. 45; por sua vez, na base Geral Combinado, ocorreu elevação expressiva de 0,417, TAB. 36, para 0,500, TAB. 45. O nível médio de estoque apresentou poucas variações. A taxa de ruptura da base Geral sem *lead time* aumentou de 0,042, TAB. 38, para 0,073, TAB. 47, e a base Geral Combinado de 0,031 para 0,042. Os resultados reforçam que a combinação dos modelos de previsão nas diferentes categorias melhoram os resultados, percebendo-se redução expressiva dos valores máximos do erro MAE, TAB. 6 e 7. Na análise entre os modelos com e sem *lead time*, destacam-se a redução dos erros e melhoras em indicadores.

A classe Regular apresenta os mesmos valores para os parâmetros  $\alpha = 0,1$  e  $\beta = 0,2$ , TAB. 4 e 7, com e sem *lead time* no Modelo TSB e variação de 174 para 173 na quantidade de itens.

A TAB. 8 apresenta a terceira análise com retirados *outliers* por categoria e, posteriormente, consolidação na base combinada com *lead time*, destacando-se a presença do modelo de previsão Bootstrap na classe Errático. Os indicadores estão disponíveis no APÊNDICE 2, TAB. 48 a 50.

TABELA 8 – Análise de previsão sem *outliers* com *lead time* por categoria e combinada

Análise consolidada por categoria com <i>lead time</i>							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Combinado
Quantidade de itens		N/A	575	1.636	5.544	295	8.050
Erro	Estatísticas	N/A	Bootstrap	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Geral
		N/A	Percentil 20	$\beta = 0,4$	$\beta = 0,3$	$\beta = 0,2$	Combinado
Erro Médio Absoluto – MAE	Mínimo	N/A	0,823	-	-	0,540	-
	Máximo	N/A	67,52	14,03	0,90	40,06	67,52
	1º quartil	N/A	3,677	0,456	0,058	1,127	0,077
	Mediana	N/A	7,969	1,173	0,125	2,484	0,227
	3º quartil	N/A	17,625	2,814	0,277	9,925	0,745
	Média	N/A	13,663	2,275	0,198	6,971	1,830
	Variância (n-1)	N/A	205,46	7,86	0,04	77,11	31,97
Desvio Padrão (n-1)	N/A	14,33	2,80	0,20	8,78	5,65	

Fonte: Elaborada pelo autor.

A retirada dos *outliers* reduziu a quantidade de itens entre as TAB. 6 e 8; na Abertura Errático, a redução foi de 672 para 575, correspondendo a 14,4%. Na Abertura Irregular, redução de 16,5% na quantidade de itens; na Intermitente, redução de 16,2%; na Regular, redução de 13,0%; na abertura Geral Combinado, a redução foi de 13,1%. Percebe-se que os valores percentuais são próximos à mesma análise sem utilização de *lead time*. A comparação dos valores das medianas dos erros MAE entre as TAB. 6 e 8 apresentou redução em todas as bases de dados com a retirada de *outliers*. A análise dos indicadores de forma comparativa, TAB. 42 a 44 e 48 a 50, APÊNDICE 2, ficou estável no indicador taxa de cobertura base Geral Combinado, TAB. 42 e 48, APÊNDICE 2, em 0,333 e apresentou melhoras significativas nas demais aberturas.

A Abertura Errático com o modelo de previsão Bootstrap apresentou redução da taxa de cobertura de 0,333, TAB. 42, para 0,018, TAB. 48, redução relevante no nível de estoque de -34,471, TAB. 43, para -226,41, TAB. 49, e elevação da taxa de ruptura de 0,167, TAB. 44, para 0,969, TAB. 50. Isso demonstra que o Método Bootstrap reduziu o erro de previsão da Abertura Errático de 10,289, TAB. 6, para 7,969, TAB. 8, o que indica que as previsões apresentam valores menores que a demanda real. Ao comparar as TAB. 7 e 8 na Abertura Errático, que abordam a retirada de *outliers*, tem-se valor máximo do erro MAE de 3,96, erro mínimo de 0,843 e desvio padrão de 0,827, TAB. 7, e erro máximo de 67,52, erro mínimo de 0,823 e desvio padrão de 14,33, TAB. 8, reforçando que o Modelo Bootstrap apresenta amplitude maior em relação aos valores previstos.

A comparação entre a retirada de *outliers* por categoria com e sem *lead time*, TAB. 5 e 8, apresenta valores muito próximos de erros MAE em todas as aberturas; na Abertura Geral Combinado, temos a variação de mediana de 0,228, TAB. 5, para 0,227, TAB. 8. As TAB. 39 a 41 e 48 a 50, APÊNDICE 2, apresentam os indicadores.

Percebe-se que os erros reduzem com a retirada de *outliers*, o que mostra que as previsões se aproximam das demandas reais. Diante das análises, o Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,5$  sem *outliers* com mediana do erro MAE 0,203, TAB. 6, e o Geral Combinado sem *outliers* com mediana do erro MAE 0,204, TAB. 6, apresentam melhor desempenho referente ao erro MAE. Na sequência, o Modelo Geral Combinado sem *outliers* por categoria com mediana 0,227, TAB. 8, seguido pelo Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,5$  no Modelo Geral com mediana de 0,310 e, por fim, o Modelo Geral Combinado com mediana 0,312, TAB. 6.

De forma geral, o modelo mais aderente, em todas as categorias, é o TSB com  $\alpha = 0,1$  e diferentes valores de  $\beta$ , com ou sem *lead time*. Destaca-se que o Bootstrap, por vezes, apresentou valores próximos aos resultados obtidos com o TSB e desempenho melhor pela métrica MAE na Categoria Errático, TAB. 8, com impacto negativo nos indicadores.

Pode-se concluir, dessas análises, que a retirada dos *outliers* permitiu visualizar a região de melhor aderência dos modelos de previsão aos dados, o que reduz a possibilidade de erro na decisão de compra das peças sobressalentes durante os ciclos mensais de previsão. O Modelo TSB apresenta-se como o mais adequado entre os modelos de previsão para peças sobressalentes. Posteriormente, o Bootstrap se mostra como uma segunda opção, porém seu elevado tempo computacional é um ponto negativo, bem como a piora identificada nos indicadores. Uma diferença dos Modelos TSB e Bootstrap para os Modelos de Amortecimento Exponencial, SBA e Croston é a forma de tratamento das previsões quando a demanda no período é nula. Outro detalhe observado é que a variação de parâmetros pode trazer melhorias nas análises de categorias. Assim, foram propostos modelos conjugados de previsão que considerem a variação dos parâmetros e previsões em períodos de demanda nula e não nula.

### 3.3 Proposição de modelos de previsão e análises

Os métodos propostos utilizam os cálculos dos modelos de previsão realizados anteriormente e realiza a variação de parâmetros ou a conjugação entre modelos. A variação consiste em alterar os valores dos parâmetros  $\alpha$ ,  $\beta$  e o percentil Bootstrap. Os modelos conjugados mesclam parte dos modelos tradicionais. A TAB. 9 apresenta um resumo desses modelos. A execução dos modelos conjugados foi realizada com variação dos melhores parâmetros para  $\alpha$  e  $\beta$  com variação de 0,1 e variação de 10 para percentil Bootstrap. A variação ocorreu para mais e para menos no entorno dos melhores resultados obtidos com os modelos de previsão pela análise da mediana do erro MAE.

Os melhores resultados dos modelos de previsão sem *lead time* foram: Amortecimento Exponencial com  $\alpha = 0,3$ , Modelo de Croston com  $\alpha = 0,4$ , Modelo SBA com  $\alpha = 0,6$ , Modelo TSB com  $\alpha = 0,1$  e  $\beta = 0,3$  e Modelo Bootstrap para percentil 10. Com *lead time*, os melhores resultados foram Amortecimento Exponencial  $\alpha = 0,4$ , Croston com  $\alpha = 0,3$ , SBA com  $\alpha = 0,7$ , TSB com  $\alpha = 0,1$  e  $\beta = 0,5$  e Bootstrap com percentil 10. Assim, os modelos propostos combinados com Amortecimento Exponencial sem *lead time* variaram com  $\alpha$  em 0,2, 0,3 e 0,4, inicialmente; em caso de melhora dos resultados, com  $\alpha = 0,4$ , por exemplo, o

modelo era executado para  $\alpha = 0,5$  até que não fossem obtidos melhores resultados. Foram realizadas 50 novas execuções dos modelos de previsão propostos com 17 análises estatísticas a cada execução. Assim tem-se 850 análises estatísticas sem *lead time* e o mesmo volume de execuções e análises com *lead time*. Somada às anteriores, temos 380 execuções de modelos de previsão com 6.460 avaliações estatísticas.

TABELA 9 – Modelos propostos

<b>Modelos de previsão variáveis</b>	<b>Execuções</b>
Amortecimento Exponencial Variável	2
Croston Variável	2
SBA Variável	2
TSB Variável	2
Bootstrap Variável	2
<b>Modelos de previsão conjugados</b>	
Amortecimento Exponencial com Bootstrap	8
Croston com Bootstrap	8
SBA com Bootstrap	8
TSB com Bootstrap	8
<b>Modelos de previsão variáveis conjugados</b>	
Amortecimento Exponencial com Bootstrap Variáveis	2
Croston com Bootstrap Variáveis	2
SBA com Bootstrap Variáveis	2
TSB com Bootstrap Variáveis	2

Fonte: Elaborada pelo autor.

Os métodos de previsão variáveis consistem em atualizar o valor dos parâmetros antes de cada previsão realizando os seguintes passos:

1. Faça a inicialização e aquecimento do método.
2. Execute o método.
3. Antes de realizar a previsão do próximo período, retorne ao período anterior e faça as previsões para todos os valores de parâmetros.
4. Armazene as previsões.
5. Calcule o  $|e_t|$  para todas as previsões.
6. Encontre o menor  $|e_t|$  e seu respectivo parâmetro.
7. Atualize o parâmetro do modelo e faça a próxima previsão.
8. Repita os passos 2 a 7 até terminar o histórico de demanda.

Os métodos conjugados realizam uma previsão Bootstrap, com a série de dados histórica existente até o período, quando ocorre demanda nula utilizando os seguintes passos:

1. Faça inicialização e aquecimento do método.
2. Execute o método.
3. Na ocorrência de demanda nula, faça uma previsão Bootstrap.



4. Atualize os parâmetros do modelo.
5. Repita os passos 2 a 5 até terminar o histórico de demanda.

Os métodos variáveis conjugados utilizam as duas lógicas propostas, como segue:

1. Faça a inicialização e aquecimento do método.
2. Execute o método.
3. Antes de realizar a previsão do próximo período, retorne ao período anterior e faça as previsões para todos os valores de parâmetros.
4. Armazene as previsões.
5. Calcule o  $|e_t|$  para todas as previsões.
6. Encontre o menor  $|e_t|$  e seu respectivo parâmetro.
7. Na ocorrência de demanda nula, faça uma previsão Bootstrap.
8. Atualize os parâmetros do modelo e faça a próxima previsão.
9. Atualize os parâmetros do modelo.
10. Repita os passos 2 a 10 até terminar o histórico de demanda.

Os modelos propostos tentam se adaptar às variações de demanda pela correção dos parâmetros a cada iteração. São apresentados apenas os resultados quando os modelos propostos apresentaram alguma melhora em relação aos modelos tradicionais com análise do MAE.

Os modelos sem *lead time* apresentaram melhoras na Categoria Errático com base completa, TAB. 10, e com retirada de *outliers* por categoria, TAB. 11.

TABELA 10 – Ganhos na Categoria Errático MAE

<b>Análise base completa</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		672	672
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math></b>	<b>SBA <math>\alpha = 0,5</math></b>
		<b><math>\beta = 0,3</math></b>	<b>com Bootstrap percentil 10</b>
Erro Médio Absoluto – MAE	Mínimo	0,845	0,871
	Máximo	10.850,44	11.747,58
	1º quartil	4,134	4,219
	Mediana	10,018	9,721
	3º quartil	29,132	29,141
	Média	145,624	141,623
	Variância (n-1)	476.856,80	484.842,70
	Desvio Padrão (n-1)	690,55	696,31

Fonte: Elaborada pelo autor.

O valor da mediana do erro MAE sem *lead time* reduziu de 10,018 para 9,721, TAB. 10. O resultado dos indicadores, TAB. 51 a 53, APÊNDICE 3, pela análise das medianas, apresentou uma redução da taxa de cobertura de 0,172 para 0,012 com valores máximos de 1; a taxa de ruptura aumentou de 0,781 para 0,979 e o nível médio de estoque passou de -30,316 para -163,425. O resultado da piora dos indicadores é explicado pelo valor máximo entre os modelos de previsão, na TAB. 52, em que o Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,3$  apresenta valor máximo do nível médio de estoque de 4.899; e o Modelo SBA  $\alpha = 0,5$  e Bootstrap percentil 10 apresenta valor máximo de nível médio de estoque de 569,11, o que mostra um volume de estoque menor e, conseqüentemente, maior exposição à ruptura.

Na terceira análise, com retirada dos *outliers* por categoria, foram obtidas duas melhoras na redução do erro MAE pela análise da mediana. Ver APÊNDICE 3, TAB. 54 a 56, para indicadores.

**TABELA 11 – Ganhos na Categoria Errático MAE**

**Análise base sem outliers por categoria**

Base de dados		Errático	Errático	Errático
Quantidade de itens		574	577	578
Erro	Estatísticas	TSB $\alpha = 0,1$	SBA com	SBA $\alpha = 0,5$
		$\beta = 0,2$	Bootstrap	com Bootstrap
			variáveis	percentil 10
Erro Médio Absoluto – MAE	Mínimo	0,843	0,829	0,871
	Máximo	65,43	67,08	66,09
	1º quartil	3,720	3,768	3,722
	Mediana	7,820	7,753	7,588
	3º quartil	17,036	17,333	17,226
	Média	13,228	13,471	13,332
	Variância (n-1)	192,03	200,78	198,00
	Desvio Padrão (n-1)	13,86	14,17	14,07

Fonte: Elaborada pelo autor.

A mediana do erro MAE reduziu de 7,820 para 7,753 e, posteriormente, 7,588 com os modelos propostos. Em relação aos indicadores com análise pela mediana, a taxa de cobertura variou de 0,170 para 0,016 e terminou em 0,013, TAB. 54; a taxa de ruptura aumentou de 0,766 para 0,969 e fechou em 0,979, TAB. 56, e o nível médio de estoque iniciou em -21,38, foi para -113,29 e terminou em -129,68, TAB. 55, indicando que as previsões geraram menos estoques, reagindo de forma mais lenta às variações de demanda. Conseqüentemente, o nível de estoque máximo ficou menor, iniciando em 1.910,74, reduzindo para 403,20 e finalizando com 569,11, TAB. 55.

Os modelos com *lead time* apresentaram melhoras na Categoria Errático, considerando a base completa de dados, TAB. 12, com redução da mediana do erro MAE de 10,289 para 10,277.

TABELA 12 – Ganhos na Categoria Errático MAE

<b>Análise base completa com <i>lead time</i></b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		672	672
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math></b>	<b>SBA <math>\alpha = 0,5</math></b>
		<b><math>\beta = 0,6</math></b>	<b>com Bootstrap percentil 20</b>
Erro Médio Absoluto – MAE	Mínimo	0,889	0,856
	Máximo	11.196,32	11.552,76
	1º quartil	4,382	4,336
	Mediana	10,289	10,277
	3º quartil	29,760	30,116
	Média	148,440	142,784
	Variância (n-1)	497.305,28	473.134,43
	Desvio Padrão (n-1)	705,20	687,85

Fonte: Elaborada pelo autor.

A avaliação dos indicadores pela mediana, TAB. 57 a 59, mostra a redução de 0,160 para 0,22 da taxa de cobertura, TAB. 56, aumento de 0,781 para 0,969 da taxa de ruptura, TAB. 58, redução do nível médio de estoque de -34,47 para -145,20, com redução do valor máximo de 5.303,54 para 626,88, TAB. 57.

Com a retirada de *outliers* por categoria, ocorreu ganho na Categoria Errático, a única com melhor desempenho pelo Bootstrap. O valor da mediana do erro MAE reduziu de 7,969 para 7,897, TAB. 13. As TAB. 60 a 62, APÊNDICE 3, apresentam os indicadores.

TABELA 13 – Ganhos na Categoria Errático MAE

<b>Análise base sem <i>outliers</i> por categoria</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		575	576
<b>Erro</b>	<b>Estatísticas</b>	<b>Bootstrap</b>	<b>SBA <math>\alpha = 0,6</math></b>
		<b>percentil 20</b>	<b>com Bootstrap percentil 10</b>
Erro Médio Absoluto – MAE	Mínimo	0,823	0,862
	Máximo	67,52	66,94
	1º quartil	3,677	3,813
	Mediana	7,969	7,897
	3º quartil	17,625	17,121
	Média	13,663	13,505
	Variância (n-1)	205,46	200,39
	Desvio Padrão (n-1)	14,33	14,16

Fonte: Elaborada pelo autor.

Pela análise das medianas, o indicador taxa de cobertura reduziu de 0,018 para 0,014, TAB. 62, a taxa de ruptura aumentou de 0,969 para 0,979, TAB. 62, e o nível médio de estoque apresentou aumento de -226,41 para -145,58, com redução do valor máximo de 833,40 para 332,06.

Por fim, uma última análise consolidou o melhor modelo de previsão por item. A busca dos menores erros por item foi realizada pelos resultados dos modelos de previsão tradicionais e propostos. Foi selecionado o menor erro MAE de previsão por item e posteriormente os modelos foram combinados. A redução dos erros ocorreu em quase todas as aberturas e formas de análise, as excessões ocorreram nos itens Regulares sem retirada de *outliers*, TAB. 14, e nos itens Intermitentes com retirada de *outliers*, TAB. 16. As TAB. 14, 15 e 16 apresentam os resultados que são comparáveis aos apresentados nas TAB. 3, 4 e 5, cujos valores são apresentados nas últimas linhas das TAB. 14, 15 e 16. Todos os indicadores estão disponíveis no APÊNDICE 3, TAB. 63 a 71.

TABELA 14 – Análise de previsão sem retirada de *outliers* e combinada por item

Modelos combinados por item						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,771	-	-	0,515
	Máximo	67.038,66	10.229,77	1.346,10	11.059,42	67.038,66
	1º quartil	0,083	3,709	0,502	0,059	1,198
	Mediana	0,290	9,128	1,452	0,146	3,529
	3º quartil	1,495	26,224	5,288	0,373	15,700
	Média	27,426	124,943	20,803	4,712	294,370
	Variância (n-1)	539.966,23	364.786,77	6.342,70	26.779,96	13.397.028,22
	Desvio Padrão (n-1)	734,82	603,98	79,64	163,65	3.660,20
<b>TABELA 3 – Mediana</b>		<b>0,314</b>	<b>10,018</b>	<b>1,578</b>	<b>0,157</b>	<b>3,529</b>

Fonte: Elaborada pelo autor.

Os itens da Categoria Regular não apresentaram variação no valor da mediana, no entanto, ocorreu a redução do desvio padrão de 3.817,78, TAB. 3, para 3.660,20, TAB. 14. Na comparação dos indicadores, TAB. 33 a 35, APÊNDICE 2, com as TAB. 63 a 65, APÊNDICE 3, ocorreu redução dos valores da taxa de cobertura e nível médio de estoque e aumento da taxa de ruptura em todas categorias. Isso pode ser explicado pela redução da mediana do nível médio de estoque, comparativo TAB. 34 e TAB. 64. Na base Geral, a redução foi de 0,934 para 0,506.

TABELA 15 – Análise de previsão sem *outliers* e combinada por item

Modelos combinados por item						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.712	159	1.336	6.045	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,771	-	-	0,515
	Máximo	3,61	3,59	3,61	3,57	3,54
	1º quartil	0,066	1,615	0,333	0,057	0,891
	Mediana	0,189	2,344	0,754	0,135	1,222
	3º quartil	0,574	2,953	1,536	0,328	1,908
	Média	0,494	2,298	1,024	0,302	1,466
	Variância (n-1)	0,50	0,58	0,78	0,23	0,56
	Desvio Padrão (n-1)	0,71	0,76	0,88	0,48	0,75
<b>TABELA 4 – Mediana</b>		<b>0,206</b>	<b>2,516</b>	<b>0,822</b>	<b>0,145</b>	<b>1,278</b>

Fonte: Elaborada pelo autor.

Destaca-se a redução dos erros em todas as categorias e um aumento na quantidade de itens de 7.699 na base Geral Combinado, TAB. 4, para 7.712, TAB. 15, apenas os itens Regulares apresentaram redução de 174 para 172.

Na comparação dos indicadores, TAB. 36 a 38, APÊNDICE 2, com as TAB. 66 a 68, APÊNDICE 3, ocorreu redução dos valores da taxa de cobertura, com exceção na categoria dos itens classificados como Irregulares, comparação TAB. 36 e TAB. 66, que manteve a mediana em 0,143 com redução do desvio padrão de 0,375 para 0,35. O nível médio de estoque reduziu em todas as categorias e a taxa de ruptura aumentou, o que pode ser explicado pela redução da mediana do nível médio de estoque, comparativo TAB. 37 e TAB. 67. Na base Geral, a redução foi de 1,0 para 0,914.

TABELA 16 – Análise de previsão sem *outliers* por categoria e combinada por item

Modelos combinados por item							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	1.630	5.548	295	8.048	575
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Erro Médio Absoluto – MAE	Mínimo	N/A	-	-	0,515	-	0,771
	Máximo	N/A	12,42	0,84	36,80	59,43	59,43
	1º quartil	N/A	0,405	0,053	1,094	0,071	3,354
	Mediana	N/A	1,040	0,116	2,438	0,208	6,979
	3º quartil	N/A	2,491	0,256	9,537	0,688	15,444
	Média	N/A	1,997	0,184	6,510	1,620	11,898
	Variância (n-1)	N/A	5,97	0,03	67,27	24,34	150,71
	Desvio Padrão (n-1)	N/A	2,44	0,18	8,20	4,93	12,28
<b>TABELA 5 – Mediana</b>		<b>N/A</b>	<b>1,141</b>	<b>0,125</b>	<b>2,426</b>	<b>0,228</b>	<b>7,820</b>

Fonte: Elaborada pelo autor.

Apenas os itens Intermitentes apresentaram aumento na mediana do erro MAE de 2,426 para 2,438, mas a TAB. 16 avalia 295 itens, enquanto a análise por modelo tem 292, TAB. 5. Mesmo com uma quantidade maior de itens, ocorreu redução no desvio padrão de 8,22 para 8,20. Na comparação dos indicadores, TAB. 39 a 41, APÊNDICE 2, com as TAB. 69 a 71, APÊNDICE 3, ocorreu redução dos valores da taxa de cobertura, com exceção na Categoria Intermitente, comparação entre a TAB. 39 e a TAB. 69, que manteve a mediana em 0,500 com redução do desvio padrão de 0,41 para 0,39. O nível médio de estoque reduziu em todas as categorias e a taxa de ruptura aumentou, devido à redução da mediana do nível médio de estoque, comparativo TAB. 40 e TAB. 70. Na base Geral, a redução foi de 0,969 para 0,873.

Os resultados dos modelos combinados por item com *lead time* são apresentados nas TAB. 17, 18 e 19 – para comparação, ver TAB. 6, 7 e 8. Todos os modelos apresentaram redução dos erros em todas aberturas. As TAB. 72 a 80, APÊNDICE 3, apresentam os valores dos indicadores.

TABELA 17 – Análise de previsão sem retirada de *outliers* com *lead time* e combinada

Modelos combinados por item com <i>lead time</i>						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Erro Médio Absoluto – MAE	Mínimo	-	0,771	-	-	0,518
	Máximo	67.038,66	10.076,20	1.346,10	13.712,26	67.038,66
	1º quartil	0,083	3,866	0,505	0,059	1,198
	Mediana	0,288	9,326	1,473	0,143	3,557
	3º quartil	1,518	27,352	5,408	0,372	16,214
	Média	27,863	125,731	20,862	5,213	295,105
	Variância (n-1)	547.397,35	361.235,91	6.341,26	38.128,55	13.395.953,01
	Desvio Padrão (n-1)	739,86	601,03	79,63	195,27	3.660,05
<b>TABELA 6 – Mediana</b>		<b>0,310</b>	<b>10,289</b>	<b>1,603</b>	<b>0,154</b>	<b>3,638</b>

Fonte: Elaborada pelo autor.

A mediana do erro MAE apresentou redução em todas as categorias, TAB. 17. Na comparação dos indicadores, TAB. 42 a 44, APÊNDICE 2, com as TAB. 72 a 74, APÊNDICE 3, ocorreu redução dos valores da taxa de cobertura e do nível médio de estoque, a taxa de ruptura aumentou, pois houve redução da mediana do nível médio de estoque, comparativo TAB. 43 e TAB. 73. Na base Geral Combinado, a redução foi de 0,908 para 0,473.

A TAB. 18 apresenta redução na mediana do erro MAE em todas as categorias com *lead time* e retirada de *outliers*. Nessa abertura, ocorreu o aumento do número de itens em

todas as categorias, no total de 7.708 itens base Geral, TAB. 7, para 7.715 Geral Combinado, TAB. 18. Apenas os itens Regulares apresentaram redução de 174 para 172. Ver TAB. 75 a 77, APÊNDICE 3, para indicadores.

**TABELA 18 – Análise de previsão sem outliers com lead time e combinada**

<b>Modelos combinados por item com lead time</b>						
<b>Base de dados</b>		<b>Geral</b>	<b>Errático</b>	<b>Irregular</b>	<b>Intermitente</b>	<b>Regular</b>
Quantidade de itens		7.715	158	1.338	6.047	172
<b>Erro</b>	<b>Estatísticas</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>
<b>Erro Médio Absoluto – MAE</b>	Mínimo	-	0,771	-	-	0,518
	Máximo	3,67	3,67	3,64	3,67	3,66
	1º quartil	0,066	1,633	0,334	0,056	0,899
	Mediana	0,188	2,355	0,764	0,133	1,222
	3º quartil	0,573	2,998	1,563	0,329	1,966
	Média	0,500	2,338	1,043	0,304	1,485
	Variância (n-1)	0,52	0,63	0,81	0,24	0,61
	Desvio Padrão (n-1)	0,72	0,79	0,90	0,49	0,78
<b>TABELA 7 – Mediana</b>		<b>0,203</b>	<b>2,492</b>	<b>0,845</b>	<b>0,143</b>	<b>1,299</b>

Fonte: Elaborada pelo autor.

Na comparação dos indicadores, TAB. 45 a 47, APÊNDICE 2, com as TAB. 75 a 77, APÊNDICE 3, ocorreu redução dos valores da taxa de cobertura, com exceção na Categoria Irregular, comparação entre a TAB. 45 e a TAB. 65, que manteve a mediana em 0,143 com redução do desvio padrão de 0,382 para 0,350. O nível médio de estoque reduziu em todas as categorias e a taxa de ruptura aumentou, isso pode ser explicado pela redução da mediana do nível médio de estoque, comparativo TAB. 46 e TAB. 76. Na base Geral, a redução foi de 0,974 para 0,862.

A TAB. 19 apresenta redução na mediana do erro MAE em todas as categorias com lead time e retirada de outliers por categoria. Nessa abertura, ocorreu redução do número de itens em todas as categorias, no total de 8.050 itens base Geral Combinado, TAB. 8, para 8.046 na Geral Combinado, TAB. 18. Ver TAB. 78 a 80, APÊNDICE 3, para indicadores.

**TABELA 19 – Análise de previsão sem outliers com lead time por categoria e combinada**

<b>Modelos combinados por item com lead time</b>							
<b>Base de dados</b>		<b>Geral</b>	<b>Errático</b>	<b>Irregular</b>	<b>Intermitente</b>	<b>Regular</b>	<b>Geral</b>
Quantidade de itens		N/A	576	1.634	5.542	294	8.046
<b>Erro</b>	<b>Estatísticas</b>	<b>N/A</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>	<b>Combinado</b>
<b>Erro Médio Absoluto – MAE</b>	Mínimo	N/A	0,771	-	-	0,518	-
	Máximo	N/A	61,70	12,66	0,84	37,38	61,70
	1º quartil	N/A	3,459	0,413	0,053	1,089	0,071
	Mediana	N/A	7,247	1,076	0,115	2,389	0,207
	3º quartil	N/A	15,943	2,573	0,256	9,178	0,693
	Média	N/A	12,265	2,052	0,183	6,511	1,659
	Variância (n-1)	N/A	163,03	6,37	0,03	65,37	25,82
	Desvio Padrão (n-1)	N/A	12,77	2,52	0,18	8,09	5,08

TABELA 8 – Mediana	N/A	7,969	1,173	0,125	2,484	0,227
--------------------	-----	-------	-------	-------	-------	-------

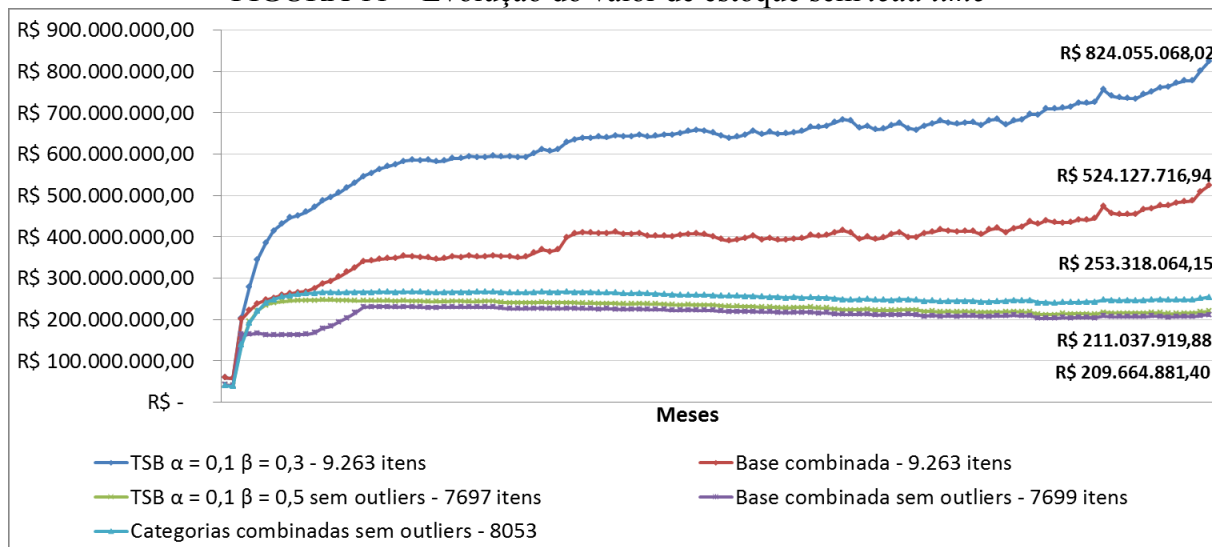
Fonte: Elaborada pelo autor.

Na comparação dos indicadores, TAB. 48 a 50, APÊNDICE 2, com as TAB. 68 a 80, APÊNDICE 3, o valor da mediana da taxa de cobertura na comparação entre as TAB. 48 e 68 base Geral Combinado se manteve em 0,333, com redução do desvio padrão de 0,40 para 0,39, com aumento de 0,018 para 0,022 na Categoria Errático. O nível médio de estoque na Categoria Errático apresentou aumento de -226,406 para -112,403, o valor máximo reduziu de 833,40 para 331,98, nesse caso ocorreu aumento da taxa de cobertura com redução de estoque. Para as demais categorias, ocorreu redução do nível médio de estoque. A taxa de ruptura da Categoria Errático se manteve constante em 0,969, comparativo TAB. 50 e 80, com redução do desvio padrão de 0,27 para 0,21; nas demais categorias, a taxa de ruptura aumentou.

De forma geral, a redução dos erros de previsão gera, na maioria das vezes, menor nível de estoque, redução da taxa de cobertura e aumento da taxa de ruptura, o que se explica pela proximidade do valor previsto e a demanda real no período.

Outra forma de análise relevante para modelos de previsão é a evolução do valor de estoque, FIG. 11, que torna mais fácil a visualização das abordagens propostas. Os valor inicial de estoque é de R\$ 59 milhões para base completa; nas bases com retirada de *outliers*, os valores iniciais são próximos a R\$ 42 milhões.

FIGURA 11 – Evolução do valor de estoque sem *lead time*




Fonte: Elaborada pelo autor.



Percebe-se que a utilização de um único modelo de previsão em todas as categorias é uma decisão incorreta, pois os valores de inventário alcançam R\$ 824 milhões, referente à aplicação do Modelo Geral TSB  $\alpha = 0,1$  e  $\beta = 0,3$ , TAB. 3. O Modelo Geral Combinado, TAB. 3, já apresenta redução significativa do valor final em estoque para R\$ 524 milhões. Com a retirada dos *outliers* por categoria, temos 8.053 itens, TAB. 5, com valor de estoque de R\$ 253 milhões. A retirada de *outliers* na base Geral apresenta 7.697 itens, TAB. 4, com valor de estoque de R\$ 211 milhões, e a base Geral Combinando com 7.699 itens, TAB. 4, valor total de estoque de R\$ 209 milhões. Os gráficos por categoria de classificação são apresentados no APÊNDICE 4. A FIG. 12 apresenta os valores com *lead time*.

FIGURA 12 – Evolução do valor de estoque com *lead time*



Fonte: Elaborada pelo autor.

A elevação do valor de estoque com *lead time* na utilização de um único modelo de previsão alcança o valor final de inventário de R\$ 659 milhões, referente à aplicação do Modelo Geral TSB  $\alpha = 0,1$  e  $\beta = 0,5$ , TAB. 6. O Modelo Geral Combinado, TAB. 6, reduz o valor final em estoque para R\$ 566 milhões. Com a retirada dos *outliers* por categoria, tem-se 8.050 itens, TAB. 8, com valor de estoque de R\$ 353 milhões. A retirada de *outliers* na base Geral apresenta 7.708 itens, TAB. 4, com valor de estoque de R\$ 269 milhões, e a base Geral Combinando com 7.700 itens, TAB. 7, com valor total de estoque de R\$ 245 milhões. Os gráficos por categoria de classificação são apresentados no APÊNDICE 4.

A retirada de *outliers* gera melhor controle do aumento do valor de estoque, caracterizado pelas curvas sem tendências de forte aumento ou redução na maior parte do

período analisado. As análises combinadas geram valores de estoque menor, se comparados à utilização de um único modelo de previsão. Mesmo com os modelos combinados e retiradas de *outliers*, o crescimento no valor de estoque ainda é significativo.

A análise dos itens, individualmente, pelo menor erro MAE apresentou uma grande variedade de modelos de previsão, conforme TAB. 20 e 21. São apresentados os modelos apenas com percentual acima de 1%, os demais foram consolidados.

TABELA 20 – Análise menor erro MAE de previsão por item

Previsão sem <i>lead time</i>					
<b>Categoria</b>	<b>Modelos</b>	<b>Menor MAE</b>	<b>Maior MAE</b>	<b>Itens</b>	<b>% Itens</b>
Errático 672 itens Modelos de previsão: 09	Bootstrap	0,77	4.754,77	387	57,59%
	TSB	0,85	1.584,47	139	20,68%
	SBA	1,52	10.229,77	76	11,31%
	Conjugado (SBA com Bootstrap)	1,78	4.563,23	51	7,59%
	Outros	2,28	12,34	21	3,13%
Irregular 1952 itens Modelos de previsão: 11	TSB	0,02	411,24	1054	54,00%
	Bootstrap	0,26	1.346,10	361	18,49%
	SBA	0,11	308,27	314	16,09%
	Amortecimento exponencial	-	11,50	126	6,45%
	Conjugado (SBA com Bootstrap variáveis)	0,86	685,14	39	2,00%
Regular 339 itens Modelos de previsão: 09	Outros	4,99	4,99	60	3,07%
	Bootstrap	0,59	3.985,70	123	36,28%
	TSB	0,53	3.390,75	122	35,99%
	SBA	0,52	67.038,66	62	18,29%
	Amortecimento exponencial	0,66	25,80	11	3,24%
Intermitente 6300 itens Modelos de previsão: 12	Conjugado (SBA com Bootstrap variáveis)	1,22	97,48	11	3,24%
	Outros	1,52	5,07	10	2,95%
	TSB	0,01	1.1059,42	2830	44,92%
	SBA	0,02	671,93	1688	26,79%
	Amortecimento exponencial	-	196,17	1589	25,22%
	Exponencial variável	-	0,67	84	1,33%
	Outros	1,19	1,19	109	1,73%

Fonte: Elaborada pelo autor.

Os resultados mostram que os Modelos TSB e Bootstrap apresentam os melhores resultados nas Categorias Errático, Irregular e Regular, no entanto, o Bootstrap apresenta erros maiores na análise do maior MAE. Na Categoria Errático, o maior erro MAE dos Modelos TSB e Bootstrap é de 1.584,47 e 4.754,77, respectivamente. Nos itens Intermitentes, os melhores Modelos são TSB, SBA e Amortecimento Exponencial. Percebe-se a ocorrência

de modelos de previsão proposto em todas as categorias; nos itens Erráticos com maior relevância, o que indica que ajustes nos modelos podem possibilitar resultados mais adequados.

TABELA 21 – Análise do menor erro MAE de previsão com *lead time* por item


Previsão com <i>lead time</i>					
Categoria	Modelos	Menor MAE	Maior MAE	Itens	% Itens
Errático 672 itens Modelos de previsão: 8	Bootstrap	0,77	3.877,02	421	62,65%
	TSB	0,86	2.017,10	116	17,26%
	SBA	0,82	10.076,20	103	15,33%
	Conjugado (SBA com Bootstrap variáveis)	1,43	4.563,23	18	2,68%
	Outros	1,73	73,03	14	2,08%
Irregular 1.952 itens Modelos de previsão: 11	TSB	0,02	385,67	1.026	52,56%
	Bootstrap	0,54	1.346,10	388	19,88%
	SBA	0,05	320,16	307	15,73%
	Amortecimento Exponencial	0,01	36,23	143	7,33%
	Conjugado (SBA com Bootstrap variáveis)	0,49	639,74	36	1,84%
	SBA Adaptativo	0,21	248,40	29	1,49%
Regular 339 itens Modelos de previsão: 8	Outros	0,02	2,35	23	1,18%
	Bootstrap	0,59	3.972,84	124	36,58%
	TSB	0,55	1.959,89	92	27,14%
	SBA	0,52	67.038,66	85	25,07%
	Amortecimento Exponencial	0,61	42,69	17	5,01%
	Croston	1,28	792,79	7	2,06%
Intermitente 6300 itens Modelos de previsão: 12	SBA variável	0,80	74,66	7	2,06%
	SBA e Bootstrap variável	0,66	97,48	7	2,06%
	TSB	0,01	13.712,26	2.860	45,40%
	Amortecimento Exponencial	-	202,83	1.656	26,29%
	SBA	0,02	276,70	1.596	25,33%
	Exponencial variável	-	1,15	73	1,16%
	Outros	0,43	90,56	115	1,83%

Fonte: Elaborada pelo autor.

Com *lead time*, os Modelos TSB e Bootstrap continuam como os mais adequados, com menor erro MAE na maioria dos itens. A ocorrência de modelos propostos ocorre novamente em todas as categorias. Na classe Intermitente, os melhores modelos continuam sendo TBS, Amortecimento Exponencial e SBA, com valores percentuais próximos. Destaca-se o elevado número de modelos diferentes por categoria com menor resultado para o erro MAE, o que dificulta mais a gestão das peças sobressalentes. A esse cenário, soma-se o elevado número de previsões por período, conforme pode ser verificado na FIG. 10.

A cada ciclo de planejamento, é necessário definir quais itens e qual quantidade estocar de cada item, o que não é trivial devido ao elevado número de materiais com previsão por período, FIG. 13. Pelas informações anteriores, é evidente que apenas a compra e estocagem das quantidades previstas são inviáveis, devido à elevação do valor de estoque. Modelos de otimização podem auxiliar esse processo decisório da quantidade a ser comprada de cada material.

FIGURA 13 – Exemplo de quantidade de previsões por período



Fonte: Elaborada pelo autor.

O Capítulo 4 apresenta o desenvolvimento do modelo de decisão combinado com o modelo de previsão de demanda, modelo multicritério e programação biobjetivo e métodos heurísticos.

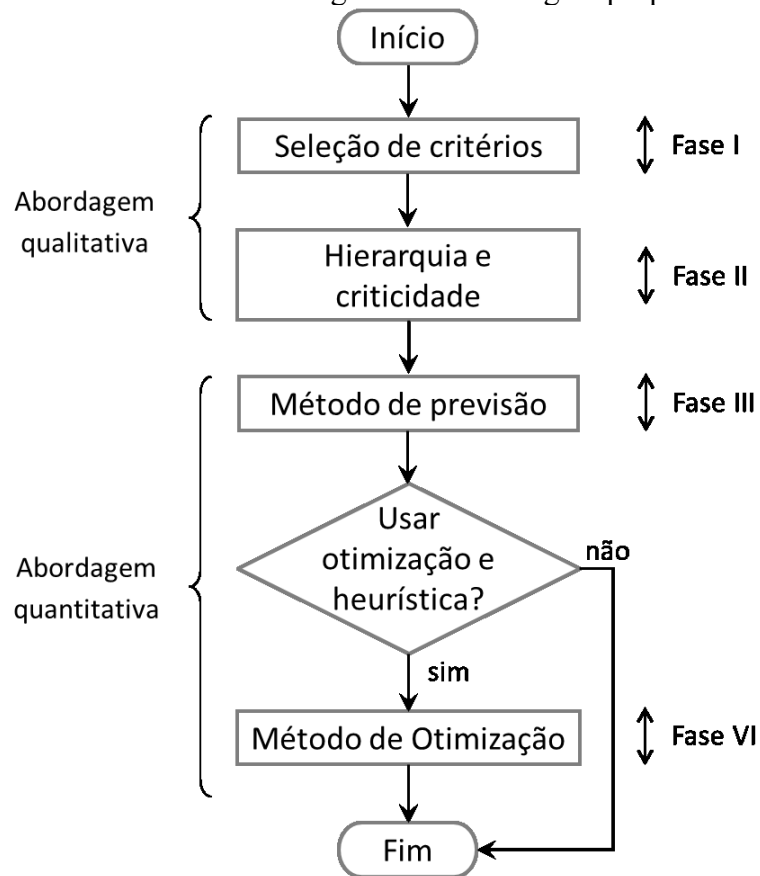
## CAPÍTULO 4

### MODELO DE DECISÃO

#### 4.1 Desenvolvimento do modelo de decisão

A fim de lidar efetivamente com um problema multicritério, foi desenvolvido uma abordagem de apoio à decisão. A abordagem proposta combina uma abordagem qualitativa (Fase I e II) com uma abordagem quantitativa (Fase III e Fase IV), conforme pode ser visto na FIG. 14.

FIGURA 14 – Fluxograma da abordagem proposta



Fonte: Elaborada pelo autor.

A Fase I define os critérios de avaliação, as faixas quantitativas de classificação no Método VED e descarta critérios inadequados, redundantes ou desnecessários, detalhado na Seção 4.2. Na Fase II, foram calculados os valores normalizados em cada nível da árvore de decisão pelo Método AHP e a realização do Método *Bottom up* para calcular a criticidade total de cada item, conforme Seção 4.3. A Fase III define os modelos de previsão a serem


executados A Fase IV define os parâmetros de execução e calibração dos modelos de otimização, Seção 4.5.

#### **4.2 Seleção dos critérios e subcritérios**

Os 56 critérios relevantes para avaliar a criticidade das peças de reposição foram coletados em trabalhos anteriores (BOTTER; FORTUIN, 2000; SURYADI, 2003; BRAGLIA; GRASSI; MONTANARI, 2004; SURYADI, 2007; BOSNJAKOVIC, 2010; MOLENAERS *et al.*, 2012; RODA *et al.*, 2014; STOLL *et al.*, 2015; HU *et al.*, 2018). Os critérios redundantes, com indisponibilidade de coleta de informações confiáveis ou impossibilidade de classificação nas faixas quantitativas do Método VED, foram descartados. Restaram 20 critérios que foram agrupados em produção, manutenção e suprimentos, baseando-se na literatura e na estrutura organizacional da empresa que disponibilizou a base de dados.

Os 20 critérios foram selecionados pelo Método Ponto de Corte (*Cut off Point*). Alguns trabalhos utilizam o Ponto de Corte em diferentes situações (TAM; TUMMALA, 2001; SURYADI, 2003; SURYADI, 2007; KUNDID; ERCEGOVAC, 2011; GALLON; YSNEL; FEUNTEUN, 2013). Para aplicar esse método, foram escolhidos, aleatoriamente, 18 especialistas da empresa em estudo das áreas de suprimentos, manutenção e produção. As entrevistas foram aplicadas individualmente para evitar influência dos julgamentos. Cada especialista atribuiu a cada critério os seguintes pesos: 1, ao considerar que o critério não é importante; 2, quando o critério é pouco importante; e 3, quando o critério é muito importante. Em seguida, calcula-se a média ponderada para cada critério, o valor do ponto de corte é obtido pela média entre o maior e o menor valor dos critérios. O resultado do ponto de corte no estudo foi de 2,3; a pontuação de cada critério é apresentada na FIG. 15. Os 14 critérios com valores acima de 2,3 foram selecionados.

FIGURA 15 – Seleção de critérios de criticidade relevantes



Fonte: Elaborada pelo autor.

Os critérios selecionados são detalhados no QUADRO 2. O setor de produção teve 7 critérios selecionados, suprimentos, 4 e manutenção, 3. Na necessidade de inclusão de um novo critério, o Método Ponto de Corte deve ser revisado e recalculado. Em caso de aplicação em outra empresa, o tomador de decisão deve reavaliar os critérios utilizados.

QUADRO 2 – Lista de critérios de criticidade

<b>Critério</b>	<b>Descrição</b>
<b>Produção</b>	
Impactos ambientais e de segurança	Impactos da segurança coletiva e danos ao meio ambiente
Material de segurança	Material de segurança para proteção de pessoas
Impacto no processo produtivo	Tempo perdido até o processo ser restabelecido
Disponibilidade do equipamento	Disponibilidade do equipamento para atendimento da produção
Perda de qualidade da produção	Redução da qualidade do produto decorrente da falha do equipamento
Criticidade da função a ser executada	Estado operacional após a falha de componentes
Processos alternativos	Possibilidade de mudança de processo sem interrupção da produção
<b>Manutenção</b>	
Prioridade do equipamento	Restrição produtiva em caso de falha do equipamento
Feito sob medida	Peça ou equipamento desenvolvido para empresa conforme projeto
Confiabilidade do material	Probabilidade de falha ou avaria da peça de reposição
<b>Suprimentos</b>	
Dificuldade de aquisição	Tempo entre solicitação de compra e a conclusão do processo de aquisição
<i>Lead time</i>	Tempo após a finalização da compra e disponibilidade na empresa
Preço	Valor de compra da peça de reposição
Número de fornecedores potenciais	Número de fornecedores que podem entregar a peça sobressalente

Fonte: Elaborado pelo autor.

Os critérios selecionados foram categorizados na escala VED, conforme QUADRO 3. A divisão de categorias foi obtida do sistema SAPTM e entrevistas com os especialistas.

QUADRO 3 – Critério e classificação VED

<b>Critérios</b>	<b>Categorias</b>		
	<b>Vital</b>	<b>Essencial</b>	<b>Desejável</b>
<b>Produção</b>			
Impactos ambientais e de segurança	Irreparável	Reparável	Sem impacto
Material de segurança	Potencial de fatalidade	Potencial de lesões graves	Potencial de lesões leves
Impacto no processo produtivo	> 50 horas paradas	≤ 50 horas paradas	Sem paradas previstas
Disponibilidade do equipamento	> 95%	≥ 90% e ≤ 95%	< 90%
Perda de qualidade da produção	> 5%	≤ 5%	Sem perda de qualidade
Criticidade da função a ser executada	Equipamento não opera	Opera com restrições	Opera normalmente
Processos alternativos	Não possui	Um processo	Mais de um processo
Manutenção			
Prioridade do equipamento	Restrição > 10%	Restrição ≤ 10%	Sem restrição produtiva
Feito sob medida	Desenho próprio	Desenho fornecedor	Item sem desenho
Confiabilidade do material	Falha imprevisível	Falha previsível	Sem necessidade previsibilidade de falha
<b>Suprimentos</b>			
Dificuldade de aquisição	Complexa > 45 dias	Difícil ≥ 15 dias e ≤ 45 dias	Fácil < 15 dias
<i>Lead time</i>	≥ 4 meses	> 1 mês e < 4 meses	≤ 1 mês
Preço	> R\$ 25.000	≥ R\$ 1.000 e ≤ R\$ 25.000	< R\$ 1.000
Número de fornecedores potenciais	1 fornecedor	> 1 e ≤ 5 fornecedores	> 5 fornecedores

Fonte: Elaborado pelo autor.

Destaca-se a dificuldade de obtenção das informações para a classificação dos materiais nas categorias VED. Dos 14 critérios, 42,86% foram obtidos diretamente dos sistemas da organização (SAPTM) e 58,14% necessitaram de dados de *softwares* proprietários e informações qualitativas e quantitativas disponíveis na empresa – em alguns casos, usou-se

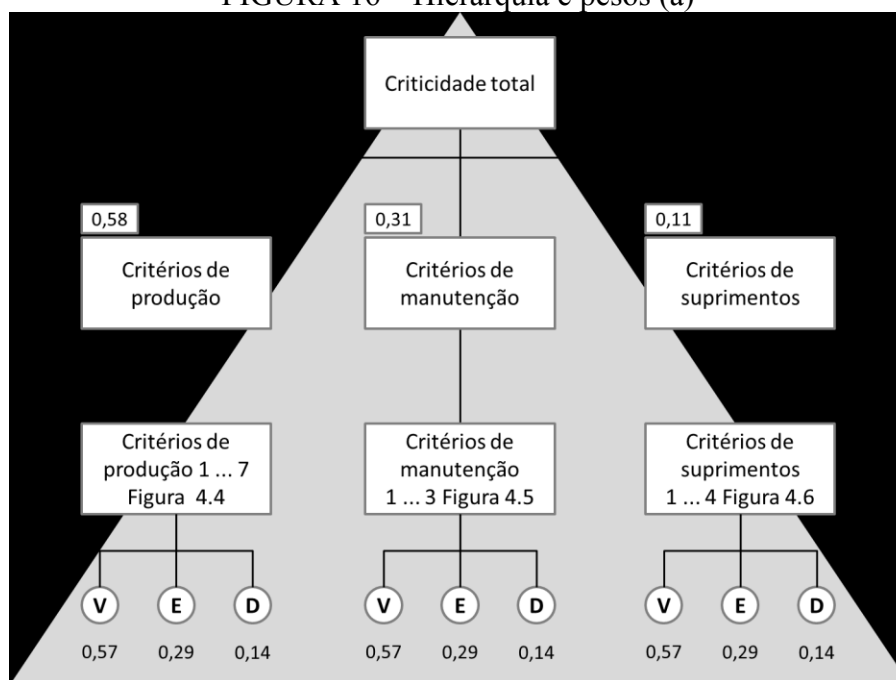


classificação manual. Alguns autores relataram dificuldades na obtenção de dados para classificação dos critérios: Roda *et al.* (2014) destacam barreiras na obtenção das informações para classificação dos dados; Zeng *et al.* (2012) relataram o ambiente altamente incerto, com informações e dados limitados; por outro lado, Stoll *et al.* (2015) selecionaram apenas critérios com obtenção direta dos sistemas automatizados da empresa.

### 4.3 Hierarquia e criticidade

Os pesos para cada critério e Categoria VED são atribuídos pela equipe de especialistas e as comparações são realizadas por meio de matrizes de julgamento, detalhadas no APÊNDICE 6. Os pesos relativos para cada elemento da matriz e os índices de consistência foram obtidos pelo *software* Super Decisions. Ink Software (2013). Foi utilizado o método de classificação com os *clusters* manutenção, produção e operação. As FIG. 16 a 19 apresentam as hierarquias e os pesos relativos utilizados na presente pesquisa.

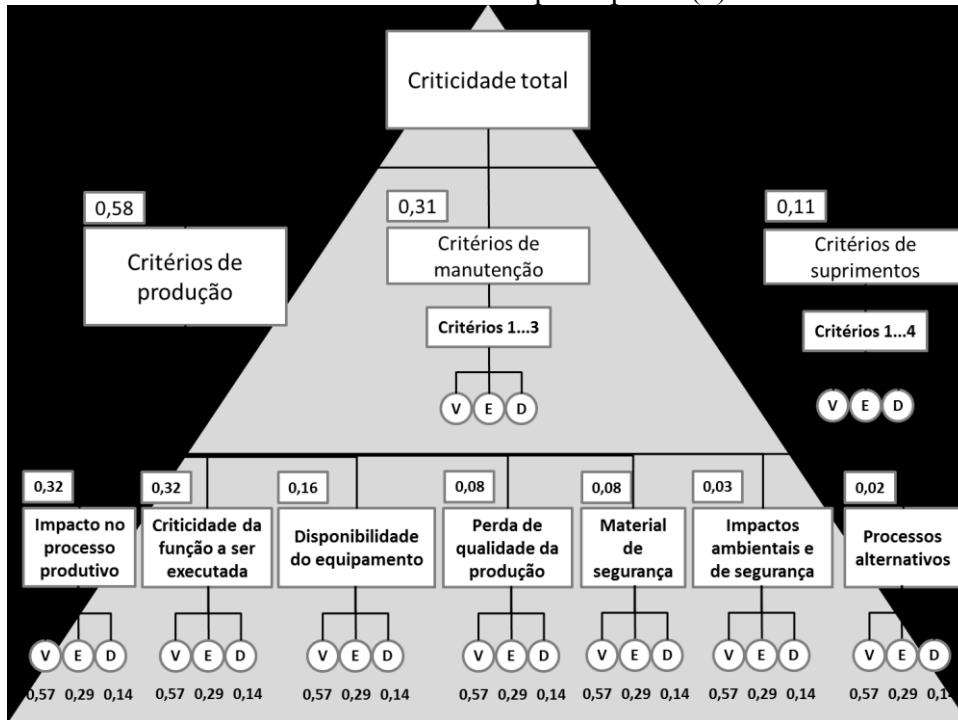
FIGURA 16 – Hierarquia e pesos (a)



Fonte: Elaborada pelo autor.

O setor de produção apresentou criticidade maior em relação à manutenção e a suprimentos, o que representa ser o setor mais relevante na avaliação de criticidade. O número de critérios de produção é o mais elevado em relação aos demais setores e considera questões ambientais e de segurança, mesmo com criticidade baixa.

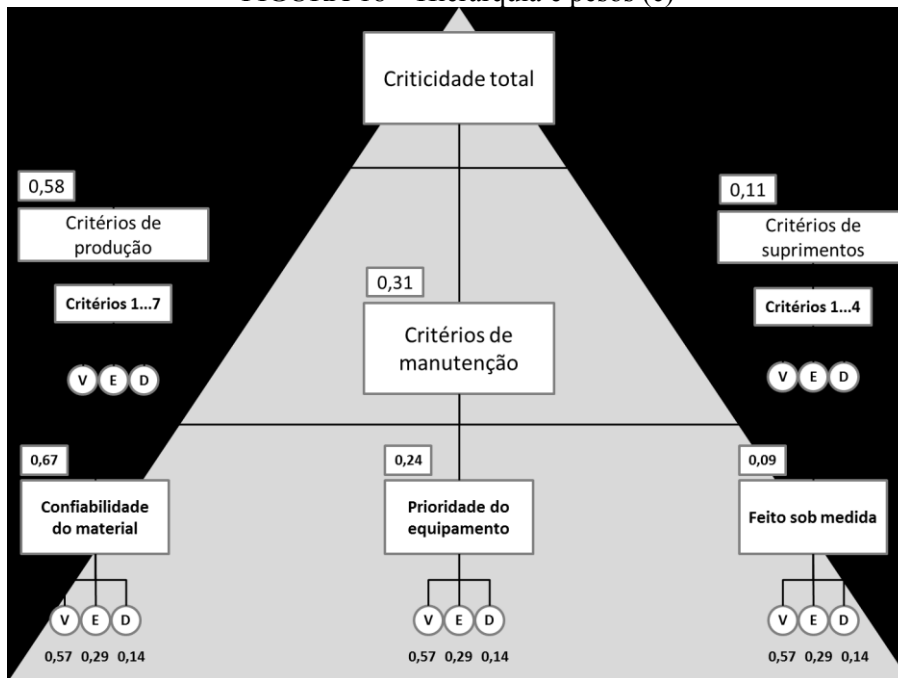
FIGURA 17 – Hierarquia e pesos (b)



Fonte: Elaborada pelo autor.

O setor de manutenção considera o critério confiabilidade do material o mais crítico, com valor superior ao dobro do segundo critério xa.

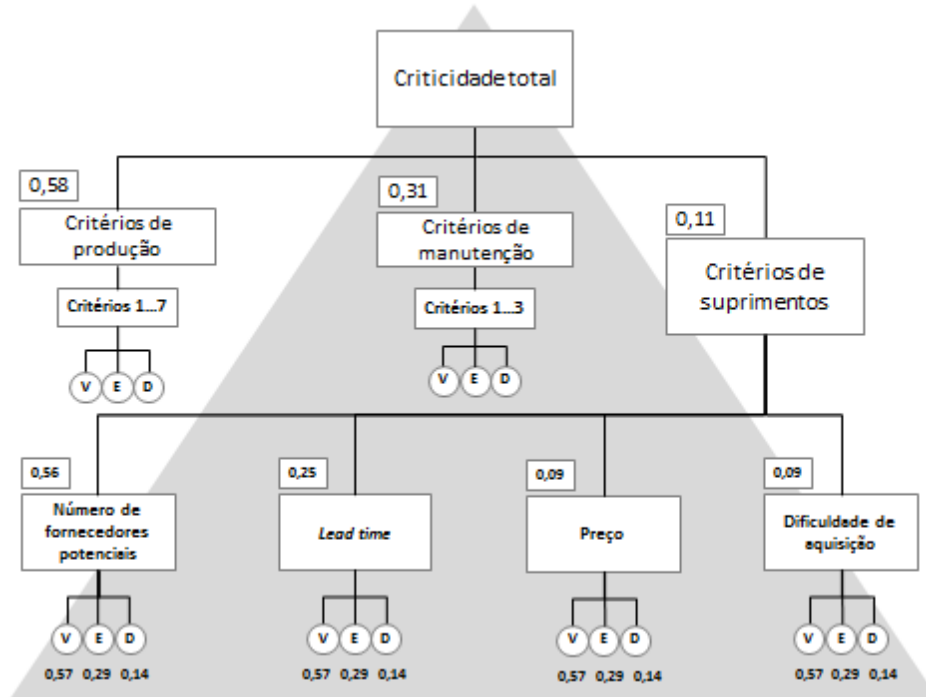
FIGURA 18 – Hierarquia e pesos (c)



Fonte: Elaborada pelo autor.

Para o setor de suprimentos, o critério mais crítico é a quantidade de fornecedores disponíveis capazes de atender às demandas organizacionais de peças sobressalentes.

FIGURA 19 – Hierarquia e pesos (d)



Fonte: Elaborada pelo autor.

O índice de consistência é adequado para valores menores que 0,1 (SAATY, 1990) e avalia a coerência dos julgamentos, ver TAB. 21. Na ocorrência de valores maiores, os julgamentos devem ser reavaliados. Todos valores de consistência encontrados foram menores que 0,1 conforme TAB. 22.

TABELA 22 – Índice de consistência

Nível de comparação	Índice de consistência
Críticidade total	0,00355
Crítérios de produção	0,03042
Crítérios de manutenção	0,00675
Crítérios de suprimentos	0,01629
Categorias VED	-

Fonte: Elaborada pelo autor.

Depois da verificação de consistência, a criticidade total de cada item foi calculada pelo Método *Botton-up*, baseado em Stoll *et al.* (2015). Nesse processo, a criticidade da Categoria  $h$ , sendo  $h$  os critérios de avaliação de abertura de cada categoria apresentados na TAB. 22;  $(P_h^{\text{total}})$  é calculada pelo  $P_h^{\text{total}} = v^h * \sum_i v^i * v^k$ , onde  $v^h$  é o peso do critério  $h$  no

segundo nível das FIG. 17 a 19;  $v^i$  é o peso do critério  $i$  no próximo nível (terceiro nível); o  $v^k$  é o peso VED da categoria em relação ao critério  $i$  no quarto nível. O  $v^k$  pode assumir valores diferentes com base na classificação do item em cada critério do terceiro nível. Finalizando, a criticidade total do item  $j$  ( $c_j$ ) é obtido pela soma da prioridade global de cada critério  $h$  do item  $j$ , assim  $c_j = \sum_h P_h^{\text{total}}$ . Por exemplo, no setor de suprimentos, um item é classificado como vital nos critérios: número potenciais de fornecedores, *lead time*, preço e dificuldade de aquisição. Considerando os pesos da Figura 16, a criticidade total é dada por  $P_h^{\text{total}} = v^h * \sum_i v^i * v^k = 0.11 * (0.56 * 0.57 + 0.25 * 0.57 + 0.09 * 0.57 + 0.09 * 0.57) = 0.062$ . Assumindo que esse item foi classificado como vital em relação aos outros critérios e que o cálculo é realizado da mesma maneira, a prioridade geral para os critérios de Produção é 0.334, e para os critérios de Manutenção é 0.177. A criticidade total do item  $j$  é dada por  $c_j = \sum_h P_h^{\text{total}} = 0.334 + 0.177 + 0.062 = 0.573$ . Assim, as classificações em todas as aberturas como vital, essencial ou desejável fornecem os limites superiores e inferiores de criticidade. A TAB. 23 apresenta os limites máximos e mínimos das criticidades de Produção, Manutenção, Suprimentos e Criticidade total.

TABELA 23 – Limites superiores e inferiores de criticidade

	Produção	Manutenção	Suprimentos	Criticidade total
<b>Limites</b>	0,082-0,334	0,043-0,177	0,015-0,062	0,140-0,573

Fonte: Elaborada pelo autor.

Percebe-se que o material com maior valor de criticidade é 0,573, e o material menos crítico tem valor de apenas 0,140. A utilização de um valor quantitativo é indispensável para que se consiga a combinação dos modelos de otimização aos métodos qualitativos. Os valores finais de criticidade foram utilizados na função objetivo do modelo matemático biobjetivo.

#### 4.4 Método de previsão

A Seção 3 apresentou detalhadamente como realizar a escolha do modelo com menor erro de previsão. Os resultados mostraram que combinar diferentes modelos de previsão é o mais adequado. A decisão de utilizar diversos modelos de previsão e em quais itens ou a utilização de um único modelo para todos os itens, deve ser realizada pelo tomador de decisão. A criticidade dos itens pode ser utilizada para auxiliar esse processo.

As quantidades previstas de cada item durante os ciclos de previsão, são utilizados como variáveis de decisão do modelo de otimização conjuntamente com os valores de criticidade dos itens. O método de otimização visa encontrar o subconjunto de itens que maximiza a criticidade estocada respeitando o valor disponibilizado no período.

Os modelos de previsão para os Modelos TSB  $\alpha = 0,1$   $\beta = 0,5$ , TAB. 4, sem *lead time* com retirada de *outliers* e TSB  $\alpha = 0,1$   $\beta = 0,8$ , TAB. 7, com *lead time* com retirada de *outliers*, foram utilizados nos testes do modelo de otimização e heurísticas.

#### 4.4 Método de otimização

O método de otimização é composto pelo modelo matemático biobjetivo e métodos heurísticos. O modelo matemático garante que o valor disponível para armazenagem de materiais no período seja respeitado. As heurísticas, detalhadas na Seção 4.5, mitigam as rupturas de estoque e auxiliam para evitar inviabilidades do modelo matemático.

O modelo matemático tem dois objetivos: (i) minimizar o valor total estocado; e (ii) maximizar a criticidade total em estoque das peças sobressalentes, destacando-se o *trade-off* entre os objetivos. Para reduzir o valor em estoque, é necessário reduzir os materiais estocados, o que acarreta a redução de criticidade total em estoque. Por outro lado, aumentar a criticidade total aumenta o capital imobilizado em estoque.

Para tratar esse problema de otimização biobjetivo, foi adotado o  $\epsilon$ -*constraint method* (método da restrição interativa). A função objetivo de minimizar o valor total estocado foi utilizada como restrição, e a de maximização da criticidade como função objetivo. Dessa forma, a cada iteração do modelo, é possível identificar os itens estocados e o valor imobilizado.

O modelo é mostrado a seguir nas funções 4.1 a 4.6, onde  $n$  é o conjunto de itens;  $C$  é um subconjunto de  $n$  dos itens críticos, devendo-se evitar estoque nulo;  $c_j$  representa criticidade total proveniente do Método AHP e do *Botton-up*;  $r_j$  é o valor imobilizado em reais para estocagem de cada item;  $x_j$  é a variável inteira de decisão;  $s_j$  representa a quantidade prevista no período;  $l_j$  é a quantidade mínima dos itens críticos que devem ser mantidos em estoque,  $m_j$  é a diferença entre saldo do item e ponto de reabastecimento;  $Disp^t$  representa o valor em reais disponível no período de previsão  $t$  e  $\epsilon_k$  é o valor limite de cada iteração  $k$  do modelo multiobjetivo. O valor de  $k$  é baseado na quantidade de pontos desejáveis na Curva Pareto Ótima.

$$\max Z'_k = \sum_{j=1}^n c_j x_j \quad (4.1)$$

s.a.

$$\sum_{j=1}^n r_j x_j \leq \varepsilon_k \quad (4.2)$$

$$\varepsilon_k \leq Disp^t \quad (4.3)$$

$$x_j \leq s_j \quad (4.4)$$

$$x_j \geq l_j \quad \forall j \in C; C \text{ conjunto de itens críticos} \quad (4.5)$$

$$x_j, s_j, m_j \in \text{inteiros} \quad (4.6)$$

A função objetivo 4.1 maximiza a criticidade total dos itens estocados, enquanto a 4.2 é a restrição iterativa usada para transformar um problema biobjetivo em um mono-objetivo, a restrição 4.3 define o limite financeiro disponível no período de previsão, a restrição 4.4 define a quantidade máxima que pode ser estocada de cada item prevista pelo modelo de previsão, a restrição 4.5 garante a quantidade mínima a ser mantida em estoque de determinado item crítico, a restrição 4.6 define o conjunto das variáveis inteiras. As equações 4.3 e 4.4 são decorrentes da função objetivo de minimização do valor estocado. Ao utilizar a restrição 4.5 deve utilizar a Heurística 1, Seção 4.5, que impede a inviabilidade quando  $s_j < l_j$ .

A quantidade de iterações a cada otimização é variável e define a quantidade de pontos na Curva Pareto Ótima. O valor disponibilizado a cada iteração é incrementado em quantidades iguais e permite analisar as implicações das variações na quantidade de itens estocados na criticidade total. A execução do modelo com valor único para  $\varepsilon_k$  a cada previsão de demanda avalia quais itens estocar, em quais quantidades e a criticidade total dessa alternativa. A quantidade de iterações gera aumento do tempo computacional de execução do modelo de forma linear. O tempo de execução do modelo é inferior a 1 minuto por iteração por período mensal de previsão.

O cálculo da disponibilidade de valor para armazenamento de material no período  $t$ , denominado  $Disp^t$ ; é obtido pela equação 4.7. O valor  $Disp^t$  é variável a cada período mensal de análise, conforme equação 4.7. O  $V_{max}$  representa o valor máximo que a empresa disponibiliza para estocagem de materiais,  $VE_{t-1}$  é o valor de estoque final no período anterior e  $D_{média}$  representa o consumo médio até o período anterior.

$$Disp^t = V_{max} - (VE_{t-1} + D_{média}) \quad (4.7)$$

Os modelos de previsão e de otimização são vinculados da seguinte forma: o modelo de previsão gera um vetor linha com a quantidade prevista de cada item  $s_j$ , que é recalculado a

cada novo período de previsão. A otimização ajusta esses valores e gera um novo vetor de previsão que é utilizado no ciclo de planejamento. O modelo de previsão é previamente definido e pode ser alterado ao longo das previsões mensais.

O submodelo itens críticos, HEURÍSTICA 1, pode ser aplicado no caso de poucos recursos para priorização dos itens críticos e em períodos nos quais não há disponibilidade de recursos para armazenagem,  $Disp^t \leq 0$ , conforme apresentado na Seção 4.5. A HEURÍSTICA 2 foi proposta com a análise do saldo final de estoque a cada período de otimização por item, nos casos de estoques negativos. Nesses casos, o módulo do saldo negativo foi somado à previsão do próximo período.

#### **4.5 Método Heurístico**

O desenvolvimento de heurísticas permite tratar as situações específicas do modelo. A HEURÍSTICA 1 garante que os itens críticos tenham quantidades repostas com prioridade sem alteração no valor previsto. Na impossibilidade de estocagem de todos os itens críticos até a quantidade mínima por falta de recursos, executa-se o submodelo de itens críticos (resModCrit), HEURÍSTICA 1, que executa a otimização apenas para itens críticos, em que  $e_j$  representa o estoque do item no período  $t$ ;  $q_j$  é a quantidade mínima; e  $total$  representa o valor total de recursos necessário para estocar os itens críticos.

## HEURÍSTICA 1 – Itens críticos

---

Entrada: Base de dados

```
1  para todo  $t \in T$  faça
2      se  $Disp^t > 0$  então
3           $s \leftarrow$  previsão ( $t$ );
4          total  $\leftarrow$  0;
5          resModCrit  $\leftarrow$  falso;
6          para todo  $j \in J$  faça
7              se  $s_j = 0$  então
8                   $l_j \leftarrow s_j$ 
9              se não se  $s_j > 0$  então
10                 se  $j$  é crítico então
11                     se  $e_j < q_j$  então
12                         se  $q_j - e_j < s_j$  então
13                              $l_j \leftarrow q_j - e_j$ ;
14                             total  $\leftarrow$  total +  $l_j r_j$ ;
15                             se total  $\geq Disp^t$  então
16                                 resModCrit  $\leftarrow$  verdadeiro;
17                             fim
18                         se não
19                              $l_j \leftarrow s_j$ ;
20                             fim
21                             se não se  $e_j \geq q_j$  então
22                                  $l_j \leftarrow 0$ ;
23                                 fim
24                             fim
25                             fim
26                         fim
27                     fim
28                 se resModCrit então
29                     Modelo Crítico ( $t, J, l$ );
30                 fim
31                 Resolve o modelo considerando o saldo restante, após Modelo Crítico;
32 fim
```

### Modelo Crítico ( $t, J, l$ )

Entrada: (período  $t$ , conjunto de itens  $J$ , limites  $l$ )

```
1   $sol_{sub} \leftarrow$  resolve submodelo dos itens críticos;
2  se  $Disp^t - f(sol_{sub}) > 0$  então
3      para todo  $j \in J: j$  crítico faça
4           $l_j \leftarrow x_j(sol_{sub})$ 
5      fim
6  fim
```

---

Fonte: Elaborada pelo autor.

A HEURÍSTICA 1 recebe a base de dados e checa se existe saldo de recursos financeiros; caso positivo, realiza-se a previsão de demanda e se reinicializa os parâmetros, o



que faz todos os itens sem previsão receberem quantidade igual a zero. Verifica-se se algum item com previsão de demanda é crítico, checa-se o item se encontra com estoque abaixo da quantidade mínima e, em caso positivo, se a diferença entre estoque atual e quantidade mínima for menor que a previsão, faz o item receber esse valor. No caso de a disponibilidade de recursos for inferior ao custo total dos itens críticos, deve-se otimizar quais dos itens críticos devem ser comprados. Após a otimização do submodelo, a quantidade mínima dos itens críticos recebem os valores ótimos do submodelo de otimização. Novamente verifica-se se ainda existe disponibilidade de recursos; em caso positivo, é executado o modelo completo, caso seja consumido todo recurso, o processo é finalizado.

Os modelos de previsão podem demorar a responder às variações dos padrões de demanda e gerar previsões com erros significativos. Nesses casos, pode ocorrer excesso ou ruptura de estoque. Com a otimização, o excesso de valor de estoque é limitado, mas o modelo não reage às rupturas de estoque e aguarda a adequação do modelo de previsão ao novo padrão de demanda. Em uma situação real de ruptura, falta de algum material, a ação imediata é a solicitação da quantidade demandada como ação corretiva. A HEURÍSTICA 2 auxilia os modelos de previsão nessa correção, sendo  $d_j$  a demanda do item no período.

### HEURÍSTICA 2 – Tratamento de rupturas

Entrada: Base de dados

```

1  para todo  $t \in T$  faça
2       $e_j = e_{j-1} + s_j - d_j$ 
3      se  $Disp^t > 0$  então
4           $s \leftarrow$  previsão( $t$ );
5          resModCrit  $\leftarrow$  falso;
6          para todo  $j \in J$  faça
7              se  $e_j < 0$  então
8                   $s_j \leftarrow s_j + |e_j|$ 
9              fim
10         fim
11         resModCrit  $\leftarrow$  verdadeiro;
12 fim

```

---

Fonte: Elaborada pelo autor.

A HEURÍSTICA 2 verifica em quais itens ocorre ruptura de estoque e soma o módulo dessa quantidade ao valor previsto. O novo valor substitui o valor previsto anteriormente e é otimizado, assim, há a possibilidade de reduzir a ruptura desse item, não havendo a necessidade de inclusão dessa quantidade em estoque, já que o valor passou pelo modelo de otimização.

Assim o Método de Otimização 1 se refere a utilização do modelo matemático biobjetivo e heurística 1, e o Método de Otimização 2 refere-se a utilização do modelo matemático biobjetivo e heurística 2.

#### 4.6 Análise dos modelos de otimização

Os modelos de otimização foram executados para os Modelos TSB  $\alpha = 0,1$   $\beta = 0,5$ , TAB. 4, sem *lead time* com retirada de *outliers* e TSB  $\alpha = 0,1$   $\beta = 0,8$ , TAB. 7, com *lead time* com retirada de *outliers*, durante todo o período. Esses modelos foram escolhidos por apresentarem menor erro MAE e baixa influência de *outliers* e as melhorias obtidas com os modelos propostos terem ocorrido pontualmente. Os resultados das otimizações são analisados nas mesmas aberturas dos modelos de previsão.

Para utilizar o modelo de otimização, foi definido o valor utilizado na variável  $V_{max}$  para cálculo do  $Disp^t$ . Esse valor foi estimado pelo estoque inicial em R\$ 42 milhões e valor máximo de consumo R\$ 67 milhões, ou seja, atender ao período com maior demanda e manter o estoque inicial, o que representa R\$ 109 milhões, corrigido pelo erro médio do modelo de previsão no total de R\$ 131 milhões.

Os resultados do método de otimização serão comparados pela base Geral entre os modelos sem *outliers*, Otimização 1 e Otimização 2. Os indicadores taxa de cobertura, nível médio de estoque e taxa de ruptura são comparados.

De acordo com a TAB. 24, percebe-se a manutenção da mediana do erro MAE após a Otimização 1, com valor em 0,206. Esse resultado é devido a pequenas variações nas quantidades previstas corrigidas pela otimização e pelo fato de não correção dos casos de ruptura. Na Otimização 2, a mediana do erro MAE reduziu para 0,198, decorrente da alteração de valores em caso de ruptura de estoque.

TABELA 24 – Análise das otimizações

Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.697	7.697	7.697
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$
		$\beta = 0,5$	$\beta = 0,5$	$\beta = 0,5$
Erro Médio Absoluto – MAE	Mínimo	-	-	-
	Máximo	3,86	3,86	3,85
	1º quartil	0,073	0,073	0,073
	Mediana	0,206	0,206	0,198
	3º quartil	0,618	0,618	0,594
	Média	0,532	0,531	0,522
	Variância (n-1)	0,58	0,58	0,58
Desvio Padrão (n-1)		0,760	0,760	0,761

Fonte: Elaborada pelo autor.

A TAB. 25 reforça que a utilização da Otimização 1 gerou pouca variação nos resultados, percebe-se que a mediana da taxa de cobertura se manteve em 0,400, com redução da média de 0,469 para 0,466. A Otimização 2 apresentou melhora significativa nesse indicador, com elevação da taxa de cobertura para 0,500. A TAB. 26 apresenta o indicador nível médio de estoque.

TABELA 25 – Análise das otimizações pela taxa de cobertura

Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.697	7.697	7.697
Indicador	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$
		$\beta = 0,5$	$\beta = 0,5$	$\beta = 0,5$
Taxa de cobertura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	-	-	-
	Mediana	0,400	0,400	0,500
	3º quartil	1,000	1,000	1,000
	Média	0,469	0,466	0,515
	Variância (n-1)	0,17	0,17	0,18
Desvio Padrão (n-1)		0,407	0,407	0,426

Fonte: Elaborada pelo autor.

De acordo com a TAB. 26, o nível médio de estoque se manteve estável com a utilização da Otimização 1 e teve leve redução com a Otimização 2, o que é desejável. Com a Otimização 2, foi possível reduzir a mediana do erro MAE, melhorar a taxa de cobertura, TAB. 25, com redução do nível de estoque. Por fim, a TAB. 27 apresenta o indicador taxa de ruptura.

TABELA 26 – Análise das otimizações pelo nível médio de estoque

<b>Análise consolidada – sem outliers</b>				
<b>Base de dados</b>		<b>Geral</b>	<b>Otimização 1</b>	<b>Otimização 2</b>
Quantidade de itens		7.697	7.697	7.697
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>
Nível médio de estoque	Mínimo	-239,489	-239,489	-241,063
	Máximo	1.000,48	1.000,48	1.000,00
	1º quartil	-0,651	-0,651	-1,646
	Mediana	1,000	1,000	0,969
	3º quartil	2,652	2,652	1,990
	Média	0,023	0,022	-0,588
	Variância (n-1)	500,72	500,72	501,12
Desvio Padrão (n-1)		22,377	22,376	22,386

Fonte: Elaborada pelo autor.

Pelos resultados da TAB. 27, a Otimização 1 manteve os resultados muito próximos ao modelo de referência TSB  $\alpha = 0,1$   $\beta = 0,5$ , e a Otimização 2 apresentou redução na mediana da taxa de ruptura de 0,042 para 0,031. De forma geral, percebe-se que o fato do Modelo TSB  $\alpha = 0,1$   $\beta = 0,5$  sem *outliers* se mostrar com erro pequeno é devido às poucas alterações nos resultados com utilização da Otimização 1. A Otimização 2 apresentou melhorias relevantes nas análises com redução do erro MAE e melhora em todos os demais indicadores.

TABELA 27 – Análise das otimizações pela taxa de ruptura

<b>Análise consolidada – sem outliers</b>				
<b>Base de dados</b>		<b>Geral</b>	<b>Otimização 1</b>	<b>Otimização 2</b>
Quantidade de itens		7.697	7.697	7.697
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,5</math></b>
Taxa de ruptura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	-	-	-
	Mediana	0,042	0,042	0,031
	3º quartil	0,510	0,510	0,573
	Média	0,262	0,263	0,276
	Variância (n-1)	0,12	0,12	0,12
Desvio Padrão (n-1)		0,339	0,340	0,347

Fonte: Elaborada pelo autor.

Os modelos de Otimização 1 e Otimização 2 foram executados da mesma forma para avaliar os resultados com *lead time*. A TAB. 28 traz os dados do erro MAE.

TABELA 28 – Análise das otimizações com *lead time*

Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.708	7.708	7.708
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$
		$\beta = 0,8$	$\beta = 0,5$	$\beta = 0,5$
Erro Médio Absoluto – MAE	Mínimo	-	-	-
	Máximo	4,07	4,07	4,07
	1º quartil	0,073	0,073	0,062
	Mediana	0,203	0,203	0,167
	3º quartil	0,629	0,629	0,448
	Média	0,549	0,548	0,403
	Variância (n-1)	0,64	0,64	0,35
Desvio Padrão (n-1)		0,800	0,800	0,592

Fonte: Elaborada pelo autor.

A TAB. 28 mostra que o modelo de Otimização 1 e de referência com *lead time* sem outliers TSB  $\alpha = 0,1$  e  $\beta = 0,8$  apresentam valores próximos para mediana do erro MAE. A Otimização 2 reduz a mediana do erro MAE de 0,203 para 0,167. A TAB. 29 traz os valores do indicador taxa de cobertura.

TABELA 29 – Análise das otimizações com *lead time* pela taxa de cobertura

Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.708	7.708	7.708
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$
		$\beta = 0,8$	$\beta = 0,5$	$\beta = 0,5$
Taxa de cobertura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	-	-	0,277
	Mediana	0,375	0,333	0,800
	3º quartil	1,000	0,909	1,000
	Média	0,457	0,443	0,640
	Variância (n-1)	0,16	0,15	0,15
Desvio Padrão (n-1)		0,401	0,394	0,392

Fonte: Elaborada pelo autor.

O modelo de Otimização 1 apresentou redução perceptível na taxa de cobertura, mesmo com variação pequena na mediana do erro MAE, conforme a TAB. 29. A Otimização 2 elevou de forma expressiva o valor do indicador de 0,375 no modelo de referência TSB  $\alpha = 0,1$  e  $\beta = 0,8$  para 0,800, mesmo com a redução do erro MAE, TAB. 28. A TAB. 30 traz os valores do indicador nível de estoque.

TABELA 30 – Análise das otimizações com *lead time* pelo nível médio de estoque

Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.708	7.708	7.708
Erro	Estatísticas	TSB $\alpha = 0,1$ $\beta = 0,8$	TSB $\alpha = 0,1$ $\beta = 0,5$	TSB $\alpha = 0,1$ $\beta = 0,5$
Nível médio de estoque	Mínimo	-239,236	-239,234	-41,229
	Máximo	1.000,00	1.000,00	1.000,00
	1º quartil	-0,906	-0,907	0,635
	Mediana	0,974	0,974	1,542
	3º quartil	2,620	2,618	5,154
	Média	-0,256	-0,257	5,819
	Variância (n-1)	525,08	525,08	382,80
Desvio Padrão (n-1)		22,915	22,915	19,565

Fonte: Elaborada pelo autor.

Na comparação entre o modelo de referência TSB  $\alpha = 0,1$  e  $\beta = 0,8$  e utilização da Otimização 1, percebe-se que ocorrem pequenas variações, conforme a TAB. 30. A Otimização 2 elevou o nível médio de estoque para 1,542, o que justifica o bom resultado da taxa de cobertura, TAB. 29. Por fim, a TAB. 31 mostra os valores das taxas de ruptura.

TABELA 31 – Análise das otimizações com *lead time* pela taxa de ruptura

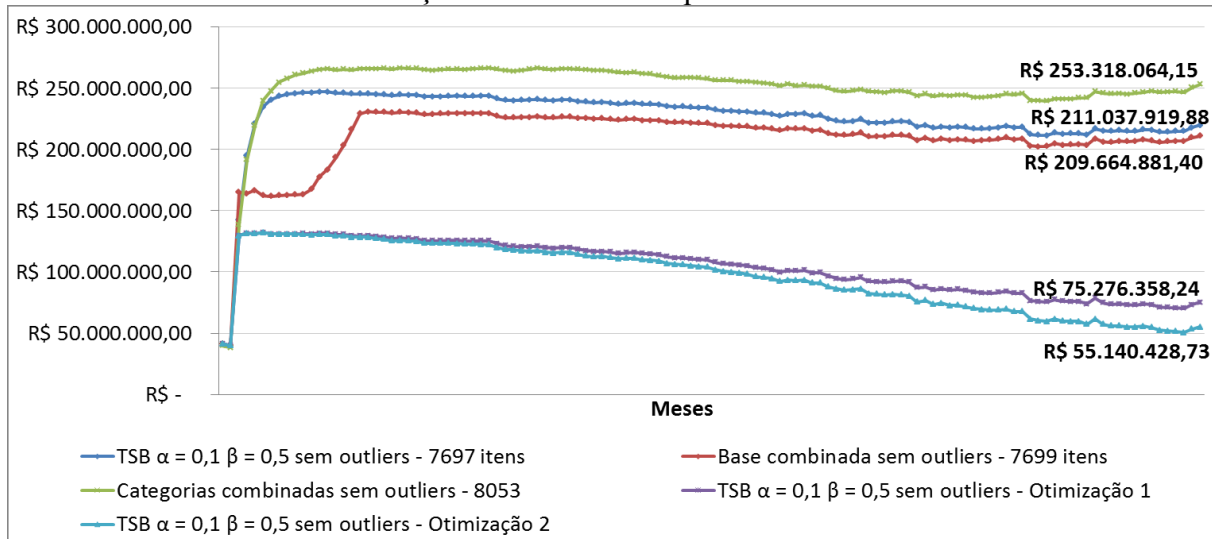
Análise consolidada – sem outliers				
Base de dados		Geral	Otimização 1	Otimização 2
Quantidade de itens		7.708	7.708	7.708
Erro	Estatísticas	TSB $\alpha = 0,1$ $\beta = 0,8$	TSB $\alpha = 0,1$ $\beta = 0,5$	TSB $\alpha = 0,1$ $\beta = 0,5$
Taxa de ruptura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	-	-	-
	Mediana	0,073	0,083	0,010
	3º quartil	0,531	0,531	0,240
	Média	0,275	0,277	0,162
	Variância (n-1)	0,11	0,11	0,07
Desvio Padrão (n-1)		0,337	0,336	0,262

Fonte: Elaborada pelo autor.

Os resultados da TAB. 31 mostram aumento da mediana da taxa de ruptura para 0,083 com a utilização da Otimização 1, se comparado ao valor do modelo de referência TSB  $\alpha = 0,1$  e  $\beta = 0,8$  de 0,073. Na análise da Otimização 2, percebe-se redução significativa da taxa de ruptura para 0,10. A taxa de ruptura alinha os resultados anteriores decorrentes da utilização da Otimização 2. De forma geral, ocorrem ganhos com os modelos propostos de otimização. A Otimização 2 se mostrou muito satisfatória, conseguindo redução de erros de previsão, aumento da taxa de cobertura e redução dos níveis de estoque e taxa de ruptura.

A heurística submodelo itens críticos foi necessária apenas duas vezes, ou seja, os recursos disponíveis eram superiores às quantidades previstas na maioria dos casos. Os resultados com e sem sua utilização sofreram variações mínimas decorrente do volume de dados analisados. O gráfico de evolução do valor de estoque com utilização da Otimização 1 e Otimização 2 sem *lead time* e sem *outliers* são apresentados na FIG. 20.


FIGURA 20 – Evolução do valor de estoque sem *lead time* sem *outliers*



Fonte: Elaborada pelo autor.

O menor valor de estoque final com a retirada de *outliers* e combinação de modelos foi de R\$ 209 milhões na base Geral, com 7.699 itens, TAB. 4. O uso da otimização ou da heurística apresentam valores menores. A otimização reduziu o valor final de estoque para R\$ 75 milhões e as heurísticas para R\$ 55 milhões. Assim, a utilização da otimização e da heurística auxiliam a tomada de decisão durante os ciclos de planejamento, mantendo o valor de estoque próximos ao valor inicial. A FIG. 21 apresenta o gráfico de evolução do valor de estoque com utilização de otimização e heurística com *lead time* sem *outliers*.

FIGURA 21 – Evolução do valor de estoque com *lead time* sem outliers



Fonte:Elaborada pelo autor.

O menor valor de estoque final com a retirada de *outliers* e combinação de modelos foi de R\$ 245 milhões na base Geral Combinada, com 7.700 itens, TAB. 7. A otimização reduziu o valor final de estoque para R\$ 86 milhões e as heurísticas para R\$ 135 milhões. Assim, a otimização garante que o valor limite para armazenamento de materiais seja respeitado. As heurísticas permitem resposta rápida para as falhas dos modelos de previsão na ocorrência de rupturas, melhorando os resultados da otimização. Em ambos os casos, os itens críticos são priorizados na armazenagem.

A última análise do modelo de otimização apresenta a Curva Pareto Ótima na avaliação de diversos cenários durante o ciclo mensal de planejamento, permitindo ao tomador de decisão escolher valores inferiores de  $Disp^t$  no período, admitindo reserva de recursos, caso seja necessário.

O modelo biobjetivo apresenta diversos cenários de forma iterativa limitados por  $\epsilon_k$  sem ultrapassar o valor máximo disponível no período, sendo possível analisar a criticidade, quantidades de itens e valor imobilizado. O modelo biobjetivo foi executado, em um mês, escolhido de forma aleatória, para obtenção de 100 pontos na Curva Pareto Ótima, com utilização das previsões do Modelo TSB  $\alpha = 0,1$  e  $\beta = 0,8$  com *lead time* sem outliers.

A TAB. 32 apresenta um resumo de 10 pontos dos valores da Curva Pareto Ótima, dados completos no APÊNDICE 7. O valor disponibilizado foi acrescido igualmente para inclusão de itens a cada iteração. O número de itens estocados apresenta pouca variação em boa parte das iterações, o que mostra a combinação de diferentes quantidades de itens



diversos com aumento da criticidade e valor estocado. A quantidade de itens aumenta com uma proporção similar à criticidade.


TABELA 32 – Dados da Curva Pareto Ótima

Iteração	Criticidade	Criticidade (%)	Valor de estoque (R\$)	Valor de estoque (%)	Itens	Itens (%)	Quantidade itens	Quantidade itens (%)
1	-	-	R\$	-	-	-	-	-
10	5.286,77	10,12%	R\$ 2.597.330,00	9,09%	337	36,24%	36.516	9,85%
20	10.898,30	20,87%	R\$ 5.483.250,00	19,19%	338	36,34%	76.598	20,66%
30	16.509,80	31,62%	R\$ 8.369.170,00	29,29%	336	36,13%	116.680	31,46%
40	22.121,30	42,36%	R\$ 11.255.100,00	39,39%	336	36,13%	156.763	42,27%
50	27.732,80	53,11%	R\$ 14.141.000,00	49,49%	337	36,24%	196.845	53,08%
60	33.344,30	63,85%	R\$ 17.026.900,00	59,60%	338	36,34%	236.927	63,89%
70	38.955,80	74,60%	R\$ 19.912.800,00	69,70%	338	36,34%	277.010	74,70%
80	44.567,30	85,35%	R\$ 22.798.800,00	79,80%	338	36,34%	317.092	85,51%
90	50.178,90	96,09%	R\$ 25.684.700,00	89,90%	337	36,24%	357.174	96,32%
100	52.219,10	100,00%	R\$ 28.570.600,00	100,00%	930	0,25%	370.831	100,00%

Fonte: Elaborada pelo autor.

A criticidade apresenta uma variação no crescimento apenas nas iterações finais, representada pela inclusão de itens com menor criticidade. Os itens estocados são incrementados de forma significativa no final das iterações, o que reforça a baixa criticidade desses materiais. A FIG. 19 apresenta graficamente esses resultados.


FIGURA 22 – Curva Pareto Ótima



Fonte: Elaborada pelo autor.

Ao analisar a evolução do número de itens, percebem-se que em diversas iterações esse valor fica estável. Esse fato reforça que a quantidade de cada item a ser estocado gera diversas combinações com pouca variação no número de diferentes itens estocados. Em um processo normal de análise, o tomador de decisão não conseguiria visualizar esse cenário. Após a iteração 91, nota-se que o número de itens estocados cresce rapidamente e que o aumento na criticidade permanece estável.

FIGURA 23 – Curva Pareto Ótima



A visualização da inclusão de itens com menor valor após a iteração 91, fica evidente com a queda do valor de estoque por item estocado. Na iteração 65 temos uma elevação mais significativa. Ao final temos a tendência de manutenção dos valores mesmo com a inclusão de uma quantidade maior de itens. Neste cenário o tomador de decisão visualiza o valor imobilizado por item estocado e permite simular cenários definindo a quantidade desejada de itens específicos.

## CAPÍTULO 5

### CONSIDERAÇÕES FINAIS

#### 5.1 Resultados e conclusões

Nesta tese, o planejamento de peças sobressalentes foi abordado. Foram analisados modelos de previsão da literatura e propostos modelos conjugados, que foram analisados estatisticamente e por indicadores. A principal contribuição teórica deste trabalho é combinar métodos qualitativos e quantitativos no gerenciamento de peças sobressalentes. Apresenta-se um método para apoio à decisão nos ciclos mensais de planejamento que utiliza modelo multicritério, modelos de previsão, otimização e heurística. Foi utilizada uma base de dados reais, os modelos de previsão foram executados 380 vezes, realizou-se 6.460 análises estatísticas, as otimizações foram executadas 186 vezes.

Foram propostos modelos de previsão baseados na conjugação de modelos da literatura e analisados na base completa, combinada, com e sem retirada de *outliers* e *lead time*. Percebe-se que a execução de um único modelo de previsão para todas as peças sobressalentes é um equívoco e que a combinação de modelos de previsão apresenta resultados melhores, de forma geral. Nota-se também que alguns itens não são aderentes a nenhum modelo de previsão e acarretam em substancial aumento do valor de estoque sem impedir a ruptura. Entre os modelos propostos ocorreram melhoras principalmente na categoria de itens Erráticos. Os modelos propostos conseguiram melhor desempenho em todas as categorias, mas em parcela pequena de itens. Vincula-se previsão de demanda e otimização por meio do modelo de decisão com método multicritério ainda não encontrado na literatura.

O modelo de decisão composto de quatro fases auxilia a tomada de decisão no gerenciamento de peças sobressalentes. O modelo preenche lacunas existentes na literatura, como a vinculação de modelos de previsão e otimização, quais peças estocar e quais quantidades, e utiliza dados empíricos, combinando metodologias qualitativas (Fases I e II) e quantitativas (Fases III e IV). Acredita-se que o modelo proposto pode ser utilizado no suporte para a decisão em empresas do ramo mineral e adaptado a outros setores industriais.

A Fase I apresenta uma seleção de critérios para a análise de peças sobressalentes em empresas de mineração, testadas com dados empíricos e validadas por especialistas. Contribui também para a eliminação de subjetividade na seleção de critérios e na classificação VED, reduzindo incertezas e o empirismo na tomada de decisões.

A Fase II permite a visualização da importância relativa de cada critério e setor por meio da representação hierárquica desenvolvida com a AHP. Mais especificamente, cada departamento pode usar a criticidade relativa do departamento ou apenas alguns critérios utilizados para suportar decisões qualitativas. O processo *Bottom up* permite quantificar os critérios qualitativos e obter um valor de criticidade para avaliar as peças sobressalentes. Ao final, tem-se valores limites de classificação para as escalas VED, por setor e criticidades individuais que servem de parâmetros ao modelo biobjetivo.

A Fase III representa o modelo de previsão, que gera valores para serem alimentados como variáveis de decisão no modelo de otimização. Observa-se que o melhor é realizar previsões com modelos parametrizados por grupo de itens e não necessariamente por categorias, conforme as TAB. 20 e 21, em que os mesmos modelos de previsão aparecem como de menor erro MAE em diferentes categorias. Mostra-se com uma análise individual por item que os erros são reduzidos de forma significativa com essa abordagem. No entanto, ficou claro que a redução dos erros de previsão gera uma maior exposição a rupturas e maior tempo de resposta à variação do comportamento da demanda. A vinculação do modelo de previsão com as criticidades é realizada na função objetivo do modelo de otimização da Fase IV.

A Fase IV fornece uma abordagem sistemática para análise do *trade-off* entre criticidade de peças de reposição, valor disponível para estocagem, quais peças estocar com esse recurso e em quais quantidades. Essa fase permite análise de sensibilidade e visualização gráfica das variáveis de decisão no ciclo de planejamento. O modelo biobjetivo, que utiliza a criticidade das Fases I e II e as quantidades previstas da Fase III, permite um controle do valor de estoque mais adequado. A HEURÍSTICA 1 permite que as quantidades mínimas de itens específicos sejam respeitadas, e a HEURÍSTICA 2 atua na minimização de rupturas. Assim, a Otimização 1 e a Otimização 2 permitem melhor controle dos valores de estoque.

Por fim, a abordagem pode ser aplicada com a combinação de fases ou com uso de fases separadas. Pode-se definir apenas critérios de análise para um caso específico (Fase I), calcular os pesos e criticidades parciais (Fases I e II), utilizar apenas os métodos de análise dos modelos de previsão (Fase III), ou apenas a execução da Curva Pareto Ótima ou otimização (Fase IV).

A abordagem é particularmente capaz de auxiliar os tomadores de decisão e pode ser replicada ou adaptada a outros setores industriais. Destaca-se ser necessário a avaliação crítica

dos julgamentos e critérios utilizados. Este trabalho contribui com a tomada de decisão no gerenciamento de peças sobressalentes, em especial no setor mineral.

## 5.2 Implicações gerenciais

As decisões referentes às peças sobressalentes na indústria mineral enfrentam questões práticas. Este estudo desenvolveu uma metodologia sistemática para auxiliar o processo decisório em questões táticas e estratégicas. Acredita-se que a abordagem, tendo sido desenvolvida no contexto da mineração de ferro brasileira, pode ser estendida para apoiar decisões em outros setores minerais e industriais no Brasil e em outras regiões.

As implicações gerenciais da Fase I criam uma referência de critérios que podem ser utilizados na análise de peças sobressalentes em mineradoras de ferro, seja em fase de projeto, seja em plantas já instaladas. Admitem, também, uma clara compreensão do que analisar e de como deve ser realizada a análise para que as decisões gerenciais sejam baseadas em critérios objetivos.

A principal contribuição gerencial da Fase II é permitir aos tomadores de decisão visualizar a importância relativa de cada critério e departamento por meio da representação hierárquica de classificação das peças sobressalentes e respectivas criticidades. Para quantificar as criticidades totais dos itens, utilizam-se os critérios obtidos na Fase I, permitindo a delimitação dos limites de cada categoria. A quantificação dos valores pode ser utilizada como parâmetro para analisar cenários e traçar estratégias.

A Fase III, referente à seleção do modelo de previsão, deixa claro que a execução de um único modelo de previsão de demanda é incorreta, o que gera retrabalhos e elevação de erros. Gerencialmente, essa fase permite ao tomador de decisão definir quais modelos de previsão utilizar e para qual conjunto de peças sobressalentes. A criticidade quantificada pelas Fases I e II podem direcionar a seleção desses modelos, na utilização de modelos mais robustos de previsão nos itens mais críticos, por exemplo.

Por fim, a Fase IV disponibiliza ao gestor uma análise sistemática do *trade-off* criticidade e preço, além de análise gráfica com informações de criticidade, valor e quantidade de peças estocadas, tornando a decisão e o gerenciamento das peças sobressalentes menos subjetiva. A Fase IV dessa metodologia também pode ser usada na análise de diferentes cenários, inclusive de forma gráfica, avaliando a imobilização de capital em estoque de acordo com a realidade orçamentária organizacional. Essa abordagem é especialmente útil

para indústrias de mineração, que sofrem de vários tipos de restrições de recursos, pois ajudará na formulação de estratégias adequadas que racionalizem recursos.

### 5.3 Contribuição científica e trabalhos futuros

Esta tese contribui com uma revisão de literatura sobre peças sobressalentes e seu gerenciamento, buscando caracterizar o estado da arte e sanar algumas lacunas existentes nos estudos acadêmicos e aplicações práticas, gerando contribuições científicas, além dos resultados apresentados nas Seções 3 e 4, como:

- o detalhamento do desenvolvimento e validação de categorias Fase I e II contribui com a lacuna de como desenvolver e validar as categorias de classificações (LOLLI; ISHIZAKA; GAMBERINI, 2014; HU *et al.*, 2018; RODA *et al.*, 2014);
- as questões: quais e quantas peças de reposição devem ser estocadas? (HU *et al.*, 2018; BOTTER; FORTUIN, 2000); quantas devem ser solicitadas? (BOSNJAKOVIC, 2010; BOTTER; FORTUIN, 2000), são respondidas com a utilização das Fases III e IV de forma consistente;
- o modelo de decisão auxilia nas lacunas sobre a falta de combinar abordagens quantitativas e qualitativas para otimização de um problema biobjetivo em peças sobressalentes (HU *et al.*, 2017) e de ausência de uma perspectiva integrada de classificação, gerenciamento da demanda e inventário (BACCHETTI; SACCANI, 2012);
- a lacuna de estudos empíricos que vinculem a previsão de demanda e controle de estoques e modelos de pesquisa operacional no gerenciamento de peças sobressalentes com base de dados reais (HU *et al.*, 2018) é atendida pelo modelo de decisão testado em base de dados reais.

As contribuições científicas do estudo atendem aos objetivos gerais e específicos propostos e resultam em um melhor entendimento sobre o gerenciamento de peças sobressalentes.

No futuro, diversos assuntos complementares podem ser estudados. Primeiro, uma avaliação mais detalhada das peças sobressalentes com subdivisões internas em cada categoria e relacionar com o modelo de previsão. Segundo, um estudo comparativo entre diversos tipos de erro em diferentes bases de dados para definir um erro padrão no estudo de peças sobressalentes. Terceiro, analisar os critérios de decisão para diferentes setores e em

diferentes empresas e analisar a consistência e a relação dos resultados. Quarto, desenvolver modelos de previsão adaptados com variação pelo *ADI* e  $CV^2$  ou outra forma de erro, que se ajuste mais rapidamente à variação do padrão de demanda, bem como definir o período de inicialização e aquecimento. Quinto, analisar o número de amostragens ideal no Método Bootstrap para previsão de peças sobressalentes em decorrência de seu elevado tempo computacional por meio de convergência do método, ou até mesmo a simplificação deste. Sexto, desenvolver modelos de otimização que levem em conta o consumo ou a probabilidade de demanda em consideração no processo de otimização e heurísticas propostas, bem como a otimização de submodelos por categoria ou setor. Finalmente, melhorias no modelo de decisão proposto em qualquer uma das fases.

## REFERÊNCIAS

- ADDINSOFT. XLSTAT Statistical and Data Analysis Solution. Long Island, NY, USA, 2019. Disponível em: <https://www.xlstat.com>. Acesso em: 29 fev. 2020.
- Akbari, Negar, Chandra A. Irawan, Dylan F. Jones, and David Menachof. 2017. “A Multi-Criteria Port Suitability Assessment for Developments in the Offshore Wind Industry.” *Renewable Energy* 102: 118–133. doi:10.1016/j.renene.2016.10.035.
- Allaoui, Hamid, Yuhan Guo, Alok Choudhary, and Jacqueline Bloemhof. 2018. “Sustainable Agro-Food Supply Chain Design Using Two-Stage Hybrid Multi-Objective Decision-Making Approach.” *Computers and Operations Research* 89: 369–384. doi:10.1016/j.cor.2016.10.012.
- Alves, Maria João, Carlos Henggeler Antunes, and João Clímaco. 2015. “Interactive MOLP Explorer-A Graphical-Based Computational Tool for Teaching and Decision Support in Multi-Objective Linear Programming Models.” *Computer Applications in Engineering Education* 23 (2): 314–326. doi:10.1002/cae.21601.
- ASSOCIAÇÃO BRASILEIRA DE NORMAS TÉCNICAS. *NBR 6023:2018 – Informação e documentação – Referências – Elaboração*. 2. ed. Rio de Janeiro. 2018. 68 p.
- Babai, M. Z., T. Ladhari, and I. Lajili. 2015. “On the Inventory Performance of Multi-Criteria Classification Methods: Empirical Investigation.” *International Journal of Production Research* 53 (1): 279–290. doi:10.1080/00207543.2014.952791.
- Babazadeh, Reza, Jafar Razmi, Mir Saman Pishvae, and Masoud Rabbani. 2017. “A Sustainable Second-Generation Biodiesel Supply Chain Network Design Problem under Risk.” *Omega (United Kingdom)* 66: 258–277. doi:10.1016/j.omega.2015.12.010.
- Bacchetti, Andrea, and Nicola Saccani. 2012. “Spare Parts Classification and Demand Forecasting for Stock Control: Investigating the Gap between Research and Practice.” *Omega* 40 (6): 722–737. doi:10.1016/j.omega.2011.06.008.
- Bosnjakovic, Mladen. 2010. “Multicriteria Inventory Model for Spare Parts.” *Technical Gazette* 17 (4): 499–504. <https://hrcak.srce.hr/62926>.
- Botter, René, and Leonard Fortuin. 2000. “Stocking Strategy for Service Parts – a Case Study.” *International Journal of Operations & Production Management* 20 (6): 656–674. doi:10.1108/01443570010321612.
- Boylan, J. E., A. A. Syntetos, and G. C. Karakostas. 2008. “Classification for Forecasting and Stock Control: A Case Study.” *Journal of the Operational Research Society* 59 (4): 473–481. doi:10.1057/palgrave.jors.2602312.



- Braglia, Marcello, Andrea Grassi, and Roberto Montanari. 2004. "Multi-attribute Classification Method for Spare Parts Inventory Management." *Journal of Quality in Maintenance Engineering* 10 (1): 55–65. doi:10.1108/13552510410526875.
- Cavalieri, S., M. Garetti, M. Macchi, and R. Pinto. 2008. "A Decision-Making Framework for Managing Maintenance Spare Parts." *Production Planning & Control* 19 (4): 379–396. doi:10.1080/09537280802034471.
- Chen, Chao, Jamie Twycross, and Jonathan M. Garibaldi. 2017. "A New Accuracy Measure Based on Bounded Relative Error for Time Series Forecasting." *PLoS ONE* 12 (3): 1–23. doi:10.1371/journal.pone.0174202.
- Chen, Kai, and Sheldon M. Ross. 2014. "An Adaptive Stochastic Knapsack Problem." *European Journal of Operational Research* 239 (3). Elsevier B.V.: 625–635. doi:10.1016/j.ejor.2014.06.027.
- Conceição, Samuel Vieira, Gerson Luis Caetano Da Silva, Dawei Lu, Nilson Tadeu Ramos Nunes, and Guilherme Corteletti Pedrosa. 2015. "A Demand Classification Scheme for Spare Part Inventory Model Subject to Stochastic Demand and Lead Time." *Production Planning and Control* 26 (16): 1318–1331. doi:10.1080/09537287.2015.1033497.
- Costantino, Francesco, Giulio Di Gravio, Riccardo Patriarca, and Lea Petrella. 2017. "Spare Parts Management for Irregular Demand Items." *Omega (United Kingdom)* 0. Elsevier Ltd: 1–10. doi:10.1016/j.omega.2017.09.009.
- Croston, J.D. 1972. "Forecasting and Stock Control for Intermittent Demands." *Operational Research Quarterly* 3 (23): 289–303.
- Davydenko, Andrey, and Robert Fildes. 2013. "Measuring Forecasting Accuracy: The Case Of Judgmental Adjustments To Sku-Level Demand Forecasts." *International Journal of Forecasting* 29 (3). Elsevier B.V.: 510–522. doi:10.1016/j.ijforecast.2012.09.002.
- De Felice, F., D. Falcone, A. Forcina, A. Petrillo, and A. Silvestri. 2014. "Inventory Management Using Both Quantitative and Qualitative Criteria in Manufacturing System." In *IFAC Proceedings*, 8048–8053. Cape Town, South Africa: The International Federation of Automatic Control.
- Dekker, Rommert, Çerağ Pinçe, Rob Zuidwijk, and Muhammad Naiman Jalil. 2013. "On the Use of Installed Base Information for Spare Parts Logistics: A Review of Ideas and Industry Practice." *International Journal of Production Economics* 143 (2): 536–545. doi:10.1016/j.ijpe.2011.11.025.
- DeWalt, Daniel M. 2014. *Maintenance Storerooms and MRO Made Simple*. Edited by Reliabilityweb.com. 1st ed. United States of America: Terrence O'Hanlon.

- Driessen, M. A., J. J. Arts, G. J. van Houtum, W. D. Rustenburg, and B. Huisman. 2010. *Maintenance Spare Parts Planning and Control: A Framework for Control and Agenda for Future Research. Beta Working Paper*. Vol. 325. Eindhoven, Netherlands: BETA publicatie. [http://cms.ieis.tue.nl/Beta/Files/WorkingPapers/wp\\_325.pdf](http://cms.ieis.tue.nl/Beta/Files/WorkingPapers/wp_325.pdf).
- Duchessi, Peter, Giri Kumar Tayi, and Joshua B. Levy. 1988. "A Conceptual Approach for Managing of Spare Parts." *International Journal of Physical Distribution & Materials Management* 18 (5): 8–15. doi:10.1108/eb014700.
- Eaves, A. H. C. 2002. "Forecasting for the Ordering and Stock-Holding of Consumable Spare Parts." Lancaster University.
- Eaves, A. H.C., and B. G. Kingsman. 2004. "Forecasting for the Ordering and Stock-Holding of Spare Parts." *Journal of the Operational Research Society* 55 (4): 431–437. doi:10.1057/palgrave.jors.2601697.
- Efron, B. 1979. "Bootstrap Methods: Another Look at the Jackknife." *The Annals of Statistics* 7 (1): 1–26. doi:10.1214/aos/1176344552.
- Fallahi, E, and S Gholinezhad. 2016. "Optimal Cropping Pattern Based on Multiple Economic, Regional, and Agricultural Sustainability Criteria in Sari, Iran: Application of a Consolidated Model of AHP and Linear Programming." *Agricultural Economics & Development* 30 (1): 37–49. <https://jead.um.ac.ir/index.php/jead/article/view/46040>.
- Fildes, Robert. 1992. "The Evaluation of Extrapolative Forecasting Methods." *International Journal of Forecasting* 8 (1): 81–98. doi:10.1016/0169-2070(92)90009-X.
- Flores, Benito E., David L. Olson, and V. K. Dorai. 1992. "Management of Multicriteria Inventory Classification." *Mathematical and Computer Modelling* 16 (12): 71–82. doi:10.1016/0895-7177(92)90021-C.
- Gajpal, Prem Prakash, L.S. Ganesh, and Chandrasekharan Rajendran. 1994. "Criticality Analysis of Spare Parts Using the Analytic Hierarchy Process." *International Journal of Production Economics* 35 (1–3): 293–297. doi:10.1016/0925-5273(94)90095-7.
- Gallon, R. K., F. Ysnel, and E. Feunteun. 2013. "Optimization of an 'in Situ' Subtidal Rocky-Shore Sampling Strategy for Monitoring Purposes." *Marine Pollution Bulletin* 74 (1). Elsevier Ltd: 253–263. doi:10.1016/j.marpolbul.2013.06.049.
- Gardner, Everette S., and Joaquin Diaz-Saiz. 2002. "Seasonal Adjustment of Inventory Demand Series: A Case Study." *International Journal of Forecasting* 18 (1): 117–123. doi:10.1016/S0169-2070(01)00108-X.
- Gil, Antonio Carlos. 2017. *Como Elaborar Projetos de Pesquisa*. 6th ed. São Paulo: Atlas.

- Goyal, Raman Kumar, and Sakshi Kaushal. 2017. "Deriving Crisp and Consistent Priorities for Fuzzy AHP-Based Multicriteria Systems Using Non-Linear Constrained Optimization." *Fuzzy Optimization and Decision Making*. Springer US, 1–15. doi:10.1007/s10700-017-9267-y.
- Goyal, Raman Kumar, Sakshi Kaushal, and Arun Kumar Sangaiah. 2016. "The Utility Based Non-Linear Fuzzy AHP Optimization Model for Network Selection in Heterogeneous Wireless Networks." *Applied Soft Computing Journal*. Elsevier B.V. doi:10.1016/j.asoc.2017.05.026.
- Gu, Jingyao, Guoqing Zhang, and Kevin W Li. 2014. "Journal of Air Transport Management Efficient Aircraft Spare Parts Inventory Management under Demand Uncertainty." *Journal of Air Transport Management* 42. doi:10.1016/j.jairtraman.2014.09.006.
- Hadi-Vencheh, A., and A. Mohamadghasemi. 2011. "A Fuzzy AHP-DEA Approach for Multiple Criteria ABC Inventory Classification." *Expert Systems with Applications* 38 (4). Elsevier Ltd: 3346–3352. doi:10.1016/j.eswa.2010.08.119.
- Ho, William, Carman K M Lee, and George To Sum Ho. 2010. "Multiple Criteria Optimization of Contemporary Logistics Distribution Network Problems." *OR Insight* 23 (1). Palgrave Macmillan: 27–43. doi:10.1057/ori.2009.7.
- Hu, Qiwei, Yongsheng Bai, Jianmin Zhao, and Wenbin Cao. 2015. "Modeling Spare Parts Demands Forecast under Two-Dimensional Preventive Maintenance Policy." *Mathematical Problems in Engineering* 2015: 1–9. doi:10.1155/2015/728241.
- Hu, Qiwei, John E. Boylan, Huijing Chen, and Ashraf Labib. 2018. "OR in Spare Parts Management: A Review." *European Journal of Operational Research* 266 (2). Elsevier B.V.: 395–414. doi:10.1016/j.ejor.2017.07.058.
- Hu, Qiwei, Salem Chakhar, Sajid Siraj, and Ashraf Labib. 2017. "Spare Parts Classification in Industrial Manufacturing Using the Dominance-Based Rough Set Approach." *European Journal of Operational Research* 262 (3). Elsevier B.V.: 1136–1163. doi:10.1016/j.ejor.2017.04.040.
- Hyndman, Rob. 2006. "Another Look At Forecast-Accuracy Metrics for Intermittent Demand." *Foresight: The International Journal of Applied Forecasting*, no. 4: 43–46. doi:10.1016/j.ijforecast.2006.03.001.
- Hyndman, Rob J., and Anne B. Koehler. 2006. "Another Look at Measures of Forecast Accuracy." *International Journal of Forecasting* 22 (4): 679–688. doi:10.1016/j.ijforecast.2006.03.001.
- Ishizaka, Alessio, and Ashraf Labib. 2011. "Review of the Main Developments in the Analytic Hierarchy Process." *Expert Systems with Applications* 38 (11): 14336–14345. doi:10.1016/j.eswa.2011.04.143.

- Ishizaka, Alessio, Francesco Lolli, Elia Balugani, Rita Cavallieri, and Rita Gamberini. 2018. "DEASort: Assigning Items with Data Envelopment Analysis in ABC Classes." *International Journal of Production Economics* 199 (January): 7–15. doi:10.1016/j.ijpe.2018.02.007.
- Jing, R., X. Zhu, Z. Zhu, W. Wang, C. Meng, N. Shah, N. Li, and Y. Zhao. 2018. "A Multi-Objective Optimization and Multi-Criteria Evaluation Integrated Framework for Distributed Energy System Optimal Planning." *Energy Conversion and Management* 166 (November 2017): 445–462. doi:10.1016/j.enconman.2018.04.054.
- Kabir, Golam. 2012. "Multiple Criteria Inventory Classification Under Fuzzy Environment." *International Journal of Fuzzy System Applications* 2 (4): 76–92. doi:10.4018/ijfsa.2012100105.
- Kabir, Golam, and Ahsan Akhtar M. Hasin. 2012. "Multiple Criteria Inventory Classification Using Fuzzy Analytic Hierarchy Process." *International Journal of Industrial Engineering Computations* 3 (2): 123–132. doi:10.5267/j.ijiec.2011.09.007.
- Kareem, B., and A. S. Lawal. 2015. "Spare Parts Failure Prediction of an Automobile under Criticality Condition." *Engineering Failure Analysis* 56: 69–79. doi:10.1016/j.engfailanal.2015.04.011.
- Kavilal, E. G., S. Prasanna Venkatesan, and K. D. Harsh Kumar. 2017. "An Integrated Fuzzy Approach for Prioritizing Supply Chain Complexity Drivers of an Indian Mining Equipment Manufacturer." *Resources Policy* 51 (January). Elsevier: 204–218. doi:10.1016/j.resourpol.2016.12.008.
- Kennedy, W. J., J. W. Patterson, and Lawrence D. Fredendall. 2002. "An Overview of Recent Literature on Spare Parts Inventories." *International Journal of Production Economics* 76 (2): 201–215. doi:10.1016/S0925-5273(01)00174-8.
- Kot, Sebastian. 2013. "Decision Support of Spare Parts Supply" 12 (1): 69–76.
- Kundid, Ana, and Roberto Ercegovac. 2011. "Credit Rationing in Financial Distress: Croatia SMEs' Finance Approach." *International Journal of Law and Management* 53 (1): 62–84. doi:10.1108/17542431111111890.
- Ladhari, Talel, M. Zied Babai, and Imen Lajili. 2016. "Multi-Criteria Inventory Classification: New Consensual Procedures." *IMA Journal of Management Mathematics* 27 (2): 335–351. doi:10.1093/imaman/dpv003.
- Li, Chong Mao, and Rui Nie. 2017. "An Evaluating System for Scientific Mining of China's Coal Resources." *Resources Policy* 53 (March). Elsevier Ltd: 317–327. doi:10.1016/j.resourpol.2017.07.012.

- Liu, Li, Miao Zhang, and Technology Beijing. 2015. "Multi-Objective Optimization Model with AHP Decision-Making for Cloud Service Composition." *KSII Transactions on Internet and Information Systems* 9 (9): 3293–3311.
- Lolli, F., A. Ishizaka, and R. Gamberini. 2014. "New AHP-Based Approaches for Multi-Criteria Inventory Classification." *International Journal of Production Economics* 156. Elsevier: 62–74. doi:10.1016/j.ijpe.2014.05.015.
- Luz, T., P. Moura, and A. de Almeida. 2017. "Multi-Objective Power Generation Expansion Planning with High Penetration of Renewables." *Renewable and Sustainable Energy Reviews* 81 (November 2016): 2637–2643. doi:10.1016/j.rser.2017.06.069.
- Mazidi, Mohammadreza, Hassan Monsef, and Pierluigi Siano. 2016. "Design of a Risk-Averse Decision Making Tool for Smart Distribution Network Operators under Severe Uncertainties: An IGDT-Inspired Augment  $\epsilon$ -Constraint Based Multi-Objective Approach." *Energy* 116: 214–235. doi:10.1016/j.energy.2016.09.124.
- Mohammed, A., R. Setchi, M. Filip, I. Harris, and X. Li. 2018. "An Integrated Methodology for a Sustainable Two-Stage Supplier Selection and Order Allocation Problem." *Journal of Cleaner Production* 192: 99–114. doi:10.1016/J.JCLEPRO.2018.04.131.
- Moharana, U. C., and S. P. Sarmah. 2015. "Determination of Optimal Kit for Spare Parts Using Association Rule Mining." *International Journal of System Assurance Engineering and Management* 6 (3): 238–247. doi:10.1007/s13198-014-0273-y.
- Moharana, U C, and S P Sarmah. 2016. "Computers & Industrial Engineering Determination of Optimal Order-up to Level Quantities for Dependent Spare Parts Using Data Mining." *Computers & Industrial Engineering* 95: 27–40. doi:10.1016/j.cie.2016.01.024.
- Molenaers, An, Herman Baets, Liliane Pintelon, and Geert Waeyenbergh. 2012. "Criticality Classification of Spare Parts: A Case Study." *International Journal of Production Economics* 140 (2): 570–578. doi:10.1016/j.ijpe.2011.08.013.
- Montgomery, Douglas C, George C Runger, and Verônica. Calado. 2016. *Estatística Aplicada e Probabilidade Para Engenheiros*. 6ª. Grupo Gen-LTC.
- Nagarur, Nagen N, Tai-san Hu, and Nirmal K Baid. 1994. "A Computer- Based Inventory Management System for Spare Parts." *Industrial Management & Data Systems* 94 (9): 22–28. doi:https://doi.org/10.1108/02635579410072135.
- Ojha, A.K., and K.K. Biswal. 2014. "Multi-Objective Geometric Programming Problem with  $\epsilon$ -Constraint Method." *Applied Mathematical Modelling*. doi:10.1016/j.apm.2013.07.003.
- Ojha, A.K., and Rashmi Ranjan Ota. 2014. "Multi-Objective Geometric Programming Problem with Karush–Kuhn–Tucker Condition Using  $\epsilon$  -Constraint Method." *RAIRO -*

*Operations Research* 48 (4). EDP Sciences: 429–453. doi:10.1051/ro/2014016.

- Ozgen, Dogan, and Bahadir Gulsun. 2014. “Combining Possibilistic Linear Programming and Fuzzy AHP for Solving the Multi-Objective Capacitated Multi-Facility Location Problem.” *Information Sciences* 268. Elsevier Inc.: 185–201. doi:10.1016/j.ins.2014.01.024.
- Partovi, Fariborz Y., and Walter E. Hopton. 1994. “The Analytic Hierarchy Process as Applied to Two Types of Inventory Problems.” *Production and Inventory Management Journal* 35 (1): 13.
- Petropoulos, Fotios, Nikolaos Kourentzes, Konstantinos Nikolopoulos, and Enno Siemsen. 2018. “Judgmental Selection of Forecasting Models.” *Journal of Operations Management* 60 (May). Elsevier: 34–46. doi:10.1016/j.jom.2018.05.005.
- Quezada, Luis E., and Héctor A. López-Ospina. 2014. “A Method for Designing a Strategy Map Using AHP and Linear Programming.” *International Journal of Production Economics* 158. Elsevier: 244–255. doi:10.1016/j.ijpe.2014.08.008.
- Rego, José Roberto do, and Marco Aurélio de Mesquita. 2011. “Controle de Estoque de Peças de Reposição Em Local Único: Uma Revisão Da Literatura.” *Production* 21 (4): 645–666. doi:10.1590/S0103-65132011005000002.
- Rego, José Roberto do, and Marco Aurélio De Mesquita. 2015. “Demand Forecasting and Inventory Control: A Simulation Study on Automotive Spare Parts.” *International Journal of Production Economics* 161: 1–16. doi:10.1016/j.ijpe.2014.11.009.
- Roda, Irene, Marco Macchi, Luca Fumagalli, and Pablo Viveros. 2014. “A Review of Multi-Criteria Classification of Spare Parts.” *Journal of Manufacturing Technology Management* 25 (4): 528–549. doi:10.1108/JMTM-04-2013-0038.
- Saaty, T L. 1990. “How to Make a Decision: The Analytic Hierarchy Process.” *European Journal of Operations Research* 48 (1): 9–26. doi:https://doi.org/10.1016/0377-2217(90)90057-I.
- Saaty, Thomas L. 2008. “Decision Making with the Analytic Hierarchy Process.” *International Journal of Services Sciences* 1 (1): 83–98. doi:10.1504/IJSSCI.2008.017590.
- Saffar, Mohammad Mahdi, G. Hamed Shakouri, and Jafar Razmi. 2015. “A New Multi Objective Optimization Model for Designing a Green Supply Chain Network under Uncertainty.” *International Journal of Industrial Engineering Computations* 6 (1): 15–32. doi:10.5267/j.ijiec.2014.10.001.
- Sahebjamnia, N., S. A. Torabi, and S. A. Mansouri. 2015. “Integrated Business Continuity and Disaster Recovery Planning: Towards Organizational Resilience.” *European Journal*

*of Operational Research* 242 (1). Elsevier Ltd.: 261–273.  
doi:10.1016/j.ejor.2014.09.055.

Shang, Delei, Guangzhi Yin, Xiaoshuang Li, Yaoji Li, Changbao Jiang, Xiangtao Kang, Chao Liu, and Chi Zhang. 2015. “Analysis for Green Mine (Phosphate) Performance of China: An Evaluation Index System.” *Resources Policy* 46. Elsevier: 71–84.  
doi:10.1016/j.resourpol.2015.08.005.

Sharif, Kamal Imran, Jafni Azhan Ibrahim, Zulkifli Mohamed Udin, and Abdul Aziz Othman. 2016. “Decision Making of Spare Parts Inventory Based on Risk Quantification.” *International Journal of Supply Chain Management* 5 (3): 96–99.

Shen, Lixin, Kamalakanta Muduli, and Akhilesh Barve. 2015. “Developing a Sustainable Development Framework in the Context of Mining Industries: AHP Approach.” *Resources Policy* 46. Elsevier: 15–26. doi:10.1016/j.resourpol.2013.10.006.

Singh, Sukhbir, Anil Kumar Gupta, Latika -, and Mahesh Devnani. 2015. “ABC and VED Analysis of the Pharmacy Store of a Tertiary Care, Academic Institute of the Northern India to Identify the Categories of Drugs Needing Strict Management Control.” *Journal of Young Pharmacists* 7 (2): 76–80. doi:10.5530/jyp.2015.2.4.

Sivakumar, R., Devika Kannan, and P. Murugesan. 2015. “Green Vendor Evaluation and Selection Using AHP and Taguchi Loss Functions in Production Outsourcing in Mining Industry.” *Resources Policy* 46. Elsevier: 64–75. doi:10.1016/j.resourpol.2014.03.008.

Sobczyk, Eugeniusz J., Jerzy Kicki, Wiktoria Sobczyk, and Marek Szuwarzyński. 2017. “Support of Mining Investment Choice Decisions with the Use of Multi-Criteria Method.” *Resources Policy* 51 (December 2016): 94–99.  
doi:10.1016/j.resourpol.2016.11.012.

Stoll, J., R. Kopf, J. Schneider, and G. Lanza. 2015. “Criticality Analysis of Spare Parts Management: A Multi-Criteria Classification Regarding a Cross-Plant Central Warehouse Strategy.” *Production Engineering* 9 (2): 225–235. doi:10.1007/s11740-015-0602-2.

Super Decisions.Ink Software. 2013. “Creative Decisions Foundation.” Pittsburgh: Creative Decisions Foundation. <http://www.superdecisions.com/>.

Suryadi, Kadarsah. 2003. “Decision Model for "material Stock vs Non Stock" Using Combination of AHP and Cut off Point Method.” In *International Symposium on the Analytic Hierarchy Process*, 6. Bali, Indonesia: ISAHP.  
[http://www.scielo.br/scielo.php?script=sci\\_nlinks&ref=000265&pid=S0103-6513201100040000900058&lng=pt](http://www.scielo.br/scielo.php?script=sci_nlinks&ref=000265&pid=S0103-6513201100040000900058&lng=pt).

Suryadi, Kadarsah. 2007. “Empirical Experience on Combining Ahp With Non-Ahp Decision Models in Managing Cross Functional Conflicts.” In *International Symposium on the*

*Analytic Hierarchy Process*, 5. Vinã Del Mar, Chile: AHP.

- Syntetos, A. A., J. E. Boylan, and J. D. Croston. 2005. "On the Categorization of Demand Patterns." *Journal of the Operational Research Society* 56 (5): 495–503. doi:10.1057/palgrave.jors.2601841.
- Syntetos, A. A., M. Keyes, and M. Z. Babai. 2009. "Demand Categorisation in a European Spare Parts Logistics Network." *International Journal of Operations and Production Management* 29 (3): 292–316. doi:10.1108/01443570910939005.
- Syntetos, A. A., and J. E. Boylan. 2001. "On the Bias of Intermittent Demand Estimates, International Journal of Production Economics, ." *International Journal of Production Economics* 71 (1–3): 457–466. doi:10.1016/S0925-5273(00)00143-2.
- Syntetos, Aris A., M. Zied Babai, and Everette S. Gardner. 2015. "Forecasting Intermittent Inventory Demands: Simple Parametric Methods vs. Bootstrapping." *Journal of Business Research* 68 (8). Elsevier Inc.: 1746–1752. doi:10.1016/j.jbusres.2015.03.034.
- Tam, Maggie C.Y., and V.M.Rao Tummala. 2001. "An Application of the AHP in Vendor Selection of a Telecommunications System." *Omega* 29 (2): 171–182. doi:10.1016/S0305-0483(00)00039-6.
- Tayman, Jeff, and David A. Swanson. 1999. "On the Validity of MAPE as a Measure of Population Forecast Accuracy." *Population Research and Policy Review* 18 (4): 299–322. doi:10.1023/A:1006166418051.
- Teunter, Ruud H., Aris A. Syntetos, and M. Zied Babai. 2011. "Intermittent Demand: Linking Forecasting to Inventory Obsolescence." *European Journal of Operational Research* 214 (3). Elsevier B.V.: 606–615. doi:10.1016/j.ejor.2011.05.018.
- Tracht, K., A. Niestegge, and P. Schuh. 2013. "Demand Planning Based on Performance Measurement Systems in Closed Loop Supply Chains." *Procedia CIRP* 12. Elsevier B.V.: 324–329. doi:10.1016/j.procir.2013.09.056.
- Tsao, Yu-chung, Vo-van Thanh, Jye-chyi Lu, and Vincent Yu. 2018. "Designing Sustainable Supply Chain Networks under Uncertain Environments: Fuzzy Multi-Objective Programming." *Journal of Cleaner Production* 174. Elsevier Ltd: 1550–1565. doi:10.1016/j.jclepro.2017.10.272.
- Willemain, Thomas R., Charles N. Smart, and Henry F. Schwarz. 2004. "A New Approach to Forecasting Intermittent Demand for Service Parts Inventories." *International Journal of Forecasting* 20 (3): 375–387. doi:10.1016/S0169-2070(03)00013-X.
- Willemain, Thomas R., Charles N. Smart, Joseph H. Shockor, and Philip A. DeSautels. 1994. "Forecasting Intermittent Demand in Manufacturing: A Comparative Evaluation of Croston's Method." *International Journal of Forecasting* 10 (4): 529–538.



doi:10.1016/0169-2070(94)90021-3.

Williams, T. M. 1984. "Stock Control with Sporadic and Slow-Moving Demand." *Journal of the Operational Research Society* 35 (10): 939–948. doi:10.1057/jors.1984.185.

Willmott, Cort J., and Kenji Matsuura. 2005. "Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in Assessing Average Model Performance." *Climate Research* 30 (1): 79–82. doi:10.3354/cr030079.

Wu, Hsin Hung, and Ya Ning Tsai. 2012. "Using AHP to Evaluate the Criteria of Auto Spare Parts Industry." *Quality and Quantity* 46 (1): 359–364. doi:10.1007/s11135-010-9367-z.

You, Fengqi, and Belinda Wang. 2011. "Life Cycle Optimization of Biomass-to-Liquid Supply Chains with Distributed-Centralized Processing Networks." *Industrial and Engineering Chemistry Research* 50 (17): 10102–10127. doi:10.1021/ie200850t.

Zeng, Yu-Rong, Lin Wang, and Jing He. 2012. "A Novel Approach for Evaluating Control Criticality of Spare Parts Using Fuzzy Comprehensive Evaluation and GRA." *International Journal of Fuzzy Systems* 14 (3): 392–401. [http://apps.isiknowledge.com/full\\_record.do?product=UA&search\\_mode=GeneralSearch&qid=5&SID=4DFez8u6VxJB46kYnYr&page=1&doc=38](http://apps.isiknowledge.com/full_record.do?product=UA&search_mode=GeneralSearch&qid=5&SID=4DFez8u6VxJB46kYnYr&page=1&doc=38).

Zhang, Xiaohong, and Jianchao Zeng. 2017. "Joint Optimization of Condition-Based Opportunistic Maintenance and Spare Parts Provisioning Policy in Multiunit Systems." *European Journal of Operational Research* 262 (2). Elsevier B.V.: 479–498. doi:10.1016/j.ejor.2017.03.019.

Zhū, kèyù, Shuang yao Zhao, Shanlin Yang, Changyong Liang, and Dongxiao Gu. 2016. "Where Is the Way for Rare Earth Industry of China: An Analysis via ANP-SWOT Approach." *Resources Policy* 49. Elsevier: 349–357. doi:10.1016/j.resourpol.2016.07.003.

Zhu, Sha, Rommert Dekker, Willem van Jaarsveld, Rex Wang Renjie, and Alex J. Koning. 2017. "An Improved Method for Forecasting Spare Parts Demand Using Extreme Value Theory." *European Journal of Operational Research*. doi:10.1016/j.ejor.2017.01.053.

## APÊNDICE 1 – Resultado experimento para MAE e MASE divergentes

FIGURA 24 – Experimento MAE e Mase divergentes

Modelo Exponencial		Taxa de cobertura				Taxa de ruptura			
Estatísticas	Erro	alfa - 0,3	Erro	alfa - 0,2	Erro	alfa - 0,3	Erro	alfa - 0,2	
Observações	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	
Mínimo		0,000		0,000		0,000			
Máximo		1,00		1,00		1,00			
1º quartil		0,059		0,059		0,000			
Mediana		0,562		0,500		0,021			
3º quartil		1,000		1,000		0,146			
Média		0,538		0,527		0,141			
Variância (n-1)		0,17		0,16		0,06			
Desvio Padrão (n-1)		0,41		0,40		0,24			
Modelo Croston		Taxa de cobertura				Taxa de ruptura			
Estatísticas	Erro	alfa - 0,3	Erro	alfa - 0,4	Erro	alfa - 0,3	Erro	alfa - 0,4	
Observações	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	
Mínimo		0,000		0,000		0,000			
Máximo		1,00		1,00		1,00			
1º quartil		0,333		0,400		0,000			
Mediana		0,929		0,960		0,000			
3º quartil		1,000		1,000		0,229			
Média		0,678		0,702		0,156			
Variância (n-1)		0,15		0,14		0,06			
Desvio Padrão (n-1)		0,39		0,38		0,25			
Modelo SBA		Taxa de cobertura				Taxa de ruptura			
Estatísticas	Erro	alfa - 0,6	Erro	alfa - 0,7	Erro	alfa - 0,6	Erro	alfa - 0,7	
Observações	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	
Mínimo		0,000		0,000		0,000			
Máximo		1,00		1,00		1,00			
1º quartil		0,069		0,059		0,000			
Mediana		0,571		0,538		0,073			
3º quartil		1,000		1,000		0,490			
Média		0,549		0,541		0,267			
Variância (n-1)		0,17		0,17		0,12			
Desvio Padrão (n-1)		0,42		0,42		0,34			
Modelo TSB alfa 0,7		Taxa de cobertura				Taxa de ruptura			
Estatísticas	Erro	beta - 0,3	Erro	beta - 0,2	Erro	beta - 0,3	Erro	beta - 0,2	
Observações	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	
Mínimo		0,000		0,000		0,000			
Máximo		1,00		1,00		1,00			
1º quartil		0,057		0,062		0,000			
Mediana		0,556		0,600		0,031			
3º quartil		1,000		1,000		0,188			
Média		0,538		0,545		0,171			
Variância (n-1)		0,17		0,17		0,08			
Desvio Padrão (n-1)		0,41		0,41		0,28			
Modelo TSB alfa 1,0		Taxa de cobertura				Taxa de ruptura			
Estatísticas	Erro	beta - 0,4	Erro	beta - 0,2	Erro	beta - 0,4	Erro	beta - 0,2	
Observações	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	Erro Médio Absoluto - MAE	9263	Erro Médio Absoluto de Escala - MASE	9263	
Mínimo		0,000		0,000		0,000			
Máximo		1,00		1,00		1,00			
1º quartil		0,125		0,122		0,000			
Mediana		0,643		0,667		0,021			
3º quartil		1,000		1,000		0,115			
Média		0,562		0,566		0,135			
Variância (n-1)		0,16		0,16		0,06			
Desvio Padrão (n-1)		0,40		0,40		0,25			
Consolidado		Taxa de cobertura				Taxa de ruptura			
Análise melhor indicador	MAE	2	MASE	3	MAE	4	MASE	1	

Fonte: Elaborada pelo autor.

## APÊNDICE 2 – Tabelas de indicadores consolidadas

TABELA 33 – Taxa de cobertura base completa

Análise consolidada base completa – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,8$	$\beta = 0,5$	
Taxa de cobertura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	-	-	0,024	0,017	-
	Mediana	0,333	0,172	0,077	0,500	0,328	0,333
	3° quartil	0,941	0,607	0,542	1,000	0,825	0,952
	Média	0,432	0,317	0,291	0,490	0,421	0,433
	Variância (n-1)	0,16	0,12	0,14	0,17	0,15	0,16
	Desvio Padrão (n-1)	0,40	0,35	0,37	0,41	0,38	0,41

Fonte: Elaborada pelo autor.

TABELA 34 – Nível médio de estoque base completa

Análise consolidada base completa – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,8$	$\beta = 0,5$	
Nível médio de estoque	Mínimo	-1.189.390,94	-71.864,76	-29.231,24	-242.845,14	-1.179.962,88	-1.179.962,88
	Máximo	27.721,81	4.899,00	3.794,63	11.241,33	21.222,27	21.222,27
	1° quartil	-4,615	-134,237	-49,471	0,176	-42,213	-4,579
	Mediana	0,934	-30,316	-6,243	1,000	-2,867	0,974
	3° quartil	2,691	3,814	4,213	2,425	6,423	2,654
	Média	-349,605	-1029,611	-331,187	-93,871	-4.030,410	-355,832
	Variância (n-1)	166.235.659,86	32.138.824,34	2.509.001,84	15.112.814,42	4.115.700.870,39	164.335.974,17
	Desvio Padrão (n-1)	12.893,24	5.669,11	1.583,98	3.887,52	64.153,73	12.819,36

Fonte: Elaborada pelo autor.

TABELA 35 – Taxa de ruptura base completa

Análise consolidada base completa – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,3$	$\beta = 0,8$	$\beta = 0,5$	
Taxa de ruptura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	0,354	0,125	-	0,135	-
	Mediana	0,135	0,781	0,594	0,021	0,604	0,104
	3° quartil	0,677	0,969	0,885	0,385	0,906	0,677
	Média	0,331	0,652	0,526	0,217	0,529	0,325
	Variância (n-1)	0,13	0,12	0,14	0,10	0,14	0,14
	Desvio Padrão (n-1)	0,37	0,35	0,37	0,32	0,38	0,37

Fonte: Elaborada pelo autor.

TABELA 36 – Taxa de cobertura base sem outliers

Análise consolidada base sem outliers – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.697	154	1.332	6.039	174	7.699
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,3$	$\beta = 0,7$	$\beta = 0,9$	$\beta = 0,2$	
Taxa de cobertura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	0,044	-	0,056	0,094	-
	Mediana	0,400	0,246	0,143	0,500	0,470	0,417
	3º quartil	1,000	0,866	0,667	1,000	0,896	1,000
	Média	0,469	0,407	0,327	0,507	0,494	0,474
	Variância (n-1)	0,17	0,15	0,15	0,17	0,14	0,17
Desvio Padrão (n-1)	0,407	0,384	0,381	0,409	0,375	0,409	

Fonte: Elaborada pelo autor.

TABELA 37 – Nível médio de estoque base sem outliers

Análise consolidada base sem outliers – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.697	154	1.332	6.039	174	7.699
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,3$	$\beta = 0,7$	$\beta = 0,9$	$\beta = 0,2$	
Nível médio de estoque	Mínimo	-239,489	-66,510	-229,542	-239,177	-49,898	-239,177
	Máximo	1.000,48	66,34	1.000,00	500,00	39,00	1.000,00
	1º quartil	-0,651	-17,078	-12,197	0,302	-6,985	-0,636
	Mediana	1,000	-4,731	-1,362	1,000	0,752	0,989
	3º quartil	2,652	7,390	4,487	2,409	5,777	2,628
	Média	0,023	-3,811	-2,704	0,564	-0,836	-0,120
	Variância (n-1)	500,72	468,88	1.957,06	195,84	167,20	507,17
Desvio Padrão (n-1)	22,377	21,654	44,239	13,994	12,930	22,520	

Fonte: Elaborada pelo autor.

TABELA 38 – Taxa de ruptura base sem outliers

Análise consolidada base sem outliers – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.697	154	1.332	6.039	174	7.699
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,3$	$\beta = 0,7$	$\beta = 0,9$	$\beta = 0,2$	
Taxa de ruptura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	0,105	0,031	-	0,060	-
	Mediana	0,042	0,646	0,464	0,021	0,406	0,031
	3º quartil	0,510	0,927	0,844	0,344	0,802	0,510
	Média	0,262	0,552	0,463	0,202	0,440	0,259
	Variância (n-1)	0,12	0,15	0,14	0,09	0,13	0,12
Desvio Padrão (n-1)	0,339	0,381	0,370	0,307	0,357	0,340	

Fonte: Elaborada pelo autor.

TABELA 39 – Taxa de cobertura por categoria sem outliers

Análise consolidada por categoria sem outliers – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	574	1.629	5.558	292	8.053
Erro	Estatísticas	N/A	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		N/A	$\beta = 0,2$	$\beta = 0,4$	$\beta = 0,5$	$\beta = 0,1$	
Taxa de cobertura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	0,011	-	0,083	0,093	-
	Mediana	N/A	0,170	0,121	0,500	0,534	0,393
	3º quartil	N/A	0,633	0,631	1,000	0,916	1,000
	Média	N/A	0,328	0,317	0,517	0,522	0,464
	Variância (n-1)	N/A	0,13	0,14	0,17	0,15	0,17
	Desvio Padrão (n-1)	N/A	0,36	0,38	0,41	0,38	0,41

Fonte: Elaborada pelo autor.

TABELA 40 – Nível médio de estoque por categoria sem outliers

Análise consolidada por categoria sem outliers – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	574	1.629	5.558	292	8.053
Erro	Estatísticas	N/A	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		N/A	$\beta = 0,2$	$\beta = 0,4$	$\beta = 0,5$	$\beta = 0,1$	
Nível médio de estoque	Mínimo	N/A	-1.180,789	-792,752	-55,014	-1.011,395	-1.180,789
	Máximo	N/A	1.910,74	1.003,58	500,00	386,05	1.910,74
	1º quartil	N/A	-87,358	-20,128	0,516	-11,769	-1,295
	Mediana	N/A	-21,388	-2,894	1,015	2,740	0,969
	3º quartil	N/A	5,717	5,231	2,361	16,289	2,716
	Média	N/A	-48,598	-12,323	1,549	-2,571	-4,981
	Variância (n-1)	N/A	40.964,98	6.797,75	82,99	11.708,60	4.952,95
	Desvio Padrão (n-1)	N/A	202,40	82,45	9,11	108,21	70,38

Fonte: Elaborada pelo autor.

TABELA 41 – Taxa de ruptura por categoria sem outliers

Análise consolidada por categoria sem outliers – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	574	1.629	5.558	292	8.053
Erro	Estatísticas	N/A	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		N/A	$\beta = 0,2$	$\beta = 0,4$	$\beta = 0,5$	$\beta = 0,1$	
Taxa de ruptura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	0,318	0,052	-	0,052	-
	Mediana	N/A	0,766	0,510	0,021	0,365	0,062
	3º quartil	N/A	0,969	0,854	0,260	0,800	0,573
	Média	N/A	0,638	0,487	0,182	0,425	0,285
	Variância (n-1)	N/A	0,13	0,14	0,09	0,13	0,13
	Desvio Padrão (n-1)	N/A	0,36	0,37	0,29	0,36	0,35

Fonte: Elaborada pelo autor.

TABELA 42 – Taxa de cobertura base completa com *lead time*

Análise consolidada base completa com <i>lead time</i> – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,6$	$\beta = 0,4$	$\beta = 0,7$	$\beta = 0,2$	
Taxa de cobertura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	-	-	0,040	0,033	-
	Mediana	0,333	0,160	0,082	0,444	0,344	0,333
	3º quartil	0,875	0,590	0,500	1,000	0,847	0,880
	Média	0,422	0,313	0,286	0,478	0,431	0,424
	Variância (n-1)	0,16	0,12	0,14	0,16	0,15	0,16
Desvio Padrão (n-1)	0,40	0,35	0,37	0,40	0,38	0,40	

Fonte: Elaborada pelo autor.

TABELA 43 – Nível médio de estoque base completa com *lead time*

Análise consolidada base completa com <i>lead time</i> – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,6$	$\beta = 0,4$	$\beta = 0,7$	$\beta = 0,2$	
Nível médio de estoque	Mínimo	-1.179.962,884	-78.611,100	-30.205,266	-248.407,447	-1.191.068,026	-1.191.068,026
	Máximo	23.530,01	5.303,54	4.249,04	12.683,70	23.582,64	23.582,64
	1º quartil	-5,156	-143,184	-52,975	0,009	-45,284	-5,103
	Mediana	0,896	-34,471	-7,032	1,000	-2,190	0,908
	3º quartil	2,651	3,870	4,103	2,414	9,818	2,645
	Média	-362,867	-1.082,499	-340,174	-95,595	-4.140,565	-366,767
	Variância (n-1)	165.030.297,98	35.386.593,25	2.616.567,29	15.867.019,41	4.200.349.353,74	168.239.745,28
Desvio Padrão (n-1)	12.846,41	5.948,66	1.617,58	3.983,34	64.810,10	12.970,73	

Fonte: Elaborada pelo autor.

TABELA 44 – Taxa de ruptura base completa com *lead time*

Análise consolidada base completa com <i>lead time</i> – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		9.263	672	1.952	6.300	339	9.263
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,5$	$\beta = 0,6$	$\beta = 0,4$	$\beta = 0,7$	$\beta = 0,2$	
Taxa de ruptura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	0,365	0,135	-	0,125	-
	Mediana	0,167	0,781	0,604	0,052	0,573	0,156
	3º quartil	0,688	0,969	0,885	0,417	0,906	0,688
	Média	0,340	0,657	0,530	0,234	0,518	0,338
	Variância (n-1)	0,13	0,12	0,14	0,10	0,14	0,13
Desvio Padrão (n-1)	0,37	0,35	0,37	0,31	0,37	0,37	

Fonte: Elaborada pelo autor.

TABELA 45 – Taxa de cobertura base sem outliers com lead time

Análise consolidada base sem outliers com lead time – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.708	150	1.336	6.041	173	7.700
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,8$	$\beta = 0,2$	$\beta = 0,5$	$\beta = 1,0$	$\beta = 0,2$	
Taxa de cobertura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	0,046	-	0,077	0,094	0,016
	Mediana	0,375	0,309	0,143	0,600	0,470	0,500
	3º quartil	1,000	0,844	0,667	1,000	0,881	1,000
	Média	0,457	0,420	0,329	0,557	0,496	0,513
	Variância (n-1)	0,16	0,15	0,15	0,18	0,14	0,18
	Desvio Padrão (n-1)	0,401	0,382	0,382	0,420	0,375	0,421

Fonte: Elaborada pelo autor.

TABELA 46 – Nível médio de estoque base sem outliers com lead time

Análise consolidada base sem outliers com lead time – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.708	150	1.336	6.041	173	7.700
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,8$	$\beta = 0,2$	$\beta = 0,5$	$\beta = 1,0$	$\beta = 0,2$	
Nível médio de estoque	Mínimo	-239,236	-66,330	-226,670	-239,130	-57,184	-239,130
	Máximo	1.000,00	98,28	1.000,48	500,00	45,71	1.000,48
	1º quartil	-0,906	-18,196	-13,376	0,184	-8,463	-0,866
	Mediana	0,974	-4,880	-1,655	1,000	0,707	0,979
	3º quartil	2,620	10,104	5,150	2,408	6,254	2,658
	Média	-0,256	-2,972	-2,413	0,509	-0,956	-0,099
	Variância (n-1)	525,08	648,53	1.991,52	202,61	225,92	523,60
	Desvio Padrão (n-1)	22,915	25,466	44,626	14,234	15,031	22,882

Fonte: Elaborada pelo autor.

TABELA 47 – Taxa de ruptura base sem outliers com lead time

Análise consolidada base sem outliers com lead time – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		7.708	150	1.336	6.041	173	7.700
Erro	Estatísticas	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
		$\beta = 0,8$	$\beta = 0,2$	$\beta = 0,5$	$\beta = 1,0$	$\beta = 0,2$	
Taxa de ruptura	Mínimo	-	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	0,123	0,042	-	0,068	-
	Mediana	0,073	0,615	0,479	0,021	0,406	0,042
	3º quartil	0,531	0,917	0,833	0,354	0,802	0,521
	Média	0,275	0,540	0,463	0,209	0,441	0,265
	Variância (n-1)	0,11	0,14	0,13	0,09	0,13	0,11
	Desvio Padrão (n-1)	0,337	0,380	0,367	0,308	0,357	0,339

Fonte: Elaborada pelo autor.

TABELA 48 – Taxa de cobertura por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers com lead time – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.636	5.544	295	8.050
Erro	Estatísticas	N/A	Bootstrap	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
			Percentil 20	$\beta = 0,4$	$\beta = 0,3$	$\beta = 0,2$	
Taxa de cobertura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	-	-	0,083	0,046	-
	Mediana	N/A	0,018	0,125	0,500	0,392	0,333
	3º quartil	N/A	0,106	0,624	1,000	0,867	0,935
	Média	N/A	0,134	0,314	0,504	0,460	0,438
	Variância (n-1)	N/A	0,07	0,14	0,16	0,15	0,16
	Desvio Padrão (n-1)	N/A	0,26	0,38	0,40	0,38	0,40

Fonte: Elaborada pelo autor.

TABELA 49 – Nível médio de estoque por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers com lead time – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.636	5.544	295	8.050
Erro	Estatísticas	N/A	Bootstrap	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
			Percentil 20	$\beta = 0,4$	$\beta = 0,3$	$\beta = 0,2$	
Nível médio de estoque	Mínimo	N/A	-2.891,740	-792,752	-54,591	-924,129	-2.891,740
	Máximo	N/A	833,40	1.003,58	500,09	2696,97	2.696,97
	1º quartil	N/A	-552,417	-21,442	0,338	-21,487	-2,286
	Mediana	N/A	-226,406	-3,398	1,050	-0,053	0,907
	3º quartil	N/A	-59,021	5,242	2,426	10,562	2,529
	Média	N/A	-406,109	-13,264	1,546	-4,428	-30,801
	Variância (n-1)	N/A	297.093,52	7.322,92	85,47	36.406,36	34.971,91
	Desvio Padrão (n-1)	N/A	545,06	85,57	9,24	190,80	187,01

Fonte: Elaborada pelo autor.

TABELA 50 – Taxa de ruptura por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers com lead time – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.636	5.544	295	8.050
Erro	Estatísticas	N/A	Bootstrap	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	TSB $\alpha = 0,1$	Combinado
			Percentil 20	$\beta = 0,4$	$\beta = 0,3$	$\beta = 0,2$	
Taxa de ruptura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	0,865	0,073	-	0,115	-
	Mediana	N/A	0,969	0,521	0,042	0,490	0,125
	3º quartil	N/A	1,000	0,854	0,312	0,875	0,635
	Média	N/A	0,848	0,489	0,204	0,486	0,319
	Variância (n-1)	N/A	0,07	0,13	0,08	0,14	0,13
	Desvio Padrão (n-1)	N/A	0,27	0,37	0,29	0,37	0,36

Fonte: Elaborada pelo autor.



### APÊNDICE 3 – Tabelas de indicadores para ganhos modelos propostos

TABELA 51 – Comparativo taxa de cobertura

Análise base completa – Taxa de cobertura			
Base de dados		Errático	Errático
Quantidade de itens		672	672
Erro	Estatísticas	TSB $\alpha = 0,1$ $\beta = 0,3$	SBA $\alpha = 0,5$ com Bootstrap percentil 10
Taxa de cobertura	Mínimo	-	-
	Máximo	1,00	1,00
	1º quartil	-	-
	Mediana	0,172	0,012
	3º quartil	0,607	0,044
	Média	0,317	0,056
	Variância (n-1)	0,12	0,02
	Desvio Padrão (n-1)	0,35	0,14

Fonte: Elaborada pelo autor.

TABELA 52 – Comparativo nível médio de estoque

Análise base completa – Nível médio de estoque			
Base de dados		Errático	Errático
Quantidade de itens		672	672
Erro	Estatísticas	TSB $\alpha = 0,1$ $\beta = 0,3$	SBA $\alpha = 0,5$ com Bootstrap percentil 10
Nível médio de estoque	Mínimo	-71.864,761	-214.380,131
	Máximo	4.899,00	569,11
	1º quartil	-134,237	-4.96,718
	Mediana	-30,316	-163,425
	3º quartil	3,814	-63,385
	Média	-1029,611	-2646,298
	Variância (n-1)	32.138.824,34	165.094.726,50
	Desvio Padrão (n-1)	5.669,11	12.848,92

Fonte: Elaborada pelo autor.

TABELA 53 – Comparativo taxa de ruptura

Análise base completa – Taxa de ruptura			
Base de dados		Errático	Errático
Quantidade de itens		672	672
Erro	Estatísticas	TSB $\alpha = 0,1$ $\beta = 0,3$	SBA $\alpha = 0,5$ com Bootstrap percentil 10
Taxa de ruptura	Mínimo	-	-
	Máximo	1,00	1,00
	1º quartil	0,354	0,938
	Mediana	0,781	0,979
	3º quartil	0,969	1,000
	Média	0,652	0,929
	Variância (n-1)	0,12	0,02
	Desvio Padrão (n-1)	0,35	0,15

Fonte: Elaborada pelo autor.

TABELA 54 – Comparativo taxa de cobertura

Análise base sem outliers por categoria – Taxa de cobertura				
Base de dados		Errático	Errático	Errático
Quantidade de itens		574	577	578
Erro	Estatísticas	TSB $\alpha = 0,1$	SBA variável	SBA $\alpha = 0,5$
		$\beta = 0,2$	com Bootstrap variável	com Bootstrap percentil 10
Taxa de cobertura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	0,011	-	-
	Mediana	0,170	0,016	0,013
	3º quartil	0,633	0,063	0,049
	Média	0,328	0,087	0,062
	Desvio Padrão (n-1)	0,36	0,19	0,15

Fonte: Elaborada pelo autor.

TABELA 55 – Comparativo nível médio de estoque

Análise base sem outliers por categoria – Nível médio de estoque				
Base de dados		Errático	Errático	Errático
Quantidade de itens		574	577	578
Erro	Estatísticas	TSB $\alpha = 0,1$	SBA variável	SBA $\alpha = 0,5$
		$\beta = 0,2$	com Bootstrap variável	com Bootstrap percentil 10
Nível médio de estoque	Mínimo	-1.180,789	-1.847,542	-1.593,830
	Máximo	1.910,74	403,20	569,11
	1º quartil	-87,358	-252,122	-291,187
	Mediana	-21,388	-113,299	-129,685
	3º quartil	5,717	-44,916	-49,544
	Média	-48,598	-200,175	-224,672
	Desvio Padrão (n-1)	40.964,98	64.939,52	74.816,78

Fonte: Elaborada pelo autor.

TABELA 56 – Comparativo taxa de ruptura

Análise base sem outliers por categoria – Taxa de ruptura				
Base de dados		Errático	Errático	Errático
Quantidade de itens		574	577	578
Erro	Estatísticas	TSB $\alpha = 0,1$	SBA variável	SBA $\alpha = 0,5$
		$\beta = 0,2$	com Bootstrap variável	com Bootstrap percentil 10
Taxa de ruptura	Mínimo	-	-	-
	Máximo	1,00	1,00	1,00
	1º quartil	0,318	0,917	0,927
	Mediana	0,766	0,969	0,979
	3º quartil	0,969	1,000	1,000
	Média	0,638	0,894	0,921
	Desvio Padrão (n-1)	0,36	0,20	0,16

Fonte: Elaborada pelo autor.

TABELA 57 – Comparativo taxa de cobertura com *lead time*

<b>Análise base completa com <i>lead time</i> – Taxa de cobertura</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		672	672
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,6</math></b>	<b>SBA <math>\alpha = 0,5</math> com Bootstrap percentil 20</b>
Taxa de cobertura	Mínimo	-	-
	Máximo	1,00	1,00
	1º quartil	-	-
	Mediana	0,160	0,022
	3º quartil	0,590	0,083
	Média	0,313	0,109
	Variância (n-1)	0,12	0,05
	Desvio Padrão (n-1)	0,35	0,22

Fonte: Elaborada pelo autor.

TABELA 58 – Comparativo nível médio de estoque com *lead time*

<b>Análise base completa com <i>lead time</i> – Nível médio de estoque</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		672	672
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,6</math></b>	<b>SBA <math>\alpha = 0,5</math> com Bootstrap percentil 20</b>
Nível médio de estoque	Mínimo	-78.611,100	-217.250,924
	Máximo	5.303,54	626,88
	1º quartil	-143,184	-452,898
	Mediana	-34,471	-145,209
	3º quartil	3,870	-46,427
	Média	-1082,499	-2468,460
	Variância (n-1)	35.386.593,25	157.397.525,61
	Desvio Padrão (n-1)	5.948,66	12.545,82

Fonte: Elaborada pelo autor.

TABELA 59 – Comparativo taxa de ruptura com *lead time*

<b>Análise base completa com <i>lead time</i> – Taxa de Ruptura</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		672	672
<b>Erro</b>	<b>Estatísticas</b>	<b>TSB <math>\alpha = 0,1</math> <math>\beta = 0,6</math></b>	<b>SBA <math>\alpha = 0,5</math> com Bootstrap percentil 20</b>
Taxa de ruptura	Mínimo	-	-
	Máximo	1,00	1,00
	1º quartil	0,365	0,885
	Mediana	0,781	0,969
	3º quartil	0,969	1,000
	Média	0,657	0,871
	Variância (n-1)	0,12	0,06
	Desvio Padrão (n-1)	0,35	0,23

Fonte: Elaborada pelo autor.

TABELA 60 – Comparativo taxa de cobertura com *lead time*

<b>Análise base sem outliers com lead time por categoria – Taxa de cobertura</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		575	576
<b>Erro</b>	<b>Estatísticas</b>	<b>Bootstrap percentil 20</b>	<b>SBA <math>\alpha = 0,6</math> com Bootstrap percentil 10</b>
Taxa de cobertura	Mínimo	-	-
	Máximo	1,00	1,00
	1° quartil	-	-
	Mediana	0,018	0,014
	3° quartil	0,106	0,045
	Média	0,134	0,064
	Variância (n-1)	0,07	0,02
	Desvio Padrão (n-1)	0,26	0,15

Fonte: Elaborada pelo autor.

TABELA 61 – Comparativo nível médio de estoque com *lead time*

<b>Análise base sem outliers com lead time por categoria – Nível médio de estoque</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		575	576
<b>Erro</b>	<b>Estatísticas</b>	<b>Bootstrap percentil 20</b>	<b>SBA <math>\alpha = 0,6</math> com Bootstrap percentil 10</b>
Nível médio de estoque	Mínimo	-2.891,740	-1.741,924
	Máximo	833,40	332,06
	1° quartil	-552,417	-315,525
	Mediana	-226,406	-145,583
	3° quartil	-59,021	-54,507
	Média	-406,109	-248,147
	Variância (n-1)	297.093,52	86.248,01
	Desvio Padrão (n-1)	545,06	293,68

Fonte: Elaborada pelo autor.

TABELA 62 – Comparativo taxa de ruptura com *lead time*

<b>Análise base sem outliers com lead time por categoria – Taxa de ruptura</b>			
<b>Base de dados</b>		<b>Errático</b>	<b>Errático</b>
Quantidade de itens		575	576
<b>Erro</b>	<b>Estatísticas</b>	<b>Bootstrap percentil 20</b>	<b>SBA <math>\alpha = 0,6</math> com Bootstrap percentil 10</b>
Taxa de ruptura	Mínimo	-	-
	Máximo	1,00	1,00
	1° quartil	0,865	0,927
	Mediana	0,969	0,979
	3° quartil	1,000	1,000
	Média	0,848	0,921
	Variância (n-1)	0,07	0,03
	Desvio Padrão (n-1)	0,27	0,16

Fonte: Elaborada pelo autor.

TABELA 63 – Taxa de cobertura base completa

Análise consolidada base completa por item – Taxa de cobertura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	-	-	0,032	0,011
	Mediana	0,250	0,020	0,067	0,400	0,150
	3º quartil	0,733	0,097	0,363	1,000	0,557
	Média	0,382	0,106	0,238	0,460	0,306
	Variância (n-1)	0,15	0,04	0,11	0,15	0,12
Desvio Padrão (n-1)		0,39	0,20	0,32	0,39	0,34

Fonte: Elaborada pelo autor.

TABELA 64 – Nível médio de estoque base completa

Análise consolidada base completa por item – Nível médio de estoque						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	-1.336.745,954	-261.560,833	-51.734,615	-244.171,759	-1.336.745,954
	Máximo	9279,87	949,48	1.508,43	9.212,64	9.279,87
	1º quartil	-10,308	-500,849	-73,007	-0,650	-103,688
	Mediana	0,506	-145,612	-10,272	0,941	-15,552
	3º quartil	1,810	-53,025	1,000	1,938	1,870
	Média	-595,424	-2.884,802	-748,416	-73,689	-4.872,219
	Variância (n-1)	219.778.584,14	208.013.966,84	12.314.027,49	10.479.543,65	5.293.457.736,63
Desvio Padrão (n-1)		14.824,93	14.422,69	3.509,13	3.237,21	72.756,15

Fonte: Elaborada pelo autor.

TABELA 65 – Taxa de ruptura base completa

Análise consolidada base completa por item – Taxa de ruptura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1º quartil	0,010	0,875	0,271	-	0,365
	Mediana	0,302	0,969	0,683	0,073	0,771
	3º quartil	0,781	1,000	0,906	0,531	0,969
	Média	0,396	0,877	0,580	0,273	0,657
	Variância (n-1)	0,14	0,04	0,12	0,11	0,12
	Desvio Padrão (n-1)	0,38	0,21	0,35	0,33	0,35

Fonte: Elaborada pelo autor.

TABELA 66 – Taxa de cobertura base sem *outliers*

Análise consolidada base sem <i>outliers</i> por item – Taxa de cobertura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.712	159	1.336	6.045	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	0,013	-	0,062	0,049
	Mediana	0,333	0,045	0,143	0,429	0,284
	3° quartil	0,869	0,231	0,500	1,000	0,640
	Média	0,434	0,186	0,294	0,473	0,369
	Variância (n-1)	0,15	0,08	0,12	0,15	0,12
Desvio Padrão (n-1)		0,39	0,28	0,35	0,39	0,34

Fonte: Elaborada pelo autor.

TABELA 67 – Nível médio de estoque base sem *outliers*

Análise consolidada base sem <i>outliers</i> por item – Nível médio de estoque						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.712	159	1.336	6.045	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	-239,489	-112,740	-220,537	-239,489	-77,010
	Máximo	1.000,04	23,38	1.000,04	500,00	28,45
	1° quartil	-1,995	-52,865	-14,147	-0,364	-15,583
	Mediana	0,914	-30,519	-2,483	0,958	-5,208
	3° quartil	1,939	-12,777	1,964	1,954	2,603
	Média	-2,143	-34,476	-6,188	-0,261	-6,988
	Variância (n-1)	466,95	867,03	1.561,90	185,97	225,66
Desvio Padrão (n-1)		21,61	29,45	39,52	13,64	15,02

Fonte: Elaborada pelo autor.

TABELA 68 – Taxa de ruptura base sem *outliers*

Análise consolidada base sem <i>outliers</i> por item – Taxa de ruptura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.712	159	1.336	6.045	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de ruptura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	0,729	0,125	-	0,234
	Mediana	0,156	0,938	0,542	0,062	0,646
	3° quartil	0,635	0,979	0,844	0,495	0,914
	Média	0,318	0,794	0,499	0,258	0,578
	Variância (n-1)	0,12	0,08	0,13	0,10	0,12
Desvio Padrão (n-1)		0,35	0,29	0,36	0,32	0,35

Fonte: Elaborada pelo autor.

TABELA 69 – Taxa de cobertura por categoria sem outliers

Análise consolidada por categoria sem outliers por item – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.630	5.548	295	8.048
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	-	-	0,100	0,017	-
	Mediana	N/A	0,021	0,111	0,500	0,167	0,333
	3º quartil	N/A	0,109	0,455	1,000	0,607	0,833
	Média	N/A	0,113	0,271	0,495	0,318	0,416
	Variância (n-1)	N/A	0,04	0,11	0,16	0,12	0,15
	Desvio Padrão (n-1)	N/A	0,21	0,34	0,39	0,34	0,39

Fonte: Elaborada pelo autor.

TABELA 70 – Nível médio de estoque por categoria sem outliers

Análise consolidada por categoria sem outliers por item – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.630	5.548	295	8.048
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	N/A	-2.584,917	-849,558	-43,515	-740,417	-2.584,917
	Máximo	N/A	331,98	1.000,04	500,00	680,60	1.000,04
	1º quartil	N/A	-295,698	-26,751	0,141	-47,144	-3,669
	Mediana	N/A	-109,859	-5,064	0,993	-11,971	0,837
	3º quartil	N/A	-44,333	1,312	1,958	2,344	1,904
	Média	N/A	-229,205	-23,181	1,078	-41,317	-21,842
	Variância (n-1)	N/A	104.536,27	5.623,77	80,44	14.849,41	12.656,06
	Desvio Padrão (n-1)	N/A	323,32	74,99	8,97	121,86	112,50

Fonte: Elaborada pelo autor.

TABELA 71 – Taxa de ruptura por categoria sem outliers

Análise consolidada por categoria sem outliers por item – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	575	1.630	5.548	295	8.048
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de ruptura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	0,875	0,188	-	0,302	-
	Mediana	N/A	0,969	0,594	0,042	0,750	0,198
	3º quartil	N/A	1,000	0,865	0,417	0,958	0,708
	Média	N/A	0,869	0,533	0,230	0,643	0,352
	Variância (n-1)	N/A	0,05	0,12	0,10	0,12	0,14
	Desvio Padrão (n-1)	N/A	0,22	0,35	0,31	0,35	0,37

Fonte: Elaborada pelo autor.

TABELA 72 – Taxa de cobertura base completa com *lead time*

Análise consolidada base completa por item com <i>lead time</i> – Taxa de cobertura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1º quartil	-	-	-	0,042	0,014
	Mediana	0,250	0,021	0,071	0,375	0,136
	3º quartil	0,700	0,108	0,363	0,949	0,528
	Média	0,378	0,103	0,240	0,455	0,288
	Variância (n-1)	0,15	0,04	0,11	0,15	0,11
Desvio Padrão (n-1)		0,38	0,19	0,33	0,39	0,33

Fonte: Elaborada pelo autor.

TABELA 73 – Nível médio de estoque base completa com *lead time*

Análise consolidada base completa por item com <i>lead time</i> – Nível médio de estoque						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	-1.336.745,954	-261.560,833	-51.734,615	-248.407,447	-13.36.745,954
	Máximo	9.212,64	949,48	2.219,09	9.212,64	7.992,95
	1º quartil	-10,774	-507,926	-77,033	-0,672	-116,391
	Mediana	0,473	-155,542	-10,780	0,914	-16,948
	3º quartil	1,788	-54,233	0,980	1,938	1,250
	Média	-603,817	-2.938,705	-749,407	-80,014	-4.871,443
	Variância (n-1)	221.112.228,97	213.413.848,94	12.309.604,68	11.735.176,73	5.295.519.106,88
Desvio Padrão (n-1)		14.869,84	14.608,69	3.508,50	3.425,66	72.770,32

Fonte: Elaborada pelo autor.

TABELA 74 – Taxa de ruptura base completa com *lead time*

Análise consolidada base completa por item com <i>lead time</i> – Taxa de ruptura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		9.263	672	1.952	6.300	339
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de ruptura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1º quartil	0,010	0,865	0,271	-	0,417
	Mediana	0,302	0,969	0,667	0,104	0,812
	3º quartil	0,771	1,000	0,906	0,521	0,969
	Média	0,397	0,881	0,578	0,275	0,678
	Variância (n-1)	0,14	0,04	0,12	0,10	0,11
Desvio Padrão (n-1)		0,38	0,20	0,35	0,32	0,34

Fonte: Elaborada pelo autor.



TABELA 75 – Taxa de cobertura base sem *outliers* com *lead time*

Análise consolidada base sem <i>outliers</i> por item com <i>lead time</i> – Taxa de cobertura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.715	158	1.338	6.047	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	0,014	-	0,062	0,049
	Mediana	0,333	0,053	0,143	0,400	0,263
	3° quartil	0,833	0,232	0,500	1,000	0,614
	Média	0,428	0,165	0,293	0,467	0,358
	Variância (n-1)	0,15	0,06	0,12	0,15	0,11
Desvio Padrão (n-1)		0,39	0,24	0,35	0,39	0,33

Fonte: Elaborada pelo autor.

TABELA 76 – Nível médio de estoque base sem *outliers* com *lead time*

Análise consolidada base sem <i>outliers</i> por item com <i>lead time</i> – Nível médio de estoque						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.715	158	1.338	6.047	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	-239,489	-112,740	-223,913	-239,489	-51,708
	Máximo	1.000,04	23,38	1.000,04	500,00	43,18
	1° quartil	-2,095	-53,270	-14,883	-0,388	-16,018
	Mediana	0,862	-33,790	-2,571	0,931	-5,523
	3° quartil	1,938	-14,833	2,009	1,956	2,684
	Média	-2,260	-36,179	-6,542	-0,280	-7,420
	Variância (n-1)	486,20	850,28	1.610,63	195,97	244,01
Desvio Padrão (n-1)		22,05	29,16	40,13	14,00	15,62

Fonte: Elaborada pelo autor.

TABELA 77 – Taxa de ruptura base sem *outliers* com *lead time*

Análise consolidada base sem <i>outliers</i> por item com <i>lead time</i> – Taxa de ruptura						
Base de dados		Geral	Errático	Irregular	Intermitente	Regular
Quantidade de itens		7.715	158	1.338	6.047	172
Erro	Estatísticas	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de ruptura	Mínimo	-	-	-	-	-
	Máximo	1,00	1,00	1,00	1,00	1,00
	1° quartil	-	0,737	0,115	-	0,302
	Mediana	0,167	0,938	0,552	0,083	0,688
	3° quartil	0,625	0,979	0,844	0,490	0,906
	Média	0,320	0,813	0,499	0,260	0,594
	Variância (n-1)	0,12	0,07	0,13	0,10	0,11
Desvio Padrão (n-1)		0,35	0,26	0,36	0,32	0,34

Fonte: Elaborada pelo autor.

TABELA 78 – Taxa de cobertura por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers por item com lead time – Taxa de cobertura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	576	1.634	5542	294	8.046
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de cobertura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	-	-	0,100	0,018	-
	Mediana	N/A	0,022	0,118	0,500	0,142	0,333
	3º quartil	N/A	0,113	0,444	1,000	0,556	0,796
	Média	N/A	0,109	0,272	0,488	0,299	0,410
	Variância (n-1)	N/A	0,04	0,11	0,15	0,11	0,15
	Desvio Padrão (n-1)	N/A	0,19	0,34	0,39	0,33	0,39

Fonte: Elaborada pelo autor.

TABELA 79 – Nível médio de estoque por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers por item com lead time – Nível médio de estoque							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	576	1-634	5-542	294	8-046
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Nível médio de estoque	Mínimo	N/A	-2.584,917	-849,558	-55,631	-596,715	-2.584,917
	Máximo	N/A	331,98	1.000,04	500,00	680,60	1.000,04
	1º quartil	N/A	-293,283	-29,248	0,116	-64,392	-3,684
	Mediana	N/A	-112,403	-5,438	0,979	-13,745	0,781
	3º quartil	N/A	-46,846	1,456	1,963	1,859	1,878
	Média	N/A	-237,394	-24,301	1,086	-46,391	-22,877
	Variância (n-1)	N/A	115.673,73	5.867,66	81,11	13.349,10	13.726,59
	Desvio Padrão (n-1)	N/A	340,11	76,60	9,01	115,54	117,16

Fonte: Elaborada pelo autor.

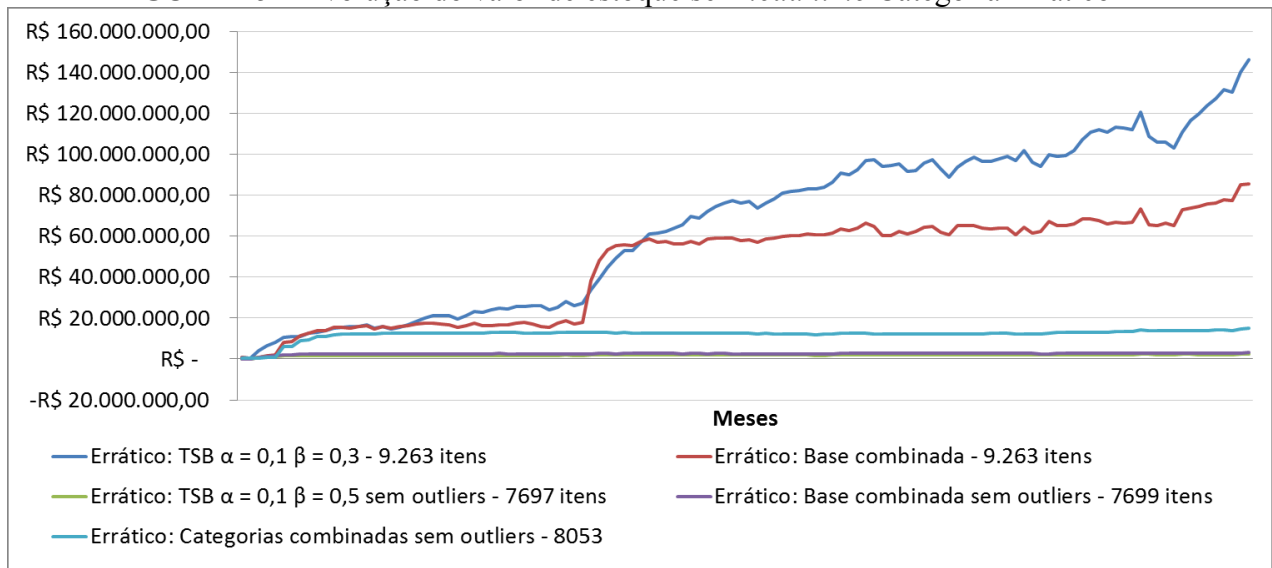
TABELA 80 – Taxa de ruptura por categoria sem outliers com lead time

Análise consolidada por categoria sem outliers por item com lead time – Taxa de ruptura							
Base de dados		Geral	Errático	Irregular	Intermitente	Regular	Geral
Quantidade de itens		N/A	576	1.634	5.542	294	8.046
Erro	Estatísticas	N/A	Combinado	Combinado	Combinado	Combinado	Combinado
Taxa de ruptura	Mínimo	N/A	-	-	-	-	-
	Máximo	N/A	1,00	1,00	1,00	1,00	1,00
	1º quartil	N/A	0,854	0,177	-	0,383	-
	Mediana	N/A	0,969	0,594	0,062	0,797	0,208
	3º quartil	N/A	1,000	0,865	0,417	0,961	0,698
	Média	N/A	0,874	0,532	0,233	0,664	0,355
	Variância (n-1)	N/A	0,04	0,12	0,09	0,12	0,13
	Desvio Padrão (n-1)	N/A	0,21	0,35	0,30	0,34	0,37

Fonte: Elaborada pelo autor.

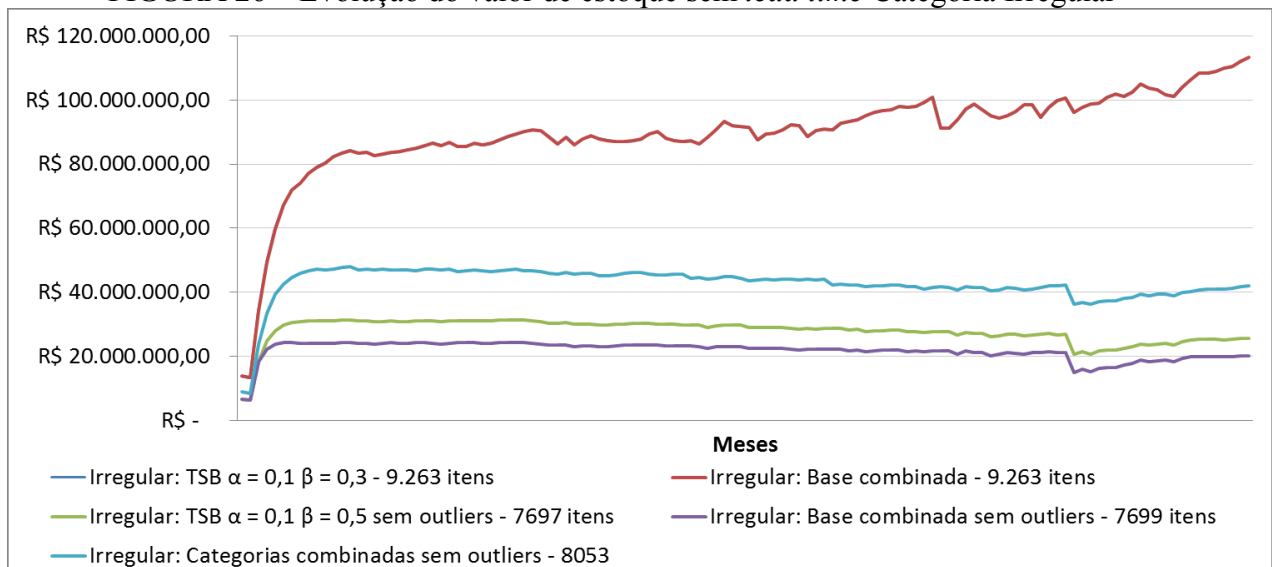
## APÊNDICE 4 – Gráficos de evolução de valor de estoque por categoria

FIGURA 25 – Evolução do valor de estoque sem *lead time* Categoria Errático



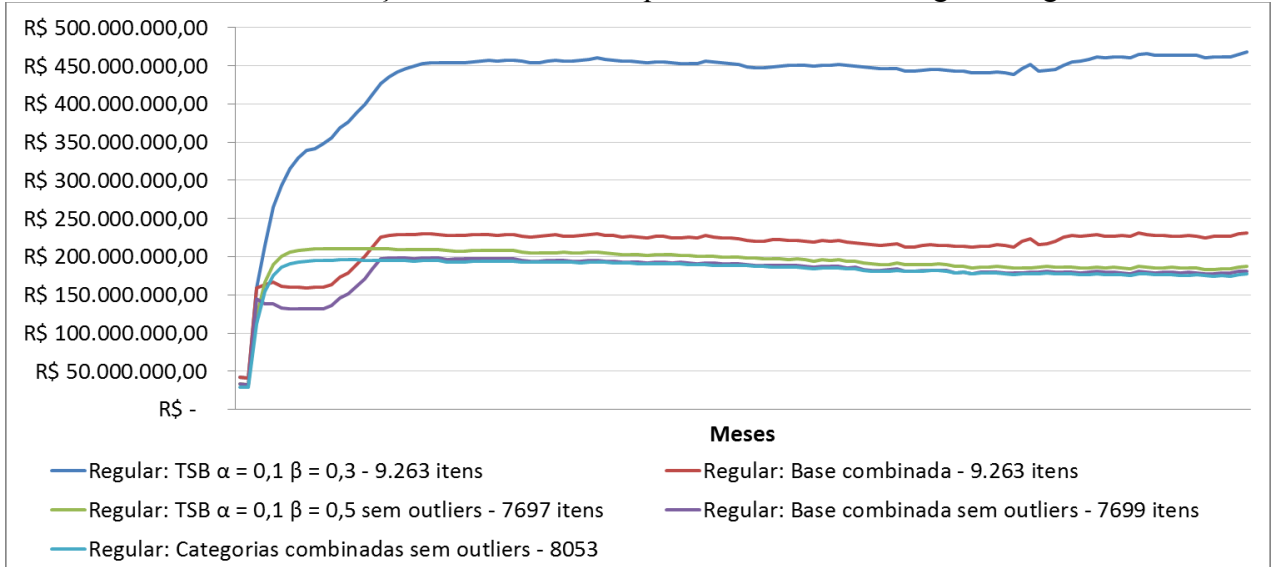
Fonte: Elaborada pelo autor.

FIGURA 26 – Evolução do valor de estoque sem *lead time* Categoria Irregular




Fonte: Elaborada pelo autor.

FIGURA 27 – Evolução do valor de estoque sem *lead time* Categoria Regular



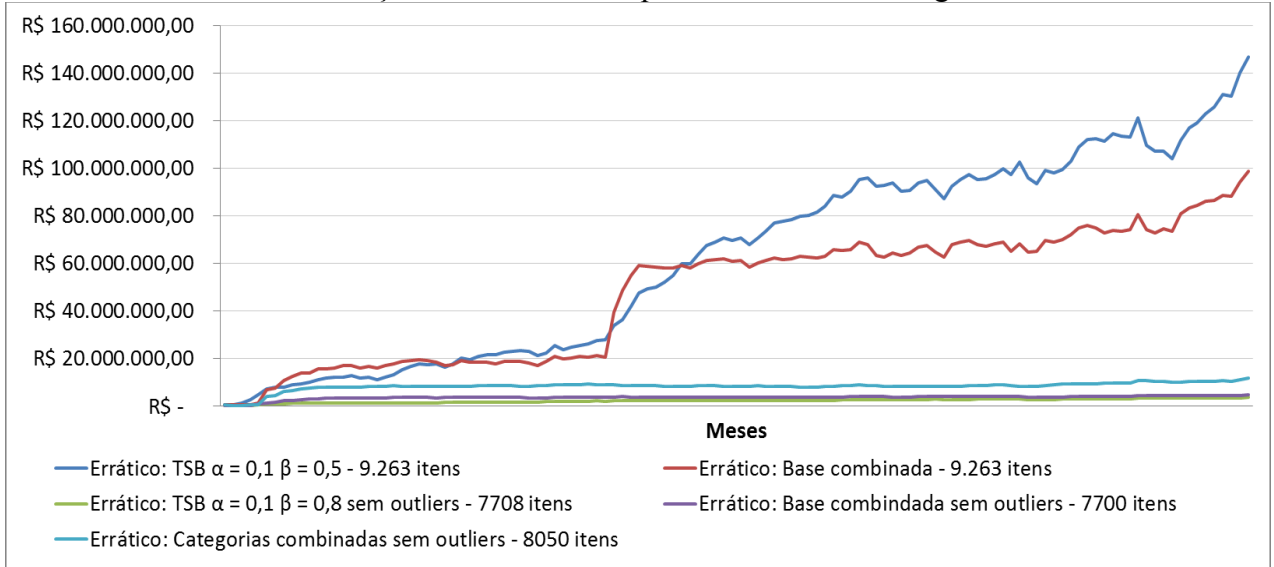
Fonte: Elaborada pelo autor.

FIGURA 28 – Evolução do valor de estoque sem *lead time* Categoria Intermitente



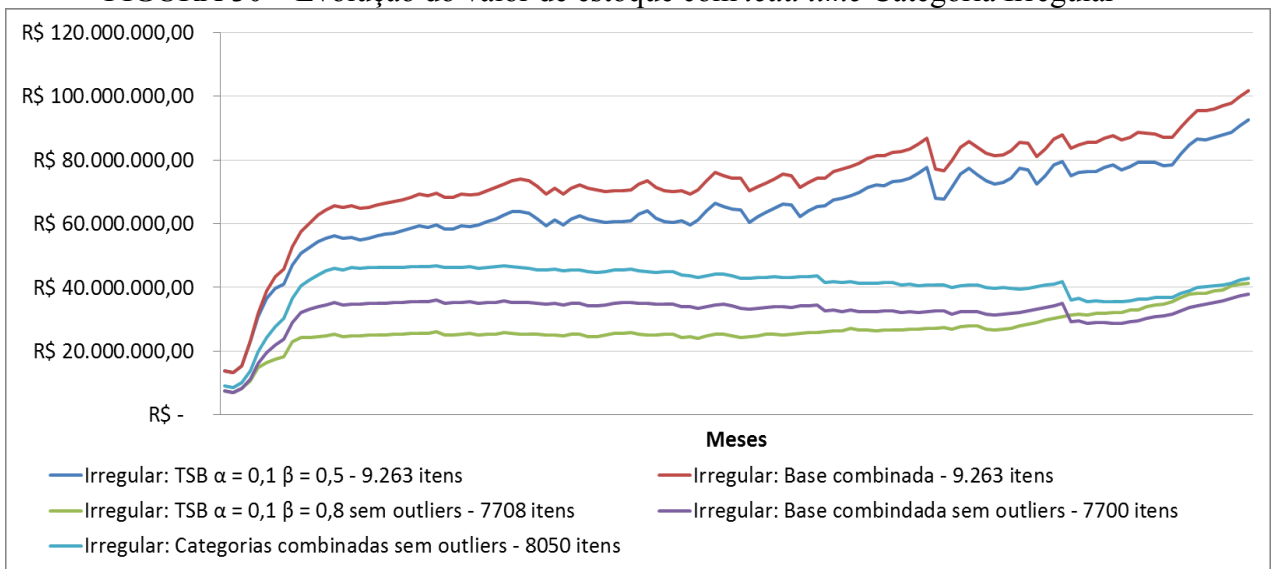
Fonte: Elaborada pelo autor.

FIGURA 29 – Evolução do valor de estoque com *lead time* Categoria Errático



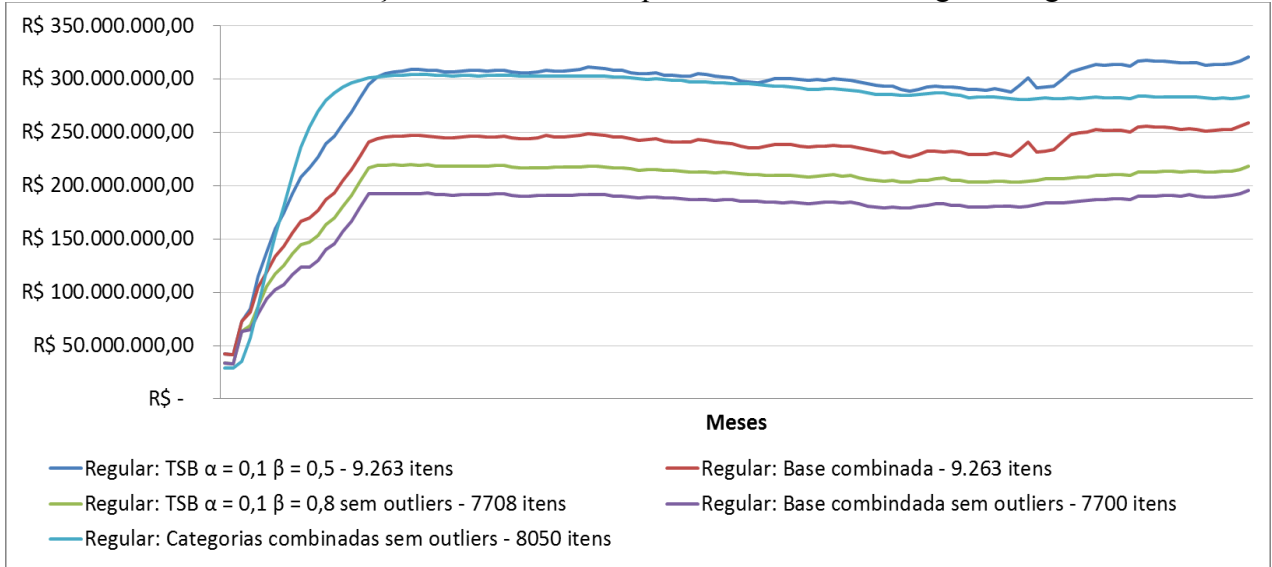
Fonte: Elaborada pelo autor.

FIGURA 30 – Evolução do valor de estoque com *lead time* Categoria Irregular




Fonte: Elaborada pelo autor.

FIGURA 31 – Evolução do valor de estoque com *lead time* Categoria Regular



Fonte: Elaborada pelo autor.

FIGURA 32 – Evolução do valor de estoque com *lead time* Categoria Intermitente



Fonte: Elaborada pelo autor.

## **APÊNDICE 5 – Pesquisa de sub-critérios do Método *Cut off Point***

Avalie cada critério usando a escala de três pontos, “não é importante”, “pouco importante” e “muito importante”, sob o ponto de vista da tomada de decisão de quais peças sobressalentes devem ser estocadas.

### **CRITÉRIOS DE OPERAÇÃO E PRODUÇÃO**

#### **1. Processos alternativos**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **2. Criticidade da função a ser executada por sistema que se torna defeituoso**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **3. Perda de qualidade da produção**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **4. Disponibilidade do equipamento**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **5. Impacto no processo produtivo**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **6. Material de segurança**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

#### **7. Impactos ambientais e de segurança**

( ) Não é importante ( ) Pouco importante ( ) Muito importante

Avalie cada critério usando a escala de três pontos, “não é importante”, “pouco importante” e “muito importante”, sob o ponto de vista da tomada de decisão de quais peças sobressalentes devem ser estocadas.

### CRITÉRIOS DE MANUTENÇÃO

1. Confiabilidade do material

Não é importante    Pouco importante    Muito importante

2. Feito sob medida

Não é importante    Pouco importante    Muito importante

3. Custo de manutenção

Não é importante    Pouco importante    Muito importante

4. Prioridade do equipamento

Não é importante    Pouco importante    Muito importante

5. Peças intercambiáveis

Não é importante    Pouco importante    Muito importante

6. Consumíveis

Não é importante    Pouco importante    Muito importante

7. População instalada do mesmo item

Não é importante    Pouco importante    Muito importante

8. Possibilidade de manutenção interna

Não é importante    Pouco importante    Muito importante



Avalie cada critério usando a escala de três pontos, “não é importante”, “pouco importante” e “muito importante”, sob o ponto de vista da tomada de decisão de quais peças sobressalentes devem ser estocadas.

#### CRITÉRIOS DE SUPRIMENTOS (compras, almoxarifado, logística)

1. Número de fornecedores potenciais

Não é importante    Pouco importante    Muito importante

2. Preço

Não é importante    Pouco importante    Muito importante

3. *Lead time*

Não é importante    Pouco importante    Muito importante

4. Espaço para armazenagem

Não é importante    Pouco importante    Muito importante

5. Dificuldade de aquisição

Não é importante    Pouco importante    Muito importante

## APÊNDICE 6 – Tabelas de comparação par a par da AHP

TABELA 81 – Comparação par a par (a)

Criticidade total	Produção	Manutenção	Suprimentos
Produção	1	2	5
Manutenção	1/2	1	3
Suprimentos	1/5	1/3	1

Fonte: Elaborada pelo autor.

TABELA 82 – Comparação par a par (b)

Produção	Processos alternativos	Criticidade da função a ser executada	Perda de qualidade da produção	Disponibilidade do equipamento	Impacto no processo produtivo	Material de segurança	Impactos ambientais e de segurança
Processos alternativos	1	1/9	1/5	1/7	1/9	1/5	1/2
Criticidade da função a ser executada	9	1	5	3	1	5	7
Perda de qualidade da produção	5	1/5	1	1/3	1/5	1	3
Disponibilidade do equipamento	7	1/3	3	1	1/3	3	5
Impacto no processo produtivo	9	1	5	3	1	5	7
Material de segurança	5	1/5	1	1/3	1/5	1	2
Impactos ambientais e de segurança	2	1/7	1/3	1/5	1/7	1/2	1

Fonte: Elaborada pelo autor.

TABELA 83 – Comparação par a par (c)

Manutenção	Confiabilidade do material	Feito sob medida	Prioridade do equipamento
Confiabilidade do material	1	3	7
Feito sob medida	1/3	1	1/3
Prioridade do equipamento	1/7	3	1

Fonte: Elaborada pelo autor.

TABELA 84 – Comparação par a par (d)

Suprimentos	Número de fornecedores potenciais	Preço	Lead time	Dificuldade de aquisição
Número de fornecedores potenciais	1	3	5	5
Preço	1/3	1	1/3	1
Lead time	1/5	3	1	3
Dificuldade de aquisição	1/5	1	1/3	1

Fonte: Elaborada pelo autor.

## APÊNDICE 7 – Dados Curva Pareto Ótima

TABELA 85 – Curva Pareto Ótima

Iteração	Criticidade	Criticidade (%)	Valor de estoque (R\$)	Valor de estoque (%)	Itens	Itens (%)	Quantidade itens	Quantidade itens (%)
1	-	-	R\$ -	-	-	-	-	-
2	797,54	1,53%	R\$ 288.589,00	1,01%	337	36,24%	4.450	1,20%
3	1.358,69	2,60%	R\$ 577.183,00	2,02%	338	36,34%	8.458	2,28%
4	1.919,88	3,68%	R\$ 865.773,00	3,03%	336	36,13%	12.467	3,36%
5	2.481,02	4,75%	R\$ 1.154.370,00	4,04%	337	36,24%	16.475	4,44%
6	3.042,16	5,83%	R\$ 1.442.960,00	5,05%	338	36,34%	20.483	5,52%
7	3.603,30	6,90%	R\$ 1.731.550,00	6,06%	338	36,34%	24.492	6,60%
8	4.164,43	7,97%	R\$ 2.020.140,00	7,07%	338	36,34%	28.500	7,69%
9	4.725,64	9,05%	R\$ 2.308.730,00	8,08%	337	36,24%	32.508	8,77%
10	5.286,77	10,12%	R\$ 2.597.330,00	9,09%	337	36,24%	36.516	9,85%
11	5.847,91	11,20%	R\$ 2.885.920,00	10,10%	338	36,34%	40.524	10,93%
12	6.409,03	12,27%	R\$ 3.174.510,00	11,11%	336	36,13%	44.532	12,01%
13	6.970,24	13,35%	R\$ 3.463.100,00	12,12%	336	36,13%	48.541	13,09%
14	7.531,38	14,42%	R\$ 3.751.690,00	13,13%	337	36,24%	52.549	14,17%
15	8.092,52	15,50%	R\$ 4.040.290,00	14,14%	338	36,34%	56.577	15,26%
16	8.653,66	16,57%	R\$ 4.328.880,00	15,15%	338	36,34%	60.566	16,33%
17	9.214,79	17,65%	R\$ 4.617.470,00	16,16%	338	36,34%	64.574	17,41%
18	9.776,00	18,72%	R\$ 4.906.060,00	17,17%	337	36,24%	68.582	18,49%
19	10.337,10	19,80%	R\$ 5.194.660,00	18,18%	337	36,24%	72.590	19,57%
20	10.898,30	20,87%	R\$ 5.483.250,00	19,19%	338	36,34%	76.598	20,66%
21	11.459,40	21,94%	R\$ 5.771.840,00	20,20%	336	36,13%	80.606	21,74%
22	12.020,60	23,02%	R\$ 6.060.430,00	21,21%	336	36,13%	84.615	22,82%
23	12.581,70	24,09%	R\$ 6.349.020,00	22,22%	337	36,24%	88.623	23,90%
24	13.142,90	25,17%	R\$ 6.637.610,00	23,23%	338	36,34%	92.631	24,98%
25	13.704,00	26,24%	R\$ 6.926.210,00	24,24%	338	36,34%	96.640	26,06%
26	14.265,20	27,32%	R\$ 7.214.800,00	25,35%	338	36,34%	100.648	27,14%
27	14.826,40	28,39%	R\$ 7.503.390,00	26,26%	337	36,24%	104.656	28,22%
28	15.387,50	29,47%	R\$ 7.791.980,00	27,27%	337	36,24%	108.664	29,30%
29	15.948,60	30,54%	R\$ 8.080.570,00	28,28%	338	36,34%	112.672	30,38%
30	16.509,80	31,62%	R\$ 8.369.170,00	29,29%	336	36,13%	116.680	31,46%
31	17.071,00	32,69%	R\$ 8.657.760,00	30,30%	336	36,13%	120.689	32,55%
32	17.632,10	33,77%	R\$ 8.946.350,00	31,31%	337	36,24%	124.697	33,63%
33	18.193,20	34,84%	R\$ 9.234.940,00	32,32%	338	36,34%	128.705	34,71%
34	18.754,40	35,91%	R\$ 9.523.530,00	33,33%	338	36,34%	132.714	35,79%
35	19.315,50	36,99%	R\$ 9.812.130,00	34,34%	338	36,34%	136.722	36,87%
36	19.876,70	38,06%	R\$ 10.100.700,00	35,35%	337	36,24%	140.730	37,95%
37	20.437,90	39,14%	R\$ 10.389.300,00	36,36%	337	36,24%	144.738	39,03%
38	20.999,00	40,21%	R\$ 10.677.900,00	37,37%	338	36,34%	148.746	40,11%
39	21.560,10	41,29%	R\$ 10.966.500,00	38,38%	336	36,13%	152.754	41,19%

40	22.121,30	42,36%	R\$ 11.255.100,00	39,39%	336	36,13%	156.763	42,27%
41	22.682,50	43,44%	R\$ 11.543.700,00	40,40%	337	36,24%	160.771	43,35%
42	23.243,60	44,51%	R\$ 11.832.300,00	41,41%	338	36,34%	164.779	44,44%
43	23.804,70	45,59%	R\$ 12.120.900,00	42,42%	338	36,34%	168.788	45,52%
44	24.365,90	46,66%	R\$ 12.409.500,00	43,43%	338	36,34%	172.796	46,60%
45	24.927,10	47,74%	R\$ 12.698.000,00	44,44%	337	36,24%	176.804	47,68%
46	25.488,20	48,81%	R\$ 12.986.600,00	45,45%	337	36,24%	180.812	48,76%
47	26.049,40	49,88%	R\$ 13.275.200,00	46,46%	338	36,34%	184.820	49,84%
48	26.610,50	50,96%	R\$ 13.563.800,00	47,47%	336	36,13%	188.828	50,92%
49	27.171,70	52,03%	R\$ 13.852.400,00	48,48%	336	36,13%	192.837	52,00%
50	27.732,80	53,11%	R\$ 14.141.000,00	49,49%	337	36,24%	196.845	53,08%
51	28.294,00	54,18%	R\$ 14.429.600,00	50,51%	338	36,34%	200.853	54,16%
52	28.855,10	55,26%	R\$ 14.718.200,00	51,52%	338	36,34%	204.862	55,24%
53	29.416,20	56,33%	R\$ 15.006.800,00	52,53%	338	36,34%	208.870	56,32%
54	29.977,40	57,41%	R\$ 15.295.400,00	53,54%	337	36,24%	212.878	57,41%
55	30.538,60	58,48%	R\$ 15.584.000,00	54,55%	337	36,24%	216.886	58,49%
56	31.099,70	59,56%	R\$ 15.872.600,00	55,56%	338	36,34%	220.894	59,57%
57	31.660,80	60,63%	R\$ 16.161.100,00	56,57%	336	36,13%	224.902	60,65%
58	32.222,00	61,71%	R\$ 16.449.700,00	57,58%	336	36,13%	228.911	61,73%
59	32.783,20	62,78%	R\$ 16.738.300,00	58,59%	337	36,24%	232.919	62,81%
60	33.344,30	63,85%	R\$ 17.026.900,00	59,60%	338	36,34%	236.927	63,89%
61	33.905,50	64,93%	R\$ 17.315.500,00	60,61%	338	36,34%	240.936	64,97%
62	34.466,60	66,00%	R\$ 17.604.100,00	61,62%	338	36,34%	244.944	66,05%
63	35.027,00	67,08%	R\$ 17.892.700,00	62,63%	337	36,24%	248.952	67,13%
64	35.588,90	68,15%	R\$ 18.181.300,00	63,64%	337	36,24%	252.960	68,21%
65	36.150,10	69,23%	R\$ 19.469.900,00	68,15%	338	36,34%	256.968	69,30%
66	36.711,20	70,30%	R\$ 18.758.500,00	65,66%	336	36,13%	260.976	70,38%
67	37.272,40	71,38%	R\$ 19.047.100,00	66,67%	336	36,13%	264.985	71,46%
68	37.833,50	72,45%	R\$ 19.335.700,00	67,68%	337	36,24%	268.993	72,54%
69	38.394,70	73,53%	R\$ 19.624.300,00	68,69%	338	36,34%	273.001	73,62%
70	38.955,80	74,60%	R\$ 19.912.800,00	69,70%	338	36,34%	277.010	74,70%
71	39.517,00	75,68%	R\$ 20.201.400,00	70,71%	338	36,34%	281.018	75,78%
72	40.078,20	76,75%	R\$ 20.490.000,00	71,72%	337	36,24%	285.026	76,86%
73	40.639,30	77,82%	R\$ 20.778.600,00	72,73%	337	36,24%	289.034	77,94%
74	41.200,40	78,90%	R\$ 21.067.200,00	73,74%	338	36,34%	293.042	79,02%
75	41.761,60	79,97%	R\$ 21.355.800,00	74,75%	336	36,13%	297.050	80,10%
76	42.322,81	81,05%	R\$ 21.644.400,00	75,76%	336	36,13%	301.059	81,18%
77	42.883,90	82,03%	R\$ 21.933.000,00	76,77%	337	36,24%	305.067	82,27%
78	43.445,00	83,22%	R\$ 22.221.600,00	77,78%	338	36,34%	309.075	83,35%
79	44.006,20	84,27%	R\$ 22.510.200,00	78,79%	338	36,34%	313.084	84,43%
80	44.567,30	85,35%	R\$ 22.798.800,00	79,80%	338	36,34%	317.092	85,51%
81	45.128,50	86,42%	R\$ 23.087.400,00	80,81%	337	36,24%	321.100	86,59%
82	45.689,70	87,50%	R\$ 23.376.000,00	81,82%	337	36,24%	325.108	87,67%
83	46.250,80	88,57%	R\$ 23.664.500,00	82,83%	338	36,34%	329.116	88,75%
84	46.811,90	89,65%	R\$ 23.953.100,00	83,84%	336	36,13%	333.124	89,83%

85	47.373,10	90,72%	R\$ 24.241.700,00	84,85%	336	36,13%	337.133	90,91%
86	47.934,30	91,79%	R\$ 24.530.300,00	85,86%	337	36,24%	341.141	91,99%
87	48.495,40	92,87%	R\$ 24.818.900,00	86,87%	338	36,34%	345.149	93,07%
88	49.056,50	93,94%	R\$ 25.107.500,00	87,88%	338	36,34%	349.158	94,16%
89	49.617,70	95,02%	R\$ 25.396.100,00	88,89%	338	36,34%	353.166	95,24%
90	50.178,90	96,09%	R\$ 25.684.700,00	89,90%	337	36,24%	357.174	96,32%
91	50.740,00	97,17%	R\$ 25.973.300,00	90,91%	337	36,24%	361.182	97,40%
92	51.301,20	98,24%	R\$ 26.261.900,00	91,92%	338	36,34%	365.190	98,48%
93	51.837,80	99,27%	R\$ 26.550.500,00	92,93%	466	50,11%	368.832	99,46%
94	52.076,70	99,73%	R\$ 26.839.000,00	93,94%	701	75,38%	370.243	99,84%
95	52.144,10	99,86%	R\$ 27.127.300,00	94,95%	801	86,13%	370.540	99,92%
96	52.174,00	99,91%	R\$ 27.415.600,00	95,96%	804	86,45%	370.641	99,95%
97	52.191,90	99,95%	R\$ 27.704.500,00	96,97%	874	93,98%	370.720	99,97%
98	52.203,50	99,97%	R\$ 27.993.200,00	97,98%	902	96,99%	370.769	99,98%
99	52.211,10	99,98%	R\$ 28.282.000,00	98,99%	918	98,71%	370.796	99,99%
100	52.219,10	100,00%	R\$ 28.570.600,00	100,00%	930	0,25%	370.831	100,00%

Fonte: Elaborada pelo autor.