



UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE
PRODUÇÃO

ARMIN KOENIG

PREVISÃO DE DEMANDA EM SÉRIES TEMPORAIS
INTERMITENTES MEDIANTE A UTILIZAÇÃO DO MÉTODO
DE CROSTON

FLORIANÓPOLIS, SC

2014

Armin Koenig

**PREVISÃO DE DEMANDA EM SÉRIES TEMPORAIS
INTERMITENTES MEDIANTE A UTILIZAÇÃO DO MÉTODO
DE CROSTON**

Dissertação submetida ao Programa de Pós-graduação em Engenharia da Produção da Universidade Federal de Santa Catarina para a obtenção do Grau de Mestre em Engenharia da Produção.

Orientador: Prof. Robert Wayne Samohyl, Ph. D.

Florianópolis, SC

2014

Koenig, Armin

Previsão de Demanda em Séries Temporais Intermitentes Mediante a Utilização do Método de Croston / Armin Koenig; orientador, Robert Wayne Samohyl – Florianópolis, SC - 2014

192 p.

Dissertação (Mestrado) – Universidade Federal de Santa Catarina, Centro Tecnológico, Programa de Pós-Graduação em Engenharia de Produção.

Inclui Referências

1. Engenharia de Produção. 2. Demanda intermitente. 3. Método de Croston. 4. Estoque. I. Samohyl, Robert Wayne. II. Universidade Federal de Santa Catarina. Programa de Pós-Graduação em Engenharia de Produção. III. Título.

Armin Koenig

**PREVISÃO DE DEMANDA EM SÉRIES TEMPORAIS
INTERMITENTES MEDIANTE A UTILIZAÇÃO DO MÉTODO
DE CROSTON**

Esta Dissertação foi julgada adequada para obtenção do Título de “Mestre em Engenharia da Produção”, e aprovada em sua forma final pelo Programa de Pós-graduação em Engenharia da Produção.

Florianópolis, 22 de dezembro de 2014.

Prof^a Lucila Maria de Souza Campos, Dr^a.

Coordenadora do Curso

Banca Examinadora:

Prof. Robert Wayne Samohyl, Ph.D.

Orientador

Universidade Federal de Santa Catarina

Prof.^a Lucila Maria de Souza Campos, Dr.^a

Universidade Federal de Santa Catarina

Prof^a Andréa Cristina Konrath, Dr^a.

Universidade Federal de Santa Catarina

Prof. Guilherme Luz Tortorella, Dr.

Universidade Federal de Santa Catarina

Este trabalho é dedicado a minha família, a todos os companheiros que partilharam desta jornada e aos meus pais Arno e Alice (in memoriam)

AGRADECIMENTOS

A minha esposa, Maria Teresinha, companheira de tantos anos.

As minhas filhas, Thais e Graziela, fonte de inspiração para as conquistas de cada dia.

A todos os meus irmãos, irmãs e sobrinhos, que me incentivaram e apoiaram ao longo da jornada.

Ao Prof. Robert Wayne Samohyl, pelo apoio, disponibilidade e orientações no decorrer do curso,

A Prof^ª Lucila Maria de Souza Campos pelas instruções claras para o bom êxito deste trabalho.

A Rosimeri Maria de Souza, secretária do Programa de Pós-graduação em Engenharia de Produção, pelo atendimento sempre cortês e prestativo.

Aos professores da UFSC pelos ensinamentos transmitidos neste tempo em que aqui estudei.

Aos colegas mestrandos e doutorandos com os quais pude compartilhar, além das disciplinas, experiências profissionais e de vida.

Ao CNPq pelo auxílio financeiro valioso, em um momento difícil da minha vida.

Ao SER SUPREMO, por todas as dádivas recebidas.

“Comece fazendo o necessário, depois faça o que é possível, e de repente estarás fazendo o que parecia impossível.”

(São Francisco de Assis, 1182-1226).

RESUMO

A suavização exponencial tem sido um método clássico empregado na previsão de demanda e fornece bons resultados quando a série temporal é cheia, isto é, há ocorrência de demanda em todos os períodos. Mas quando a série apresenta comportamento intermitente, as demandas nulas (zeros) afetam o desempenho do método da suavização exponencial. Neste cenário, o método de Croston, desenvolvido em 1972, responde de forma mais assertiva. Vários estudos sucederam o trabalho pioneiro apresentado por Croston, focando na busca das menores discrepâncias entre o previsto e o observado. O objetivo central deste trabalho é aplicar o Método de Croston em séries temporais intermitentes e observar os possíveis ganhos, frente a outros métodos, oriundos da previsão de demanda. Nos objetivos específicos busca-se: a) investigar a formulação do Método de Croston; b) investigar métodos alternativos que surgiram a partir do método original proposto por Croston; c) confrontar estes métodos, próprios para demanda intermitente, com métodos tradicionais de previsão de demanda; d) utilizar ferramentas acessíveis de previsão, com vistas à aplicação em pequenas empresas. São apresentadas e utilizadas medidas de discrepância próprias para séries intermitentes e que balizam a escolha de um método de previsão sobre outro. Potenciais ganhos na previsão da demanda foram avaliados. A partir destes ganhos, um melhor nível de serviço e conseqüente nivelamento do estoque mereceram análise. Os resultados obtidos mostram que nem sempre o método de Croston ou suas variantes tem desempenho superior aos demais métodos de previsão consagrados na literatura, principalmente quando comparados com a suavização exponencial. Isto denota a importância de se testar diversos métodos até se encontrar aquele que melhor responda ao comportamento da série temporal, seja ela intermitente em baixa, média ou alta intensidade.

Palavras-chave: Demanda intermitente. Método de Croston. Estoque.

ABSTRACT

The exponential smoothing has been a classic method used to forecast demand and provides good results when the time series is full, that is, there is demand to occur in all periods. But when the series presents intermittent behavior, null demands (zeros) affect the performance of the exponential smoothing method. In this scenario, the Croston method, developed in 1972, responds more assertively. Several studies followed the pioneering work presented by Croston, focusing on the search of the smallest discrepancies between predicted and observed. The central objective of this work is to apply the Croston's method on intermittent time series and watch the possible gains, compared to other methods, arising from the demand forecast. In the specific goals we seek to: a) investigate the formulation of Croston's method; b) investigate alternative methods that have emerged from the original method proposed by Croston; c) To compare these methods, suitable for intermittent demand, with traditional demand forecasting methods; d) use available tools for forecasting, in order to apply them in small businesses. Forecasting error measures are presented and are used to select whether one method has more potential over another. Potential gains in forecasting demand were evaluated. From those gains, a better level of service and consequent stock leveling deserved analysis. The results show that not always the Croston's method or its variants have superior performance to other forecasting methods established in the literature, especially when compared with the exponential smoothing. This shows the importance of testing different methods until you find the one that best responds to the behavior of the time series, whether intermittent in low, medium or high intensity.

Keywords: Intermittent demand. Croston's method. Inventory.

LISTA DE FIGURAS

Figura 01 – Método da suavização exponencial simples aplicada para a produção de petróleo (em milhões de toneladas) na Arábia Saudita – 1996 a 2007 (HYNDMAN et al., 2013).....	40
Figura 02 – Criação de ovelhas na Ásia entre 1970 e 2000 – comportamento da tendência (nível e crescimento) (HYNDMAN et al., 2013).....	46
Figura 03 – Criação de ovelhas na Ásia - previsões com diferentes métodos, enfatizando a tendência amortecida (<i>damped trend</i>) (HYNDMAN et al., 2013).....	47
Figura 04 – As quatro etapas propostas por Box na execução da metodologia ARIMA.....	52
Figura 05 – Classificação da intermitência das séries temporais (segundo SYNTETOS et al, 2005).....	56
Figura 06 – Intervalos de previsão, com diferentes métodos, sobre série intermitente (SHENSTONE et al., 2005).....	68
Figura 07 – Exemplo de série intermitente, com cálculo da previsão ingênua e DAM dentro da amostra.....	73
Figura 08 – Lote econômico de compra (LEC) – exemplo hipotético...76	
Figura 09 – Fluxograma da metodologia proposta – investigação do melhor método de previsão e ajuste do estoque.....	91
Figura 10 – Componente Kit pistola – demanda e intermitência (zeros) ao longo do tempo.....	95
Figura 11 – Kit pistola – a série apresenta erro aditivo, tendência e sazonalidade.....	95
Figura 12 – Kit pistola – demanda real (demandas nulas foram suprimidas).....	96
Figura 13 – Kit pistola – intervalo entre as demandas (períodos = meses).....	97
Figura 14 – Kit pistola – Comparativo entre o Método MS3M e Método NNQ-STAT - fora da amostra - seis períodos à frente.....	101
Figura 15 – Comparativo: Método TS6 versus Método SB5 - fora da amostra - seis períodos à frente.....	102

Figura 16 – Kit pistola – Método TS6 com previsões de seis períodos à frente.....	102
Figura 17 – Kit pistola – previsões sobre a série original – métodos MS3M e TS6.....	103
Figura 18 – Kit pistola – demanda últimos 12 meses, com média e desvio padrão.....	105
Figura 19 – Kit pistola – <i>Lead time</i> (tempo de ressurgimento) e sua estatística descritiva.....	106
Figura 20 – Kit pistola – desvio padrão entre demanda planejada e demanda real.....	107
Figura 21 – Kit pistola – Cálculo do estoque de segurança para nível de serviço 95%.....	108
Figura 22 – Kit pistola – estoque máximo proposto.....	109
Figura 23 – Kit pistola – Nível de serviço desejado versus real – para atendimento a 95%.....	110
Figura 24 – Meio filtrante – série temporal com 36 dados.....	111
Figura 25 – Componente Meio filtrante – demanda e intermitência (zeros) ao longo do tempo.....	112
Figura 26 – Meio filtrante – a série apresenta erro e sazonalidade aditivas.....	112
Figura 27 – Meio filtrante – demanda real (demandas nulas foram suprimidas).....	113
Figura 28 – Meio filtrante – intervalo entre as demandas (períodos = meses).....	114
Figura 29 - Meio filtrante - Previsão com Média Simples 3 Meses e Holt-Winters (NNQ-STAT) - fora da amostra - seis períodos à frente.....	118
Figura 30 - Meio filtrante - Previsão com Holt-Winters e SES - fora da amostra - seis períodos à frente.....	119
Figura 31 – Meio filtrante – Previsão por SES – 6 passos à frente....	
Figura 32 – Meio filtrante – MS3M versus SES – comportamento previsões (36 meses).....	122
Figura 33 – Meio filtrante – demanda últimos 12 meses, com média e desvio padrão.....	123

Figura 34 – Meio filtrante – Lead time médio e desvio padrão.....	124
Figura 35 – Meio filtrante – desvio padrão entre demanda planejada e demanda real.....	125
Figura 36 – Meio filtrante – Cálculo do estoque de segurança (ES) para nível de serviço 98%.....	126
Figura 37 – Meio filtrante – estoque máximo proposto.....	126
Figura 38 – Meio filtrante – Nível de serviço desejado versus real – para atendimento a 98%.....	127
Figura 39 – Kit Pistola e Meio Filtrante – readequação dos estoques de segurança e máximo.....	128
Figura 40 – Sensor de oximetria neonatal – comportamento da série temporal – demanda ao longo de 55 semanas.....	130
Figura 41 – Sensor de oximetria – decomposição da série – 55 dados..	131
Figura 42 – Sensor de oximetria neonatal – análise das demandas.....	131
Figura 43 – Sensor neonatal – Demandas reais (demandas nulas foram suprimidas do histograma).....	132
Figura 44 – Sensor neonatal – histograma dos intervalos entre demandas.....	133
Figura 45 – Sensor de oximetria – Previsão com seis passos à frente – Método MS3S versus Método Holt-Winters.....	137
Figura 46 – Sensor de oximetria – Previsão com seis passos à frente – Método de Holt versus SES.....	138
Figura 47 – Sensor neonatal – Previsão com 6 passos à frente, utilizando SES.....	138
Figura 48 – Sensor neonatal - Comparação entre os métodos MS3S e SES – previsões no conjunto de 55 dados.....	142

LISTA DE TABELAS

Tabela 01 – Combinações possíveis entre tendência e sazonalidade (conforme GARDNER, 2006).....	48
Tabela 02 – Série testada por J. D. Croston em 1972 – resumo estatístico.....	61
Tabela 03 – Kit pistola - Conjunto amostral: ferramentas, métodos e coeficientes utilizados.....	98
Tabela 04 – Kit pistola - Conjunto amostral – Predições - Comparativo entre o método do cliente e os métodos do estudo.....	100
Tabela 05 – Kit pistola – desempenho dos métodos MS3M e TS6 – predições sobre a série original (36 dados).....	103
Tabela 06 – Meio filtrante – Conjunto amostral: ferramentas, métodos e coeficientes utilizados.....	116
Tabela 07 – Meio filtrante – predições no conjunto amostral - comparativo entre o método do cliente e os métodos do estudo.....	117
Tabela 08 – Meio filtrante – Previsão fora do conjunto amostral - redução das discrepâncias – comparação entre os métodos.....	120
Tabela 09 – Meio filtrante – Predições sobre a série completa (36 meses) - Comparativo entre o método da Empresa P (MS3M) e a SES.....	122
Tabela 10 – Sensor de oximetria – ferramentas, métodos e coeficientes utilizados no conjunto amostral (49 dados).....	135
Tabela 11 – Sensor de oximetria – Predições no conjunto amostral (49 dados) – Acurácia dos métodos.....	136
Tabela 12 – Sensor neonatal – Previsão fora do conjunto amostral – seis períodos à frente – análise das discrepâncias – comparação entre os métodos.....	139
Tabela 13 – Sensor neonatal – Predições sobre a série original – Método MS3S versus SES – comparativo das acurácias.....	141
Tabela 14 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – RQDQM.....	143
Tabela 15 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – DAM.....	143

Tabela 16 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – AIC.....	144
Tabela 17 – Sensor Neonatal – resultado da previsão, aplicando SES, com diferentes constantes de suavização (α).....	144
Tabela 18 – Kit pistola – resultados comentados.....	146
Tabela 19 – Meio filtrante – resultados e comentários.....	149
Tabela 20 – Sensor neonatal – demonstração dos resultados.....	151

LISTA DE ABREVIATURAS E SIGLAS

α – (alfa) – constante de suavização

ADI - Intervalo da demanda média (*Average Demand Interval*)

AIC – *Akaike's Information Criterion*.

AR - Auto regressivo (AR)

ARIMA – Auto regressivo integrado de médias móveis (*Auto Regressive Integrated Moving Average*)

ARMA - modelo Auto regressivo e de Médias Móveis

CT - Custo total

CTE - Custo total de estocagem

CTP - Custo total dos pedidos

CV - coeficiente de variação

DAM - Desvio absoluto médio

DM – Desvio médio

DPAM Discrepância percentual absoluta média

DQM – Discrepância quadrada média

DS - Sistema de Demanda (*Demand System*)

ERP – Software para o planejamento da produção e compra de materiais (*Enterprise Requirement Planning*)

ES - Estoque de segurança

ETS – Erro + tendência + sazonalidade

EWMA - Média móvel exponencialmente ponderada (*Exponentially Weighted Moving Average*)

FS - Sistema de Previsão (*Forecasting System*)

JIT – Entrega programada de materiais (*Just in Time*)

LEC - Lote econômico de compra

MA - modelo de Médias Móveis

MASE – Desvio médio absoluto escalar (*Mean Absolute Scaled Error*)

MS3M - Média simples dos últimos 3 meses

MS3S - Média simples das últimas três semanas

NNQ-STAT- *Software estatístico* desenvolvido pelo Núcleo de Normalização e Qualimetria da UFSC

NS - Nível de serviço

R - *Software estatístico R*

RQDQM - Raiz quadrada do desvio quadrado médio

SBA – Método de previsão de demanda desenvolvido por Syntetos & Boylan (*Syntetos-Boylan Approximation*)

SES - Suavização exponencial simples

U – U de Theil

UTI – Unidade de terapia intensiva

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO	29
1.1 APRESENTAÇÃO DO PROBLEMA	29
1.2 OBJETIVOS DO TRABALHO	30
1.2.1 Objetivo geral	30
1.2.2 Objetivos específicos	30
1.3 JUSTIFICATIVA E IMPORTÂNCIA DO TRABALHO	31
1.4 ESTRUTURA DO TRABALHO	32
CAPÍTULO 2 – FUNDAMENTAÇÃO TEÓRICA	35
2.1 MÉTODO DA MÉDIA SIMPLES.....	36
2.2 MÉTODOS DE SUAVIZAÇÃO EXPONENCIAL.....	37
2.2.1 Suavização exponencial simples (SES)	38
2.2.2 Método de Holt	40
2.2.3 Método de Holt-Winters	42
2.2.4 Métodos com tendência amortecida	44
2.2.5 Classificação dos métodos de suavização exponencial	47
2.3 MODELOS ARIMA E A ABORDAGEM DE BOX E JENKINS..	49
2.3.1. Modelos Auto Regressivos e de Médias Móveis	49
2.3.2. Modelo de Box e Jenkins	51
2.4 A DEMANDA INTERMITENTE E SEUS MÉTODOS DE PREVISÃO.....	53
2.4.1 A magnitude do problema da demanda intermitente	53
2.4.2 Como classificar a demanda intermitente?	54
2.4.3 O método de Croston	56
2.4.4 As modificações propostas por Syntetos e Boylan	62
2.4.5 A proposta de Levén e Segerstedt	65
2.4.6 O método proposto por Teunter e Sani	66

2.4.7 O estudo de Shenstone e Hyndman	67
2.5 MEDIDAS DE DISCREPÂNCIA	68
2.5.1 Discrepância Média	69
2.5.2 Discrepância quadrada média	70
2.5.3 Discrepância absoluta média	71
2.5.4 Discrepância absoluta escalar média	71
2.6 GESTÃO DE ESTOQUES	73
2.6.1 O estoque e suas características básicas	74
2.6.2 Sistemas de revisão de estoques	77
2.6.3 Estoque de segurança e nível de serviço	81
2.7 CONSIDERAÇÕES FINAIS	84
CAPÍTULO 3 – METODOLOGIA PROPOSTA	87
3.1 MODELOS DE PREVISÃO SELECIONADOS	87
3.2 O CÁLCULO DA CONSTANTE DE SUAVIZAÇÃO	88
3.3 APLICAÇÃO DA METODOLOGIA	89
CAPÍTULO 4 - APLICAÇÃO DA METODOLOGIA PROPOSTA EM CASOS PRÁTICOS	93
4.1 A EMPRESA DO SEGMENTO INDUSTRIAL	93
4.1.1 Breve Histórico	93
4.1.2 Componente Kit Pistola	94
4.1.3 Componente Meio Filtrante	94
4.1.4 Aplicação da metodologia para o kit pistola	94
4.1.5 Aplicação da metodologia para o meio filtrante	111
4.2 A EMPRESA DO SEGMENTO HOSPITALAR	128
4.2.1 Breve Histórico	128
4.2.2 Componente Sensor Neonatal	129
4.2.3 Aplicação da metodologia para o sensor neonatal	130
4.3 DISCUSSÃO DOS RESULTADOS	145

4.3.1 Kit pistola.....	145
4.3.2 Meio filtrante.....	147
4.3.3 Sensor Neonatal.....	150
CAPÍTULO 5 – CONCLUSÃO.....	153
5.1 SUPERIORIDADE NÃO CONFIRMADA.....	153
5.2 SUGESTÕES PARA TRABALHOS FUTUROS.....	155
REFERÊNCIAS BIBLIOGRÁFICAS.....	157
APÊNDICE A – Equações utilizadas em suavização exponencial.....	167
APÊNDICE B – Nível de serviço e desvio padrão normalizado, calculado em planilha eletrônica.....	168
APÊNDICE C – Kit Pistola – Procurando a melhor constante de suavização (α) para a série, aplicando o Método de Croston.....	169
APÊNDICE D – Kit pistola – tabela resumo do Apêndice C - valores de RQDM e DAM para 30 simulações geradas no R.....	170
APÊNDICE E – Meio filtrante – Procurando a melhor constante de suavização (α) para a série.....	171
APÊNDICE F – Meio filtrante – tabela resumo de α otimizado.....	172
APÊNDICE G – Sensor neonatal – Procurando a melhor constante de suavização (α) para a série.....	173
APÊNDICE H – Sensor neonatal – tabela resumo de α otimizado....	174
APÊNDICE I – Kit pistola – a série temporal (36 meses) e sua estatística descritiva.....	175
APÊNDICE J – Kit pistola – intervalo médio entre as demandas e o coeficiente de variação da série.....	176
APÊNDICE K – Kit pistola (série com 30 dados) – previsões calculadas pelos métodos: ARIMA, HW, Holt, SES, SES(OT), CR-D e CR-Z – utilizando o software R.....	177
APÊNDICE L – Kit pistola (30 dados) – Previsão pelo Método SB5, com $\alpha = 0,10$.....	179

APÊNDICE M – Kit pistola (30 dados) – Previsão pelo Método TS6, com $\alpha = 0,10$	180
APÊNDICE N – Kit pistola (30 dados) – Previsão pelo Método NNQ-STAT, que resultou no modelo AAdA.....	181
APÊNDICE O – Componente Meio Filtrante – a série temporal e sua estatística descritiva.....	182
APÊNDICE P – Meio filtrante – métodos de previsão: ARIMA, SES, SES(OT), Holt, HW, CR-D e CR-Z, mediante utilização do software R.....	183
APÊNDICE Q – Meio filtrante – cálculo da previsão mediante o Método SB5, com horizonte de um a seis passos à frente.....	185
APÊNDICE R – Meio filtrante – aplicação do Método TS6, gerando previsões de um a seis períodos à frente.....	186
APÊNDICE S – Meio filtrante – cálculo da previsão mediante o Método Holt-Winters (A, N, A), mediante o uso da ferramenta NNQ-STAT, com horizonte de um a seis passos à frente.....	187
APÊNDICE T – Sensor neonatal (ou de oximetria) – a série temporal (com 55 dados) e sua estatística descritiva.....	188
APÊNDICE U – Sensor neonatal – utilização do software R para o cálculo das previsões, nos seguintes métodos: SES, SES(OT), Holt, CR-D e CR-Z.....	189
APÊNDICE V – Sensor neonatal – Previsão com horizonte de seis períodos à frente, pelo Método SB5.....	190
APÊNDICE W – Sensor neonatal – Previsão com horizonte de seis períodos à frente, pelo Método TS6.....	191
APÊNDICE X – Sensor de oximetria (neonatal) – cálculo da previsão mediante a utilização do software NNQ-STAT, com horizonte de um a seis passos à frente.....	192

CAPÍTULO 1 – INTRODUÇÃO

1.1 APRESENTAÇÃO DO PROBLEMA

Diante da atual conjuntura mundial, a economia, cada vez mais globalizada, é impulsionada pelo avanço tecnológico e traz como consequência um mercado cada vez mais competitivo. Nesse cenário, as empresas estão em busca constante de melhorias em seus processos que lhe permitam atender do melhor modo aos seus clientes. Tais necessidades compreendem a oferta de produtos com qualidade e capacidade de entrega eficiente. No entanto, muitas vezes, as empresas não dispõem dessa capacidade exigida devido a uma gama de clientes com necessidades diferenciadas. Procurando diminuir ao máximo a distância entre a oferta e a demanda, e assim evitar o descontentamento de seus clientes, as grandes indústrias estão voltando a sua atenção para a utilização de ferramentas que permitam a tomada de decisões em torno da programação de produção, dentre as quais merecem destaque os métodos de previsão de demanda.

O presente trabalho procura ir além das simples previsões, investigando um campo ainda mais difícil para as empresas: a demanda intermitente. A demanda intermitente assola tanto a área de Vendas, quanto a Produção, Manutenção e Controle dos estoques. Com este objetivo o trabalho é direcionado para a demanda intermitente de produtos fabricados ou comprados em empresas de pequeno e médio porte.

Na década de 60, a série temporal com demandas nula, isto é, ausência de demanda em alguns períodos (diário, semanal, mensal, trimestral, anual) era analisada pelo método da suavização exponencial. Contudo, este método é mais robusto para séries cheias, com dados em todos os períodos. J. D. Croston (1972) trouxe à luz uma nova metodologia que resultasse em previsões mais confiáveis, sobrepujando desta maneira a suavização exponencial.

Os dados para este trabalho vieram de duas empresas de médio porte do Norte Catarinense. A Empresa P (nome fictício) é fabricante de sistemas de pintura industrial e colaborou com dois componentes, fornecendo dados de demanda dos últimos trinta e seis meses (Maio 2010 a Abril 2013). Já a Empresa H (também nome fictício) atua no

segmento da saúde – como hospital privado - e ofertou um componente cuja demanda é semanal, sendo a série temporal composta por cinquenta e cinco semanas (2011 a 2012). Todas as três séries apresentam demanda intermitente, em maior ou menor intensidade.

A metodologia empregada aplica um total de dez métodos de previsão e os compara com a prática atual das empresas. Tanto a Empresa P quanto a Empresa H, quando muito, valem-se da média simples das últimas três demandas. Dentre os dez métodos se espera encontrar um que gere a melhor previsão possível para a empresa. Ainda, para a Empresa P é realizada uma análise do inventário em função do custo unitário e do volume demandado, anualmente, destes dois componentes.

Como medidas de acurácia das predições e previsões, três indicadores consagrados na literatura serão utilizados:

RQDQM: Raiz quadrada do desvio quadrado médio;

DAM: Desvio absoluto médio;

MASE (*Mean Absolute Scaled Error*), que pode ser traduzido por Desvio Médio Absoluto Escalar. Neste trabalho, será mantida a sigla MASE, dada a sua popularidade no âmbito das previsões. Estas três medidas são apropriadas para séries temporais intermitentes, não tendo seus resultados afetados por demandas nulas (zeros).

1.2 OBJETIVOS DO TRABALHO

1.2.1 Objetivo Geral

Aplicar o Método de Croston em séries temporais intermitentes e observar os possíveis ganhos, frente a outros métodos, oriundos da previsão de demanda.

1.2.2 Objetivos Específicos

Para o desenvolvimento do objetivo geral é necessário o estudo dos objetivos específicos citados a seguir:

- Investigar a formulação do Método de Croston;
- Investigar métodos alternativos que surgiram a partir do método original proposto por Croston;
- Confrontar estes métodos, próprios para demanda intermitente, com métodos tradicionais de previsão de demanda.
- Observar possíveis ganhos nas previsões;
- Utilizar ferramentas acessíveis de previsão, com vistas a aplicação em pequenas empresas.
- De posse das melhores previsões, investigar o balanceamento dos estoques em dois componentes industriais.

1.3 JUSTIFICATIVA, IMPORTÂNCIA E LIMITAÇÕES

Duas empresas do Norte Catarinense gentilmente cederam os dados de três componentes – dois industriais e um hospitalar - que apresentam demanda intermitente. Atualmente, ambas as empresas possuem softwares de gestão, que auxiliam no gerenciamento diário de Vendas, Produção, Manutenção, Estoques e Expedição. Na Empresa P, o software entrega algumas informações úteis na gestão de estoques, entre elas, a média do consumo (quantidade de peças requisitadas) nos últimos três períodos (meses). O profissional responsável pelos estoques e novas compras utiliza esta e outras informações adicionais para decidir se emitirá um pedido ou não. Não há um horizonte de previsão estabelecido, tal qual: três ou seis ou doze meses à frente. Na Empresa H, o software também fornece este dado, mas ele não é considerado. A decisão de repor o estoque do componente ocorre após a ‘inspeção visual’ do técnico responsável na área de Manutenção no próprio inventário (gavetas). Portanto, percebe-se que há alguma tecnologia da informação disponível, mas ela não é plenamente utilizada.

Sugerir um método de previsão que permita enxergar três ou seis períodos à frente – e que traga ganhos financeiros e confiança aos usuários é a proposta principal deste trabalho. A importância do mesmo está no fato de testar diversos métodos, com o intuito de encontrar a melhor resposta para a demanda nestas três séries temporais intermitentes.

Ao longo do Capítulo 4 será demonstrado que os três componentes, objetos deste estudo, apresentam comportamento intermitente e que para estas o Método de Croston e variantes deste deveriam produzir as melhores previsões. Mas, esta é uma suposição que deverá ser comprovada, pois apenas três séries de dados são insuficientes para indicar se o Método de Croston é realmente superior a outros métodos de previsão ou não. Deste modo, a principal limitação do trabalho reside na pequena base de dados disponível, onde se compara Croston com outros métodos de previsão.

1.4 ESTRUTURA DO TRABALHO

Este trabalho estrutura-se em cinco capítulos. O primeiro capítulo, já apresentado anteriormente, é uma introdução, abordando as dificuldades encontradas em cada empresa, os objetivos, justificativas e importância do mesmo, e por fim, os resultados esperados.

No segundo capítulo, será apresentada uma revisão / resumo da literatura dos métodos de previsões a serem utilizados neste trabalho, e também uma apresentação das três importantes medidas de discrepâncias de previsões (RQDQM, DAM e MASE). Uma quarta medida, o DM – Desvio Médio - será incluído em todos os cálculos e tabelas, mas não terá caráter decisório. Servirá apenas para dar uma ideia de sub ou superestimação.

No terceiro capítulo é apresentada a metodologia a ser utilizada, confrontando a prática de previsão de demanda corrente nas duas empresas com métodos mais elaborados: Croston e suas variantes, suavização exponencial e outros. Seis etapas básicas serão cumpridas e uma sétima, alternativa, somente para a Empresa P. Ainda, a busca de uma constante de suavização – alfa – que aperfeiçoe a previsão fará parte deste capítulo.

No quarto capítulo, serão apresentadas as séries temporais dos três componentes e respectivas estatísticas descritivas. A seguir, a aplicação dos métodos de previsões ‘dentro da amostra’, com a ajuda de softwares computacionais (*R* e *NNQ-STAT*), gerando as ‘predições’ e validando os melhores modelos a escolher. Por fim, os três melhores modelos de previsão obtidos nas predições (sobre o conjunto de dados chamado ‘dentro da amostra’) serão submetidos à previsão de seis períodos à frente e comparados com os dados da série ‘fora da amostra’.

Novamente, o principal foco serão os indicadores de acurácia, que deverão ser os menores possíveis. Disto resultará o modelo de previsão com o melhor desempenho e será sugerido para implantação nas empresas participantes.

No quinto e último capítulo serão apresentadas as conclusões referentes aos resultados obtidos e sugestões para trabalhos futuros.

Ao término desta introdução, onde foram descritos os objetivos, importância, limitações e estrutura do trabalho, segue-se para a revisão da literatura, tema central do Capítulo 2.

CAPÍTULO 2 - FUNDAMENTAÇÃO TEÓRICA

Este capítulo está estruturado em três grandes blocos:

a) Abordagem da literatura que trata dos métodos de previsão de séries temporais, com ênfase nos métodos desenvolvidos para a demanda intermitente.

b) Investigação das medidas de discrepância que tem a função de indicar quanto determinada previsão se aproxima do realizado, isto é, acurácia do método de previsão. O enfoque será nas medidas apropriadas para séries temporais intermitentes.

c) Gestão de estoques: conceitos e equações dos métodos tradicionais para controle do estoque de segurança e nível de serviço.

Sendo o foco deste trabalho a previsão sobre demanda intermitente, podem-se classificar os métodos de previsão em dois grupos:

- Métodos de previsão adequados para séries temporais contínuas, isto é, sem demandas nulas e,
- Métodos de previsão específicos para demandas intermitentes.

Mas esta linha limítrofe não é estanque e permite que o pesquisador experimente diferentes métodos sem se apegar em demasia ao fato da intermitência. E esta também será a tônica neste trabalho, analisando um leque de dez diferentes métodos de previsão, tanto cobrindo o campo da intermitência quanto da não intermitência. Espera-se que as medidas de discrepância revelem os melhores métodos para cada série temporal, indicando as melhores acurácias.

A revisão da literatura abordará os seguintes métodos univariados de previsão:

- Média simples,
- Suavização exponencial simples,
- Método de Holt, para séries que apresentam tendência,
- Método de Holt-Winters, que além da tendência ainda engloba a sazonalidade,
- Método de Box-Jenkins, mais conhecido por ARIMA;
- Método de Croston, desenvolvido especificamente para séries temporais com demanda intermitente.

- Métodos de Croston modificados: serão introduzidas variantes ao Método de Croston, que podem ser classificadas como ‘otimizações’ deste.

Em seguida, será apresentada a classificação dos métodos de suavização exponencial, abordando erro, tendência e sazonalidade, o que resulta na sigla mais conhecida por ETS. Esta classificação será útil no desenrolar deste trabalho.

Na continuidade, seis indicadores de acurácia para séries temporais serão abordados:

- Discrepância média (DM),
- Raiz quadrada da discrepância quadrada média (RQDQM),
- Discrepância absoluta média (DAM),
- Discrepância absoluta escalar média (MASE),
- Discrepância percentual absoluta média (DPAM) e,
- U de Theil (U).

Uma breve abordagem sobre logística, administração de estoques e níveis de serviço encerra este capítulo. Este tema será útil no estudo dos dois componentes da Empresa P, pois, além das previsões de demanda, há um interesse em avaliar-se o comportamento atual do estoque e o que pode ser aperfeiçoado na gestão deste.

2.1 MÉTODO DA MÉDIA SIMPLES

A principal característica da previsão por média simples é que todas as observações da série são utilizadas para o cálculo da média, isto é, a previsão para o próximo período. Esta busca pela média acaba atribuindo o mesmo peso ($1/n$), a todas as observações. A equação da previsão, com horizonte de um período à frente, é dada por:

$$P_{n+1} = \frac{1}{n} \sum_{t=1}^n O_t \quad (1)$$

onde:

P_{n+1} = previsão de um período à frente,

O_t = valor observado,

t = intervalo de tempo (hora, dia, semana, mês, trimestre, etc.).

n = número de observações.

Para exemplificar, apresenta-se uma série com 20 observações ($n = 20$). Nota-se que cada observação passada contribuirá com um peso de: $1/20 = 0,05$. Considerando a previsão de um período à frente (P_{21}), se teria:

$$P_{21} = 0,05P_1 + 0,05P_2 + 0,005P_3 + \dots + 0,05P_{20}$$

É fácil perceber que este método não enfatiza as observações mais recentes, atribuindo pesos iguais tanto aos valores mais antigos quanto aos novos. Samohyl, Souza e Miranda (2008), além de enfatizarem esta distribuição uniforme dos pesos para cada dado observado, ainda alertam de que o Método da Média Simples não é adequado para séries que contenham tendência e sazonalidade.

Outra restrição que o Método da Média Simples (total ou dos últimos períodos) apresenta é a sua capacidade de prever somente um ‘passo à frente’, isto é, previsão de um período à frente. Para se prever três, quatro ou seis meses à frente, o pesquisador precisa valer-se de um artifício denominado ‘rolagem’. A rolagem consiste, a partir do segundo período à frente, incluir o primeiro período previsto na composição da média. Já para o terceiro período, toma-se o último dado observado da série (P_{t0} e se adiciona os dois dados previstos (períodos P_{t+1} e P_{t+2}). Assim, $P_{t+3} = (P_{t0} + P_{t+1} + P_{t+2}) / 3$. Nota-se que para o quarto período à frente – e daí em diante – a previsão passa a ser a ‘previsão sobre as médias’, o que torna estas previsões bastante frágeis.

2.2 MÉTODOS DE SUAUIZACÃO EXPONENCIAL

Estes métodos utilizam apenas as observações da própria série de dados, não dependendo de nenhuma variável externa para fazer previsões. Esta é uma das vantagens de se utilizar estas metodologias. A previsão é feita de forma rápida, pois não é preciso buscar outras informações externas.

Os métodos de suavização exponencial consistem em decompor a série em componentes (tendência e sazonalidade) e suavizar seus valores passados, ou seja, dar pesos diferenciados, cujos valores decaem

exponencialmente para zero quanto mais antiga for a observação, portanto, dando mais peso e valorizando as observações mais recentes. Já no método de previsão por média simples, todas as observações passadas recebem o mesmo peso.

2.2.1 – Suavização Exponencial Simples (SES)

A suavização exponencial é uma técnica que pode ser aplicada aos dados de uma série temporal, seja para produzir dados suavizados para uma apresentação, ou para fazer previsões. A própria série em si contém toda a sequência de observações no tempo. O fenômeno pode ser observado essencialmente como um processo aleatório ou ser um processo ordenado, porém com ruído. Como já comentado, na média móvel simples as observações passadas são ponderadas igualmente, enquanto na suavização exponencial os pesos atribuídos vão diminuindo ao longo do tempo. A suavização exponencial é comumente aplicada para o mercado financeiro e dados econômicos, mas pode ser utilizada com qualquer conjunto discreto de medições repetidas. A sequência dos dados brutos é muitas vezes representada por $\{x_t\}$ e a saída do algoritmo de amortecimento exponencial é geralmente escrita como $\{s_t\}$, que pode ser considerada como a melhor estimativa para o próximo valor de x . Quando a sequência de observações começa no tempo $t = 0$, a forma mais simples de suavização exponencial é dada pelas fórmulas:

$$s_0 = x_0, \quad t = 0 \quad (2)$$

$$s_t = \alpha x_{t-1} + (1 - \alpha)s_{t-1}, \quad t > 0 \quad (3)$$

onde α é o *fator de suavização*, e $0 < \alpha < 1$.

- **A média móvel exponencial**

A suavização exponencial foi primeiramente sugerida por Robert Goodell Brown em 1956, e em seguida, expandida por Charles C. Holt em 1957. A formulação seguinte, que é a vulgarmente utilizada, é atribuída a Brown e é conhecida como "Suavização exponencial simples

de Brown". A forma mais simples de amortecimento exponencial é dada pela equação (3), onde α é a constante de suavização e seu valor varia entre zero e um. Em outras palavras, a estatística de suavização s_t é uma média ponderada simples da observação anterior x_{t-1} e a estatística de suavização anterior s_{t-1} .

O *fator de suavização*, termo aplicado aqui à alfa (α) tem os seguintes efeitos: valores maiores de α efetivamente reduzem o nível de suavização, e no caso limite com $\alpha = 1$ a série resultante é da mesma forma como a série original (com defasagem de uma unidade de tempo), isto é, torna-se uma previsão ingênua. Os valores de α perto de um tem menos efeito de alisamento (suavização) e dão maior peso às mudanças recentes nos dados, enquanto que os valores de α mais próximo de zero tem um efeito de alisamento maior e são menos sensíveis às mudanças recentes. Não existe um procedimento formalmente correto para a escolha de α . Às vezes, o julgamento do estatístico é usado para escolher um fator apropriado. Alternativamente, uma técnica estatística pode ser usada para 'aperfeiçoar' o valor de α . Por exemplo, o Método dos Mínimos Quadrados pode ser usado para determinar o valor de α para o qual a soma das quantidades de $(s_{n-1} - x_{n-1})^2$ é minimizada. De forma geral, a constante de suavização α oscila entre 0,05 e 0,30, faixa onde produz as melhores suavizações. A suavização exponencial simples é facilmente aplicada, e tão logo duas observações estejam disponíveis, a estatística suavizada (s_t) será produzida.

Ao contrário de alguns outros métodos de suavização, essa técnica não exige um número mínimo de observações a serem feitas antes de começar a produzir resultados. Na prática, no entanto, uma "boa média", não será atingida até várias amostras formarem um bom conjunto médio, por exemplo, um sinal constante levará aproximadamente $3/\alpha$ fases para atingir 95% do valor real. Para reconstruir o sinal original com precisão, sem perda de informação de todos os estágios da média móvel exponencial, todos os valores devem estar disponíveis, inclusive os mais velhos, porque todos participam do decaimento exponencial com algum peso. Isto está em contraste com uma média simples, em que algumas amostras possam ser ignoradas (valores nulos ou ausentes, por exemplo) sem perda de informações, devido ao peso constante de amostras dentro da média. Se um número conhecido de amostras for perdido, pode-se ajustar a uma média ponderada para estes, bem como, dando o mesmo peso para as novas amostras e a todas aquelas a serem ignoradas.

Esta forma simples de suavização exponencial também é conhecida como Média Móvel Exponencialmente Ponderada (EWMA – *Exponentially Weighted Moving Average*). A Figura 01, extraída de Hyndman e Athanasopoulos (2013), apresenta uma previsão com três períodos à frente ($h = 3$) para a produção de petróleo na Arábia Saudita. Nota-se que a série tem variação na média, mas não se observa tendência e nem sazonalidade. Adotando-se três valores para a constante de suavização: $\alpha = 0,2$; $\alpha = 0,6$ e $\alpha = 0,89$ (aperfeiçoado mediante o Método dos Mínimos Quadrados), se obtém diferentes previsões e previsões (ver linhas azul, vermelha e verde). É fácil perceber que $\alpha = 0,89$ proporcionou as menores discrepâncias entre o predito (linha verde) e o observado (linha preta), no período de 1996 a 2007.




Figura 01– Método da suavização exponencial simples aplicada para a produção de petróleo (em milhões de toneladas) na Arábia Saudita – 1996 a 2007. Fonte: Hyndman & Athanasopoulos (2013)

2.2.2 Método de Holt

A suavização exponencial simples não desempenha adequadamente quando há ‘tendência’ presente nos dados (série temporal) (NIST, 2003). A tendência envolve ‘nível’ e ‘crescimento’,

que não são captadas corretamente pela SES. Samohyl, Souza e Miranda (2008) demonstram de forma gráfica, para uma série temporal contendo tendência, como a SES subestima as previsões (modelo ajustado) – sempre com valores menores que o observado – mesmo com a utilização da constante de suavização bastante elevada, isto é, $\alpha = 0,99$ (p. 139). A SES não consegue boas previsões na presença da tendência porque lhe falta um componente na fórmula. Foi Holt (1957) quem sugeriu uma segunda constante de suavização a ser incorporada na fórmula da SES de modo a considerar a presença da tendência linear. O Método de Holt será apresentado a seguir. O Método de Holt funciona da seguinte forma: considerar o ‘nível’ e o ‘crescimento’ da série temporal. O nível é o cálculo do valor atual da série (onde a série está em um determinado período) e o crescimento é o quanto a série vai crescer a partir daquele período (SAMOHYL, 2008). A equação que representa o nível (n_t), tal como na SES, é uma combinação entre o observado e o previsto no tempo t :

$$n_t = \alpha O_t + (1 - \alpha) \frac{(n_{t-1} + c_{t-1})}{\text{tendência}} \quad (4)$$

Já o crescimento (c_t), que representa a diferença entre níveis sequenciais, é dado pela Equação (4):

$$c_t = \beta \frac{(n_t - n_{t-1})}{\text{crescimento}} + (1 - \beta) c_{t-1} \quad (5)$$

Notar que $\alpha + \beta = 1$, devendo estas duas constantes variar entre 0,01 e 0,99. A constante de suavização α exprime o nível e a constante β exprime o crescimento da série. Disto, a combinação de (4) e (5) resulta na equação (6), própria para a suavização exponencial de séries com tendência linear, com previsão de k períodos à frente:

$$P_{t+k} = n_t + k \cdot c_t \quad (6)$$

Um segundo método, conhecido como suavização exponencial linear ou de Brown (SEL) ou suavização exponencial dupla de Brown funciona da seguinte forma (DUKE, 2011):

$$s'_0 = x_0 \quad (7)$$

$$s''_0 = x_0 \quad (8)$$

$$s'_t = \alpha x_t + (1 - \alpha)s'_{t-1} \quad (9)$$

$$s''_t = \alpha s'_t + (1 - \alpha)s''_{t-1} \quad (10)$$

$$F_{t+m} = a_t + mb_t \quad (11)$$

onde a_t é o nível estimado no tempo t e b_t é a tendência estimada no tempo t , são dados por:

$$a_t = 2s'_t - s''_t \quad (12)$$

$$b_t = \frac{\alpha}{1-\alpha} (s'_t - s''_t) \quad (13)$$

2.2.3 – Método de Holt-Winters

O Método de Holt-Winters foi sugerido por Peter Winters, em 1960. Estudante de Charles Holt, Winters estendeu o método deste para lidar com o caso de dados com sazonalidade. Alguns chamam este método de Suavização Exponencial Tripla, mas, popularmente, o método ficou conhecido como Holt-Winters e passou a possuir três equações:

- uma para ajuste do nível n_t (equação 4),
- outra para ajuste do crescimento c_t (equação 5),
- e outra para a sazonalidade s_t (equação 16).

O método possui duas formas, uma com sazonalidade aditiva e outra multiplicativa. Para a sazonalidade aditiva, o desenvolvimento das

fórmulas foi adaptado de Samohyl (2008). A equação (4), que define o nível n_t , pode ser reescrita como:

$$n_t = \underbrace{\alpha(O_t - s_{t-m})}_{\text{observado sem sazonalidade}} + \underbrace{(1 - \alpha)(P_t - s_{t-m})}_{\text{ajustado sem sazonalidade}} \quad (14)$$

A sazonalidade aditiva detém a seguinte equação:

$$s_t = \gamma(O_t - n_{t-1} - c_{t-1}) + (1 - \gamma)s_{t-m} \quad (15)$$

onde m representa o ciclo. O ciclo pode se apresentar de diferentes modos: mensal ($m = 12$), trimestral ($m = 4$) [pois há quatro trimestres no ano], quadrimestral ($m = 3$). A equação acima pode ser reescrita como:

$$s_t = \underbrace{\gamma(O_t - n_{t-1} - c_{t-1})}_{\text{índice sazonal observado}} + \underbrace{(1 - \gamma)(P_t - n_{t-1} - c_{t-1})}_{\text{índice sazonal ajustado}} \quad (16)$$

Agrupando as equações (4), (7) e (8), obtém-se a equação geral da suavização exponencial na presença de tendência e sazonalidade aditiva:

$$P_{t+k} = \underbrace{n_t + k \cdot c_t}_{\text{tendência}} + s_{t-m+k} \quad (17)$$

onde k representa os períodos à frente (na previsão desejada). O método é chamado de aditivo porque a sazonalidade é somada à tendência da série, que por sua vez é a soma do nível com o crescimento.

Nota-se que agora três constantes de suavização estão presentes, a saber:

- α para o nível,
- β para o crescimento (tendência) e
- γ para a sazonalidade. Estas constantes variam entre 0,01 e 0,99.

Quanto à sazonalidade multiplicativa, suas equações serão descritas a seguir, para o nível n_t , o crescimento c_t e a sazonalidade s_t :

$$n_t = \underbrace{\alpha(O_t/s_{t-m})}_{\text{observado sem sazonalidade}} + \underbrace{(1-\alpha)(P_t/s_{t-m})}_{\text{ajustado sem sazonalidade}} \quad (18)$$

$$c_t = \beta \underbrace{(n_t - n_{t-1})}_{\text{crescimento}} + (1-\beta)c_{t-1} \quad (\text{ver equação 5})$$

$$s_t = \underbrace{\gamma(O_t/(n_{t-1} + c_{t-1}))}_{\text{índice sazonal observado}} + \underbrace{(1-\gamma)(P_t/(n_{t-1} + c_{t-1}))}_{\text{índice sazonal ajustado}} \quad (19)$$

A partir das equações (5), (18) e (19) obtém-se a equação da suavização exponencial contemplando a sazonalidade multiplicativa:

$$P_{t+k} = \underbrace{(n_t + k \cdot c_t)}_{\text{tendência}} \cdot s_{t-m+k} \quad (20)$$

É recomendado que o horizonte das previsões feitas com estes métodos (Holt-Winters aditivo ou multiplicativo) não ultrapasse o ciclo sazonal da série, pois as previsões com um horizonte maior tendem a ser pouco precisas (SAMOHYL, 2008).

2.2.4 Métodos com tendência amortecida

As previsões geradas pelo método linear de Holt exibem uma tendência constante (aumentando ou diminuindo) indefinidamente no futuro. Ainda mais extremas são as previsões geradas pelo método de tendência exponencial que incluem tanto o crescimento exponencial ou seu declínio.

A evidência empírica indica que estes métodos tendem para o excesso de previsão, especialmente para longos horizontes de previsão. Motivado por esta observação, Gardner e McKenzie (1985) introduziram um parâmetro que "amortece" a tendência para uma linha reta em algum momento no futuro. Métodos que incluem tendência amortecida (*damped trend*) têm provado serem muito bem sucedidos e

são, indiscutivelmente, os métodos individuais mais populares quando as previsões são geradas automaticamente para muitas séries. Há dois métodos a serem apreciados:

a) Método com tendência amortecida aditiva

Em conjunto com as constantes de suavização α e β (cujos valores oscilam entre 0 e 1, como visto no Método de Holt), este método inclui ainda um parâmetro de ‘amortecimento’ φ (fi), oscilando entre 0 e 1 ($0 < \varphi < 1$). As equações a seguir foram extraídas de Hyndman e Athanasopoulos (2013):

$$\hat{y}_{t+h|t} = l_t + (\varphi + \varphi^2 + \dots + \varphi^h)b_t \quad (21)$$

$$l_t = \alpha \cdot y_t + (1 - \alpha)(l_{t-1} + \varphi \cdot b_{t-1}) \quad (22)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta) \cdot \varphi \cdot b_{t-1} \quad (23)$$

Se $\varphi = 1$, então o método é idêntico ao método da tendência linear de Holt. Para valores entre 0 e 1, o coeficiente φ amortece a tendência de modo que se aproximará de uma constante em algum período futuro. De fato, as previsões convergem para $l_T + \varphi \cdot b_T / (1 - \varphi)$ quando $h \rightarrow \infty$ para qualquer valor $0 < \varphi < 1$. O efeito disto é que as previsões de curto prazo conterão a variação da tendência, enquanto que no longo prazo a tendência se tornará constante.

b) Método com tendência amortecida multiplicativa

Inspirado nas melhorias obtidas nas previsões com o método da tendência aditiva, Taylor propôs, em 2003, um parâmetro de amortecimento ao método de tendência, focando o aspecto multiplicativo desta. As equações que regem o Método com Tendência Amortecida Multiplicativa serão descritos a seguir e foram extraídas de Hyndman e Athanasopoulos (2013):

$$\hat{y}_{t+h|t} = l_t b_t^{(\varphi + \varphi^2 + \dots + \varphi^h)} \quad (24)$$

$$l_t = \alpha y_t + (1 - \alpha) \cdot l_{t-1} \cdot b_{t-1}^\varphi \quad (25)$$

$$b_t = b_{t-1}^\varphi + \alpha\beta \frac{e_t}{l_{t-1}} \quad (26)$$

A seguir, um exemplo gráfico de previsão realizado com os dois métodos, pertinente à criação de ovelhas na Ásia, entre 1970 e 2000 – e com um horizonte de previsão de dez anos à frente. A Figura 02 mostra o comportamento da tendência (linear e aditiva amortecida). Já a Figura 03 apresenta as previsões com diferentes métodos e as linhas de cor azul claro e rosa são as de interesse (tendência aditiva amortecida e tendência multiplicativa amortecida). Notar que a linha vermelha (SES) resultou em previsões fracas – gerando uma linha bem abaixo quando comparada aos demais métodos. Isto comprova que a SES não desempenha adequadamente na presença de tendência e/ou sazonalidade.

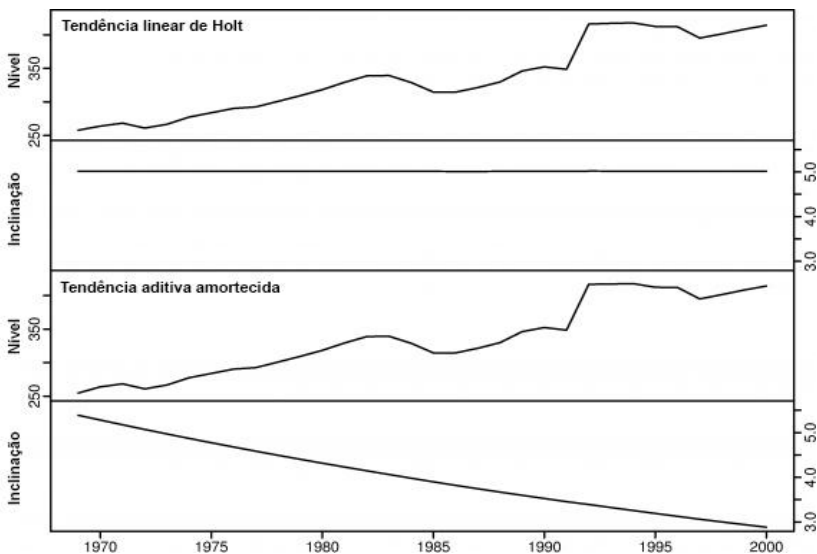


Figura 02 – Criação de ovelhas na Ásia entre 1970 e 2000 – comportamento da tendência (nível e crescimento). Fonte: Hyndman & Athanasopoulos, 2013.




Figura 03 – Criação de ovelhas na Ásia - previsões com diferentes métodos, enfatizando a tendência amortecida (*damped trend*). Fonte: Hyndman & Athanasopoulos, 2013.

2.2.5 Classificação dos métodos de suavização exponencial

Como visto na seção anterior, há dois componentes básicos na suavização exponencial: a tendência e a sazonalidade. Mas como estas podem apresentar-se de diversas maneiras, foi proposto por Hyndman et al (2002) uma nomenclatura que permitisse reunir numa tabela as diversas combinações possíveis. O Apêndice A contém as equações clássicas dos métodos de suavização exponencial, sendo todas extensões do trabalho de Brown (1959, 1963), Holt (1957), e Winters (1960). Esta tabela foi adaptada de Miranda (2009) com base em Gardner (2006). As equações tradicionais foram usadas nos trabalhos originais de Brown e Holt e ainda hoje são amplamente utilizadas. A classificação desenvolvida por Hyndman, Koehler, Snyder, e Grose (2002), e expandida por Taylor (2003), é útil na descrição dos métodos. Cada método recebe uma ou duas letras para a ‘tendência’ (na tabela veja as linhas) e uma letra para a ‘sazonalidade’ (veja as colunas). Por exemplo, o Método N-N denota: sem tendência e sem sazonalidade, isto é, a suavização exponencial simples (Brown, 1959). Os outros métodos não sazonais são: tendência aditiva (A-N) (Holt, 1957), tendência aditiva amortecida (DA-N) (Gardner e McKenzie, 1985), tendência

multiplicativa (M-N) (Pegels, 1969) e a tendência multiplicativa amortecida (DM-N), estudada por Taylor (2003a). Para os métodos sazonais, todos são formulados a partir de Winters (1960) e implicam em: sazonalidade aditiva e sazonalidade multiplicativa. Observar que as equações para os métodos sazonais são válidas somente para um horizonte de previsão (m) menor ou igual ao comprimento do ciclo sazonal (p). Com os cinco possíveis formatos da tendência, associados às três possibilidades da sazonalidade, têm-se 15 combinações possíveis, conforme tabela abaixo.

Tabela 01 – Combinações possíveis entre tendência e sazonalidade, conforme Gardner, 2006.

Componente: Tendência	Componente: Sazonalidade		
	N (não há)	A (aditiva)	M (multiplicativa)
N (não há)	N-N	N-A	N-M
A (aditiva)	A-N	A-A	A-M
DA (aditiva amortecida)	DA-N	DA-A	DA-M
M (multiplicativa)	M-N	M-A	M-M
DM (multiplicativa amortecida)	DM-N	DM-A	DM-M

Hyndman *et al.* (2002) não separaram a tendência amortecida em aditiva e multiplicativa. Simplesmente a classificaram como ‘tendência amortecida’. Com isto, suas combinações se reduzem a 12 possibilidades. Como para cada um dos 12 métodos existem dois modelos estado-espaco, sendo que um corresponde ao erro aditivo e outro ao erro multiplicativo, então o total de combinações possíveis sobe para 24 métodos. Tanto o modelo ‘aditivo’ quanto o modelo ‘multiplicativo’ produzem os mesmos pontos médios de previsão, porém, diferentes intervalos de previsão e verossimilhança.

A partir destas 24 combinações possíveis, os autores propuseram um método automático de previsão que, para cada série temporal o software testa os 24 modelos e indica o ‘mais adequado’. Como ele faz isto? Os autores usam como métrica o *AIC – Akaike’s Information Criterion*. Teoricamente, o menor valor de AIC corresponde ao melhor método a ser utilizado no cálculo das previsões.

Samohyl, Souza e Miranda (2008) desenvolveram técnica semelhante no seu software NNQ-STAT, sendo possível testar automaticamente a série temporal frente aos diversos métodos. A exemplo do software estatístico R, o NNQ-STAT também retorna os melhores métodos baseado no AIC, informando um conjunto de três ou quatro letras: erro, tendência e sazonalidade (ETS). Por exemplo, o menor AIC para M-A-M significa que a série temporal (univariada) apresenta: erro multiplicativo, tendência aditiva e sazonalidade multiplicativa e pode fornecer a melhor previsão com a adoção do método de Holt-Winters (sazonalidade multiplicativa).

2.3 MODELOS ARIMA E A ABORDAGEM DE BOX E JENKINS

Durante a década de 1960 os professores George E. P. Box e Gwilyn M. Jenkins escreveram diversos trabalhos sobre a teoria de controle e análise de séries temporais. Em 1970 publicaram o livro *Time Series Analysis: forecasting and control* apresentando uma metodologia para a análise de séries temporais e em 1976 foi lançada a versão revisada desse livro e que normalmente é a mais mencionada. O grande mérito desse trabalho foi reunir as técnicas existentes numa metodologia para construir modelos que descrevessem com precisão e de forma parcimoniosa o processo gerador da série temporal, proporcionando dessa forma previsões acuradas de valores futuros.

2.3.1. Modelos Auto Regressivos e de Médias Móveis

Wheelwright e Makridakis (1985) descrevem três procedimentos capazes de representar as observações de uma série temporal estacionária: modelo *Auto Regressivo* (AR), modelo de *Médias Móveis* (MA) e o modelo *Auto Regressivo e de Médias Móveis* (ARMA).

a) Modelo Auto regressivo

A especificação de um modelo Auto Regressivo (AR) é dada pela equação:

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + e_t \quad (27)$$

Onde:

x_t corresponde à observação da série temporal no tempo t ;

ϕ_p corresponde ao parâmetro do modelo AR de ordem p e

e_t representa o erro de eventos aleatórios que não podem ser explicados pelo modelo.

Caso as observações da série temporal possam ser representadas pela equação (28), a ordem do modelo puder ser determinada e os parâmetros estimados, é possível prever o valor futuro da série em análise.

b) Modelo de Médias Móveis

Um modelo de Médias Móveis (MA) fica definido conforme a equação:

$$x_t = e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (28)$$

onde:

e_t representa o erro de eventos aleatórios que não podem ser explicados pelo modelo e,

θ_q corresponde ao parâmetro do modelo MA de ordem q .

A equação (28) é similar à equação (27), exceto pelo fato de que o valor previsto para a observação α depende dos valores dos erros observados em cada período passado, ao invés das observações propriamente ditas (MUELLER, 1996).

c) Modelo Auto regressivo e de Médias Móveis

Wheelwright e Makridakis (1985) especificam o modelo misto Auto Regressivo e de Médias Móveis (ARMA) por meio da equação (29), como sendo a combinação dos modelos AR e MA.

$$x_t = \phi_1 x_{t-1} + \phi_2 x_{t-2} + \dots + \phi_p x_{t-p} + e_t - \theta_1 e_{t-1} - \theta_2 e_{t-2} - \dots - \theta_q e_{t-q} \quad (29)$$

Analisando a equação (29) é possível verificar que os modelos ARMA relacionam os valores futuros com as observações passadas, assim como também com os erros passados apurados entre os valores reais e os previstos.

2.3.2. Modelo de Box e Jenkins

O destaque atribuído ao modelo de George Box e Gwilyn Jenkins (BOX, 1976), que também pode ser incluído nesta classificação, é devido principalmente a sua fundamentação teórica, sendo a princípio capaz de manipular séries temporais de qualquer natureza, contendo ou não tendência e sazonalidade.

O método de Box e Jenkins consiste na busca de um modelo ARIMA (*Auto Regressive Integrated Moving Average*) que represente o processo estocástico gerador da série temporal, a partir de um modelo ARMA aplicável na descrição de séries temporais estacionárias, estendendo esse conceito para séries temporais não estacionárias (NELSON, 1973).

Genericamente, um processo ARIMA (p, d, q) pode ser representado pela equação (30):

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + e_t - \theta_1 e_{t-1} - \dots - \theta_q e_{t-q} \quad (30)$$

sendo: $w_t = x_t - x_{t-d}$

onde:

ϕ_p e θ_q são os parâmetros dos processos Auto regressivo e de Média Móvel de ordem p e q (ARMA (p, q));

e_t corresponde ao erro de eventos aleatórios que não podem ser explicados pelo modelo e

d equivale ao grau de homogeneidade não estacionária.

De acordo com Box (1976), a estratégia para construção de um modelo ARIMA envolve uma abordagem iterativa que pode ser sumarizada conforme ilustra a Figura 04.

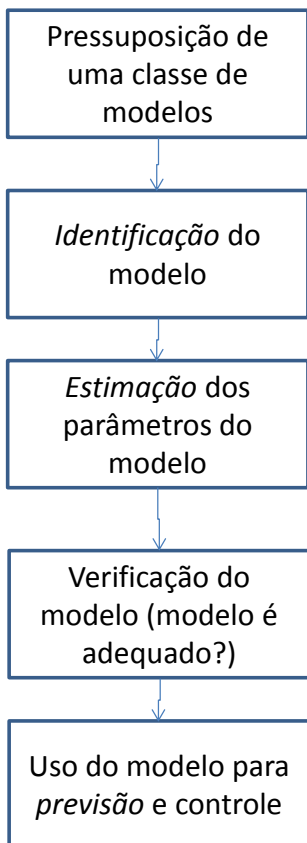


Figura 04 – As quatro etapas propostas por Box na execução da metodologia ARIMA.

O objetivo da *identificação* é determinar os valores de p , d e q do modelo ARIMA (p, d, q) . Inicialmente, a série temporal X^T é diferenciada para se obter uma série estacionária. Com isso, o processo fica reduzido a um modelo ARMA (p, q) . Em seguida, a ordem do processo ARMA é identificada pela análise dos coeficientes de auto correlação e auto correlação parcial. Ainda nesta etapa são efetuadas estimativas preliminares dos parâmetros do modelo identificado.

Após a identificação do modelo que seja uma representação adequada do mecanismo gerador da série, a *estimação* dos parâmetros

desse modelo é efetuada. Judge (1988) coloca que os parâmetros do processo AR são estimados através de métodos de regressão; caso o processo MA esteja envolvido, a estimação dos parâmetros deste modelo é obtida pela aplicação de algum algoritmo de otimização não linear.

Estimado o modelo, a *verificação* de sua habilidade em representar os fenômenos observáveis da série temporal é confirmada pela análise dos erros do modelo proposto. Caso a inadequação fique evidenciada, o ciclo de identificação, estimação e verificação é novamente aplicado, até que a representação apropriada seja encontrada.

Após a validação do modelo, a *previsão* dos valores futuros da série temporal modelada pode, enfim, ser obtida.

Em termos computacionais, o *software R* contém uma função denominada '*auto.arima*', que executa vários cálculos e informa os valores (p, d, q) automaticamente, economizando tempo ao pesquisador.

2.4 A DEMANDA INTERMITENTE E SEUS MÉTODOS DE PREVISÃO

2.4.1 A magnitude do problema da demanda intermitente

Demanda intermitente é uma série de valores aleatórios que aparecem em intervalos aleatórios, deixando muitos períodos sem demanda (SILVER, 1981).

Na maioria das pesquisas de previsão, e quase todos os softwares comerciais de previsão de demanda existentes, o pressuposto é que a demanda é "suave" (contínua) em vez de intermitente. No entanto, os planejadores de produção e gerentes de estoques frequentemente se deparam com demanda intermitente (WATSON, 1987; TAVARES e ALMEIDA, 1983). Quando existe demanda intermitente, os benefícios de soluções computadorizadas para previsões são ilusórios (SMART, 2002). E existe uma boa razão para tanto. Os métodos tradicionais de previsão não funcionam bem porque a demanda intermitente normalmente contém uma grande percentagem de valores iguais à zero –

vinte por cento ou mais – e com os valores diferentes de zero distribuídos aleatoriamente.

A literatura inclui apenas um número relativamente pequeno de soluções propostas para este problema de previsão (CROSTON, 1972; RAO, 1973; JOHNSTON, 1980; WILLIAMS, 1982 e 1984; WRIGHT, 1986; SCHULTZ, 1987; DUNSMUIR e SNYDER, 1989; SYNTETOS e BOYLAN, 2001 e 2005; TEUTNER e SANI, 2006).

Métodos tradicionais de previsão estatística – como os de suavização exponencial ou de médias móveis – que funcionam bem com demanda normal, regular, não apresentam resultados precisos com dados intermitentes porque ignoram o papel especial dos valores iguais a zero e das características especiais de dados intermitentes, ao efetuar a análise e estimativa da demanda. Além do mais, esses métodos tradicionais assumem que a curva de distribuição da demanda total para um produto particular em um determinado tempo de ressuprimento (*lead time*) corresponde a uma curva de distribuição normal.

Demanda intermitente é comumente encontrada nos segmentos de peças de reposição das indústrias: aeroespacial, automotiva, de alta tecnologia, eletrônica, infra-estrutura e equipamentos industriais. É também encontrada em empresas que fabricam bens de capital de altíssimo valor unitário e, em alguma extensão, no varejo. Em pesquisa realizada nos EUA, em 2001, observou-se que os gastos com peças de reposição representaram cerca de oito por cento (8%) do produto interno bruto americano (SMART, 2002). Em função do volume financeiro que o segmento de peças de reposição representa é fácil se perceber o interesse das empresas em exercer um melhor controle sobre seus estoques e política de compras.

2.4.2 Como classificar a demanda intermitente?

Para determinar e comparar as técnicas de previsão de demanda, onde os dados contém zeros esporádicos, é importante entender a natureza desta esporadicidade (ALTAY, 2008).

Regattieri (2005) apresenta uma classificação bastante interessante para a natureza intermitente da demanda, extraída de Ghobbar e Friend, 2002:

- Demanda lenta movendo-se sem grande variação nos intervalos entre as demandas e nas quantidades requisitadas.
- Demanda estritamente intermitente, sem variações extremas nas quantidades, mas com a demanda ausente em muitos períodos de tempo.
- Demanda errática é altamente irregular em escala (quantidades), mas com melhor consistência nos intervalos entre requisições.
- Demanda protuberante (em inglês, *lumpy*) apresenta consumo zero em muitos períodos de tempo, mas, quando a demanda ocorre, as quantidades geralmente são significativas, isto é, há grande variabilidade nestas.

Williams (1984) dissecou a variabilidade (variância) da demanda em variância do tamanho das ordens (quantidades) e variância dos tempos de ressurgimento (lead time). Expandindo a ideia de Williams, Syntetos desenvolveu um esquema de categorização com base no intervalo da demanda média (ADI – *Average Demand Interval*) e o coeficiente de variação (CV), calculado utilizando apenas valores de demanda não zero (SYNTETOS, 2001; SYNTETOS et al, 2005). A Figura 05 mostra este quadro, no qual foram mantidos os verbetes em língua inglesa, especialmente para *lumpy demand*.

Johnston e Boylan investigaram o nível de ADI quando o método de Croston supera o método EWMA – Média Móvel Exponencialmente Ponderada (JOHNSTON e BOYLAN, 1996). Eles relataram que o método de Croston é superior ao método EWMA quando o ADI é maior do que 1,25. Isto essencialmente traduz-se a uma série de dados com 20% de zeros. Syntetos (2001) move este gatilho para ADI = 1,32 na sua categorização, o que corresponde a 24,4% de zeros na série. Mas, de modo geral, prevalece o valor ADI = 1,25 – proposto por Johnston & Boylan – como o divisor de águas entre séries não intermitentes e intermitentes (GARDNER, 2006).

Regattieri et al. (2005) apontam a fórmula para o cálculo do CV:

$$CV = \frac{\sqrt{\sum_{t=1}^n (y_t - \mu)^2 / n}}{\mu} \quad (31)$$

onde:

n = número de períodos;

y_i = demanda no período i ;

μ = demanda média de todos os períodos.

Originalmente, pode-se definir CV como o quociente entre o desvio padrão (σ) e a média (μ) do conjunto de dados, isto é: $CV = \sigma/\mu$.

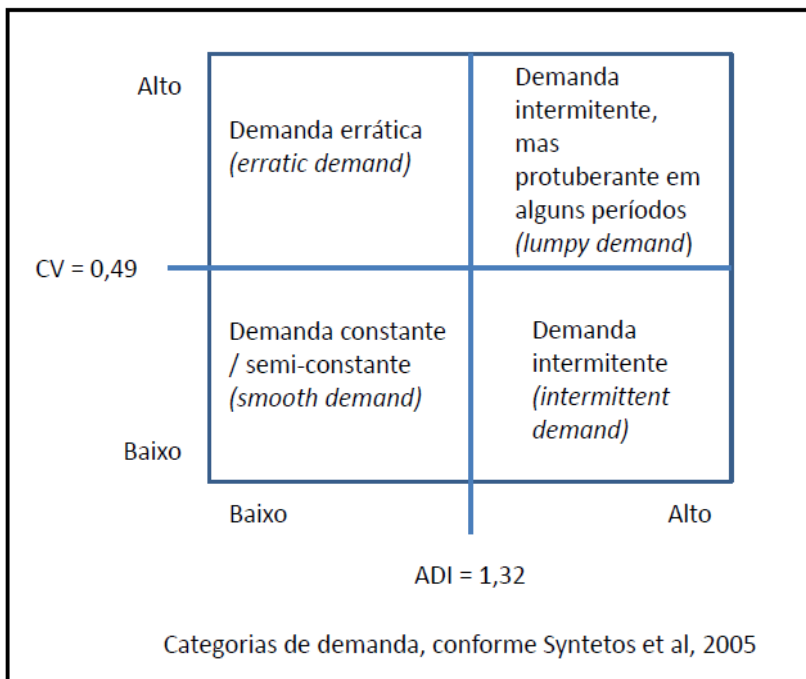


Figura 05 – Classificação da intermitência das séries temporais, segundo Syntetos et al, 2005.

2.4.3 O método de Croston

Croston (1972) publicou o trabalho pioneiro no que tange à previsão de demanda para componentes ou eventos que apresentem comportamento irregular. Ele propôs um novo método: aplicar a

suavização exponencial sobre a demanda (z) e separadamente sobre o intervalo entre demandas (p). Depois, dividir z por p , obtendo a previsão da demanda (z^*), isto é: $z^* = z/p$. Afirmava que tal procedimento eliminaria o viés causado pela única suavização exponencial aplicada sobre a série temporal. Portanto, o método de Croston significa executar a suavização exponencial tanto sobre a demanda (quantidades) quanto sobre o intervalo entre as demandas (períodos) e depois obter o quociente entre estas, resultando na previsão de demanda (quantidade por período).

Para formular este novo método, Croston valeu-se de quatro suposições, que serão analisadas a seguir.

- a) Intervalo entre as demandas: considerou-o como um processo estacionário e a distribuição como sendo iid, isto é, independente e identicamente distribuída.
- b) Demanda: considerou-a como um processo de Bernoulli, isto é, tem/não tem demanda (processo binário). Deve ser estacionária e ser iid normal, isto é, com distribuição normal.
- c) Relação entre Intervalo e Demanda: devem ser independentes entre si.
- d) Tamanho da demanda (quantidades requisitadas): deve ter média μ , variância σ^2 e apresentar distribuição normal.

Para uma melhor comparação entre o método da suavização exponencial e o método de Croston, uma notação deve ser estabelecida (WILLEMAIN et al, 1994):

x_t = indicador binário de demanda no tempo t ;

z_t = tamanho da demanda;

$y_t = x_t \cdot z_t$ = demanda para um item no tempo t ;

μ = média da demanda, quando esta não é nula;

σ_2 = variância da demanda, quando esta não é nula;

p = número médio de períodos (de tempo) entre as demandas;

α = coeficiente de suavização

y'_t = estimativa da demanda média para o período (suavização exponencial);

y^* = estimativa da demanda imediatamente após a ocorrência de uma demanda (suavização exponencial);

q = intervalo de tempo desde a última demanda;

p_t'' = estimativa do intervalo médio entre demandas (Croston);

z_t'' = estimativa média do tamanho da demanda (Croston);

y_t'' = estimativa média da demanda por período.

Quando a demanda é estável, a meta dos métodos de previsão é estimar a demanda média por período, μ/p .

Em situações reais, nem sempre a série é estacionária. É comum os dados apresentarem tendência e foi esta constatação que motivou Wright (1986) a desenvolver uma modificação no método de Holt. Este método calcula uma linha de tendência, por meio da suavização exponencial. Esta característica do método o torna um bom candidato a ser aplicado na previsão em séries que são intermitentes e ao mesmo tempo apresentam tendência.

- **Suavização exponencial:**

A seguir, uma análise mais detalhada da suavização exponencial frente à previsão de estoques. A cada período de revisão do estoque, quer no período tenha havido demanda ou não, o método da suavização exponencial fará a seguinte atualização:

$$y'_t = y'_{t-1} + \alpha(y_t - y'_{t-1}) \quad (32)$$

Croston demonstrou que estas estimativas contém 'viés para cima' em dois casos:

a) Quando uma demanda constante de tamanho μ ocorre regularmente a cada p períodos, a demanda estimada por período, de forma segura, não é $y^* = \mu/p$, mas sim:

$$y^* = \left(\frac{\mu}{p}\right) \left\{ \frac{p\alpha}{[1 - (1 - \alpha)^p]} \right\} \quad (33)$$

b) Quando a demanda é aleatória, com média μ e variância σ^2 , e tem a probabilidade de Bernoulli $1/p$ de ocorrer em qualquer período de revisão, a estimativa feita justamente após a ocorrência de uma demanda produz um valor esperado com viés:

$$E\{y^*\} = \left(\frac{\mu}{p}\right) \left\{ \frac{\alpha + (1 - \alpha)}{p} \right\} \quad (34)$$

e variância

$$V\{y^*\} = \alpha^2 \sigma^2 + \left[\frac{\alpha(1 - \alpha)^2}{(2 - \alpha)} \right] \left[\frac{(p - 1)\mu^2}{p^2} + \frac{\sigma^2}{p} \right] \quad (35)$$

• **A formulação de Croston:**

O método de Croston executa, separadamente, duas suavizações exponenciais. Primeiramente, utiliza a suavização exponencial simples sobre a demanda, estimando a demanda média futura. Em seguida, aplica a suavização exponencial simples sobre o intervalo entre as demandas, estimando o intervalo médio futuro. O método atualiza as estimativas após a ocorrência de demanda. Se não ocorrer demanda no espaço entre uma revisão do período e outra (período t), o método somente incrementa a contagem dos períodos desde a última demanda. Para que fosse possível esta contagem dos períodos entre as demandas, Croston introduziu a variável q , que será explicada a seguir.

Têm-se então duas situações possíveis:

a) Se não houver demanda no período, isto é, $y_t = 0$:

$$z_t^* = z_{t-1}^* \quad (36)$$

$$p_t^* = p_{t-1}^* \quad (37)$$

$$q = q + 1 \quad (38)$$

b) Se houver demanda no período, isto é, $y_t \neq 0$:

$$z_t^* = z_{t-1}^* + \alpha(y_t - z_{t-1}^*) \quad (39)$$

$$p_t^* = p_{t-1}^* + \alpha(q - p_{t-1}^*) \quad (40)$$

$$q = 1 \quad (41)$$

Combinando a previsão do tamanho da demanda com a previsão do intervalo entre demandas, obtém-se a equação central proposta por Croston:

$$y_t^* = \frac{z_t^*}{p_t^*} \quad (42)$$

Estas estimativas (previsões) são atualizadas somente quando uma demanda ocorrer.

Notar também a variável q , conforme equações (38) e (41): se a cada período de revisão, digamos, ao final de cada mês, não se verificou demanda, a variável q vai crescendo (equação 38), até que uma demanda se confirme no período. Quando a demanda ocorrer, naturalmente a variável q assume o valor 1 (um), conforme atesta a equação (41). Esta foi a maneira que J. D. Croston encontrou para administrar os períodos sem demanda e permitir o uso da suavização exponencial.

Croston mostrou que o valor esperado da previsão, imediatamente após a ocorrência de demanda, não contém viés:

$$E\{y_t^*\} = \frac{\mu}{p} \quad (43)$$

e que a variância aproximada é:

$$V\{y_t^*\} = \left[\frac{\alpha}{(2 - \alpha)} \right] \left[\frac{(p - 1)^2 \mu^2}{p^4} + \frac{\sigma^2}{p^2} \right] \quad (44)$$

Esta variância (equação 44) é menor que a da suavização exponencial (equação 35). Quando a demanda ocorre em todos os períodos de revisão, isto é, a série se torna contínua, o método de

Croston passa a ser idêntico à suavização exponencial convencional, o que pode ser observado pelas equações (39), (40), (41) e (42).

• **A constante de suavização**

Tomando as equações (39) e (40) observa-se que o coeficiente de suavização α está presente nas duas equações, quer seja no tamanho da demanda (quantidade) quanto no intervalo entre demandas (tempo). O coeficiente α deve ser o mesmo para as duas equações, isto é, suavização da demanda e do intervalo? Ou convém utilizar coeficientes diferenciados? Croston ocupou-se deste tema, analisando trabalhos anteriores (HOLT, BROWN, WINTERS, WARD, HARRISON, BURGIN). Todos estes autores sugeriam $0,1 \leq \alpha \leq 0,2$ exceto o trabalho de Box & Jenkins, focando principalmente em preços de ações, que sugeria α mais próximo de 1,0. Croston então realizou suas previsões com cinco valores de α : 0,05; 0,1; 0,3; 0,6 e 1,0 – numa série intermitente com 180 dados. A estatística descritiva está demonstrada abaixo.

Tabela 02 – Série testada por J. D. Croston em 1972 – resumo estatístico.

Série testada por J. D. Croston	
Observações	180 dados
Intervalo médio entre as demandas	6 períodos de tempo
Demanda média	3,5 unidades
Desvio padrão da demanda	1,6 unidades
Máxima quantidade demandada	6 unidades
Mínima quantidade demandada	1 unidade

Fonte: Operational Research Quarterly, vol. 23, nº 3, p. 289-303, 1972

Ele concluiu que tanto para z_t (previsão da demanda), quanto para p_t (previsão do intervalo) a constante poderia ser a mesma e que os melhores resultados ocorreriam com $0,1 \leq \alpha \leq 0,3$. O autor estava interessado em três métricas: previsão da quantidade, desvio absoluto médio e nível de reposição (R) do estoque e os gráficos indicam que α

oscilando entre 0,1 a 0,3 produz os melhores resultados (p. 293). Somente para exemplificar, a função ‘croston’, no pacote “forecast” do *software estatístico R* adota como padrão – tanto para demanda quanto para intervalo, $\alpha = 0,10$.

2.4.4 As modificações propostas por Syntetos e Boylan

Em 2001, no trabalho intitulado *On the bias of intermittent demand estimates*, os autores A. A. Syntetos e J. E. Boylan argumentam que a formulação proposta por Croston em 1972 apresenta viés para cima, isto é, a previsão tende a carregar o estoque e diante disto propuseram uma modificação na equação deste.

Uma vez que o método de Croston não consegue produzir a estimativa de demanda (previsão) no período sem viés, os autores se propuseram a encontrar uma alternativa que satisfizesse o valor esperado na equação (33), repetida abaixo e mantida a notação já estabelecida:

$$E\{y_t^*} = \frac{\mu}{p} \quad (45)$$

E tal proposta traduz-se na equação (46):

$$E\{y_t^*} = E\{z_t^*} E\left(\frac{1}{p_t^* \cdot c^{p_t^*-1}}\right) = \frac{\mu}{p} \quad (46)$$

onde:

$c = \epsilon$ é uma constante. Teoricamente, c tem de ser infinitamente grande para permitir a Equação (46) ser verdadeira. Não obstante, o resultado é uma boa aproximação se c é suficientemente grande.

Portanto, com base no conceito de Croston de construir estimativas de demanda de eventos constituintes (demandas reais), os autores propuseram uma alternativa que, em teoria, elimina o viés na demanda associado à formulação de Croston. Quando a demanda ocorre, o comprimento do último intervalo entre demandas, p_t é registrado e o valor do quociente $1/p_t c^{p_t-1}$ é calculado. Consequentemente, tanto o

tamanho da demanda quanto $1/p_t c^{p_t-1}$ são atualizados com suavização exponencial, somente após a ocorrência de uma demanda e são combinados como se segue:

$$y_t^* = z_t^* \frac{1}{p_t^* c^{p_t^*-1}} \quad (47)$$

onde: $c > 100$.

Os autores realizaram um experimento simulado, assegurando que as séries apresentassem intermitência mínima ($ADI \geq 1,25$) contendo 200 combinações de fatores, dez diferentes valores para a constante de suavização α : 0,1; 0,2;... 0,9; 1,0; cinco intervalos entre demandas: 2, 4, 6, 8 e 10 e quatro combinações entre médias (μ) e desvio padrão (σ), $\mu = 1, 6, 10$ e 20 e $\sigma = 0, 1, 2$ e 2 . Executaram a simulação com auxílio de *Visual Basic*, em planilha eletrônica. Concluíram que a equação (36) produz melhores previsões do que a equação (32), especialmente quando $\alpha > 0,15$. Finalizam o trabalho chamando a nova equação (36) de Método de Croston Revisado e alertando que a equação original de Croston produz viés mais acentuado na previsão da demanda quando α supera a marca de 0,15.

No presente trabalho, o método proposto por Syntetos e Boylan (2001) foi testado em planilha eletrônica, com $c = 100$, mas não apresentou resultados consistentes, ficando aquém do modelo original proposto por Croston. A partir desta constatação, foi abandonado durante a testagem e validação dos métodos de previsão (Capítulo 4).

Syntetos e Boylan voltaram ao cenário da demanda intermitente em 2005, ao apresentarem o que ficou conhecido como SBA – *Syntetos-Boylan Approximation* (REGO e MESQUITA, 2010). Ao invés de adotarem uma constante (c), optaram por utilizar o próprio coeficiente de suavização (α) no denominador da equação original de Croston. Os autores não utilizaram simulação, mas sim, 3.000 séries intermitentes obtidas de componentes da indústria automotiva. Reconhecem que o Método de Croston é superior à Média Móvel Simples e à Suavização Exponencial e que atualmente é utilizado nos pacotes computacionais de ponta, além de ter motivado uma quantidade substancial de pesquisa nos últimos anos.

Retomam a questão do viés para cima na previsão da demanda – que carrega desnecessariamente os estoques – e demonstram como o método SBA pode superar Croston original, ao reduzir este viés. O viés cresce porque, se é esperado que o tamanho da demanda e o intervalo entre demandas sejam independentes, então:

$$E\left(\frac{z_t^*}{p_t^*}\right) = E(z_t^*)E\left(\frac{1}{p_t^*}\right) \quad (48)$$

mas,

$$E\left(\frac{1}{p_t^*}\right) \neq \frac{1}{E p_t^*} \quad (49)$$

Portanto, o método de Croston contém viés. A magnitude do erro depende do valor da constante de suavização que é utilizada. Na prática, os autores demonstram que o viés associado à Croston, para $0 < \alpha < 1$, pode ser aproximado a:

$$\frac{\alpha}{2 - \alpha} \mu \frac{(p - 1)}{p^2} \quad (50)$$

Este viés também pode ser expresso como um percentual da demanda média:

$$100 \frac{\alpha}{2 - \alpha} \left(1 - \frac{1}{p}\right) \quad (51)$$

Incorporando o viés, os autores propõe então uma nova formulação para Croston:

$$y_t^* = \left(1 - \frac{\alpha}{2}\right) \frac{z_t^*}{p_t^*} \quad (52)$$

Recomendam adotar o mesmo α tanto para suavizar a demanda (z_t^*) quanto para o intervalo (p_t^*), apesar de Schultz (1987) sugerir que

coeficientes diferentes para demanda e intervalo possam ser aplicados. Ao testarem as 3.000 séries, utilizaram: $\alpha = 0,05; 0,10; 0,15$ e $0,20$.

Confrontaram quatro métodos: Média Móvel 13 períodos, Suavização Exponencial Simples, Croston e SBA. Concluem que o Método SBA sobrepuja os demais, gerando as melhores previsões.

No Capítulo 4, a equação (52) será aplicada sobre as séries em estudo, pois testes preliminares indicaram que se trata de um método de previsão confiável.

2.4.5 A proposta de Levén e Segerstedt

Levén e Segerstedt (2004) sugeriram um método modificado de Croston construído em torno de um moderno sistema ERP – *Enterprise Requirement Planning*, isto é, uma ferramenta computacional conhecida na administração de compras e estoques. Simularam uma série de periodicidade diária, contendo 11 mil períodos. Suas simulações comprovaram que o método de Croston desempenha melhor que a suavização exponencial com a premissa de distribuição normal. Concluem o trabalho afirmando que seu método de Croston modificado resulta em poucas faltas de peças (*stock out*), sem elevar o nível de estoques (como ocorre com Croston original). A equação e a correspondente notação desenvolvidas pelos autores estão a seguir:

$$y_t^* = \alpha \frac{z_t^*}{p_t} + (1 - \alpha) y_{t-1}^* \quad (53)$$

No decorrer da simulação utilizaram $0,05 \leq \alpha \leq 0,90$ e a superioridade do método de Levén-Segerstedt sobre a suavização exponencial simples (SES) surge a partir de $\alpha = 0,25$. No entanto, Boylan e Syntetos (2006a) mostraram que Levén-Segerstedt utilizaram uma métrica inválida para a acurácia da previsão e isto produziu viés nas previsões. Compararam-no com o método original de Croston e perceberam-no com desempenho inferior. No presente trabalho, a proposta de Levén-Segerstedt foi testada numa fase inicial, mas não demonstrou desempenho superior sobre aos métodos de autores concorrentes.

2.4.6 O método proposto por Teunter e Sani

Ruud Teunter e Babangida Sani (2006) lembraram que o método de Croston sofre de um ‘viés positivo’ e criticaram os trabalhos prévios (SYNTETOS-BOYLAN, 2001 e 2005; LEVÉN-SEGERSTEDT, 2004). Quanto a Syntetos-Boylan, de que não haviam resolvido adequadamente o viés na equação de Croston, provocando agora um ‘viés negativo’, que poderia inclusive ser maior que o viés positivo original. Para Levén-Segerstedt, argumentaram que o método proposto por estes era ainda mais enviesado que o método SBA.

A partir do modelo SBA iniciaram a construção de um novo método. Após um estudo numérico, constataram ser este superior aos métodos concorrentes – em toda a gama de parâmetros relevantes ao processo de previsão. Tomando a mesma equação inicial utilizada por Syntetos-Boylan:

$$E(C_r) = \left[\frac{z_t^*}{p_t^*} \right] \approx \frac{\mu}{p} \left(1 + \frac{\alpha}{2 - \alpha} \frac{p - 1}{p} \right) \quad (54)$$

Mas não abandonaram o termo $(p-1)/p$ – que foi ignorado no método SBA – e reescrevendo a equação (54), os autores obtiveram:

$$E \left[\frac{z_t^*}{p_t^*} \right] \approx \frac{\mu}{p} \left(\frac{2p - \alpha}{2p - \alpha p} \right) \quad (55)$$

E a partir desta sugerem:

$$y_t^* = \frac{z_t^* (2p^* - \alpha p^*)}{p_t^* (2p^* - \alpha)} = \frac{z_t^* (2 - \alpha)}{2p^* - \alpha} \quad (56)$$

Que resulta em:

$$y_t^* = \left(1 - \frac{\alpha}{2} \right) \frac{z_t^*}{p_t^* - \frac{\alpha}{2}} \quad (57)$$

Teunter e Sani realizaram simulação numérica, empregando um fatorial cheio, contendo 48 experimentos, sendo a série gerada aleatoriamente e contendo 10 mil períodos. Consideraram:

- $\alpha = 0,10; 0,20$ e $0,30$.
- $1/p$ (probabilidade de demanda) = $0,1; 0,3; 0,5$ e $0,7$.
- Distribuição da demanda: normal e discreta.

Na conclusão do trabalho, mostram que o Método Teunter-Sani produziu, na média, apenas 1% de viés nas previsões, enquanto SBA produziu 5%, Croston original 6% e Levén-Segerstedt 71% de viés. Dada esta boa robustez, este método será empregado no Capítulo 4, quando três séries intermitentes serão testadas.

2.4.7 O estudo de Shenstone e Hyndman

Estes autores procuraram identificar modelos estocásticos que pudessem suportar o método de Croston, isto é, mostrar a distribuição da previsão e os intervalos da própria previsão, com valor mínimo e máximo para cada período à frente. Esta ferramenta é bastante aplicada na suavização exponencial. A Figura 06 traz mais detalhes. Percebe-se que a série é bem intermitente e que a previsão pelo método de Croston fornece apenas pontos. De todo o modo, percebe-se que nenhum dos modelos proporcionou intervalos de previsão adequados (ver linhas pontilhadas). Shenstone e Hyndman (2005) enfatizam que isto de forma nenhuma invalida Croston e os posteriores métodos modificados. Apenas confirma que os modelos que usaram sobre a demanda intermitente (Croston, log-Croston, Modified Croston e Modified log-Croston) não se adéquam para a obtenção da distribuição da previsão e os intervalos desta. Portanto, nas previsões obtidas por Croston original ou seus sucessores (SBA, Levén-Segerstedt, Teunter-Sani) o pesquisador obterá apenas os pontos médios.

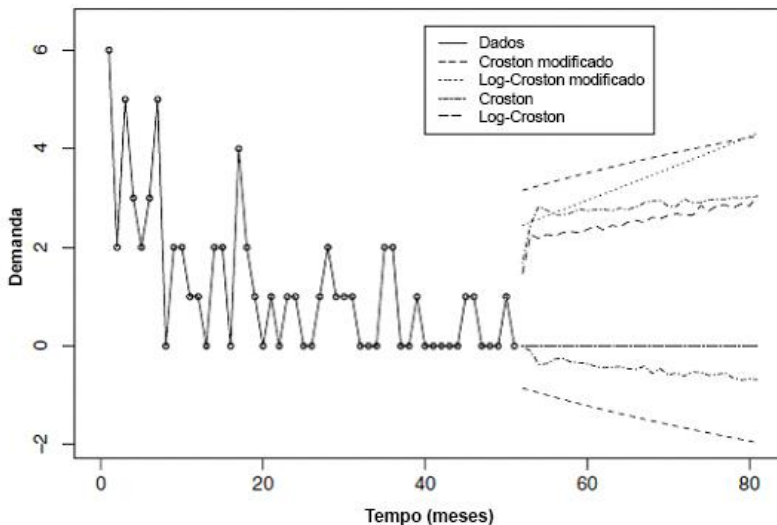


Figura 06 – Intervalos de previsão, com diferentes métodos, sobre série intermitente. Fonte: Shenstone & Hyndman (2005).

2.5 MEDIDAS DE DISCREPÂNCIA

Previsões de demanda sempre produzem alguma discrepância, até porque não há ‘previsão perfeita’. Mas é justamente a partir das discrepâncias oriundas das previsões que se inicia o processo de melhoria contínua. Portanto, as discrepâncias entre o ‘previsto’ e o ‘observado’ – quer seja para cima ou para baixo – são as pérolas que o pesquisador, ou administrador, gerente, dono da empresa não podem negligenciar. Trabalhar no sentido de depurar o processo de previsão, obtendo discrepâncias cada vez menores com o passar do tempo deve ser a grande meta de todo administrador. Discrepâncias cada vez menores levam a outro termo que será bastante utilizado neste trabalho, especialmente no Capítulo 4: melhoria na acurácia.

Com o desenvolvimento das técnicas de previsão, as medidas de discrepância também foram evoluindo. Há algumas clássicas, tal como o Desvio Médio (DM) até as mais recentes como MASE – Discrepância Absoluta Escalar Média (*Mean Absolute Scaled Error*), proposta por Rob Hyndman em 2006. Na presente seção, quatro medidas de

discrepância serão abordadas e posteriormente aplicadas no Capítulo 4, dada a natureza dos dados investigados.

2.5.1 Discrepância Média

A discrepância – ou erro, ou desvio da previsão – pode ser determinada como a diferença entre o valor previsto e o valor observado (real).

$$\underbrace{E}_{\text{Discrepância de previsão}} = \underbrace{P}_{\text{valor previsto}} - \underbrace{O}_{\text{valor observado}} \quad (58)$$

A partir da equação (58) percebem-se duas possibilidades: a ‘subestimação’, quando o valor previsto (P) for menor que o observado (O), gerando um sinal negativo ao erro e a ‘superestimação’, quando $P > O$ e o erro (E) carrega o sinal positivo. Para o administrador, nem a subestimação e nem a superestimação interessam, pois ambas implicam em custos. A subestimação que prejudica o correto atendimento às demandas (falta de componentes) e a superestimação que acaba ‘carregando’ os estoques com mais componentes que o necessário (demanda não absorve). Portanto, o alvo é $E \approx 0$.

A discrepância média (DM) é a medida mais simples e também a mais frágil para se avaliar o ajuste de um determinado método à realidade observada (SAMOHYL, 2008). Isto se justifica pelo fato do cálculo da DM assumir um valor próximo à zero, devido às discrepâncias possuírem valores positivos e negativos que, quando somados, acabam se neutralizando. Portanto, $DM \approx 0$ e é justamente por isso que ela não se mostra tão eficaz na escolha de um método em relação a outro. Por outro lado, a DM é muito útil como medida de viés. Por exemplo, se um fabricante de motonetas 125 cc. lança um novo modelo e sistematicamente superestima as vendas, ao final de um ano (período de 12 meses) estará com os estoques cheios. Se nas suas previsões mensais, tivesse prestado atenção à DM, teria observado um consistente sinal positivo, indicando que o estoque estava sendo carregado, isto é, vendas abaixo do estimado.

A DM é calculada a partir de uma série histórica. A sua equação é bem simples, resultando na média dos erros:

$$DM = \frac{1}{n} \sum_{t=1}^n e_t = \frac{1}{n} \sum_{t=1}^n (P_t - O_t) \cong 0 \quad (59)$$

onde:

n = nº de dados

t = tempo

P_t = previsto

O_t = observado

2.5.2 Discrepância quadrada média

No uso da discrepância média (DM) há o inconveniente dos sinais, levando os erros a se anularem, o que resulta em $DM \approx 0$. Para evitar esta armadilha e obter maior robustez, os estatísticos da era anterior à computação decidiram elevar o desvio ao quadrado. Desta forma, não importava se o erro tivesse sinal positivo ou negativo. A equação da DQM é:

$$DQM = \frac{1}{n} \sum_{t=1}^n e_t^2 = \frac{1}{n} \sum_{t=1}^n (P_t - O_t)^2 \quad (60)$$

Esta é uma medida clássica, amplamente utilizada entre estatísticos, dada à facilidade que proporciona nas operações algébricas e matemáticas, característica esta não encontrada no cálculo dos erros em termos absolutos. Ocorre que elevar os erros ao quadrado resulta em valores elevados e, ao se extrair a média, mesmo assim o valor médio acaba sendo alto. Para equacionar esta desvantagem, os estatísticos decidiram extrair a raiz quadrada da DQM, o que resultou na RQDQM – Raiz Quadrada da Discrepância Quadrada Média, isto é:

$$RQDQM = (DQM)^{1/2} \quad (61)$$

De forma geral, a RQDQM se aproxima bastante da DAM – Discrepância Absoluta Média, tema da próxima seção.

2.5.3 Discrepância absoluta média

Com o advento dos dispositivos eletrônicos de calcular (calculadoras, computador), operar com valores absolutos tornou-se fácil e rápido para pesquisadores e estatísticos. Hyndman e Athanasopoulos (2013) definem a DAM – discrepância absoluta média – como sendo:

$$DAM = média(|e_t|) \quad (62)$$

Que pode ser reescrita como:

$$DAM = \frac{1}{n} \sum_{t=1}^n |e_t| = \frac{1}{n} \sum_{t=1}^n |P_t - O_t| \quad (63)$$

A DAM é mais robusta do que o erro médio (DM), pois trabalha com seus valores individuais na forma absoluta, isto é, sem sinal, tratando cada erro como se fosse uma distância. No final, não deixa de ser uma medida de distância, medindo a diferença entre a tentativa (previsão) e o alvo (observado). A DAM é uma medida da qualidade da previsão. É apropriada para analisar as previsões de um único produto. Se dois ou mais produtos estiverem sendo comparados, outra medida de discrepância deve ser empregada tendo base escalar ou percentual.

2.5.4 Discrepância absoluta escalar média

Quando a série histórica é intermitente, os vários períodos com demanda nula (zero) causam dificuldade aos denominadores das medidas de discrepância, especialmente para a DPAM – Discrepância Percentual Absoluta Média. Visando contornar este inconveniente, Hyndman e Koehler (2006), propuseram uma medida de discrepância que fosse livre de escala. Desta forma, poderia absorver séries

intermitentes e ainda ser comparada com outras séries. Neste trabalho, manteremos a sigla original inglesa MASE (*Mean Absolute Scaled Error*), que traduziremos por Discrepância Absoluta Escalar Média. A formulação é dada abaixo:

$$\text{MASE} = \text{m\u00e9dia} (|q_t|) \quad (64)$$

onde:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (65)$$

sendo:

q_t = erro escalar;

$e_t = Y_t - F_t$, sendo Y_t o valor observado e F_t o valor da previs\u00e3o.

O denominador da equa\u00e7\u00e3o (65) \u00e9 a DAM do m\u00e9todo ing\u00eanuo, dentro da amostra. Portanto, q_t pode ser reescrito como:

$$q_t = \frac{e_t}{\text{DAM ing\u00eanuo (dentro da amostra)}} \quad (66)$$

Para melhor entendimento da equa\u00e7\u00e3o (66), um exemplo ser\u00e1 apresentado. Suponha uma s\u00e9rie intermitente com 36 dados, sendo os primeiros 24 utilizados para calcular a previs\u00e3o com 12 per\u00edodos \u00e0 frente, mediante o m\u00e9todo da previs\u00e3o ing\u00eanua. A Figura 07 apresenta a s\u00e9rie, a previs\u00e3o com um per\u00edodo \u00e0 frente e a discrep\u00e2ncia de previs\u00e3o (DAM) dentro da amostra. O denominador de q_t ser\u00e1 a m\u00e9dia dos erros assinalados em azul.

Exemplo - Série intermitente - Medida de discrepância MASE		
Série (Y_t)	Dentro da amostra (24 dados)	Fora da amostra (12 dados)
	0 2 0 1 0 1 0 0 0 0 2 0 6 3 0 0 0 0 0 7 0 0 0 0	0 0 0 3 1 0 0 1 0 1 0 0
Previsão ingênua (\hat{Y}_t)	0 2 0 1 0 1 0 0 0 0 2 0 6 3 0 0 0 0 0 7 0 0 0 0	0 0 0 0 0 0 0 0 0 0 0 0 0 0
DAM [$Y_t - \hat{Y}_t$]	2 2 1 1 1 1 0 0 0 2 2 6 3 3 0 0 0 0 7 7 0 0 0 0	0 0 0 3 1 0 0 1 0 1 0 0

Fonte: Hyndman e Koehler, 2006

Figura 07– Exemplo de série intermitente, com cálculo da previsão ingênua e DAM dentro da amostra.

O resultado é escalar, não está preso a nenhum sistema de unidades. Uma discrepância escalar $q_t < 1$ surgirá de uma previsão superior ao método ingênuo (dentro da amostra). Opostamente, $q_t > 1$ quando o método de previsão empregado tem desempenho inferior ao método ingênuo, computado dentro da amostra.

A MASE tanto pode ser utilizada em séries intermitentes, quanto com tendência e/ou sazonalidade. A única restrição, que leva os valores de MASE ao infinito (ou indefinidos) é quando a série é completamente constante, isto é, $Y_t = Y_{t-1} = Y_{t-2} = \dots = Y_{t-n}$. No presente trabalho, a medida MASE será aplicada, dada a intermitência das séries a serem investigadas.

2.6 GESTÃO DE ESTOQUES

A previsão de demanda é um dos principais fatores que contribui para a eficiência na cadeia produtiva das empresas. Ela é fundamental para o planejamento da demanda, e por extensão, para o início do processo de suprimento. Neste sentido, quanto maior a acurácia da previsão de demanda, menores serão os impactos financeiros e no nível de atendimento da cadeia de suprimentos, contribuindo favoravelmente na gestão dos estoques. O não atendimento destas condições aumenta os custos do produto e afeta a lucratividade do negócio.

2.6.1 O estoque e suas características básicas

Existem certas características que são comuns a todos os problemas de controle de estoque, não importando se são matérias primas, material em processo ou produtos acabados. Esses traços básicos são: (a) custos associados aos estoques, (b) objetivos do estoque, (c) previsão de incertezas.

a) Custos associados aos estoques

Removendo-se a despesa de aquisição da mercadoria, os gastos associados aos estoques podem ser divididos em três categorias:

- i) Custo de pedir: são as despesas administrativas, tais como: preencher o pedido de compra, serviço burocrático na contabilidade e no almoxarifado e receber o pedido.
- ii) Custos de manter estoque: são geralmente definidos em termos monetários por unidade, por período. Incluem componentes como: gastos com armazenagem, seguro, deterioração e obsolescência e de oportunidade (manter o dinheiro aplicado no mercado financeiro).
- iii) Custo total: é definido como a soma do pedir e de manter estoque. Ele é importante no modelo do lote econômico de compra (LEC), pois o objetivo deste é determinar a quantidade do pedido que o minimize. O custo total pode ser determinado mediante a seguinte equação:

$$CT = C_p \cdot \frac{D}{Q} + i \cdot C_m \cdot \left(\frac{Q}{2} + S \right) \quad (67)$$

onde:

C_p = custo fixo de cada pedido;

D = demanda anual;

Q = quantidade do pedido

i = custo-percentagem de manter estoques;

C_m = preço unitário da mercadoria estocada;

$i \cdot C_m$ = custos unitários de estocagem;

D/Q = número de pedidos durante o ano;

S = estoque de segurança.

$Q/2$ = Estoque médio no período entre pedidos.

O custo anual dos pedidos é expresso por:

$$CTP = C_p \cdot \frac{D}{Q} \quad (68)$$

E o custo total de estocagem por:

$$CTE = i \cdot Cm \cdot \left(\frac{Q}{2} + S \right) \quad (69)$$

De forma abreviada, a equação (67) pode ser reescrita como:

$$CT = CTP + CTE \quad (70)$$

b) Objetivos do estoque

Segundo Ballou (1995), há dois objetivos principais:

- i) Objetivo de custo, isto é, encontrar o equilíbrio entre aquisição e demanda. Estoque em excesso significa dinheiro parado. Estoque muito baixo pode significar perda de vendas, pedidos incompletos, baixo nível de serviço. Apoiado nas equações (67) a (69) é possível se calcular o LEC – Lote Econômico de Compra, que pode ser facilmente calculado em planilha eletrônica. O LEC é um plano de suprimento que minimize o custo total (CT). A seguir, demonstra-se, graficamente, um exemplo hipotético. Observar a linha amarela (custo total), que tem formato em U. No seu ponto mais baixo está o equilíbrio que o LEC deve buscar, isto é, $LEC \approx 400$ unidades, que minimiza o custo de estocagem (CTE) e o custo dos pedidos (CTP).

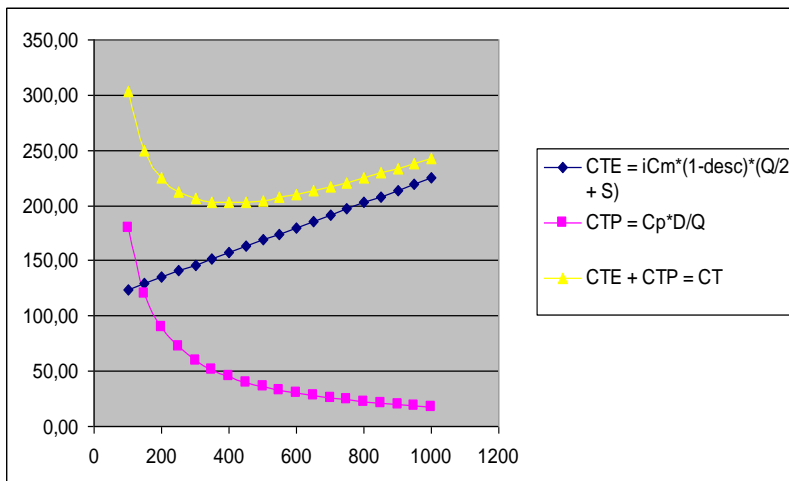


Figura 08– Lote econômico de compra (LEC) – exemplo hipotético.

ii) Objetivo de nível de serviço, onde, às vezes, a dificuldade em estimar os custos de faltas leva ao estabelecimento de metas não realistas. Por exemplo, se a empresa fixa a seguinte meta: “98% dos pedidos do item X devem ser atendidos em 48 horas”. Deve-se ter grande cautela para fixar o nível de serviço de estoque desta forma. Aumentar a disponibilidade em apenas alguns pontos percentuais, por causa da pressão da área de vendas, tem um efeito dramático no capital investido em estoque. Uma vez que o nível de estoque cresce explosivamente com disponibilidades elevadas, o nível de serviço (NS) utilizado, na maioria das vezes, é menor que 100%. Deve-se obter o equilíbrio possível entre a produção e o custo total de estoque, de um lado, e o nível de serviço prestado aos clientes, de outro.

c) Previsão de incertezas

Contratar o nível de estoque tem seus riscos associados. Nunca se tem certeza da quantidade a ser solicitada pelos clientes e da quantidade a ser enviada para o depósito (armazenagem). Para complicar ainda mais a situação, não é possível prever com exatidão quando chegarão os

suprimentos para iniciar a produção e abastecer os estoques. Uma das primeiras questões consideradas no controle de estoques é a previsão de vendas futuras, da demanda, bem como a estimativa do tempo de ressurgimento (*lead time*), desde a colocação do pedido no fornecedor, sua produção até a chegada do material nas instalações da empresa. Mas não há dúvida de que realizar a previsão da demanda, sistematicamente, ajuda em muito. Num estágio já mais adiantado, onde a empresa realiza previsão de demanda para seus itens regularmente, Wemmerlöv (1989) assinala: “de fato, há uma diferença fundamental entre ambientes (empresas) que operam com erros de previsão e aqueles sem erros de previsão”. Ora, sabe-se que não há previsões perfeitas e as discrepâncias sempre estarão presentes, mas, a ênfase do autor aqui é no sentido de melhorar continuamente a acurácia das previsões. Quanto menores os erros de previsão, mais confiança no sistema, melhorando o equilíbrio entre nível de estoques (que é custo) e o atendimento adequado aos clientes (que é satisfação).

2.6.2 Sistemas de revisão de estoques

Existem dois tipos gerais de sistemas de revisão de estoque: Sistema de Revisão Contínua (Q) e Sistema de Revisão Periódica (P). A diferenciação entre os sistemas se dá no que diz respeito aos períodos de revisão e às quantidades de reposição (WERNER, LEMOS e DAUDT, 2006).

a) Sistema de Revisão Contínua (Q)

As questões principais no gerenciamento de estoques, seja em grandes cadeias, sejam em uma organização isolada, continuam sendo quando e quanto repor, levando em conta as possíveis variabilidades, tanto no suprimento quanto na demanda. Um das políticas de gestão de estoques mais conhecidas e utilizadas é o sistema de lote econômico com ponto de pedido, também conhecido como sistema $\langle Q, r \rangle$. Neste modelo, uma quantidade Q é ordenada assim que o estoque disponível atinge o patamar de r unidades, chamado de ponto de pedido ou nível de

reposição. A quantidade Q é usualmente determinada pela expressão do Lote Econômico de Ressuprimento (ou LEC – Lote Econômico de Compra, com visto na seção 2.6.1.b) ou por algum outro modelo de otimização, como pode ser visto em livros clássicos de gestão de estoques como Hadley & Within (1963) e Brown (1967), ou em livros mais recentes como Silver, Rycke & Peterson (1998) [citados por GARCIA e FERREIRA FILHO, 2009]. Já o ponto de pedido r se baseia em atingir algum padrão de nível de serviço, tendo em consideração a variabilidade estocástica da demanda total durante o tempo de ressuprimento, também conhecida como demanda no *lead-time*. Embora existam muitas maneiras de se definir nível de serviço, como disponibilidade de produto (*fill rate*), uma abordagem comum é considerá-lo como a probabilidade de não ocorrência de uma ruptura de estoques (*stockout*) durante o tempo de ressuprimento. Com base no nível de serviço desejado, r é em geral calculado como a demanda média no *lead-time* mais um estoque de segurança. Para o cálculo apropriado deste estoque de segurança deve-se conhecer a distribuição de probabilidades da demanda no *lead-time* (ressuprimento). Alternativamente, outro método usual de calcular o estoque de segurança é utilizando a previsão da demanda no *lead-time*, juntamente com os respectivos erros de previsão. As equações que regem este sistema são:

$$D_{LT} + ES \quad (71)$$

em que:

r = ponto de pedido ou ponto de reposição.

D_{LT} = demanda durante o lead time.

ES = estoque de segurança.

$$Q = \sqrt{\frac{2AD}{iC}} \quad (72)$$

onde:

Q = quantidade a ser adquirida (constante)

A = custo do pedido

D = taxa de demanda

i = taxa de manutenção dos estoques (custo percentual).

C = preço de compra unitário.

A quantia Q a ser adquirida é sempre a mesma e o estoque de segurança é utilizado somente em casos onde a demanda ou o tempo de ressuprimento tiverem uma variabilidade maior do que a esperada (STAUDT, 2011).

b) Sistema de Revisão Periódica (P)

O modelo de revisão periódica também pode ser encontrado com vários nomes na literatura: *periodic review model*, *periodic order model*, *(R, T) model*, *fixed reorder cycle system*, entre outros. Em suma, esse modelo consiste em definir um intervalo ótimo (I_p) entre cada solicitação. A quantidade solicitada a cada novo pedido varia de acordo com o consumo no período anterior (BUFFA, 1968). Normalmente, a quantidade solicitada é diferente da quantidade ótima, devendo ser suficiente para cobrir a demanda durante o intervalo considerado (SLACK et al., 1997).

A principal vantagem da sistemática P é a flexibilidade na determinação da periodicidade a ser empregada. De acordo com Novaes e Alvarenga (1994), as revisões são feitas a intervalos fixos, eliminando a necessidade de controle contínuo sobre o nível atual do estoque, como requerido na sistemática Q. Sendo assim, o intervalo pode ser convenientemente escolhido de forma a fazer coincidir, numa mesma data, as emissões dos pedidos de vários produtos, facilitando o processo de aquisição e aproveitando eventuais descontos no transporte (NOVAES;ALVARENGA, 1994; TUBINO, 2000). Essa característica faz com que a sistemática P seja, segundo Novaes e Alvarenga (1994), mais empregada pelas empresas. Contudo, a escolha do intervalo mais conveniente pode seguir outro critério qualquer de interesse (TUBINO, 2000). Naturalmente, a determinação do intervalo pode ser feita de forma a obter-se o intervalo ótimo que resultaria do emprego de algum dos modelos de lote econômico. O intervalo ótimo entre pedidos (ou intervalo econômico de pedido) pode ser escrito, para o caso do modelo clássico, como (GAITHER e FRAZIER, 2001):

$$I_p = \sqrt{\frac{2K}{D \cdot i \cdot C}} \quad (73)$$

em que:

I_p = intervalo ótimo entre pedidos;

K = custo fixo de pedido;

D = demanda anual constante;

i = taxa de encargos sobre o estoque;

C = custo unitário do produto.

O nível máximo de estoque (T) é dado por:

$$T = D_t \cdot (t_r + I_p) + ES \quad (74)$$

onde:

D_t = demanda média por unidade de tempo;

t_r = tempo médio de ressurgimento;

ES = estoque de segurança.

A quantidade (Q) solicitada em cada pedido, que elevará o estoque ao nível (T), deve levar em conta o saldo atual em estoque (Q_f). Portanto, define-se $Q = T - Q_f$. De acordo com Tubino (2000), para casos em que $I_p < t_r$ haverá quantidades solicitadas pendentes (Q_p) que deverão ser consideradas. Ainda, se demandas reprimidas (Q_r) devem ser atendidas assim que possível, então, pode-se escrever:

$$Q = D_t(t_r + I_p) - Q_f - Q_p + Q_r + ES \quad (75)$$

Há vantagem do Sistema Q sobre o Sistema P ou vice-versa? Rosa, Mayerle e Gonçalves (2010) debruçaram-se sobre esta questão e, num estudo com simulação concluíram que a Sistemática Q é superior quando $t_r < I_p$, isto é, o tempo médio de ressurgimento é menor do que o

intervalo entre pedidos. Em situações de elevado t_r e desvio padrão, a Sistemática P deve ser considerada, pois o modelo da revisão periódica possui facilidades inerentes à sua operacionalização.

2.6.3 Estoque de segurança e nível de serviço

Encontrar um ponto de equilíbrio entre bom nível de serviço a um custo razoável de estoques e capacidade instalada é ponto chave para obtenção da desejada vantagem competitiva. Reduzir os custos com produtos parados (grande volume de estoques) ao mesmo tempo em que se mantenha baixa probabilidade de faltar mercadorias para venda (causadora de um elevado custo implícito de vendas perdidas) pode ser o diferencial entre o sucesso ou o fracasso do negócio no mercado (COELHO, 2008).

Na administração de estoques, o estoque de segurança (ES) e o nível de serviço (NS) caminham juntos, pois a decisão que o administrador tomar sobre um inevitavelmente afetará o outro. O estoque de segurança tem a função de compensar variações do tempo de atendimento (tempo de ressuprimento), as variações da demanda e os desvios da previsão em relação à demanda. Com o suprimento da demanda pelos estoques, anula-se qualquer problema que surgir durante o tempo de ressuprimento que poderia comprometer algum prazo de entrega aos clientes.

Os dois métodos mais utilizados para calcular o estoque de segurança são baseados no sistema de demanda (sigla DS - também denominado reativo) e no sistema de previsão (sigla FS - também denominado ativo). O método reativo quantifica o estoque de segurança a partir da variabilidade da demanda, já o método ativo, pela variabilidade dos erros de previsão de demanda (STAUDT, 2011).

• Sistema de Demanda - DS

No modelo DS a previsão implícita para cada período é a demanda média. Como resultado, o desvio padrão da demanda equivale ao desvio padrão da “previsão” de erros. O FS é mais complexo e caro de implantar que o DS, mas potencialmente mais eficiente, pois requer a estimação do erro de previsão, o que é obtido usando aproximações baseadas, por exemplo, na teoria de regressão ou análise de séries

temporais, para prever a demanda para cada período futuro (FIGUEIREDO e NETTO, 2001). Para a formulação do método DS, será considerado o caso onde ocorre variabilidade da demanda e do tempo. A equação clássica é:

$$ES = Z_{\alpha} \sqrt{\mu_{TR} \cdot \sigma_D^2 + \mu_D^2 \cdot \sigma_{TR}^2} \quad (76)$$

onde:

Z_{α} = nível de atendimento desejado;

μ_{TR} = tempo médio de ressuprimento (lead time);

σ_D = desvio padrão da demanda;

μ_D = demanda média;

σ_{TR} = desvio padrão do tempo de ressuprimento.

O nível de serviço Z_{α} a ser praticado por uma empresa é uma decisão que envolve custos de capital imobilizado. Figueiredo e Netto (2001) relatam que a grande vantagem de expressar o nível de serviço desta forma existe devido às tabelas já existentes da probabilidade de faltar estoque, medido em números de desvios padrão em relação à média da amostra de dados. Os autores comentam ainda que a tabela foi originalmente desenvolvida por Brown (1967) e os valores nela contidos foram obtidos a partir da premissa de que a demanda e os erros de sua previsão apresentam uma distribuição normal.

• Sistema de Previsão - FS

A previsão de demanda é um dos principais fatores que contribui para a eficiência na cadeia produtiva das empresas. Ela é fundamental para o planejamento da demanda, e por extensão, para o início do processo de suprimento. Neste sentido, quanto maior a acurácia da previsão de demanda, menor serão os impactos no nível de atendimento e custos da cadeia de suprimentos. O não atendimento destas condições aumenta os custos do produto e afeta a lucratividade do negócio.

Como consequência natural de considerar demandas com tendências, sazonalidades e saltos, e a filosofia JIT (*Just in Time*), surgiram decisões de compra baseadas diretamente em previsões, nas

quais se compra o estritamente necessário para atender as necessidades (SANTORO e FREIRE, 2008). Portanto, para a avaliação das demandas com suas respectivas características, faz-se necessária a utilização do método ativo. Para sua implantação, necessita-se de um histórico da demanda do produto, que pode variar de acordo com o método de previsão a ser aplicado. A partir do histórico, aplicam-se os métodos de previsão de demanda. Posteriormente, avalia-se o desempenho de cada modelo pela mensuração dos erros conforme a equação:

$$\sigma_D = \sqrt{\frac{\sum_{i=1}^n (x_i - x_m)^2}{n - 1}} \quad (77)$$

em que:

x_i = valor de determinada diferença entre previsão de demanda e a demanda real (observado);

x_m = média das diferenças entre previsão de demanda e demanda real (observado);

n = número de períodos analisados.

A partir da equação (78) definem-se as equações para os estoques de segurança:

$$ES = Z_\alpha \cdot \sigma_D \cdot \sqrt{TR} \rightarrow \text{Sistema Contínuo (Q)} \quad (78)$$

$$ES = Z_\alpha \cdot \sigma_D \cdot \sqrt{IR + TR} \rightarrow \text{Sistema de Revisão Periódica (P)} \quad (79)$$

onde:

IR = Intervalo entre as revisões,

TR = Tempo de ressuprimento (lead time).

Santoro e Freire (2008) compararam o sistema ativo (FS) com o reativo (DS), utilizando séries simuladas com tendência e sazonalidade versus séries com demanda constante. Observaram que o Sistema FS é

superior na presença de tendência e sazonalidade, enquanto o Sistema DS se adéqua bem para demanda constante. Ainda, Figueiredo e Netto (2001), baseados nos estudos de Zinn e Marmorstein (1990) indicam que o Sistema FS tende a reduzir o estoque de segurança (ES) em 15% quando comparado ao Sistema DS. No presente trabalho, a preferência recairá sobre o Sistema FS, pois três séries temporais intermitentes serão pesquisadas e os estoques de segurança na Empresa P redimensionados. No Apêndice B são apresentados os níveis de serviço (em percentual) associados ao Z_α (desvio padrão normalizado).

2.7 CONSIDERAÇÕES FINAIS

O Capítulo 2 foi dividido em três partes:

- a) Métodos de previsão;
- b) Medidas de discrepância e,
- c) Gestão de estoques.

Na abordagem dos métodos de previsão, procurou-se mostrar o que distingue uma série temporal contínua de uma intermitente. Ao longo da década de 1960 as séries com demanda não contínua eram tratadas igualmente com o método da suavização exponencial, desenvolvido por Robert G. Brown em 1956 e aperfeiçoado por Holt em 1957. Observou-se que a literatura sobre demanda intermitente não é tão vasta quanto para as séries cheias e que o maior volume de trabalhos surgiu após a proposta pioneira de Croston, em 1972, ao propor uma dupla suavização exponencial para a demanda intermitente: inicialmente sobre a demanda em si e a seguir sobre o intervalo entre as demandas. O quociente entre estas duas suavizações resultaria na demanda média nos próximos períodos. Croston manteve a mesma constante de suavização (alfa) utilizada na equação de Brown (ver Equação 03) e afirmou que seu método eliminava o viés causado pela suavização simples. Na fundamentação de seu método, Croston valeu-se de quatro suposições: i) o intervalo entre as demandas como um processo estacionário, b) a demanda como um processo de Bernoulli, isto é, há ou não há, c) que o intervalo e a demanda fossem independentes entre si e d) que as quantidades requisitadas (tamanho da demanda) tivesse: média, variância e distribuição normal. Para contornar a ausência de demanda no período, isto é, $y_t = 0$, Croston introduziu a variável q , conforme Equações (38), (40) e (41).

Vários trabalhos sucederam Croston (RAO, 1973; JOHNSTON, 1980; WILLIAMS, 1982 e 1984; WRIGHT, 1986; SCHULTZ, 1987; DUNSMUIR e SNYDER, 1989; SYNTETOS e BOYLAN, 2001 e 2005; LEVÉN e SEGERSTEDT, 2004; TEUNTER e SANI, 2006) todos buscando aprimorar o método original, isto é, focando na menor discrepância possível entre o previsto e o efetivamente realizado. Johnston e Boylan (1996) propuseram uma classificação para a demanda de uma série temporal em quatro quadrantes, a saber: demanda constante ou semi-constante, intermitente, errática e protuberante. A Figura 02 mostra estes quadrantes.

A maneira mais confiável de avaliar se um determinado método produz boas previsões ou não é mediante a leitura do erro (discrepância) entre o previsto e o observado. Como a demanda intermitente apresenta demandas nulas (ou ausência de destas), as seguintes medidas são as mais adequadas: DM – Discrepância Média, RQDQM – Raiz Quadrada da Discrepância Quadrada Média, DAM – Discrepância Absoluta Média e MASE (*Mean Absolute Scaled Error*), que traduziremos por Discrepância Absoluta Escalar Média, apresentada por Hyndman & Koehler em 2006.

Na gestão de estoques foram abordados os dois sistemas mais utilizados na revisão de estoques: a revisão contínua (Q) e a revisão periódica (P). Quanto ao estoque de segurança e o nível de serviço desejado, o sistema de demanda (DS) e o de previsão (FS) foram estudados. Retomando a citação de Figueiredo e Netto (2001), baseados nos estudos de Zinn e Marmorstein (1990), indicaram que o Sistema FS tende a reduzir o estoque de segurança (ES) em 15% quando comparado ao Sistema DS. Portanto, utilizar métodos de previsão na busca de um estoque de segurança equilibrado parece ser uma prática salutar. O presente capítulo encerra com a investigação da gestão de estoques, tema que será retomado no Capítulo 4, quando dois componentes (Kit pistola e Meio filtrante) terão seus estoques analisados. A seguir, no Capítulo 3, será detalhada a metodologia proposta para os três componentes deste estudo.

CAPÍTULO 3 – METODOLOGIA PROPOSTA

3.1 MODELOS DE PREVISÃO SELECIONADOS

A Empresa P adota o método de previsão de ‘um passo a frente’, baseando-se na média simples dos três últimos consumos – que denominaremos por ‘média simples 3 meses’ (MS3M). Ela possui um software de gestão, que automaticamente fornece a média dos três últimos consumos. De posse deste e de outros dados, o comprador utiliza estas informações como ponto de partida para novas compras, com horizonte de um a três meses. Como os componentes são importados, o *lead time* (tempo entre o pedido e a reposição) varia entre 45 e 60 dias. Por segurança, adota um horizonte de 90 dias (três meses). Já a Empresa H faz o seu controle de estoques semanalmente. O controle é apenas visual e o técnico responsável decide se um novo lote de sensores deve ser adquirido ou não. Vale ressaltar que a Empresa H possui um reconhecido software de gestão, mas ele não é utilizado para auxiliar nas decisões de reposição/compra do sensor de oximetria. Para efeito deste estudo, considerar-se-á que as duas empresas adotam o método de previsão da ‘Média Simples dos Últimos Três Meses (MS3M)’ e da ‘Média Simples das Últimas Três Semanas (MS3S)’.

O presente estudo tem por objetivo encontrar o método de previsão que forneça a melhor acurácia. Como se tratam de componentes com demanda intermitente, a pesquisa englobará dez diferentes métodos de previsão. Há um particular interesse no Método de Previsão por Croston (1972) e os dele derivados, pela capacidade de se ajustarem a dados intermitentes. Estes dez métodos serão então comparados com a metodologia atualmente utilizada pelos clientes (média simples dos últimos três períodos). O principal enfoque será sobre os resíduos (discrepâncias) entre o ‘previsto’ e o ‘observado’ duas medidas de acurácia serão priorizadas: RQDQM – Raiz Quadrada do Desvio Quadrado Médio e DAM – Discrepância Absoluta Média. Quanto menores os valores de RQDQM e DAM, melhor a acurácia da previsão. Se a série temporal não apresenta grandes distorções, normalmente RQDQM e DAM são muito próximos entre si. Os onze métodos (da empresa + os selecionados) valem-se do uso de duas ferramentas (*softwares*): planilha eletrônica e o *software estatístico R* (*GNU R Project*).

- A) Previsões calculadas com auxílio de planilha eletrônica:
- i) Empresa – Média simples dos últimos três períodos (MS3M);
 - ii) NNQ-STAT – desenvolvido pelo Núcleo de Qualimetria do Departamento de Engenharia de Produção da Universidade Federal de Santa Catarina (UFSC), em 2008;
 - iii) Syntetos & Boylan, 2005 (SB5) – Também conhecido por Syntetos-Boylan Approximation – é uma modificação ao Método de Croston;
 - iv) Teunter & Sani, 2006 (TS6) – Também um Método de Croston modificado.
- B) Previsões calculadas com o auxílio do software estatístico R:
- i) SES – Suavização Exponencial Simples;
 - ii) SES otimizada [SES(OT)];
 - iii) Método de Holt – que apenas considera a tendência da série (HOLT)
 - iv) Método de Holt-Winters – que leva em conta tendência e sazonalidade (HW);
 - v) ARIMA – Auto regressivo Integrado de Médias Móveis;
 - vi) CR-D – Método de Croston. Por *default* (padrão), o R opera com $\alpha = 0,10$.
 - vii) CR-Z – Método de Croston otimizado – utilizando a constante de suavização ótima para cada série temporal.

3.2 O CÁLCULO DA CONSTANTE DE SUAVIZAÇÃO

Partindo do pressuposto de que as três séries a serem investigadas têm comportamento intermitente, alguns autores, tais como: Schultz (1987), Willemain et al (1994), Johnston e Boylan (1996), Shenstone e Hyndman (2003), Levén e Segerstedt (2004) e Eaves e Kingsman (2004) mostram que a constante de suavização (α), para os métodos de Croston, deve oscilar entre 0,1 e 0,3. Visando obter a melhor previsão, isto é, com os menores resíduos possíveis (RQDQM e DAM), partiu-se para a pesquisa de um alfa ótimo. O script desta rotina e os resultados da simulação encontram-se nos Apêndices: C e D (kit pistola); E e F (meio filtrante) e G e H (sensor neonatal). Resumindo, as constantes ótimas de

suavização encontradas para cada série e que resultaram nas menores RQDQM e DAM são:

- a) Kit pistola: $\alpha = 0,10$;
- b) Meio filtrante: $\alpha = 0,18$;
- c) Sensor neonatal: $\alpha = 0,23$.

Além do método de Croston (calculado no R), decidiu-se aplicar estas constantes nos seguintes métodos:

- i) SB5;
- ii) TS6;
- iii) SES(OT)
- iv) CR-Z.

3.3 APLICAÇÃO DA METODOLOGIA

Para os três componentes, a metodologia será a mesma, a saber:

I) Primeira Etapa: Análise da série original.

Visando obter mais detalhes sobre a série temporal (todos os dados), os seguintes passos serão aplicados:

- a) Decompor a série, avaliando: tendência e ciclo, sazonalidade e valores aleatórios.
- b) Avaliar o intervalo médio e o coeficiente de variação da demanda (ADI e CV).
- c) Investigar a distribuição da demanda.
- d) Pesquisar/avaliar a distribuição do intervalo entre as demandas.

II) Segunda Etapa: Realizar as previsões sobre o conjunto amostral.

- a) Remover, da série original, os seis dados finais, que serão utilizados posteriormente na confrontação com as previsões. A este conjunto de dados remanescente (30 meses e 49 semanas, respectivamente), chamar-se-á de 'conjunto amostral'.
- b) Aplicar o Método da Média Simples dos últimos três períodos (metodologia da empresa) e calcular as previsões com o uso dos 30 ou 49 dados, respectivamente. Calcular os indicadores de acurácia: RQDQM, DAM e MASE. Verificar a normalidade dos resíduos, executando o Teste de Shapiro-Wilk (esperado: p-valor $> 0,05$).

- c) Aplicar os dez métodos de previsão (NNQ-STAT, SB5, TS6, SES, SES otimizada, Holt, Holt-Winters, ARIMA, CR-D e CR-Z). Avaliar e eleger os menores valores de RQDQM e DAM (menores resíduos). Ainda, avaliar a normalidade destes resíduos, aplicando o Teste de Shapiro-Wilk.
- d) Selecionar os três melhores métodos e confrontá-los com a prática atual nas empresas (MS3M ou MS3S).

III) Terceira Etapa: Conjunto amostral – Previsão com seis passos à frente.

Para a Média Simples (MS3M e MS3S) e para os três melhores métodos selecionados na Etapa IIc), aplicar a previsão com seis períodos à frente. Focar nas menores discrepâncias entre o ‘previsto’ e o ‘realizado’.

IV) Quarta Etapa: Ganhos potenciais.

Confrontando com o método de previsão usado na empresa, utilizar os indicadores de acurácia (RQDQM e DAM) dos três melhores métodos de previsão e avaliar os possíveis ganhos potenciais (volume de estoque, financeiro, lead time, etc.) que tais métodos possam trazer para a empresa.

V) Quinta Etapa: Série original versus previsões.

Tomar a série original (36 ou 55 dados) e aplicar:

- a) Método MS3M/MS3S,
- b) Melhor método selecionado. Comparar as acurácias e confirmar se o melhor método selecionado tem desempenho superior ou não sobre a série.

VI) Sexta Etapa: Aplicar na empresa.

- a) Apresentar os melhores métodos de previsão para as duas empresas e verificar o interesse destas em migrar para um método de desempenho superior ao Método da Média Simples dos últimos 3 períodos.
- b) Se houver interesse, auxiliar as empresas na implantação e monitoramento do novo método, por pelo menos doze períodos.

No caso da Empresa P, haverá uma sétima etapa, a saber:

VII) Sétima Etapa: Ajustar a previsão de demanda aos estoques (inventário).

- a) Verificar qual o sistema de controle de estoques utilizado na Empresa P.
- b) Calcular o estoque de segurança, a partir das previsões realizadas (seis períodos à frente) com base nos níveis de serviço desejados.
- c) Dimensionar o estoque máximo para os níveis de serviço estabelecidos pela empresa.
- d) Demonstrar possíveis ganhos financeiros advindos do ajuste de estoques.

Nota: A sétima etapa será aplicada somente aos dois componentes da Empresa P, conforme acordo entre o pesquisador e a empresa.

Para facilitar o entendimento da metodologia proposta, as sete etapas são apresentadas na Figura 09, em forma de fluxograma:

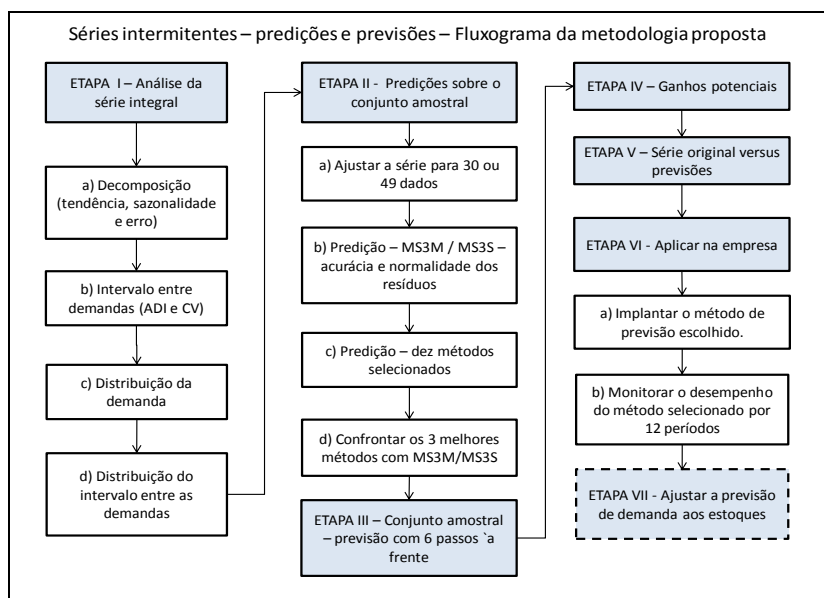


Figura 09 – Fluxograma da metodologia proposta – investigação do melhor método de previsão e ajuste do estoque.

Neste capítulo foram enfatizados:

- i) Os modelos de previsão a serem utilizados na investigação prática (Capítulo 4);
- ii) A elaboração de uma rotina que permita encontrar a constante de suavização (alfa) que produza as melhores previsões para alguns dos métodos citados no item i);
- iii) O passo a passo da metodologia, conforme o fluxograma da Figura 09. No próximo capítulo a abordagem será prática, quando dez métodos de previsão serão testados e os três melhores escolhidos e comparados entre si – sempre com foco na menor diferença entre o previsto e o real.

CAPÍTULO 4 - APLICAÇÃO DA METODOLOGIA EM CASOS PRÁTICOS

Por questões de confidencialidade, as empresas receberão nomes fictícios neste estudo. A Empresa P é uma fabricante de sistemas de pintura industrial e conta com aproximadamente 120 funcionários, está há mais de 20 anos no mercado e fornece sistemas de pintura para os mercados: brasileiro e sul americano. Dois componentes foram disponibilizados para o estudo: kit pistola para pintura e meio filtrante – cujas demandas são intermitentes. A Empresa H é um hospital, com 12 anos de funcionamento, conta com 165 leitos, três UTIs (geral, cardiológica e neonatal) e maternidade. O componente selecionado para o estudo é um sensor de oximetria, utilizado na UTI Neonatal – cuja demanda também é intermitente.

4.1 A EMPRESA DO SEGMENTO INDUSTRIAL

4.1.1 Breve Histórico

Instalada no Norte Catarinense, a empresa P é especializada em sistemas de pintura para a indústria em geral. Além de fabricar e entregar novos sistemas de pintura ao mercado, ela também presta assistência técnica a seus clientes, repondo componentes. Isto exige que mantenha um bom nível de componentes em estoque. Conforme relatado pela empresa, o seu almoxarifado de peças – que atende tanto a área de fabricação quanto a assistência técnica a clientes – tem a seguinte composição financeira: 70% equivalem a materiais importados e 30% representam as peças nacionais. Em volume de materiais, a relação é inversa: 70% dos materiais são de origem nacional e 30% são importados. Considerando que importar peças exige um *lead time* (tempo de aquisição) mais longo e considerando ainda que alguns itens são marcados pela demanda intermitente, a Empresa P está bem interessada em aprimorar seu método de previsão de demanda, principalmente para os componentes de custo unitário mais elevado. Em reunião realizada com a direção da Empresa P, foram definidos dois componentes para este estudo: a) kit pistola para pintura e b) meio filtrante.

4.1.2 Componente Kit Pistola

Este componente é importado da Europa e seu custo unitário, tomando por base 30/04/2013, é de R\$ 5.393,93. O processo de aquisição (*lead time*) é de seis semanas (aproximadamente 45 dias). Mas, considerando os efeitos da burocracia (documentação, aduana, etc.), a empresa P considera doze semanas (três meses). O modal de transporte é aéreo e é preferido pelo cliente, dado o baixo peso do componente. O cliente deseja oferecer ao seu mercado um nível de serviço entre 95 a 97%. No final de abril/2013, havia vinte peças de kit pistola em estoque, totalizando R\$ 107.878,00 no inventário.

A partir de uma série temporal com os últimos trinta e seis consumos mensais (maio 2010 a abril 2013), elaborou-se a estatística descritiva, que é apresentada no Apêndice I. O Kit ‘pistola automática’ é composto de: pistola pulverizadora de tinta, bomba de pó, cabo e fonte de alimentação.

4.1.3 Componente Meio Filtrante

Também importado da Europa, este componente tem por meta filtrar os resíduos oriundos dos processos de pintura. Trata-se de uma manta, tipo papel-filtro e cuja função é similar a de um coador de café. Sua descrição técnica é: Meio filtrante (falso tecido) de poliéster plissado, fibras sobrepostas, termo ligado, com peso superior a 150 g/m², utilizado na montagem de filtros para remoção de poeira em ambientes industriais, FS 1200 mm. Seu custo unitário não é elevado (R\$ 306,89), mas o volume consumido sim. Desta forma, os clientes requisitam, normalmente, várias peças num único pedido – sendo a reposição o principal mercado. No Apêndice O apresenta-se a estatística descritiva desta série temporal, também com trinta e seis dados (maio 2010 a abril 2013). No final de abril/2013 a Empresa P dispunha em seu almoxarifado um total de 381 unidades do Meio Filtrante, o que significa R\$ 116.925,09 em inventário.

4.1.4 Aplicação da metodologia para o kit pistola

A) Análise do conjunto de dados

A série temporal do componente Kit Pistola inicia-se em Maio/2010 e termina em Abril/2013, totalizando trinta e seis meses de observações (ver Apêndice I). Percebe-se que há alguns ‘zeros’, indicando meses com ausência de demanda. A Figura 10 mostra o gráfico de linha desta série.




Figura 10– Componente Kit pistola – demanda e intermitência (zeros) ao longo do tempo.

B) Componentes da série

Aplicou-se a função ‘*decompose*’ e o *R* retornou num gráfico os três componentes da série: tendência, sazonalidade e aleatoriedade. A Figura 11 mostra a série decomposta. A tendência é decrescente ao longo do tempo e a sazonalidade parece ser do tipo aditiva, com comportamento bem regular e a componente aleatória não apresenta surpresas.

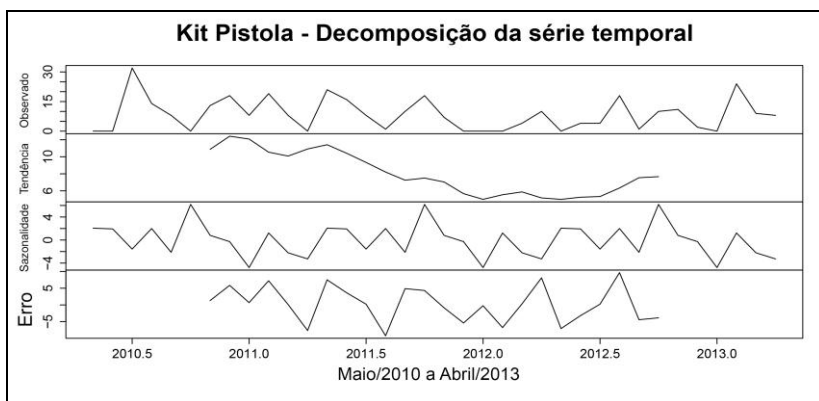


Figura 11 – Kit pistola – a série apresenta erro aditivo, tendência e sazonalidade.

C) Intermitência da demanda e coeficiente de variação

Regattieri et al. (2005) apresentaram uma classificação para as séries temporais intermitentes, sendo: baixa demanda (*slow moving*), demandas erráticas (*erratic*), intermitente (*intermittent*) e demandas maiores, mas de forma ocasional (*lumpy*). Esta classificação é obtida pelo cálculo do ADI – Intervalo Médio entre Demandas e do CV – Coeficiente de Variação. Estes cálculos foram realizados em planilha eletrônica e o resultado está no Apêndice J. Como já constatado, há uma pequena divergência na literatura, pois Regattieri *et al.* (2005) recomendam um ADI > 1,32 para considerar a série intermitente, enquanto Johnston & Boylan (1996) recomendam um ADI > 1,25. A série demonstra ADI = 1,33 e se classifica como intermitente. Já o CV está acima do mínimo recomendado: CV = 0,65 > 0,49.

D) Distribuição da demanda

Alguns pesquisadores alertam que séries intermitentes não possuem distribuição normal na demanda (CROSTON, 1972; JOHNSTON e BOYLAN, 1996; JOHSTON, BOYLAN e SHALE, 2003; LEVÉN e SEGERSTEDT, 2004). A Figura 12 apresenta o histograma das demandas para o Kit pistola, confirmando a não normalidade na distribuição.

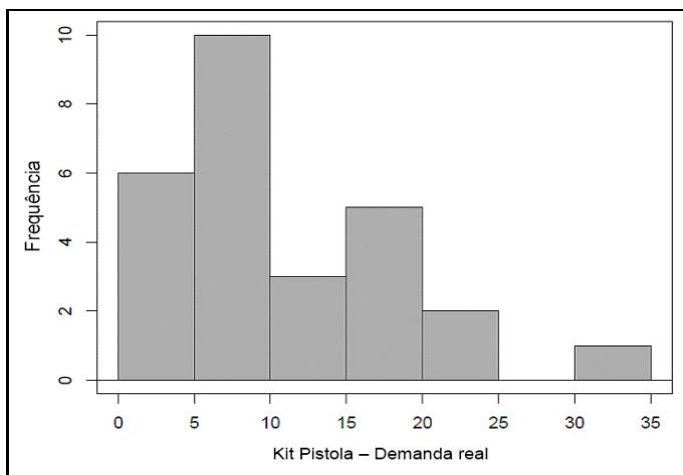


Figura 12 – Kit pistola – demanda real (demandas nulas foram suprimidas)

E) Distribuição do intervalo entre as demandas

A Figura 13 traz o histograma da distribuição do intervalo entre as demandas para o componente Kit pistola. É notório que os intervalos entre demandas estão, na sua maioria entre um a dois períodos, demonstrando que a série não tem longos períodos sem demanda.

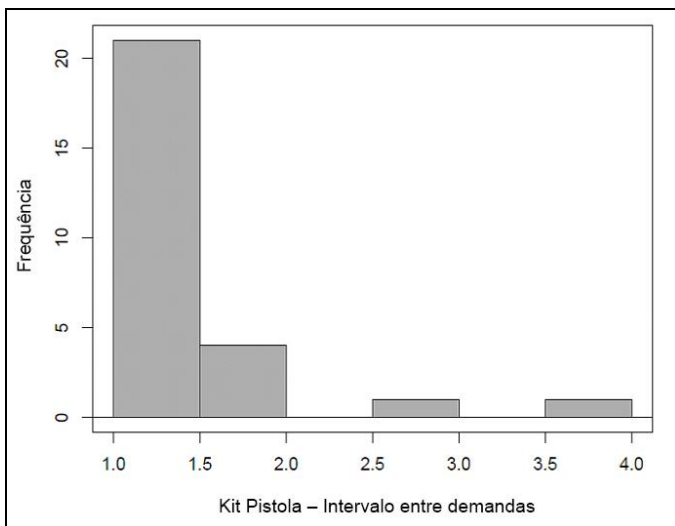


Figura 13 – Kit pistola – intervalo entre as demandas (períodos = meses).

F) Conjunto amostral – previsão pelo Método da Média Simples dos últimos três períodos

Apesar da Empresa P possuir seu próprio *software* de gestão – e que apenas informa o “consumo médio dos últimos três meses” – neste trabalho utilizar-se-á planilha eletrônica para calcular a previsão pela média simples dos últimos três períodos (MS3M). Quatro indicadores, já descritos na seção 3.5, serão empregados:

- i) Desvio médio (DM);
- ii) Raiz quadrada do desvio quadrado médio (RQDQM);
- iii) Desvio absoluto médio (DAM);
- iv) Desvio absoluto médio escalar (MASE).

Na previsão com trinta dados, o Método MS3M forneceu: DM = -0,568; RQDQM = 8,471; DAM = 7,086 e MASE = 0,784, indicando que o método é superior em 16% ($1,00 - 0,784 = 0,16$). Os resíduos para

este método apresentaram um comportamento muito bem distribuído, com p -valor = 0,9461. Estes resultados foram incorporados na Tabela 04, item 1 - onde são comparados com os outros dez métodos de previsão.

G) Conjunto amostral: predição pelos dez métodos selecionados e comparados ao método da Empresa P.

Nesta seção, aplicaram-se os dez métodos selecionados (NNQ-STAT, SB5, TS6, SES, SES(OT), Holt, HW, ARIMA, CR-D e CR-Z) e os resultados das predições estão nas Tabelas 03 e 04. Percebe-se que o método NNQ-STAT entregou um modelo Holt-Winters, com erro aditivo, tendência adormecida e sazonalidade aditiva. Associado com os métodos: TS6 e SB5, que são métodos de Croston modificados, estes se sobrepuseram aos demais e ao método utilizado pelo cliente. A menor discrepância de cada indicador – RQDQM, DAM e MASE - está assinalada em negrito. O Apêndice K traz o script e os resultados para os métodos: ARIMA, HW, Holt, SES, SES(OT), CR-D e CR-Z calculados no *software R*. O Método SB5 está no Apêndice L, o Método TS6 no M e o Apêndice N apresenta o Método NNQ-STAT, calculados em planilha eletrônica.

Tabela 03 – Kit pistola - Conjunto amostral: ferramentas, métodos e coeficientes utilizados.

Item	Ferramenta	Método	Modelo espaço estado (ETS)	Coeficientes
1	Planilha eletrônica	MS3M (Empresa P)		---
2	Planilha eletrônica	NNQ-STAT	A,Ad,A	$\alpha = 0,01$; $\beta = 0,01$; $\gamma = 0,01$; $\varphi = 0,99$
3	Planilha eletrônica	SB5		$\alpha = 0,10$

4	Planilha eletrônica	TS6		$\alpha = 0,10$
5	R	SES	A,N,N	$\alpha = 1E-4$
6	R	SES(OT)	A,N,N	$\alpha = 0,10$
7	R	Holt	A,A,N	$\alpha = 1E-4;$ $\beta = 1E-4$
8	R	HW	A,A,A	$\alpha = 1E-4;$ $\beta = 1E-4;$ $\gamma = 0,4656$
9	R	ARIMA	(0,0,0)	---
10	R	CR-D		$\alpha = 0,10$
11	R	CR-Z		$\alpha = 0,10$

Legenda:

NNQ-STAT: suplemento escrito em VBA, para suavização exponencial.

SB5: Método de Syntetos & Boylan (2005).

TS6: Método de Teunter & Sani (2006).

SES: Suavização exponencial simples.

SES(OT): Suavização exponencial simples com alfa otimizado.

ARIMA: Auto regressivo Integrado de Médias Móveis.

CR-D: Método de Croston padrão do R (default).

CR-Z: Método de Croston modificado (alfa otimizado).

Tabela 04 – Kit pistola - Conjunto amostral – Predições - Comparativo entre o método do cliente e os métodos do estudo

Item	Método	DM	RQDQM	DAM	MASE	Resíduos (p-valor)	Classificação
1	MS3M	-0,568	8,471	7,086	0,784	0,9461	
2	NNQ-STAT	0,225	7,443	6,257	0,683	0,1910	1º
3	SB5	-0,194	7,744	6,320	0,700	0,0757	3º
4	TS6	-0,860	7,525	6,112	0,677	0,1713	2º
5	SES	-0,248	8,081	6,597	0,516	0,0037	
6	SES(OT)	-0,796	8,301	6,889	0,539	0,0153	
7	Holt	0,958	8,045	6,399	0,501	0,0122	
8	HW	0,596	10,154	7,106	0,556	0,1415	
9	ARIMA	3,330	8,077	6,547	0,512	0,0037	
10	CR-D	-0,609	9,073	6,902	0,540	0,0015	
11	CR-Z	-0,609	9,073	6,902	0,540	0,0015	

H) Kit pistola: previsão com seis períodos à frente – qualidade das previsões

Atualmente a Empresa P não executa uma previsão de vários períodos à frente. Ela simplesmente utiliza a média simples dos últimos 3 períodos como uma informação para planejar o próximo mês. Mas, para fins didáticos, simulamos a Empresa P executando a previsão do Kit pistola com um horizonte de seis períodos à frente. O objetivo é avaliar a robustez do método atual contra os três novos métodos propostos. As Figuras 14 e 15 mostram o comparativo entre o método empregado pela Empresa P e cada um dos três melhores métodos previamente selecionados: Holt-Winters (NNQ-STAT), TS6 e SB5, todos fora da amostra. Observa-se que para este curto espaço – seis meses de previsão – nenhum dos 3 métodos sobrepuja a MS3M. Mas, há um perigo a ser considerado: sem o uso da ‘rolagem’ das previsões, não é possível prever-se seis períodos à frente com o Método da Média Simples 3 Meses. Por segurança e considerando o médio/longo prazo, recomendamos aplicar o Método TS6 – que é um modelo próprio para séries intermitentes - por um período experimental de 12 meses ou mais. Acredita-se que num período mais longo, TS6 mostrará menores discrepâncias (RQDQM, DAM e MASE) do que o método MS3M em uso na Empresa P. A Figura 16 mostra o conjunto amostral (30 meses) já com a previsão de seis períodos à frente, pelo Método TS6.

KIT PISTOLA - Previsão com 6 passos a frente													
Comparativo: Média Simples últimos 3 períodos (MS3M) vs Método NNQ-STAT													
Série original		Método: MS3M (Cliente)						Método: NNQ-STAT (Holt-Winters - AAdA)					
Período	Observado (qtde)	Previsão (qtde)	Erro de previsão [Prev-Obs] (unid)	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado	Previsão (qtde)	Erro de previsão [Prev-Obs] (unid)	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado
nov/12	11	9,67	-1,33	-12%	1,78	1,33	0,15	6,03	-4,97	-145%	24,68	4,97	0,55
dez/12	2	6,89	4,89	244%	23,90	4,89	0,54	5,42	3,42	71%	11,72	3,42	0,38
jan/13	0	8,85	8,85	100%	78,36	8,85	0,98	2,16	2,16	100%	4,66	2,16	0,24
fev/13	24	8,47	-15,53	-65%	241,21	15,53	1,72	5,84	-18,16	-176%	329,92	18,16	2,01
mar/13	9	8,07	-0,93	-10%	0,86	0,93	0,10	3,53	-5,47	-161%	29,89	5,47	0,61
abr/13	8	8,46	0,46	6%	0,21	0,46	0,05	2,85	-5,15	-164%	26,54	5,15	0,57
Média dos erros (ME):		-0,598						-4,69					
RQDQM		7,597						8,440					
DAM		5,333						6,555					
MASE		0,590						0,726					

Figura 14 – Kit pistola – Comparativo entre o Método MS3M e Método NNQ-STAT - fora da amostra - seis períodos à frente

KIT PISTOLA													
COMPARAÇÃO ENTRE OS MELHORES MODELOS DE PREVISÃO - FORA DA AMOSTRA - COM 6 PASSOS A FRENTE													
Série original		Método: TS6						Método: SB5					
Período	Observado (qtde)	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Obs-Prev]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado
nov/12	11	7,11	-3,89	-35%	15,13	3,89	0,43	6,81	-4,19	-138%	17,56	4,19	0,46
dez/12	2	7,11	5,11	256%	26,11	5,11	0,57	6,81	4,81	141%	23,14	4,81	0,53
jan/13	0	7,11	7,11	100%	50,55	7,11	0,79	6,81	6,81	100%	46,38	6,81	0,75
fev/13	24	7,11	-16,89	-70%	285,27	16,89	1,87	6,81	-17,19	-172%	295,50	17,19	1,90
mar/13	9	7,11	-1,89	-21%	3,57	1,89	0,21	6,81	-2,19	-124%	4,80	2,19	0,24
abr/13	8	7,11	-0,89	-11%	0,79	0,89	0,10	6,81	-1,19	-115%	1,42	1,19	0,13
Média dos erros (ME):		-1,890						-2,190					
RQDQM		7,973						8,050					
DAM		5,963						6,063					
MASE		0,660						0,671					

Figura 15 – Comparativo: Método TS6 versus Método SB5 - fora da amostra - seis períodos à frente




Figura 16 – Kit pistola – Método TS6 com previsões de seis períodos à frente.

D) Confrontação dos métodos MS3M versus TS6 – previsões sobre a série temporal original

Ao se aplicar os dois métodos de previsão sobre a série original (36 dados), as previsões confirmaram a hipótese levantada na seção 4.5.1.H, revelando a superioridade do Método TS6 sobre o Método MS3M. Focando em três indicadores de acurácia, se tem os seguintes progressos:

- i) RQDQM: $8,568/7,547 =$ melhoria de 11,92%;
- ii) DAM: $6,929/6,009 =$ melhoria de 13,27%.
- iii) MASE: $0,772/0,670 =$ melhoria de 13,21%.

Pode-se prever que no médio prazo (doze meses e adiante), o Método TS6 trará uma melhoria de aproximadamente 12% nas

previsões, o que é significativo para um componente cujo custo de aquisição está na casa dos R\$ 5.000,00 por unidade. A Tabela 05 apresenta os dois métodos, e os menores valores de RQDQM, DAM e MASE estão em negrito. A Figura 17 mostra, graficamente, a predição dos dois métodos. Observa-se que TS6 tem um comportamento mais balanceado nas predições, auxiliando na redução das discrepâncias (erros de previsão).

Tabela 05 – Kit pistola – desempenho dos métodos MS3M e TS6 – predições sobre a série original (36 dados)

Item	Método	DM	RQD QM	DAM	MA SE	Resíduos (p-valor)	Coefficientes
1	MS3M	-0,303	8,568	6,929	0,772	0,9847	---
2	TS6	-0,450	7,547	6,009	0,670	0,2388	$\alpha = 0,10$




Figura 17 – Kit pistola – predições sobre a série original – métodos MS3M e TS6

J) Análise do estoque

Nas áreas: industrial ou de serviços, previsões normalmente impactam em estoques. Estoques, por sua vez, são custos e devem ser minimizados, embora devam equilibrar o custo financeiro e o adequado atendimento ao cliente (nível de serviço). Para a Empresa P realizou-se uma análise do sistema de controle de estoques. Em entrevista com a empresa e a verificação dos dados de estoque, descobriu-se que a empresa opera com o sistema de revisão periódica, apesar de, num

primeiro momento afirmarem que operavam no sistema de revisão contínua.

Os dois mais conhecidos sistemas de controle de estoque são: sistema de reposição contínua e sistema de reposição periódica. No sistema contínuo, sempre que o estoque cair até um nível pré-determinado, chamado ponto de reposição, uma ordem de compra (quantidade fixa) é disparada, não importando o intervalo entre as compras. Já no sistema de revisão periódica, o nível de estoque é revisado em intervalos fixos, isto é, diário, semanal, mensal e assim por diante. Neste caso, as quantidades a serem adquiridas, para novamente completar o estoque máximo (T), são variáveis. Isto pode ser expresso pela equação:

$$Q = NM - NR \quad (80)$$

onde:

Q= quantidade a ser adquirida (pedido de ressurgimento);

NM = nível máximo do estoque (T);

NR = nível do estoque no momento da revisão.

Ching (2001) frisa que o método da revisão periódica de estoque (Q móvel) é preferível ao sistema de revisão contínua (Q fixo), especialmente para grandes volumes, quando há possibilidade em se negociar descontos. Do lado do comprador, revisão periódica pode significar uma menor quantidade de pedidos emitidos. O método da revisão periódica requer um estoque de segurança que consiga suprir a demanda durante o lead time (tempo de ressurgimento) e as demais aleatoriedades pertinentes ao processo. Também requer o cálculo do estoque máximo, evitando assim compras excessivas, que impactam tanto financeiramente quanto na acomodação deste volume de estoque na empresa.

Para o componente Kit Pistola, foram investigados:

- J1) Demanda média dos últimos 12 meses e seu respectivo desvio padrão;
- J2) Cálculo do lead time médio e seu desvio padrão;
- J3) Cálculo do estoque de segurança versus o estoque de segurança praticado na Empresa P;

- J4) Cálculo do estoque máximo – volume desejável confrontado com a prática corrente;
- J5) Nível de serviço desejado e o efetivamente realizado;
- J6) Impacto financeiro para implementar o estoque de segurança e o estoque máximo.

J1) Demanda média e seu desvio padrão

Na Figura 18 é apresentada a demanda média dos últimos doze meses que compõe a série temporal. Mesmo com alguma intermitência, a média de consumo do item é de 7,58 pcs/mês, enquanto o desvio padrão situa-se em 7,46 pcs/mês.

KIT PISTOLA: 25 - 36 M		
Datas	t	O(t)
mai/12	25	0,00
jun/12	26	4,00
jul/12	27	4,00
ago/12	28	18,00
set/12	29	1,00
out/12	30	10,00
nov/12	31	11,00
dez/12	32	2,00
jan/13	33	0,00
fev/13	34	24,00
mar/13	35	9,00
abr/13	36	8,00
Média (d)		7,58
Desvio padrão (σ)		7,46

Figura 18 – Kit pistola – demanda últimos 12 meses, com média e desvio padrão.

J2) Cálculo do *lead time* médio e seu desvio padrão

Foram investigados os últimos 12 pedidos, inicialmente calculados em número de dias e posteriormente adaptados para o formato mensal. Em média, o *lead time* – também conhecido como tempo de

ressuprimento ou tempo de reabastecimento, é da ordem de 2,45 meses. Deve-se lembrar de que este componente é importado (via aérea) e um dos fatores impactantes neste tempo é a burocracia alfandegária quando da chegada do componente ao Brasil. Apesar do *lead time* médio aproximar-se dos 75 dias, o desvio padrão deste processo de compra/importação é relativamente pequeno (28 dias), o que impactará positivamente no cálculo do estoque de segurança. A Figura 19 apresenta o *lead time* médio do Kit Pistola, seu desvio padrão e outras informações estatísticas.

KIT PISTOLA				
Período	Tempo de Ressuprimento (<i>lead time</i>)			
	Data Pedido	Chegada Pedido	Número de dias	Núm meses
1	11/04/2011	25/06/2011	75	2,50
2	26/06/2011	19/09/2011	85	2,83
3	20/09/2011	09/12/2011	80	2,67
4	10/12/2011	29/03/2012	110	3,67
5	30/03/2012	11/05/2012	42	1,40
6	12/05/2012	11/09/2012	122	4,07
7	12/09/2012	19/10/2012	37	1,23
8	20/10/2012	29/11/2012	40	1,33
9	30/11/2012	05/02/2013	67	2,23
10	06/02/2013	26/03/2013	48	1,60
11	27/03/2013	11/06/2013	76	2,53
12	12/06/2013	19/09/2013	99	3,30
		MÍNIMO:	37	1,23
		MÁXIMO:	122	4,07
		MÉDIA:	73,42	2,45
		MEDIANA:	75,50	2,52
		DESVIO PADR	28,05	0,94

Figura 19 – Kit pistola – *Lead time* (tempo de ressuprimento) e sua estatística descritiva.

J3) Cálculo do estoque de segurança

A Empresa P definiu, em seu controle de estoque, três níveis para o componente kit pistola: Estoque máximo = 38 peças, Estoque de segurança = 19 peças e um Estoque mínimo = 3 peças. Como opera no sistema de revisão periódica, este estoque mínimo de 3 peças não faz muito sentido. Será proposta uma readequação no Estoque de Segurança (ES) e no Estoque Máximo (T).

Como o método TS6 apresentou as melhores previsões de demanda para este componente, foram então utilizados os seis últimos períodos da série temporal para o cálculo do desvio padrão entre as quantidades planejadas e as efetivamente demandadas. A equação utilizada foi extraída do trabalho de Staudt (2011):

$$\sigma_D = \sqrt{\frac{\sum_{i=1}^n (x_i - x_m)^2}{n - 1}} \quad (81)$$

onde:

x_i – valor de determinada diferença entre previsão de demanda e demanda;

x_m – média das diferenças entre previsão de demanda e demanda

n – numero de períodos analisados

Quanto ao nível de serviço (NS), a empresa deseja operar num intervalo de confiança de 95%, isto é, em cada cem demandas dos clientes, admitem-se cinco ordens incompletas ou não atendidas. Na prática corrente, o nível de serviço não é mensurado e faltas esporádicas de peças tem ocorrido. A Figura 20 demonstra o cálculo do desvio padrão σ_D , realizado em planilha eletrônica.

Empresa P							
Componente: Kit pistola							
Previsão com 6 períodos à frente - Cálculo do desvio padrão entre previsão e demanda real							
Período	Observado (qtde)	Previsão (qtde)	$x_i = \text{prev} - \text{observ}$	$x_m = \text{média das difer. (prev-obs)}$	$(x_i - x_m)$	$(x_i - x_m)^2$	$\sigma_D = \text{raiz}(\Sigma/(n-1))$
nov/12	11	7,11	-3,89	-1,89	-2,00	4,00	
dez/12	2	7,11	5,11	-1,89	7,00	49,00	
jan/13	0	7,11	7,11	-1,89	9,00	81,00	
fev/13	24	7,11	-16,89	-1,89	-15,00	225,00	
mar/13	9	7,11	-1,89	-1,89	0,00	0,00	
abr/13	8	7,11	-0,89	-1,89	1,00	1,00	
x_i = diferença entre valor previsto e demanda real; x_m = Média das diferenças entre previsão de demanda e demanda real; n = 6 meses; σ_D = desv padr prev x demanda			-1,89		Somatório (Σ)	360,00	8,4853
Fonte: Fórmulas conforme STAUDT (2011).							

Figura 20 – Kit pistola – desvio padrão entre demanda planejada e demanda real

Para o cálculo do estoque de segurança (ES), foram utilizadas três diferentes abordagens:

- i) As fórmulas propostas no trabalho de Rosa, Mayerle e Gonçalves (2010);
- i) As equações extraídas do trabalho de Werner, Lemos e Daudt (2006) e,
- ii) As equações sugeridas na pesquisa de Staudt (2011).

Todas as equações são pertinentes ao sistema de revisão periódica de estoques (P). Percebem-se na Figura 21 que os métodos de Rosa e Staudt entregaram quantidades iguais para o estoque de segurança – com um nível de serviço de 95% ($z = 1,645$), enquanto que a abordagem de Werner, Lemos e Daudt (2006) entregou quantidade menor. Por segurança, optou-se por manter o ES no nível obtido por Staudt e Rosa, isto é, vinte e seis peças. A quantidade selecionada está destacada em negrito. Observar ainda que foram aplicados três níveis de serviço: 95, 98 e 99,87%, apenas para futura demonstração à Empresa P. Torna-se óbvio de que, quanto mais alta a exigência de serviço, mais carregado será o ES, o que pode ser comprovado pelo volume financeiro (R\$).

KIT PISTOLA							
Cálculo do estoque de segurança (ES)							
Metodologias empregadas: Rosa, Werner e Staudt							
Nível de serviço desejado (%)	z (desvio padrão padronizado)	Rosa		Werner		Staudt	
		Qtde (pc)	Qtde x custo unit (R\$)	Qtde (pc)	Qtde x custo unit (R\$)	Qtde (pc)	Qtde x custo unit (R\$)
95,00	1,645	26	140.242,18	23	124.060,39	26	140.242,18
98,00	2,054	32	172.605,76	28	151.030,04	32	172.605,76
99,87	3,000	47	253.514,71	42	226.545,06	47	253.514,71

Figura 21 – Kit pistola – Cálculo do estoque de segurança para nível de serviço 95%.

J4) Cálculo do estoque máximo

Atualmente, a empresa tem definido o estoque máximo (T), também chamado de estoque total, em 38 peças. O responsável pelas compras não sabe quem, quando e como este valor foi definido. Baseado nas metodologias extraídas dos trabalhos de Werner et al (2006) e Rosa (2010), conclui-se que este estoque máximo deva ser superior a 38 peças, isto é, 49 peças, de forma a abrigar as flutuações inerentes a este componente (demanda intermitente, lead time, imprevistos, etc.). Tanto para a adequação do ES quanto para regularizar o estoque máximo (T), a Empresa P terá algum desembolso financeiro, pois os critérios atuais

não oferecem adequada margem de segurança quanto ao nível de serviço desejado (95%). No confronto dos resultados, optou-se pela metodologia de Werner, por oferecer quantidade menor de estoque máximo. Isto se deve ao custo unitário do kit pistola, que ultrapassa os R\$ 5.000,00. A Figura 22 aponta o volume ideal de peças para o estoque máximo (T).

KIT PISTOLA								
Cálculo do estoque total (T) - nível máximo								
Metodologias empregadas: Rosa e Werner								
Nível de serviço desejado (%)	z (desvio padrão padronizado)	Rosa		Werner		Diferença (qtde)	Diferença (%)	Diferença (R\$)
		Qtde (pc)	Qtde x custo unit (R\$)	Qtde (pc)	Qtde x custo unit (R\$)			
95,00	1,645	50	269.696,50	49	264.302,57	1	2,04%	5.393,93
98,00	2,054	58	312.847,94	54	291.272,22	4	7,41%	21.575,72
99,87	3,000	73	393.756,89	68	366.787,24	5	7,35%	26.969,65

Figura 22 – Kit pistola – estoque máximo proposto

J5) Nível de serviço desejado

Os níveis de serviço podem ser escalonados em diversos patamares e tem por função atender prontamente aos pedidos do cliente (demandas). Se por exemplo, a empresa fixar seu nível de serviço em 98%, isto significa uma probabilidade de que em cada 100 pedidos vindos do cliente, noventa e oito deles poderão ser atendidos imediatamente. Os outros dois pedidos ou estarão incompletos (faltam peças para completar o lote solicitado) ou nulos (ausência da peça no estoque). Em inglês, isto é chamado de *stock out*.

Conhecendo bem a sua carteira de clientes, a Empresa P definiu o nível de serviço de 95% para o Kit Pistola. Ela argumenta que eventuais faltas (probabilidade de 5 em 100 pedidos) são toleráveis e o cliente concorda em receber seu pedido parcialmente ou aguardar alguns dias até o pedido completo ser entregue. Ao investigar o atual nível de serviço para o Kit Pistola, verificou-se que a empresa não vem respeitando o estoque de segurança, fechando os meses com quantidades em estoque muito aquém da margem de segurança. Fatalmente, isto impactará negativamente no NS. Tomando a equação (66) e conhecendo o ES, foi possível calcular o desvio padronizado Z_{α} e a partir deste, o nível de serviço.

$$ES = Z_{\alpha} * \sigma_D * \sqrt{IR * TR} \quad (82)$$

que pode ser reescrita como:

$$Z_{\alpha} = \frac{ES}{\sigma_D * \sqrt{IR * TR}} \quad (83)$$

onde:

ES = estoque de segurança;

Z_{α} = desvio padronizado;

σ_D = desvio padrão entre previsão e demanda

IR = intervalo de revisão

TR = tempo de reposição (lead time)

Em seguida, com a ajuda da tabela de distribuição normal, pôde-se calcular o equivalente NS para estes baixos estoques. A Figura 23 aponta estes resultados e servirá para alertar a empresa que seu nível de serviço está bem aquém do desejado (95%). Fechando o mês com somente cinco peças em estoque, a empresa corre o risco de não atender ao próximo pedido em 33%, pois o NS caiu a 67%. Somente quando o volume de estoque sobrepõe-se ao ES (26 peças) – veja fevereiro e março/2013 – então o NS supera os 95%. Lembrando que o *lead time* médio é de 2,45 meses e a demanda média mensal de 7,58 peças, o atendimento aos pedidos dos clientes, no mês seguinte, estará bem fragilizado.

Empresa P							
Componente: Kit pistola							
Nível de serviço desejado: 95%							
Nível do Estoque de Segurança vs Nível de Serviço - Fechamento do mês							
Data	Estoque fechamento mês	Estoque Secur. (qtde)	Diferença Estoque fechamento vs Est Seg	Z α (Nível serviço em desvios padronizados)	Valor tabela distr norm	Nível serviço real	Notas
30/11/2012	7	26	-19	0,44	0,3300	67,00%	Abaixo da meta (95%)
30/12/2012	5	26	-21	0,32	0,3745	62,55%	Abaixo da meta (95%)
30/01/2013	5	26	-21	0,32	0,3745	62,55%	Abaixo da meta (95%)
28/02/2013	27	26	1	1,71	0,0436	95,64%	OK
30/03/2013	28	26	2	1,78	0,0375	96,25%	OK
30/04/2013	20	26	-6	1,27	0,1020	89,80%	Abaixo da meta (95%)

Figura 23 – Kit pistola – Nível de serviço desejado versus real – para atendimento a 95%.

J6) Impacto financeiro para readequar o estoque de segurança e o estoque máximo.

Da Figura 23 é fácil deduzir de que a Empresa P deverá desembolsar certo volume financeiro para organizar tanto seu estoque de segurança (26 peças) quanto seu estoque máximo (49 peças). Este sacrifício inicial será compensado com a tranquilidade na gestão do estoque, permitindo que as revisões periódicas ocorram sem sobressaltos. O impacto financeiro mais detalhado desta operação de elevação dos estoques será mostrado no item 4.2.2 – subitem J6, conjuntamente com o componente Meio Filtrante.

4.1.5 Aplicação da metodologia para o meio filtrante

A) Análise do conjunto de dados

A série temporal do componente Meio filtrante também inicia em Maio/2010 e termina em Abril/2013, totalizando trinta e seis meses de observações, que são apresentadas na Figura 24.

MEIO FILTRANTE								
Datas	t	O(t)	Datas	t	O(t)	Datas	t	O(t)
mai/10	1	100	mai/11	13	100	mai/12	25	100
jun/10	2	0	jun/11	14	0	jun/12	26	0
jul/10	3	100	jul/11	15	122	jul/12	27	0
ago/10	4	0	ago/11	16	158	ago/12	28	0
set/10	5	0	set/11	17	0	set/12	29	142
out/10	6	100	out/11	18	0	out/12	30	112
nov/10	7	0	nov/11	19	0	nov/12	31	150
dez/10	8	91	dez/11	20	0	dez/12	32	0
jan/11	9	0	jan/12	21	100	jan/13	33	150
fev/11	10	122	fev/12	22	105	fev/13	34	0
mar/11	11	0	mar/12	23	0	mar/13	35	0
abr/11	12	58	abr/12	24	0	abr/13	36	100

Figura 24 – Meio filtrante – série temporal com 36 dados.

Comparativamente ao componente Kit pistola, a série temporal do Meio filtrante possui mais ‘zeros’, indicando maior ausência de demanda. A Figura 25 mostra o gráfico de linha desta.




Figura 25 – Componente Meio filtrante – demanda e intermitência (zeros) ao longo do tempo.

B) Componentes da série

Aplicou-se a função ‘*decompose*’ e o *R* retornou num gráfico os três componentes da série: tendência, sazonalidade e aleatoriedade. A Figura 26 mostra a série decomposta graficamente. A tendência decresce e volta a subir dando uma ideia de ausência desta no contexto da série e a sazonalidade parece ser do tipo aditiva, com um comportamento bem regular e a componente aleatória não apresenta surpresas.

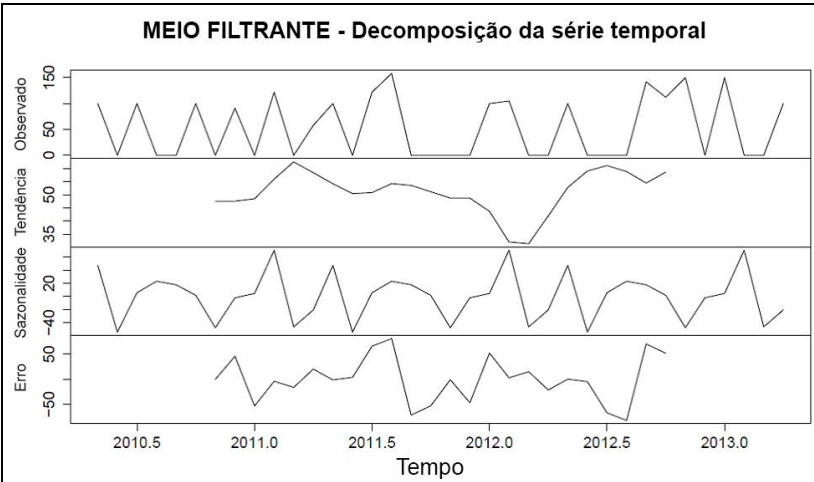


Figura 26 – Meio filtrante – a série apresenta erro e sazonalidade aditivas.

C) Intermitência da demanda e coeficiente de variação

Com um ADI = 2,19, o Meio filtrante apresenta demandas mais intercaladas do que o Kit pistola. Já o CV = 0,22 denota pouca variação nas quantidades demandadas.

D) Distribuição da demanda

Somente demandas de uma ou mais peças foram consideradas. As várias demandas nulas (ausência de demanda) presentes na série foram suprimidas durante a elaboração do histograma. Não se observa a distribuição normal, ratificando a literatura.

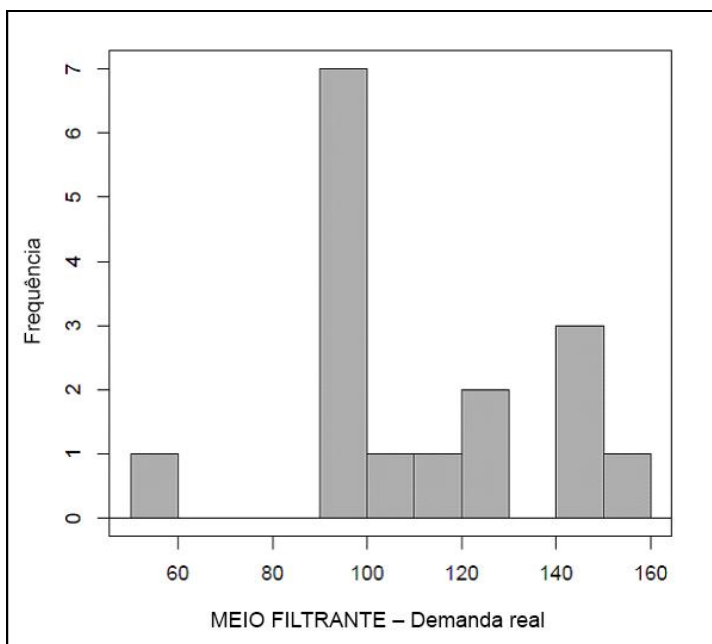


Figura 27 – Meio filtrante – demanda real (demandas nulas foram suprimidas)

E) Distribuição do intervalo entre as demandas

A Figura 28 traz o histograma da distribuição do intervalo entre as demandas para o componente Meio filtrante. Os intervalos entre demandas oscilam entre um e cinco períodos, demonstrando que a série já é mais intermitente do que a série do Kit pistola.

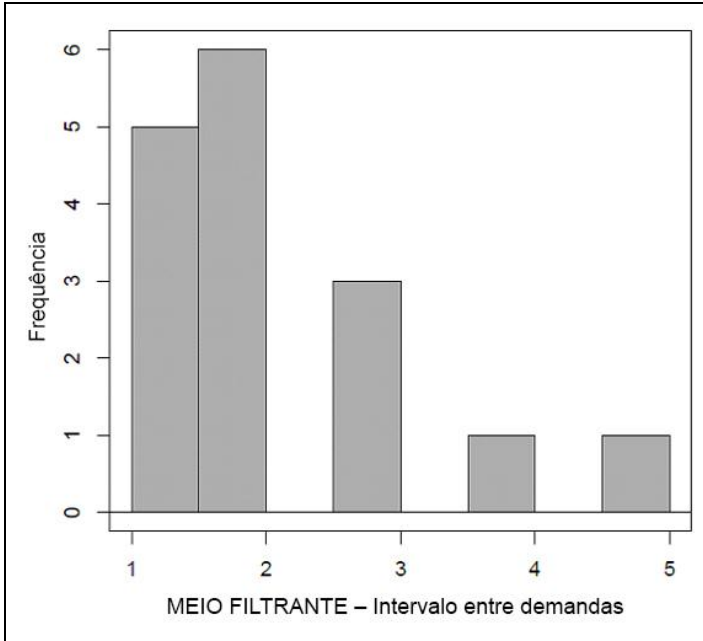


Figura 28 – Meio filtrante – intervalo entre as demandas (períodos = meses).

F) Predições sobre o conjunto amostral - comparativo entre o método do cliente e os dez métodos selecionados.

Para realizar as predições no conjunto amostral, suprimiram-se os seis dados finais da série completa Meio filtrante (dados 31 a 36). Posteriormente, estes serão usados no estudo da previsão “fora da amostra”. Para os 30 dados, repetiram-se as predições com os onze métodos: cliente e dez do estudo. As Tabelas 06 e 07 apresentam os resultados. O *software* NNQ-STAT apresenta um modelo Holt-Winters com $ETS = A,N,A$, indicando erro aditivo, sem tendência e com sazonalidade aditiva. Os valores de DAM e MASE são os mais baixos entre todos os dez métodos. Já o R, que também aponta para um modelo Holt-Winters, entrega o $ETS = A,A,A$, isto é, com a presença de tendência. Parece que a tendência quase não tem influência sobre a série, o que permite ao modelo A,N,A entregar o menor desvio quadrado médio ($RQDQM = 44,916$). Apesar da intermitência da série, a SES surge em terceiro lugar como uma boa alternativa de previsão da demanda. Já os modelos Croston, próprios para demandas intermitentes,

não conseguem competir com o Método Holt-Winters. Observou-se ainda que o Método ARIMA assemelhou-se muito com a SES. As menores discrepâncias obtidas nos três indicadores de acurácia – **RQDQM**, **DAM** e **MASE** são destacados em negrito. No Apêndice P estão os métodos ARIMA, SES, SES(OT), Holt, HW, CR-D e CR-Z desenvolvidos em R. O Método SB5 está no Apêndice Q, o Método TS6 no Apêndice R e a ferramenta NNQ-STAT no Apêndice S, sendo estes três desenvolvidos em planilha eletrônica.

Tabela 06 – Meio filtrante – Conjunto amostral: ferramentas, métodos e coeficientes utilizados.

Item	Ferramenta	Método	Modelo espaço-estado (ETS)	Coeficientes
1	Planilha eletrônica	MS3M (cliente)		---
2	Planilha eletrônica	NNQ-STAT	A,N,A	$\alpha = 0,01$; $\beta = 0,00$; $\gamma = 0,01$; $\varphi = 0,00$
3	Planilha eletrônica	SB5		$\alpha = 0,18$
4	Planilha eletrônica	TS6		$\alpha = 0,18$
5	R	SES	A,N,N	$\alpha = 1E-4$
6	R	SES(OT)	A,N,N	$\alpha = 0,18$
7	R	Holt	A,A,N	$\alpha = 4E-4$; $\beta = 4E-4$
8	R	HW	A,A,A	$\alpha = 3E-4$; $\beta = 2E-4$; $\gamma = 2E-4$
9	R	ARIMA	(0,0,0); $\mu \neq 0$	---
10	R	CR-D		$\alpha = 0,10$
11	R	CR-Z		$\alpha = 0,18$

Tabela 07 – Meio filtrante – predições no conjunto amostral - comparativo entre o método do cliente e os métodos do estudo

Item	Método	DM	RQDQM	DAM	MASE	Resíduos (p-valor)	Classificação
1	MS3M	2,716	68,054	61,728	0,884	0,0247	
2	NNQ-STAT	-1,560	44,916	35,390	0,524	0,2672	1°
3	SB5	4,243	58,241	55,650	0,797	1,8E-4	
4	TS6	-0,171	58,776	56,479	0,809	3,0E-4	
5	SES	-0,001	56,011	53,692	0,895	1,2E-5	3°
6	SES (OT)	1,521	60,688	57,868	0,964	3,5E-4	
7	Holt	1,112	56,092	53,807	0,897	3,6E-5	
8	HW	0,363	53,411	28,730	0,479	1,8E-5	2°
9	ARIMA	4,74 E-15	56,008	53,689	0,895	1,2E-5	
10	CR-D	-22,802	63,401	57,864	0,964	2,6E-3	
11	CR-Z	-16,371	62,315	57,246	0,954	4,2E-3	

G) Meio filtrante - previsão com seis períodos à frente – qualidade das previsões

Tanto para o Kit pistola quanto para o Meio filtrante, a Empresa P utiliza o horizonte futuro de um período à frente (um mês), o que é coerente, pois o Método MS3M, matematicamente, só permite este um passo à frente. Mas, para fins de comparação com os outros métodos selecionados, será aplicada a ‘rolagem’, isto é, usa-se a previsão $P_{(t+1)}$ para prever $P_{(t+2)}$ e assim até atingir $P_{(t+6)}$, em face de ausência de valores observados. As Figuras 30 e 31 trazem os resultados aos pares: MS3M e NNQ-STAT (A,N,A) e Holt-Winters (A,A,A) com SES. No lado esquerdo das figuras têm-se a série original, com os seis últimos dados observados. Comparando-se as Figuras 29 e 30, e focando nos indicadores: RQDQM, DAM e MASE percebe-se que apenas a SES é superior ao método do cliente (MS3M), nas previsões com seis passos à frente. Os métodos Holt-Winters foram fragilizados pela intermitência do período (três demandas nulas) e apresentaram $MASE > 1,00$.

MEIO FILTRANTE													
COMPARATIVO DAS PREVISÕES: MS3M versus NNQ-STAT - FORA DA AMOSTRA - COM 6 PASSOS A FRENTE													
Série original		Método: MS3M						Método: NNQ-STAT (Holt-Winters - A,N,A)					
Período	Observado (qtde)	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalar	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalar
nov/12	150	84,67	-65,33	-44%	4268,44	65,33	0,94	16,89	-133,11	-189%	17717,81	133,11	1,91
dez/12	0	112,89	112,89	100%	12743,90	112,89	1,62	47,25	47,25	100%	2232,50	47,25	0,68
jan/13	150	103,19	-46,81	-31%	2191,63	46,81	0,67	50,03	-99,97	-167%	9994,07	99,97	1,43
fev/13	0	100,25	100,25	100%	10049,44	100,25	1,44	91,82	91,82	100%	8431,18	91,82	1,32
mar/13	0	105,44	105,44	100%	11117,66	105,44	1,51	16,84	16,84	100%	283,44	16,84	0,24
abr/13	100	102,96	2,96	3%	8,75	2,96	0,04	36,24	-63,76	-164%	4065,30	63,76	0,91
Média dos erros (ME):		34,898						-23,489					
RQDQM		82,036						84,384					
DAM		72,280						75,457					
MASE		1,036						1,081					

Figura 29 - Meio filtrante - Previsão com Média Simples 3 Meses e Holt-Winters (NNQ-STAT) - fora da amostra - seis períodos à frente.

MEIO FILTRANTE													
COMPARATIVO DAS PREVISÕES - FORA DA AMOSTRA - COM 6 PASSOS A FRENTE - HOLT-WINTERS versus SUAUIZACÃO EXPONENCIAL													
Série original		Método: Holt-Winters (R Project)						Método: SES (Suavização Exponencial Simples)					
Período	Observado (qtde)	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalado
nov/12	150	4,29	-145,71	-97%	21231,40	145,71	2,09	50,34	-99,66	-166%	9933,03	99,66	1,43
dez/12	0	96,44	96,44	100%	9300,67	96,44	1,38	50,34	50,34	100%	2533,66	50,34	0,72
jan/13	150	3,52	-146,48	-98%	21456,39	146,48	2,10	50,34	-99,66	-166%	9933,03	99,66	1,43
fev/13	0	126,86	126,86	100%	16093,46	126,86	1,82	50,34	50,34	100%	2533,66	50,34	0,72
mar/13	0	5,11	5,11	100%	26,11	5,11	0,07	50,34	50,34	100%	2533,66	50,34	0,72
abr/13	100	62,91	-37,09	-37%	1375,67	37,09	0,53	50,34	-49,66	-150%	2466,57	49,66	0,71
Média dos erros (ME):		-16,812						-16,331					
RQDQM		107,613						70,632					
DAM		92,948						66,667					
MASE		1,332						0,955					

Figura 30 - Meio filtrante - Previsão com Holt-Winters e SES - fora da amostra - seis períodos à frente.

H) Ganhos potenciais com os três melhores métodos de previsão – fora da amostra

No horizonte de seis períodos à frente, entre aplicar o Método da Média Simples 3 Meses e a SES, é possível um ganho conservador de dez por cento (valor intermediário entre RQDQM, DAM e MASE). A outra vantagem é de que a suavização exponencial utiliza todos os dados da série e isto torna este modelo mais robusto e confiável do que o método atual empregado pela Empresa P. A Tabela 08 mostra os ganhos e perdas percentuais entre os diversos métodos de previsão e a Figura 31 exhibe graficamente a SES com previsão de seis passos à frente e os respectivos limites de previsão, isto é, com intervalos de confiança de 80 e 95% respectivamente. A linha verde (central) representa os valores preditos.

Tabela 08 – Meio filtrante – Previsão fora do conjunto amostral - redução das discrepâncias – comparação entre os métodos

Método	RQDQM	Ganho (%)	DAM	Ganho (%)	MASE	Ganho (%)
MS3M (Empresa P)	82,036	0,00	72,280	0,00	1,036	0,00
NNQ-STAT (A,N,A)	84,384	-2,86	75,457	-4,39	1,081	-4,16
Holt-Winters (A,A,A)	107,613	-31,18	92,948	-28,60	1,332	-22,22
SES (A,N,N)	70,632	+13,90	66,667	+7,76	0,955	+8,48




Figura 31 – Meio filtrante – Previsão por SES – 6 passos à frente

I) Confrontação dos métodos MS3M versus SES – previsões sobre a série temporal original

Aplicando-se os dois métodos de previsão sobre a série original (36 dados), as previsões confirmaram o resultado já obtido na seção anterior, de que a SES é superior à MS3M. Focando nos três indicadores de acurácia, se percebe os seguintes progressos:

- i) RQDQM: $71,005/58,639 =$ melhoria de 17,4%;
- ii) DAM: $64,525/56,006 =$ melhoria de 13,20%.
- iii) MASE: $0,865/0,905 =$ piora de 4,62%.

Pode-se dizer que no médio prazo, o Método SES, com uma constante de suavização muito pequena ($\alpha = 0.0001$) trará uma melhoria de aproximadamente 10% nas previsões (tomando-se a média entre RQDQM, DAM e MASE), o que é significativo para o componente Meio filtrante, cujo volume de compras e demandas é acentuado durante o ano. A Tabela 09 apresenta os dois métodos, preditos sobre a série original, e os menores valores de RQDQM, DAM e MASE estão em negrito. A Figura 32 compara graficamente as previsões dos 2 métodos. Como a constante de suavização é muito pequena ($\alpha = 0,0001 = 1/10.000$), a SES praticamente resulta numa linha média por entre a série.

Tabela 09 – Meio filtrante – Predições sobre a série completa (36 meses) - Comparativo entre o método da Empresa P (MS3M) e a SES.

Item	Método	DM	RQD QM	DAM	MA SE	Resíduos (p-valor)	Coefficientes
1	MS3M (Empresa P)	-1,010	71,005	64,525	0,865	0,0449	---
2	SES	0,003	58,639	56,006	0,905	2,9E-6	$\alpha = 1E-4$




Figura 32 – Meio filtrante – MS3M versus SES – comportamento das previsões (36 meses)

J) Análise do estoque

Procedeu-se a investigação dos estoques do componente Meio Filtrante, seguindo os mesmos passos desencadeados no Kit Pistola, a saber:

- J1) Demanda média dos últimos 12 meses e seu respectivo desvio padrão;
- J2) Cálculo do *lead time* médio e seu desvio padrão;
- J3) Cálculo do estoque de segurança versus o estoque de segurança praticado na Empresa P;
- J4) Cálculo do estoque máximo – volume desejável confrontado com a prática corrente;
- J5) Nível de serviço desejado e o efetivamente realizado;

J6) Impacto financeiro para implementar o estoque de segurança e o estoque máximo.

J1) Demanda média e seu desvio padrão

Na Figura 33 é apresentada a demanda média dos últimos doze meses que compõe a série temporal. A intermitência é mais acentuada e a média do período é de 62,83 pcs/mês, enquanto o desvio padrão situa-se em 67,64 pcs/mês.

MEIO FILTRANTE: 25 - 36 M		
Datas	t	O(t)
mai/12	25	100
jun/12	26	0
jul/12	27	0
ago/12	28	0
set/12	29	142
out/12	30	112
nov/12	31	150
dez/12	32	0
jan/13	33	150
fev/13	34	0
mar/13	35	0
abr/13	36	100
Média		62,83
Desvio padrão		67,64

Figura 33 – Meio filtrante – demanda últimos 12 meses, com média e desvio padrão.

J2) Cálculo do *lead time* médio e seu desvio padrão

Os últimos 12 pedidos, inicialmente calculados em número de dias e posteriormente adaptados para o formato mensal. Em média, o *lead time* é de 70 dias (2,35 meses), com desvio padrão de 48 dias (1,6 meses). A

Figura 34 apresenta o *lead time* médio do Meio Filtrante e o desvio padrão deste.

MEIO FILTRANTE				
Período	Tempo de Ressuprimento (<i>lead time</i>)			
	Data Pedido	Chegada Pedido	Número de dias	Núm meses
1	03/05/2011	22/06/2011	50	1,67
2	23/06/2011	16/07/2011	23	0,77
3	17/07/2011	25/09/2011	70	2,33
4	26/09/2011	13/10/2011	17	0,57
5	14/10/2011	26/10/2011	12	0,40
6	27/10/2011	16/11/2011	20	0,67
7	17/11/2011	15/03/2012	119	3,97
8	16/03/2012	31/05/2012	76	2,53
9	01/06/2012	29/10/2012	150	5,00
10	30/10/2012	20/01/2013	82	2,73
11	21/01/2013	19/04/2013	88	2,93
12	20/04/2013	06/09/2013	139	4,63
		MÍNIMO:	12	0,40
		MÁXIMO:	150	5,00
		MÉDIA:	70,50	2,35
		MEDIANA:	73,00	2,43
		DESVIO PADR	48,00	1,60

Figura 34 – Meio filtrante – Tempo de ressuprimento (*lead time*) médio e desvio padrão.

J3) Cálculo do estoque de segurança

Para o componente Meio Filtrante também há três níveis de estoque contemplados no *software* de gerenciamento: Estoque máximo = 1000 peças, Estoque de segurança = 360 peças e um Estoque mínimo = 30 peças. Como opera no sistema de revisão periódica, este estoque mínimo de 30 peças não faz muito sentido. Será proposta uma readequação no Estoque de Segurança (ES) e no Estoque Máximo (T).

Como o método da Suavização Exponencial (SES) apresentou as melhores previsões de demanda para este componente, foram então utilizados os seis últimos períodos da série temporal para o cálculo do desvio padrão entre as quantidades planejadas e as efetivamente demandadas. A equação (83) foi utilizada na obtenção do desvio padrão (σ_D), que resultou em 75,28 pcs/mês.

Quanto ao nível de serviço (NS), a empresa deseja operar num intervalo de confiança de 98%. Na prática corrente, o nível de serviço não é mensurado e faltas esporádicas de peças tem ocorrido.

A Figura 35 demonstra o cálculo do desvio padrão σ_D , realizado em planilha eletrônica.

Empresa P							
Componente: Meio filtrante							
Previsão com 6 períodos à frente - Cálculo do desvio padrão entre previsão e demanda real							
Período	Observado (qtde)	Previsão (qtde)	$x_i = \text{prev} - \text{observ}$	$x_m = \text{média das difer. (prev-obs)}$	$(x_i - x_m)$	$(x_i - x_m)^2$	$\sigma_D = \text{desv padr prev x dem}$
30/11/2012	150	50,34	-99,66	-16,33	-83,33	6944,44	
30/12/2012	0	50,34	50,34	-16,33	66,67	4444,44	
30/01/2013	150	50,34	-99,66	-16,33	-83,33	6944,44	
28/02/2013	0	50,34	50,34	-16,33	66,67	4444,44	
30/03/2013	0	50,34	50,34	-16,33	66,67	4444,44	
30/04/2013	100	50,34	-49,66	-16,33	-33,33	1111,11	
$x_i = \text{diferença entre valor previsto e demanda real};$			-16,33		Somatório (Σ)	28.333,33	75,2773
$x_m = \text{Média das diferenças entre previsão de demanda e demanda real};$							
$n = 6 \text{ meses}$							
$\sigma_D = \text{desv padr prev x dem: } \sigma_D = \text{raiz}[\Sigma/(n-1)]$							
Fonte: Fórmulas conforme STAUDT (2011)							

Figura 35 – Meio filtrante – desvio padrão entre demanda planejada e demanda real.

Para o cálculo do estoque de segurança (ES), foram utilizadas três diferentes abordagens:

- i) As fórmulas propostas no trabalho de Rosa et al (2010);
- ii) As equações extraídas do trabalho de Werner et al (2006) e,
- iii) As equações sugeridas na pesquisa de Staudt (2011).

Todas as equações são pertinentes ao sistema de revisão periódica de estoques (P). Na Figura 36 observa-se que as equações utilizadas por Staudt (2011) entregaram quantidades intermediárias para o estoque de segurança – com um nível de serviço de 98% ($z = 2,054$) – quando comparadas com Rosa e Werner. Por segurança, optou-se por manter o ES no nível obtido por Staudt, isto é, 283 peças. A quantidade selecionada está destacada em negrito. Observar ainda que foram

aplicados três níveis de serviço: 95, 98 e 99,87%, apenas para futura demonstração à Empresa P. Notar que o NS desejado significa aproximadamente R\$ 87.000,00 (volume financeiro) para a quantidade de peças necessárias na faixa de segurança.

MEIO FILTRANTE							
Cálculo do estoque de segurança (ES)							
Metodologias empregadas: Rosa, Werner e Staudt							
Nível de serviço desejado (%)	z (desvio padrão padronizado)	Rosa		Werner		Staudt	
		Qtde	Qtde x custo unitário (R\$)	Qtde	Qtde x custo unitário (R\$)	Qtde	Qtde x custo unitário (R\$)
95,00	1,645	262	80.405,18	204	62.605,56	227	69.664,03
98,00	2,054	328	100.659,92	254	77.950,06	283	86.849,87
99,87	3,000	478	146.693,42	371	113.856,19	413	126.745,57

Figura 36 – Meio filtrante – Cálculo do estoque de segurança (ES) para nível de serviço 98%.

J4) Cálculo do estoque máximo

O Meio Filtrante tem seu estoque máximo (T) definido em 1.000 peças, o que equivaleria a $1000 \times 306,89 = R\$ 306.890,00$. O responsável pelas compras não sabe quem, quando e como este valor foi definido. Baseado nas metodologias extraídas dos trabalhos de Werner (2006) e Rosa (2010), conclui-se que este estoque máximo deve ser reduzido. Tanto para a adequação do ES quanto para regularizar o estoque máximo (T), a Empresa P terá um potencial de economia, pois ambos estão superdimensionados para o NS = 98%. No confronto dos resultados, optou-se pela metodologia de Werner, por oferecer quantidade menor de estoque máximo, isto é, 465 peças. A Figura 37 aponta o volume ideal de peças para o estoque máximo (T).

MEIO FILTRANTE								
Cálculo do estoque total (T) - nível máximo								
Metodologias empregadas: Rosa e Werner								
Nível de serviço desejado (%)	z (desvio padrão padronizado)	Rosa		Werner		Diferença (qtde)	Diferença (%)	Diferença (R\$)
		Qtde	Qtde x custo unit (R\$)	Qtde	Qtde x custo unit (R\$)			
95,00	1,645	473	145.158,97	414	127.052,46	59	14,25%	18.106,51
98,00	2,054	538	165.106,82	465	142.703,85	73	15,70%	22.402,97
99,87	3,000	689	211.447,21	582	178.609,98	107	18,38%	32.837,23

Figura 37 – Meio filtrante – estoque máximo proposto.

J5) Nível de serviço desejado

A empresa informa que este componente (meio filtrante) é um elemento fundamental para o funcionamento do sistema de pintura. Sem este

filtro, o equipamento não consegue operar. Assim, a Empresa P definiu o nível de serviço de 98%. Porém, ao investigar-se o atual nível de serviço, constatou-se que a empresa não vem respeitando o estoque de segurança, fechando os meses com quantidades muito aquém da margem de segurança. Fatalmente, isto impactará negativamente no NS. Com auxílio da equação (69) e conhecendo-se o ES, foi possível calcular o desvio padronizado Z_{α} e a partir deste, o nível de serviço praticado. Em seguida, com a ajudada tabela de distribuição normal, pôde-se calcular o equivalente NS para estes baixos estoques. A Figura 38 aponta estes resultados e servirá para alertar a empresa que seu nível de serviço está bem aquém do desejado (98%). Nota-se que dos seis períodos pesquisados, somente em Abril/2013 a empresa elevou seu estoque para acima da linha de segurança, possibilitando um nível de serviço de 99,72%. Salientando que o *lead time* é de 2,35 meses e a demanda média mensal de 63 peças, manter estoques entre 183 a 193 peças fatalmente levará a *stockouts*.

Empresa P							
Componente: Meio filtrante							
Nível de serviço desejado: 98%							
Nível do Estoque de Segurança vs Nível de Serviço - Fechamento do mês							
Data	Estoque fechamento mês	Estoque Seg (qtde)	Diferença Estoque fechamento vs Est Seg	Z_{α} (Nível serviço em desvios padronizados)	Valor tabela distr norm	Nível Serviço	Notas
30/11/2012	183	283	-100	1,33	0,0918	90,82%	Abaixo da meta (98%)
30/12/2012	183	283	-100	1,33	0,0918	90,82%	Abaixo da meta (98%)
30/01/2013	193	283	-90	1,40	0,0808	91,92%	Abaixo da meta (98%)
28/02/2013	193	283	-90	1,40	0,0808	91,92%	Abaixo da meta (98%)
30/03/2013	193	283	-90	1,40	0,0808	91,92%	Abaixo da meta (98%)
30/04/2013	381	283	98	2,77	0,0028	99,72%	OK

Figura 38 – Meio filtrante – Nível de serviço desejado versus real – para atendimento a 98%.

J6) Impacto financeiro – análise conjunta – kit pistola e meio filtrante.

Nesta seção serão agrupados o kit pistola e o meio filtrante no que tange à readequação dos estoques de segurança e máximo, demonstrando-se financeiramente o impacto que causará à Empresa P. Da Figura 39 é fácil deduzir que para o kit pistola haverá desembolso da ordem de R\$ 97.000,00 para readequar os estoques. Já para o meio filtrante, haverá uma economia de R\$ 187.000,00, pois tanto o ES quanto o estoque máximo (T) atualmente estão atualmente

superdimensionados. No cômputo final, haverá uma economia de R\$ 90.700,00 para atingir-se o dimensionamento adequado dos estoques.

Empresa P								
Kit pistola & Meio filtrante								
Ajuste dos níveis de estoque								
Componente	Nível de serviço desejado	Estoque segurança (ES) - qtde						
		Nível atual	Valor (R\$)	Nível proposto	Valor (R\$)	Desembolso (R\$)	Economia (R\$)	Saldo (R\$)
Kit Pistola	95%	19	102.484,67	26	140.242,18	37.757,51		
Meio Filtrante	98%	360	110.480,40	283	86.849,87		23.630,53	
								-14.126,98
Estoque total (T) - qtde								
Componente	Nível de serviço desejado	Nível atual	Valor (R\$)	Nível proposto	Valor (R\$)	Desembolso (R\$)	Economia (R\$)	Saldo (R\$)
Kit Pistola	95%	38	204.969,34	49	264.302,57	59.333,23		
Meio Filtrante	98%	1000	306.890,00	465	142.703,85		164.186,15	
								104.852,92
Ajuste do Estoque de Segurança (ES) + Ajuste do Nível Máximo (T) - Economia possível (R\$):								90.725,94

Figura 39 – Kit Pistola e Meio Filtrante – readequação dos estoques de segurança e máximo.

4.2 A EMPRESA DO SEGMENTO HOSPITALAR

4.2.1 Breve Histórico

A Empresa H, um hospital privado do Norte Catarinense, em funcionamento desde 2001, além dos 165 leitos e três UTIs (Unidades de Terapia Intensiva), possui um Departamento chamado Engenharia Clínica. Este departamento tem por missão assegurar a correta manutenção dos equipamentos médicos e hospitalares. Além da manutenção corretiva, também engloba a manutenção preventiva, calibração de instrumentos, terceirização de manutenções e controle dos contratos com empresas prestadoras de serviços de manutenção. Outra responsabilidade é avaliar os pedidos dos médicos quanto à compra de novos equipamentos / novas tecnologias, emitindo parecer técnico de viabilidade e retorno do investimento. O Departamento de Engenharia Clínica conta com uma área de aproximadamente vinte metros

quadrados. Este espaço é pequeno, frente à atual demanda de consertos, calibrações e verificações dos equipamentos que lhe são enviados pelas demais áreas do hospital. A estrutura de pessoal é assim constituída: um engenheiro eletricista, atuando como gerente e consultor técnico do departamento, dois técnicos com formação em eletroeletrônica e uma secretária, responsável pelos trabalhos burocráticos, itens de controle e emissão dos pedidos de compra de componentes.

A maioria dos componentes é adquirida no Brasil, não sendo necessariamente componentes nacionais. As grandes multinacionais, usualmente, têm centros de distribuição instalados no Brasil e assim conseguem suprir os hospitais rapidamente com itens importados. Este é o caso do Sensor Neonatal Nellcor, fabricado pela Covidien USA em sua unidade no México – um sensor de oximetria utilizado na UTI Neonatal. Apesar do lead time (tempo de aquisição) ser de apenas uma semana, a Engenharia Clínica se defronta com o consumo irregular deste componente.

4.2.2 Componente Sensor Neonatal

O sensor de oximetria neonatal tem a função de medir a quantidade de oxigênio no sangue, função esta de vital importância quando o paciente está sob o efeito de anestesia geral ou quando respira com o auxílio de aparelhos. O modelo em estudo é dotado de um sensor infravermelho, fita adesiva, cabo e soquete. Ocorre que devido ao adesivo, este sensor de oximetria neonatal passa a ser um componente de uso descartável. Não há como reaproveitá-lo num próximo paciente. Como já frisado, a Empresa H toma um grande cuidado para que não falem sensores de oximetria neonatais em seu almoxarifado (Engenharia Clínica). Por isso, a verificação dos estoques é realizada semanalmente. O fabricante entrega em embalagens contendo vinte e cinco sensores e o tempo entre emitir o pedido e receber o componente não excede sete dias corridos. Assim, o lead time estabelecido é de uma semana, mas, por razões de segurança, a Empresa H trabalha com três semanas. Desta forma, as previsões são realizadas numa perspectiva de três semanas. O custo unitário do sensor de oximetria neonatal é de R\$ 56,75. No final de Dezembro/2012 havia 28 sensores em estoque, totalizando R\$ 1.589,00 em inventário. O Apêndice T traz a estatística descritiva desta série de 55 semanas.

4.2.3 Aplicação da metodologia para o sensor neonatal

A) Análise do conjunto de dados

A série temporal do componente Sensor Neonatal é composta de cinquenta e cinco observações, iniciando na semana 45/2011 e terminando na semana 47/2012. Nas demandas, constata-se um consumo anômalo na semana 27/2012, quando 22 sensores de oximetria foram requisitados. Demais consumos oscilam entre 3 e 14 peças. Ainda, a série apresenta intermitência mais forte, principalmente entre o meio e o final desta. No Apêndice T é apresentada a série e a Figura 40 traz o gráfico da mesma.

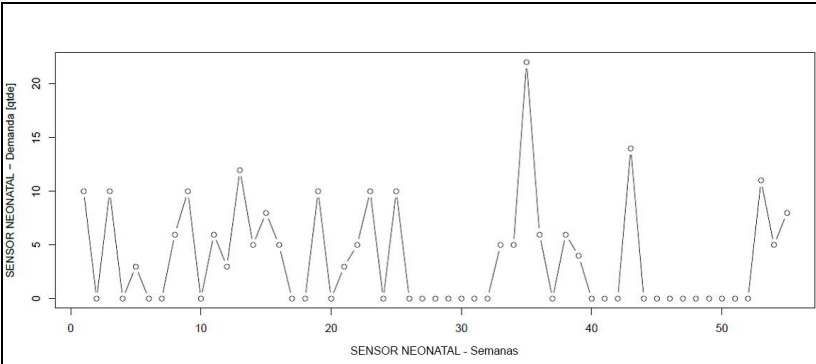


Figura 40 – Sensor de oximetria neonatal – comportamento da série temporal – demanda ao longo de 55 semanas

B) Componentes da série

O conjunto de dados das 55 semanas foi submetido à função ‘*decompose*’, no *R* e as componentes: tendência, sazonalidade, nível e aleatórios podem melhor ser observados na Figura 41. Nota-se que a tendência diminui e depois volta a subir. E parece haver um comportamento sazonal aditivo na série, enquanto que o erro (resíduo) também tem comportamento aditivo.




Figura 41 – Sensor de oximetria – decomposição da série – 55 dados

C) Análise da intermitência

Da Figura 42 observa-se que há mais semanas sem consumo (52,73%), do que semanas com consumo e isto resulta em: $ADI = 2,16$ e $CV = 0,53$, indicando que a série tem comportamento intermitente.

SENSOR DE OXIMETRIA		
55 semanas - Nov 2011 a Nov 2012		
		Participação (%)
Semanas com consumo	26	47,27
Semanas sem consumo	29	52,73
Consumo médio semanal	3,67	
Consumo mínimo	3	
Consumo máximo	22	

Figura 42 – Sensor de oximetria neonatal – análise das demandas.

D) Distribuição da demanda

A exemplo dos componentes da Empresa P, também para o sensor neonatal será analisada a distribuição da demanda. Pelos valores obtidos na estatística descritiva, espera-se verificar uma distribuição não normal. Na Figura 43, apresentam-se as demandas reais, oscilando entre 3 e 14 peças. Uma excepcional demanda de 22 sensores, já citada previamente, também é observada. Confirmou-se a distribuição não normal.

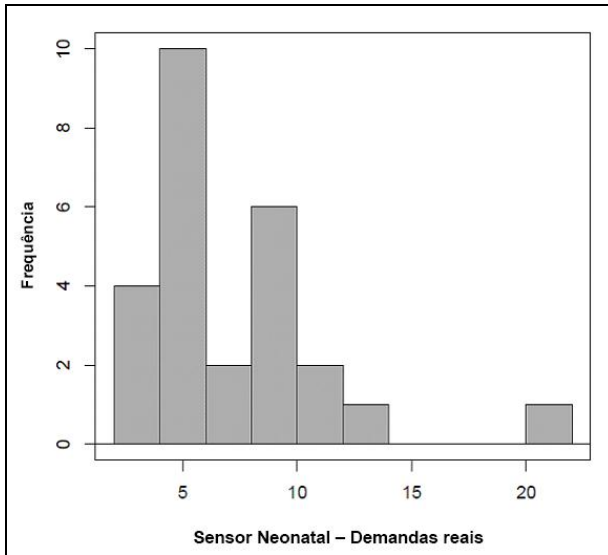


Figura 43 – Sensor neonatal – Demandas reais (demandas nulas foram suprimidas do histograma).

E) Análise do intervalo entre as demandas

Intervalos entre demandas da ordem de 6 a 10 períodos (semanas) ocorrem esporadicamente, conforme o histograma da Figura 44.

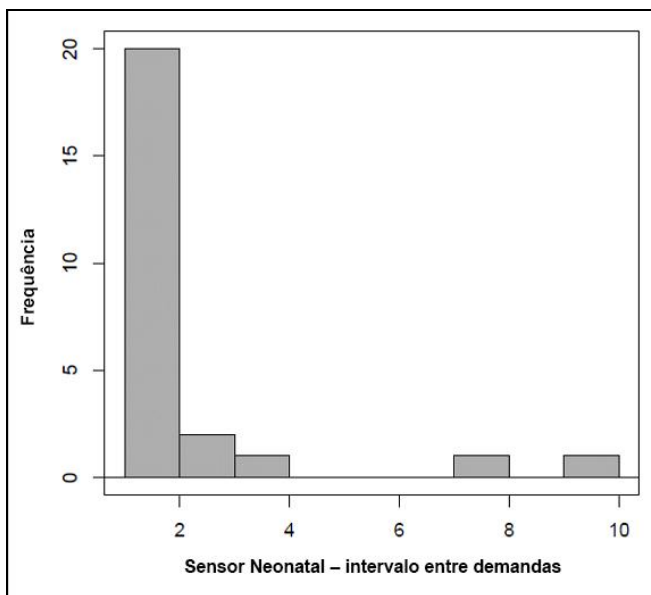


Figura 44 – Sensor neonatal – histograma dos intervalos entre demandas.

F) Análise do conjunto amostral – previsões com os onze métodos

A partir da série temporal do sensor de oximetria neonatal, que possui cinquenta e cinco dados – e a estes designamos ‘série integral’, nesta seção serão utilizados somente os quarenta e nove dados iniciais – e serão chamados de ‘conjunto amostral’. Os seis últimos dados da série serão guardados para futura comparação com as previsões dos melhores métodos. O objetivo nesta seção é testar o modelo de previsão atualmente adotado pelo Hospital H com mais dez outros métodos propostos. Para tal, compara-se o método deste com os métodos que apresentarem as melhores acurácias, isto é, as menores discrepâncias nas previsões. As Tabelas 10 e 11 demonstram os onze métodos, suas medidas de acurácia e o p-valor dos resíduos, calculados via Teste de Shapiro-Wilk, com $\alpha = 0,05$. Os melhores resultados de acurácia estão destacados em negrito. Notar que para os métodos que envolvem Croston, aplicou-se o ‘alfa otimizado’ $\alpha = 0,23$ – conforme detalhado na seção 4.2. O método NNQ-STAT apresentou as menores discrepâncias nas previsões, com um modelo Holt-Winters, tendo: erro aditivo, tendência aditiva amortecida e sazonalidade aditiva. Mas, os resíduos não apresentaram distribuição normal. Em seguida surgem os métodos

de Holt e Suavização exponencial, também com os resíduos reprovados no teste da normalidade. Quanto aos métodos desenhados para demanda intermitente, nem Croston original (CR-D) e Croston com alfa otimizado (CR-Z) e ainda Croston modificado (SB5 e TS6) não superaram Holt, Holt-Winters e SES. Estes quatro métodos, a saber: NNQ-STAT (Holt-Winters), Holt, SES e MS3S serão utilizados posteriormente na previsão com 6 períodos à frente. O Apêndice U reporta as previsões calculadas em R , enquanto o Apêndice V retrata o Método SB5, o Apêndice W traz o Método TS6 e o Apêndice X resume o uso da ferramenta NNQ-STAT.

Tabela 10 – Sensor de oximetria – ferramentas, métodos e coeficientes utilizados no conjunto amostral (49 dados).

Item	Ferramenta	Método	Modelo espaço-estado (ETS)	Coeficientes
1	Plamilha eletrônica	MS3S (cliente)		---
2	Plamilha eletrônica	NNQ-STAT	A,Ad,A	$\alpha = 0,01;$ $\beta = 0,01;$ $\gamma = 0,01;$ $\varphi = 0,99$
3	Plamilha eletrônica	SB5		$\alpha = 0,23$
4	Plamilha eletrônica	TS6		$\alpha = 0,23$
5	R	SES	A,N,N	$\alpha = 1E-4$
6	R	SES(OT)	A,N,N	$\alpha = 0,23$
7	R	Holt	A,A,N	$\alpha = 1E-4;$ $\beta = 1E-4$
8	R	HW	ND	ND
9	R	ARIMA	ND	ND
10	R	CR-D		$\alpha = 0,10$
11	R	CR-Z		$\alpha = 0,23$

Tabela 11 – Sensor de oximetria – Predições no conjunto amostral (49 dados) – Acurácia dos métodos

Item	Método	DM	RQDQM	DAM	MASE	Resíduos (p-valor)	Classificação
1	MS3S (cliente)	-0,290	5,569	4,043	0,822	8,3E-4	
2	NNQ-STAT	-0,009	4,600	3,526	0,717	9,8E-6	1°
3	SB5	-0,361	4,863	3,953	0,804	6,4E-6	
4	TS6	-0,755	4,920	4,057	0,822	1,4E-5	
5	SES	-0,001	4,852	3,933	0,800	1,4E-7	3°
6	SES(OT)	-0,335	5,177	4,109	0,836	6,9E-5	
7	Holt	-0,106	4,785	3,771	0,767	1,1E-5	2°
8	HW	ND	ND	ND	ND	ND	
9	ARIMA	ND	ND	ND	ND	ND	
10	CR-D	-2,294	5,586	4,627	0,941	4,6E-5	
11	CR-Z	-1,590	5,435	4,391	0,893	1,5E-5	

Fonte: Cálculos executados no *software R* e em planilha eletrônica.

Legenda: ND = não disponível.

G) Sensor neonatal - previsão com seis períodos à frente – qualidade das previsões

A Empresa H não tem o hábito de realizar previsões. Mesmo contando com um software de gestão que permite, ao menos, exibir a média do consumo dos últimos três períodos, ela não se vale deste recurso. Para fins didáticos, considerar-se-á que esta utiliza a ‘previsão pela média simples dos três últimos consumos’ (3 semanas). Como este método de previsão só assegura previsões de um passo à frente, será necessário aplicar a ‘rolagem’. A Figura 45 mostra a série original (seis últimos valores observados) comparados com a previsão de seis passos à frente e fora da amostra, sempre aos pares: Média simples versus Holt-Winters e na Figura 46, Holt versus SES. Nota-se que a Média simples 3 semanas foi afetada pela intermitência da série e assim resultando em previsões nulas. Isto é decorrente da pouca elasticidade deste método, pois se utilizam somente os últimos três valores observados. Portanto, para séries com intermitência superior a três períodos, o método da Média simples não é robusto. Os demais métodos, que aproveitam melhor o conjunto amostral, mostraram desempenho superior em termos de RQDQM, DAM e MASE. Dentre os três métodos, particularmente a SES apresentou a melhor acurácia (RQDQM = 4,375, DAM = 4,00 e MASE = 0,814) e sua previsão com seis passos à frente está graficamente representada na Figura 47. Já os métodos próprios para séries intermitentes, isto é, Croston e seus derivados, não entregaram acurácias tão competitivas quanto era esperado, apesar de o Sensor neonatal denotar longos períodos sem demanda.

SENSOR NEONATAL													
COMPARAÇÃO ENTRE OS MELHORES MODELOS DE PREVISÃO - FORA DA AMOSTRA - COM 6 PASSOS A FRENTE													
Série original		Método: MS3S (Empresa H)					Método: NNQ-STAT (Holt-Winters - AAdA)						
Período (semanas)	Observado (qtde)	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalari	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalari
42/12	0	0,00	0,00	0	0	0	0,00	5,68	5,68	100%	32,26	5,68	1,16
43/12	0	0,00	0,00	0	0	0	0,00	2,26	2,26	100%	5,11	2,26	0,46
44/12	0	0,00	0,00	0	0	0	0,00	0,99	0,99	100%	0,98	0,99	0,20
45/12	11	0,00	-11,00	100	121	11	2,24	1,57	-9,43	-86%	88,92	9,43	1,92
46/12	5	0,00	-5,00	100	25	5	1,02	1,73	-3,27	-65%	10,69	3,27	0,67
47/12	8	0,00	-8,00	100	64	8	1,63	1,17	-6,83	-85%	46,65	6,83	1,39
Média dos erros (ME):		-4,000					-1,767						
RQDQM		5,916					5,547						
DAM		4,000					4,743						
MASE		0,814					0,965						

Figura 45 – Sensor de oximetria – Previsão com seis passos à frente – Método MS3S versus Método Holt-Winters.

SENSOR NEONATAL													
COMPARAÇÃO ENTRE OS MELHORES MODELOS DE PREVISÃO - FORA DA AMOSTRA - COM 6 PASSOS A FRENTE													
Série original		Método: Holt (A,A,N)						Método: SES (Suavização Exponencial Simples)					
Período (semanas)	Observado (qtde)	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalar	Previsão (qtde)	Erro de previsão (unid) [Prev-Obs]	Erro de previsão (%) [Prev-Obs]	Desvio ao quadrado	Desvio absoluto	Desvio absoluto escalar
42/12	0	1,97	1,97	100%	3,88	1,97	0,40	3,63	3,63	100%	13,18	3,63	0,74
43/12	0	1,90	1,9	100%	3,61	1,90	0,39	3,63	3,63	100%	13,18	3,63	0,74
44/12	0	1,83	1,83	100%	3,35	1,83	0,37	3,63	3,63	100%	13,18	3,63	0,74
45/12	11	1,76	-9,24	-84%	85,38	9,24	1,88	3,63	-7,37	-167%	54,32	7,37	1,50
46/12	5	1,69	-3,31	-66%	10,96	3,31	0,67	3,63	-1,37	-127%	1,88	1,37	0,28
47/12	8	1,61	-6,39	-80%	40,83	6,39	1,30	3,63	-4,37	-155%	19,10	4,37	0,89
Média dos erros (ME):		-2,207						-0,370					
RQDQM		4,967						4,375					
DAM		4,107						4,000					
MASE		0,835						0,814					

Figura 46 – Sensor de oximetria – Previsão com seis passos à frente – Método de Holt versus SES.




Figura 47 – Sensor neonatal – Previsão com 6 passos à frente, utilizando SES.

H) Ganhos potenciais com os três melhores métodos de previsão – análise fora da amostra

Por certo a Empresa H terá ganhos no volume de estoque e no financeiro se aplicar algum dos três métodos selecionados. Analisando a RQDQM, DAM e MASE - entre aplicar o método atual (MS3S) em comparação com a aplicação dos Métodos: NNQ-STA, Holt e SES, é possível, numa estimativa conservadora, um ganho de aproximadamente vinte por cento (valor intermediário de RQDQM) na acurácia das previsões. Já os indicadores DAM e MASE não mostram a mesma robustez, tendo no melhor caso o empate com a MS3S. É claro que um universo de seis passos à frente não fornece muita segurança, mas dá

uma pista do que pode ser alcançado na realidade da empresa. Escolher entre o Método de Holt e a SES, a preferência recai sobre a SES, dada a sua fácil formulação matemática. A outra vantagem é de que a suavização exponencial apresentou o mesmo valor de DAM e MASE que a própria MS3S, tornando este modelo mais robusto e confiável para ser implantado na empresa. Sugere-se que a Empresa H pratique o método SES por pelo menos doze semanas e após este período meça a confiança na metodologia e os ganhos financeiros. O Método de Holt, como alternativa, também traria ganhos significativos. A Tabela 12 mostra os ganhos e perdas percentuais entre os diversos métodos de previsão.

Tabela 12 – Sensor neonatal – Previsão fora do conjunto amostral – seis períodos à frente – análise das discrepâncias – comparação entre os métodos

Método	RQDQM	Ganho (%)	DAM	Ganho (%)	MASE	Ganho (%)
MS3S (Empresa H)	5,916	0,00	4,000	0,00	0,814	0,00
NNQ-STAT (AAaA)	5,547	6,24	4,743	-18,00	0,965	-15,65
Holt (A,A,N)	4,967	16,04	4,107	-2,67	0,835	-2,50
SES (A,N,N)	4,375	26,05	4,000	0,00	0,814	0,00

I) Confrontação dos métodos MS3S versus SES – predições sobre a série temporal original

Com o propósito de comprovar a superioridade do método da SES sobre o atual método empregado pela Empresa H, aplicaram-se os dois métodos de previsão sobre a série original (55 dados). As predições confirmaram o resultado já obtido na seção anterior, de que a SES é superior à MS3M. Focando nos três indicadores de acurácia, se percebe os seguintes progressos:

- i) RQDQM: $5,471/4,802 =$ melhoria de 13,93%;
- ii) DAM: $3,865/3,947 =$ piora de 2,08%.
- iii) MASE: $0,815/1,480 =$ piora de 44,93%.

Ao dividir-se o valor de MASE da MS3 (0,815) pelo da SES (1,480), nota-se uma piora de 45% na acurácia. Por outro lado, a DAM

tem uma pequena piora e apenas a RQDQM se mostra mais robusta. Pode-se dizer que no médio prazo, o Método SES, com uma constante de suavização muito pequena ($\alpha = 0.0001$) trará uma melhoria de aproximadamente 14% ou mais nas previsões (apenas avaliando-se a RQDQM), o que é significativo para o componente Sensor de oximetria neonatal. A Empresa H deve ser encorajada a aplicar esta técnica e continuamente monitorar RQDQM, DAM e MASE. A Tabela 13 apresenta os dois métodos - preditos sobre a série original - e os menores valores de RQDQM, DAM e MASE estão em negrito. A Figura 48 compara graficamente as previsões dos 2 métodos. Como a constante de suavização é muito pequena ($\alpha = 0,0001$), a SES praticamente resulta numa linha média por entre a série.

Tabela 13 – Sensor neonatal – Predições sobre a série original – Método MS3S versus SES – comparativo das acurácias

Item	Método	Modelo espaço-estado (ETS)	DM	RQDQM	DAM	MASE	Resíduos (p-valor)	Coefficientes
1	MS3S		0,032	5,471	3,865	0,815	8,7E-4	---
2	SES	A,N,N	-0,002	4,802	3,947	1,480	6,4E-8	$\alpha = 1E-4$




Figura 48 – Sensor neonatal - Comparação entre os métodos MS3S e SES – previsões no conjunto de 55 dados.

J) Robustez do método da suavização exponencial frente a diferentes coeficientes de suavização

De modo geral, a literatura recomenda a constante de suavização α oscilando entre 0,1 e 0,3. No entanto, no presente trabalho observou-se que o *software R* utilizou coeficiente muito mais baixo para o cálculo das previsões, tanto para o componente Meio Filtrante quanto para o Sensor Neonatal. Em ambos, as previsões e previsões que ofereceram as melhores acurácias (RQDQM, DAM e AIC) foram calculadas, automaticamente, com $\alpha = 1 \times 10^{-4}$ (1/10.000) Uma constante de suavização tão pequena praticamente atribui o mesmo peso a todos os dados da série, desde os mais recentes aos mais antigos. Graficamente, a predição e/ou previsão torna-se praticamente uma linha reta passeando por entre os dados, como pode ser visto na Figura 48. Ainda, vale destacar que Samohyl, Souza e Miranda (2008) recomendam que: $0,01 \leq \alpha \leq 0,99$. No seu *software NNQ-STAT*, limitaram as constantes de suavização a um valor mínimo de $1/100 = 0,01$. Surge então uma questão: Como as previsões para o Sensor Neonatal se comportariam com diferentes valores de α ? Foram selecionados e testados os seguintes valores de α : $1/10.000$ (1×10^{-4}), $1/1.000$ (1×10^{-3}), $1/100$ (1×10^{-2}), $1/10$ (1×10^{-1}), 0,50 e 0,99 na série contendo 49 dados. O *software R* permite que valores de α sejam inseridos manualmente. Os resultados encontram-se nas Tabelas 14 a 17. Observa-se que para valores $0,0001 \leq \alpha \leq 0,01$ não há praticamente diferença na quantidade prevista e a variação na acurácia também é muito pequena. Mesmo para $\alpha = 0,1$ a variação da acurácia não chega a 5%. Isto comprova o procedimento

adotado por Samohyl, Souza e Miranda (2008), ao limitarem a constante mínima para $\alpha \geq 0,01$ (1/100). Percebe-se também que RQDQM é o indicador mais sensível às variações de α , quando confrontado com DAM e AIC. Esta variação pode ser percebida na Figura 49, onde os três indicadores estão dispostos graficamente.

Tabela 14 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – RQDQM.

Item	α	RQDQM		
		Resultado	Incremento (%)	Incremento acumulado (%)
1	0,0001	4,852	0,00	0,00
2	0,001	4,854	0,04	0,04
3	0,01	4,874	0,40	0,45
4	0,1	5,007	2,73	3,19
5	0,50	5,556	10,96	14,51
6	0,99	6,785	22,12	39,84

Tabela 15 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – DAM.

Item	α	DAM		
		Resultado	Incremento (%)	Incremento acumulado (%)
1	0,0001	3,933	0,00	0,00
2	0,001	3,936	0,08	0,08
3	0,01	3,968	0,80	0,89
4	0,1	4,055	2,19	3,10
5	0,50	4,222	4,12	7,35
6	0,99	4,800	13,69	22,04

Tabela 16 – Sensor Neonatal – robustez do método da SES com diferentes constantes de suavização (α) – AIC.

Item	α	AIC		
		Resultado	Incremento (%)	Incremento acumulado (%)
1	0,0001	347,48	0,00	0,00
2	0,001	347,52	0,01	0,01
3	0,01	347,92	0,12	0,13
4	0,1	350,57	0,76	0,89
5	0,50	360,76	2,91	3,82
6	0,99	380,35	5,43	9,46

Tabela 17 – Sensor Neonatal – resultado da previsão, aplicando SES, com diferentes constantes de suavização (α).

Método SES – Cálculo das previsões mediante a utilização de diferentes valores para a constante de suavização (α)

Item	A	Previsão com 6 períodos à frente – nº pcs
1	0,0001	3,6323
2	0,001	3,6327
3	0,01	3,6008
4	0,1	2,3138
5	0,50	0,1139
6	0,99	$1,38 \times 10^{-11}$

4.3 DISCUSSÃO DOS RESULTADOS

4.3.1 Kit pistola

Este componente apresentou uma demanda intermitente leve, atingindo um $ADI = 1,33$. Quando submetido aos onze métodos de previsão selecionados neste trabalho, os três modelos que apresentaram as menores discrepâncias nas previsões (teste dentro da amostra = 30 dados) foram: 1) Holt-Winters (NNQ-STAT) com erro aditivo, tendência amortecida e sazonalidade aditiva, 2) TS6, que reflete o método de Croston modificado e 3) SB5, que também é um modelo adaptado a partir de Croston.

Quando estes três métodos foram submetidos à previsão fora da amostra, isto é, com horizonte de seis períodos à frente, o melhor desempenho ficou com o Método MS3M, seguido de TS6 e SB5. Isto causou surpresa, porém, sabe-se que a previsão com média simples permite apenas previsões de um passo à frente, o que não é o escopo deste estudo. Portanto, sugere-se que a Empresa P aplique a previsão da demanda calculada pelo método TS6 – por pelo menos 12 meses - e avalie a superioridade deste método sobre a previsão com média simples.

No que tange ao estoque, foram calculados: o *lead time*, o estoque de segurança e o estoque máximo, haja vista que a empresa opera pelo sistema de revisão periódica. Os resultados demonstraram que a empresa vem operando com níveis de estoque muito baixos, comprometendo desta forma sua meta de nível de serviço (95%). Deverá, ainda, desembolsar em torno de R\$ 97.000,00 para regularizar o estoque de segurança e o estoque máximo. A Tabela 18 resume os resultados obtidos com o kit pistola.

Tabela 18 – Kit pistola – resultados comentados.

KIT PISTOLA – Resumo dos resultados				Comentários	
Comportamento da série		Método	Classificação		
ADI	CV		Predição (30 dados)	Previsão (6 passos a frente)	
1,33	0,65	MS3M		1º	MS3M (empresa P) – horizonte de 1 passo a frente. Demais períodos, aplicar rolagem (não consistente).
ETS	Clas se	NNQ-STAT	1º		NNQ-STAT não aceita demandas nulas (zeros).
A,N,N	<i>Lum py</i>	TS6	2º	2º	Método de Croston aperfeiçoado.
		SB5	3º	3º	Método de Croston aperfeiçoado.
Ajuste do estoque			R\$ (-) 97.000,00		Desembolso financeiro

4.3.2 Meio filtrante

Apresentou uma demanda intermitente moderada, com ADI = 2,19. Tanto quanto o Kit Pistola, este componente também tem sua previsão da demanda calculada pelo método da média simples dos últimos três períodos (MS3M).

Aplicaram-se os onze métodos de previsão, isto é, o método da empresa (MS3M) e os dez selecionados neste trabalho e as menores discrepâncias – no âmbito das previsões (série com 30 dados) – resultaram dos métodos: 1) Holt-Winters (NNQ-STAT), com erro aditivo, sem tendência e com sazonalidade aditiva, 2) Holt-Winters (calculado no R), que revelou (A,A,A), isto é, erro aditivo, tendência aditiva e sazonalidade aditiva, 3) SES, com o R escolhendo automaticamente $\alpha = 1/10.000$.

Ao submeterem-se estes quatro métodos, a saber: MS3M, HW (NNQ-STAT), HW (R) e SES com um horizonte de seis meses à frente, a melhor acurácia foi obtida pela SES. Entre aplicar o Método da Média Simples 3 Meses (MS3M) e a SES, é possível um ganho conservador de dez por cento (valor intermediário entre RQDQM, DAM e MASE). A outra vantagem é de que a suavização exponencial utiliza todos os dados da série e isto torna este modelo mais robusto e confiável do que o método atual empregado pela Empresa P. Deste modo, recomenda-se que a empresa exercite o método da SES por um período de 12 meses (1 ano) e após este período faça uma análise crítica, ponderando sobre os ganhos ou perdas.

Na análise dos estoques, neste componente a empresa vem operando com níveis muito baixos, comprometendo o nível de serviço. Vale lembrar que a meta é NS = 98%, mas em seis meses analisados, este NS situou-se na faixa de 90 – 92%. Portanto, a empresa deve disparar pedidos maiores visando readequar seu estoque de segurança e também o estoque máximo, caso queira manter-se fiel ao nível de serviço de 98%. Teoricamente, para readequar seu estoque de segurança (ES) de 360 para 283 peças, a redução significaria uma economia de R\$ 23.630,00. E para baixar o estoque máximo de 1.000 para 465 peças, se economizaria R\$ 164.186,00. Portanto, readequar os estoques do Meio Filtrante, teoricamente, geraria uma economia de R\$ 187.800,00. A empresa deve ser incentivada a adotar estes novos níveis de estoque,

pois ajudarão na meta de atingir o de serviço de 98%. Na Tabela 19 apresentam-se os resultados de forma resumida.

Tabela 19 – Meio filtrante – resultados e comentários.

Comportamento da série		Método	Classificação		Comentários
			Predição (30 dados)	Previsão (6 passos a frente)	
ADI	CV				
2,19	0,22	MS3M		2°	MS3M (empresa P) – horizonte de 1 passo a frente. Demais períodos, aplicar rolagem (não consistente).
ETS	Classe	NNQ-STAT	1°	3°	NNQ-STAT não aceita demandas nulas (zeros).
A,N,N	Intermitente	HW	2°		Método de Croston aperfeiçoado.
		SES	3°	1°	Suavização exponencial, com escolha automática de alfa.
Ajuste do estoque			R\$ (+) 187.000,00		Potencial economia, com ajuste do ES e Estoque Máximo.

4.3.3 Sensor Neonatal

O sensor de oximetria para uso em bebês (neonatal) confirmou uma demanda intermitente moderada, com $ADI = 2,16$ – bastante similar ao componente meio filtrante. Apesar do recurso instalado (*software* de gestão), a Empresa H não utiliza a média simples das últimas três semanas para fins de previsão de demanda. A revisão do estoque é feita de forma semanal, observando o volume de sensores na gaveta da oficina de manutenção (Engenharia Clínica). Considerando que o *software* de gestão já está instalado, o primeiro passo é convencer a empresa a praticar a previsão de demanda. Ao sensor neonatal foram aplicados os onze métodos de previsão, isto é, uma suposta média simples das três últimas semanas (MS3S) e os dez métodos selecionados neste trabalho. Novamente, as menores discrepâncias – no âmbito das predições (série com 49 dados) foi o foco do estudo. Obtiveram-se os seguintes resultados: 1) SES (suavização exponencial), com o R escolhendo automaticamente $\alpha = 1/10.000$; 2) Holt (calculado no R), que revelou (A,A,N), isto é, erro aditivo, tendência aditiva e sazonalidade ausente e 3) Holt-Winters (NNQ-STAT), com modelo espaço-estado AAdA, isto é, erro aditivo, tendência amortecida e com sazonalidade aditiva. Entre aplicar o Método da Média Simples 3 Semanas (MS3S) e a SES, é possível um ganho conservador de vinte por cento (valor intermediário entre RQDQM, DAM e MASE). Recomenda-se que a empresa exercite o método da SES por um período de 12 semanas (aproximadamente 3 meses) e após este período faça uma análise crítica, ponderando sobre os ganhos ou perdas no período testado.

Por último, analisou-se a influência da constante de suavização (alfa) sobre a qualidade da predição (a série contendo 49 dados). Observou-se que para o sensor neonatal, não há alteração significativa na previsão de demanda se alfa oscila entre $1/10.000$ a $1/10$. É intuitivo perceber que valores muito pequenos ($\alpha = 0,0001$) não são atraentes para o usuário comum. Portanto, $\alpha = 0,01$ ou $\alpha = 0,1$ são mais apelativos, sem causar prejuízo nas previsões com seis passos à frente.

Como a Empresa H não mostrou interesse em cálculo dos estoques e nível de serviço, o estudo de caso limitou-se apenas em encontrar o método de previsão de demanda que possibilitasse as menores discrepâncias. A Tabela 20 agrupa os resultados encontrados.

Tabela 20 – Sensor neonatal – demonstração dos resultados.

SENSOR NEONATAL – Resumo dos resultados					
Comportamento da série		Método	Classificação		Comentários
			Predição (49 dados)	Previsão (6 passos a frente)	
ADI	CV		1°	3°	NNQ-STAT não aceita demandas nulas (zeros).
2,16	0,53	NNQ-STAT			
ETS	Clas se	Holt	2°	2°	Calculado no <i>R</i> , com escolha automática da constante de suavização.
A,N,N	<i>Lumpy</i>	SES	3°	1°	Suavização exponencial, com escolha automática de alfa.
Ajuste do estoque			Não realizado		Não houve interesse da Empresa H.

A ênfase neste capítulo foi a aplicação de dez diferentes métodos de previsão sobre três séries temporais com demanda intermitente. Percebeu-se que o método de Croston e os deste derivados, juntamente com o método da suavização exponencial, produzem boas previsões, sobrepujando métodos como por exemplo, ARIMA. No balanceamento dos estoques – para os componentes: kit pistola e meio filtrante – com níveis de serviço oscilando entre 95 e 98%, observou-se que se colocado em prática, trará economia para a Empresa P. No Capítulo 5 será encaminhada uma análise mais detalhada dos resultados obtidos acima.

CAPÍTULO 5 - CONCLUSÃO

5.1 SUPERIORIDADE NÃO CONFIRMADA

Neste trabalho observou-se certo paradoxo. É dito que o método de Croston e os métodos dali derivados (SB5, TS6, Levén-Segerstedt e outros) prezam-se para demandas intermitentes. Na revisão da literatura – Capítulo 2 – evidenciou-se que o método da suavização exponencial, especialmente a simples, preza-se para séries contínuas, estacionárias e que preferencialmente obedeçam ao modelo espaço-estado A,N,N, isto é, erro aditivo, sem tendência e sem sazonalidade. Ocorre que no presente trabalho, os três componentes investigados apresentaram níveis de intermitência de leves a moderados, a saber: 1) Kit pistola, com ADI = 1,33; 2) Meio filtrante, com ADI = 2,19 e; 3) Sensor neonatal, com ADI = 2,16. Esperava-se que quanto mais intermitente a série, melhor fosse o desempenho do Método de Croston ou seus congêneres, mas isto não se confirmou. Justamente na série menos intermitente (kit pistola) observou-se a melhor aplicação de uma variante do Método de Croston, quando o modelo TS6 produziu as menores discrepâncias, num horizonte de previsão de um a seis períodos à frente. Já para os componentes com $ADI > 2,00$ – que se aplica aos componentes: meio filtrante e sensor neonatal – a consagrada SES sobrepujou o Método de Croston e seus seguidores. Isto vem a reforçar a proposta de que não se pode generalizar, ao simplesmente associar os métodos de Croston aos ADI's e esperar que tais métodos produzam as melhores previsões. Consideramos ainda que, três séries testadas são insuficientes para afirmar-se a superioridade dos métodos de Croston. Acreditamos que abre-se uma janela para mais pesquisa, simulando uma gama de valores de ADI combinados com outra de valores de CV. Talvez exista algum limite a partir do qual os métodos de Croston sempre respondam melhor que outros métodos tradicionais como, por exemplo, a suavização exponencial.

Defendemos que testar diferentes métodos de previsão, desde os mais básicos, tais como a média simples dos últimos períodos demandados, a média simples total, a média móvel (centrada ou não), a previsão ingênua, evoluindo para a suavização exponencial, aos métodos de Holt e Winters, aos modelos ARIMA e por fim aos modelos de Croston constitui-se em prática sadia. De posse desse leque de

resultados variados, o pesquisador poderá escolher com mais segurança aqueles métodos que produzirão as menores discrepâncias de previsão, no horizonte de vários períodos à frente.

Quanto aos indicadores de acurácia, são medidas clássicas: a RQDQM – raiz quadrada do desvio quadrado médio, o DAM – desvio absoluto médio, que em valores práticos é muito similar a RQDQM, o DPAM – desvio percentual absoluto médio, o U de Theil (U) e o AIC – *Akaike Information Criterion*. O DPAM, apesar de ser uma medida de discrepância bastante utilizada, não é plausível para demanda intermitente, pois quando a demanda é zero, seu denominador enfrenta dificuldade (não é possível ter-se denominador valendo zero). Para suprir esta deficiência o MASE – *Mean Absolute Scaled Error*, que traduzimos como discrepância escalar absoluta média, torna-se uma boa alternativa. No seu denominador somente ocorrerá o valor zero se a série for estritamente estacionária, isto é, se não houver variação nas quantidades demandadas. Como as séries estudadas sempre apresentaram variação na demanda, entre um período e outro, a MASE pôde ser aplicada aos três componentes. Ressalta-se ainda que foi mantida a sigla MASE, dada a popularidade desta na literatura em língua inglesa. Em termos gerais, a MASE reflete quanto o método de previsão em teste é melhor ou pior em comparação ao método da previsão ingênua. Portanto, os valores de MASE geralmente oscilam entre zero e um, indicando que o método testado é superior ao método da previsão da caminhada aleatória (ingênua). Outro indicador de acurácia bastante utilizado é o U de Theil, que compara o método de previsão escolhido com a previsão ingênua, mas que também não se aplica para séries intermitentes, pois fatalmente o denominador (na equação) estará sujeito ao valor zero. A medida de acurácia AIC é o recurso padrão do software NNQ-STAT, mas no presente trabalho o indicador de acurácia preferencial foi a RQDQM. Utilizou-se o critério AIC somente no teste da robustez da suavização exponencial frente a variados valores de alfa (ver Tabela 16). Quanto menor o valor do AIC, mais robusto é o método de previsão para aquele conjunto de dados.

No que tange aos estoques, o apropriado cálculo do estoque de segurança (ES) e do estoque máximo (T), para a Empresa P, refletirá em ganhos financeiros no médio prazo, menor tensão no ambiente de previsão/compras e aumento no nível de serviço (NS).

Já para a Empresa H, cujo componente ajusta-se melhor ao método de previsão por SES, foram testados diferentes valores de alfa (α),

comprovando que não é necessário operar-se com uma constante de suavização tão pequena quanto a fornecida pelo *software R*, isto é, $\alpha = 1 \times 10^{-4}$. Operando com $0,01 \leq \alpha \leq 0,10$, os resultados de previsão são muito similares, sofrendo diferenças inferiores a 5%.

O estudo demonstrou, para os três componentes cedidos pelas duas empresas, que utilizar ferramentas de previsão de demanda com toda a certeza levará a resultados superiores do que apenas basear-se na simples média da demanda dos últimos três períodos. Neste caso, tanto o Método TS6 quanto o Método SES não implicam em dificuldade de implantação, pois ambos possuem equações simples que facilmente poderão ser inseridas nos *softwares* de gestão empregados nas duas empresas.

5.2 SUGESTÕES PARA TRABALHOS FUTUROS

No presente estudo, criou-se uma rotina a ser executada no *software R*, pacote *Forecast*, visando identificar a melhor constante de suavização (alfa) para o Método de Croston. No caso do kit pistola, esta constante ótima é: $\alpha = 0,10$. Para o meio filtrante: $\alpha = 0,18$ e para o sensor de oximetria: $\alpha = 0,23$. Além de terem sido aplicados ao método original de Croston (calculado no *R*), estas constantes ótimas também foram aproveitadas em TS6, SB5 e SES(OT). Como sugestão para trabalhos futuros, aperfeiçoar a constante de suavização – para cada um dos métodos a testar – poderia ser obtida com a ajuda do SOLVER, um recurso disponível em planilha eletrônica. Vale à pena encontrar este ‘alfa ótimo’, pois refletirá em menores discrepâncias nas predições e previsões.

Quanto ao *software* NNQ-STAT, ele requer um mínimo de 36 dados para realizar os cálculos e assim determinar o modelo de previsão mais indicado. A sugestão para pesquisas futuras é que se obtenham séries mais longas - com 48 ou mais dados - pois isto permitirá um maior conjunto de dados (36 ou mais) para testar as predições.

Outro desafio seria o de programar as equações modificadas de Croston diretamente no *software estatístico R*, a saber: Método SB5 (equação 39) e Método TS6 (equação 42). Como no *R* – pacote *Forecast* - encontra-se instalada somente a equação clássica (32), com a constante α fixada em 0,10 (*default*), esta iniciativa eliminaria o uso paralelo de planilha eletrônica quando da utilização do Método de Croston e suas

modificações. Considerando a superioridade do *software R* sobre as planilhas eletrônicas existentes, espera-se a obtenção de resultados estatísticos mais robustos e a possibilidade de comparar os resultados dentro do mesmo ambiente.

Por último, como já mencionado na seção 5.1, o desafio de simular em computador séries temporais intermitentes com diferentes valores de ADI – Intervalo Médio entre Demandas e CV – Coeficiente de Variação, utilizando Croston e Suavização Exponencial. Analisando a Figura 05, percebe-se que a demanda intermitente é caracterizada pelas linhas divisórias: $ADI = 1,32$ e $CV = 0,49$. Partindo-se do quadrante inferior esquerdo com um conjunto $(ADI, CV) = (0,1;0,1)$ até, por exemplo $(3;3)$, todos os quatro quadrantes seriam cobertos. O foco central seria nas medidas de discrepância que os métodos de Croston e a Suavização Exponencial entregariam em cada quadrante. Talvez ao final da simulação algum dos quadrantes revele onde Croston sobrepuja a SES e vice-versa. O pesquisador deverá ter cuidado na montagem das séries temporais intermitentes, considerando séries mais longas. Parece-nos que séries curtas, como as utilizadas neste trabalho (36 dados) não seriam robustas o suficiente num estudo com simulação.

REFERÊNCIAS

AKAIKE, H. Statistical predictor identification. **Annals of the Institute of Statistical Mathematics**, vol. 22, p. 203–217, 1970.

ALTAY, Nezh; RUDISILL, Frank; LITTERAL, Lewis A. Adapting Wright's modification of Holt's method to forecasting intermittent demand. **International Journal of Production Economics**, vol. 111, p. 389–408, 2008.

BALLOU, Ronald H. **Logística empresarial: transportes, administração de materiais e distribuição física**. São Paulo: Atlas, 1995.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis: Forecasting and Control**. San Francisco: Holden-Day, 2ª edição, 1976.

BOYLAN, J.E.; SYNTETOS, A. The accuracy of a modified Croston procedure. **International Journal of Production Economics**, disponível online, doi:10.1016/j.ijpe.2006.10.005, 2006a. Acesso em 21/08/2013.

BOYLAN, J.E.; SYNTETOS, A. Accuracy and accuracy- implication metrics for intermittent demand. **Foresight: The International Journal of Applied Forecasting**, vol. 4, p. 39–42, 2006b.

BROWN, Robert Goodell. **Exponential smoothing for predicting demand**, Little, 1956.

BROWN, R. G. **Statistical forecasting for inventory control**. New York, McGraw-Hill, 1959.

BROWN, R. G. **Smoothing, forecasting and prediction of discrete time series**. Englewood Cliffs, NJ: Prentice-Hall, 1963.

BUFFA, E. S. **Production inventory systems: planning and control**. Illinois: Richard D. Irwin, 1968.

BURGIN, T. A.; WILD, A. R. Stock control – experience and usable theory. **Operational Research Quarterly**, vol. 18, p. 35, 1967.

COELHO, Leandro Callegari. **Utilização de modelos de suavização exponencial para previsão de demanda com gráficos de controle combinados Shewhart-CUSUM**. Dissertação (mestrado). Florianópolis: UFSC / Programa de Pós- Graduação em Engenharia de Produção, 2008.

CROSTON, J. D. Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, vol. 23, nº 3, p. 289-303, 1972.

DUKE University. **Averaging and Exponential Smoothing Models**. <http://people.duke.edu/~rnau/411avg.htm>, 2011. Acesso em 07/outubro/2013

DUNSMUIR, W. T. M.; SNYDER, R. D. Control of inventories with intermittent demand. **European Journal of Operational Research**, vol. 40, p. 16-21, 1989.

FIGUEIREDO, E. D.; NETTO, M. A. C. Modelo de centralização de estoques para a logística de suprimento da exploração e produção da Petrobras. **Pesquisa Operacional**, vol. 21, nº 2, p. 137-158, julho a dezembro de 2001.

GAITHER, N.; FRAZIER, G. Sistemas de estoques com demanda independente. In: **Administração da produção e operações**. São Paulo: Pioneira, 2001. p. 268-307.

GARCIA, Eduardo Saggiaro; FERREIRA FILHO, Virgílio José Martins. Cálculo do ponto de pedido baseado em previsões de uma política $\langle Q, r \rangle$ de gestão de estoques. **Pesquisa Operacional**, vol. 29, nº 3, p. 605-622, Setembro a Dezembro de 2009.

GARDNER JR., E. S.; McKENZIE, E. Forecasting trends in time series. **Management Science**, vol. 31, p. 1237–1246, 1985.

GARDNER JR., Everette S. Exponential smoothing: The state of the art—Part II. **International Journal of Forecasting**, vol. 22, p. 637-666, 2006.

GHOBBAR, A.A.; FRIEND, C.H. Sources of intermittent demand for aircraft spare parts within airline operations. **Journal of Air Transport Management**, vol. 8, p. 221–231, 2002.

HARRISON, P. J. Short term sales forecasting. **Applied Statistics**, vol. 14, p. 102, 1965.

HOLT, Charles C. **Forecasting seasonal and trends by exponentially weighted moving averages**. Pittsburgh, Pennsylvania, Carnegie Institute of Technology, 1957.

HONG, Yuh Ching. **Gestão de estoques na cadeia de logística integrada**. Supply Chain, 2ª edição, São Paulo: Atlas, 2001.

HOOVER, J. Measuring forecast accuracy: omissions in today's forecasting engines and demand planning software. **Foresight: The International Journal of Applied Forecasting**, vol. 4, p. 32–35, 2006.

HYNDMAN, R. J.; KOEHLER, A. B.; SNYDER, R. D.; GROSE, S.A state space framework for automatic forecasting using exponential smoothing methods. **International Journal of Forecasting**, vol. 18, p. 439 – 454, 2002.

HYNDMAN, R. J. Another look at forecast-accuracy metrics for intermittent demand. **Foresight: The International Journal of Applied Forecasting**, vol. 4, p. 43–46, 2006.

HYNDMAN, R.J.; KOEHLER, A.B. Another look at measures of forecast accuracy. **International Journal of Forecasting**, vol. 22, p. 679–688, 2006.

HYNDMAN, R. J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. Disponível em: <https://www.otexts.org/fpp/>, 2013. Acesso em 15/outubro/2013.

JOHNSTON, F. R. An interactive stock control system with a strategic management role. **Journal of the Operational Research Society**, vol. 31, p. 1069-1084, 1980.

JOHNSTON, F. R.; BOYLAN, J. E. Forecasting intermittent demand: A comparative evaluation of Croston's method. Comment. **International Journal of Forecasting**, vol.12, p. 297– 298, 1996.

JOHNSTON, F. R.; BOLYLAN, J. E. e SHALE, E. A. An examination of the size of orders from customers, their characterization and the implications for inventory control of slow moving items. **Journal of the Operational Research Society**, vol. 54, p. 833-837, 2003.

JUDGE, George G. et al. **Introduction to the Theory and Practice of Econometrics**. 2th edition. New York: John Wiley & Sons Inc, p. 673 – 750, 1988.

LEVÉN, Erik; SEGERSTEDT, Anders. Inventory control with a modified Croston procedure and Erlang distribution. **International Journal of Production Economics**, vol. 90, p. 361–367, 2004.

MIRANDA, Rodrigo Gabriel de. **Espaço admissível para os parâmetros do modelo de suavização exponencial com dupla sazonalidade aditivo**. Tese (Doutorado em Engenharia de Produção). Florianópolis: Universidade Federal de Santa Catarina, Biblioteca Universitária, Março 2009.

MORETTIN, P. A. **Introdução à Estatística para Ciências Exatas**, São Paulo, Editora Atual, 1981.

MUELLER, Alessandro. **Uma aplicação de redes neurais artificiais na previsão do mercado acionário**. Dissertação (Mestrado em Engenharia de Produção). Florianópolis: Universidade Federal de Santa Catarina, Biblioteca Universitária, 1996.

NELSON, Charles R. **Applied Time Series Analysis**. San Francisco: Holden-Day, 1973.

NIST/SEMATECH **e-Handbook of Statistical Methods**, <http://www.itl.nist.gov/div898/handbook> (2003), updated: April 2012. Acesso em 23 Outubro 2013.

NNQ-STAT – Software estatístico. Universidade Federal de Santa Catarina, Departamento de Engenharia de Produção, Núcleo de Normalização e Qualimetria (NNQ), Florianópolis, 2008. Disponível em <http://qualimetria.wordpress.com/2012/12/09/previsao/>.

NOVAES, A. G.; ALVARENGA, A. C. Armazenagem de produtos. In: **Logística Aplicada: suprimento e distribuição física**. São Paulo: Pioneira, 1994. p. 183-213.

PEGELS, C. Exponential forecasting: Some new variations. **Management Science**, vol. 15, p. 311 – 315, 1969.

R PROJECT. **The R Foundation for Statistical Computing**. R version 3.0.1 (2013-05-16) - "Good Sport". Copyright (C) 2013. Disponível em: <http://www.r-project.org/>.

RAO, A. Vijaya. A comment on: Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, vol. 24, n° 4, p. 639-640, 1973.

REGATTIERI, A; GAMBERI, M.; GAMBERINI, R.; MANZINI, R. Managing lumpy demand for aircraft spare parts. **Journal of Air Transportation Management**, vol. 11, p. 426-431, 2005.

REGO, José Roberto do; MESQUITA, Marco Aurélio de. Controle de estoque de peças de reposição em local único: uma revisão da literatura. **Revista Produção**, vol. 21, n° 4, p. 645-666, 2011.

ROSA, Hobed; MAYERLE, Sérgio Fernando; GONÇALVES, Mirian Buss. Controle de estoque por revisão contínua e revisão periódica: uma análise comparativa utilizando simulação. **Revista Produção**, v. 20, n. 4, p. 626-638, out./dez. 2010.

SAMOHYL, Robert Wayne; SOUZA, Gueibi Peres; MIRANDA, Rodrigo Gabriel de. **Métodos simplificados de previsão empresarial**, Rio de Janeiro, Editora Ciência Moderna Ltda., 2008.

SANTORO, M. C.; FREIRE, G. Análise comparativa entre modelos de estoque. **Revista Produção**, vol. 18, n° 1, p. 089-098, janeiro a abril de 2008.

SAP AG. **Model: Second-Order Exponential Smoothing**. www.sap.com, Germany. Acesso em 18/outubro/2013.

SCHULTZ, Carl R. Forecasting and inventory control for sporadic demand under periodic review. **Journal of the Operational Research Society**, vol. 38, nº 5, p. 453-458, 1987.

SHENSTONE, L.; HYNDMAN, R. J. Stochastic models underlying Croston's method for intermittent demand forecasting. **Journal of Forecasting**, vol. 24, p. 389-402, 2005.

SILVER, E. Operations research in inventory management: a review and critique. **Operations Research**, vol. 29, nº 4, p. 628-645, 1981.

SLACK, N. et al. Planejamento e controle de estoques. In: **Administração da produção**. São Paulo: Atlas, 1997. p. 380-409.

SMART, C.N. Accurate intermittent demand/inventory forecasting: new technologies and dramatic results. In: **Proceedings of APICS International Conference**, p. C-08, 2002.

SNYDER, Ralph. Forecasting sales of slow and fast moving inventories. **European Journal of Operational Research**, vol. 140, p. 684-699, 2002.

STAUDT, Francielly Hedler. Cálculo do estoque de segurança: as suas diferentes abordagens. **Revista Mundo Logístico** (online), edição 18, www.revistamundologistica.com.br, Setembro e Outubro 2011.

SYNTETOS, A. A.; BOYLAN, J. E. On the bias of intermittent demand estimates. **International Journal of Production Economics**, vol. 71, p. 457-466, 2001.

SYNTETOS, A. A.; BOYLAN, J. E.; CROSTON, J. D. On the categorization of demand patterns. **Journal of the Operational Research Society**, vol. 56, p. 495-503, 2005.

TAVARES, L. V.; ALMEIDA, L. T. A binary decision model for the stock control of very slow moving items. **Journal of the Operational Research Society**, vol. 34, n° 3, p. 249-252, 1983.

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

TEUNTER, Ruud; BABANGIDA, Sani. On the bias of Croston's forecasting method. **Lancaster University Management School**, Working Paper, 2006/030 (versão impressa).

THEIL, Henri. **Applied economic forecasting**, Amsterdam, 474 p., 1966.

TUBINO, D. F. Administração dos estoques. In: **Manual de planejamento e controle da produção**. São Paulo: Atlas, 2000. p. 103-145.

WARD, D. H. Comparison of different systems of exponentially weighted prediction. **The Statistician**, vol. 13, p. 173, 1963.

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

WEMMERLÖV, Urban (1989). The Behavior of Lot-Sizing Procedures in the Presence of Forecast Errors. **Journal of Operations Management**, vol. 8, n° 01, Janeiro 1989.

WERNER, Liane; LEMOS, Fernando de Oliveira; DAUDT, Tiago. **Previsão de demanda e níveis de estoque: uma abordagem conjunta aplicada no setor siderúrgico**. In: XIII Simpep, Bauru (SP), Novembro 2006.

WHEELWRIGHT, Steven C.; MAKRIDAKIS, Spyros. **Forecasting Methods for Management**. 4th edition. New York: John Wiley & Sons Inc, 1985.

WILLEMMAIN, T. R.; SMART, C. N.; SHOCKOR, J. H.; DeSAUTELS, P. A. Forecasting intermittent demand in manufacturing: A comparative evaluation of Croston's method. **International Journal of Forecasting**, vol. 10, p. 529-538, 1994.

WILLEMMAIN, T. R., SMART, C. N., SCHWARZ, H. F. A new approach to forecasting intermittent demand for service parts inventories. **International Journal of Forecasting**, vol. 20, p. 375-387, 2004.

WILLIAMS, T. M. Reorder Levels for Lumpy Demand. **Journal of the Operational Research Society**, vol. 33, n° 2, p. 185-189, 1982.

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

WINTERS, Peter R. Forecasting sales by exponentially weighted moving averages. **Management Science**, vol. 6, p. 324, 1960.

WRIGHT, D. J. Forecasting data published at irregular time intervals using an extension of Holt's method. **Management Science**, vol. 32, n° 4, p. 499-510, 1986.

ZINN, W., MARMORSTEIN, H. Comparing two alternative methods determining safety stock levels: the demand and the forecast systems. **Journal of Business Logistics**, vol. 11, n° 1, 1990.

APÊNDICE A – Equações utilizadas em suavização exponencial

Métodos de suavização exponencial tradicionais.

Adaptado de Miranda (2009), a partir de Gardner (2006).

Tendência	Sazonalidade		
	N	A	M
N	$l_t = \alpha y_t + (1 - \alpha)l_{t-1}$ $F_{t+k} = l_t$	$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)l_{t-1}$ $s_t = \gamma(y_t - l_{t-1}) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t + s_{t-m+k}$	$l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)l_{t-1}$ $s_t = \gamma(y_t/l_{t-1}) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t s_{t-m+k}$
A	$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}$ $F_{t+k} = l_t + kb_t$	$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} - b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t + kb_t + s_{t-m+k}$	$l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}$ $s_t = \gamma(y_t/(l_{t-1} + b_{t-1})) + (1 - \gamma)s_{t-m}$ $F_{t+k} = (l_t + kb_t)s_{t-m+k}$
Ad	$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)\phi b_{t-1}$ $F_{t+k} = l_t + \sum_{i=1}^k \phi^i b_t$	$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} - \phi b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)\phi b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - \phi b_{t-1}) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t + \sum_{i=1}^k \phi^i b_t + s_{t-m+k}$	$l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)(l_{t-1} + \phi b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1 - \beta)\phi b_{t-1}$ $s_t = \gamma(y_t/(l_{t-1} + \phi b_{t-1})) + (1 - \gamma)s_{t-m}$ $F_{t+k} = \left(l_t + \sum_{i=1}^k \phi^i b_t \right) s_{t-m+k}$
M	$l_t = \alpha y_t + (1 - \alpha)l_{t-1}b_{t-1}$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}$ $F_{t+k} = l_t b_t^k$	$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)l_{t-1}b_{t-1}$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1}b_{t-1}) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t b_t^k + s_{t-m+k}$	$l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)l_{t-1}b_{t-1}$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}$ $s_t = \gamma(y_t/(l_{t-1}b_{t-1})) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t b_t^k s_{t-m+k}$
Md	$l_t = \alpha y_t + (1 - \alpha)l_{t-1}b_{t-1}^\phi$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}^\phi$ $F_{t+k} = l_t b_t^{\sum_{i=1}^k \phi^i}$	$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)l_{t-1}b_{t-1}^\phi$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}^\phi$ $s_t = \gamma(y_t - l_{t-1}b_{t-1}^\phi) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t b_t^{\sum_{i=1}^k \phi^i} + s_{t-m+k}$	$l_t = \alpha(y_t/s_{t-m}) + (1 - \alpha)l_{t-1}b_{t-1}^\phi$ $b_t = \beta(l_t/l_{t-1}) + (1 - \beta)b_{t-1}^\phi$ $s_t = \gamma(y_t/(l_{t-1}b_{t-1}^\phi)) + (1 - \gamma)s_{t-m}$ $F_{t+k} = l_t b_t^{\sum_{i=1}^k \phi^i} s_{t-m+k}$

Legenda:

N = Nenhuma;

A = Aditiva;

Ad = Aditiva amortecida (*damped*);

M = Multiplicativa;

Md = Multiplicativa amortecida (*damped*).

**APÊNDICE B – Nível de serviço e desvio padrão normalizado,
calculado em planilha eletrônica.**

Estoque de Segurança x Nível de Serviço		
Tabela do Desvio Padrão Normalizado		
Nível de serviço (%)	Probabilidade desejada	Valor de $Z\alpha$
80,00	0,8000	0,842
85,00	0,8500	1,036
90,00	0,9000	1,282
95,00	0,9500	1,645
96,00	0,9600	1,751
97,00	0,9700	1,881
98,00	0,9800	2,054
99,00	0,9900	2,326
99,10	0,9910	2,366
99,20	0,9920	2,409
99,30	0,9930	2,457
99,40	0,9940	2,512
99,50	0,9950	2,576
99,60	0,9960	2,652
99,70	0,9970	2,748
99,80	0,9980	2,878
99,85	0,9985	2,968
99,86	0,9986	2,989
99,87	0,9987	3,000
99,88	0,9988	3,036
99,89	0,9989	3,062
99,90	0,9990	3,090
99,95	0,9995	3,291
99,99	0,9999	3,719
Equação: $Z\alpha = f(\text{INV.NORMP}(N))$		

Fonte: desenvolvido pelo autor

APÊNDICE C - Kit Pistola – Procurando a melhor constante de suavização (α) para a série, aplicando o Método de Croston.

Linhas de programa gerados no software R.

Autor: Prof. Robert Wayne Samohyl, Ph.D.

#Rotina implementada no R para encontrar a melhor constante de suavização (alfa) – para o KIT PISTOLA:

>ets=ets(x) #procura automática do melhor modelo espaço-estado para a série.

#x: é a série temporal.

>edit(ets) #edita a série, mostrando todos os valores calculados durante o processo ETS.

> for (i in 1:30) {print(i);croston=croston(x,h=3,alpha=i/100) #onde 'i' representa o fracionamento, iniciando em 0,01 e finalizando em 0,30, totalizando trinta frações.

>edit(ets)

```
> for (i in 1:30) {print(i); croston=croston(pistolats,h=3,alpha=i/100);
summary(croston);          fitted(croston);          plot(croston,ylim=c(-
11,30),main=c("alpha",  i/100));  lines(fitted(croston),col="green");
lines(residuals(croston),col="red")}
```

APÊNDICE D – Kit pistola – tabela resumo do Apêndice C - valores de RQDM e DAM para 30 simulações geradas no R.

Observar que $\alpha = 0,10$ gerou o menor DAM.

PISTOLA - Método de previsão: Croston Otimizado			
Simulação - Melhor alfa x menores resíduos			
Alfa	DM (ME)	RQDQM (RMSE)	DAM (MAE)
0,01	-2.2766369	7.3714164	6.2837700
0,02	-2.1790779	7.3462746	6.2394900
0,03	-2.0731627	7.3224390	6.1999630
0,04	-1.9615545	7.3011843	6.1715109
0,05	-1.8471108	7.283457	6.153413
0,06	-1.7325971	7.2697943	6.1372909
0,07	-1.6204929	7.2603376	6.1364238
0,08	-1.5128168	7.2549042	6.1356561
0,09	-1.4110796	7.2530952	6.1350418
0,10	-1.3162907	7.2544005	6.1346344
0,11	-1.2290136	7.2582839	6.1344863
0,12	-1.1494463	7.2642395	6.1346467
0,13	-1.0775070	7.2718245	6.1351601
0,14	-1.0129144	7.2806715	6.1360644
0,15	-0.9552562	7.2904883	6.1395156
0,16	-0.9040430	7.3010509	6.1462405
0,17	-0.8587491	7.3121932	6.1536424
0,18	-0.8188422	7.3237958	6.1617141
0,19	-0.7838030	7.3357761	6.1704429
0,20	-0.7531376	7.3480790	6.1798115
0,21	-0.7263851	7.3606701	6.1897995
0,22	-0.7031210	7.3735293	6.2003846
0,23	-0.6829580	7.3866465	6.2115430
0,24	-0.6655454	7.4000184	6.2232511
0,25	-0.6505672	7.4136456	6.2354850
0,26	-0.6377398	7.4275311	6.2482216
0,27	-0.6268092	7.4416788	6.2614385
0,28	-0.6175485	7.4560925	6.2751141
0,29	-0.6097550	7.4707756	6.2892281
0,30	-0.6032482	7.4857305	6.3037607

Fonte: desenvolvido pelo autor

APÊNDICE E – Meio filtrante – Procurando a melhor constante de suavização (α) para a série.

Linhas de programa gerados no software R.

Autor: Prof. Robert Wayne Samohyl, Ph.D.

```
>edit(ets)
>      for      (i      in      1:30)
{ print(i);croston=croston(filtrots,h=3,alpha=i/100);summary(croston);fit
ted(croston)
+      plot(croston,ylim=c(-60,200),main=c("alpha",
i/100));lines(fitted(croston),col="green");lines(residuals(croston),col="r
ed")}
```

**APÊNDICE F – Meio filtrante – tabela resumo de α otimizado.
Notar que $\alpha = 0,18$ apresentou a menor DAM.**

MEIO FILTRANTE

Alfa	DM (ME)	RQDQM (RMSE)	DAM (MAD)
0,01	-41.4175030	72.5456523	62.3625733
0,02	-36.2374023	70.2049477	61.6779505
0,03	-32.1758640	68.6084459	61.1057632
0,04	-28.9029033	67.4738203	60.7106097
0,05	-26.2115479	66.6421478	60.4228643
0,06	-23.9641428	66.0179489	60.1835719
0,07	-22.0649033	65.5409074	59.9838160
0,08	-20.4447390	65.1713688	59.8168776
0,09	-19.0523329	64.8824002	59.6775776
0,10	-17.8486298	64.6552081	59.5618460
0,11	-16.803290	64.476375	59.466430
0,12	-15.8923267	64.3361327	59.3886928
0,13	-15.0964876	64.2272469	59.3264662
0,14	-14.4001143	64.1442797	59.2779488
0,15	-13.7903245	64.0830880	59.2416269
0,16	-13.2564106	64.0404772	59.2162165
0,17	-12.7893919	64.0139564	59.2006186
0,18	-12.3816749	64.0015632	59.1938850
0,19	-12.0267922	64.0017365	59.1951913
0,20	-11.719199	64.013223	59.203816
0,21	-11.4541149	64.0350051	59.2191216
0,22	-11.2273919	64.0662522	59.2405449
0,23	-11.0354164	64.1062769	59.2693240
0,24	-10.875024	64.154505	59.333076
0,25	-10.7434311	64.2104543	59.3991365
0,26	-10.6381795	64.2737108	59.4673002
0,27	-10.5570895	64.3439189	59.5373782
0,28	-10.498221	64.420768	59.609197
0,29	-10.4598415	64.5039819	59.6825965
0,30	-10.4403970	64.5933150	59.7574269

APÊNDICE G – Sensor neonatal – Procurando a melhor constante de suavização (α) para a série.

Linhas de programa gerados no software R.

Autor: Prof. Robert Wayne Samohyl, Ph.D.

```
>edit(ets)
```

```
> for (i in 1:30)
{print(i);croston=croston(sensorts,h=3,alpha=i/100);summary(croston);f
itted(croston);plot(croston,ylim=c(-11,30),main=c("alpha",
i/100));lines(fitted(croston),col="green");lines(residuals(croston),col="r
ed")}
```

**APÊNDICE H – Sensor neonatal – tabela resumo de α otimizado.
 Notar que $\alpha = 0,23$ apresentou o menor DAM.**

SENSOR NEONATAL			
R Project - 30 corridas - determinar ALFA otimizado			
Alfa	DM (ME)	RQDQM (RMSE)	DAM (MAE)
0,01	-5.245539	7.108711	6.319767
0,02	-4.425380	6.573091	5.802625
0,03	-3.827765	6.231006	5.426668
0,04	-3.374040	6.000560	5.162660
0,05	-3.019487	5.839147	5.000432
0,06	-2.736470	5.722670	4.883949
0,07	-2.506838	5.636640	4.790904
0,08	-2.3181011	5.5719227	4.7145356
0,09	-2.161350	5.522538	4.651293
0,10	-2.030037	5.484440	4.598533
0,11	-1.9192387	5.4548204	4.5551427
0,12	-1.8251765	5.4316773	4.5234124
0,13	-1.7449036	5.4135569	4.4967241
0,14	-1.6760896	5.3993823	4.4741987
0,15	-1.6168693	5.3883421	4.4551683
0,16	-1.5657346	5.3798158	4.4436276
0,17	-1.5214549	5.3733226	4.4341411
0,18	-1.4830183	5.3684852	4.4263451
0,19	-1.4495865	5.3650044	4.4200617
0,20	-1.4204608	5.3626411	4.4149767
0,21	-1.395055	5.361202	4.410672
0,22	-1.3728764	5.3605302	4.4069944
0,23	-1.3535058	5.3604977	4.4052018
0,24	-1.3365875	5.3609993	4.4068554
0,25	-1.3218177	5.3619481	4.4088096
0,26	-1.3089356	5.3632725	4.4109331
0,27	-1.2977167	5.3649132	4.4131533
0,28	-1.2879671	5.3668212	4.4154090
0,29	-1.2795189	5.3689558	4.4176477
0,30	-1.2722262	5.3712835	4.4198250

Fonte: desenvolvido pelo autor

APÊNDICE I – Kit pistola – a série temporal (36 meses) e sua estatística descritiva:

KIT PISTOLA - 36 M		
Datas	t	O(t)
mai/10	1	0,00
jun/10	2	0,00
jul/10	3	32,00
ago/10	4	14,00
set/10	5	8,00
out/10	6	0,00
nov/10	7	13,00
dez/10	8	18,00
jan/11	9	8,00
fev/11	10	19,00
mar/11	11	8,00
abr/11	12	0,00
mai/11	13	21,00
jun/11	14	16,00
jul/11	15	8,00
ago/11	16	1,00
set/11	17	10,00
out/11	18	18,00
nov/11	19	7,00
dez/11	20	0,00
jan/12	21	0,00
fev/12	22	0,00
mar/12	23	4,00
abr/12	24	10,00
mai/12	25	0,00
jun/12	26	4,00
jul/12	27	4,00
ago/12	28	18,00
set/12	29	1,00
out/12	30	10,00
nov/12	31	11,00
dez/12	32	2,00
jan/13	33	0,00
fev/13	34	24,00
mar/13	35	9,00
abr/13	36	8,00
ESTATÍSTICA DESCRITIVA:		
Média		8,50
Erro padrão		1,36
Mediana		8,00
Modo		0,00
Desvio padrão		8,14
Variância da amostra		66,26
Curtose		0,47
Assimetria		0,91
Intervalo		32,00
Mínimo		0,00
Máximo		32,00
Soma		306,00
Contagem		36,00

Fonte: desenvolvido pelo autor, calculado em planilha eletrônica.

APÊNDICE J – Kit pistola – intervalo médio entre as demandas e o coeficiente de variação da série.

KIT PISTOLA - Cálculo de ADI e CV, segundo REGATTIERI et al, 2005.			
Intervalo médio entre as demandas (ADI)	$E_r(i) =$ Demanda $X(t)$	$[E_r(i) -$ $E_{média}]^2$	CV - Coeficiente de Variação (CV)
3	32	427,11	
1	14	7,11	
1	8	11,11	
2	13	2,78	
1	18	44,44	
1	8	11,11	
1	19	58,78	
1	8	11,11	
2	21	93,44	
1	16	21,78	
1	8	11,11	
1	1	106,78	
1	10	1,78	
1	18	44,44	
1	7	18,78	
4	4	53,78	
1	10	1,78	
2	4	53,78	
1	4	53,78	
1	18	44,44	
1	1	106,78	
1	10	1,78	
1	11	0,11	
1	2	87,11	
2	24	160,44	
1	9	5,44	
1	8	11,11	
1,33	11,33	1452,00	0,65

Fonte: Regattieri et al, 2005.

APÊNDICE K – Kit pistola (série com 30 dados) – previsões calculadas pelos métodos: ARIMA, HW, Holt, SES, SES(OT), CR-D e CR-Z – utilizando o software R (apenas linhas de programa).

Observar: RQDQM (RMSE), DAM (MAD) e o Teste de Normalidade Shapiro-Wilk para os resíduos (discrepâncias).

```
pistolats2=ts(PISTOLA,frequency=12,start=c(2010,5),end=c(2012,10))
```

```
> pistets2=ets(pistolats2)
```

```
>summary(pistets2)
```

```
> pistses2=ses(pistolats2)
```

```
>summary(pistses2)
```

```
>print(pistolats2)
```

```
>hist(pistses2$residuals)
```

```
>shapiro.test(pistses2$residuals)
```

```
> pistses2ot=ses(pistolats2,alpha=0.10)
```

```
>summary(pistses2ot)
```

```
>hist(pistses2ot$residuals)
```

```
>shapiro.test(pistses2ot$residuals)
```

```
> pish2=holt(pistolats2)
```

```
>summary(pish2)
```

```
>hist(pish2$residuals)
```

```
>shapiro.test(pisth2$residuals)
```

```
> pisthw2=hw(pistolats2)
```

```
>summary(pisthw2)
```

```
>hist(pisthw2$residuals)
```

```
>shapiro.test(pisthw2$residuals)
```

```
> pistar2=auto.arima(pistolats2)
```

```
>summary(pistar2)
```

```
>hist(pistar2$residuals)
```

```
>shapiro.test(pistar2$residuals)
```

```
> pistcros2=croston(pistolats2)
```

```
>summary(pistcros2)
```

```
>hist(pistcros2$residuals)
```

```
>shapiro.test(pistcros2$residuals)
```

```
> pistcrotim2=croston(pistolats2,alpha=0.10)
```

```
>summary(pistcrotim2)
```

```
>shapiro.test(pistcrotim2$residuals)
```

**APÊNDICE L – Kit pistola (30 dados) – Previsão pelo Método SB5,
com $\alpha = 0,10$.**

PIST-SB5-30M									
PREVISÃO - 30 MESES - com 6 passos à frente					$Y'(t) = (1-\alpha/2)*(z't/p't)$	Discrepâncias			
Mês (t)	Dem	$z'(t)$	$p(t)$	$p'(t)$	SB5	Dem - Prev	Soma erros ao quadrado	DAM	Erro absoluto escalar (ing)
mai/10	0								
jun/10	0	0,00		0,00					
jul/10	32	3,20	3	0,30	10,13	21,87	478,15	21,87	2,42035162
ago/10	14	4,28	1	0,37	10,99	3,01	9,06	3,01	0,33325705
set/10	8	4,65	1	0,43	10,21	-2,21	4,87	2,21	0,24422674
out/10	0	4,65		0,43	10,21	-10,21	104,17	10,21	1,12972124
nov/10	13	5,49	2	0,59	8,84	4,16	17,31	4,16	0,46054873
dez/10	18	6,74	1	0,63	10,15	7,85	61,64	7,85	0,86901352
jan/11	8	6,86	1	0,67	9,77	-1,77	3,12	1,77	0,19559797
fev/11	19	8,08	1	0,70	10,95	8,05	64,82	8,05	0,89115144
mar/11	8	8,07	1	0,73	10,49	-2,49	6,20	2,49	0,27568138
abr/11	0	8,07		0,73	10,49	-10,49	110,05	10,49	1,16117588
mai/11	21	9,36	2	0,86	10,37	10,63	112,99	10,63	1,17655566
jun/11	16	10,03	1	0,87	10,92	5,08	25,76	5,08	0,56181392
jul/11	8	9,82	1	0,88	10,55	-2,55	6,50	2,55	0,28209218
ago/11	1	8,94	1	0,90	9,48	-8,48	71,87	8,48	0,93836156
set/11	10	9,05	1	0,91	9,48	0,52	0,27	0,52	0,05754661
out/11	18	9,94	1	0,92	10,31	7,69	59,11	7,69	0,85096298
nov/11	7	9,65	1	0,92	9,92	-2,92	8,50	2,92	0,32274321
dez/11	0	9,65		0,92	9,92	-9,92	98,32	9,92	1,09755089
jan/12	0	9,65		0,92	9,92	-9,92	98,32	9,92	1,09755089
fev/12	0	9,65		0,92	9,92	-9,92	98,32	9,92	1,09755089
mar/12	4	9,08	4	1,23	7,00	-3,00	9,03	3,00	0,33258299
abr/12	10	9,18	1	1,21	7,21	2,79	7,78	2,79	0,30868836
mai/12	0	9,18		1,21	7,21	-7,21	52,00	7,21	0,79817975
jun/12	4	8,66	2	1,29	6,39	-2,39	5,69	2,39	0,26413899
jul/12	4	8,19	1	1,26	6,18	-2,18	4,76	2,18	0,24140224
ago/12	18	9,17	1	1,23	7,07	10,93	119,54	10,93	1,21020688
set/12	1	8,36	1	1,21	6,56	-5,56	30,92	5,56	0,61551192
out/12	10	8,52	1	1,19	6,81	3,19	10,19	3,19	0,35330525
nov/12		8,52		1,19	6,81				
dez/12		8,52		1,19	6,81				
jan/13		8,52		1,19	6,81				
fev/13		8,52		1,19	6,81				
mar/13		8,52		1,19	6,81				
abr/13		8,52		1,19	6,81				
					SUM ERR	-5,427			
					ME=DM	-0,194			
					MSE		59,975		
					RQDQM (RMSE)		7,744		
					DAM (MAD)			6,320	
					MASE (ing)				0,700

Fonte: desenvolvido pelo autor

APÊNDICE M – Kit pistola (30 dados) – Previsão pelo Método TS6, com $\alpha = 0,10$.

KIT PIST - TS6 - 30M									
PREVISÃO - 30 MESES - com 6 passos à frente					$Y'(t) = (1-\alpha/2) * (z' t / (p' t - \alpha/2))$	Discrepâncias			
Mês (t)	Dem	$z'(t)$	$p(t)$	$p'(t)$	TS6	Dem - Prev	Soma erros ao quadrado	DAM (MAD = MAE)	Erro absoluto escalar (ing)
mai/10	0								
jun/10	0	0,00	0,00		0,00	0,00	0,00	0,00	0,00
jul/10	32	3,20	3	0,30	12,16	19,84	393,63	19,84	2,20
ago/10	14	4,28	1	0,37	12,71	1,29	1,67	1,29	0,14
set/10	8	4,65	1	0,43	11,54	-3,54	12,52	3,54	0,39
out/10	0	4,65	0,43		11,54	-11,54	133,15	11,54	1,28
nov/10	13	5,49	2	0,59	9,66	3,34	11,17	3,34	0,37
dez/10	18	6,74	1	0,63	11,02	6,98	48,68	6,98	0,77
jan/11	8	6,86	1	0,67	10,56	-2,56	6,54	2,56	0,28
fev/11	19	8,08	1	0,70	11,79	7,21	51,98	7,21	0,80
mar/11	8	8,07	1	0,73	11,26	-3,26	10,63	3,26	0,36
abr/11	0	8,07	0,73		11,26	-11,26	126,81	11,26	1,25
mai/11	21	9,36	2	0,86	11,01	9,99	99,75	9,99	1,11
jun/11	16	10,03	1	0,87	11,59	4,41	19,46	4,41	0,49
jul/11	8	9,82	1	0,88	11,18	-3,18	10,11	3,18	0,35
ago/11	1	8,94	1	0,90	10,04	-9,04	81,68	9,04	1,00
set/11	10	9,05	1	0,91	10,03	-0,03	0,00	0,03	0,00
out/11	18	9,94	1	0,92	10,91	7,09	50,31	7,09	0,79
nov/11	7	9,65	1	0,92	10,48	-3,48	12,13	3,48	0,39
dez/11	0	9,65	0,92		10,48	-10,48	109,89	10,48	1,16
jan/12	0	9,65	0,92		10,48	-10,48	109,89	10,48	1,16
fev/12	0	9,65	0,92		10,48	-10,48	109,89	10,48	1,16
mar/12	4	9,08	4	1,23	7,30	-3,30	10,90	3,30	0,37
abr/12	10	9,18	1	1,21	7,52	2,48	6,14	2,48	0,27
mai/12	0	9,18	1,21		7,52	-7,52	56,59	7,52	0,83
jun/12	4	8,66	2	1,29	6,64	-2,64	6,99	2,64	0,29
jul/12	4	8,19	1	1,26	6,44	-2,44	5,94	2,44	0,27
ago/12	18	9,17	1	1,23	7,37	10,63	113,10	10,63	1,18
set/12	1	8,36	1	1,21	6,84	-5,84	34,15	5,84	0,65
out/12	10	8,52	1	1,19	7,11	2,89	8,37	2,89	0,32
nov/12		8,52	1,19		7,11				
dez/12		8,52	1,19		7,11				
jan/13		8,52	1,19		7,11				
fev/13		8,52	1,19		7,11				
mar/13		8,52	1,19		7,11				
abr/13		8,52	1,19		7,11				
SUM ERR						-24,928			
ME=DM						-0,860			
MSE							56,623		
RQDQM (RMSE)							7,525		
DAM (MAD)								6,112	
MASE (ing)									0,677

Fonte: desenvolvido pelo autor

APÊNDICE N – Kit pistola (30 dados) – Previsão pelo Método NNQ-STAT, que resultou no modelo AAdA.

NNQ-STAT: KIT PISTOLA - 30 MESES - Suavização Exponencial - modelo: AAdA - Previsão com 6 passos à frente												
								Parâmetros do modelo				
Datas	t	Previsão	AJUST	Linf 80	LSup 80	n(0)	c(0)	s(0)	alfa	beta	gama	fi
nov/12	37	14,43	6,03	5,54	23,32	19,77	-0,18	0,26	0,01	0,01	0,01	0,99
dez/12	38	13,82	5,42	4,93	22,72			-0,22				
jan/13	39	10,56	2,16	1,66	19,45			-3,36				
fev/13	40	14,24	5,84	5,34	23,13			0,44				
mar/13	41	11,93	3,53	3,04	20,83			-1,74				
abr/13	42	11,25	2,85	2,35	20,14			-2,31				
mai/13	43	12,05		3,15	20,94			-1,40				
jun/13	44	11,69		2,79	20,58			-1,64				
jul/13	45	19,85		10,95	28,75			6,65				
ago/13	46	16,19		7,29	25,09			3,09				
set/13	47	11,48		2,58	20,38			-1,50				
out/13	48	14,61		5,71	23,51			1,74				

Avaliação do modelo			
desv pad e(t)	DPAM	U de Theil	AIC
6,939	39,09%	0,646	301,470

Dados do modelo		
Nome da variável:	PIST_30M	
nº de observações:	36	nº de previsões: 12
Começo dos dados:	nov/09	Começo das previsões: nov/12
Final dos dados:	out/12	Final das previsões: out/13
Previsão realizada em:	29/07/2013 14:47	

Fonte: desenvolvido pelo autor

APÊNDICE O – Componente Meio Filtrante – a série temporal e sua estatística descritiva:

MEIO FILTRANTE		
Datas	t	O(t)
mai/10	1	100
jun/10	2	0
jul/10	3	100
ago/10	4	0
set/10	5	0
out/10	6	100
nov/10	7	0
dez/10	8	91
jan/11	9	0
fev/11	10	122
mar/11	11	0
abr/11	12	58
mai/11	13	100
jun/11	14	0
jul/11	15	122
ago/11	16	158
set/11	17	0
out/11	18	0
nov/11	19	0
dez/11	20	0
jan/12	21	100
fev/12	22	105
mar/12	23	0
abr/12	24	0
mai/12	25	100
jun/12	26	0
jul/12	27	0
ago/12	28	0
set/12	29	142
out/12	30	112
nov/12	31	150
dez/12	32	0
jan/13	33	150
fev/13	34	0
mar/13	35	0
abr/13	36	100
ESTATÍSTICA DESCRITIVA		
Média		53,06
Erro padrão		9,91
Mediana		0,00
Modo		0,00
Desvio padrão		59,47
Variância da amostra		3536,40
Curtose		-1,62
Assimetria		0,38
Intervalo		158,00
Mínimo		0,00
Máximo		158,00
Soma		1910,00
Contagem		36,00

Fonte: desenvolvido pelo autor

APÊNDICE P – Meio filtrante – métodos de previsão: ARIMA, SES, SES(OT), Holt, HW, CR-D e CR-Z, mediante utilização do software R.

Nota: Apenas as linhas de programa são apresentadas.

```
filtrots2=ts(MEIO_FILT,frequency=12,start=c(2010,5),end=c(2012,10))
```

```
>print(filtrots2)
```

```
> mfets2=ets(filtrots2)
```

```
>summary(mfets2)
```

```
> mfses2=ses(filtrots2)
```

```
>summary(mfses2)
```

```
>hist(mfses2$residuals)
```

```
>shapiro.test(mfses2$residuals)
```

```
> mfsesotim2=ses(filtrots2,alpha=0.18)
```

```
>summary(mfsesotim2)
```

```
>hist(mfsesotim2$residuals)
```

```
>shapiro.test(mfsesotim2$residuals)
```

```
> mfh2=holt(filtrots2)
```

```
>summary(mfh2)
```

```
>hist(mfh2$residuals)
```

```
>shapiro.test(mfh2$residuals)
```

```
> mfhw2=hw(filtrots2)
>summary(mfhw2)
>hist(mfhw2$residuals)
>shapiro.test(mfhw2$residuals)
```

```
> mfar2=auto.arima(filtrots2)
>summary(mfar2)
```

```
>hist(mfar2$residuals)
>shapiro.test(mfar2$residuals)
```

```
> mfcf2=croston(filtrots2)
>summary(mfcf2)
```

```
>hist(mfcf2$residuals)
>shapiro.test(mfcf2$residuals)
```

```
> mfcrotim2=croston(filtrots2,alpha=0.18)
>summary(mfcrotim2)
>hist(mfcrotim2$residuals)
>shapiro.test(mfcrotim2$residuals)
```


APÊNDICE Q – Meio filtrante – cálculo da previsão mediante o Método SB5, com horizonte de um a seis passos à frente.

Meio Filtrante - SB5 - 30M						
Mês (t)	Demanda X(t)	Y'(t) = (1- α /2)*z't/ ρ 't)	Dem - Prev	DQM	DAM (MAD)	Erro absoluto escalar (ing)
		SB 2005				
mai-10	100					
jun-10	0					
jul-10	100	45,50	54,50	2970,25	54,50	0,78
ago-10	0	45,50	-45,50	2070,25	45,50	0,65
set-10	0	45,50	-45,50	2070,25	45,50	0,65
out-10	100	35,69	64,31	4135,27	64,31	0,92
nov-10	0	35,69	-35,69	1274,06	35,69	0,51
dez-10	91	37,66	53,34	2844,98	53,34	0,76
jan-11	0	37,66	-37,66	1418,40	37,66	0,54
fev-11	122	42,94	79,06	6250,12	79,06	1,13
mar-11	0	42,94	-42,94	1844,04	42,94	0,62
abr-11	58	38,55	19,45	378,16	19,45	0,28
mai-11	100	45,85	54,15	2931,94	54,15	0,78
jun-11	0	45,85	-45,85	2102,46	45,85	0,66
jul-11	122	48,30	73,70	5431,69	73,70	1,06
ago-11	158	61,08	96,92	9393,62	96,92	1,39
set-11	0	61,08	-61,08	3730,68	61,08	0,88
out-11	0	61,08	-61,08	3730,68	61,08	0,88
nov-11	0	61,08	-61,08	3730,68	61,08	0,88
dez-11	0	61,08	-61,08	3730,68	61,08	0,88
jan-12	100	41,81	58,19	3386,02	58,19	0,83
fev-12	105	47,12	57,88	3350,24	57,88	0,83
mar-12	0	47,12	-47,12	2220,17	47,12	0,68
abr-12	0	47,12	-47,12	2220,17	47,12	0,68
mai-12	100	42,66	57,34	3287,53	57,34	0,82
jun-12	0	42,66	-42,66	1820,13	42,66	0,61
jul-12	0	42,66	-42,66	1820,13	42,66	0,61
ago-12	0	42,66	-42,66	1820,13	42,66	0,61
set-12	142	39,54	102,46	10498,03	102,46	1,47
out-12	112	44,79	67,21	4517,00	67,21	0,96
nov-12	150	44,79				
dez-12	0	44,79				
jan-13	150	44,79				
fev-13	0	44,79				
mar-13	0	44,79				
abr-13	100	44,79				
Soma Discrep.			118,799			
DM			4,243			
Soma DQM				3392,064		
RQDQM				58,241		
DAM					55,650	
MASE (ing)						0,797

Fonte: desenvolvido pelo autor

APÊNDICE R – Meio filtrante – aplicação do Método TS6, gerando previsões de um a seis períodos à frente.

Meio Filtrante - TS6 - 30M										
Mês (t)	Demanda X(t)	z'(t)	p(t)	p'(t)	Y'(t) = (1-α/2)*(z't/(p't-α/2))	Dem - Prev	DQM	DAM	Desvio absoluto escalar (ing)	
					TS 2006					
mai-10	100									
jun-10	0	0,00		0,00						
jul-10	100	18,00	2	0,36	60,67	39,33	1547,11	39,33	0,56	
ago-10	0	18,00		0,36	60,67	-60,67	3680,44	60,67	0,87	
set-10	0	18,00		0,36	60,67	-60,67	3680,44	60,67	0,87	
out-10	100	32,76	3	0,84	40,00	60,00	3599,42	60,00	0,86	
nov-10	0	32,76		0,84	40,00	-40,00	1600,39	40,00	0,57	
dez-10	91	43,24	2	1,04	41,21	49,79	2478,90	49,79	0,71	
jan-11	0	43,24		1,04	41,21	-41,21	1698,38	41,21	0,59	
fev-11	122	57,42	2	1,22	46,37	75,63	5719,56	75,63	1,08	
mar-11	0	57,42		1,22	46,37	-46,37	2150,38	46,37	0,66	
abr-11	58	57,52	2	1,36	41,29	16,71	279,21	16,71	0,24	
mai-11	100	65,17	1	1,29	49,28	50,72	2572,32	50,72	0,73	
jun-11	0	65,17		1,29	49,28	-49,28	2428,71	49,28	0,71	
jul-11	122	75,40	2	1,42	51,57	70,43	4960,80	70,43	1,01	
ago-11	158	90,27	1	1,34	65,46	92,54	8563,65	92,54	1,33	
set-11	0	90,27		1,34	65,46	-65,46	4285,01	65,46	0,94	
out-11	0	90,27		1,34	65,46	-65,46	4285,01	65,46	0,94	
nov-11	0	90,27		1,34	65,46	-65,46	4285,01	65,46	0,94	
dez-11	0	90,27		1,34	65,46	-65,46	4285,01	65,46	0,94	
jan-12	100	92,02	5	2,00	43,78	56,22	3160,94	56,22	0,81	
fev-12	105	94,36	1	1,82	49,57	55,43	3072,85	55,43	0,79	
mar-12	0	94,36		1,82	49,57	-49,57	2456,86	49,57	0,71	
abr-12	0	94,36		1,82	49,57	-49,57	2456,86	49,57	0,71	
mai-12	100	95,37	3	2,03	44,64	55,36	3064,97	55,36	0,79	
jun-12	0	95,37		2,03	44,64	-44,64	1992,54	44,64	0,64	
jul-12	0	95,37		2,03	44,64	-44,64	1992,54	44,64	0,64	
ago-12	0	95,37		2,03	44,64	-44,64	1992,54	44,64	0,64	
set-12	142	103,76	4	2,39	41,09	100,91	10183,11	100,91	1,45	
out-12	112	105,25	1	2,14	46,76	65,24	4256,33	65,24	0,93	
nov-12	150	105,25		2,14	46,76					
dez-12	0	105,25		2,14	46,76					
jan-13	150	105,25		2,14	46,76					
fev-13	0	105,25		2,14	46,76					
mar-13	0	105,25		2,14	46,76					
abr-13	100	105,25		2,14	46,76					
					DM	-0,171				
					Soma DQM		3454,618			
					RQDQM		58,776			
					DAM			56,479		
					MASE (ing)				0,809	

Fonte: desenvolvido pelo autor

APÊNDICE S – Meio filtrante – cálculo da previsão mediante o Método Holt-Winters (A, N, A), mediante o uso da ferramenta NNQ-STAT, com horizonte de um a seis passos à frente.

NNQ-STAT: MEIO FILTR - 30M - Método: Suavização Exponencial - modelo: ANA (Holt-Winters)												
									Parâmetros do modelo			
Datas	t	Previsão	PREV AJUST	Linf 80	L.Sup 80	n(0)	c(0)	s(0)	alfa	beta	gama	fi
nov/12	37	67,23	16,89	12,12	122,33	100,71	0,00	-33,42	0,01	0,00	0,01	0,00
dez/12	38	97,58	47,25	42,48	152,69			-3,06				
jan/13	39	100,36	50,03	45,25	155,47			-0,30				
fev/13	40	142,15	91,82	87,04	197,27			41,48				
mar/13	41	67,17	16,84	12,05	122,28			-33,48				
abr/13	42	86,57	36,24	31,46	141,69			-14,07				
mai/13	43	150,36		95,24	205,48			49,71				
jun/13	44	50,34		-4,78	105,46			-50,31				
jul/13	45	124,49		69,36	179,61			23,85				
ago/13	46	103,00		47,88	158,13			2,35				
set/13	47	97,61		42,47	152,74			-3,06				
out/13	48	120,96		65,83	176,09			20,30				
									Avaliação do modelo			
									desv pad			
									e(t)	DPAM	U de Theil	AIC
									42,998	42,43%	0,606	426,795
Dados do modelo												
Nome da variável:		MF_30M										
nº de observações:		36										
Começo dos dados:		nov/09		nº de previsões:		12						
Final dos dados:		out/12		Começo das previsões:		nov/12						
Previsão realizada em:		29/07/2013 15:11		Final das previsões:		out/13						

Fonte: desenvolvido pelo autor

APÊNDICE T– Sensor neonatal (ou de oximetria) – a série temporal (com 55 dados) e sua estatística descritiva:

Sensor de Oximetria		Sensor de Oximetria	
Semana (t)	Demanda X(t)	Semana (t)	Demanda X(t)
45.11	10	21.12	0
46.11	0	22.12	0
47.11	10	23.12	0
48.11	0	24.12	0
49.11	3	25.12	5
50.11	0	26.12	5
51.11	0	27.12	22
52.11	6	28.12	6
01.12	10	29.12	0
02.12	0	30.12	6
03.12	6	31.12	4
04.12	3	32.12	0
05.12	12	33.12	0
06.12	5	34.12	0
07.12	8	35.12	14
08.12	5	36.12	0
09.12	0	37.12	0
10.12	0	38.12	0
11.12	10	39.12	0
12.12	0	40.12	0
13.12	3	41.12	0
14.12	5	42.12	0
15.12	10	43.12	0
16.12	0	44.12	0
17.12	10	45.12	11
18.12	0	46.12	5
19.12	0	47.12	8
20.12	0		
ESTATÍSTICA DESCRITIVA:			
Média		3,6727	
Erro padrão		0,6534	
Mediana		0	
Modo		0	
Desvio padrão		4,8460	
Variância da amostra		23,4835	
Curtose		2,3656	
Assimetria		1,4416	
Intervalo		22	
Mínimo		0	
Máximo		22	
Soma		202	
Contagem		55	

Fonte: desenvolvido pelo autor

APÊNDICE U – Sensor neonatal – utilização do software R para o cálculo das previsões, nos seguintes métodos: SES, SES(OT), Holt, CR-D e CR-Z.

Nota: Apenas as linhas de programa.

```
sensors=ts(SENS_NEO,frequency=52,start=c(2011,45),end=c(2012,41))
```

```
>print(sensors)
```

```
>summary(sensors)
```

```
>sensorses=ses(sensors,h=6);summary(sensorses)
```

```
>sensorsesotim=ses(sensors,alpha=0.23,h=6);summary(sensorsesotim)
```

```
>sensorh=holt(sensors,h=6);summary(sensorh)
```

```
>sensorcr=croston(sensors,h=6);summary(sensorcr)
```

```
>sensorcrotim=croston(sensors,alpha=0.23,h=6);summary(sensorcrotim)
```

APÊNDICE V – Sensor neonatal – Previsão com horizonte de seis períodos à frente, pelo Método SB5.

Notar que as semanas 05/12 a 27/12 foram suprimidas para melhorar a visualização do quadro.

Sensor Neonatal - SB5 - 49 SEMANAS							
Semana	Demanda X(t)	Y'(t) = (1- α /2)*(z't/p't)	Dem - Prev	DQM	DAM	Desvio absoluto escalar (ing)	
		SB 2005					
45.11	10						
46.11	0						
47.11	10	4,43	5,58	31,08	5,58	1,13	
48.11	0	4,43	-4,43	19,58	4,43	0,90	
49.11	3	2,68	0,33	0,11	0,33	0,07	
50.11	0	2,68	-2,68	7,16	2,68	0,54	
51.11	0	2,68	-2,68	7,16	2,68	0,54	
52.11	6	2,20	3,80	14,43	3,80	0,77	
01.12	10	3,43	6,57	43,16	6,57	1,34	
02.12	0	3,59	-3,59	12,90	3,59	0,73	
03.12	6	3,94	2,06	4,25	2,06	0,42	
04.12	3	3,67	-0,67	0,45	0,67	0,14	
28.12	6	4,22	1,78	3,15	1,78	0,36	
29.12	0	4,22	-4,22	17,84	4,22	0,86	
30.12	6	3,85	2,15	4,62	2,15	0,44	
31.12	4	3,81	0,19	0,04	0,19	0,04	
32.12	0	3,81	-3,81	14,51	3,81	0,77	
33.12	0	3,81	-3,81	14,51	3,81	0,77	
34.12	0	3,81	-3,81	14,51	3,81	0,77	
35.12	14	3,52	10,48	109,89	10,48	2,13	
36.12	0	3,52	-3,52	12,37	3,52	0,72	
37.12	0	3,52	-3,52	12,37	3,52	0,72	
38.12	0	3,52	-3,52	12,37	3,52	0,72	
39.12	0	3,52	-3,52	12,37	3,52	0,72	
40.12	0	3,52	-3,52	12,37	3,52	0,72	
41.12	0	3,52	-3,52	12,37	3,52	0,72	
42.12		3,52					
43.12		3,52					
44.12		3,52					
45.12		3,52					
46.12		3,52					
47.12		3,52					
		Soma Erros	-16,955				
		DM	-0,361				
		DQM		23,651			
		RQDQM		4,863			
		DAM			3,953		
		MASE (ing)				0,804	

Fonte: desenvolvido pelo autor

APÊNDICE W – Sensor neonatal – Previsão com horizonte de seis períodos à frente, pelo Método TS6.

Notar que as semanas 51/11 a 10/12 foram suprimidas para melhorar a visualização do quadro.

Sensor Neonatal - TS6 - 49 semanas										
Semana	Demanda X(t)	z'(t)	p(t)	p'(t)	Y'(t) = (1-α/2)*(z't/(p't-α/z))	Dem - Prev	DQM	DAM	Desvio absoluto escalar (ing)	
					TS 2006					
45.11	10									
46.11	0									
47.11	10	2,30	2	0,46	5,90	4,10	16,81	4,10	0,83	
48.11	0	2,30		0,46	5,90	-5,90	34,81	5,90	1,20	
49.11	3	2,46	2	0,81	3,11	-0,11	0,01	0,11	0,02	
50.11	0	2,46		0,81	3,11	-3,11	9,70	3,11	0,63	
11.12	10	7,02	3	1,49	4,52	5,48	30,06	5,48	1,12	
12.12	0	7,02		1,49	4,52	-4,52	20,41	4,52	0,92	
13.12	3	6,10	2	1,61	3,61	-0,61	0,38	0,61	0,12	
14.12	5	5,84	1	1,47	3,82	1,18	1,39	1,18	0,24	
15.12	10	6,80	1	1,36	4,83	5,17	26,70	5,17	1,05	
16.12	0	6,80		1,36	4,83	-4,83	23,36	4,83	0,98	
17.12	10	7,54	2	1,51	4,79	5,21	27,15	5,21	1,06	
18.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
19.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
20.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
21.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
22.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
23.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
24.12	0	7,54		1,51	4,79	-4,79	22,94	4,79	0,97	
25.12	5	6,95	8	3,00	2,13	2,87	8,22	2,87	0,58	
26.12	5	6,50	1	2,54	2,37	2,63	6,90	2,63	0,53	
27.12	22	10,07	1	2,19	4,30	17,70	313,23	17,70	3,60	
28.12	6	9,13	1	1,91	4,49	1,51	2,27	1,51	0,31	
29.12	0	9,13		1,91	4,49	-4,49	20,20	4,49	0,91	
30.12	6	8,41	2	1,93	4,09	1,91	3,63	1,91	0,39	
31.12	4	7,40	1	1,72	4,08	-0,08	0,01	0,08	0,02	
32.12	0	7,40		1,72	4,08	-4,08	16,66	4,08	0,83	
33.12	0	7,40		1,72	4,08	-4,08	16,66	4,08	0,83	
34.12	0	7,40		1,72	4,08	-4,08	16,66	4,08	0,83	
35.12	14	8,92	4	2,24	3,71	10,29	105,94	10,29	2,09	
36.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
37.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
38.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
39.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
40.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
41.12	0	8,92		2,24	3,71	-3,71	13,74	3,71	0,75	
42.12		8,92		2,24	3,71					
43.12		8,92		2,24	3,71					
44.12		8,92		2,24	3,71					
45.12		8,92		2,24	3,71					
46.12		8,92		2,24	3,71					
47.12		8,92		2,24	3,71					
Soma Erros						-35,483				
DM						-0,755				
DQM							24,207			
RQDQM							4,920			
DAM								4,057		
MASE (in)									0,825	

Fonte: desenvolvido pelo autor

**APÊNDICE X – Sensor de oximetria (neonatal) – cálculo da
previsão mediante a utilização do software NNQ-STAT, com
horizonte de um a seis passos à frente.**

NNQ-STAT - SENSOR NEO - 49 SEM - Método: Suavização Exponencial - modelo: AAdA												
						Parâmetros do modelo						
Datas	t	Previsão	PREV AJUST	L.inf 80	L.Sup 80	n(0)	c(0)	s(0)	alfa	beta	gama	fi
(1/8)	50	9,31	5,68	3,35	15,27	8,65	-0,07	3,21	0,01	0,01	0,01	0,99
(2/8)	51	5,90	2,26	-0,06	11,85			-0,16				
(3/8)	52	4,62	0,99	-1,33	10,58			-1,40				
(4/8)	53	5,21	1,57	-0,75	11,16			-0,78				
(5/8)	54	5,36	1,73	-0,59	11,32			-0,58				
(6/8)	55	4,81	1,17	-1,15	10,76			-1,10				
(7/8)	56	6,68		0,72	12,63			0,80				
Avaliação do modelo												
desv pad	DPAM		U de		AIC							
e(t)			Theil									
4,648	58,92%		0,804		364,257							
Dados do modelo												
Nome da variável	SENSOR_49S											
nº de observações	49	nº de previsões		7								
Começo dos dados	(1/1)	Começo das previsões		(1/8)								
Final dos dados	(7/7)	Final das previsões		(7/8)								
Previsão realizada em:	29/07/2013 14:12:54											
Outliers e(t)												
t	e(t)											
35	18,30											

Fonte: desenvolvido pelo autor