

**FUNDAÇÃO INSTITUTO CAPIXABA DE PESQUISAS EM
CONTABILIDADE, ECONOMIA E FINANÇAS - FUCAPE**

CARLOS ALEXANDRE VIEIRA DE CARVALHO

**ANÁLISE DE PREVISÃO DE ITENS DE DEMANDA INTERMITENTE
UTILIZANDO O MODELO SYNTETOS-BOYLAN APPROXIMATION**

**VITÓRIA
2012**

CARLOS ALEXANDRE VIEIRA DE CARVALHO

**ANÁLISE DE PREVISÃO DE ITENS DE DEMANDA INTERMITENTE
UTILIZANDO O MODELO SYNTETOS-BOYLAN APPROXIMATION**

Dissertação apresentada ao Programa de Pós-Graduação em Administração de Empresas, da Fundação Instituto Capixaba de Pesquisas em Contabilidade, Economia e Finanças (FUCAPE), como requisito parcial para obtenção do título de Mestre em Administração de Empresas – na área de concentração Estratégia.

Orientador: Marcelo Sanches Pagliarussi

**VITÓRIA
2012**

CARLOS ALEXANDRE VIEIRA DE CARVALHO

**ANÁLISE DE PREVISÃO DE ITENS DE DEMANDA INTERMITENTE
UTILIZANDO O MODELO SYNTETOS-BOYLAN APPROXIMATION**

Dissertação apresentada ao Programa de Pós-Graduação em Administração de Empresas da Fundação Instituto Capixaba de Pesquisas em Contabilidade, Economia e Finanças (FUCAPE), como requisito parcial para obtenção do título de Mestre em Administração de Empresas na área de concentração Estratégia.

Aprovada em 31 de Agosto de 2012.

COMISSÃO EXAMINADORA

**Profº Dr.: MARCELO SANCHES PAGLIARUSSI
(FUCAPE)**

**Profº Dr.: CRISTIANO M. COSTA
(FUCAPE)**

**Profº Dr. : HÉLIO ZANQUETO FILHO
(Universidade Federal do Espírito Santo - UFES)**

RESUMO

Esta pesquisa se concentra em métodos de Suavização Exponencial específica para itens com demandas intermitentes e apresenta um modelo de previsão para comparar o desempenho de dois métodos. Primeiramente são investigados na literatura medidas de precisão para que os métodos sejam avaliados. A adaptação de um modelo de previsão para comparar o desempenho dos dois métodos é apresentada. Os estudos anteriores sobre o tema nos fazem refletir sobre qual será a melhor forma de prever a demanda intermitente de peças sobressalentes, já que a grande maioria dos estudos sobre o tema se preocupa apenas com o valor esperado do erro das previsões e com a acurácia dos modelos sem levar em consideração os resultados de indicadores de desempenho. Partindo da hipótese de que com a utilização do método de Croston, desenvolvido para aplicação em demandas intermitentes, corrigido por Syntetos-Boylan será possível melhorar o desempenho do reabastecimento de peças sobressalentes de demanda intermitente. O objetivo deste estudo é testar se o método *Syntetos-Boylan Approximation* (SBA) é o modelo mais indicado como modelo de previsão de demanda intermitente de peças sobressalentes, a partir de dados históricos de uma empresa mineradora multinacional, comparando os resultados obtidos entre o modelo de Croston e o modelo SBA, apontados pela literatura como os modelos de melhor desempenho. O estudo se mostra relevante por considerar as particularidades dos itens com demanda intermitente ou esporádica em um modelo de previsão, além de trazer mais dados empíricos para testar o modelo SBA através de previsões que são avaliadas por indicadores de desempenho operacionais obtidos através de análise de cenários de atendimento de demanda, e não apenas por medidas de erros tradicionais.

Palavras - Chave: Croston, Suavização Exponencial, Syntetos-Boylan Approximation (SBA), Indicador de desempenho.

ABSTRACT

This research focuses on specific methods of Exponential Smoothing for items with intermittent demand and provides a forecast model to compare the performance of two methods. First are investigated in the literature for measures of accuracy that the methods are evaluated. The adaptation of a forecasting model to compare the performance of both methods is presented. Previous studies on the subject make us reflect on what will be the better way to forecast the intermittent demand of spare parts, since the vast majority of studies on the subject is concerned only with the expected value of the error of estimates and the accuracy of models without taking into account the results of operational performance. Assuming that the use of the Croston method, developed for use in intermittent demands, corrected by Syntetos-Boylan will be possible to improve the performance of replenishment spare parts for intermittent demand. The objective of this study is to test if the method Syntetos-Boylan Approximation (SBA) is the model most indicated as a model to forecast intermittent demand of spare parts, from historical data from a multinational mining company, by comparing the results between the model Croston and model of SBA, indicated by the literature as models for best performance. The study shows that by considering the particular relevance of the items with intermittent demand or sporadic in a forecasting model, and bring more empirical data to test the model through the SBA estimates that are measured by indicators of operational performance data derived from the scenario analysis of service demand, not only by traditional measures of errors.

Key - Words: Croston, Exponential Smoothing, Syntetos-Boylan Approximation (SBA), indicator of performance.

LISTA DE FIGURAS

FIGURA 1: VALORES DE CORTE-----	21
FIGURA 2: MODELAGEM DA LÓGICA DE ATENDIMENTO DA DEMANDA -----	30

LISTA DE QUADROS

QUADRO 1: RESUMO DE MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS (QUANTITATIVA).....	15
QUADRO 2: NOTAÇÃO	19
QUADRO 3: MODELOS DE PREVISÃO POR INDICADOR.....	46

LISTA DE TABELAS

TABELA 1: BASE DE ITENS PARA ORDENAÇÃO POR VALOR	33
TABELA 2: CÁLCULO DO MÉTODO DE CROSTON.....	35
TABELA 3: MEDIDAS DE ERRO	38
TABELA 4: RESULTADO DE INDICADORES PARA α IDEAL (IN SAMPLE) – MASE MINIMIZADO.....	42
TABELA 5: INDICADORES UTILIZANDO α IDEAL (OUT SAMPLE)	43
TABELA 6: RESULTADO DE INDICADORES PARA α IDEAL (IN SAMPLE) – DISPONIBILIDADE MAXIMIZADO.....	44
TABELA 7: INDICADORES PARA α IDEAL (OUT SAMPLE).....	45

SUMÁRIO

1. INTRODUÇÃO	10
2. REFERÊNCIAL TEÓRICO.....	14
2.1 PREVISÕES DE DEMANDA	14
2.2 MODELOS DE SÉRIES TEMPORAIS	15
2.3 MODELOS DE CROSTON E CROSTON MODIFICADO (SBA) PARA DEMANDAS INTERMITENTES.....	17
2.4 CLASSIFICAÇÕES DE PEÇAS SOBRESSALENTE.....	20
2.5 ERROS DE PREVISÃO	22
3. METODOLOGIA	26
3.1 INDICADORES DE DESEMPENHO	29
4. RESULTADOS.....	33
4.1 MODELOS DE PREVISÃO	34
4.2 IMPLANTAÇÃO DO MODELO	36
5. CONCLUSÕES	48
REFERÊNCIAS.....	51
APÊNDICE A – PREVISÃO DE CROSTON & SBA – ITEM 1	54
APÊNDICE B – PREVISÃO DE CROSTON & SBA – ITEM 2	55
APÊNDICE C – PREVISÃO DE CROSTON & SBA – ITEM 3	56
APÊNDICE D – PREVISÃO DE CROSTON & SBA – ITEM 4	57
APÊNDICE E – PREVISÃO DE CROSTON & SBA – ITEM 5.....	58
APÊNDICE F – PREVISÃO DE CROSTON & SBA – ITEM 6.....	59
APÊNDICE G – PREVISÃO DE CROSTON & SBA – ITEM 7	60
APÊNDICE H – PREVISÃO DE CROSTON & SBA – ITEM 8	61

1. INTRODUÇÃO

O conceito de estoque é antigo à humanidade, que, ao longo de sua história, tem usado estoques de diferentes recursos, como alimentos e ferramentas, para apoiar sua sobrevivência e desenvolvimento. Segundo Garcia et al (2006, p. 9), “A gestão de estoque é um conceito amplamente difundido, estando presente em praticamente todo o tipo de organização, até mesmo no dia-a-dia das pessoas”.

Para as empresas, se por um lado, baixos níveis de estoque podem levar a perda de economias de escala e altos custos devido a estoque com nível zero de produtos, o excesso de estoques representa, por outro lado, custos operacionais e de oportunidade do capital empatado. Encontrar o ponto ótimo nesse *trade - off* não é, em geral, uma tarefa simples.

Buscando um equilíbrio deste *trade – off*, dentro do universo de peças de Manutenção, reparo e operação, muitos autores tratam da previsão de demanda intermitente de peças sobressalentes (ou de reposição), dentre os quais: Croston (1972), Syntetos e Boylan (2001, 2005 e 2006), Eaves e Kingsman (2004), Willemain, Smart e Schwarz (2004), Hua et al. (2007), Teunter e Duncan (2009) .

O trabalho seminal de Croston (1972) demonstra que os métodos de Suavização Exponencial e o método de Média Móvel Simples não são necessariamente os modelos mais apropriados para serem utilizados em previsão de itens de demandas intermitentes, uma vez que podem gerar erros de previsão e, como consequência, tomadas de decisão equivocadas, no que se refere a estoques. Sendo assim, ele propõe um método que separa a estimação dos intervalos entre demandas da estimação dos volumes demandados em cada ocorrência.

Syntetos e Boylan (2001, 2005) demonstraram que o método de Croston é viesado, devido a um erro na derivação matemática da estimativa da demanda esperada de seu modelo, e propuseram uma nova versão. No artigo de Syntetos e Boylan (2005), quatro métodos foram testados em 3.000 séries de dados com demandas intermitentes de uma indústria automotiva resultando em um melhor desempenho do método de Croston corrigido, em relação aos demais métodos testados.

Eaves e Kingsman (2004), ao avaliarem técnicas de previsão de demanda de peças de sobressalentes da Força Aérea Britânica, incluindo os métodos de Croston e SBA, constataram a superioridade do método SBA para um determinado nível de serviço.

Willemain, Smart e Schwarz (2004) desenvolveram modelos de previsão para demandas intermitentes utilizando a técnica de *Bootstrapping* para sugerir a distribuição da demanda durante o *lead-time*, considerando auto-correlação e inserindo variações de demanda nos dados originais. Comparando o novo modelo com a Suavização Exponencial e com o método de Croston, concluíram que o modelo proposto fornece resultados superiores, principalmente em séries históricas pequenas.

Hua et al (2007) utilizaram a técnica de *Bootstrapping* conjuntamente com a regressão na previsão de demanda de peças sobressalentes na indústria petroquímica, e apontaram vantagens deste modelo.

Teunter e Duncan (2009) compararam os métodos de Média Móvel, Suavização Exponencial Simples, Croston original, SBA e *Bootstrapping*. O estudo, realizado com 5000 peças de reposição da Força Aérea Britânica, revelou a superioridade das técnicas de Croston, SBA e *Bootstrapping*.

A grande maioria dos estudos sobre o tema se preocupa com o valor esperado do erro das previsões e com a acurácia dos modelos, que são os principais indicadores de desempenho dos modelos, já que, quanto menor o erro, mais eficaz é o modelo.

Neste trabalho, foram levados em consideração os resultados de desempenho de outros indicadores como, por exemplo, a disponibilidade das peças sobresselentes nos armazéns, visando à agregação de valor e à ampliação das possibilidades de avaliação dos modelos.

Partiu-se da hipótese de que, com a utilização do método de Croston (1972), desenvolvido para aplicação em demandas intermitentes, corrigido por Syntetos-Boylan (2001, 2005 e 2006), será possível melhorar o desempenho do reabastecimento de peças sobresselentes, classificadas como demanda intermitente forte, conforme classificação adotada no capítulo 2.4.

Desta forma, o objetivo deste estudo é avaliar se o método *Syntetos-Boylan Approximation* (SBA) é o modelo mais indicado para a previsão de demanda intermitente forte, de peças sobresselentes. Para isso, será realizado um levantamento de dados históricos, comparando os resultados obtidos entre o modelo de Croston e o modelo SBA, apontados pela literatura como os de melhor desempenho.

Itens de demanda intermitente são exemplos de casos nos quais a distribuição de probabilidades normal raramente se mostra adequada para descrever a demanda durante certo intervalo de tempo. Dessa forma, a tomada de decisões de reabastecimento com base apenas nas estatísticas médias e desvio-padrão pode levar a custos sub-otimizados (GARCIA et al, 2006).

Em vista das considerações delineadas, a presente proposta de estudo se mostra relevante por: considerar as particularidades dos itens com demanda intermitente ou esporádica forte, ou seja, séries com muitos períodos com demanda zero, em um modelo de previsão de série temporal; e trazer mais dados empíricos para testar o modelo conhecido como *Syntetos-Boylan Approximation* (SBA). Foram desenvolvidas previsões que são avaliadas por indicadores de desempenho obtidos através de análise de cenário de atendimento de demanda. Além disso, há que se registrar as medidas de erros tradicionais, em 8 peças mais representativas economicamente, das 433 peças classificadas como intermitente ou esporádica forte, e dentre as 2706 peças sobressalentes, de origem importada, e consequentemente mais caras e com tempo de entrega maior.

2. REFERÊNCIAL TEÓRICO

A previsão de demanda é o ponto de partida para o planejamento estratégico de qualquer empresa, pois proporcionam, aos administradores, subsídios para planejem adequadamente suas ações. Nas próximas seções, será delineado o quadro teórico necessário para conceituar a previsão de demanda em relação à administração de materiais.

2.1 PREVISÕES DE DEMANDA

Para Monks (1987, p. 194), as previsões “são avaliações de ocorrência de eventos futuros incertos”. Uma “previsão da demanda” (conhecimento antecipado da demanda antes que ela ocorra) pode ser feita de maneira simples e intuitiva, com quase nenhuma análise de dados, ou mais quantitativa e complexa, em que a análise é bastante utilizada (MORETTIN e TOLOI, 2006, p. 7).

As técnicas quantitativas são utilizadas na análise de dados passados, através de modelos matemáticos, com o intuito de estimar a demanda futura. As técnicas baseadas em séries temporais relacionam os dados históricos da demanda com o tempo, não sofrendo influência de outras variáveis (TUBINO, 2000).

Os modelos clássicos baseados em séries temporais são: i) Média Móvel, que usa dados de períodos recentes para gerar a previsão; e ii) Média Exponencial Móvel, que utiliza um peso para cada observação decrescente no tempo em progressão geométrica ou exponencialmente (TUBINO, 2000). Outra metodologia muito utilizada é conhecida como Box e Jenkins, que consiste em ajustar modelos

auto-regressivos de médias móveis a um conjunto de dados (MORETTIN e TOLOI, 2006).

2.2 MODELOS DE SÉRIES TEMPORAIS

Podemos considerar muitos modelos de série temporais para descrever o comportamento de uma série em particular. Para Monks (1987, p. 198), série temporal é “um grupo de observações de uma variável no tempo. É geralmente catalogada ou grafada para mostrar a natureza da dependência do tempo”.

No Quadro 1, a seguir, estão relacionados os modelos de séries temporais mais utilizados segundo Monks (1987).

QUADRO 1: RESUMO DE MÉTODOS DE PREVISÃO DE SÉRIES TEMPORAIS (QUANTITATIVA)

Método	Descrição	Horizonte de Tempo
Ingênuo	Usa a regra simples de que a previsão iguala o último valor ou o último acréscimo de um fator de correção.	Curto Prazo
Média Móvel	A previsão é a média dos n períodos mais recentes.	Curto Prazo
Projeção de Tendência	A previsão é linear, exponencial, ou outra projeção de tendência passada.	Médio e Longo Prazo
Decomposição	A série de tempo é dividida em componentes de tendência, periódicos, cíclicos e aleatórios.	Curto e Longo Prazo
Ajuste Exponencial	A previsão é uma média móvel ponderada exponencialmente, na qual os dados mais recentes têm maior peso.	Curto Prazo
Box-Jenkins	Um modelo de regressão de série de tempo é proposto, testado estatisticamente, modificado e novamente testado até ficar satisfatório.	Médio e longo Prazo

Fonte: Monks (1987, p. 197)

Nota: Adaptado pelo autor.

Os modelos utilizados para descrever séries temporais são, para Morettin e Toloi (2006, p. 19), “processos estocásticos, isto é, processos controlados por leis probabilísticas”, e podem ser classificados segundo o número de parâmetros envolvidos em modelos paramétricos (número finito de parâmetros) e em modelos não-paramétricos (número infinito de parâmetros).

Para os modelos paramétricos, a análise é realizada em relação ao Tempo, sendo os mais utilizados: modelos de regressão, os modelos auto-regressivos e de médias moveis (ARMA), modelos auto-regressivos integrados e de médias móveis (ARIMA), modelos de memória longa (ARFIMA), modelos estruturais e modelos não lineares. Em relação aos modelos não-paramétricos, que têm sua análise baseada na frequência, os mais utilizados são a função de autocovariância e o espectro. (MORETTIN e TOLOI, 2006).

Dada a série temporal, existem 4 interesses: 1) investigar seu mecanismo gerador; 2) realizar previsões de valores futuros; 3) descrever seu comportamento e 4) procurar periodicidades relevantes nos dados. Para todos os casos são construídos modelos (probabilísticos ou estocásticos) para fazer previsões e controlar a série de saída. (MORETTIN e TOLOI, 2006).

Segundo Eaves (2002), os métodos tradicionais de previsão frequentemente se baseiam em pressupostos que não se aplicam a itens com demanda irregular, já que para as demandas erráticas existem muitos períodos com demanda zero, intercalados por demandas irregulares diferentes de zero.

No estudo de Syntetos e Boylan (2005), com mais de 3000 produtos do setor automotivo, como demanda intermitente, os autores conseguiram demonstrar que o método SBA é mais preciso que o de Croston e demais modelos testados. Outra comparação realizada por Syntetos e Boylan (2006) mostrou novamente um desempenho superior do modelo SBA, seguido por Média Móvel e Croston.

No estudo de Teunter e Duncan (2008), foi demonstrado superioridade de desempenho dos modelos de Croston e SBA em relação à Média Móvel e à Suavização Exponencial.

Syntetos e Boylan (2010) analisaram os mais bem sucedidos procedimentos de previsão de demanda intermitente em termos de variação de suas estimações, dentre eles os modelos de Croston e o modelo SBA. Através da métrica de acurácia MSE, concluíram pela superioridade do método de Croston.

Teunter, Syntetos e Babai (2011) propõem um novo método de previsão de demanda (TSB) e também utilizam o MSE para concluir, por meio de uma extensa experiência de simulação que indica desempenho superior e permite obter vínculo entre a previsão de demanda e obsolescência.

Com o objetivo de encontrar a demanda média por período, e considerando um cenário de transações com pouca frequência, é preferível a previsão de dois componentes separados do processo: 1 - Intervalo entre transações consecutivas; 2 - tamanho das transações individuais (EAVES, 2002).

Como este trabalho tem interesse em realizar previsões de peças com demandas intermitentes, utilizam-se dois modelos baseados em Suavização Exponencial (Ajuste Exponencial), os quais serão explorado no tópico a seguir.

2.3 MODELOS DE CROSTON E CROSTON MODIFICADO (SBA) PARA DEMANDAS INTERMITENTES

Em seu artigo seminal, Croston (1972) propôs um método de Suavização Exponencial para previsão de demanda que separa a estimação dos intervalos entre demandas da estimação dos volumes demandados em cada ocorrência.

Syntetos e Boylan (2001, 2005) demonstraram que o método de Croston é viesado, devido a um erro na derivação matemática da estimativa da demanda

esperada de seu modelo, e propuseram uma nova versão. No artigo de Syntetos e Boylan (2005), quatro métodos foram testados em 3.000 séries de dados com demandas intermitentes de uma indústria automotiva resultando em um melhor desempenho do método de Croston corrigido, em relação aos demais métodos testados.

O método Syntetos-Boylan Approximation (SBA) atualiza o tamanho da demanda e o intervalo da demanda separadamente, tal como em Croston (1972), tendo como objetivo estimar a demanda média por período, corrigindo o viés do modelo de Croston, conforme equação (7). A atualização do método ocorre apenas em momentos de demandas positivas; caso contrário, apenas é incrementada a contagem de períodos de tempo desde a última demanda.

Assim, seguem as equações (1) a (6) e (8), conforme Croston (1972):

Se $y_t = 0$,

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

$$z_t = z_{t-1} \quad (2)$$

$$q = q + 1 \quad (3)$$

Onde:

p_t = Estimativa de Croston de intervalo médio entre transações;

z_t = Estimativa de Croston do tamanho médio da demanda;

q = Intervalo de tempo desde a última demanda;

Se não,

$$p_t = p_{t-1} + \alpha(q - p_{t-1}) \quad (4)$$

$$z_t = z_{t-1} + \alpha(y_t - z_{t-1}) \quad (5)$$

$$q=1 \quad (6)$$

O método SBA, segundo Eaves e Kingman (2004), apresenta as previsões de demanda por período, como em (7):

$$\hat{y}_t = \left(1 - \frac{\alpha}{2}\right) \frac{z_t}{p_t} \quad (7)$$

Corrigindo a previsão apresentada por Croston na equação (8):

$$\hat{y}_t = \frac{z_t}{p_t} \quad (8)$$

QUADRO 2: NOTAÇÃO

Notação	Definição
y_t	Demanda de um item no tempo t ;
p_t	Estimativa de Croston de intervalo médio entre transações;
z_t	Estimativa de Croston do tamanho médio da demanda;
$\hat{y}_t$	Estimativa de Croston da demanda média por período;
q	Intervalo de tempo desde a última demanda;
α	Parâmetro de suavização entre 0 e 1;

Fonte: Croston (1972)

Nota: Adaptado pelo autor.

Segundo Teunter e Duncan (2009), valores do parâmetro de suavização α entre 0,1 e 0,3 são adequados para serem utilizados com o método de Suavização Exponencial. Em seu estudo, utilizaram parâmetro de suavização $\alpha = 0,15$; porém, existem muitas sugestões na literatura para o método de Croston. O próprio Croston (1972) recomenda $0,2 < \alpha < 0,3$ quando há uma alta proporção de itens não estacionários ou $0,1 < \alpha < 0,2$, em caso contrário. Para Syntetos e Boylan (2001), o parâmetro de suavização α não deve ser superior a 0,15.

Vários pesquisadores adotaram a mesma postura adotada por Croston em seu artigo. Porém, não há a necessidade de utilizar o mesmo valor de Suavização para o intervalo médio entre transações e o tamanho médio da demanda (EAVES, 2002).

Segundo Hua et al (2007), grande parte das peças sobressalentes possuem demanda intermitente, caracterizada por longos intervalos de ausência de demanda, o que dificulta a sua previsão de demanda. Syntetos, Boylan e Croston elaboraram um método de classificação que identifica a intermitência dos itens, assunto da seção 2.4.

Na previsão de demanda de baixa movimentação é comum a assunção da ausência de sazonalidade ou tendência, devido à falta de evidências para esses fatores em séries com muitos zeros (TEUNTER e DUNCAN, 2009).

2.4 CLASSIFICAÇÕES DE PEÇAS SOBRESSALENTES

Muitos autores já deram sua contribuição com relação à classificação de peças sobressalentes, como Williams (1984), Johnston e Boylan (1996), Eaves (2002), Syntetos et al. (2005) e Boylan et al. (2008).


Como o objetivo desta pesquisa são as demandas de padrão intermitente, vale esclarecer que o termo intermitente é utilizado para classificar demandas que apresentam muitos períodos de tempos sem demanda aleatoriamente. A demanda errática é caracterizada por apresentar o tamanho da demanda muito variável. O termo *Lumpy* é atribuído a demandas com características erráticas e intermitentes. Já o termo *slow-moving* apresenta demanda intermitente com o tamanho da

demanda igual a 1 ou um número muito reduzido de itens (GHOBBAR e FRIEND, 2002).

Syntetos, Boylan e Croston (2005) classificaram os itens em quatro quadrantes, levando em consideração dois eixos: intervalo médio entre demandas (p) e o quadrado do coeficiente de variação da demanda (CV^2). Os pontos de divisão nos eixos [$p = 1,32$] e [$CV^2 = 0,49$] foram estabelecidos teoricamente e testados com 3.000 séries de demanda de autopeças. O artigo comparou os métodos de previsão Suavização Exponencial Simples, Croston e SBA, e indicou o método de Croston para o quadrante III ($p < 1,32$ e $CV^2 < 0,49$) e o método SBA nos demais.

O esquema de categorização de Syntetos, Boylan e Croston (2005) é indicado na Figura 1, distribuído em quadrantes como: I – Errático (mas não muito intermitente); II – *Lumpy*; III – *Smooth*; e IV – Intermitente (mas não muito errático).

FIGURA 1: VALORES DE CORTE



Fonte: Syntetos, Boylan e Karakostas (2008)

Nota: Adaptado pelo autor.

Boylan, Syntetos e Karakostas (2008) utilizaram o método de classificação citado anteriormente, em um estudo empírico com base de dados de aproximadamente 16000 peças das indústrias automotiva, aeroespacial e química, e

concluíram que o desenvolvimento de esquemas de categorização de demanda não tem recebido a devida atenção acadêmica merecida. As regras de categorização de demanda ditam os métodos de previsão e controle de estoques a serem utilizados para peças sobressalentes diferentes, e, conseqüentemente têm implicações significativas em termos de estoques e satisfação do cliente.

2.5 ERROS DE PREVISÃO

Não podemos evitar que ocorram variações entre a demanda real e sua previsão. É quase certo que o erro de previsão sempre existirá, impactando o processo de planejamento de qualquer empresa. Por isso, além de identificar o erro, é importante saber também como ele varia. Neste ponto de vista, técnicas quantitativas e análises de cenário de atendimento de demanda são esforços essenciais para aprimorar a acurácia dos modelos de previsão de demanda.

Para comparar o desempenho de cada método de previsão, são utilizadas medidas de erros. Uma medida comum de controle de estoque é o *Mean Absolute Deviation* (MAD) ou Desvio Médio Absoluto, que consiste no módulo da diferença entre o previsto e o realizado. É muito utilizada na literatura universal, e, conforme Tubino (2000, p. 84), a equação (9) demonstra como é realizado o cálculo do valor MAD:

$$MAD = \frac{\sum |D_{atual} - D_{prevista}|}{n} \quad (9)$$

Onde:

D_{atual} = demanda ocorrida no período;

$D_{prevista}$ = demanda prevista no período;

n = número de períodos;

Medidas de erro quadrático médio, como o MAD, o *Mean Square Error* (MSE) ou Erro Quadrático Médio, e o *Root Mean Square Error* (RMSE) ou Raiz do Erro Quadrático Médio recebem muitas críticas por serem pouco confiáveis e sensíveis aos “*outliers*”, e devido ao fato de que nenhuma delas pode ser usada para comparação entre séries temporais distintas, por serem medidas absolutas relacionadas com uma série específica (EAVES, 2002).

Pesquisadores como Makridakis e Hibon (1979) e Lawrence et al (1985) sugerem o *Mean Absolute Percentage Error* (MAPE) ou Erro Percentual Absoluto Médio, cujo cálculo é realizado através da equação (10) – trata-se do percentual da diferença entre o previsto e o realizado, em módulo, devido a algumas características, tais como ser independente de escala e menos afetado por “*outliers*” da previsão. Porém Gardner (1990) identificou que o MAPE é indefinido quando existem zeros na série, o que constitui uma característica das séries temporais analisadas neste estudo.

$$MAPE = \frac{\sum_{t=1}^n \frac{|e_t|}{y_t} \times 100}{n} \quad (10)$$

Armstrong e Collopy (1992) indicam o *Median Absolute Performance Error* (MdAPE) ou Mediana Absoluta da Performance do Erro, como alternativa para reduzir os efeitos dos “*outliers*”, já que a medida é menos afetada por erros extremos do que medidas quadráticas por utilizar Medianas.

Segundo Eaves (2002), o MdAPE é calculado conforme equação (11) se o número de observações for ímpar. Caso seja par, o MdAPE é calculado como a equação (12):

$$MdAPE = (n+1)/2 \quad (11)$$

$$MdAPE = \left(\frac{\left(\frac{n}{2} \right) + \left(\left(\frac{n}{2} \right) + 1 \right)}{2} \right) \quad (12)$$

Na concepção de Eaves (2002), para comparar previsões de séries diferentes, deve ser utilizado o MAPE, que por ser uma unidade métrica livre, consegue relacionar o tamanho do erro para uma observação real proporcionalmente. Porém, o MAPE subestima os erros por não poder ser calculado quando a demanda é zero (HOOVER, 2006).

Uma proposta diferente para mensurar o desempenho do modelo de previsão para os itens com demanda intermitente é dada por Hyndman e Koehler (2006), o *Mean Absolute Scaled Error* (MASE) ou Erro Absoluto Médio Escalonado, que, segundo o autor, é a melhor medida de erro, pois nunca serão obtidos valores infinitos ou indefinidos.

Assumindo que:

$$e_t = Y_t - F_t \quad (13)$$

Onde:

e_t = Erro de previsão de um modelo;

Y_t = Demanda real observada no período t ;

F_t = Previsão de demanda para o período t ;

Então, temos o erro escalonado, definido por:

$$q_t = \frac{e_t}{\frac{1}{n-1} \sum_{i=2}^n |Y_i - Y_{i-1}|} \quad (14)$$

Onde o numerador representa o erro na previsão de demanda usando o modelo de interesse e o denominador representa o erro absoluto médio da previsão de demanda para um período à frente, usando o modelo ingênuo. Deste modo, Hyndman e Koehler (2006) propõem que o erro absoluto médio escalonado é definido por:

$$MASE = média(|q_t|) \quad (15)$$

O cálculo do MASE é realizado pela divisão do erro da previsão que está sendo utilizada pela média do erro Naive. Valores menores que 1 mostram que o modelo de previsão adotado gera menores erros que o modelo ingênuo. Contrariamente, valores de MASE maiores que 1 apontam que o modelo de previsão em questão gera erros maiores que o modelo ingênuo.

Neste estudo foi utilizado o MASE, como medida de identificação de erro de previsão, para indicar qual dos modelos, entre Croston ou SBA, é mais acurado. Segundo Hyndman e Koehler (2006), ele pode ser usado para comparar métodos de previsão em uma série única e também para comparar a precisão entre as séries, além de ser adequado para demandas de séries intermitentes, porque nunca resulta em valores indefinidos ou infinitos. A única circunstância em que o MASE pode ser infinito ou indefinido é quando todas as observações históricas são iguais.

3. METODOLOGIA

A empresa objeto de estudo, por ser multinacional, possui milhares de peças em estoque em armazéns ao redor do mundo. Diante disso, é necessário um critério de seleção das peças que serão analisadas. Por isso, foi utilizada a metodologia de classificação de peças sobressalentes, abordada na seção 2.4, classificação proposta por Syntetos, Boylan e Croston (2005) para classificar os itens com demanda intermitente. Dentro desta abordagem, o estudo restringe-se aos itens classificados como *Lumpy*, por apresentarem comportamento tanto errático quanto intermitente.

Para tanto, foram realizados os seguintes passos:

- Busca dos itens com demanda no período compreendido entre Janeiro de 2005 a Dezembro de 2010;
- Realização da classificação Syntetos, Boylan e Croston (2005) com os pontos de divisão nos eixos [$p = 1,32$] e [$CV^2 = 0,49$];
- Identificação dos 433 itens classificados como *Lumpy*, segundo Syntetos, Boylan e Croston (2005), com os pontos de divisão nos eixos ($p > 1,32$ e $CV^2 > 0,49$);
- Escolha dos oito itens mais representativos economicamente – juntos, representam 40% do capital em estoque;
- Realização da previsão de demanda com o Método de Croston com a demanda dos oito itens selecionados conforme Syntetos, Boylan e Croston (2005);

- Realização da previsão de demanda com o Método SBA com a demanda dos mesmos oito itens selecionados conforme Syntetos, Boylan e Croston (2005);
- Mensuração do desempenho dos Erros de previsão de cada Modelo e demais indicadores de desempenho.

Para realizar a análise dos dados, foi utilizado o método de previsão de demanda de Croston e o método de previsão de demanda Syntetos-Boylan Approximation (SBA), gerando para cada modelo uma previsão de demanda com os itens classificados como demanda *Lumpy* com auxílio de planilhas eletrônicas. Os resultados foram confrontados com os resultados obtidos por meio de indicadores selecionados para medir a disponibilidade das peças, citados na seção 3.1, a seguir.

Antes de confrontar os dados, foi preciso determinar o parâmetro de suavização α Ideal, que minimiza os erros de previsão. Para isso, foi utilizado o SOLVER, disponível no software EXCEL, que é uma ferramenta de testes de hipótese que encontra o valor ideal de uma célula de destino, alterando os valores nas células usadas para o cálculo da célula de destino. Desta forma, foram encontrados os parâmetros de suavização α , para os indicadores de erro de previsão e demais indicadores associados ao Modelo de Previsão de Croston. O mesmo foi realizado para o Modelo de Previsão SBA.

O processo foi realizado para os dados de demanda do período dentro da amostra (*In Sample*), para se encontrar o parâmetro de suavização α ideal, e testá-lo com os dados de demanda do período fora da amostra (*Out Sample*), conforme Hyndman e Koehler (2006). Nos 72 meses de dados de demanda, no período compreendido entre Janeiro de 2005 a Dezembro de 2010, as etapas foram distribuídas da seguinte forma: 12 meses iniciais para gerar os parâmetros de

inicialização para o modelo; 48 meses de dados de demanda para gerar o parâmetro de suavização α ideal (*In Sample*); e os últimos 12 meses de dados (*Out Sample*), para testar o parâmetro de suavização α ideal, em relação aos indicadores de erro de previsão e de desempenho.

Apesar de diminuir o universo da amostra de dados, a separação entre dados *In Sample* e dados *Out Sample*, se faz necessária devido ao fato do Erro Absoluto Médio Escalonado (MASE), ser baseado no Desvio Médio Absoluto (MAD), calculado no período dentro da amostra (*In Sample*), originado do método de previsão ingênuo. O MAD *In Sample* é utilizado no denominador da formula 14 (seção 2.5) no cálculo do MASE, porque é sempre disponível e efetivamente escalona o erro. O MAD *Out Sample* pode ser zero para o método ingênuo, por, geralmente, ser baseado em menos observações.

Os modelos foram escolhidos devido à literatura sobre o assunto apontá-los como os melhores modelos para demanda esporádica, apresentando os melhores resultados em grande parte dos artigos consultados, tais como: Croston (1972), Syntetos e Boylan (2005), (2006) e (2010), Hyndman (2006), Teunter e Duncan (2008).

Para aplicar os métodos de previsão de Croston e SBA, foi necessário investigar a demanda do material e verificar se a série temporal apresenta valores zero no consumo de alguns períodos. Em seguida, faz-se indispensável observar o parâmetro q - número de unidades de tempo, já que a demanda anterior ocorreu (se uma demanda ocorre no período t) - para estimar o parâmetro p_t - a previsão para o intervalo da demanda após o período t - utilizando a equação (1) ou (4) citada na seção 2.3 deste trabalho.

A demanda realizada no período t , parâmetro y_t , é utilizada na equação (2) ou (5) para estimar o parâmetro z_t - previsão para o tamanho da demanda média, após o período t .

A previsão para a demanda média por período após o período t , parâmetro $\hat{y}_t$, é dada pela equação (7), para o método SBA, e pela equação (8), para o método de Croston. A previsão para a demanda por período é, então, calculada como a razão das previsões de tamanho da demanda z_t e intervalo de demanda p_t , corrigida por $1 - (\alpha/2)$, onde α é a constante de suavização, dado que ocorreu demanda no período.

Na Tabela 2 da seção 4.1 deste trabalho é apresentado o resultado das previsões utilizando as equações apresentadas até o momento.

3.1 INDICADORES DE DESEMPENHO

O gerenciamento de estoques tem duas preocupações primordiais. Uma delas é o nível de serviço, isto é, ter os produtos certos, em quantidade suficiente, no lugar certo e no momento certo. Os custos de pedido e de manutenção do estoque constituem a outra preocupação (STEVENSON, 2001, p.426).

O objetivo global do gerenciamento de estoques é alcançar um nível de serviço satisfatório e ao mesmo tempo manter o custo de manutenção do estoque dentro de limites razoáveis. Para isso, o tomador de decisão procura alcançar, dentro da estratégia de estocagem, um estudo de equilíbrio. Ele tem que tomar duas decisões fundamentais: o momento de fazer os pedidos e o tamanho dos pedidos, isto é, quando encomendar e quanto (STEVENSON, 2001, p.426).

Para este estudo, foram escolhidos quatro indicadores que, em conjunto, nos permitem comparar a disponibilidade dos itens face a demanda real e a prevista:

- Disponibilidade;
- Percentual de meses com *stockout* (estoque igual à zero);
- Percentual de meses com *stockover* (estoque acima do nível máximo);
- Estoque médio.

Os indicadores de desempenho foram obtidos por meio da análise de cenário de atendimento de demanda adaptado de Garcia et al (2006), apresentado na Figura 2, utilizando as políticas de estoque da empresa estudada:

FIGURA 2: MODELAGEM DA LÓGICA DE ATENDIMENTO DA DEMANDA

ARRISCA Sobre... Adicionar Output Excluir Output Simular Opções Visualizar													
D9		=SE(B9>C9;C9;B9)											
	A	B	C	D	E	F	G	H	I	J	K	L	M
1	Inputs				Outputs								
2		Ponto de Máximo		52		% Disponibilidade		100,00%					
3		Lead Time (dias)		30		% Dias com Stockout		0,00%					
4		Ponto de Mínimo		44		Estoque Médio (un)		52					
5						% Dias com Stockover		51,23%					
6													
7	Dia	Estoque Inicial	Demanda	Demanda Atendida	Estoque Final	Quantidade Recebida	Quantidade em Trânsito	Quantidade Pedida	Dia de Recebimento do Pedido	Data da Movimentação	Min	Max	Stockover
8	1	52	0	0	52	0	0	0	31	01/01/2007	44	52	0
9	2	52	32	32	20	0	0	32	32	02/01/2007	44	52	0
10	3	20	0	0	20	0	32	0	33	03/01/2007	44	52	0
11	4	20	0	0	20	0	32	0	34	04/01/2007	44	52	0
12	5	20	0	0	20	0	32	0	35	05/01/2007	44	52	0
13	6	20	0	0	20	0	32	0	36	06/01/2007	44	52	0
14	7	20	0	0	20	0	32	0	37	07/01/2007	44	52	0
15	8	20	0	0	20	0	32	0	38	08/01/2007	44	52	0
16	9	20	0	0	20	0	32	0	39	09/01/2007	44	52	0
17	10	20	0	0	20	0	32	0	40	10/01/2007	44	52	0
18	11	20	0	0	20	0	32	0	41	11/01/2007	44	52	0
19	12	20	0	0	20	0	32	0	42	12/01/2007	44	52	0
20	13	20	0	0	20	0	32	0	43	13/01/2007	44	52	0
21	14	20	0	0	20	0	32	0	44	14/01/2007	44	52	0
22	15	20	0	0	20	0	32	0	45	15/01/2007	44	52	0
23	16	20	0	0	20	0	32	0	46	16/01/2007	44	52	0

Fonte: Garcia et al (2006).

Nota: Adaptado pelo autor.

A Demanda Atendida será a própria demanda, caso haja o volume necessário em estoque. Caso contrário, a demanda atendida será igual ao estoque inicial. Nesta simulação, não é admitido *backorder*, ou seja, o Estoque Final não poderá ficar negativo – indicando demanda a receber. Este é dado, então, pelo estoque inicial menos a Demanda Atendida.

Se:

$$(E.F + Q.R + Q.T) \leq MÍNIMO \quad (16)$$

Então:

$$PEDIDO = S \quad (17)$$

Se não:

$$PEDIDO = 0 \quad (18)$$

Conforme equações (16), (17) e (18), a lógica do pedido é em função do Ponto de Mínimo e do Ponto de Máximo em estoque. Se a soma do Estoque Final ($E.F$), a Quantidade Recebida ($Q.R$) e o Estoque em Trânsito ($E.T$) for menor ou igual ao Ponto de Mínimo, então pede-se um lote, que é dado através da diferença entre o Ponto de Máximo e a soma do Estoque Final com a Quantidade Recebida e o Estoque em Trânsito. Se não, não se pede nada.

Desta maneira, o modelo obtido através de análise de cenário de atendimento de demanda faz uso da política de estoque de revisão contínua $\prec s, S \succ$, também chamada de “Min./Max”. Toda vez que a posição de estoque atinge o ponto de pedido s ou um nível inferior, um pedido é colocado para elevar a posição de estoque para S unidades.

O Dia de Recebimento do Pedido é dado pela soma do dia atual com o *lead-time*. O Estoque Inicial é a soma do Estoque Final do dia anterior com a Quantidade Recebida. A Quantidade Recebida é a soma de todos os pedidos que tenham o dia de recebimento igual ao dia atual. A Quantidade em Trânsito é igual à quantidade em trânsito no dia anterior mais o pedido anterior menos o recebimento.

O próximo passo foi modelar os indicadores de desempenho da análise de cenários. Foram escolhidos quatro indicadores, a saber: Disponibilidade, Percentual de meses com *stockout*, Percentual de meses com *stockover* e estoque médio.

A Disponibilidade é a demanda atendida sobre a demanda total. O Percentual de meses com *stockout* é o percentual de meses com estoque igual à zero em relação ao número total de meses. Este indicador foi escolhido devido a sua melhor associação ao custo de falta.

O Estoque Médio é dado pela média das posições diárias de estoque final. Neste estudo, utilizou-se este indicador devido à alta complexidade de obtenção do custo de estoque que seria utilizado como indicador, no intuito de não subestimar este dado.

Por último, o Percentual de meses com *stockover*, que é igual ao percentual de meses com posição de estoque maior que o nível máximo em relação ao número total de meses. Este indicador foi escolhido devido a sua melhor associação ao custo de capital e obsolescência do estoque.

4. RESULTADOS

O Conjunto de itens analisados foi de 2706 itens de peças sobressalentes, classificadas pela empresa como itens de “consumo”, com dados de demanda de seis anos (2005 a 2010) para o armazém de peças AXO-A. Foram selecionadas 8 peças mais representativas economicamente, dentre as 433 classificadas como demanda tipo *Lumpy* (intermitente e errático). As peças armazenadas neste armazém são, em sua maioria, de origem importada, o que as torna mais interessantes para o estudo em questão, uma vez que são mais caras e levam mais tempo para chegar aos armazéns.

TABELA 1: BASE DE ITENS PARA ORDENAÇÃO POR VALOR

ITEM	VALOR UNITARIO	(%) UNITARIO	VALOR ACUMULADO	(%) ACUM.
1	R\$ 243.458,56	13,76%	R\$ 243.458,56	13,76%
2	R\$ 105.402,82	5,96%	R\$ 348.861,39	19,72%
3	R\$ 84.893,93	4,80%	R\$ 433.755,32	24,52%
4	R\$ 62.951,01	3,56%	R\$ 496.706,33	28,08%
5	R\$ 55.936,38	3,16%	R\$ 552.642,71	31,24%
6	R\$ 54.395,07	3,08%	R\$ 607.037,78	34,32%
7	R\$ 45.588,26	2,58%	R\$ 652.626,04	36,89%
8	R\$ 44.973,03	2,54%	R\$ 697.599,07	39,44%
9	R\$ 38.904,34	2,20%	R\$ 736.503,41	41,64%
10	R\$ 37.898,96	2,14%	R\$ 774.402,37	43,78%
11	R\$ 34.127,63	1,93%	R\$ 808.530,00	45,71%
12	R\$ 29.303,57	1,66%	R\$ 837.833,57	47,36%
13	R\$ 26.724,99	1,51%	R\$ 864.558,57	48,87%
14	R\$ 24.220,21	1,37%	R\$ 888.778,78	50,24%
15	R\$ 23.143,88	1,31%	R\$ 911.922,66	51,55%
16	R\$ 21.552,80	1,22%	R\$ 933.475,46	52,77%
17	R\$ 20.888,57	1,18%	R\$ 954.364,03	53,95%
18	R\$ 20.807,80	1,18%	R\$ 975.171,83	55,13%
19	R\$ 19.660,21	1,11%	R\$ 994.832,03	56,24%
20	R\$ 18.952,40	1,07%	R\$ 1.013.784,43	57,31%
21	R\$ 18.717,42	1,06%	R\$ 1.032.501,86	58,37%
22	R\$ 17.637,28	1,00%	R\$ 1.050.139,13	59,37%
23	R\$ 16.569,16	0,94%	R\$ 1.066.708,29	60,30%
432	R\$ 0,48	0,00%	R\$ 1.768.935,27	100,00%

433	R\$ 0,44	0,00%	R\$ 1.768.935,71	100,00%
------------	----------	-------	------------------	---------

Fonte: Criado pelo autor

Realizada a classificação proposta por Syntetos, Boylan e Croston (2005), para encontrar os itens com demanda esporádica (forte), citado na seção 2.4, foram encontradas 433 peças dentro dos parâmetros de demanda *Lumpy*. Chegou-se, assim, às oito peças sobressalentes de locomotiva, mais representativas economicamente, conforme Tabela 1. Juntas, as oito peças representam quase 40% do valor do capital investido em estoque. A partir do número 23, os itens foram suprimidos por representarem menos de 1% do valor total de estoque individualmente, conforme Tabela 1.

4.1 MODELOS DE PREVISÃO

Seguindo o objetivo de estimar a demanda média por período, o método desenvolvido por Croston, assim como o método corrigido por Boylan, aplica suavização exponencial separadamente para o intervalo entre as demandas e o tamanho das demandas. EAVES (2002).

Segundo Eaves (2002), a atualização do modelo só ocorre em momentos de demanda positiva. No caso de não haver demanda, o método incrementa a contagem de períodos de tempo desde a última demanda.

Na Tabela 2, para o modelo de Croston, segue uma representação usando os dados de demanda do item 8, para apresentar as estimativas de Croston (z_t , p_t e $\hat{y}_t$):

TABELA 2: CÁLCULO DO MÉTODO DE CROSTON

Mês	Demanda Atual	Intervalo desde a última demanda	Tamanho Médio da Demanda	Intervalo Médio entre Transações	Demanda Média Por Período
	y_t	q	z_t	p_t	$\hat{y}_t$
1	0				
2	8	2			
3	35	1			
4	33	1			
5	5	1			
6	5	1			
7	0				
8	0				
9	17	3			
10	2	1			
11	0				
12	0		11,503	0,998	12,190
13	20	3	14,052	1,598	8,791
14	7	1	11,937	1,419	8,413
15	0		11,937	1,419	8,413
16	0		11,937	1,419	8,413
17	13	3	12,256	1,893	6,473
18	4	1	9,779	1,625	6,017
19	12	1	10,445	1,438	7,265
20	0		10,445	1,438	7,265
21	0		10,445	1,438	7,265
22	2	3	7,912	1,906	4,150
23	0		7,912	1,906	4,150
24	4	2	6,738	1,934	3,483
25	0		6,738	1,934	3,483
26	0		6,738	1,934	3,483
27	0		6,738	1,934	3,483
28	0		6,738	1,934	3,483
29	0		6,738	1,934	3,483
30	0		6,738	1,934	3,483
31	0		6,738	1,934	3,483
32	0		6,738	1,934	3,483
33	0		6,738	1,934	3,483
34	0		6,738	1,934	3,483
35	0		6,738	1,934	3,483
36	0		6,738	1,934	3,483
37	0		6,738	1,934	3,483
38	2	14	5,317	5,554	0,957
39	21	1	10,022	4,188	2,393
40	1	1	7,315	3,232	2,264
41	0		7,315	3,232	2,264
42	0		7,315	3,232	2,264
43	0		7,315	3,232	2,264
44	22	4	11,721	3,462	3,385
45	3	1	9,104	2,723	3,343
46	3	1	7,273	2,206	3,296
47	0		7,273	2,206	3,296
48	0		7,273	2,206	3,296
49	0		7,273	2,206	3,296
50	0		7,273	2,206	3,296
51	0		7,273	2,206	3,296
52	2	6	5,691	3,344	1,702
53	0		5,691	3,344	1,702
54	0		5,691	3,344	1,702

55	6	3	5,784	3,241	1,785
56	0		5,784	3,241	1,785
57	0		5,784	3,241	1,785
58	1	3	4,349	3,169	1,372
59	2	1	3,644	2,518	1,447
60	0		3,644	2,518	1,447
61	10	2	5,551	2,363	2,349
62	0		5,551	2,363	2,349
63	0		5,551	2,363	2,349
64	2	3	4,486	2,554	1,756
65	3	1	4,040	2,088	1,935
66	2	1	3,428	1,761	1,946
67	0		3,428	1,761	1,946
68	0		3,428	1,761	1,946
69	0		3,428	1,761	1,946
70	0		3,428	1,761	1,946
71	0		3,428	1,761	1,946
72	0		3,428	1,761	1,946

Fonte: Eaves (2002).

Nota: Adaptado pelo autor.

Ainda segundo Eaves (2002), para iniciar os parâmetros de previsão, são necessários 12 meses. O tamanho da demanda média inicial é calculado a partir das demandas reais do primeiro ano, ocorrendo o mesmo para o intervalo de transações. A partir do 13º mês, o tamanho médio da demanda e o intervalo médio são atualizados através de um parâmetro de suavização α . A atualização só ocorre em períodos de demanda positiva; caso contrário, os valores anteriores são rolados para frente. A demanda média por período é calculada pelo tamanho da demanda média dividida pelo intervalo médio.

Para o modelo SBA, é utilizada a mesma tabela acima. Porém, para o cálculo da demanda média por período ($\hat{y}_t$), é utilizada a equação (7), apresentada na seção 2.3.

4.2 IMPLANTAÇÃO DO MODELO

Para comparar os 2 métodos de previsão, é apresentado nesta seção o desenvolvimento do modelo de previsão. Primeiramente, avaliou-se o desempenho

individual dos métodos e, posteriormente, foram comparados outros indicadores, como Disponibilidade de peças, Estoque Médio, *Stockout* e *Stockover*. Outra consideração no que se refere à previsão é acerca de quando devem ser feitas as comparações. Segundo Eaves (2002), existem dois métodos de implantação a serem considerados:

1. Medir os erros observados em cada ponto no tempo;
2. Apenas medir os erros imediatamente após a ocorrência de uma demanda;

A primeira implantação é adequada para sistemas de reposição de estoque com revisão periódica, com reabastecimento que pode ocorrer em qualquer fase do ciclo de estoques. Por sua vez, a segunda implantação é recomendada a uma abordagem de revisão contínua, quando um novo pedido só pode ser colocado após a ocorrência de demanda. Neste caso, a precisão das previsões é considerada apenas nos períodos em que uma ordem de compra pode ser colocada, e exclui os períodos em que não será colocada uma ordem de compra. As duas implantações podem utilizar o método de Croston, pois só há atualização do método depois da ocorrência de uma demanda. EAVES (2002)

Como a empresa estudada utiliza o método de revisão contínua, e como o valor do MASE se relaciona com o MAD do modelo Ingênuo, calculado a cada ponto no tempo, foi atribuída ênfase aos resultados de desempenho do método 2. Usando o mesmo item da amostra da seção anterior para demonstrar o método de Croston, a Tabela 3 ilustra a maneira na qual os erros são medidos. Por último, um método de seleção de valores de parâmetros de suavização é apresentado.

TABELA 3: MEDIDAS DE ERRO

<i>Mês</i>	<i>Demanda Atual</i>	<i>Previsão de Croston</i>	<i>Erro Croston</i>	<i>Previsão Método Ingênuo</i>	<i>Erro Método Ingênuo</i>	<i>Erro Percentual Absoluto (APE)</i>	<i>Erro Absoluto Médio Escalonado (MASE)</i>
	y_t	$\hat{y}_t$	e_t	F_t	$ Y_t - F_t $	(6)	q_t
1	0						
2	8			0			
3	0			8			
4	0			0			
5	0			0			
6	0			0			
7	0			0			
8	0			0			
9	30			0			
10	0			30			
11	40			0			
12	100	4,386	95,614	40			
13	60	16,541	43,459	100	40	72,432	0,83
14	50	22,898	27,102	60	10	54,204	0,52
15	72	31,457	40,543	50	22	56,310	0,77
16	112	44,526	67,474	72	40	60,245	1,28
17	72	48,722	23,278	112	40	32,330	0,44
18	0	48,722	-48,722	72	72	-	0,93
19	0	48,722	-48,722	0	0	-	0,93
20	96	43,080	52,920	0	96	55,124	1,01
21	48	43,627	4,373	96	48	9,111	0,08
22	130	53,116	76,884	48	82	59,142	1,46
23	76	55,605	20,395	130	54	26,835	0,39
24	32	53,060	-21,060	76	44	65,811	0,40
25	102	58,296	43,704	32	70	42,847	0,83
26	0	58,296	-58,296	102	102	-	1,11
27	0	58,296	-58,296	0	0	-	1,11
28	0	58,296	-58,296	0	0	-	1,11
29	0	58,296	-58,296	0	0	-	1,11
30	0	58,296	-58,296	0	0	-	1,11
31	78	39,438	38,562	0	78	49,439	0,73
32	152	47,495	104,505	78	74	68,753	1,99
33	50	47,679	2,321	152	102	4,641	0,04
34	170	56,935	113,065	50	120	66,509	2,15
35	0	56,935	-56,935	170	170	-	1,08
36	50	52,338	-2,338	0	50	4,676	0,04
37	0	52,338	-52,338	50	50	-	1,00
38	0	52,338	-52,338	0	0	-	1,00
39	0	52,338	-52,338	0	0	-	1,00
40	0	52,338	-52,338	0	0	-	1,00

41	0	52,338	-52,338	0	0	-	1,00
42	0	52,338	-52,338	0	0	-	1,00
43	68	37,041	30,959	0	68	45,528	0,59
44	50	37,740	12,260	68	18	24,521	0,23
45	132	43,065	88,935	50	82	67,375	1,69
46	0	43,065	-43,065	132	132	-	0,82
47	0	43,065	-43,065	0	0	-	0,82
48	0	43,065	-43,065	0	0	-	0,82
49	0	43,065	-43,065	0	0	-	0,82
50	0	43,065	-43,065	0	0	-	0,82
51	0	43,065	-43,065	0	0	-	0,82
52	0	43,065	-43,065	0	0	-	0,82
53	0	43,065	-43,065	0	0	-	0,82
54	0	43,065	-43,065	0	0	-	0,82
55	320	38,798	281,202	0	320	87,876	5,35
56	0	38,798	-38,798	320	320	-	0,74
57	0	38,798	-38,798	0	0	-	0,74
58	0	38,798	-38,798	0	0	-	0,74
59	174	39,486	134,514	0	174	77,307	2,56
60	220	46,536	173,464	174	46	78,847	3,30
61	0	46,536	-46,536	220	220	-	0,885
62	0	46,536	-46,536	0	0	-	0,885
63	0	46,536	-46,536	0	0	-	0,885
64	0	46,536	-46,536	0	0	-	0,885
65	0	46,536	-46,536	0	0	-	0,885
66	0	46,536	-46,536	0	0	-	0,885
67	400	49,008	350,992	0	400	87,748	6,675
68	0	49,008	-49,008	400	400	-	0,932
69	0	49,008	-49,008	0	0	-	0,932
70	0	49,008	-49,008	0	0	-	0,932
71	0	49,008	-49,008	0	0	-	0,932
72	347	52,190	294,810	0	347	84,960	5,607
						MAPE	50,448
						MdAPE	55,717
						MASE	1,057

Fonte: Eaves (2002).

Nota: Adaptado pelo autor.

Comparações entre o valor real e o valor previsto não são realizadas nos primeiros 12 meses, pois este período é usado para inicialização do modelo. Os últimos 12 meses são utilizados para testar o alfa ideal, calculado com os dados de demanda do item entre os meses 13 e 60. A demanda real de cada mês, para o item

7, é apresentada na coluna (y_t). Na coluna ($\hat{y}_t$) é fornecida a estimativa de Croston da demanda média por período, constante na Tabela 3. Na coluna (F_t) é apresentada a previsão Naive (Ingênuo), tomada como base para cálculo do erro MASE atingida através das equações (14) e (15) apresentadas na seção 2.5.

Usando a metodologia aplicada por Eaves (2002), as comparações são realizadas dos meses 13 aos 60. Porém, ao invés de utilizar o MAPE ou MAdPE, conforme seu modelo original, é utilizado o MASE, que relaciona o erro na previsão de demanda usando o modelo de interesse (Croston e SBA) com o erro absoluto médio da previsão de demanda para um período à frente, conforme Hyndman e Koehler (2006) sugerem, uma vez que o Erro Percentual Absoluto só pode ser calculado quando a demanda real não é nula. Devido a isso, alguns períodos não têm valor definido.

Para atender o objetivo deste estudo, que é verificar se o método *Syntetos-Boylan Approximation* (SBA) é o modelo mais indicado para previsão de demanda intermitente de peças sobressalentes, a partir de dados históricos, comparando os resultados obtidos entre o modelo de Croston e o modelo SBA – apontados pela literatura como os modelos de melhor desempenho –, todas as etapas determinadas pela metodologia foram aplicadas aos 8 itens mais representativos da amostra. No Apêndice A, é apresentado o comportamento da demanda do principal item da amostra por valor individual de estoque, o item 1.

Os valores para as implantações das previsões diferem para MAPE, MdAPE e MASE, leva ao questionamento de qual medida de desempenho deve ser usada e, até mesmo, qual implantação de previsão deve ser usada. Por isso, uma abordagem

alternativa para a medida de desempenho foi utilizar análise de cenário de atendimento de demanda para gerar indicadores de desempenho operacionais.

Antes, porém, foi necessário determinar os valores dos parâmetros de suavização que fornecem os melhores resultados para os métodos de suavização. Os resultados foram obtidos através do SOLVER, disponível no software EXCEL, citado no capítulo 3. Dessa forma, foram encontrados os parâmetros de suavização α para os indicadores de erro e de desempenho associados ao Modelo de Previsão de Croston e para o Modelo de Previsão de SBA.

Embora tenha-se utilizado apenas o MASE para determinar o melhor modelo, no que diz respeito a acurácia, os valores observados para MAPE, MdAPE e MASE diferem substancialmente. A comparação apenas por essas medidas de erro de precisão tradicionais, MAPE e MdAPE, e até mesmo a medida de erro alternativa, MASE, deixa margem para diferentes pesquisadores concluírem resultados divergentes, dependendo da metodologia pela qual optarem.

Assim sendo, o propósito das comparações é o fator crucial para determinar a implantação do modelo mais adequado. Se o propósito é uma questão apenas de precisão das previsões, comparações do tradicional um período a frente, utilizado no método de previsão Ingênuo, podem ser satisfatórias, como relata Eaves (2002). Porém, quando o propósito é tomar decisões de reabastecimento, outras variáveis podem se tornar decisivas para atender ao cliente da melhor forma. Além disso, outros indicadores de desempenho, além do erro de previsão, podem ser determinantes.

TABELA 4: RESULTADO DE INDICADORES PARA α IDEAL (IN SAMPLE) – MASE MINIMIZADO

Item	Modelo	α	MASE	Stockover	Stockout	Disponibilidade	Estoque Médio	Custo Unitário (R\$)	Custo Total (R\$)
1	Croston	0,190	1,195	0,00%	85,42%	26,90%	0,06	243.458,56	13.598,33
	SBA	0,386	1,104	4,17%	70,83%	28,37%	0,15		37.207,87
2	Croston	1,000	0,841	16,67%	66,67%	26,56%	6,54	105.402,82	689.266,15
	SBA	1,000	0,814	14,58%	37,50%	51,57%	7,18		756.875,23
3	Croston	0,303	0,909	0,00%	58,33%	33,40%	0,27	84.893,93	22.969,04
	SBA	0,409	0,902	0,00%	47,92%	34,01%	0,32		27.322,76
4	Croston	1,000	1,024	4,17%	91,67%	4,24%	0,10	62.951,01	6.295,10
	SBA	1,000	1,002	0,00%	85,42%	8,00%	0,06		3.540,99
5	Croston	0,929	1,174	6,25%	72,92%	13,46%	0,21	55.936,38	11.963,99
	SBA	0,956	0,968	4,17%	41,67%	25,05%	0,26		14.513,40
6	Croston	0,320	1,078	0,00%	100,00%	36,33%	0,00	54.395,07	0,00
	SBA	0,568	0,970	0,00%	70,83%	40,37%	0,07		3.576,87
7	Croston	0,100	1,057	0,00%	100,00%	2,12%	0,00	45.588,26	0,00
	SBA	0,586	1,039	0,00%	100,00%	2,33%	0,00		0,00
8	Croston	1,000	0,697	6,25%	16,67%	73,74%	5,49	44.973,03	246.749,36
	SBA	1,000	0,661	0,00%	8,33%	94,03%	7,24		325.675,25

Nota: Adaptado pelo autor.

Conforme observado na Tabela 4, para os dados dentro da amostra, ou seja, para os dados referentes a demanda dos itens dentro do período compreendido entre o meses 13 a 60, são apresentados os valores do parâmetro de suavização α que minimizam o valor do Erro MASE, utilizado para indicar o modelo com maior acurácia. O modelo SBA foi indicado através do MASE como melhor opção de modelo de previsão para itens com demanda intermitente para todos os oito elementos da amostra.

Utilizando o parâmetro de suavização α ideal, relacionado na Tabela 4, o mesmo procedimento foi adotado para os dados de fora da amostra, ou seja, aqueles compreendidos entre os meses 61 e 72, referentes aos dados de demanda dos oito itens da amostra citado no capítulo 3, e apresentados na Tabela 5. O resultado encontrado confirma a superioridade do modelo SBA, como modelo de menor erro de previsão, em relação ao modelo de Croston, conforme já

demonstrado por Syntetos e Boylan (2001, 2005 e 2006), Eaves e Kingsman (2004), Willemain, Smart e Schwarz (2004), Hua et al. (2007), Teunter e Duncan (2009), entre outros. Apenas para os itens 3 e 7, foram constatados desempenho superior para o Modelo de Croston. Todavia, a esta diferença de desempenho pode estar relacionado o número menor de observações levadas em consideração para médias, como alerta Hyndman e Koehler (2006).

TABELA 5: INDICADORES UTILIZANDO α IDEAL (OUT SAMPLE)

Item	Modelo	α	MASE	Stockover	Stockout	Disponibilidade	Estoque Médio	Custo Unitário (R\$)	Custo Total (R\$)
1	Croston	0,190	3,583	0,00%	100,00%	25,44%	0,00	243.458,56	0,00
	SBA	0,386	3,387	0,00%	83,33%	28,68%	0,02		3.948,09
2	Croston	1,000	0,762	0,00%	0,00%	100,00%	11,13	105.402,82	1.173.582,36
	SBA	1,000	0,692	0,00%	0,00%	100,00%	13,57		1.430.013,77
3	Croston	0,303	1,362	0,00%	100,00%	8,86%	0,00	84.893,93	0,00
	SBA	0,409	1,385	0,00%	100,00%	9,38%	0,00		0,00
4	Croston	1,000	7,524	0,00%	91,67%	2,57%	0,03	62.951,01	1.748,64
	SBA	1,000	4,833	0,00%	91,67%	5,14%	0,06		3.497,28
5	Croston	0,929	0,670	0,00%	50,00%	33,61%	0,37	55.936,38	20.416,85
	SBA	0,956	0,590	0,00%	33,33%	53,32%	0,47		26.440,36
6	Croston	0,320	0,993	0,00%	100,00%	42,67%	0,00	54.395,07	0,00
	SBA	0,568	0,875	0,00%	66,67%	56,57%	0,10		5.546,90
7	Croston	0,100	0,820	0,00%	100,00%	1,91%	0,00	45.588,26	0,00
	SBA	0,586	0,852	0,00%	100,00%	1,84%	0,00		0,00
8	Croston	1,000	1,090	0,00%	8,33%	90,82%	5,89	44.973,03	264.841,19
	SBA	1,000	0,872	0,00%	0,00%	100,00%	7,18		322.931,36

Nota: Adaptado pelo autor.

Para verificar se o melhor modelo segundo a acurácia dos erros de previsão também é o melhor modelo segundo indicadores de desempenho, foi empregada a mesma metodologia utilizando o SOLVER. No entanto, ao invés de minimizar o MASE para encontrar o parâmetro de suavização α ideal, foi maximizado o indicador operacional Disponibilidade, e os resultados são apresentados na Tabela 6.

TABELA 6: RESULTADO DE INDICADORES PARA α IDEAL (IN SAMPLE) – DISPONIBILIDADE MAXIMIZADO.

Item	Modelo	α	Stockover	Stockout	Disponibilidade	Estoque Médio	Custo Unitário (R\$)	Custo Total (R\$)
1	Croston	0,100	0,00%	89,58%	26,58%	0,03	243.458,56	8.005,57
	SBA	0,266	2,08%	75,00%	28,82%	0,11		26.719,95
2	Croston	0,100	2,08%	58,33%	41,12%	2,93	105.402,82	308.983,39
	SBA	0,100	0,00%	56,25%	42,17%	2,85		300.478,47
3	Croston	0,100	0,00%	58,33%	48,24%	0,27	84.893,93	23.120,30
	SBA	0,100	0,00%	58,33%	49,90%	0,29		24.389,83
4	Croston	0,100	0,00%	100,00%	6,86%	0,00	62.951,01	0,00
	SBA	0,100	0,00%	100,00%	7,22%	0,00		0,00
5	Croston	0,100	0,00%	87,50%	18,21%	0,03	55.936,38	1.791,83
	SBA	1,000	0,00%	52,08%	24,50%	0,27		14.890,01
6	Croston	0,316	0,00%	100,00%	36,33%	0,00	54.395,07	0,00
	SBA	0,428	0,00%	89,58%	44,10%	0,02		1.223,64
7	Croston	0,100	0,00%	100,00%	2,12%	0,00	45.588,26	0,00
	SBA	1,000	0,00%	100,00%	2,39%	0,00		0,00
8	Croston	0,438	4,17%	10,42%	85,95%	4,96	44.973,03	223.066,01
	SBA	0,849	6,25%	4,17%	96,25%	7,22		324.878,05

Nota: Adaptado pelo autor.

Na Tabela 6 estão apresentados os valores do parâmetro de suavização α que maximizam o valor do indicador operacional Disponibilidade, utilizado para indicar o modelo com melhor desempenho operacional para os itens de dentro da amostra (meses 13 ate 60). O modelo SBA foi indicado, por meio da Disponibilidade, como a melhor opção de modelo de previsão para itens com demanda intermitente para todos os oito itens da amostra.

Utilizando o parâmetro de suavização α ideal, encontrado na Tabela 6, foram calculados e apresentados na Tabela 7, os valores dos indicadores operacionais para os itens de fora da amostra (meses 61 a 72).

TABELA 7: INDICADORES PARA α IDEAL (OUT SAMPLE)

Item	Modelo	α	Stockover	Stockout	Disponibilidade	Estoque Médio	Custo Unitário (R\$)	Custo Total (R\$)
1	Croston	0,100	0,00%	100,00%	25,50%	0,00	243.458,56	0,00
	SBA	0,266	0,00%	83,33%	28,09%	0,01		3.329,23
2	Croston	0,100	0,00%	58,33%	51,27%	3,24	105.402,82	341.618,81
	SBA	0,100	0,00%	50,00%	53,97%	3,46		364.870,30
3	Croston	0,100	0,00%	100,00%	16,81%	0,00	84.893,93	0,00
	SBA	0,100	0,00%	100,00%	17,69%	0,00		0,00
4	Croston	0,100	0,00%	100,00%	7,20%	0,00	62.951,01	0,00
	SBA	0,100	0,00%	100,00%	7,58%	0,00		0,00
5	Croston	0,100	0,00%	83,33%	36,78%	0,07	55.936,38	3.912,73
	SBA	0,100	0,00%	33,33%	53,00%	0,48		26.956,52
6	Croston	0,316	0,00%	100,00%	42,59%	0,00	54.395,07	0,00
	SBA	0,428	0,00%	66,67%	48,81%	0,03		1.410,58
7	Croston	0,100	0,00%	100,00%	1,91%	0,00	45.588,26	0,00
	SBA	1,000	0,00%	100,00%	1,31%	0,00		0,00
8	Croston	0,438	0,00%	0,00%	100,00%	6,21	44.973,03	279.268,23
	SBA	0,849	16,67%	0,00%	100,00%	8,39		377.433,41

Nota: Adaptado pelo autor.

Pelo ponto de vista dos indicadores *Stockover*, *Stockout*, Disponibilidade e Estoque médio, juntamente com o custo da peça (que representa capital de giro empatado em estoque), nem todos os índices confirmam a superioridade do modelo SBA. Desta vez, o modelo de Croston foi indicado para o item 7, com Disponibilidade de 1,91% contra 1,31% de resultado para o mesmo indicador do modelo SBA. O item 8 apresentou máximo desempenho – 100% de Disponibilidade – para ambos os modelos, fato que nos leva de volta ao fator crucial das comparações, citado anteriormente. Caso o motivo seja apenas disponibilidade de peça, para o item 8, qualquer um dos dois modelos atingirá o objetivo. Contudo, caso o intuito seja baseado na melhor disponibilidade com o menor valor empatado em estoque, opta-se pelo modelo de Croton, com custo de estoque R\$ 279.268,23, contra R\$ 377.433,41 para o modelo SBA, conforme Tabela 7. Análise similar pode ser feita com foco nos indicadores *Stockover* e *Stockout*. Os demais itens

apresentaram melhor desempenho no que se refere a Disponibilidade para o modelo SBA.

Outro fato para se levar em consideração é o parâmetro de suavização α utilizado como ideal. Apenas para o item 7 (modelo de Croston), apresentado na Tabela 7, o valor de α foi o mesmo para os melhores resultados de acurácia e desempenho, para os mesmos itens presentes na Tabela 5; sendo, pois, superior ao valor do parâmetro de suavização $\alpha = 0,3$ contraria autores como Teunter e Duncan (2009), o próprio Croston (1972) e Syntetos e Boylan (2001).

O Quadro 3 resume a escolha dos modelos por indicadores de erro ou indicadores de desempenho. Com relação aos elementos analisados, quando avaliados em relação aos erros de previsão, seis itens (1, 2, 4, 5, 6 e 8) registraram melhor resultado no modelo SBA, e dois itens (3 e 7) foram melhores no modelo de Croston. Quando avaliados em relação aos indicadores de desempenho, com foco em maximizar o indicador Disponibilidade, o item 7 teve melhor desempenho registrado no modelo de Croston. Para o item 8, o desempenho independe do modelo de previsão. Para os demais itens, o modelo SBA foi superior no quesito Disponibilidade.

QUADRO 3: MODELOS DE PREVISÃO POR INDICADOR

<i>Item</i>	<i>Indicador de Desempenho</i>	<i>Indicador de Erro</i>
1	SBA	SBA
2	SBA	SBA
3	SBA	Croston
4	SBA	SBA
5	SBA	SBA
6	SBA	SBA
7	Croston	Croston
8	Croston/SBA	SBA

Nota: Adaptado pelo autor.

Neste estudo de comparação entre os modelos de previsão de Croston e SBA, não foram levadas em consideração alterações de *Lead-time* e de parâmetros da política de estoque Min./Max, que permaneceram inalterados nos períodos considerados para os cálculos das previsões de demanda e seus resultados operacionais através de simulação de atendimento de demanda.

Para a análise de cenários de atendimento de demanda, o cálculo de estoques de segurança, e consequentemente os parâmetros Min./Max, foram replicados dos modelos já existentes e utilizados pela empresa. Caso o modelo de análise de cenários de atendimento de demanda, tivesse a função agregada de recalcular os parâmetros Min./Max, reajustando-os de acordo com a posição de estoques e a demanda dos itens, os resultados obtidos, como parâmetros de suavização ideais segundo os indicadores de desempenho, poderiam ser diferentes.

5. CONCLUSÕES

Como foi apresentado na introdução e realizado conforme capítulos 3 e 4, o objetivo deste estudo foi verificar e avaliar se o método Syntetos-Boylan Approximation (SBA) é o modelo mais indicado como modelo de previsão de demanda intermitente de peças sobressalentes, a partir de dados históricos, comparando os resultados obtidos entre o modelo de Croston e o modelo SBA, apontados pela literatura, descrita no capítulo 2, como os modelos de melhor desempenho.

Segundo a literatura, o melhor método de encontrar a demanda média por período, considerando um cenário de transações com pouca frequência, é a previsão de dois componentes do processo: 1 - Intervalo entre transações consecutivas; 2 - tamanho das transações individuais, separadamente. Por isso, foram escolhidos os modelos SBA e de Croston para o teste.

A metodologia de classificação de demanda juntamente com a metodologia de previsão de demanda SBA avaliada por indicadores de desempenho, adotados neste trabalho, atende parcialmente o objetivo inicial, com resultados bem sucedidos para classificação da demanda de itens como *Lumpy*, passo inicial para modelagem dos dados, e também para a análise de cenários.

A razão pela qual a metodologia não atendeu plenamente aos resultados esperados é a subjetividade da decisão de melhor cenário, uma vez identificado o fator motivacional que deve ser considerado para esses fins, acurácia ou desempenho. Ao escolher maximizar o desempenho do indicador Disponibilidade, a maior parte dos itens analisados apresentou superioridade do modelo SBA para os dados *Out Sample*, superioridade essa foi observada para os dados *In Sample*. Da

mesma forma, quando minimizado o erro de previsão MASE, foi verificada para a maior parte dos itens analisados, como ocorreu nos dados *In Sample*, a superioridade do modelo SBA para os dados *Out Sample*. Esse fato pode ser explicado pelo menor número de observações no período *Out Sample*, em relação ao período *In Sample*.

Outro fato para se levar em consideração é o parâmetro de suavização α utilizado como ideal. Quando observados os valores dos indicadores de desempenho e acurácia para α , percebe-se que, o mesmo é superior ao valor do parâmetro de suavização $\alpha = 0,3$, contrariando, desta forma, autores como Teunter e Duncan (2009), o próprio Croston (1972) e Syntetos e Boylan (2001).

Para todos os oito itens analisados, quando avaliados em relação aos erros de previsão, o modelo SBA obteve melhor resultado para seis itens, e o modelo de Croston obteve melhor resultado para dois itens. Quando avaliados em relação aos indicadores de desempenho, com foco em maximizar o indicador Disponibilidade, o modelo de Croston teve melhor desempenho para um item, e para o item 8, o desempenho independe do modelo de previsão. Para os demais itens, o modelo SBA foi superior no quesito Disponibilidade. Esse resultado indica que, segundo a amostra estudada e as ferramentas envolvidas nos testes, apesar do modelo SBA ter apresentado o menor erro de previsão MASE, ele não representa, necessariamente, o modelo de previsão de demanda mais indicado para todos os itens com demanda intermitente, segundo os resultados de desempenho, e até mesmo de acurácia.

Frente aos resultados obtidos nesta pesquisa, vale destacar sua relevância para o meio acadêmico, por agregar ao modelo de previsão de demanda, um modelo de análise de cenário de atendimento de demanda, com a utilização de

planilhas eletrônicas, de forma simples e objetiva, para peças com padrão de demanda *Lumpy*.

Os resultados encontrados neste estudo podem ser refinados – por parte do modelo de análise de cenário de atendimento de demanda, incluindo cálculos de parametrização da política Min./Max – para novas pesquisas nesta área, a fim de se estabelecer o parâmetro de suavização ideal para obter o melhor desempenho.

REFERÊNCIAS

ARMSTRONG, J.; COLLOPY, F. Error measures for generalizing about forecasting methods: empirical comparisons. **International Journal of Forecasting**, 8, 69-80, 1992.

BOYLAN, J. E.; SYNTETOS, A. A.; KARAKOSTAS, G. C. Classification for forecasting and stock control: a case study. **Journal of the Operational Research Society**, v. 59, p. 473-481, 2008.

CROSTON, J. D. Forecasting and stock control for intermittent demands. **Operational Research Quarterly**, v.23, p. 289-303, 1972.

EAVES, A. H. C. **Forecasting for the ordering and stock-holding of consumable spare parts**. Tese. Department of Management Science The Management School, Lancaster University, Lancaster, Inglaterra, 2002.

EAVES, A. H. C.; KINGSMAN, B. G. Forecasting for the ordering and stock-holding of spare parts. **Journal of the Operational Research Society**, v. 50, p. 431-437, 2004.

GARCIA, E. S. et al.; **Gestão de estoques: otimizando a logística e a cadeia de suprimentos**. Rio de Janeiro: E-Papers Serviços Editoriais, 2006, p. 144.

GARDNER, E. Evaluating forecast performance in an inventory control System. **Management Science**, 36, 490-499, 1990.

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

HYNDMAN, R. J., KOEHLER, A. B. **Another look at forecast-accuracy metrics for intermittent demand**. Foresight: Int J Appl Forecast 4: 43–46, 2006.

HOOVER, J. **Measuring Forecast Accuracy: Omissions in Today's Forecasting Engines and Demand-Planning Software**. Foresight: Int J Appl Forecast 4: 32–35, 2006

HUA, Z. S. et al. A new approach of forecasting intermittent demand for spare parts inventories in the process industries. **Journal of the Operational Research Society**, v. 58, p. 52-61, 2007.

LAWRENCE, M.; R. EDMUNDSON; M. O'CONNOR. An Examination of the accuracy of judgemental extrapolation of time series. **International Journal of Forecasting**, 1, 25-35, 1985.

MAKRIDAKIS, S.; M. HIBON. Accuracy of forecasting: an empirical investigation, **Journal of the Royal Statistical Society**, 142, 97-125, 1979.

MONKS, Joseph G. **Administração da produção**. São Paulo: McGraw-Hill, 1987.

MORETTIN, Pedro A. e TOLOI, Clélia M. C. **Análise de séries temporais**. São Paulo: Edgard Blucher, 2006.

SYNTETOS, A. A., BOYLAN, J. E. The Accuracy of intermittent demand estimates. **International Journal of Forecasting**, v. 21, p. 303-314, 2005.

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

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

SYNTETOS, A. A.; BOYLAN, J. E.; DISNEY, S. M. Forecasting for inventory planning: a 50-year review. **Journal of the Operational Research Society**, v. 60, p. S149-S160, 2009.

SYNTETOS, A. A.; BOYLAN, J. E. On the variance of intermittent demand estimates. **Journal of the Operational Research Society**, v. 128, p546-555, (2010).

SNYDER et al. Forecasting the intermittent demand for slow-moving inventories - a modeling approach. **International Journal of Forecasting**, 2011.

STEVENSON, W. J; **Administração das operações de produção**. Rio de Janeiro: LTC, 2001, p. 701.


TEUNTER, R. H.; DUNCAN, L. Forecasting intermittent demand: a comparative study. **Journal of the Operational Research Society**, v. 60-3, p. 321-329, 2009.

Teunter, R. H.; Syntetos, A. A; Babai, M. Z. Intermittent demand - Linking forecasting to inventory obsolescence. **European Journal of Operational Research**, v. 214, p. 606–615, 2011.

TUBINO, DALVIO FERRARI. **Manual de planejamento e controle da produção**. 2. ed. -São Paulo: Atlas, 2000.


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

APÊNDICE A – PREVISÃO DE CROSTON & SBA – ITEM 1




APÊNDICE B – PREVISÃO DE CROSTON & SBA – ITEM 2

APÊNDICE C – PREVISÃO DE CROSTON & SBA – ITEM 3




APÊNDICE D – PREVISÃO DE CROSTON & SBA – ITEM 4






APÊNDICE F – PREVISÃO DE CROSTON & SBA – ITEM 6



APÊNDICE G – PREVISÃO DE CROSTON & SBA – ITEM 7



APÊNDICE H – PREVISÃO DE CROSTON & SBA – ITEM 8

