

Análise do processo de predição de demanda de peças de reposição com demanda intermitente**Analysis of the spare parts demand prediction process with intermittent demand**

DOI:10.34117/bjdv6n9-212

Recebimento dos originais: 08/08/2020

Aceitação para publicação: 09/09/2020

Sérgio Neri de Almeida

Mestrado em Engenharia e Gestão de Processos e Sistemas pelo IETEC, MG

Instituição: Vale S.A.

Endereço: Rua João de Paula 350/ap402 - Sagrada Família, 31035-340, Belo Horizonte, MG, Brasil

E-mail: sergio.neri@gmail.com

José Helvécio Martins

PhD em Engenharia Agrícola pela Purdue University, Estados Unidos

Instituição: Instituto de Educação Tecnológica – IETEC, MG

Endereço: Rua Didico Bonicontrol, 93 – Fátima, 36572-152, Viçosa – MG, Brasil

E-mail: j.helvecio.martins@gmail.com

RESUMO

Este artigo procurou analisar a demanda intermitente de peças de reposição de uma empresa do setor de mineração, para propor melhorias no processo de previsão para planejamento. Muitas destas peças possuem vários intervalos sem consumo intercalados com a demanda real, o que aumenta a incerteza de previsões, juntamente com outros fatores como a obsolescência. Este artigo então buscou comparar o desempenho dos modelos de previsão e suas otimizações, para a demanda intermitente, e avaliar como a escolha de medidas de erro pode influenciar este resultado. Foram aplicados métodos descritos na literatura, convencionais e alternativos, principalmente a partir do estudo de Croston (1972). Também foram utilizadas medidas de erro convencionais e alternativas, possibilitando uma análise conjunta de resultados entre modelos, medidas de erro e processos de otimização. Por fim, pretende-se contribuir para futuras aplicações dos métodos estudados, inclusive para fins de automatização de previsões utilizando técnicas como *Machine Learning* e *Neuro-Fuzzi*.

Palavras-chave: Previsão, Demanda intermitente, Séries temporais, Estoque, Otimização.

ABSTRACT

This article sought to analyze the intermittent demand for spare parts from a mining company, to propose improvements in the planning prediction process. Many of these parts have several non-consumption intervals interspersed with actual demand, which increases the uncertainty of predictions, along with other factors such as obsolescence. This article then sought to compare the performance of the prediction models and their optimizations, for intermittent demand, and to evaluate how the choice of error measures can influence this result. Conventional and alternative methods described in the literature were applied, mainly from the study of Croston (1972). Conventional and alternative error measures were also used, allowing a joint analysis of results between models, error measures and optimization processes. Finally, it is intended to contribute to future applications of the studied methods, including for the purpose of automating predictions using techniques such as *Machine Learning* and *Neuro-Fuzzi*.

Keywords: Prediction, Intermittent demand, Time series, Stock, Optimization.

1 INTRODUÇÃO

A predição de demanda é um processo essencial para tomada de decisão em diversos seguimentos de negócio (SILVA et al., 2020). É aplicável em atividades como planejamento de curto prazo, planejamento de estoques, predição de vendas, estimativas estratégicas de longo prazo, dentre outras. O trabalho de predição, no entanto, não é simples quando realizado para itens com natureza de consumo intermitente. Esta dificuldade pode resultar em falhas nos processos de aquisição e, em consequência, provocar problemas como a ruptura de estoque, ou o desperdício de materiais em excesso. Discrepâncias no processo de aquisição de produtos podem ocorrer na área hospitalar, de varejo, de vendas, de manutenção, e outros segmentos distintos como o automotivo, aeronáutico, marítimo e mineração. Sendo este último a delimitação deste artigo.

As peças de reposição, são exemplos de itens com demandas normalmente classificadas como esporádica ou intermitente, formando séries temporais diferentes das convencionais, devido à presença de vários períodos com demanda zero. Em muitos casos, esses itens podem representar até 60% do valor total do estoque (JOHNSTON; BOYLAN; SHALE, 2003). Quanto maior o volume, preço unitário, criticidade e risco de obsolescência destes itens, maior será o possível impacto dos desvios de predição da demanda.

Não é simples prever a demanda intermitente devido à sua natureza errática e as vezes irregular (TEUNTER; SANI, 2009). Os intervalos de demanda são pouco frequentes, contendo muitos períodos com demanda zero, juntamente com tamanhos variados.

Vários métodos para predição de demanda são discutidos na literatura (SILVA et al, 2020). A primeira sugestão de que os métodos tradicionais de predição, como a Média Móvel Simples (MMS) e Suavização Exponencial Simples (SES) podem ser inadequados para itens de baixo ou baixíssimo giro, surgiu em 1972 com Croston. Ele demonstrou que estes métodos podem levar a decisões de estoque inadequadas e propôs um procedimento alternativo de predição, em que o intervalo entre demandas e o tamanho da demanda são atualizados separadamente, e somente em períodos com demanda positiva. Neste método, a mesma constante de suavização pode ser utilizada para as duas séries decompostas e o estimador consiste no quociente do tamanho da demanda pelo intervalo entre demandas então suavizados, visando obter predições melhores.

A abordagem de Croston (1972) é utilizada para prever demanda intermitente, inclusive quando estão envolvidas grandes quantidades de itens, e está presente em programas computacionais como *Forecast Pro*, SAS e SAP/APO. Todavia, foi demonstrado um viés neste método por Syntetos e Boylan (2001) e outras opções foram propostas por Syntetos e Boylan (2005), Shale, Boylan e Johnston (2006) e Teunter, Syntetos e Babai (2011).

Apesar do desenvolvimento ao longo dos anos, muitas indústrias continuam utilizando abordagens tradicionais de previsão, como Média Móvel Simples (MMS) e Suavização Exponencial Simples (SES). Embora existam modelos de classificação para apoiar uma escolha entre alguns métodos alternativos, a literatura não oferece diretrizes universais para selecionar o método mais adequado para séries temporais intermitentes (SYNTETOS; BOYLAN, 2005).

Neste contexto, o objetivo geral deste artigo foi comparar o desempenho dos métodos para previsão de demanda intermitente, buscando benefícios destas técnicas em dados de demanda real de peças de reposição do setor de mineração. Foram simuladas previsões com os métodos de Croston (1972), SBA (SYNTETOS; BOYLAN, 2005), SBJ (SHALE; BOYLAN; JOHNSTON, 2006) e TSB (TEUNTER; SYNTETOS; BABAI, 2011). Estes resultados foram comparados com os valores obtidos com Média Móvel Simples (MMS), Suavização Exponencial Simples (SES), e com as referências *NAÏVE* e *ZERO*. A otimização e as análises de desempenho foram realizadas com medidas de erro convencionais e alternativas, indicadas na literatura.

Como objetivos específicos, este artigo procurou descrever o processo de classificação de demanda categorizando os itens intermitentes, indicar requisitos para separação da amostra para treino e teste, simular previsões utilizando otimização de parâmetros e parâmetros convencionais e analisar o desempenho dos resultados para medidas de erros específicas.

O restante do artigo está organizado com a Seção 2 contendo a revisão da literatura, Seção 3 a metodologia, Seção 4 a apresentação e análise dos resultados e Seção 5 as conclusões.

2 REVISÃO DA LITERATURA

O propósito deste estudo é a contextualização do processo de previsão de demanda intermitente e formas de se obter um melhor desempenho. Pretende-se contribuir para o melhor entendimento de alguns modelos aplicáveis e os possíveis benefícios de sua utilização.

2.1 PREDIÇÃO DA DEMANDA INTERMITENTE

Os estudos de previsão de demanda intermitente começaram com a indústria da aviação, a fim de prever o consumo de peças de reposição, uma vez que são de custo elevado, com intervalos de consumo aleatórios e possuem dificuldades de manuseio e movimentação.

A Suavização Exponencial Simples (SES) foi o primeiro método de previsão aplicado a dados de natureza intermitente. O modelo consiste na atribuição de um fator de ponderação para cada valor da série temporal, de forma que os valores de demanda mais recentes recebem ponderações maiores (PELLEGRINI; FOGLIATTO, 2001).

A estimação da demanda pelo método SES é feita utilizando as expressões (MAKRIDAKIS; WHEELRIGHT; HYNDMAN, 1998):

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

$$\hat{y}_t = \alpha \cdot y_{t-1} + (1 - \alpha)\hat{y}_{t-1} \quad (2)$$

Em que:

- \hat{y}_t = Predição da demanda para o período t ;
- \hat{y}_{t-1} = Predição da demanda para o período anterior a t ;
- y_{t-1} = Demanda observada para o período anterior a t ;
- α = Declividade da curva de \hat{y}_t (constante entre 0 e 1).

Apesar de ser um método de predição considerado simples, é possível observar a utilização do método de SES em muitos trabalhos de pesquisa e em programas computacionais de predição utilizados na indústria. No entanto, a utilização da Suavização Exponencial Simples (SES) para predições de demandas intermitentes, quase sempre, produzem níveis inadequados de estoque, porque a reposição de quantidades constantes em intervalos fixos pode gerar níveis de estoque de até o dobro da quantidade realmente necessária (CROSTON, 1972).

Croston (1972) concluiu que métodos tradicionais, incluindo o SES, não tinham um bom desempenho em séries temporais intermitentes. Ele então desenvolveu outro método, utilizando estimativas separadas do tamanho da demanda e da frequência em que a demanda irá ocorrer, aplicando-se uma mesma constante de suavização (α). A predição final é então determinada pelo quociente das duas estimativas e representa a procura média por período. O autor assume que a demanda ocorre como um processo de Bernoulli e o intervalo entre demandas segue uma distribuição geométrica. De acordo com o método de Croston, todos os estimadores são atualizados apenas quando ocorre uma demanda:

Se $y_t = 0$, tem-se:

$$\hat{p}_t = \hat{p}_{t-1}; \quad \hat{z}_t = \hat{z}_{t-1}; \quad q = q + 1 \quad (3)$$

Se $y_t \neq 0$, tem-se:

$$\hat{p}_t = \hat{p}_{t-1} \alpha(q - \hat{p}_{t-1}); \quad \hat{z}_t = \hat{z}_{t-1} + \alpha(y_t - \hat{z}_{t-1}); \quad q = 1 \quad (4)$$

Em que:

- q = Intervalo desde a última demanda;
- z_t = Tamanho da demanda;
- p = Intervalo entre demandas;
- p_t = Representa a ocorrência de demanda;
- \hat{p}_t = Intervalo entre demanda, suavizado exponencialmente, atualizado apenas se a demanda ocorrer no período t ;
- \hat{z}_t = Tamanho da demanda exponencialmente suavizado, atualizado somente se a demanda ocorrer no período t .

De acordo com o procedimento de estimativa em que $0 \leq \alpha \leq 1$ é uma constante de suavização, \hat{y}_t é a demanda predita no período t , dada pela Equação (5):

$$\hat{y}_t = \frac{\hat{z}_t}{\hat{p}_t} \quad (5)$$

Alguns autores como Sani e Kingsman (1997) sugeriram posteriormente, a ocorrência de perdas no desempenho do método de Croston. Foi demonstrado que o método possuía viés e, desde então, algumas modificações foram apresentadas na literatura, como em Syntetos e Boylan (2001). Vale ressaltar o longo período de aproximadamente 30 anos entre a publicação do método de Croston (1972) e a comprovação do viés por Syntetos e Boylan (2001).

Uma destas pesquisas resultou no método de Aproximação de Syntetos e Boylan - *Syntetos Boylan Approximation* (SBA) que trouxe melhoria na proposta de Croston (1972), como confirmado em outros estudos destes mesmos autores (SYNTETOS; BOYLAN; CROSTON, 2005).

Por meio da análise de mais de 3.000 produtos do setor automotivo de demanda intermitente, Syntetos e Boylan (2005) demonstraram que o método SBA é mais acurado que o de Croston (1972). O estimador definido como Aproximação de Boylan e Syntetos (SBA) está descrito na Equação (6).

$$\hat{y}_t = \left(1 - \frac{\alpha}{2}\right) \left(\frac{\hat{z}_t}{\hat{p}_t}\right) \quad (6)$$

Estudos posteriores realizados por Teunter e Sani (2009) e Wallström e Segerstedt (2010) mostraram que, apesar da modificação do método SBA, pode ainda surgir viés quando a intermitência da série temporal em análise é baixa. Uma modificação diferente, mais apropriada, denominada de modelo SBJ, foi apresentada, considerando que os pedidos de itens de reposição

chegam como um processo de Poisson (SHALE; BOYLAN; JOHNSTON, 2006). Então um estimador mais apropriado é dado pela Equação (7), que define o método SBJ.

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

Um novo procedimento de predição, denominado de TSB, que tratava da questão da obsolescência do inventário, foi apresentado em 2011 por Teunter, Syntetos e Babai (2011). Neste método, a predição é ajustada para baixo toda vez que for encontrada uma demanda zero, diferente de Croston (1972). Como resultado, o novo método foi considerado mais adequado para lidar com problemas de obsolescência, pois permitia modelar uma diminuição gradual de demanda, a ponto da demanda se tornar nula, para itens descontinuados. Se essa obsolescência não for modelada, será formado um excesso de estoque para estes itens (TEUNTER; SYNTETOS; BABAI, 2011).

O método TSB utiliza estimativas separadas e exponencialmente ajustadas do tamanho da demanda e da probabilidade de demanda. A estimativa do tamanho da demanda é atualizada apenas no final dos períodos com demanda positiva. Já a estimativa da probabilidade de ocorrência é atualizada a cada período. Assim, cada etapa de suavização utiliza um parâmetro diferente. O método TSB é descrito de acordo com as equações (8), (9) e (10).

Se $y_t = 0$:

$$\hat{p}_t = \hat{p}_{t-1} + \beta(0 - \hat{p}_{t-1}); \quad \hat{z}_t = \hat{z}_{t-1} \quad (8)$$

Se $y_t > 0$:

$$\hat{p}_t = \hat{p}_{t-1} + \beta(1 - \hat{p}_{t-1}); \quad \hat{z}_t = \hat{z}_{t-1} + \alpha(z_t - \hat{z}_{t-1}) \quad (9)$$

$$\hat{y}_t = \hat{p}_t \cdot \hat{z}_t \quad (10)$$

Uma proposta para otimização dos parâmetros da constante de suavização e valores iniciais de demanda e intervalo para os métodos anteriores, foi sugerida no trabalho de Kourentzes (2014). Nesta abordagem, os valores iniciais e constante de suavização dos modelos são otimizados por meio da minimização de cada uma das funções de perda DMA, DQM, TAM e TQM, detalhadas na próxima Seção.

2.2 MEDIDAS DE ERRO

Para comparar o desempenho de cada método de previsão de demanda, um processo típico é a utilização de medidas de erros ou de acurácia operacional. Estas medidas podem ser utilizadas também como funções de perda no processo de otimização das previsões (KOURENTZES, 2014).

Uma medida comum para controle de estoque é o Desvio Médio Absoluto (DMA), que consiste no módulo da diferença entre o valor real e o estimado (TUBINO, 2000).

$$\bar{D}_{abs} = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i \quad (11)$$

Considerando a otimização de séries temporais convencionais, uma outra função de perda popular é o Desvio Quadrático Médio (DQM):

$$\bar{D}_{quad} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (12)$$

Uma proposta diferente para determinar o desempenho dos itens com demanda intermitente é dada por Hyndman e Koehler (2006), denominado Erro Médio Absoluto Escalonado (EMAE) que, segundo o autor, é uma medida de erro mais adequada, pois nunca se obtém valores infinitos ou indefinidos. O cálculo do EMAE é realizado dividindo-se o erro absoluto da previsão (D_p), pela média do erro do método ingênuo (*NAÏVE*). No método ingênuo, a previsão da demanda do próximo período é igual à demanda do período atual, ou seja, um período à frente. O valor do EMAE é calculado usando a Equação (13):

$$\bar{E}_{absE} = \frac{1}{n} \sum_{i=1}^n \left| \frac{D_p}{\left[\left(\frac{1}{n-1} \right) \cdot \sum_{i=2}^n (|y_i - y_{i-1}|) \right]} \right| \quad (13)$$

A aplicabilidade dessas medidas de erro para séries temporais intermitentes tem sido contestada, no entanto, por alguns autores. Estas medidas tendem a polarizar as previsões em favor da previsão de demanda zero e não forneceriam boa aproximação para as decisões de inventário. Outras medidas de somatório acumulativo foram então sugeridas. Uma delas é a medida do Período

em Estoque Escalonado Absoluto Modificado (PEEEAm), que pode ser calculado usando a Equação (14):

$$P_{PEEEAm} = \frac{\left| -\sum_{i=1}^h \sum_{j=1}^i (y_j - \hat{y}_j) \right|}{\frac{1}{n} \sum_{i=1}^n y_i} \quad (14)$$

Uma vantagem desta medida seria penalizar adequadamente as previsões de demanda zero (KOURENTZES, 2014). O autor também salienta que o método de Croston e suas variantes fornecem uma "taxa de demanda" com unidade diferente da demanda real, e medir esta diferença não seria significativo com DMA e DQM.

A propriedade destas novas previsões poderia ser utilizada para derivar novas metodologias para otimização através de medidas de taxa acumulativa do erro: a Taxa Média Absoluta (TAM) e Taxa do Quadrado da Média (TQM). O detalhe envolvendo a TAM e a TQM é ajustar as previsões de demanda intermitente pela demanda média por período, ao invés da demanda realizada (KOURENTZES, 2014), Equações (15) e (16):

$$\bar{T}_{abs} = \sum_{i=1}^n \left| \hat{y}_i - \frac{1}{n} \cdot \sum_{j=1}^n y_j \right| \quad (15)$$

$$\bar{T}_{quad} = \sum_{i=1}^n \left(\hat{y}_i - \frac{1}{n} \cdot \sum_{j=1}^n y_j \right)^2 \quad (16)$$

Para as medidas DMA, DQM, TAM e TQM também é possível uma versão escalonada, dividindo-se o valor da medida de erro pela média da amostra. O erro escalonado é um erro relativo, cujo objetivo é a remoção da escala, para que os erros de diferentes séries temporais que compõem o conjunto de dados, possam ser comparados. As medidas EMAE e PEEEA_m já contemplam o escalonamento em suas equações.

2.3 ESCOLHA DO MELHOR MODELO

Depois de conhecer alguns métodos de previsão e medidas de erro, é usual buscar a avaliação de qual é o método mais adequado para a previsão da demanda intermitente. A literatura, no entanto, traz uma avaliação de que este objetivo não é trivial.

De acordo com Wallström e Segerstedt (2010), quando um erro de predição é mensurado, não é o método que é medido, mas a combinação de como este método responde a este erro. As relações entre diferentes erros variam de acordo com o método aplicado, o valor inicial e as constantes de suavizações utilizadas. Outras relações são as medidas de variância e de viés. Os autores descrevem também que, apesar do foco estar geralmente nos métodos de predição, estes podem estar relacionados a erros distorcidos, e por isto é relevante pesquisas que possam identificar quando um determinado erro pode ser usado ou não.

Estudos sobre a robustez dos métodos de predição, mostraram quão robustos são os métodos para a demanda intermitente, considerando diferentes constantes de suavização e valores iniciais (WALLSTRÖM; SEGERSTEDT, 2010). Os autores concluíram que não existe, em geral, uma medida melhor, por duas razões principais. A primeira é a dimensão de um erro e a distorção de um erro em combinação com um método de predição. A segunda é que, sob certas circunstâncias, os erros favoreceram determinado tipo de viés.

No estudo a medida DMA teve um comportamento distorcido para os métodos. Para Croston e SBA, os itens diminuíram DMA com o aumento da constante de suavização, para as mesmas variáveis significativas. Para esta medida, os métodos de melhor desempenho são os que tendem a subestimar a demanda e, portanto, não é considerada uma medida adequada para a demanda intermitente. A medida DQM demonstrou ser estável e suficiente e não mostrou qualquer comportamento distorcido, como a redução do erro com um aumento da constante de suavização. DQM foi então considerada uma medida confiável (WALLSTRÖM; SEGERSTEDT, 2010).

Estas evidências concordam com a descoberta de Teunter e Duncan (2009), que afirma que DMA favorece a subestimação de métodos, e que DQM também o faz, mas não no mesmo grau. Também concorda com a descrição de Kourentzes (2014), de que DMA beneficia a predição zero de amostras com demandas intermitentes.

A escolha do método de predição não deve se basear apenas no erro de predição, mas também sobre as consequências para a organização do método escolhido. A escolha deve refletir as estratégias da organização, embora reconheça que é mais fácil escrever esse objetivo do que implementá-lo na prática. Em logística, existe uma tendência de sempre minimizar o custo em vez de aumentar o lucro. Às vezes, a minimização cria uma sub otimização, seja na própria organização ou na cadeia de suprimentos (WALLSTRÖM; SEGERSTEDT, 2010).

3 METODOLOGIA

Este artigo foi realizado em três etapas. Uma abordagem descritiva, com o objetivo de descrever os fatos, analisá-los, classificá-los e interpretá-los, sem interferência do pesquisador. Uma abordagem exploratória, visando proporcionar maior familiaridade com o problema em pauta. Uma abordagem prática, visando solucionar um problema a partir da observação de dados reais. A abordagem da pesquisa pode ser categorizada também como quantitativa, pois requer o uso de recursos matemáticos e técnicas estatísticas para análise do problema proposto.

3.1 AMOSTRA

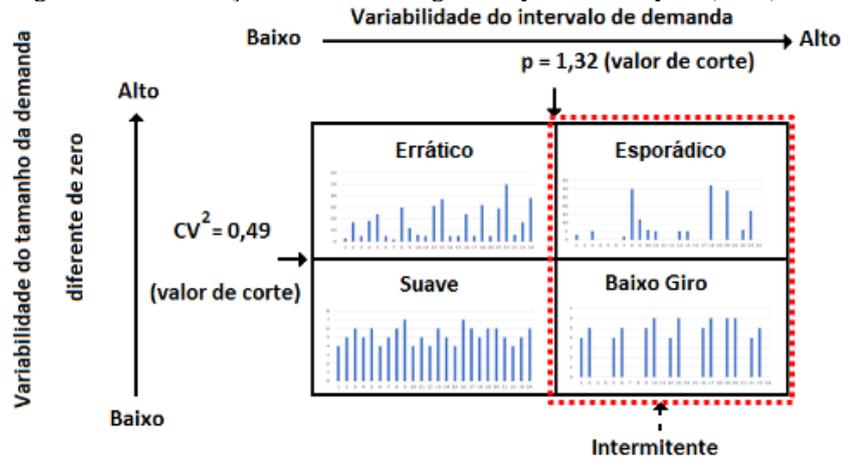
A base de dados constitui de uma amostra de consumo mensal de 2.403 Unidades de Manutenção de Estoque - UME (*Stock Keeping Unit – SKU*) no período de 38 meses (janeiro de 2016 a fevereiro de 2019). O conjunto de itens é formado por peças de Manutenção, Reparo e Operação (MRO) do seguimento de mineração, coletado a partir do sistema ERP. Por questões de confidencialidade, não foram utilizadas informações adicionais sobre os itens.

O período da amostra foi dividido com uma aproximação de 80% para treino e 20% para teste, de acordo com recomendação de Hyndman e Athanasaupolos (2018). Desta forma, a amostra de treino contemplou um período de 32 meses utilizada para predições de um passo à frente e suas otimizações. A amostra de teste, contemplou o período dos 6 meses restantes usado para aferição entre a predição e o consumo real observado. Este segundo período foi dividido em 3 horizontes: um mês, três meses e seis meses. A agregação temporal adotada foi a mensal, em que se considerou pouca perda nas séries temporais, pois a natureza dos itens é, em sua maioria, de alta intermitência, sem observar fatores como sazonalidade e tendência.

3.2 CLASSIFICAÇÃO DA DEMANDA DE ITENS

Para identificação dos itens com demanda intermitente a partir da amostra, foi realizada uma classificação em quatro quadrantes, conforme Syntetos e Boylan (2005). Levou-se em consideração dois eixos que se cruzam perpendicularmente. Um dos eixos é o intervalo médio entre demandas (p) e o outro é quadrado do coeficiente de variação dos tamanhos de demanda (c_v^2). Os pontos de corte nos eixos ($p = 1,32$ e $c_v^2 = 0,49$) seguiram as recomendações do estudo. A demanda intermitente foi categorizada nos quadrantes Esporádico e Baixo Giro, conforme a Figura 1:

Figura 1 - Classificação de demanda segundo Syntetos e Boylan (2005).



3.3 OTIMIZAÇÃO DOS MODELOS E AVALIAÇÃO DE DESEMPENHO

A predição de demanda de peças de reposição foi realizada por meio de simulação, utilizando as abordagens do método de Croston (CROSTON, 1972), do método SBA (SYNTETOS; BOYLAN, 2005), do método SBJ (SHALE; BOYLAN; JOHNSTON, 2006) e do método TSB (TEUNTER; SYNTETOS; BABAI, 2011). Os métodos convencionais de Média Móvel Simples (MMS) e Suavização Exponencial Simples (SES) foram utilizados para comparação. Ainda para referência dos resultados de predições, o método “ingênuo” (*NAÏVE*) e o método predição “zero” foram também aplicados.

Para a otimização dos parâmetros α (coeficiente de suavização) e l_0 (valor inicial em $t = 0$) dos componentes dos métodos, optou-se pela sub-rotina específica *tsintermittent*, que faz parte da plataforma de programação *R-Studio*. O objetivo foi procurar pelos menores valores de erro das funções de perda especificadas no programa, que são DMA, DQM, TAM e TQM. Os resultados foram comparados com parâmetros convencionais indicados na literatura: a constante de suavização $\alpha = 0,1$; o parâmetro de suavização da probabilidade de demanda $\beta = 0,2$ para o método TSB, e os valores iniciais do intervalo entre demandas com método ingênuo (*naïve*) e média. A versão utilizada da biblioteca *tsintermittent* foi desenvolvida por Nikolaos Kourentzes e Fotios Petropoulos em 2016 e possui funções para análise de predição de demanda intermitente. Foram utilizadas as funções dos modelos SES, CROSTON, SBA, SBJ e TSB.

O programa Excel 2016 foi escolhido para categorização dos itens, estimação dos erros, cálculo da Média Móvel, método Ingênuo (*Naïve*) e predição zero, que não estavam presentes na biblioteca R utilizada. O programa Minitab foi utilizado para apresentação dos resultados.

Para a avaliação de desempenho foram utilizadas as versões escalonadas das medidas de erro descritas na Seção 2.2., obtidas pelo quociente do valor da medida de erro pela média da amostra.

São elas: o Desvio Médio Absoluto Escalonado (DMAE), o Desvio Quadrático Médio Escalonado (DQME), o erro Médio Absoluto Escalonado (EMAE), o Período em Estoque Escalonado Absoluto Modificado (PEEEAm), a Taxa Absoluta Média Escalonada (TAME) e a Taxa do Quadrado da Média Escalonada (TQME).

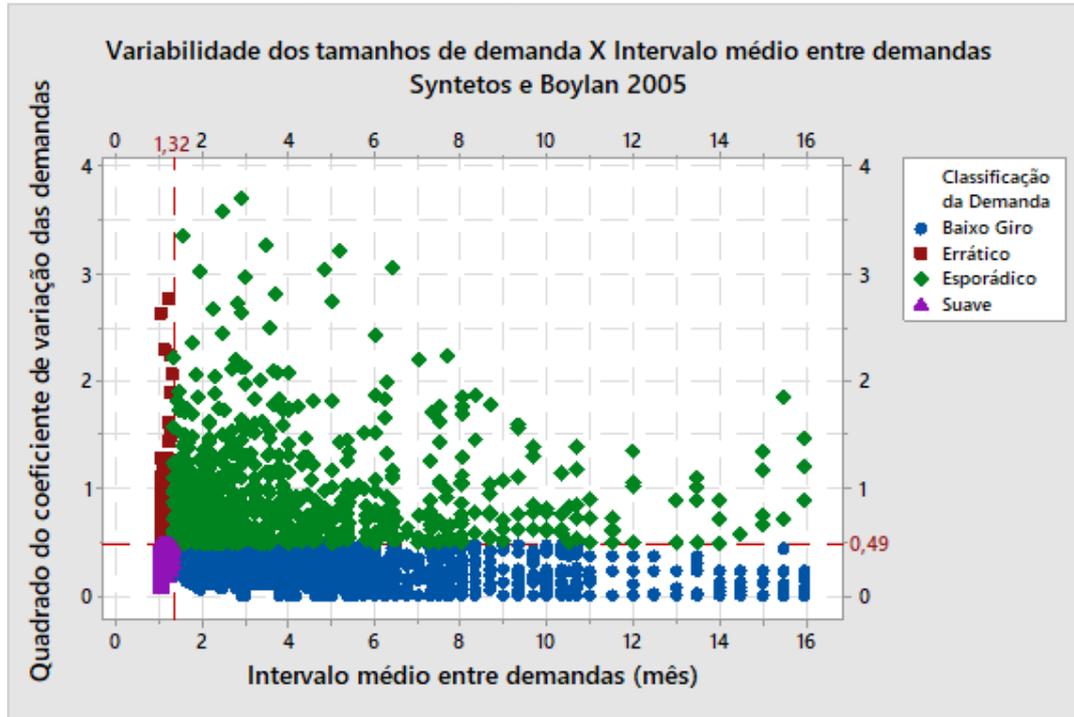
A forma de apresentação dos resultados foi a classificação de posições, tomando-se como referência os erros (amostra de teste) encontrados e seguindo o critério de quanto menor a posição na classificação, melhor o desempenho da otimização ou do modelo.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

De acordo com a base de dados, primeiramente é apresentada a classificação das séries da amostra utilizada (SYNTETOS; BOYLAN, 2005), conforme ilustrada na Figura 2.

Observou-se que 84% dos itens, que correspondem a 2.023 Unidades de Manutenção de Estoque - UME (*Stock Keeping Unit - SKU*), possuíam demandas classificadas como de baixo giro ou esporádicas, o que configura um cenário majoritariamente formado por séries intermitentes. Apesar de não estar sendo avaliados os valores de peças de reposição e sim a quantidade, este resultado sinaliza uma possível conformidade com o fato de que esses itens podem representar até 60% do valor total do estoque (JOHNSTON; BOYLAN; SHALE, 2003). Isto indica a necessidade de pesquisas ligadas a este tipo de demanda. As análises a seguir trazem a posição na classificação de erros das otimizações e dos modelos de predição, considerando dois grupos de medidas associadas por proximidade no resultado.

Figura 2 - Classificação da demanda da amostra.



4.1 RESULTADO DO PRIMEIRO GRUPO DE MEDIDAS DE ERRO PARA DEMANDA INTERMITENTE

Neste primeiro grupo, foram consideradas as médias de erro DMAE, EMAE e PEEEA_m, associadas por proximidade de resultados na classificação de otimização e desempenho dos modelos. Este grupo apresentou o melhor benefício para a otimização DMA (Tabela 1) e para o método de referência ZERO (Tabela 2), na amostra de teste.

Este resultado sugere uma semelhança com o descrito por Wällstrom e Segerstedt (2010), que destacam que em certas circunstâncias o DMA tende a subestimar a demanda, preferindo a predição zero. Portanto, a predição ficará mais distorcida, e um intervalo maior entre demanda tornará o DMA menos confiável. O DMA não seria considerado adequado para uso em séries com demanda intermitente, o que estaria coincidindo também com as descobertas de Teunter e Duncan (2009), ao afirmarem que o DMA favorece a subestimação de métodos e que o DQM também o faz, mas não no mesmo grau. Também está de acordo com a descrição de Kourentzes (2014), que afirma que esta medida beneficia a predição zero de amostras com demandas intermitentes. Todos os métodos, exceto o método ZERO, tentam obter a correta predição por período, mas são punidos ao fazê-lo no cálculo de DMA.

Tabela 1 - Classificação das medidas de erros DMAE, EMAE e PEEEA_m, para séries intermitentes (Primeiro Grupo), usando otimização.

Tipo de Otimização	0Amostra				
	Treino	Teste			
	Classificação	T+1	T+3	T+6	Classificação
DMA	2,33	1,00	1,00	1,00	1,00
DQM	1,67	2,00	2,00	2,00	2,00
TAM	2,67	3,00	3,00	3,00	3,00
TQM	3,67	4,00	4,33	4,00	4,11
$\alpha = 0,1; p_i: \text{naïve}$	6,00	6,00	6,00	6,00	6,00
$\alpha = 0,1; p_i: \text{média}$	4,67	5,00	4,67	5,00	4,89

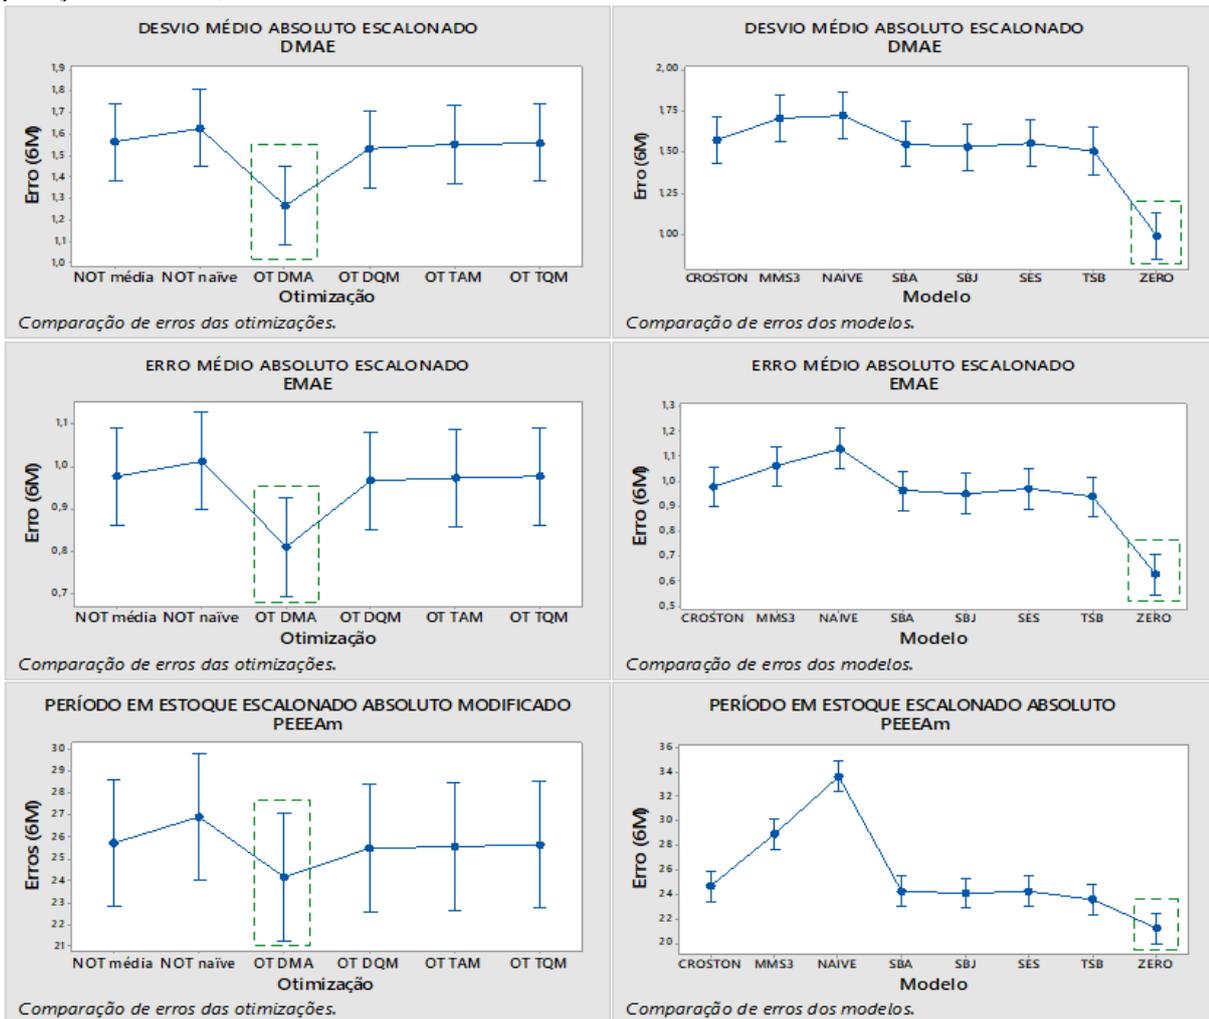
Tabela 2 - Classificação das medidas de erros DMAE, EMAE e PEEEA_m, para séries intermitentes (Primeiro Grupo), usando modelos de predição.

Método de Predição	Amostra				
	Treino	Teste			
	Classificação	T+1	T+3	T+6	Classificação
<i>MMS3</i>	5,33	7,00	7,00	7,00	7,00
<i>SBA</i>	5,00	4,00	4,00	4,33	4,11
<i>CROSTON</i>	6,33	6,00	6,00	6,00	6,00
<i>SBJ</i>	4,67	3,00	3,00	3,00	3,00
<i>SES</i>	3,00	5,00	5,00	4,67	4,89
ZERO	3,33	1,00	1,00	1,00	1,00
<i>NAÏVE</i>	5,67	8,00	8,00	8,00	8,00
<i>TSB</i>	2,67	2,00	2,00	2,00	2,00

As medidas de erro pelo DMA, EMAE e PEEEA_m são afetadas pelos mesmos benefícios da predição zero. Nestas medidas, uma predição sendo zero todo o tempo seria a preferida, mesmo que esta predição seja inútil para um processo de produção. Já para a medida PEEEA_m houve uma discordância com o descrito por Kourentzes (2014), de que seria uma vantagem desta medida a penalização adequada das predições de demanda zero.

Foi observado também que o método CROSTON apresentou desempenho inferior em relação ao seu sucessor, SBA. O método TSB ficou na segunda posição entre todos os modelos, e os métodos MMS3 e NAÏVE apresentaram os maiores erros. Uma ilustração das comparações de erros de predição e otimizações para o horizonte (h+6) meses, está na Figura 3.

Figura 3 - Comportamento de medidas de erro e modelos nas otimizações do Primeiro Grupo para um horizonte de previsão de 6 meses, usando desvios absolutos.



4.2 RESULTADO DO SEGUNDO GRUPO DE MEDIDAS DE ERRO PARA DEMANDA INTERMITENTE

No Segundo Grupo de medidas de erro, associados por proximidade nos resultados na classificação de otimização e desempenho dos modelos, foram consideradas as medidas de desvio DQME, TAME e TQME. Mesmo o DQME sendo uma medida pontual, seus resultados se aproximaram dos resultados das medidas das taxas acumulativas TAME e TQME.

Os resultados das três medidas foram consolidados na forma de uma única classificação, sendo a menor posição equivalente ao melhor desempenho, na Tabela 3. Já a classificação usando modelos de previsão, encontra-se na Tabela 4.

Na Tabela 3 uma diferença observada no Segundo Grupo em relação ao Primeiro Grupo foi a inversão do benefício do DMA que, no Segundo Grupo, apresentou pior desempenho.

Neste segundo grupo, os melhores desempenhos foram obtidos com a otimização das taxas TAM e TQM, tanto na amostra de treino quanto na de teste. Este resultado era em parte esperado, porque as funções de perda destas otimizações têm origem nas próprias medidas de erros alternativas (Kourentzes, 2014).

Na Tabela 4 observou-se que o melhor resultado de desempenho na amostra teste, do Segundo Grupo, foi para os métodos SBA e SBJ. Já os métodos *NAÏVE*, MMS3 e ZERO apresentaram os piores desempenhos. Observa-se também que o método CROSTON apresentou resultado inferior ao do seu método sucessor SBA.

Tabela 3 - Classificação das medidas de erros DQME, TAME e TQME, para séries intermitentes (Segundo Grupo), usando otimização

Tipo de Otimização	Amostra				
	Treino	Teste			
	Classificação	T+1	T+3	T+6	Classificação
DMA	5,33	6,00	6,00	6,00	6,00
DQM	2,67	4,33	4,67	4,67	4,56
TAM	2,67	1,00	1,00	1,00	1,00
TQM	1,67	2,00	2,00	2,00	2,00
$\alpha = 0,1$; pt: <i>naïve</i>	5,67	4,67	4,33	4,33	4,44
$\alpha = 0,1$; pt: média	3,00	3,00	3,00	3,00	3,00

Tabela 4 - Classificação das medidas de erros DQME, TAME e TQME, para séries intermitentes (Segundo Grupo), usando modelos de previsão

Método de Predição	Amostra				
	Treino	Teste			
	Classificação	T+1	T+3	T+6	Classificação
<i>MMS3</i>	6,67	7,00	7,00	7,00	7,00
SBA	1,33	1,33	1,67	2,00	1,67
<i>CROSTON</i>	3,33	3,33	3,33	3,67	3,44
SBJ	2,67	2,33	2,00	2,00	2,11
<i>SES</i>	4,67	4,00	4,00	4,00	4,00
<i>ZERO</i>	6,33	6,00	6,00	6,00	6,00
<i>NAÏVE</i>	8,00	8,00	8,00	8,00	8,00
<i>TSB</i>	3,00	4,00	4,00	3,33	3,78

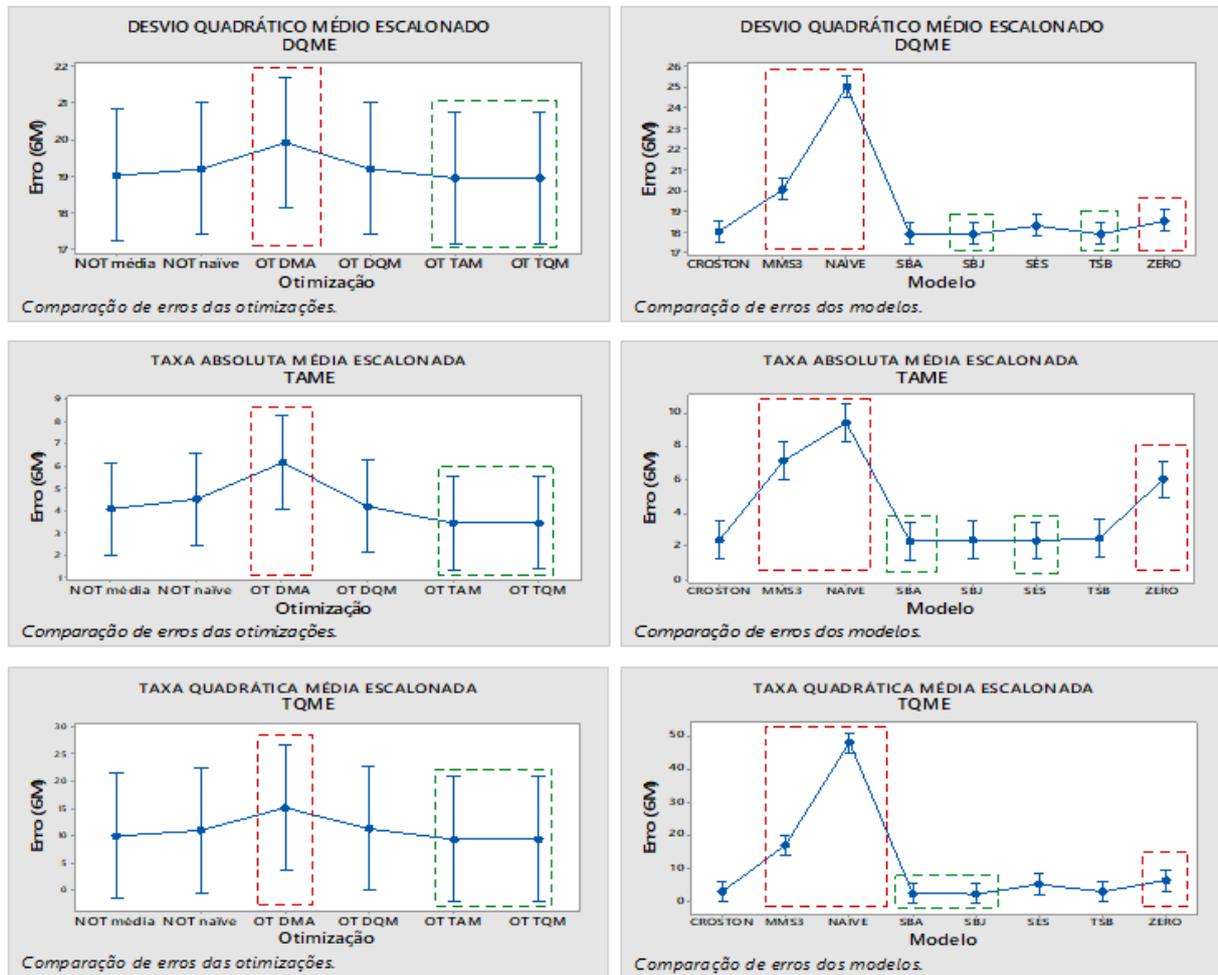
O método TSB destacou-se por apresentar flexibilidade, ficando posicionado em uma classificação intermediária para os dois grupos de medidas. O método é interessante para objetivos de inventário, pois trata a obsolescência. Ele permite prever uma diminuição gradual de demanda, a ponto desta se tornar zero para itens descontinuados, evitando-se excessos no inventário.

Como exemplo do padrão de comportamento dos erros das otimizações e modelos deste Segundo Grupo, é apresentada a Figura 4, para o horizonte de predição de 6 meses.

Sugere-se, portanto, que a escolha das medidas de erro pode influenciar no desempenho das otimizações e dos modelos. Os dois grupos de medidas definidos para simplificação do resultado da pesquisa, descrevem padrões de comportamentos distintos quanto aos resultados da otimização e conseqüentemente quanto ao desempenho de cada método. Desta forma, para cada aplicação, cabe a medida de erro e modelo de predição mais adequado ao trabalho.

Estes resultados também sugerem uma concordância com Wallström e Segerstedt (2010), os quais relataram que, quando um erro de predição é mensurado, não é o método que é medido, mas a combinação de como este método responde ao erro. As relações entre diferentes erros podem variar de acordo com o método aplicado, o valor inicial, as constantes de suavização, as medidas de variância e viés.

Figura 4 - Comportamento de medidas de erro e modelos nas otimizações do Segundo Grupo para um horizonte de predição de 6 meses, usando desvios quadráticos e acumulativos



As recomendações, a partir das evidências encontradas neste trabalho, são resumidas no Quadro 1. É importante destacar que as sugestões acompanham a amostra estudada, e para novos conjuntos de dados faz-se necessárias análises específicas.

Quadro 1 - Resumo de sugestões para predições de itens com demanda intermitente

Natureza da demanda	Objetivo	Sugestões para predições de demanda intermitente			
		Medidas de erro	Otimização	Método	Observação
Intermitente	Controle de inventário combinado ao processo de produção	DQME TAME TQME	TAM TQM	SBA SBJ	Reduz a tendência de predições zero, quando ocorre otimização. Necessário o acompanhamento posterior de itens obsoletos.
	Ajuste automático de predição para itens obsoletos	DQME TAME TQME	TAM TQM	TSB	Predição se ajusta automaticamente para itens obsoletos até a completa descontinuidade.

5 CONCLUSÕES

A predição de itens com demanda intermitente próximas ao valor real é um dos objetivos para uma boa gestão de inventário. Com este objetivo, algumas técnicas de predição descritas na literatura foram testadas e avaliadas quanto ao desempenho. Para isto, foi utilizada uma amostragem real de peças de reposição do setor de manutenção na indústria de mineração. Procurou-se mensurar e identificar o padrão de comportamento dos erros, a partir de dados reais, conforme medidas e métodos utilizados.

Os resultados encontrados sugerem que a escolha da medida de erro interfere no resultado de desempenho, tanto das otimizações quanto dos modelos. Esta constatação foi considerada com base na avaliação da classificação dos erros em dois grupos distintos de medidas. Estes grupos foram definidos por semelhança de resultado na classificação e padrões de comportamento dos erros.

Como o objetivo do trabalho foi a avaliação da predição de peças de reposição com demanda intermitente, em que não faz sentido predições zero, recomenda-se as medidas de erro do Segundo Grupo (TAME, TQME ou DQME). O melhor benefício ocorreu para as otimizações TAM e TQM e, conseqüentemente, com tendência à escolha dos modelos SBA e SBJ. Sugere-se que estes métodos sejam mais adequados ao objetivo de controle de inventário combinado ao processo de produção. É importante que estes métodos sejam acompanhados por um controle de itens obsoletos, uma vez que a predição é contínua mesmo após a descontinuidade de consumo de determinado item. O mesmo não ocorre com o método TSB, indicado para controle automático de itens obsoletos e que apresentou resultados intermediários e regulares. Destaca-se que estes resultados estão

relacionados à natureza da amostra da pesquisa, e novos estudos são necessários para outros conjuntos de dados.

Com base nas análises, concluiu-se que não se pode afirmar quais medidas, modelos e tipos de otimização são melhores, sem que antes seja definido o objetivo do trabalho. Isto porque quando um erro de predição é mensurado, não é o método que é medido, mas a combinação de como este método responde à medida de erro. Portanto, a definição do objetivo da predição é o primeiro passo antes da escolha da medida de erro adequada e posterior seleção do modelo e da técnica de otimização.

Os resultados desta pesquisa sugerem que o tema abordado ainda necessita ser explorado, haja vista que os sistemas de predição disponíveis nos programas (ou plataformas) computacionais empresariais não se aplicam diretamente à demanda intermitente e, quando existem, podem não ser bem compreendidos e aplicados. Como resultado, espera-se contribuir para melhor gestão de demanda intermitente, tanto para processos de manufatura quanto para objetivos específicos de inventário.

Uma limitação deste trabalho foi a análise do reflexo no nível de serviço e o custo de inventário, haja vista que, pela indisponibilidade de dados de inventário e seus custos, optou-se pela abordagem de erros das predições.

Para novas pesquisas, sugere-se procurar por métodos que detectem quando as medidas de erros de predição são adequadas ou não para um determinado modelo. Buscar formas de medir a sensibilidade dos erros em relação às alterações das constantes de suavização e valores iniciais também seriam interessantes. Aplicações de redes neurais e aprendizado de máquina (*machine learning*) poderiam ser úteis para viabilizar modelos com constantes de suavização dinâmicas ao longo das séries. Outras técnicas viáveis poderiam ser exploradas como agregação, geração empírica de distribuições de dados (*bootstrapping*), sistema *Neuro-Fuzzy*, dentre outras. Para avaliação de desempenho de modelos e/ou técnicas de predição, sugerem-se pesquisas considerando indicadores de desempenho de nível de serviço e custo de inventário.

AGRADECIMENTOS

Os autores agradecem a todos os colaboradores do Instituto de Educação Tecnológica de Minas Gerais, que direta ou indiretamente contribuíram para a elaboração e melhoria deste estudo.

REFERÊNCIAS

- Croston, J. D. Forecasting And Stock Control For Intermittent Demands. *Journal Of The Operational Research Society*, V. 23, N. 3, P. 289–303, 1972.
- Hyndman, R. J.; Athanasaupolos, G. Forecasting: Principles And Praticce. Disponível Em: <<https://www.otexts.org/Fpp2>. Acesso Em 20/11/19>.
- Hyndman, R. J.; Koehler, A. B. Another Look At Measures Of Forecast Accuracy. *International Journal Of Forecasting*, V. 22, N. 4, P. 679–688, 2006.
- Johnston, F. R.; Boylan, J. E.; Shale, E. A. An Examination Of The Size Of Orders From Customers, Their Characterisation And The Implications For Inventory Control Of Slow Moving Items. *Journal Of The Operational Research Society*, V. 54, N. 8, P. 833–837, 2003.
- Kourentzes, N. On Intermittent Demand Model Optimisation And Selection. *International Journal Of Production Economics*, V. 156, P. 180–190, 2014.
- Makridakis, S.; Wheelright, S. C.; Hyndman, R. J. *Forecasting - Methods And Applications*. 3. Ed. New York: Jonh Wiley, 1998.
- Pellegrini, F. R.; Fogliatto, F. S. Passos Para Implantação De Sistemas De Previsão De Demanda: Técnicas E Estudo De Caso. *Production*, V. 11, N. 1, P. 43–64, 2001.
- Sani, B.; Kingsman, B. G. Selecting The Best Periodic Inventory Controldemand Forecasting Methods For Low Demand Items. *Journal Of The Operational Research Society*, V. 48, N. 7, P. 700–713, 1997.
- Shale, E. A.; Boylan, J. E.; Johnston, F. R. Forecasting For Intermittent Demand: The Estimation Of An Unbiased Average. *Journal Of The Operational Research Society*, V. 57, N. 5, P. 588–592, 2006.
- Silva, M. C.; Barbosa, N. M.; Pedroza, W. N.; Santiago, S. B.; Souza Júnior, A. A. Métodos De Previsão: Estudo De Caso No Setor De Transporte De Uma Universidade Federal. *Brazilian Journal Of Development*, Curitiba, V. 6, N. 2, P.9374-9390, 2020.
- Syntetos, A. A.; Boylan, J. E. On The Bias Of Intermittent Demand Estimates. *International Journal Of Production Economics*, V. 71, N. 1–3, P. 457–466, 2001.
- Syntetos, A. A.; Boylan, J. E. The Accuracy Of Intermittent Demand Estimates. *International Journal Of Forecasting*, V. 21, N. 2, P. 303–314, 2005.
- Syntetos, A. A.; Boylan, J. E.; Croston, J. D. On The Categorization Of Demand Patterns. *Journal Of The Operational Research Society*, V. 56, N. 5, P. 495–503, 2005.
- Teunter, R. H.; Duncan, L. Forecasting Intermittent Demand: A Comparative Study. *Journal Of The Operational Research Society*, V. 60, N. 3, P. 321–329, 2009.

Brazilian Journal of Development

Teunter, R. H.; Syntetos, A. A.; Babai, M. Z. Intermittent Demand: Linking Forecasting To Inventory Obsolescence. *European Journal Of Operational Research*, V. 214, N. 3, P. 606–615, 2011.

Teunter, R.; Sani, B. On The Bias Of Croston's Forecasting Method. *European Journal Of Operational Research*, V. 194, N. 1, P. 177–183, 2009.

Tubino, D. F. *Manual De Planejamento E Controle Da Produção*. 2. Ed. São Paulo: Atlas, 2000.
Wallström, P.; Segerstedt, A. Evaluation Of Forecasting Error Measurements And Techniques For Intermittent Demand. *International Journal Of Production Economics*, V. 128, N. 2, P. 625–636, 2010.