

Otimização de parâmetros no processo de predição de demanda intermitente**Optimization of parameters in the intermittent demand prediction process**

DOI:10.34117/bjdv6n9-215

Recebimento dos originais: 08/08/2020

Aceitação para publicação: 10/09/2020

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 Bonicontró, 93 – Fátima, 36572-152, Viçosa – MG, Brasil

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

RESUMO

O planejamento adequado de peças de reposição pode otimizar o estoque, favorecendo o nível de serviço requerido e minimizando faltas e excessos no inventário. É comum que para grande parte destes itens o monitoramento preditivo seja inviável, e uma alternativa de previsão seja a análise de séries temporais intermitentes. Para propor melhorias nesse processo, este artigo analisou a demanda real de peças de reposição de uma empresa do setor de mineração. Este artigo procurou avaliar como a otimização de parâmetros de suavização e inicialização pode beneficiar o desempenho de modelos de previsão. Para isto, foram aplicados métodos descritos na literatura, juntamente com recursos de otimização de parâmetros presentes no algoritmo de uma rotina computacional específica da plataforma R-Studio. Para pesquisas futuras, sugere-se uma associação com o aprendizado de máquina, que é uma área dedicada ao desenvolvimento de algoritmos que aprendem com os dados e que contribui para o processo de modelagem e previsão.

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

ABSTRACT

Proper planning of spare parts can optimize inventory, favoring the level of service required and minimizing shortages and excesses in the inventory. It is common that for most of these items, predictive monitoring is not viable, and an alternative for prediction is the analysis of intermittent time series. To propose improvements in this process, this article analyzed the real demand for spare parts from a mining company. This article sought to evaluate how the optimization of smoothing and initialization parameters can benefit the performance of prediction models. For this, methods described in the literature were applied, along with parameter optimization features present in the algorithm of a specific computational routine of the R-Studio platform. For future research, an association with machine learning is suggested, which is an area dedicated to the development of algorithms that learn from data and that contributes to the modeling and prediction process.

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. 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 de 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. 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 outros métodos foram propostos por Syntetos, Boylan (2005), Shale, Boylan e Johnston (2006) e Teunter, Syntetos e Babai (2011).

Temos, ainda, que a escolha dos parâmetros de suavização e valor de início para os componentes dos métodos citados também não é simples. Uma abordagem comum na literatura é aplicar um conjunto de parâmetros diferentes em todas as séries temporais de um conjunto de dados (SYNTETOS; BOYLAN, 2005; TEUNTER; SANI, 2009).

Outra abordagem para série temporal intermitente, é minimizar o erro, procurando os parâmetros ótimos para se chegar ao melhor resultado do modelo de predição escolhido. Esta foi a abordagem utilizada neste artigo ao descrever a utilização de parâmetros ótimos para cada série temporal, ao invés da escolha de parâmetros por enumeração simples. Este método para a otimização dos modelos de predição foi descrito em Kourentzes (2014).

Neste contexto, o objetivo geral deste artigo foi comparar o efeito da técnica de otimização de parâmetros, nos resultados de desempenho de modelos de predição para uma amostragem de demanda intermitente real de peças de reposição do setor de mineração. Para isto, foram realizadas predições utilizando os modelos 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*.

Como objetivos específicos, este artigo procurou descrever o processo de otimização de parâmetros através da minimização de funções de perda, indicar requisitos para separação da amostra para treino e teste, simular predições com modelos convencionais e alternativos 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 análises dos resultados e Seção 5 as conclusões.

2 REVISÃO DA LITERATURA

O propósito deste artigo é a contextualização do processo de otimização da função de perda para predição de demanda intermitente, como forma de se obter um melhor desempenho dos modelos. Pretende-se contribuir para o melhor entendimento do processo de otimização e os possíveis benefícios de sua utilização.

2.1 O MÉTODO DA SUAUIZACÃO EXPONENCIAL SIMPLES E O PROCESSO DE OTIMIZACÃO

A Suavização Exponencial Simples (SES) foi o primeiro método de predição 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 de Suavização Exponencial Simples (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).

Para o método SES, quanto menor a constante de suavização (parâmetro α), mais suavizada fica a curva e menor o efeito de grande variação na demanda. Quanto maior o valor da constante de suavização (α), menor o tempo de reação da série a mudanças bruscas na demanda. Desta forma, antes de implementar um modelo, diferentes valores da constante (α) devem ser testados e ajustados de acordo com as medidas de erro e tipo de série temporal.

O modelo da Suavização Exponencial Simples também constitui a base para os componentes de outros métodos como o modelo de Croston e seus derivados, que serão abordados neste artigo. Por isto, será elucidado o processo de otimização para a busca de parâmetros α (constante de suavização) e l_0 (predição inicial em $t = 0$) para o modelo SES.

2.1.1 Otimização da Suavização Exponencial Simples

Syntetos e Boylan (2005), argumentam que otimizar parâmetros para o método de demanda intermitente não é simples, devido a observações limitadas não nulas. A série de demanda curta prejudica a inicialização do método. Este problema poderia ser superado otimizando os parâmetros de suavização e de início, ajustando-os a série estudada. Esta abordagem foi descrita também em Kourentzes (2014).

Para a seleção de parâmetros de modelos de predição intermitente, é encontrado na literatura principalmente o método de enumeração simples (SYNTETOS; BOYLAN, 2005; TEUNTER; DUNCAN, 2009; WALLSTRÖM; SEGERSTEDT, 2010).

Existem várias formas para obtenção dos parâmetros α (constante de suavização) e l_0 (predição inicial em $t = 0$) da Suavização Exponencial Simples (SES). No modelo de enumeração simples, por exemplo, depois de calcular os valores de erro de predição para toda a sequência, o

valor da constante de suavização é alterado em um pequeno incremento, e um novo cálculo é realizado. Este procedimento é repetido até que todos os valores possíveis de parâmetros sejam enumerados. Seleciona-se o valor de α que resultou no menor valor de erro. Contudo, trabalhos como de Petropoulos e Nikolopoulos (2013), relatam que a seleção de parâmetros otimizados permite obter resultados melhores e diminui a tendenciosidade dos métodos, quando comparados com os mesmos métodos com valores arbitrados.

Para o parâmetro de predição inicial em $t = 0$ (l_0) também existem várias recomendações na literatura para sua escolha. Por exemplo, o valor inicial (l_0) pode ser definido como o primeiro elemento de uma sequência ($l_0 = y_1$), como a média da série observada ou a média de três, quatro ou mais elementos iniciais da sequência, com o objetivo de suavizar discrepâncias aleatórias. Porém, nenhum destes métodos pode garantir a ausência de erros nos primeiros estágios do algoritmo de suavização. Desta forma, para minimizar este impacto, utiliza-se o método de otimização para definir l_0 (valor inicial), que resultará no erro de predição mínimo.

Kourentzes (2014) demonstrou que a eficiência dos métodos, quando se recorre à utilização de parâmetros de suavização e valores iniciais otimizados, resultam em melhorias consideráveis na aplicação do modelo de Croston e seus derivados. O processo de otimização consiste em minimizar a função de perda do erro, para se obter os valores ótimos dos parâmetros dos componentes do modelo.

Para elucidar este processo, segue o desenvolvimento algébrico de Sanjoy (2011), iniciado pela equação de predição para Suavização Exponencial Simples (SES):

$$\hat{y}_{t+h|t} = l_t \quad (3)$$

$$l_t = \alpha y_t + (1 - \alpha) l_{t-1} \quad (4)$$

A otimização por meio de seleção dos parâmetros ótimos de inicialização, implica em determinar os parâmetros α e l_0 , em que l_0 é a predição inicial a considerar para o período zero e α é o parâmetro de suavização. Então, segue que:

$$l_t = \sum_{j=1}^{t-1} \alpha (1 - \alpha)^j y_{t-j} + (1 - \alpha)^t l_0 \quad (5)$$

$$\hat{y}_{t+h|t} = \sum_{j=1}^t \alpha (1 - \alpha)^{t-j} y_j + (1 - \alpha)^t l_0, \quad (0 \leq \alpha \leq 1) \quad (6)$$

Em que:

- $\hat{y}_{t+h|t}$ = Predição para o período posterior a t ;
- y_j = Demanda observada;
- l_0 = Valor inicial em $t = 0$;
- α = Declividade da curva $y_{(t+1)}$ (constante de suavização entre 0 e 1).

Para a etapa de minimização do erro, uma medida comum utilizada é o Desvio Quadrático Médio (DQM), entretanto, outras medidas podem ser utilizadas, como as que serão descritas na Seção 2.3.

O DQM utiliza exponenciação e, conseqüentemente, possui boas propriedades matemáticas que facilitam o cálculo de sua derivada em comparação com o Desvio Médio Absoluto (\bar{D}_{abs}):

$$D_{abs} = y_t - \hat{y}_{t|t-1} \quad (7)$$

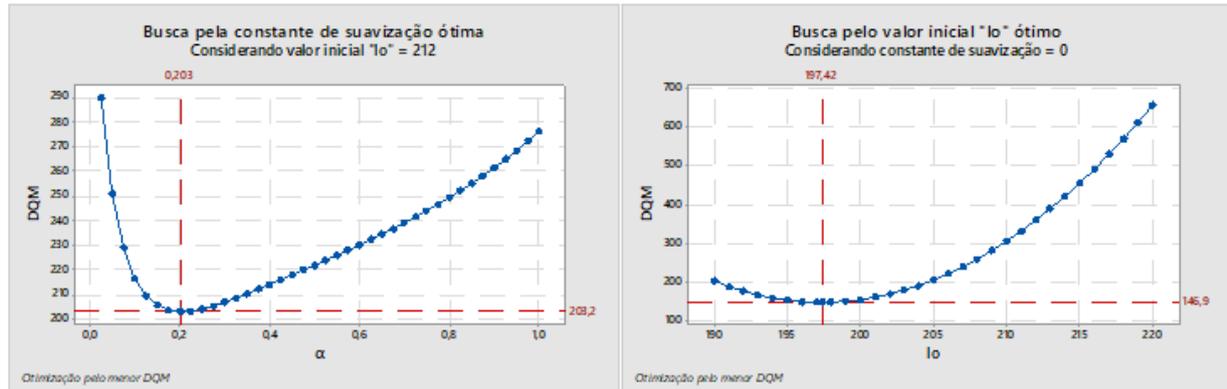
$$\bar{D}_{quad} = \frac{1}{T} \sum_{t=1}^T (y_t - \hat{y}_{t|t-1})^2 = \frac{1}{T} \sum_{t=1}^T (D_{abs})^2 \quad (8)$$

Combinando-se as Equações (6) e (8), em função de α e de l_0 , tem-se:

$$\bar{D}_{quad} = \frac{1}{T} \sum_{t=1}^T \left[(y_t - \sum_{j=1}^t \alpha(1-\alpha)^{t-j} y_j + (1-\alpha)^t l_0) \right]^2 \quad (9)$$

Minimizando a soma dos quadrados destes erros ao longo de toda a amostra, pode-se determinar o valor ideal do coeficiente α e o valor inicial l_0 para uma dada sequência. No entanto, para uma procura automática para vários itens, séries longas e com mais parâmetros de otimização, será necessário um grande esforço computacional e a solução numérica por algoritmos passa a ser uma melhor opção. Por exemplo, em alguns algoritmos de pacotes de predição estima-se os parâmetros por meio da máxima verossimilhança. Mas outros métodos não lineares também são disponíveis para uma função multivariável, como Mínimo Quadrados; Descida de Gradiente; Método de Gauss-Newton; Método de Levenberg-Marquardt; Método de Powell e Método Quasi-Newton.

Um exemplo de procura de parâmetros está ilustrado na Figura 1, mostrando a minimização do DQM para busca de valores ótimos dos coeficientes α e l_0 , neste caso, apresentados separadamente.

Figura 1 - Exemplo de busca de α e l_0 para uma Suavização Exponencial Simples (SES).

Como escolha para ilustração deste artigo, será descrito o Método de Powell. O método de Powell não requer cálculo de derivativos da função objetivo e pode demonstrar uma abordagem para otimização de predição.

2.1.2 Método das Direções Conjugadas de Powell

O método de Powell considera que toda função pode ser aproximada por uma função quadrática próxima do mínimo. Neste método, a cada passo a função a ser minimizada é aproximada localmente por uma função quadrática (SILVA, 2003):

$$f(x) = \frac{1}{2}x^T \cdot Q \cdot x + b^T \cdot x + c \quad (10)$$

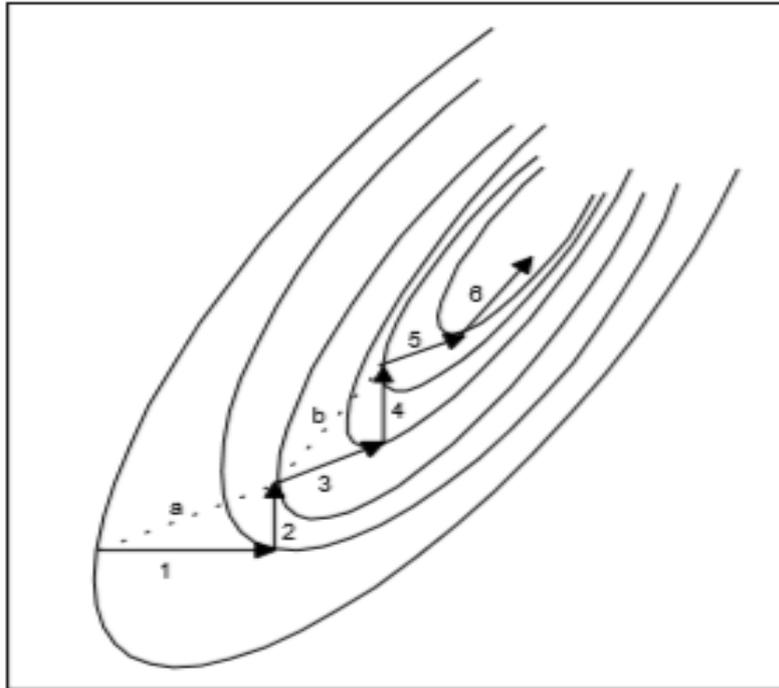
Em que:

- $f(x)$ = Função objetivo a ser minimizada;
- x = Vetor de variáveis independentes;
- Q = Matriz constante de dimensões compatíveis ao problema;
- b = Grandeza vetorial;
- c = Grandeza escalar.

O caminho seguido pelo algoritmo das direções conjugadas de Powell durante as iterações (Powell¹, 1964, citado por Silva, 2003) pode ser ilustrado pela Figura 2.

¹ Powell, M. J. . An efficient method for finding the minimum of a function of several variables without calculating derivatives. The Computer Journal, v. 7 (2), p. 155–162, 1964.

Figura 2 – Ilustração do processo de minimização pelo método de Powell.



2.2 MODELOS DE PREDIÇÃO

A maioria dos trabalhos sobre previsão de demanda intermitente faz referência ao artigo de Croston (1972). Este artigo seminal introduziu a ideia de separar tamanhos de demanda diferente de zero (z_t) e intervalos entre demandas (p_t) para obtenção de previsões melhores do que a tradicional Suavização Exponencial Simples (SES). Neste modelo, 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, os dois componentes são suavizados apenas quando uma demanda ocorre e \hat{y}_t é a demanda predita no período t , dada pela Equação (11):

$$\hat{y}_t = \frac{\hat{z}_t}{\hat{p}_t} \quad (11)$$

Com o intuito de aperfeiçoar o método de Croston (1972), foi apresentado por Syntetos e Boylan (2005) o estimador definido como Aproximação de Boylan e Syntetos (SBA), descrito na Equação (12).

$$\hat{y}_t = \left(1 - \frac{\alpha}{2}\right) \left(\frac{\hat{z}_t}{\hat{p}_t}\right) \quad (12)$$

No método de Aproximação de Syntetos e Boylan - *Syntetos Boylan Approximation* (SBA), foi inserido um corretor de viés na equação de predição, 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).

Shale, Boylan e Johnston (2006) mostraram posteriormente que, se a quantidade de pedidos de um determinado item seguir um processo de Poisson, um estimador mais apropriado é dado pela Equação (13), que define o método SBJ.

$$\hat{y}_t = \left(1 - \frac{\alpha}{2 - \alpha}\right) \left(\frac{\hat{z}_t}{\hat{p}_t}\right) \quad (13)$$

Já o método TSB, foi apresentado em 2011 por Teunter, Syntetos e Babai (2011) e trata da questão da obsolescência do inventário. O método permite que o valor da predição se aproxime de zero em períodos contínuos sem demanda e isto o torna diferenciado em relação aos demais métodos, pois permite tomar decisões de gestão de estoques.

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 e a estimativa da probabilidade de ocorrência é atualizada a cada período. O estimador é dado pela Equação (14):

$$\hat{y}_t = \hat{p}_t \cdot \hat{z}_t \quad (14)$$

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.

2.3 MEDIDAS DE ERRO

Para comparar o desempenho de cada método de predição de demanda e obter o benefício do processo de otimização descrito, um processo típico é a utilização de medidas de erros ou de

acurácia operacional. Estas medidas podem ser utilizadas como funções de perda no processo de otimização das predições (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):

$$\bar{D}_{abs} = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i \quad (15)$$

Considerando a otimização de séries temporais convencionais, uma outra função de perda popular é o Desvio Quadrático Médio (DQM). Esta foi a medida utilizada como exemplo no processo de otimização da SES, na Seção 2.1.1.:

$$\bar{D}_{quad} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (16)$$

A aplicabilidade dessas medidas de erro tem sido contestada para séries temporais intermitentes, no entanto, por alguns autores. Estas medidas tendem a polarizar as predições em favor da predição de demanda zero e não forneceriam boa aproximação para as decisões de inventário. 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.

Outras medidas de somatório acumulativo foram então sugeridas, visando impedir a preferência pelas predições de demanda zero em uma série temporal muito intermitente (KOURENTZES, 2014).

A propriedade destas novas predições poderia ser utilizada para derivar outras metodologias para otimização, considerando a taxa acumulativa do erro como a Taxa Média Absoluta (TAM) e a Taxa do Quadrado da Média (TQM). O detalhe envolvendo a TAM e a TQM é ajustar as predições de demanda intermitente pela demanda média por período, ao invés da demanda realizada (KOURENTZES, 2014), Equações (17) e (18):

$$\bar{T}_{abs} = \sum_{i=1}^n \left| \hat{y}_i - \frac{1}{n} \cdot \sum_{j=1}^n y_j \right| \quad (17)$$

$$\bar{T}_{quad} = \sum_{i=1}^n \left(\hat{y}_i - \frac{1}{n} \cdot \sum_{j=1}^n y_j \right)^2 \quad (18)$$

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.

3 METODOLOGIA

Este artigo foi realizado em três etapas. Uma abordagem descritiva, com o objetivo de descrever os fatos, analisá-lo, 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 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 (LAZARIN et al., 2019). 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), 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.

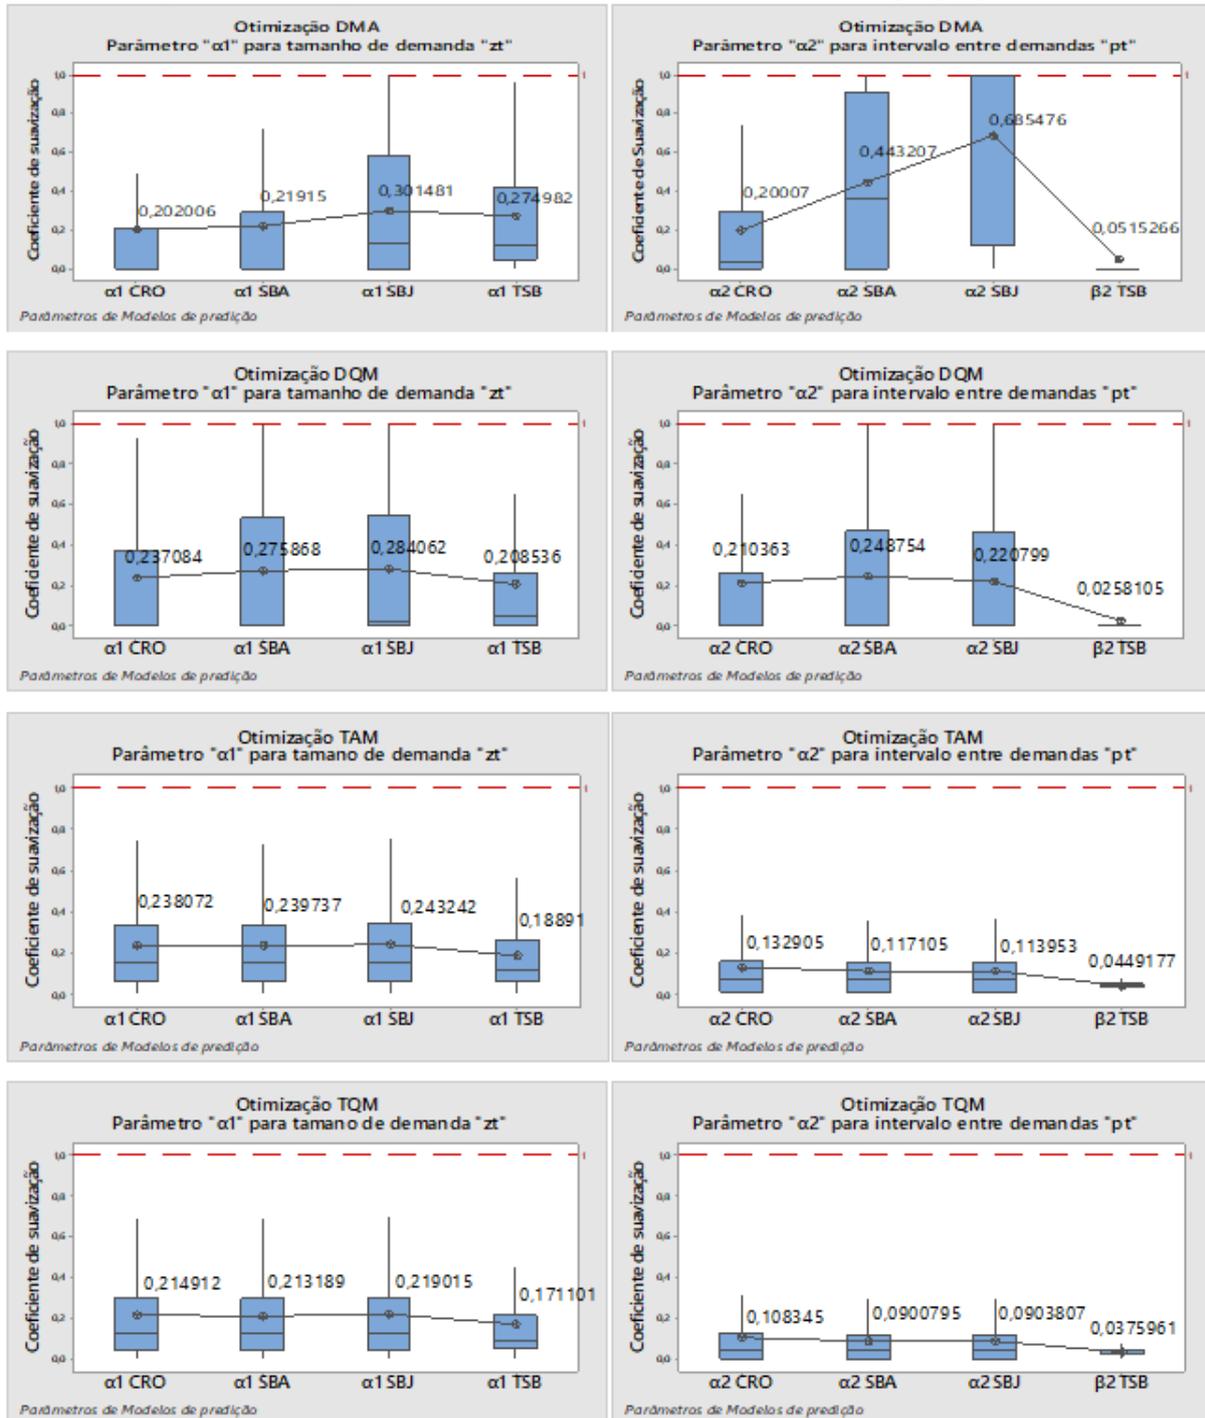
4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

A seguir serão apresentadas as análises dos parâmetros de suavização e as avaliações de desempenho dos modelos e otimizações conforme a metodologia adotada.

4.1 ANÁLISE DE PARÂMETROS DE SUAVIZAÇÃO PARA DEMANDA INTERMITENTE

Foram avaliados os efeitos das otimizações dos parâmetros de suavização do tamanho da demanda (α_1), do intervalo entre demandas (α_2) e probabilidade de demanda ($\beta_2 - \text{TSB}$). Os resultados destas avaliações estão apresentados nos gráficos da Figura 3.

Por análise comparativa foi possível identificar o comportamento irregular das constantes de suavização para a otimização por meio do DMA. A principal variação entre o DMA e as demais otimizações, ocorre para o parâmetro α_2 , a constante de suavização do intervalo entre demandas. Os valores destes parâmetros são bem menores e nivelados para as otimizações por meio de TAM e TQM.

Figura 3 - Otimizações usando o DMA, DQM, TAM, TQM (média, α_1 , α_2 ; β_2 - TSB).

Os resultados encontrados coincidem com Kourentzes (2014), que afirma que os valores dos parâmetros de DMA e DQM costumam ser mais altos, resultando em modelos mais sensíveis e que não funcionam bem para a demanda intermitente. Também concorda com a evidência de que as otimizações TAM e TQM possuem parâmetros resultantes mais baixos, e consequentemente os diferentes métodos de previsão funcionam melhor. Considerando que as séries de demanda intermitente são tipicamente curtas e são aconselháveis baixos parâmetros de suavização, as

predições podem ser influenciadas pelos valores de inicialização. O processo de otimização evita valores de parâmetros arbitrados, que podem não ser representativos para a série estudada e por consequência levar a piores predições. Na literatura, os parâmetros de suavização de métodos de demanda intermitente são tipicamente pequenos (SYNTETOS; BOYLAN, 2005; TEUNTER; SYNTETOS; BABAI, 2011).

Um menor valor da constante de suavização combinado com um menor valor inicial, aumenta a possibilidade de menor erro para predições de demanda intermitente (WALLSTRÖM; SEGERSTEDT, 2010). O objetivo de se encontrar uma constante de suavização adequada é reduzir o tamanho do estoque de segurança afetado pelo erro de predição. O processo de otimização também pode contribuir na automatização em sistemas de predição e software em modelos como Croston e seus derivados (KOURENTZES, 2014).

Especificamente para o método TSB, foi observado os menores valores do parâmetro de probabilidade de demanda (β_2) em relação ao parâmetro de tamanho de demanda (α_1). Este resultado sugere conformidade à constatação de Teunter, Syntetos e Babai (2011), de que o parâmetro de suavização da probabilidade de demanda deve ser menor que o parâmetro de suavização do tamanho da demanda. Para comparar o efeito destes parâmetros no desempenho das otimizações e modelos, foram analisadas as simulações de predição a seguir.

4.2 ANÁLISE DOS RESULTADOS DAS OTIMIZAÇÕES E MODELOS

Para a medida de erro DMAE, o melhor benefício na amostra de teste e treino foi obtido para a otimização DMA (Tabela 1) e para o método de predição ZERO (Tabela 2). Este resultado era em parte esperado, uma vez que a função de perda utilizada teve origem na própria medida de erro (DMA).

Tabela 1 - Classificação da medida de erro DMAE, para séries intermitentes, usando otimização.

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

Tabela 2 - Classificação da medida de erro DMAE, para séries intermitentes, usando modelos de predição.

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

Os resultados das medidas DQME, TAME e TQME foram consolidados na forma de uma única classificação de posição, por terem apresentados resultados semelhantes. Mesmo o DQME sendo uma medida pontual, seus resultados se aproximaram dos resultados das medidas das taxas acumulativas TAME e TQME.

Na Tabela 3, observa-se que os melhores desempenhos foram obtidos com a otimização das taxas acumulativas 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 propostas por Kourentzes (2014).

Quanto ao desempenho dos métodos para as medidas DQME, TAME e TQME observou-se na Tabela 4 que os melhores resultados de desempenho na amostra de teste e de treino foram para os métodos SBA e SBJ. Já o método CROSTON mostrou desempenho inferior em relação ao seu sucessor, SBA.

O método TSB destacou-se por apresentar flexibilidade, ficando em uma posição intermediária. O método é interessante para objetivos de inventário, pois trata a obsolescência ao predizer uma diminuição gradual de demanda, a ponto desta se tornar zero para itens descontinuados. Esta característica favorece o processo de automatização de predições.

Tabela 3 - Classificação das medidas de erros DQME, TAME e TQME, para séries intermitentes, 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

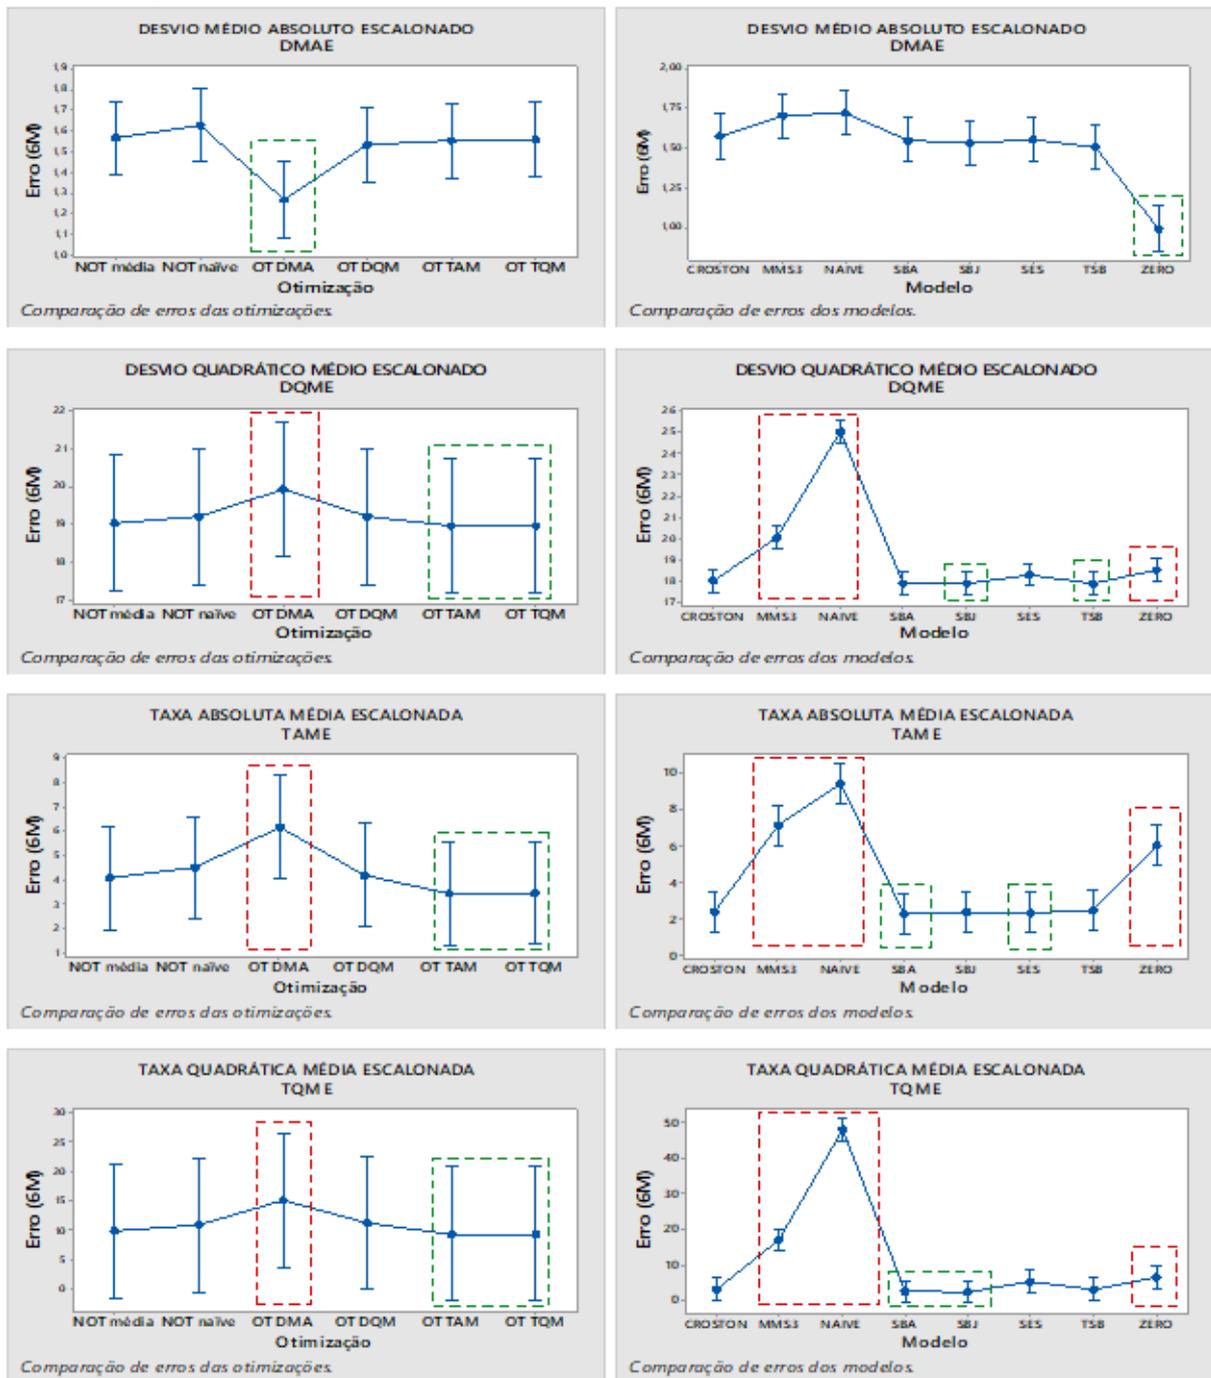
Tabela 4 - Classificação das medidas de erros DQME, TAME e TQME, para séries intermitentes, usando modelos de predição.

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
<i>SBA</i>	1,33	1,33	1,67	2,00	1,67
<i>CROSTON</i>	3,33	3,33	3,33	3,67	3,44
<i>SBJ</i>	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

Para ilustrar o padrão de comportamento dos erros das otimizações e respectivos modelos, segue o exemplo comparativo para o horizonte (h+6) meses, (Figura 4).

Observa-se na Figura 4 que a medida de erro DMAE foi afetada pelo benefício da predição zero. Nesta medida, uma predição sendo zero todo o tempo seria a preferida, mesmo que esta predição seja inútil para um processo de produção. Outra observação nas comparações da Figura 4, foi a inversão do benefício da otimização DMA que, para as medidas DQME, TAME e TQME apresentou pior desempenho.

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



Os resultados sugerem, portanto, a otimização pelas funções de perda TAM e TQM para demandas intermitentes, pois apresentaram tanto menores parâmetros de suavização, como também isto refletiu em menores erros para as medidas DQME, TAME e TQME. Já a otimização pela função de perda DMA indicou preferência para a predição ZERO, e por isto não seria a opção indicada para séries intermitentes.

5 CONCLUSÕES

A predição de itens com demanda intermitente próximas ao valor real é um dos objetivos para uma boa gestão de inventário. Uma proposta para se obter melhor desempenho de modelos de predições para a demanda intermitente é a otimização de parâmetros de suavização e de valores iniciais. O processo de otimização dispensa a necessidade de utilizar valores de parâmetros arbitrados, que podem não ser representativos para a série estudada e por consequência levar a piores predições.

Com o objetivo de identificar benefícios desta técnica em modelos de predição descritos na literatura, foram realizadas simulações cujos resultados de desempenho foram avaliados. Para isto, foi utilizada uma amostragem real de peças de reposição do setor de manutenção na indústria de mineração. Procurou-se mensurar e identificar padrões de comportamento dos erros, a partir de dados reais, conforme medidas e métodos utilizados.

Os parâmetros ótimos foram obtidos pelo processo de otimização seguindo a abordagem de Kourentzes (2014). Com base nas análises, concluiu-se que é possível obter benefício ao se otimizar os parâmetros de modelos de predições: constante de suavização e valor de inicialização para o tamanho da demanda, e para o intervalo entre demandas. Estes benefícios foram observados na amostra de teste da base utilizada. No entanto, é necessário atentar para a importância da escolha da medida de erro adequada para este processo.

Neste estudo o melhor benefício de desempenho observado ocorreu para as otimizações TAM e TQM e, conseqüentemente, com tendência à escolha dos modelos SBA e SBJ. Concluiu-se que estes métodos demonstram ser mais adequados ao processo de controle de inventário combinado ao processo de produção. Destaca-se que estes resultados estão relacionados à natureza da amostra da pesquisa, e novos estudos são necessários para outros conjuntos de dados.

Constatou-se para o método TSB, baixos valores dos parâmetros analisados, compatíveis com a demanda intermitente. Mesmo tendo obtido resultados intermediários, o método oferece o benefício de controle automático de itens obsoletos do inventário.

Este artigo avaliou, portanto, a opção de seleção de parâmetros ótimos para modelos de predição de demanda intermitente de peças de reposição, ao invés da enumeração simples. E indicou o possível benefício para a automatização de predições em softwares, já que os sistemas ERP atuais, exigem que o usuário indique parâmetros arbitrados para alguns modelos.

Recomenda-se 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.

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 previsões.

Para novas pesquisas, sugere-se buscar formas de medir a sensibilidade dos erros em relação às alterações das constantes de suavização e valores iniciais. 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 previsão, indicam-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 artigo.

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.
- HADDAD, M. F. **Estudo comparativo entre sínteses de controle robusto paramétrico**. Rio de Janeiro: Instituto Militar de Engenharia, 2001.
- HYNDMAN, R. J.; ATHANASAUPOLOS, G. **Forecasting: principles and practice**. Disponível em: <<https://www.otexts.org/fpp2>. Acesso em 20/11/19>.
- 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.
- LAZARIN, D. F.; STURARAO, V. A.; SILVA, G. B.; CASTILLO, L. A. M. Análise de métodos de previsão de demanda de séries temporais: estudo de caso em uma empresa fabricante de máquinas e equipamentos eletromecânicos. **Brazilian Journal of Development**, Curitiba, v. 5, n. 12, p. 28479-28492, 2019.
- MAKRIDAKIS, S.; WHEELRIGHT, S. C.; HYNDMAN, R. J. **Forecasting - Methods and Applications**. 3. ed. New York: John 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.
- PETROPOULOS, F.; NIKOLOPOULOS, K. Optimizing Theta model for monthly data. **ICAART 2013 - Proceedings of the 5th International Conference on Agents and Artificial Intelligence**, v. 1, p. 190–195, 2013.
- POWELL, M. J. . An efficient method for finding the minimum of a function of several variables without calculating derivatives. **The Computer Journal**, v. 7 (2), p. 155–162, 1964.
- SANJOY, K. P. Determination of exponential smoothing constant to minimize mean square error and mean absolute deviation. **Global Journal of Research in Engineering**, v. 11, n. 3, p. 30–34, 2011.
- 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, E. C. N. **PMR 5215 - Otimização Aplicada ao Projeto de Sistemas Mecânicos**. Departamento de Engenharia Mecatrônica e Sistemas Mecânicos, Escola Politécnica da USP, 2000.
- 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.

Brazilian Journal of Development

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.; 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.