

Modelos de séries temporais: a análise da acurácia das previsões da demanda de uma linha de produtos em empresa do setor do vestuário

Time series models: an analysis of demand forecast accuracy for a product line in a clothing company

Guilherme Issao Chiba¹ - Federal University of Santa Catarina, Brazil

Mônica Maria Mendes Luna² - Federal University of Santa Catarina, Brazil

RESUMO

Objetivo – O objetivo deste artigo é comparar o desempenho de métodos de previsão de séries temporais para uma linha de produtos de uma empresa de vestuário com base na acurácia das previsões.

Metodologia – Este artigo apresenta um estudo de caso em uma grande empresa de vestuário. Diferentes métodos foram usados para obter dados quantitativos e qualitativos. Os dados qualitativos foram usados, principalmente, para descrever o processo de previsão de demanda e os quantitativos para fazer previsões. Três modelos de séries temporais foram aplicados e uma análise da acurácia das previsões feita usando diferentes medidas de erro.

Resultados – Dos três modelos de séries temporais usados, o método estático é indicado para a linha de produtos considerada, principalmente quando se considera o impacto dos erros de previsão sobre os custos de manutenção e de rupturas de estoques. Também são identificadas vantagens dos métodos quantitativos e analisada a acurácia das previsões, buscando destacar a importância desse procedimento na escolha do modelo.

Contribuições – Poucos estudos descrevem detalhadamente o uso de métodos quantitativos, especialmente descrevendo o processo de previsão e a análise dos erros. Este artigo descreve a aplicação de três modelos de séries temporais para prever a demanda da principal linha de produtos de uma grande empresa brasileira de confecções. Além disso, sugere como analisar o impacto dos erros de previsão nas decisões relativas aos estoques e enfatiza a importância da previsão para apoiar as decisões gerenciais, tema raramente abordado na literatura.

Palavras-chave - Previsão de demanda. Séries temporais. Método estático. Modelo de Winter.

ABSTRACT

Purpose – The purpose of this paper is to compare the performance of time series forecasting methods for a product line in a clothing company by analyzing the accuracy of demand forecasts

Design/methodology/approach – This paper presents a case study in a large clothing company. Several methods were used to obtain both quantitative and qualitative data. Qualitative data were mainly used to describe the demand forecasting process and the quantitative data to make forecasts. Three time series models were applied to make forecasts and an accuracy analysis was done using different error measures.

Findings – Regarding the three time series models applied in this case study, the static one is suitable for the product line considered, especially taking into account the impact of forecasting errors for carrying inventory and stockouts. We also identified advantages of quantitative methods and highlighted the importance of the forecast's accuracy evaluation to choose an adequate model.

Originality/value – There are few studies describing in detail the use of quantitative forecasting methods, specially addressing the forecasting process and error accuracy evaluation. This paper describes the use of three different time-series models to forecast the demand of the main product line in a large Brazilian clothing company.

Furthermore, it suggests how to analyze the impact of forecasting errors on level inventory decisions and emphasizes forecast's accuracy importance to support management decisions, a topic rarely addressed in the literature.

Keywords - Demand forecasting. Time series forecast. Static methods. Winter Model

1.guilherme.chiba@gmail.com, <https://orcid.org/0000-0003-1268-5476>; 2 R. Eng. Agrônomo Andrei Cristian Ferreira, s/n - Trindade, Florianópolis - SC, 88040-900, monica.luna@ufsc.br, <https://orcid.org/0000-0001-9884-7493>

CHIBA, G.J.; LUNA, M.M.M. Modelos de séries temporais: a análise da acurácia das previsões da demanda de uma linha de produtos em empresa do setor do vestuário. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 15, n. 4, p. 219 - 251, 2020.

DOI: <http://dx.doi.org/10.15675/gepros.v15i4.2664>

1. INTRODUÇÃO

As previsões são essenciais para o gerenciamento das diversas atividades da produção de uma empresa, como planejamento da produção, previsão orçamentária, dimensionamento de equipes e de ativos, dentre outras (DALRYMPLE, 1975; TUBINO, 1999; PELLEGRINI; FOGLIATTO, 2001). As boas previsões reduzem as incertezas e podem contribuir para a obtenção de melhores resultados por parte das empresas ao permitir a definição de níveis de estoques adequados, a melhor utilização de ativos com redução de desperdícios de mão-de-obra e materiais e, no âmbito da cadeia de suprimentos, uma melhor coordenação das atividades entre fornecedores e clientes.

Uma das dificuldades ao se trabalhar com previsões consiste em definir quais os métodos a adotar, considerando as diversas peculiaridades e limitações impostas pelo cenário e realidade de cada empresa (LINDBERG; ZACKRISSON, 1991; LEMOS, 2006). Atualmente, é possível utilizar ferramentas sofisticadas para tratar grandes volumes de dados e realizar previsões acuradas (HOFMANN; RUTSCHMANN, 2018). No entanto, com base em pesquisa sobre os métodos de previsão usados por empresas brasileiras, Cecatto e Belfiore (2015) observam uma predominância do uso de métodos simples, como analogia histórica, análise de mercado e média móvel. Armstrong e Fildes (2006) também destacam que, apesar do progresso no desenvolvimento de melhores métodos de previsão, a difusão desses métodos tem sido decepcionante.

Além da acurácia das previsões, diversos fatores influenciam a escolha dos métodos de previsão. A facilidade de entendimento e de uso do método, o horizonte da previsão, o custo e tempo despendido, e a disponibilidade de *software* para a previsão são alguns desses fatores (CECATTO; BELFIORE, 2015). A facilidade de entendimento é indicada como um dos fatores mais importantes na escolha dos referidos métodos. A acurácia, ou o erro da previsão, por sua vez, é citado como um critério relevante para identificar o estágio de maturidade do processo de previsão (ARMSTRONG, 2001 *apud* CECATTO; BELFIORE, 2015).

O erro faz parte do processo de previsão visto que “as previsões estão sempre erradas”, mas esse deve, dentro do possível, ser minimizado (CHOPRA; MEINDL; JUARÉZ *et al.*, 2016). O erro pode ser usado como um indicador de desempenho do processo de previsão e, como afirma Tubino (1997) e Chopra e Meindl (2016), o seu monitoramento é

importante, principalmente, porque indica se o método de previsão é adequado ou se um novo método deve ser adotado. Além disso, é com base na magnitude desse erro que eventuais planos de contingência são elaborados, como a definição de ações a serem tomadas no caso de excesso ou falta de produtos.

O presente trabalho avalia a acurácia da previsão da demanda agregada de uma linha de produtos de uma empresa de grande porte do setor do vestuário. Usando três métodos de séries temporais, são feitas previsões para os doze meses de 2018. O método estático e dois métodos de suavização exponencial – modelos de Winter aditivo e multiplicativo – são aplicados usando dados de vendas referente ao período de 2014 a 2017. Os erros de previsão são calculados comparando os valores obtidos, com a aplicação dos referidos métodos, aos valores das vendas de 2018.

Uma análise do impacto da adoção destes modelos sobre os custos de estoques também é apresentada neste artigo com o intuito de destacar a relação entre os erros de previsão e as decisões nos negócios.

2. REFERENCIAL TEÓRICO

A previsão de demanda consiste em estimar e analisar a demanda futura para determinado produto, componente ou serviço com base em informações do histórico de vendas, estimativas de especialistas e diferentes técnicas de previsão (VERÍSSIMO *et al.*, 2013). Em função do tipo de informação usada para realizar a previsão, pode-se identificar três diferentes abordagens: qualitativa, que se baseia em opiniões e conhecimentos de especialistas; quantitativa, que utiliza histórico de vendas e ferramentas estatísticas para análise dos dados; e mistas, que conjugam ambas as técnicas (TUBINO, 1997).

Os métodos qualitativos têm natureza subjetiva e, por isso, devem ser utilizados com cautela, pois podem refletir o comportamento, com as tendências e vieses, daqueles que realizam a previsão (TUBINO, 1999; PELLEGRINI; FOGLIATTO; SPEDDING; CHAN, 2000; LEMOS, 2006). No entanto, estes métodos são muito indicados em situações em que não se dispõe de histórico de demanda ou em que não há tempo suficiente para aplicar métodos quantitativos ou, ainda, quando o cenário, mercado ou quadro econômico e político é muito instável (TUBINO, 1997; JAIN; MALEHORN, 2006; PEINADO; GRAEML, 2007). Para sua aplicação, é necessário que os envolvidos na elaboração da previsão conheçam não

somente as características dos produtos e serviços ofertados, mas também as particularidades e comportamento dos consumidores (SANDERS; MANRODT, 1994).

Dentre os métodos qualitativos, pode-se citar: análise de cenários, analogia histórica, pesquisa de mercado e método Delphi.

A análise de cenários consiste em gerar diversas previsões possíveis de acordo com possíveis ações e acontecimentos atuais e futuros (ROSSETTO *et al.*, 2011; RIBEIRO *et al.*, 2016). Schoemaker (1993) sugere que sejam elaboradas, pelo menos, previsões para três diferentes cenários: o mais provável de ocorrer, um pessimista e um otimista.

A analogia histórica procura elaborar previsões com base no desempenho documentado de outros produtos que apresentem características semelhantes àquelas dos produtos cujas previsões estão sendo elaboradas (ROSSETTO *et al.*, 2011). Esse é um dos métodos mais utilizados pelas empresas em situações nas quais não há histórico de vendas, o que é frequentemente observado no caso de previsão para novos produtos (LEMOS, 2006; JAIN; MALEHORN; RIBEIRO *et al.*, 2016).

A pesquisa de mercado, por sua vez, consiste em uma pesquisa sistemática e objetiva que visa a obter informações necessárias para se tomar uma decisão correta como, por exemplo, entender a necessidade e desejos dos clientes e quais suas intenções de compra para o novo produto proposto (ZAMBERLAN, 2008). Na aplicação desse método, coletam-se informações de uma amostra de consumidores, por meio de perguntas objetivas, e as respostas são analisadas com uso de ferramentas estatísticas a fim de possibilitar as previsões (ROSSETTO *et al.*, 2011; RIBEIRO *et al.*, 2016).

A pesquisa de mercado pode ser aplicada diretamente às equipes de vendas, caso em que cada equipe elabora uma previsão, as quais serão, posteriormente, agregadas para gerar uma previsão final consolidada (ROSSETTO *et al.*, 2011; RIBEIRO *et al.*, 2016). Essa é uma alternativa baseada na experiência e visão da equipe de vendas, pois é, provavelmente, o grupo que mais conhece os clientes e melhor pode estimar as quantidades que esses estão dispostos a consumir (RITZMAN; KRAJEWSKI, 2003).

O Método Delphi, por sua vez, pode ser definido como um método eficaz para orientar o processo de comunicação de um grupo de indivíduos, sendo adequado para lidar com problemas complexos (LINSTONE *et al.*, 1975). Assim, a previsão é elaborada com base na opinião de um grupo seletivo de pessoas e estruturada para garantir que o resultado considere as percepções de todos (LEMOS, 2006; ROSSETTO *et al.*, 2011). As pessoas desse grupo

devem ser capazes de opinar sobre a previsão que será elaborada, mas não devem desempenhar atividades rotineiras diretamente ligadas à elaboração da previsão (RIBEIRO *et al.*, 2016). O papel fundamental do responsável pelas previsões, quando se usa o Método Delphi, é mediar a comunicação entre os especialistas e conciliar suas análises para gerar um resultado comum (LINSTONE *et al.*, 1975).

Enquanto os métodos qualitativos incorporam aspectos subjetivos, os métodos quantitativos se apoiam em premissas objetivas e supõem que os fatores influenciadores na demanda passada continuarão presentes na demanda futura e continuarão a influenciá-la como influenciaram as demandas anteriores (TUBINO, 1997; VERÍSSIMO *et al.*, 2013).

Os métodos quantitativos são classificados em duas categorias: séries temporais e métodos causais. As séries temporais relacionam a demanda futura com dados históricos, e com a mudança dos dados ao longo do tempo, enquanto os métodos causais relacionam a demanda futura com uma ou mais variáveis que justifiquem a série histórica (TUBINO, 1997; CORRÊA *et al.*, 2001).

O objetivo da aplicação de séries temporais é estimar os componentes da demanda para elaborar a equação que matematicamente represente seu comportamento (CHOPRA; MEINDL, 2016). As séries temporais são os métodos quantitativos mais simples, mais fáceis de aplicar e entender e, quando elaboradas adequadamente, apresentam bons resultados (TUBINO, 1997, 1999; JAIN; MALEHORN, 2006).

As previsões usando séries temporais podem ser realizadas considerando que os componentes da demanda se mantêm constante ao longo do tempo – métodos estáticos – ou são atualizados à medida que novos registros são observados – métodos adaptativos (CHOPRA; MEINDL, 2016).

2.1. Métodos estáticos

Ao aplicar métodos estáticos para realizar a previsão de demanda, assume-se que os componentes da demanda – ciclo, sazonalidade e tendência – não variam com os novos registros de demanda e podem ser estimados com base em dados históricos (CHOPRA; MEINDL, 2016). Estes componentes são definidos, segundo Morretin e Toloí (1987), Werner (2005) e Santos *et al.* (2017), como segue:

- ciclo é caracterizado pelo comportamento ondulatório que, ao longo de vários anos, tende a se repetir;

- sazonalidade é caracterizada pelo comportamento ondulatório de curta duração, em geral, inferior a um ano;
- tendência indica o sentido do deslocamento dos dados ao longo dos anos.

Quando uma série temporal não apresenta o comportamento de tendência, ou seja, seus valores de demanda variam em torno de uma média ou nível, tem-se uma série estacionária (MORRETIN e TOLOI, 1987). Além desses componentes sistemáticos, há um componente aleatório da demanda, o ruído ou erro, que constitui variabilidades intrínsecas não explicadas com base nos componentes anteriores (MORRETIN e TOLOI, 1987).

Para aplicação do modelo estático, inicialmente, deve-se retirar o componente sazonal da série histórica, calculando-se a média de vendas dos p períodos registrados no período t . O cálculo depende da paridade do período p estipulado. Cada componente da série histórica dessazonalizada (\bar{D}_t) é estimada, conforme apresentado em Chopra e Meindl (2016) e mostrado na Equação 2.1.

$$\bar{D}_t = \begin{cases} \frac{(D_{t-\frac{p}{2}} + D_{t+\frac{p}{2}} + 2 * \sum_{i=t+1-\frac{p}{2}}^{t-1+\frac{p}{2}} D_i)}{2p}, & \text{para } p \text{ par} \\ \frac{\sum_{i=t-\frac{p-1}{2}}^{t+\frac{p-1}{2}} D_i}{p}, & \text{para } p \text{ ímpar} \end{cases} \quad (2.1)$$

Segundo os autores, há uma relação linear entre a demanda dessazonalizada e o período (t), como apresentada na Equação 2.2. A componente de tendência (T) é interpretada como a taxa de crescimento das vendas ao longo dos períodos (t) e o nível (L) como a demanda não sazonal para o primeiro período da série em $t = 0$.

$$\bar{D}_t = L + T * t \quad (2.2)$$

A estimativa dos valores das componentes da demanda é feita aplicando-se uma regressão linear simples com a demanda dessazonalizada (\bar{D}_t) e os diferentes períodos analisados. Com os valores dos componentes de nível e tendência, calcula-se o valor de cada

um dos fatores sazonais (\bar{S}_t) da série histórica como a razão entre a demanda real (D_t) pela demanda dessazonalizada (\bar{D}_t) de cada período, como apresentado na Equação 2.3 (CHOPRA; MEINDL, 2016).

$$\bar{S}_t = \frac{D_t}{\bar{D}_t} \quad (2.3)$$

Os componentes sazonais (S_i) utilizados para a previsão de demanda são iguais em períodos semelhantes, ou seja, todos os componentes sazonais do primeiro período sazonal da série são iguais e são calculados como a média dos fatores sazonais (\bar{S}_t) semelhantes, como apresentado na Equação 2.4. Nessa equação, r representa o número de vezes que o período sazonal se repete na série histórica e i o período para o qual se está sendo calculado o fator sazonal (CHOPRA; MEINDL, 2016).

$$S_i = \frac{\sum_{j=0}^{r-1} \bar{S}_{i+j*p}}{r} \quad (2.4)$$

Por fim, a previsão de demanda para os períodos futuros da série histórica é encontrada multiplicando-se, para cada período ($t + n$), sua previsão dessazonalizada por sua componente sazonal como apresentado a seguir (CHOPRA; MEINDL, 2016).

$$F_{t+n} = \bar{D}_{t+n} * S_{t+n} \quad (2.5)$$

Na Equação 2.5, F_{t+n} representa a previsão para o período n futuro, \bar{D}_{t+n} a estimativa da demanda sem sazonalidade para o período n futuro e S_{t+n} a estimativa sazonal para o mesmo período (CHOPRA; MEINDL, 2016).

2.2. Métodos adaptativos

As previsões adaptativas são elaboradas atualizando as estimativas dos componentes da demanda a cada novo registro observado, como é o caso dos métodos de médias móveis e alisamento exponencial. Os métodos de alisamento exponencial incluem os métodos de suavização exponencial simples, suavização exponencial de séries com tendência, ou modelo

de Holt, e suavização exponencial de séries com tendência e com sazonalidade, modelos de Winter aditivo e multiplicativo.

A aplicação dos métodos de previsão adaptativas, segundo Chopra e Meindl (2016), segue quatro passos:

- i. iniciar calculando as estimativas iniciais de nível (L_0), tendência (T_0) e índices sazonais (S_1, \dots, S_p);
- ii. prever a demanda para o período $t + 1$;
- iii. estimar erro por meio da comparação da demanda real com a prevista para o período $t+1$;
- iv. modificar estimativas de nível, tendência e fatores sazonais de acordo com o erro estimado.

As estimativas encontradas no passo iv são utilizadas como base para as estimativas futuras (CHOPRA; MEINDL, 2016).

2.2.1 Média móvel

A média móvel é recomendada para previsões cuja série histórica apresenta um comportamento estável (TUBINO, 1997; RIBEIRO *et al.*, 2016). Neste método, define-se a quantidade de períodos (N) que serão considerados para a elaboração da previsão (F_t) e calcula-se a média de vendas dos N períodos mais recentes como apresentado por Juárez *et al.* (2016):

$$F_t = \frac{\sum_{i=1}^N C_i * D_{t-i}}{\sum_{i=1}^N C_i} \quad (2.6)$$

Na Equação 2.6, D_t representa a demanda real para cada período (t), N representa o número total de períodos considerados da série histórica e C_i o peso atribuído para demanda de cada período (JUÁREZ *et al.*, 2016). Os registros anteriores aos N períodos mais recentes não são considerados para a elaboração da previsão e, dependendo da quantidade de períodos selecionados, a previsão pode apresentar alta ou baixa responsividade a novos registros (CHOPRA; MEINDL, 2016). Normalmente, ao atribuir pesos (C_i) diferentes para cada período, os registros mais recentes recebem pesos maiores (TUBINO, 1997).

2.2.2 Alisamento exponencial

Os métodos de alisamento exponencial utilizam ponderações distintas para cada registro da série temporal, decaindo sua relevância exponencialmente com o tempo e sendo corrigidos pelo erro da previsão período a período (PELLEGRINI; FOGLIATTO, 2001; BEZERRA, 2006; JUÁREZ *et al.*, 2016;).

O alisamento exponencial simples é recomendado quando a série temporal se mantém constante ou próximo de um nível (PELLEGRINI; FOGLIATTO, 2001). Para sua aplicação, inicialmente, define-se a estimativa inicial L_0 como a média dos n valores de venda da série histórica, como apresentado na Equação 2.7 (CHOPRA; MEINDL, 2016).

$$L_0 = \frac{1}{n} * \sum_{i=1}^n D_i \quad (2.7)$$

Após observar a demanda realizada em $t + 1$, a estimativa de nível (L_{t+1}) é revista com base na demanda observada (D_{t+1}) e na constante de alisamento de nível α ($0 < \alpha < 1$), como apresentado na Equação 2.8 (CHOPRA; MEINDL, 2016). A previsão para o próximo e para todos os próximos períodos, F_{t+1} e F_{t+n} respectivamente, são iguais à nova estimativa de nível, como apresentado na Equação 2.9 (CHOPRA; MEINDL, 2016).

$$L_{t+1} = \alpha D_{t+1} + (1 - \alpha)L_t \quad (2.8)$$

$$F_{t+1} = L_t \text{ e } F_{t+n} = L_t \quad (2.9)$$

O valor da constante de alisamento α é arbitrário, mas deve seguir uma lógica de redução dos erros do modelo, assim, por exemplo, a constante de alisamento α pode ser estimada de forma a minimizar a média dos erros quadráticos da previsão (PELLEGRINI; FOGLIATTO, 2001), como em Bezerra (2006), ou o erro médio absoluto, como em Santos *et al.* (2017). A magnitude da constante α determina o grau de resposta do modelo às mudanças de demanda, e quanto maior sua magnitude mais rápida será sua resposta (PELLEGRINI; FOGLIATTO, 2001).

O alisamento exponencial corrigido pela tendência, ou Modelo de Holt, é recomendado para séries históricas que apresentam tendência linear não nula, mas ainda sem sazonalidade (CHOPRA; MEINDL, 2016). O Modelo de Holt relaciona linearmente o comportamento da demanda com o tempo, podendo ser representado como mostrado a seguir (CHOPRA; MEINDL, 2016).

$$D_t = a * t + b \tag{2.10}$$

Neste formato, a demanda é relacionada a um componente dependente do período analisado e um independente (CHOPRA; MEINDL, 2016). Para as estimativas iniciais de nível (L_0) e tendência (T_0), Pellegrini e Fogliatto (2001) apresentam duas possibilidades: i) assumir L_0 como o valor mais recente da série temporal e T_0 como a média da inclinação das retas entre cada período e ; ii) aplicar uma regressão linear simples com os dados da série temporal.

O Modelo de Holt, diferentemente do alisamento exponencial simples, suaviza tanto a componente de nível (L_t) quanto a componente da tendência (T_t), como pode ser observado nas Equações 2.11 e 2.12 mostradas a seguir (CHOPRA; MEINDL, 2016).

$$L_{t+1} = \alpha D_{t+1} + (1-\alpha)(L_t + T_t) \tag{2.11}$$

$$T_{t+1} = \beta (L_{t+1} - L_t) + (1-\beta)T_t \tag{2.12}$$

Os valores das constantes de alisamento de nível α ($0 < \alpha < 1$) e de tendência β ($0 < \beta < 1$) podem ser determinados de forma análoga àquela utilizada no método de alisamento exponencial simples (PELLEGRINI; FOGLIATTO, 2001). A previsão para o próximo e para os próximos períodos, F_{t+1} e F_{t+n} respectivamente, seguem as relações lineares apresentadas por Chopra e Meindl (2016), como mostram as Equações 2.13 e 2.14.

$$F_{t+1} = L_t + T_t \tag{2.13}$$

$$F_{t+n} = L_t + nT_t \tag{2.14}$$

O alisamento exponencial corrigido pela tendência e sazonalidade (Modelo de Winter) é recomendado quando a série histórica apresenta tendência linear não nula e um componente de sazonalidade (CHOPRA; MEINDL, 2016). E, como apresentado por Pellegrini e Fogliatto (2001), o modelo é classificado em dois tipos: aditivo ou multiplicativo.

O modelo aditivo é recomendado em situações em que a série histórica apresenta valores razoavelmente constantes entre picos e vales de demanda de um ciclo sazonal (PELLEGRINI; FOGLIATTO, 2011). Segundo os autores, a previsão do próximo e dos próximos períodos, F_{t+1} e F_{t+n} respectivamente, podem ser encontradas como apresentado pelas Equações 2.15 e 2.16.

$$F_{t+1} = L_t + T_t + S_{t+1} \quad (2.15)$$

$$F_{t+n} = L_t + nT_t + S_{t+n} \quad (2.16)$$

Analogamente aos métodos de alisamento apresentados anteriormente, o Modelo de Winter suaviza, além das componentes de nível e tendência, a componente de sazonalidade. O modelo aditivo pode ser observado nas Equações 2.17, 2.18 e 2.19, apresentadas por Pellegrini e Fogliatto (2001).

$$L_{t+1} = \alpha(D_{t+1} - S_{t+1}) + (1 - \alpha)(L_t + T_t) \quad (2.17)$$

$$T_{t+1} = \beta(L_{t+1} - L_t) + (1 - \beta)T_t \quad (2.18)$$

$$S_{t+1} = \gamma(D_{t+1} - L_{t+1}) + (1 - \gamma)S_{t+1} \quad (2.19)$$

O modelo multiplicativo, por sua vez, é recomendado em situações em que a série histórica apresenta variação na diferença entre os picos e vales dos ciclos sazonais (PELLEGRINI; FOGLIATTO, 2001). As previsões para os próximos períodos, assim como apresentado por Chopra e Meindl (2016), podem ser elaboradas seguindo a Equação 2.20 e as componentes de demanda obtidas usando as Equações 2.21, 2.22 e 2.23.

$$F_{t+n} = (L_t + nT_t)S_{t+n} \quad (2.20)$$

$$L_{t+1} = \alpha \frac{D_{t+1}}{S_{t+1}} + (1 - \alpha)(L_t - T_t) \quad (2.21)$$

$$T_{t+1} = \beta(L_{t+1} - L_t) + (1 - \beta)T_t \quad (2.22)$$

$$S_{t+p+1} = \gamma \frac{D_{t+1}}{L_{t+1}} + (1 - \gamma)S_{t+1} \quad (2.23)$$

Em ambos os modelos, Modelo de Winter aditivo e multiplicativo, as constantes de alisamento de nível α ($0 < \alpha < 1$), de tendência β ($0 < \beta < 1$) e de sazonalidade ($0 < \gamma < 1$) são estimadas de maneira a minimizar o erro da previsão (PELLEGRINI; FOGLIATTO, 2001). Quanto mais próximos os valores das constantes do valor unitário, maior o peso para as informações mais recentes, ou seja, valores maiores de α dão mais importância para os registros de vendas mais recentes, de β para os padrões mais recentes de tendência e de γ para os padrões de sazonalidade (HOLT, 2004).

Para a estimativa inicial dos componentes de demanda, L_0 , T_0 e S_0 , é necessário a existência de registros de, pelo menos, um ciclo sazonal completo para que seja possível observar os pesos sazonais de cada período (PELLEGRINI; FOLGIATTO, 2001). As estimativas iniciais desses componentes podem ser calculadas pelas estimativas encontradas com a aplicação dos métodos estáticos (ver Equações 2.1 a 2.5) (CHOPRA; MEINDL, 2016).

Para estimar os valores das constantes de alisamento, ferramentas como o Solver do *software Microsoft Excel* são comumente utilizadas, como observado em Chopra e Meindl (2016) e Santos *et al.* (2007).

2.3 Acurácia das previsões: as medidas de erros

Como afirmam Chopra e Meindl (2006), “as previsões estão sempre erradas e devem, por isso, incluir o valor esperado e uma medida de erros de previsão”. Em outras palavras, as previsões têm um componente aleatório que precisa ser acompanhado, pois esse é o erro que indica a precisão das previsões. Como destacam Zanella *et al.* (2016), quanto maior o erro na previsão, mais dificuldade terá a empresa para realizar seu planejamento, o que pode gerar

perdas financeiras ou de competitividade perante os concorrentes, decorrentes, por exemplo, de excesso ou de falta de estoques.

A acurácia da previsão é citada como fator importante na escolha de um método de previsão (MENTZER; COX, 1984). No entanto, não há consenso na literatura sobre a medida de erro a ser usada para avaliar a acurácia da previsão (MAKRIDAKIS, 1993; HYNDMAN, 2006), pois isso depende do objetivo da previsão e de características das informações disponíveis. Do ponto de vista prático, a medida de erro deve ser compreensível, fazer sentido e ser correta (MAKRIDAKIS, 1993).

O erro para um período t de uma previsão (E_t) é a diferença entre o valor fornecido pela previsão (F_t) e a demanda realizada (D_t) neste período, como apresentado em Chopra e Meindl (2016) e mostrado na Equação 2.25.

$$E_t = F_t - D_t \quad (2.25)$$

Os limites aceitáveis para os erros apresentados pelos modelos de previsão estão associados às características do mercado e a capacidade de cada empresa para lidar com os erros (DIAS, 1999). Uma medida de erro de previsão é o EQM (erro quadrático médio), que avalia quadraticamente os erros da previsão penalizando os maiores erros (CHOPRA; MEINDL, 2016). Segundo os autores, o EQM pode ser aplicado se a distribuição de erros for simétrica e centrada em zero, sendo recomendado em situações em que o erro maior custa muito mais. Chopra e Meindl (2016) apresentam a definição do EQM como mostra a Equação 2.26.

$$EQM_n = \frac{1}{n} \sum_{t=1}^n E_t^2 \quad (2.26)$$

Outra medida de erro é o DMA (desvio médio absoluto), entendido como o erro absoluto médio da previsão. É definido por Tubino (1997) e Chopra e Meindl (2016), como:

$$DMA_n = \frac{1}{n} \sum_{t=1}^n |E_t| \quad (2.27)$$

Admitindo-se que os erros estão distribuídos aleatoriamente, o DMA pode ser usado para estimar o desvio-padrão do componente aleatório: ao multiplicar o valor do DMA por 1,25, obtém-se o desvio padrão (σ) (TUBINO, 1997).

O MAPE (*Mean Absolute Percentage Error*) é uma das poucas medidas de erro que trazem significado simples, o que facilita a interpretação por parte dos analistas (MAKRINDAKIS, 1993).

$$MAPE_t = \left| \frac{D_t - F_t}{D_t} \right| \quad (2.28)$$

Aparentemente, o MAPE é a forma mais popular para medir a precisão de um método de previsão e o método mais recomendado para comparar erros, seja do ponto de vista teórico ou prático. Mas alguns pontos devem ser observados antes de sua aplicação (MAKRINDAKIS, 1993):

- i. erros iguais podem resultar em *MAPEs* diferentes, o que pode ser corrigido substituindo o denominador da Equação 2.28 pela média dos valores da previsão (F_t) e da demanda realizada (D_t), como apresentado na Equação 2.29;

$$MAPE_t = \left| \frac{D_t - F_t}{(D_t + F_t)/2} \right| \quad (2.29)$$

- ii. caso sejam observados valores de demanda (D_t) nulos ou muito próximos de zero, o valor do *MAPE* apresentará valores muito elevados.

Chopra e Meindl (2016) apresentam maneiras de rastrear e monitorar os métodos de previsão por meio do seu “viés” e sinal de acompanhamento (SA):

$$viés_n = \sum_{t=1}^n E_t \quad (2.30)$$

$$SA_t = \frac{viés_t}{DMA_t} \quad (2.31)$$

O viés avalia o erro acumulado da previsão e, caso o erro realmente seja aleatório e não enviesado, deve flutuar em torno de zero (CHOPRA; MEINDL, 2016). Para Zanella *et al.* (2016), o viés indica uma tendência que ocorre por alguma causa identificável, podendo ser posteriormente eliminada. O SA, ou razão de viés, também deve ser analisado e caso seu valor, em algum momento, esteja fora do intervalo entre seis negativo e seis positivo, o método de previsão é falho ou o padrão de demanda anterior mudou (CHOPRA; MEINDL, 2016).

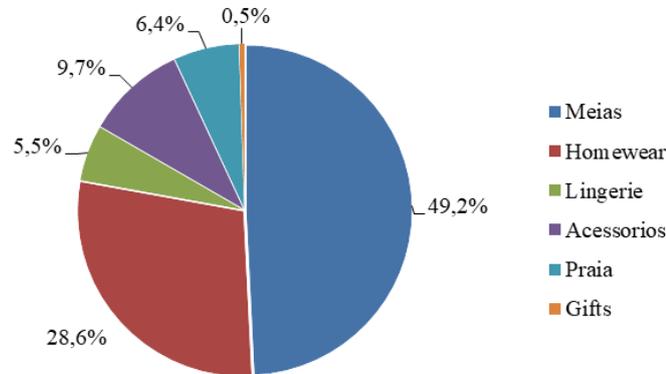
3. PROCEDIMENTOS METODOLÓGICOS

Para avaliar a acurácia de previsões de vendas ao utilizar diferentes modelos de séries temporais, é imprescindível o uso de dados reais, ou seja, é preciso comparar as estimativas de vendas, obtidas ao aplicar os diversos métodos, com as vendas realizadas. Com esse objetivo, o presente trabalho apresenta um estudo de caso no qual são usados três diferentes métodos para prever a demanda de uma linha de produtos de uma grande empresa do setor de vestuário e, posteriormente, avaliar os erros de previsão.

A empresa objeto do presente estudo iniciou suas atividades na década de 80, produzindo e comercializando meias por meio de revendedores e representantes. Após quinze anos de operação, abriu a sua primeira loja e, atualmente, comercializa seus produtos por meio de franquias, lojas multimarcas e loja virtual em mais de 400 pontos de venda em três países, incluindo o Brasil. A expansão, viabilizada com a implementação de franquias, permitiu que a empresa, a partir de 2004, passasse a comercializar outras linhas de produtos, como *lingeries* e pijamas, linha praia, presentes e acessórios.

Alguns dos produtos comercializados pela empresa são confeccionados internamente e outros adquiridos de terceiros. Dentre os produtos de fabricação própria, 80% são da linha meias, que também representam quase 50% do faturamento da empresa, conforme dados de 2018 (Figura 1).

Figura 1 - Participação em faturamento das linhas de produtos em 2018.



Fonte: Desenvolvido pelo autor.

No que diz respeito à coleta de dados para a realização do presente estudo, diferentes instrumentos foram usados para obter dados de natureza quantitativa e qualitativa. Reuniões e entrevistas não estruturadas com diretores e funcionários de diversas áreas foram realizadas, assim como observação das atividades afetas ao processo de previsão da demanda, visando a obter dados que permitissem descrever esse processo na referida empresa. Além disso, o objetivo era identificar as ferramentas e tecnologias utilizadas pela empresa, bem como os setores envolvidos.

Os dados obtidos, em especial de natureza qualitativa, permitem descrever o processo de previsão de vendas na empresa e, para facilitar a compreensão desse processo, as diversas atividades são representadas por meio de fluxogramas, tanto para os casos de previsão de novos produtos quanto de previsão de reposição.

Em relação aos dados de natureza quantitativa, esses foram obtidos, principalmente, a partir de planilhas com informações sobre os produtos (como peso, composição de cores, linha dos produtos, público alvo, origem, preço e custo) e histórico de vendas, tanto com os profissionais que estavam envolvidos com as atividades de planejamento de demanda quanto com o setor de Tecnologia da Informação (TI).

Os dados de vendas referentes a anos anteriores a 2016 foram obtidos por meio de consultas em bases *Structured Query Language* (SQL) fornecidas pelo setor de TI. No setor de planejamento, os dados foram obtidos a partir de um *software* que armazena diversas informações relativas às vendas da empresa e de suas franquias, além de relatórios de vendas disponíveis em planilhas. Estes dados foram tratados e os volumes de vendas organizados por mês, produto e canal de vendas.

No presente estudo são usados os dados agregados da linha de produtos de meias para todos os canais de venda, referente aos anos de 2014 a 2018. Com esses dados são elaboradas previsões de demanda segundo diferentes métodos de previsão de séries temporais, bem como avaliada a acurácia dessas previsões.

3.1 O processo de previsão de demanda por produtos e por linha de produto

Na empresa analisada, a área de planejamento é a principal responsável pelo processo de previsão de demanda. Para cada uma das linhas há uma equipe encarregada de elaborar a previsão de vendas, ou seja, são seis equipes para as seis linhas.

A previsão agregada para cada linha de produtos é realizada usando duas diferentes abordagens. A primeira abordagem baseia-se nos dados do histórico de vendas e utiliza médias das vendas passadas, ponderações subjetivas ou ajustes propostos pela equipe. A segunda abordagem consolida as várias previsões feitas para cada produto de cada linha. Os valores obtidos segundo as duas abordagens são comparados e, se houver discrepâncias, a equipe analisa as previsões para identificar fatores que possam justificar as diferenças nas previsões.

No que se refere às previsões para cada produto, estas são realizadas em três principais etapas: i) são feitas as previsões agregadas para todos os canais de vendas da linha de produtos; ii) as previsões obtidas na primeira etapa são desagregadas para cada produto, mas ainda incluem todos os canais de vendas; iii) com base no faturamento de cada canal de vendas nos períodos analisados, a previsão é desagregada para cada canal de vendas.

Os processos de previsão adotados para cada produto também dependem do objetivo da produção, se para a reposição de produtos ou lançamento de novos produtos.

No caso dos produtos novos, a primeira etapa do processo de previsão consiste em um *briefing*, quando os responsáveis pelo desenho da arte e estratégia de *mix* de produtos se reúnem com a equipe de planejamento de demanda e apresentam os novos produtos e seus detalhes na composição da vitrine e *mix* em loja. A partir desse primeiro contato, a equipe de previsão de demanda identifica produtos comercializados no passado com funções, aparência, faixa de preço ou outras características semelhantes ao produto cuja demanda deve ser prevista, para que tenham alguma referência a ser usada no processo de previsão.

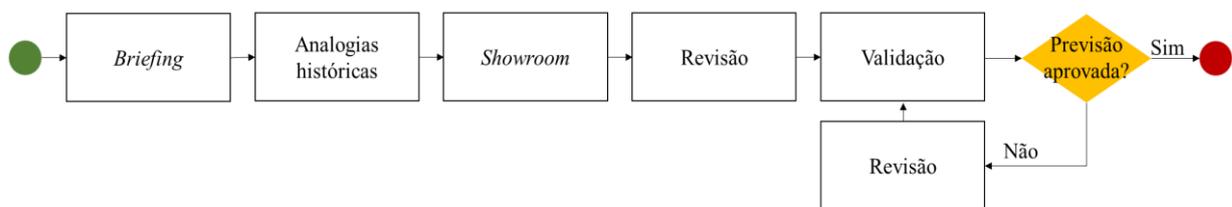
Na análise das vendas de produtos com características semelhantes, a equipe de planejamento leva em consideração as ações promocionais e discute razões que expliquem

mudanças no comportamento da demanda, como sazonalidade, ruptura de estoques, problemas de abastecimento de lojas, entre outros. Em outras palavras, a equipe usa o processo de analogia histórica no qual tanto o histórico de vendas dos produtos, que servirão de referências, quanto análises subjetivas, baseadas nas experiências anteriores da equipe, são importantes.

Usando esses dados, a equipe estima o volume de vendas de cada produto para todos os canais de vendas e, na sequência, com base no faturamento de cada canal, é feita a estimativa de vendas por canal. Essas primeiras previsões são apresentadas no *showroom* como uma sugestão de compra de cada produto para cada franqueado. Esse *showroom* conta com a presença física dos franqueados que veem a vitrine e a composição de *mix* de produtos e definem a quantidade de cada produto que desejam adquirir para revender.

Com base na previsão de vendas, elaborada por meio de analogia histórica pela equipe de planejamento e nas quantidades solicitadas pelos franqueados, as demandas são revisadas considerando políticas de estoque, estratégias de produto e a possibilidade que novos lotes do produto sejam, após lançamento, solicitados pelos franqueados. Essas previsões revisadas e as justificativas dos ajustes são apresentadas para os gerentes e diretor de planejamento e, caso aprovadas, seguem para as etapas de planejamento da produção ou compra de produtos. Caso a previsão não seja aprovada, a equipe de planejamento procede uma reavaliação das quantidades previstas e reapresenta as novas previsões, como ilustrado na Figura 2.

Figura 2 - Processo de previsão para o caso de produto novos.



Fonte: Desenvolvido pelo autor.

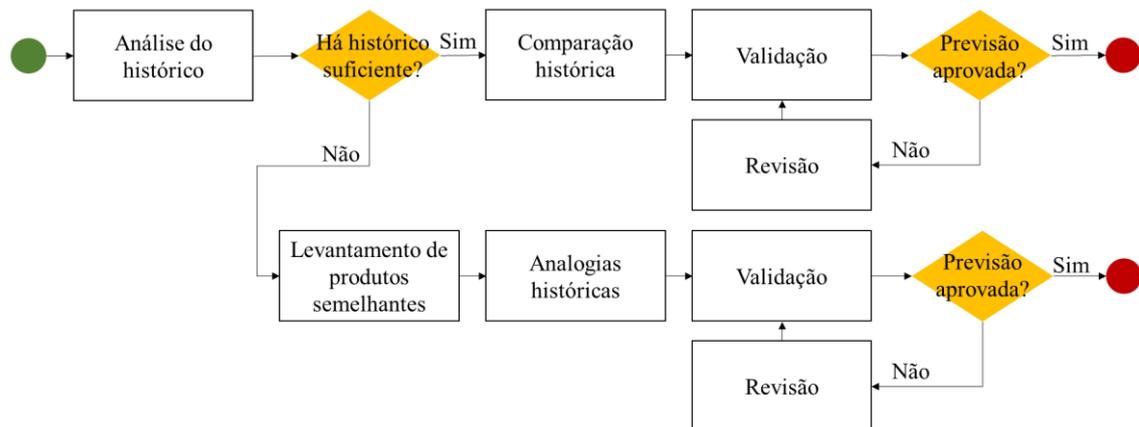
O processo de previsão de demanda para o caso de reposição dos produtos tem início na análise do histórico de vendas do produto do ano anterior e visa à identificação de fatores que devam ser considerados no processo, como ocorrência de rupturas de estoque, problemas de abastecimento das lojas, eventos externos, entre outros.

Caso o histórico de vendas do ano anterior seja considerado útil, como base para a previsão da demanda, a equipe de planejamento usa esses valores e realiza ajustes que julgam

pertinentes, dependendo da natureza dos eventos identificados como, por exemplo, aumento do volume de vendas decorrente de promoções. Caso contrário, ou seja, se a equipe de previsão de demanda identifica que o histórico de vendas não representa a demanda do produto para o próximo período, são listados produtos semelhantes ao analisado para, por meio de analogias históricas, realizar a previsão.

De forma semelhante à previsão para produtos novos, as estimativas de vendas para reposição de produtos são apresentadas aos diretores de planejamento para apreciação e validação.

Figura 3 - Processo de previsão de reposição de produtos.



Fonte: Desenvolvido pelo autor.

Recentemente, a empresa incluiu uma última etapa no processo de previsão, a etapa de registro e avaliação de erros das previsões, que consiste em comparar a demanda realizada no mês anterior com sua previsão inicial – aquela elaborada antes de se dar início ao processo de compra ou produção dos produtos – para cada uma das linhas de produtos.

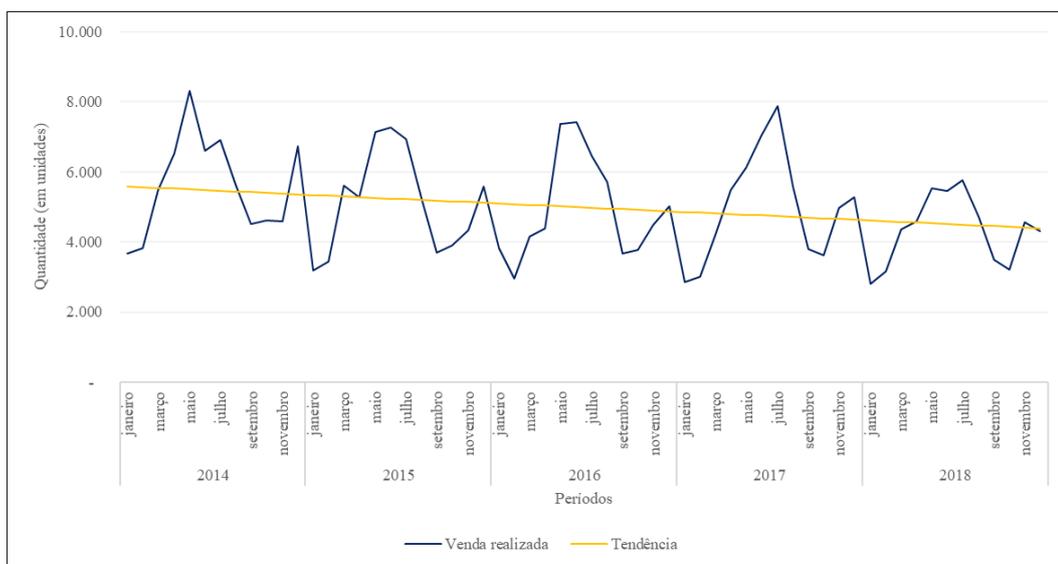
3.2. Previsão de demanda para a linha de meias usando séries temporais

Para realizar a previsão agregada da demanda para a linha de meias da empresa e analisar a acurácia dessa previsão, três métodos de séries temporais são aplicados usando dados das vendas de 2014 a 2018: método estático e os modelos de Winter aditivo e multiplicativo.

Em uma primeira análise, com o auxílio do *software Microsoft Excel*, os dados de vendas mensais são representados graficamente para que possam ser identificadas características de sazonalidade e tendência ou *outliers*. E, embora se possa observar, no

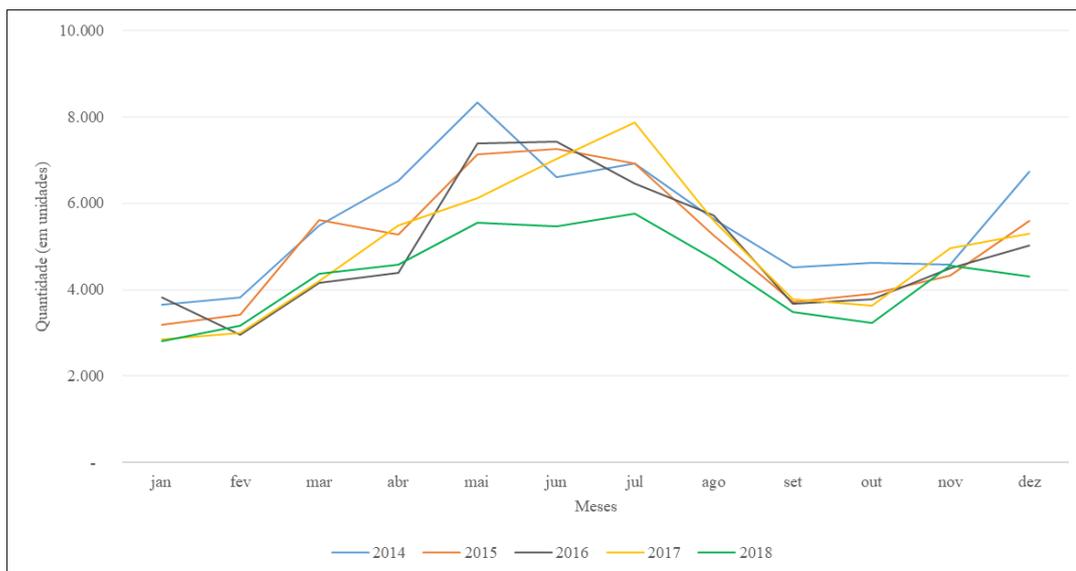
gráfico da Figura 4, que a série tem uma tendência não nula e sazonalidade, os dados de vendas mensais também são representados ano a ano e sobrepostos, como mostra a Figura 5, o que permite confirmar o referido comportamento da demanda.

Figura 4 – Demanda mensal de meias entre 2014 e 2018.



Fonte: Desenvolvido pelo autor.

Figura 5 - Vendas de meias para análises sazonais.



Fonte: Desenvolvido pelo autor.

Para aplicação dos métodos de séries temporais e avaliação da aderência da previsão, os dados de vendas de 2014 a 2018 são separados em dois conjuntos, conforme sugere

Werner (2000). Assim, os dados de 2014 até 2017 compõem o primeiro conjunto e os dados de 2018 o segundo conjunto. O primeiro conjunto é usado para realizar as previsões para o ano de 2018 e o segundo para comparar o desempenho dos métodos de previsão usados, ou seja, para avaliar a acurácia da previsão elaborada para os vários meses do ano de 2018, segundo os três métodos.

O método estático é usado nesse primeiro conjunto de dados. O primeiro passo consiste em dessazonalizar a demanda de cada período t , com o auxílio da equação 3.1, considerando sazonalidade p igual a doze meses. Com as demandas sem sazonalidade (\bar{D}_t), é aplicada uma regressão linear com o auxílio do *software Microsoft Excel* e obtida a equação do comportamento da demanda sem sazonalidade (Equação 3.1), como apresentada a seguir.

$$\bar{D}_t = 5.585,303 - 20,183 * t \tag{3.1}$$

Os componentes sazonais, cujos valores estão apresentados na Tabela 1, são definidos usando as Equações 2.3 e 2.4.

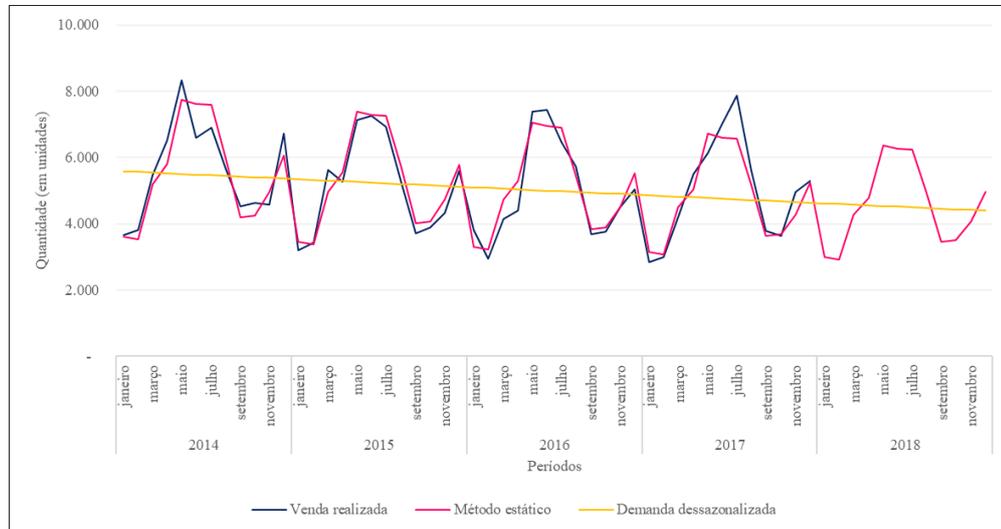
Tabela 1 - Componentes sazonais (método estático).

Mês	Componente (i)	Componente sazonal (S_i)
Janeiro	1	0,647
Fevereiro	2	0,634
Março	3	0,936
Abril	4	1,049
Maio	5	1,406
Junho	6	1,388
Julho	7	1,388
Agosto	8	1,096
Setembro	9	0,775
Outubro	10	0,788
Novembro	11	0,919
Dezembro	12	1,130

Fonte: Desenvolvido pelo autor.

Os valores da demanda prevista para os 12 meses do ano de 2018 são obtidos usando a Equação 2.5 e estão representados pela linha vermelha mostrada no gráfico da Figura 6.

Figura 6 - Previsão de vendas para os meses de 2018 usando o método estático.



Fonte: Desenvolvido pelo autor.

Considerando que a série histórica apresenta características de tendência não nula e sazonalidade, os Modelos de Winter, dentre os métodos adaptativos de previsão, são os mais recomendados, de acordo com Chopra e Meindl (2016).

Para as estimativas iniciais de nível, tendência e sazonalidade, necessárias para a aplicação do Modelo de Winter multiplicativo, são usados os valores estimados pelo método estático, apresentados anteriormente, como sugerido por Chopra e Meindl (2016).

As constantes de alisamento α , β e γ para os Modelos de Winter multiplicativo e aditivo são estimadas de forma a minimizar o MAPE (Equação 2.28) da previsão da série histórica. A ferramenta de otimização *Solver do Microsoft Excel*, a exemplo de Chopra e Meindl (2016) e Santos *et al.* (2007), é usada nesse caso. As estimativas das constantes de alisamento e as quantidades de vendas previstas estão apresentadas na Tabela 2 e nas Figuras 7 e 8, respectivamente.

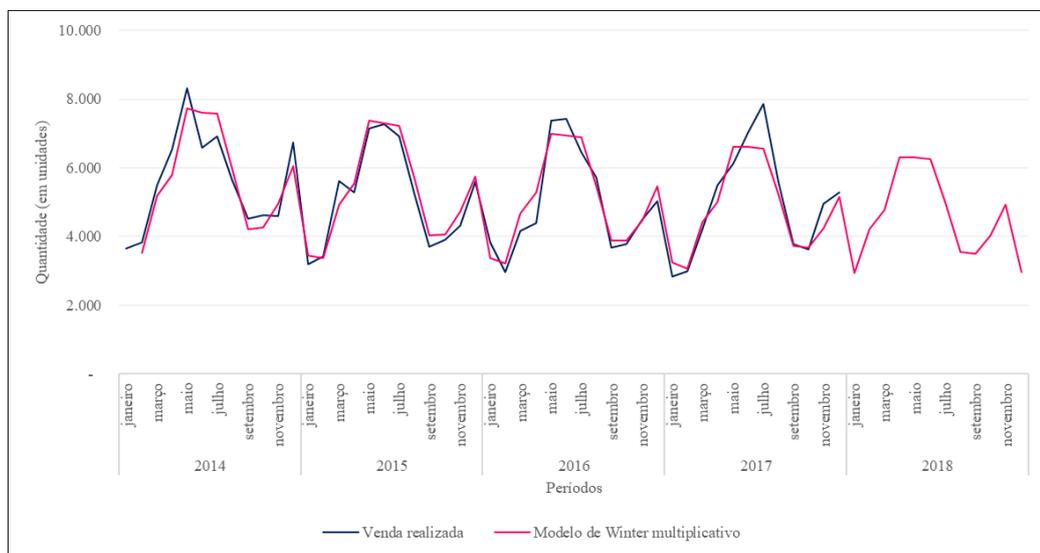
Tabela 2 - Constantes de alisamento do Modelo de *Winter*.

Constantes	Multiplicativo	Aditivo
Alfa (α)	0,000	0,355
Beta (β)	0,100	0,130
Gama (γ)	0,021	0,074

Fonte: Desenvolvido pelo autor.

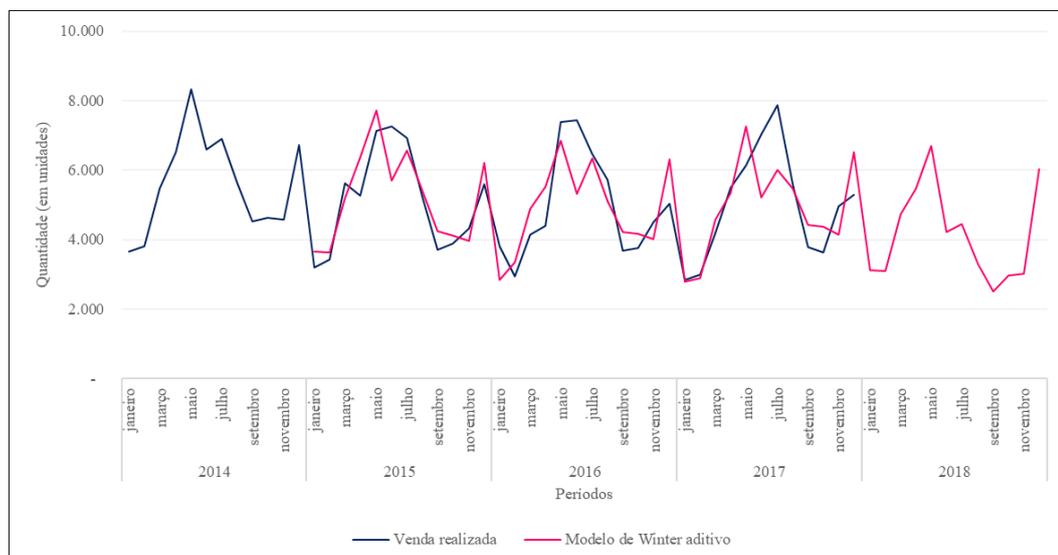
Com base em Holt (2004), pode-se afirmar que os valores estimados para as constantes de alisamento mostram que a série histórica para o Modelo de Winter multiplicativo está estável ($\alpha \approx 0$) e que o comportamento sazonal da série histórica para os modelos multiplicativo e aditivo não muda significativamente no decorrer do tempo (valores baixos de γ).

Figura 7 - Previsão de vendas com aplicação do Modelo de *Winter* multiplicativo.



Fonte: Desenvolvido pelo autor.

Figura 8 - Previsão de vendas com aplicação do Modelo de *Winter* aditivo.



Fonte: Desenvolvido pelo autor.

3.3. Medição dos erros de previsão

O cálculo dos erros das previsões de vendas obtidas com a aplicação dos diferentes métodos consiste em uma etapa importante do processo de previsão porque são esses erros que indicam o grau de incerteza em relação aos valores obtidos.

De fato, a acurácia da previsão pode ter um impacto importante sobre o resultado econômico da empresa, pois previsões superestimadas elevam os níveis de estoques e, conseqüentemente, os custos associados à manutenção desses estoques. Por outro lado, subestimar a demanda pode levar à perda de vendas, com conseqüente insatisfação dos clientes e prejuízos para a imagem da empresa.

Assim, para avaliar a acurácia das previsões e comparar o desempenho dos métodos de previsão usados são medidos os erros de previsão de cada período, ou seja, os erros dos vários meses do ano de 2018.

As Tabelas 3, 4 e 5 mostram os valores das vendas realizadas e as previsões obtidas para cada mês, de acordo com os modelos estático, o Winter multiplicativo e o aditivo, respectivamente. Os valores dos erros percentuais (MAPE) para cada mês, segundo os modelos de Winter, também constam nas tabelas.

Tabela 3 - Dados da previsão de acordo com modelo estático.

Período t	Ano	Mês	Venda Realizada	Demanda s/ sazonalidade	Previsão
48	2018	janeiro	2.805	4.617	2.988
49	2018	fevereiro	3.171	4.596	2.912
50	2018	março	4.373	4.576	4.283
51	2018	abril	4.592	4.556	4.780
52	2018	maio	5.545	4.536	6.376
53	2018	junho	5.462	4.516	6.269
54	2018	julho	5.755	4.495	6.240
55	2018	agosto	4.715	4.475	4.906
56	2018	setembro	3.491	4.455	3.454
57	2018	outubro	3.227	4.435	3.496
58	2018	novembro	4.570	4.415	4.059
59	2018	dezembro	4.310	4.395	4.964

Fonte: Desenvolvido pelo autor.

Tabela 4 - Dados da previsão de acordo com Modelo de *Winter* multiplicativo.

Período t	Ano	Mês	Venda Realizada	Previsão	MAPE
48	2018	Janeiro	2.805	2.937	2,27%
49	2018	Fevereiro	3.171	4.223	4,69%
50	2018	Março	4.373	4.780	33,18%
51	2018	Abril	4.592	6.303	9,30%
52	2018	Maiο	5.545	6.320	37,27%
53	2018	Junho	5.462	6.268	13,97%
54	2018	Julho	5.755	4.988	14,76%
55	2018	Agosto	4.715	3.552	13,33%
56	2018	Setembro	3.491	3.510	24,65%
57	2018	Outubro	3.227	4.049	0,55%
58	2018	Novembro	4.570	4.925	25,46%
59	2018	Dezembro	4.310	2.975	7,76%

Fonte: Desenvolvido pelo autor.

Tabela 5 - Dados da previsão de acordo com Modelo de *Winter* aditivo.

Período t	Ano	Mês	Venda Realizada	Previsão	MAPE
48	2018	Janeiro	2.805	3.125	11,40%
49	2018	Fevereiro	3.171	3.093	2,46%
50	2018	Março	4.373	4.742	8,45%
51	2018	Abril	4.592	5.483	19,41%
52	2018	Maiο	5.545	6.693	20,69%
53	2018	Junho	5.462	4.213	22,86%
54	2018	Julho	5.755	4.460	22,49%
55	2018	Agosto	4.715	3.297	30,07%
56	2018	Setembro	3.491	2.500	28,39%
57	2018	Outubro	3.227	2.965	8,11%
58	2018	Novembro	4.570	3.023	33,86%
59	2018	Dezembro	4.310	6.040	40,13%

Fonte: Desenvolvido pelo autor.

Para avaliar o erro, considerando o horizonte de planejamento de um ano, é utilizada a medida de erro MAPE (Equação 2.28) e o viés, cujos resultados constam na Tabela 6. Pode-se verificar que o Modelo de *Winter* aditivo apresenta o menor erro e um viés negativo.

O viés indica a direção dos erros, ou seja, se as previsões são superiores ou inferiores aos valores da demanda. Assim, nesta aplicação, o método estático e o modelo de *Winter* multiplicativo tendem a superestimar a demanda, enquanto o método de *Winter* aditivo a subestimar.

Tabela 6 - Teste de aderência das previsões (2018).

Método	Demanda prevista	MAPE	Viés
Previsão estática	54.728	5,22%	2.713
Modelo de <i>Winter</i> multiplicativo	54.829	5,41%	2.814
Modelo de <i>Winter</i> aditivo	49.634	4,58%	- 2.381

Fonte: Desenvolvido pelo autor.

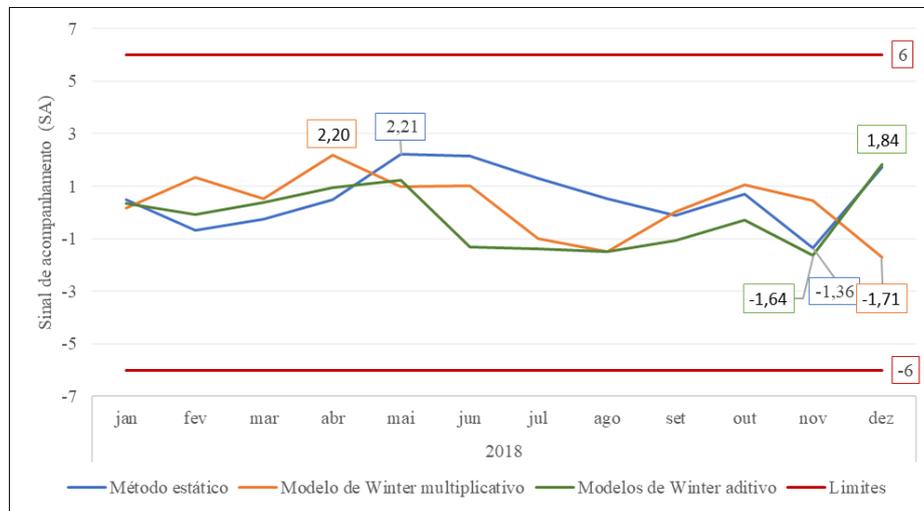
É importante analisar, como destaca Chopra e Meindl (2016), se esses erros estão dentro dos limites, o que pode ser feito por meio do sinal de acompanhamento (SA) das previsões. Os valores do SA, obtidos usando as Equações 2.30 e 2.31 e mostrados na Tabela 7, indicam que as previsões podem ser utilizadas, pois, para todos os meses de 2018, os valores estão dentro dos limites citados na literatura – entre seis negativo e positivo.

Tabela 7 - Monitoramento do sinal de acompanhamento das previsões (2018).

Método	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
Previsão estática	0,49	-0,69	-0,24	0,50	2,21	2,15	1,29	0,51	-0,10	0,72	-1,36	1,74
Winter multiplicativo	0,17	1,35	0,52	2,20	1,00	1,04	-0,99	-1,49	0,02	1,06	0,46	-1,71
Winter aditivo	0,34	-0,08	0,39	0,95	1,22	-1,33	-1,37	-1,51	-1,05	-0,28	-1,64	1,84

Fonte: Desenvolvido pelo autor.

Figura 9 - Evolução do sinal de acompanhamento para as previsões (2018).



Fonte: Desenvolvido pelo autor.

4. RESULTADOS E DISCUSSÕES

A empresa objeto do presente estudo de caso adota métodos qualitativos para a previsão de demanda de seus produtos, apesar de manter registro das vendas de vários anos. A analogia histórica é usada tanto para previsão de vendas de produtos novos quanto para reposição dos estoques. Em ambos os casos, a demanda é estimada com base em dados das

vendas do ano anterior. No caso de produtos novos, uma pesquisa de mercado também é realizada com os franqueados – semelhante ao que a literatura propõe para equipes de vendas.

A preferência pelo uso de métodos qualitativos observada na empresa é também destacada na literatura. Cecatto e Belfiore (2015), por exemplo, ao analisar uma amostra de 65 indústrias de alimentos, identificaram que o modelo de analogia histórica é um dos mais usados pelas empresas. Apesar da facilidade de entendimento e aplicação, previsões qualitativas são subjetivas sendo, portanto, sujeitas a tendências e vieses. Além disso, esses métodos são indicados para séries com alta variabilidade ou maiores oscilações, ou quando os dados são escassos (WERNER; RIBEIRO, 2006), o que não é o caso da empresa em questão.

Se a variabilidade da demanda é média ou alta, a combinação de métodos quantitativos e qualitativos fornece uma melhora na acurácia (WERNER; RIBEIRO, 2006). Ainda segundo esses autores, os modelos quantitativos constituem a melhor escolha no caso de previsões de séries estáveis (WERNER; RIBEIRO, 2006).

A aplicação de métodos de séries temporais para a previsão de demanda de uma linha de produtos, como apresentada nesse trabalho, parece mais indicada para o caso analisado. Além da disponibilidade dos dados, observa-se um padrão de sazonalidade dos dados sem variações esporádicas.

Três diferentes métodos foram aplicados e, avaliados segundo a acurácia da previsão. Usando o MAPE, medida mais comum para comparar erro de previsão, obtém-se valores em torno entre 4,5 e 5,5% no horizonte de planejamento considerado. Dentre os três métodos, o modelo de Winter aditivo apresentou menor MAPE, 4,58%, seguido do método estático, com 5,22%.

O método de Winter aditivo, apesar de menor erro, é mais adequado no caso de oscilações de mercado, ou maior variabilidade. Aliás, esta é a característica principal dos métodos adaptativos, ou seja, estes métodos permitem aumentar a velocidade de resposta das previsões da empresa caso ocorram mudanças bruscas nas vendas.

O método estático apresenta a vantagem de facilidade de elaboração e de manutenção do modelo matemático. Esse método de previsão pode ser indicado para o caso em questão, pois, analisando os resultados das constantes de alisamento estimadas com a aplicação dos Modelos de Winter, percebe-se que há um padrão da sazonalidade das vendas de meias. E, como destaca Chopra e Meindl (2016), um modelo estático supõe que as estimativas de tendência e sazonalidade não variam conforme uma nova demanda é observada.

Ao analisar a acurácia dos métodos e o impacto sobre os estoques, o viés positivo do método estático indica que os valores da previsão de demanda tendem a ser superiores às vendas efetivas. Logo, a escolha desse método de previsão leva à definição de níveis de estoques mais elevados. O método de Winter aditivo, por outro lado, tem um viés negativo, ou seja, as demandas são subestimadas, o que pode levar à ruptura de estoque e, conseqüentemente, à perda das vendas.

Para uma gestão de estoques adequada é fundamental uma boa previsão de vendas (TUBINO, 1999; PELLEGRINI; FOGLIATTO, 2001). Assim, é importante avaliar qual o efeito de uma demanda superestimada ou subestimada em cada caso. Isso depende das características dos produtos – por exemplo, produtos perecíveis ou que se tornam rapidamente obsoletos tem, em geral, um custo de estoque mais elevado – e do mercado – mercado com acirrada concorrência pode ter custo de venda perdida mais elevado.

Para o caso da empresa em questão, a análise dos custos associados aos erros de previsão de demanda pode ser feita a partir dos valores de custos de manutenção dos estoques e custos das vendas perdidas, considerando o nível de serviço que se pretende oferecer aos clientes e as características dos diferentes produtos. Uma estimativa dos custos de estoques e de vendas perdidas, ao se adotar os três diferentes métodos, pode permitir à equipe uma análise sob uma perspectiva de gestão de estoques.

Uma análise simples é sugerida estimando-se os custos unitários de manter estoque e de vendas perdidas para cada mês. Ou seja, considera-se o custo de manter estoque ao final de cada mês no caso da previsão superior à demanda real, ou custo de vendas perdidas no caso de demanda subestimada.

Os dados obtidos com essa análise são mostrados nas Tabelas 8 e 9 e permitem comparar o desempenho dos métodos estático e Winter aditivo com base em valores de custos obtidos para três situações hipotéticas: i) custos de estoques e vendas perdidas idênticos, ambos considerados iguais a uma unidade monetária ao final de cada período; ii) custos de estoques iguais a uma unidade monetária e custo de vendas perdidas nulo, e; iii) custos de estoques nulo e custos de vendas perdidas iguais a uma unidade monetária.

Observa-se que o método estático apresenta valores de custos mais baixos para as três situações consideradas, sendo principalmente indicado se a empresa considera mais importante ter disponibilidade de estoque – caso em que o custo de venda perdida é igual a uma unidade monetária e o custo de manter estoque foi considerado nulo.

Como destacam Werner e Ribeiro (2006), a previsão da demanda está relacionada às tarefas de disponibilizar recursos para viabilizar o atendimento aos clientes e gerenciar as necessidades da empresa. Esse tipo de análise, baseada na acurácia do método, mostra-se útil, pois permite avaliar como a previsão afeta os níveis de estoques e, conseqüentemente, os custos associados a esses.

Tabela 8 - Custos de estoques e vendas perdidas para valores de demanda obtidos pelo método estático.

Ano	Mês	Venda Realizada	Previsão	Erro	Custo de estoque e de vendas perdidas idêntico (=1)	Custo de venda perdida = 0 e custo de estoque = 1	Custo de venda perdida = 1 e custo de estoque = 0
2018	Janeiro	2.805	2.988	183	183	183	0
2018	Fevereiro	3.171	2.912	-259	259	0	259
2018	Março	4.373	4.283	-90	90	0	90
2018	Abril	4.592	4.780	188	188	188	0
2018	Maio	5.545	6.376	831	831	831	0
2018	Junho	5.462	6.269	807	807	807	0
2018	Julho	5.755	6.240	485	485	485	0
2018	Agosto	4.715	4.906	191	191	191	0
2018	Setembro	3.491	3.454	-37	37	0	37
2018	Outubro	3.227	3.496	269	269	269	0
2018	Novembro	4.570	4.059	-511	511	0	511
2018	Dezembro	4.310	4.964	654	654	654	0
					\$4.505	\$3.608	\$897

Fonte: Elaborado pelo autor.

Tabela 9 - Custos de estoques e vendas perdidas para valores de demanda obtidos pelo Modelo de *Winter* aditivo.

Ano	Mês	Venda Realizada	Previsão	Erro	Custo de estoque e de vendas perdidas idêntico (=1)	Custo de venda perdida = 0 e custo de estoque = 1	Custo de venda perdida = 1 e custo de estoque = 0
2018	Janeiro	2.805	3.125	320	320	320	0
2018	Fevereiro	3.171	3.093	-78	78	0	78
2018	Março	4.373	4.742	369	369	369	0
2018	Abril	4.592	5.483	891	891	891	0
2018	Maio	5.545	6.693	1.148	1.148	1.148	0
2018	Junho	5.462	4.213	-1.249	1.249	0	1.249

2018	Julho	5.755	4.460	-1.295	1.295	0	1.295
2018	Agosto	4.715	3.297	-1.418	1.418	0	1.418
2018	Setembro	3.491	2.500	-991	991	0	991
2018	Outubro	3.227	2.965	-262	262	0	262
2018	Novembro	4.570	3.023	-1.547	1.547	0	1.547
2018	Dezembro	4.310	6.040	1.730	1.730	1.730	0
					\$11.298	\$4.458	\$6.840

Fonte: Elaborado pelo autor.

Em relação às ferramentas computacionais para realizar a previsão, o *software Microsoft Excel*, usado nesse trabalho, pode ser adotado pela empresa para elaboração das previsões de demanda, para qualquer dos três métodos de previsão. Assim, não é necessário investimento em *softwares* específicos. Por outro lado, como destacam Pellegrini e Fogliatto (2001), os custos incluem não somente aquisição de pacotes computacionais, mas também dedicação de pessoal. E, nesse caso, é importante que os responsáveis pela previsão da demanda procurem se familiarizar com os métodos e procedimentos de previsão para que possam explorar e melhor compreender os valores obtidos.

Por fim, cabe ressaltar que, dependendo do nível de agregação dos dados e do horizonte de planejamento, os erros da previsão para o mesmo grupo de dados são diferentes. Conforme Pellegrini e Fogliatto (2001), quando se está analisando uma série contendo dados é importante identificar um padrão no comportamento. Nesse estudo, os dados foram agregados em meses, períodos, e foi considerado um horizonte de planejamento, ou ciclos, de um ano.

5. CONCLUSÕES

Apesar da relevância dos modelos de séries temporais, e da disponibilidade de softwares de baixo custo que podem ser usados para realizar previsões, esses são pouco usados pelas empresas. A equipe de previsão de vendas da empresa, objeto do presente estudo de caso, é uma das várias empresas que adota métodos qualitativos, mesmo dispondo de dados históricos – como destaca a literatura. Estudos com descrições de aplicações de métodos quantitativos para previsão de demanda, em especial tratando de todo o processo de previsão e avaliando os erros, também são escassos. Pellegrini e Fogliatto (2001) e Werner e Ribeiro (2006) são dois raros artigos nacionais que sugerem procedimento de sistema de

previsão de demanda usando métodos quantitativos, analisam a acurácia da previsão e apresentam aplicações por meio de estudo de caso.

O presente artigo traz uma contribuição relevante ao descrever a aplicação de três modelos de séries temporais para previsão da demanda da principal linha de produtos de uma empresa brasileira de grande porte do setor de vestuário. O método estático e dois métodos de suavização exponencial, Winter aditivo e multiplicativo, são aplicados com auxílio do software Microsoft Excel usando dados das vendas referente ao período de 2014 a 2017. Os erros de previsão foram calculados comparando as previsões obtidas, de acordo com os referidos métodos, e os dados de vendas de 2018. O trabalho também sugere como avaliar o impacto dos erros de previsão para subsidiar decisões relacionadas à gestão de estoques, ilustrando como as técnicas de previsão podem apoiar as decisões gerenciais – aspecto destacado por Pellegrini e Fogliatto (2001).

Para que esse trabalho constitua uma referência àqueles que buscam incorporar métodos quantitativos aos sistemas de previsão de demanda, ou que tratam do tema em suas pesquisas, o artigo descreve os procedimentos de forma detalhada e simplificada e analisa os resultados com ilustrações baseadas no estudo de caso.

No que se refere à aplicação dos modelos de séries temporais, pode-se afirmar que os três métodos se mostram adequados ao caso em questão. A acurácia da previsão, avaliada segundo os parâmetros definidos na literatura, indica que os erros estão dentro dos limites aceitáveis. Cabe ressaltar que a escolha dos métodos depende das características da série temporal (PELLEGRINI; FOGLIATTO, 2001), nesse caso caracterizada por um padrão de sazonalidade sem alta variabilidade da demanda.

Referências

ARMSTRONG, J. S., FILDES, R. Making progress in forecasting. **International Journal of Forecasting**, v.22, n.3, p. 433-441, 2006.

BEZERRA, M. I. S. **Apostila de Análise de séries temporais**. UNESP: Curso de estatística. São Paulo, SP. 2006.

CECATTO, C.; BELFIORE, P. O uso de métodos de previsão de demanda nas indústrias alimentícias brasileiras. **Gestão e Produção**, v. 22, n. 2, p. 404-418, 2015.

CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos: estratégia, planejamento e operações**. 6. ed. São Paulo: Pearson Education do Brasil, 2016. 522 p.

CORRÊA, H. L.; GIANESI, I. G; CAON, M. **Planejamento, programação e controle da produção**. São Paulo: Atlas, v. 1, 2001.

DIAS, G. P. P. **Proposta de processo de previsão de vendas para bens de consumo**. Disponível em: http://www.abepro.org.br/biblioteca/ENESEP1999_A0687.PDF . Acesso em: 16 jul 2019.

HOFMANN, E., RUTSCHMANN, E. Big data analytics and demand forecasting in supply chains: a conceptual analysis. **International Journal of Logistics Management**, v. 29 n. 2, p. 739-766, 2018.

HOLT, C. C. Forecasting seasonals and trends by exponentially weighted moving averages. **International Journal of Forecasting**, v. 20, n. 1, p. 5-10, 2004.

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.

JAIN, C. L.; MALEHORN, J. **Benchmarking forecasting practices: a guide to improving forecasting performance**. Institute of Business Forecasting, 2006.

JUÁREZ, A. C. *et al.* Análisis de series de tiempo en el pronóstico de la demanda de almacenamiento de productos perecederos. **Estudios Gerenciales**, v. 32, n. 141, p. 387-396, 2016.

LEMOS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. 2006.

LINDBERG, E.; ZACKRISSON, U. Deciding about the uncertain: The use of forecasts as an aid to decision-making. **Scandinavian Journal of Management**, v. 7, n. 4, p. 271-283, 1991.

LINSTONE, H. A. *et al.* (Ed.). **The Delphi method**. Reading, MA: Addison-Wesley, 1975.

MAKRIDAKIS, S. Accuracy measures: theoretical and practical concerns. **International Journal of Forecasting**, v. 9, n. 4, p. 527-529, 1993.

PEINADO, J.; GRAEML, A. R. Administração da produção. **Operações industriais e de serviços**. Unicenp, 2007.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Estudo comparativo entre modelos de Winters e de Box-Jenkins para a previsão de demanda sazonal. **Revista Produto e Produção**, v. 4, p. 72-85, 2000.

PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Revista PRODUÇÃO**, v. 11, n. 1, p. 43-64, 2001.

- RIBEIRO, G. F. *et al.* **Classificação de métodos de previsão de demanda para novos produtos**: estudo no sistema brasileiro de franquias. 125p. 2016. Dissertação de Mestrado. Universidade Tecnológica Federal do Paraná, 2016.
- RITZMAN, L. P.; KRAJEWSKI, L. J. **Administração da produção e operações**. Prentice Hall, 2003.
- ROSSETTO, M. *et al.* Técnicas Qualitativas de Previsão de Demanda: um Estudo Multicasos com Empresas do Ramo de Alimentos. In: SIMPÓSIO DE EXCELÊNCIA EM GESTÃO E TECNOLOGIA, 8, 2011. **Anais...** Rio de Janeiro, 2011.
- SANDERS, N. R.; MANRODT, K. B. Forecasting practices in US corporations: survey results. **Interfaces**, v. 24, n. 2, p. 92-100, 1994.
- SANTOS, J. L. F. *et al.* Previsão de demanda: Aplicação e técnica de ajustamento exponencial com tendência em uma empresa de montagem de equipamentos para beleza. In: ENCONTRO DE ENGENHARIA DE PRODUÇÃO AGROINDUSTRIAL, 9, 2017. **Anais...** EEPA, 2017.
- SCHOEMAKER, P. J. H. Multiple scenario development: Its conceptual and behavioral foundation. **Strategic management journal**, v. 14, n. 3, p. 193-213, 1993.
- SPEDDING, T. A.; CHAN, K. K. Forecasting demand and inventory management using Bayesian time series. **Integrated Manufacturing Systems**, v. 11, n. 5, p. 331-339, 2000.
- TUBINO, D. F. **Manual de Planejamento e Controle da Produção**. Atlas, 1997.
- TUBINO, D. F. **Sistemas de produção: a produtividade no chão de fábrica**. Bookman, 1999.
- VERÍSSIMO, A. J. *et al.* Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. **Revista Gestão Industrial**, v. 8, n. 4, 2013.
- WERNER, L. **Análise de séries de tempo: modelos de suavização exponencial**. Porto Alegre: UFRGS, 2000. 33 slides, PeB. Disponível em: <http://www.producao.ufrgs.br/arquivos/disciplinas/119_teq7_st_suaviz_expon.pdf>. Acesso em: 12 jan. 2019.
- WERNER, L.; RIBEIRO, J. L. D. Modelo composto para prever demanda através da integração de previsões. **Production**, v. 16, n. 3, p. 493-509, 2006.
- ZANELLA, C. *et al.* Previsão de demanda: um estudo de caso em uma agroindústria de carnes do oeste catarinense. **GEPROS. Gestão da Produção, Operações e Sistemas**, v. 11, n. 1, p. 45, 2016.