

MODELOS DE PREVISÃO APLICADOS EM UMA INDÚSTRIA FARMACÊUTICA E COSMÉTICA

¹Bruno Martins Moreira; ¹bruno.moreira@uemg.br; ¹Universidade do Estado de Minas Gerais-UEMG;
²Jessica Cândida Silva e Salles; ²jessicacsalles@gmail.com; ²Universidade do Estado de Minas Gerais-UEMG;
³Pedro Vitor Damasceno Machado; ³pedrovdm@outlook.com; ²Universidade do Estado de Minas Gerais-UEMG;

RESUMO: *A previsão de demanda é uma ferramenta de grande necessidade no planejamento estratégico e operacional das empresas que procuram otimizar suas operações. Dentro deste contexto, este trabalho tem como objetivo encontrar um modelo de previsão de demanda para um determinado produto que apresente um erro menor que o método utilizado pela empresa. Este trabalho apresenta um estudo de caso onde foram aplicadas técnicas de previsão de demanda em um produto que pertence ao portfólio de uma empresa do ramo farmacêutico e cosmético localizada no centro-oeste de Minas Gerais. Dentre as 6 técnicas utilizadas, a que apresentou o menor erro foi o método de média móvel ponderada, onde o erro resultante do modelo apresentou um decréscimo em relação ao método em vigor na empresa. Atualmente o erro está em 38,5% e foi reduzido para 12% com a novo modelo de previsão.*

PALAVRAS-CHAVE: *previsão; demanda; outliers.*

ABSTRACT: *Demand forecasting is a tool of great need in the strategic and operational planning of companies seeking their operations. Within this context, this work aims to find a demand forecast model for a given product that presents a smaller error than the method used by the company. This work presents a case study where demand forecasting techniques were applied to a product that belongs to the portfolio of a pharmaceutical and cosmetic company located in the central-west of Minas Gerais. Among the 6 techniques used, a that show display the smallest error was the method of weighted moving average, where the error resulting from the model show a decrease in Relation to the Method In Force at the Company Currently the error is 38.5% and was reduced to 12% with a new forecast model.*

KEYWORDS: *forecasting; demand; outliers*

1. Introdução

A previsão de demanda é tomada como ponto de partida para o planejamento de várias atividades realizadas nas empresas, dentre elas, o planejamento do fluxo de caixa, da produção, de vendas, controle de estoques, compras, entre outras. Quanto maior o erro na previsão de demanda, maior é a dificuldade da empresa em se planejar nas diversas áreas funcionais que a compõe e essa dificuldade pode vir a ocasionar desperdícios nas e acabar reduzindo sua competitividade perante os concorrentes. (MIRANDA et al, 2011)

Diante desse contexto, esse artigo tem por objetivo analisar os resultados de análises de previsão de demanda de uma empresa situada em Divinópolis/MG, realizadas por meio de métodos de previsão utilizando o software Minitab.

2. Revisão Bibliográfica

2.1 Previsão de Demanda

De acordo com Moreira (2011), a previsão de demanda consiste em um processo lógico, que tem como finalidade de extrair informações sobre o valor das vendas futuras de um produto específico, de um mix ou família de produtos.

Dias (2011) diz que: “Toda atividade de planejamento requer previsões sobre um fato futuro. Quanto melhor for essa previsão, melhores serão as hipóteses utilizadas para o planejamento”.

As empresas buscam estabelecer planos, metas e definir os seus objetivos visando atender as diversas exigências de seus clientes com o intuito de poder oferecer seus produtos no prazo estipulado e com a melhor qualidade (Moreira,2011).

Segundo Turbino (2009), a previsão de demanda, geralmente se baseia em dados históricos e, na maioria das vezes, fornece dados com grande precisão. Ela é uma ferramenta gerencial que tem muita importância, é o input do planejamento e é utilizada para auxiliar nas tomadas de decisão, na determinação de recursos necessários na empresa, no planejamento e controle das áreas produtivas, no desenvolvimento de estratégias e para identificar e avaliar prioridades, certezas e riscos em situações internas e externas.

Ainda para Tubino (2009) a previsão da demanda não é uma ciência exata, pode ser necessário o envolvimento e julgamento do planejador. Elas podem ser de curto, médio e longo prazo. É necessária uma avaliação do erro de previsão para que as decisões tomadas a partir de seus modelos sejam mais assertivas. Um fluxograma do processo de previsão pode ser desenhado de acordo com a Figura 1.

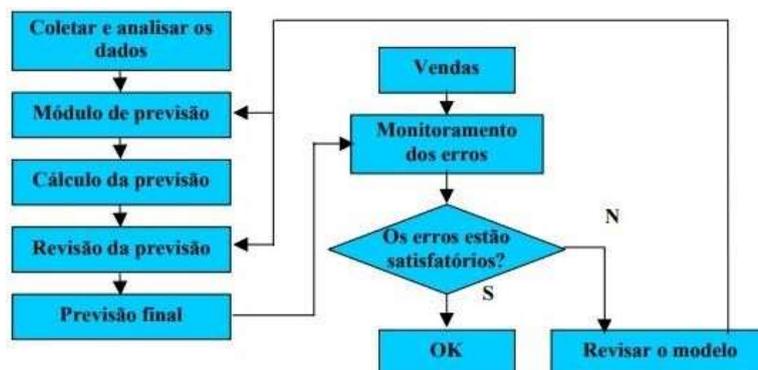


FIGURA 1 – Processo de previsão. Fonte: Dias (2009)

Existem diversas técnicas, métodos e recursos utilizados para realizar a previsão a partir de uma série temporal. No decorrer do presente artigo serão abordados de forma sucinta alguns

métodos quantitativos de previsão de demanda.

2.2 Séries Temporais

As séries temporais utilizam dados de forma organizada em uma linha temporal crescente. Estes dados podem ser: chuvas anuais em uma cidade, observações diárias de um processo químico, crescimento anual da população de lebres, média mensal de temperatura em uma cidade e quantidade mensal de vendas de um filtro de óleo (CRYER; CHAN, 2008).

É possível entender como uma característica intrínseca de uma série temporal a interdependência entre as observações vizinhas, ou seja, dados relacionados com a demanda do passado podem ser usados para prever a demanda no futuro. E ainda, a tendência que gerou a demanda no passado continuará gerando a demanda no futuro. (FIGUEIREDO, 2008).

De acordo com Box et al. (2016) a análise de séries temporais preocupa-se em desenvolver técnicas para análise da dependência entre os dados da série temporal, requerendo o desenvolvimento de modelos estocásticos e dinâmicos para diferentes áreas. Durante a análise de uma série temporal pode-se identificar os componentes apresentados no Quadro 1.

QUADRO 1 – Componentes de uma série temporal

Característica	Descrição	Fonte
Tendência	É o comportamento da série a longo prazo.	Lemos (2006)
Sazonalidade	São picos e vales regulares de valores que se repetem anualmente.	Lemos (2006)
Estacionariedade	Uma série temporal é dita estacionária quando seu comportamento se desenvolve ao redor de uma mesma média constante, podendo ser estacionária por períodos curtos ou longos.	Portal Action (2020)
Outliers	São as observações de uma série que não são explicadas pelas outras observações;	Lemos (2006)

Fonte: os autores (2020).

2.3 Técnicas quantitativas de previsão de demanda

2.3.1 Média Móvel

Para Makridakis et al. (1998) a média móvel é considerada um indicador que busca medir

a tendência baseada nos dados históricos mais recentes, seja ela medida em três ou mais períodos. Geralmente, sua representação gráfica é feita por meio de uma linha que se altera a cada dado incluído na parametrização.

O método da Média Móvel é amplamente utilizado pela sua facilidade de implementação e manutenção e pela necessidade de poucos dados históricos para a sua aplicação. Entretanto, este método é apropriado somente para previsões de curto prazo e para dados históricos irregulares, onde o padrão da série temporal não apresenta tendência e sazonalidade (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

A média móvel simples é calculada como mostra a fórmula a seguir:

$$MMS_n = \frac{(V_1 + V_2 + \dots + V_n)}{n} \quad (1)$$

Onde n refere-se ao número de períodos e V a cada valor presente nos dados.

2.3.2 Média Móvel Ponderada

Segundo Moreira (2011) a média móvel ponderada atribui diferentes importâncias aos valores utilizando a multiplicação de pesos para realizar suas medições. O cálculo da média ponderada é realizado por meio do somatório das multiplicações entre valores e pesos divididos pelo somatório dos pesos e se dá pela seguinte fórmula:

$$MMS_n = \frac{(V_1 * P_1) + (V_2 * P_2) + \dots + (V_n * P_n)}{n} \quad (2)$$

A soma dos pesos deve ser igual a 1. Tal como no caso da média móvel, a escolha de n é arbitrária, assim como a escolha dos pesos. A vantagem sobre a média móvel é que os valores mais recentes da demanda, que podem revelar alguma tendência, recebem importância maior (MOREIRA, 2011).

2.3.3 Suavização Exponencial

Os métodos de suavização exponencial possuem um esquema de ponderação que tem pesos decrescentes à medida que as observações envelhecem, ou seja, “os valores recentes têm um peso relativamente maior na previsão do que as observações mais antigas” (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

2.3.3.1 Suavização Exponencial Simples

O método de suavização exponencial considera que o padrão da série temporal contém apenas componentes de nível e ruído.

O método de suavização exponencial simples obtém uma previsão F_{t+1} a partir do ajuste da previsão anterior F_t usando o erro de previsão. O erro é obtido a partir diferença entre a observação Y_t e a previsão F_t , ou seja: $Y_t - F_t$. A partir disso, podemos concluir que a previsão para o próximo período é dada pela fórmula:

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (3)$$

onde α é uma constante entre 0 e 1 (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

Para iniciar o método, é necessário F_t , que pode ser obtido de 2 maneiras:

- Considerando a última observação da série temporal;
- Considerando uma média das últimas n observações da série temporal.

A previsão obtida por este modelo sempre seguirá a tendência na série temporal trabalhada, pois o máximo que o método pode fazer é ajustar a próxima previsão para algum percentual do erro mais recente. Quando α é próximo de 1, a nova previsão incluirá um grande ajuste do erro da previsão anterior, e quando é próximo de 0 esse ajuste é pequeno (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

2.3.3.2 Suavização Exponencial Dupla

Também conhecida como Suavização Linear de Holt, este método considera também os conjuntos de dados que apresentam tendência linear, ele complementa o método de Suavização Exponencial Simples.

Também conhecida como Suavização Linear de Holt, este método considera também os conjuntos de dados que apresentam tendência linear, ele complementa o método de Suavização Exponencial Simples.

Em complemento, na Suavização Exponencial Dupla utiliza duas constantes de suavização não relacionadas, α e β (com valores entre 0 e 1) (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

Para obter a previsão, o modelo utiliza 3 equações, uma para previsão, uma para nível e outra para tendência:

$$\text{Previsão: } F_{t+m} = L_t + b_t m \quad (4)$$

$$\text{Nível: } L_t = \alpha Y_t + (1 - \alpha)(L_{t+1} + b_{t+1}) \quad (5)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (6)$$

onde,

F_{t+m} = previsão para o período $t+m$;

m = horizonte de previsão;

L_t = estimativa do nível da série temporal no período t ;

b_t = estimativa de tendência da série temporal para o período t .

Os valores da previsão são obtidos através da soma da estimativa de nível com a estimativa de tendência multiplicada pelo horizonte de previsão; a função da equação de nível é ajudar na eliminação do atraso na incorporação de mudanças de padrão na demanda; e a equação de tendência atualiza a tendência da série ao longo da análise das observações t (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1998).

2.3.6 Holt-Winters

O método de Holt-Winters é utilizado em situações em que as séries temporais apresentam padrão de demanda com tendência linear e sazonalidade. O método aplica equações de suavização para estimar o nível, a tendência e a sazonalidade da série temporal analisada no processo de previsão (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 1998).

Existem duas abordagens do método, nas quais dependem da forma da modelação da sazonalidade. As formas são: Multiplicativa ou Aditiva. Onde a forma multiplicativa é indicada para séries temporais em que a amplitude da sazonalidade varia com o nível da demanda e a forma aditiva é apropriada para séries temporais cuja amplitude da sazonalidade é independente do nível de demanda (WINTERS, 1960).

As equações básicas para o método multiplicativo de Holt-Winters são:

$$Nível: L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$Tendência: b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$

$$Sazonal: S_t = \gamma \frac{Y_t}{Y_{t-s}} + (1 - \gamma)S_{t-s} \quad (9)$$

$$Previsão: F_{t+m} = (L_t + b_t m)S_{t-s+m} \quad (10)$$

Onde s é a duração da sazonalidade (por exemplo, número de meses ou trimestres em um ano), L_t representa o nível da série, b_t denota a tendência, S_t é o componente sazonal e F_{t+m} é a previsão para m períodos à frente. (MAKRIDAKIS; WHELLWRIGHT; HYNDMAN, 1997).

2.3.7 Erro médio de previsão (EPAM)

De acordo com Moreira (2012), por mais sofisticados e precisos que os métodos de previsão sejam, ainda possuem um grau de incerteza. Para verificar as medidas de adequação e desempenho da precisão que o modelo possui são empregados erros de previsão. Quando as previsões estão muito próximas dos dados reais os erros obtidos são mais baixos.

$$EPAM = \frac{F_t - Y_t}{Y_t} * 100 \quad (11)$$

onde,

F_t = previsão para o período t ;

Y_t = vendas reais no período t .

3. Metodologia

Esta pesquisa trata-se de um estudo de caso, visando conhecer como e por que de um determinado processo de uma indústria farmacêutica e cosmética. Possui abordagem qualitativa, uma vez que são realizadas análises utilizando métodos matemáticos e análises visuais de gráficos, e natureza aplicada, sendo dirigido a solução de um problema (GERHARDT; SILVEIRA, 2009).

A empresa está localizada no centro-oeste de Minas Gerais, possui um portfólio de mais de 500 produtos, cerca de 1000 funcionários, em uma instalação 56000m². A empresa possui participação no mercado de cosméticos e farmacêuticos da América Latina.

A empresa conta com um processo de previsão de demanda que apresenta erro em alguns de seus produtos, especificamente para o produto estudado (Produto X) foi selecionado pois o erro atual em sua previsão é de 38,59% . Esta baixa assertividade influencia em toda a cadeia de valor da empresa, uma vez que o processo de previsão de demanda é a primeira etapa da cadeia.

Os dados foram coletados diretamente do sistema ERP da empresa. Através de análises e simulações realizadas no Minitab 19, foram trabalhadas as tendências, sazonalidades e possíveis cortes na série temporal com o intuito de encontrar o modelo com o menor erro percentual quando comparado ao método empírico apresentado utilizado pela empresa atualmente.

4. Resultados e discussões

Os dados coletados para a análise do Produto X são representados em unidades e formam uma série temporal de 68 períodos, contemplando os meses de janeiro de 2015 a agosto de 2020. O erro de previsão médio do Produto X na empresa é de 38,59%. Os dados da série temporal estão representados no Figura 2.

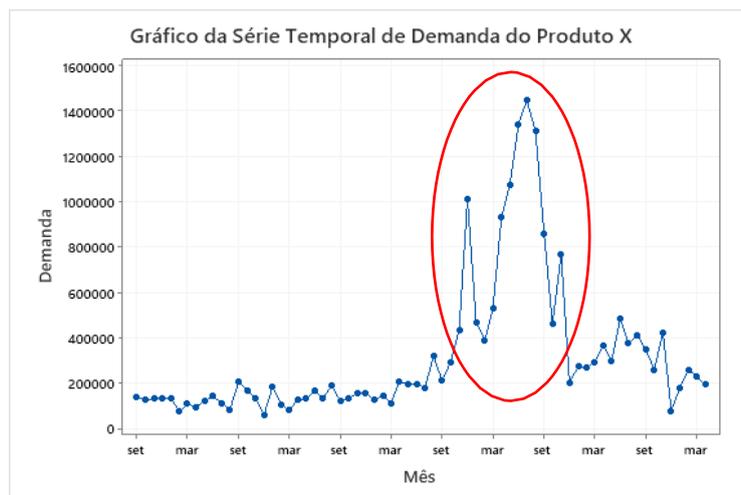


FIGURA 2 Série temporal da demanda do período de janeiro de 2015 até agosto de 2020. Fonte: os autores (2020)

Pode-se observar o ano de 2018 apresentou um comportamento atípico na série temporal. O motivo deste aumento de demanda está diretamente relacionado com a uma nova aplicação do produto. Conseqüentemente o produto ampliou o seu mercado usual, passando a abarcar o nicho das crianças e adolescentes. Durante a análise, foi identificada a necessidade de gerar cortes na série temporal, ou seja, retirar os *outliers* para obter padrões ao longo da demanda afim de encontrar o melhor modelo de previsão.

Na Figura 3 é mostrada a série temporal sem os *outliers* e organizada de acordo com 2 patamares de demanda: o 1º patamar de demanda é composto pelos períodos 1 ao 35; o 2º patamar é composto dos dados seguidos aos períodos retirados da série temporal.

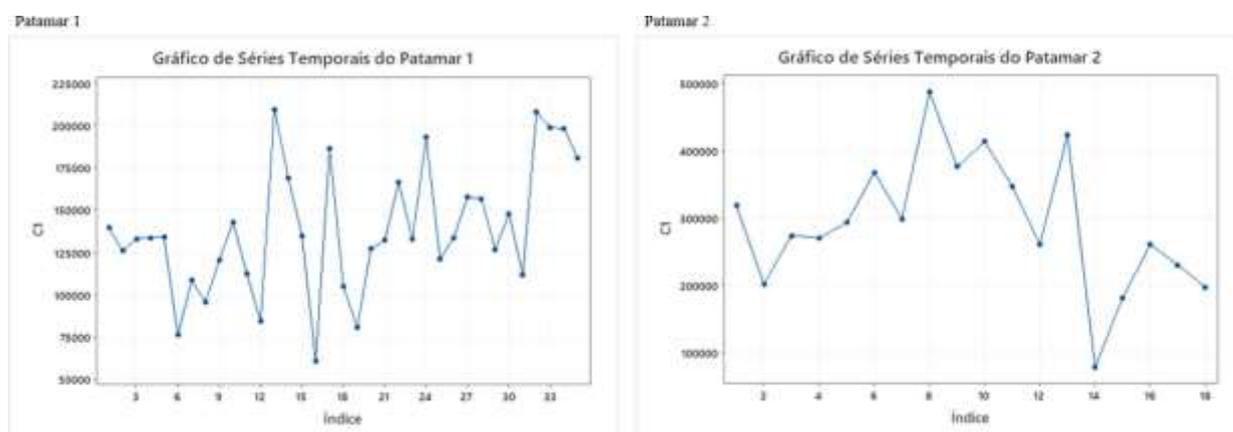
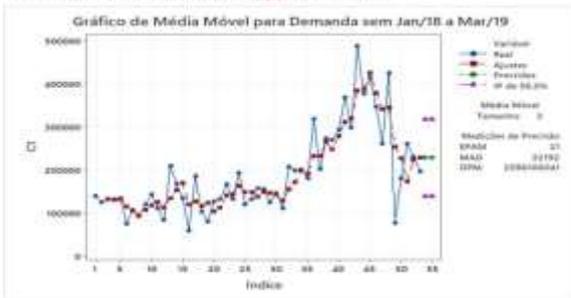


FIGURA 3 - Séries temporais dos Patamares 1 e 2. Fonte: os autores (2020)

Após a definição dos patamares de análise, foram utilizados os seguintes métodos de previsão: média móvel, média móvel ponderada, suavização exponencial simples e dupla e o método de Winters. É importante frisar que os dados apresentados se referem somente ao métodos da média móvel e média móvel ponderada, pois foram estes métodos que apresentam os menores erros.

O método de média móvel (3 períodos) utiliza os três últimos períodos reais para obter a previsão para o período seguinte, sendo assim a previsão para todos os períodos subsequentes serão iguais até que os dados reais sejam adicionados a série, conforme apresentado na Figura 4.

Média Móvel – Demanda sem jan/18 a mar/19



Média Móvel – Patamar 1



Média Móvel – Patamar 2



Média Móvel – Previsões

Previsões – Demanda sem jan/18 a mar/19

Período	Previsão Inferior	Superior
34	229248	318982
35	229248	318982

Previsões – Patamar 1

Período	Previsão Inferior	Superior
36	192240	248813
37	192240	248813

Previsões – Patamar 2

Período	Previsão Inferior	Superior
19	229248	359788
20	229248	359788

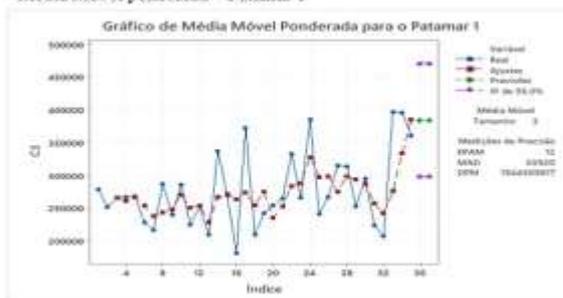
FIGURA 4 – Média Móvel para a série sem jan/18 a mar/19, Patamar 1 e Patamar 2. Fonte: os autores (2020)

O método de média móvel ponderada utiliza de pesos para ponderar os dados da previsão. Foram atribuídos pesos de 1 a 5 de acordo com a flutuação da demanda, nos quais as menores demandas receberam pesos maiores, e as demandas maiores, que se acredita que não irão se repetir, receberam pesos menores. Assim como no método da média móvel simples, na Figura 5 podemos observar as previsões para todos os períodos subsequentes serão iguais até que os dados reais sejam adicionados a série, tenham seus respectivos pesos atribuídos e ponderados em seguida.

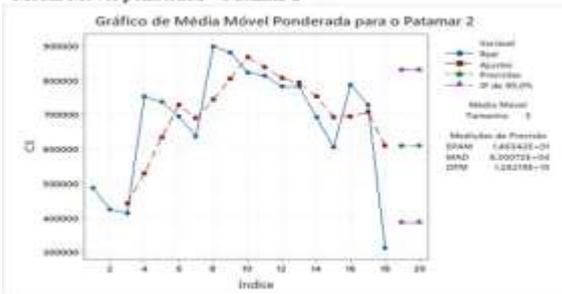
Média Móvel ponderada – Demanda sem jan/18 a mar/19



Média Móvel ponderada – Patamar 1



Média Móvel ponderada – Patamar 2



Média Móvel Ponderada – Previsões

Previsões – Demanda sem jan/18 a mar/19

Período	Previsão Inferior	Superior
34	753336	955208
35	753336	955208

Previsões – Patamar 1

Período	Previsão Inferior	Superior
36	384480	470903
37	384480	470903

Previsões – Patamar 2

Período	Previsão Inferior	Superior
19	609312	831246
20	609312	831246

Figura 5 – Média Móvel Ponderada para a série sem jan/18 a mar/19, Patamar 1 e Patamar 2. Fonte: Os Autores (2020)

Analisando todos os métodos, foi observado que o método de média móvel ponderada apresentou melhor ajuste e o menor erro de previsão em todas as séries simuladas.

A previsão sugerida para os próximos períodos que apresentou o menor erro foi o método de média móvel ponderada aplicada ao Patamar 1, conforme podemos observar na figura 13.

Figura 12 – Erros de previsão médio por método de análise

	Método da empresa	Média Móvel	Média Móvel Ponderada	Suavização Exponencial Simples	Suavização Exponencial Dupla	Holt-Winters Aditivo	Holt-Winters Multiplicativo
Demanda sem jan/18 a mar/19	39%	21%	15%	29%	31%	32%	32%
Patamar 1		18%	12%	22%	25%	23%	23%
Patamar 2		27%	15%	37%	40%	42%	40%

Fonte: Os Autores (2020)

O erro médio de previsão elevado das análises da demanda “sem jan/18 a mar 19” e o Patamar 2 apresentarem pode ser explicado pelos meses de mar/20 a ago/20 cujas demandas foram afetadas pelo período de pandemia do Covid-20.

5. Considerações Finais

Os cortes na demanda foram necessários por serem períodos atípicos na demanda que nunca ocorreram e não voltaram a ocorrer até a data final deste estudo, portanto estes períodos influenciariam a análise de maneira negativa, ou seja, aumentado o erro médio de previsão nas análises.

Os resultados do estudo após os cortes se mostraram satisfatórios, uma vez que foi encontrado um método de previsão que apresenta um erro médio de 12%, o erro de previsão atual da empresa é de 38,59%.

A previsão de demanda sugerida para o próximo período por este método foi de 384480 unidades, podendo variar de 298057 até 470903. Após apuração das vendas reais da empresa foi observada uma venda de 378504 unidades, que está entre os valores mínimo e máximo da previsão. O erro médio real foi de 1,58%, indicando que a melhor escolha para previsão desta série temporal é o modelo de média móvel ponderada.

6. Referências Bibliográficas

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C.; LJUNG, Greta M.. **Time Series Analysis: forecasting and control**. 5. ed. Hoboken: Wiley, 2016. 669 p.

CRYER, Jonathan D.; CHAN, Kung-sik. **Time Series Analysis: with applications in r**. 2. ed. New York: Springer, 2008. 501 p.

DIAS, G. P. P.. **Proposta de processo de previsão de vendas para bens de consumo**. 2009. Disponível em: <http://www.proage.com.br/proage/exe/empresa/publicacoes/bens_de_consumo.pdf>. Acesso em: 13 de agosto

FIGUEIREDO, Clodoaldo José. **Previsão de Séries Temporais Utilizando a Metodologia Box & Jenkins e Redes Neurais para Inicialização de Planejamento e Controle de Produção**. 2008. 176 f. Dissertação (Mestrado) - Curso de Métodos Numéricos em Engenharia, Departamento de Construção Civil e do Departamento de Matemática, Universidade Federal do Paraná, Curitiba, 2008.

LEMOS, Fernando de Oliveira. **Metodologia para seleção de métodos de previsão de demanda**. 2006. 183 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Engenharia de Produção, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

MAKRIDAKIS, Spyros G. *et al.* **Forecasting: methods and applications**. 3. ed. New York, United States: John Wiley & Sons Inc, 1997.

MOREIRA, Daniel Augusto. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2011.

PORTAL ACTION. **Séries Temporais**. Disponível em: <http://www.portalaction.com.br/series-temporais/11-estacionariedade>. Acesso em: 10 jun. 2020.