

Comparação entre modelos de previsão de demanda: estudo de caso de um restaurante de comida japonesa

Anderson Barboza da Cruz
Faculdade Machado Sobrinho (FMS), Juiz de Fora, MG, Brasil
cruz.andersom@gmail.com

Resumo

Este artigo tem o objetivo de analisar os modelos de previsão aplicados em um restaurante de comida japonesa onde foram encontrados níveis significativos de tendência e sazonalidade. Trata-se de um estudo de caso cujo período de observação foi delimitado entre abril e setembro de 2015. O estudo é o primeiro passo para a gestão dos estoques e partiu da classificação ABC para verificar qual produto deveria ter maior atenção. Foram testados os métodos das Médias, Amortecimento Exponencial, Amortecimento Exponencial de Holt, Amortecimento Exponencial de Winters e Métodos de Box e Jenkins. Para validação dos métodos foram utilizados os testes de Erro Absoluto Médio Percentual (EAMP) e Desvio Absoluto Médio (DAM). Ao término dos testes, verificou-se que o Método de Amortecimento Exponencial para séries com Tendência e Sazonalidade de Winters foi o mais indicado para a série temporal em questão.

Palavras-chave: Previsão de Demanda. Estoque. Modelos de Previsão.

Abstract

This article aims to analyze the predictive models applied in a Japanese restaurant where we find significant levels of trend and seasonality. It is a case study whose period of observation conducted between April and September 2015. The study is the first step in the management of inventories and left the ABC classification to determine which product should have more attention. The methods of Averages were tested, Exponential Smoothing, Holt Exponential Smoothing, Exponential Smoothing Winters, Box and Jenkins Methods. To validate the methods it was used the Mean Absolute Percentage Error tests (EAMP) and Mean Absolute Deviation (MAD). At the end of the tests, it was found that the exponential smoothing method for series and with trends seasonality Winters was the most appropriate for the time series in question.

Keywords: Forecast of Demand. Stock. Forecast Models.

1. Introdução

Saber prever a demanda pode ser uma forma de amenizar prejuízos no meio organizacional e, desta forma, ter no estoque somente o necessário.

Como Tzu (2012, p. 34) disse em A Arte da Guerra: “Se te conhece e conhece teu inimigo, não temerás o resultado de cem batalhas. Se te conhece e não conhece teu inimigo para cada vitória terás uma derrota. Se não te conhece nem conhece teu inimigo, não terás vitória alguma”. Fazendo uma analogia com as palavras de Tzu, deve-se conhecer a empresa e seus clientes para tomar as melhores decisões.

Segundo Slack *et al.* (2009), a incerteza faz com que tanto o planejamento como o controle sejam mais difíceis. Makridakis *et al.* (1998) dizem que realizar previsões de demanda é importante para auxiliar na determinação dos recursos necessários para a empresa. Em um ambiente onde a concorrência está cada vez mais acirrada, os lucros vêm diminuindo e com o cliente cada vez mais exigente, o uso destas técnicas pode garantir vantagem competitiva.

Este trabalho é um estudo de caso realizado no Restaurante de comida japonesa Sensei, situado em Juiz de Fora, onde foram analisadas as necessidades de materiais através da verificação dos melhores métodos de previsão a serem utilizados. Este estudo tem o objetivo de pesquisar na literatura modelos de previsão que apresentem maior assertividade reduzindo faltas e perdas para o negócio.

Para Tubino (2000), a previsão de demanda permite que os administradores das organizações antecipem o futuro e planejem de forma mais conveniente suas ações. A previsão de demanda serve de guia para a organização, pois o estoque de matéria prima, por exemplo, é o que move a empresa.

Assim, acredita-se que a relevância deste estudo esteja na possibilidade de associar a literatura disponível e um estudo de caso.

2. Embasamento teórico

Atualmente conta-se com modelos de previsão tanto quantitativos quanto qualitativos. Neste estudo optou-se por utilizar modelos quantitativos, uma vez que a fonte de dados para o estudo foi a série histórica de vendas do restaurante que é o objeto deste estudo. Os modelos quantitativos podem ser baseados em séries temporais ou modelos causais. As séries temporais são baseadas no histórico da empresa, ou seja, baseados no passado. Os modelos causais analisam o quanto uma variável interna ou externa pode impactar nas vendas, por exemplo, e analisam causa e efeito.

Os modelos de séries temporais são mais adequados nos casos em que se espera que a demanda futura siga os padrões históricos (CHOPRA; MEINDL, 2003), porém não são perfeitos. Ballou (2006) diz que pelo fato do futuro não refletir perfeitamente o passado, pode haver erros. Esses podem ser quantificados como sendo a diferença entre a demanda real e a prevista. Por este motivo, não se deve utilizar somente um modelo, mas sempre verificar o que melhor se enquadra à necessidade.

2.1. Métodos de previsão

Será feito um breve apanhado sobre alguns métodos de previsão, a saber: média móvel, média móvel ponderada, amortecimento exponencial simples, amortecimento exponencial de séries com tendência (Holt), amortecimento exponencial de séries com tendência e variações de estado (Winter) e modelo de Box e Jenkins.

2.1.1. Média Móvel

Segundo Ballou (2006), o modelo de média móvel deve ser usado quando a demanda não apresenta tendência ou sazonalidade. Nesse modelo, estimamos o nível em t pela média da demanda durante os N períodos mais recentes:

$$L_t = \frac{D_t + D_{t-1} + \dots + D_{t-N+1}}{N} \quad (1)$$

A previsão atual para todos os períodos futuros é a mesma e baseia-se na estimativa de nível atual (CHOPRA; MEINDL, 2011):

$$L_{t+1} = L_t \text{ e } F_{t+n} = L_t \quad (2)$$

2.1.2. Média Móvel Ponderada

Segundo Moreira (2013), a média móvel ponderada se diferencia da média móvel, pois os valores recebem pesos diferentes, geralmente refletindo uma maior importância dada aos valores mais recentes da demanda. A soma dos pesos de ponderação deve ser igual a 1.

$$P_t = W_t Y_t + W_{t-1} Y_{t-1} \dots + W_{t-N+1} Y_{t-N+1} \quad (3)$$

onde W é o valor da ponderação.

2.1.3. Amortecimento Exponencial Simples

O método é considerado uma média ponderada de dados anteriores, com peso de ponderação diminuindo exponencialmente à medida que se afastam da data atual (CORREA; CORREA, 2006). A equação pode ser definida por:

$$P_{t+1} = \alpha D_t + (1-\alpha)P_t \quad (4)$$

onde:

P_{t+1} – Previsão para o tempo seguinte;

D_t – Demanda no instante t ;

P_t – Previsão para o instante t ;

α – Constante de ponderação, variando entre 0 e 1.

Este método é indicado se tendência e sazonalidade não representam variações substanciais (BALLOU, 2006).

Já para Correa e Correa (2006), o nível em um determinado período pode ser representado como uma função entre a demanda atual e o nível no período anterior:

$$P_{t+1} = \sum_{n=0}^{t+1} \alpha (1-\alpha)^n D_{t+1-n} \quad (5)$$

A estimativa atual do nível é a média ponderada de todas as observações anteriores de demanda, com observações recentes com peso maior que as antigas observações. Um valor mais alto de α corresponde a uma previsão mais responsiva a observações recentes, ao passo que um valor mais baixo de α representa uma previsão mais estável e menos responsiva (CHOPRA; MEINDL, 2011).

2.1.4. Amortecimento Exponencial de Séries com Tendência (Holt)

O “Modelo de Holt” é indicado quando existe tendência, porém ausência de sazonalidade. Nesse caso, a equação que representa o método é dada por:

$$D_t = a_t + b \quad (6)$$

Para Moreira (2013), é aconselhável a execução da regressão linear entre demanda e períodos de tempo, pois a demanda possui uma tendência, mas não possui sazonalidade. A relação entre tempo e demanda é linear, logo b mede a estimativa em $t=0$ e é uma estimativa do nível inicial L_0 . A inclinação α mede a mudança na demanda por período de tempo e é estimativa de tendência T_0 . Logo:

$$F_{t+1} = L_t + T_t \quad \text{e} \quad F_{t+n} = L_t + nT_t \quad (7)$$

onde a componente de nível pode ser encontrada com a seguinte fórmula:

$$L_{t+1} = \alpha D_{t+1} + (1-\alpha)(L_t + T_t) \quad (8)$$

A componente de tendência é encontrada com a seguinte fórmula:

$$T_t = \beta(L_{t+1} - L_t) + (1-\beta)T_t \quad (9)$$

onde:

α – Constante de suavização para o nível (valor entre 0 e 1);

β – Constante de suavização para a tendência (valor entre 0 e 1).

Em cada uma das atualizações, a estimativa é a média ponderada entre o valor observado e a antiga estimativa (BALLOU, 2006).

2.1.5. Amortecimento Exponencial de Séries com Tendência e Variações de Estado (Winter)

Este modelo é indicado quando a demanda possui tendência e sazonalidade. Neste caso, o componente sistemático da demanda é dado por:

$$\text{Componente sistemático da demanda} = (\text{nível} + \text{tendência}) \times \text{fator de sazonalidade} \quad (10)$$

O processo para se obter as estimativas é igual ao da Suavização Exponencial de Séries com tendência.

No período t , dadas as estimativas L_t , tendência T_t e fatores de sazonalidade $S_t \dots, S_{t-p+1}$, a previsão para os períodos futuros é dada por:

$$F_{t+1} = (L_t + T_t)S_{t+1} \quad \text{e} \quad F_{t+n} = (L_t + nT_t)S_{t+n} \quad (11)$$

Para Moreira (2013), as estimativas para o nível acontecem quando observamos o período $t+1$:

$$L_{t+1} = \alpha \left(\frac{D_{t+1}}{S_{t+1}} \right) + (1-\alpha)(L_t + T_t) \quad (12)$$

$$T_{t+1} = \beta(L_{t+1} - L_t) + (1-\beta)T_t \quad (13)$$

$$S_{t+p+1} = \gamma \left(\frac{D_{t+1}}{L_{t+1}} \right) + (1-\gamma)S_{t+1} \quad (14)$$

onde:

α – Constante de suavização para o nível (valor entre 0 e 1);

β – Constante de suavização para a tendência (valor entre 0 e 1);

γ – Constante de suavização para a sazonalidade (valor entre 0 e 1).

Cada uma das atualizações (nível, tendência e sazonalidade), a estimativa é a média ponderada entre o valor observado e a antiga estimativa (TUBINO, 2000).

2.1.6. Modelo de Box e Jenkins

Modelos Autorregressivos Integrados de Média Móvel partem do princípio que os valores de uma série temporal mantêm relação de dependência. Logo, cada valor atual pode ser explicado através do valor anterior (PELLEGRINI; FOGLIATTO, 2001).

Como foi dito por Morettin e Tolo (2006), os principais recursos utilizados para a identificação e diagnóstico das séries onde se possa utilizar o Método ARIMA são as funções de autocorrelação (FAC) e autocorrelação parcial (FACP). Para podermos utilizar o método, as funções devem se comportar como um modelo estocástico. Os modelos ARIMA são regidos pela seguinte equação geral:

$$x_t - x_{t-d} = w_t = \Phi(w) + e_t - \theta(e) \quad (15)$$

$$\Phi(w) = \Phi_1 w_{t-1} + \Phi_2 w_{t-2} + \dots + \Phi_p w_{t-p} \quad (16)$$

$$\theta(e) = \theta_1 e_{t-1} + \theta_2 e_{t-2} + \dots + \theta_q e_{t-p} \quad (17)$$

onde:

x_t – Valores da série observados em determinado tempo;

e_t – Erro associado aos valores observados;

p – Ordem do modelo auto regressivo de coeficiente Φ ;

q = Ordem de um modelo de média móvel de coeficientes θ ;

d = Ordem de integração do modelo.

2.2. Validação dos métodos de previsão de demanda

Segundo Ballou (2006), as previsões são baseadas no erro. Errar menos é o que faz um modelo eficaz. O erro E , de um período t , é dado por $E(t)$ e pode ser escrita:

$$E_t = F_t - D_t \quad (18)$$

onde:

E_t – Erro;

F_t – Previsão para período t ;

D_t – Demanda para período t .

Isso significa que o erro no período t é a diferença entre a demanda real e a demanda prevista (DIAS, 1993).

Neste estudo utilizaremos o Desvio Absoluto Médio e Erro Absoluto Médio Percentual para testar a acurácia dos métodos.

Desvio absoluto médio (DAM):

$$DAM_n = \frac{1}{n} \sum_{t=1}^n At \quad (19)$$

$$At = |Et| \quad (20)$$

Pode ser interpretado como sendo a média aritmética dos erros observados. Os valores são calculados em módulo para que durante a soma não se anulem, pois podem conter valores positivos e negativos.

Erro absoluto médio percentual (EAMP):

$$EAMP_n = \frac{\sum_{t=1}^n \left| \frac{Et}{Dt} \right| 100}{n} \quad (21)$$

“É o erro absoluto médio com a porcentagem de demanda” (CHOPRA; MEINDL, 2011, p. 88). O EAMP pode ser entendido como a média dos erros percentuais encontrados na série.

3. Pesquisa de campo

Os dados apresentados neste trabalho foram coletados diretamente com o dono do restaurante durante trabalho de consultoria realizado em janeiro de 2015.

Os maiores problemas com os restaurantes desse tipo estão relacionados à matéria prima. Armazenamento, tempo de vida do produto e tempo para pagamento do fornecedor. Uma falha no gerenciamento de estoque pode gerar perda, aumentar o custo de armazenagem ou falta de matéria prima.

A pesquisa realizada foi autorizada pelo proprietário do restaurante. Os dados divulgados são reais e atuais, uma vez que a empresa foi fundada recentemente. Para apoiar a pesquisa foi desenvolvido um software para automação comercial, que vem sendo utilizado desde o primeiro dia de funcionamento do restaurante.

3.1. Classificação dos estoques

Para Chiavenato (2008), os estoques são classificados segundo o volume de suas quantidades ou do seu valor monetário. Quase sempre um pequeno número de itens corresponde à quase totalidade dos valores. Temos três classes a saber:

- **Classe A:** Pequeno número de itens que totaliza uma grande porcentagem do valor total. Geralmente são os mais caros.
- **Classe B:** Produtos intermediários, entre A e C, que, segundo Chiavenato (2008), merecem atenção individualizada, pois ainda detêm uma porcentagem considerável.
- **Classe C:** Muitos produtos que correspondem a percentual relativamente baixo do estoque.

Essa classificação denominada Curva ABC pode mostrar quais os itens mais importantes do estoque e que serão alvo de estudo.

3.2. Análise dos dados

A análise prévia serve para identificar fatores como sazonalidade e tendências. A descoberta desses fatores auxilia na escolha do modelo de previsão que melhor venha a atender. Para tal, serão utilizadas planilhas eletrônicas, gráficos e relatórios gerados pelo sistema de automação comercial. A análise, segundo Pellegrini e Fogliatto (2000), tem a capacidade de exibir os outliers e ciclos.

Todos os métodos de previsão de demanda que foram descritos no embasamento teórico serão utilizados para verificar a aderência dos modelos. Todos terão os mesmos dados à disposição e irão prever os mesmos intervalos de tempo.

3.3. Validação do modelo

Como foi dito, todos os modelos de previsão são baseados no erro (BALLOU, 2006), pois o que demonstra a capacidade de um modelo de previsão é o menor erro. Para validação dos erros de previsão usaremos os seguintes métodos:

- Desvio absoluto médio (DAM);
- Erro Absoluto Médio Percentual (EAMP).

Após checados os erros em todos os modelos de previsão, eles serão comparados e o modelo que apresentar o menor erro será aquele com maior assertividade.

4. Resultados

Foram coletados os dados das vendas dos primeiros seis meses de funcionamento do restaurante, que foram de abril a setembro de 2015. Os dados foram exportados do MS-Access para planilhas do MS-Excel onde foram modelados. Devido à rotatividade do estoque e o tipo de produto armazenado, o horizonte de previsão não deve ultrapassar 7 dias.

4.1. Classificação

Os dados foram classificados seguindo a curva ABC. Para tal, feito o levantamento e exportado para o MS-Excel, foram selecionados os produtos que são responsáveis por 70% do faturamento, correspondendo à Classe A; em seguida, os responsáveis por mais 20% do faturamento, que correspondem à Classe B; e, para encerrar, o restante dos produtos foi associado à classe C. A ideia é que, “na análise ABC, vamos separar justamente os poucos materiais que custam mais, dos muitos que custam menos” (ZORZO, 2015, p. 27).

Tabela 1 – Classificação dos produtos (Curva ABC).

Receita	Valor	Nº Itens	% Itens	% do Montante
Receita Total	R\$ 131.169,16	120		
Receita em A	R\$ 92.303,61	7	5,83%	70,37%
Receita em B	R\$ 26.636,60	25	20,83%	20,31%
Receita em C	R\$ 12.228,95	88	73,33%	9,32%

Fonte: Dados da pesquisa.

De acordo com a Tabela 1, o produto no topo da Classificação ABC é o Rodízio e será o alvo deste estudo (Tabela 2).

Tabela 2 – Dados Rodizio: Primeiro da Classe A.


Descrição	Total	R\$ Unid.	R\$ Total	% Receita	% R Acum.	Classe
Rodizio	1099	R\$ 54,99	R\$ 60.434,01	46,07%	46,07%	A

Fonte: Dados da pesquisa.

4.2. Análise inicial dos dados

Os dados foram analisados dia a dia, devido à rotatividade do estoque e ao pouco tempo de armazenamento. Para selecionar os modelos que melhor se aplicam à série temporal, foram gerados gráficos a fim de encontrar tendências e sazonalidades.

Figura 1 – Histórico de vendas.



Fonte: Dados da pesquisa.

Após plotados os dados (Figura 1), pode-se verificar uma leve tendência de crescimento das vendas, indicada pela declividade positiva da reta, e sazonalidade, indicada pela variação repetida em intervalos de tempos iguais. Alguns outliers foram encontrados e verificados com o gerente do estabelecimento, que confirmou se tratar de datas especiais como aniversários e reuniões de empresas.

4.3. Aplicação dos modelos de previsão da demanda


Serão utilizados os métodos descritos no referencial teórico: Métodos das Médias: Média Móvel, Média Móvel Ponderada; Amortecimento Exponencial Simples; Amortecimento Exponencial para Séries com Tendência; Amortecimento Exponencial para Séries com Tendência e Sazonalidade e Modelos de Box e Jenkins.

4.3.1. Aplicação do Método da Média Móvel

Na Figura 2, pode-se ver a aplicação do modelo da Média Móvel. Nela, percebe-se que a média móvel apresentou resultados defasados em relação à demanda real. Para análise foi utilizado $N=3$. Segundo Moreira (2013), um valor elevado para N pode suavizar a previsão e

esconder alterações bruscas. Os valores encontrados para DAM e EAMP foram 5,26 e 93,58%, respectivamente.

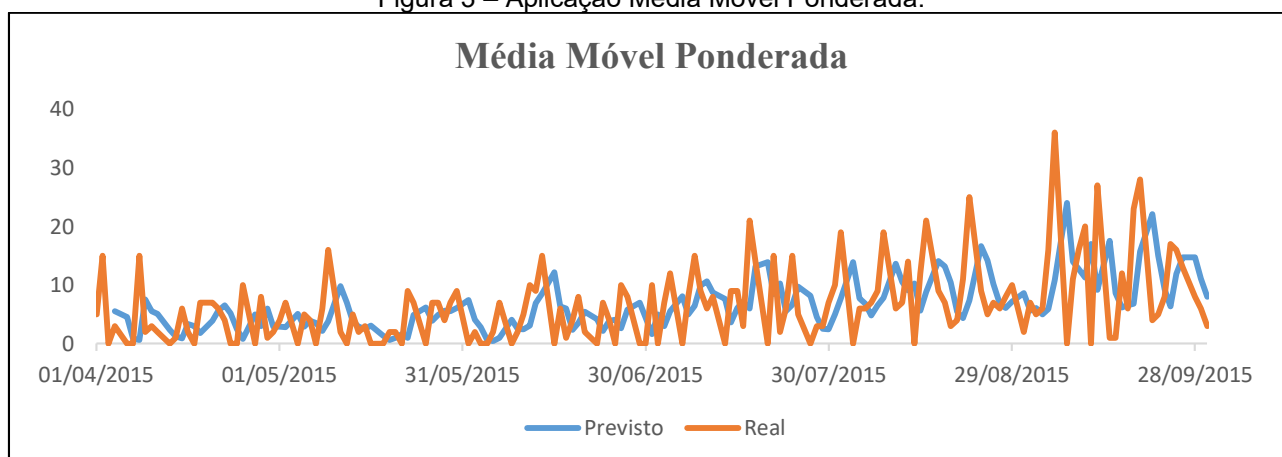
Figura 2 – Aplicação Média Móvel.



Fonte: Dados da pesquisa.

Na Figura 3, pode-se ver a aplicação do modelo da Média Móvel Ponderada. Nela, percebe-se uma maior proximidade entre demanda real e prevista. Ao aplicar a média móvel ponderada com $N=3$ e coeficientes de ponderação de 0,5, 0,3 e 0,2, os valores encontrados para DAM e EAMP foram 6,58 e 75,81%, respectivamente. Quando colocado o coeficiente de ponderação, agrega-se maior valor às observações mais recentes, o que justifica a diferença entre os valores de DAM e EAMP para as médias móveis.

Figura 3 – Aplicação Média Móvel Ponderada.




Fonte: Dados da pesquisa.

4.3.2. Aplicação do Método de Amortecimento Exponencial Simples

O amortecimento exponencial simples trata a demanda como sendo sem tendência e/ou sazonalidade, logo tende a manter o valor central. Para aproximação do valor adequado de alfa foi utilizado o Software Forecast Pro for Windows, o qual retornou o valor de 0,053, o que gerou os valores de DAM e EAMP 4,62 e 78,87%, respectivamente. O Forecast Pro for Windows é um

software para análise e previsão baseado em séries temporais. O software tem a capacidade de ajustar os valores de alfa para garantir melhor aderência do modelo.

Figura 4 – Aplicação do Método Amortecimento Exponencial Simples.



Fonte: Dados da pesquisa.

4.3.3. Aplicação do Método de Amortecimento Exponencial Holt


O amortecimento exponencial de Holt é utilizado quando há tendência na série. A tendência pode ser visualizada na Figura 1, onde se pode verificar a declividade positiva da reta. A equação da reta foi obtida através de regressão linear simples:

$$y = 0,0581x + 1,9907 \quad (22)$$

Para aproximação do valor adequado de alfa e beta foi utilizado o Software Forecast Pro for Windows, o qual retornou $\alpha = 0,02487$ e $\beta = 0,15952$, gerando valores para DAM e EAMP de 4,70 e 84,11%, respectivamente.

A Figura 5 mostra o Amortecimento Exponencial de Holt. Pode-se verificar que o método acompanha a linha de tendência, o que reduz a defasagem e atraso encontrados nos métodos anteriores.

Figura 5 – Amortecimento Exponencial de Holt.



Fonte: Dados da pesquisa.

4.3.4. Amortecimento Exponencial de Winters

O amortecimento exponencial de Winters atua em séries onde existem tendência e sazonalidade. O método escolhido foi o aditivo. Os valores sugeridos pelo Software Forecast Pro for Windows para os coeficientes de amortecimento e sazonalidade foram $\alpha= 0,00731$, $\beta=0,49258$ e $\gamma= 0,15911$. Como os ciclos sazonais foram divididos semanalmente, o intervalo de dias úteis foi de 6 dias. Os índices de sazonalidade encontrados constam na Tabela 3.


Tabela 3 – Índices de sazonalidade.

Segunda	Terça	Quarta	Quinta	Sexta	Sábado
-0.78021	2.6689	9.8887	-5.9849	-3.6691	-2.1233

Fonte: Dados da pesquisa.

A Figura 6 mostra os resultados encontrados, com os valores de DAM e EAMP em 3,92 e 76,97%, respectivamente.

Figura 6 – Amortecimento Exponencial de Winters.



Fonte: Dados da pesquisa.

4.3.5. Aplicação dos Métodos de Box e Jenkins


Dentre os modelos existentes no método de Box e Jenkins, o escolhido foi o ARIMA (0,0,0)*(1,0,1). O que justifica a escolha são as funções de autocorrelação e autocorrelação parcial.

“A correlação de uma série com seus próprios valores defasados é chamada de auto correlação ou correlação serial. A primeira auto correlação é a correlação entre Y_t e Y_{t-1} , ou seja, é a correlação entre os valores de Y em duas datas diferentes” (STOCK, 2004, p. 295) e tem a função de encontrar padrões de repetição e verificar o quanto uma variável é capaz de influenciar as adjacentes.

A Figura 7 mostra a função de autocorrelação entre os dados. Quando um gráfico de autocorrelação é examinado e verifica-se a possibilidade de uso de um modelo AR, recorre-se ao gráfico de autocorrelação parcial, que pode ser visualizado na Figura 8. Este exibe o resultado da


função de autocorrelação parcial que é usada comumente para identificação do modelo de Box e Jenkins ou ordem do modelo autorregressivo. Os resultados da aplicação do modelo assim como a comparação com os valores reais podem ser visualizados na Figura 9.

Figura 7 – Função de autocorrelação.



Fonte: Software Forecast Pro For Windows 2000.


Figura 8 – Função de autocorrelação parcial.



Fonte: Software Forecast Pro for Windows 2000.

Com o método ARIMA foram encontrados os seguintes valores para DAM e EAMP, respectivamente: 3,89 e 72,15%.

Figura 9 – Aplicação dos Modelos de Box e Jenkins.



Fonte: Dados da pesquisa.

4.4. Aplicação dos métodos de validação para os modelos

Para validação dos modelos serão comparados os valores encontrados para DAM e EAMP. O que apresentar os menores valores será o mais indicado para este tipo de demanda.

Tabela 4 – Comparação dos métodos de previsão.


Métodos	Média Móvel	Média Móvel Ponderada	Amortecimento Exponencial	Amortecimento Exponencial de Holt	Amortecimento Exponencial de Winters	Box e Jenkins
DAM	5,26	6,58	4,62	4,70	3,92	3,88
EAMP	93,58%	75,81%	78,87%	84,11%	76,97%	72,15%

Fonte: Dados da pesquisa.

Após análise dos resultados de DAM e EAMP, verifica-se que o modelo que apresenta níveis mais baixos é o ARIMA de Box e Jenkins. Pode-se verificar que todos os modelos de previsão geraram altos níveis para EAMP, que demonstra ineficácia dos modelos, pois mede o percentual da demanda comprometida com falhas de previsão. Os altos índices de EAMP são justificados pela alta variação na demanda gerada por dias de demanda nula e que não podem ser descartados da série histórica, pois fazem parte do ciclo de sazonalidade. Quando analisados dia a dia, os níveis de venda são mais baixos, o que justifica um baixo valor para o DAM, pois os valores da série são menores.


Para aumentar a acurácia dos testes, fora feito um novo comparativo com as séries agregadas de forma semanal em vez de diária. Com o novo teste, os dias de demanda nula foram diluídos e os valores de cada série foram maiores. Os novos períodos de previsão foram de quatro semanas e ciclos de sazonalidade mensais, gerando quatro ciclos por mês. As figuras de 10 a 15 mostram os resultados dos novos testes.

Figura 10 – Novo teste Média Móvel.



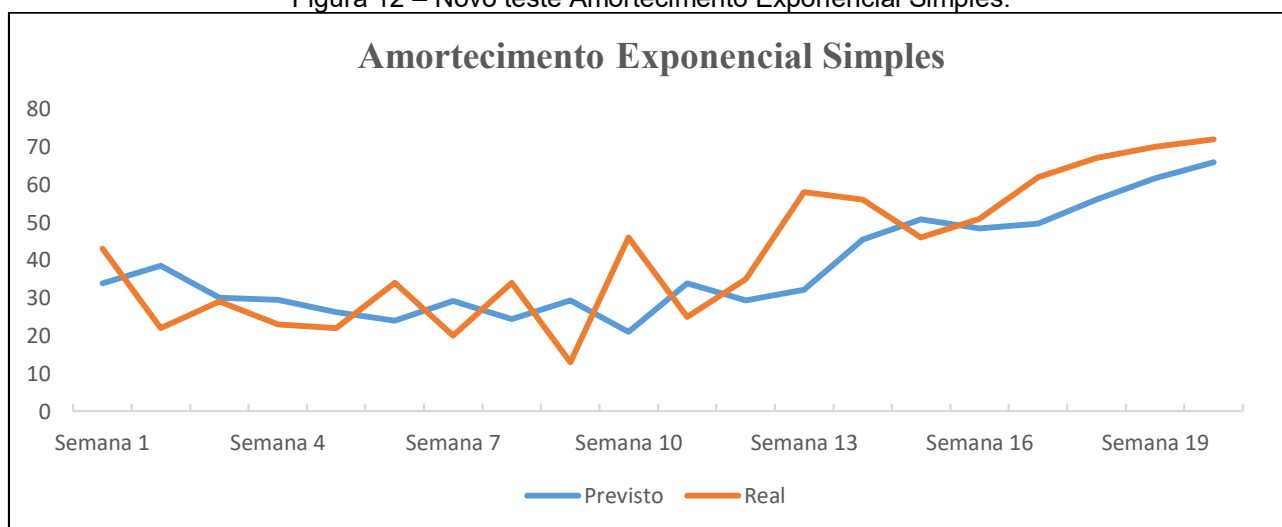
Fonte: Dados da pesquisa.

Figura 11 – Novo teste Média Móvel Ponderada.




Fonte: Dados da pesquisa.

Figura 12 – Novo teste Amortecimento Exponencial Simples.




Fonte: Dados da pesquisa.

Figura 13 – Novo teste Amortecimento de Holt.




Fonte: Dados da pesquisa.

Figura 14 – Novo teste Amortecimento de Winters.



Fonte: Dados da pesquisa.

Figura 15 – Novo teste ARIMA.



Fonte: Dados da pesquisa.

Tabela 5 – Comparação entre os modelos de previsão corrigidos.

Métodos	Média Móvel	Média Móvel Ponderada	Amortecimento Exponencial	Amortecimento Exponencial de Holt	Amortecimento Exponencial de Winters	Box e Jenkins
DAM	9,94	11,05	10,18	8,09	7,99	8,72
EAMP	30,19%	37,48%	30,89%	23,79%	23,40%	24,76%

Fonte: Dados da pesquisa.

Após a correção dos dados, verifica-se que o modelo que apresenta melhor aderência é o de Amortecimento Exponencial para Séries com Tendência e Sazonalidade de Winters. Não foram encontrados na literatura valores ideais para DAM e EAMP, desde que os “erros observados estejam dentro das estimativas históricas de erros” (CHOPRA; MEINDL, 2003, p. 87).

5. Considerações finais

Durante a coleta dos dados verificou-se uma gama de 120 itens. Para dar atenção ao produto que causa maior impacto na receita utilizou-se a Classificação ABC, o que reduziu para 7 o número de itens. No topo da Classificação ABC, encontra-se o Rodízio, que foi alvo deste estudo.

Foram testados os modelos das Médias, Amortecimento Exponencial Simples, Amortecimento Exponencial de Séries com Tendência (Holt), Amortecimento Exponencial de Séries com Tendência e Variações de Estado (Winters) e Box e Jenkins. A assertividade dos modelos foi verificada com o DAM (Desvio Absoluto Médio) e EAMP (Erro Absoluto Médio Percentual). No primeiro momento, com os dados aglomerados diariamente, os valores de DAM e EAMP foram muito elevados, pois havia dias de demanda nula seguidos de dias com demanda elevada. Em seguida, os dados foram aglomerados por semana, o que gerou uma queda nos níveis de EAMP, porém gerou aumento no DAM. A compara os valores de DAM e EAMP antes e depois da mudança na aglomeração dos dados.

Tabela 6 – Resultados dos testes.

Método	DAM	EAMP	DAM	EAMP
	Diária		Semanal	
Amortecimento Exponencial de Winters	3,92	76,97%	7,99	23,40%
Amortecimento Exponencial de Holt	4,7	84,11%	8,09	23,79%
Box e Jenkins	3,88	72,15%	8,72	24,76%
Média Móvel	5,26	93,58%	9,94	30,19%
Amortecimento Exponencial	4,62	78,87%	10,18	30,89%
Média Móvel Ponderada	6,58	75,81%	11,05	37,48%

Fonte: Dados da pesquisa.

Comparando a Tabela 6 com as Figuras de 10 a 15, pode-se verificar que os modelos nos quais o EAMP é menor, as curvas Real e Previsto se aproximam. Com o estudo, verifica-se que o modelo mais indicado para a série temporal em questão é o Amortecimento Exponencial de Winters, pois apresenta os menores índices de DAM e EAMP. Não foram encontrados na

literatura valores ideais para DAM e EAMP. O procedimento indicado é a avaliação de seus valores durante o tempo. Caso apresentem elevação ou flutuações, indica-se a troca do modelo de previsão para manter o nível de assertividade. O estudo apresentado gera impactos diretos no estoque de matéria prima, redução nos custos de fabricação, aumento da disponibilidade e redução de perdas.

Referências

- BALLOU, R. H. **Gerenciamento da cadeia de suprimentos**: logística empresarial. 5. ed. Porto Alegre: Bookman, 2006.
- CHIAVENATO, Idalberto. **Planejamento e controle da Produção**. 2. ed. São Paulo: Pearson, 2008.
- CHOPRA, Sunil; MEINDL, Peter. **Gerenciamento da Cadeia de Suprimentos**: Estratégia, planejamento e operações. São Paulo: Prentice Hall, 2003.
- CHOPRA, Sunil; MEINDL, Peter. **Gestão da Cadeia de Suprimentos**: Estratégia; planejamento e operações. 4. ed. São Paulo: Pearson Prentice Hall, 2011.
- CORRÊA, H. L.; CORRÊA, C. A. **Administração da Produção e Operações**. São Paulo: Atlas, 2006.
- DIAS, M. A. P. **Administração de Materiais**: uma abordagem logística. São Paulo: Atlas, 1993.
- MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting**: methods and applications. 3. ed. New York: John Wiley, 1998.
- MOREIRA, Daniel Augusto. **Administração da Produção e Operações**. 2. ed. São Paulo: Cengage Learning, 2013.
- MORETTIN, P. A.; TOLOI, C. M. **Análise de Séries Temporais**. São Paulo: Edgar Blucher, 2006.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. Estudo comparativo entre os modelos de Winters e de Box-Jenkins para previsão de demanda sazonal. **Revista Produto & Produção**, Porto Alegre, v. 4, n. especial, p. 72-85, abr. 2000.
- PELLEGRINI, F. R.; FOGLIATTO, F. S. Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. **Revista Produção**, Rio de Janeiro, v. 11, n. 1, p. 43-64, 2001.
- SLACK, Nigel; CHAMBERS, Stuart; JOHNSTON, Robert. **Administração da Produção**. São Paulo: Atlas, 2009.
- STOCK, James H. **Econometria**. São Paulo: Addison Wesley, 2004.
- TUBINO, Dalvio Ferrari. **Manual de Planejamento e Controle da Produção**. 2. ed. São Paulo: Atlas, 2000.
- TZU, Sun. **A Arte da Guerra**. Trad. COTRIM, Ana Aguiar. São Paulo: WMF Martins Fontes, 2012.
- ZORZO, Adalberto. **Gestão de Produtos e Operações**. São Paulo: Pearson Education do Brasil, 2015.