

CENTRO UNIVERSITÁRIO DOUTOR LEÃO SAMPAIO
CURSO DE GRADUAÇÃO EM ADMINISTRAÇÃO

FABIANA MARIA DA SILVA

**APLICAÇÃO DOS FORMALISMOS DE SÉRIES TEMPORAIS NA PREVISÃO DE
DEMANDA NA INDÚSTRIA DE MANUFATURA**

Juazeiro do Norte-CE
2019

FABIANA MARIA DA SILVA

**APLICAÇÃO DOS FORMALISMOS DE SÉRIES TEMPORAIS NA PREVISÃO DE
DEMANDA NA INDÚSTRIA DE MANUFATURA**

Trabalho de Conclusão de Curso – *Artigo Científico*, apresentado à Coordenação do Curso de Graduação em Administração do Centro Universitário Doutor Leão Sampaio, em cumprimento às exigências para a obtenção do grau de Bacharel.

Orientador: Professor Me José Eduardo Carvalho Lima

Juazeiro do Norte-CE
2019

**APLICAÇÃO DOS FORMALISMOS DE SÉRIES TEMPORAIS NA PREVISÃO DE
DEMANDA NA INDÚSTRIA DE MANUFATURA**

Este exemplar corresponde à redação final aprovada do
Trabalho de Conclusão de Curso de FABIANA MARIA
DA SILVA

Data da Apresentação ____/____/_____

BANCA EXAMINADORA

Assinatura: _____
Orientador (Me JOSÉ EDUARDO DE CARVALHO LIMA)

Assinatura: _____
Membro: (Esp ALYNE LEITE DE OLIVEIRA/ UNILEÃO)

Assinatura: _____
Membro: (Esp ANTÔNIO RANIEL SILVA LIMA/ UNILEÃO)

Juazeiro do Norte-CE

2019

APLICAÇÃO DOS FORMALISMOS DE SÉRIES TEMPORAIS NA PREVISÃO DE DEMANDA NA INDÚSTRIA DE MANUFATURA

Fabiana Maria da Silva¹
José Eduardo de Carvalho Lima²

RESUMO

O planejamento da demanda é de importância significativa para as empresas de manufatura, visto que este baseia-se em previsões. O presente trabalho teve como objetivo aplicar modelos de previsão de demanda subjacentes a séries temporais para auxiliar no planejamento da produção de auto veículos. As séries temporais foram obtidas por meio da ANFAVEA e contempla um recorte temporal de janeiro de 2005 a agosto de 2019. A análise segue a aplicação da metodologia Box-Jenkins (ARIMA) e método ETS, com o auxílio de planilhas do *software Excel*. Foram utilizados os modelos de previsão suavização exponencial e o modelo ARIMA, sendo que os modelos que melhor se ajustaram a série temporal estudada, foram os modelos de suavização exponencial simples e ARIMA (1, 1, 1). Como medidas de acurácia foram considerados MAD, MAPE e MDS. Verificou-se que o melhor modelo foi o de suavização exponencial simples em virtude do menor erro encontrado, porém só foi possível prever o mês de setembro, já o modelo ARIMA gerou previsão, para o período de seis meses.

Palavras-chave: Planejamento. Previsão. Séries temporais.

ABSTRACT

Demand planning is of significant importance to manufacturing companies as it is based on forecasts. The present work aimed to apply demand forecasting models underlying time series to assist in the planning of auto vehicle production. The time series were obtained through ANFAVEA and include a timeframe from January 2005 to August 2019. The analysis follows the application of Box-Jenkins methodology (ARIMA) and ETS method, with the aid of Excel spreadsheets. Exponential smoothing and ARIMA models were used, and the models that best fit the time series studied were the simple exponential smoothing and ARIMA models (1, 1, 1). Accuracy measures were considered MAD, MAPE and MDS. It was found that the best model was the simple exponential smoothing due to the smallest error found, but it was only possible to predict the month of September, whereas the ARIMA model generated forecast for the period of six months.

Keywords: Planning. Forecast. Time series.

1 INTRODUÇÃO

¹ Graduanda do curso de Administração do Centro Universitário Doutor Leão Sampaio - UNILEÃO, Juazeiro do Norte, Ceará, e-mail <fabianasilvaadm07@gmail.com>.

² Professor orientador do Centro Universitário Doutor Leão Sampaio - UNILEÃO, Juazeiro do Norte, Ceará, e-mail <joseduardo@leaosampaio.edu.br>.

O setor de manufatura como um todo, sofre constantemente mudanças significativas em termos de escala, complexidade e tecnologia. Na busca para se manterem competitivas, as empresas têm que produzir produtos de qualidade, com baixo custo e, atender às demandas que mudam rapidamente. O planejamento e controle da produção (PCP) tem um papel fundamental permitindo ao fabricante obter visibilidade e controle sobre todos os aspectos das atividades de fabricação (KILGER; WAGNER, 2008). Do lado da demanda, há uma pressão maior sobre o fabricante para cumprir os prazos e fornecer ao cliente um serviço rápido e eficiente, com informações precisas sobre o tempo de entrega e um produto de melhor qualidade, dentro do prazo.

O planejamento da demanda é de importância significativa para as empresas de manufatura, uma vez que, as etapas subsequentes do planejamento da produção baseiam-se em previsões de demanda (VOROSMARTY; DOBOS, 2013; JEON; KIM, 2016). Desenvolver um processo confiável de previsão de demanda é o passo inicial para o aperfeiçoamento do processo geral de planejamento e ajudam as empresas a planejarem a produção. Assim, a previsão de demanda e os formalismos de séries temporais ajudam a indústria de produção de bens a avaliarem a quantidade de produtos que irão produzir, de modo que possam atender o mercado (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; CHOPRA; MEIDL, 2016).

Nos últimos anos, pesquisadores desenvolveram diversos formalismos de séries temporais abrangentes e sofisticados aplicados a previsão. Tendo em vista a importância da previsão de demanda para o setor de manufatura, a pesquisa tem o objetivo aplicar modelos de previsão de demanda subjacentes a séries temporais para auxiliar no planejamento da produção, buscando identificar o melhor modelo e quantificar as estimativas de evolução para o planejamento do sistema produtivo. Neste sentido, é importante que empresas de manufatura desenvolvam mecanismos que as tornem ágeis para lidar com as mudanças na demanda por seus produtos, permitindo assim, condições de configurar de maneira otimizada suas instalações de produção, que representam sua capacidade produtiva e as exigências do mercado.

2 REFERENCIAL TEÓRICO

2.1 PREVISÃO DE DEMANDA

Compreende-se a previsão de demanda, como um processo que define dados futuros por meio de modelos estatísticos, matemáticos, econôméticos (MARTINS; LAUGENI, 2005) ou através de modelos subjetivos estruturados, classificados como modelos qualitativos de

previsão (JACOBS, 2011). A previsão de demanda é importante para o planejamento da produção, visto que ela é a base para o direcionamento da produção (LOBO; SILVA, 2014). Sendo também a principal informação aplicada ao PCP e as suas atividades, influenciando diretamente a execução das funções de planejamento e controle do sistema produtivo (TUBINO, 2017).

O planejamento da demanda é parte integrante de qualquer processo de planejamento de produção. As previsões precisas ajudam as indústrias de manufaturas a planejar efetivamente o processo de produção para que os níveis de produtos possam ser otimizados e a oferta possa ser correspondida de perto com a demanda. O planejamento da demanda também pode ajudar outras áreas como: marketing, logística, produção ou finanças (MAKRIDAKIS, WHEELWRIGHT, & HYNDMAN, 1998). O envolvimento dos diferentes aspectos e fatores que influenciam as previsões de demanda, precisam ser gerenciados. Para Corrêa (2019), a gestão de demanda envolve cinco áreas principais: previsão de demanda, promessa de prazos, priorização e alocação de recursos, comunicação com o mercado e influência sobre a demanda.

Desenvolver um processo confiável de previsão leva a otimização do processo geral de planejamento. Deste modo, Corrêa (2019) menciona a importância da utilização das ferramentas disponíveis, como meio para prever a demanda e analisar a precisão. Esse mecanismo pode envolver a base de dados históricos de vendas, informações e explicações sobre as variações e comportamentos de períodos anteriores, bem como, o uso de modelos formais adequados para que auxilie na explicação de tais comportamentos como na compreensão de fatores e variáveis internas e externas.

Diante da complexidade em estimar a demanda, Tubino (2017) apresenta 5 fases indispensáveis para desenvolver o processo de modelagem da previsão de demanda, onde deve-se: definir o objetivo do modelo, coletar e analisar os dados, selecionar a técnica mais adequada, calcular a previsão de demanda e então monitorar a atualização dos parâmetros inserido no modelo por meio da análise do erro de previsão.

Há vários métodos utilizados para estimar o valor futuro da previsão de demanda. De acordo com Lobo (2014), os métodos mais utilizados são os casuais, os modelos qualitativo e quantitativo (séries temporais). O modelo casual considera fatores relacionados ao mercado, ações de marketing, concorrência e os dados históricos. Funcionários e especialistas fomentam e analisam as técnicas qualitativas, já as séries temporais ponderam o histórico de demanda da organização.

2.2 SÉRIES TEMPORAIS

Uma série temporal é uma sequência de observações equidistante e cronológica para o período no tempo (MONTGOMERY; JENNINGS; KULAHCI, 2015). Podem ser univariadas ou multivariadas de acordo com a sua característica ou suas características (MAURICIO, 2007). Para Walter et al. (2013), uma série pode ser usada para prever o futuro. Compreendendo a previsão desta série temporal como o estabelecimento dos valores futuros da série, então a previsão é a estimativa acerca da verossimilhança de eventos futuros, baseados na informação atual e histórica.

Sendo que, a análise de uma série temporal objetiva identificar padrões não aleatórios, de modo que a observação deste comportamento passado permita fazer previsões sobre o futuro. Em geral, são os métodos estatísticos de previsão de séries temporais que buscam identificar o padrão de comportamento da série e utiliza-o para prever os valores futuros (SIEBEN, 2017). Montgomery et al. (2015) afirmam que os modelos gerais de séries temporais são responsáveis por aplicar as propriedades estatísticas dos dados históricos e assim, especificam um modelo formal e, em seguida, estimam os parâmetros desconhecidos desse modelo frequentemente por mínimos quadrados. Tais modelos estão sendo estudados ao longo do tempo.

Por meados de 1920, a previsão adivinha por meio da extrapolação simples de um valor global ajustado em função do tempo. Em 1927, Yule desenvolveu o modelo Autorregressivo (AR), onde o valor previsto dependia de valores passados. Durante vinte anos após o desenvolvimento de Yule, os pesquisadores enxergavam o comportamento de uma série como dependência somente aos modelos lineares e do ruído, porém, pesquisas adiante mostraram que os modelos lineares não suprem totalmente a análise de séries temporais (SIEBEN, 2017). Em 1950, o Alisamento Exponencial passou a ser utilizado. A metodologia de Box-Jenkins surgiu em 1970, onde é capaz de fornecer modelos ARIMA. Os estudos prosseguiram e com eles surgiram novos modelos com o intuito de melhorar a precisão, estando entre eles: Redes Neurais Artificiais, os Algoritmos Genéticos e os Algoritmos Evolutivos (SIEBEN, 2017).

Os dados de séries temporais têm a aplicabilidade ampla, nos mais diversos campos como nas ciências políticas, economia, sociologia, psicologia, estatística biomédica, meteorologia e demanda (YAFEE; MCGEE, 2000). Almeida e Cesar (2018) desenvolveram conceitos e ferramentas de previsão de demanda através de uma abordagem relacionada em séries temporais sugerindo uma nova metodologia de previsão para as vendas futuras de uma indústria que atua no segmento de torrefação, moagem e distribuição de café.

O trabalho de Santos et al. (2018) motivado pela busca da melhoria no planejamento da demanda em uma indústria química, analisou as séries temporais para assim, aplicar três

modelos de previsão de demanda, focando nos produtos que possuem muitos períodos sem demanda, podendo ter alta ou baixa variação na quantidade demandada. O estudo de Almeida e Cesar (2018) reduziu o erro em 4,57% comparado ao método atual aplicado, essa redução se deu por meio do método da média móvel ponderada com $t=5$ períodos. Deste modo, obteve-se um ganho de quase 50% na previsão de vendas futuras, impactando significativamente o planejamento de investimentos e consideravelmente redução nos custos de estoque.

No trabalho de Santos et al. (2018), o melhor método foi o de Croston pois foi o que gerou maior assertividade para as previsões, assim a aplicação deste poderá melhorar o atendimento de pedidos de produtos que possuem grandes intervalos entre demandas e alta variação de volume, o que garante melhor nível de atendimento ao cliente e consequentemente o nível de estoque no armazém.

2.3 MODELOS AUTOREGRESSIVOS INTEGRADOS DE MÉDIAS MÓVEIS

Em particular, os modelos Autoregressivos Integrados de Médias Móveis (ARIMA) são uma modelagem estocástica para séries temporais de uma variável (BROCKWELL; DAVIS; FIENBERG, 1991; BOX et al., 2015). Esses modelos expressam a observação no tempo t como uma função linear de observações anteriores, um termo de erro atual e uma combinação linear de termos de erro anteriores (RUBY-FIGUEROA et al., 2017). Desenvolvido na década de 70 é um dos formalismos mais populares para análise de previsão de séries temporais (BOX; JENKINS, 1976). ARIMA é o nome genérico, proveniente de seus três componentes autoregressivo (AR), integrado (I) e média móvel (MA). Os modelos de MA permitem identificar tendências nos dados, enquanto os modelos de AR podem explicar o tempo atual como uma função linear do passado, permitindo identificar periodicidade, como variações sazonais conduzidas por fortes processos dinâmicos de causa e efeito (ZHANG, 2001; KHATIBI et al., 2014; BOX et al., 2015).

Na análise do modelo ARIMA, um processo subjacente identificado é gerado com base em observações de uma série temporal para gerar um bom modelo que mostra o mecanismo de geração de processos com precisão (BOX; JENKINS, 1976). A técnica ARIMA inclui características como identificação (ABDEL-AAL e AL GARNI, 1997; ZHANG, 2001), estimativa (ABDEL-AAL e AL GARNI, 1997) e verificação de diagnóstico (ABDEL-AAL e AL GARNI, 1997; ZHANG, 2001; BROCKWELL e DAVIS, 2016). Assim, em um modelo ARIMA o valor futuro de uma variável é assumido como uma função linear de várias observações passadas e erros aleatórios (Eq. 1).

$$u_t^d = \theta_0 + \sum_{i \in I_u} \theta_i^{ar} u_{t-ti}^d + \sum_{j \in I_u} \theta_j^{ma} e_{t-tj}^d + e_t^d \quad (1)$$

em que, θ_0 é o intercepto do modelo dedicado a u_t^d , d é o número de diferenciações para que a u_t se torne estacionária, $\{\theta_i^{ar}\}_{i \in I_u}$ é o conjunto de coeficientes que ponderam as defasagens temporais referentes à série diferenciada, $\{\theta_j^{ma}\}_{j \in I_u}$ é o conjunto de coeficientes que ponderam as defasagens temporais referentes aos resíduos do modelo, \hat{u}_t^d é o modelo ajustado a u_t^d e e_t^d é o ruído correspondente ao modelo ajustado a u_t^d .

Em relação à Equação 1, os somatórios representam, respectivamente, os componentes AR e MA do modelo. Já em relação às diferenciações tem-se que (Eq. 2):

$$u_t^0 = u_t; u_t^1 = u_t - u_{t-1}; u_t^d = u_t^{d-1} - u_{t-1}^{d-1} \quad (2)$$

Os modelos ARIMA não sazonais são geralmente designados ARIMA (p, d, q) em que os parâmetros p , d e q são números inteiros não negativos, p é a ordem do modelo autorregressivo, d é o grau de diferenciação e q é o de ordem do modelo de média móvel. Os modelos sazonais de ARIMA são geralmente designados SARIMA (p, d, q)(P, D, Q)[s], onde [s] refere-se ao número de períodos em cada estação e os maiúsculos P , D , Q referem-se a autorregressivo, diferenciação, e termos da média móvel da parte sazonal do modelo ARIMA (CRYER; CHAN, 2008; RUBY-FIGUEROA et al., 2017).

2.4 MODELOS DE SUAVIZAÇÃO EXPONENCIAL

Os métodos de suavização exponencial são técnicas de previsão que são amplamente utilizadas para a análise de séries temporais univariadas, devido à sua simplicidade e robustez como procedimentos automáticos de previsão (GARDNER, 2006; CORBERÁN-VALLET; BERMÚDEZ; VERCHER, 2011). A metodologia descreve historicamente uma classe de modelos baseados em agregar as observações passadas de modo que o peso dado a cada uma decresce exponencialmente no sentido das mais recentes para as mais antigas. A ideia teve origem na década de 50 e os métodos tiveram contribuições de Robert G. Brown, Charles Holt, Peter Winters e John Muth (HOLT, 2004; BROWN, 1959).

Para esta família de modelos, inicialmente se define o tipo de tendência (T), que é uma combinação dos termos de nível (l) e de crescimento (b). Considere-se T_h a previsão da tendência a h passos e ϕ , tal que $0 < \phi < 1$, então os cinco tipos de tendências são: inexistente (Eq. 3), aditivo (Eq. 4), aditivo amortecido (Eq. 5), multiplicativo (Eq. 6) e multiplicativo aditivo (Eq. 7) (HYNDMAN et al., 2008).

$$T_h = l \quad (03)$$

$$T_h = l + bh \quad (04)$$

$$T_h = l + (\phi + \phi^2 + \dots + \phi^h)b \quad (05)$$

$$T_h = lb^h \quad (06)$$

$$T_h = lb^{(\phi+\phi^2+\dots+\phi^h)} \quad (07)$$

Após análise sobre a componente tendência, inclui-se a componente sazonal (S), que pode ser aditiva ou multiplicativa, e, por fim, a componente do erro (E), que também pode ser aditiva ou multiplicativa (HYNDMAN *et al.*, 2008).

Os métodos mais comuns, desconsiderando o erro, são os seguintes: alisamento exponencial simples (sem tendência e sem sazonalidade), método linear de Holt (tendência aditiva e sem sazonalidade), aditivo de Holt-Winters (tendência e sazonalidade aditivas) e multiplicativo de Holt-Winters (tendência aditiva e sazonalidade multiplicativa) (WINTERS, 1960; HYNDMAN *et al.*, 2008).

3 MÉTODO

A pesquisa tem como cenário o setor de manufatura da produção nacional de veículo automotores. A série temporal pesquisada é apresentada no quadro 1 e descreve as 176 observações do registro mensal da produção de auto veículos: automóveis, comerciais leves, caminhões e ônibus, referentes ao período de janeiro de 2005 à agosto de 2019. Obtidas por meio do banco de dados estatístico da Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA).

Quadro 1: Produção mensais de auto veículos

período	produção	período	produção	período	produção	período	produção
1	155533	45	286610	89	286215	133	152778
2	176760	46	280178	90	277722	134	144333
3	211944	47	187374	91	301142	135	200352
4	197607	48	91314	92	333192	136	171298
5	207369	49	180242	93	288049	137	178895
6	213767	50	196546	94	324483	138	186250
7	199959	51	266162	95	314720	139	191779
8	210961	52	244700	96	268315	140	181197
9	198855	53	262452	97	292247	141	172105
10	182962	54	276445	98	240602	142	177570
11	206894	55	271385	99	328932	143	219084
12	194561	56	284904	100	352531	144	201143

13	183640	57	263767	101	344555	145	179376
14	190099	58	306291	102	323853	146	201763
15	212794	59	282512	103	316739	147	236568
16	184761	60	240594	104	343562	148	191554
17	219343	61	233395	105	322776	149	253398
18	205415	62	236614	106	322677	150	214838
19	202943	63	318011	107	293155	151	225377
20	221843	64	274873	108	231107	152	266489
21	188600	65	297374	109	237288	153	239763
22	207656	66	283997	110	281627	154	253906
23	208897	67	290756	111	272754	155	254073
24	177689	68	308387	112	277091	156	219697
25	190778	69	278441	113	281355	157	218717
26	190518	70	293567	114	215934	158	213498
27	234951	71	301940	115	252718	159	267539
28	212376	72	264780	116	264626	160	266140
29	241844	73	239301	117	300806	161	212329
30	232836	74	295946	118	293328	162	256305
31	253138	75	296322	119	264830	163	245641
32	263924	76	283219	120	203837	164	291099
33	241700	77	305251	121	204705	165	223081
34	283405	78	296050	122	205950	166	263186
35	262729	79	308798	123	255066	167	244771
36	217025	80	326213	124	219622	168	177503
37	242456	81	261130	125	213043	169	199145
38	239214	82	270949	126	187185	170	257939
39	268285	83	273358	127	223140	171	240763
40	283294	84	261245	128	216969	172	267561
41	274542	85	210604	129	173811	173	275747
42	292422	86	219068	130	203868	174	233150
43	305384	87	313178	131	173864	175	266992
44	299556	88	266275	132	141798	176	269809

Fonte: Anfavea (2019)

A análise do trabalho segue a aplicação da metodologia Box-Jenkins (ARIMA) e ETS, a fim de determinar a previsão de demanda dos produtos e com base nas medidas de erros determina-se o melhor dos modelos gerados. Fundamentada no ciclo iterativo de quatro fases: identificação do modelo, estimação do modelo identificado, verificação ou diagnóstico e a realização das previsões. Na sequência, foi executada uma análise prévia dos dados na tentativa de identificar componentes de nível, tendência, sazonalidade, ciclo e *outliers*. Em seguida, o

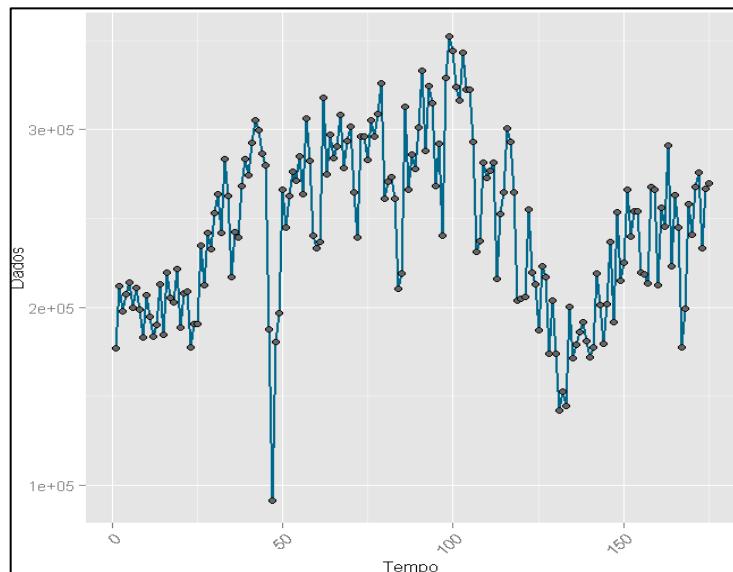
modelo de suavização simples e o modelo ARIMA foram aplicados aos dados da série histórica em estudo, com o auxílio de planilhas do *software Excel*.

Em todos os modelos de previsão existe uma incerteza associada que precisa ser mensurada. Assim, com o intuito de validar o modelo, foi determinado o melhor modelo ARIMA e o melhor modelo de suavização para os dados da série temporal de forma automática. Comparou-se as previsões do melhor modelo aos dados reais, analisando o erro absoluto em unidade e percentual. Por fim, a escolha do método foi aquele responsável por gerar os menores erros de previsão, sendo considerados o MAD, MAPE e o MSD.

4 ANÁLISE E DISCUSSÃO DOS RESULTADOS

A produção nacional de auto veículos é objeto de estudo desta pesquisa, disponibilizado por meio da ANFAVEA, permite através dos seus dados gerar o gráfico da série temporal analisada por período, demonstrada na figura 1, indispensável para os cálculos dos modelos de previsão da série observada.

Figura 1: Série temporal em estudo



Fonte: Elaborado pelo autor (2019)

O setor automobilístico passa por grandes variações e momentos cíclicos que influenciam no volume de produção e no planejamento de ações. O mercado teve um crescimento por volta da década de 50 e 70, entrando em declínio logo em seguida, voltando a crescer nos anos 90, impulsionado pelo uso da tecnologia. Em 2015 o Brasil passou por crise econômica e política, onde percebeu-se uma retração acentuada no setor. A frota brasileira é composta por aproximadamente 43,5 milhões de veículos e a indústria automobilística reflete

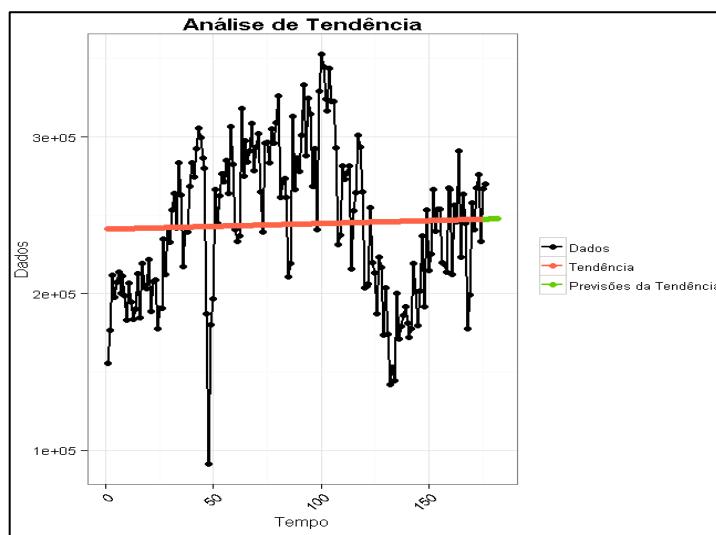
no aspecto macroeconômico do país, contando com investimentos bilionários de capital estrangeiro (PORTILLO, 2019).

Tendo em vista a importância da previsão de demanda para o planejamento de ações para a produção de automóveis, Pereira e de Carvalho Lima (2018) analisaram um modelo de previsão de séries temporais por meio da metodologia Box-Jenkins, que se adeque as características do setor em questão, concluindo como o modelo mais apto SARIMA (1,0,0) (1,0,0), com tendência desfavorável.

Em seguida, realizou-se o teste de normalidade para verificar a distribuição dos dados utilizando o teste de *Kolmogorov-Smirnov*, cujo resultado da estatística de teste é 0,078140693 e p-valor igual a 0,0111. Deste modo comprehende-se que os dados da série temporal analisada fazem parte de uma distribuição normal, visto que o valor crítico encontrado $0,102514 > 0,078140693$, assim não temos evidência para rejeitar a hipótese de normalidade dos dados.

Seguindo com a análise de tendência utilizando o teste não paramétrico de *Wald-Wolfowitz*, a fim de descobrir os valores da estatística de teste e de p-valores. O teste considera números pequenos de grupo com símbolos iguais para rejeitarmos a hipótese nula de que não há tendência. Os valores encontrados foram respectivamente, estatística de teste de -7,4082 e p-valor igual a 0, diante dos valores obtidos rejeita-se a hipótese nula evidenciando que há tendência como pode ser visto na figura 2.

Figura 2: Tendência



Fonte: Elaborado pelo autor (2019)

Para analisar a estacionariedade da série foi utilizado o teste de *Phillips-Perron* cujo valor da estatística de teste é -37,5294167, onde o p-valor obtido caracteriza a série como

estacionária, visto que o valor encontrado $0,01 < 1$, deste modo rejeitamos a hipótese nula de que na série existe pelo menos uma raiz unitária (não é estacionaria).

Seguindo com a verificação para identificar se há presença de sazonalidade na série, foi aplicado o teste de *Kruskal-Wallis* cujo o p-valor 1,25E-15 rejeita a hipótese nula de que não há sazonalidade, assim a série possui sazonalidade determinística com período de 12 meses.

Para prever as séries temporais foram aplicados os modelos de suavização exponencial e os modelos autoregressivos integrados de médias móveis. O melhor modelo entre os vários possíveis, foram selecionados utilizando-se o método ETS automático para ajustar a série temporal de forma otimizada, ou seja, modelos com menor envolvimento de parâmetros possíveis a serem estimados e que esclareça bem a variável resposta. Isso para ambas aplicações deste trabalho.

Ao analisar os dados históricos da produção em questão através do modelo de suavização exponencial, deve-se considerar as constantes de suavização α , β e γ , com o intuito de reduzir as medidas de acurácia. Em que, α é o parâmetro de nível, β de tendência e γ de sazonalidade, essas constantes se encontram entre o intervalo 0 e 1, onde foi possível identificar apenas o nível, assim a suavização exponencial é simples, cujo modelo definiu o erro como multiplicativo, livre de tendência e sazonalidade. Para o modelo ARIMA foram considerados os coeficientes de AR e MA, nesse sentido foi gerado um modelo livre de sazonalidade, com apenas 1 diferença incluída no modelo. A seguir na tabela 2 pode ser visto os valores referentes as considerações dos dois modelos:

Tabela 2: Componentes de Suavização e coeficientes

Nível	0,363613314
ar1	0,437698
ma1	-0,82441

Fonte: Elaborado pelo autor (2019)

Prosseguindo verifica-se a previsão de produção para um período de seis meses, para os dois modelos adotados na pesquisa, conforme demonstra a tabela 3.

Tabela 3: Previsão da produção

Modelo	Mês	Limite Inferior	Previsão	Limite Superior
Suavização Simples	setembro	326859,1641	260465,4782	194071,7924
	outubro	331181,7971	260465,4782	189749,1594
	novembro	335263,8701	260465,4782	185667,0864
	dezembro	339142,8541	260465,4782	181788,1024

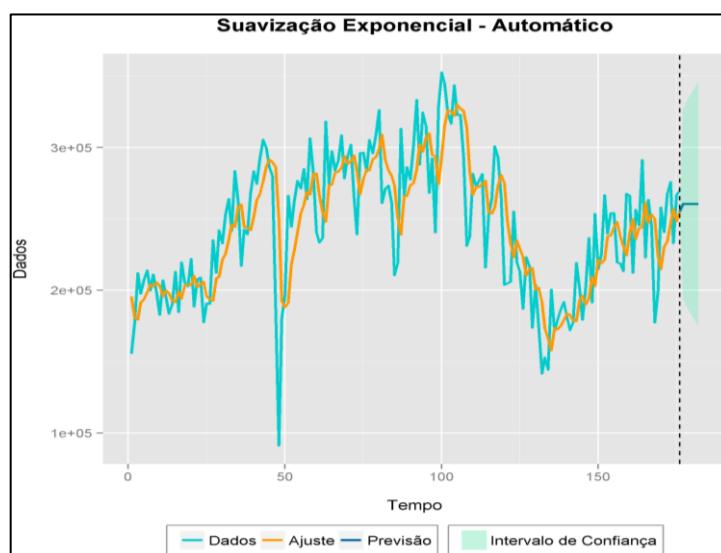
	janeiro	342847,4597	260465,4782	178083,4968
	fevereiro	346400,2594	260465,4782	174530,6971
Modelo	Mês	Limite Inferior 95%	Previsão	Limite Superior 95%
ARIMA (1,1,1)	setembro	222585,1987	261529,7289	300474,2591
	outubro	212220,7996	257905,906	303591,0125
	novembro	207471,5238	256319,7649	305168,0061
	dezembro	204697,0176	255625,5137	306554,0098
	janeiro	202724,3106	255321,6411	307918,9716
	fevereiro	201105,1719	255188,6366	309272,1013

Fonte: Elaborado pelo autor (2019)

Como visto, entre os métodos de suavização Exponencial, o modelo de suavização Simples foi o que melhor se ajustou a série, a estimativa dos dados desenvolveu valores que se repetiu para todo o período previsto, indicando que foi possível prever apenas o mês de setembro, isso deve-se a uma característica no modelo, que limita a previsão em um único período. Enquanto o modelo ARIMA, ajustado em ARIMA (1, 1, 1) gerou previsões que engloba os meses de setembro a fevereiro, incluindo os limites que determina até quanto o volume de produção é aceitável.

Na figura 3 apresentada na sequência, expõe os dados da série onde é possível identificar a suavização do modelo e a previsão para o período.

Figura 3: Modelo de Suavização Exponencial Simples

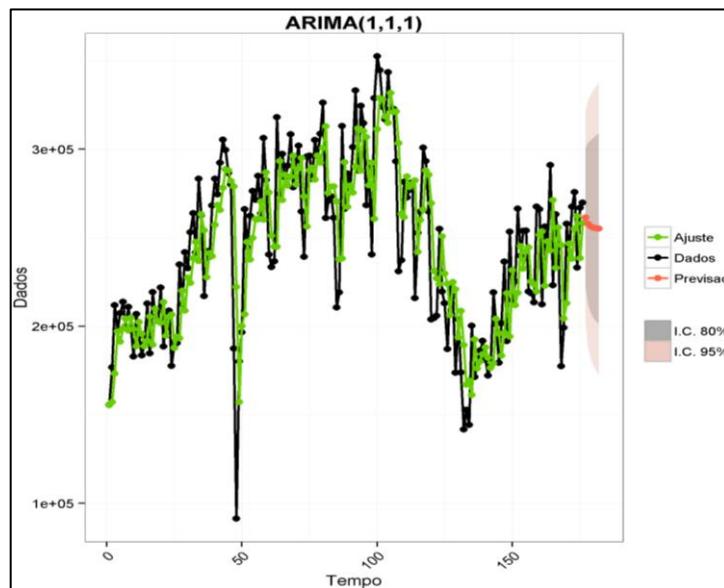


Fonte: Elaborado pelo autor (2019)

O modelo ARIMA (p, d, q) calculado com auxílio do Excel gerou um ARIMA (1, 1, 1,) o que implica dizer que o modelo mostrou Lag 1, com 1 diferença e média móvel 1 diretamente ligada a Lag, ou seja, o dado é previsto com base no dado anterior.

Como pode ser visto a seguir na figura 4, os dados foram ajustados e realizada a previsão, aceitando os limites estimado do volume de produção, em 95% de confiabilidade.

Figura 4: Modelo ARIMA



Fonte: Elaborado pelo autor (2019)

Após realizar as previsões faz-se necessário validar o modelo por meio das medidas de erro de previsão, nesta pesquisa foram adotadas o MAD, MAPE e o MSD. Os modelos geram os seguintes valores:

Tabela 4: Medidas de Acurácia (Erro de Previsão)

Modelo	MAD	MAPE	MSD
Suavização Exponencial Simples	0,09612527	4,34806E-05	0,016771579
ARIMA	22837,37089	9,600171967	918218868,3

Fonte: Elaborado pelo autor (2019)

Levando em consideração as medidas de acurácia o modelo de suavização simples gerou o melhor resultado se comparado com o modelo ARIMA (1,1,1), tendo em vista que quanto menor o erro, maior a precisão, diminuindo os riscos associados às previsões. Porém o modelo

de suavização só foi possível prever o mês de setembro, como pode ser visto na tabela 3, enquanto o modelo ARIMA estimou os valores para o período estabelecido.

5 CONSIDERAÇÕES FINAIS

A pesquisa teve como objetivo aplicar modelos de previsão de demanda subjacentes a séries temporais para auxiliar no planejamento da produção nacional de auto veículos, prevista para o período de seis meses a seguir do mês de setembro até fevereiro.

Os modelos gerados para realizar as previsões foram os modelos de suavização simples e o ARIMA (1,1,1). Onde foi utilizado o MAPE, MAD e MDS como métrica de erro para verificar qual modelo proporciona o menor erro de previsão. Constatou-se que o modelo de suavização simples apresentou menores medidas de acurácia em relação ao modelo ARIMA, porém o modelo possui uma característica, visto que o mesmo só consegue prever um período, o mês de setembro.

Diante disso, acredita-se que o planejamento da produção, baseado em previsões precisas contribuem para a alocação de recursos de produção, otimização de processos estratégicos, redução de custos e consequentemente atendimento ao mercado.

Embora existam muitos estudos sobre séries temporais, falta aprofundamento sobre aplicação e análise das metodologias, visto que alguns materiais abordam de forma parcial os critérios e parâmetros necessários para aplicar e analisar com precisão os métodos relacionados a séries temporais.

Com base na variação nos níveis de produção do setor de auto veículos, o estudo e aplicação de ferramentas para previsão de demanda pode representar um imenso diferencial competitivo para a indústria automobilística, visto que esse processo auxilia diretamente no planejamento estratégico. Como sugestão para estudos posteriores pode-se aplicar novos modelos de previsão de demanda como também a combinação entre eles, para obter previsões ainda mais acuradas.

REFERÊNCIAS

ABDEL-AAL, R. E.; AL-GARNI, A. Z. Forecasting monthly electric energy consumption in eastern Saudi Arabia using univariate time-series analysis. *Energy*, v. 22, n. 11, p. 1059-1069, 1997.

ALMEIDA, F. B. de; CÉSAR, H. P. Aplicação de métodos de previsão de demanda em uma indústria do setor alimentício. 2018.

ANFAVEA. **Séries temporais auto veículos.** Disponível em: <
<http://www.anfavea.com.br/estatisticas.html> > Acesso em: 17 de set 2019.

BOX, G. E. P. and JENKINS, G. M. (1976) Time Series Analysis: Forecasting and Control. **San Francisco, CA: Holden-Day**, v. 3226, n. 3228, p. 10, 1976.

BOX, George E.P et al. **Time series analysis: forecasting and control.** John Wiley & Sons, 2015.

BROCKWELL, Peter J.; DAVIS, Richard A.; FIENBERG, Stephen E. **Time Series: Theory and Methods: Theory and Methods.** Springer Science & Business Media, 1991.

BROWN, Robert Goodell. **Statistical forecasting for inventory control.** McGraw/Hill, 1959.

CHOPRA, Sunil; MEINDL, Peter. **Supply chain management: Strategy, planning and operation.** 2016.

CORBERÁN-VALLET, Ana; BERMÚDEZ, José D.; VERCHER, Enriqueta. Forecasting correlated time series with exponential smoothing models. **International Journal of Forecasting**, v. 27, n. 2, p. 252-265, 2011.

CORRÊA, L H. **Planejamento programação e controle de produção:** 6 ed. São Paulo: Atlas, 2014.

CRYER, Jonathan D.; CHAN, Kung-Sik. Time series regression models. **Time series analysis: with applications in R**, p. 249-276, 2008.

GARDNER JR, Everette S. Exponential smoothing: The state of the art—Part II. **International journal of forecasting**, v. 22, n. 4, p. 637-666, 2006.

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

HYNDMAN, R.; KOEHLER, A. B. ORD, K. J.; SNYDER, R. D. **Forecasting with exponential smoothing: the state space approach.** Springer Science & Business Media, 2008.

JACOBS, W. **Modelos de Suavização Exponencial, ARIMA e Redes Neurais Artificiais: Um estudo comparativo para a previsão de demanda de produtos.** UNIVATES. Lajeado. 2011.

JEON, Su Min; KIM, Gitae. A survey of simulation modeling techniques in production planning and control (PPC). **Production Planning & Control**, v. 27, n. 5, p. 360-377, 2016.

KHATIBI, R. et al. Inter-comparison of time series models of lake levels predicted by several modeling strategies. **Journal of Hydrology**, v. 511, p. 530-545, 2014.

- KILGER, Christoph; WAGNER, Michael. Demand planning. In: **Supply chain management and advanced planning**. Springer, Berlin, Heidelberg, 2008. p. 133-160.
- LOBO, N. R. **Planejamento e controle da produção:** 1 ed. São Paulo: Erica, 2014.
- MAKRIDAKIS, S., WHEELWRIGHT, S., & HYNDMAN, R. (1998). **Methods and Applications**. 3. ed. New York: John Wiley & Sons.
- MAKRIDAKIS, Spyros; WHEELWRIGHT, Steven C.; HYNDMAN, Rob J. **Forecasting methods and applications**. Jonh wiley & sons, 2008.
- MARTINS, P. G. & LAUGENI, F. P. **Administração da Produção**. 2.ed. São Paulo: Saraiva, 2005.
- MAURICIO, José A. Introducción al análisis de series temporales. **Universidad Complutense de Madrid**, 2007.
- MONTGOMERY, Douglas C.; JENNINGS, Cheryl L.; KULAHCI, Murat. **Introduction to time series analysis and forecasting**. John Wiley & Sons, 2015.
- PEREIRA, Séfora Laissa Alcântara; DE CARVALHO LIMA, José Eduardo. Aplicação do Modelo Box-Jenkins na Previsão da Produção de Automóveis. **Id on Line REVISTA DE PSICOLOGIA**, v. 12, n. 42, p. 1073-1097, 2018.
- PORTILLO, Julian Alexienco. Uma análise das estratégias do setor automobilístico e investimentos das quatro maiores montadoras brasileiras até 2020: aplicação da matriz insumo-produto. **Práticas em Contabilidade e Gestão**, v. 7, n. 1, 2019.
- RUBY-FIGUEROA, René et al. Permeate flux prediction in the ultrafiltration of fruit juices by ARIMA models. **Journal of Membrane Science**, v. 524, p. 108-116, 2017.
- SANTOS, M. [et al.]. **Cálculo da previsão de demanda de uma multinacional**. Disponível em:< <http://www.brjd.com.br/index.php/BRJD/article/view/309>>. Acesso em: 11 mar. 2019.
- SIEBEN, Evelim. Modelos Para Previsão em Séries Temporais: A Metodologia Box e Jenkins na Prática. 2017.
- TUBINO, F. D. **Planejamento e controle da produção**. 3 ed. São Paulo: Atlas, 2017
- VÖRÖSMARTY, Gyöngyi; DOBOS, Imre. Analysis of purchasing activity with discounted cash flow inventory models. **Periodica Polytechnica Social and Management Sciences**, v. 21, n. 2, p. 67-70, 2013.
- WALTER, OMFC et al. Aplicação de um modelo SARIMA na previsão de vendas de motocicletas. **Exacta-EP**, São Paulo, v. 11, n. 1, p. 77-88, 2013.
- WINTERS, Peter R. Forecasting sales by exponentially weighted moving averages. **Management science**, v. 6, n. 3, p. 324-342, 1960.

YAFFEE, Robert A.; MCGEE, Monnie. **An introduction to time series analysis and forecasting: with applications of SAS® and SPSS®**. Elsevier, 2000.

ZHANG, Guoqiang Peter. An investigation of neural networks for linear time-series forecasting. **Computers & Operations Research**, v. 28, n. 12, p. 1183-1202, 2001.