

Universidade Federal de Santa Catarina – UFSC
Centro Sócio Econômico
Departamento de Economia e Relações Internacionais

TIAGO FAGUNDES FONSECA

Previsão de demanda de bolsas para o pequeno varejo:
Um estudo de caso da empresa BSM Bag Store de 2012 a 2018

Florianópolis, 2018

TIAGO FAGUNDES FONSECA

**Previsão de demanda de bolsas para o pequeno varejo:
Um estudo de caso da empresa BSM Bag Store de 2012 a 2018**

Monografia submetida ao curso de Ciências Econômicas da Universidade Federal de Santa Catarina, como requisito obrigatório para obtenção do grau de Bacharelado em Ciências Econômicas

Orientador: Prof. Gueibi Peres Souza

FLORIANÓPOLIS, 2018

Ficha de identificação da obra

A ficha de identificação é elaborada pelo próprio autor.

Orientações em:

<http://portalbu.ufsc.br/ficha>

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CURSO DE GRADUAÇÃO EM CIÊNCIAS ECONÔMICAS

A Banca examinadora resolveu atribuir a nota 9,0 (nove) ao aluno Tiago Fagundes Fonseca na disciplina CNM 7107 – Monografia pela apresentação deste trabalho.

Banca Examinadora:

Prof. Dr. Gueibi Peres Souza
Orientador
Universidade Federal de Santa Catarina

Prof. Dr. Luiz Carlos de Carvalho Júnior
Universidade Federal de Santa Catarina

Prof. Dr. Roberto Meurer
Universidade Federal de Santa Catarina

Aos meus pais Paulo e Sueli

Por abrirem as portas à este caminho

À minha família e amigos pelo incentivo segui-lo

À minha esposa pelo apoio para percorre-lo

AGRADECIMENTOS

Agradeço a meu professor e orientador Gueibi Peres de Souza pela atenção impar dedicada, pela generosidade com que dividiu seus conhecimentos, pela compreensão com que lidou com minhas dificuldades e pela paciência que teve sobre minhas limitações.

Agradeço a minha esposa Carla pelo incondicional apoio e atenção a mim dedicados. Aos meus pais Paulo e Sueli pela educação a mim fornecida. A minha irmã, meus avós, tios, tias, primos e amigos pelo incentivo ao longo desta trajetória

Mares calmos não fazem bons marinheiros.
(Autor desconhecido)

RESUMO

O planejamento no varejo de moda tem sua complexidade associada às peculiaridades que o caracterizam tais como: constante variação do padrão de sortimento em virtude da introdução de novos produtos, forte sazonalidade, intensa influência das tendências de moda entre outros. Uma vez em que a previsão de vendas se constitui de parte importante do planejamento de uma organização, a obtenção de maior precisão nesta atividade revela-se como um valioso recurso estratégico capaz contribuir para a necessária manutenção de sua competitividade. Tratando-se especialmente da empresa de pequeno porte, os recursos financeiros e técnicos disponíveis tendem a não oferecer soluções para obtenção de previsões tão numerosas quando comparado a aqueles disponíveis a organizações de grande porte. Neste sentido, uma vez que as pequenas e, grandes empresas atuam em uma economia de mercado, demonstra-se relevante à primeira a definição e a utilização de técnicas, aplicáveis às suas características, que direcionem no sentido mantê-la competitiva. A partir deste contexto, o presente trabalho propôs investigar, através do estudo de caso de uma pequena empresa varejista catarinense, a BSM Bag Store, sugestões de técnicas para previsão de vendas para uma categoria de produto por ela comercializado, no caso, “bolsas”. Como parte do escopo deste trabalho, portanto, direcionou-se a pesquisa para a indicação de técnicas e metodologias elegíveis às características e recursos da empresa em questão. Observados estes pré-requisitos, os resultados indicaram a viabilidade de uma heurística de previsão mais precisa em comparação as previsões obtidas com a metodologia adotada pela empresa até então. Tal resultado foi obtido através do uso combinado de dois métodos estruturados de previsão, ambos univariados, o de Suavização exponencial e metodologia Box-Jenkins.

Palavras-chave: previsão de vendas, gestão de pequeno varejo, suavização exponencial, Box-Jenkins, combinação de previsões.

ABSTRACT

Retail planning in fashion has its complexity associated with the peculiarities that characterize it such as: constant variation of the assortment pattern due to the introduction of new products, strong seasonality, intense influence of fashion trends among others. Since sales forecasting constitutes an important part of an organization's planning, obtaining greater precision in this activity proves to be a valuable strategic resource capable of contributing to the necessary maintenance of its competitiveness. Especially the small business, the financial and technical resources available tend not to offer solutions to obtain such forecasts when compared to those available to large organizations. In this sense, since small and large companies operate in a market economy, it is relevant to the first to define and use techniques, applicable to their characteristics, that guide in the sense of keeping it competitive. From this context, the present work proposes to investigate, through the case study of a small retailer from Santa Catarina, the BSM Bag Store, suggestions of techniques for forecasting sales for a category of product it commercializes, in this case, handbags. As part of the scope of this work, therefore, the research was directed towards the indication of techniques and methodologies that are eligible for the characteristics and resources of the company in question. Observed these prerequisites, the results indicated the feasibility of a more accurate prediction heuristic in comparison to the forecasts obtained with the methodology adopted by the company until then. This result was obtained through the combined use of two predictive structured methods, both univariate, exponential Smoothing and Box-Jenkins methodology.

Keywords: sales forecasting, small retail management, exponential smoothing, Box-Jenkins, forecasting combination.

LISTA DE FIGURAS

Figura 01 – Métodos de suavização exponencial.....	24
Figura 02 - Resíduos SARIMA	43
Figura 03 - Ajustado X Ocorrido Modelo SARIMA	44
Figura 04 - Ajustado X Ocorrido – Modelo de Suavização Exponencial.....	46
Figura 05 - Ajustado X Ocorrido - Previsão Combinada	47

LISTA DE TABELAS

Tabela 01 – Previsão venda mensal BSM Bag Store (log do faturamento total em R\$).....	40
Tabela 02 - Venda mensal BSM Bag Store (log dos valores em R\$).....	41
Tabela 03 - Comparação de Resultados.....	48

LISTA DE ABREVIATURAS E SIGLAS

ABNT – Associação Brasileira de Normas Técnicas

IBGE – Instituto Brasileiro de Geografia e Estatística

SUMÁRIO

1 INTRODUÇÃO	15
1.1 APRESENTAÇÃO DO PROBLEMA.....	15
1.2 DEFINIÇÃO DO PROBLEMA DE PESQUISA	17
1.3 HIPÓTESE BÁSICA	17
1.4 OBJETIVOS.....	17
1.4.1 Objetivo Geral	17
1.4.2 Objetivos Específicos	18
1.5 METODOLOGIA	18
1.6 JUSTIFICATIVA.....	18
1.7 LIMITAÇÕES DO TRABALHO	19
1.8 ESTRUTURA DO TRABALHO	20
2 REFERENCIAL TEÓRICO	21
2.1 METODOLOGIAS DE PREVISÃO	21
2.1.1 Modelos de regressão linear	21
2.1.2 Suavização Exponencial	23
2.1.3 Metodologia <i>Box-Jenkins</i> (modelos ARIMA)	25
2.1.4 Redes neurais artificiais	27
2.3 MEDIDAS DE ERRO DE PREVISÕES	28
2.3.1 Discrepância percentual absoluta média (MAPE)	28
2.3.2 Erro escalar médio absoluto (MASE)	29
2.3.3 U de Theil	30
2.4 COMBINAÇÃO DE PREVISÕES.....	31
2.4.1 Método de combinação por média simples	31
2.4.2 Método da variância e covariância	32
2.4.3 Técnicas de minimização	33
2.5 AVALIAÇÃO DE PREVISÕES	33

2.6 SELEÇÃO DAS METODOLOGIAS DE PREVISÃO A SEREM EMPREGADAS	34
3 ANÁLISE EMPÍRICA	37
3.1 APRESENTAÇÃO DA EMPRESA	37
3.2 MÉTODO DE PREVISÃO REALIZADO PELA EMPRESA	39
3.3 APRESENTAÇÃO DOS DADOS	40
3.3 APLICAÇÕES DAS TÉCNICAS DE PREVISÃO PROPOSTAS	42
3.3.1 Metodologia Box-Jenkins.....	42
3.3.2 Previsão por suavização exponencial.....	45
3.3.3 Combinação de Previsões.....	47
3.4 COMPARAÇÃO ENTRE RESULTADOS	48
4 CONSIDERAÇÕES FINAIS.....	50
4.1 SUGESTÕES DE TRABALHOS FUTUROS	52
REFERÊNCIAS.....	53
ANEXO A –Técnicas de Previsão Hanke et al. (2001).....	55
APÊNDICE A - MODELO SARIMA.....	56
APÊNDICE B - PREVISÃO AJUSTADA SARIMA.....	57
APÊNDICE C - TESTES DE ESPECIFICAÇÃO SARIMA.....	58
APÊNDICE D - MODELO ETS.....	59
APÊNDICE E - COMBINAÇÃO SIMPLES.....	60
APÊNDICE F - COMBINAÇÃO PONDERADA.....	61
APÊNDICE G – CÁLCULO U DE THEIL.....	62

1 INTRODUÇÃO

1.1 APRESENTAÇÃO DO PROBLEMA

De acordo com Moreira et al (2009), planejar é uma atividade comum a diversos tipos, tamanhos ou ramos de atuação empresarial, sendo a previsão de demanda a base para elaboração deste planejamento. Neste sentido, a utilização de técnicas de previsão demonstra-se relevante no que tange o planejamento das empresas.

Para Gaither e Frazier (2004), prever, ou estimar a demanda futura de produtos e serviços, bem como os recursos necessários para produzi-los, é o primeiro passo da etapa do planejamento. As estimativas das vendas futuras seriam também, segundo os autores, o ponto de partida para as demais previsões da organização, como, por exemplo, para a previsão de compras ou de fluxo de caixa.

Tratando-se dos desafios envolvidos na estimação de demanda em empresas ligadas ao varejo de moda, Kuns e Crone (2014), atentam para as particularidades dos dados relacionados a este setor, os quais indicam:

- a) a variação contínua do sortimento em virtude da introdução e descontinuidade de produtos;
- b) a presença de forte sazonalidade; e
- c) a intermitência de demanda, causada por produtos de venda lenta ou mesmo por rupturas de estoque.

Tais desafios são potencializados tratando-se de micro e pequenas empresas, as quais possuem condições gerenciais específicas - uma vez que as ferramentas de gestão e recursos disponíveis são diferentes daquelas que estão à disposição da grande empresa (DRUCKER, 1981).

Neste sentido Silva et al. (2016), ressaltam a importância da escolha de uma heurística de previsão de demanda adequada às particularidades do pequeno varejo de moda, como forma de otimizar relevantes problemas de impactos diretos nos resultados destas organizações. Entre os principais ligados a atividade de compras, estariam, portanto, o excesso e falta ou (insuficiência) de produtos no ponto de venda.

Partindo dos resultados obtidos em um experimento conduzido por Lopes e Herero (2017), duas conclusões podem ser extraídas acerca da percepção dos clientes sobre a falta de produtos em uma loja.

A primeira contribui para confirmar que, sob a perspectiva do cliente, uma eventual indisponibilidade de um produto que o mesmo procurou na gondola do estabelecimento geraria nele a percepção de que o produto esgotou levando-o a concluir que a loja pratica “preços baixos”. Este efeito seria, isoladamente, favorável sob o ponto de vista deste lojista, uma vez que o cliente tenderia a preferir esta loja em compras futuras em virtude dos “preços baixos que pratica” ao invés de comprar em estabelecimentos concorrentes.

A segunda conclusão, no entanto, traz um revés acerca da circunstância de falta de produtos na prateleira. Ao mesmo tempo em que os clientes assumem que a falta de produtos está associada a pratica de preços baixos, tendem a associar esta falta do produto à falta de organização/planejamento, ou seja, de “qualidade da operação do lojista”.

Em suma, a partir destas duas constatações, o estudo de Lopes e Herero (2017) conclui que a magnitude da perda na imagem da empresa (loja) por conta da percepção de baixa qualidade supera os eventuais ganhos oriundos da percepção de “preços baixos” por parte dos clientes quando defrontados com a falta de produtos.

Em extensão a este efeito de percepção de baixa qualidade da operação do lojista, eventualmente negativo a imagem da empresa por parte do cliente, somam-se outras consequências também desfavoráveis aos resultados do varejista. Como, por exemplo, a perda de vendas em si ou a perda para concorrência, na medida em que os consumidores não encontram os produtos desejados (SILVA et al. 2016).

No sentido oposto, o excesso de estoque também tende a repercutir de modo desfavorável aos resultados da organização. À medida que os investimentos em estoque ultrapassam excessivamente os níveis de demanda efetivos, incorrem-se custos de capital dispensáveis em relação às compras, quantitativamente mais elevados do que a demanda observada (SILVA et al. 2016; ANGELO et al. 2011).

Neste contexto, onde a obtenção de previsões de vendas mais precisas demonstra-se como um valoroso recurso estratégico para o planejamento das empresas, o presente estudo desenvolve-se com o intuito de verificar a possibilidade de concepção de uma heurística estruturada de previsões de vendas para a empresa BSM Bag Store. Isto com o propósito de fornecer informações a seus gestores, de modo que subsidie decisões mais precisas em termos das demandas de seus clientes, o que consequentemente geraria um incremento em seus resultados financeiros.

Pertencente à fração varejista dentre as micro e pequenas empresas brasileiras, a BSM é uma empresa catarinense atuante no nicho de produtos como bolsas, malas, pastas e

mochilas. Quando observadas características de porte e segmento aqui brevemente exploradas, são estudadas neste trabalho as alternativas para obtenção de previsões de demanda mais precisas, do que as empregadas atualmente em sua categoria de produtos denominada “bolsas”, comercializadas pela empresa.

1.2 DEFINIÇÃO DO PROBLEMA DE PESQUISA

A partir da exploração de metodologias estruturadas, compatíveis aos recursos técnicos e financeiros disponíveis à empresa, seria possível obter previsões para vendas de bolsas que se mostrassem mais acuradas do que aquelas geradas pela atual heurística empregada na empresa?

1.3 HIPÓTESE BÁSICA

Amparando-se este estudo na pesquisa em torno do referencial teórico acerca das ferramentas preditivas disponíveis, entende-se como possível a obtenção de previsões que diminuam o erro percentual absoluto médio em relação aos obtidos atualmente, ainda que, respeitando a razoabilidade quanto ao nível de complexidade pertinente às características desta pequena empresa.

1.4 OBJETIVOS

1.4.1 Objetivo Geral

Explorar diferentes teorias quantitativas de previsão, respeitando a razoabilidade quanto ao nível de complexidade pertinente as características da pequena empresa, isto é, suas limitações de recursos técnicos e financeiros, obter heurística de geração de previsões de demanda para bolsas femininas que diminua as discrepâncias em relação aos resultados obtidos atualmente.

1.4.2 Objetivos Específicos

- a) Baseado na tabela de previsões proposta por Hank et al. (2001), indicar metodologias e técnicas de previsão compatíveis com as características da organização estudada, isto é, as que se demonstrem aderentes aos seus dados e cuja complexidade seja factível ao seu porte;
- b) A partir da escolha do método ou técnica mais indicado, construir modelos de previsão quantitativos utilizando os dados de vendas fornecidos pela empresa;
- c) Combinar diferentes modelos de previsão de modo a comparar com o desempenho destes individualmente ou aqueles obtidos atualmente.

1.5 METODOLOGIA

A presente pesquisa apresenta natureza aplicada, na medida em que objetiva gerar conhecimentos para aplicação prática e exploratória, utilizando-se do levantamento bibliográfico para revisão do tema proposto (PRODANOV e DE FREITAS, 2013).

Quanto ao procedimento técnico, foram utilizadas tanto a pesquisa bibliográfica como a pesquisa documental, no que se refere à consulta tanto de como o assunto foi tratado por outros autores quanto como ao manuseio dos dados fornecidos pela empresa. Sendo assim, o trabalho foi desenvolvido sob uma abordagem qualitativa quanto a seleção dos modelos indicados e quantitativa a partir da utilização de métodos estatísticos para formulação das previsões (PRODANOV e DE FREITAS, 2013).

1.6 JUSTIFICATIVA

Presume-se que a implementação de técnicas de gestão mais eficientes por parte das organizações, é uma constante e progressiva característica da evolução cronológica do ambiente empresarial. Os avanços das técnicas de gestão, por sua vez, podem ser indicados como relevantes partes da evolução desta lógica histórica.

A previsão constitui-se numa ferramenta fundamental para o controle das atividades e o planejamento de vendas. Segundo Passari (2003), previsões precisas subsidiam informações

para tomada de decisões corretas dentro das empresas, prestando, portanto, relevante contribuição no aumento de vantagens competitivas para a mesma.

Inserida neste cenário, e impactada por este processo, a pequena empresa tem sua competitividade estreitamente determinada pelo conjunto de variáveis que a caracterizam, tendendo seu porte condicioná-la a limitações contundentes no que tange sua busca sistemática e permanente por práticas mais eficientes.

Entre outros fatores, o número reduzido de funcionários, comparativamente menor ao da grande empresa, tende a repercutir em um aprofundamento técnico mais superficial. Isto ocorre na medida em que ganhos oriundos da especialização do trabalho (SMITH, 1996) tornam-se menos prováveis em comparação a escalas produtivas maiores observadas em grandes corporações.

Para Druker (1981), a restrição de ferramentas e recursos disponíveis a este porte de empresa, diverge daquelas de maior porte. Neste mesmo sentido, Semler (1989) destaca o baixo embasamento técnico na tomada de decisões.

Se por um lado, as condições gerenciais da pequena empresa aparentemente a condicionam para absorção de conhecimento e técnicas de modo retardatário, Semler (1989) também destaca características relacionadas ao seu porte que a colocam em posição de potencialmente em vanguarda, como:

- a) Agilidade nas decisões;
- b) Aproveitamento rápido de oportunidades de curto prazo;
- c) Agilidade nas decisões e adaptação a mudanças de rumo.

1.7 LIMITAÇÕES DO TRABALHO

As limitações deste trabalho estão relacionadas às características da empresa estudada, uma vez que se exploram alternativas de previsão sujeitas às particularidades e limitações de recursos que seu porte (pequeno) genericamente a caracterizam.

Assim, a renúncia de técnicas cuja demasiada complexidade ou mesmo o tempo para o desenvolvimento sejam identificadas, será procedida por considerar-se as mesmas como incompatíveis com a realidade da empresa estudada, mesmo que isto possa significar conseqüente renúncia de resultados mais acurados.

1.8 ESTRUTURA DO TRABALHO

Além deste primeiro capítulo que tratou da apresentação e contextualização da problemática estudada e apresentada ao longo deste trabalho, o estudo traz também outros três capítulos.

O segundo capítulo é dedicado à exploração da literatura acessada acerca da previsão de vendas, visando apresentar os conceitos aplicáveis à empresa contemplada neste estudo de caso - em observância às suas características específicas.

Os resultados das previsões obtidas a partir dos modelos selecionados no segundo capítulo, em observância às características da empresa, são descritos no terceiro capítulo além de uma breve descrição da empresa e de sua metodologia de previsão empregada. Também neste são comparados os resultados dos modelos propostos entre si, sua combinação e com as previsões obtidas pela empresa.

Já as principais conclusões obtidas neste trabalho são colocadas no capítulo 4, que encerra o desenvolvimento deste estudo de caso. Neste também pode ser observado um conjunto de sugestões de possíveis trabalhos futuros complementares.

2 REFERENCIAL TEÓRICO

2.1 METODOLOGIAS DE PREVISÃO

De acordo com Hyndman (2009) as empresas frequentemente utilizam-se de métodos de previsão relativamente simples, os quais geralmente não são baseados em modelagem estatística. Sobre o desenvolvimento de sistemas de previsão o autor coloca:

Uma organização precisa desenvolver um sistema de previsão que envolva várias abordagens para prever eventos incertos. Esses sistemas de previsão exigem o desenvolvimento de experiência na identificação de problemas de previsão, aplicação de uma variedade de métodos de previsão, seleção de métodos apropriados para cada problema e avaliação e refinamento de métodos de previsão ao longo do tempo. Também é importante ter forte suporte organizacional para o uso de métodos formais de previsão, a fim de que sejam usados com sucesso. (HYNDMAN,2009 p.1).¹

2.1.1 Modelos de regressão linear

Segundo Gujarati (2011), pode-se modelar através de uma regressão o relacionamento entre duas ou mais variáveis de interesse:

Nestes modelos, uma variável, chamada de variável dependente, é expressa como uma função linear de uma ou mais outras variáveis, denominadas variáveis explicativas. Em tais modelos, assume-se implicitamente que as relações causais, se houver, entre as variáveis dependentes e explicativas fluem em apenas uma direção, nomeadamente, das variáveis explicativas para a variável dependente (GUJARATI, 2011 p. 15).

Representando a técnica inicial do modelo de regressão, a regressão linear modela o relacionamento entre a variável explicada Y e a variável explicativa X. Segundo, Gujarati (2011), pode ser representada pela equação:

$$Y = \alpha + \beta X + \varepsilon \quad (1)$$

Onde:

ε = erro aleatório com média zero

α = coeficiente estimado (termo independente)

¹ Tradução própria: An organization needs to develop a forecasting system involving several approaches to predicting uncertain events. Such forecasting systems require the development of expertise in identifying forecasting problems, applying a range of forecasting methods, selecting appropriate methods for each problem, and evaluating and refining forecasting methods over time. It is also important to have strong organizational support for the use of formal forecasting methods if they are to be used successfully.

β = coeficiente estimado.

Adicionando-se mais variáveis explicativas, obtém-se o modelo de regressão múltipla, representado pela equação:

$$Y = \alpha + \beta_1 x_1 + \beta_2 x_2 + \beta_3 x_3 + \dots + \beta_k x_k + \varepsilon \quad (2)$$

Portanto, segundo Armstron et al. (2010), a análise de regressão consiste em estimar coeficientes de modelos causais a partir de dados históricos (sendo possível também para dados em seção cruzada). Tratam-se, segundo o autor, de modelos com uma ou mais equações de regressão usadas para representar a relação entre duas variáveis: variável dependente e variáveis explicativas.

Estendendo a aplicação desta abordagem, Gujarati e Porter (2011) tratam de da possibilidade de diferença temporal entre causa e efeito. Isto ocorre, segundo os autores, na medida em que razões institucionais, tecnológicas e psicológicas de uma ou mais variáveis independentes do modelo possam responder com alguma defasagem em relação à variável dependente.

Assim, denomina-se modelos que aportam esta possibilidade como análise auto-regressiva com defasagens distribuídas (MADD) ou simplesmente análise de regressão dinâmica (PITTA, 2013). Podem estes modelos serem representados, segundo Wong et al (2007) e Souza (2005), a partir da equação:

$$Y_t = \phi_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \beta_1 X_{t-1} + \beta_2 X_{t-2} + \beta_p X_{t-p} + u_t \quad (3)$$

Onde:

Y_t = Variável dependente;

ϕ_0 = Constante;

ϕ_1, ϕ_2, ϕ_p e $\beta_1, \beta_2, \beta_p$ = Parâmetros das variáveis explanatórias;

Y_{t-p} = Variável dependente defasada no tempo;

X_{t-p} = Variáveis independentes defasadas no tempo;

u_t = Erro aleatório.

Atentam também Gujarati e Porter (2011), sobre a necessidade de cumprimento das hipóteses aplicáveis ao método MQO (Mínimos Quadrados Ordinários) utilizado para estimar a regressão. São estas:

- a) hipótese 1: O modelo de regressão é linear nos parâmetros;
- b) hipótese 2: Valores de regressores fixos e independentes do termo de erro;
- c) hipótese 3: Valor médio do termo do erro igual a zero;
- d) hipótese 4: Homoscedasticidade, ou seja, variância constante no erro;
- e) hipótese 5: Ausência de autocorrelação entre os termos de erro;
- f) hipótese 6: Quantidade de observações superior ao de parâmetros estimados;
- g) hipótese 7: Pressuposição de distribuição normal no erro.

Indicando a utilização de regressões para situações com muitas observações e poucas variáveis, Armstrong et al (2010) aponta três princípios a serem verificados em modelagens econométricas deste tipo: (1) O uso de conhecimento prévio e teoria, não ajuste estatístico, para selecionar variáveis e para especificar as direções dos efeitos; (2) O uso de modelos simples e o (3) descarte de variáveis nos casos em que relação estimada entrar em conflito com a teoria ou evidência anterior.

2.1.2 Suavização Exponencial

O conceito base da suavização exponencial trata da investigação da influência de comportamentos mais recentes sobre os dados da série, a fim de que se prevejam valores futuros (ARMSTRONG et al., 2010). De modo diverso a análise de regressão múltipla, o método de suavização exponencial simples não torna necessário conhecimento teórico prévio dos dados por parte do pesquisador. Discorrem os autores a respeito:

Os métodos de suavização exponencial não aproveitam o conhecimento das pessoas sobre os dados, mas supõem que as forças causais que moldaram a história continuarão. Se essa suposição estiver errada, os erros de previsão podem ser grandes. Como consequência, deve-se apenas extrapolar as tendências quando elas correspondem às expectativas anteriores dos especialistas da área em questão. Se essa suposição estiver errada, os erros de previsão podem ser grandes. (ARMSTRONG et al., 2010 p. 4)

Estendendo a abordagem tradicional de aplicação de técnicas de suavização exponencial simples, Winters estendendo o método desenvolvido por Holt, concebeu a metodologia que veio a ser conhecido pela literatura como modelo Holt-Winters (ANGELO et al., 2011).

Em uma abordagem mais ampla a suavização exponencial constitui-se de três equações básicas. Uma para ajuste do nível (Nt), uma para ajuste do crescimento (Ct) e outra

para ajuste da sazonalidade (St). Para a composição destas equações em uma previsão deve-se observar o comportamento da série quanto à tendência (nenhuma, aditiva, aditiva amortecida, multiplicativa e multiplicativa amortecida) bem como a sazonalidade (nenhuma, aditiva e multiplicativa) (SAMOHYL et al., 2008).

Esta classificação pode ser observada através da Figura 1, apresentada por Samohyl et al. (2008):

Figura 01 – Métodos de suavização exponencial

Tendência	Sazonalidade		
	S	A	M
S	$n_t = \alpha Y_t + (1 - \alpha)n_{t-1}$ $\hat{Y}_{t+h} = n_t$	$n_t = \alpha(Y_t - s_{t-s}) + (1 - \alpha)n_{t-1}$ $s_t = \gamma(Y_t - n_{t-1}) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t + s_{t-s+h}$	$n_t = \alpha(Y_t + s_{t-s}) + (1 - \alpha)n_{t-1}$ $s_t = \gamma(Y_t + n_{t-1}) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t \times s_{t-s+h}$
A	$n_t = \alpha Y_t + (1 - \alpha) \times (n_{t-1} + c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)c_{t-1}$ $\hat{Y}_{t+h} = n_t + h \times c_t$	$n_t = \alpha(Y_t - s_{t-s}) + (1 - \alpha) \times (n_{t-1} + c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)c_{t-1}$ $s_t = \gamma(Y_t - n_{t-1} - c_{t-1}) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t + h \times c_t + s_{t-s+h}$	$n_t = \alpha(Y_t + s_{t-s}) + (1 - \alpha) \times (n_{t-1} + c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)c_{t-1}$ $s_t = \gamma(Y_t + (n_{t-1} + c_{t-1})) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = (n_t + h \times c_t) \times s_{t-s+h}$
Aa	$n_t = \alpha Y_t + (1 - \alpha) \times (n_{t-1} + \varphi c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)\varphi c_{t-1}$ $\hat{Y}_{t+h} = n_t + \sum_{i=1}^h \varphi^i c^t$	$n_t = \alpha(Y_t - s_{t-s}) + (1 - \alpha) \times (n_{t-1} + \varphi c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)\varphi c_{t-1}$ $s_t = \gamma(Y_t - n_{t-1} - \varphi c_{t-1}) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t + \sum_{i=1}^h \varphi^i c^t + s_{t-s+h}$	$n_t = \alpha(Y_t + s_{t-s}) + (1 - \alpha) \times (n_{t-1} + \varphi c_{t-1})$ $c_t = \beta(n_t - n_{t-1}) + (1 - \beta)\varphi c_{t-1}$ $s_t = \gamma(Y_t + (n_{t-1} - \varphi c_{t-1})) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = \left(n_t + \sum_{i=1}^h \varphi^i c^t \right) \times s_{t-s+h}$
M	$n_t = \alpha Y_t + (1 - \alpha) \times (n_{t-1} \times c_{t-1})$ $c_t = \beta(n_t \times n_{t-1}) + (1 - \beta)c_{t-1}$ $\hat{Y}_{t+h} = n_t \times c_t^h$	<i>Instável</i>	$n_t = \alpha(Y_t + s_{t-s}) + (1 - \alpha) \times (n_{t-1} \times c_{t-1})$ $c_t = \beta(n_t \times n_{t-1}) + (1 - \beta)c_{t-1}$ $s_t = \gamma(Y_t + (n_{t-1} \times c_{t-1})) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t \times c_t^h \times s_{t-s}$
Ma	$n_t = \alpha Y_t + (1 - \alpha) \times (n_{t-1} \times c_{t-1}^\varphi)$ $c_t = \beta(n_t \times n_{t-1}) + (1 - \beta)c_{t-1}^\varphi$ $\hat{Y}_{t+h} = n_t \times c_t^{\sum_{i=1}^h \varphi^i}$	<i>Instável</i>	$n_t = \alpha(Y_t + s_{t-s}) + (1 - \alpha)n_{t-1} \times c_{t-1}^\varphi$ $c_t = \beta(n_t \times n_{t-1}) + (1 - \beta)c_{t-1}^\varphi$ $s_t = \gamma(Y_t + (n_{t-1} \times c_{t-1}^\varphi)) + (1 - \gamma)s_{t-s}$ $\hat{Y}_{t+h} = n_t \times c_t^{\sum_{i=1}^h \varphi^i} \times s_{t-s}$

Fonte: Samohyl et al. (2008 p 161).

Na presente tabela constam as diferentes possibilidades de classificação de modelos de suavização exponencial segundo as características de seus componentes (n,c,s). Conforme explanado acima cada componente é representado por uma constante de suavização ($\alpha, \beta, \gamma, \varphi$).

No entanto, existem dois modelos, com tendência multiplicativa e sazonalidade aditiva (MA) e com tendência multiplicativa amortecida e sazonalidade aditiva (MaA), cujas equações não são apresentadas. Isto se deve ao fato de serem dois modelos que se mostraram instáveis (variância tendendo ao infinito e, conseqüentemente, esperança indefinida), o que inviabilizaria a utilização prática destes.

Aprofundando-se especificamente sobre a estimação dos parâmetros no modelo Holt-Winters (Formulações apresentadas na segunda linha e terceira coluna da Tabela 1), Angelo et al. (2011, p.7) discorrem sobre a minimização de erros para o ajuste dos dados:

Para que a suavização seja obtida é preciso, portanto, considerar o componente permanente (nível), a tendência e a sazonalidade. Os parâmetros de amortecimento são atribuídos de modo a realizar o melhor ajuste possível aos dados. Os programas estatísticos calculam esses parâmetros interativamente e automaticamente de modo a minimizar os erros (ANGELO et al 2011, p .7).

De modo geral, uma vez estimadas as constantes de suavização (α , β , γ), sua interpretação se dá em uma espécie de peso atribuído a observação mais recente, ou seja, esta estimativa fica mais próxima de um quando seu padrão de comportamento se modifica com relativa frequência e mais próxima de zero quando se mantem relativamente estável ao longo da amostra (SAMOHYL et al. 2008).

Ainda sobre a estimação destes coeficientes, aponta-se a necessidade de escolha do critério de erro a ser minimizado (SAMOHYL et al. 2008). Para estimação do modelo de suavização exponencial proposta neste estudo de caso utilizou-se o AIC – critério “padrão” na ferramenta computacional utilizada neste trabalho (algoritmo “ets” disponível no pacote *Forecast* do *software R*).

2.1.3 Metodologia *Box-Jenkins* (modelos ARIMA)

De acordo com Passari (2003), constituem-se os métodos auto-regressivos de uma classe genérica de modelos, os quais contemplam técnicas estatístico-regressivas: regressão com base no tempo, médias móveis e diferenciação para séries que apresentem padrão não estacionário.

Referenciam-se, portanto, as equações ARIMA (p,d,q) elementos os quais Souza (2005, p. 40) respectivamente detalha:

É um método em que as previsões dependem do cálculo de cada um de seus processos, o processo auto-regressivo (p) que representa a ordem de relacionamento com seus valores passados; o processo de integração ou diferenciação (d) que representa a ordem do processo integrado não estacionário, ou seja, o número de “d” vezes que o processo integrado deve ser submetido a diferenciações para que se torne estacionário. E por fim o processo de média móvel (q), isto é, da ordem de defasagem dos erros, que representa o número de defasagens dos ruídos não correlacionados que terá “ Y_t ” como função linear. (SOUZA, 2005, p. 40).

Segundo Box e Jenkins (1976) constituem-se os passos para a construção do modelo:

- a) a partir da utilização de ferramental estatístico, testa-se a estrutura de autocorreção da série, de modo a identificar os modelos temporalmente mais ajustados (utilizando-se da classe genérica ARIMA);
- b) a partir do uso de técnicas lineares, estimam-se os parâmetros do modelo (similarmente ao executado em modelos de regressão, sendo os parâmetros destes, no caso estimados de modo linear);
- c) definição do modelo mais ajustado, a partir do diagnóstico e mensuração dos erros resultantes de cada um.

Citando a necessidade de cumprimento do critério de estacionariedade em nível, Luppe et al. (2011) indicam a sua possibilidade a partir da aplicação da primeira diferença aos dados. Na medida em que se verifique persistência da não estacionariedade, aplica-se a segunda diferença.

Tratando-se da identificação quanto à estacionariedade da série, Souza (2005) trata ainda sobre o teste de raiz unitária, obtido por meio da metodologia desenvolvida por Dickey-Fuller: “Nele se testa se a raiz de um polinômio que determinara a influência de um valor defasado para explicar o valor atual de Y, será igual ou estará entre -1 e 1.”

Quanto à nomenclatura dos modelos ARIMA, esclarecem Bundchen e Werner (2016):

Diversos modelos ARIMA podem ser utilizados para modelar uma série temporal de acordo com as suas características, sendo que os modelos podem ter apenas componentes auto-regressivos (AR), componentes de média móvel (MA) e ambos componentes (ARMA). Além disso, séries não estacionárias podem ser modeladas através de modelos ARIMA, onde são realizadas diferenças com o intuito de tornar a série estacionária, e séries com componente sazonal são modeladas através de modelos denominados SARIMA. (BUNCHEN; WERNER, 2016 p. 12).

Por fim, por tratar-se de modelos de regressão, torna-se necessário a conformidade dos modelos estimados quanto ao cumprimento das pré-condições exigíveis a estes. Enumeram-se estes segundo Souza (2005), em adição aos demais critérios previamente abordados:

- 1): valor esperado do resíduo deve ser igual a zero, isto é, $E(e_i)=0$;
- 2): a variância do resíduo deve ser constante, isto é, $E(e^2)=\text{constante}=\sigma^2$. Se isso não for verdadeiro, então o teste de hipóteses dos coeficientes e os intervalos de confiança assumem variabilidade inapropriada, e, portanto, a significância dos estimadores não pode ser verificada, devido à heteroscedasticidade residual; e por fim
- 3): os resíduos do modelo devem seguir a distribuição normal, isto é $e_t \sim N(0,1)$. (SOUZA 2005 p. 44).

Diante do exposto, torna-se também relevante a popularidade alcançada pelos modelos ARIMA citada por Wheel Wright e Makridakis (1973), atribuída segundo estes a flexibilidade em lidar com diversos tipos de dados de séries temporais, em parte por suas fortes bases teóricas, e em parte graças ao seu sucesso em comparações empíricas, sendo ele tão preciso quanto muitos modelos econométricos complexos.

2.1.4 Redes neurais artificiais

Definem-se como redes neurais artificiais a “distribuição de sistemas de processamento de informações”, compostos pela interação entre muitos elementos computacionais através de conexões com diferentes ponderações (PASSARI, 2003). Sua denominação remete ao funcionamento das redes neurais biológicas conforme explica Angelo et al. (2011):

As redes neurais artificiais são inspiradas no comportamento de redes neurais biológicas. Elas são compostas de nós denominados neurônios ligados entre si por conexões que guardam relação com as ligações formadas por axônios e dendritos componentes de células neurais biológicas. Em geral uma RNA é constituída de um grande número de nós organizados em camadas e que se conectam a outros nós por meio de conexões nas quais fluem sinais, da mesma forma que entre neurônios biológicos fluem sinais de natureza elétrica. Cada conexão de um nó a outro nó tipicamente tem associado um peso que, guardadas as devidas diferenças, pode ser entendido como representando o grau de acoplamento existente entre dois neurônios biológicos. (ANGELO et al. 2011, p. 9).

Cada um destes “nós” é densamente interconectado com conexões diretas e operam em função de dois estágios. O primeiro destes estágios calcula a soma dos sinais de entrada, de modo a atribuir-lhes pesos, sendo no segundo aplicada uma função de saída, denominada função de ativação (PASSARI, 2003).

Tratando-se do uso para séries temporais, Angelo et.al. (2011) indicam o modelo MLP (*Multi Layer Perceptron*) como o mais utilizado para a realização de previsões. Aplicam-se nestes tipos de modelo, no entanto, “uma camada de nós de entrada, uma ou mais intermediária e uma de saída”. Deste modo, são as variáveis independentes representadas por cada nó de entrada ao passo em que o nó de saída representa a dependente que está sendo prevista pela rede. Os mesmos autores descrevem acerca da etapa de treinamento sobre a qual passa uma rede MLP:

Em geral uma rede MLP passa por uma etapa inicial dita de treinamento para, a seguir, ser executada o que, no caso da previsão, corresponde a tarefa de efetivamente computar previsões. Na etapa de treinamento são computados os pesos das conexões a partir de um conjunto de pares entrada-saída, pertinentes aos valores

conhecidos das variáveis independentes e correspondentes valores das variáveis dependentes. Nessa fase, a partir dos valores conhecidos dos sinais de entrada, são computados os correspondentes valores dos sinais de saída, que por sua vez são comparados com os valores conhecidos das variáveis dependentes. Em síntese a diferença entre os valores conhecidos e os computados determina um ajuste iterativo nos pesos das conexões de forma a minimizar esta diferença ou erro. Na etapa de execução são apresentados à rede treinada os valores das variáveis de entrada e ela computa os valores das variáveis de saída ou valores previstos. Nas duas etapas a computação de saídas a partir de entradas em cada nó é realizada de acordo com o funcionamento anteriormente especificado do neurônio artificial. (ANGELO et al. 2011, p. 10).

Assim, segundo Sacramento (2014), representam os parâmetros das redes neurais os pesos atribuídos das conexões entre os neurônios e os *biases* de nós. A partir disto, por meio do algoritmo proposto por Levenberg e Marquardt (LVMQ) (HAGAN e MENHAJ, 1994) ajustam-se os pesos e biases. A partir do LVMQ otimiza-se o treinamento da rede, sendo este “o algoritmo de retro propagação mais rápido para o aprendizado não supervisionado” (SACRAMENTO, 2014 p. 41)

2.3 MEDIDAS DE ERRO DE PREVISÕES

Segundo Samohyl et al. (2008), a identificação e investigação discrepâncias frequentemente estão associados a melhores resultados de previsão. Segundo os mesmos autores, define-se discrepâncias como a diferença entre os valores observados e os previstos.

Deste modo Passari (2003, p.24), define a importância das medidas de desempenho dos modelos de previsão:

Uma vez que a acurácia é o critério mais importante na seleção e avaliação das técnicas de previsão, ela precisa ser definida matematicamente. A fim de avaliar o desempenho (acurácia) absoluto relativo dos diversos modelos de previsão diversas ferramentas matemáticas foram desenvolvidas com o tempo (PASSARI 2003, p.24).

A medida que o presente estudo busca apresentar técnicas de previsão mais precisas, nas próximas subseções serão expostas alguma das medidas de erro utilizadas no desenvolvimento deste trabalho.

2.3.1 Discrepância percentual absoluta média (MAPE)

Também tratada na literatura como MAPE (*Mean Absolute Percentual Error*) possui esta medida possui a característica de neutralizar o sinal dos erros (SAMOHYL et al., 2008). Pode ser representada pela equação:

$$MAPE = \frac{1}{n} \sum_{n=1}^n \left| \frac{P_t - O_t}{O_t} \right| \quad (4)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

Segundo Samohyl et al., (2008) são frequentemente utilizadas nos cálculos das engenharias e administrações posto que sua representação torna intuitiva e rápida sua interpretação.

Advertem, no entanto, sobre algumas falhas desta medida de discrepância em casos em que os valores observados sejam iguais a zero, como por exemplo em casos onde o produto que está sendo previsto não apresenta vendas em determinado período. Nestes casos o valor da DPAM tende ao infinito, sendo necessária utilização de medidas de previsão mais sofisticadas (SAMOHYL et al., 2008)

2.3.2 Erro escalar médio absoluto (MASE)

O erro escalar médio absoluto ou *Mean Absolute Scaled Error* (MASE) é independente da escala dos dados, portanto, pode ser usado para comparar previsões em conjuntos de dados com diferentes escalas Hyndman e Koehler (2006).

Segundo Hyndman (2014), é dado pela fórmula:

$$MASE = \frac{1}{K} \sum_{k=1}^K [y_{T+k} - \hat{y}_{t+k|T}] / Q \quad (5)$$

$$Q = \frac{1}{T-1} \sum_{t=2}^T |y_t - y_{t-1}| \quad (6)$$

Onde:

$\hat{y}_{t+k|t}$ = Estimativa para y_{t+k} dadas $y_1, y_2 \dots y_T$ observações;

Q = Fator de escala

T = tamanho da amostra

Segundo Hyndman e Koehler (2006), o MASE é indicado como uma das melhores medidas da precisão das previsões. Entre as vantagens atribuídas os autores citam que o MASE possui unidade de medida escalar. Sobre este ponto, reforçam ainda: “propomos que medidas baseadas em erros escalonados devam se tornar a abordagem padrão em comparar a precisão das previsões entre as séries em diferentes escalas (HYDMAN e KOEHLER, 2006 p. 4).

Quando $MASE < 1$, o método proposto fornece em média, erros menores que o de que os obtidos pelo método ingênuo (HYNDMAN e KOEHLER, 2006).

2.3.3 U de Theil

O U de Theil consiste em uma medida relativa de erro um a vez em que compara os erros da previsão obtida com os erros provenientes de uma previsão de um passo atrás. (SAMOHYL et al. 2008). Representa-se através da equação:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left[\left(\frac{\hat{Y}_{t+1} - Y_t}{Y_t} \right) - \left(\frac{Y_{t+1} - Y_t}{Y_t} \right) \right]^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (7)$$

Onde:

Y = Observado

\hat{Y} = Previsto

Segundo Samohly et al. (2008), trata-se o U de Theil de uma importante medida de erro a medida em que pode auxiliar em decisões sobre investimento de esforços para obtenção de previsões:

Esta medida assume um papel decisivo na determinação de utilização ou não de uma técnica de previsão específica, seja ela quantitativa, qualitativa, formal ou informal, pois possui a capacidade de demonstrar se tal esforço é compensador e faz sentido dependê-lo, ou se resultados melhores poderiam ser atingidos utilizando-se a mais singela das técnicas, ou seja, a previsão ingênuo. (SAMOHLY et al., 2008 p 69).

Deste modo, a medida que o U de Theil aproxima-se de um (1,00) interpreta-se proximidade da previsão com aquela obtida pelo método ingênuo, uma vez que o valor projetado é igual ao último ocorrido ($\hat{Y}_{t+1}=Y_t$). Da mesma forma em que a proximidade do zero, por sua vez, indica similaridade com a previsão perfeita ($\hat{Y}_{t+1}=Y_{t+1}$).

2.4 COMBINAÇÃO DE PREVISÕES

De acordo com Hyndman (2009), o uso de diferentes métodos de preditivos de forma simultânea indica-se como um caminho simples para obtenção de previsões mais precisas em séries temporais. Segundo o autor, a combinação de previsões, mesmo que construída a partir da média aritmética simples, apresenta-se como uma possibilidade recorrentemente promissora no sentido da obtenção de previsões mais acuradas.

Mencionando também a robustez de resultados obtidos a partir de modelos por média simples, o estudo de Clemen (1989), reforça o êxito em termos maior acurácia em previsões obtidas com a aplicação de modelos combinados em diversos campos de estudo.

Baseado nesta convergência, o presente estudo de caso buscará obter resultados de previsão mais precisos a partir da combinação de diferentes métodos. Serão, portanto, produzidas previsões obtidas a partir da combinação por média simples, como também por metodologia que explore critério de ponderação alternativo (otimizado).

Por fim, à medida que se indique o uso de metodologias quantitativas estruturadas para modelagem de previsões combinadas, adotar-se-á esta abordagem no desenvolvimento do presente estudo de caso, excluindo, portanto, o método utilizado pela empresa (MARTINS E WERNER, 2013).

2.4.1 Método de combinação por média simples

Segundo Martins e Werner (2013), o método de combinação por média simples consiste na combinação linear de duas previsões.

$$Fc = 0,5F_1 + 0,5F_1$$

(8)

Onde:

f_c = Previsão gerada pela combinação

F_1 = Previsão 1

F_2 = Previsão 2

A previsão resulta do somatório de cada previsão multiplicada pelo seu respectivo peso, dividido pelo somatório dos pesos (que será igual a 1). Deste modo, atenta-se ao fato de todas as previsões que comporão a previsão combinada, por média simples, receberem o mesmo peso. (MARTINS E WERNER, 2013).

2.4.2 Método da variância e covariância

Nesse método, os pesos são determinados por uma matriz de covariâncias, na qual a precisão das previsões únicas é incorporada nas variâncias, enquanto a dependência entre as previsões únicas é interpretada pelas covariâncias (WONG et al. 2007).

Deste modo a representação matemática do método de combinação por variância e covariâncias é:

$$w_1 = \frac{(\sum e_{2t}^2 - \sum e_{1t}e_{2t})}{(\sum e_{1t}^2 + \sum e_{2t}^2 - 2 \sum e_{1t}e_{2t})} \quad (9)$$

$$w_2 = \frac{(\sum e_{1t}^2 - \sum e_{1t}e_{2t})}{(\sum e_{1t}^2 + \sum e_{2t}^2 - 2 \sum e_{1t}e_{2t})} \quad (10)$$

Onde:

e_1 = Erro no tempo 1

e_2 = Erro no tempo 2

w_1 = Peso de uma previsão

w_2 = Peso de outra previsão

Assim, segundo Wong et al (2017), atribui-se maior peso aos modelos cujas previsões apresentem menor variância. O modelo resultante, portanto, é aquele que apresenta menor variância uma vez retirados os efeitos da covariância entre diferentes previsões.

No entanto, acrescentam Winkler e Makridakis (1983), que algumas metodologias que utilizam variância e covariância são mais precisas que a técnica de combinação simples e que

as previsões individuais, e os procedimentos em que a covariância é ignorada, por vezes, são mais precisos do que aqueles em que a variância é considerada.

2.4.3 Técnicas de minimização

Segundo Bates e Granger (1969), a previsão combinada (simples) pode ser representada por:

$$F_c = wF_1 + (1 - w)F_2$$

(11)

Onde:

F_1 = Previsão 1 a ser combinada;

F_2 = Previsão 2 a ser combinada.

w = Peso da previsão 1;

$(w - 1)$ = Peso da previsão 2

A partir disto, em adição ao critério de erro adotado pelo pesquisador torna-se possível a combinação ponderada com peso otimizado (PITTA, 2013). Para esta otimização a literatura visitada sugere a utilização de um algoritmo computacional destinado a este fim como, por exemplo, para situações associadas a particularidades da pequena empresa, o MS-Solver® (SOUZA, 2005 e PITTA, 2013).

No entanto, neste estudo conduz-se a otimização pelo algoritmo disponível através do pacote *ForecastHybrid do software R*, o qual estabelece os pesos ótimos visando minimizar o MASE. Portanto, a opção pela combinação por média ponderada por pesos otimizados teve em vista tanto a facilidade pratica fornecida pelo software utilizado, quanto pela evidenciada robustez adequação do método.

2.5 AVALIAÇÃO DE PREVISÕES

Alguns estudos acerca da aplicação de diferentes medidas de erro para comparar a *performance* de previsão diferentes métodos, frequentemente convergem para mesma métrica (Song et al., 2003b e Martin e Witt, 1989). A medida mais recorrentemente mais utilizada é o erro percentual absoluto médio (MAPE).

Tendo em vista esta convergência, as quais são ligadas as suas inerentes vantagens (não depende das magnitudes e interpretação intuitiva), será ela uma das métricas de comparação utilizadas neste estudo. Adicionalmente o trabalho contará também com o U de Theil, a medida que este também avalia a heurística em comparação ao método ingênuo em termos de precisão e possui uma associação com o MASE conforme apresentado na seção 2.4.2. (HYNDMAN e KOEHLER, 2006).

Considera-se, como dados aos quais cada metodologia será submetida, portanto, o período de observações compreendido de janeiro de 2012 a maio de 2018, sendo este recorte a fonte de dados para estimação dos modelos sugeridos neste trabalho.

A exceção caberá às previsões fornecidas pela abordagem utilizada pela empresa, as quais, em virtude de características inerentes a sua metodologia, possuem dados somente a partir de 2015. Segundo informação de seus gestores, o período anterior a este não possui dados de previsão posto que esta atividade não era realizada pela empresa.

2.6 SELEÇÃO DAS METODOLOGIAS DE PREVISÃO A SEREM EMPREGADAS

Visando esclarecer o conteúdo ao qual está seção se propõe, torna-se oportuna a diferenciação entre fatores envolvidos na seleção de metodologias de previsão e na avaliação de previsões. Acerca deste tema destaca Passari (2003):

É importante distinguir os critérios de técnicas com aqueles de avaliação de previsões. Durante a seleção, a preocupação é a escolha da técnica mais adequada ao problema, aquela capaz de modelar o fenômeno com maior precisão ou atingir outro critério de seleção especificado. Já durante o processo de avaliação, está-se preocupado com a performance do modelo criado a partir da técnica selecionada, ou seja, com a medida de qualidade das previsões efetuadas. Naturalmente uma escolha acertada da técnica de previsão deve levar a uma melhor capacidade preditiva do modelo gerado. (PASSARI, 2003 p.24)

Deste modo, partindo da classificação proposta por Hanke et al. (2001)², demonstraram-se inicialmente como as abordagens indicados ao problema em questão: previsão ingênua, suavização exponencial, metodologia Box-Jenkins e regressão múltipla para séries temporais.

Tal seleção decorre dos modelos e técnicas sugeridas pelos autores segundo as características identificadas nos dados deste estudo, isto é, marcante presença de sazonalidade e possível ciclo e tendência, além do necessário e prudente curto horizonte de previsões.

² Disponível no Apêndice A

Ainda que inicialmente elegível para este estudo segundo a avaliação inicial efetuada com base nos critérios de Hanke et al. (2001), optou-se pela não utilização do modelo de regressão. Lastreia-se esta decisão, em 3 fatores a saber.

O primeiro relaciona-se diretamente a maior necessidade de manuseio de dados exigidos por esta metodologia, uma vez que inerentemente utiliza-se de variáveis explicativas (ALMEIDA; PESSARI, 2004). Dados estes que exigiriam periódica coleta (por não fazerem parte do banco de dados da empresa), além de frequente monitoramento, possíveis tratamentos e eventuais projeções fora da amostra (devido a possibilidade de significância estatística de parâmetros associados a variáveis explicativas no mesmo período de tempo).

O segundo está ligado à necessidade de cumprimento das hipóteses inerentes a este método explanadas na secção deste trabalho que o trata. Tendo em vista a capacitação técnica do capital humano disponível, cujo o tamanho e atribuições já são condizentes e ajustadas ao tanto ao porte da empresa, quanto a capacidade de absorção desta rubrica na estrutura de custos, a torna não compatível ao contexto.

O terceiro está ligado a recorrente indicação por parte da literatura sobre o desempenho igual ou inferior desta metodologia em previsões de curto horizonte de tempo - em comparação a outras técnicas como Box Jenkins e Suavização Exponencial (PESSARI, 2003; HANKE et al., 2001; ALMEIDA E PESSARI, 2004).

Por outro lado, ainda que não presente entre as técnicas contempladas no estudo de Hanke et al (2001), avaliou-se a possibilidade de uso da metodologia de previsão baseada em redes neurais artificiais. Tal iniciativa motivou-se a partir da crescente difusão de menções em meios informais acerca dos recentes avanços na capacidade de processamento de dados e interações computacionais.

A utilização desta metodologia, no entanto, demonstrou-se também não indicada para a empresa dada complexidade envolvida nas modelagens deste tipo, as quais incluem: escolha de “camadas”, número de “nós”, “algoritmo de treinamento” bem como no próprio processo de obtenção, seleção e processamento dos dados (ALMEIDA E PESSARI 2004, p.23).

Em convergência a conclusões de outros trabalhos, citam Almeida e Pessari (2004) estudo sobre previsão de vendas no varejo por eles conduzido com o uso de redes neurais artificiais:

O processo de obtenção, seleção e tratamento dos dados mostrou-se bastante trabalhoso e oneroso. O grande volume de dados de transações de apenas uma loja fez com que as análises fossem bastante demoradas. Somente para as subamostras selecionadas o tempo de treinamento das redes neurais levou até 12 horas para cada rede.(ALMEIDA E PESSARI 2004, p.23)

Deste modo, na medida em que se busca sugerir metodologias de previsão cuja execução seja compatível com as limitações de tempo e recurso da empresa estuda - também comuns a outras do mesmo porte – foram por motivos similares, modelos de análise de regressão e redes neurais não recomendados para este caso.

Quanto à previsão ingênua, considera-se esta incluída na medida em que se utiliza neste estudo o U de Theil como métrica complementar de avaliação da precisão das previsões, o que permite uma comparação com esta técnica e também justifica sua utilização e não o MASE.

Por fim, a opção pelos métodos citados de Suavização Exponencial e Metodologia Box-Jenkins, demonstrou-se, portanto, amparada pela adesão entre a bibliografia que as trata (SILVA, et al. 2016; PASSARI, 2003; HANKE et al, 2001; PITTA, 2013 e SOUZA, 2005) e as características dos dados deste estudo.

Foram, portanto, primeiramente reproduzidos os dados à abordagem utilizada atualmente pela organização. Em seguida, foram estes submetidos a técnicas que se utilizam do comportamento da própria série de dados no tempo (univariadas) representadas neste estudo pela Suavização Exponencial e Metodologia Box-Jenkins (ARIMA).

Em seguida, buscou-se combinar as diferentes abordagens, com intuito de explorar a complementariedade informacional contida nas diferentes abordagens metodológicas, o que contribui para a maior precisão nas previsões. O procedimento foi realizado utilizando o algoritmo de otimização disponível no pacote do *software* R (*ForecastHybrid*).

Destaca-se que este *software* foi configurado para indicar uma ponderação distinta entre as técnicas e metodologias utilizadas, a qual seria capaz de gerar a previsão mais ajustada segundo os critérios de qualidade anteriormente citados. Esta configuração pode ser observada no apêndice F.

3 ANÁLISE EMPÍRICA

3.1 APRESENTAÇÃO DA EMPRESA

Contextualizando o estudo de caso ao qual este trabalho se propõe, esta seção visa apresentar uma breve descrição da empresa a que ele trata.

A BSM Bag Store é uma pequena empresa familiar, varejista, localizada no Shopping Via Catarina, em Palhoça. Inaugurada em dezembro de 2010, possui aproximadamente 96m² de área de loja. Atuando como uma multimarca é especializada na venda de bolsas, mochilas, malas e artigos de viagem em geral os quais são detalhadamente expostas no manual de compras, conforme o Manual BSM (2018):

- a) Bolsas: categoria sob a qual se direcionam as previsões deste trabalho. Produto com apelo de visual, cuja venda está frequentemente associada à escolha por impulso por parte do cliente, muito embora a preocupação com características ligadas a ergonomia e a durabilidade estejam também fortemente presentes. Entre as que possuem patamares de preço relativamente maiores, variáveis ligadas às tendências de moda, oscilação do prestígio das marcas assim como o cuidado com a exposição dos produtos na loja tendem a apresentar maior relevância. Entre os concorrentes podem-se citar boutiques, lojas de confecção em geral e principalmente lojas de calçado feminino, sendo para este caso representado por lojas com posicionamento

progressivamente “elitizado”, na medida em que o preço é comparativamente maior. Os exemplos partem de redes nacionais como Arezzo, Schutz, Capodarte, redes regionais como Imperador Calçados e Carioca Calçados bem como numerosa base de lojistas calçadistas individuais. Tratando-se de patamares inferiores de preço para este produto, observa-se aparente aumento da sensibilidade com que a quantidade demandada responde a variações de precificação, embora as outras variáveis indicadas para bolsas de valor elevado permaneçam presentes. Para este grupo, redes como Studio Z, Marisa e Renner, (lojas “*fast fashion*”, de autoatendimento) aparentam, segundo percepção dos gestores, proporcionar maior embate concorrencial. (MANUAL BSM, 2018).

- b) Malas: possuem fluxo de venda relacionado com desempenho de outros itens de viagem como frasqueiras e bolsas de viagem. Segundo os gestores da empresa, os clientes deste tipo de produto em geral manifestam comportamento de uma compra planejada quando se trata de viagem de férias: frequentemente pesquisam preços semanas antes de sua viagem. Por outro lado, para clientes cuja compra é motivada por viagem a trabalho, esse comportamento não é tão evidente. Enquanto a venda relacionada à utilização em viagens a lazer tende a priorizar malas de maior volume e diversidade de estampas, vendas direcionadas a viagem de negócios costumam priorizar volumes menores, praticidade dos espaços internos e cores mais neutras. Entre os principais concorrentes estão os supermercados (Giassi) e algumas lojas de departamento (Americanas, Miliun). (MANUAL BSM, 2018).
- c) Mochilas: enquanto itens de viagem, observamos a polarização quanto à motivação de compra em majoritariamente dois grandes grupos, as vertentes para mochilas são ainda mais generosas. Mochilas de utilização escolar podem divididas grosseiramente em dois grupos etários: Infantil e infanto-juvenil. Enquanto o primeiro encontra como decisor de compra os pais (ou outro adulto ligado a criança) o segundo grupo tem influência mais forte dos adolescentes. Além disso, os dois grupos são impactados pela preferência por personagem ou licenças, particulares à específicas faixas etárias e direcionamento de gênero, cuja relevância está sujeita a também particulares formas de disseminação: enquanto para crianças a veiculação de desenhos na tv (aberta ou paga) e filmes tem papel mais relevante para a disseminação dos personagens, o público adolescente é impactado pela eficácia em que os gestores das licenças divulgam-nas via *youtubers*, esportistas, “celebridades”, games, filmes e outros.

Tratando-se ainda de mochilas, uma linha mais “básica” no que se refere aos atributos visuais do produto (geralmente em cores mais sóbrias como preto o marinho) atendem clientes cuja diversidade de utilização torna complexo qualquer iniciativa que se proponha a agrupá-lo. Demandantes desse tipo de mochila vão de clientes que intenciam seu uso no deslocamento para o trabalho, para academia, faculdades ou mesmo por adolescentes não impactados pelas múltiplas licenças a eles direcionadas. Há ainda um vasto grupo de mochilas denominadas “mochilas para notebook” muito embora esta classificação possa induzir a percepção de que são majoritariamente direcionadas para usuários de computadores móveis, quando não necessariamente são de fato. Tratam-se de produtos com materiais de maior qualidade, durabilidade e que possuem na maior parte das vezes compartimento dimensionado para notebooks. Quando tratamos dos principais concorrentes para o produto mochila, compreendendo aqui a maior parte de suas variações apresentadas estão as lojas de departamento (Americanas, Havan), papelarias as quais costumam ser frequentemente representadas pelas locais em adição a algumas redes (Kalunga) bem como a supermercados. (MANUAL BSM, 2018).

3.2 MÉTODO DE PREVISÃO REALIZADO PELA EMPRESA

Segundo informações fornecidas por seus gestores para a empresa é importante a acurácia da previsão porque a partir dela consegue-se determinar as cotas de compra dividindo-se volume previsto pelo *mark-up*. Quanto ao horizonte de previsão verificou-se especial importância para o período de 3 meses à frente.

Também a partir do relato dos gestores da organização, buscou-se caracterizar a forma como são por eles geradas atualmente as previsões de vendas de bolsas. Verificou-se com estes, a sua percepção quanto a forte influência sazonal deste produto final. Tal percepção, seria segundo eles motivada tanto pelo “senso comum” quanto pela melhor *performance* em meses como maio (Dia das Mães), junho (Dia dos namorados) e dezembro (Natal). Especialmente por notar relativa similaridade entre o formato dos gráficos de vendas mensais em diferentes anos, mesmo em meses diferentes aos citados.

Baseada nesta percepção, a metodologia de previsão adotada consistia em calcular uma média das vendas do mesmo mês nos últimos 3 anos. Determinada subjetivamente a média aritmética de 3 períodos, buscava minimizar eventual impacto de meses “atípicos”.

Segundo seus gestores, múltiplos fatores relevantes, de modo aproximadamente “aleatório”, tenderiam a impactar o resultado de determinado mês como, por exemplo, ocorrência de greves, períodos de agitação política mais acentuada, copa do mundo e olimpíadas. De modo, a minimizar o impacto distorcido que uma previsão baseada apenas no último período e eventualmente afetada por alguma destas “atipicidades” adotou-se, na ausência de um critério técnico para decisão, subjetivamente a referida média.

Tendo em vista, as correções envolvidas com as variações dos níveis gerais de preço, relataram-se o acréscimo sistemático de 10% acima das médias calculadas, afim de que se obtivessem as previsões finais. Tal percentual possuiria a função de acomodar a inflação do ano anterior, sendo a eventual diferença em relação à inflação “efetivamente auferida”, uma meta de acréscimo real de faturamento.

Abaixo tabela com as previsões apresentadas pela empresa

Tabela 01 – Previsão venda mensal BSM Bag Store (log do faturamento total em R\$)

Mês	2015	2016	2017	2018
Jan.	10,354785	10,556851	10,685961	10,851408
Fev.	10,753469	10,782401	10,866539	10,921586
Mar	10,606534	10,932978	11,031894	11,263739
Abr	10,607311	10,712679	10,863811	11,075101
Mai	11,205726	11,487505	11,493937	11,750121
Jun	10,684485	10,850477	10,95477	
Jul	10,636366	10,694886	10,822604	
Ago	10,672617	10,757178	10,849984	
Set	10,74993	10,980037	11,112017	
Out	10,723625	10,954568	10,952871	
Nov	10,584006	10,772535	10,916819	
Dez	11,850635	11,936902	12,106576	

Fonte: Base de dados da empresa (2018).

3.3 APRESENTAÇÃO DOS DADOS

Os dados de vendas de bolsas foram disponibilizados pela empresa em consulta ao *software* de gestão, ou ERP (*Enterprise Resource Planning*), por ela utilizado. Contou-se ainda, com o auxílio do módulo de BI (*Business Intelligence*) para a extração de informações, uma vez em que este, integrado ao ERP, possibilita a organização dos dados em informações de modo customizado.

Consideraram-se para estudo, o histórico de vendas de bolsas mensais em valores monetários na forma logarítmica. O recorte temporal utilizado, por sua vez, refere-se ao período compreendido entre janeiro de 2012 e junho de 2018.

Embora as operações da organização tenham iniciado em dezembro de 2010, optou-se pela não utilização dos dados compreendidos entre a respectiva data e o mês de dezembro de 2011. A supressão dos dados referentes aos 13 primeiros meses de operação da empresa baseou-se nas informações fornecidas por seus gestores. Segundo estes, os dados de vendas referentes ao respectivo período, possuíam baixa confiabilidade uma vez em que:

- a) a empresa não possuía um *software* de gestão, cuja compilação dos dados de vendas realizava-se automaticamente na medida em que as mesmas ocorriam;
- b) não são claros, segundo seus gestores, os critérios em que os números disponíveis foram contabilizados na ocasião, isto é, se referem às vendas totais somadas ou subtraídas dos descontos concedidos aos clientes.

A Tabela 02 apresenta os dados de vendas de bolsas no período contemplado neste estudo pela BSM Bag Store:

Tabela 02- Venda mensal BSM Bag Store (log dos valores em R\$)

Mês	2012	2013	2014	2015	2016	2017	2018
Jan.	9,295	9,555	9,391	9,846	9,907	9,842	9,713
Fev.	9,947	9,773	9,607	10,026	10,003	9,757	9,737
Mar	9,473	9,650	9,804	10,363	9,919	10,437	10,274
Abr	9,683	9,556	9,691	9,970	9,968	10,267	10,214
Mai	9,993	10,461	10,107	10,762	10,478	10,806	10,677
Jun	9,746	9,860	9,534	10,199	10,144	10,293	
Jul	9,625	9,689	9,694	9,785	10,038	10,041	
Ago	9,683	9,697	9,727	9,914	9,951	10,124	
Set	9,444	9,814	10,060	10,071	10,174	9,982	
Out	9,541	9,824	9,881	10,171	9,819	10,232	
Nov	9,577	9,607	9,681	10,091	10,001	10,173	
Dez	10,717	10,574	11,030	10,952	11,036	11,103	

Fonte: Base de dados da empresa (2018).

3.3 APLICAÇÕES DAS TÉCNICAS DE PREVISÃO PROPOSTAS

Propondo-se, para fins de estimativas futuras de vendas, investigar abordagens estruturadas que apresentassem viabilidade e maior precisão (desempenho) em comparação aos obtidos atualmente pela empresa, conduziram-se aplicações das metodologias mencionadas no capítulo anterior.

Consideraram-se, portanto, como parâmetros de medida de qualidade das previsões obtidas em cada forma, a discrepância percentual absoluta média (DPAM) e também do coeficiente de desigualdade U de Theil como medida complementar.

3.3.1 Metodologia Box-Jenkins

A primeira modelagem de previsão proposta baseou-se na Metodologia Box-Jenkins para obtenção do modelo mais ajustado aos dados.

Utilizando-se o *software* R, desta vez através do comando *auto.arima*, cuja função encontra o modelo mais ajustado a partir de critérios de minimização definidos no algoritmo (AIC e BIC)⁴. Para os dados da amostra, o programa forneceu o modelo SARIMA (1,0,0)(1,1,0)[12].


Quanto a significância estatística do modelo estimado, o mesmo revelou apresentar resíduos normais, lineares e não auto correlacionados, porém estacionário somente como aproximadamente com 71% de confiança conforme resultados do apêndice C. Considerando ser este o modelo mais ajustado aos dados segundo o algoritmo *auto.arima* do *software* R, credenciou-se a preocupação em não maximização de probabilidade de se cometer erro tipo 2 neste aspecto considerando-se assim o modelo como apto a utilização de previsões.

Segundo a figura 02 abaixo, é possível observar que a perda de confiança para a rejeição da hipótese nula de não estacionaridade aparentemente está ligada ao comportamento dos resíduos nos anos de 2014-2015. Considerando o comportamento das vendas em t-1 e t-12 (estrutura do modelo estimado), contidos na tabela 02 acima, é possível observar uma quebra no padrão de tendência nestes períodos, o que se refletiu nas maiores dificuldades em termos de precisão das previsões de vendas.

⁴ Critério de informação de AKAIKE e critério de informação Bayesiano.

Quanto aos resíduos mais destacados parte deles pode encontrar uma explicação na generalização tanto no impacto das vendas observadas em $t-1$ quanto em $t-12$, uma vez que é razoável presumir que tal impacto apresenta relativas diferenças para cada um dos 12 meses do ciclo sazonal. Tal situação, porém, poderia ser mitigada com a utilização de modelos auto regressivos com defasagens distribuídas complementados com a exploração de variáveis dummy para cada um dos meses do ciclo sazonal. No entanto, isto exigiria a recomendável estimação de um modelo de regressão causal.

Figura 02 - Resíduos SARIMA



Fonte: Elaborado pelo próprio autor no *software* R. (2018).

Quanto a implicação do modelo estimado para a discussão proposta, o mesmo indica de forma marcante a já esperada sazonalidade nas vendas. A partir dos parâmetros estimados nota-se uma indicação da relação positiva entre as vendas do período imediatamente anterior e o atual, e negativa com o respectivo período sazonal anterior.

Tais resultados indicam uma relativa tendência de curto prazo nas vendas de bolsas, uma vez que se as vendas cresceram em t-1 também crescerão em t e se reduziram em t-1 também reduziram em t. No entanto, este comportamento parece estar associado a maturação acerca do tamanho de mercado ocupado pela empresa, uma vez que quanto maior foi a venda no período sazonal anterior menor será a venda no atual e quanto menor no período sazonal imediatamente anterior maior será no período atual. Sugerem os resultados deste modo, um aprofundamento da investigação dos possíveis fatores ligados a este comportamento.

As estimativas dos parâmetros corroboram para esta hipótese, na medida em que o coeficiente auto regressivo de primeira ordem é 0,3 e o coeficiente auto regressivo de primeira ordem sazonal é -0,6 conforme revelado no apêndice A.

Quanto ao ajuste do modelo estimado (Figura 03), objeto de investigação deste estudo, observou-se um erro percentual absoluto médio (MAPE) de 1,26%. Já em relação a comparação do modelo estimado com o que seria obtido pelo método ingênuo, verificou-se um U de Theil de 0,3232⁵. Isto pode ser interpretado como um erro tolerável tanto em comparação ao método ingênuo, quanto por parte da empresa (MAPE 7,7130%).

Figura 03 – Ajustado X Ocorrido Modelo SARIMA

⁵ Calculo disponível no apêndice 3



Fonte: Elaborado pelo próprio autor no *software* R (2018).

3.3.2 Previsão por suavização exponencial

Assim como feito com a estimação do modelo SARIMA, com auxílio do *software* R obteve-se o modelo de suavização exponencial mais aderente aos dados. Utilizando-se o comando *ets*, o algoritmo automaticamente mensurou as constantes de suavização que minimizaram os resíduos (critério de AIC e BIC) conforme mostra apêndice D.

O modelo encontrado pelo *software* foi do tipo (AAA), isto é, tendência, sazonalidade e erro aditivos, o que indica não significativa mudança de variabilidade nas vendas com a mudança de nível no período observado.

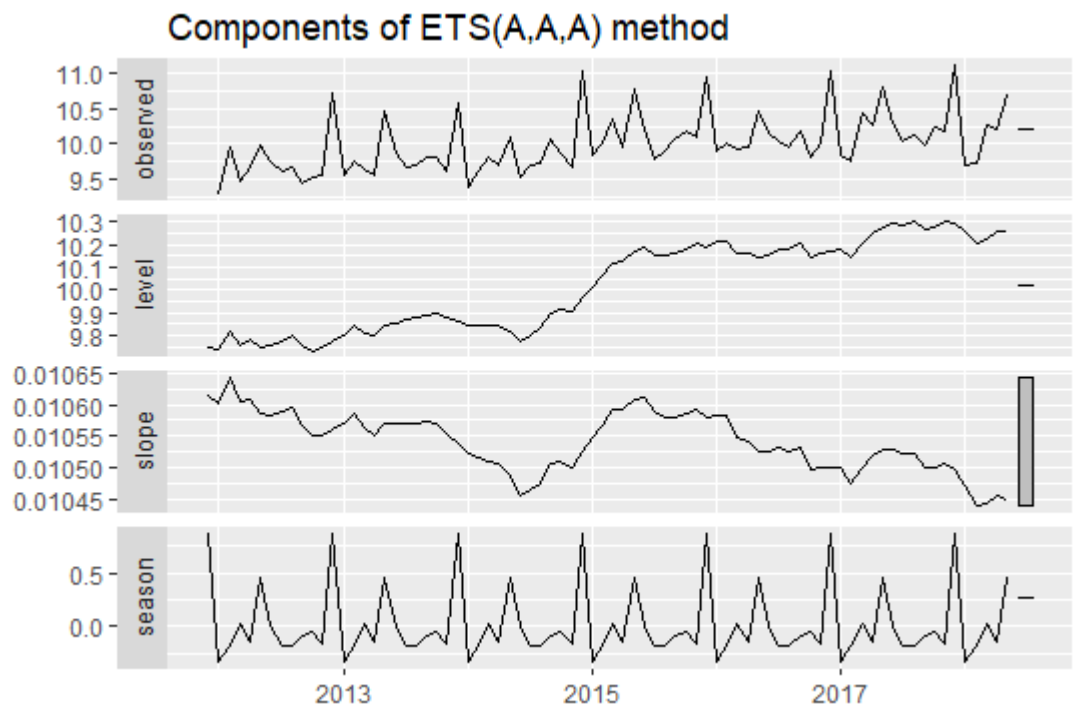
Isto revela, para este modelo, uma sutil, porém insignificante mudança de nível ($\alpha=0,18$ e $\beta=0,0001$), a mesma que provavelmente reduziu o grau de confiança para rejeição da hipótese nula de não-estacionaridade do modelo SARIMA.

A constante de suavização do nível sendo 0,18 significa uma relativa mudança de nível da serie ao longo da amostra, porém, mais baixa do que o usualmente observado (valores entre 0,3 e 0,4). Já a constante de suavização para o crescimento (β) ter se mostrado com valor muito próximo a zero, revela a relativa estabilidade nas diferenças entre níveis ao longo da amostra

Quanto a sazonalidade, assim como o esperado, e também corroborado pelo modelo Box Jenkins este componente se mostrou marcante ao longo de toda a série estudada ($\gamma=0,0001$)

O comportamento pode ser observado os comportamentos dos componentes da série a partir do gráfico na Figura 04.

Figura 4 – Componentes Modelo Suavização Exponencial




Fonte: Elaborado pelo próprio autor no *software R*

Como pode ser observado na figura acima, a já comentada quebra de padrão de tendência da série (nível + crescimento) ocorre a partir de 2014-2015 e se estabiliza a partir de então. No entanto, tais alterações não impactaram de maneira representativa a capacidade de projeção relativamente precisa das vendas de bolsas no período analisado ($\alpha=0,18$ e $\beta=0,0001$) o que foi corroborado pelos resultados em termos de desempenho do modelo acima (MAPE 1,21% e U de Theil de 0,3387), conforme pode ser observado no apêndice D.

Na Figura 04 é possível observar o comportamento do modelo de suavização estimado.

Figura 04 – Ajustado X ocorrido – Modelo de Suavização Exponencial



Fonte: Elaborado pelo próprio autor no *software R* (2018).

3.3.3 Combinação de Previsões

Oferecendo alternativa adicional, foram combinadas as metodologias e técnicas anteriormente expostas de modo a proporcionar resultados de previsão eventualmente superiores. Com auxílio do *software R* foi testada a combinação entre os métodos e técnicas estruturadas descritas que apresentaram melhor performance de previsão.

Foram, portanto, inicialmente comparados os desempenhos obtidos a partir da combinação por média simples entre os modelos Box Jenkins (0,5) e pela suavização exponencial (0,5). Os resultados em termos de erro percentual absoluto médio foram de 1,1233% e 0,2833 como U de Theil⁶.

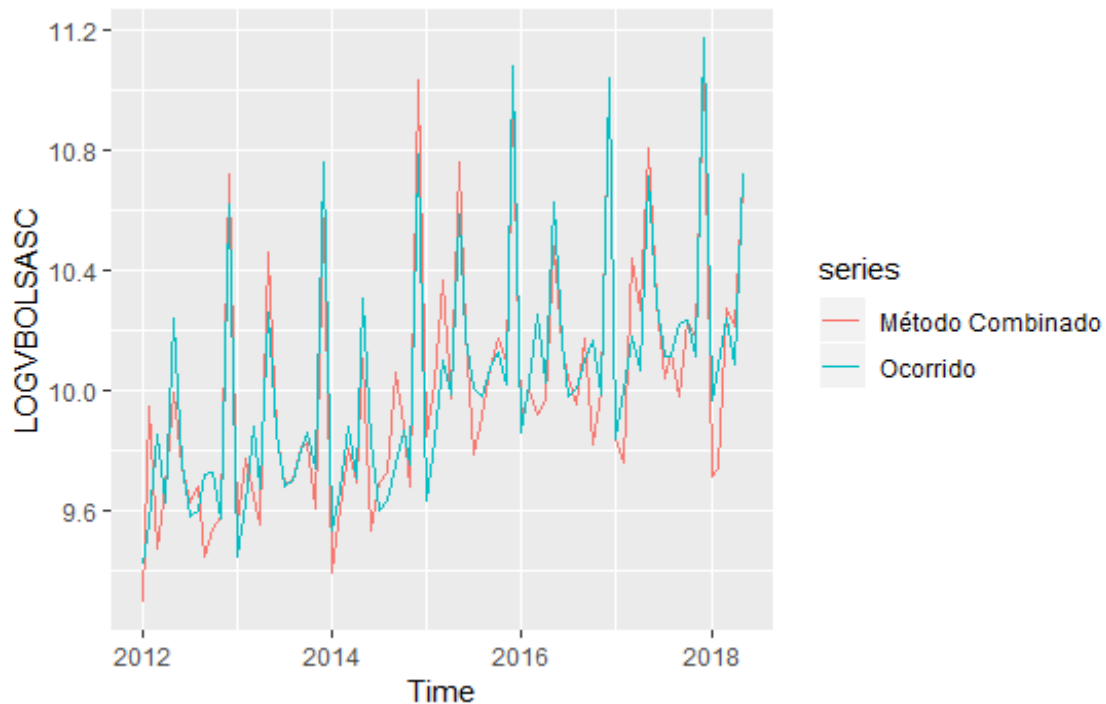
Quanto à segunda metodologia de combinação proposta, utilizando-se o critério de minimização do erro quadrático médio (MASE), configurou-se o referido aplicativo para a obtenção dos valores ponderativos entre as previsões da mostra que o minimizassem.

Observou-se a ponderação para o modelo de Suavização Exponencial (0,512) e SARIMA (0,488). Sendo a ponderação individual obtida apenas sutilmente diferente a de média simples (0,5), conseqüentemente notou-se também uma pequena melhora no desempenho em termos de MAPE (1,1233%) e U de Theil (0,2832).

⁶ Calculo disponível no apêndice 6

Abaixo a Figura 05 expressa o desempenho da combinação por pesos otimizados.

Figura 05 – Ajustado x Ocorrido - Previsão Combinada



Fonte: Elaborado pelo próprio autor (2018).

Detalhes sobre a condução das combinações simples e ponderas obtidas a partir do comando *ForecastHybrid* do *software* R estão disponibilizadas no apêndice 6 deste trabalho.

3.4 COMPARAÇÃO ENTRE RESULTADOS

Os desempenhos das técnicas e metodologias propostas para o presente estudo de caso foram compilados na Tabela 03. Nela estão contidas as comparações entre metodologias de previsão em termos de diferentes medidas de discrepância para as previsões obtidas.

No entanto, é necessário considerar que para efetiva comparação entre os desempenho das diferentes técnicas estruturadas (cientificamente elaboradas) e a empregada na empresa, seria necessário a construção de previsões um passo à frente exatamente como foram realizadas as projeções de demanda por parte da empresa.

Tabela 03 - Comparação de Resultados

Modelos e Métodos	Método Empresa⁷	Suavização Exponencial	SARIMA	Combinado Média Simples	Combinado Ponderado
MAPE (Amostral)	7,7130%	1,2148%	1,2671%	1,1239%	1,1233%
U de Theil (Amostral)	1,6100	0,3387	0,3232	0,2833	0,2832

Fonte: Elaborado pelo autor (2018).

Observando-se a Tabela 03, tratando-se de MAPE percebe-se superior desempenho para as metodologias Box Jenkins e Holt Winters, ainda que analisadas individualmente, em relação à abordagem utilizada pela empresa.

Corroborando com o resultado obtido por outros estudos, é também notável a relevância dos resultados obtidos pela combinação por média simples (MARTINS E WERNER, 2013; WONG et al. 2007). Percebe-se nesta metodologia de combinação uma *performance* muito próxima ao obtido pela combinação ponderada.

Deste modo, tratando-se da aplicabilidade das metodologias propostas para a empresa objeto deste estudo indica-se nítido potencial de ganho em termos de precisão com adoção destas técnicas. Ainda que avaliadas de modo isolado, ambas metodologias uni variadas utilizadas, além de oferecer precisão substancialmente maior do que o obtido pela empresa, torna possível a extração de informações relevantes em termos estratégicos tais como padrões de crescimento e sazonalidade.

⁷ Para previsões a partir de 2015.

4 CONSIDERAÇÕES FINAIS

Importantes características pertinentes às pequenas empresas brasileiras já se encontram catalogadas pela literatura. Muito embora, seja ampla a variedade de fatores que influenciam a estrutura das organizações, como capacitação profissional de seus colaboradores, setor de atuação, disponibilidade de capital, características regionais e conjunturas econômicas, verificam-se fatores comuns, recorrentemente observáveis nos pequenos negócios.

Tratando-se de aspectos gerenciais impactantes no desempenho da pequena empresa, de modo convergente, indica-se sua agilidade para a tomada de decisões como relevante característica atuante em prol de sua competitividade. De modo oposto, por sua vez, são também recorrentes as observações no sentido de apontar frequente fragilidade, ou mesmo ausência de estruturação técnica das heurísticas que orientam suas decisões.

Entende-se que a obtenção de previsões de vendas mais acuradas viabiliza o ganho de eficiência em diferentes departamentos organizacionais, tais como: compras; financeiro e marketing. Embora, torna-se clara a potencialidade quanto à adoção de técnicas capazes de minimizar os erros associados ao processo de previsão.

Neste contexto, sendo uma das representantes das pequenas empresas brasileiras, buscou-se sugerir para a BSM Bag Store alternativas disponíveis na literatura de previsão de demanda capazes de promover a diminuição de seus erros. Simultaneamente, fazendo parte do escopo deste estudo, a aplicabilidade das mencionadas sugestões, postas as características e os recursos disponíveis da empresa estudada, as quais são comuns a outras organizações do mesmo porte.

Deste modo, sugeriu-se neste estudo a utilização de métodos univariados como os mais indicados para a empresa em questão. Dada a maior praticidade e imediatismo na obtenção de previsões, além da mais elevada intuitividade no desenvolvimento dos processos e interpretação de seus resultados, principalmente em comparação a análises de regressão dinâmica e redes neurais artificiais demonstraram-se, mais indicados para o tempo e os recursos disponíveis que a empresa contempla. Dentre estas, as técnicas de Suavização Exponencial e Metodologia Box-Jenkins foram as empregadas.

Em termos de precisão de previsão, auferida e comparada através do erro percentual absoluto médio (MAPE) em cada uma das metodologias, demonstraram-se mais aderentes os

resultados obtidos pelas técnicas formalmente estabelecidas propostas neste estudo em relação à metodologia atualmente utilizada pela empresa.

Individualmente, os resultados das abordagens indicaram dentro da amostra um MAPE de 7,7% para o método utilizado pela empresa, enquanto que 1,21% para a suavização exponencial e 1,26% para a técnica Box-Jenkins.

Considerando, os modelos combinados obtidos pelo pacote *ForecastHybrid* do R, os resultados foram sensivelmente superiores em comparação as previsões oriundas de cada uma destas metodologias isoladamente. Comparativamente, combinações por média simples e ponderada entre si, apresentaram diferenças em seus resultados ainda mais sutis, mais especificamente 0,0006 p.p. de distância entre si.

Em uma otimizada ponderação, os pesos resultantes da combinação que minimizavam o MASE atribuíram 48,8% para o modelo SARIMA e 51,2% para o de Suavização Exponencial. Esta maior ponderação atribuída ao modelo SARIMA, mesmo o de Suavização tendo apresentado o menor MAPE, se deve ao fato da já mencionada semelhança do MASE e do U de Theil, medida esta cujo modelo Box-Jenkins apresentou desempenho mais preciso.

O trabalho obteve também os coeficientes obtidos através das técnicas aplicadas neste estudo de caso. Registrando na suavização exponencial ($\alpha = 0,42$, $\gamma = 1e-04$, $\beta = 1e-04$) e SARIMA ((1,0,0)(1,1,0)[12] ; ar1: 0,3113; sar1 -0,5931) demonstrou-se evidente o peso da sazonalidade no comportamento da série de dados analisada.

Em suma, conclui-se como confirmada há hipótese levantada no capítulo inicial deste trabalho. A partir do uso de técnicas estruturada, cuja utilização pela tecnologia hoje se tornou simplificada, inclusive com avanços em interfaces como no caso do *software* R, permitiu que se obtivessem resultados com menores discrepâncias em comparação aos obtidos com a metodologia antes adotada pela empresa.

Em complementariedade, especialmente tratando do modelo composto, sugere-se neste trabalho um periódico monitoramento dos erros, afim de que se controle a adesão do modelo proposto no decorrer do tempo, ou a sua respectiva necessidade de ajuste.

Sendo assim, percebe-se como viável a adoção de técnicas quantitativas estruturadas por parte da empresa objeto deste estudo ao mesmo tempo em que se sugere, também, como viáveis para outras empresa de pequeno porte. A partir da previa existência de um sistema de registro de dados de vendas, organizados em um Software ERP, em adição ao conhecimento das técnicas e metodologias exploradas neste trabalho, entende-se como factível e indicada a

adoção de metodologias quantitativas estruturadas como estas por parte de pequenas organizações.

Além das implicações operacionais diretas ligadas a extração de uma previsão mais precisas (como compras mais precisas que viabilizam menor mobilização de estoque) ganhos adjacentes podem ser obtidos.

Tal constatação baseia-se a partir das informações extraídas acerca do comportamento dos dados da série (crescimento, sazonalidade) os quais podem fornecer preciosos insights para os gestores desta e de outras empresas de pequeno porte do varejo brasileiro.

4.1 SUGESTÕES DE TRABALHOS FUTUROS

A literatura disponível acerca da previsão de vendas tornam vastas as possibilidades para a exploração e análise dos dados de séries temporais. Ao longo do desenvolvimento deste trabalho, algumas destas possibilidades tornaram-se especialmente promissoras, o que permite que sejam sugeridos estudos complementares:

- a) utilização de modelos causais, investigando e mensurando o impacto de variáveis potencialmente ligadas aos níveis de vendas como, por exemplo, o índice de atividade econômica, paridade cambial, nível de emprego, taxa de inflação entre diversos outros;
- b) investigação dos dados a partir de recortes temporais alternativos ao utilizado neste estudo (mensal) entre os quais: diário, semanal ou quinzenal;
- c) testar aderência dos dados a modelos preditivos construídos a partir de redes neurais;
- d) mensurar eventual eficiência obtida a partir de *inputs* qualitativos, oriundos dos colaboradores ligados ao planejamento da empresa, como forma de ajuste de previsões obtidas em técnicas estritamente quantitativas, como as que foram aqui discutidas.
- e) investigar performance dos modelos fora da amostra.
- f) testar o desempenho das metodologias propostas nas outras categorias de produtos comercializados pela empresa

REFERÊNCIAS

- ANGELO, F. C.; ZWICKER, R.; FOUTO, D. M. M. N.; LUPPE, R. M. **Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro**. Brazilian Business Review. v.8, n.2, Vitória-ES, abr-jun. 2011.
- ARMSTRONG, J. Scott; GREEN, Kesten C.; GRAEFE, Andreas. Forecasting Principles: Evidence-based Forecasting. 2010. Disponível em: <http://www.forecastingprinciples.com/index.php?option=com_content&task=view&id=3&Itemid=3#field_2> Acesso em: 13 mai. 2011.
- BATES, John M., and GRANGER, Clive WJ. **The combination of forecasts**. Operational Research Quarterly, 1969, p. 451-468.
- BOX, George EP; JENKINS, Gwilym M. **Time series analysis: forecasting and control, revised ed**. Holden-Day, 1976.
- BSM Bag Store. **Manual de compras da empresa**. Florianópolis, 2018
- BUNDCHEN, Cristiane; WERNER, Liane. **Comparação da acurácia de previsões de demanda turística em sedes olímpicas**. Revista Turismo em Análise, v. 27, n. 1, p. 85-107, 2016.
- CLEMEN, R. T.; WINKLER, R. L. **Combining economic forecasts**. Journal of Business and Economic Statistics, v. 4, p. 39-46, 1986.
- DRUCKER, P. **Prática de Administração de Empresas**. [s.l.] Cengage Learning Editores, 1981.
- GAITHER, N.; FRAZIER, G. **Administração da Produção e Operações**. São Paulo: Thomson Learning, 2004.
- GRANGER, Clive WJ; RAMANATHAN, Ramu. Improved methods of combining forecasts. **Journal of Forecasting**, v. 3, n. 2, p. 197-204, 1984.
- GUJARATI, D, N,; PORTER, D, C,; **Econometria básica**. 5ª edição. Porto Alegre: Mc Graw Hill, 2011. 923 p.
- GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria Básica-5**. Amgh Editora, 2011.
- HAGAN, M. T.; MENHAJ, M. B. **Training feedforward networks with the marquardt algorithm**. IEEE Transactions on Neural Networks, v. 5, n. 6, p. 989–993, Nov. 1994.
- HANKE, J.E.; REITSCH, A.G; WICHERN, D.W. **Business Forecasting**. 7 ed.

New Jersey: Prentice Hall, 2001.

HYNDMAN, Rob. **Business forecasting methods**. 2009 Disponível em: <<https://robhyndman.com/papers/businessforecasting.pdf>>. Acesso em: 10 out.2018.

HYNDMAN, Rob. Cross Validated. **Time series forecasting accuracy measure: MAPE and MASE**. 2014 Disponível em: <<https://stats.stackexchange.com/questions/116267/time-series-forecasting-accuracy-measures-mape-and-mase>>. Acesso em: 10 out. 2018

HYNDMAN, Rob J.; KOEHLER, Anne B. Another look at measures of forecast accuracy. **International journal of forecasting**, v. 22, n. 4, p. 679-688, 2006.

HYNDMAN, Rob.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. OTexts, 2018.

KUNZ, Timo P.; CRONE, Sven F. Demand models for the static retail price optimization problem-a revenue management perspective. In: OASICs-OpenAccess Series in Informatics. Schloss Dagstuhl-Leibniz-Zentrum fuer Informatik, 2014.

LOPES, Evandro, E. HERRERO, Eliane. "**Puxa Daqui e Estica de Lá**": Um Estudo Experimental sobre os Efeitos do Out-of-stock no Varejo" *11º Congresso Latino-Americano de Varejo: "Engaging and Interactive Shopper Experience"* (2017): n. pag. Web. 15 out. 2018

LUPPE, Marcos Roberto. A heurística da ancoragem e seus efeitos no julgamento: decisões de consumo. São Paulo, 2011. Tese de Doutorado. Dissertação de Mestrado. FEA/USP. Disponível em:< <http://www.teses.usp.br/teses/disponiveis/12/12139/tde-18102006-204007/pt-br.php>>. Acesso em: 17 out.

MAKRIDAKIS, Spyros; WINKLER, Robert L. **Averages of forecasts: Some empirical results**. Management Science, v. 29, n. 9, p. 987-996, 1983.

MARTINS, Vera Lúcia Milani; WERNER, Liane. **Comparação de previsões individuais e suas combinações: um estudo com séries industriais**. Produção, Porto Alegre, v. 24, n. 3, p. 618-627, 2013.

MOREIRA, Erika Santana; TAVARES, Marcelo; DE CARVALHO, Claudinê Jordão. Adequação de Escala Multiitens para Avaliar a Aplicação do Planejamento Estratégico em Micro e Pequenas Empresas. RAC-Eletrônica, v. 3, n. 1, 2009.

PASSARI, Antonio Fabrizio Lima. Exploração de dados atomizados para previsão de vendas no varejo utilizando redes neurais. 2003. Tese de Doutorado. Universidade de São Paulo.

PITTA, R. **Combinação de métodos de previsão: Um estudo aplicado à demanda doméstica Brasileira entre 2004 e 2009**. Monografia (Graduação em Ciências Econômicas) – Universidade Federal de Santa Catarina, 2013.

PRODANOV, C. C.; DE FREITAS, E. C. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico**. 2ª ed. Feevale, 2013.

SACRAMENTO, S. L. I. **Redução dimensional dos dados de entrada em previsões de consumo industrial de energia no longo prazo.** Dissertação (Mestrado em Ciência da Computação) – Universidade Federal de Santa Catarina, 2014.

SAMOHYL, Robert Wayne; SOUZA, Gueibi Peres; DE MIRANDA, Rodrigo Gabriel. **Métodos simplificados de previsão empresarial.** Ciência Moderna, 2008.

SAUER, L. **A visão das associações comerciais e industriais de Santa Catarina sobre os fatores de sucesso de pequenas e médias empresas.** Universidade Federal de Santa Catarina, 1996.

SEMLER, R. **Virando a própria mesa.** 25ª ed. São Paulo: Best Seller, 1989.

SILVA, S. P. M.; HESPANHOL, M. R.; LEMOS, K. F. Previsão de demanda aplicada à compra de produtos para revenda no pequeno varejo de calçados. **XXIII Simpósio de Engenharia de produção.** Gestão de Operações em serviços e seus Impactos Sociais. Bauru, SP, 2016.

SMITH, Adam. **A riqueza das nações.** Nova Fronteira, 1996.

SOUZA, P. G. **Previsão do consumo industrial de energia elétrica no estado de Santa Catarina:** Uma aplicação da combinação de previsões entre modelos univariados e de regressão dinâmica. Dissertação [Programa de Pós Graduação em Engenharia de Produção], Departamento de Engenharia de Produção e Sistemas. Universidade Federal de Santa Catarina, 2005.

SOUZA, M. C. A. F.; COELHO, J. M. A importância do planejamento estratégico para as empresas de pequeno porte. **VI Congresso Brasileiro de Custos**, p. 1–13, 1999. Disponível em: <<https://anaiscbc.emnuvens.com.br/anais/article/view/3206>>. Acesso em: 10 out. 2018.

WHEELWRIGHT, Steven C. et al. **Forecasting methods for management.** 1973.

WONG, Kevin KF et al. **Tourism forecasting:** To combine or not to combine?. *Tourism management*, v. 28, n. 4, p. 1068-1078, 2007.

ANEXO A –Técnicas de Previsão Hanke et al. (2001)

TABLE 3.6 Choosing a Forecasting Technique

Method	Pattern of Data	Time Horizon	Type of Model	Minimal Data Requirements	
				Nonseasonal	Seasonal
Naive	ST, T, S	S	TS	1	
Simple averages	ST	S	TS	30	
Moving averages	ST	S	TS	4–20	
Exponential smoothing	ST	S	TS	2	
Linear exponential smoothing	T	S	TS	3	
Quadratic exponential smoothing	T	S	TS	4	
Seasonal exponential smoothing	S	S	TS		2 × s
Adaptive filtering	S	S	TS		5 × s
Simple regression	T	I	C	10	
Multiple regression	C, S	I	C	10 × V	
Classical decomposition	S	S	TS		5 × s
Exponential trend models	T	I, L	TS	10	
S-curve fitting	T	I, L	TS	10	
Gompertz models	T	I, L	TS	10	
Growth curves	T	I, L	TS	10	
Census X-12	S	S	TS		6 × s
Box-Jenkins	ST, T, C, S	S	TS	24	3 × s
Leading indicators	C	S	C	24	
Econometric models	C	S	C	30	
Time series multiple regression	T, S	I, L	C		6 × s

Pattern of the data: ST, stationary; T, trended; S, seasonal; C, cyclical.

Time horizon: S, short term (less than three months); I, intermediate; L, long term.

Type of model: TS, time series; C, causal.

Seasonal: s, length of seasonality.

Variable: V, number of variables.

APÊNDICE A – MODELO SARIMA

```

> summary(auto.arima(log(VBOLSASC)))
Series: log(VBOLSASC)
ARIMA(1,0,0)(1,1,0)[12] with drift

Coefficients:
      ar1      sar1      drift
      0.3113 -0.5931  0.0078
s.e.    0.1168  0.0953  0.0019


sigma^2 estimated as 0.03542:  log likelihood=15.23
AIC=-22.46  AICc=-21.79  BIC=-13.76

Training set error measures:
MASE      ACF1      ME      RMSE      MAE      MPE      MAPE
Training set 0.002345845 0.1688896 0.1267821 0.004912256 1.267125 0.
6152367 -0.04717232

```

APÊNDICE B – PREVISÃO AJUSTADA SARIMA

```
autoplot(fitted(auto.arima(log(VBOLSASC))))
```



APÊNDICE C – TESTES DE ESPECIFICAÇÃO SARIMA

```
> white.test(residuals(auto.arima(log(VBOLSASC)))) #Linearidade#  
  
White Neural Network Test  
  
data: residuals(auto.arima(log(VBOLSASC)))  
X-squared = 3.6634, df = 2, p-value = 0.1601  
  
> adf.test(residuals(auto.arima(log(VBOLSASC)))) #  
  
Augmented Dickey-Fuller Test  
  
data: residuals(auto.arima(log(VBOLSASC)))  
Dickey-Fuller = -2.7183, Lag order = 4, p-value = 0.2822  
alternative hypothesis: stationary  
  
> Box.test(residuals(auto.arima(log(VBOLSASC))))  
  
Box-Pierce test  
  
data: residuals(auto.arima(log(VBOLSASC)))  
X-squared = 0.17134, df = 1, p-value = 0.6789  
  
> jarque.bera.test(residuals(auto.arima(log(VBOLSASC))))  
  
Jarque Bera Test  
  
data: residuals(auto.arima(log(VBOLSASC)))  
X-squared = 0.018134, df = 2, p-value = 0.991
```

APÊNDICE D – MODELO ETS

```

> summary(ets(log(VBOLSASC), allow.multiplicative.trend = TRUE, opt.crit =
c("mae")))
ETS(A,A,A)

Call:
ets(y = log(VBOLSASC), opt.crit = c("mae"), allow.multiplicative.trend = T
RUE)

Smoothing parameters:
alpha = 0.1845
beta  = 1e-04
gamma = 1e-04

Initial states:
l = 9.7501
b = 0.0106
s = 0.8658 -0.17 -0.0436 -0.0887 -0.1823 -0.1852
      0.0024 0.4508 -0.1459 0.0261 -0.1903 -0.3391

sigma: 0.1817

      AIC      AICC      BIC
87.90896 98.28184 127.75365

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE      MASE
ACF1
Training set -0.02131675 0.1617272 0.1209729 -0.2353321 1.214893 0.5870461
0.06153108

```

APÊNDICE E - COMBINAÇÃO SIMPLES

```

hybridModel(y = LOGVBOLSASC, models = "ae", e.args = list(allow.multiplicative.trend = TRUE,opt.crit = c("mae")))
Fitting the auto.arima model
Fitting the ets model
Hybrid forecast model comprised of the following models: auto.arima,
ets
#####
auto.arima with weight 0.5
#####
ets with weight 0.5
accuracy(hybridModel(y = LOGVBOLSASC, models = "ae", e.args = list(allow.multiplicative.trend = TRUE,opt.crit = c("mae"))))
Fitting the auto.arima model
Fitting the ets model

```

	ME	RMSE	MAE	MPE	MAPE	ACF1	Th
eil's U							
Test set	-0.009485454	0.1482877	0.1123185	-0.1152099	1.123926	0.06399541	0.2833607

APÊNDICE F - COMBINAÇÃO PONDERADA

```

> hybridModel(y = LOGVBOLSASC, models = "ae", e.args = list(allow.mu
multiplicative.trend = TRUE,opt.crit = c("mae")), weights = c("insample.error
s"), errorMethod = c("MASE"))
  Fitting the auto.arima model
  Fitting the ets model
Hybrid forecast model comprised of the following models: auto.arima,
ets
#####
auto.arima with weight 0.488
#####
ets with weight 0.512
accuracy(hybridModel(y = LOGVBOLSASC, models = "ae", e.args = list(allow.mu
multiplicative.trend = TRUE,opt.crit = c("mae")), weights = c("insample.error
s"), errorMethod = c("MASE")))
Fitting the auto.arima model
Fitting the ets model

```

	ME	RMSE	MAE	MPE	MAPE	ACF1	Thei
1's U							
Test set	-0.00976287	0.148204	0.1122513	-0.1180265	1.123318	0.06562037	0.28
32099							

APÊNDICE G – CÁLCULO U DE THEIL

U de Theil - SARIMA			
a	b	a-b ²	b ²
0,06916126	0,07022979	0,00000114	0,00493222
-0,04865224	-0,04770224	0,00000090	0,00227550
0,02112290	0,02214181	0,00000104	0,00049026
0,03103853	0,03206663	0,00000106	0,00102827
-0,02565520	-0,02468457	0,00000094	0,00060933
-0,01342249	-0,01244051	0,00000096	0,00015477
0,00501353	0,00601309	0,00000100	0,00003616
-0,02567406	-0,02470600	0,00000094	0,00061039
0,00932377	0,01032591	0,00000100	0,00010662
0,00273241	0,00372723	0,00000099	0,00001389
0,11790804	0,11901729	0,00000123	0,01416512
-0,12035703	-0,10842116	0,00014247	0,01175515
0,04975989	0,02287867	0,00072260	0,00052343
-0,02641115	-0,01265987	0,00018910	0,00016027
0,01078508	-0,00974288	0,00042140	0,00009492
0,05738205	0,09472421	0,00139444	0,00897268
-0,05005171	-0,05748237	0,00005521	0,00330422
-0,01440080	-0,01725948	0,00000817	0,00029789
0,00659974	0,00083130	0,00003327	0,00000069
-0,01308314	0,01206559	0,00063246	0,00014558
-0,00771687	0,00097706	0,00007558	0,00000095
-0,01280403	-0,02207874	0,00008602	0,00048747
0,11671229	0,10060888	0,00025932	0,01012215
-0,10117885	-0,11186398	0,00011417	0,01251355
0,06227359	0,02299644	0,00154269	0,00052884
-0,00457210	0,02055961	0,00063160	0,00042270
0,00096760	-0,01158796	0,00015764	0,00013428
0,06329432	0,04296873	0,00041313	0,00184631
-0,02338579	-0,05674997	0,00111317	0,00322056
0,01460259	0,01680256	0,00000484	0,00028233
0,01139311	0,00339763	0,00006393	0,00001154
-0,00187404	0,03424389	0,00130451	0,00117264
-0,01555971	-0,01777851	0,00000492	0,00031608
-0,01211830	-0,02018433	0,00006506	0,00040741
0,11442951	0,13924175	0,00061565	0,01938827
-0,12002957	-0,10732739	0,00016135	0,01151917
0,00744204	0,01834079	0,00011878	0,00033638
-0,01115338	0,03360001	0,00200287	0,00112896
-0,04322985	-0,03794080	0,00002797	0,00143950
0,05625055	0,07939904	0,00053585	0,00630421
-0,07380448	-0,05226515	0,00046394	0,00273165
-0,02539082	-0,04062643	0,00023212	0,00165051
0,00569305	0,01317315	0,00005595	0,00017353

U de Theil - ETS			
a	b	a-b ²	b ²
0,38949438	0,92083715	0,28232514	0,84794106
0,02426995	-0,37781238	0,16167020	0,14274219
0,19658640	0,23336596	0,00135274	0,05445967
0,71326130	0,36409296	0,12191853	0,13256369
-0,29100624	-0,21860626	0,00524176	0,04778870
-0,18652208	-0,11418833	0,00523217	0,01303898
-0,04193591	0,05958490	0,01030647	0,00355036
0,06375518	-0,21276639	0,07646418	0,04526954
0,16404897	0,10242951	0,00379696	0,01049180
-0,04714965	0,03620280	0,00694763	0,00131064
1,52881383	2,12620652	0,35687803	4,52075418
-0,71175512	-0,68711591	0,00060709	0,47212828
0,11731212	0,24433562	0,01613497	0,05969990
0,14672548	-0,11638191	0,06922550	0,01354475
0,02155103	-0,08973169	0,01238385	0,00805178
0,86597100	1,47231392	0,36765174	2,16770829
-0,46943881	-0,45190891	0,00030730	0,20422166
-0,15647977	-0,15647881	0,00000000	0,02448562
0,00537149	0,00808732	0,00000738	0,00006540
0,12412515	0,12412499	0,00000000	0,01540701
-0,03187645	0,00963544	0,00172324	0,00009284
-0,09873856	-0,19499086	0,00926451	0,03802143
1,83446689	1,62888464	0,04226406	2,65326517
-0,66149821	-0,69358404	0,00102950	0,48105883
0,24104775	0,24104792	0,00000000	0,05810410
0,21834958	0,21836785	0,00000000	0,04768452
-0,12805161	-0,10739579	0,00042666	0,01153386
0,72000701	0,51648820	0,04141990	0,26676006
-0,33435792	-0,43649428	0,01043184	0,19052726
-0,05089260	0,17373110	0,05045580	0,03018249
-0,10549532	0,03348406	0,01931527	0,00112118
0,03863004	0,39525651	0,12718244	0,15622771
-0,17446068	-0,16376614	0,00011437	0,02681935
-0,08368528	-0,18080977	0,00943317	0,03269217
1,83294198	2,84995226	1,03430991	8,12222788
-0,72539834	-0,69387677	0,00099361	0,48146497
0,10099061	0,19791021	0,00939341	0,03916845
0,16154907	0,40057683	0,05713427	0,16046180
-0,21379050	-0,32509810	0,01238938	0,10568878
0,90889062	1,20694478	0,08883628	1,45671570
-0,43022284	-0,43019297	0,00000000	0,18506599
-0,14063597	-0,33923397	0,03944116	0,11507968
0,17948155	0,13757266	0,00175636	0,01892624

0,01676474	0,01590874	0,00000073	0,00025309
-0,00727752	0,00990890	0,00029537	0,00009819
-0,03253659	-0,00787636	0,00060813	0,00006204
0,09031102	0,08531537	0,00002496	0,00727871
-0,11084692	-0,09542331	0,00023789	0,00910561
0,00763507	0,00968519	0,00000420	0,00009380
0,02009753	-0,00834032	0,00080871	0,00006956
-0,00484120	0,00487838	0,00009447	0,00002380
0,05603026	0,05121657	0,00002317	0,00262314
-0,05146757	-0,03191542	0,00038229	0,00101859
-0,02025075	-0,01047768	0,00009551	0,00010978
-0,00371946	-0,00868321	0,00002464	0,00007540
0,02633095	0,02249575	0,00001471	0,00050606
-0,00384287	-0,03489009	0,00096393	0,00121732
0,00762489	0,01845609	0,00011732	0,00034063
0,11468142	0,10357431	0,00012337	0,01072764
-0,09529923	-0,10821818	0,00016690	0,01171117
0,02721621	-0,00865018	0,00128640	0,00007483
0,04579948	0,06966204	0,00056942	0,00485280
-0,02743986	-0,01625720	0,00012505	0,00026430
0,05592458	0,05248256	0,00001185	0,00275442
-0,04418161	-0,04741350	0,00001045	0,00224804
-0,02597419	-0,02454056	0,00000206	0,00060224
0,00374052	0,00826843	0,00002050	0,00006837
0,01503824	-0,01396680	0,00084129	0,00019507
0,01070878	0,02501311	0,00020461	0,00062566
-0,00120184	-0,00577302	0,00002090	0,00003333
0,09361005	0,09138192	0,00000496	0,00835065
-0,09762535	-0,12520750	0,00076078	0,01567692
0,02470919	0,00252565	0,00049211	0,00000638
0,04552105	0,05515872	0,00009288	0,00304248
-0,00366666	-0,00581781	0,00000463	0,00003385
0,05267967	0,04531811	0,00005419	0,00205373

Total	Total
0,0221	0,2120
U de Theil	0,323223

0,14979552	0,17083191	0,00044253	0,02918354
-0,04192862	0,10494618	0,02157221	0,01101370
-0,14759866	-0,07698711	0,00498599	0,00592702
1,53500506	1,36534998	0,02878285	1,86418056
-0,66271626	-0,64833583	0,00020680	0,42033935
0,14285509	0,10070478	0,00177665	0,01014145
0,24524897	-0,08004206	0,10581425	0,00640673
0,04958112	0,04958094	0,00000000	0,00245827
0,74328062	0,66615685	0,00594808	0,44376494
-0,36567085	-0,28424832	0,00662963	0,08079711
-0,19696248	-0,10083177	0,00924111	0,01016705
-0,05655206	-0,08346889	0,00072452	0,00696706
0,14495406	0,25087622	0,01121951	0,06293888
-0,07912963	-0,29881558	0,04826191	0,08929075
0,08975128	0,19868762	0,01186712	0,03947677
1,51299418	1,81737468	0,09264749	3,30285074
-0,69626319	-0,69709618	0,00000069	0,48594309
0,17227960	-0,08161229	0,06446109	0,00666057
0,41241602	0,97326164	0,31454781	0,94723822
-0,27085410	-0,15605694	0,01317839	0,02435377
0,60663303	0,71401037	0,01152989	0,50981081
-0,40444325	-0,40090802	0,00001250	0,16072724
-0,14355373	-0,22322682	0,00634780	0,04983021
0,06478922	0,08656563	0,00047421	0,00749361
0,11291269	-0,13185623	0,05991183	0,01738606
0,12535118	0,28363056	0,02505236	0,08044630
-0,14245812	-0,05735962	0,00724175	0,00329013
1,51392082	1,53358680	0,00038675	2,35188847
-0,67755207	-0,75096055	0,00538880	0,56394175
0,36919277	0,02483393	0,11858301	0,00061672
0,45432314	0,71101434	0,06589037	0,50554139
-0,20344687	-0,05802195	0,02114841	0,00336655
0,58817741	0,58867164	0,00000024	0,34653430

Total	Total
4,1200	35,9151
U de Theil	0,338698