

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
DEPARTAMENTO DE CIÊNCIAS ADMINISTRATIVAS  
ESCOLA DE ADMINISTRAÇÃO

ANDERSON FERNANDES BINS

**COMPARAÇÃO ENTRE REDES NEURAS ARTIFICIAIS E MÉTODOS  
TRADICIONAIS DE PREVISÃO DE DEMANDA POR SÉRIES TEMPORAIS COM  
ENFOQUE EM TOMADORES DE DECISÃO**

Porto Alegre

2017

ANDERSON FERNANDES BINS

**COMPARAÇÃO ENTRE REDES NEURAIS ARTIFICIAIS E MÉTODOS  
TRADICIONAIS DE PREVISÃO DE DEMANDA POR SÉRIES TEMPORAIS COM  
ENFOQUE EM TOMADORES DE DECISÃO**

Trabalho de conclusão de curso de graduação, apresentado ao Departamento de Ciências Administrativas da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Bacharel em Administração.

Professor Orientador: Prof. Dr. Antônio Domingos Padula

Porto Alegre

2017

ANDERSON FERNANDES BINS

**COMPARAÇÃO ENTRE REDES NEURAIS ARTIFICIAIS E MÉTODOS  
TRADICIONAIS DE PREVISÃO DE DEMANDA POR SÉRIES TEMPORAIS COM  
ENFOQUE EM TOMADORES DE DECISÃO**

Trabalho de conclusão de curso de graduação, apresentado ao Departamento de Ciências Administrativas da Universidade Federal do Rio Grande do Sul, como requisito parcial para a obtenção do grau de Bacharel em Administração.

Aprovado em 6 de dezembro de 2017

BANCA EXAMINADORA

---

Profa. Dra. Fernanda Maciel Reichert – UFRGS

---

Prof. Dr. Antônio Domingos Padula (Orientador) - UFRGS

Porto Alegre  
2017

## **AGRADECIMENTOS**

Agradeço aos meus pais por me ensinarem a ser resiliente, pois a cada vez que falhamos estamos um passo mais próximos do sucesso.

Agradeço aos meus demais familiares por me darem esperança, mostrando que tudo vai dar certo no final.

Agradeço aos meus amigos por tornarem a minha vida mais leve e divertida, mesmo quando passei por momentos difíceis.

Agradeço aos meus professores por me mostrarem o caminho, tornando-me a cada dia melhor naquilo que faço.

Agradeço aos meus técnicos de tênis da SGNH por terem me treinado para fazer o meu melhor sempre, mesmo que os resultados não viessem.

If you always do what you've always done, you'll always get what you've always got.

*Autor desconhecido*

## LISTA DE QUADROS

Quadro 1 - Comparação entre métodos quantitativos e qualitativos de previsão – 2015.....	23
Quadro 2 - Classes de métodos e métodos de previsão de demanda por séries temporais – 2017.....	29
Quadro 3 – Comparação entre as classes de métodos quantitativos de previsão de demanda baseados em séries temporais – 2017.....	51
Quadro 4 - Detalhamento das séries temporais obtidas – 2017.....	54
Quadro 5 – Softwares e funções utilizados para a obtenção de previsões – 2017.....	55
Quadro 6 – Avaliação dos métodos de previsão de demanda baseados em séries temporais quanto à facilidade de aplicação – 2017.....	58
Quadro 7 – Justificativas das avaliações negativas dos métodos de previsão de demanda baseados em séries temporais quanto a critérios de facilidade de aplicação – 2017.....	59
Quadro 8 – Resultados da avaliação dos métodos de previsão de demanda baseados em séries temporais quanto a critérios de facilidade de aplicação – 2017.....	60
Quadro 9 – MAPE segregado por período projetado adiante – 2017.....	61
Quadro 10 – MAPE segregado por empresa analisada..... – 2017.....	62
Quadro 11 – MAPEMAX segregado por período projetado adiante – 2017.....	70
Quadro 12 – MAPEMAX segregado por empresa analisada – 2017.....	71
Quadro 13 – Precisão geral dos métodos – 2017.....	72
Quadro 14 – Ranking de precisão geral dos métodos de previsão – 2017.....	73

## LISTA DE GRÁFICOS

Gráfico 1 – Série Temporal da Empresa A – 2017.....	64
Gráfico 2 – Séries Temporais da Empresa B – 2017.....	65
Gráfico 3 – Séries Temporais da Empresa C – 2017.....	66
Gráfico 4 – Série Temporal da Empresa D – 2017.....	67
Gráfico 5 – Séries Temporais da Empresa E – 2017.....	68

## RESUMO

Previsões de demanda são relevantes aos tomadores de decisão, pois viabilizam o planejamento estratégico e operacional de suas organizações. Existem diversos métodos quantitativos de previsão de demanda, os quais se diferenciam em termos de precisão e facilidade de aplicação. Este trabalho de monografia tem como objetivo comparar estes métodos entre si e determinar qual deles gera o resultado mais preciso de forma fácil, na perspectiva de tomadores de decisão que não possuam conhecimento técnico em previsão de demanda. Sendo assim, foram obtidas previsões a partir da aplicação de 15 métodos de previsão de demanda em 31 séries temporais reais, contendo 36 períodos cada, provenientes de cinco empresas distintas. Após a análise, percebeu-se que somente dois métodos de previsão de demanda, ARMA e Suavização Exponencial Simples, possuem precisão superior ao método ingênuo quando aplicados automaticamente. Assim, os outros 12 métodos de previsão de demanda, incluindo as redes neurais artificiais, não se mostraram úteis aos tomadores de decisão neste contexto. Adicionalmente, demonstrou-se que a comparação entre os erros das previsões por meio do MAPE não é eficaz para séries temporais que decrescem acentuadamente. Foi proposto o MAPEMAX, mensuração de erro desenvolvida pelo autor, como forma de solucionar esta imprecisão.

**Palavras-chave:** Previsão de Demanda. ARMA. Suavização Exponencial. Redes Neurais Artificiais. MAPE.



## ABSTRACT

Demand forecasts are relevant to decision makers as they enable the strategic and operational planning of their organizations. There are several quantitative methods of demand forecasting, which differ in terms of accuracy and ease of application. This study aims at comparing these methods among each other and determining which of them generates the most accurate result in an easy way, from the perspective of decision makers who do not have technical knowledge in demand forecasting. Thus, forecasts were obtained from the application of 15 methods of demand forecasting in 31 real time series, containing 36 periods each, from five different companies. After the analysis, it was noticed that only two methods of demand forecasting, ARMA and Simple Exponential Smoothing, have superior precision to the naive method when applied automatically. Thus, the other 12 demand forecasting methods, including artificial neural networks, have not proved themselves useful to decision makers in this context. Additionally, it has been shown that the comparison of forecast errors through MAPE is not effective for time series which decrease sharply. MAPEMAX, an error measurement method developed by the author, has been proposed as a way of solving this imprecision.

**Keywords: Demand Forecast. ARMA. Exponential Smoothing. ANN. MAPE.**

## SUMÁRIO

<b>1</b>	<b>DEFINIÇÃO DO TEMA DE ESTUDO .....</b>	<b>13</b>
1.1	OBJETIVOS .....	18
1.1.1	Objetivo Geral.....	18
1.1.2	Objetivos Específicos.....	18
<b>2</b>	<b>JUSTIFICATIVA .....</b>	<b>19</b>
<b>3</b>	<b>REFERENCIAL TEÓRICO .....</b>	<b>20</b>
3.1	PREVISÃO .....	20
3.1.1	Previsão de Demanda.....	21
3.2	MÉTODOS DE PREVISÃO DE DEMANDA .....	22
3.2.1	Métodos Quantitativos .....	24
3.3	SÉRIES TEMPORAIS .....	24
3.3.1	Componentes dos Métodos de Séries Temporais.....	25
3.4	SELEÇÃO DOS MÉTODOS DE SÉRIES TEMPORAIS.....	25
3.4.1	Definição de Critérios de Facilidade de Aplicação.....	27
3.5	MÉTODOS DE SÉRIES TEMPORAIS .....	28
3.5.1	Método Ingênuo (INGÊNUO) .....	29
3.5.2	Classe de Métodos de Decomposição.....	30
3.5.3	Classe de Métodos de Suavização Exponencial .....	32
3.5.4	Classe de Métodos Auto-Regressivos Integrados .....	35
3.5.5	Classe de Métodos de Redes Neurais Univariadas Automáticas .....	42
3.6	EVOLUÇÃO CRONOLÓGICA DOS MÉTODOS DE PREVISÃO.....	47
3.6.1	Método Ingênuo.....	48
3.6.2	Classe de Métodos de Decomposição.....	48
3.6.3	Classe de Métodos de Suavização Exponencial .....	49
3.6.4	Classe de Métodos Auto-Regressivos Integrados .....	49
3.6.5	Classe de Métodos de Redes Neurais Artificiais.....	50

3.7	COMPARAÇÃO ENTRE AS CLASSES DE MÉTODOS .....	50
<b>4</b>	<b>PROCEDIMENTOS METODOLÓGICOS .....</b>	<b>52</b>
4.1	ESTUDO BIBLIOGRÁFICO DOS MÉTODOS DE PREVISÃO.....	52
4.2	COLETA DE DADOS .....	52
4.3	LIMPEZA DOS DADOS.....	53
4.4	OBTENÇÃO DOS SOFTWARES PARA REALIZAR ANÁLISES .....	54
4.5	APLICAÇÃO DOS MÉTODOS DE PREVISÃO.....	56
4.6	OBTENÇÃO DOS RESULTADOS .....	56
4.7	ANÁLISE DOS RESULTADOS .....	57
<b>5</b>	<b>RESULTADOS .....</b>	<b>58</b>
5.1	FACILIDADE DE APLICAÇÃO DOS MÉTODOS .....	58
	5.1.1 Avaliação da Facilidade de Aplicação dos Métodos .....	58
	5.1.2 Justificativas das Avaliações Negativas da Facilidade de Aplicação dos	59
<b>Métodos</b>		
	5.1.3 Resultados da Avaliação da Facilidade de Aplicação dos Métodos .....	60
5.2	PRECISÃO DOS MÉTODOS .....	61
	5.2.1 MAPE Segregado por Período Projetado Adiante .....	61
	5.2.2 MAPE Segregado por Empresa Analisada .....	62
	5.2.3 Análise Gráfica das Séries Temporais.....	63
	5.2.4 Alternativa ao MAPE para Análise da Precisão dos Métodos .....	69
	5.2.5 MAPEMAX Segregado por Período Projetado Adiante .....	70
	5.2.6 MAPEMAX Segregado por Empresa Analisada .....	71
	5.2.7 Precisão Geral dos Métodos.....	72
5.3	ESCOLHA DO MELHOR MÉTODO .....	74
5.4	COMPARAÇÃO COM RESULTADOS OBTIDOS POR OUTROS	
<b>AUTORES</b>		<b>74</b>

<b>6 CONCLUSÕES EM IMPLICAÇÕES GERENCIAIS E METODOLÓGICAS .....</b>	<b>76</b>
6.1 CONCLUSÕES E PRINCIPAIS RESULTADOS DA PESQUISA .....	76
6.2 PRINCIPAIS LIMITAÇÕES DA PESQUISA .....	77
6.3 HIPÓTESES PARA ESTUDOS FUTUROS.....	78
<b>REFERÊNCIAS.....</b>	<b>81</b>

## 1 DEFINIÇÃO DO TEMA DE ESTUDO

Diuturnamente, gestores precisam tomar decisões importantes, e a grande parte delas refere-se a eventos futuros. Embora seja impossível conhecer o futuro em sua totalidade, os gestores podem tentar entender, ainda que com certa margem de erro, alguns acontecimentos que ocorrerão dentro de certo período de tempo. Ao passo que alguns acontecimentos posteriores podem ser conhecidos antecipadamente com um maior grau de certeza, como o nascer do sol; outros são quase totalmente desconhecidos (MAKRIDAKIS, 1985).

Os gestores procuram compreender melhor o futuro para aumentar a chance de sucesso em suas decisões. Ao fundamentarem seu juízo em acontecimentos plausíveis, com probabilidade de ocorrência, suas chances de desenvolverem planos que venham a gerar os resultados esperados aumentam. O conhecimento de quais acontecimentos provavelmente ocorrerão pode ser obtido por intermédio de previsões (MAKRIDAKIS, 1990).

Previsões podem ser consideradas antecipações de ocorrências de eventos, compreendidos antes de se concretizarem. Elas providenciam informações que permitem a empresas planejarem e tomarem decisões antes de afetarem ou serem afetadas pelos fatos previstos. Logo, gestores necessitam de previsões para que possam se adaptar aos eventos futuros ou tentar modificá-los (ARCHER, 1980). Em suma, elas são utilizadas pelos gerentes como base para a tomada de decisão, pois possibilitam a escolha de quais ações devem ser realizadas no presente, em virtude do conhecimento prévio dos prováveis resultados gerados por cada uma delas, alternativamente.

Podem ser feitas previsões úteis sobre os mais diversos tópicos, como a ocorrência de furacões em determinado local, o sucesso ou não do aumento do salário mínimo, ou o prognóstico da economia. Uma modalidade, de grande importância para as empresas, é a previsão de demanda:

Na maioria dos casos, os processos produtivos não são capazes de fornecer resposta instantânea à demanda, o que implica no fato que as empresas não

podem começar a produzir apenas depois de o cliente manifestar seu interesse pelo produto (a não ser no caso de vendas sob encomenda). Por isso, a produção precisa ser acionada antes de se ter um conhecimento absoluto das quantidades e da variedade de produtos que serão solicitados pelos clientes, o que torna essencial a realização de algum tipo de previsão (PEINADO; GRAEML, 2007, p.329).

Percebe-se que a previsão de demanda pode ser aplicada tanto em níveis mais altos (estratégicos) quanto em níveis mais baixos (operacionais).

Nos níveis mais altos ela é a base para realizar o planejamento estratégico a longo prazo. Nas áreas funcionais de finanças e de contabilidade, a previsão de demanda fornece a base do planejamento orçamentário e do controle de custos. O setor de marketing confia na previsão de vendas para planejar novos produtos, premiar os vendedores, e tomar outras decisões importantes. As funções de administração de produção utilizam as previsões para tomar decisões periódicas envolvendo seleção de processos, planejamento da capacidade, melhorias de leiaute, e para decisões contínuas sobre planejamento da produção, da programação e do estoque (DAVIS; CHASE; AQUILANO, 2001).

As empresas que dominam a gestão de demanda têm desfrutado de grande crescimento em seu valor de mercado e de significativa vantagem competitiva (LEE, 2001). Sua aplicação é fundamental para gerenciar a cadeia de suprimentos, desenvolver produtos, definir a estratégia de tecnologia, administrar os serviços de suporte e estruturar a organização. A gestão integrada da demanda promove valor (ESPER et al., 2010), pois faz com que os produtos e serviços desejados pelos consumidores sejam disponibilizados no mercado.

A gestão de demanda por unidade ou por linha de produtos permite aos gestores compreender o comportamento da demanda futura específica para cada segmento pontual de sua oferta. Nas empresas que produzem bens, cada unidade ou linha de produtos demanda suprimentos, produção e distribuição específicos. Ao conhecer a demanda futura dos produtos de forma mais detalhada e específica, essas empresas podem otimizar a alocação de recursos em três etapas distintas: na compra de matérias-primas, na produção e na distribuição. Já as empresas que prestam serviços, ao compreenderem a quantidade demandada de suas atividades ofertadas,

podem adaptar os recursos disponíveis àqueles necessários para desempenhar suas operações.

Entretanto, são poucas as empresas que possuem gestão de demanda eficiente sem utilizar métodos quantitativos de previsão. A acurácia das previsões sem a utilização desses métodos é prejudicada de duas maneiras (LAWRENCE; O'CONNOR; EDMUNDSON, 2000). Primeiro, o processo de realização de previsões se torna ineficiente por si só, pois os julgamentos utilizados pelas empresas possuem grande quantidade de erro, sendo menos precisos, em várias oportunidades, do que, até mesmo, a simples utilização do último valor observado como previsão para o próximo período. O segundo aspecto seria que as previsões ficam sujeitas a outros fatores que não contribuem para a sua acurácia, como interesses políticos e vieses intencionais dos desenvolvedores das previsões. Alguns departamentos utilizam a previsão de demanda como forma de captar mais recursos ou de definir metas mais difíceis de serem atingidas.

Dessa forma, quando dados históricos estão disponíveis, é apropriada a utilização de métodos quantitativos para a realização de previsões (VU, 2015). Existem vários desses métodos (CLAVERIA; TORRA, 2014; INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS; INTERNATIONAL ISLAMIC UNIVERSITY MALAYSIA, 2008; KLING; BESSLER, 1985; MAKRIDAKIS, 1990; VOYANT et al., 2011; VU, 2015), como as redes neurais, as regressões simples e múltiplas, as suavizações exponenciais, entre outros. Como escolher quais métodos serão utilizados? Quais critérios devem ser adotados ao realizar essa opção?

Um dos critérios que deve ser utilizado é a qualidade ou eficácia da previsão, que se chama acurácia - a acurácia é o fator mais importante da previsão (LAWRENCE; O'CONNOR; EDMUNDSON, 2000). Enquanto uma previsão completamente equivocada pode trazer prejuízos, uma previsão precisa torna-se confiável e útil. Por esse motivo, a acurácia deve ser considerada no momento da escolha dos métodos.

Além da acurácia, diversos fatores de escolha são importantes para a seleção de uma técnica de previsão (ARMSTRONG, 2001a): pontualidade na prestação de previsões, economias de custos geradas, facilidade de interpretação, flexibilidade, facilidade na utilização de dados disponíveis, facilidade de uso, facilidade de

implementação, incorporação de julgamentos, confiabilidade dos intervalos de confiança, custos de desenvolvimento, custos de manutenção e relevância teórica. Esses fatores recebem prioridades diferentes entre tomadores de decisão, praticantes, pesquisadores e professores quanto à escolha de métodos de previsão. Ao passo que pesquisadores dão maior valor para acurácia, tomadores de decisão preferem métodos de previsão mais flexíveis, mais fáceis de usar, de interpretar e de implementar. Estes profissionais não tomam como base principal a relevância teórica das técnicas utilizadas, comparados aos outros grupos. Assim, percebe-se a preferência por métodos mais fáceis, que não precisam, necessariamente, de relevância teórica.

Existem dois grandes grupos de métodos quantitativos de previsão: análises associativas e séries temporais. Enquanto os métodos do primeiro grupo são de maior dificuldade na utilização, por trabalharem com múltiplas variáveis, os métodos do segundo grupo são mais compreensíveis por fazerem uso somente de suas próprias séries históricas (CHASE, 2009; VU, 2015). Ambos produzem resultados similares (KIRBY; WATSON; DOUGHERTY, 1997), porém com distintos graus de dificuldade. Ao possuírem acurácia e facilidade de utilização, os métodos de séries temporais demonstram formas viáveis de realização de previsões de demanda para as empresas, capazes de produção de bons resultados.

Ao considerar que os métodos de séries temporais são um conjunto de métodos, e não somente um método, ainda se faz necessário compreender as diferenças entre eles e suas relevâncias para as empresas. Ao passo que alguns métodos de séries temporais são fáceis de serem utilizados, outros apresentam maior dificuldade de compreensão e utilização para os tomadores de decisão. Adicionalmente, determinados métodos são mais precisos, enquanto outros geram resultados com maiores margens de erro.

As diferenças entre esses métodos não são profundamente conhecidas. Portanto, ainda não há uma resposta definitiva sobre quais métodos devem ser utilizados pelos gestores para realizarem previsões de demanda, a partir dos critérios precisão e facilidade de uso.

É preciso comparar as previsões geradas por esses diferentes métodos a partir de múltiplas séries temporais de demanda, segregadas por unidades de produto



ou linhas de produto, para que se possa compreender os resultados gerados por esses métodos. Deve-se analisar séries temporais provenientes de contextos distintos, possibilitando a análise dos métodos de previsão de demanda por meio de uma abordagem genérica, que possa ser aplicada em diferentes cenários empresariais.

A partir da análise dessas séries, seria possível observar o comportamento desses métodos e determinar suas distinções quanto aos quesitos valorizados pelos gestores. Além disso, a análise de séries temporais de diferentes contextos do mercado não estaria restrita a padrões específicos nos dados, o que favorece a empregabilidade prática dos métodos de previsão por tomadores de decisão.

No contexto desse trabalho, serão analisadas séries temporais de volume de vendas (em quantidade de itens vendidos), contendo 36 meses cada, de cinco empresas de diferentes contextos: uma indústria de transformação (celulose), uma distribuidora (equipamentos eletrônicos), duas varejistas (medicamentos e mobílias) e uma do setor de serviços (transporte aéreo). Dessa forma, busca-se avaliar métodos de previsão de demanda que sejam fáceis de serem aplicados a todos esses contextos, e que gerem resultados precisos.

Por meio de uma comparação aplicada entre métodos de previsão de demanda, por séries temporais, procura-se responder aos seguintes questionamentos: qual desses métodos os tomadores de decisão devem escolher para preverem demanda? Dentro do grupo de métodos de séries temporais, qual método eles devem utilizar? Qual é o melhor? Ao utilizar os critérios acurácia e facilidade de uso para a definição do método a ser escolhido, a partir da análise da aplicação dos métodos de previsão em séries temporais, em contextos empresariais distintos, busca-se descobrir: **qual método de previsão de demanda baseado em séries temporais gera o resultado mais preciso de forma fácil?**

## 1.1 OBJETIVOS

### 1.1.1 Objetivo Geral

Determinar qual método genérico de previsão de demanda baseado em séries temporais gera resultados mais precisos de forma fácil.

### 1.1.2 Objetivos Específicos

I- Analisar dados históricos de empresas de setores variados por meio de diferentes métodos de previsão de demanda por séries temporais, encontrados na literatura, que atendam a critérios de facilidade de aplicação previamente definidos, com ênfase no tomador de decisão;

II- Comparar os métodos aplicados quanto ao quesito erro de previsão.

## 2 JUSTIFICATIVA

A utilização de um sistema eficaz e fácil de previsão de demanda por séries temporais por determinada empresa traria contribuições de três formas.

Primeiramente, o sistema auxiliaria os gestores da empresa na tomada de decisão estratégica. A partir da compreensão da volatilidade do mercado por meio do entendimento da demanda futura, os tomadores de decisão teriam maior conhecimento para fundamentarem suas decisões.

Em segundo lugar, embasaria o planejamento de vendas. Ao saberem quais seriam as vendas estimadas dos períodos seguintes, os tomadores de decisão otimizariam a definição de metas e a alocação de recursos, trazendo maiores resultados para a organização.

Por fim, aperfeiçoaria a gestão de produção e logística de duas maneiras: a empresa diminuiria a produção e estocagem de produtos em quantidades superiores às necessárias, reduzindo os custos relacionados, e evitaria a ausência de produtos demandados no momento da venda, reduzindo os prejuízos causados pela indisponibilidade dos produtos.

### 3 REFERENCIAL TEÓRICO

O presente capítulo possui como objetivo reunir o material teórico relevante sobre o tema abordado para embasar a realização do estudo de forma lógica. Assim, conceitos, abordagens e interpretações são apresentados para fundamentar a pesquisa, situar o problema pesquisado e dar consistência ao trabalho. Logo, torna-se possível sua contribuição futura.

#### 3.1 PREVISÃO

Previsões são importantes em muitos aspectos de nossas vidas. Como indivíduos, tentamos prever o sucesso em nossos casamentos, empregos e investimentos. Quando falamos em organizações, precisamos ter em mente que estas investem grandes somas de dinheiro em novos produtos, fábricas, lojas de varejo e contratos com executivos. Agências governamentais precisam de previsões sobre economia, impactos ambientais e resultados de programas sociais, por exemplo. As previsões ajudam pessoas e organizações a planejarem seu futuro, a tomarem decisões racionais e a avaliarem os possíveis resultados de sentenças que possam ser tomadas (ARMSTRONG, 2001b).

As previsões podem ser utilizadas sempre que o futuro for incerto. Embora os valores previstos frequentemente não ocorram, não se pode desenvolver um plano sem que se possua uma forma razoável de formar uma opinião sensata sobre o que possivelmente ocorrerá no futuro, o que é chamado de previsão (VU, 2015). As previsões perdem sua utilidade quando os eventos podem ser controlados (ARMSTRONG, 2001b). Não é necessário fazer uma previsão para saber se o elevador de certo prédio se encontrará em determinado andar em algum momento específico, pois isso pode ser controlado pelo pressionamento de um simples botão.

### 3.1.1 Previsão de Demanda

Uma das inúmeras previsões que podem ser realizadas é a previsão de demanda. Ela representa um conjunto de processos de negócios, ferramentas analíticas e tecnologias que possibilitam às organizações analisarem, escolherem e executarem canais, consumidores, segmentos geográficos e conjuntos de produtos que lhes auxiliem a alcançar seus objetivos de negócios baseados em seus clientes (CHASE, 2009). A previsão de demanda possui várias utilidades para as empresas.

A dita previsão é fundamental para a tomada de decisões estratégicas, pois auxilia a compreensão da volatilidade do mercado e a elaboração do orçamento (SHIM, 2000). Ao possibilitar um melhor entendimento das intenções de compras futuras, a empresa tem condições de realizar ações no presente para responder a essas previsões por meio do planejamento estratégico.

Além disso, ela é fundamental na gestão da cadeia de suprimentos (VAN LANDEGHEM; VANMAELE, 2002). Ao entender quais serão as quantidades demandadas de seus produtos em um futuro próximo, a empresa pode ajustar seus estoques por meio de sua produção, de acordo com a quantidade de produtos que espera vender. É preciso adaptar a gestão de demanda com o planejamento de vendas para que as mercadorias possam ser entregues nos momentos desejados, de forma que a produção e a entrega de produtos permaneçam em equilíbrio (HARRISON; HOEK, 2008). Assim, diminuem-se os custos causados não somente pelo excesso de mercadorias, mas também pela falta de produtos disponíveis para venda (CORSTEN; GRUEN, 2003; EMMELHAINZ; STOCK; EMMELHAINZ, 1991; GRUEN; CORSTEN, 2007). O referido excedente gera custos de várias formas: utilização de espaço físico, manutenção do estoque, perecibilidade das mercadorias e investimento em capital de giro nos produtos acabados. Já a indisponibilidade de produtos para venda se torna custosa de várias maneiras, como pelo prejuízo da imagem da empresa - por meio da insatisfação do cliente ao não conseguir realizar a compra -, pela não obtenção do lucro proveniente da venda que seria realizada ou em razão da perda de fatia do mercado.

Ademais, a elaboração de previsões de demanda também possui grande utilidade para a área de vendas. Ao providenciarem embasamento para o

desenvolvimento do planejamento de vendas, as previsões de demanda se tornam cruciais para as empresas (MENTZER; COX, 1984). Na verdade, as previsões de vendas nada mais são do que previsões de demanda: a primeira significa conhecer a quantidade que os clientes desejam comprar e, para tanto, desenvolver um planejamento para que essa quantidade seja, de fato, vendida (MENTZER; MOON, 2004).

Entretanto, é necessário que as previsões sejam entendidas e aplicadas para que realmente possam ter influência positiva para a tomada de decisão (GOODWIN; ÖNKAL; THOMSON, 2010). Os números não precisam ser tão exatos e precisos para os tomadores de decisão quanto para os acadêmicos, nem ter tanta relevância teórica, mas precisam ser facilmente entendidos, interpretados e utilizados (YOKUMA; ARMSTRONG, 1995). Dessa forma, as previsões têm contribuição limitada para a tomada de decisão se forem muito complexas, o que sugere a utilização de métodos que possam ser compreendidos por gestores sem maiores dificuldades. Como resultado da utilização de métodos de previsão mais factíveis, as empresas poderiam ser beneficiadas pelas contribuições advindas das previsões de demanda.

### 3.2 MÉTODOS DE PREVISÃO DE DEMANDA

Grande parte dos métodos de previsão de demanda estão contidos em uma das seguintes categorias: qualitativos ou quantitativos. Ao passo que os métodos qualitativos são formados por julgamentos subjetivos por uma pessoa ou um grupo de pessoas, os métodos quantitativos baseiam-se somente no histórico de vendas ou no relacionamento entre o histórico de vendas e outras variáveis (CHASE, 2009).

Esses conjuntos de métodos possuem os seguintes aspectos positivos e negativos (PILINKIENĖ, 2015):

Quadro 1 – Comparação entre métodos quantitativos e qualitativos de previsão

	<b>Aspectos Positivos</b>	<b>Aspectos Negativos</b>
<b>Métodos Quantitativos</b>	Utilizam dados que podem ser acessados sem complicações; Servem para a previsibilidade de pontos de mudança nos negócios; Podem ser interrelacionados com indicadores econômicos.	São impróprios para as previsões de demanda para novos produtos; Possuem custos elevados devido a eventuais análises de mercado e constante armazenamento de dados; Podem se tornar complicados de aplicar; Geram resultados que podem ser interpretados incorretamente.
<b>Métodos Qualitativos</b>	Não requerem dados dos períodos anteriores; São adequados para previsões de demanda em novos mercados; São adequados para previsões de demanda com nova equipe de vendas; Permitem a diversidade de opiniões; Se tornam mais confiáveis ao utilizarem opiniões de experts de forma anônima.	São formados por opiniões que podem se tornar subjetivas; Não consideram as flutuações históricas nos dados; Não podem ser interrelacionados com indicadores econômicos; Não são aplicáveis para previsões de curto prazo.

Fonte: Selection of Market Demand Forecast Methods: Criteria and Application – 2015.

Adaptado pelo autor.

Os três principais métodos qualitativos utilizados são: julgamento individual, painel de *experts*, e método Delphi (CHASE, 2009; LINSTONE; TUROFF, 2002; VU, 2015). O método de julgamento individual é praticado por um *expert* que utiliza sua própria experiência, dados passados do mercado e o estado atual dos negócios e da economia para realizar previsões, por meio da análise desses itens. Já o painel de *experts* é uma previsão feita por um grupo de profissionais de forma conjunta, na qual as opiniões são combinadas, balanceadas e ajustadas com base nas discussões e avaliações feitas por todos os membros do grupo. O método Delphi, por sua vez, pode ser considerado como um método para estruturar o processo de comunicação em grupo de forma que indivíduos, conjuntamente, possam lidar de forma eficiente com um

problema complexo. É parecido com o painel de *experts*, porém os *experts* não podem discutir o problema entre si diretamente.

### 3.2.1 Métodos Quantitativos

Existem dois grandes grupos de métodos de previsão quantitativos: análise de séries temporais e análise associativa. Enquanto a análise de séries temporais utiliza somente dados históricos de sua própria série, a análise associativa é baseada na investigação de vários fatores externos que podem afetar o movimento de um mercado (VU, 2015). Há também uma significativa diferença na utilização desses métodos: Ao passo que a análise de séries temporais é facilmente compreendida e utilizada, a análise associativa necessita de fortes conhecimentos estatísticos, demanda grande tempo para ser desenvolvida e confunde vários gerentes (CHASE, 2009).

O método utilizado nesse trabalho será o de análise de séries temporais, por três motivos. Primeiro, pela adequação do método (ou classes de métodos) aos dados disponíveis, que é um importante fator na seleção do método de previsão (BROCKWELL; DAVIS, 2002). Os dados disponíveis, ao seu turno, são de séries históricas, o que torna inviável a utilização de análises associativas. Em segundo lugar, pela facilidade de utilização do método. Um dos objetivos desse trabalho é estudar métodos de fácil aplicação e que produzam bons resultados, pois, dessa forma, podem ser utilizados e compreendidos por gerentes mais facilmente. Por último, pela menor quantidade de tempo requerida. A realização de uma grande quantidade de análises tornaria inviável análises associativas, pois isso demandaria uma quantidade de tempo indisponível.

## 3.3 SÉRIES TEMPORAIS

Algumas variáveis possuem um padrão que se repete de forma parecida ao longo do tempo. Consumo, variação no salário mínimo e produção industrial, por exemplo, podem mostrar uma tendência de crescimento positivo ou negativo. Já gastos com turismo e vendas no varejo possuem um padrão similar a cada ano, aumentando



próximo ao verão e ao natal. Essas variáveis podem ser analisadas por métodos econométricos, de forma a possibilitar previsões baseadas em dados históricos sobre seus comportamentos futuros (FRANSES; DIJK; OPSCHOOR, 2014).

Uma série temporal é um conjunto de observações medidas em determinado período de tempo. Os métodos de séries temporais auxiliam no entendimento do comportamento de dados ao longo do tempo por meio de seus componentes (BROCKWELL; DAVIS, 2002). A seguir, serão analisados os principais componentes e conceitos relacionados às séries temporais.

### **3.3.1 Componentes dos Métodos de Séries Temporais**

Os métodos de séries temporais possuem quatro componentes: tendência, sazonalidade, ciclicidade e ruído aleatório (CHATFIELD, 2016; HAMILTON, 1994; VU, 2015). O componente de tendência mede a direção geral da série temporal, que pode ser de movimentação para cima, para baixo ou ambígua (sem tendência). Sazonalidade é o movimento de flutuação que ocorre com periodicidade anual. Ciclicidade, por sua vez, refere-se ao movimento de flutuação que ocorre com periodicidade superior a um ano, podendo chegar, até mesmo, a várias décadas. Por fim, o componente de ruído aleatório representa a flutuação imprevisível de qualquer série temporal, composto por movimentos irregulares de padrão indefinido.

## **3.4 SELEÇÃO DOS MÉTODOS DE SÉRIES TEMPORAIS**

Enquanto alguns métodos de séries temporais são confiáveis somente para o próximo período a ser previsto, outros conseguem realizar previsões para mais períodos adiante. Entretanto, a acurácia das previsões diminui à medida em que aumentam os períodos previstos. A confiabilidade da previsão para o período seguinte é maior do que a do segundo período, e assim sucessivamente. O futuro próximo é mais fácil de ser mensurado a partir da utilização de métodos de séries temporais.

Alguns métodos de previsão, baseados em séries temporais, podem ser utilizados para uma quantidade maior de casos, sendo mais genéricos. Outros são

específicos e podem ser aplicados com eficiência somente se a série temporal analisada apresenta determinado comportamento, requerido pelo método. Existem métodos específicos para séries temporais lineares quanto à média, e outros para séries que possuem heterocedasticidade, por exemplo.

Existem métodos mais fáceis de serem entendidos por um tomador de decisão pois realizam apenas cálculos simples na última observação da série histórica analisada. Por outro lado, alguns métodos utilizam algoritmos extremamente complexos, que não podem ser compreendidos sem um estudo prévio. O entendimento do cálculo realizado pelo método nem sempre é claro e perceptível.

Adicionalmente, certos métodos demandam uma série de análises prévias nos conjuntos de dados, como: análise gráfica, autocorrelação, autocorrelação parcial, heterocedasticidade, linearidade e entre outras. Dessa maneira, esses métodos não podem ser aplicados com facilidade por tomadores de decisão que não possuam conhecimentos avançados em estatística. Além disso, essas análises teriam de ser feitas para cada série histórica analisada. Caso seja feita uma análise de previsão de demanda por unidade de produto, por exemplo, se tornaria inviável realizá-la manualmente.

Apesar de todas essas análises possuírem sua utilidade e, em alguns casos, serem essenciais para a aplicação dos métodos, não serão realizadas, neste trabalho, análises manuais. Essas análises não serão aplicadas pois o presente trabalho possui o objetivo de comparar métodos de forma genérica, quando aplicados por tomadores de decisão que não possuem conhecimentos avançados em estatística. Ademais, as análises manuais se tornam inviáveis de serem realizadas em uma grande quantidade de séries temporais individualmente.

Muitas dessas análises, se não todas, podem ser automatizadas. Porém, algumas precisariam ser feitas anteriormente à aplicação do método. Ou seja, o tomador de decisão não poderia simplesmente aplicar o método sobre a série histórica bruta, mas teria que executar as análises anteriormente. As análises automatizadas que serão realizadas neste trabalho seguirão o seguinte critério: só serão utilizadas as executadas de forma automática pelo próprio algoritmo do método de previsão de demanda. Assim, o tomador de decisão terá de efetuar apenas um comando ou análise para elaborar a

previsão. Só serão considerados os *outputs* da análise prévia realizada pelo método se forem automaticamente incluídos como inputs na nova análise, sem a necessidade de comandos adicionais por parte do tomador de decisão.

Esse critério foi definido para considerar as limitações do tomador de decisão em transportar e modelar um conjunto de dados gerados por uma das referidas análises para outro método. O tomador de decisão não necessitará executar vários comandos, ou “passos”, para gerar a previsão de demanda, mas apenas um.

Dessa maneira, o presente trabalho não possui foco nas nuances teóricas de cada método, mas visa proporcionar uma forma simples, prática e automática para que o tomador de decisão obtenha a melhor previsão de demanda possível sem que possua conhecimentos avançados em estatística. Para isso, faz-se necessária a definição de critérios de facilidade de aplicação.

### **3.4.1 Definição de Critérios de Facilidade de Aplicação**

Para que seja possibilitada uma efetiva comparação entre os métodos aqui apresentados, se faz necessária a definição de critérios e limites nas aplicações dos métodos. A facilidade de aplicação pode ser definida a partir de cinco componentes de qualidade (NIELSEN, 2012): facilidade de aprendizagem, eficiência, facilidade de memorização, ausência ou recuperação de erros e satisfação.

A facilidade na aplicação tem como objetivo principal possibilitar ao tomador de decisão que não possui conhecimentos avançados em estatística ou grande quantidade de tempo disponível obter previsões de demanda que possuam o maior grau de precisão possível. Portanto, esse trabalho considerará as restrições de tempo e conhecimento enfrentadas pelo aplicador dos métodos.

Visto isso, os seguintes critérios foram estabelecidos como definidores de facilidade de aplicação e devem ser englobados por todos os métodos aqui utilizados:

- a) Disponibilidade: disponibilidade pública de ferramenta ou software capaz de realizar a aplicação do método, ainda que por tempo limitado ou em período de testes;

- b) Adaptabilidade: ausência da necessidade de análises manuais de dados anteriores à aplicação do método;
- c) Automatização: ausência de necessidade de processar mais de uma vez a série histórica utilizada como base de dados para a obtenção das previsões, ou seja, possibilidade de aplicar o método somente com um comando, em qualquer que seja a ferramenta;
- d) Generalidade: aplicabilidade ampla do método nas mais variadas séries históricas, sem profundos impedimentos teóricos que restrinjam a eficácia do método sob determinadas circunstâncias;
- e) Independência: capacidade de aprendizagem do método por meio da própria série histórica analisada, de maneira automática, sendo desnecessário o aprendizado anterior baseado em outras séries históricas ou outras variáveis;
- f) Escala: ausência da necessidade de programar o algoritmo do método utilizado especialmente para cada série histórica;
- g) Simplicidade: ausência da necessidade de conhecimento teórico ou técnico profundo para a aplicação do método.

### 3.5 MÉTODOS DE SÉRIES TEMPORAIS

Existem diversas classes de métodos de séries temporais (CHASE, 2009). Cada uma dessas classes possui um ou mais métodos de previsão de demanda por séries temporais. As principais classes de métodos, seus respectivos métodos e as denominações utilizadas para os métodos nesse trabalho são definidas conforme o quadro abaixo.

Quadro 2 – Classes de métodos e métodos de previsão de demanda por séries temporais - 2017

<b>Classe</b>	<b>Método</b>	<b>Denominação Utilizada no Trabalho</b>
Método Ingênuo	Ingênuo	INGÊNUO
Decomposição	Decomposição Aditiva	ADITI
Decomposição	Decomposição Multiplicativa	MULTI
Suavização Exponencial	Suavização Exponencial Simples	EXPSIMPLES
Suavização Exponencial	Holt – dois parâmetros	HOLT
Suavização Exponencial	Winters – três parâmetros	WINTERS
Métodos Auto-Regressivos Integrados	Auto-Regressivo	AR
Métodos Auto-Regressivos Integrados	Média Móvel	MA
Métodos Auto-Regressivos Integrados	Auto-Regressivo de Média Móvel	ARMA
Métodos Auto-Regressivos Integrados	Auto-Regressivo Integrado de Média Móvel	ARIMA
Métodos Auto-Regressivos Integrados	Auto-Regressivo Integrado de Média Móvel Sazonal	SARIMA
Redes Neurais Univariadas Automáticas	Redes Alimentadas Adiante com Camada Única	RAAUNI
Redes Neurais Univariadas Automáticas	Redes Alimentadas Adiante com Camadas Múltiplas	RAAMULTI
Redes Neurais Univariadas Automáticas	Redes Recorrentes	RECOR

Fonte: elaborado pelo autor.

### 3.5.1 Método Ingênuo (INGÊNUO)

É o método mais simples de previsão. O método ingênuo é a simples repetição do último valor observado para ser utilizado como previsão para os valores futuros (HYNDMAN; ATHANASOPOULOS, 2014a). Ou seja, prevê que o futuro próximo

será exatamente igual ao presente. Esse método não utiliza nenhuma análise, somente projeta o valor observado por último para o período seguinte.

Seus pontos fortes são: grande facilidade de aplicação, baixo custo de tempo e de recursos computacionais e fácil compreensão. Apesar de ser muito simples, é uma ferramenta legítima de previsão que deve ser considerada nas análises.

O principal defeito desse método é a incapacidade de realizar previsões com alta precisão (CHASE, 2009). Além disso, falha em detectar padrões de comportamento nos dados, por mais simples que sejam. Quando for necessário obter elevado poder preditivo, esse método não deve ser aplicado.

Segundo o ele, o valor da previsão para o próximo período é exatamente o valor observado no período antecedente:

$$Z_t = Z_{t-1}$$

$Z$                       Valor previsto da série;  
 $t = 1, \dots, N,$       Períodos da série temporal;

### 3.5.2 Classe de Métodos de Decomposição

A decomposição é um conjunto de métodos clássicos que efetua a previsão com base em somas ou multiplicações dos componentes não observáveis da série temporal. Dessa forma, separa os valores observados em cada um dos quatro componentes das séries temporais (tendência, sazonalidade, ciclicidade e ruído aleatório). Existem dois métodos de decomposição: decomposição aditiva e decomposição multiplicativa.

Uma de suas grandes contribuições é no ajuste de sazonalidade, de forma que pode ser aplicado em conjunto com outras classes de métodos, como ARIMA. É uma classe de métodos simples, que serviu de base para o desenvolvimento de outros métodos mais complexos.

Embora a decomposição clássica ainda seja utilizada, ela não é recomendada (SOUZA, 1981). Existem outras classes de métodos melhores, que possuem maior

precisão. Um de seus pressupostos é que a sazonalidade se repete anualmente, o que pode não acontecer em séries mais longas. Mudanças na sazonalidade não podem ser detectadas por essa classe de métodos. Adicionalmente, os métodos baseados em decomposição não são robustos o suficiente para serem utilizados em séries que possuam alguns valores não usuais, que podem ser chamados de *outliers*.

### 3.5.2.1 Método de Decomposição Aditiva (ADITI)

O método clássico de decomposição aditiva utiliza os componentes tendência e ciclicidade multiplicados de forma conjunta, como se fossem apenas um, formando o componente “tendência-ciclicidade”. Os componentes de sazonalidade e de ruído aleatório são somados a esse componente, formando o valor previsto:

$$Z_t = T_t + S_t + R_t$$

$Z$	Valor previsto da série;
$T$	Tendência-ciclicidade;
$S$	Sazonalidade;
$R$	Ruído aleatório;
$t = 1, \dots, N,$	Períodos da série temporal;

### 3.5.2.2 Método de Decomposição Multiplicativa (MULTI)

O método de decomposição multiplicativa utiliza os mesmos componentes do método aditivo, porém multiplicados. Dessa forma, o valor previsto para o próximo período é a multiplicação dos componentes tendência-ciclicidade, sazonalidade e ruído aleatório:

$$Z_t = T_t \times S_t \times R_t$$

$Z$	Valor previsto da série;
-----	--------------------------

$T$	Tendência-ciclicidade;
$S$	Sazonalidade;
$R$	Ruído aleatório;
$t = 1, \dots, N,$	Períodos da série temporal;

### 3.5.3 Classe de Métodos de Suavização Exponencial

Suavizações exponenciais utilizam as observações passadas com pesos que decrescem exponencialmente, a partir do último valor observado, e realizam uma média que elimina as variações acima do normal ocorridas nos períodos anteriores. Em outras palavras, a suavização exponencial atenua os picos da série histórica por meio da utilização de coeficientes cada vez menores (KALEKAR, 2004). É uma extensão dos métodos de média móvel. A previsão para um novo valor observado é idêntica à previsão antiga, porém com um ajuste para o erro de previsão do último valor observado.

Os métodos baseados em suavização exponencial produzem bons resultados quando as previsões precisam ser feitas para centenas ou milhares de produtos, pois podem ser aplicados automaticamente utilizando baixa quantidade de dados. Esses métodos possuem baixo custo e podem ser facilmente compreendidos (GARDNER; DANNENBRING, 1980). São os métodos mais populares para previsão de demanda.

Um dos problemas dessa classe de métodos é definir qual expoente deve ser aplicado para a definição dos pesos dos métodos passados, o que normalmente é feito por tentativa e erro (GARDNER, 1985). O resultado previsto para o próximo período pode variar consideravelmente de acordo com o peso escolhido, o que torna este um dos seus pontos fracos. Assim como os métodos de média móvel, essa classe de métodos só consegue realizar previsões com acurácia para um período adiante. Ela não tem capacidade de prever ou perceber mudanças bruscas na demanda, o que a torna lenta. Adicionalmente, é sensível à presença de *outliers*, que podem provocar distorções nas previsões obtidas (CIPRA, 1992; GELPER; FRIED; CROUX, 2009). Por último, é facilmente automatizada e pode ser aplicada em escala.



### 3.5.3.1 Método de Suavização Exponencial Simples (EXPSIMP)

O método de suavização exponencial simples utiliza como parâmetro somente a constante de suavização para definir qual será o peso dos últimos valores observados na composição da previsão do próximo período. Dessa forma, sua previsão é simplesmente a média dos últimos valores observados ponderada exponencialmente a partir da constante de suavização:

$$Z_t = \alpha \sum_{j=0}^{t-1} (1 - \alpha)^j Z_{t-j} + (1 - \alpha)^t Z_0$$

$Z$	Valor previsto da série;
$\alpha$	Constante de suavização entre 0 e 1;
$t = 1, \dots, N,$	Períodos da série temporal;

### 3.5.3.2 Método de Holt – Dois Parâmetros (HOLT)

O método de Holt é uma expansão do método de suavização exponencial simples, que passou a incluir um componente de tendência linear (KALEKAR, 2004). Assim, podem ser realizadas previsões com dados que possuam este componente associado. A partir dessa modificação, o método passa a utilizar dois parâmetros: a constante de suavização, aplicada por meio de uma soma de nível, e a tendência.

Essa contribuição faz com que os resultados obtidos pelo método sejam melhorados significativamente (CHASE, 2009) ao se adequar melhor aos dados históricos. Dessa forma, torna-se mais completo, porém não perde capacidade de ser automatizado.

Apesar das melhorias obtidas, possui os mesmos problemas dos métodos anteriores: é lento, não consegue perceber mudanças bruscas na demanda e não suporta sazonalidade de forma eficiente. Somente consegue realizar previsões com

acurácia para um período adiante, assim como o método de suavização exponencial simples.

O método de Holt utiliza uma soma de nível aliada ao componente de tendência, para obter o valor previsto para determinado período:

$$Z_t = L_t + T_t$$

$$L_t = \alpha L_t + (1 - \alpha)(L_{t-1} + T_{t-1})$$

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

$Z$	Valor previsto da série;
$L$	Soma de nível;
$T$	Valor de tendência da série;
$\alpha$	Constante de suavização entre 0 e 1;
$\beta$	Constante de suavização entre 0 e 1, tal que $\alpha \geq \beta$ ;
$t = 2, \dots, N,$	Períodos da série temporal;

### 3.5.3.3 Método de Winters – Três Parâmetros (WINTERS)

Seu principal objetivo é resolver os problemas relacionados à sazonalidade dos métodos anteriores (GOODWIN, 2010). Uma terceira equação é adicionada, considerando a sazonalidade histórica. Esse método possui duas variações: pode ser multiplicativo ou aditivo. Normalmente, o multiplicativo é preferido (KALEKAR, 2004), porém o aditivo pode ser utilizado quando o outro não se aplica de forma eficiente. A única diferença entre essas duas variações é que os índices sazonais são multiplicados ou divididos na variação multiplicativa, e somados ou subtraídos na variação aditiva.

O método de Winters é o mais utilizado para a realização de previsões, e tornou-se mais completo com a aplicação de mais um elemento. Dessa forma, é capaz de utilizar o componente sazonal.

Entretanto, com exceção dessa dificuldade solucionada, possui os mesmos problemas dos anteriores. O método de Winters continua sendo lento, e não possui acurácia em previsões de mais de um período adiante.

A variante mais usual do método de Winters considera o componente sazonalidade como sendo multiplicativo, enquanto o componente tendência continua sendo aditivo. O método multiplicativo de Winters é representado da seguinte forma:

$$Z_t = S_t L_t + T_t$$

$$S_t = \gamma \left( \frac{Z_t}{L_t} \right) + (1 - \gamma) S_{t-p}$$

$$L_t = \alpha \left( \frac{Z_t}{S_{t-\varepsilon}} \right) + (1 - \alpha) (L_{t-1} + T_{t-1})$$

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

$Z$	Valor previsto da série;
$L$	Soma de nível;
$T$	Valor de tendência da série;
$\alpha$	Constante de suavização entre 0 e 1;
$\beta$	Constante de suavização entre 0 e 1, tal que $\alpha \geq \beta$ ;
$\gamma$	Constante de suavização da sazonalidade entre 0 e 1;
$p$	Quantidade de períodos da sazonalidade;
$t = 2, \dots, N,$	Períodos da série temporal;

### 3.5.4 Classe de Métodos Auto-Regressivos Integrados

A classe de métodos auto-regressivos integrados possui vários componentes que representam pequenos métodos utilizados em conjunto (NGO, 2013). Primeiramente, foram desenvolvidos os métodos auto-regressivo (AR) e média móvel (MA), que foram aplicados de forma conjunta, formando o chamado método auto-regressivo de média móvel (ARMA). Esse método recebeu mais um componente para

que se tornasse capaz de realizar previsões satisfatórias para séries não estacionárias, tornando-se o método auto-regressivo integrado de média móvel (ARIMA). Por último, foi adicionado o componente de sazonalidade, que, até então, não era detectado. Assim, o método ARIMA tornou-se SARIMA, auto-regressivo integrado de média móvel sazonal. Cada um desses métodos, será analisado e aplicado nesse trabalho.

#### 3.5.4.1 Método Auto-Regressivo (AR)

O método auto-regressivo especifica que o valor previsto depende linearmente dos últimos valores observados de sua própria série somados a um ruído aleatório. Os valores futuros dependem somente de uma soma balanceada dos valores passados: é uma simples regressão linear dos últimos valores observados. A quantidade de valores utilizados para a regressão pode ser chamada de ordem ou memória desse método. Esse método funciona de forma similar a uma regressão múltipla, na qual suas variáveis seriam as últimas observações da série temporal. Assim, o valor previsto para o próximo período depende somente de uma regressão realizada sobre a própria série histórica.

O método auto-regressivo é muito flexível, sendo conhecido por sua utilização nas mais variadas séries temporais. É um dos componentes do método ARIMA, sendo aplicado normalmente em conjunto com os demais.

O método AR não traz resultados satisfatórios quando aplicado de forma isolada em séries não estacionárias, o que é resolvido posteriormente pelo método ARIMA com a aplicação conjunta de outros componentes. Adicionalmente, não possui estrutura para lidar com sazonalidade ou adaptar o erro encontrado nas previsões anteriores para valores já obtidos. Suas principais dificuldades são resolvidas pelos demais métodos de sua classe. A quantidade de termos que o método AR utiliza (operador de defasagem) deve ser definida durante a aplicação do método, ou seja, o número utilizado de valores observados na série histórica não é fixo para todos os casos. Dessa forma, essa é uma dificuldade trazida pelo método, que precisa ser analisada durante a sua aplicação na série de dados.

O método auto-regressivo é uma regressão baseada somente nos últimos valores observados de uma série histórica. A previsão para determinado período é encontrada da seguinte forma, a partir do método AR(p):

$$Z_t = c + \sum_{j=1}^p \varphi_j Z_{t-j}$$

$Z$	Valor previsto da série;
$c$	Constante;
$\varphi$	Parâmetros determinados a partir do operador de defasagem;
$p$	Operador de defasagem (ordem);
$t = 1, \dots, N,$	Períodos da série temporal;

#### 3.5.4.2 Método de Média Móvel (MA)

O método de média móvel utiliza uma média dos últimos valores observados, que serve como previsão para o próximo período. Dessa forma, o valor a ser previsto é relacionado com os últimos erros de previsão. A cada novo período, o valor observado mais antigo é substituído pelo novo valor observado, a fim de compor uma nova média (VU, 2015).

Essa técnica possui alguns pontos fortes: requer uma mínima quantidade de dados e pode ser automatizada facilmente. O método de média móvel é simples de ser aplicado e pode ser utilizado quando não há sazonalidade associada com a previsão. Funciona bem com componentes de tendência e ciclicidade (CHASE, 2009).

Como pontos negativos, este método não consegue realizar previsões de forma eficaz quando há sazonalidade, ou para mais de um período adiante. Ao passo que remove grandes variações dos últimos períodos, pode minimizar flutuações importantes, de forma que passem despercebidas. As mudanças bruscas de demanda não podem ser previstas com rapidez. Um ponto chave desse método é determinar qual

o número ótimo de períodos que deve ser utilizado, que irá compor a ordem do método, o que pode se tornar uma dificuldade para o tomador de decisão.

Ao passo que os valores observados em cada período podem receber pesos diferentes, e a quantidade de períodos utilizados para compor a média varia, o valor previsto se altera de acordo com essas definições. Por isso, esses critérios devem ser definidos de acordo com a série histórica de dados analisada. Dessa forma, devem ser determinados os pesos que cada valor receberá e a quantidade de períodos que será utilizada no momento da aplicação do método. Apesar da possibilidade de serem obtidas previsões díspares a partir de aplicações desse método com quantidade de períodos e pesos diferentes, esses valores serão ajustados pelo próprio algoritmo no momento da análise. Assim, é dispensada a análise manual desses valores por parte do tomador de decisão.

A previsão para determinado período a partir do método de médias móveis é uma regressão linear do valor atual da série a partir dos erros obtidos nas últimas previsões. A partir do método AR(q), a previsão pode ser obtida da seguinte forma:

$$Z_t = \mu + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

$Z$	Valor previsto da série;
$\mu$	Média das séries;
$\theta$	Parâmetros determinados a partir do operador de defasagem;
$\varepsilon$	Erro observado em determinado período;
$q$	Operador de defasagem (ordem);
$t = 1, \dots, N,$	Períodos da série temporal;

#### 3.5.4.3 Método Auto-Regressivo de Média Móvel (ARMA)

Esse método utiliza os dois métodos anteriores de forma conjunta: auto-regressão (AR) e médias móveis (MA). Além de utilizar os erros dos últimos períodos,

com as médias móveis, também percebe a correlação entre os últimos valores, a partir da auto-regressão. Por isso, esse método possui duas ordens: uma para o componente AR e outro para o MA.

Assim como os métodos AR e MA, também considera que a previsão para o próximo período depende somente dos últimos valores observados. Esse método, assim como os anteriores, considera que a série histórica não possui componente de tendência. Ou seja, os dados supostamente flutuam ao redor de uma média constante, independentemente do tempo – o método considera que a série histórica é estacionária.

O método ARMA(p,q) gera o valor previsto para determinado período da seguinte maneira:

$$Z_t = c + \sum_{j=1}^p \varphi_j Z_{t-j} + \sum_{j=1}^q \theta_j \varepsilon_{t-j}$$

$Z$	Valor previsto da série;
$c$	Constante;
$\varphi$	Parâmetros determinados a partir da ordem AR;
$\theta$	Parâmetros determinados a partir da ordem MA;
$\varepsilon$	Erro observado em determinado período;
$p$	Operador de defasagem auto-regressivo (ordem AR);
$q$	Operador de defasagem média móvel (ordem MA);
$t = 1, \dots, N,$	Períodos da série temporal;

#### 3.5.4.4 Método Auto-Regressivo Integrado de Média Móvel (ARIMA)

O método ARIMA possui os três componentes: médias móveis (MA), auto-regressão (AR), e integração (I). É uma união dos métodos anteriores de auto-regressão e médias móveis (AR e MA) integrado (WATSON, 2001). Ele utiliza três parâmetros, ou ordens, para prever a demanda da série histórica analisada.

Sua principal diferença prática em relação aos métodos anteriores é que a série passa a ser considerada não-estacionária, ou seja, a previsão dos valores da série histórica depende do tempo. O método ARIMA pode lidar com praticamente qualquer conjunto de dados. Possui grande acurácia e pode ser utilizado para previsões de até três períodos.

Entretanto, este método se apresenta de forma complexa, o que desencoraja muitos tomadores de decisão e analistas. Profissionais que não possuem conhecimento de estatística dificilmente conseguem entender os resultados gerados por esse método. Ademais, a aplicação desse método normalmente precisa ser refeita quando novos dados são observados na série histórica, o que requer acompanhamento. As previsões não utilizam o componente de sazonalidade, perdendo precisão quando há variação constante entre determinados números de períodos.

A previsão gerada para determinado período por meio da utilização do método ARIMA possui a seguinte forma:

$$\left(1 - \sum_{j=1}^p \varphi_j B^j\right) (1 - B)^d Z_t = \delta + \left(1 + \sum_{j=1}^q \theta_j B^j\right)$$

$Z$	Valor previsto da série;
$\delta$	Constante;
$\varphi$	Parâmetros determinados a partir da ordem AR;
$\theta$	Parâmetros determinados a partir da ordem MA;
$p$	Operador de defasagem auto-regressivo (ordem AR);
$d$	Operador de integração (ordem I);
$q$	Operador de defasagem média móvel (ordem MA);
$B$	Operador de defasagem para cada somatório;
$t = 1, \dots, N,$	Períodos da série temporal;



### 3.5.4.5 Método Auto-Regressivo Integrado de Média Móvel Sazonal (SARIMA)

O método ARIMA pode gerar melhores resultados em séries sazonais a partir da utilização de componentes sazonais multiplicativos ou aditivos, definidos de acordo com a sazonalidade observada na série histórica do método. Para isso, recebe um parâmetro sazonal para cada um de seus componentes (AR, I, e MA). Ao receber os novos parâmetros, o método torna-se SARIMA.

Esse método não possui outras diferenças em relação ao ARIMA, possuindo os mesmos pontos fortes e fracos, diferenciando-se pela melhoria na capacidade preditiva em séries sazonais (CHU, 2009). Entretanto, torna-se complexo, de forma que dificilmente é compreendido a partir de sua equação.

Nesse trabalho, o método sazonal utilizado será multiplicativo, pois usualmente gera melhores resultados que o aditivo. A previsão para determinado período, definida a partir do método SARIMA multiplicativo, é obtida da seguinte forma:

$$\begin{aligned} & \left(1 - \sum_{j=1}^p \varphi_j B^j\right) \left(1 - \sum_{j=1}^P \varphi_j B^j\right) (1 - B)^d (1 - B)^D Z_t \\ &= \delta + \left(1 + \sum_{j=1}^q \theta_j B^j\right) \left(1 + \sum_{j=1}^Q \theta_j B^j\right) \end{aligned}$$

$Z$	Valor previsto da série;
$\delta$	Constante;
$\varphi$	Parâmetros determinados a partir da ordem AR;
$\theta$	Parâmetros determinados a partir da ordem MA;
$p$	Operador de defasagem auto-regressivo (ordem AR);
$d$	Operador de integração (ordem I);

$q$	Operador de defasagem média móvel (ordem MA);
$P$	Número de termos sazonais para a ordem AR;
$D$	Número de termos sazonais para a ordem I;
$Q$	Número de termos sazonais para a ordem MA;
$B$	Operador de defasagem para cada somatório;
$t = 1, \dots, N,$	Períodos da série temporal;

### 3.5.5 Classe de Métodos de Redes Neurais Univariadas Automáticas

Redes neurais são inspiradas em cérebros de animais, que podem reproduzir padrões aprendidos por meio de análises em grandes quantidades de dados. Essas redes são capazes de computar valores de entrada e saída em cada um de seus “neurônios”, ou “nós”. Ao aprenderem, as redes neurais tornam-se capazes de gerar soluções generalizadas para uma série de problemas (MAIER; DANDY, 2000). Podem possuir três (entrada - recebimento de dados; intermediária – processamento; saída – apresentação de dados) ou mais camadas. O número de camadas é diretamente proporcional à capacidade de aprendizado da rede neural.

As redes neurais possuem grande capacidade de lidar com dados que não se encontram em equilíbrio, ou seja, podem ser utilizadas de maneira genérica, mesmo quando os dados não são lineares ou estacionários (BAKHARY; YAHYA; NG, 2012). As redes neurais artificiais (RNA) possuem algoritmos para tarefas de aprendizagem, modelagem e otimização, da mesma forma que as redes neurais naturais. Dessa forma, conseguem detectar padrões e comportamentos nos mais variados conjuntos de dados.

O elemento mais importante das RNAs é o neurônio, responsável por executar todas as análises da classe de métodos. Cada rede possui vários neurônios que são conectados entre si por sinapses. Dessa forma, os valores de entradas e saídas de dados dos neurônios estão relacionados a outros neurônios que são interligados. As sinapses são responsáveis por lidar com a troca de dados entre os neurônios em uma rede neural artificial.

A partir da entrada de dados em determinada rede por meio de sinapses entre os neurônios, os dados são submetidos a operações de acordo com variados pesos,

definidos automaticamente. Posteriormente, as operações realizadas são combinadas por meio de uma junção aditiva, que pode ser modificada por um viés. O viés é a modificação da junção aditiva, aumentando ou diminuindo seu valor de saída.

O resultado da junção aditiva, modificado pelo viés, serve como entrada para a função de ativação. Essa função é responsável por determinar o valor de saída do neurônio, sintetizando as operações realizadas. Em seu método mais conhecido, o valor de saída é binário, determinado por meio de uma função sigmoide logística.

Um neurônio pode ser definido pelas seguintes equações:

$$y = \varphi(u + b)$$

$$u = \sum_{j=1}^m w_j x_j$$

$x$	Sinais de entrada;
$w$	Pesos sinápticos;
$u$	Saída do combinador linear;
$m$	Quantidade de entradas;
$b$	Viés;
$\varphi$	Função de ativação;
$y$	Sinal de saída;
$j$	Cada uma das sinapses ligadas ao neurônio;

A partir das operações realizadas por meio de uma rede de neurônios, os métodos de RNAs possuem aspectos positivos não observados nos outros métodos de previsão de demanda por séries temporais. O principal ponto forte dessa classe de métodos em relação às demais é sua capacidade de aprender: ao receber dados de entrada e saída, a rede cria uma representação do processo de transformação desses dados, tornando-se capaz de responder a partir dessas informações. Ela se organiza

independentemente, de forma que o usuário não fica encarregado do processo de definição da representação utilizada.

Entretanto, o resultado gerado não é facilmente explicado ou entendido. As múltiplas operações realizadas não são compreendidas por tomadores de decisão. Além disso, as RNAs não são capazes de responder a variações bruscas na série histórica, de maneira que voltam a replicar as oscilações detectadas na série histórica analisada no momento de aprendizado.

A quantidade de camadas de cada rede varia, podendo ser definida no momento de aplicação do método, assim como o fluxo de dados entre as sinapses. Podem ser geradas diferentes redes a partir do fluxo de informação e da quantidade de neurônios utilizados. A classe de métodos de RNAs, quanto à sua topologia, pode ser segregada em três métodos: redes alimentadas adiante com camada única, redes alimentadas adiante com camadas múltiplas e redes recorrentes.

#### 3.5.5.1 Método de Redes Alimentadas Adiante com Camada Única (RAAUNI)

O método de redes alimentadas adiante com camada única contém apenas a camada de entrada dos neurônios, onde são recebidos os dados analisados e a camada de saída, onde os resultados são verificados. Dessa forma, não há camadas ocultas, pois tanto os dados de entrada quanto os dados de saída podem ser visualizados pelo tomador de decisão, no momento da aplicação. O fluxo de dados ocorre somente em uma direção, da camada de entrada para a camada de saída da rede.

O método de camada única é o mais simples (ou menos complexo) de se entender. Como não existem camadas que não possam ser observadas pelo aplicador do método, os cálculos realizados podem, ainda que não de forma intuitiva, ser compreendidos. Esse método serve como base aos demais, que são mais complexos.

Ao passo que possui somente uma camada, esse método não é indicado para lidar com cálculos complexos ou com operações que exijam grande acurácia. Como o seu fluxo é unidirecional, os erros observados no período de treinamento não retornam em cada análise da rede, o que diminui sua precisão. Possui poder computacional limitado.

O método de redes alimentadas adiante com camada única segue a seguinte equação:

$$Z = b_0 + \sum_{j=1}^n w_j y_j$$

$Z$	Valor previsto da série;
$b$	Viés inicial;
$j$	Cada um dos valores de entrada para a previsão;
$n$	Número de valores de entrada para a previsão;
$w$	Pesos utilizados para os valores de entrada dos neurônios;
$y$	O valor de saída de cada um dos neurônios;

### 3.5.5.2 Método de Redes Alimentadas Adiante com Camadas Múltiplas (RAAMULTI)

As redes com camadas múltiplas utilizam uma camada de entrada, uma ou mais camadas ocultas, e uma camada de saída (ABDEL-AAL, 2008). Os cálculos realizados pelo método, no momento da aplicação, não podem ser visualizados pelo tomador de decisão, pois as operações matemáticas realizadas nas camadas ocultas não podem ser individualmente definidas ou alteradas pelo usuário. Esse método é o mais conhecido entre os métodos da classe de RNAs.

O principal ponto forte desse método é o aumento da capacidade computacional da rede. Ao utilizar múltiplas camadas, realiza mais operações matemáticas, o que tende a otimizar a previsão gerada pelo método. As redes de camadas múltiplas podem realizar cálculos de alta complexidade.

Apesar de ser mais potente computacionalmente, esse método ainda não utiliza a retroalimentação, ou seja, seu comportamento não é dinâmico. Adicionalmente, o desconhecimento dos procedimentos executados nas camadas ocultas gera o efeito “caixa preta”: não é possível compreender o que está sendo calculado pelo método no

momento da aplicação, ou quais foram os passos utilizados pelo algoritmo para gerar seu resultado nas camadas de saída.

O método de redes alimentadas adiante com camadas múltiplas pode ser representado a partir do seguinte conjunto de equações:

$$Z_k = f(v_k)$$

$$v_k = b_{0k} + \sum_{j=1}^m w_{jk}y_j$$

$Z$	Valor previsto da série para cada um dos neurônios de saída;
$b$	Viés inicial para cada um dos neurônios de saída;
$k$	Número de neurônios de saída;
$m$	Número de neurônios ocultos;
$j$	Cada um dos valores de entrada para a previsão;
$w$	Pesos utilizados entre os neurônios ocultos e os de saída;
$y$	O valor de saída de cada um dos neurônios ocultos;
$v$	Soma dos valores de entrada;
$f$	Função de ativação de cada um dos neurônios de saída;

### 3.5.5.3 Método de Redes Recorrentes (RECOR)

As redes recorrentes possuem esse nome pois utilizam os dados de saída, gerados pela rede, como dados de entrada da mesma rede em mais de um neurônio. Os neurônios na camada de saída realizam sinapses, enviando dados, com os neurônios da camada de entrada. Ou seja, o fluxo de dados dentro da rede se torna cíclico, e não mais unidirecional.

Essa característica possibilita ao método realizar cálculos dinâmicos e não-lineares. Sua precisão aumenta (ZHANG; PATUWO; HU, 1998), pois a rede passa a

refazer as operações nas camadas ocultas, diminuindo o erro do resultado na camada de saída.

É o método mais complexo de RNAs e possui o mesmo efeito “caixa preta” das redes alimentadas adiante com camadas múltiplas. Sua aplicação demanda a definição de uma quantidade maior de parâmetros em relação aos métodos anteriores, pois os dados são reutilizados pela rede. A reutilização dos dados pela rede é mais um fator a ser definido, no algoritmo de aplicação do método.

Como exemplo de rede recorrente, segue abaixo um conjunto de equações demonstrando a versão tradicional da Longa Memória de Curto Prazo:

$$h_t = \sigma_t \cdot \sigma_h(c_t)$$

$$f_t = \sigma_g(W_f x_t + U_f h_{t-1} + b_f)$$

$$i_t = \sigma_g(W_i x_t + U_i h_{t-1} + b_i)$$

$$o_t = \sigma_g(W_o x_t + U_o h_{t-1} + b_o)$$

$$c_t = f_t \cdot c_{1-t} + i_t \cdot \sigma_c(W_c x_t + U_c h_{t-1} + b_c)$$

$\cdot$	Produto de Hadamard;
$f$	Vetor do portão de esquecimento;
$i$	Vetor do portão de entrada;
$\sigma$	Vetor do portão de saída;
$W$	Matriz paramétrica;
$U$	Matriz paramétrica distinta;
$b$	Vetor de parâmetros;
$x$	Vetor de entrada;
$h$	Vetor de saída;
$c$	Vetor do estado da célula
$t$	Cada um dos passos da rede recorrente;

### 3.6 EVOLUÇÃO CRONOLÓGICA DOS MÉTODOS DE PREVISÃO

Ao passo que a capacidade computacional disponível para a realização de previsões aumentou, foi possível desenvolver métodos mais robustos de previsão que consomem maior processamento. Juntamente com o aumento da capacidade computacional, foram criados softwares que facilitam a utilização de métodos complexos pelo tomador de decisão. Dessa forma, a partir da automatização e da disponibilização dos métodos, o conhecimento necessário para obter previsões de demanda diminuiu.

Em sequência, será realizada uma breve apresentação e comparação, em ordem cronológica, entre os principais métodos de previsão de demanda a partir dos quesitos precisão e facilidade de aplicação.

### **3.6.1 Método Ingênuo**

O método ingênuo, que consiste somente na replicação do último valor observado para o próximo período, não representa qualquer avanço científico quanto à previsão de demanda. Serve somente de base de comparação para a precisão das previsões geradas pelos demais métodos. Ao passo que não exige qualquer conhecimento, é extremamente simples. Entretanto, a sua extraordinária simplicidade também se reflete na sua imprecisão.

### **3.6.2 Classe de Métodos de Decomposição**

Os métodos de decomposição, ou métodos clássicos, são originários de, aproximadamente, 1920. São simples e formam a base de todos os outros métodos. A partir da contextualização de seus componentes (tendência, ciclicidade, sazonalidade), os métodos mais robustos foram desenvolvidos. Apesar de explicarem de forma acessível quais seriam os componentes de uma série temporal e de ainda serem utilizados, não são indicados para a realização de previsões, já que existem diversos métodos melhores (HYNDMAN; ATHANASOPOULOS, 2014a).



### **3.6.3 Classe de Métodos de Suavização Exponencial**

Os métodos de suavização exponencial surgiram durante os anos 1950 e 1960, e foram desenvolvidos em seu formato inicial até meados de 1980. Esses métodos providenciam uma forma simples, porém útil, de analisar o componente de tendência em séries temporais, suavizando os erros aleatórios dos últimos períodos (DE GOOIJER; HYNDMAN, 2006). Durante a década de 90, foram realizados inúmeros estudos comparando a utilização desses métodos em diferentes contextos. Cada método possui uma das cinco formas de analisar o componente de tendência (nenhuma, aditiva, aditiva amortecida, multiplicativa e multiplicativa amortecida), e uma das três formas de analisar o componente de sazonalidade (nenhuma, aditiva e multiplicativa). Portanto, existem 15 variações desses métodos. Nos anos seguintes, surgiram variações desses métodos que lidavam com séries temporais específicas - não genéricas. Os métodos de suavização exponencial mostraram-se robustos, embora acessíveis (HYNDMAN et al., 2002).

### **3.6.4 Classe de Métodos Auto-Regressivos Integrados**

Os métodos ARIMA receberam o seu terceiro componente (I, em adição aos componentes AR e MA) por volta de 1970. A partir desse momento, tornaram-se capazes de obter previsões semelhantes às realizadas pelos mais renomados profissionais (GEURTS; IBRAHIM, 1975). Com a expansão da capacidade computacional, a utilização desses métodos tornou-se mais viável. O sucesso desses métodos é resultante da capacidade de se moldar às séries temporais analisadas por meio do recebimento de vários parâmetros. Nos anos seguintes, foram desenvolvidas variações do método para diferentes séries temporais (sazonalidade, heterocedasticidade, múltiplos períodos de previsão, entre outras). Apesar de produzirem bons resultados, eventualmente precisam ser analisados manualmente para a melhor definição da forma de aplicação do método (NGO, 2013).

### 3.6.5 Classe de Métodos de Redes Neurais Artificiais

As redes neurais artificiais são mais recentes e receberam maior atenção a partir do aumento da capacidade computacional. Foram desenvolvidas por volta de 1990 (ZHANG; PATUWO; HU, 1998) e estão em constantemente aperfeiçoamento. Existem múltiplas variações desses dos métodos de RNA (híbridos, recorrentes, de múltiplas camadas, entre outras). Por um lado, são capazes de modelar funções não-lineares a partir de seus neurônios. Por outro, utilizam fórmulas que não são facilmente entendidas, tornando-se “caixas pretas”. Como consequência, embora a capacidade de previsão desses métodos seja grande, pois os algoritmos podem ser moldados em múltiplas dimensões de acordo com a série temporal analisada, esses métodos não são amplamente utilizados por tomadores de decisão em razão de sua elevada complexidade (SAMARASINGHE, 2016).

## 3.7 COMPARAÇÃO ENTRE AS CLASSES DE MÉTODOS

Há consenso entre os principais pesquisadores de que o método ingênuo e os métodos de decomposição não fornecem previsões precisas, e, portanto, não devem ser utilizados (CHASE, 2009; HYNDMAN; ATHANASOPOULOS, 2014b). Entretanto, há divergências sobre qual é a mais precisa das três classes de métodos restantes (suavização exponencial, ARIMA e redes neurais artificiais).

Alguns pesquisadores obtêm previsões mais precisas com a utilização exclusiva de algum método pertencente a alguma dessas classes de métodos. Alternativamente, outros propõem a utilização de métodos híbridos (utilização simultânea de classes de métodos distintas em um mesmo método) para alcançar maior precisão. Todavia, as pesquisas sobre essas diferentes abordagens foram embasadas em uma pequena quantidade de séries temporais específicas (BRENTAN et al., 2017; JAIPURIA; MAHAPATRA, 2014; KOURENTZES; PETROPOULOS; TRAPERO, 2014; PETROPOULOS et al., 2014; RUIZ-AGUILAR; TURIAS; JIMNEZ-COME, 2014; SHAHRABI; HADAVANDI; ASADI, 2013; WANG; ZENG; CHEN, 2015). Dessa forma, não há consenso sobre qual das três é a mais precisa classe de métodos genéricos de

previsão de demanda baseada em séries temporais, tampouco sobre a existência de um método híbrido que seja superior aos demais métodos em análises preditivas de séries temporais genéricas.

Adicionalmente, há dissenso sobre a classe de métodos a ser aplicada pelo tomador de decisão, considerando o quesito facilidade de aplicação – não foram encontradas pesquisas recentes com esse propósito específico que abordassem essas três classes de métodos.

Quadro 3 – Comparação entre as classes de métodos quantitativos de previsão de demanda baseados em séries temporais - 2017

<b>Classe de Métodos</b>	<b>Precisão</b>	<b>Facilidade de Aplicação</b>	<b>Década de Maior Desenvolvimento</b>
Ingênuo	Baixa	Alta	-
Decomposição	Baixa	Média	1920
Suavização Exponencial	Média	Média	1990
ARIMA	Alta	Média	2000
Redes Neurais Artificiais	Alta	Baixa	2010

Fonte: elaborado pelo autor.

## 4 PROCEDIMENTOS METODOLÓGICOS

Os procedimentos metodológicos para a elaboração deste trabalho de monografia serão compostos por sete etapas. Nos próximos subcapítulos, as atividades executadas serão listadas, detalhadas e apresentadas cronologicamente.

### 4.1 ESTUDO BIBLIOGRÁFICO DOS MÉTODOS DE PREVISÃO

Primeiramente, foi realizada uma análise da bibliografia existente com o objetivo de entender quais são os principais métodos genéricos de previsão de demanda por séries temporais utilizados atualmente. A análise bibliográfica foi executada através da revisão dos principais artigos e livros existentes na área de previsão de demanda por séries temporais. Os documentos foram sintetizados e citados, de modo a representar o conhecimento científico existente até o momento da realização desse trabalho.

Para tanto, os métodos foram abordados em conjunto com as classes de métodos às quais pertencem. As limitações e vantagens dos principais métodos genéricos foram debatidas e comparadas, servindo de insumo para a pesquisa desenvolvida nesse trabalho.

### 4.2 COLETA DE DADOS

Após uma revisão dos conceitos bibliográficos, como citado no subcapítulo anterior, realizou-se a coleta de dados de séries temporais de volume de vendas de cinco empresas, segregadas por produto ou por linha de produtos (número de unidades vendidas por mês). O objetivo dessa etapa foi obter séries temporais reais de três anos, com comportamentos variados, que de fato representem o dia-a-dia dos tomadores de decisão. Foi coletada a maior quantidade possível de séries temporais, para que os resultados do trabalho possuíssem maior confiabilidade estatística.

As séries temporais coletadas não iniciaram simultaneamente. Cada uma delas representa um conjunto de 36 meses distinto, ou seja, a data de início e término das séries temporais não é a mesma.

A obtenção dos dados foi realizada digitalmente. O autor entrou em contato com gestores de empresas com os quais possui relacionamento pessoal. A partir dos vínculos pessoais existentes e da confiança recebida, o autor solicitou séries temporais contendo três anos de volume de vendas aos gestores responsáveis.

Os cinco gestores que concordaram em ceder as séries temporais extraíram os dados necessários dos sistemas digitais de suas respectivas empresas. Os dados foram exportados para bases digitais em formato de planilha (txt, xlsx, entre outros) conforme a viabilidade técnica dos sistemas digitais de cada uma das empresas. Na sequência, os gestores enviaram os dados por meio eletrônico (e-mail) ao autor.

#### 4.3 LIMPEZA DOS DADOS

Em um terceiro momento, as séries temporais recebidas pelo autor foram limpas, com o objetivo de eliminar imperfeições nos dados que inviabilizariam análises. Dessa forma, a obtenção de previsões tornou-se tecnicamente viável.

Para limpar os dados, o autor analisou visualmente cada uma das séries temporais e identificou valores incorretos ou imperfeitos. Adicionalmente, realizou o transporte dos dados nos formatos recebidos para uma planilha digital no software Excel®, que acusaria possíveis erros nos dados observados.

As imperfeições observadas foram, quando possível, corrigidas manualmente. No caso de impossibilidade de recuperar com precisão algum valor original observado em determinada série temporal, a série temporal em questão foi descartada. Todas as séries temporais que não eram confiáveis quanto à integridade dos dados foram excluídas da análise.

As séries temporais íntegras foram transformadas em séries temporais mensais por meio de planilhas eletrônicas, resultando em 36 períodos por série, de um

mês cada. Desses 36 períodos, os 30 primeiros foram utilizados para aprendizado dos métodos e os seis para teste das previsões geradas pelos métodos.

As séries temporais que apresentaram padrões não usuais não foram excluídas da análise, a não ser que os padrões não usuais fossem decorrentes de medições equivocadas.

Após a limpeza do dados e exclusão das séries temporais não íntegras, resultaram 31 séries temporais confiáveis, de 5 empresas, para a realização das análises. Abaixo segue o detalhamento das séries temporais obtidas com as cinco empresas, denominadas, pelo autor, de empresas “A”, “B”, “C”, “D” e “E”.

Quadro 4 – Detalhamento das séries temporais obtidas - 2017

<b>Empresa</b>	<b>Atuação</b>	<b>Quantidade de Séries Temporais Confiáveis</b>	<b>Segregação das Séries Temporais</b>
A	Produtora de Papelão	1	Linha de Produto
B	Varejista de Farmácia	12	Linha de Produto
C	Produtora de Acessórios de Celulares	12	Produto
D	Transporte Aéreo de Passageiros	1	Linha de Produto
E	Varejista de Colchões	5	Produto

Fonte: elaborado pelo autor.

#### 4.4 OBTENÇÃO DOS SOFTWARES PARA REALIZAR ANÁLISES

Em quarto lugar, foram obtidas as aplicações digitais necessárias para a execução dos métodos de previsão abordados previamente na análise bibliográfica. O autor pesquisou na internet e na bibliografia existente softwares gratuitos (mesmo que em período de testes) capazes de realizar com confiabilidade as análises das séries temporais, para cada um dos métodos de previsão. Os softwares foram obtidos eletronicamente e instalados no computador pessoal do autor. Cada software foi

utilizado para a execução de uma ou mais aplicações de métodos de previsão de demanda por séries temporais, conforme detalhamento abaixo.

Quadro 5 – Softwares e funções utilizados para a obtenção de previsões - 2017

<b>Método</b>	<b>Software Utilizado</b>	<b>Função Utilizada para Obtenção de Previsões</b>
INGÊNUO	Excel	-
ADITI	Excel	Desenvolvida pelo autor
MULTI	Excel	Desenvolvida pelo autor
EXPSIMPLES	Excel + Solver	Desenvolvida pelo autor
HOLT	Excel + Solver	Desenvolvida pelo autor
WINTERS	Excel + Solver	Desenvolvida pelo autor
AR	Excel + XLSTAT	Forecast - ARIMA
MA	Excel + XLSTAT	Forecast - ARIMA
ARMA	R	auto.arima
ARIMA	R	auto.arima
SARIMA	R	auto.arima
RAAUNI	-	-
RAAMULTI	R	nnetar
RECOR	-	-

Fonte: elaborado pelo autor.

Depois de devidamente instalados os softwares, o autor testou-os com séries temporais públicas, para a certificação de que estivessem operando corretamente. Quando foram necessárias intervenções nos softwares (programações ou modelagens) para a execução das análises propostas no presente trabalho, o autor as realizou.

Dessa forma, os softwares estavam disponíveis para o trabalho conforme a necessidade. Na sequência, realizou a análise dos dados coletados. Nesse momento, iniciou a aplicação dos métodos de previsão propostos nesse trabalho.

#### 4.5 APLICAÇÃO DOS MÉTODOS DE PREVISÃO

Os softwares obtidos previamente foram alimentados com os dados referentes às séries temporais já limpas. A forma pela qual os softwares foram alimentados variou em função de três fatores: estrutura técnica e linguagem de programação presente em cada software; modo de aprendizado e treinamento requerido por cada um dos métodos aplicados e; capacidade técnica do autor.

Os dados foram alimentados aos softwares de forma que geraram previsões para os seis próximos períodos, conforme cada um dos métodos de previsão. Os valores previstos para os seis próximos períodos foram arquivados em planilhas digitais para que o autor obtivesse e analisasse os resultados do trabalho.

#### 4.6 OBTENÇÃO DOS RESULTADOS

Em sexto lugar, as previsões geradas pelos softwares foram comparadas aos valores reais observados nos seis últimos períodos de cada série temporal a partir do teste estatístico de precisão amplamente aceito Média Absoluta Percentual dos Erros - MAPE. O resultado do teste, que mediu o erro de cada uma das previsões, providenciou informações relevantes quanto à precisão de cada um dos métodos utilizados, possibilitando a análise dos resultados.

Adicionalmente, o autor aplicou uma variação no MAPE, para que a comparação realizada entre os métodos quanto ao quesito precisão se tornasse mais realista. A variação aplicada, nomeada de MAPEMAX pelo autor, foi descrita posteriormente.

Os testes estatísticos realizados com cada método foram segregados em seis grupos: MAPE e MAPEMAX, segregados pela quantidade de períodos projetados adiante; MAPE e MAPEMAX, segregados por empresa analisada e; MAPE e MAPEMAX geral. Dessa forma, tornou-se possível comparar a precisão dos métodos entre si.



#### 4.7 ANÁLISE DOS RESULTADOS

Por fim, os resultados obtidos pelos testes estatísticos de precisão foram analisados pelo autor. Dessa forma, os métodos de previsão de demanda foram comparados entre si quanto a dois quesitos: facilidade de aplicação e precisão. O método aprovado no quesito facilidade de aplicação e que apresentou a maior precisão foi escolhido como o melhor método para o tomador de decisão.

Os resultados encontrados foram comparados à análise bibliográfica estabelecida previamente, com enfoque na percepção de possíveis diferenças entre os resultados obtidos através desse trabalho e os resultados obtidos através dos trabalhos de outros autores. Portanto, buscou-se divergir ou convergir de outros autores quanto à precisão dos métodos testados nesse trabalho, ampliando o conhecimento científico existente sobre previsão de demanda por séries temporais.

## 5 RESULTADOS

Os resultados foram divididos em três blocos: Facilidade de Aplicação dos Métodos, Precisão dos Métodos e Escolha do Melhor Método.

### 5.1 FACILIDADE DE APLICAÇÃO DOS MÉTODOS

Cada método abordado no presente trabalho foi avaliado quanto à sua facilidade de aplicação a partir dos critérios mencionados e detalhados previamente: Disponível; Adaptável; Automático; Genérico; Independente; Escalável e Simples. A avaliação de cada método a partir de cada critério foi definida como “S” (segue os critérios mencionados) ou “N” (não segue os critérios mencionados). Nos casos de avaliação “N”, foi fornecida justificativa para tal.

Os métodos que receberem avaliação “N” em qualquer um dos critérios não foram analisados quanto às suas precisões, em virtude da inviabilidade de aplicação prática dos respectivos métodos pelos tomadores de decisão. Dessa forma, esses métodos foram reprovados e excluídos da parte de testes do presente trabalho. Os métodos que receberam avaliação “S” em todos os critérios foram aprovados, e, posteriormente, avaliados quanto às suas precisões.

#### 5.1.1 Avaliação da Facilidade de Aplicação dos Métodos

Quadro 6 – Avaliação dos métodos de previsão de demanda baseados em séries temporais quanto à facilidade de aplicação – 2017

<b>Critério</b> <b>Método</b>	<b>Disponível</b>	<b>Adaptável</b>	<b>Automático</b>	<b>Genérico</b>	<b>Independente</b>	<b>Escala</b>	<b>Simples</b>
INGÊNUO	S	S	S	S	S	S	S
ADITI	S	S	S	S	S	S	S
MULTI	S	S	S	S	S	S	S
EXPSIMPLES	S	S	S	S	S	S	S
HOLT	S	S	S	S	S	S	S

WINTERS	S	S	S	S	S	S	S
AR	S	S	S	S	S	S	S
MA	S	S	S	S	S	S	S
ARMA	S	S	S	S	S	S	S
ARIMA	S	S	S	S	S	S	S
SARIMA	S	S	S	S	S	S	S
RAAUNI	N	S	S	S	S	S	N
RAAMULTI	S	S	S	S	S	S	S
RECOR	S	N	S	S	S	S	N

Fonte: elaborado pelo autor.

### 5.1.2 Justificativas das Avaliações Negativas da Facilidade de Aplicação dos Métodos

Quadro 7 – Justificativas das avaliações negativas dos métodos de previsão de demanda baseados em séries temporais quanto a critérios de facilidade de aplicação – 2017

<b>Método</b>	<b>Critério Avaliado Negativamente</b>	<b>Justificativa</b>
RAAUNI	Disponível	Não foi encontrada pelo autor ferramenta pública que possibilitasse a aplicação do método. A ausência de ferramentas para a aplicação desse método pode ser explicada por sua baixa aplicabilidade prática (em virtude de ser complexo e impreciso).
RAAUNI	Simple	Os softwares disponibilizados publicamente para a aplicação do método demandam extenso conhecimento técnico para a programação e aplicação desse método. Não há função pré-programada, simples e direta para a obtenção de previsões a partir desse método, sendo necessário o desenvolvimento de algoritmos – o que inviabiliza a sua utilização pelo tomador de decisão.
RECOR	Adaptável	Os softwares disponibilizados publicamente para a aplicação do

		método demandam análises e transformações manuais prévias nos dados. Não é possível simplesmente inserir os dados das séries temporais em suas formas originais nos softwares.
RECOR	Simple	Os softwares disponibilizados publicamente para a aplicação do método demandam extenso conhecimento técnico para a programação e aplicação desse método. Não há função pré-programada, simples e direta para a obtenção de previsões a partir desse método, sendo necessário o desenvolvimento de algoritmos – o que inviabiliza a sua utilização pelo tomador de decisão.

Fonte: elaborado pelo autor.

### 5.1.3 Resultados da Avaliação da Facilidade de Aplicação dos Métodos

Considerando a análise dos métodos a partir dos critérios de facilidade de aplicação, foram obtidos os seguintes resultados:

Quadro 8 – Resultados da avaliação dos métodos de previsão de demanda baseados em séries temporais quanto a critérios de facilidade de aplicação – 2017

<b>Método</b>	<b>Resultado</b>
INGÊNUO	Aprovado
ADITI	Aprovado
MULTI	Aprovado
EXPSIMPLES	Aprovado
HOLT	Aprovado
WINTERS	Aprovado
AR	Aprovado
MA	Aprovado
ARMA	Aprovado
ARIMA	Aprovado

SARIMA	Aprovado
RAAUNI	Reprovado
RAAMULTI	Aprovado
RECOR	Reprovado

Fonte: elaborador pelo autor.

## 5.2 PRECISÃO DOS MÉTODOS

A precisão dos métodos, determinada a partir da análise do MAPE, está segregada abaixo de duas maneiras: por período projetado adiante e por empresa analisada.

### 5.2.1 MAPE Segregado por Período Projetado Adiante

Quadro 9 – MAPE segregado por período projetado adiante – 2017

<b>Período</b> <b>Método</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
INGÊNUO	0,28	0,48	0,53	0,89	1,20	2,14
ADITI	2,09	7,47	7,03	13,05	9,17	14,55
MULTI	2,84	19,23	10,45	29,51	19,96	23,97
EXPSIMPLES	0,24	0,46	0,52	0,87	1,18	2,12
HOLT	0,39	0,61	0,78	1,19	2,11	2,90
WINTERS	0,51	0,83	1,60	1,94	5,20	6,23
AR	0,41	2,42	2,76	5,75	6,95	9,98
MA	1,07	8,04	8,90	19,17	16,41	21,24
ARMA	0,28	0,39	0,41	1,08	1,01	1,91
ARIMA	0,44	0,88	1,19	2,46	4,24	6,23
SARIMA	0,91	1,75	2,69	4,27	9,08	10,84
RAAMULTI	0,49	0,53	3,05	3,06	2,63	7,98

Fonte: elaborado pelo autor.

A partir dos resultados verificados acima, percebe-se que a precisão média dos modelos (mensurada a partir do MAPE) é significativamente baixa. Em múltiplos casos o MAPE é maior do que 1 (o que representa um erro de previsão maior do que 100% do valor observado). A partir do MAPE segregado por empresa analisada, busca-se entender a razão da tamanha imprecisão dos métodos.

### 5.2.2 MAPE Segregado por Empresa Analisada

Quadro 10 – MAPE segregado por empresa analisada – 2017

<b>Período</b> <b>Método</b>	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>	<b>E</b>
INGÊNUO	0,08	0,24	1,89	0,19	0,54
ADITI	0,06	0,13	22,62	0,02	0,51
MULTI	0,06	0,13	45,26	0,05	0,51
EXPSIMPLES	0,06	0,21	1,88	0,19	0,50
HOLT	0,06	0,25	2,88	0,25	0,65
WINTERS	0,07	0,19	6,45	0,04	0,87
AR	0,06	0,12	11,85	0,14	0,45
MA	0,06	0,14	31,87	0,05	0,46
ARMA	0,07	0,14	1,84	0,12	0,44
ARIMA	0,07	0,16	6,27	0,19	0,48
SARIMA	0,07	0,18	12,33	0,19	0,48
RAAMULTI	0,09	0,19	7,20	0,03	0,57

Fonte: elaborado pelo autor.

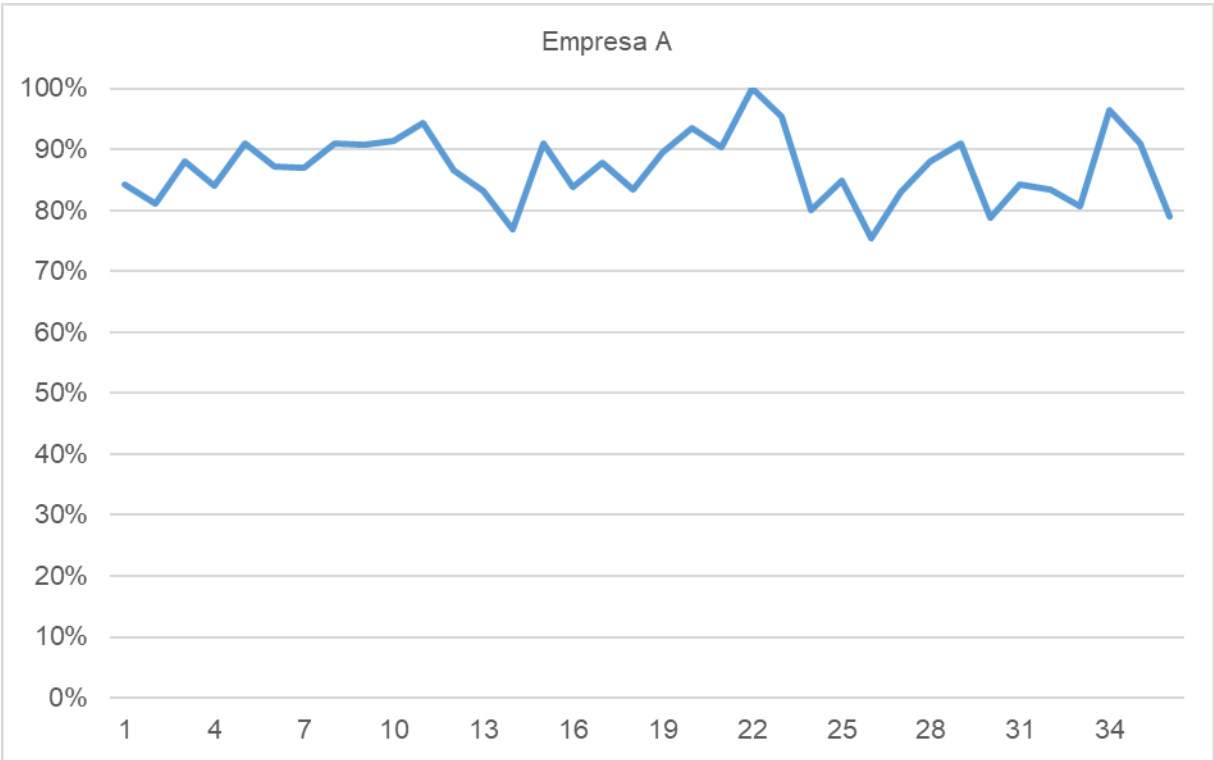
Considerando a segregação do MAPE por empresa analisada, percebe-se que a empresa “C” é uma exceção: para esta empresa, o MAPE de todos os métodos foi maior do que 1, ao passo que para as demais empresas, o MAPE de todos os métodos foi inferior a este número. Dessa forma, faz-se necessária uma análise desse acontecimento.

Para isso, as séries históricas de cada empresa serão analisadas graficamente, buscando-se entender o comportamento das séries temporais ao longo do tempo. Mais precisamente, procura-se entender qual a diferença entre as séries históricas da empresa “C” e as séries históricas das demais empresas.

### **5.2.3 Análise Gráfica das Séries Temporais**

A seguir, serão disponibilizadas graficamente as séries temporais das cinco empresas analisadas. As 30 primeiras observações de cada série temporal foram utilizadas para o aprendizado, enquanto as últimas seis foram utilizadas para teste. Para facilitar a visualização das séries temporais e preservar a confidencialidade das empresas, os valores das séries temporais estão dispostos em termos percentuais do maior valor observado em cada série. Cada linha do gráfico representa uma série temporal.

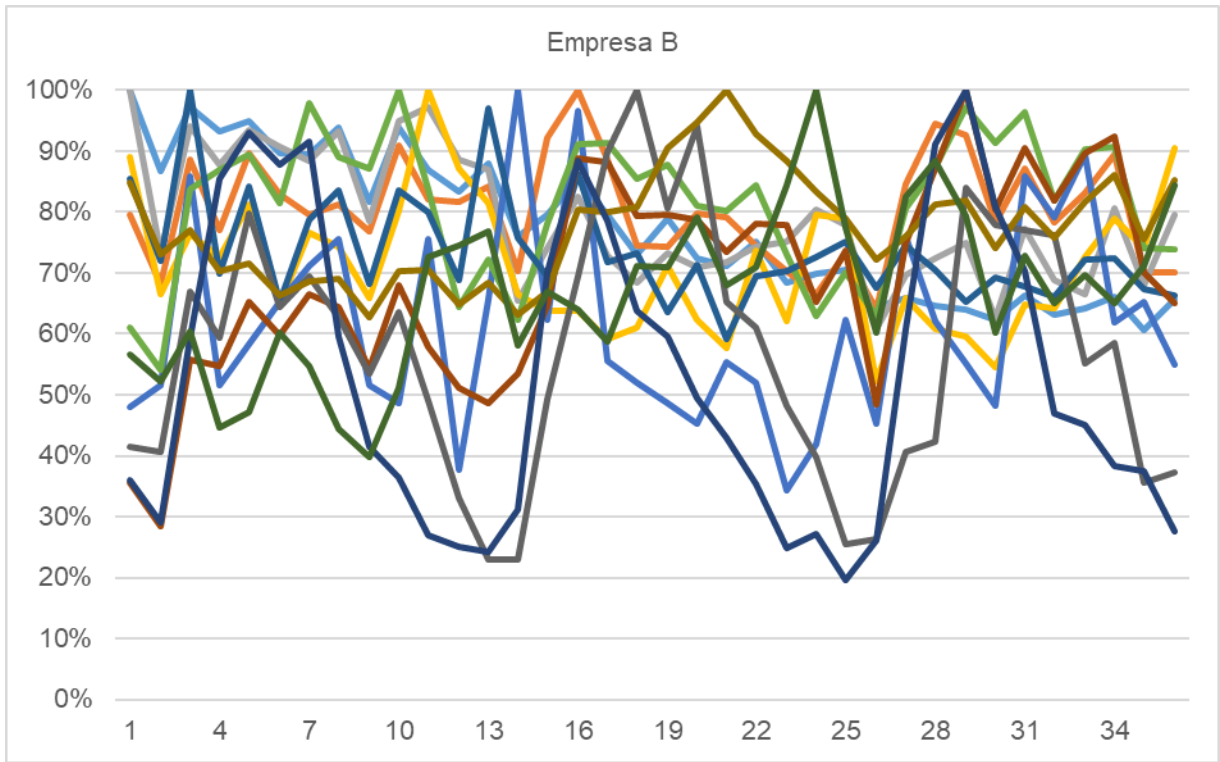
Gráfico 1 – Série Temporal da Empresa A – 2017



Fonte: elaborador pelo autor.




Gráfico 2 – Séries Temporais da Empresa B – 2017




Fonte: elaborador pelo autor.

Gráfico 3 – Séries Temporais da Empresa C – 2017




Fonte: elaborador pelo autor.

Gráfico 4 – Série Temporal da Empresa D – 2017



Fonte: elaborador pelo autor.

Gráfico 5 – Séries Temporais da Empresa E – 2017



Fonte: elaborado pelo autor.

Observa-se que as séries temporais da empresa “C” possuem comportamento diferente das demais, principalmente nos períodos utilizados para teste dos métodos (últimos seis períodos). Ao passo que 10 das 12 séries temporais da empresa “C” apresentam valores abaixo dos 10% (muito próximos de zero) nos últimos seis períodos, todas séries temporais das demais empresas possuem valores que oscilam entre 10% e 100% (do maior valor de cada série histórica) nos últimos seis períodos. Isso ocorre porque os produtos vendidos pela empresa “C” possuem um ciclo de vida pequeno (menos de 36 períodos). Ou seja, a quantidade de unidades vendidas nos últimos 12 meses de cada série temporal do produto tende a ser próxima de zero.

O MAPE é calculado em termos percentuais e considera a diferença entre o valor observado e o valor previsto, para cada um dos períodos previstos. Dessa forma, se o valor observado para algum dos períodos previstos tender a zero, o MAPE tenderá ao infinito (o erro absoluto da previsão, por menor que seja, terá enorme impacto no erro

percentual). Assim, nota-se que, apesar de o MAPE ser extremamente alto para as séries temporais da empresa “C”, os erros das projeções, em valores absolutos, não são necessariamente grandes.

Para solucionar o problema de o MAPE ser extremamente alto para valores próximos de zero, é proposta abaixo uma variação do MAPE para a avaliação da precisão dos métodos.

#### 5.2.4 Alternativa ao MAPE para Análise da Precisão dos Métodos

A alternativa ao MAPE desenvolvida pelo autor - MAPEMAX - consiste na realização de uma modificação simples para a medição da precisão dos métodos de previsão. Abaixo, será demonstrada a fórmula do MAPE tradicional, e também a fórmula do MAPEMAX, desenvolvido pelo autor:

$$MAPE = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - Z_t}{y_t} \right|$$

$Z$	Valor previsto da série para cada período;
$t$	Cada um dos períodos previstos;
$n$	Quantidade de períodos previstos;
$y$	Valor observado para cada período previsto.

$$MAPEMAX = \frac{100}{n} \sum_{t=1}^n \left| \frac{y_t - Z_t}{h} \right|$$

$Z$	Valor previsto da série para cada período;
$t$	Cada um dos períodos previstos;
$n$	Quantidade de períodos previstos;
$y$	Valor observado para cada período previsto;
$h$	Maior valor observado nos períodos de aprendizado.

O MAPE tradicional mede o percentual de erro da previsão de cada período em relação ao valor observado de cada período e depois realiza uma média de seus percentuais. O MAPEMAX, por sua vez, mede o percentual de erro de cada período da previsão em relação ao maior valor observado no período de aprendizado da série temporal e depois realiza uma média de seus percentuais. Assim, o segundo método considera apropriadamente a relevância da previsão em relação à série histórica, pois assume que o erro percentual nas previsões para quantidades de unidades vendidas próximas de zero não é representativo para o tomador de decisão.

### 5.2.5 MAPEMAX Segregado por Período Projetado Adiante

Quadro 11 – MAPEMAX segregado por período projetado adiante – 2017

<b>Período</b> <b>Método</b>	<b>1</b>	<b>2</b>	<b>3</b>	<b>4</b>	<b>5</b>	<b>6</b>
INGÊNUO	0,16	0,18	0,26	0,38	0,50	0,54
ADITI	0,40	0,32	0,38	0,44	0,42	0,56
MULTI	0,50	0,47	0,54	0,63	0,70	0,83
EXPSIMPLES	0,13	0,16	0,24	0,36	0,48	0,53
HOLT	0,18	0,23	0,32	0,42	0,56	0,62
WINTERS	0,29	0,37	0,69	0,87	1,08	1,13
AR	0,17	0,16	0,27	0,39	0,47	0,54
MA	0,22	0,26	0,37	0,56	0,62	0,68
ARMA	0,16	0,13	0,20	0,33	0,41	0,46
ARIMA	0,18	0,18	0,26	0,39	0,49	0,56
SARIMA	0,20	0,23	0,32	0,44	0,54	0,61
RAAMULTI	0,32	0,22	0,50	0,56	0,49	0,64

Fonte: elaborado pelo autor.

A partir dos resultados verificados acima, percebe-se que a precisão média dos modelos mensurada a partir do MAPEMAX é mais realista do que a precisão média projetada pelo MAPE. Somente em dois casos o MAPEMAX é maior do que 1 (o que representa um erro de previsão maior do que 100% do maior valor observado no período de aprendizagem da série histórica).

Observa-se que, para o 1º período projetado adiante, o método EXPSIMPLES possui o menor MAPEMAX (0,13). Para demais períodos (2º; 3º; 4º; 5º; e 6º) o método ARMA possui o menor MAPEMAX (0,13; 0,20; 0,33; 0,41; e 0,46). A tendência de aumento do MAPEMAX em função das quantidades de períodos projetados ocorre para todos os métodos.

### 5.2.6 MAPEMAX Segregado por Empresa Analisada

Quadro 12 – MAPEMAX segregado por empresa analisada – 2017

<b>Empresa</b> <b>Método</b>	<b>A</b>	<b>B</b>	<b>C</b>	<b>D</b>	<b>E</b>
INGÊNUO	0,08	0,21	0,22	0,19	1,00
ADITI	0,05	0,14	0,59	0,02	0,85
MULTI	0,05	0,14	1,11	0,05	0,78
EXPSIMPLES	0,06	0,18	0,22	0,19	0,97
HOLT	0,06	0,23	0,25	0,25	1,20
WINTERS	0,07	0,19	1,01	0,04	1,67
AR	0,06	0,12	0,37	0,14	0,86
MA	0,06	0,13	0,66	0,06	0,86
ARMA	0,07	0,13	0,23	0,12	0,86
ARIMA	0,07	0,15	0,33	0,19	0,92
SARIMA	0,06	0,17	0,44	0,19	0,92
RAAMULTI	0,09	0,19	0,57	0,03	0,96

Fonte: elaborado pelo autor.

A partir dos resultados verificados acima, percebe-se que a precisão média dos modelos mensurada a partir do MAPEMAX, segregada por empresa, é mais realista do que a precisão média projetada pelo MAPE. A comparação entre os erros se torna mais fácil. Somente em cinco casos o MAPEMAX é maior do que 1 (o que representa um erro de previsão maior do que 100% do maior valor de aprendizado observado da série histórica) e, em nenhum caso, o MAPEMAX é maior do que 2.

Observa-se que, para a empresa “A”, os métodos de decomposição ADITI e MULTI obtiveram os melhores resultados (MAPEMAX de 0,05). Para a empresa “B”, os métodos AR, MA e ARMA obtiveram os resultados mais precisos (MAPEMAX de 0,12; 0,13; e 0,13). A empresa “C” apresentou valores de MAPEMAX realistas, para os quais os métodos INGÊNUO, EMPSIMPLES e ARMA demonstraram os resultados mais precisos (MAPEMAX de 0,22; 0,22; e 0,23). Para a empresa “D”, os métodos ADITI e RAAMULTI foram os mais precisos (MAPEMAX de 0,02; e 0,03). Para a empresa “E”, o método mais preciso foi o MULTI (MAPEMAX de 0,78).

### 5.2.7 Precisão Geral dos Métodos

A precisão geral dos métodos será mesurada a partir dos dois critérios utilizados anteriormente (MAPE e MAPEMAX), levando simultaneamente em consideração todas as previsões realizadas. Os métodos serão ranqueados para cada um dos critérios, a partir do número um, em ordem do mais preciso para o menos preciso. Os rankings de cada critério serão somados. O método mais preciso será aquele que possuir a menor soma no valor da soma dos rankings.

Quadro 13 – Precisão geral dos métodos – 2017

<b>Critérios</b> <b>Método</b>	<b>MAPE</b>	<b>Ranking</b> <b>MAPE</b>	<b>MAPEMAX</b>	<b>Ranking</b> <b>MAPEMAX</b>	<b>SOMA</b> <b>Rankings</b>
INGÊNUO	0,919	3	0,336	4	7
ADITI	8,892	10	0,419	8	18
MULTI	17,659	12	0,612	11	23
EXPSIMPLES	0,897	2	0,317	2	4



HOLT	1,328	4	0,389	6	10
WINTERS	2,716	6	0,739	12	18
AR	4,712	8	0,334	3	11
MA	12,470	11	0,452	9	20
ARMA	0,847	1	0,284	1	2
ARIMA	2,572	5	0,342	5	10
SARIMA	4,925	9	0,391	7	16
RAAMULTI	2,957	7	0,456	10	17

Fonte: elaborado pelo autor.

Quadro 14 – Ranking de precisão geral dos métodos de previsão – 2017

<b>Método</b>	<b>Ranking GERAL</b>
ARMA	1
EXPSIMPLES	2
INGÊNUO	3
HOLT	4
ARIMA	5
AR	6
SARIMA	7
RAAMULTI	8
ADITI	9
WINTERS	10
MA	11
MULTI	12

Fonte: elaborado pelo autor.

### 5.3 ESCOLHA DO MELHOR MÉTODO

O melhor método de previsão de demanda para os tomadores de decisão é o ARMA, por dois motivos. Primeiro, ele foi aprovado em todos os critérios de facilidade de aplicação. Segundo, obteve a maior precisão entre os métodos testados.

Adicionalmente, percebe-se que o método EXPSIMPLES obteve, assim como o ARMA, aprovação nos critérios de facilidade de aplicação e precisão maior do que a fornecida pelo método INGÊNUO. Dessa forma, torna-se uma alternativa ao ARMA para os tomadores de decisão.

Os métodos considerados mais complexos e mais robustos (SARIMA, RAAMULTI, WINTERS) não apresentaram resultados satisfatórios: eles são menos precisos do que o método INGÊNUO ao serem aplicados automaticamente sobre as séries temporais. Portanto, não devem ser utilizados por tomadores de decisão.

Os métodos de redes neurais artificiais (RAAUNI, RAAMULTI e RECOR) mostraram-se insatisfatórios para os tomadores de decisão por duas razões. Primeiro, a aplicação de tais métodos não é simples, exige conhecimentos técnicos profundos. Somente um método de redes neurais artificiais foi aprovado nos critérios de facilidade de aplicação (RAAMULTI). Os demais métodos não podem ser replicados por gestores automaticamente e com facilidade. Segundo, a precisão do método RAAMULTI, o único dos três métodos de redes neurais artificiais que foi aprovado nos critérios de facilidade de aplicação, é insatisfatória. Seus resultados foram inferiores aos obtidos pelo método ingênuo.

### 5.4 COMPARAÇÃO COM RESULTADOS OBTIDOS POR OUTROS AUTORES

O presente trabalho fornece resultados surpreendentes quanto à escolha do melhor método de previsão de demanda para os gestores. O método ARMA, aprovado em todos os critérios de facilidade de aplicação e mais preciso que todos os outros

métodos testados, é simples e antigo. Utiliza apenas dois componentes e pode ser compreendido facilmente pelo tomador de decisão.

A partir do referencial teórico abordado nesse trabalho, nota-se que os métodos de séries temporais “evoluíram” muito a partir do ARMA, com o desenvolvimento de novos componentes e diferentes maneiras de realizar as projeções. Entretanto, a partir das análises realizadas pelo autor nesse trabalho, esses “avanços” não se mostraram úteis para o tomador de decisão.

Os resultados obtidos nesse trabalho contrariam os estudos dos principais pesquisadores de séries temporais, analisados no referencial teórico: os métodos ARMA e EXPSIMPLES foram os únicos que criaram valor para o tomador de decisão, ao se mostrarem mais precisos do que o método INGÊNUO. Os métodos desenvolvidos mais recentemente e que utilizam maior poder computacional (por exemplo: SARIMA, RAAUNI, RAAMULTI e RECOR) não apresentaram resultados práticos satisfatórios.

## 6 CONCLUSÕES EM IMPLICAÇÕES GERENCIAIS E METODOLÓGICAS

### 6.1 CONCLUSÕES E PRINCIPAIS RESULTADOS DA PESQUISA

O melhor método de previsão de demanda para tomadores de decisão é o ARMA, por dois motivos. Primeiro, é suficientemente fácil de ser aplicado, possibilitando a obtenção de previsões de demanda sem a necessidade de conhecimentos técnicos específicos. Segundo, é o mais preciso entre os métodos genéricos de previsão de demanda por séries temporais testados.

O segundo melhor método de previsão de demanda para gestores é o EXPSIMPLES, pois também é suficientemente fácil de ser aplicado e possui a segunda melhor precisão entre os métodos testados. Dessa forma, torna-se uma alternativa ao ARMA.

Todos os demais métodos de previsão de demanda aplicados nesse trabalho (exceto EXPSIMPLES e ARMA), incluindo métodos mais complexos e robustos, quando aplicados automaticamente, não são úteis aos tomadores de decisão, pois os resultados que geram são mais imprecisos do que os resultados gerados pelo método INGÊNUO. Dessa forma, os métodos de previsão de demanda mais recentes, que utilizam maior poder computacional (incluindo os métodos de redes neurais artificiais), não devem ser utilizados pelos gestores, já que geram previsões pouco precisas.

O MAPE não é uma forma eficaz de comparar a precisão de previsões de demanda quando os valores observados e previstos das séries temporais se encontram próximos de zero. Ao passo que os erros de previsão são medidos pelo MAPE em valores relativos aos valores observados em cada período, quando os valores observados nos períodos em que são realizadas as previsões tendem a zero, o erro observado das previsões, por menor que seja em valores absolutos, tende ao infinito em valores relativos, comprometendo a confiabilidade da comparação.

O MAPEMAX, forma de comparar precisão de métodos de previsão de demanda desenvolvida pelo autor, se mostra mais robusto que o MAPE ao comparar previsões de demanda entre diferentes séries temporais quando os valores observados das séries temporais tendem a zero ao longo do tempo. O MAPEMAX usa como

referência para o cálculo de erro de cada previsão, em cada série temporal, o valor mais alto observado no período de aprendizado da respectiva série temporal. Dessa forma, ao contrário do MAPE, não supervaloriza erros nas previsões em períodos que possuem valores observados próximos de zero.

## 6.2 PRINCIPAIS LIMITAÇÕES DA PESQUISA

A pesquisa apresenta quatro principais limitações, descritas abaixo.

A primeira é a relativa ausência de análise visual dos modelos de previsão gerados pelos métodos. Os métodos foram aplicados e selecionados pelos softwares automaticamente. Dessa forma, os modelos de previsão gerados pelos softwares para cada um dos métodos não foram visualizados pelo autor. Apesar de possuírem o menor erro possível nos períodos de aprendizado, talvez esses modelos não sejam confiáveis para a realização de previsões em razão de possíveis inconsistências ou variações presentes nos dados dos períodos de aprendizado.

A segunda limitação refere-se à utilização de séries temporais segregadas somente de forma mensal. Ao passo que a quantidade vendida mês a mês pelas empresas pode apresentar grandes variações em função das “entregas de mercadorias” e dos “pedidos de venda” realizados (principalmente nos casos das empresas “A” e “C”, que vendem somente para outras empresas, e não para o consumidor final), a utilização de séries temporais segregadas em períodos de tempo distintos (semanal, trimestral, semestral, etc.) poderia trazer resultados mais confiáveis nas previsões.

Em terceiro plano, à ausência de modificações prévias (eliminação da tendência, eliminação da sazonalidade, eliminação de *outliers*, normalização, eliminação de heterocedasticidade, entre outras) nos dados de aprendizagem das séries temporais, antes da aplicação dos métodos. Os dados obtidos com os gestores foram aplicados diretamente aos softwares depois de limpos, o que dificulta o aprendizado dos métodos e, conseqüentemente, a obtenção de previsões confiáveis.

Por último, foi utilizado somente um software para cada método de previsão. Caso os softwares utilizados não tenham gerado o melhor modelo de previsão possível

para cada um dos métodos, a análise da precisão dos métodos de séries temporais torna-se prejudicada.

### 6.3 HIPÓTESES PARA ESTUDOS FUTUROS

É necessária a realização de estudos futuros com o objetivo de replicar a metodologia utilizada nesse trabalho e compreender quais foram os motivos que levaram o ARMA e o EXPSIMPLES a serem os únicos métodos que geraram previsões mais precisas do que o método INGÊNULO. Para auxiliar na realização de estudos futuros, busca-se elencar algumas hipóteses que explicariam os resultados obtidos nesse trabalho:

a) as séries temporais analisadas possuem dados imprecisos e, apesar de estarem completas, não foram contabilizadas corretamente pelos gestores que as forneceram;

b) os métodos aplicados nesse trabalho não se mostram precisos em razão da ausência de modificações prévias manuais nos dados das séries temporais (eliminação da tendência, eliminação da sazonalidade, eliminação de *outliers*, normalização, eliminação de heterocedasticidade, entre outras);

c) os métodos aplicados nesse trabalho não podem ser automatizados, demandando julgamento humano acerca da pertinência das previsões geradas, com base em análises gráficas no momento da aplicação dos métodos;

d) os métodos de previsão de demanda não são genéricos e demandam comportamentos específicos das séries temporais para que sejam satisfatoriamente precisos.

e) os softwares e seus parâmetros utilizados nesse trabalho não são adequados e não geram o melhor modelo de previsão possível para cada um dos métodos.

São necessárias as seguintes considerações sobre as hipóteses previamente elencadas, respectivamente:

a) os dados encaminhados pelos gestores ao autor representam os registros contábeis que suas empresas possuem. Dessa forma, demonstram fielmente os dados que as organizações utilizam diariamente. Ao passo que os métodos de previsão de demanda são alimentados, em termos práticos, com séries temporais imperfeitas, a comparação entre a precisão dos métodos neste cenário ainda se mostra válida.

b) os tomadores de decisão não possuem conhecimento teórico específico para a realização de alterações prévias nos dados. Portanto, se faz necessário o seguinte questionamento: métodos que dependem de alterações prévias nos dados são úteis aos gestores?

c) quando é necessário julgamento humano sobre as previsões geradas pelos métodos, a escalabilidade destes é reduzida. Adicionalmente, demanda-se conhecimento técnico especializado, indisponível aos tomadores de decisão. Ademais, as previsões geradas deixam de ser imparciais, pois passam a depender de julgamentos efetuados pelos tomadores de decisão no momento de aplicação dos métodos.

d) métodos de previsão de demanda, ao serem aplicados por tomadores de decisão que não possuem conhecimento específico, devem ser genéricos: é inviável a identificação de padrões contidos nas séries temporais sem que exista profunda compreensão teórica.

e) os tomadores de decisão não possuem condições técnicas de avaliar se os softwares de previsão de demanda utilizados por eles geram os melhores modelos de previsão. Assim, métodos que possuem grande variabilidade quanto à consistência dos modelos gerados são pouco confiáveis.

A partir das hipóteses elencadas, são sugeridas as seguintes análises em estudos futuros:

a) Utilização de séries temporais distintas e em maior quantidade na replicação desse trabalho;

b) Realização de modificações manuais nas séries temporais antes de serem aplicadas aos métodos;

c) Realização de análise gráfica, visual, dos modelos gerados pelos métodos de previsão de demanda, individualmente;

d) Utilização de séries temporais que apresentem padrões específicos para cada um dos métodos de previsão empregados nesse trabalho;

e) Utilização de softwares diferentes e variados para a aplicação dos métodos.



## REFERÊNCIAS

- ABDEL-AAL, R. E. Univariate modeling and forecasting of monthly energy demand time series using abductive and neural networks. **Computers & Industrial Engineering**, v. 54, n. 4, p. 903–917, maio 2008.
- ARCHER, B. H. Forecasting demand: quantitative and intuitive techniques. **International Journal of Tourism Management**, v. 1, n. 1, p. 5–12, 1980.
- ARMSTRONG, J. S. Selecting forecasting methods. In: **Principles of forecasting**. [s.l.] Springer, 2001a. p. 365–386.
- ARMSTRONG, J. S. **Principles of forecasting: a handbook for researchers and practitioners**. Boston, MA: Kluwer Academic, 2001b.
- BAKHARY, N.; YAHYA, K.; NG, C. N. Univariate Artificial Neural Network in Forecasting Demand of Low Cost House in Petaling Jaya. **Jurnal Teknologi**, v. 40, n. 1, p. 1–16, 2012.
- BRENTAN, B. M. et al. Hybrid regression model for near real-time urban water demand forecasting. **Journal of Computational and Applied Mathematics**, v. 309, p. 532–541, jan. 2017.
- BROCKWELL, P. J.; DAVIS, R. A. **Introduction to time series and forecasting**. 2nd ed ed. New York: Springer, 2002.
- CHASE, C. **Demand-driven forecasting: a structured approach to forecasting**. Hoboken, N.J: John Wiley & Sons, 2009.
- CHATFIELD, C. **The analysis of time series: an introduction**. [s.l.] CRC press, 2016.
- CHU, F.-L. Forecasting tourism demand with ARMA-based methods. **Tourism Management**, v. 30, n. 5, p. 740–751, out. 2009.
- CIPRA, T. Robust exponential smoothing. **Journal of Forecasting**, v. 11, n. 1, p. 57–69, 1992.
- CLAVERIA, O.; TORRA, S. Forecasting tourism demand to Catalonia: Neural networks vs. time series models. **Economic Modelling**, v. 36, p. 220–228, jan. 2014.
- CORSTEN, D.; GRUEN, T. Desperately seeking shelf availability: an examination of the extent, the causes, and the efforts to address retail out-of-stocks. **International Journal of Retail & Distribution Management**, v. 31, n. 12, p. 605–617, dez. 2003.
- DAVIS, M. M.; CHASE, R. B.; AQUILANO, N. J. **Fundamentos Da Administracao Da Producao**. [s.l.] Bookman, 2001.

DE GOOIJER, J. G.; HYNDMAN, R. J. 25 years of time series forecasting. **International journal of forecasting**, v. 22, n. 3, p. 443–473, 2006.

EMMELHAINZ, M. A.; STOCK, J. R.; EMMELHAINZ, L. W. Consumer responses to retail stock-outs. **Journal of Retailing Summer**, 1991.

ESPER, T. L. et al. Demand and supply integration: a conceptual framework of value creation through knowledge management. **Journal of the Academy of Marketing Science**, v. 38, n. 1, p. 5–18, fev. 2010.

FRANSES, P. H.; DIJK, D. VAN; OPSCHOOR, A. **Time series models for business and economic forecasting**. Second edition ed. United Kingdom: Cambridge University Press, 2014.

GARDNER, E. S. Exponential smoothing: The state of the art. **Journal of forecasting**, v. 4, n. 1, p. 1–28, 1985.

GARDNER, E. S.; DANNENBRING, D. G. Forecasting with exponential smoothing: Some guidelines for model selection. **Decision Sciences**, v. 11, n. 2, p. 370–383, 1980.

GELPER, S.; FRIED, R.; CROUX, C. Robust forecasting with exponential and Holt-Winters smoothing. **Journal of Forecasting**, p. n/a-n/a, 2009.

GEURTS, M. D.; IBRAHIM, I. B. Comparing the Box-Jenkins Approach with the Exponentially Smoothed Forecasting Model Application to Hawaii Tourists. **Journal of Marketing Research**, v. 12, n. 2, p. 182, maio 1975.

GOODWIN, P. The holt-winters approach to exponential smoothing: 50 years old and going strong. **Foresight**, v. 19, p. 30–33, 2010.

GOODWIN, P.; ÖNKAL, D.; THOMSON, M. Do forecasts expressed as prediction intervals improve production planning decisions? **European Journal of Operational Research**, v. 205, n. 1, p. 195–201, ago. 2010.

GRUEN, T. W.; CORSTEN, D. S. A comprehensive guide to retail out-of-stock reduction in the fast-moving consumer goods industry. 2007.

HAMILTON, J., D. **Time Series Analysis**. [s.l.] Princeton University Press, 1994.

HARRISON, A.; HOEK, R. I. VAN. **Logistics management and strategy: competing through the supply chain**. 3rd ed ed. Harlow, England ; New York: Prentice Hall Financial Times, 2008.

HYNDMAN, R. J. et al. A state space framework for automatic forecasting using exponential smoothing methods. **International Journal of Forecasting**, v. 18, n. 3, p. 439–454, 2002.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice.** [s.l.] OTexts., 2014a.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice.** [s.l.] OTexts., 2014b.

INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS; INTERNATIONAL ISLAMIC UNIVERSITY MALAYSIA (EDS.). **2008 International Conference on Computer and Communication Engineering: [ICCCE 08]; Kuala Lumpur, Malaysia, 13 - 15 May 2008; [part of IIUM Engineering Congress 2008].** Piscataway, NJ: IEEE Service Center, 2008.

JAIPURIA, S.; MAHAPATRA, S. S. An improved demand forecasting method to reduce bullwhip effect in supply chains. **Expert Systems with Applications**, v. 41, n. 5, p. 2395–2408, abr. 2014.

KALEKAR, P. S. Time series forecasting using holt-winters exponential smoothing. **Kanwal Rekhi School of Information Technology**, v. 4329008, p. 1–13, 2004.

KIRBY, H. R.; WATSON, S. M.; DOUGHERTY, M. S. Should we use neural networks or statistical models for short-term motorway traffic forecasting? **International Journal of Forecasting**, 1997.

KLING, J. L.; BESSLER, D. A. A comparison of multivariate forecasting procedures for economic time series. **International Journal of Forecasting**, v. 1, n. 1, p. 5–24, 1985.

KOURENTZES, N.; PETROPOULOS, F.; TRAPERO, J. R. Improving forecasting by estimating time series structural components across multiple frequencies. **International Journal of Forecasting**, v. 30, n. 2, p. 291–302, abr. 2014.

LAWRENCE, M.; O'CONNOR, M.; EDMUNDSON, B. A field study of sales forecasting accuracy and processes. **European Journal of Operational Research**, v. 122, n. 1, p. 151–160, 2000.

LEE, H. L. **Ultimate enterprise value creation using demand-based management.** Stanford Global Supply Chain Management Forum. **Anais...**2001

LINSTONE, H. A.; TUROFF, M. The Delphi Method. **Techniques and applications**, v. 53, 2002.

MAIER, H. R.; DANDY, G. C. Neural networks for the prediction and forecasting of water resources variables: a review of modelling issues and applications. **Environmental modelling & software**, v. 15, n. 1, p. 101–124, 2000.

MAKRIDAKIS, S. **The art and science of forecasting: an assessment and future directions.** [s.l.] INSEAD, 1985.

MAKRIDAKIS, S. G. **Forecasting, planning, and strategy for the 21st century.** 1990.

MENTZER, J. T.; COX, J. E. Familiarity, application, and performance of sales forecasting techniques. **Journal of Forecasting**, v. 3, n. 1, p. 27–36, 1984.

MENTZER, J. T.; MOON, M. A. **Sales Forecasting Management: A Demand Management Approach**. [s.l.] Sage Publications, 2004.

NGO, T. **The Box-Jenkins Methodology for Time Series Models**. 2013.

NIELSEN, J. **Usability 101: Introduction to Usability**. Disponível em: <<https://www.nngroup.com/articles/usability-101-introduction-to-usability/>>. Acesso em: 5 jun. 2017.

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

PETROPOULOS, F. et al. ?Horses for Courses? in demand forecasting. **European Journal of Operational Research**, v. 237, n. 1, p. 152–163, ago. 2014.

PILINKIENÉ, V. Selection of market demand forecast methods: Criteria and application. **Engineering Economics**, v. 58, n. 3, 2015.

RUIZ-AGUILAR, J. J.; TURIAS, I. J.; JIM?NEZ-COME, M. J. Hybrid approaches based on SARIMA and artificial neural networks for inspection time series forecasting. **Transportation Research Part E: Logistics and Transportation Review**, v. 67, p. 1–13, jul. 2014.

SAMARASINGHE, S. **Neural networks for applied sciences and engineering: from fundamentals to complex pattern recognition**. [s.l.] CRC Press, 2016.

SHHRABI, J.; HADAVANDI, E.; ASADI, S. Developing a hybrid intelligent model for forecasting problems: Case study of tourism demand time series. **Knowledge-Based Systems**, v. 43, p. 112–122, maio 2013.

SHIM, J. K. **Strategic business forecasting: the complete guide to forecasting real world company performance**. [s.l.] CRC Press, 2000.

SOUZA, R. C. Metodologias para a análise e previsão de séries temporais univariadas e multivariadas. **Brazilian Review of Econometrics**, v. 1, n. 2, p. 78–105, 1981.

VAN LANDEGHEM, H.; VANMAELE, H. Robust planning: a new paradigm for demand chain planning. **Journal of operations management**, v. 20, n. 6, p. 769–783, 2002.

VOYANT, C. et al. Optimization of an artificial neural network dedicated to the multivariate forecasting of daily global radiation. **Energy**, v. 36, n. 1, p. 348–359, jan. 2011.

VU, T. B. **Seeing the future: how to build basic forecasting models**. [s.l: s.n.].

WANG, L.; ZENG, Y.; CHEN, T. Back propagation neural network with adaptive differential evolution algorithm for time series forecasting. **Expert Systems with Applications**, v. 42, n. 2, p. 855–863, fev. 2015.

WATSON, M. W. Time Series: Economic Forecasting. 2001.

YOKUMA, J. T.; ARMSTRONG, J. S. Beyond accuracy: Comparison of criteria used to select forecasting methods. **International Journal of Forecasting**, v. 11, n. 4, p. 591–597, dez. 1995.

ZHANG, G.; PATUWO, B. E.; HU, M. Y. Forecasting with artificial neural networks:: The state of the art. **International journal of forecasting**, v. 14, n. 1, p. 35–62, 1998.

### ANEXO A – Dados obtidos com os gestores

As séries temporais obtidas com os gestores de cada empresa encontram-se na vertical, segregadas ao longo de 36 meses (períodos). Os 30 primeiros períodos observados (1 ao 30) foram utilizados para aprendizagem dos métodos. Os últimos seis períodos observados (31 ao 36) foram utilizados para a avaliação das previsões obtidas pelos métodos.

Período	A1	B1	B2	B3	B4	B5	B6	B7	B8
1	37429	10031	464	997	385	14	1203	413	214
2	36016	8699	397	731	288	15	1065	348	171
3	39097	9742	516	937	331	25	1647	483	336
4	37330	9343	449	875	314	15	1712	337	330
5	40404	9524	523	932	352	17	1759	406	394
6	38744	8981	483	905	281	19	1602	315	361
7	38641	8974	464	881	332	21	1925	380	401
8	40457	9423	474	930	322	22	1753	403	388
9	40328	8179	448	782	285	15	1714	329	328
10	40623	9416	530	947	347	14	1969	403	410
11	41930	8711	479	969	433	22	1648	386	349
12	38414	8349	476	883	377	11	1268	332	309
13	36925	8818	491	867	353	19	1422	468	293
14	34133	7624	410	652	288	29	1228	366	322
15	40410	7968	537	739	276	18	1536	335	390
16	37224	8572	583	823	276	28	1792	417	536
17	39006	7986	517	726	256	16	1796	347	531
18	37037	7330	434	682	264	15	1681	354	478
19	39733	7910	433	731	308	14	1727	307	479
20	41497	7261	465	708	270	13	1596	345	475
21	40103	7130	461	716	250	16	1580	286	443
22	44428	7540	434	740	319	15	1660	335	471
23	42339	6854	410	748	269	10	1437	339	470
24	35551	7018	388	802	344	12	1240	351	393
25	37682	7078	427	776	342	18	1380	363	444

26	33524	6469	373	606	226	13	1239	326	292
27	36915	6605	493	695	285	22	1587	360	452
28	39072	6489	551	721	263	18	1720	340	525
29	40382	6423	540	746	258	16	1913	315	603
30	35021	6239	456	624	236	14	1800	334	485
31	37396	6656	508	769	281	25	1898	327	546
32	37047	6339	456	686	278	23	1613	319	493
33	35848	6433	484	663	314	26	1776	349	540
34	42870	6623	521	804	342	18	1785	350	557
35	40417	6076	409	678	321	19	1459	325	423
36	35105	6592	408	794	392	16	1456	320	392

<b>Período</b>	<b>B9</b>	<b>B10</b>	<b>B11</b>	<b>B12</b>	<b>C1</b>	<b>C2</b>	<b>C3</b>	<b>C4</b>	<b>C5</b>
1	49	2714	286	318	350	467	195	883	553
2	48	2334	231	293	219	239	55	157	273
3	79	2461	471	340	180	153	24	37	197
4	70	2248	679	251	425	472	17	20	196
5	94	2289	740	265	402	515	102	54	174
6	76	2123	697	338	482	480	106	972	208
7	82	2193	727	308	363	426	121	887	162
8	74	2205	474	250	417	560	187	884	192
9	63	2008	329	224	472	534	124	986	187
10	75	2248	289	287	415	496	116	737	141
11	58	2257	215	408	511	499	121	599	153
12	39	2075	200	419	463	462	86	432	130
13	27	2184	192	432	187	157	54	238	74
14	27	2017	248	326	130	83	79	327	134
15	58	2141	557	376	56	62	44	164	80
16	82	2572	703	360	50	398	32	115	57
17	106	2555	624	330	32	83	21	67	50
18	118	2585	507	400	14	24	32	81	30
19	95	2893	474	399	14	16	17	58	45
20	111	3026	393	445	6	34	12	39	22

21	77	3198	342	382	3	12	15	32	18
22	72	2967	281	398	20	27	23	56	18
23	57	2827	197	474	33	156	21	58	21
24	47	2664	216	562	211	243	49	63	29
25	30	2522	156	435	278	330	33	67	19
26	31	2310	207	338	338	331	13	19	13
27	48	2430	483	463	267	305	9	15	13
28	50	2595	725	497	293	330	3	4	13
29	99	2620	795	446	362	293	7	2	10
30	92	2368	643	338	436	314	11	6	5
31	91	2587	558	409	431	313	18	17	11
32	90	2420	373	365	409	358	23	12	4
33	65	2611	358	391	221	367	20	7	5
34	69	2751	304	365	459	199	3	7	4
35	42	2419	298	400	187	58	8	2	2
36	44	2726	219	474	69	48	5	2	4

<b>Período</b>	<b>C6</b>	<b>C7</b>	<b>C8</b>	<b>C9</b>	<b>C10</b>	<b>C11</b>	<b>C12</b>	<b>D1</b>	<b>E1</b>
1	194	659	992	533	198	704	2352	7800	8
2	161	529	752	297	91	368	2043	8200	8
3	147	401	567	247	83	323	1432	8300	11
4	252	531	959	229	95	265	1439	9100	10
5	158	484	157	220	76	276	1453	9400	12
6	184	511	453	220	60	299	2328	8500	14
7	167	755	976	217	66	267	1722	8400	12
8	147	725	1173	261	88	378	1849	6350	17
9	127	793	1433	295	86	413	1437	6020	9
10	128	809	1361	267	85	365	1421	5980	15
11	170	750	1354	235	118	354	1569	5800	7
12	99	704	1116	242	114	239	1283	6670	13
13	55	379	493	181	55	132	774	9000	12
14	83	729	227	215	98	204	1035	9500	7
15	43	413	76	148	47	143	416	9500	4
16	38	175	65	170	65	142	213	10140	9



17	36	144	20	92	54	86	116	10400	13
18	44	81	161	81	52	86	147	9550	21
19	58	62	326	102	31	70	130	9680	15
20	41	38	107	76	32	56	135	7710	19
21	35	39	52	75	27	61	45	7500	9
22	121	33	75	39	27	44	94	7500	16
23	50	34	37	45	13	38	55	7400	15
24	21	51	33	35	22	31	30	8500	13
25	18	74	38	32	49	33	16	9900	15
26	6	50	20	21	25	34	9	10600	13
27	21	41	12	13	20	20	20	10600	9
28	7	25	15	20	16	16	10	11300	6
29	7	13	32	3	14	22	10	11500	15
30	41	30	704	6	16	20	15	10800	13
31	52	21	959	11	37	25	18	10900	4
32	22	14	1006	17	13	28	2	8800	11
33	6	14	977	6	18	19	4	9000	17
34	6	87	705	3	7	6	2	8770	34
35	4	187	271	2	4	7	6	8200	31
36	3	131	218	2	1	2	5	9400	27

<b>Período</b>	<b>E2</b>	<b>E3</b>	<b>E4</b>	<b>E5</b>
1	2	14	36	13
2	3	15	7	12
3	2	23	17	19
4	9	16	9	55
5	6	15	24	59
6	3	11	21	48
7	3	14	36	52
8	4	23	22	53
9	10	15	23	74
10	8	19	31	42
11	10	22	31	59
12	9	19	36	51

13	5	19	41	37
14	11	18	16	25
15	3	5	3	16
16	11	11	27	44
17	12	12	18	21
18	9	21	37	35
19	11	8	22	28
20	13	12	18	30
21	5	11	8	30
22	12	11	29	33
23	10	22	38	37
24	2	16	16	24
25	13	11	31	19
26	12	9	17	40
27	13	10	21	36
28	7	7	29	25
29	8	5	25	16
30	6	10	21	19
31	12	11	19	21
32	16	13	22	27
33	12	28	27	30
34	24	33	41	41
35	19	38	47	77
36	24	39	65	50

## ANEXO B – Previsões Obtidas pelos Métodos

As previsões obtidas estão segregadas por período previsto (quadros), série temporal de cada empresa (linhas) e por método utilizado para a obtenção das previsões (colunas).

### Previsões Obtidas para o Período 31

Série Temporal	INGÊNUO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	38814,96	38773,29	37346,21	38410,50	37404,74
B1	6239,00	6276,52	6267,78	6359,92	6102,65	6131,35
B2	456,00	436,92	436,44	482,20	484,99	444,55
B3	624,00	654,25	654,60	682,75	684,51	658,30
B4	236,00	274,78	273,65	251,22	232,77	265,75
B5	14,01	15,21	15,62	18,00	15,81	18,26
B6	1800,00	1840,12	1846,88	1807,45	1874,72	2170,09
B7	334,00	298,27	301,25	337,01	334,32	320,76
B8	485,00	552,27	575,91	489,22	522,44	504,54
B9	92,00	81,67	76,44	92,00	101,45	73,81
B10	2368,00	2815,91	2814,95	2394,34	2497,17	2442,68
B11	643,00	589,63	551,32	643,00	599,34	610,98
B12	338,00	460,40	463,60	420,24	445,10	424,88
C1	436,00	151,10	279,62	436,00	448,69	329,70
C2	314,00	118,89	202,15	314,00	307,07	254,68
C3	11,00	-1,93	-12,68	11,00	8,66	8,44
C4	6,00	84,32	-149,16	6,00	-7,86	-50,31
C5	5,00	-74,15	-76,58	5,00	2,87	0,24
C6	41,00	1,16	-45,08	41,00	9,87	6,31
C7	30,00	-72,52	-118,19	30,00	19,97	41,76
C8	704,00	100,17	-970,59	704,00	675,60	2173,48
C9	6,00	-56,96	-42,80	6,00	-9,12	8,55
C10	16,00	-17,08	-0,32	15,72	11,07	14,48
C11	20,00	-108,57	-87,22	20,00	2,41	14,83
C12	15,00	-443,81	-713,52	15,00	13,46	9,24
D1	10800,00	10821,63	10935,66	10800,00	10965,16	11069,29
E1	13,00	14,58	15,72	10,76	11,42	9,41
E2	6,00	10,55	12,03	7,77	6,04	3,46
E3	10,00	4,27	5,64	8,46	7,20	5,90
E4	21,00	29,25	41,67	20,00	23,90	32,15
E5	19,00	29,10	32,71	26,02	15,21	12,86

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	37735,11	37881,32	38679,83	38679,83	39733,00	41708,37
B1	6342,27	6906,50	6475,21	6172,74	6172,74	6355,90
B2	466,09	462,66	470,20	470,20	470,20	403,04
B3	724,06	725,92	724,05	689,83	689,83	706,01
B4	277,01	286,10	277,01	236,00	236,00	299,41
B5	17,13	17,15	17,20	17,20	14,00	15,36
B6	1702,08	1786,89	1702,08	1702,08	1702,08	1744,90
B7	340,01	346,70	360,77	327,13	327,13	317,09
B8	458,69	421,40	458,69	485,00	485,00	479,99
B9	111,70	95,39	84,92	84,92	84,92	104,24
B10	2388,79	2297,96	2388,78	2368,00	2705,70	2322,52
B11	450,47	414,35	519,27	519,27	519,27	392,98
B12	348,72	329,33	329,33	338,00	338,00	778,19
C1	412,50	414,56	412,50	412,50	436,00	406,42
C2	309,56	299,56	309,56	314,00	314,00	303,22
C3	23,03	37,22	23,03	11,00	11,00	-14,61
C4	48,38	107,62	5,25	6,00	-256,31	13,94
C5	12,61	41,74	4,92	-13,90	-13,90	13,97
C6	35,42	25,19	21,93	3,87	34,58	270,45
C7	60,46	70,44	28,71	30,00	30,00	27,60
C8	674,73	690,65	674,74	704,00	869,00	202,53
C9	13,09	31,28	5,92	-12,17	-12,17	9,30
C10	24,70	43,80	14,83	7,07	7,07	31,90
C11	31,01	88,36	19,67	-3,59	-3,59	21,60
C12	62,64	217,03	14,68	15,00	15,00	13,96
D1	9916,06	10219,01	9826,02	10800,00	10800,00	10835,64
E1	12,17	12,06	12,00	12,00	12,00	17,66
E2	7,39	7,47	7,73	7,05	7,05	8,56
E3	12,65	13,54	12,65	10,00	10,00	8,64
E4	23,65	24,63	23,67	23,67	23,67	19,50
E5	25,20	31,88	25,20	25,20	25,20	27,55

### Previsões Obtidas para o Período 32

Série Temporal	INGÊNULO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	40627,88	40563,38	38191,55	38275,19	37644,37
B1	6239,00	6164,56	6117,47	6423,84	5972,32	6338,31
B2	456,00	458,62	457,69	490,70	494,80	460,76
B3	624,00	665,25	658,89	706,85	682,50	661,02
B4	236,00	250,15	251,23	258,57	223,85	257,67
B5	14,01	15,26	15,51	18,00	15,93	19,61
B6	1800,00	1682,11	1687,39	1812,41	1923,53	2048,51

B7	334,00	328,10	327,52	337,67	333,67	346,37
B8	485,00	543,33	560,34	493,29	531,74	440,74
B9	92,00	86,11	79,18	92,00	110,90	64,57
B10	2368,00	2907,98	2911,90	2417,88	2478,85	2452,64
B11	643,00	424,95	401,78	643,00	555,67	359,43
B12	338,00	457,24	448,56	436,88	442,86	381,00
C1	436,00	166,61	285,21	436,00	461,39	380,29
C2	314,00	186,41	281,05	314,00	300,14	208,09
C3	11,00	28,70	-23,58	11,00	6,56	8,18
C4	6,00	70,31	-178,64	6,00	-13,53	-105,74
C5	5,00	-65,10	-83,94	5,00	-0,27	-4,05
C6	41,00	-17,27	-47,74	41,00	8,84	0,65
C7	30,00	-104,58	-136,78	30,00	9,94	37,63
C8	704,00	87,98	-752,98	704,00	647,20	3401,42
C9	6,00	-44,26	-58,70	6,00	-16,13	13,46
C10	16,00	-4,98	-4,36	15,50	8,28	21,14
C11	20,00	-55,97	-128,98	20,00	-2,45	16,72
C12	15,00	-370,44	-1048,71	15,00	13,67	8,14
D1	10800,00	8818,82	8471,42	10800,00	11130,32	8667,47
E1	13,00	18,89	20,69	10,70	11,24	11,41
E2	6,00	11,83	14,33	7,89	5,04	1,27
E3	10,00	10,63	8,46	7,64	6,63	9,87
E4	21,00	20,16	28,94	20,00	24,59	18,88
E5	19,00	29,22	33,08	27,43	10,77	5,23

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	38406,48	38649,75	38679,83	38679,83	41497,00	43429,90
B1	6146,13	7191,43	6680,74	6058,68	6058,68	6255,91
B2	468,88	470,11	470,20	470,20	470,20	395,00
B3	706,21	735,23	706,20	689,83	689,83	701,97
B4	293,50	304,66	293,50	236,00	236,00	239,76
B5	17,25	17,26	17,20	17,20	13,00	16,71
B6	1647,76	1680,93	1647,76	1647,76	1647,76	1698,58
B7	335,76	344,21	360,77	324,11	324,11	329,03
B8	440,08	387,65	440,07	485,00	485,00	494,15
B9	97,67	85,15	79,94	79,94	79,94	99,37
B10	2405,45	2291,67	2405,44	2368,00	2864,33	2305,22
B11	306,98	344,36	489,86	489,86	489,86	280,12
B12	355,33	368,95	368,95	338,00	338,00	447,02
C1	392,69	347,07	392,69	392,69	428,00	367,33
C2	306,39	317,36	306,39	314,00	314,00	300,76
C3	32,45	42,52	32,46	11,00	11,00	17,10
C4	96,68	170,24	4,60	6,00	-321,39	12,99

C5	19,94	95,21	4,84	-32,79	-32,79	11,57
C6	44,17	31,02	20,91	-2,36	17,58	-7,10
C7	87,91	146,83	27,48	30,00	30,00	16,82
C8	650,92	635,75	650,94	704,00	650,00	137,20
C9	19,96	51,25	5,85	-30,34	-30,34	8,96
C10	32,08	68,27	14,90	2,58	2,58	33,19
C11	41,58	81,71	19,36	-27,17	-27,17	21,23
C12	108,01	384,79	14,37	15,00	15,00	14,32
D1	8894,73	9742,90	8828,66	10800,00	10800,00	9073,64
E1	12,01	11,99	12,00	12,00	12,00	17,30
E2	7,63	7,70	7,73	7,02	7,02	9,51
E3	13,57	14,12	13,57	10,00	10,00	7,32
E4	23,67	24,70	23,67	23,67	23,67	18,89
E5	28,74	29,75	28,74	28,74	28,74	21,79

### Previsões Obtidas para o Período 33

Série Temporal	INGÊNUIO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	39940,99	39882,11	37653,54	38139,88	35959,16
B1	6239,00	5468,92	5609,52	6393,71	5841,99	5565,02
B2	456,00	444,03	443,70	484,96	504,60	441,75
B3	624,00	593,70	604,32	692,64	680,49	568,78
B4	236,00	221,09	226,58	254,77	214,92	228,00
B5	14,01	13,26	14,02	18,00	16,05	14,13
B6	1800,00	1653,03	1658,76	1810,75	1972,34	2045,14
B7	334,00	262,46	269,68	337,15	333,02	283,59
B8	485,00	499,27	497,45	493,14	541,03	321,59
B9	92,00	64,31	60,48	92,00	120,35	44,08
B10	2368,00	2911,70	2893,25	2415,37	2460,54	2230,41
B11	643,00	326,31	312,10	643,00	512,01	222,46
B12	338,00	415,45	393,56	423,60	440,62	304,45
C1	436,00	181,81	313,33	436,00	474,08	432,20
C2	314,00	147,90	237,35	314,00	293,20	114,14
C3	11,00	-4,24	-23,50	11,00	4,47	1,85
C4	6,00	98,26	-228,25	6,00	-19,19	-179,96
C5	5,00	-71,35	-99,07	5,00	-3,41	-8,17
C6	41,00	-31,25	-52,60	41,00	7,80	-2,72
C7	30,00	-79,82	-192,69	30,00	-0,08	38,46
C8	704,00	180,97	-817,51	704,00	618,80	5119,53
C9	6,00	-29,63	-84,39	6,00	-23,14	18,79
C10	16,00	-9,67	-8,05	15,55	5,48	23,22
C11	20,00	-39,53	-180,25	20,00	-7,30	13,59
C12	15,00	-633,31	-833,19	15,00	13,88	4,94

D1	10800,00	8551,84	8120,19	10800,00	11295,48	8501,08
E1	13,00	9,89	10,42	10,76	11,06	5,10
E2	6,00	10,60	14,52	7,78	4,04	-3,30
E3	10,00	6,19	6,18	8,02	6,05	7,31
E4	21,00	15,37	21,83	20,00	25,29	15,65
E5	19,00	38,12	38,33	26,30	6,32	-3,69

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	38572,56	38649,75	38679,83	38679,83	40103,00	38541,11
B1	5967,24	7278,40	6859,58	5916,28	5916,28	6211,90
B2	469,65	470,11	470,20	470,20	470,20	391,70
B3	740,11	794,88	740,10	689,83	689,83	691,51
B4	300,14	304,66	300,13	236,00	236,00	254,68
B5	17,26	17,26	17,20	17,20	16,00	15,07
B6	1617,63	1527,19	1617,63	1617,63	1617,63	1654,07
B7	346,80	359,96	360,77	331,20	331,20	312,54
B8	426,91	398,16	426,90	485,00	485,00	479,49
B9	86,49	69,88	76,44	76,44	76,44	102,51
B10	2418,80	2366,70	2418,79	2368,00	3058,46	2297,74
B11	255,68	364,29	471,39	471,39	471,39	260,90
B12	359,41	368,95	368,95	338,00	338,00	430,79
C1	375,98	291,65	375,98	375,98	425,00	399,50
C2	304,14	295,66	304,13	314,00	314,00	298,03
C3	39,82	55,47	39,83	11,00	11,00	-45,40
C4	139,48	231,18	4,03	6,00	-328,39	11,46
C5	27,02	129,44	4,76	-51,69	-51,69	11,17
C6	46,99	81,98	26,95	-8,59	11,58	-474,22
C7	112,66	240,25	26,30	30,00	30,00	13,36
C8	631,55	879,43	631,58	704,00	595,00	132,10
C9	26,62	87,43	5,77	-48,52	-48,52	10,10
C10	38,34	67,90	14,49	-1,91	-1,91	33,87
C11	51,71	109,27	19,04	-50,76	-50,76	21,45
C12	151,21	659,86	14,06	15,00	15,00	9,03
D1	7894,01	9013,43	7995,46	10800,00	10800,00	8889,10
E1	11,98	11,99	12,00	12,00	12,00	11,83
E2	7,67	7,70	7,73	6,67	6,67	9,90
E3	13,89	14,12	13,89	10,00	10,00	3,86
E4	23,67	24,73	23,67	23,67	23,67	9,27
E5	30,78	34,53	30,78	30,78	30,78	21,78

### Previsões Obtidas para o Período 34

Série Temporal	INGÊNULO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	42236,30	42157,83	37995,96	38004,57	36046,19
B1	6239,00	6297,29	6160,43	6407,92	5711,65	6322,87
B2	456,00	469,31	466,52	488,84	514,40	530,01
B3	624,00	687,24	672,83	701,02	678,49	633,44
B4	236,00	285,81	281,11	256,73	205,99	277,52
B5	14,01	12,28	13,16	18,00	16,17	13,54
B6	1800,00	1822,42	1828,22	1811,30	2021,15	2374,53
B7	334,00	324,29	323,22	337,56	332,37	342,99
B8	485,00	554,67	571,49	493,15	550,33	300,16
B9	92,00	68,59	64,25	92,00	129,81	43,34
B10	2368,00	2924,68	2934,94	2415,64	2442,22	2493,51
B11	643,00	273,71	262,67	643,00	468,34	171,68
B12	338,00	453,48	447,08	434,19	438,37	343,27
C1	436,00	156,24	322,36	436,00	486,78	381,54
C2	314,00	126,77	232,29	314,00	286,27	39,18
C3	11,00	-7,76	-33,38	11,00	2,37	-2,15
C4	6,00	-36,33	-270,67	6,00	-24,86	-180,86
C5	5,00	-97,70	-103,49	5,00	-6,55	-9,34
C6	41,00	13,16	-142,24	41,00	6,77	-8,33
C7	30,00	-84,00	-240,22	30,00	-10,11	36,48
C8	704,00	151,39	-1069,84	704,00	590,40	5778,04
C9	6,00	-64,89	-79,20	6,00	-30,16	20,25
C10	16,00	-11,10	-12,51	15,54	2,69	25,61
C11	20,00	-77,37	-184,70	20,00	-12,16	7,88
C12	15,00	-641,29	-1476,79	15,00	14,09	3,97
D1	10800,00	8539,04	8081,08	10800,00	11460,64	8726,76
E1	13,00	16,58	18,19	10,70	10,88	7,11
E2	6,00	13,11	17,53	7,88	3,04	-9,80
E3	10,00	8,31	6,72	7,84	5,48	8,75
E4	21,00	29,38	42,42	20,00	25,99	19,26
E5	19,00	23,22	29,33	27,20	1,88	-8,33

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	38613,64	38649,75	38679,83	38679,83	44428,00	47402,04
B1	6333,93	7842,72	7015,20	5837,49	5837,49	6278,87
B2	469,87	470,11	470,20	470,20	470,20	388,63
B3	743,27	794,88	743,26	689,83	689,83	723,58
B4	302,80	304,66	302,80	236,00	236,00	288,74
B5	17,26	17,26	17,20	17,20	15,00	16,47
B6	1600,92	1564,29	1600,92	1600,92	1600,92	1450,88



B7	345,51	359,96	360,77	325,15	325,15	324,52
B8	417,60	398,16	417,59	485,00	485,00	481,54
B9	68,14	67,85	73,98	73,98	73,98	95,11
B10	2429,50	2459,00	2429,49	2368,00	2846,56	2302,83
B11	289,74	403,58	459,80	459,80	459,80	233,50
B12	361,93	368,95	368,95	338,00	338,00	434,22
C1	361,88	265,68	361,89	361,89	442,00	308,28
C2	302,53	295,66	302,52	314,00	314,00	298,11
C3	45,59	67,60	45,61	11,00	11,00	20,41
C4	176,55	289,98	3,52	6,00	-304,39	14,83
C5	33,84	136,21	4,68	-70,59	-70,59	11,19
C6	51,55	87,37	23,43	-14,82	97,58	399,37
C7	134,97	308,41	25,17	30,00	30,00	4,23
C8	615,79	704,10	615,83	704,00	618,00	125,11
C9	33,06	118,23	5,70	-66,69	-66,69	6,40
C10	43,65	66,16	14,28	-6,40	-6,40	33,98
C11	61,44	152,29	18,73	-74,34	-74,34	21,17
C12	192,35	816,15	13,76	15,00	15,00	12,55
D1	7211,56	8727,43	7445,10	10800,00	10800,00	8910,88
E1	11,98	11,99	12,00	12,00	12,00	16,92
E2	7,68	7,70	7,73	6,93	6,93	5,61
E3	14,00	14,12	14,00	10,00	10,00	2,64
E4	23,67	25,12	23,67	23,67	23,67	24,58
E5	31,94	34,53	31,94	31,94	31,94	18,88

### Previsões Obtidas para o Período 35

Série Temporal	INGÉNUO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	41786,47	41697,97	37778,03	37869,26	34954,66
B1	6239,00	5605,90	5623,28	6401,22	5581,32	5846,02
B2	456,00	428,76	427,66	486,22	524,20	485,71
B3	624,00	700,12	680,25	696,07	676,48	637,49
B4	236,00	304,02	291,94	255,72	197,07	346,20
B5	14,01	13,52	13,64	18,00	16,29	20,35
B6	1800,00	1547,85	1552,69	1811,12	2069,96	2045,66
B7	334,00	317,46	317,40	337,24	331,72	333,07
B8	485,00	522,14	522,49	493,15	559,63	213,82
B9	92,00	52,57	49,68	92,00	139,26	29,14
B10	2368,00	2860,13	2866,28	2415,61	2423,91	2500,00
B11	643,00	191,72	187,24	643,00	424,68	110,06
B12	338,00	549,30	576,09	425,75	436,13	467,73
C1	436,00	207,81	431,55	436,00	499,47	471,69
C2	314,00	190,93	357,58	314,00	279,34	-29,29

C3	11,00	-8,11	-40,51	11,00	0,27	-5,85
C4	6,00	-125,80	-300,93	6,00	-30,53	-184,67
C5	5,00	-93,96	-143,00	5,00	-9,69	-13,59
C6	41,00	0,08	-114,09	41,00	5,74	-16,77
C7	30,00	-119,87	-290,11	30,00	-20,14	31,27
C8	704,00	114,84	-1020,89	704,00	562,00	6659,34
C9	6,00	-81,51	-99,12	6,00	-37,17	20,68
C10	16,00	-2,54	-17,16	15,54	-0,11	32,70
C11	20,00	-92,22	-210,78	20,00	-17,02	3,63
C12	15,00	-610,62	-1519,92	15,00	14,30	2,89
D1	10800,00	8410,39	7899,66	10800,00	11625,80	8737,75
E1	13,00	12,16	12,49	10,76	10,70	2,77
E2	6,00	13,30	18,36	7,79	2,04	-19,92
E3	10,00	15,37	9,69	7,92	4,91	11,50
E4	21,00	33,46	48,34	20,00	26,68	14,40
E5	19,00	34,58	37,48	26,48	-2,56	-20,47

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	38623,80	38649,75	38679,83	38679,83	42339,00	39972,22
B1	5955,75	7616,42	7150,61	5708,66	5708,66	6154,71
B2	469,92	470,11	470,20	470,20	470,20	387,94
B3	757,51	794,88	757,50	689,83	689,83	743,93
B4	303,88	304,66	303,88	236,00	236,00	240,84
B5	17,26	17,26	17,20	17,20	10,00	19,97
B6	1591,65	1564,29	1591,65	1591,65	1591,65	1121,88
B7	348,24	359,96	360,77	327,82	327,82	327,60
B8	411,01	398,16	411,00	485,00	485,00	496,01
B9	51,08	67,85	72,25	72,25	72,25	93,76
B10	2438,07	2459,00	2438,06	2368,00	2723,04	2341,18
B11	370,02	413,90	452,51	452,51	452,51	199,96
B12	363,48	368,95	368,95	338,00	338,00	639,76
C1	350,00	265,68	350,00	350,00	455,00	350,21
C2	301,39	295,66	301,38	314,00	314,00	374,40
C3	50,11	67,60	50,13	11,00	11,00	-41,59
C4	183,99	289,98	3,09	6,00	-302,39	15,68
C5	40,41	136,21	4,61	-89,48	-89,48	11,58
C6	55,00	87,37	22,87	-21,05	26,58	151,65
C7	155,07	339,56	24,09	30,00	30,00	19,42
C8	602,97	495,13	603,01	704,00	580,00	132,36
C9	39,31	166,81	5,63	-84,86	-84,86	7,49
C10	48,15	66,16	14,00	-10,89	-10,89	34,27
C11	70,78	182,64	18,43	-97,93	-97,93	21,11
C12	231,52	816,15	13,47	15,00	15,00	9,87

D1	6889,99	8733,00	7219,94	10800,00	10800,00	8822,81
E1	11,98	11,99	12,00	12,00	12,00	18,36
E2	7,68	7,70	7,73	6,87	6,87	8,02
E3	14,04	14,12	14,04	10,00	10,00	11,34
E4	23,67	24,08	23,67	23,67	23,67	27,48
E5	32,61	34,53	32,61	32,61	32,61	20,18

### Previsões Obtidas para o Período 36

Série Temporal	INGÊNULO	ADITI	MULTI	EXPSIMPLES	HOLT	WINTERS
A1	35021,01	36688,75	36648,69	37916,73	37733,96	30717,77
B1	6239,00	5508,69	5538,64	6404,38	5450,99	5623,80
B2	456,00	415,90	414,76	487,99	534,01	489,32
B3	624,00	684,65	669,52	698,99	674,47	590,99
B4	236,00	313,61	302,89	256,24	188,14	301,34
B5	14,01	9,16	10,43	18,00	16,41	10,90
B6	1800,00	1252,81	1259,18	1811,18	2118,77	1612,45
B7	334,00	295,79	299,74	337,49	331,07	297,48
B8	485,00	463,59	447,30	493,15	568,93	129,94
B9	92,00	37,35	36,31	92,00	148,71	15,98
B10	2368,00	2690,70	2667,48	2415,61	2405,59	2295,20
B11	643,00	192,81	188,27	643,00	381,01	85,96
B12	338,00	601,24	636,59	432,48	433,88	546,09
C1	436,00	268,09	661,70	436,00	512,17	429,10
C2	314,00	214,59	405,38	314,00	272,41	-89,09
C3	11,00	-11,77	-71,97	11,00	-1,82	-7,24
C4	6,00	-208,47	-346,85	6,00	-36,20	-160,36
C5	5,00	-104,81	-192,04	5,00	-12,83	-14,48
C6	41,00	-50,62	-70,01	41,00	4,70	-13,17
C7	30,00	-141,76	-410,65	30,00	-30,17	26,96
C8	704,00	-45,10	-912,40	704,00	533,60	6239,68
C9	6,00	-86,52	-112,72	6,00	-44,18	24,23
C10	16,00	-1,71	-25,46	15,54	-2,90	41,27
C11	20,00	-158,95	-186,94	20,00	-21,88	-0,26
C12	15,00	-771,54	-1352,47	15,00	14,50	1,35
D1	10800,00	9404,67	9067,31	10800,00	11790,96	10363,13
E1	13,00	14,18	15,32	10,70	10,53	3,28
E2	6,00	8,88	10,73	7,88	1,04	-21,45
E3	10,00	10,77	7,18	7,88	4,34	8,71
E4	21,00	24,95	35,76	20,00	27,38	10,52
E5	19,00	24,91	29,14	27,06	-7,01	-25,27

Série Temporal	AR	MA	ARMA	ARIMA	SARIMA	RAAMULTI
A1	38626,31	38649,75	38679,83	38679,83	35551,00	31955,98
B1	6070,83	8007,76	7268,43	5590,95	5590,95	6174,47
B2	469,94	470,11	470,20	470,20	470,20	387,75
B3	763,02	794,88	763,02	689,83	689,83	745,93
B4	304,31	304,66	304,31	236,00	236,00	304,86
B5	17,26	17,26	17,20	17,20	12,00	26,42
B6	1586,51	1564,29	1586,51	1586,51	1586,51	1298,56
B7	351,81	359,96	360,77	328,25	328,25	331,64
B8	406,35	398,16	406,34	485,00	485,00	475,90
B9	41,99	67,85	71,04	71,04	71,04	89,34
B10	2444,95	2459,00	2444,93	2368,00	2574,27	2367,21
B11	450,44	423,78	447,94	447,94	447,94	200,33
B12	364,44	368,95	368,95	338,00	338,00	605,01
C1	339,98	265,68	339,98	339,98	633,00	284,15
C2	300,57	295,66	300,56	314,00	314,00	477,01
C3	53,66	67,60	53,67	11,00	11,00	20,65
C4	180,96	289,98	2,70	6,00	-297,39	16,26
C5	46,75	136,21	4,53	-108,38	-108,38	12,53
C6	58,45	87,37	23,74	-27,28	-2,42	-510,26
C7	173,20	343,30	23,06	30,00	30,00	32,32
C8	592,55	495,13	592,59	704,00	576,00	134,94
C9	45,35	182,99	5,56	-103,03	-103,03	4,86
C10	51,97	66,16	13,75	-15,38	-15,38	34,14
C11	79,74	214,39	18,13	-121,52	-121,52	21,01
C12	268,83	816,15	13,18	15,00	15,00	8,59
D1	6937,35	8733,00	7294,01	10800,00	10800,00	9620,02
E1	11,98	11,99	12,00	12,00	12,00	15,14
E2	7,68	7,70	7,73	6,82	6,82	8,97
E3	14,05	14,12	14,05	10,00	10,00	11,99
E4	23,67	24,08	23,67	23,67	23,67	19,36
E5	32,99	34,53	32,99	32,99	32,99	28,38