

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO ENGENHARIA DE PRODUÇÃO ELÉTRICA

Bianka Pisani de Souza

Projeções das receitas líquidas de empresas do ramo têxtil durante o período de flexibilização das medidas sanitárias da pandemia do Covid-19: um comparativo entre as previsões dos modelos de Redes Neurais, Sarima e Holt-Winters

Florianópolis
2022

Bianka Pisani de Souza

Projeções das receitas líquidas de empresas do ramo têxtil durante o período de flexibilização das medidas sanitárias da pandemia do Covid-19: um comparativo entre as previsões dos modelos de Redes Neurais, Sarima e Holt-Winters

Trabalho Conclusão do Curso de Graduação em Engenharia de Produção Elétrica do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Engenharia, área Elétrica, habilitação em Produção Elétrica.

Orientador(a): Prof. Daniel Christian Henrique

Florianópolis

2022

Ficha de identificação da obra elaborada pelo autor,
através do Programa de Geração Automática da Biblioteca Universitária da UFSC.

Souza, Bianka Pisani de

Projeções das receitas líquidas de empresas do ramo têxtil durante o período de flexibilização das medidas sanitárias da pandemia do Covid-19: um comparativo entre as predições dos modelos de Redes Neurais, Sarima e Holt Winters / Bianka Pisani de Souza ; orientador, Daniel Christian Henrique , 2022.

107 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia de Produção Elétrica, Florianópolis,
2022.

Inclui referências.

1. Engenharia de Produção Elétrica. 2. Previsão de demanda. 3. Comparação entre metodologias. 4. Métricas de erro. 5. Redes Neurais. I. , Daniel Christian Henrique. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Produção Elétrica. III. Título.

Bianka Pisani de Souza

Projeções das receitas líquidas de empresas do ramo têxtil durante o período de flexibilização das medidas sanitárias da pandemia do Covid-19: um comparativo entre as previsões dos modelos de Redes Neurais, Sarima e Holt-Winters

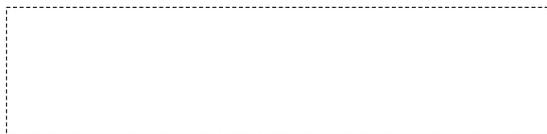
Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de Engenheira Eletricista com habilitação em Produção de Engenharia Elétrica e aprovado em sua forma final pelo Curso Engenharia de Produção Elétrica.

Florianópolis, 17 de dezembro de 2022.



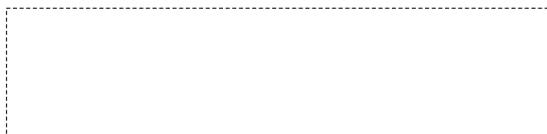
Coordenação do Curso

Banca examinadora



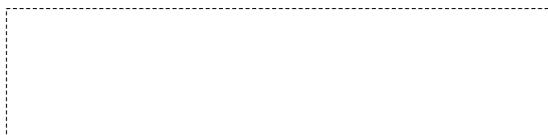
Prof.(a) Daniel Christian Henrique, Dr.(a)

Orientador(a)



Prof.(a) Ricardo Villarroel Davalos Dr.(a)

Instituição Universidade Federal de Santa Catarina



Prof.(a) Marco Goulart Dr.(a)

Instituição Universidade Federal de Santa Catarina

AGRADECIMENTOS

Agradeço ao meu orientador Daniel Christian Henrique pelo auxílio dado durante a criação dessa monografia, por seus excelentes ensinamentos, por todos os conselhos, pela ajuda e paciência com a qual guiaram meu aprendizado durante esse trabalho. Agradeço aos meus queridos professores, pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho em meu processo na formação profissional ao longo do curso. Também agradeço a instituição de ensino Universidade Federal de Santa Catarina, fundamental no meu processo de formação profissional. Obrigado ao meu pai e irmã que apesar de todas as dificuldades estiveram sempre presentes e compreenderam minha ausência em diversos momentos ao longo do TCC. Agradeço também ao meu namorado e a sua família, sem eles eu certamente não estaria onde estou hoje. Por fim, a todos que estiverem direta ou indiretamente fizeram parte da minha formação, o meu muito obrigado.

RESUMO

Previsões de demanda tem sua importância justificada por servirem de auxílio aos tomadores de decisão de todos os tipos de empresas, viabilizando o planejamento estratégico e operacional de suas organizações além de influenciar em diferentes horizontes de tempo. Ao longo dos anos diversas técnicas foram utilizadas para gerar previsões de demanda cada vez mais precisa. Nos dias atuais recursos computacionais ganharam destaque, por fornecerem uma forma mais rápida e simples de se obter previsões de curto e longo prazo, muitas vezes fornecendo melhor acuracidade que os métodos tradicionais, portanto, estão sendo mais utilizados por diversas empresas. O cenário instaurado em meados de 2019, o qual estabeleceu-se estado pandêmico devido a COVID-19, impactou fortemente a economia global, estabelecendo novas formas de consumo e mudando significativamente o perfil do consumidor. Para o setor têxtil tais mudanças foram fortemente sentidas e a queda percebida nas receitas durante período foi evidente. O presente trabalho se propõe a analisar projeções de receitas utilizando diferentes métodos de previsão de demanda para diferentes empresas do setor têxtil após o período de flexibilização da pandemia, analisou-se as projeções para o curto prazo pelas métricas de Machine Learning e estatísticas para séries temporais, considerando que os modelos fariam as ponderações necessárias frente as fortes mudanças nas receitas líquidas que o período pandêmico ocasionou no setor têxtil. Adotou-se como premissa que no momento da coleta dos dados o cenário de flexibilização estaria associado a presença ativa da Covid-19. Em sua conclusão será feito uma comparação utilizando testes de acuracidade, que serão fatores fundamentais para escolha do modelo que melhor se ajusta a empresa estudada.

Palavras-chave: previsão de demanda; planejamento de produção; métricas de erro; métodos tradicionais; machine learning; métodos estatísticos; redes neurais.

ABSTRACT

Demand forecasts have their importance justified by serving as an aid to decision makers of all types of companies, enabling the strategic and operational planning of their organizations, in addition to influencing different time horizons. Over the years several techniques have been used to generate increasingly accurate demand forecasts. Nowadays computational resources have gained prominence, as they provide a faster and simpler way of obtaining short and long-term forecasts, often providing better accuracy than traditional methods, therefore, they are being used more by several companies. The scenario established in mid-2019, which established a pandemic state due to COVID-19, had a strong impact on the global economy, establishing new forms of consumption and significantly changing the consumer profile. For the textile sector, such changes were strongly felt and the perceived drop in revenues during the period was evident. The present work proposes to analyze revenue projections using different demand forecasting methods for different companies in the textile sector after the pandemic easing period, analyzing short-term projections using Machine Learning metrics and statistics for time series, considering that the models would make the necessary weights in view of the strong changes in net revenues that the pandemic period caused in the textile sector. It was adopted as a premise that at the time of data collection, the flexibility scenario would be associated with the active presence of Covid-19. In its conclusion, a comparison will be made using accuracy tests, which will be fundamental factors for choosing the model that best fits the company studied.

Keywords: demand forecast; production planning; error metrics; traditional methods; machine learning; statistical methods; neural networks.

LISTA DE FIGURAS

Figura 1 – Curvas características das séries temporais.....	24
Figura 2 – Representação gráfica do funcionamento de uma rede neural.....	25
Figura 3 – Etapas para implementação de um sistema de previsão.....	34
Figura 4 – Produção do setor têxtil Brasileiro.....	37
Figura 5 – Percentual (%) de consumidores realizando a primeira compra online (01/02/2020 - 18/03/2020).....	39
Figura 6 – Dados históricos da ROL da empresa Karsten S.A.....	41
Figura 7 – Dados históricos da ROL - Dohler S.A.....	42
Figura 8 – Dados históricos da ROL - Santanense S.A.....	43
Figura 9 – Dados históricos da ROL – Cedro S.A.....	44
Figura 10 – Dados históricos da ROL – Indústria Cataguases.....	45
Figura 11 – Dados históricos da ROL – Pettenati S.A.....	46
Figura 12 – Dados históricos da ROL –Textil Renaux S.A.....	46
Figura 13 – Decomposição da ROL para a empresa Karsten S.A.....	48
Figura 14 – Previsão SARIMA da ROL para a empresa Karsten S.A.....	51
Figura 15 – Previsão Holt-Winters Multiplicativa da ROL para a empresa Karsten S.A.....	51
Figura 16 – Previsão Holt-Winters Aditiva da ROL para a empresa Karsten S.A.....	52
Figura 17 – Previsões HW Multiplicativa/Aditiva da ROL para a empresa Karsten S.A.....	53
Figura 18 – Previsões do modelo NNAR (4,1,2) ₄ da ROL para a empresa Karsten S.A.....	54
Figura 19 – Comparação entre os modelos preditivos para a Karsten S.A.....	54
Figura 20 – Decomposição da ROL para a empresa Dohler S.A.....	56
Figura 21 – Previsão SARIMA da ROL da empresa Dohler S.A.....	57
Figura 22 – Previsão Holt-Winters Multiplicativo da ROL da empresa Dohler S.A.....	57
Figura 23 – Previsão Holt-Winters Aditivo da ROL para a empresa Dohler S.A.....	58
Figura 24 – Previsões HW Multiplicativa/Aditiva da ROL para a empresa Dohler S.A.....	59
Figura 25 – Previsões do modelo NNAR (1,1,2) ₄ da ROL da empresa Dohler S.A.....	60
Figura 26 – Comparação entre os modelos preditivos para a empresa Dohler S.A.....	60
Figura 27 – Decomposição da ROL da empresa Pettenati S.A.....	62
Figura 28 – Previsão SARIMA da ROL da empresa Pettenati S.A.....	63
Figura 29 – Previsão Holt-Winters Multiplicativo da ROL da empresa Pettenati S.A.....	63
Figura 30 – Previsão Holt-Winters Aditivo da ROL da empresa Pettenati S.A.....	64
Figura 31 – Previsões HW Multiplicativa/Aditiva da ROL da empresa Pettenati S.A.....	65
Figura 32 – Previsões do modelo NNAR (1,1,2) ₄ da ROL para a empresa Pettenati S.A.....	66

Figura 33 – Comparação entre os modelos preditivos para a empresa Pettenati S.A.....	67
Figura 34 – Decomposição da ROL da empresa Industrial Cataguases.....	68
Figura 35 – Previsão SARIMA da Receita Operacional Liquida da empresa Dohler S.A.....	69
Figura 36 – Previsão Holt-Winters Multiplicativo da ROL da empresa Indústrias Cataguases	70
Figura 37 – Previsão Holt-Winters Aditivo da ROL da empresa Indústrias Cataguases.....	71
Figura 38 – Previsões HW Multiplicativa/Aditiva da ROL da empresa Industrial Cataguases	72
Figura 39 – Previsões do modelo NNAR (1,1,2) ₄ da ROL para Indústrias Cataguases.....	73
Figura 40 – Comparação entre os modelos preditivos para a empresa Indústria Cataguases...	73

LISTA DE TABELAS

Tabela 1 – Teste de Acuracidade da empresa Karsten S.A.....	55
Tabela 2 – Teste de Acuracidade da empresa Dohler S.A.....	61
Tabela 3 – Teste de Acuracidade da empresa Pettenati S.A.....	67
Tabela 4 – Teste de Acuracidade da Indústria Cataguases S.A.....	74

LISTA DE ABREVIATURAS E SIGLAS

ABIT – Associação Brasileira de Indústria Têxtil e Confecção

ACF – Função de autocorrelação

AIC – Critério de informação Akaike

IEMI – Instituto de Estudos e Marketing Indústria

MAE – Erro médio absoluto

MAPE – Erro percentual absoluto médio

MASE – Erro escalado médio absoluto

PACF – Função de autocorrelação parcial

PCP – Planejamento e Controle da Produção

RMSE – Erro quadrático médio

ROL – Receita operacional líquida

SUMÁRIO

1	INTRODUÇÃO.....	16
1.1	JUSTIFICATIVA.....	18
1.2	OBJETIVO GERAL.....	19
1.3	OBJETIVOS ESPECÍFICOS.....	19
2	ESTRUTURA DO TRABALHO.....	20
3	REFERENCIAL TEÓRICO.....	21
3.1	PREVISÃO DE DEMANDA.....	21
3.1.1	MÉTODOS QUALITATIVOS.....	22
3.1.2	Grass Roots.....	22
3.1.3	Pesquisa de Mercado.....	22
3.1.4	Painel de Consenso.....	22
3.1.5	Analogia histórica.....	23
3.1.6	Método Delphi.....	23
3.2	MÉTODOS QUANTITATIVOS.....	23
3.2.1	SÉRIES TEMPORAIS.....	24
3.2.2	MODELOS DE OTIMIZAÇÃO.....	25
3.3	MÉTODOS DE PREVISÃO.....	25
3.3.1	Redes Neurais Artificiais.....	25
3.3.2	Suavização Exponencial Simples.....	26
3.3.3	Método de Holt-Winters (Suavização Exponencial Tripla).....	26
3.3.4	Holt-Winters Multiplicativo.....	27
3.3.5	Holt-Winters Aditivo.....	28
3.3.6	Box-Jenkins (ARIMA).....	28
3.4	MÉTODOS CAUSAIS.....	30
3.4.1	Regressão Linear Simples.....	30
3.4.2	Regressão linear múltipla.....	30
3.5	ERROS DE PREVISÃO.....	31
3.5.1	MASE (MeanAbsoluteEscalaError).....	31
3.5.2	MAE (MeanAbsoluteError).....	32
3.5.3	RMSE (MeanAbsolutePercentError).....	32
3.5.4	MAPE (MeanAbsolutePercentError).....	33
4	PROCEDIMENTOS METODOLÓGICOS.....	34
4.1	CARACTERIZAÇÃO DO MÉTODO DE PESQUISA.....	34

4.2	METODOLOGIA PROPOSTA.....	34
4.3	DELIMITAÇÕES DO TRABALHO.....	34
4.4	ETAPAS DA PESQUISA.....	35
5	DESENVOLVIMENTO.....	37
5.1	DEFINIÇÃO DO PROBLEMA.....	37
5.2	COLETA DE DADOS.....	40
5.3	SELEÇÃO DO PACOTE COMPUTACIONAL.....	41
5.4	ANÁLISE PRELIMINAR.....	41
5.5	ESCOLHA E IMPLEMENTAÇÃO DOS MÉTODOS DE PREVISÃO.....	47
5.6	APLICAÇÃO DOS MODELOS.....	47
5.6.1	Karsten S.A.....	48
5.6.2	Dohler S.A.....	54
5.6.3	Pettenati S.A.....	60
5.6.4	Indústria Cataguases S.A.....	67
6	CONCLUSÃO.....	74
	REFERÊNCIAS.....	76
	APÊNDICE A – Modelo Holt-Winters Multiplicativo – Dohler S.A.....	79
	79
	79
	APÊNDICE B – Modelo Holt-Winters Aditivo – Dohler S.A.....	79
	79
	80
	APÊNDICE C – Modelo SARIMA – Dohler S.A.....	80
	80
	81
	82
	83
	83
	84
	APÊNDICE D – Modelo Redes Neurais – Dohler S.A.....	84
	84
	84
	APÊNDICE E – Modelo Holt-Winters Multiplicativo – Karsten S.A.....	84
	84

.....	85
APÊNDICE F – Modelo Holt-Winters Aditivo – Karsten S.A.....	85
.....	85
.....	85
APÊNDICE G – Modelo SARIMA – Karsten S.A.....	86
.....	86
.....	86
.....	87
.....	87
APÊNDICE H – Modelo Redes Neurais – Karsten S.A.....	88
.....	88
.....	88
APÊNDICE I – Modelo Holt-Winters Multiplicativo – Pettenati S.A.....	88
.....	88
.....	88
APÊNDICE J – Modelo Holt-Winters Aditivo – Pettenati S.A.....	89
.....	89
.....	89
APÊNDICE K – Modelo SARIMA – Pettenati S.A.....	89
.....	89
.....	90
.....	91
.....	92
.....	93
.....	94
.....	94
APÊNDICE L – Modelo Redes Neurais – Pettenati S.A.....	94
.....	94
.....	95
APÊNDICE M – Modelo Holt-Winters Multiplicativo – Indústria Cataguases S.A	95
.....	95
.....	95
APÊNDICE N – Modelo Holt-Winters Aditivo – Indústria Cataguases S.A.....	95

.....	95
.....	96
APÊNDICE O – Modelo SARIMA – Indústria Cataguases S.A.....	96
.....	96
APÊNDICE p – Modelo Redes Neurais – Indústria Cataguases.....	97
.....	97
.....	98
.....	99
.....	100
.....	101
.....	102
.....	102

1 INTRODUÇÃO

O Brasil classifica-se em 5ª lugar no ranking de maior Indústria têxtil do mundo e 4º lugar no segmento de vestuário, cuja produção média, em toneladas, é da ordem de 1,3 milhão de têxteis e 6,71 milhões de vestuários (FIEG, 2018). Segundo Cavalcanti e Santos (2021), é o 2º maior empregador da Indústria de manufatura, perdendo apenas para alimentos e bebidas. Nesse competitivo ambiente empresarial, é necessário um diferencial para conseguir alcançar resultados melhores que dos concorrentes. Para isso é essencial um bom gerenciamento empresarial (OLIVEIRA. B, 2022).

O planejamento e controle da produção é uma ferramenta essencial, e tem como uma de suas funções auxiliar o tomador de decisão em sua tarefa de gerenciamento empresarial. Segundo Chiavenato (2008), cabe ao PCP estabelecer o que a empresa deverá produzir, quanto deverá dispor de matérias primas e materiais, pessoas, máquinas e de equipamentos, assim como de estoque de produtos acabados para suprir as vendas. Além de monitorar o desempenho da produção, garantindo que o processo produtivo ocorra de acordo com o planejado. O PCP apresenta forte conexão com a previsão de demanda, e necessita que ela seja feita com qualidade, para que possa auxiliar de forma correta o tomador de decisão.

A previsão de demanda fornece dados que são utilizados em diversos setores da empresa, e está intimamente associada a gestão dos estoques. Com ela pode-se garantir uma produção sem excessos e desperdícios ao longo da cadeia produtiva garantindo um fluxo adequado de materiais e satisfazendo o cliente final (RIBEIRO, L. 2020). Desta forma, é fundamental uma boa gestão dos estoques, pois imprecisões podem ocasionar em falta de produtos para suprir a demanda (previsão subdimensionada) ou no aumento do capital de giro (previsão superdimensionada) (Rechatiko e Lemos, 2016).

Apesar de se mostrar essencial para uma empresa, prever dados é uma tarefa passível de erros, devido a fatores como sazonalidade, tendência e aleatoriedade. Uma forma de minimizar esses erros, é escolher um modelo que se adéque as necessidades da empresa, considerando o cenário em que ela está inserida e o horizonte de tempo no qual deseja que as previsões tenham efeito.

O setor têxtil sentiu desde o fim de março de 2020 o impacto causado pela pandemia de COVID-19. A quarenta estabelecida gerou fechamento de Indústrias, demissões em massa e uma grande mudança do perfil do consumidor, que passou a optar por meios de vendas digitais. O

novo cenário trouxe dificuldades para gerar previsões futuras de demanda, pois a mudança no comportamento do consumidor criou novos padrões na série histórica, impedindo utilizar a análise de períodos anteriores para prever o comportamento futuro, fazendo com que muitas empresas revessem seus métodos de previsão de demanda e processos produtivos.

Diferentes tipos de negócios requerem diferentes métodos de previsão. As previsões de demanda se distinguem quanto a metodologia utilizada nas projeções dos produtos e serviços, conforme o tipo de mercado em que a empresa está inserida e a necessidade de previsões que cubram horizontes de tempos variados. Os métodos utilizados pode mudar de um produto para outro, como meio de refletir mudanças de mercado, tal qual a entrada de novos produtos, competidores ou mudanças no comportamento dos consumidores (MOREIRA, 2013). O avanço da tecnologia está possibilitando cada vez mais que organizações de todo o porte possam utilizar e testar vários métodos de uma vez só, além de verificar qual prevê com maior acuracidade sua demanda. Métodos novos estão sendo criados e obtendo grande sucesso em sua utilização. Destaca-se as metodologias que utilizam Machine Learning para realizar projeções, que em muitos casos superam as acuracidades obtidas nos testes feitos pelos métodos estatísticos, ou mesmo competem nesse quesito. O presente trabalho tem como um dos objetivos estudar as diferenças comportamentais nas projeções obtidas pelas duas metodologias.

Dessa forma é fundamental ter amplo conhecimento da empresa, do cenário em que ela está inserida, assim como dos métodos que se deseja utilizar, para que se obtenha projeções com qualidade e de alta confiabilidade.

1.1 JUSTIFICATIVA

O trabalho se mostra importante devido aos benefícios que uma previsão de demanda gera a uma empresa, entre eles tem-se o auxílio na gestão empresarial e o diferencial competitivo proporcionado. O objetivo do estudo é auxiliar o tomador de decisão na escolha do método de previsão de demanda que mais se adéqua a sua empresa, para isso foram feitas projeções de sua receita operacional líquida. Devido à grande variedade de métodos existentes e o avanço da tecnologia que permitem sua fácil e rápida aplicação, foi utilizado softwares estatísticos para aplicar diferentes métodos de previsão, comparar os resultados e definir qual o melhor modelo a ser utilizado.

1.2 OBJETIVO GERAL

O objetivo do presente trabalho é realizar projeções de receita para 24 meses, considerando o cenário da permanência amena do Covid-19 e continuidade da flexibilização das medidas sanitárias para Indústrias do ramo têxtil. Serão utilizados métodos tradicionais de previsão de demanda, com o auxílio de softwares estatísticos.

1.3 OBJETIVOS ESPECÍFICOS

- a) Identificar padrões e características presentes nos dados coletados das Indústrias selecionadas.
- b) Escolher as técnicas de previsão de demanda que mais se adequam aos padrões encontrados nos dados.
- c) Realizar a previsão de demanda para as empresas utilizando os métodos de previsão selecionados.
- d) Comparar os resultados obtidos através dos métodos tradicionais e machine learning utilizando medidas de acuracidade.

2 ESTRUTURA DO TRABALHO

O trabalho está dividido em seis capítulos. No primeiro capítulo é feita uma introdução ao tema e conceitualizado o assunto abordado. O segundo capítulo é explorado o desenvolvimento do trabalho, os objetivos gerais e específico, assim como as limitações do trabalho. O terceiro capítulo aborda o referencial teórico, junto dos conceitos que vão servir como fundamento para o entendimento geral do trabalho. O quarto capítulo explora o procedimento metodológico da pesquisa deste estudo, assim como o enquadramento do tipo de pesquisa. O desenvolvimento da metodologia de pesquisa é iniciada no quarto capítulo e aprofundada no quinto. Toda a análise dos dados, escolha e implementação dos modelos preditivos e conclusões dos resultados é explorada neste capítulo. No sexto e último capítulo tem-se as conclusões derivadas dos resultados obtidos e são sugeridas recomendações para trabalhos futuros.

3 REFERENCIAL TEÓRICO

O trabalho tem como propósito prever a receita operacional líquida de empresas controladoras de cada grupo empresarial, utilizando como dados de entrada os períodos anteriores. A limitação imposta de utilizar apenas os dados de empresas controladoras, tem como objetivo fazer com que as análises não sejam influenciadas por possíveis empresas deficitárias dentro do grupo. Além disso, optou-se por utilizar o período de 24 meses como limite de previsão, o objetivo é diminuir incertezas e discrepâncias nos resultados finais.

3.1 PREVISÃO DE DEMANDA

A previsão de demanda mostra-se fundamental em diversas áreas de uma empresa, entre elas podemos citar (RITZMAN & KRAJEWSKI, 2009):

- a) Financeiro: Através dela pode-se obter projeções futuras de caixa.
- b) Marketing: Utiliza para criar estratégias para atrair consumidores.
- c) Recursos Humanos: Planejar necessidade de mão de obra
- d) Operações: Apoios as decisões gerenciais

Segundo Pacheco e Silva (2003) os métodos de previsão podem se dividir em três tipos, qualitativos, quantitativos e uma combinação de ambos.

Métodos qualitativos são utilizados quando não temos dados disponíveis, ou os dados não são os corretos para a previsão (HYNDAMNN, 2014), São baseados na opinião e julgamento de pessoas-chaves dentro da empresa, variando de executivos das principais áreas da empresa, como a área comercial, ou mesmo os vendedores, e os próprios clientes (TUBINO, 2007). São geralmente caros ou trabalhosos, e tendem a apresentar um baixo grau de precisão (PELLEGRINI & FOGLIATTO,2001).

Métodos quantitativos ramificam-se em dois tipos: séries temporais e modelos causais.

Séries temporais utilizam dados passados da demanda para determinar projeções futuras da mesma (ROMÃO & NEPOMUCENO, 2020). Neste caso analisa-se uma sequência de observações de uma variável em um determinado período de tempo, podendo assumir quatro tipos de padrões: Média, Tendência, Cíclico e Sazonal.

Os modelos causais buscam relações entre uma variável dependente (demanda) e variáveis independentes (inflação, clima, PIB, etc). Para relacionar as variáveis se utiliza técnicas de regressão linear e não-linear (PACHECO & SILVA, 2003).

Métodos, qualitativos ou quantitativos usam o mesmo princípio básico, a identificação de padrões existentes ou relações. A diferença está na forma como a informação é registrada e processada na previsão (MAKRIDAKIS, 1985).

3.1.1.1 MÉTODOS QUALITATIVOS

Métodos qualitativos são baseados em julgamento, intuição, pesquisas e opiniões, a fim de produzir estimativas quanto ao futuro (BALLOU, 2004). Por ser um método de natureza não científica, é difícil validar sua exatidão e acurácia.

3.1.1.2 Grass Roots

Reúne informações daqueles ao final da hierarquia que lidam com o que está sendo previsto. O método pede as pessoas mais próximas do usuário final que determinem o que venderão no próximo período e em seguida soma-se todos os valores para obter uma previsão geral. Funciona melhor em ambientes não varejistas, onde vendedores ou gerentes tem relacionamentos mais próximos com os clientes e entendem plenamente sua base.

3.1.1.3 Pesquisa de Mercado

É uma abordagem sistemática para determinar o interesse do consumidor externo em um serviço ou produto, criando e testando hipóteses por meio de pesquisa e coleta de dados. Na pesquisa de mercado é projetado e aplicado um questionário, após isso se seleciona uma amostra representativa e são analisadas as informações usando ferramentas estatísticas e de avaliações qualitativas para interpretar as respostas (KRAJEWSKI E RITZMAN, 2009).

3.1.1.4 Painel de Consenso

Nessa técnica considera-se que um grupo de pessoas podem chegar a uma solução melhor do que apenas uma pessoa. As previsões de painel são desenvolvidas por meio de reuniões abertas com a troca livre de ideias por todos os níveis de gerenciamento e posições. A principal dificuldade encontrada nesta técnica é de que os funcionários de níveis hierárquicos mais baixos muitas vezes se sentem intimidados pelos que ocupam cargos de alta gerência, desta forma o consenso acaba sendo direcionado por apenas uma parcela da organização (CHASE, 2006).

3.1.1.5 Analogia histórica

Parte-se de um produto já existente, similar a um novo que pretende prever a demanda. É feita a comparação entre ambos, partindo do princípio de que a demanda para este novo produto será similar à do primeiro, já existente. É importante no planejamento de novos produtos em que a previsão pode ser gerada utilizando o histórico de um produto semelhante (CHASE, 2006).

3.1.1.6 Método Delphi

O método Delphi corrige o problema existente no método Consenso de Painel, onde as opiniões têm uma origem e um peso definido. Nessa técnica a identidade dos participantes do estudo é mantida em sigilo e todos possuem o mesmo peso (CHASE, 2009).

Um coordenador envia as perguntas para cada membro do grupo de especialistas externos. Ele prepara um resumo estatístico das respostas junto com um resumo de argumentos para respostas específicas. O relatório é enviado ao mesmo grupo para outra rodada e os participantes podem escolher modificar suas respostas anteriores. Essas rodadas continuam até que seja obtido um consenso. Geralmente em torno de três partidas consegue-se alcançar bons resultados. O tempo necessário depende do número de participantes, da quantidade de trabalho necessária para realizar as previsões e a agilidade em oferecer as respostas.

3.2 MÉTODOS QUANTITATIVOS

Segundo Ruschel et al. (2007), as técnicas quantitativas utilizam modelos matemáticos para prever a demanda ao longo do tempo. Considera-se que os padrões existentes nos dados

passados irão se repetir no futuro. Entre os métodos quantitativos estão as séries temporais e os modelos causais.

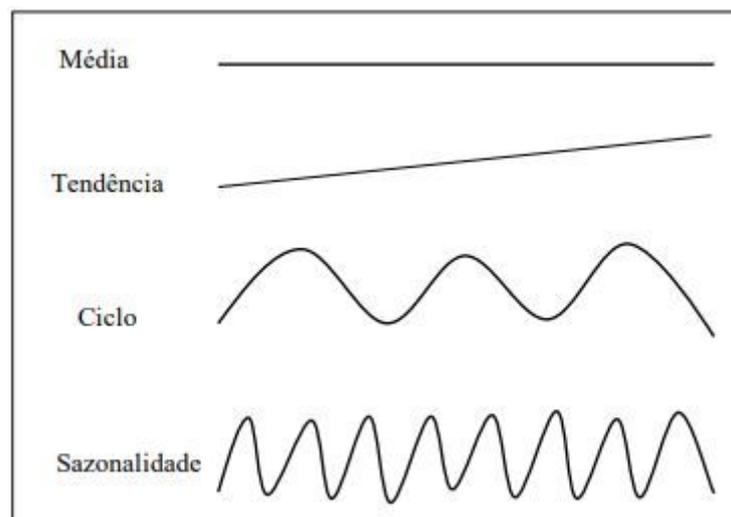
3.2.1.1 SÉRIES TEMPORAIS

Uma série temporal é composta por sequências de observações ao longo do tempo, e partem do princípio que os dados futuros serão uma projeção dos dados passados. Aplica-se em casos onde o comportamento da variável a ser analisada apresenta um padrão recorrente, e pode ser visualizado através de uma representação gráfica (MONEGAT et al. 2017).

Segundo Pellegrini e Fogliatto (2007), pode-se observar até quatro características em uma série temporal, são elas: média, sazonalidade, ciclo e tendência.

- Média: Existente quando os valores da série flutuam em torno de uma média constante.
- Sazonalidade: Quando a série possui padrões cíclicos de variação que se repetem em intervalos constantes no tempo.
- Ciclo: A variação cíclica existe quando a série exibe variações crescentes e decrescentes, porém não apresenta intervalos regulares de tempo.
- Tendência: Ocorre quando a série possui variações crescentes e decrescentes em um intervalo longo de tempo.

Figura 1 – Curvas características das séries temporais



Fonte: elaboração própria.

3.2.2 *MODELOS DE OTIMIZAÇÃO*

O aprendizado de máquina é uma parte da inteligência artificial responsável pela produção de algoritmos que aprendem com informações obtidas por uma base de dados. Fundamenta-se no princípio de que o erro é capaz de melhorar as respostas obtidas, ou seja, o aprendizado é obtido pela experiência. Os algoritmos dessa área são divididos em duas categorias: algoritmos de aprendizado supervisionado e não-supervisionado.

3.2.3 *Algoritmos supervisionados*

O aprendizado supervisionado requer um “supervisor”, que tem conhecimento de qual a resposta é esperada de um sistema dado uma entrada específica. Para efetuar o aprendizado, o algoritmo compara a saída obtida com a do supervisor, para que assim minimize cada vez mais o erro de sua resposta (BISHOP, 2006). Segundo Shalev-Shwartz e Ben-David (2014), esses algoritmos são treinados através de rótulos e características pré-definidas, realizando o reconhecimento e a classificação das informações de acordo com o aprendizado adquirido na fase de treinamento.

São exemplos de algoritmos supervisionados: Máquina de vetor de suporte, árvore de decisão e k-vizinhos mais próximos.

3.2.4 *Algoritmos não supervisionados*

Esses algoritmos são utilizados quando não se possui forma de classificar os dados. O processamento dos dados ocorre com objetivo de criar um resumo em uma versão compacta dos dados. Monard (2016), diz que algoritmos não supervisionados possuem dados de entrada e nenhuma resposta de saída, sua utilização origina grupos (clusters) de dados com características em comum, estes normalmente precisam de uma análise para extração de conhecimento de cada agrupamento.

Como exemplos de aprendizados não supervisionados tem-se os algoritmos: Algoritmos baseados em Centroid, Redes, Probabilístico e Redução da Dimensionalidade.

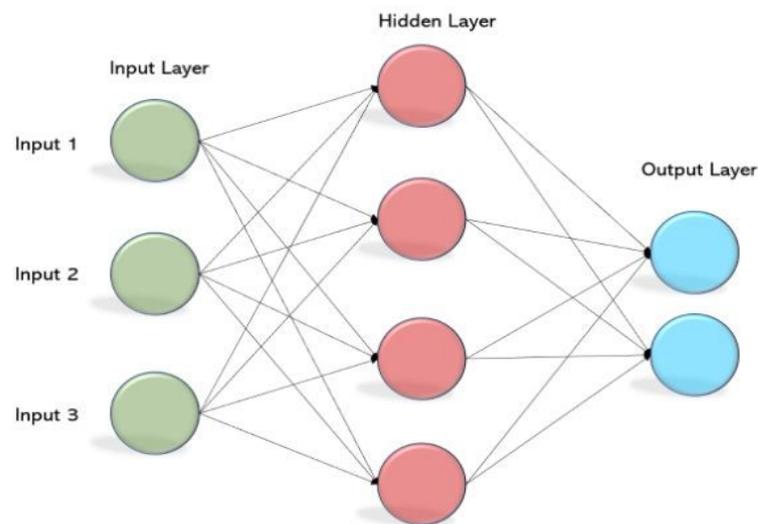
3.3 MÉTODOS DE PREVISÃO

3.3.1.1 *Redes Neurais Artificiais*

De acordo com Ballou (2008), dentre as técnicas de previsão de demanda está método de Redes Neurais. O método pode ser visto como um sistema de processamento de informações distribuídos, compostos por muitos elementos computacionais simples que interagem através de conexões e pesos distintos. Usando como inspiração a arquitetura do cérebro humano, o modelo exibe características únicas, destacando-se sua capacidade de treinamento para identificação de padrões (TORRES et al. 2005).

Haykin (2001), explica que redes neurais artificiais são construídas a partir de “neurônios”, que são divididos em três camadas distintas: input, intermediária e output. A primeira camada, conhecida como input layer, é responsável por receber o vetor de variáveis, que contém os dados a serem processados pela rede. A segunda camada, é a intermediária, podendo ser composta por uma ou várias subcamadas, tem como função o processamento da informação recebida pela camada de entrada. Por último tem-se a camada de saída, denominada output, que corresponde a saída, nela vão ser obtidas as previsões desejadas.

Figura 2 – Representação gráfica do funcionamento de uma rede neural.



Fonte: BecomingHuman (2019).

A quantidade adequada de neurônios da camada de entrada é determinada pelo número de atributos do problema, dependendo da estrutura de autocorrelação presente nos dados a serem analisados. Um número elevado de neurônios pode acabar gerando um aumento no tempo de treino e conseqüentemente piorando a capacidade de generalização da rede.

Uma das características das Redes Neurais, é capacidade de aprender com os dados de entrada e melhorar sua resposta final, fornecendo melhores previsões e aumentando seu desempenho. Haykin (2001), diz que o aprendizado da rede ocorre quando é fornecido uma série de valores de entrada, e os pesos da rede são ajustados até que ela forneça a saída desejada. As estratégias de treinamento são divididas em aprendizado supervisionado e não-supervisionado.

Segundo Refenes (1995) o aprendizado supervisionado requer inicialmente valores de entrada e de saída, a partir do qual o erro é calculado e posteriormente utilizado para ajustar o peso dos nós da rede. Inicialmente a é apresentada a diversos exemplos de um determinado problema, do qual retira características durante o processo de aprendizagem, após isso o conhecimento adquirido é aplicado em outros dados do mesmo tipo de problema.

Após o treinamento, a Rede Neural passa por uma análise que avalia seu potencial em apresentar soluções com os dados que ainda não foram apresentados. Essa etapa é fundamental, pois é uma forma de garantir que a rede aprendeu os padrões gerais e não apenas memorizou o conjunto de dados iniciais.

A desvantagem desse tipo de aprendizado é que na ausência de dados de treinamento, a rede não consegue aprender novas estratégias para situações diferentes das já simuladas. Pode-se citar como algoritmos para aprendizado supervisionado, os algoritmos de Naive Bayes, Árvores de Decisão e K-Nearest Neighbor.

De acordo com Haykin (2001), no aprendizado não supervisionado a rede aprende sem a necessidade de um conjunto de treinamento. Não requer ajuste de pesos, já que possui um monitoramento de desempenho interno da rede, o qual analisa as regularidades ou tendências dos dados de entrada, de forma a adaptar-se as necessidades da rede. Nesse tipo de aprendizado é necessário a cooperação entre as camadas de unidades de processamento. A competição entre elas é a base para o aprendizado da rede. Quando a competição pelo aprendizado ocorre, somente os pesos pertencentes as unidades vencedoras são ajustados. Entre os tipos de algoritmos, podemos citar K-Means Clustering, Boosting e Gaussian Mixtures.

3.3.1.2 Suavização Exponencial Simples

Os métodos de suavização exponencial surgiram na década de 1950, sua ideia é trabalhar com a atribuição de pesos aos dados da série, nesses métodos os dados possuirão menores pesos a medida que a série se distancia do ponto de origem, de forma que essa redução é feita de forma exponencial (OLIVEIRA et al. 2020). Utiliza-se o artifício de atribuir pesos menores aos extremos da série, pois considera-se que representam aleatoriedade, assim suavizando-os pode ser obtida uma previsão mais confiável. Por não ser recomendado a presença de sazonalidade ou tendência na série, o método é utilizado apenas em casos onde a série é estacionaria.

O método consiste em prever o período desejado, utilizando a demanda do período anterior mais a diferença entre a demanda projetada e efetiva do mesmo período (MONEGAT et al. 2020). Para seu cálculo é considerado a presença do fator de amortecimento() que tem a função de minimizar a média percentual dos erros de previsão (SCHNEIDER, et al, 2021).

O modelo é representado pela fórmula matemática:

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

Onde:

F_{t+1} = Previsão para o período t+1;
 D_t = Demanda Real para o período t;
 F_t = Previsão calculada para o período t;
 α = Constante de amortecimento.

3.3.1.3 Método de Holt-Winters (Suavização Expoencial Tripla)

O método de Holt-Winters é um dos mais conhecidos, é utilizado em casos onde a demanda possui fator sazonal, nível e tendência. Nela aplicam-se equações de suavização para estimar a tendência, sazonalidade e nível da série a ser estudada (PIRATELLI, C.L; SILVA, J.G, 2019). Destaca-se como um bom método de previsões para demandas de curto-prazo, devido a sua simplicidade, baixo custo de operação, boa precisão e capacidade rápida de adaptação as mudanças.

A técnica subdivide-se em duas abordagens distintas, a Multiplicativa e a Aditiva, de forma que a utilização de uma ou de outra depende do comportamento da sazonalidade presente nos dados utilizados (RODOLFO, et al, 2017). Quando a amplitude da sazonalidade varia de acordo com o nível da demanda aplica-se o modelo Multiplicativo, quando ela independe do nível da demanda, utiliza-se o Aditivo (SANTOS, et al, 2016).

3.3.1.4 Holt-Winters Multiplicativo

O modelo multiplicativo varia sua amplitude de sazonalidade de acordo com a variação da demanda. Seu cálculo requer aplicação de três equações alisadoras, referentes ao nível, tendência e sazonalidade. São descritas matematicamente pelas fórmulas abaixo:

$$F_{t+m} = (L_t + b_{t-m}) S_{t-s+m} \quad (2)$$

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1-\alpha) L_{t-1}; 0 \leq \alpha \leq 1 \quad (3)$$

$$b_t = \beta (L_t - L_{t-1}) + (1-\beta) b_{t-1}; 0 \leq \beta \leq 1 \quad (4)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma) S_{t-s}; 0 \leq \gamma \leq 1 \quad (5)$$

Onde:

L_t = Componente de Nível
 b_t = Componente de Tendência
 S_t = Componente de Sazonalidade
 α = Constante de suavização de nível
 β = Constante de suavização de Tendência
 γ = Constante de suavização de Sazonalidade.
 s = Comprimento da sazonalidade
 F_{t+m} = Previsão para m períodos a frente

Tem-se acima 4 equações: (1) calcula a previsão desejada, (2) e (3) são utilizadas para estimar o nível, a tendência da série no período atual, e (4) calcula o fator de sazonalidade que se refere ao último período de sazonalidade. Já são utilizadas para ponderar os pesos em relação ao nível, tendência e sazonalidade (VERISSIMO, 2012).

3.3.1.5 Holt-Winters Aditivo

O modelo é utilizado para séries que apresentam efeito de tendência e sazonalidade em seus dados. Caso a componente de tendência não esteja presente, pode ser desconsiderada do modelo. É representado pelas seguintes equações:

$$F_{t+m} = L_t + b_{t-m} + S_{t-s+m} \quad (6)$$

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

$$b_t = \beta (L_t - L_{t-1}) + (1 - \beta) b_{t-1}; 0 \leq \beta \leq 1 \quad (8)$$

$$S_t = \gamma (Y_t - L_t) + (1 - \gamma) S_{t-s}; 0 \leq \gamma \leq 1 \quad (9)$$

Onde:

L_t = Componente de Nível
 b_t = Componente de Tendência
 S_t = Componente de Sazonalidade
 α = Constante de suavização de nível
 β = Constante de suavização de Tendência
 γ = Constante de suavização de Sazonalidade.
 s = Comprimento da sazonalidade
 F_{t+m} = Previsão para m períodos a frente

3.3.1.6 Box-Jenkins (ARIMA)

O modelo de Box-Jenkins, ou modelo Auto-regressivo Integrado de Média Móvel (Arima) foi desenvolvido com o objetivo de identificar o comportamento da autocorrelação entre os valores de séries temporais (SAFADI, 2004). Pereira (2018), salienta que é uma técnica muito utilizada devido a sua generalidade e fácil aplicabilidade.

Uma das principais características do método é sua restrição a séries estacionárias, caso seja não-estacionária é necessário aplicar uma conversão. A série estacionária pode ser modelada como processo auto-regressivo (AR), processo de média móvel (MA) ou processo auto-regressivo de médias móveis (ARMA) (MARTIN et al., 2016). O modelo ARIMA (p,d,q), são não estacionários, e diferem-se dos modelos ARMA (p,q), pelo fato de que diferenciação ocorrerá d vezes, até transformar a série em estacionária.

Segundo Lemos (2006), para verificar se uma série é estacionária é feito uma análise gráfica e numérica dos coeficientes de auto-correlação (ACF) e auto-correlação parcial (PACF).

O coeficiente de auto-correlação (r_k) é representado pela equação abaixo.

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \bar{Y})(Y_{t-k} - \bar{Y})}{\sum_{t=1}^n (Y_t - \bar{Y})^2} \quad (10)$$

R_k é o coeficiente de correlação da observação Y_t com a observação Y_{t-k} , k a ordem do coeficiente de correlação, Y_t equivale a demanda observada no período t e \bar{Y} a média das observações da série temporal.

O coeficiente de r_k irá mensurar o grau de associação entre Y_t e Y_{t-k} . O coeficiente de auto-correlação parcial (PACF) de ordem k (a_k) será calculado após fazer a regressão de Y_t com as observações da mesma variável em períodos passados. Os coeficientes de a_k são as estimativas dos coeficientes b_k da regressão múltipla da equação abaixo.

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_k Y_{t-k} \quad (11)$$

De forma que para séries estacionárias os coeficientes ACF e PACF são próximos de zero, porém para não estacionárias diferem de zero em vários períodos.

A aplicação do método Box-Jenkins requer a conversão de séries não estacionárias para estacionárias. Para realizar o procedimento utiliza-se uma técnica de diferenciação, que gera uma série de $n-1$ valores, obtidos da equação (12):

$$Y_t = Y_t - Y_{t-1} \quad (12)$$

No modelo ARIMA, a variável é representada pela soma do valor anterior e do ruído na parcela auto-regressiva (AR). Na parte da média móvel assume-se que os valores atuais são dependentes de erros de previsão de períodos passados. A parte integrada indica diferença entre os valores atuais e os anteriores ao processo diferenciador, que pode ocorrer várias vezes, ou seja, remove a tendência de série temporal.

No caso de a série possuir sazonalidade, utiliza-se o modelo ARIMA sazonal multiplicativo, mais conhecido como SARIMA $(p,d,q)(P,D,Q)m$.

Onde:

- p – ordem máxima dos parâmetros de auto-regressão simples
- d – número de diferenciações não-sazonais aplicadas para tornar a série estacionária
- q – Ordem máximo dos parâmetros da média móvel simples
- P – Ordem máxima dos parâmetros de auto-regressão sazonal
- D – Número de diferenciações sazonais
- Q – Ordem máxima dos parâmetros de média móvel sazonal
- m – Número de períodos por ciclo sazonal

3.4 MÉTODOS CAUSAIS

Também chamado de previsões baseadas em correlações, os métodos causais são utilizados quando dados históricos da demanda estão disponíveis e possuem correlação com outros fatores a serem previstos, podendo ser internos ou externos.

3.4.1.1 Regressão Linear Simples

A técnica trabalha com duas ou mais variáveis correlacionadas, sendo utilizado uma para prever a outra. Primeiramente é colocado os dados obtidos em um gráfico para verificar a existência de comportamento linear. Caso a relação entre as variáveis X e Y formem uma linha reta, a regressão é do tipo linear (CHASE,2006).

A linha da regressão tem o formato, com Y equivalendo ao valor da variável dependente, X da variável independente, b o declive da linha, a o ponto de intercepção com o eixo Y e representa a parcela do erro responsável pela variabilidade em y que não pode ser explicada pela relação linear entre x e y.

Devido à simplicidade do método e a limitação de ser aplicado apenas a séries que apresentam correlação, torna o modelo pouco utilizado por empresas, que precisam de modelos com maior precisão e detalhamento.

3.4.1.2 Regressão linear múltipla

A regressão linear múltipla considera o efeito que múltiplas variáveis têm na previsão de demanda. Segundo Montgomery & Runger (2009), o modelo tem a seguinte equação:

$$Y = \beta + \beta_1 x_1 + \dots + \beta_k x_k + \varepsilon \quad (13)$$

Onde:

Y = Variável dependente;

X = Variável independente;

β = Parâmetros desconhecidos do modelo;

ε = Erro aleatório.

A utilização do método é conveniente quando diversos fatores influenciam a variável de interesse. Entretanto mostra-se de difícil execução, devido aos trabalhosos cálculos matemáticos.

3.5 ERROS DE PREVISÃO

Um fator importante a considerar é a acurácia das previsões. Definir o quão bem ela consegue prever os dados é fundamental. Essa análise é feita calculando-se os erros de previsão, que medirão os desvios entre os valores obtidos na previsão e os valores observados. Para fazer tal medição existem diversos modelos matemáticos (Pacheco, Silva 2003).

Analistas de previsão tentam minimizar os efeitos dos erros, selecionando modelos de previsão apropriados, mas sabe-se de antemão que eliminar todas os erros é impossível, dessa forma ao realizar uma previsão é comum apresentar os erros presentes nos dados previstos. Destaca-se quatro tipos:

3.5.1.1 MASE (MeanAbsoluteEscapedError)

Proposto por Hyndman e Koehler, a métrica é calculada através da divisão do erro da previsão pela média dos erros obtidos através do “método ingênuo”. Caso o resultado dessa divisão seja menor que 1, considera-se que as previsões possuem menores erros do que o “método ingênuo”. De acordo com os autores a vantagem do erro é a adequação a séries intermitentes, onde existem vários períodos sem qualquer consumo. O MASE é calculado através da seguinte equação matemática:

$$MASE = Média \frac{E_t}{1/n \sum F_t - F_{t-1}} \quad (14)$$

3.5.1.2 MAE (MeanAbsoluteError)

O MAE calcula a diferença média entre o valor real e o previsto para a demanda. Por existir valores negativos e positivos, é considerado o módulo desse número. Quanto menor o valor de MAE, melhores são os resultados preditos pelo modelo. Além disso, a métrica não leva em consideração valores discrepantes (outliers).

Pode ser calculado de acordo com a equação (15):

$$MAE = \frac{1}{n} \sum_{n=1}^n |y_t - y'_t| \quad (15)$$

Onde:

n = Número de observações;

y_t = Previsto no período t;

y'_t = Observado no período t.

3.5.1.3 RMSE (MeanAbsolutePercentError)

O RMSE(Root Mean Square Error) é definido pela fórmula matemática:

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (O_i - P_i)^2} \quad (16)$$

Onde:

N = Número de observações;

P_i = Previsão no período i ;

O_i = Valor observado no período i .

Ao contrário dos outros indicadores, esse apresenta uma dimensão, sendo igual à dimensão dos valores observados e preditos. O RMSE é uma medida do erro absoluto que eleva os desvios ao quadrado, de forma que os desvios positivos e negativos não se cancelem. Essa medida tende a aumentar os erros grandes, o que ajuda a eliminar os métodos com esses erros.

Sua interpretação segue a mesma lógica do MAE, por exemplo, o resultado da métrica sendo igual a 8 metros, significa que o modelo pode estar 8 metros para mais ou para menos. Por esse motivo a métrica é utilizada quando é preciso uma avaliação mais criteriosa sobre as previsões do modelo.

3.5.1.4 MAPE (MeanAbsolutePercentError)

O erro percentual absoluto médio, corresponde à média percentual da divisão do erro de previsão e do valor observado. Ele relaciona o erro de previsão ao nível de demanda (KRAJEWKSI E RITZMAN, 2009).

Tem sua representação matemática dada por:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_t - O_t}{O_t} \right| \quad (17)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

4 PROCEDIMENTOS METODOLÓGICOS

Optou-se por inicialmente abordar a caracterização do método de pesquisa conforme sua natureza, abordagem, seus objetivos e procedimentos. Em um segundo momento será apresentado uma descrição de cada etapa que compõe o estudo.

4.1 CARACTERIZAÇÃO DO MÉTODO DE PESQUISA

Segundo Gil (1996), o presente estudo apresenta abordagem quantitativa uma vez que as informações utilizadas são quantificadas e matematicamente modeladas. Possui caráter explicativo, pois procura identificar fatores que determinam ou contribuem para ocorrência dos fenômenos. Classifica-se como pesquisa experimental pois seleciona-se as variáveis que influenciam o estudo, define-se as formas de controle e de observação dos efeitos que as variáveis produzem no estudo.

O trabalho estrutura-se na área de Pesquisa Operacional – Planejamento e Controle da Produção dentro da subárea Previsão de Demanda.

4.2 METODOLOGIA PROPOSTA

Segundo Lemos (2006), cinco etapas são necessárias para correta implementação de um sistema de previsão de demanda, porém optou-se pela adição da etapa de Análise Preliminar, constituindo um total de seis etapas. Pode-se observar sua ordem segundo a diagrama abaixo:

Figura 3 – Etapas para implementação de um sistema de previsão



Fonte: elaboração própria.

4.3 DELIMITAÇÕES DO TRABALHO

O trabalho tem como propósito prever a receita operacional líquida de empresas controladoras de cada grupo empresarial, utilizando como dados de entrada os períodos anteriores. A limitação imposta de utilizar apenas os dados de empresas controladoras, tem como objetivo fazer com que as análises não sejam influenciadas por possíveis empresas deficitárias dentro do grupo. Além disso, optou-se por utilizar o período de 24 meses como limite de previsão, o objetivo é diminuir incertezas e discrepâncias nos resultados finais.

4.4 ETAPAS DA PESQUISA

O primeiro passo a ser executado para escolha do método de previsão de demanda é a definição do problema a ser resolvido. Primeiro procurou-se identificar quais empresas seriam selecionadas, assim como que tipo de dados seriam utilizados. Em um segundo momento decidiu-se o período, horizonte e intervalo de previsão, tendo a intenção de direcionar a coleta de informações nas etapas subsequentes.

A próxima etapa na escolha de um método de previsão envolve a coleta de dados para resolver o problema formulado na etapa anterior. Os dados selecionados para coleta foram os valores das receitas líquidas operacionais das empresas mais relevantes do setor Têxtil listadas na B3. Com horizonte de tempo dos dados a serem utilizados foi de 2015 até o segundo trimestre de 2022. Dessa forma utilizou-se a frequência de períodos trimestrais, além de considerar o ajuste da inflação nos dados coletados. Devido as empresas selecionadas serem de capital aberto, os dados foram obtidos através do banco de dados no software Economatica.

Em seguida selecionou-se um pacote computacional para trabalhar com os dados coletados e fornecer as previsões necessárias. Como critérios decisivos foram considerados a rapidez com que as previsões seriam geradas, limitações quanto ao tipo e número de previsões, custos e dificuldade em se obter as previsões. Dentre os softwares considerados, o escolhido foi o software R, com ele utilizou-se pacotes para os métodos de previsão de séries temporais e suas representações gráficas dos dados gerados.

Na etapa de Análise preliminar procurou-se agrupar os dados históricos e representá-los graficamente. O objetivo dessa análise é identificar valores atípicos na série, que podem

comprometer a qualidade da previsão, além de verificar a presença de sazonalidade ou tendência nos dados. Tais estudos forneceram informações suficientes para auxiliar na seleção dos modelos quantitativos a serem utilizados na modelagem das séries.

Após estudar os dados obtidos, buscou-se decidir quais métodos quantitativos seriam utilizados. A escolha foi baseada nas análises gráficas feita na etapa anterior.

Nesta parte serão aplicados os modelos de previsão nos dados das empresas selecionadas, posteriormente seu desempenho será analisado de acordo com os testes de acuracidade, com objetivo de definir o melhor método de previsão para cada caso.

Por último propõe-se a validação do modelo com a intenção de assegurar sua total funcionalidade. No trabalho utilizou-se quatro diferentes testes de acuracidade: o Erro Percentual Absoluto Médio(MAPE), Mean Absolute Square Error(MASE), Mean Squared Error(MSE) e Raiz do Erro Quadrático Médio(RMSE). Ao comparar as previsões de demanda com os valores realizados, procurou-se avaliar a eficiência dos métodos e potencial para utilização futura.

Ao utilizar diferentes métricas de erro buscou-se identificar qual método apresentado é o que possui menor diferença entre os valores previstos e observados, de forma que o modelo a possuir tal característica será selecionado como vencedor.

5 DESENVOLVIMENTO

O tópico presente consiste na exposição do estudo realizado em quatro empresas de capital aberto do setor Têxtil, utilizando como base a receita operacional líquida trimestral disponibilizada nos relatórios obtidos do software *Economática*. O método aplicado será o mesmo para as quatro empresas, baseado no detalhamento dado nos tópicos anteriores.

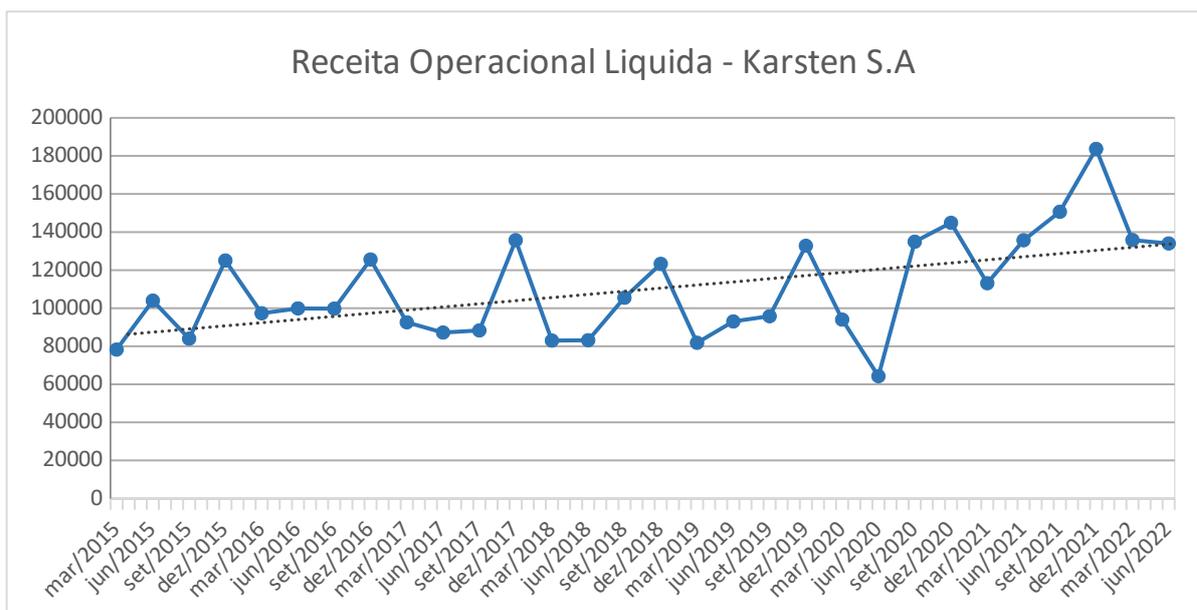
5.1 DEFINIÇÃO DO PROBLEMA

As etapas descritas anteriormente foram aplicadas para quatro empresas do ramo têxtil, sendo elas Karsten, Dohler, Pettenati e Indústrias Cataguases.

O motivo da escolha é devido à semelhança em relação aos produtos ofertados, formas de vendas similares e por serem as empresas mais relevantes no segmento têxtil no momento presente.

Primeiramente buscou-se analisar o volume de produção têxtil do Brasil como um todo, datando de 2015, até o momento presente. Tendo como objetivo entender o comportamento do setor ao passar dos anos.

Figura 4 – Produção do setor têxtil Brasileiro



Fonte: elaboração própria.

Segundo a ABIT (2020), os anos de 2015 e 2016 foram de recessão. Os índices apresentados previam um aumento de 1% na produção para 2017. A produção têxtil que teve um recuo de 5,3% em 2016, também indicava crescimento de 1%. A baixa de importações de têxteis foi de 2,3%, totalizando 1,10 milhão de toneladas. O investimento em máquinas e equipamentos foi de US\$ 479 milhões, 25,5% a baixo do que em 2015. O total do faturamento do setor têxtil e de confecção no Brasil foi de R\$ 129 bilhões, 1,5% menor que 2015.

Já em 2017 a expectativa era de um aumento de 5,6% na produtividade em relação a 2016, resultando em um faturamento de R\$ 144 bilhões. Como resultado do ano a produção chegou a R\$ 5,9 bilhões de peças e o aumento da fabricação em 4,2% com 1,77 milhão de toneladas produzidas. Segundo a ABIT (2020), tal melhora teve início no segundo semestre de 2016, devido a recuperação do consumo, substituição de importações, e também influência dos cenários políticos e econômicos no período.

Em 2019 foi previsto um crescimento de 3% no volume de produção e 7% no faturamento, produzindo um crescimento real de aproximadamente 3,5%, considerou-se o cenário político e financeiro positivo que estava se estabelecendo.

Entretanto a produção têxtil fechou o ano com queda de 1,6%, totalizando R\$ 2,05 bilhões de toneladas e um faturamento de 186 bilhões (IEMI 2021). A produção têxtil ficou em baixa devido ao aumento das exportações e a queda das importações. Os fatores que interromperam o ritmo crescente do setor foram além da greve dos caminhoneiros, as mudanças no cenário político e econômico.

Em março de 2020 a OMS, Organização Mundial de Saúde, oficializou o estado de pandemia devido ao novo Coronavírus, originado na china, em dezembro de 2019. O cenário impactou fortemente na economia, gerando uma das maiores crises econômicas que o mundo já viveu nas últimas décadas.

Como forma de impedir a propagação do vírus, governos do mundo todo estabelecem o isolamento social, criando medidas de quarentenas como forma de segurança. Devido ao novo cenário imposto pelo isolamento social, o mercado ficou impossibilitado de gerar demanda e oferta de produtos e serviços, impactando negativamente na economia.

No ramo têxtil, segundo a ABIT (2020), em 2019 o Brasil se posicionava como a maior cadeia têxtil do ocidente. Representando 5,7% do PIB do faturamento da Indústria de transformação, o setor gerava um faturamento de R\$ 185 bilhões, se posicionando como o

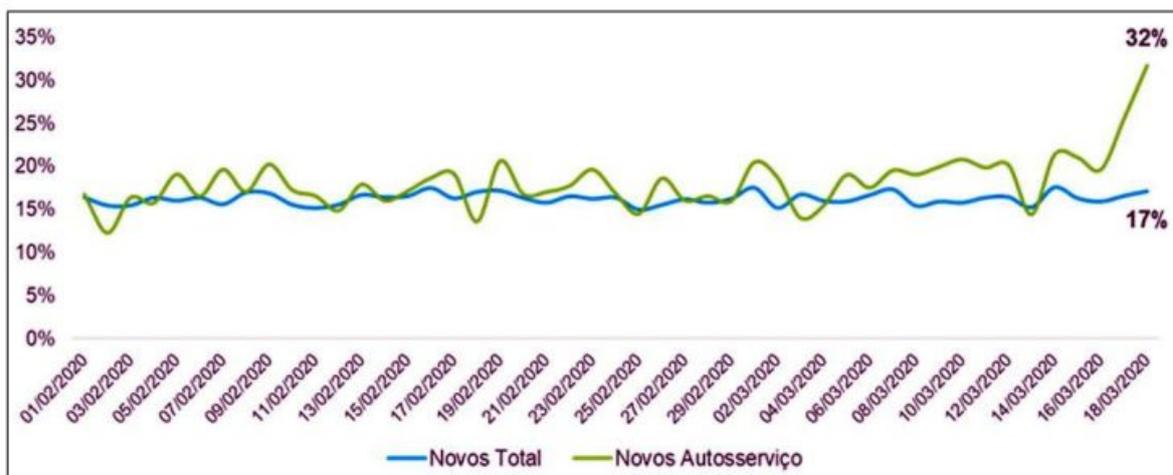
segundo maior empregador da Indústria de transformação, com 9,5 milhões de trabalhadores (ABIT,2020).

Os resultados do primeiro semestre de 2020, após o anúncio do estado de pandemia impactaram de forma abrupta o volume de produção e faturamento do setor quando comparados ao ano de 2019. Terminou-se o ano de 2020 com um faturamento 13% menor que o obtido em 2019, passando de R\$ 186 bilhões para R\$ 161 bilhões (IEMI, 2021), com volume de produção retraindo em 7%, passando de 2,05 milhões para 1,91 milhão em 2020.

Em contrapartida o cenário imposto pela pandemia impulsionou fortemente o setor digital, que obteve grande vantagem competitiva ao gerar uma alternativa segura de consumir. Segundo o estudo da Ebit|Nielsen (2020), o faturamento das empresas que atuavam no ambiente digital cresceu 47%. O aumento da necessidade do consumidor e maior confiança em relação a compras virtuais, levou milhares de brasileiros a comprar pela primeira vez no e-commerce. O pico das compras online ocorreu no auge das restrições de circulação nas cidades brasileiras para a contenção da Covid-19.

De acordo com os dados fornecidos pela Ebit|Nielsen (2020), após a confirmação do primeiro caso do Covid-19 no Brasil houve um crescimento superior à média de novos consumidores fazendo pela primeira vez uma compra online:

Figura 5 – Percentual (%) de consumidores realizando a primeira compra online (01/02/2020 - 18/03/2020)



Fonte: Ebit| Nielsen Company Online Sales (2020).

A participação do e-commerce se mostrou fundamental para a recuperação do setor, que em 2021 obteve-se um faturamento de R\$ 194 bilhões, um aumento de 20% em relação a 2020, as exportações cresceram 25%, indo de US\$ 801,8 milhões em 2020 para US\$ 1,06 bilhão em 2021, importações cresceram aproximadamente 20%.

Já em dezembro de 2021 o setor começou a sofrer queda, entre os principais motivos estão o aumento da inflação, preço do algodão e aumento da taxa de juros. A volta da inflação desaqueceu o mercado, reduzindo a capacidade de consumo da sociedade. E, ao mesmo tempo, o aumento da taxa de juros torna a venda a prazo muito mais cara, servindo de contraponto ao consumo.

O estudo procura trazer o impacto que a pandemia trouxe para o setor têxtil de empresas de capital aberto e fornecer uma análise comparativa de diferentes modelos estatísticos de previsão de suas receitas líquidas, considerando a atuação de três cenários, o de pré-pandemia, pandemia e pós-pandemia.

Como a pandemia praticamente em seus momentos finais, é possível ter uma janela segura de previsão para os próximos meses. Considerou-se que o e-commerce continuará aquecido, devido não só a previsões qualitativas, mas efetivamente aos dados obtidos, que demonstram o crescimento do e-commerce é algo que permanecerá e além disso, se tornou uma nova forma de nossa forma de consumir, através dele é possível interligar praticidade e rapidez na obtenção dos produtos que se deseja, com a maior qualidade possível e menor tempo de entrega.

5.2 COLETA DE DADOS

A coleta de dados foi feita utilizando-se o software Economatica, através dele foi obtida a receita operacional líquida não consolidada das empresas selecionadas. A receita operacional líquida (ROL) corresponde ao montante recebido pela venda de produtos ou prestação de serviços, ela representa o resultado das vendas brutas após a dedução dos impostos sobre vendas, descontos, abatimentos e devoluções. Dessa forma escolheu-se a Receita Operacional Líquida como indicador ROL por estar fortemente atrelada a rentabilidade da empresa, refletindo os lucros reais da empresa.

Para realizar as previsões utilizou-se para cada empresa uma amostra de 30 trimestres, já ajustados pela inflação. Para as projeções das receitas optou-se por um período de 8 trimestres,

que engloba os dois últimos trimestres de 2022, o ano de 2023 e os dois primeiros trimestres de 2024.

5.3 SELEÇÃO DO PACOTE COMPUTACIONAL

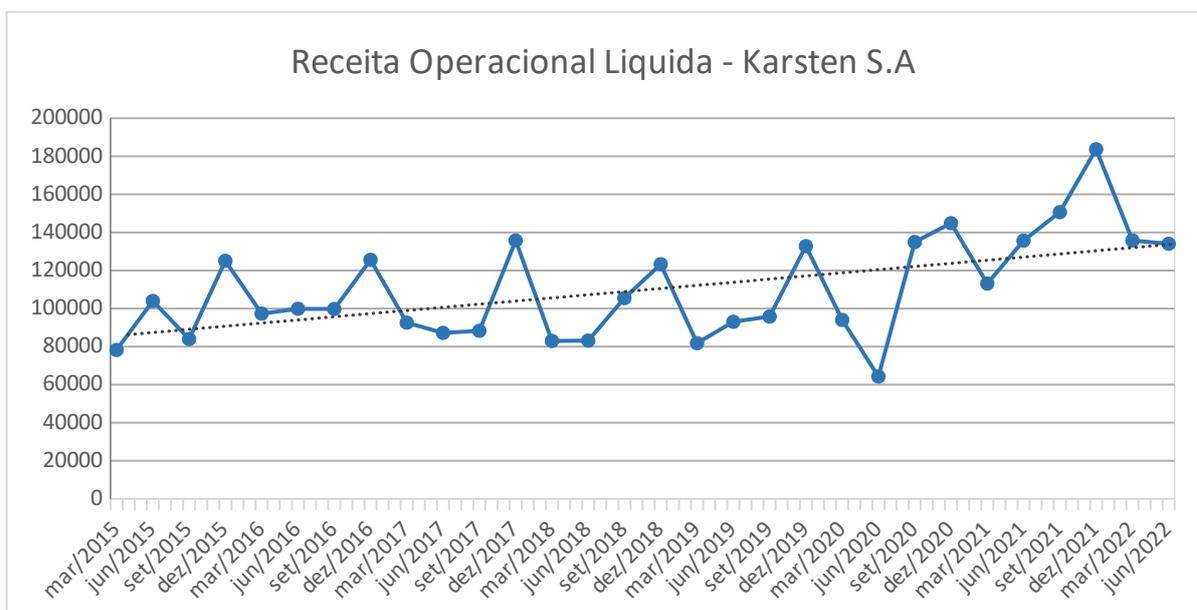
Para realizar as simulações optou-se pelo software R, entre os motivos de sua escolha, as que mais impactaram na decisão foram sua interface intuitiva que gerou facilidade em seu uso, rapidez em gerar previsões numéricas e gráficas com grande detalhamento e qualidade, pacotes com bibliotecas para utilização de diversos métodos estatísticos e ser um software livre.

5.4 ANÁLISE PRELIMINAR

Esta etapa é essencial para a visualização de tendências e sazonalidades. Nesta etapa, os dados históricos foram agrupados e graficamente representados, desta forma é possível identificar padrões e visualizar o comportamento apresentado pela receita. Períodos anormais de receita, tanto de alta ou baixa, foram mantidos mesmo sendo considerados pontos fora da curva (outliers).

Abaixo temos os gráficos dos dados históricos das empresas assim como suas análises.

Figura 6 – Dados históricos da ROL da empresa Karsten S.A

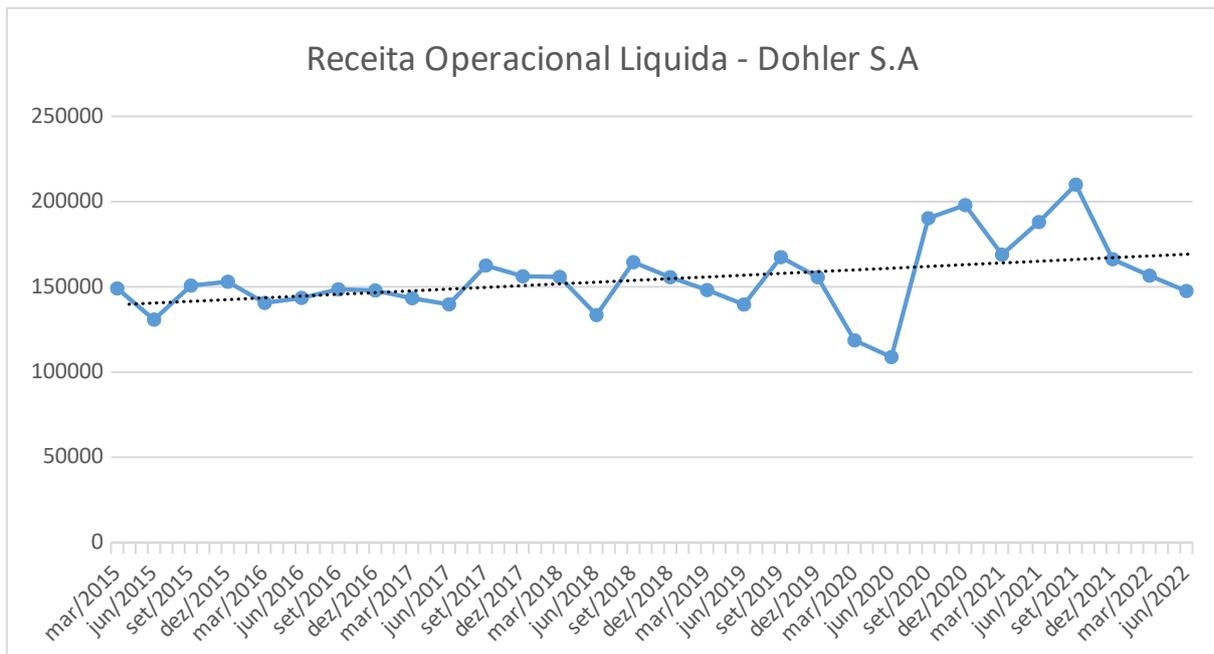


Fonte: elaboração própria.

A Figura 6 representa o comportamento de 2015 até o segundo trimestre de 2022 da Karsten S.A. Nota-se uma tendência de crescimento, embora de forma pouco expressiva. A sazonalidade mostra-se constante nos últimos trimestres de cada ano, sendo um comportamento esperado e comum no setor têxtil, tal fato se explica pelas datas comemorativas de fim de ano e o acontecimento da Black Friday. Vale destacar o impacto da pandemia que teve na empresa, tendo seu menor faturamento em junho de 2020, com uma recuperação iniciando em setembro de 2020 e atingindo seu máximo no mês de dezembro.

O aumento da receita operacional líquida em dezembro de 2021, é resultado de investimentos em máquinas e equipamentos, modernização na área produtiva da empresa e principalmente a redução da ociosidade do COVID-19, comparado com o período anterior.

Figura 7 – Dados históricos da ROL - Dohler S.A

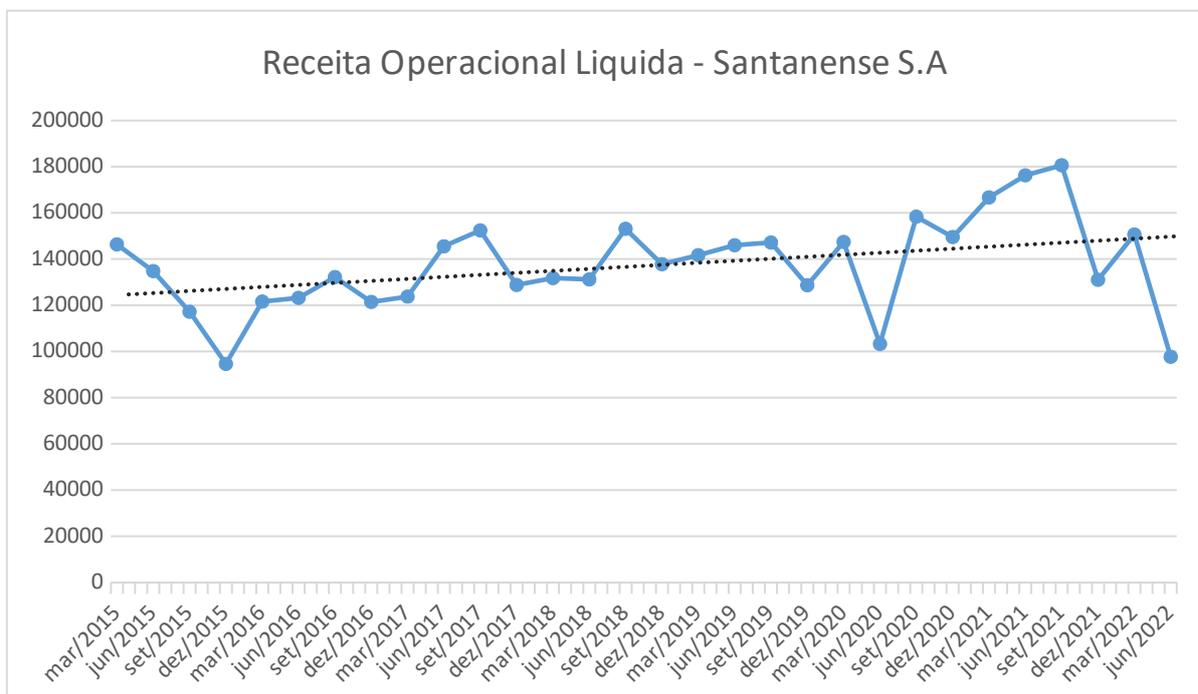


Fonte: elaboração própria.

A figura 7 representa a série temporal da empresa Dohler S.A, que apresenta leve tendência de crescimento ao longo do tempo, apresentando sazonalidade constante ao longo dos últimos trimestres. Nota-se um comportamento similar ao da empresa Karsten, com o menor faturamento em junho de 2020, devido aos efeitos da pandemia, e recuperação em dezembro de 2020. Atingindo seu maior faturamento em setembro de 2021.

Importante destacar que a Companhia, atualmente avança fortemente na migração para ambiente virtual, com Gerência constituída para conduzir o processo e, consultorias especializadas para a sua implementação. A empresa trabalhou fortemente durante o ano de 2020 para preparar o seu ingresso no E-COMMERCE de forma consistente. Essa estratégia teve um impacto nos resultados positivos de 2021.

Figura 8 – Dados históricos da ROL - Santanense S.A

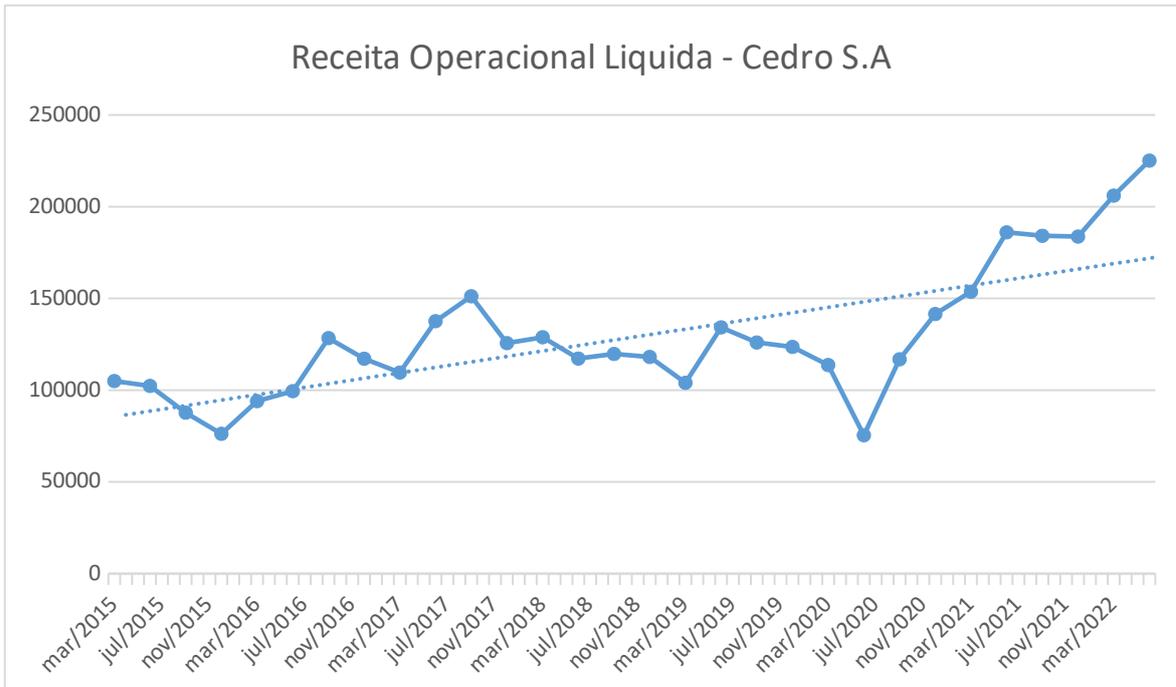


Fonte: elaboração própria.

A série temporal da empresa Santanense S.A apresenta uma tendência de crescimento com sazonalidade fortemente presente. É visível também o impacto que a pandemia causou em 2020, afetando abruptamente as receitas em junho de 2020, sendo um dos piores resultados apresentados, mas no trimestre seguinte a empresa consegue retomar as vendas, com um aumento de 53% em seu faturamento. Após uma queda de 6% no faturamento no último trimestre do ano, a empresa fecha o ano com um faturamento de R\$ 149 milhões.

Após um crescimento no faturamento até setembro de 2021, houve uma queda de 27% no último trimestre de 2021, fazendo com que a Santanense obtivesse um faturamento de R\$ 131,09 milhões.

Figura 9 – Dados históricos da ROL – Cedro S.A

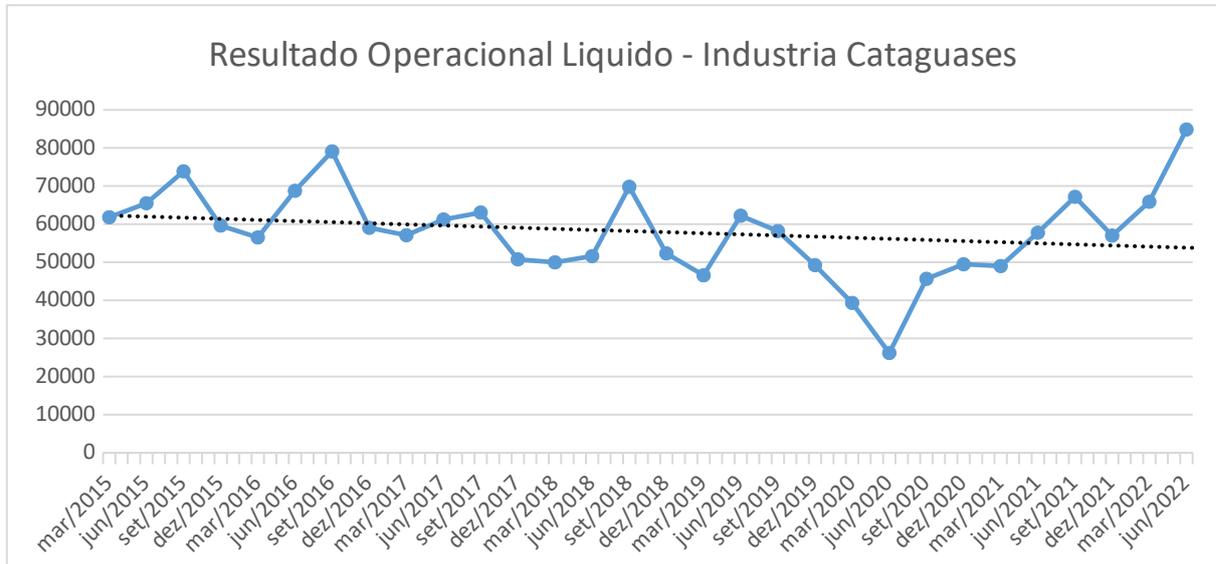


Fonte: elaboração própria.

O histórico de receitas da Cedro S.A apresenta forte tendência de crescimento, e forte sazonalidade. Destaca-se o impacto da pandemia no faturamento da empresa, em junho de 2020 houve forte queda, seguindo o padrão até o momento visto nas outras empresas do ramo.

Entretanto a rápida resposta da empresa proporcionou resultados muito positivos já em dezembro de 2020. O crescimento continuou intenso em 2021, sendo a maior parte dele devido a ajustes de preços, uma medida necessária para fazer frente aos aumentos dos insumos, notadamente algodão e produtos químicos. Em adição, houve aumento da quantidade de tecidos vendidos. O crescimento nas vendas, com enfrentamento da pressão de custos, melhor aproveitamento da capacidade de produção (melhorando a diluição dos custos fixos) e controle das despesas foram fatores que contribuíram para melhora dos resultados

Figura 10 – Dados históricos da ROL – Indústria Cataguases

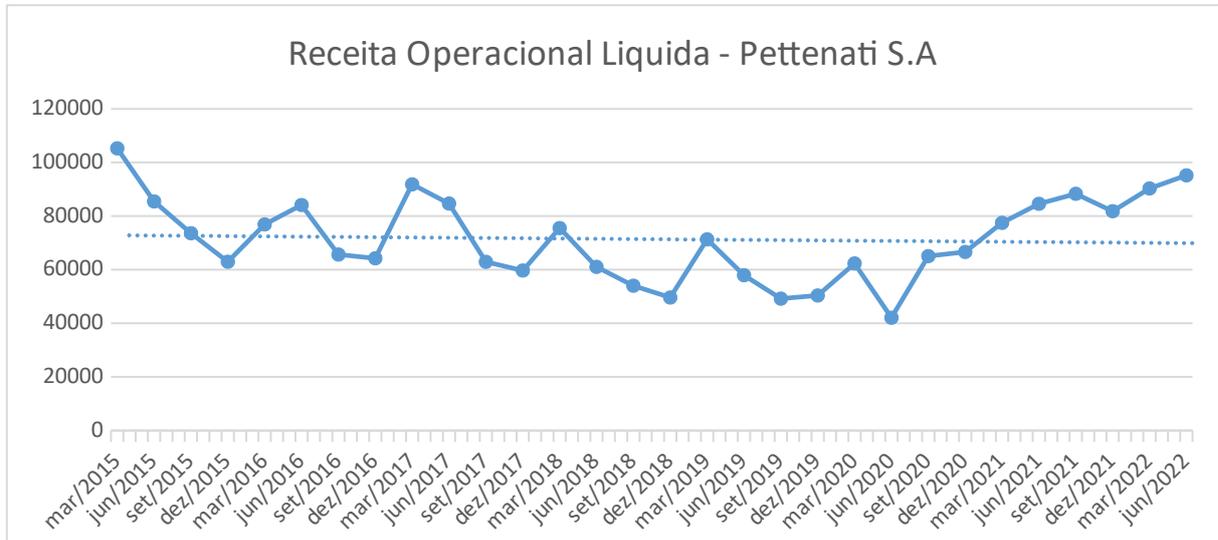


Fonte: elaboração própria.

Analisando o ROL da Indústria Cataguases, nota-se uma tendência de decréscimo, com sazonalidade fortemente presente. Após a queda sofrida em 2020 a Indústria adotou medidas e realizou planejamentos que previam um novo ciclo de crescimento. A alta demanda pelos produtos nos mercados interno e externo, combinados a um aumento da eficiência operacional surtiram o efeito desejado. No ano de 2021, registrou-se resultados operacionais robustos, a Receita Líquida cresceu 52,9% comparada a 2020 e 20% quando comparada a 2019.

Apesar dos resultados positivos de 2021, não é esperado o mesmo cenário para 2022, os fatores são vários, entre eles a alta geral dos preços dos insumos, piora no cenário macroeconômico, redução da disponibilidade de renda da população e aumento da taxa básica de juros. Estes pontos devem ser sentidos com mais força ao longo de 2022, razão pela qual a Companhia busca reforçar ainda mais sua gestão operacional de forma a garantir o melhor uso de seus recursos.

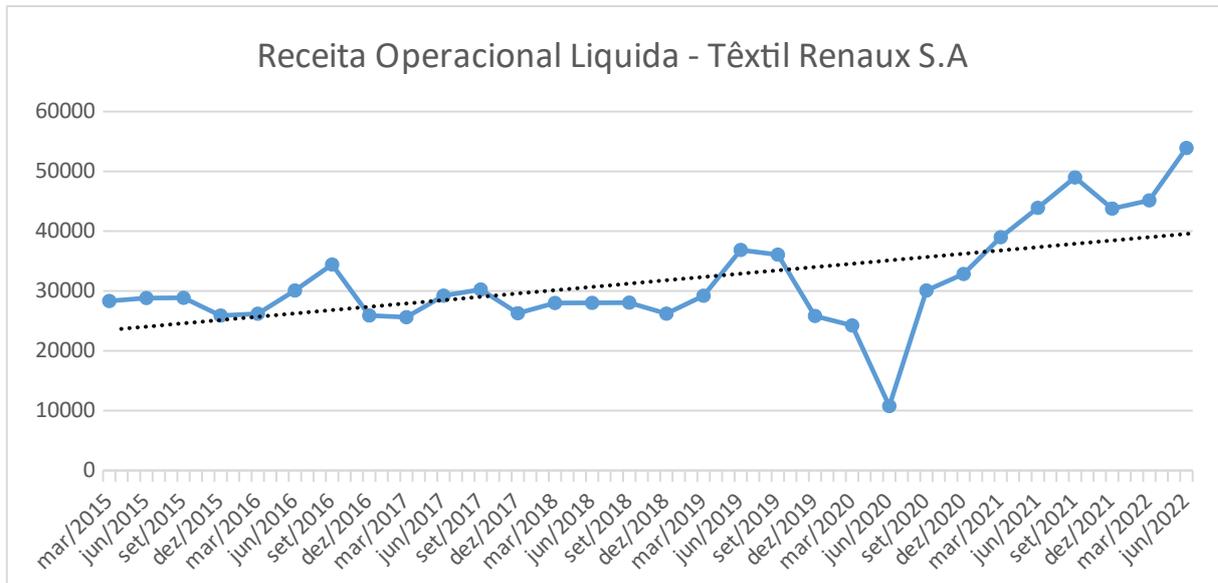
Figura 11 – Dados históricos da ROL – Pettenati S.A



Fonte: elaboração própria.

Observa-se uma fraca tendência de decrescimento, com picos de sazonalidade trimestrais. Após a queda de faturamento originária da pandemia do COVID, a empresa cresceu fortemente a partir de 2021. Parte da melhora nos resultados deu-se pela recuperação de impostos, oriundo dos processos de exclusão do ICMS na base de cálculo do Pis e da Cofins. Junto disso, temos uma melhora no setor econômico, frente as mudanças sociais causadas pela diminuição das restrições de circulação do COVID, o que ativamente contribuiu para a melhora no faturamento.

Figura 12 – Dados históricos da ROL –Textil Renaux S.A



Fonte: elaboração própria.

Os dados analisados da empresa Têxtil Renaux mostram uma forte tendência de crescimento, com picos de sazonalidade trimestrais, fator que se mostrou presente em todas as séries analisadas, devido as características sazonais do setor têxtil.

O faturamento de 2021 foi superior se comparado ao ano de 2020, que foi fortemente impactado pela pandemia da COVID-19. Comparando os três primeiros trimestres de 2020 com de 2021, temos um crescimento de 103% nas receitas. A maior perda no faturamento do ano de 2020 ocorreu no segundo trimestre, resultando numa perda total de 44% no período. Entretanto 2020 terminou com um resultado positivo, com uma grande retomada em seu faturamento em setembro, que se manteve durante o ano de 2021.

O ano de 2022 teve um comportamento muito similar ao final de 2021, com um bom nível de pedidos e faturamento, em contraste, o instável cenário no qual o mundo se encontra, tende a elevar os custos de produção do algodão e os níveis de inflação, além da taxa de cambio volátil devido ao ano de eleições. O que pode vir a impactar no faturamento dos meses que virão.

5.5 ESCOLHA E IMPLEMENTAÇÃO DOS MÉTODOS DE PREVISÃO

Com os dados e demandas definidas, assim como suas características identificadas, buscou-se escolher que métodos de previsão mais se adequavam as empresas, para posterior aplicação.

Os modelos quantitativos escolhidos para serem comparados devem permitir que a série apresente tendência e sazonalidade nas demandas, de modo que os métodos escolhidos foram: Modelo SARIMA, Holt-Winters Multiplicativo e Aditivo, e o modelo de Redes Neurais.

5.6 APLICAÇÃO DOS MODELOS

Com o objetivo de identificar como a tendência, sazonalidade e a aleatoriedade se comportam em cada série, foi feita uma decomposição de seus dados históricos através do software R, para isso se utilizou a biblioteca Forecast.

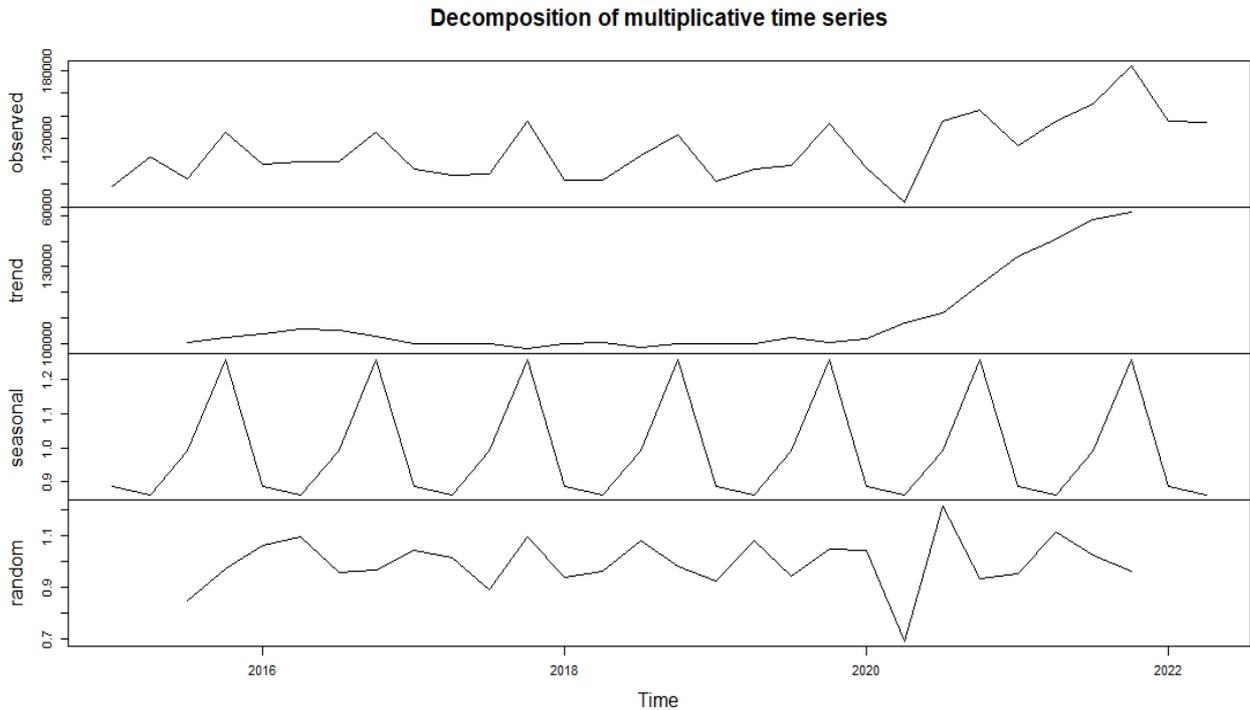
A tendência representa a forma como os dados tendem a se desenvolver ao longo do tempo, já a sazonalidade mostrará a existência de variações regulares ao longo do tempo, o termo aleatório são flutuações de curto prazo, sem uma explicação muito clara, considerados um deslocamento aleatório, portanto de difícil previsão.

Após analisado esses pontos foram aplicados os modelos estatísticos SARIMA, Holt-Winters Multiplicativo e Aditivo e Redes neurais. Finalizadas as previsões foram analisados a acuracidade de cada modelo, com objetivo de decidir qual deles fornece a melhor previsão.

5.6.1.1 *Karsten S.A*

A figura 2 demonstra a decomposição temporal da série temporal dos dados referentes a empresa Karsten S.A.

Figura 13 – Decomposição da ROL para a empresa Karsten S.A



Fonte: elaboração própria.

A decomposição evidencia uma tendência de crescimento a partir a partir do ano de 2020. A componente de sazonalidade se mostra fortemente presente. Dessa forma fica demonstrado claramente forte sazonalidade e tendência na série, comportamento já esperado do setor.

Em seguida foi aplicado o modelo Arima, Holt-Winters Aditivo/Multiplicativo e Redes Neurais para realizar as previsões dos próximos dois anos.

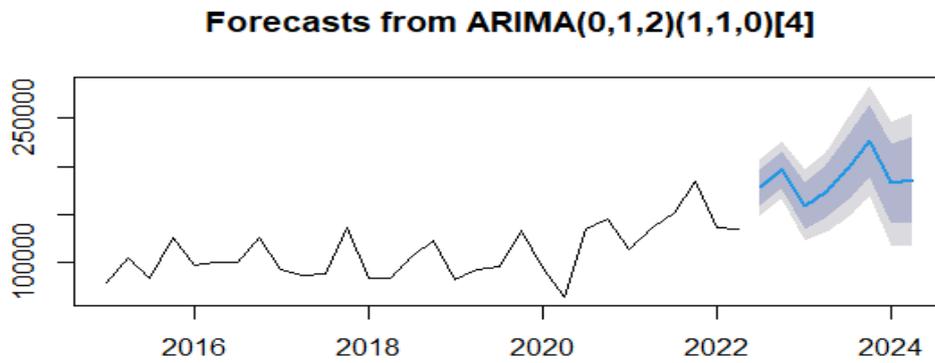
Modelo SARIMA

Utilizou-se o pacote Forecast, desenvolvido por Hyndman e Khandakar (2008), que automatiza o processo de obtenção de previsões, tal pacote contém uma biblioteca específica para execução do modelo SARIMA. Tal biblioteca usa a métrica de Critério de Informação Akaike (AIC). De acordo com Velasco(2019), a métrica obtém conjuntos de cada parâmetro p , d e q . Esses conjuntos geram um desempenho AIC possibilitando encontrar qual deles fornecem parâmetros que geram a melhor previsão. Dessa forma, os parâmetros p , d , e q são escolhidos de acordo com o menor AIC gerado.

Inicialmente foram encontrados os parâmetros ótimos $(p,d,q)(P,D,Q)_m$ da série temporal, com o primeiro parêntese referindo à parte não-sazonal do modelo e m identificando o número de períodos sazonais da série. Os parâmetros definidos como ótimos para o modelo SARIMA foram $(0,1,2)(1,1,0)_4$.

Dessa forma, conclui-se que para gerar estacionariedade foi necessária 1 diferenciação na parte sem sazonalidade, sendo que seus dados trimestrais podem ser explicados pelos erros dos últimos dois trimestres. Já na parte com sazonalidade houve 1 defasagem de 1º ordem, e os dados trimestrais não podem ser explicados pelos erros de seus valores anteriores. A Figura 3 apresenta a previsão para os próximos 12 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores. Nota-se que nos primeiros 12 meses a previsão está mais próxima do intervalo de confiança, já no segundo tem-se um distanciamento maior desse intervalo. Isso ocorre devido as incertezas ao se prever períodos muito longos, por tal motivo teve-se como objetivo principal analisar as projeções para os próximos 12 meses e complementarmente os 12 últimos meses. A figura 14 mostra a previsão para o método SARIMA.

Figura 14 – Previsão SARIMA da ROL para a empresa Karsten S.A

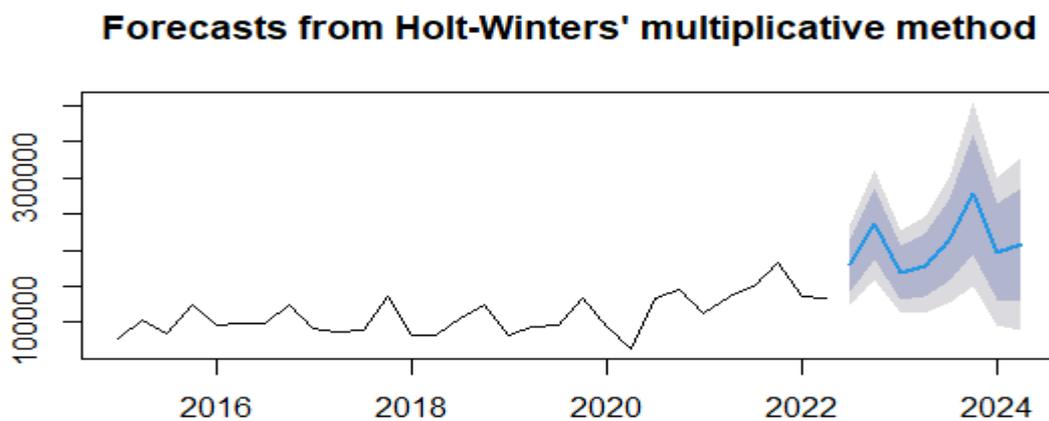


Fonte: elaboração própria.

Modelo Holt-Winters Aditivo/Multiplicativo

Ao aplicar o modelo de Holt-Winters foi analisado o parâmetro alpha, devido a forte influência no comportamento das previsões, tal parâmetro varia de 0 a 1, definindo qual conjunto de dados terá mais impacto nos dados previstos, os períodos passados ou períodos atuais. Quanto mais próximo de 1 alpha estiver maior influência terão os períodos trimestrais finais da série temporal na previsão, concluindo-se que o cenário atual irá se manter. A Figura 15 mostra a previsão dentro do intervalo de confiança de 80% a 95% nos valores.

Figura 15 – Previsão Holt-Winters Multiplicativa da ROL para a empresa Karsten S.A



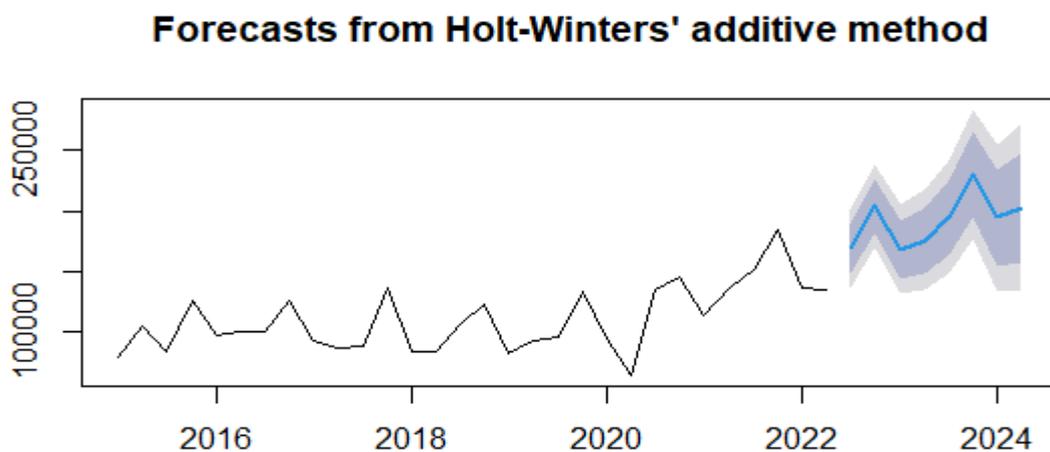
Fonte: elaboração própria.

Os parâmetros de suavização do modelo HW Multiplicativo encontrados foram:

- Alpha: 0.1325
- Beta 0.1325
- Gama: 1e-04

Dessa forma nota-se que no modelo Multiplicativo foi encontrado um valor de alpha baixo, portanto foi dado prioridade aos dados passados, ou seja, considerou-se que os períodos de pré-pandemia e os últimos dois trimestres influenciam de forma mais significativa as previsões dos próximos 24 meses. A Figura 16 mostra a previsão do modelo Aditivo do método de Holt-Winters, dentro do intervalo de confiança de 80% a 95%.

Figura 16 – Previsão Holt-Winters Aditiva da ROL para a empresa Karsten S.A



Fonte: elaboração própria.

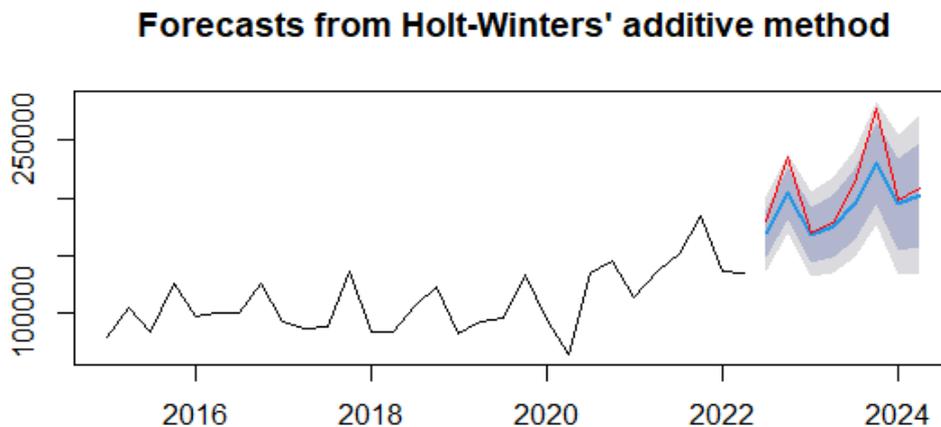
Os parâmetros de suavização do modelo HW Aditivo encontrados foram:

- Alpha: 0.2483
- Beta 0.1109
- Gama: 1e-04

Nota-se no modelo Aditivo o alpha ainda se mantém pequeno, novamente proporcionando maior peso e conseqüente importância aos períodos passados. Resultando em

uma maior influência nas previsões do período pré-pandêmico e últimos trimestres de pandemia. Realizando agora uma comparação entre o modelo Aditivo e Multiplicativo obtemos o seguinte gráfico ilustrado na Figura 17:

Figura 17 – Previsões HW Multiplicativa/Aditiva da ROL para a empresa Karsten S.A



Fonte: elaboração própria.

Legenda: Vermelho = HW Multiplicativo; Azul = HW Aditivo

Observa-se um comportamento parecido em ambos métodos, dando preferência aos dados passados para projetar os dados futuros, dessa forma consideram que o cenário de pré-pandemia e pandemia se manterá nos próximos trimestres.

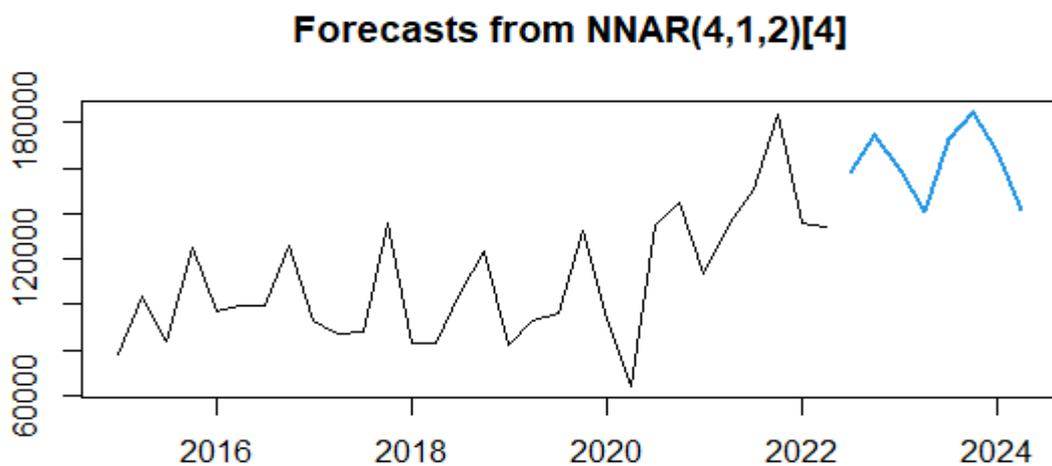
Modelo Redes Neurais

O modelo de rede neural usado pertence a uma biblioteca específica do R e denomina-se nnetar. Este modelo funciona de forma semelhante aos neurônios do cérebro, com uma arquitetura da rede neural composta por camadas.

A rede neural descrita funciona de forma auto regressiva no formato NNAR(p, P, k)m, onde: p é o número de observações passadas utilizadas; P é a quantidade de observações equivalentes dos períodos anteriores utilizadas, no caso de séries com sazonalidade; k é o número de nós ou “neurônios” da camada oculta; e m é o número de observações por ano (NEVES; DORNELES; BELTRÃO, 2020).

O conjunto identificado como ótimo foi o $(4,1,2)_4$. Neste modelo, identificou-se o $p = 4$, que representa uma rede neural para dados sazonais com as últimas 4 observações utilizadas como entradas, de ordem sazonal $P = 1$, portanto possui 1 lag sazonal, $size = 2$, possuindo dois neurônios na camada oculta e tamanho do número de observações de 4 trimestres. A Figura 18 traz a representação gráfica das previsões realizadas.

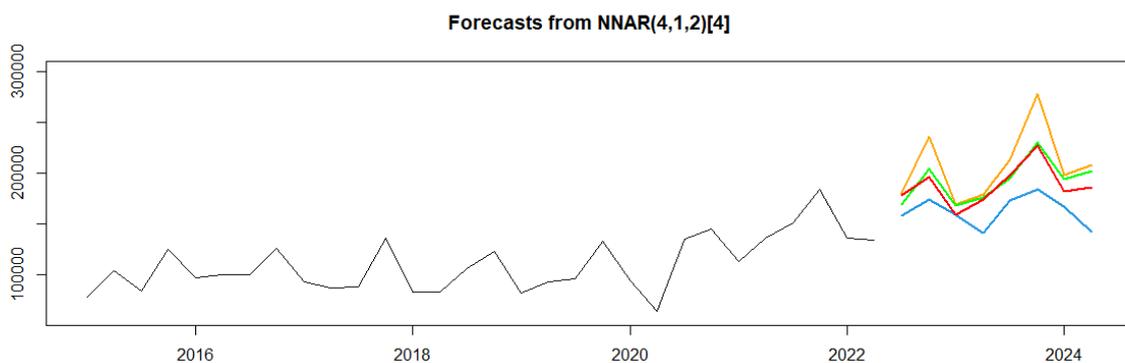
Figura 18 – Previsões do modelo NNAR $(4,1,2)_4$ da ROL para a empresa Karsten S.A



Fonte: elaboração própria.

Como forma de sintetizar a visualização dos resultados, os gráficos com as previsões de cada modelo e a série original foram compilados na Figura 19.

Figura 19 – Comparação entre os modelos preditivos para a Karsten S.A



Fonte: elaboração própria.

Legenda: Verde = HW Aditivo; Laranja = HW Multiplicativo; Vermelho: SARIMA ; Azul: Rede Neural

Pode-se observar que os modelos HW Multiplicativo, Hw Aditivo e SARIMA obtiveram comportamentos semelhantes, mas com o modelo HW Multiplicativo prevendo receitas superiores a todas as outras previsões, sendo, portanto, mais otimista em relação as previsões futuras. Já o modelo das redes neurais previu um cenário de manutenção das receitas dos últimos trimestres, iniciando em meados de 2023, sendo previsões mais estáveis, estando de acordo com as tendências apontadas para o setor têxtil pela ABIT(2022), que é de desaceleramento e estabilidade do setor.

Após a etapa de previsão foram calculadas as medidas de acuracidades MAPE, RMSE, MAE e MASE de cada modelo.

Tabela 1 – Teste de Acuracidade da empresa Karsten S.A

	RMSE	MAE	MAPE	MASE
Rede Neural	6263,438	4581,925	4.6 %	0,288063
SARIMA	12725,11	9166,68	8.7%	0,576305
HW Aditivo	13965,61	10992,28	10.40%	0,691079
HW Multiplicativo	13798,66	11009,68	10.42%	0,692173

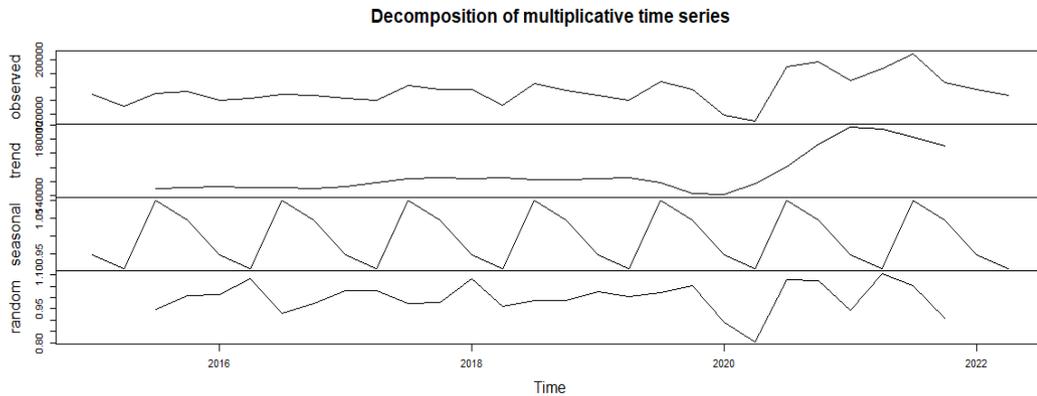
Fonte: elaboração própria.

O modelo Rede Neural obteve os melhores resultados nos quatro testes. Conclui-se que a projeção mais acurada nos próximos 24 meses da empresa Karsten S.A é previsto pelo modelo de Rede Neural.

5.6.1.2 Dohler S.A

A figura 20 demonstra a decomposição temporal da série temporal dos dados referentes a empresa Dohler S.A.

Figura 20 – Decomposição da ROL para a empresa Dohler S.A



Fonte: elaboração própria.

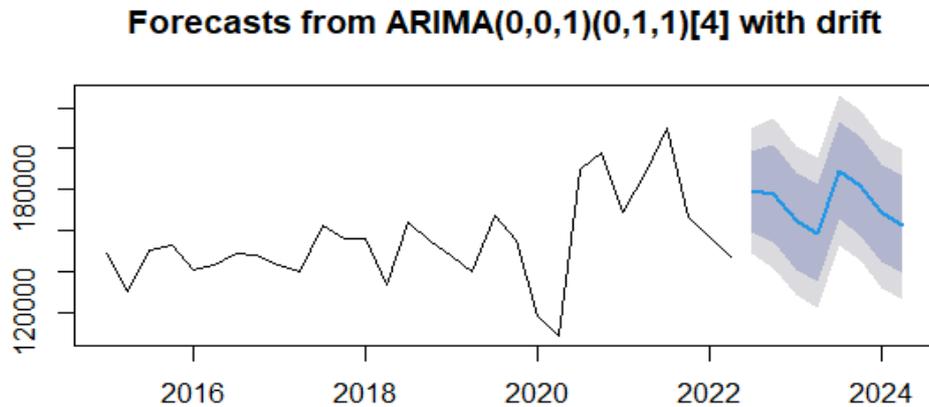
A decomposição evidencia uma tendência de crescimento a partir do início de 2020. A componente de sazonalidade se mostra fortemente presente em períodos trimestrais. Dessa forma fica evidente a presença de sazonalidade e tendência na série. Segundo a proposta metodológica do estudo foi aplicado o modelo Arima, Holt-Winters Aditivo/Multiplicativo e Redes Neurais para realizar as previsões dos próximos 24 meses.

Modelo Arima

Inicialmente foram encontrados os parâmetros ótimos $(p,d,q)(P,D,Q)_m$ da série temporal. Os parâmetros definidos como ótimos para o modelo SARIMA foram $(0,0,1)(0,1,1)_4$.

Portanto para gerar estacionariedade não foram necessárias diferenciações, já um de seus dados trimestrais podem ser explicados pelo erro do último trimestre. Na parte com sazonalidade houve 1 diferenciação da série, e um dado trimestral pode ser explicado pelo erro de seu valor anterior. A Figura 21 apresenta a previsão para os próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.

Figura 21 – Previsão SARIMA da ROL da empresa Dohler S.A

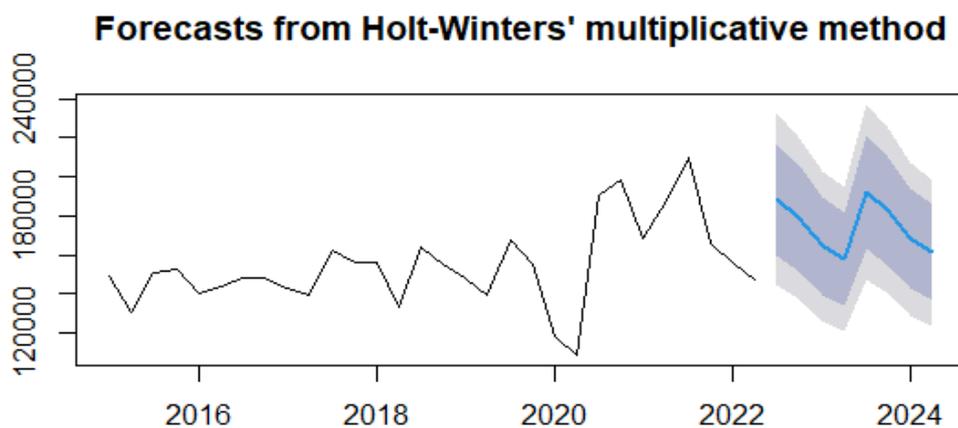


Fonte: elaboração própria.

Modelo Holt-Winters Aditivo/Multiplicativo

Inicialmente aplicou-se o modelo de Holt-Winters Multiplicativo, obteve-se o gráfico ilustrado na figura 22.

Figura 22 – Previsão Holt-Winters Multiplicativo da ROL da empresa Dohler S.A



Fonte: elaboração própria.

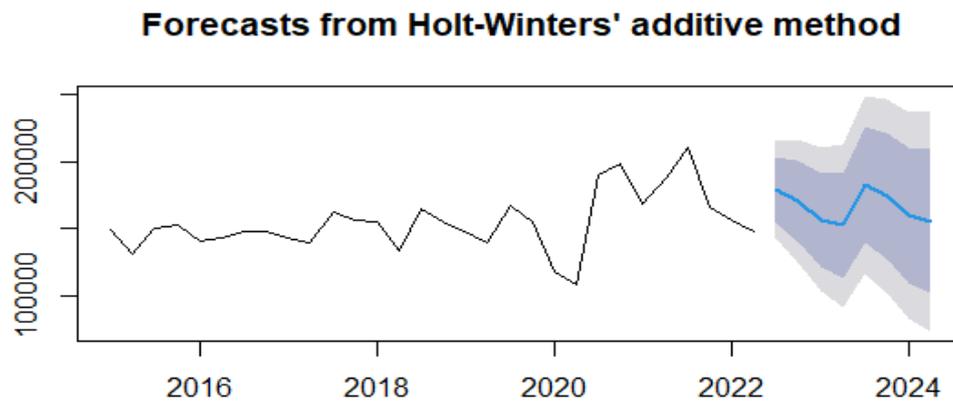
Os parâmetros de suavização do modelo HW Multiplicativo encontrados foram:

- Alpha: 0.024

- Beta: 1e-04
- Gama: 4e-04

Ao analisar o parâmetro alpha encontrado pode-se concluir que foi dado prioridade aos dados passados, ou seja os períodos de pré-pandemia influenciam fortemente as previsão dos próximos 24 meses. A Figura 23 demonstra a previsão obtida através do modelo Aditivo de Holt-Winters, dentro do intervalo de confiança de 80% a 95%:

Figura 23 – Previsão Holt-Winters Aditivo da ROL para a empresa Dohler S.A



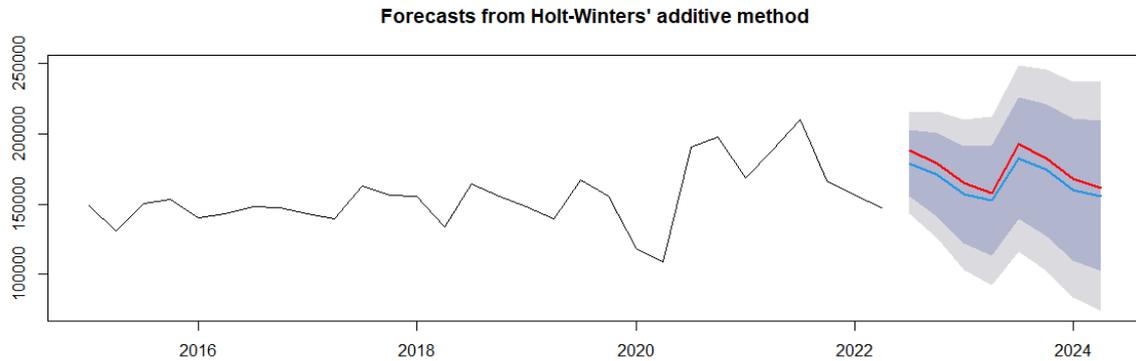
Fonte: elaboração própria.

Os parâmetros de suavização do modelo HW Aditivo encontrados foram:

- Alpha: 0.7701
- Beta: 1e-04
- Gama: 1e-04

Nota-se no modelo Aditivo que o alpha está próximo de um, resultando em um cenário no qual os últimos trimestres influenciam fortemente o resultado da previsão. Portanto considera-se as receitas líquidas do período pós-pandêmico ser manterão equivalentes. Realizando agora uma comparação entre o modelo Aditivo e Multiplicativo obtemos o gráfico ilustrado na Figura 24.

Figura 24 – Previsões HW Multiplicativa/Aditiva da ROL para a empresa Dohler S.A



Fonte: elaboração própria.

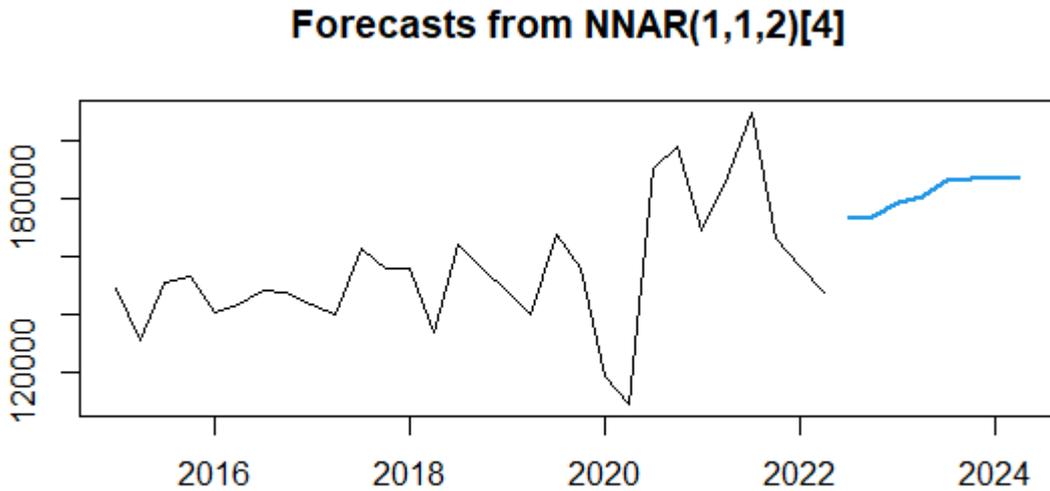
Legenda: Vermelho = HW Multiplicativo; Azul = HW Aditivo

Contrastando com as projeções da empresa Karsten S.A, o modelo HoltWinters Multiplicativo da empresa Dohler S.A não apresentou forte variação em relação ao modelo Aditivo. O comportamento apresentado é devido ao primeiro priorizar dados passados, menos voláteis, já o ultimo atribui maior peso aos trimestres recentes, que possuem mais volatilidade ao longo do tempo. A diferença observada na previsão de receita entre os dois métodos, ocorre devido ao modelo Multiplicativo incluir seu fator multiplicativo nas projeções futuras.

Modelo Redes Neurais

Utilizando o modelo de redes neurais, foi identificado o conjunto (1,1,2)4 como ótimo. Identificou-se $p = 1$, que representa uma rede neural voltada para dados sazonais com a última observação utilizada como entrada, possui 1 defasagem e $size = 2$, tendo dois neurônios na camada oculta e tamanho do número de observações de 4 trimestres. A Figura 25 traz a representação gráfica das previsões realizadas.

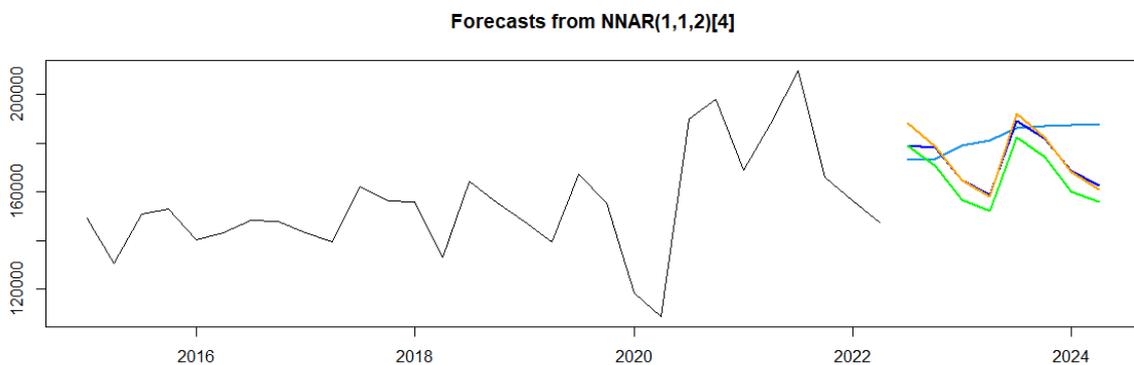
Figura 25 – Previsões do modelo NNAR (1,1,2)₄ da ROL da empresa Dohler S.A



Fonte: elaboração própria.

Verifica-se que o modelo não seguiu a sazonalidade dos outros períodos. Isso ocorreu pois foi definido o $p = 1$, portanto utilizou-se apenas uma defasagem realizar as projeções, não sendo suficiente para captar os picos e vales sazonais. Com objetivo de sintetizar os resultados, os gráficos com as previsões de cada modelo e a série original foram compilados na Figura 26.

Figura 26 – Comparação entre os modelos preditivos para a empresa Dohler S.A



Fonte: elaboração própria.

Legenda: Verde = HW Aditivo; Laranja = HW Multiplicativo; Vermelho: SARIMA ; Azul: Rede Neural

Pode-se observar que os modelos HW Multiplicativo e SARIMA obtiveram comportamentos semelhantes, já o modelo HW Aditivo prevê um resultado que acompanha o último trimestre. O modelo das redes neurais prevê um cenário intermediário das receitas dos últimos trimestres.

Após a etapa de previsão foram calculadas as medidas de acuracidades RMSE, MAE, MAPE e MASE de cada modelo, representadas na Tabela 2:

Tabela 2 – Teste de Acuracidade da empresa Dohler S.A

	RMSE	MAE	MAPE	MASE
Rede Neural	12360,02	9400,19	6,22%	0,5374
SARIMA	13159,70	9615,44	6,29%	0,5497
HW Aditivo	15757,68	11294,12	7,24%	0,6457
HW Multiplicativo	15988,88	12229,25	8,09%	0,6992

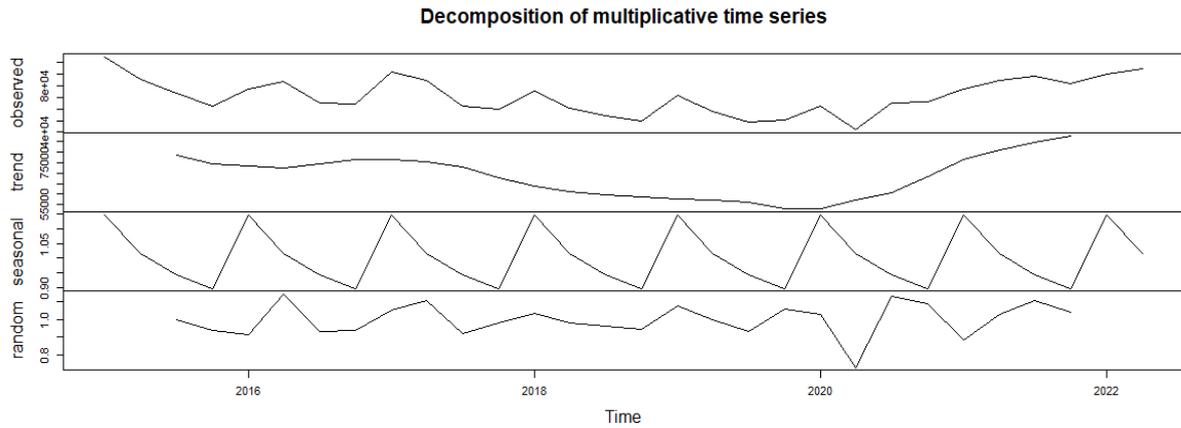
Fonte: elaboração própria.

O modelo Rede Neural obteve os melhores resultados em todos os testes. Conclui-se, portanto, que em termos residuais a melhor projeção para os próximos 24 meses da empresa Dohler S.A é previsto pelo modelo Rede Neural. Porém a abordagem do modelo SARIMA se mostra mais oportuna, pois obteve erros residuais muito próximos ao modelo de Redes Neurais e projeta as sazonalidades que certamente ocorrerão no futuro, conforme demonstrado pela decomposição da série na Figura 7.

5.6.1.3 Pettenati S.A

A figura 27 demonstra a decomposição da série temporal referente a empresa Pettenati S.A.

Figura 27 – Decomposição da ROL da empresa Pettenati S.A



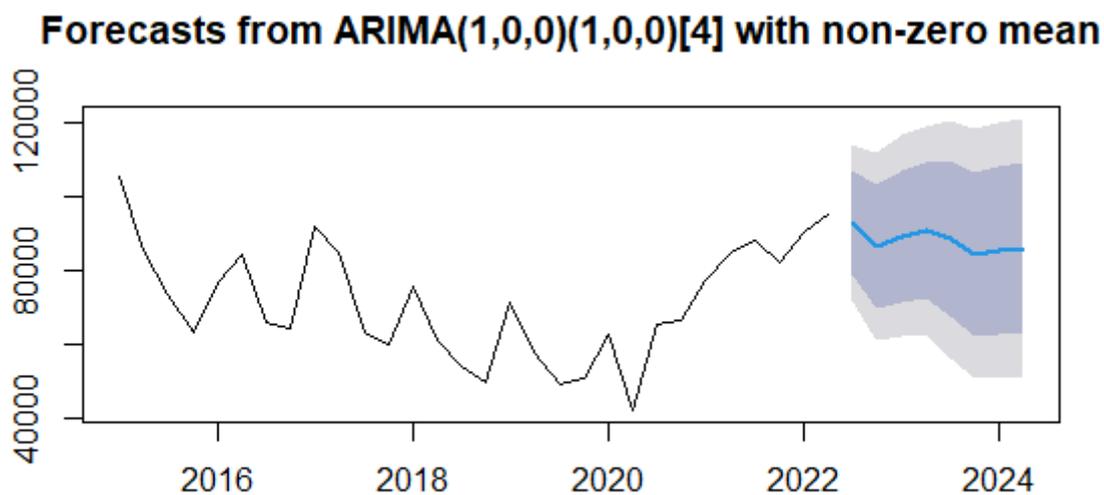
Fonte: elaboração própria.

Analisando a decomposição da série, podemos notar uma tendência de crescimento no início de 2020. A sazonalidade está fortemente presente, com picos trimestrais bem definidos e intervalados. Deste modo, constata-se a presença das componentes sazonais e de tendência na série. Em seguida foi aplicado o modelo Arima, Holt-Winters Aditivo/Multiplicativo e Redes Neurais para realizar as previsões dos próximos 24 meses.

Modelo Arima

Inicialmente foram definidos os parâmetros (p, d, q) $(P, D, Q)_m$ da série. De acordo com o modelo selecionado, os parâmetros $(1,0,0)$ $(1,0,0)_4$ foram considerados ótimos. Pode-se notar que na parte sem sazonalidade ocorreu 1 defasagem, sem necessidade de diferenciar a série para obter a estacionariedade. Enquanto na parte com sazonalidade houve também 1 defasagem, sem necessidade de diferenciação ou explicação pelos erros. A figura 28 representa a previsão para os próximos 24 meses, dentro do intervalo de confiança de 80% a 95%.

Figura 28 – Previsão SARIMA da ROL da empresa Pettenati S.A

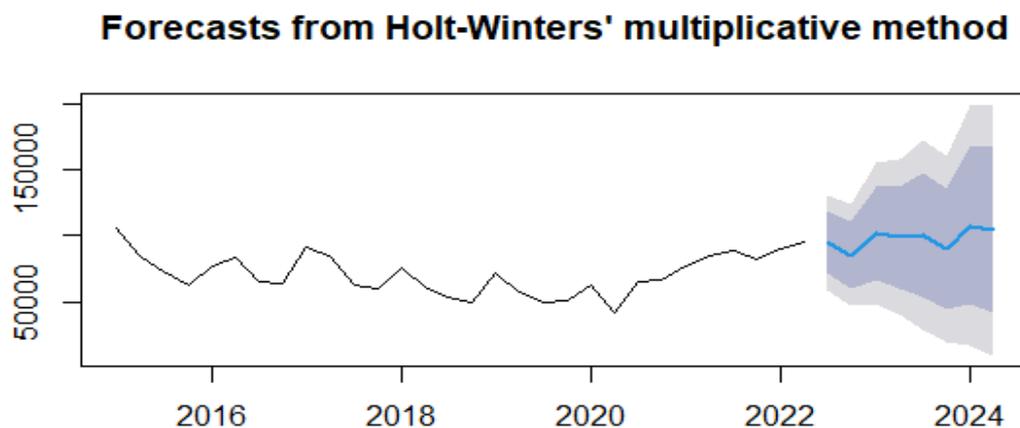


Fonte: elaboração própria.

Modelo Holt-Winters Aditivo e Multiplicativo

Primeiramente aplicou-se o modelo de Holt-Winters Multiplicativo para a série, posteriormente sendo gerada a previsão representada pela Figura 29.

Figura 29 – Previsão Holt-Winters Multiplicativo da ROL da empresa Pettenati S.A



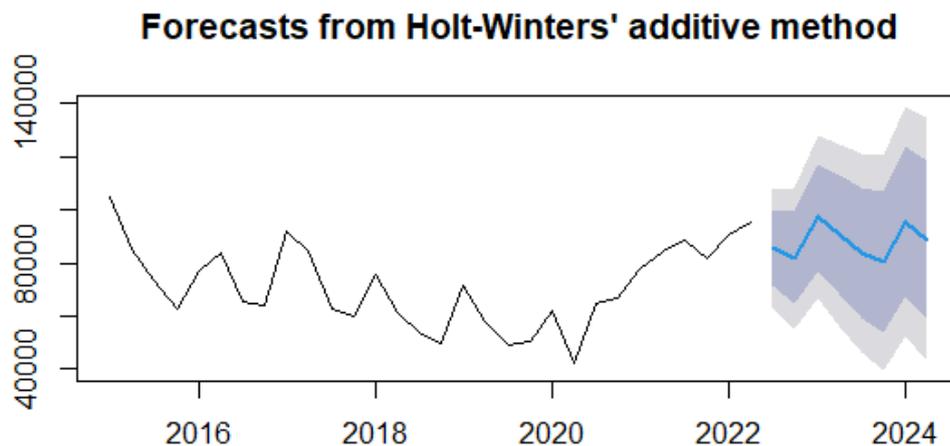
Fonte: elaboração própria.

Foi encontrado se os seguintes valores para Alpha, Beta e Gamma:

- Alpha = 0.6145
- Beta = 0.0415
- Gamma = 0.2744

Observando o valor de Alpha, verifica-se que está próximo de 1, portanto foi dado mais importância aos dados recentes, resultando em um cenário no qual os últimos trimestres foram mais determinantes para a previsão obtida. Dessa forma foi considerado que o cenário de receitas líquidas estabelecido pelo período pós-pandêmico irá se manter nos próximos dois anos. A Figura 30 representa a previsão obtida através do modelo Aditivo de Holt-Winters, dentro do intervalo de confiança de 80% a 95%.

Figura 30 – Previsão Holt-Winters Aditivo da ROL da empresa Pettenati S.A



Fonte: elaboração própria.

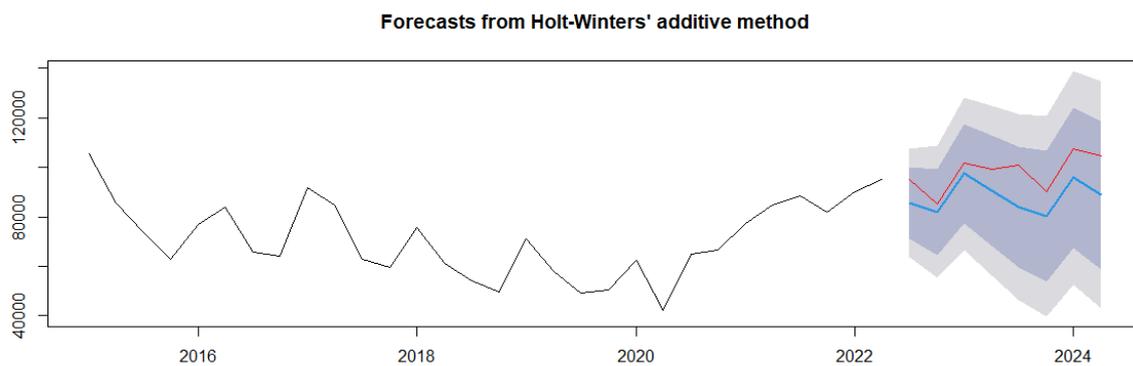
Aplicando o modelo de Holt-Winters Aditivo foram encontrados os seguintes parâmetros para Alpha, Beta e Gamma:

- Alpha = 0,6948
- Beta = 1e-04
- Gamma = 1e-04

O valor definido para Alpha, similar ao modelo Multiplicativo, está próximo de 1, implicando em uma previsão que será mais influenciada pelos períodos recentes. Consequentemente, os últimos trimestres, referentes ao período de saída de pandemia, terá maior predominância na previsão, estabelecendo um cenário de continuação do período pós-pandêmico para os próximos 24 meses.

Realizando uma comparação entre os dois modelos, obtemos o gráfico representado pela Figura 31.

Figura 31 – Previsões HW Multiplicativa/Aditiva da ROL da empresa Pettenati S.A



Fonte: elaboração própria.

Legenda: Vermelho = HW Multiplicativo; Azul = HW Aditivo

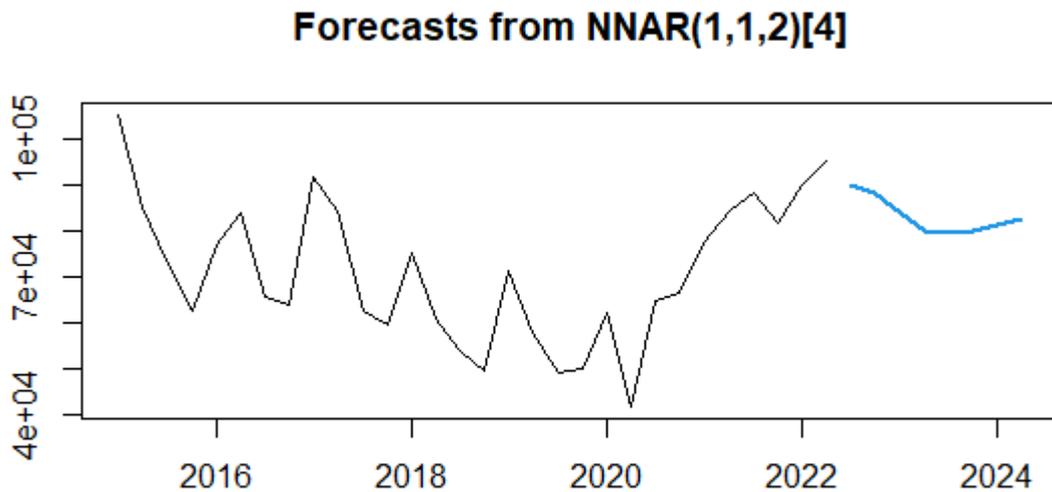
Observa-se um comportamento similar das receitas projetadas pelos dois modelos. Isso ocorre pois ambos possuem praticamente o mesmo valor de Alpha, atribuindo mais peso aos últimos trimestres. A diferença observada nos picos e vales, é devido ao modelo Multiplicativo ter associado a si o fator multiplicativo, fazendo com que as receitas previstas por ele tenham mais amplitude que o Aditivo.

Modelo Redes Neurais

Aplicou-se o modelo de redes neurais, sendo identificado o conjunto (1,1,2)4 como ótimo. Neste modelo, identificou-se o $p = 1$, significando que é uma rede neural voltada para

dados sazonais, com ordem sazonal 1 e size = 2, ou seja, utiliza-se 1 lag sazonal, possui dois neurônios na camada oculta e número de observações é de 4 trimestres. A Figura 32 traz a representação gráfica das previsões obtidas.

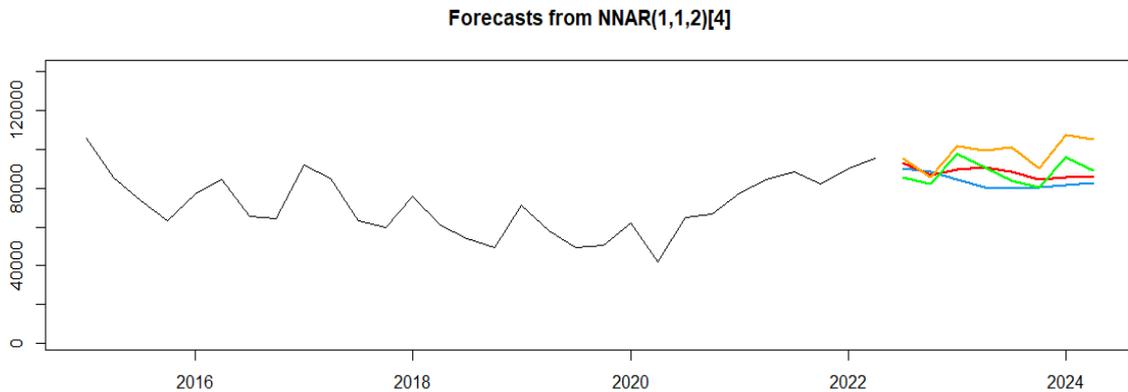
Figura 32 – Previsões do modelo NNAR (1,1,2)₄ da ROL para a empresa Pettenati S.A



Fonte: elaboração própria.

Com objetivo de fornecer uma visão global dos resultados obtidos com as previsões de cada modelo, compilou-se os gráficos na Figura 33.

Figura 33 – Comparação entre os modelos preditivos para a empresa Pettenati S.A



Fonte: elaboração própria.

Legenda: Verde = HW Aditivo; Laranja = HW Multiplicativo; Vermelho: SARIMA ; Azul: Rede Neural

Observa-se que entre as previsões, a obtida pelo modelo Redes Neurais e SARIMA fornecem as menores oscilações sazonais, isso ocorre devido ao enfoque maior dado nos últimos trimestres, este bem mais ameno quando comparado aos períodos anteriores. Como resultado os modelos fornecem baixa sazonalidade nas projeções, conforme pode ser visto na Figura 33. O modelo de Holt-Winters Multiplicativo é o que fornece maior oscilação, e ocorre devido a suas previsões possuírem o fator multiplicativo associado as projeções.

Após realizar as previsões, foram encontradas as medidas de acuracidades RMSE, MAE, MAPE e MASE de cada modelo, representadas na Tabela 3:

Tabela 3 – Teste de Acuracidade da empresa Pettenati S.A

	RMSE	MAE	MAPE	MASE
Rede Neural	8137,99	6475,45	9,83%	0,54201
SARIMA	10305,36	8469,90	12,46%	0,71006
HW Aditivo	9565,74	7703,32	11,01%	0,64683
HW Multiplicativo	9124,19	7078,26	10,11%	0,59340

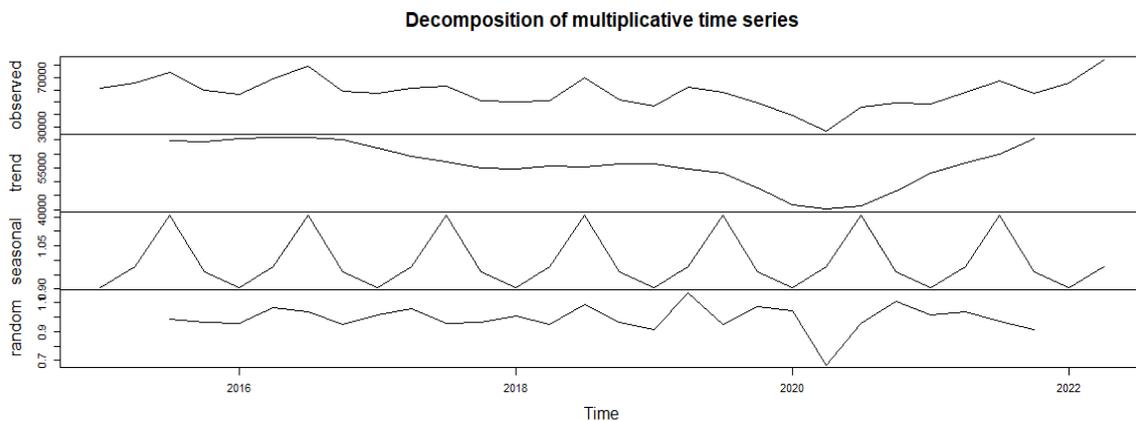
Fonte: elaboração própria

O modelo Rede Neural foi o mais acurado de acordo com as quatro métricas. Conclui-se, portanto, que a melhor projeção para os próximos 24 meses da empresa Pettenati S.A é realizado pelo modelo Rede Neural. No caso da empresa Pettenati é oportuno usar o modelo de Rede Neural, frente as baixas oscilações sazonais que os períodos passados realizaram, todavia, é oportuno manter-se atento ao modelo HoltWinters Multiplicativo, que obteve valores de acuracidade muito próximos ao modelo vencedor, mas por sua vez acompanha mais aos picos e vales sazonais.

5.6.1.4 Indústria Cataguases S.A

A Figura 34 representa a decomposição da série temporal da empresa Indústria Cataguases S.A.

Figura 34 – Decomposição da ROL da empresa Industrial Cataguases



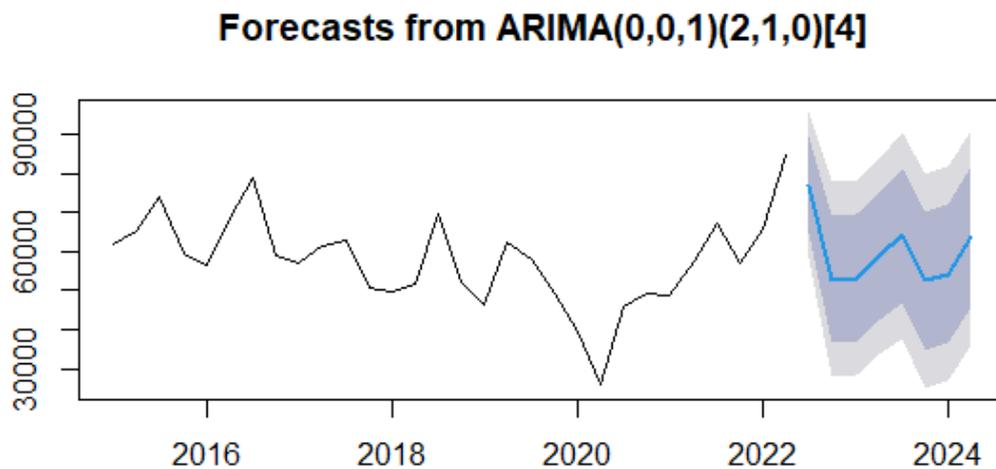
Fonte: elaboração própria.

Observando a decomposição da série, pode-se verificar uma tendência até 2019, ocorrendo uma grande queda no início de 2020, devido ao cenário de pandemia que se estabeleceu, porém com grande recuperação nos trimestres seguintes. A componente sazonal se mostra presente, com picos nos últimos trimestres de cada ano. Na sequência, foram realizadas as previsões utilizando os modelos SARIMA, Holt-Winters Aditivo/Multiplicativo, e Redes neurais.

Modelo SARIMA

No modelo SARIMA os parâmetros ótimos $(p,d,q)(P,D,Q)m$ encontrados foram $(0,0,1)(2,1,0)4$. Na parte sem sazonalidade, os dados sem defasagem foram priorizados, não havendo necessidade de diferenciação para gerar estacionariedade na série. Já seus dados trimestrais podendo ser explicados pelo erro do último trimestre. Na parte com sazonalidade houve duas defasagens de 2ª ordem, uma diferenciação e nenhum de seus dados trimestrais podem ser explicados pelos erros dos trimestres passados. A Figura 35 demonstra a previsão para os próximos 24 meses, dentro da faixa de confiança de 80% e 95%.

Figura 35 – Previsão SARIMA da Receita Operacional Líquida da empresa Dohler S.A

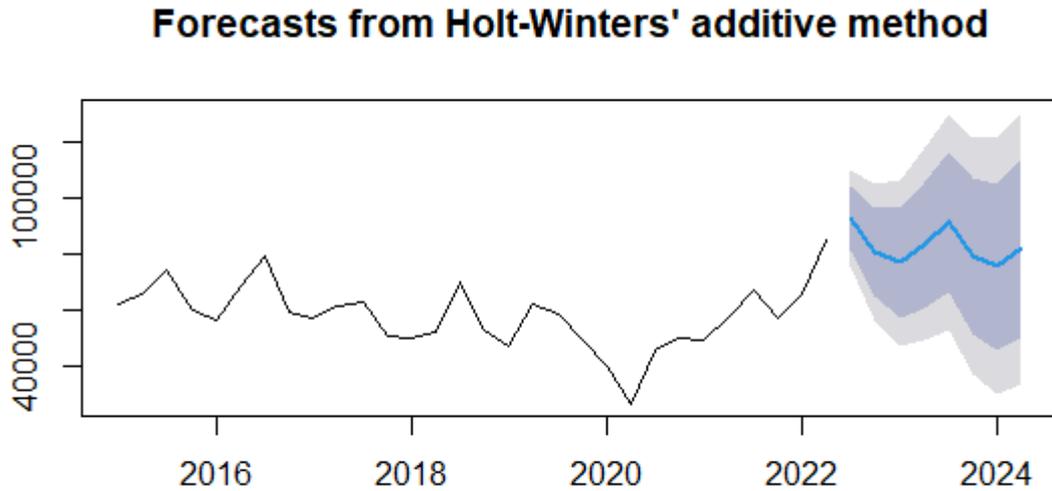


Fonte: elaboração própria.

Modelo Holt-Winters Aditivo/Multiplicativo

Inicialmente aplicou-se o modelo de Holt-Winters Multiplicativo, as previsões obtidas estão representadas na Figura 36.

Figura 36 – Previsão Holt-Winters Multiplicativo da ROL da empresa Indústrias Cataguases



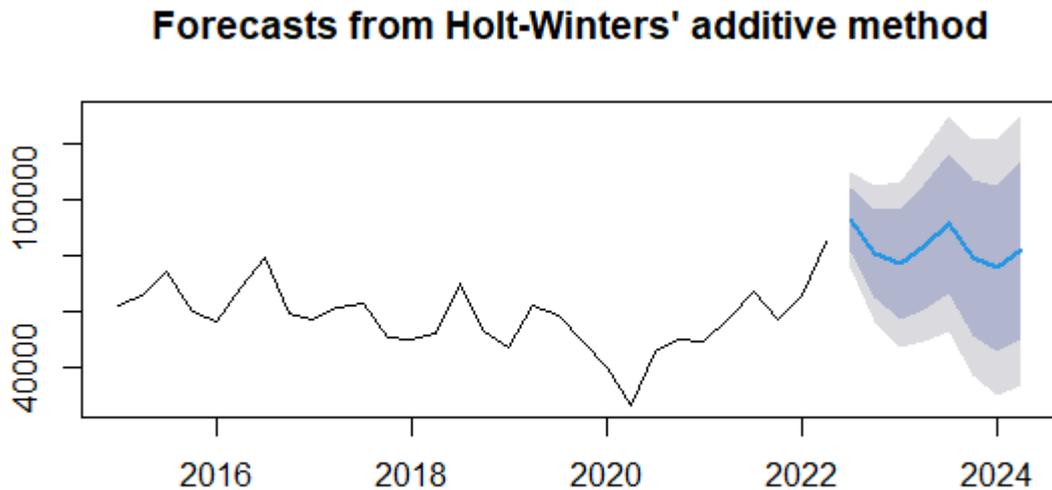
Fonte: elaboração própria.

O modelo apresentou os seguintes parâmetros de suavização:

- Alpha = 0.9252
- Beta = 1e-04
- Gamma = 1e-04

Verifica-se que o parâmetro Alpha está bem próximo de 1, implicando em um maior peso aos períodos recentes, dessa forma a previsão considerará o cenário no qual os últimos trimestres determinam o comportamento futuro dos dados. Portanto o modelo Multiplicativo considera que o cenário pós-pandêmico permanecerá pelos próximos 24 meses. Ao aplicar o modelo de Holt-Winters Aditivo, obteve-se a previsão ilustrada pela Figura 37.

Figura 37 – Previsão Holt-Winters Aditivo da ROL da empresa Indústrias Cataguases



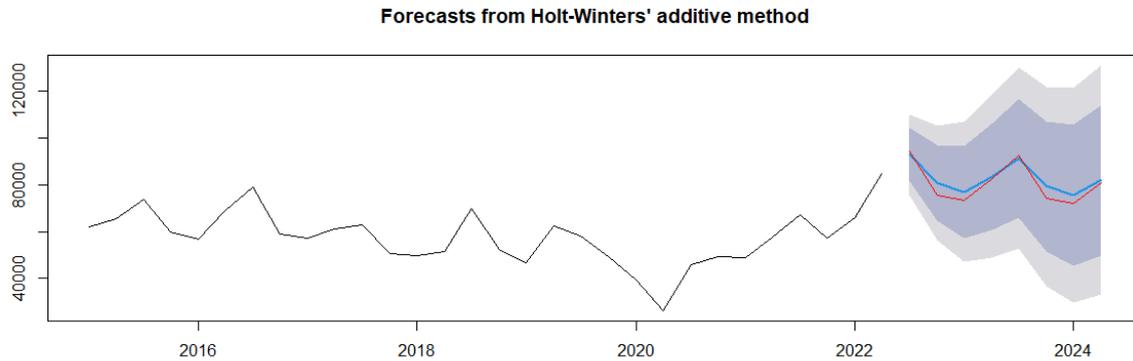
Fonte: elaboração própria.

O modelo Aditivo apresentou os parâmetros Alpha, Beta e Gamma com os seguintes valores:

- Alpha = 0.9999
- Beta = 1e-04
- Gamma = 1e-04

O parâmetro de suavização está muito próximo de 1, portanto a previsão de receitas líquidas dará maior relevância aos últimos trimestres, implicando em um cenário onde os dados mais recentes influenciarão o comportamento futuro da série. Realizou-se uma comparação entre o modelo Aditivo e Multiplicativo, obtendo o gráfico ilustrado na Figura 38.

Figura 38 – Previsões HW Multiplicativa/Aditiva da ROL da empresa Indústria Cataguases



Fonte: elaboração própria.

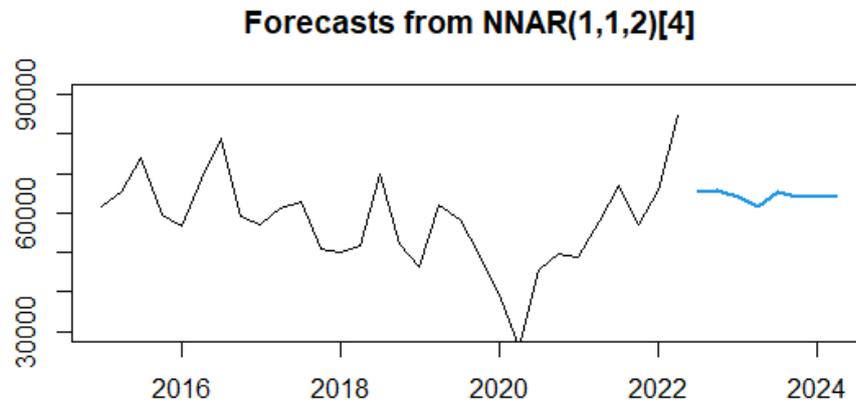
Legenda: Vermelho = HW Multiplicativo; Azul = HW Aditivo.

Constata-se um comportamento similar nas duas previsões, que ocorre devido a possuírem parâmetros de suavização próximos. Dessa forma, os dois modelos realizam a previsão com base no comportamento dos dados mais recentes.

Modelo Redes Neurais

Aplicando o modelo de redes neurais, foi encontrado o conjunto $(1,1,2)_4$ como ótimo. Portanto tem-se $p = 1$, significando que a rede neural é voltada para dados sazonais, possui ordem sazonal $P = 1$ e $size = 2$, ou seja, utiliza 1 lag sazonal, possui dois neurônios na camada oculta e tamanho do número de observações de 4 trimestres. A Figura 39 traz a representação gráfica da previsão obtida.

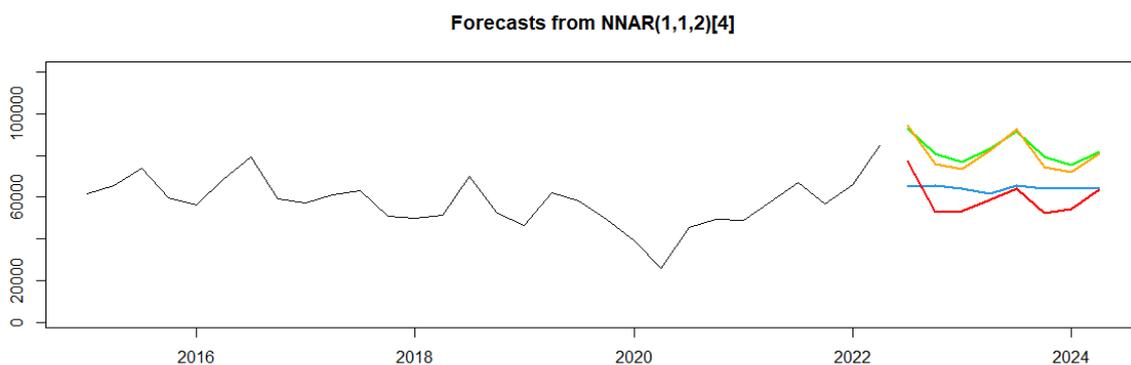
Figura 39 – Previsões do modelo NNAR (1,1,2)₄ da ROL para Indústrias Cataguases



Fonte: elaboração própria.

Como forma de visualizar as previsões obtidas por todos os modelos, foi criado um gráfico geral, estando representado pela Figura 40.

Figura 40 – Comparação entre os modelos preditivos para a empresa Indústria Cataguases



Fonte: elaboração própria.

Legenda: Verde = HW Aditivo; Laranja = HW Multiplicativo; Vermelho: SARIMA ; Azul: Rede Neural

É possível observar que os modelos SARIMA e Holt-Winters Multiplicativo e Aditivo tiveram comportamentos semelhantes, porém o modelo SARIMA projetou receitas inferiores,

enquanto o modelo Rede Neural gerou previsões com tendências mais suavizadas em relação aos períodos anteriores, sendo um valor médio entre as projeções.

Em seguida foram obtidas as medidas de acuracidades RMSE, MAE, MAPE e MASE de cada modelo, representadas na Tabela 4.

Tabela 4 – Teste de Acuracidade da Indústria Cataguases S.A

	RMSE	MAE	MAPE	MASE
Rede Neural	8101,75	6812,45	12,59%	0,66413
SARIMA	8338,18	5911.16	11,59%	0,56006
HW Aditivo	7567.23	5709,04	11,28%	0,52463
HW Multiplicativo	7360,67	5463,63	10,85%	0,52340

Fonte: elaboração própria

A previsão obtida pelo modelo de Holt-Winters Multiplicativo obteve os melhores resultados em todos os testes realizados, dessa forma conclui-se que é a projeção mais acurada para os próximos 24 meses da Indústria Cataguases S.A.

É possível observar que os modelos SARIMA e Holt-Winters Multiplicativo e Aditivo tiveram comportamentos semelhantes, porém o modelo SARIMA projetou receitas inferiores, enquanto o modelo Rede Neural gerou previsões com tendências mais suavizadas em relação aos períodos anteriores, sendo um valor médio entre as projeções.

Em seguida foram obtidas as medidas de acuracidades RMSE, MAE, MAPE e MASE de cada modelo, representadas na Tabela 4.

A empresa Indústria Cataguases S.A teve melhor desempenho nos testes de acuracidade utilizando o modelo Holt-Winters Multiplicativo. Analisando as outras simulações, verifica-se que o comportamento das projeções do modelo Holt-Winters Aditivo e SARIMA estão similares ao Holt-Winters Multiplicativo, porém esse fornece melhores resultados nos testes, se mostrando a melhor previsão para a empresa.

6 CONCLUSÃO

O trabalho realizado teve como objetivo a aplicação e análise de diferentes métodos de previsão de demanda para quatro empresas do setor têxtil após o período de flexibilização, sendo elas a Karsten S.A, Dohler S.A, Pettenati S.A e Indústrias Cataguases S.A. Analisou-se as projeções para o curto prazo pelas métricas de machine learning e estatísticas para séries temporais, considerando que os modelos fariam as ponderações necessárias frente as fortes mudanças nas receitas líquidas que o período pandêmico ocasionou nas empresas do setor têxtil. Adotou-se como premissa que no momento da coleta dos dados o cenário de flexibilização permaneceria em conjunto com a presença da COVID-19. Com as previsões buscou-se identificar que método fornece maior acuracidade.

A coleta de dados foi feita através do software *Economática*, a partir dele foi possível acessar os dados históricos referentes a receita operacional líquida das empresas dos últimos 8 anos. Os dados obtidos foram utilizados para analisar série temporal de cada empresa e selecionar quais modelos de previsão seriam utilizados. Foram escolhidos quatro métodos, Holt-Winters Aditivo, Holt-Winters Multilicativo, SARIMA e Redes Neurais.

O modelo de Redes Neurais apresentou os melhores resultados na maioria dos testes de acuracidade. Nas análises da receita líquida histórica da empresa Indústria Cataguases S.A, o modelo vencedor nos testes foi o Holt-Winters Multiplicativo. Vale ressaltar que no caso da Dohler S.A o modelo de Redes Neurais venceu, porém, analisando a decomposição da empresa e o teste de acuracidade do modelo SARIMA, verifica-se que é mais vantajoso planejar a demanda utilizando esse modelo, pois adota as sazonalidades em suas projeções.

A empresa Pettenati S.A apresentou em sua série histórica sazonalidade menos acentuada devido à forte amenização das sazonalidades no período pandêmico. Dessa forma, mesmo com o modelo vencedor sendo o de redes neurais, valeria a pena observar também o Holt-Winters Multiplicativo, pois possui uma sazonalidade levemente melhor desenhada e com testes de acuracidades muito próximos ao modelo vencedor.

Analisando a empresa Karsten S.A nota-se que o modelo de Rede Neural obteve os melhores resultados em todos os testes de acuracidade, o modelo projetou uma manutenção das receitas dos últimos trimestres, o motivo é devido a utilizar 1 lag sazonal para realizar as projeções, focando no curto-prazo que apresenta baixa sazonalidade. Os modelos SARIMA, Holt-Winters Aditivo e Holt-Winters Multiplicativo obtiveram gráficos parecidos, mostrando

mais otimismo em relação as projeções futuras. Dessa forma o recomendado foi utilizar o modelo de Redes Neurais para prever os dados da empresa.

No caso da empresa Dohler S.A é observado um comportamento sazonal similar ao da Karsten S.A, sendo constante durante os últimos trimestres. O modelo de Rede Neural obteve desempenho melhor nos testes de acuracidade, porém observando as projeções do modelo SARIMA percebe-se que são muito semelhantes ao de Rede Neural, e oferta um gráfico que se mostra mais fiel ao comportamento da série, dessa forma optou-se por considerar também o modelo como apto a ser escolhido.

A empresa Indústria Cataguases S.A teve melhor desempenho nos testes de acuracidade utilizando o modelo Holt-Winters Multiplicativo. Analisando as outras simulações, verifica-se que o comportamento das projeções do modelo Holt-Winters Aditivo e SARIMA estão similares ao Holt-Winters Multiplicativo, porém esse fornece melhores resultados nos testes, se mostrando a melhor previsão para a empresa Indústria Cataguases S.A.

Como sugestão para trabalhos futuros é indicado a utilização de diferentes métodos de previsão. Também recomenda-se testar o método de HoltWinters com valores ajustados de Alpha, Beta e Gamma para projeção de cenários diferentes incluindo a eliminação da pandemia ou mesmo a volta de totais restrições sanitárias. A manipulação desses dados influencia diretamente a previsão de demanda, podendo ser ajustado de maneiras que se adequem ao cenário e a empresa desejada, seja dando maior peso aos dados recentes ou passados. Dessa forma pode-se avaliar o quanto os ajustes desses parâmetros influenciam em previsões mais confiáveis.

REFERÊNCIAS

- ABIT, **Comportamento das vendas online no Brasil, 2020**. Disponível em: <https://nielseniq.com/global/pt/insights/analysis/2020/covid-19-comportamento-das-vendas-online-no-brasil/>, 2022.
- ALMEIDA, R. F. / SILVA, P. A. L. **Métodos de previsão de demanda de materiais**: Aplicação em uma empresa de administração pública. XXVII Simpósio de Engenharia de Produção. Novembro 2020.
- AYKIN, S. **Neural networks**: a comprehensive foundation. New York, Macmillan College Publishing Company.
- BISHOP, C. M. **PATTERN RECOGNITION AND MACHINE LEARNING**. [S.l.]: SPRINGER-VERLAG, 2006.
- CNN, **Produção da Indústria têxtil deve crescer apenas 1,2% em 2022: Pelos prognósticos da Abit, o crescimento da produção deve desacelerar para 1,2% em 2022**. Eduardo Laguna. Disponível em: <https://www.cnnbrasil.com.br/business/producao-da-Industria-textil-deve-crescer-apenas-12-em-2022-preve-abit>, 2022.
- DALLA, Amanda; PASOLINI, Mônica; FRANCO, Mateus; ORLANDIN, Bruna; CORSO, Lenadro. **Análise de métodos de previsão de demanda para projeção de vendas de produtos de uma Indústria do ramo moveleiro**. XL ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Outubro, 2020.
- REFENES, A. P. **Neural networks in the capital markets**. New York: J. Wiley, 1995
- GIL, A. C. **Como elaborar projetos de pesquisa**. São Paulo: Atlas, 1996
- HAYKIN, S. **Redes neurais: princípios e prática**. 2. ed. Porto Alegre: Bookman, 2001.
- IEMI; **Brasil Têxtil, 2021**. Disponível em: <https://www.iemi.com.br/produto/brasil-textil/>
- KRAJEWSKI, L., RITZMAN L., MALHOTRA, M. **Administração de Produção e Operações**. 8 ed., SP: Pearson, 2009
- LEMOS, F. O. **Metodologia para Seleção de Método de Previsão de Demanda**. Porto Alegre: UFRGS, 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006
- LIMA, Marcos Bruno Santos Pereira. **Aplicação do modelo de previsão de demanda holtwinters em uma regional de corte e dobra de aço**. Encontro nacional de engenharia de produção. Fortaleza: XXXV ENEGEP, 2015.

MARTIN, A. C. et al. **Análise de séries temporais para previsão da evolução do número de automóveis no Município de Joinville.** Disponível em <http://www.revistaespacios.com/a16v37n06/16370629.html>, 2016.

MOREIRA, B.M; FREITAS, T.R.G. **Internet das coisas e redes neurais artificiais aplicadas à manutenção preditiva Industrial.** XLI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO “Contribuições da Engenharia de Produção para a Gestão de Operações Energéticas Sustentáveis”. Foz do Iguaçu, Paraná, Brasil, 18 a 21 de outubro de 2021.

MOREIRA, D. A. **Administração da produção e operações.** São Paulo, 1996.

MONARD, M.C; BARANAUSKAS, A.J. **Conceito sobre aprendizado de Máquina,** 2019.

NEVES EDUARDO, T.N., DORNES COSTA, G.R., BELTRÃO MODESTO, L.P. **Análise de Séries temporais na projeção de custos de infraestrutura rodoviária:** Um estudo de caso utilizando custos médios gerenciais. 34º Congresso de Pesquisa e Ensino em Transporte da ANPET. 6 a 21 de novembro de 2020;

PEINADO, Jurandi; GRAEML, Alexandre Reis. **Administração da Produção (Operações Industriais e de Serviços).** Curitiba, 2007.

PARIZ, Tiago; BICCA, Alexandre. **EBIT|NIELSEN: E-commerce no brasil cresce 47% no primeiro semestre, maior alta em 20 anos.** Disponível em: <https://static.poder360.com.br/2020/08/EBIT-ecommerce-Brasil-1semestre2020.pdf>, 2022.

PELLEGRINI, Fernando Rezende. **Metodologia para implementação de sistemas de previsão de demanda.** Porto Alegre, 2000.

RODRIGUES, Bruno; SILVA, José; SALES, Jair. **Desenvolvimento de modelos para previsão de demanda do consumo de energia elétrica no sudeste brasileiro.** XL ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Outubro, 2020.

RODRIGUES, Valdecir; LEPRE, THAIS; BICALHO, Alan; et al. **Anais – E-commerce,** 7º Encontro Científico de Ciências Administrativas, volume 4. Disponível em: https://www.unoeste.br/Areas/Eventos/Content/documentos/EventosAnais/672/Volume_4_N_1_2021%20-%20Anaisdo7EC.pdf#page=49, 2021.

ROMÃO, F.M; NEPOMUCENO, N. **Processo de planejamento colaborativo da demanda em empresas de bens de consumo de mercados dinâmicos:** Artefato de software e estudo de caso. XXVII SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO; Bauru, novembro de 2020

RUSCHEL, L. P.; WERNER, L.; LEMOS, F. O. **Previsão de demanda de novos produtos:** aplicação integrada de métodos quantitativo e qualitativo. ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, 27., 2007, Foz do Iguaçu.

SANTOS, Luiza; CHRISTO, Eliane; COSTA, Kelly. **Aplicação dos modelos de alisamento exponencial de holt-winters e sarima para previsão de benefícios emitidos pela previdência.** XXIII SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO. Novembro, 2016.

SCHNEIDER, Ana; ZANOTTO, Monique; CORSO, Leandro. **Aplicação de métodos de previsão de demanda para projeção de consumo de chapas de MDP de uma Indústria do ramo moveleiro.** XLI ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO “Contribuições da Engenharia de Produção para a Gestão de Operações Energéticas Sustentáveis” Outubro, 2021.

SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding Machine Learning.** Cambridge, 2015.

SILVA, Guilherme; PIRATELLI, CLAUDIO. **Previsão de vendas por séries temporais em uma empresa de nutrição para animais domésticos.** XXXIX ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO, Outubro, 2019.

SILVA, Marcos; BARBOSA, Nathália; SOUZA, Stanley; SANTIAGO, Braval. **Capacidade Preditiva da Modelagem de Suavização Exponencial: caso da Covid-19 no Brasil.** XL ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Outubro, 2020.

SILVA, R. B. / SALES FILHO, N. / AIRES, F. F. C. / OENNING-SOARES, E. J. / PORTO, A. G. **Análise do desempenho de previsões individuais e combinadas: Um estudo de caso em uma empresa varejista da cadeia automobilística.** XXIV SIMPÓSIO DE ENGENHARIA DE PRODUÇÃO. Novembro, 2017.

TORRES JÚNIOR, R. G., MACHADO, M. A. S., SOUZA, R. C. **Previsão de Falhas em Manutenção Industrial Usando Redes Neurais.** Engevista Volume 7, 2005.

VELASCO, Julián A.; GONZÁLEZ-SALAZAR, Constantino. **Akaike information criterion should not be a “test” of geographical prediction accuracy in ecological niche modelling.** *Ecological Informatics*, v. 51, 2019.

VERÍSSIMO, A. J.; ALVEZ, C. da C.; HENNING, E.; AMARAL, C. E. do; CRUZ, A. C. da; **Métodos Estatísticos de Suavização Exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico.** Congresso Brasileiro De Engenharia De Produção, 2, 2012. Ponta Grossa, PR, Brasil: CONBREPPO, 2012

VIEITOS, Eduardo; GUTIERREZ, Ruben HUAMANCHUMO; **Aplicação de um modelo alternativo para médias móveis: Estudo de caso.** XXVII Simpósio de Engenharia de Produção. Novembro 2020.

VILLETI, Rafaela; JUNKES, ValdericeHerth; PETERSON, Rony; PEDROSO, Marcos Augusto Machado; BRADÃO, Jessycka. **Previsão de Demanda: Uma Análise quantitativa baseada em Média Móvel Simples e Média Móvel Centrada em uma empresa fabricante de salgados.** X Encontro de engenharia de produção agroIndústria, 2016.

APÊNDICE A – MODELO HOLT-WINTERS MULTIPLICATIVO – DOHLER S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	188530.9	159925.3	217136.5	144782.4	232279.4
2022 Q4	178742.5	151614.2	205870.9	137253.3	220231.7
2023 Q1	164814.0	139792.3	189835.7	126546.7	203081.3
2023 Q2	158012.1	134016.1	182008.1	121313.4	194710.8
2023 Q3	192343.6	163125.2	221562.0	147658.0	237029.3
2023 Q4	182339.1	154632.4	210045.7	139965.4	224712.7
2024 Q1	168113.7	142561.2	193666.2	129034.6	207192.8
2024 Q2	161159.8	136657.3	185662.4	123686.4	198633.3

Holt-winters' multiplicative method

Call:

```
hw(y = Receita_ts, h = 8, seasonal = "multiplicative")
```

Smoothing parameters:

alpha = 0.024

beta = 1e-04

gamma = 4e-04

Initial states:

l = 146706.8101

b = 875.8161

s = 1.0382 1.1006 0.9087 0.9525

sigma: 0.1184

	AIC	AICC	BIC
	700.6530	709.6530	713.2637

APÊNDICE B – MODELO HOLT-WINTERS ADITIVO – DOHLER S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	179140.9	155559.0	202722.7	143075.56	215206.2
2022 Q4	170814.7	141048.5	200581.0	125291.22	216338.3
2023 Q1	156647.6	121775.9	191519.4	103315.86	209979.4
2023 Q2	152314.3	112993.3	191635.2	92178.06	212450.5
2023 Q3	182643.1	139325.6	225960.7	116394.74	248891.6
2023 Q4	174317.0	127341.8	221292.3	102474.57	246159.5
2024 Q1	160149.9	109781.0	210518.8	83117.28	237182.5
2024 Q2	155816.6	102267.8	209365.3	73920.80	237712.3

>

```

Holt-winters' additive method

Call:
hw(y = Receita_ts, h = 8, seasonal = "additive")

Smoothing parameters:
  alpha = 0.7701
  beta  = 1e-04
  gamma = 1e-04

Initial states:
  l = 146483.847
  b = 876.8981
  s = 6523.223 15724.91 -13727.49 -8520.639

sigma: 18401.01

      AIC      AICc      BIC
699.9409 708.9409 712.5517

```

APÊNDICE C – MODELO SARIMA – DOHLER S.A

```

ARIMA(0,0,0)(0,1,0)[4] : 603.664
ARIMA(0,0,0)(0,1,0)[4] with drift : 605.4615
ARIMA(0,0,0)(0,1,1)[4] : 597.3576
ARIMA(0,0,0)(0,1,1)[4] with drift : Inf
ARIMA(0,0,0)(0,1,2)[4] : 598.8255
ARIMA(0,0,0)(0,1,2)[4] with drift : 596.1543
ARIMA(0,0,0)(1,1,0)[4] : 597.2563
ARIMA(0,0,0)(1,1,0)[4] with drift : 595.7578
ARIMA(0,0,0)(1,1,1)[4] : 599.2259
ARIMA(0,0,0)(1,1,1)[4] with drift : 596.0941
ARIMA(0,0,0)(1,1,2)[4] : 601.2127
ARIMA(0,0,0)(1,1,2)[4] with drift : 599.1891
ARIMA(0,0,0)(2,1,0)[4] : 598.9131
ARIMA(0,0,0)(2,1,0)[4] with drift : 596.433
ARIMA(0,0,0)(2,1,1)[4] : 601.8607
ARIMA(0,0,0)(2,1,1)[4] with drift : 599.1872
ARIMA(0,0,0)(2,1,2)[4] : 604.3078
ARIMA(0,0,0)(2,1,2)[4] with drift : Inf
ARIMA(0,0,1)(0,1,0)[4] : 593.4322
ARIMA(0,0,1)(0,1,0)[4] with drift : 595.9133
ARIMA(0,0,1)(0,1,1)[4] : 588.1133
ARIMA(0,0,1)(0,1,1)[4] with drift : 587.9138
ARIMA(0,0,1)(0,1,2)[4] : 590.8344
ARIMA(0,0,1)(0,1,2)[4] with drift : 590.874
ARIMA(0,0,1)(1,1,0)[4] : 589.4481
ARIMA(0,0,1)(1,1,0)[4] with drift : 590.4776
ARIMA(0,0,1)(1,1,1)[4] : 590.8623
ARIMA(0,0,1)(1,1,1)[4] with drift : 590.8757
ARIMA(0,0,1)(1,1,2)[4] : Inf
ARIMA(0,0,1)(1,1,2)[4] with drift : 594.295
ARIMA(0,0,1)(2,1,0)[4] : 590.9826
ARIMA(0,0,1)(2,1,0)[4] with drift : 591.6255
ARIMA(0,0,1)(2,1,1)[4] : 593.8437

```

ARIMA(0,0,1)(2,1,1)[4]	with drift	: 594.2939
ARIMA(0,0,1)(2,1,2)[4]		: Inf
ARIMA(0,0,1)(2,1,2)[4]	with drift	: Inf
ARIMA(0,0,2)(0,1,0)[4]		: 596.0006
ARIMA(0,0,2)(0,1,0)[4]	with drift	: 598.7268
ARIMA(0,0,2)(0,1,1)[4]		: 590.5993
ARIMA(0,0,2)(0,1,1)[4]	with drift	: 591.0024
ARIMA(0,0,2)(0,1,2)[4]		: 593.6531
ARIMA(0,0,2)(0,1,2)[4]	with drift	: 594.294
ARIMA(0,0,2)(1,1,0)[4]		: 592.1755
ARIMA(0,0,2)(1,1,0)[4]	with drift	: 593.5726
ARIMA(0,0,2)(1,1,1)[4]		: 593.6641
ARIMA(0,0,2)(1,1,1)[4]	with drift	: 594.2956
ARIMA(0,0,2)(1,1,2)[4]		: Inf
ARIMA(0,0,2)(1,1,2)[4]	with drift	: 598.0959
ARIMA(0,0,2)(2,1,0)[4]		: 593.9301
ARIMA(0,0,2)(2,1,0)[4]	with drift	: 595.0461
ARIMA(0,0,2)(2,1,1)[4]		: 597.0099
ARIMA(0,0,2)(2,1,1)[4]	with drift	: 598.0942
ARIMA(0,0,3)(0,1,0)[4]		: Inf
ARIMA(0,0,3)(0,1,0)[4]	with drift	: Inf
ARIMA(0,0,3)(0,1,1)[4]		: 592.9286
ARIMA(0,0,3)(0,1,1)[4]	with drift	: Inf
ARIMA(0,0,3)(0,1,2)[4]		: 596.2234
ARIMA(0,0,3)(0,1,2)[4]	with drift	: 598.0789
ARIMA(0,0,3)(1,1,0)[4]		: 593.3288
ARIMA(0,0,3)(1,1,0)[4]	with drift	: 595.8266
ARIMA(0,0,3)(1,1,1)[4]		: 596.2505
ARIMA(0,0,3)(1,1,1)[4]	with drift	: 598.0792
ARIMA(0,0,3)(2,1,0)[4]		: 596.245
ARIMA(0,0,3)(2,1,0)[4]	with drift	: 598.5433
ARIMA(1,0,0)(0,1,0)[4]		: 596.6632
ARIMA(1,0,0)(0,1,0)[4]	with drift	: 599.2155
ARIMA(1,0,0)(0,1,1)[4]		: 589.2755

ARIMA(1,0,0)(0,1,1)[4]	with drift	: 590.6031
ARIMA(1,0,0)(0,1,2)[4]		: 591.7472
ARIMA(1,0,0)(0,1,2)[4]	with drift	: 593.1731
ARIMA(1,0,0)(1,1,0)[4]		: 590.0925
ARIMA(1,0,0)(1,1,0)[4]	with drift	: 591.6635
ARIMA(1,0,0)(1,1,1)[4]		: 591.7748
ARIMA(1,0,0)(1,1,1)[4]	with drift	: 593.1435
ARIMA(1,0,0)(1,1,2)[4]		: Inf
ARIMA(1,0,0)(1,1,2)[4]	with drift	: 596.5638
ARIMA(1,0,0)(2,1,0)[4]		: 591.8605
ARIMA(1,0,0)(2,1,0)[4]	with drift	: 593.3316
ARIMA(1,0,0)(2,1,1)[4]		: 594.855
ARIMA(1,0,0)(2,1,1)[4]	with drift	: 596.5627
ARIMA(1,0,0)(2,1,2)[4]		: Inf
ARIMA(1,0,0)(2,1,2)[4]	with drift	: Inf
ARIMA(1,0,1)(0,1,0)[4]		: 596.0001
ARIMA(1,0,1)(0,1,0)[4]	with drift	: 598.7267
ARIMA(1,0,1)(0,1,1)[4]		: 590.4634
ARIMA(1,0,1)(0,1,1)[4]	with drift	: 591.0028
ARIMA(1,0,1)(0,1,2)[4]		: 593.5268
ARIMA(1,0,1)(0,1,2)[4]	with drift	: 594.294
ARIMA(1,0,1)(1,1,0)[4]		: 592.1005
ARIMA(1,0,1)(1,1,0)[4]	with drift	: 593.5724
ARIMA(1,0,1)(1,1,1)[4]		: 593.5343
ARIMA(1,0,1)(1,1,1)[4]	with drift	: 594.2956
ARIMA(1,0,1)(1,1,2)[4]		: Inf
ARIMA(1,0,1)(1,1,2)[4]	with drift	: 598.0954
ARIMA(1,0,1)(2,1,0)[4]		: 593.8532
ARIMA(1,0,1)(2,1,0)[4]	with drift	: 595.046
ARIMA(1,0,1)(2,1,1)[4]		: 596.9013
ARIMA(1,0,1)(2,1,1)[4]	with drift	: 598.0942
ARIMA(1,0,2)(0,1,0)[4]		: 598.7728
ARIMA(1,0,2)(0,1,0)[4]	with drift	: 601.803
ARIMA(1,0,2)(0,1,1)[4]		: 593.2567

ARIMA(1,0,2)(0,1,1)[4] with drift	: 594.4269
ARIMA(1,0,2)(0,1,2)[4]	: 596.5696
ARIMA(1,0,2)(0,1,2)[4] with drift	: 598.0948
ARIMA(1,0,2)(1,1,0)[4]	: 594.9256
ARIMA(1,0,2)(1,1,0)[4] with drift	: 596.9528
ARIMA(1,0,2)(1,1,1)[4]	: 596.5965
ARIMA(1,0,2)(1,1,1)[4] with drift	: 598.0964
ARIMA(1,0,2)(2,1,0)[4]	: 596.9269
ARIMA(1,0,2)(2,1,0)[4] with drift	: 598.8372
ARIMA(1,0,3)(0,1,0)[4]	: Inf
ARIMA(1,0,3)(0,1,0)[4] with drift	: Inf
ARIMA(1,0,3)(0,1,1)[4]	: 596.1506
ARIMA(1,0,3)(0,1,1)[4] with drift	: Inf
ARIMA(1,0,3)(1,1,0)[4]	: 596.7251
ARIMA(1,0,3)(1,1,0)[4] with drift	: 599.6272
ARIMA(2,0,0)(0,1,0)[4]	: 597.2671
ARIMA(2,0,0)(0,1,0)[4] with drift	: 599.9879
ARIMA(2,0,0)(0,1,1)[4]	: 591.458
ARIMA(2,0,0)(0,1,1)[4] with drift	: 592.1996
ARIMA(2,0,0)(0,1,2)[4]	: 594.4537
ARIMA(2,0,0)(0,1,2)[4] with drift	: 595.5267
ARIMA(2,0,0)(1,1,0)[4]	: 592.6151
ARIMA(2,0,0)(1,1,0)[4] with drift	: 594.2592
ARIMA(2,0,0)(1,1,1)[4]	: 594.4646
ARIMA(2,0,0)(1,1,1)[4] with drift	: 595.5196
ARIMA(2,0,0)(1,1,2)[4]	: Inf
ARIMA(2,0,0)(1,1,2)[4] with drift	: 599.3183
ARIMA(2,0,0)(2,1,0)[4]	: 594.6636
ARIMA(2,0,0)(2,1,0)[4] with drift	: 596.1255
ARIMA(2,0,0)(2,1,1)[4]	: 597.8763
ARIMA(2,0,0)(2,1,1)[4] with drift	: 599.3134
ARIMA(2,0,1)(0,1,0)[4]	: 597.9255
ARIMA(2,0,1)(0,1,0)[4] with drift	: 600.992
ARIMA(2,0,1)(0,1,1)[4]	: 593.1876
ARIMA(2,0,3)(0,1,0)[4] with drift	: Inf
ARIMA(3,0,0)(0,1,0)[4]	: 599.0671
ARIMA(3,0,0)(0,1,0)[4] with drift	: 601.7816
ARIMA(3,0,0)(0,1,1)[4]	: Inf
ARIMA(3,0,0)(0,1,1)[4] with drift	: Inf
ARIMA(3,0,0)(0,1,2)[4]	: 596.0941
ARIMA(3,0,0)(0,1,2)[4] with drift	: 597.9054
ARIMA(3,0,0)(1,1,0)[4]	: 595.3459
ARIMA(3,0,0)(1,1,0)[4] with drift	: 597.5032
ARIMA(3,0,0)(1,1,1)[4]	: 596.3691
ARIMA(3,0,0)(1,1,1)[4] with drift	: 597.934
ARIMA(3,0,0)(2,1,0)[4]	: 596.7714
ARIMA(3,0,0)(2,1,0)[4] with drift	: 598.9284
ARIMA(3,0,1)(0,1,0)[4]	: Inf
ARIMA(3,0,1)(0,1,0)[4] with drift	: Inf
ARIMA(3,0,1)(0,1,1)[4]	: 596.2899
ARIMA(3,0,1)(0,1,1)[4] with drift	: Inf
ARIMA(3,0,1)(1,1,0)[4]	: 597.5955
ARIMA(3,0,1)(1,1,0)[4] with drift	: 600.0976
ARIMA(3,0,2)(0,1,0)[4]	: Inf
ARIMA(3,0,2)(0,1,0)[4] with drift	: Inf

Best model: ARIMA(0,0,1)(0,1,1)[4] with drift

```

Series: Receita_ts
ARIMA(0,0,1)(0,1,1)[4] with drift

Coefficients:
          ma1          sma1          drift
          0.6624        -0.9301         971.9936
s.e.       0.1686         0.9007         470.8780

sigma^2 = 225883996:  log likelihood = -289
AIC=586.01  AICc=587.91  BIC=591.04

```

APÊNDICE D – MODELO REDES NEURASIS – DOHLER S.A

```

Series: Receita_ts
Model:  NNAR(1,1,2)[4]
Call:  nnetar(y = Receita_ts)

```

Average of 20 networks, each of which is
a 2-2-1 network with 9 weights
options were - linear output units

sigma^2 estimated as 152770029

	Qtr1	Qtr2	Qtr3	Qtr4
2022			173292.8	173841.4
2023	179027.0	181095.3	186231.8	186941.9
2024	187408.3	187594.6		

APÊNDICE E – MODELO HOLT-WINTERS MULTIPLICATIVO – KARSTEN S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	179961.0	143575.2	216346.9	124313.74	235608.4
2022 Q4	236009.8	186747.2	285272.4	160669.15	311350.4
2023 Q1	169343.2	131806.8	206879.5	111936.31	226750.0
2023 Q2	178824.4	135653.4	221995.3	112800.04	244848.7
2023 Q3	213253.0	156197.7	270308.3	125994.43	300511.6
2023 Q4	277740.5	194659.5	360821.6	150679.01	404802.0
2024 Q1	198018.5	131641.1	264395.9	96503.08	299533.9
2024 Q2	207875.4	129937.3	285813.4	88679.39	327071.4

Holt-winters' multiplicative method

Call:

```
hw(y = karsten_ts, h = 8, seasonal = "multiplicative")
```

Smoothing parameters:

alpha = 0.1325

beta = 0.1325

gamma = 1e-04

Initial states:

l = 99540.5225

b = 1200.006

s = 1.2574 1.0032 0.8754 0.864

sigma: 0.1578

AIC	AICc	BIC
694.1610	703.1610	706.7717

APÊNDICE F – MODELO HOLT-WINTERS ADITIVO – KARSTEN S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	168527.8	147627.9	189427.8	136564.1	200491.6
2022 Q4	203775.0	181567.5	225982.5	169811.6	237738.5
2023 Q1	168084.4	143800.3	192368.6	130945.1	205223.8
2023 Q2	175779.1	148627.8	202930.4	134254.8	217303.5
2023 Q3	194592.0	163828.3	225355.7	147543.0	241641.0
2023 Q4	229839.2	194796.7	264881.7	176246.3	283432.1
2024 Q1	194148.6	154239.6	234057.6	133113.1	255184.1
2024 Q2	201843.3	156551.0	247135.6	132574.8	271111.9

Holt-winters' additive method

Call:

```
hw(y = karsten_ts, h = 8, seasonal = "additive")
```

Smoothing parameters:

alpha = 0.2483

beta = 0.1109

gamma = 1e-04

Initial states:

l = 99246.4898

b = 1219.1957

s = 27991.42 -740.2529 -13036.15 -14215.02

sigma: 16308.32

AIC	AICc	BIC
692.6971	701.6971	705.3079

APÊNDICE G – MODELO SARIMA – KARSTEN S.A

Series: karsten_ts
ARIMA(0,1,2)(1,1,0)[4]

Coefficients:

	ma1	ma2	sar1
	-0.7642	0.4946	-0.6863
s.e.	0.1576	0.2185	0.1406

sigma^2 = 220811639: log likelihood = -275.52
AIC=559.05 AICC=561.05 BIC=563.92

ARIMA(0,1,0)(0,1,0)[4]	: 584.032
ARIMA(0,1,0)(0,1,1)[4]	: 574.2184
ARIMA(0,1,0)(0,1,2)[4]	: Inf
ARIMA(0,1,0)(1,1,0)[4]	: 568.7828
ARIMA(0,1,0)(1,1,1)[4]	: 571.3553
ARIMA(0,1,0)(1,1,2)[4]	: Inf
ARIMA(0,1,0)(2,1,0)[4]	: 571.3542
ARIMA(0,1,0)(2,1,1)[4]	: 574.2113
ARIMA(0,1,0)(2,1,2)[4]	: Inf
ARIMA(0,1,1)(0,1,0)[4]	: 572.2197
ARIMA(0,1,1)(0,1,1)[4]	: 566.3169
ARIMA(0,1,1)(0,1,2)[4]	: Inf
ARIMA(0,1,1)(1,1,0)[4]	: 562.5982
ARIMA(0,1,1)(1,1,1)[4]	: 565.4523
ARIMA(0,1,1)(1,1,2)[4]	: Inf
ARIMA(0,1,1)(2,1,0)[4]	: 565.4515
ARIMA(0,1,1)(2,1,1)[4]	: Inf
ARIMA(0,1,1)(2,1,2)[4]	: Inf
ARIMA(0,1,2)(0,1,0)[4]	: Inf
ARIMA(0,1,2)(0,1,1)[4]	: 564.7788
ARIMA(0,1,2)(0,1,2)[4]	: Inf
ARIMA(0,1,2)(1,1,0)[4]	: 561.0495
ARIMA(0,1,2)(1,1,1)[4]	: 564.0257
ARIMA(0,1,2)(1,1,2)[4]	: Inf
ARIMA(0,1,2)(2,1,0)[4]	: 563.8369
ARIMA(0,1,2)(2,1,1)[4]	: 566.8138
ARIMA(0,1,3)(0,1,0)[4]	: Inf
ARIMA(0,1,3)(0,1,1)[4]	: 567.5469
ARIMA(0,1,3)(0,1,2)[4]	: Inf
ARIMA(0,1,3)(1,1,0)[4]	: 564.1969
ARIMA(0,1,3)(1,1,1)[4]	: 567.3958
ARIMA(0,1,3)(2,1,0)[4]	: 567.0192

ARIMA(2,1,1)(0,1,1)[4]	: 565.0532
ARIMA(2,1,1)(0,1,2)[4]	: Inf
ARIMA(2,1,1)(1,1,0)[4]	: 564.1809
ARIMA(2,1,1)(1,1,1)[4]	: 567.6813
ARIMA(2,1,1)(2,1,0)[4]	: 567.6706
ARIMA(2,1,2)(0,1,0)[4]	: Inf
ARIMA(2,1,2)(0,1,1)[4]	: Inf
ARIMA(2,1,2)(1,1,0)[4]	: Inf
ARIMA(2,1,3)(0,1,0)[4]	: Inf
ARIMA(3,1,0)(0,1,0)[4]	: 563.8056
ARIMA(3,1,0)(0,1,1)[4]	: 564.8635
ARIMA(3,1,0)(0,1,2)[4]	: Inf
ARIMA(3,1,0)(1,1,0)[4]	: 563.9121
ARIMA(3,1,0)(1,1,1)[4]	: 567.4169
ARIMA(3,1,0)(2,1,0)[4]	: 567.4121
ARIMA(3,1,1)(0,1,0)[4]	: 566.0926
ARIMA(3,1,1)(0,1,1)[4]	: 568.1671
ARIMA(3,1,1)(1,1,0)[4]	: 567.3226
ARIMA(3,1,2)(0,1,0)[4]	: Inf

Best model: ARIMA(0,1,2)(1,1,0)[4]

ARIMA(1,1,0)(0,1,1)[4]	: 566.9461
ARIMA(1,1,0)(0,1,2)[4]	: Inf
ARIMA(1,1,0)(1,1,0)[4]	: 562.4435
ARIMA(1,1,0)(1,1,1)[4]	: 565.2781
ARIMA(1,1,0)(1,1,2)[4]	: Inf
ARIMA(1,1,0)(2,1,0)[4]	: 565.2615
ARIMA(1,1,0)(2,1,1)[4]	: 568.3305
ARIMA(1,1,0)(2,1,2)[4]	: Inf
ARIMA(1,1,1)(0,1,0)[4]	: 573.0044
ARIMA(1,1,1)(0,1,1)[4]	: 567.1487
ARIMA(1,1,1)(0,1,2)[4]	: Inf
ARIMA(1,1,1)(1,1,0)[4]	: 563.5033
ARIMA(1,1,1)(1,1,1)[4]	: 566.6606
ARIMA(1,1,1)(1,1,2)[4]	: Inf
ARIMA(1,1,1)(2,1,0)[4]	: 566.6603
ARIMA(1,1,1)(2,1,1)[4]	: Inf
ARIMA(1,1,2)(0,1,0)[4]	: Inf
ARIMA(1,1,2)(0,1,1)[4]	: 567.921
ARIMA(1,1,2)(0,1,2)[4]	: Inf
ARIMA(1,1,2)(1,1,0)[4]	: 564.2045
ARIMA(1,1,2)(1,1,1)[4]	: 567.4931
ARIMA(1,1,2)(2,1,0)[4]	: 567.2092
ARIMA(1,1,3)(0,1,0)[4]	: Inf
ARIMA(1,1,3)(0,1,1)[4]	: 570.5619
ARIMA(1,1,3)(1,1,0)[4]	: 567.0907
ARIMA(2,1,0)(0,1,0)[4]	: 566.6399
ARIMA(2,1,0)(0,1,1)[4]	: 564.1626
ARIMA(2,1,0)(0,1,2)[4]	: Inf
ARIMA(2,1,0)(1,1,0)[4]	: 561.7915
ARIMA(2,1,0)(1,1,1)[4]	: 564.9439
ARIMA(2,1,0)(1,1,2)[4]	: Inf
ARIMA(2,1,0)(2,1,0)[4]	: 564.9401
ARIMA(2,1,0)(2,1,1)[4]	: 568.2435
ARIMA(2,1,1)(0,1,0)[4]	: 563.6368

APÊNDICE H – MODELO REDES NEURAIS – KARSTEN S.A

```

Series: karsten_ts
Model: NNAR(4,1,2)[4]
Call: nnetar(y = karsten_ts)

Average of 20 networks, each of which is
a 4-2-1 network with 13 weights
options were - linear output units

sigma^2 estimated as 39230653

```

	Qtr1	Qtr2	Qtr3	Qtr4
2022			157705.1	174240.7
2023	158702.1	140479.4	172678.7	184273.8
2024	166607.6	141879.8		

APÊNDICE I – MODELO HOLT-WINTERS MULTIPLICATIVO – PETTENATI S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	95193.70	71552.57	118834.8	59037.718	131349.7
2022 Q4	85371.88	59968.66	110775.1	46521.001	124222.8
2023 Q1	101688.83	66667.51	136710.1	48128.350	155249.3
2023 Q2	99134.34	60478.62	137790.1	40015.516	158253.2
2023 Q3	100701.50	53413.33	147989.7	28380.485	173022.5
2023 Q4	90259.09	44081.97	136436.2	19637.286	160880.9
2024 Q1	107449.32	47920.81	166977.8	16408.321	198490.3
2024 Q2	104692.28	42202.43	167182.1	9122.303	200262.3

Holt-winters' multiplicative method

Call:

```
hw(y = receita_ts, h = 8, seasonal = "multiplicative")
```

Smoothing parameters:

alpha = 0.6145

beta = 0.0415

gamma = 0.2744

Initial states:

l = 82004.4114

b = -393.7668

s = 0.8557 0.9133 1.0606 1.1703

sigma: 0.1938

AIC	AICC	BIC
680.4369	689.4369	693.0477

APÊNDICE J – MODELO HOLT-WINTERS ADITIVO – PETTENATI S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	85585.02	71269.60	99900.44	63691.48	107478.6
2022 Q4	81906.04	64473.33	99338.75	55245.01	108567.1
2023 Q1	97407.23	77334.96	117479.49	66709.34	128105.1
2023 Q2	90494.50	68090.90	112898.10	56231.16	124757.8
2023 Q3	83886.20	59370.83	108401.57	46393.18	121379.2
2023 Q4	80207.22	53748.09	106666.35	39741.47	120673.0
2024 Q1	95708.40	67438.35	123978.46	52473.08	138943.7
2024 Q2	88795.68	58823.44	118767.92	42957.09	134634.3

Holt-winters' additive method

Call:

```
hw(y = receita_ts, h = 8, seasonal = "additive")
```

Smoothing parameters:

alpha = 0.6948

beta = 1e-04

gamma = 1e-04

Initial states:

l = 83131.115

b = -427.5312

s = -7154.146 -3899.882 2283.614 8770.415

sigma: 11170.38

AIC	AICC	BIC
669.9925	678.9925	682.6033

APÊNDICE K – MODELO SARIMA – PETTENATI S.A

Series: receita_ts

ARIMA(1,0,0)(1,0,0)[4] with non-zero mean

Coefficients:

	ar1	sar1	mean
	0.6706	0.5466	79304.21
s.e.	0.1431	0.1539	10973.21

sigma^2 = 1.18e+08: log likelihood = -320.91

AIC=649.81 AICC=651.41 BIC=655.42

>

ARIMA(0,0,0)	with zero mean	: 759.1361
ARIMA(0,0,0)	with non-zero mean	: 667.8559
ARIMA(0,0,0)(0,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,0)(0,0,1)[4]	with non-zero mean	: 664.4178
ARIMA(0,0,0)(0,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,0)(0,0,2)[4]	with non-zero mean	: Inf
ARIMA(0,0,0)(1,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,0)(1,0,0)[4]	with non-zero mean	: 663.604
ARIMA(0,0,0)(1,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,0)(1,0,1)[4]	with non-zero mean	: 665.7232
ARIMA(0,0,0)(1,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,0)(1,0,2)[4]	with non-zero mean	: Inf
ARIMA(0,0,0)(2,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,0)(2,0,0)[4]	with non-zero mean	: 665.1144
ARIMA(0,0,0)(2,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,0)(2,0,1)[4]	with non-zero mean	: 667.0698
ARIMA(0,0,0)(2,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,0)(2,0,2)[4]	with non-zero mean	: Inf
ARIMA(0,0,1)	with zero mean	: 731.6567
ARIMA(0,0,1)	with non-zero mean	: 660.9116
ARIMA(0,0,1)(0,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,1)(0,0,1)[4]	with non-zero mean	: 656.9496
ARIMA(0,0,1)(0,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,1)(0,0,2)[4]	with non-zero mean	: 655.5493
ARIMA(0,0,1)(1,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,1)(1,0,0)[4]	with non-zero mean	: 654.5698
ARIMA(0,0,1)(1,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,1)(1,0,1)[4]	with non-zero mean	: 657.4404
ARIMA(0,0,1)(1,0,2)[4]	with zero mean	: 671.6561
ARIMA(0,0,1)(1,0,2)[4]	with non-zero mean	: 658.5496
ARIMA(0,0,1)(2,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,1)(2,0,0)[4]	with non-zero mean	: 657.4229
ARIMA(0,0,1)(2,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,1)(2,0,1)[4]	with non-zero mean	: Inf

ARIMA(0,0,1)(2,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,1)(2,0,2)[4]	with non-zero mean	: 661.9558
ARIMA(0,0,2)	with zero mean	: Inf
ARIMA(0,0,2)	with non-zero mean	: 660.3831
ARIMA(0,0,2)(0,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,2)(0,0,1)[4]	with non-zero mean	: 658.3024
ARIMA(0,0,2)(0,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,2)(0,0,2)[4]	with non-zero mean	: 657.4543
ARIMA(0,0,2)(1,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,2)(1,0,0)[4]	with non-zero mean	: 656.3478
ARIMA(0,0,2)(1,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,2)(1,0,1)[4]	with non-zero mean	: 659.493
ARIMA(0,0,2)(1,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,2)(1,0,2)[4]	with non-zero mean	: 660.7579
ARIMA(0,0,2)(2,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,2)(2,0,0)[4]	with non-zero mean	: 659.4882
ARIMA(0,0,2)(2,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,2)(2,0,1)[4]	with non-zero mean	: 662.8306
ARIMA(0,0,3)	with zero mean	: Inf
ARIMA(0,0,3)	with non-zero mean	: 662.1795
ARIMA(0,0,3)(0,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,3)(0,0,1)[4]	with non-zero mean	: 661.1521
ARIMA(0,0,3)(0,0,2)[4]	with zero mean	: Inf
ARIMA(0,0,3)(0,0,2)[4]	with non-zero mean	: Inf
ARIMA(0,0,3)(1,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,3)(1,0,0)[4]	with non-zero mean	: Inf
ARIMA(0,0,3)(1,0,1)[4]	with zero mean	: Inf
ARIMA(0,0,3)(1,0,1)[4]	with non-zero mean	: Inf
ARIMA(0,0,3)(2,0,0)[4]	with zero mean	: Inf
ARIMA(0,0,3)(2,0,0)[4]	with non-zero mean	: Inf
ARIMA(1,0,0)	with zero mean	: 663.5232
ARIMA(1,0,0)	with non-zero mean	: 657.9942

ARIMA(1,0,0) (0,0,1) [4]	with zero mean	: 659.9468
ARIMA(1,0,0) (0,0,1) [4]	with non-zero mean	: 654.5936
ARIMA(1,0,0) (0,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,0) (0,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,0) (1,0,0) [4]	with zero mean	: 656.3485
ARIMA(1,0,0) (1,0,0) [4]	with non-zero mean	: 651.4127
ARIMA(1,0,0) (1,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,0) (1,0,1) [4]	with non-zero mean	: 654.7681
ARIMA(1,0,0) (1,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,0) (1,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,0) (2,0,0) [4]	with zero mean	: 657.0984
ARIMA(1,0,0) (2,0,0) [4]	with non-zero mean	: 653.6802
ARIMA(1,0,0) (2,0,1) [4]	with zero mean	: 659.8178
ARIMA(1,0,0) (2,0,1) [4]	with non-zero mean	: 656.526
ARIMA(1,0,0) (2,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,0) (2,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,1)	with zero mean	: Inf
ARIMA(1,0,1)	with non-zero mean	: 660.6533
ARIMA(1,0,1) (0,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,1) (0,0,1) [4]	with non-zero mean	: 657.4043
ARIMA(1,0,1) (0,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,1) (0,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,1) (1,0,0) [4]	with zero mean	: Inf
ARIMA(1,0,1) (1,0,0) [4]	with non-zero mean	: 654.2994
ARIMA(1,0,1) (1,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,1) (1,0,1) [4]	with non-zero mean	: 657.9493
ARIMA(1,0,1) (1,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,1) (1,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,1) (2,0,0) [4]	with zero mean	: Inf
ARIMA(1,0,1) (2,0,0) [4]	with non-zero mean	: 656.6685
ARIMA(1,0,1) (2,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,1) (2,0,1) [4]	with non-zero mean	: 659.6553

ARIMA(1,0,2)	with zero mean	: Inf
ARIMA(1,0,2)	with non-zero mean	: 662.4613
ARIMA(1,0,2) (0,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,2) (0,0,1) [4]	with non-zero mean	: 660.1488
ARIMA(1,0,2) (0,0,2) [4]	with zero mean	: Inf
ARIMA(1,0,2) (0,0,2) [4]	with non-zero mean	: Inf
ARIMA(1,0,2) (1,0,0) [4]	with zero mean	: 662.1038
ARIMA(1,0,2) (1,0,0) [4]	with non-zero mean	: 659.8804
ARIMA(1,0,2) (1,0,1) [4]	with zero mean	: 661.8311
ARIMA(1,0,2) (1,0,1) [4]	with non-zero mean	: 660.0803
ARIMA(1,0,2) (2,0,0) [4]	with zero mean	: 661.2432
ARIMA(1,0,2) (2,0,0) [4]	with non-zero mean	: 659.7427
ARIMA(1,0,3)	with zero mean	: 667.6341
ARIMA(1,0,3)	with non-zero mean	: Inf
ARIMA(1,0,3) (0,0,1) [4]	with zero mean	: Inf
ARIMA(1,0,3) (0,0,1) [4]	with non-zero mean	: Inf
ARIMA(1,0,3) (1,0,0) [4]	with zero mean	: Inf
ARIMA(1,0,3) (1,0,0) [4]	with non-zero mean	: Inf
ARIMA(2,0,0)	with zero mean	: Inf
ARIMA(2,0,0)	with non-zero mean	: 660.6698
ARIMA(2,0,0) (0,0,1) [4]	with zero mean	: 662.0933
ARIMA(2,0,0) (0,0,1) [4]	with non-zero mean	: 657.4556
ARIMA(2,0,0) (0,0,2) [4]	with zero mean	: Inf
ARIMA(2,0,0) (0,0,2) [4]	with non-zero mean	: Inf
ARIMA(2,0,0) (1,0,0) [4]	with zero mean	: 658.3054
ARIMA(2,0,0) (1,0,0) [4]	with non-zero mean	: 654.3047
ARIMA(2,0,0) (1,0,1) [4]	with zero mean	: Inf
ARIMA(2,0,0) (1,0,1) [4]	with non-zero mean	: 657.0481
ARIMA(2,0,0) (1,0,2) [4]	with zero mean	: Inf
ARIMA(2,0,0) (1,0,2) [4]	with non-zero mean	: Inf
ARIMA(2,0,0) (2,0,0) [4]	with zero mean	: Inf
ARIMA(2,0,0) (2,0,0) [4]	with non-zero mean	: 656.7446

```

ARIMA(2,0,0)(2,0,1)[4] with zero mean : 661.9463
ARIMA(2,0,0)(2,0,1)[4] with non-zero mean : 659.8001
ARIMA(2,0,1) with zero mean : Inf
ARIMA(2,0,1) with non-zero mean : 663.4316
ARIMA(2,0,1)(0,0,1)[4] with zero mean : Inf
ARIMA(2,0,1)(0,0,1)[4] with non-zero mean : 660.3627
ARIMA(2,0,1)(0,0,2)[4] with zero mean : Inf
ARIMA(2,0,1)(0,0,2)[4] with non-zero mean : Inf
ARIMA(2,0,1)(1,0,0)[4] with zero mean : Inf
ARIMA(2,0,1)(1,0,0)[4] with non-zero mean : 657.0644
ARIMA(2,0,1)(1,0,1)[4] with zero mean : Inf
ARIMA(2,0,1)(1,0,1)[4] with non-zero mean : 660.4209
ARIMA(2,0,1)(2,0,0)[4] with zero mean : 662.8797
ARIMA(2,0,1)(2,0,0)[4] with non-zero mean : 659.9522
ARIMA(2,0,2) with zero mean : Inf
ARIMA(2,0,2) with non-zero mean : 665.5938
ARIMA(2,0,2)(0,0,1)[4] with zero mean : Inf
ARIMA(2,0,2)(0,0,1)[4] with non-zero mean : 663.5432
ARIMA(2,0,2)(1,0,0)[4] with zero mean : Inf
ARIMA(2,0,2)(1,0,0)[4] with non-zero mean : 660.07
ARIMA(2,0,3) with zero mean : Inf
ARIMA(2,0,3) with non-zero mean : Inf
ARIMA(3,0,0) with zero mean : Inf
ARIMA(3,0,0) with non-zero mean : 660.8547
ARIMA(3,0,0)(0,0,1)[4] with zero mean : Inf
ARIMA(3,0,0)(0,0,1)[4] with non-zero mean : 659.7543
ARIMA(3,0,0)(0,0,2)[4] with zero mean : Inf
ARIMA(3,0,0)(0,0,2)[4] with non-zero mean : Inf
ARIMA(3,0,0)(1,0,0)[4] with zero mean : Inf
ARIMA(3,0,0)(1,0,0)[4] with non-zero mean : 656.9235
ARIMA(3,0,0)(1,0,1)[4] with zero mean : Inf
ARIMA(3,0,0)(1,0,1)[4] with non-zero mean : 659.5711
ARIMA(3,0,0)(2,0,0)[4] with zero mean : Inf
ARIMA(3,0,0)(2,0,0)[4] with non-zero mean : 658.9619
ARIMA(3,0,1) with zero mean : Inf
ARIMA(3,0,1) with non-zero mean : 663.7684
ARIMA(3,0,1)(0,0,1)[4] with zero mean : Inf
ARIMA(3,0,1)(0,0,1)[4] with non-zero mean : 663.1526
ARIMA(3,0,1)(1,0,0)[4] with zero mean : 661.7934
ARIMA(3,0,1)(1,0,0)[4] with non-zero mean : 659.4486
ARIMA(3,0,2) with zero mean : Inf
ARIMA(3,0,2) with non-zero mean : Inf

```

Best model: ARIMA(1,0,0)(1,0,0)[4] with non-zero mean

APÊNDICE L – MODELO REDES NEURAIIS – PETTENATI S.A

```

Series: receita_ts
Model: NNAR(1,1,2)[4]
Call: nnetar(y = receita_ts)

```

```

Average of 20 networks, each of which is
a 2-2-1 network with 9 weights
options were - linear output units

```

```

sigma^2 estimated as 66226947

```

	Qtr1	Qtr2	Qtr3	Qtr4
2022			90101.48	88526.38
2023	84186.40	80124.71	79828.42	80071.52
2024	81228.80	82799.08		

**APÊNDICE M – MODELO HOLT-WINTERS MULTIPLICATIVO – INDÚSTRIA
CATAGUASES S.A**

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	92781.97	81457.38	104106.57	75462.51	110101.4
2022 Q4	80676.31	64660.92	96691.70	56182.88	105169.7
2023 Q1	76912.38	57296.96	96527.81	46913.19	106911.6
2023 Q2	83406.47	60755.59	106057.36	48764.94	118048.0
2023 Q3	91359.45	66033.35	116685.55	52626.52	130092.4
2023 Q4	79253.78	51509.23	106998.34	36822.14	121685.4
2024 Q1	75489.86	45520.96	105458.77	29656.38	121323.3
2024 Q2	81983.95	49944.36	114023.55	32983.62	130984.3

Holt-winters' multiplicative method

call:

```
hw(y = indc_ts, h = 8, seasonal = "multiplicative")
```

Smoothing parameters:

alpha = 0.9252

beta = 1e-04

gamma = 1e-04

Initial states:

l = 67029.6802

b = -381.1675

s = 0.9268 1.151 1.0186 0.9036

sigma: 0.1919

AIC	AICc	BIC
667.5506	676.5506	680.1614

**APÊNDICE N – MODELO HOLT-WINTERS ADITIVO – INDÚSTRIA CATAGUASES
S.A**

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2022 Q3	92781.97	81457.38	104106.57	75462.51	110101.4
2022 Q4	80676.31	64660.92	96691.70	56182.88	105169.7
2023 Q1	76912.38	57296.96	96527.81	46913.19	106911.6
2023 Q2	83406.47	60755.59	106057.36	48764.94	118048.0
2023 Q3	91359.45	66033.35	116685.55	52626.52	130092.4
2023 Q4	79253.78	51509.23	106998.34	36822.14	121685.4
2024 Q1	75489.86	45520.96	105458.77	29656.38	121323.3
2024 Q2	81983.95	49944.36	114023.55	32983.62	130984.3

```

Holt-winters' additive method

Call:
hw(y = indc_ts, h = 8, seasonal = "additive")

Smoothing parameters:
alpha = 0.9999
beta = 1e-04
gamma = 1e-04

Initial states:
l = 66803.886
b = -358.4634
s = -2945.63 8804.16 496.3449 -6354.874

sigma: 8836.625

      AIC      AICC      BIC
655.9309 664.9309 668.5417

```

APÊNDICE O – MODELO SARIMA – INDÚSTRIA CATAGUASES S.A

```

Series: indc_ts
ARIMA(0,0,1)(2,1,0)[4]

Coefficients:
      ma1      sar1      sar2
      0.8878 -0.5533 -0.3499
s.e.  0.1541  0.2519  0.2554

sigma^2 = 90685277: log likelihood = -275.55
AIC=559.1  AICC=561.01  BIC=564.13

```

APÊNDICE P – MODELO REDES NEURAIIS – INDÚSTRIA CATAGUASES

ARIMA(0,0,0)(0,1,0)[4]	:	572.1107
ARIMA(0,0,0)(0,1,0)[4] with drift	:	574.4264
ARIMA(0,0,0)(0,1,1)[4]	:	571.648
ARIMA(0,0,0)(0,1,1)[4] with drift	:	Inf
ARIMA(0,0,0)(0,1,2)[4]	:	Inf
ARIMA(0,0,0)(0,1,2)[4] with drift	:	Inf
ARIMA(0,0,0)(1,1,0)[4]	:	573.232
ARIMA(0,0,0)(1,1,0)[4] with drift	:	575.8011
ARIMA(0,0,0)(1,1,1)[4]	:	Inf
ARIMA(0,0,0)(1,1,1)[4] with drift	:	Inf
ARIMA(0,0,0)(1,1,2)[4]	:	Inf
ARIMA(0,0,0)(1,1,2)[4] with drift	:	Inf
ARIMA(0,0,0)(2,1,0)[4]	:	573.3628
ARIMA(0,0,0)(2,1,0)[4] with drift	:	Inf
ARIMA(0,0,0)(2,1,1)[4]	:	Inf
ARIMA(0,0,0)(2,1,1)[4] with drift	:	Inf
ARIMA(0,0,0)(2,1,2)[4]	:	Inf
ARIMA(0,0,0)(2,1,2)[4] with drift	:	Inf
ARIMA(0,0,1)(0,1,0)[4]	:	Inf
ARIMA(0,0,1)(0,1,0)[4] with drift	:	Inf
ARIMA(0,0,1)(0,1,1)[4]	:	Inf
ARIMA(0,0,1)(0,1,1)[4] with drift	:	Inf
ARIMA(0,0,1)(0,1,2)[4]	:	Inf
ARIMA(0,0,1)(0,1,2)[4] with drift	:	Inf
ARIMA(0,0,1)(1,1,0)[4]	:	Inf
ARIMA(0,0,1)(1,1,0)[4] with drift	:	Inf
ARIMA(0,0,1)(1,1,1)[4]	:	Inf
ARIMA(0,0,1)(1,1,1)[4] with drift	:	Inf
ARIMA(0,0,1)(1,1,2)[4]	:	Inf
ARIMA(0,0,1)(1,1,2)[4] with drift	:	Inf
ARIMA(0,0,1)(2,1,0)[4]	:	561.0058
ARIMA(0,0,1)(2,1,0)[4] with drift	:	563.9488
ARIMA(0,0,1)(2,1,1)[4]	:	Inf

ARIMA(0,0,1)(2,1,1)[4]	with drift	: Inf
ARIMA(0,0,1)(2,1,2)[4]		: Inf
ARIMA(0,0,1)(2,1,2)[4]	with drift	: Inf
ARIMA(0,0,2)(0,1,0)[4]		: Inf
ARIMA(0,0,2)(0,1,0)[4]	with drift	: Inf
ARIMA(0,0,2)(0,1,1)[4]		: Inf
ARIMA(0,0,2)(0,1,1)[4]	with drift	: Inf
ARIMA(0,0,2)(0,1,2)[4]		: Inf
ARIMA(0,0,2)(0,1,2)[4]	with drift	: Inf
ARIMA(0,0,2)(1,1,0)[4]		: 562.0122
ARIMA(0,0,2)(1,1,0)[4]	with drift	: 565.0936
ARIMA(0,0,2)(1,1,1)[4]		: Inf
ARIMA(0,0,2)(1,1,1)[4]	with drift	: Inf
ARIMA(0,0,2)(1,1,2)[4]		: Inf
ARIMA(0,0,2)(1,1,2)[4]	with drift	: Inf
ARIMA(0,0,2)(2,1,0)[4]		: Inf
ARIMA(0,0,2)(2,1,0)[4]	with drift	: 566.0619
ARIMA(0,0,2)(2,1,1)[4]		: Inf
ARIMA(0,0,2)(2,1,1)[4]	with drift	: Inf
ARIMA(0,0,3)(0,1,0)[4]		: Inf
ARIMA(0,0,3)(0,1,0)[4]	with drift	: Inf
ARIMA(0,0,3)(0,1,1)[4]		: Inf
ARIMA(0,0,3)(0,1,1)[4]	with drift	: Inf
ARIMA(0,0,3)(0,1,2)[4]		: Inf
ARIMA(0,0,3)(0,1,2)[4]	with drift	: Inf
ARIMA(0,0,3)(1,1,0)[4]		: Inf
ARIMA(0,0,3)(1,1,0)[4]	with drift	: Inf
ARIMA(0,0,3)(1,1,1)[4]		: Inf
ARIMA(0,0,3)(1,1,1)[4]	with drift	: Inf
ARIMA(0,0,3)(2,1,0)[4]		: Inf
ARIMA(0,0,3)(2,1,0)[4]	with drift	: Inf
ARIMA(1,0,0)(0,1,0)[4]		: 564.6591

```

ARIMA(1,0,0)(0,1,0)[4] with drift : 567.1361
ARIMA(1,0,0)(0,1,1)[4] : Inf
ARIMA(1,0,0)(0,1,1)[4] with drift : Inf
ARIMA(1,0,0)(0,1,2)[4] : Inf
ARIMA(1,0,0)(0,1,2)[4] with drift : Inf
ARIMA(1,0,0)(1,1,0)[4] : 561.0232
ARIMA(1,0,0)(1,1,0)[4] with drift : 563.5684
ARIMA(1,0,0)(1,1,1)[4] : Inf
ARIMA(1,0,0)(1,1,1)[4] with drift : Inf
ARIMA(1,0,0)(1,1,2)[4] : Inf
ARIMA(1,0,0)(1,1,2)[4] with drift : Inf
ARIMA(1,0,0)(2,1,0)[4] : Inf
ARIMA(1,0,0)(2,1,0)[4] with drift : 561.0201
ARIMA(1,0,0)(2,1,1)[4] : Inf
ARIMA(1,0,0)(2,1,1)[4] with drift : Inf
ARIMA(1,0,0)(2,1,2)[4] : Inf
ARIMA(1,0,0)(2,1,2)[4] with drift : Inf
ARIMA(1,0,1)(0,1,0)[4] : Inf
ARIMA(1,0,1)(0,1,0)[4] with drift : Inf
ARIMA(1,0,1)(0,1,1)[4] : Inf
ARIMA(1,0,1)(0,1,1)[4] with drift : Inf
ARIMA(1,0,1)(0,1,2)[4] : Inf
ARIMA(1,0,1)(0,1,2)[4] with drift : Inf
ARIMA(1,0,1)(1,1,0)[4] : 561.6312
ARIMA(1,0,1)(1,1,0)[4] with drift : 564.7035
ARIMA(1,0,1)(1,1,1)[4] : Inf
ARIMA(1,0,1)(1,1,1)[4] with drift : Inf
ARIMA(1,0,1)(1,1,2)[4] : Inf
ARIMA(1,0,1)(1,1,2)[4] with drift : Inf
ARIMA(1,0,1)(2,1,0)[4] : Inf
ARIMA(1,0,1)(2,1,0)[4] with drift : Inf
ARIMA(1,0,1)(2,1,1)[4] : Inf

```

```

ARIMA(1,0,0)(0,1,1)[4] : Inf
ARIMA(1,0,0)(0,1,1)[4] with drift : Inf
ARIMA(1,0,0)(0,1,2)[4] : Inf
ARIMA(1,0,0)(0,1,2)[4] with drift : Inf
ARIMA(1,0,0)(1,1,0)[4] : 561.0232
ARIMA(1,0,0)(1,1,0)[4] with drift : 563.5684
ARIMA(1,0,0)(1,1,1)[4] : Inf
ARIMA(1,0,0)(1,1,1)[4] with drift : Inf
ARIMA(1,0,0)(1,1,2)[4] : Inf
ARIMA(1,0,0)(1,1,2)[4] with drift : Inf
ARIMA(1,0,0)(2,1,0)[4] : Inf
ARIMA(1,0,0)(2,1,0)[4] with drift : 561.0201
ARIMA(1,0,0)(2,1,1)[4] : Inf
ARIMA(1,0,0)(2,1,1)[4] with drift : Inf
ARIMA(1,0,0)(2,1,2)[4] : Inf
ARIMA(1,0,0)(2,1,2)[4] with drift : Inf
ARIMA(1,0,1)(0,1,0)[4] : Inf
ARIMA(1,0,1)(0,1,0)[4] with drift : Inf
ARIMA(1,0,1)(0,1,1)[4] : Inf
ARIMA(1,0,1)(0,1,1)[4] with drift : Inf
ARIMA(1,0,1)(0,1,2)[4] : Inf
ARIMA(1,0,1)(0,1,2)[4] with drift : Inf
ARIMA(1,0,1)(1,1,0)[4] : 561.6312
ARIMA(1,0,1)(1,1,0)[4] with drift : 564.7035
ARIMA(1,0,1)(1,1,1)[4] : Inf
ARIMA(1,0,1)(1,1,1)[4] with drift : Inf
ARIMA(1,0,1)(1,1,2)[4] : Inf
ARIMA(1,0,1)(1,1,2)[4] with drift : Inf
ARIMA(1,0,1)(2,1,0)[4] : Inf
ARIMA(1,0,1)(2,1,0)[4] with drift : Inf
ARIMA(1,0,1)(2,1,1)[4] : Inf

```

ARIMA(1,0,2)(0,1,0)[4]	: Inf
ARIMA(1,0,2)(0,1,0)[4] with drift	: Inf
ARIMA(1,0,2)(0,1,1)[4]	: Inf
ARIMA(1,0,2)(0,1,1)[4] with drift	: Inf
ARIMA(1,0,2)(0,1,2)[4]	: Inf
ARIMA(1,0,2)(0,1,2)[4] with drift	: Inf
ARIMA(1,0,2)(1,1,0)[4]	: 562.8969
ARIMA(1,0,2)(1,1,0)[4] with drift	: 566.1361
ARIMA(1,0,2)(1,1,1)[4]	: Inf
ARIMA(1,0,2)(1,1,1)[4] with drift	: Inf
ARIMA(1,0,2)(2,1,0)[4]	: Inf
ARIMA(1,0,2)(2,1,0)[4] with drift	: 565.7824
ARIMA(1,0,3)(0,1,0)[4]	: Inf
ARIMA(1,0,3)(0,1,0)[4] with drift	: Inf
ARIMA(1,0,3)(0,1,1)[4]	: Inf
ARIMA(1,0,3)(0,1,1)[4] with drift	: Inf
ARIMA(1,0,3)(1,1,0)[4]	: Inf
ARIMA(1,0,3)(1,1,0)[4] with drift	: Inf
ARIMA(2,0,0)(0,1,0)[4]	: 567.2237
ARIMA(2,0,0)(0,1,0)[4] with drift	: 569.9477
ARIMA(2,0,0)(0,1,1)[4]	: Inf
ARIMA(2,0,0)(0,1,1)[4] with drift	: Inf
ARIMA(2,0,0)(0,1,2)[4]	: Inf
ARIMA(2,0,0)(0,1,2)[4] with drift	: Inf
ARIMA(2,0,0)(1,1,0)[4]	: 563.6978
ARIMA(2,0,0)(1,1,0)[4] with drift	: 566.5473
ARIMA(2,0,0)(1,1,1)[4]	: Inf
ARIMA(2,0,0)(1,1,1)[4] with drift	: Inf
ARIMA(2,0,0)(1,1,2)[4]	: Inf
ARIMA(2,0,0)(1,1,2)[4] with drift	: Inf
ARIMA(2,0,0)(2,1,0)[4]	: Inf
ARIMA(2,0,0)(2,1,0)[4] with drift	: 563.9904
ARIMA(2,0,0)(2,1,1)[4]	: Inf
ARIMA(2,0,0)(2,1,1)[4] with drift	: Inf

ARIMA(2,0,1)(0,1,0)[4]	: Inf
ARIMA(2,0,1)(0,1,0)[4] with drift	: Inf
ARIMA(2,0,1)(0,1,1)[4]	: Inf
ARIMA(2,0,1)(0,1,1)[4] with drift	: Inf
ARIMA(2,0,1)(0,1,2)[4]	: Inf
ARIMA(2,0,1)(0,1,2)[4] with drift	: Inf
ARIMA(2,0,1)(1,1,0)[4]	: Inf
ARIMA(2,0,1)(1,1,0)[4] with drift	: Inf
ARIMA(2,0,1)(1,1,1)[4]	: Inf
ARIMA(2,0,1)(1,1,1)[4] with drift	: Inf
ARIMA(2,0,1)(2,1,0)[4]	: Inf
ARIMA(2,0,1)(2,1,0)[4] with drift	: 565.7866
ARIMA(2,0,2)(0,1,0)[4]	: Inf
ARIMA(2,0,2)(0,1,0)[4] with drift	: Inf
ARIMA(2,0,2)(0,1,1)[4]	: Inf
ARIMA(2,0,2)(0,1,1)[4] with drift	: Inf
ARIMA(2,0,2)(1,1,0)[4]	: Inf
ARIMA(2,0,2)(1,1,0)[4] with drift	: Inf
ARIMA(2,0,3)(0,1,0)[4]	: Inf
ARIMA(2,0,3)(0,1,0)[4] with drift	: Inf
ARIMA(3,0,0)(0,1,0)[4]	: 569.7795
ARIMA(3,0,0)(0,1,0)[4] with drift	: 572.7617
ARIMA(3,0,0)(0,1,1)[4]	: Inf
ARIMA(3,0,0)(0,1,1)[4] with drift	: Inf
ARIMA(3,0,0)(0,1,2)[4]	: Inf
ARIMA(3,0,0)(0,1,2)[4] with drift	: Inf
ARIMA(3,0,0)(1,1,0)[4]	: 566.1309
ARIMA(3,0,0)(1,1,0)[4] with drift	: 569.2844
ARIMA(3,0,0)(1,1,1)[4]	: Inf
ARIMA(3,0,0)(1,1,1)[4] with drift	: Inf
ARIMA(3,0,0)(2,1,0)[4]	: Inf
ARIMA(3,0,0)(2,1,0)[4] with drift	: Inf
<hr/>	
ARIMA(3,0,1)(0,1,0)[4]	: Inf
ARIMA(3,0,1)(0,1,0)[4] with drift	: Inf
ARIMA(3,0,1)(0,1,1)[4]	: Inf
ARIMA(3,0,1)(0,1,1)[4] with drift	: Inf
ARIMA(3,0,1)(1,1,0)[4]	: Inf
ARIMA(3,0,1)(1,1,0)[4] with drift	: Inf
ARIMA(3,0,2)(0,1,0)[4]	: 565.7929
ARIMA(3,0,2)(0,1,0)[4] with drift	: 569.4534

Best model: ARIMA(0,0,1)(2,1,0)[4]