



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
CURSO DE ENGENHARIA DE PRODUÇÃO

RAPHAEL ALBUQUERQUE XAVIER E SILVA

**ESTUDO DE CASO SOBRE APLICAÇÕES DE MODELOS CLÁSSICOS DE
PREVISÃO DE DEMANDA PARA UMA EMPRESA DE DELIVERY DE ALIMENTOS**

Recife
2023

RAPHAEL ALBUQUERQUE XAVIER E SILVA

**ESTUDO DE CASO SOBRE APLICAÇÕES DE MODELOS CLÁSSICOS DE
PREVISÃO DE DEMANDA PARA UMA EMPRESA DE DELIVERY DE ALIMENTOS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Produção da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel em
Engenharia de Produção.

Orientador (a): Isis Didier Lins

Recife

2023

Ficha de identificação da obra elaborada pelo autor,
através do programa de geração automática do SIB/UFPE

Silva, Raphael Albuquerque Xavier e .

Estudo de caso sobre aplicações de modelos clássicos de previsão de
demanda para uma empresa de delivery de alimentos / Raphael Albuquerque
Xavier e Silva. - Recife, 2023.

44 : il., tab.

Orientador(a): Isis Didier Lins

Trabalho de Conclusão de Curso (Graduação) - Universidade Federal de
Pernambuco, Centro de Tecnologia e Geociências, Engenharia de Produção -
Bacharelado, 2023.

1. Previsão de Demanda. 2. Delivery de Alimentos. 3. Séries temporais. 4.
Suavização exponencial. I. Lins, Isis Didier. (Orientação). II. Título.

620 CDD (22.ed.)

RAPHAEL ALBUQUERQUE XAVIER E SILVA

**ESTUDO DE CASO SOBRE APLICAÇÕES DE MODELOS CLÁSSICOS DE
PREVISÃO DE DEMANDA PARA UMA EMPRESA DE DELIVERY DE ALIMENTOS**

Trabalho de Conclusão de Curso
apresentado ao Curso de Engenharia de
Produção da Universidade Federal de
Pernambuco, como requisito parcial para
obtenção do título de Bacharel em
Engenharia de Produção.

Aprovado em: 27/04/2023

BANCA EXAMINADORA

Profa. Dra. Isis Didier Lins (Orientadora)
Universidade Federal de Pernambuco

Prof. Dr. João Mateus Marques de Santana (Examinador Interno)
Universidade Federal de Pernambuco

Profa. Dr. Suzana de Franca Dantas Daher (Examinadora Interna)
Universidade Federal de Pernambuco

AGRADECIMENTOS

Agradeço esse trabalho a todas pessoas que cruzaram meu caminho durante essa trajetória e que de alguma forma me fizeram ter chegado até aqui, algumas dessas gostaria de deixar uma atenção especial.

Primeiramente a meus pais Ana Regina e Moisés e meu irmão Phillipe por terem investido tantos recursos na minha educação e sempre me apoiarem nas minhas decisões e me darem a base para conseguir trilhar essa trajetória.

Um agradecimento especial àqueles que estiveram comigo durante a graduação e fizeram com que essa fase da minha vida tenha sido tão incrível Bia Souto, Nana, Andressa, Bruna Valois, Luiza, Rafa e Concílio por todos resumos divididos, caronas, desabafos e revisões pré provas são amizades que a universidade me deu e levarei para a vida. Agradeço também a Bruna Araújo, Amanda, Tullio, Sofia e Deb por todo suporte durante a faculdade como um todo e em especial ao período de construção deste trabalho de conclusão.

Gostaria também de reconhecer a agradecer o Movimento Empresa Júnior que de longe foi uma das melhores experiências da minha vida e de certa forma uma segunda graduação durante o período vivido na faculdade, onde pude aplicar de forma prática toda a teoria aprendida e foi fundamental para a formação do profissional que estou me formando. Agradeço a Ciclo, FEJEPE, Brasil Júnior e todos que estiveram comigo nessas organizações, porém que não mencionarei para não cometer a gafe de esquecer algum nome, tendo em vista que são tantos.

Um agradecimento especial para a empresa do estudo vigente pela minha inserção no mercado de trabalho e por estar sendo uma grande escola de desenvolvimento técnico e comportamental. Em especial para Keize, Giovanna, Anna, Patrícia, Luis, Júlia, Dani e Mari por todo o apoio e ensinamentos que tive durante essa oportunidade, em especial durante a construção deste trabalho.

Por fim, mas não menos importante, agradeço a toda a infraestrutura da UFPE, todo o corpo docente do Departamento de Engenharia de Produção pelos aprendizados durante a trajetória acadêmica, em especial a professora Isis por todos ensinamentos, apoio e orientação durante a construção das etapas deste trabalho.

RESUMO

O setor de delivery de alimentos cresceu significativamente nos últimos anos, obtendo um aumento de 187% em 2020 devido aos impactos da pandemia. Com o aumento da procura pelos serviços de entrega, empresas do setor precisam de uma maior acurácia na sua previsão de demanda para se tornarem competitivas no mercado. Este trabalho considera os dados reais de uma empresa específica do setor de delivery de alimentos e tem como objetivo avaliar métodos e modelos de previsão de demanda (suavização exponencial Holt e Holt-Winters, ARIMA e SARIMA) de forma comparativa com o método utilizado pela própria empresa, de forma que seja possível identificar aquele que apresenta melhor desempenho. O software do RStudio foi utilizado para executar os experimentos e, com os resultados obtidos, foram utilizados uma base histórica de 60 dados mensais, desde janeiro de 2018 até dezembro de 2022, sendo os primeiros 48 meses utilizados para treinar os modelos e os 12 mais recentes para analisar os resultados obtidos, dessa forma foi possível realizar o comparativo entre os métodos clássicos de previsão e o método atual implementado pela empresa a partir das medidas de erro encontradas nas previsões. Como resultados obtidos, pode-se identificar que o método de previsão atual da empresa apresentou o melhor desempenho para o estudo de caso, apresentando os menores resultados para todos indicadores de erro analisados, de forma a trazer uma validação para empresa acerca do método escolhido e utilizado atualmente, dentre dos métodos estatísticos clássicos de previsão, o destaque foi para o método de Holt-Winters, apresentando melhor resultado para três dos quatro indicadores analisados.

Palavras-chave: Delivery de Alimentos, Previsão de demanda, Séries temporais, Suavização exponencial.

ABSTRACT

The food delivery sector has grown significantly in recent years, seeing an increase of 187% in 2020 due to the impacts of the pandemic. With the increase in demand for delivery services, companies in the sector need greater accuracy in their demand forecast to become competitive in the market. This work considers real data from a specific company in the food delivery sector and aims to evaluate demand forecasting methods and models (Holt and Holt-Winters exponential smoothing, ARIMA and SARIMA) in a comparative way with the method used by the company itself, so that it is possible to identify the one with the best performance. The RStudio software was used to run the experiments and, with the results obtained, a historical base of 60 monthly data were used, from January 2018 to December 2022, the first 48 months being used to train the models and the 12 more to analyze the results obtained, in this way it was possible to make a comparison between the classic forecasting methods and the current method implemented by the company based on the error measures found in the forecasts. As results obtained, it can be identified that the company's current forecast method presented the best performance for the case study, presenting the lowest results for all analyzed error indicators, in order to bring validation to the company about the chosen method and currently used, among the classic statistical forecasting methods, the highlight was the Holt-Winters method, presenting the best result for three of the four analyzed indicators.

Keywords: Food Delivery, Demand forecasting, Time series, Exponential smoothing.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Série temporal de todo histórico de dados	34
Figura 2 –	Sazonalidade anual da série temporal	35
Figura 3 –	Sazonalidade anual da série temporal para 2018 e 2019	36
Figura 4 –	Desagregação da série por turno do dia	36
Figura 5 –	Comparativo entre os métodos de análise	38

LISTA DE TABELAS

Tabela 1 –	Resumo da revisão da literatura	29
Tabela 2 –	Análise descritiva da base de dados	33
Tabela 3 –	Resultados obtidos por mês para os métodos de previsão	38
Tabela 4 –	Comparativo entre os erros por modelo	39
Tabela 5 –	Comparativo entre os erros, desconsiderando outliers	40

SUMÁRIO

1	INTRODUÇÃO	11
1.1	SETOR DE DELIVERY DE ALIMENTOS	11
1.2	JUSTIFICATIVA E RELEVÂNCIA DO ESTUDO	12
1.3	OBJETIVOS	12
1.3.1	Objetivo Geral	12
1.3.1	Objetivos Específicos	12
1.4	METODOLOGIA	13
1.5	ESTRUTURA DO TRABALHO	14
2	REVISÃO BIBLIOGRÁFICA	16
2.1	FUNDAMENTAÇÃO TEÓRICA	16
2.1.1	Conceitos e Definições de Previsão de Demanda	16
2.1.2	Modelos Qualitativos	17
2.1.3	Modelos Quantitativos	17
2.1.3.1	<i>Suavização Exponencial - Holt e Holt-Winters</i>	18
2.1.3.2	<i>Modelos ARIMA e SARIMA</i>	20
2.1.4	Erros nas previsões	22
2.2	REVISÃO DA LITERATURA	25
3	ESTUDO DE CASO	31
3.1	DESCRIÇÃO DO PROBLEMA	31
3.2	MÉTODO DE PREVISÃO DA EMPRESA	31
3.3	COLETA DE DADOS	32
3.4	TRATAMENTO DE CARACTERIZAÇÃO DOS DADOS	33
4	RESULTADOS OBTIDOS	37
4.1	IMPLEMENTAÇÃO DOS MÉTODOS E MODELOS DE PREVISÃO DE DEMANDA	37
4.2	ANÁLISE DOS RESULTADOS OBTIDOS	39
5	CONCLUSÃO	41
5.1	CONSIDERAÇÕES FINAIS	41
5.2	LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS	41
	REFERÊNCIAS	43

1 INTRODUÇÃO

1.1 SETOR DE DELIVERY DE ALIMENTOS

O ramo de food delivery, ou delivery de alimentos, é um segmento do mercado de alimentação que vem crescendo significativamente nos últimos anos. Segundo a Fundação Getúlio Vargas (FGV) o ramo teve um aumento de 187%, no ano de 2020, no seu volume devido aos impactos da pandemia, movimentando aproximadamente R\$35 bilhões no ano de 2021 com base em estudos da Associação Brasileira de Bares e Restaurantes (Abrasel). Esse modelo de negócio consiste em oferecer aos consumidores a possibilidade de pedir comida por meio de aplicativos e receber a entrega em casa, sem precisar sair para buscar a refeição.

Com o aumento da procura por esse tipo de serviço, empresas do setor precisam lidar com um desafio constante: garantir que o tempo de entrega seja adequado e que a comida chegue aos clientes em boas condições. Para isso, é fundamental que essas empresas façam uma boa previsão de demanda, ou seja, estimem com precisão quantos pedidos serão recebidos em determinado período.

A previsão de demanda é fundamental para as empresas que buscam uma operação mais eficiente e sustentável. (Makridakis & Hibon, 2000). É uma atividade realizada por toda e qualquer empresa, independente do ramo de atividade, do tamanho ou de sua estratégia e objetivos a longo prazo. Isso acontece devido ao caráter fundamental dessa previsão, sendo sua importância dada, também, pela influência exercida em diferentes partes da empresa, tendo em vista a quantidade de tomadas de decisão que serão realizadas a partir dos resultados previstos.

A partir da análise de dados e tendências de consumo, é possível planejar as operações e alocar recursos adequadamente, evitando atrasos e entregas inapropriadas. No setor de delivery de alimentos, a previsão precisa de demanda é uma atividade crítica, tendo em vista que a pandemia trouxe mudanças significativas na tendência de consumo deste ramo, impactando toda a cadeia de suprimentos e o planejamento logístico. Nesse sentido, a assertividade nos planejamentos de demanda tornou-se um dos principais diferenciais competitivos para as empresas, permitindo que elas se adaptem às mudanças do mercado e atendam às demandas dos consumidores de forma mais eficiente. Além disso, a previsão precisa de

demanda também contribui para a redução de desperdícios de alimentos, reduzindo custos e promovendo a sustentabilidade do negócio.

1.2 JUSTIFICATIVA E RELEVÂNCIA DO ESTUDO

Estudos comprovam que uma alta acurácia na previsão de demanda exerce uma grande influência em relação ao nível de serviço ofertado pela empresa, além de ser de extrema relevância para o custo total do serviço, consequentemente a lucratividade da empresa. Além disso, a baixa acurácia pode desencadear três situações: o não atendimento da demanda, o atendimento com atrasos e também o excesso de estoques.

A sazonalidade do mercado e dias especiais com comportamentos diferentes são os principais problemas para o time responsável pelo planejamento de demanda, tendo em vista que os modelos de previsão levam em consideração resultados históricos e as variações ano a ano trazem complexidade para os modelos matemáticos.

Diante disso, com base nos impactos da acurácia na complexidade relacionada à construção de um modelo de previsão e no impacto para os resultados da organização este estudo surge buscando entender os benefícios que podem ser obtidos pela empresa a partir da aplicação do melhor modelo de previsão de demanda, levando em consideração o seu modelo de negócios.

1.3 OBJETIVOS

1.3.1 Objetivo Geral

O objetivo deste trabalho é realizar um estudo de caso com dados históricos de uma empresa do ramo de delivery de alimentos, a fim de comparar o método de previsão de demanda desenvolvido pela empresa com métodos clássicos de previsão de demanda, a fim de identificar aquele que apresenta maior precisão para o ramo em específico.

1.3.2 Objetivos Específicos

- Realização do mapeamento da história do estado da arte a partir de fontes seguras como livros e periódicos científicos com o objetivo de ter um maior entendimento do ramo de delivery de alimentos e da

aplicação de ferramentas de previsão de demanda para ele;

- Definição dos métodos de previsão de demanda que serão utilizados durante a realização do estudo de caso e aplicar os métodos propostos para realizar a previsão de demanda da empresa em questão, utilizando dados simulados;
- Analisar as medidas de erros encontradas nas previsões realizadas pelos métodos estudados;
- Realização de uma análise comparativa entre os resultados encontrados e levantamento de insights para a empresa estudada a partir dos resultados obtidos e análises realizadas.

1.4 METODOLOGIA

A metodologia do trabalho presente, leva em consideração os estudos de Gil (2008) o método científico do estudo realizado pode ser classificado como fenomenológico por ser um estudo de caso que descreve diretamente a experiência vivida, utilizando como base a ciência para aplicar em um cenário específico e estudar o fenômeno observado.

A finalidade do estudo pode ser classificada como aplicada, devido à utilização de dados reais de uma empresa e a aplicação de modelos matemáticos com a simulação desses dados para a obtenção dos resultados a serem estudados

Devido ao caráter aplicado e à utilização de modelos matemáticos e dados históricos, o estudo é classificado quanto como de natureza quantitativa, devido a utilização desses valores para realização das simulações dos cenários futuros de previsão e também da utilização de métodos estatísticos para avaliação dos resultados obtidos e comparação entre os métodos simulados.

Quanto ao objetivo da pesquisa, pode ser considerado como uma pesquisa descritiva, pelo seu objetivo de descrever o fenômeno de análise, da utilização dos dados históricos da organização para estudar técnicas, pré-estabelecidas, diferentes de previsão de demanda com o intuito de descrever os resultados obtidos, e fazer uma análise comparativa entre eles.

Por fim, quanto aos dados, trata-se de um estudo de caso descritivo, pela relação com o objetivo do estudo. As técnicas de pesquisa a serem aplicadas na realização do projeto consiste na documentação direta, tendo em vista que os dados obtidos para realização do estudo serão obtidos na própria empresa em que a

análise será realizada, através do levantamento de dados históricos para realização do estudo de caso, que utiliza dos dados quantitativos e de modelos matemáticos para a realização das simulações necessária que irão levar em consideração o contexto específico em que o fenômeno está sendo aplicado.

1.5 ESTRUTURA DO TRABALHO

Este presente trabalho é composto por cinco capítulos descritos da seguinte forma:

Capítulo 1: Introdução

O primeiro capítulo tem como objetivo introduzir o setor em que a empresa está inserida e a importância da acurácia na previsão de demanda para empresas do ramo de delivery de alimentos, principalmente após o crescimento do mercado acelerado pela pandemia do COVID-19. Além de especificar os objetivos do trabalho e metodologia utilizada para sua realização.

Capítulo 2: Fundamentação Teórica e Revisão da Literatura

Este capítulo traz a base teórica de conhecimento para aplicação dos modelos e entendimento do trabalho como um todo, a partir da definição de conceitos básicos sobre previsão de demanda, modelos de previsão e indicadores de acompanhamento do erro das previsões, assim como uma abordagem mais detalhada de cada um dos métodos que serão aplicados no estudo de caso. Além disso, são apresentados artigos em que esses métodos já foram trabalhados e como esses estudos anteriores influenciaram a aplicação do estudo de caso presente para o setor.

Capítulo 3: Estudo de Caso

O terceiro capítulo apresenta a empresa que está sendo estudada e os problemas identificados que influenciaram a definição do objeto de estudo. A partir deste cenário é descrito como foram coletados e tratados os dados no estudo, aplicando uma análise descritiva do histórico da demanda da empresa e analisadas as características da série temporal estudada.

Capítulo 4: Resultados Obtidos

Neste capítulo os métodos de análise são aplicados para a série

histórica e seus resultados são expressos e analisados em comparação com os dados reais obtidos pela empresa, assim como comparados com o modelo de previsão atual da organização. A partir dos resultados obtidos com as modelagem é realizado uma análise comparativa entre os métodos por meio da utilização dos indicadores de erro para o modelos estatísticos e comparando seus resultados.

Capítulo 5: Conclusão

O último capítulo traz, de forma resumida, uma visão geral do trabalho abarcando os objetivos do trabalho e os resultados obtidos a partir da análise, sugerindo os próximos passos do estudo de caso para implementação na empresa, assim como as limitações do estudo e sugestões para trabalhos futuros.

2 REVISÃO BIBLIOGRÁFICA

2.1 FUNDAMENTAÇÃO TEÓRICA

2.1.1 Conceitos e Definições da Previsão de Demanda

Segundo Moreira (2008), o planejamento está atrelado a todos os tipos de empresas, seja qual for o tamanho ou seu ramo, se tornando uma atividade que envolve todas as áreas da organização e dá base para diversos tipos de decisões de negócios a partir do planejamento realizado. A previsão de demanda é a principal base para realizar o planejamento da operação da organização, tendo em vista que ela tem o caráter de ponto de partida para as decisões de negócio, a partir do planejamento de quando a empresa realizará as vendas de cada um de seus produtos, simulando a receita total da organização e dando base para diversos outros cálculos, como custos atrelados à equipe para realizar a produção, matéria-prima necessária, entre outros. Slack, Chambers & Johnston (2002) trazem a importância da diminuição dos erros atrelados às previsões, levando em consideração não apenas o número previsto pelo modelo, como também a estimativa de erro do modelo, buscando sempre esforços para melhorar os processos de previsão, tendo em vista que uma melhor desempenho da previsão está ligada à redução de custos desnecessários e aumento da competitividade de mercado da empresa em questão. Além disso, Slack, Chambers & Johnston (2002) trazem dois conceitos importantes na previsão:

- A importância do horizonte de tempo analisado, podendo influenciar diretamente no erro aceitável e nos métodos de previsão de demanda que serão utilizados em cada caso.
- Nível de agregação dos dados, que é muitas vezes atrelado ao horizonte temporal; a agregação dos dados está relacionada a qual granularidade deve ser alcançada, por exemplo um restaurante precisa saber a quantidade de vendas por dia, por tipo de prato, por turno ou uma combinação dessas variáveis para a tomada de decisão.

Em relação aos possíveis métodos utilizados para realização da previsão de demanda, levando em consideração os aspectos apontados, Moreira (2008) traz a classificação dos métodos de previsão como qualitativos e quantitativos a depender da natureza dos dados que são utilizados para a realização da previsão.

2.1.2 Modelos Qualitativos

Moreira (2008) classifica os métodos qualitativos como aqueles que são geralmente utilizados quando não existem dados para serem analisados, ou quando estes não são confiáveis, dessa forma as previsões são realizadas levando em consideração fatores subjetivos como o conhecimento e a experiência das pessoas que lidam com aquele tipo específico de demanda, como funcionários da empresa, clientes, fornecedores etc. Geralmente os métodos qualitativos podem sofrer bastantes flutuações em seus resultados devido ao caráter da análise e ao caráter dados qualitativos que estão sendo processados para realização das previsões. Entre os métodos qualitativos estão:

- Opiniões de executivos: previsões, geralmente de longo prazo e atreladas ao planejamento estratégico da empresa, realizadas por um grupo pequeno de pessoas do alto executivo da organização, comumente de áreas diferentes e que tenham relação com a demanda futura;
- Opinião da força de vendas: realizadas pelos responsáveis pelas vendas da organização, devido ao conhecimento do mercado e entendimento de possíveis alterações que a demanda pode sofrer, sejam sazonais ou comportamentos de mercado;
- Pesquisas junto a consumidores: pesquisas de mercado para entender o perfil do consumidor e as suas necessidades de consumo, buscando na raiz da demanda qual a previsão estimada para o período de previsão;
- Método Delphi: Trata-se de uma técnica de pesquisa denominada "painel de especialistas", que envolve a convocação de um grupo de indivíduos com expertise na área de interesse. Esse grupo é reunido de maneira a minimizar a interação entre os participantes, evitando que as opiniões sejam influenciadas ou viesadas pelas crenças e percepções dos demais membros. As opiniões dos especialistas são documentadas em relatórios que orientam a realização das previsões.

2.1.3 Modelos Quantitativos

Segundo Moreira (2008), são os métodos que levam em consideração os modelos matemáticos para realizar as previsões, exigindo que exista conhecimento

prévio dos dados preliminares para a realização de análises e identificação de padrões de consumo visando a realização das previsões futuras. Moreira (2008) subdivide os métodos quantitativos em duas principais grandes esferas, comentadas a seguir.

Métodos causais realizam a previsão da demanda a partir da análise de uma variável dentro da organização (variável causal) que tem correlação com a demanda da empresa, dessa forma, a partir da estimativa dessa variável é realizada a previsão de demanda do produto ou grupo de produtos analisado. A principal subdivisão do método causal é a regressão simples no caso de levar em consideração apenas uma variável causal e regressão múltipla no caso de serem levadas em conta duas ou mais variáveis causais.

Métodos ou modelos de previsão de séries temporais levam em consideração os resultados passados da demanda, olhando para padrões de tempos especificados e a partir dos resultados já coletados são realizadas as previsões para tempos futuros, levando em consideração que o comportamento histórico poderá ser projetado para realização das previsões futuras. Dentro da classificação de séries temporais existem diversos modelos e métodos para realização das análises dos dados. Os utilizados neste trabalho são introduzidos a seguir.

2.1.3.1 Suavização Exponencial - Holt e Holt-Winters

A suavização exponencial foi um método proposto por Brown (1959), Holt (1957) e Winters (1960), sendo os pioneiros na utilização da ferramenta para previsão de séries temporais. A suavização exponencial é um método de previsão que utiliza médias ponderadas de observações anteriores, com os pesos decaindo exponencialmente à medida que as observações envelhecem. Isso gera previsões confiáveis rapidamente e para uma ampla gama de séries temporais (HYNDMAN, 2013). Os métodos de suavização exponencial podem ser dos mais simples, levando em consideração apenas o histórico recente para previsões, como podem ter evoluções nos seus estudos e passarem a levar em consideração inclusive tendências e sazonalidade, como são os métodos de Holt e Holt-Winters, utilizados para este estudo.

Conhecido como método de tendência linear, Holt (1957) estendeu a suavização exponencial simples para incluir a tendência da série temporal na sua análise, o método utiliza além do histórico de valores passados a tendência atual para prever os valores futuros, sendo a tendência estimada por meio de uma

suavização. Dessa forma, a previsão é obtida a partir de uma combinação entre o nível e a tendência da série, utilizando as seguintes fórmulas (HYNDMAN, 2013):

$$\text{Equação de previsão: } Y_{t+h|t} = (L_t + hB_t)$$

$$\text{Equação de nível: } L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + B_{t-1})$$

$$\text{Equação de tendência: } B_t = \beta(L_t - L_{t-1}) + (1 - \beta)B_{t-1}$$

em que:

Y_t é o valor observado no tempo t ;

L_t é o nível da série no tempo t ;

h é previsão a frente;

B_t é a média ponderada da tendência estimada no tempo t ;

α é a constante de suavização para o nível;

β é a constante de suavização para a tendência.

Esse método de previsão apresenta uma tendência constante, seja de crescimento ou de decrescimento, seguindo indefinidamente no futuro. É, portanto, indicado principalmente para horizontes curtos de previsão, devido a possibilidade de superestimar as tendências, principalmente para dados de um futuro distante, além disso não são indicados para séries com sazonalidade (HYNDMAN, 2013).

A partir da identificação de sazonalidade nas séries temporais, Holt (1957) e Winters (1960) utilizaram a suavização com tendência linear como base para desenvolvimento de um método que captura a sazonalidade da série temporal, realizando a previsão a partir da combinação da tendência que está ligada à direção dos dados da série temporal (isto é, crescimento ou decrescimento), da sazonalidade atrelada a padrões repetitivos que acontecem no tempo e do nível que está associado ao valor médio da série tempo. Dessa forma o método é obtido a partir da combinação dessas componentes e é apresentado na fórmula:

$$\text{Equação de previsão: } Y_{t+h|t} = (L_t + hB_t)S_{t+h-m(k+1)}$$

Equação de nível: $L_t = \alpha \frac{Y_t}{S_{t-m}} + (1 - \alpha)(L_{t-1} + B_{t-1})$

Equação de tendência: $B_t = \beta(L_t - L_{t-1}) + (1 - \beta)B_{t-1}$

Equação da sazonalidade: $S_t = \gamma \frac{Y_t}{(L_{t-1} + B_{t-1})} + (1 - \gamma)S_{t-m}$

Onde:

k é a parte inteira de $(h-1)/m$;

S_t é a componente sazonal;

γ o parâmetro de suavização para a sazonalidade. (HYNDMAN, 2013)

Para aplicação do modelo, é necessário fornecer as séries temporais com relação ao nível e tendência (no caso da aplicação de Holt) e, além delas, a sazonalidade no caso Holt-Winters, além de fornecer os valores dos parâmetros alpha, beta e gama para aplicação do modelo.

2.1.3.2 Modelos ARIMA e SARIMA

Nos anos 1970, George Box e Gwilym Jenkins popularizaram o método chamado ARIMA (sigla para Auto-Regressive Integrated Moving Average, traduzido como modelo autorregressivo integrado de médias móveis). O modelo estatístico é utilizado para prever séries temporais a partir de três componentes:

Componente da Autorregressão (AR), expresso por p = ordem da parte autoregressiva: utiliza valores passados da série temporal para realizar a previsão dos valores futuros, sendo obtida a variável de interesse a partir de uma combinação linear dos valores passados desta variável, conforme a fórmula:

$$Y_t = c + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t$$

Em que:

c é uma constante;

Y_t é a observação no tempo t ;

ε_t é o erro aleatório no tempo t ;

ϕ_t é o coeficiente da autorregressão para as observações de períodos anteriores, que indicam a influência dos valores passados na previsão do valor atual.

Componente Integrado (I), expresso por d = grau de diferenciação envolvido: utilizado para lidar com séries temporais não-estacionárias, transformando-as em séries num formato estacionário, para a aplicação do método na série temporal, estabilizando a média e removendo as mudanças de nível da série, dessa forma há uma redução na tendência e sazonalidade da série. A aplicação da diferenciação, pode ser obtida conforme a fórmula (HYNDMAN, 2013):

$$Y'_t = Y_t - Y_{t-1}$$

Onde:

Y'_t é a diferenciação de primeira ordem da série temporal no tempo t .

Para casos em que a série temporal permaneça no formato não-estacionária, a diferenciação poderá ser realizada outras vezes, até encontrar a diferenciação que torne a série temporal estacionária.

Componente das Médias Móveis (MA), expresso por q = ordem da parte das médias móveis: utiliza dos valores dos erros passados da série temporal para fazer a previsão do valor futuro, sendo obtida a variável de interesse a partir de uma combinação linear dos valores passados do erro, conforme a fórmula:

$$Y_t = c + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q}$$

Em que:

c é uma constante;

Y_t é a série temporal e sua atribuição no tempo;

ε_t é o componente do erro aleatório do modelo, chamado de ruído branco;

$\theta_{t-1}, \theta_{t-2}, \dots, \theta_{t-q}$, são os coeficientes dos erros de períodos anteriores, que indicam a influência dos erros passados na previsão do valor atual.

O modelo de ARIMA é obtido a partir do somatório da autorregressão (AR) com a diferenciação da série (I) e um modelo de média móvel (MA), sendo disposto pela fórmula:

$$Y'_t = c + \phi_1 Y'_{t-1} + \dots + \phi_p Y'_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t$$

Onde:

Y'_t é a série diferenciada.

O método SARIMA é uma extensão do modelo ARIMA que leva em consideração a sazonalidade dos dados, seguindo a utilização dos mesmos três

componentes principais, porém este é modelado por meio de componentes adicionais para a tendência sazonal. Suas equações são obtidas a partir das equações do ARIMA, tendo a adição do fator sazonal na análise

P = Ordem do componente da auto regressão sazonal;

D = Número de diferenças sazonais necessárias para tornar a série estacionária;

Q = Ordem do componente de média móvel sazonal. (HYNDMAN, 2013).

2.1.4 Erros nas Previsões

Independentemente do método de previsão de demanda utilizado, o fato de realizar uma previsão está atrelado à realização de uma suposição do acontecimento futuro a partir de análises e projeções, dessa forma as previsões sempre geram resultados próximos do realizado de fato, tendo uma faixa diferença entre os cenários, categorizando o erro da previsão.

De acordo com Corrêa & Corrêa (2007) e Moreira (2008), a precisão das previsões pode ser melhorada considerando dois fatores principais: a tendência e a sazonalidade da demanda. A capacidade de prever o crescimento ou decréscimo da demanda ao longo do tempo é essencial para a precisão dos modelos de previsão, bem como a capacidade de identificar padrões sazonais em diferentes janelas de tempo, como dias da semana, horários do dia ou meses.

Além disso, o horizonte de tempo em que a previsão será realizada deve ser considerado, uma vez que alguns modelos são mais adequados para previsões de curto prazo, enquanto outros funcionam melhor em horizontes de médio ou longo prazo. Este estudo tem como objetivo destacar a importância desses fatores para aprimorar as previsões em busca da redução dos erros dos métodos e modelos.

Para a realização da análise de métodos diferentes e entendimento da adequação do método escolhido frente ao cenário analisado, Moreira (2008) define duas classes diferentes de indicadores que dão base à realização das análises do erro atrelado ao método, buscando um melhor desempenho do método, essas indicadores podem ser divididos em:

- **Classe de indicadores de adequação**

Indicadores que buscam adequar a previsão à partir da análise da discrepância entre os resultados previstos e os resultados reais. Esses indicadores têm como objetivo chegar a novos resultados de previsão a partir do erro do método em si.

- **Classe de indicadores de avaliação de desempenho**

Nesse trabalho serão focados em indicadores de avaliação de desempenho, que tem como objetivo fazer comparações entre os resultados obtidos pelos métodos aplicados. Entre os os indicadores de avaliação de desempenho, Corrêa & Corrêa (2007) trazem o conceito de viés que está atrelado ao fato de os erros acontecerem sempre inteiramente para mais ou para menos, através da realização de uma previsão que seja sempre subdimensionada ou sempre superdimensionada, geralmente esse fenômeno está atrelado a alguma causa não identificada no processo de previsão. Segundo Moreira (2008), o principal indicador de desempenho é a medida do viés da previsão que tem como objetivo captá-lo através da relação da demanda real e prevista e o sinal encontrado na variação desses resultados.

- **RAIZ DO ERRO MÉDIO QUADRÁTICO (RMSE)**

O RMSE é uma medida de avaliação de desempenho de um modelo de previsão que mede a diferença média entre os valores previstos pelo modelo e os valores reais observados. Tem a vantagem de penalizar erros maiores com maior peso do que os erros menores (HYNDMAN & KOEHLER, 2005). O RMSE é calculado a partir da raiz quadrada da média dos erros ao quadrado entre as previsões do modelo e os valores reais, conforme a equação:

$$RMSE = \sqrt{\frac{1}{N} \sum_{t=1}^N (y_t - p_t)^2}$$

Onde:

y_t é o valor real da observação t

p_t é o valor previsto pelo modelo para a observação t

N é o número total de observações.

- **ERRO ABSOLUTO MÉDIO (MAE)**

O MAE é uma medida de avaliação de desempenho de um modelo de previsão que mede a média das diferenças absolutas entre os valores previstos pelo modelo e os valores reais observados. Tem a vantagem de ser menos sensível a outliers do que o RMSE (HYNDMAN & KOEHLER, 2005). O MAE é calculado a partir da média dos erros absolutos entre as previsões do modelo e os valores reais,

conforme a equação:

$$MAE = \frac{1}{N} \sum_{t=1}^N |y_t - p_t|$$

Onde:

y_t é o valor real da observação t

p_t é o valor previsto pelo modelo para a observação t

N é o número total de observações.

• ERRO PERCENTUAL ABSOLUTO MÉDIO (MAPE)

O MAPE é uma medida de avaliação de desempenho de um modelo de previsão que mede a média das diferenças percentuais absolutas entre os valores previstos pelo modelo e os valores reais observados (HYNDMAN & KOEHLER, 2005). Esse método não deve ser aplicado quando há valores reais da observação igual ou próximos de zero, devido ao caráter de seu cálculo. O MAPE é calculado a partir da média das diferenças percentuais absolutas entre as previsões do modelo e os valores reais, conforme a equação:

$$MAPE = \frac{1}{N} \sum_{t=1}^N \frac{|y_t - p_t|}{y_t} \times 100\%$$

Onde:

y_t é o valor real da observação t

p_t é o valor previsto pelo modelo para a observação t

N é o número total de observações.

• ERRO ESCALAR ABSOLUTO MÉDIO (MASE)

O MASE é uma medida de avaliação de desempenho de um modelo de previsão que mede a precisão das previsões em relação a um modelo de referência simples. É uma das métricas mais utilizadas em problemas de previsão de séries temporais e tem a vantagem de ser uma medida comparativa, ou seja, permite comparar o desempenho de diferentes modelos em séries temporais com diferentes níveis de variabilidade (HYNDMAN & KOEHLER, 2005).

O MASE deve ser aplicado sempre que você quiser avaliar a qualidade das

previsões de um modelo de previsão de séries temporais e comparar seu desempenho com um modelo de referência simples. É particularmente útil em séries temporais com diferentes níveis de variabilidade e sazonalidade, em que outras métricas, como o MAE e o RMSE, podem não ser tão adequadas.

O MASE é calculado a partir da razão entre o erro absoluto médio do modelo em questão e o erro absoluto médio de um modelo de referência simples, conforme a equação:

$$MASE = \frac{1}{N} \sum_{t=1}^N \frac{|y_t - p_t|}{\left((N-1)^{-1} \sum_{t=2}^N |y_t - y_{t-1}| \right)^{-1}}$$

Onde:

y_t é o valor real da observação t

p_t é o valor previsto pelo modelo para a observação t

N é o número total de observações.

2.2 REVISÃO DA LITERATURA

Hess, Spinler & Winkerbach (2021) trazem a complexidade relacionada ao modelo de negócios das plataformas de delivery e a necessidade de uma previsão de demanda mais detalhada, tendo em vista o curto espaço de tempo entre o pedido realizado e a expectativa de entrega por parte do cliente, atrelada à complexidade da previsão, tendo em vista que diversos fatores influenciam na operação, como a geografia do local, necessitando ter um detalhamento maior de em que parte da cidade/bairro a demanda acontece, o dia da semana e sua sazonalidade. No estudo de Hess, Spinler & Winkerbach (2021), é desenvolvida uma metodologia robusta utilizando os princípios teóricos da previsão da demanda, baseado no método de séries temporais, atrelado a modelos de machine learning, obtendo resultados que podem ser replicados para ambientes semelhantes, desde que algumas condições que foram levantadas durante o estudo sejam respeitadas. O estudo torna-se bastante completo, considerando as análises e discussões dos resultados obtidos ao comparar o Machine Learning com os métodos tradicionais de previsão, dando destaque para a precisão associada a esses métodos, além de trazer enfoque na utilização do erro escalar absoluto médio (MASE) para análise do erro.

A pesquisa de Crivellari, Beinart, Caetano, Seydoux & Cardoso (2022) traz um estudo de caso real de uma empresa de delivery de alimentos, utilizando o

regressor CNN-LSTM, baseado no método de rede neural profunda, treinado de forma a trazer previsões em séries temporais a partir da especificidade do local de análise. O modelo faz o comparativo entre os resultados obtidos com o Machine Learning com resultados de métodos empíricos, sobressaindo os resultados obtidos com o aprendizado de máquina, porém sem utilizar a comparação de erros com métodos estatísticos de previsão, apenas comparando com métodos empíricos.

A pesquisa de Haberleitne, Meyr & Taudes (2010) apresenta um estudo de caso numa indústria de refratários que tem seu modelo de negócios definido por produção sob encomenda, contando com um perfil de demanda sazonal e com alto índice de cancelamentos. O estudo mostra que para o perfil volátil de demanda o algoritmo perde a confiabilidade em horizontes de tempo maiores, dessa forma é proposta uma metodologia que compara os erros de previsão e seleciona o método mais preciso. Apesar do desenvolvimento de um método específico, o estudo trata de forma superficial essa formulação e também a base de referência utilizada, com a falta de uma análise prévia dos dados que estão sendo levados em consideração no estudo de caso.

O estudo de Tanizaki, Hoshino, Shimmura & Takenaka (2019) utiliza o aprendizado de máquina e análises estatísticas para realizar a previsão de demanda de cinco diferentes lojas reais. Na análise, são usados dados para simular os resultados a partir dos modelos de machine learning: Bayesian linear regression, boosted decision tree regression e decision forest regression, e do método stepwise para análise estatística, são obtidos resultados para cada uma das lojas por modelo e comparado os resultados obtidos, identificando o método boosted decision tree regression como o menos acurado entre os quatro e os outros três métodos atingindo resultados positivos a depender de variáveis externas ao modelo, como tamanho da loja, localidade. O estudo torna-se bastante completo devido às variáveis externas à demanda que são levadas em consideração quando estão sendo simulados os dados, como dia da semana, feriados e interferência climática, porém não traz o detalhamento de como foi feito o treinamento dos métodos expostos.

O estudo de Spiliotis, Makridakis & Semenoglou (2020) tem como objetivo entender a previsão de demanda diária por SKU, levando em consideração a irregularidade dessa demanda e a variabilidade atrelada a ela, trazendo maior complexidade ao modelo estudado. No estudo foram abordados 11 diferentes tipos de modelos estatísticos, além de 7 diferentes métodos de machine learning. A partir

da simulação de dados reais com base no modelo de análise, foi realizado um estudo de caso comparando os 18 métodos entre si em relação a sua precisão através da análise dos erros, além da relação entre o tempo computacional necessário para rodar cada um dos modelos. A partir das análises pode-se identificar que os métodos de Machine Learning foram capazes de trazer previsões mais precisas do que os métodos estatísticos para séries temporais contínuas e regulares, trazendo uma indefinição sobre sua superioridade quando comparado de forma geral a relação entre Machine Learning x Métodos Clássicos. O estudo é bastante completo fazendo uma análise prévia aos dados que serão analisados, guiando a decisão dos métodos utilizados para a análise, além de fazer uma série de comparações entre os erros, buscando identificar de fato o melhor método independente do indicador de erro analisado.

O estudo de Lasek, Cercone & Saunders (2016) tem como objetivo pesquisar e classificar os métodos mais famosos de previsão de demanda, o estudo tem como direcional trazer o ponto de vista da previsão de restaurantes, tendo em vista sua complexidade, devido a fatores externos como o tempo, condições climáticas, fatores econômicos, além de casos aleatórios que acontecem e outras variáveis que possam influenciar nos resultados. São analisados os métodos de regressão múltipla; regressão de Poisson; suavização exponencial e modelo de Holt-Winters; ARIMA e modelos Box-Jenkins; redes neurais; rede bayesiana; e métodos híbridos e a partir da revisão da análise de aplicabilidade de cada um deles são discutidas as suas vantagens e desvantagens.

Meneghini, Anzanello, Kahmann & Tortorella (2018) realizaram um estudo de caso em um restaurante fast food. Na abordagem, é categorizada a importância de uma previsão de demanda combinada, levando em consideração análises quantitativas, realizadas com base no modelo matemático proposto no estudo, além de análise qualitativa com base na opinião de especialistas. Foi identificado que o erro das previsões diminuíram bastante quando realizada no formato combinado, tendo em vista os fatores externos a que o contexto de restaurantes está submetido.

Schmidt, Ul Kabir & Hoque (2022) realizaram um estudo de caso sobre modelos de previsão de demanda implementando aprendizado de máquina, utilizando dados reais de um restaurante. Foram utilizados três conjuntos diferentes de dados e mais de 20 modelos diferentes durante o teste, comparando os resultados entre os modelos, puderam perceber que a maioria dos modelos acabam trazendo bons resultados a curto prazo, porém existe um grande gap em relação às

previsões de mais longo prazo. Foi observado que contextos qualitativos, externos ao modelo matemático, influenciam nesse resultado e encontraram o modelo de rede neural recorrente apresentou melhores resultados a longo prazo apesar dessas dificuldades.

No estudo de Çetinkaya & Erdal (2020), foi analisada a demanda de uma cafeteria, no estudo foi utilizado apenas o modelo quantitativo de rede neural devido à revisão da literatura prévia realizada pelos autores e identificado o método como de bastante sucesso e também a grande quantidade de estudos realizados por outros autores relacionados ao método. A partir das previsões realizadas foi encontrado no modelo uma exatidão muito alta, a partir da análise do MAPE e do RMSE e determinada não só a demanda da cafeteria como um todo, como também a demanda por SKU presente na cafeteria.

Com base nos estudos realizados por Spiliotis, Makridakis & Semenoglou (2020) e Hess, Spinler & Winkerbach (2021), foi visto que não há uma superioridade diretamente ligada aos métodos de Machine Learning, quando se comparado com métodos clássicos de previsão de demanda. Atualmente a empresa do estudo de caso está em fase de desenvolvimento interno de um método próprio de Machine Learning, utilizando variáveis específicas do setor de delivery de alimentos para adequar a forma que o método de Machine Learning será treinada para o setor em específico que a empresa está inserida. Essa adequação ao setor é de suma importância como visto por Crivellari, Beinát, Caetano, Seydoux & Cardoso (2022), Haberleitne, Meyr & Taudes (2010) e Tanizaki, Hoshino, Shimmura & Takenaka (2019). Diante disso, este estudo de caso será focado na comparação entre métodos estatísticos clássicos de previsão de demanda. Além disso, com base na formulação de Hess, Spinler & Winkerbach (2021), esse estudo utilizará do método MASE para avaliação dos erros atrelados aos modelos propostos, devido a aplicabilidade do indicador de erro para realização de avaliações entre a qualidade de previsões entre modelos em comparação com o modelo base de referência.

Foi visto na literatura que muitos trabalhos utilizam de regressões para aplicação das previsões, como pode ser observado na Tabela 1, trazendo o contexto de aplicação e método utilizado nos estudos. Entretanto, para o presente trabalho, os métodos de regressão não serão utilizados, tendo em vista que o princípio das regressões levam como base a demanda sendo explicadas por variáveis diferentes. Este trabalho terá a abordagem de séries temporais, com a utilização de métodos clássicos de previsão de Holt, Holt-Winters, ARIMA e SARIMA, utilizados como base

por outros estudos e

Tabela 1: Resumo da revisão da literatura, autoria própria

Referência	Contexto de aplicação	Métodos Utilizados
Hess, Spinler & Winkerbach (2021)	Estudo aplicado ao setor de plataformas de delivery de alimentos	Método ingênuo (naive); Método trivial; Croston (1972); Holt; Holt-Winters; Média Móvel Simples (SMA); Método theta; Suavização Exponencial Simples; ETS; Arima; Decomposição de tendência sazonal; Regressão de vetor de suporte (SVR); loess; Aprendizagem supervisionada; Validação cruzada; Regressão de floresta aleatória.
Crivellari, Beinat, Caetano, Seydoux & Cardoso (2022)	Estudo aplicado ao setor de plataformas de delivery de alimentos	Redes Neurais (Regressor CNN-LSTM multi-alvo); ARIMA; FBProphet; Estimativas históricas.
Haberleitne, Meyr & Taudes (2010)	Aplicação em uma cadeia de suprimentos no ramo da indústria	Algoritmo aditivo; Combinação entre métodos convencionais.
Tanizaki, Hoshino, Shimmura & Takenaka (2019)	Aplicação em cinco restaurantes	Regressão Linear Bayesiana; Boosted decision tree regression; Regressão da árvore de decisão; Método stepwise.
Spiliotis, Makridakis & Semenoglou (2020)	Aplicação para SKUs diários de uma empresa de ramo não explicitado no estudo	Método ingênuo (naive); Método ingênuo sazonal; Suavização exponencial simples; Médias móveis; Método Croston; Aproximação de Syntetos-Boylan; Aproximação de Shale-Boylan-Johnston; Método de Teunter-Syntetos-Babai; Abordagem de Demanda Intermitente Agregada-Desagregada; Algoritmo de previsão de agregação múltipla intermitente; Multi-Layer Perceptron (MLP); Rede Neural Bayesiana; Floresta aleatória; Árvores de aumento de gradiente; K-regressão do vizinho mais próximo; Regressão do vetor de suporte (SVR); Processo Gaussiano.
Lasek, Cercone & Saunders (2016)	Aplicação em um restaurante	regressão múltipla; regressão de Poisson; suavização exponencial e modelo de Holt-Winters; ARIMA e modelos Box-Jenkins; redes neurais; rede bayesiana; e métodos híbridos
Meneghini, Anzanello, Kahmann & Tortorella (2018)	Aplicação em restaurante fast-food	Suavização exponencial simples; Holt; Holt-Winters; Métodos qualitativos.

Schmidt, UI Kabir & Hoque (2022)	Aplicação em um restaurante	Regressão linear; Regressão SGD; Regressão Ridge; Regressão Lasso; Regressão rede elástica; Regressão Bayesiana; Regressão de Kernel; Regressão árvore de decisão; Regressão do vetor de suporte (SVR); Nu SVR; Linear SVR; K-regressão do vizinho mais próximos; Regressão Gaussiana; Regressão empilhamentos; Regressão de votação; Regressão de árvores extras; Regressão XGB; Regressão LGBM; Rede neural recorrente; Perceptron de várias camadas; Memória de longo-curto prazo; Unidade recorrente fechada; Transformador de fusão emporal; Regressão multi-saída.
Çetinkaya & Erdal (2020)	Aplicação em um restaurante	Rede neural artificial

Fonte: O autor (2023).

3 ESTUDO DE CASO

3.1 DESCRIÇÃO DO PROBLEMA

A empresa em questão é uma organização que atua no ramo de entrega de alimentos pela internet, por meio de um aplicativo que conecta seus três principais stakeholders: o restaurante, responsável por disponibilizar seu cardápio de forma virtual e preparar os alimentos para seus clientes, os consumidores, que têm acesso a diversos restaurantes e podem realizar seus pedidos, acompanhar o período de entrega e receber a encomenda em sua residência, e os entregadores parceiros ao aplicativo, que são acionados mediante a demanda e encarregados de buscar o pedido na origem e entregá-lo no destino final. A empresa, por sua vez, é responsável por gerenciar toda a logística envolvida entre esses stakeholders.

No ambiente em que a empresa atua, há expectativas distintas entre as partes envolvidas. Os restaurantes, por exemplo, esperam ter uma maior receita possível, enquanto os consumidores buscam receber seus pedidos de forma rápida e com qualidade. Por sua vez, os entregadores desejam realizar o máximo de entregas e receber uma remuneração justa por isso. Ademais, a empresa tem a expectativa de satisfazer todos os stakeholders envolvidos e maximizar sua receita por meio dos valores pagos pelo serviço prestado.

Frequentemente, essas expectativas são confrontadas com situações de ganha-perde, nas quais a satisfação de um dos stakeholders implica em perdas para outros. Em momentos em que a operação está mais crítica, geralmente em virtude de eventos externos, como mudanças climáticas, feriados ou manifestações, todos os stakeholders podem ser afetados e a relação passa a ser de perda-perda. Fazendo-se necessária, portanto, uma gestão cuidadosa de sua logística e da previsão de demanda, tendo em vista que um bom planejamento é capaz de garantir que a operação comporte a demanda e exista uma relação ganha-ganha entre os stakeholders envolvidos, atingindo o sucesso em sua atuação.

3.2 MÉTODO DE PREVISÃO DA EMPRESA

O método de previsão de demanda da empresa é um dos seus destaques competitivos e uma estratégia confidencial da organização, sendo desenvolvido por um time interno, levando em conta o cenário em específico em que está inserida. O método utiliza uma combinação de metodologias para simulação da previsão,

analisando o histórico da série temporal, com o acompanhamento dos resultados planejados e desvio padrão da realidade nesses períodos, combinado com análise qualitativa, utilizando o time responsável pelas vendas e também a diretoria da organização com o pensamento de crescimento para o próximo mês, a partir da combinação dos resultados é obtida a previsão de demanda para o período de análise.

Além da previsão propriamente dita, o time é responsável por fazer a relação entre previsto x realizado e utiliza indicadores para acompanhar a efetividade das previsões e acompanhamento do erro atrelado ao método desenvolvido.

3.3 COLETA DE DADOS

O presente estudo utilizou o banco de dados relacionado às demandas da empresa em questão. Com o intuito de preservar a confidencialidade dos resultados da organização, foi empregado um valor multiplicador arbitrário para garantir que os valores não fossem expostos, mas mantivessem a proporção entre os dados analisados.

Os dados de previsão de demanda foram coletados apenas em relação aos pedidos realizados por restaurantes da cidade de São Paulo, não sendo consideradas outras unidades de negócio da empresa, como supermercados e farmácias, tampouco outras cidades onde a organização atua. A análise foi conduzida ao longo de 60 pontos de amostra, considerando o período de janeiro de 2018 a dezembro de 2022.

Destes 60 pontos de amostra, os dados do período de janeiro de 2018 e dezembro de 2021 foram utilizados para treinar os métodos aplicados, tendo uma base de 48 períodos de análises, sendo 4 anos completos de sazonalidade presente nas amostras. Já os dados de janeiro até dezembro de 2022 foram utilizados para fazer a análise comparativa entre os resultados obtidos com os métodos de análise e as observações reais da demanda da empresa em questão.

Para a caracterização e tratamento dos dados, foram utilizadas as ferramentas do Microsoft Office Excel, para a modelagem dos métodos de previsão de séries temporais foi utilizado o software computacional RStudio, amplamente adotado no meio acadêmico, além disso o Microsoft Office Excel serviu de apoio para modelagem dos métodos de previsões e para a modelagem da análise comparativa dos erros. Por fim, para visualização dos dados, foram utilizadas o

software Tableau e novamente a ferramenta do Microsoft Office Excel.

3.4 TRATAMENTO E CARACTERIZAÇÃO DOS DADOS

Com o objetivo de analisar sistematicamente a base de dados utilizada neste estudo, foi conduzida uma análise descritiva que considerou a média, mediana, desvio padrão, mínimo e máximo dos resultados anuais (Tabela 2).

A partir dos resultados, observou-se uma variação significativa nos dados ao longo dos anos, sendo que o ano de 2020 se destacou como um valor discrepante na análise, com resultados de demanda bastante afetados pela pandemia.

Isso gerou dois comportamentos distintos na base de dados, um anterior à pandemia e outro posterior, fazendo com que o ano de 2020 se tornasse um valor discrepante e provocasse uma mudança significativa nos padrões de comportamento da demanda para a organização.

Tabela 2: Análise descritiva da base de dados, autoria própria

Ano	Média de Pedidos	Mín. Pedidos	Máx. Pedidos	Mediana de Pedidos	Desvio Padrão	Coefficiente de variação
2018	54.743	10.619	124.675	47.761	29.550	0,540
2019	263.252	167.672	380.491	232.147	66.581	0,253
2020	861.560	407.913	1.163.215	967.969	265.417	0,308
2021	1.457.676	1.301.843	1.708.390	1.463.072	129.274	0,089
2022	1.526.562	1.349.009	1.675.401	1.542.771	84.756	0,056
2023	1.419.062	1.376.960	1.456.176	1.424.049	32.531	0,023

Fonte: O autor (2023).


Foi produzido um gráfico com base no histórico da demanda da empresa, a fim de analisar o comportamento da série temporal ao longo do tempo. O gráfico abaixo apresenta a evolução da demanda e permite observar, por meio de inspeção visual, a existência de uma tendência de crescimento que pode ser dividida em três períodos principais.

- O primeiro período de análise ocorreu entre 2018 e 2019, caracterizado por um aumento gradual da demanda ao longo dos meses;
- O segundo período de análise teve início em fevereiro de 2020, coincidindo com o começo da pandemia de COVID-19. Durante esse período, houve uma forte demanda pelo segmento de delivery de alimentos, resultando em um crescimento disruptivo e uma aceleração significativa no número de pedidos.

voltando a apresentar um comportamento de volta ao normal apenas após o mês de Agosto de 2020;

- O terceiro período de análise, iniciado após março de 2022, apresenta uma estagnação maior no crescimento da demanda, mas ainda assim com uma leve tendência de crescimento.

Figura 1: Série temporal de todo histórico de dados




Fonte: O autor (2023).

Buscando entender o comportamento através dos meses da demanda foi construído o gráfico da evolução da demanda através dos meses na Figura 2, a partir de uma primeira análise visual pode-se identificar um fator sazonal, trazendo um grande crescimento da demanda no mês de Março em todos anos de análise. Além disso, utilizando como base a análise acima dos três períodos anteriores expressos, existe também um padrão comportamental das curvas de crescimento entre os períodos relatados.

- Sendo o primeiro período marcado por um grande fator sazonal no segundo semestre aumentando a demanda no final do ano;
- O período de 2020, tendo um padrão outlier devido aos impactos das mudanças comportamentais da sociedade durante os primeiros meses de pandemia da COVID-19;
- No terceiro período houve uma queda no início do ano, marcado pelo maior auge de demanda no mês de Março e uma tendência à redução de demanda mês após mês até o final do ano.


Figura 2: Sazonalidade anual da série temporal



Fonte: O autor (2023).

A Figura 3 traz um recorte dos anos de 2018 e 2019, buscando uma análise mais aprofundada do comportamento da sazonalidade para os dois meses de análises. Dessa forma, é notável um padrão de aumento de pedidos no mês de Março, mais acentuado nos dois últimos anos, além de um pico de pedidos também no mês de Agosto, exceto no ano de 2022, além de um padrão de crescimento da demanda nos últimos meses do ano, seguido de uma queda sempre no mês de Dezembro.


Figura 3: Sazonalidade anual da série temporal para 2018 e 2019



Fonte: O autor (2023).

Por fim, buscando entender a necessidade ou não da agregação da curva de demanda entre os períodos do dia, pode-se identificar um padrão parecido de comportamento da demanda entre os turnos de madrugada, café da manhã, almoço, tarde e jantar, com séries que acompanham o perfil da demanda para todos os turnos, mostrando um crescimento equilibrado durante todos os períodos, sem necessitar de aprofundar a análise de previsão por período do dia, tendo em vista que a agregação de todos os dados garantem uma boa previsibilidade para todos os turnos expressos.

Figura 4: Desagregação da série por turno do dia



Fonte: O autor (2023).

4 RESULTADOS OBTIDOS

4.1 IMPLEMENTAÇÃO DOS MÉTODOS E MODELOS DE PREVISÃO DE DEMANDA

Para a implementação, o histórico de dados foi subdividido em duas amostras. A primeira amostra relacionada com os dados entre janeiro de 2018 e dezembro de 2021, totalizando 48 meses, foram usados para ajustar os modelos.. Já a segunda amostra, com os dados de janeiro de 2022 a dezembro de 2022, totalizando 12 meses, foi utilizada para testar os modelos e fazer uma análise comparativa com os dados reais da empresa, utilizando dos indicadores de erro para identificar os métodos que tiveram os melhores resultados obtidos.

Para a análise, foram aplicados 4 métodos clássicos de previsão de séries temporais, além do método construído pela própria empresa e implementado nos planejamentos atuais da organização. Para os métodos estatísticos clássicos de previsão de demanda foi utilizado o modelo de Holt, Holt-Winters que é uma evolução do anterior levando em consideração a sazonalidade, ARIMA e SARIMA que também é uma evolução do anterior, porém trazendo a sazonalidade para o método.

À partir do treinamento dos modelos foi obtida a tabela 3 com os valores previstos para cada um dos métodos e a comparação com os dados reais obtidos pelo histórico realizado pela empresa:


Tabela 3: Resultados obtidos por mês para os métodos de previsão

Mês	Holt	Holt Winters	ARIMA	SARIMA	Empresa	Real
janeiro/22	1.465.578	1.516.250	1.409.560	1.481.017	1.367.221	1.496.647
fevereiro/22	1.499.643	1.524.525	1.407.349	1.433.499	1.460.558	1.386.460
março/22	1.533.707	1.703.652	1.408.583	1.870.592	1.471.865	1.675.401
abril/22	1.567.772	1.600.568	1.407.894	1.807.352	1.511.507	1.557.063
maio/22	1.601.836	1.612.239	1.408.279	1.763.018	1.481.533	1.599.699
junho/22	1.635.900	1.606.416	1.408.064	1.717.671	1.452.842	1.556.753
julho/22	1.669.965	1.648.894	1.408.184	1.743.882	1.600.329	1.515.048
agosto/22	1.704.029	1.686.889	1.408.117	1.806.989	1.479.479	1.349.009
setembro/22	1.738.094	1.666.070	1.408.154	1.745.331	1.436.967	1.528.790
outubro/22	1.772.158	1.722.319	1.408.134	1.784.406	1.471.845	1.574.060
novembro/22	1.806.222	1.755.260	1.408.145	1.796.500	1.453.525	1.572.002
dezembro/22	1.840.287	1.764.217	1.408.139	1.738.346	1.417.367	1.507.813

Fonte: O autor (2023).

Os métodos foram plotados em um gráfico comparativo, buscando identificar inicialmente de forma visual, comparando com a linha roxa relacionada com a observação real da demanda no período de análise, destacando, principalmente o mês de Agosto que os métodos sazonais apontaram um crescimento da demanda, porém na realidade a empresa apresentou uma queda acentuada de pedidos, sendo um comportamento outlier da série temporal que influenciou de forma negativa os resultados obtidos pelos métodos que utilizam da sazonalidade para seu desenvolvimento.

Figura 5: Comparativo entre os métodos de análise



Fonte: O autor (2023).

O mês de Agosto provou-se um grande diferencial entre os métodos clássicos em comparação com o método desenvolvido pela empresa, tendo em vista que este último conseguiu prever o comportamento atípico de queda na demanda neste mês para o ano de 2022, comportamento diferente do apresentado em todos anos anteriores e estimados para cima nos métodos clássicos de previsão, devido a serem métodos exclusivamente quantitativos e apresentarem uma tendência de crescimento e uma sazonalidade de aumento de pedidos para o mês. Já o método da empresa, pelo seu caráter de combinação entre métodos qualitativos e quantitativos, consegue prever esse comportamento anormal.

4.2 ANÁLISE DOS RESULTADOS OBTIDOS

A partir do desempenho individual de cada um dos modelos de previsão foi realizado o estudo do erro atrelado ao valor previsto pelo modelo em comparação com o valor real observado para o mês de análise, foram utilizados os métodos de raiz do erro médio quadrático (RMSE), erro absoluto médio (MAE), erro percentual absoluto médio (MAPE) e erro escala absoluto médio (MASE) para identificar qual o método teve um melhor desempenho na realização das previsões para o ano de 2022. A tabela 4 apresenta o desempenho dos métodos para cada uma das análises de erro que foram aplicadas.

Tabela 4: Comparativo entre os erros por modelo

	Holt	Holt Winters	ARIMA	SARIMA	Empresa
RMSE	191.207	157.319	145.487	225.935	113.980
MAE	155.164	124.046	131.678	200.093	107.784
MAPE	10,36%	8,39%	8,44%	13,24%	7,04%
MASE	1,88E+12	1,50E+12	1,60E+12	2,43E+12	1,31E+12

Fonte: O autor (2023).

Com base na análise dos erros, pode-se perceber que o modelo de previsão apresentou um melhor desempenho, quando comparado com os outros métodos aplicados, destacando principalmente pelo maior amortecimento no mês de Agosto que foi um destaque negativo para os outros modelos, destaque esse atribuído principalmente pelo caráter também qualitativo do método, tendo em vista que nos últimos 4 anos o mês de Agosto apresentou um destaque positivo, porém em 2022 apresentou uma queda acentuada, queda essa também observada no modelo de previsão da empresa.

Apesar dos resultados obtidos pelo método atual da empresa, os modelos de ARIMA e Holt-Winters foram os que tiveram melhor desempenho entre os modelos estatísticos de previsão, com destaque para o segundo, que foi melhor em 3 dos 4 indicadores de erro.

Foi realizada uma segunda análise excluindo o mês de Agosto, outlier identificado nos padrões, os resultados são expressos na tabela 5. É possível constatar que tanto o método de Holt-Winters quanto o método da empresa demonstraram os melhores desempenhos. Cada um desses métodos se destacou em duas das medidas de erro utilizadas. Além disso, o modelo de suavização obteve o melhor resultado na medida MASE, que é a principal medida utilizada para fundamentar o estudo. Esses achados evidenciam o potencial aplicado a esse modelo, seja por meio de sua utilização direta ou combinada com algum modelo qualitativo. Tal abordagem visa identificar de maneira mais precisa possíveis resultados atípicos que não seriam prontamente identificados apenas pelo método estatístico.

Tabela 5: Comparativo entre os erros, desconsiderando outliers

	Holt	Holt Winters	ARIMA	SARIMA	Empresa
RMSE	161.422	123.433	144.482	183.215	107.577
MAE	125.579	95.890	126.752	161.928	96.911
MAPE	8,17%	6,30%	8,07%	10,41%	6,23%
MASE	1,04E+12	7,98E+11	1,05E+12	1,35E+12	8,06E+11

Fonte: O autor (2023).

5 CONCLUSÃO

5.1 CONSIDERAÇÕES FINAIS

Durante o desenvolvimento deste trabalho, os métodos estatísticos clássicos de previsão de demanda apresentaram um resultados satisfatório, entretanto não obtiveram resultados melhores que o método atual implementado pela empresa, tivemos destaque para os métodos de suavização exponencial. Além disso, foi observada a importância da escolha do método de análise do erro implementado no estudo, tendo em vista que para uma mesma previsão os indicadores de erro podem apresentar diferentes resultados, podendo influenciar na análise realizada pela empresa e nos resultados obtidos, fazendo-se necessário o estudo por trás do método escolhido, ou utilização de mais de um indicador de análise de desempenho para análises comparativas e implementação da escolha do método de previsão que será utilizado pela organização.

Além disso, é de suma importância que empresas competitivas no mercado utilizem de métodos de previsão quantitativos como base para suas análises, porém sempre levando em consideração a opinião dos gestores na tomada de decisões final em relação ao planejamento final, tendo em vista que os métodos não conseguem prever estratégias internas de crescimento e campanhas que possam ser realizadas em meses específicos, sendo necessária uma combinação entre as análises puramente quantitativas com a percepção qualitativa das pessoas que estão guiando o processo e também a estratégia desenvolvida pelo negócio para os próximos meses.

5.2 LIMITAÇÕES E SUGESTÕES PARA TRABALHOS FUTUROS

No estudo presente foi observado o histórico recente dos resultados da organização, com o impacto de um fator externo da pandemia do COVID-19 que influenciou de forma significativa nesse histórico obtido, fazendo com que a série temporal tivesse mudanças comportamentais expressivas durante a análise, além disso, a empresa é muito recente no mercado e traz consigo um histórico pequeno de dados armazenados, fazendo com que o desempenho dos modelos aplicados não necessariamente tenham sido os melhores possíveis. Para estudos futuros com um maior período de análise os métodos podem ser treinados novamente a apresentarem melhores desempenhos de análise.

Como sugestão para trabalhos futuros, a empresa pode implementar os

métodos clássicos de previsão em períodos diferentes temporais e de agregação, como na visão dia a dia, levando como base a sazonalidade por dia da semana da demanda e também os padrões comportamentais dentro do próprio mês de análise, além da expansão do estudo para a demanda de forma regionalizada ou de toda a demanda do Brasil, não apenas da cidade de São Paulo que foi o enfoque do estudo. Além da possibilidade de expansão para os outros negócios para além dos pedidos realizados por restaurantes, podendo haver a expansão para análise de outras unidades de negócio da empresa como supermercados e farmácias.

Além disso, a utilização de um estudo combinado entre o método de Holt-Winters e o método desenvolvido pela empresa podem ser uma aposta, tendo em vista a assertividade atrelada ao método de suavização, combinado com a maior adequação à sazonalidade atrelado ao modelo desenvolvido pela empresa.

Por fim, outras abordagens de previsão também podem ser testadas, como por exemplo a utilização de machine learning para simulação dos dados que vêm apresentando resultados promissores em pesquisas recentes.

REFERÊNCIAS

CRIVELLARI, A., BEINAT, E., CAETANO, S., SEYDOUX, A., CARDOSO, T. Multi-target CNN-LSTM regressor for predicting urban distribution of short-term food delivery demand. **Journal of Business Research** 144 (2022) 844–853

CORRÊA, H. L., CORRÊA, C. A. **Administração de produção e operações**. 2ªed. São Paulo: Atlas, 2007.

ÇETINKAYA, Z., ERDAL, E. Daily Food Demand Forecast with Artificial Neural Networks: Kırıkkale. **Conference Paper** · September 2019

GIL, A. C. Métodos e técnicas da pesquisa social. 6ªed. São Paulo: Atlas, 2008.
HABERLEITNER, H., MEYR, H., TAUDES, A. Implementation of a demand planning system using advance order information. **Int. J. Production Economics** 128 (2010) 518–526, 2010.

HESS, A., SPINLER, S. WINKENBACH, M. Real-time demand forecasting for an urban delivery platform. **Transportation Research Part E** 145 (2021) 102147

Holt, C. C. (1957). Forecasting seasonals and trends by exponentially weighted averages (ONR Memorandum No. 52). Carnegie Institute of Technology, Pittsburgh USA. Reprinted in the International Journal of Forecasting, 2004.

HYNDMAN R. J.; ATHANASOPOULOS G. Forecasting principles and practice. OTexts, 2013.

HYNDMAN & KOEHLER, 2005. "Another Look at Measures of Forecast Accuracy," Monash Econometrics and Business Statistics Working Papers 13/05, Monash University, Department of Econometrics and Business Statistics.

LASEK, A., CERCONE, N., SAUNDERS, J. Restaurant Sales and Customer Demand Forecasting: Literature Survey and Categorization of Methods. **ICST Institute for Computer Sciences, Social Informatics and Telecommunications Engineering**, 2016.

MAKRIDAKIS, S.; HIBON, M. The M3-Competition: results, conclusions and implications. **International Journal of Forecasting**, v. 16, p. 451–476, 2000.

MASSA, R. O "Boom" das plataformas de Delivery no Brasil e suas consequências peculiares, FGV 2022. Disponível em: <<https://portal.fgv.br/artigos/boom-plataformas-delivery-brasil-e-suas-consequencias-peculiares>>. Acessado em: 01 Abr. 2023.

MENEGHINI, M., ANZANELLO, M., KAHMANN, A., TORTORELLA, G. L. Quantitative Demanda Forecasting Adjustment Based on Qualitative Factors: Case Study at a Fast Food Restaurant. **Systems & Management** 13 (2018), pp 68-80.

MOREIRA, D, A. **Administração da Produção e Operações**. 2ªed. São Paulo: Cengage Learning BR, 2008.

SLACK, N; CHAMBERS, S; JOHNSTON, R. **Administração da Produção**. São Paulo: Atlas, 2002.

SCHIMIDT, A., KABIR, M. W. U., HOQUE, M. T. Machine Learning Based Restaurant Sales Forecasting. **Mach. Learn. Knowl. Extr.** 2022, 4, 105–130.

SPILITIOTIS, E., MAKRIDAKIS, S., SEMENOGLOU, A. A., ASSIMAKOPOULOS, V. Comparison of statistical and machine learning methods for daily SKU demand forecasting. **Springer-Verlag GmbH Germany**, part of Springer Nature 2020.

TANIZAKI, T., HOSHINO, T., SHIMMURA, T., TAKENAKA, T. Demand forecasting in restaurants using machine learning and statistical analysis. **12th CIRP Conference on Intelligent Computation in Manufacturing Engineering**, 18-20 July 2018, Gulf of Naples, Italy