Thiago Gabriel Milbradt

MODELOS DE PREVISÃO DE DEMANDA PARA SUPORTE À TOMADA DE DECISÃO EM GESTÃO DE ESTOQUES

Horizontina-RS

2024

Thiago Gabriel Milbradt

MODELOS DE PREVISÃO DE DEMANDA PARA SUPORTE À TOMADA DE DECISÃO EM GESTÃO DE ESTOQUES

Projeto do Trabalho Final de Curso apresentado como requisito parcial para a o Trabalho Final de Curso na Engenharia de Produção da Faculdade Horizontina, sob a orientação da Prof. Me. Ivete Ruppenthal Ebrin

Horizontina-RS

2024

FAHOR - FACULDADE HORIZONTINA

CURSO DE ENGENHARIA DE PRODUÇÃO

A Comissão Examinadora, abaixo assinada, aprova o trabalho final de curso

“Modelos de previsão de demanda para suporte à tomada de decisão em gestão de estoques”

Elaborada por:

Thiago Gabriel Milbradt

Como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Produção

Aprovado em: 02 de dezembro de 2024

Pela Comissão Examinadora

_____

Me. Ivete Ruppenthal Ebrin

Presidente da Comissão Examinadora - Orientador

_____

Me. Eliane Garlet

FAHOR – Faculdade Horizontina

_____

Me. Fabrício Desbessel

FAHOR – Faculdade Horizontina

Horizontina - RS

2024

RESUMO

Este trabalho tem como objetivo analisar e comparar métodos tradicionais e avançados de previsão de demanda para suporte à gestão de estoques, utilizando uma abordagem quantitativa que explora técnicas como médias móveis, suavização exponencial e modelos estatísticos avançados, além de algoritmos de aprendizado de máquina como ARIMA, redes neurais artificiais, florestas aleatórias e *Gradient Boosting Machines* (GBM), com os dados sendo processados em *Python* no ambiente Visual Studio Code. A metodologia adotada combina análise estatística e modelagem preditiva com aprendizado de máquina. Os dados foram coletados de um banco público chamado *Kaggle*, abrangendo demandas históricas de produtos em formato estruturado, o que permitiu a limpeza, análise de séries temporais e modelagem preditiva. O objetivo geral do trabalho é aprimorar a precisão da previsão de demanda para reduzir custos operacionais e melhorar a eficiência da gestão de estoques, enquanto os objetivos específicos incluem comparar a eficácia de métodos tradicionais e técnicas avançadas, identificar padrões e sazonalidades em séries temporais e propor modelos preditivos de alto desempenho e aplicabilidade prática. Os resultados indicaram que os métodos tradicionais são úteis em cenários de baixa variabilidade, mas apresentam limitações em situações complexas, enquanto os modelos avançados, como redes neurais e GBM, demonstraram melhor desempenho na captura de padrões não lineares e sazonalidades, com destaque para a redução do erro médio quadrático. As conclusões reforçam que a aplicação de técnicas avançadas de previsão é uma oportunidade estratégica para a gestão de estoques, pois contribui para a redução de custos, maior eficiência operacional e melhor atendimento ao cliente, além de propor diretrizes práticas que podem ser aplicadas em cenários reais, demonstrando a importância da inovação tecnológica na engenharia de produção e no aprimoramento da competitividade industrial.

Palavras-chave: Previsão de demanda. Gestão de estoques. Aprendizado de máquina.

LISTA DE FIGURAS

Figura 1 - Relacionamento entre a função produção e outras funções centrais e de apoio da organização 14
Figura 2 - Fatores que influenciam séries históricas 16
Figura 3 - Variações irregulares 16
Figura 4 - Equação de regressão 19
Figura 5 - Rede neural 20
Figura 6 - Exemplo de árvore de decisão 21
Figura 7 - Fluxograma das etapas realizadas 34
Figura 8 - Demanda de Pedidos e Média móvel simples 36
Figura 9 - Demanda de pedidos e suavização exponencial simples 37
Figura 10 - Aplicação do ARIMA 39
Figura 11 - Demanda de pedidos e regressão linear 41
Figura 12 - Demanda de pedidos e analise de sazonalidade e ciclos 42
Figura 13 - Demanda de pedidos e redes neurais artificiais 44
Figura 14 - Demanda de pedidos e floresta aleatória 45
Figura 15 - Demanda de pedidos e *gradiente boosting machines* 47
Figura 16 - Comparativo dos Resultados dos Modelos de Previsão de Demanda 48

SUMÁRIO

INTRODUÇÃO 8
1.1 TEMA 9
1.2 DELIMITAÇÃO DO TEMA 9
1.3 PROBLEMA DE PESQUISA 9
1.4 HIPÓTESES 11
1.5 JUSTIFICATIVA 11
1.6 OBJETIVOS 12
1.6.1 Objetivo geral 12
1.6.2 Objetivos específicos 12
2 REFERENCIAL TEÓRICO 13
2.1 ADMINISTRAÇÃO DA PRODUÇÃO 13
2.1.1 Importância da Administração da Produção 13
2.2 CONCEITOS FUNDAMENTAIS DA PREVISÃO DE DEMANDA 14
2.2.1 Importância da previsão para a gestão de estoques 15
2.2.2 Demanda sazonal, cíclica e variações irregulares 15
2.3 MÉTODOS TRADICIONAIS DE PREVISÃO DE DEMANDA 17
2.3.1 Médias móveis 17
2.3.2 Suavização exponencial 18
2.4 MACHINE LEARNING 18
2.4.1 Algoritmos de regressão 18
2.4.2 Redes neurais 19
2.4.3 Árvores de decisão 20
2.5 ANÁLISE DE SÉRIES TEMPORAIS 22
2.5.1 ARIMA (*Autoregressive Integrated Moving Average*) 22
2.5.2 Modelos Sazonais 23
2.5.3 *Gradient Boosting Machines* (GBM) 24
2.6 ESTRATÉGIAS DE IMPLEMENTAÇÃO 24
2.6.1 Processo de implementação 25
2.7 *VISUAL STUDIO CODE* (VS CODE) E BIBLIOTECAS UTILIZADAS 26
2.7.1 *Pandas*: Manipulação e Análise de Dados 26

2.7.2 *NumPy*: Cálculo Numérico Avançado 26
***2.7.3 Matplotlib: Visualização de Dados* 27**
***2.7.4 Scikit-learn: Aprendizado de Máquina* 27**
***2.7.5 Statsmodels: Modelagem Estatística* 27**
3 METODOLOGIA 29
3.1 MÉTODOS DE ABORDAGEM 29
3.2 MÉTODO DE PROCEDIMENTO TÉCNICO 31
3.3 TÉCNICAS DE COLETA DE DADOS 31
3.4 TÉCNICAS DE ANÁLISE DE DADOS 32
3.5 MATERIAIS E EQUIPAMENTOS 33
3.6 ETAPAS DA PESQUISA 33
4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS 35
4.1 MÉDIA MÓVEL SIMPLES 35
4.2 SUAVIZAÇÃO EXPONENCIAL 36
4.3 ARIMA 38
4.4 REGRESSÃO LINEAR 40
4.5 ANÁLISE DE SAZONALIDADE E CICLOS 42
4.6 REDES NEURAIS ARTIFICIAIS 43
4.7 FLORESTA ALEATÓRIA 45
4.8 GRADIENT BOOSTING MACHINES 46
4.9 ANÁLISE COMPARATIVA 47
4.10 RECOMENDAÇÕES 49
CONCLUSÃO 53
REFERÊNCIAS 56
APENDICE A – Código ARIMA 59
APENDICE B - Código Média Móvel Simples 60
APENDICE C – Código Suavização Exponencial Simples 61
APENDICE D – Código Regressão Linear 62
APENDICE E – Código SARIMA 63
APENDICE F – Código Redes Neurais Artificiais 65
APENDICE G – Código Floresta Aleatória 67
APENDICE H – Código *Gradient Boosting Machines* 68
APENDICE I – Dados utilizados nas previsões 69

INTRODUÇÃO

A engenharia de produção há tempos dedica esforços para que as organizações se tornem mais eficientes. Para manter a competitividade, as empresas estão se adequando à grande demanda através da implantação de tecnologias modernas em seus processos. Nesse sentido, elas buscam integrar técnicas já consolidadas e inovadoras com vistas ao gerenciamento das atividades de programação e controle da produção, garantindo níveis de qualidade altos e assegurando a continuidade da empresa através de uma boa gestão financeira (Martelli; Dandaro, 2015).

Neste contexto, técnicas de previsão de demanda se tornam importantes, visto que, sem o prognóstico assertivo da demanda do mercado consumidor, as empresas enfrentam dificuldades ao comprar matérias-primas, suprimentos, fazer negociações, e até mesmo relacionado a capacidade fabril e número de colaboradores. Consul e Werner (2010) explicam a importância da previsão de demanda pelo fato de se ficar evidente o “que”, “quanto” e “quando” comprar. Os autores ainda expressam que os benefícios dessa previsão afetam a velocidade de entrega e o custo do produto.

Pellegrini e Fogliatto (2001) argumentam que as técnicas de previsão possibilitam a realização de modelagem matemática por meio dos dados disponíveis, o que permite fazer prognósticos mais precisos em relação às previsões feitas com base na intuição. Enquanto Werner, Lemos e Daudt (2006) sugerem que previsões ruins podem de alguma forma causar problemas para a empresa, seja pela incapacidade de atender a demanda do mercado - uma previsão subdimensionada, seja por apresentar sobra de produto acabado, gerando estoque não planejado - uma previsão superdimensionada.

Ao se tratar de gestão de estoques, é uma atividade das que mais tem contribuído para o avanço dos processos de gestão empresarial. Compreende desde a quantidade de matéria que a empresa tem armazenado, a decisão de quando encomendar mais peças, a distribuição dessas encomendas em lotes, etc. (Ballou, 2006). E de acordo com Dias (2010), é possível definir uma quantidade ótima de estoque de cada componente, mas só é possível defini-la a partir da previsão de demanda de consumo do produto.

Dessa forma, o objetivo deste trabalho é explorar a importância da gestão de estoques e da previsão de demanda, analisar as principais técnicas e metodologias

utilizadas nessa área e propor estratégias para aprimorar a gestão de estoques em empresas de diferentes setores. O estudo contribuirá para a área da engenharia de produção, fornecendo conhecimentos e insights que poderão ser aplicados por profissionais e pesquisadores interessados em melhorar a eficiência operacional e a competitividade das empresas, por meio de uma gestão de estoques eficaz.

Além disso, a tomada de decisão é um processo fundamental em qualquer organização, e a análise da previsão de demanda desempenha um papel crucial nesse contexto, pois ao basear decisões em dados e projeções objetivas em vez de depender exclusivamente da experiência ou intuição, as empresas podem tomar medidas mais embasadas e precisas. Isso não apenas aumenta a eficiência operacional, mas também ajuda a minimizar riscos e otimizar recursos, permitindo que as organizações atinjam seus objetivos de maneira mais eficaz e eficiente.

1.1 TEMA

Modelos de previsão de demanda para suporte à tomada de decisão em gestão de estoques.

1.2 DELIMITAÇÃO DO TEMA

Modelos de previsão de demanda para suporte à tomada de decisão em gestão de estoques por meio de revisão bibliográfica e uma análise aprofundada da importância da previsão de demanda e sua interligação com a gestão de estoques, explorando as principais técnicas e metodologias utilizadas para a previsão de demanda, propondo estratégias eficazes para otimizar a gestão de estoques.

1.3 PROBLEMA DE PESQUISA

As empresas enfrentam inúmeros desafios diários relacionados à gestão de estoques, que podem afetar diretamente sua eficiência, competitividade e lucratividade. Entre os problemas mais recorrentes estão a dificuldade em prever com precisão a demanda futura, o que leva frequentemente a situações de excesso de estoque ou escassez de produtos. O excesso de estoque resulta em custos elevados de armazenamento, obsolescência de produtos e imobilização de capital, enquanto a falta de estoque compromete o atendimento ao cliente, prejudica a reputação da empresa e pode levar à perda de oportunidades de mercado.

Outro desafio significativo é lidar com a sazonalidade e as variações irregulares na demanda. Eventos sazonais, como feriados ou datas comemorativas, e fatores externos, como mudanças econômicas ou alterações climáticas, tornam o planejamento de estoques ainda mais complexo. Além disso, em mercados cada vez mais dinâmicos e competitivos, as preferências dos consumidores mudam rapidamente, dificultando a adaptação das empresas e a previsão de suas necessidades.

Empresas que dependem exclusivamente de métodos tradicionais, como médias móveis ou suavização exponencial, enfrentam limitações na capacidade de capturar padrões complexos e mudanças abruptas na demanda. Esses métodos não conseguem identificar relações não lineares ou compreender plenamente fatores externos que influenciam o consumo, como campanhas de marketing ou comportamento sazonal específico.

A pressão por redução de custos e aumento da eficiência também coloca a gestão de estoques em uma posição estratégica. Decisões baseadas em dados imprecisos ou na intuição podem gerar desperdício de recursos e atrasos operacionais, impactando negativamente a cadeia de suprimentos como um todo. Além disso, a implementação inadequada de estratégias de previsão pode limitar a capacidade da empresa de antecipar tendências de mercado, deixando-a vulnerável a mudanças inesperadas.

Neste contexto, o uso de técnicas avançadas de previsão de demanda baseadas em aprendizado de máquina e análise de séries temporais tem se mostrado uma solução promissora. Essas técnicas, como ARIMA, redes neurais artificiais, florestas aleatórias e *Gradient Boosting Machines*, são capazes de identificar padrões sazonais, ciclos e tendências com maior precisão, além de incorporar variáveis externas que impactam o comportamento do consumidor. A aplicação dessas ferramentas pode contribuir significativamente para reduzir os custos de estoques, melhorar o atendimento ao cliente e aumentar a competitividade empresarial.

Dessa forma, a pergunta que orienta este estudo é: Como a gestão de estoque pode ser melhorada aplicando técnicas avançadas de previsão de demanda na indústria?

1.4 HIPÓTESES

- Hipótese A: A aplicação de técnicas avançadas de previsão de demanda, como modelos estatísticos, algoritmos de aprendizado de máquina e análise de séries temporais, resultará em benefícios significativos para a gestão de estoques na indústria.
- Hipótese B: Os modelos de aprendizado de máquina demonstrarão valores mais assertivos na previsão de demanda em comparação aos modelos tradicionais da estatística.
- Hipótese C: A análise de séries temporais permitirá identificar padrões sazonais e tendências de demanda de forma mais eficaz, contribuindo na gestão de estoque.

1.5 JUSTIFICATIVA

A gestão eficiente de estoques é essencial para empresas de manufatura, pois afeta diretamente a eficiência operacional, os custos e a capacidade de atendimento ao cliente. Conforme Chopra e Meindl (2016), o gerenciamento de estoque bem-sucedido pode levar a melhorias significativas na eficiência e lucratividade do negócio.

No entanto, a precisão da previsão de demanda é um desafio na indústria devido à complexidade dos processos de produção e às flutuações da demanda. Nesse sentido, Silver, Pyke e Peterson (1998) afirmam que o uso de técnicas avançadas de previsão de demanda pode melhorar significativamente a precisão das previsões, levando a um gerenciamento de estoque mais eficiente e a custos operacionais reduzidos.

Conforme destacado por Mentzer et al. (2001), a aplicação de métodos avançados de previsão de demanda pode resultar em uma alocação mais eficaz dos recursos de estoque, promovendo a diminuição de despesas operacionais e aprimorando significativamente o nível de atendimento ao cliente. Essa abordagem desempenha um papel crucial na busca pela competitividade das empresas de manufatura, permitindo que elas se destaquem no mercado ao garantir um equilíbrio sólido entre oferta e demanda.

Nesse contexto, a justificativa deste estudo consiste na necessidade de investigar e propor a aplicação de técnicas avançadas de previsão de demanda na indústria de transformação para melhorar a gestão de estoques, reduzir custos

operacionais e melhorar a capacidade de atendimento ao cliente. Isso contribuirá para o desenvolvimento do conhecimento na área de engenharia de produção e fornecerá insights práticos para profissionais e gestores interessados em aprimorar a gestão de estoques em suas empresas.

1.6 OBJETIVOS

1.6.1 Objetivo geral

O objetivo geral deste estudo é analisar técnicas avançadas de previsão de demanda para aprimorar a gestão de estoques, buscando maior eficiência operacional, redução de custos e minimização de riscos no gerenciamento de estoques.

1.6.2 Objetivos específicos

Os objetivos específicos que orientam o objetivo geral são:

- Analisar os desafios e as limitações da gestão de estoques na indústria;
- Comparar diferentes técnicas avançadas de previsão de demanda, como modelos estatísticos, algoritmos de aprendizado de máquina e análise de séries temporais, visando mais adequada às necessidades.
- Avaliar os benefícios da aplicação das técnicas avançadas de previsão de demanda na gestão de estoques;
- Validar as propostas por meio de estudos de caso ou simulações para comprovar a eficácia das técnicas;
- Identificar oportunidades de melhoria por meio da aplicação de técnicas avançadas de previsão de demanda;
- Apresentar recomendações práticas e conclusões relevantes que possam ser aplicadas por profissionais da indústria para otimizar a gestão de estoques.

2 REFERENCIAL TEÓRICO

Conforme ressaltado por Lakatos (2003), o uso do referencial teórico desempenha um papel fundamental ao possibilitar a avaliação do estado atual do problema de pesquisa, tanto do ponto de vista teórico quanto em relação a estudos e pesquisas anteriores. Além disso, ele oferece uma base sólida para a construção do conhecimento, fornecendo diretrizes cruciais para a condução de investigações bem embasadas e contribuindo para o avanço do entendimento sobre o tema em questão.

2.1 ADMINISTRAÇÃO DA PRODUÇÃO

Pode-se dizer que todas as atividades desenvolvidas por uma empresa para atingir objetivos de curto, médio e longo prazo estão interligadas, que muitas vezes ocorrem de maneiras extremamente complexas. Tais atividades, no esforço de transmudar insumos como matérias-primas em produtos e/ou serviços finais, sempre consomem recursos, mas nem sempre agregam valor ao produto final. A gestão eficaz dessas atividades é o objetivo da administração da produção / operação, que, no contexto deste conceito, está presente em todas as áreas de atuação dos gerentes, diretores, supervisores e/ou qualquer funcionário da empresa (Laugeni, 2015).

Ainda segundo o mesmo autor, a gestão de operações refere-se à maneira como uma organização cria e entrega seus produtos e serviços. Essa atividade envolve o gerenciamento dos recursos necessários para produzir e disponibilizar esses produtos e serviços. A função de produção é a área dentro da organização encarregada dessas atividades.

Cada organização, independentemente de seu tipo, possui uma função de produção, já que todas elas estão envolvidas na criação de produtos ou na prestação de serviços específicos. No entanto, é importante notar que nem todas as organizações usam o termo "função de produção" para descrever essa área. Os gerentes de produção são os profissionais responsáveis pela administração de parte ou de todos os recursos relacionados à função de produção (Slack; Brandon-Jones; Burgess, 2023).

2.1.1 Importância da Administração da Produção

Em alguns tipos de organização, segundo Slack (2023), é relativamente fácil visualizar a função de produção e o que ela faz. Qualquer empresa que produz algo

deve utilizar recursos para fazê-lo, portanto deve haver atividade produtiva. Portanto, por exemplo, agências de publicidade e fábricas de automóveis têm uma coisa importante em comum: ambas têm um propósito maior, que é lucrar criando e fornecendo serviços ou produtos.

No entanto, as organizações sem fins lucrativos também utilizam os seus recursos para produzir serviços, não com fins lucrativos, mas para servir a sociedade de alguma forma. Pode-se observar os seguintes exemplos sobre o que a administração da produção faz em cinco organizações bastante diferentes na Figura 01 e alguns temas comuns aparecem.

Figura 1 - Relacionamento entre a função produção e outras funções centrais e de apoio da organização

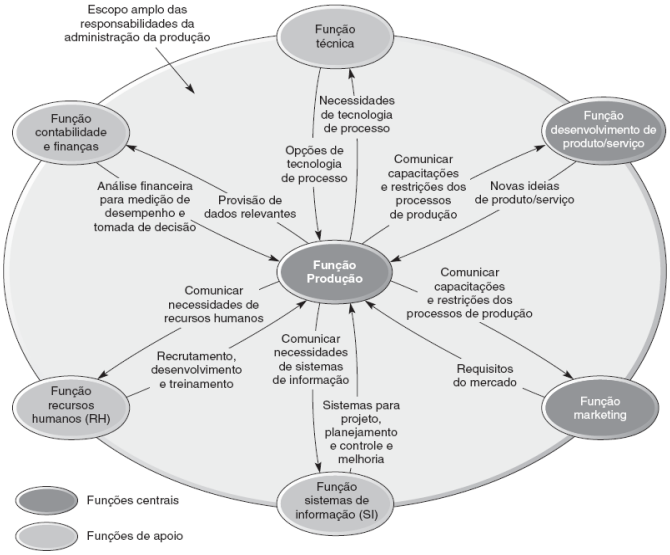

Fonte: Slack et. al, (2023, p. 08)

A Figura 01 mostra algumas relações entre a função de produção e algumas outras funções em termos de fluxo de informações entre elas. Embora não seja exaustivo, dá uma ideia da natureza de cada relacionamento. As funções de suporte têm uma relação com a produção diferente de outras funções essenciais. A responsabilidade do gerenciamento de operações nas funções de suporte é principalmente garantir que eles entendam as necessidades da produção e ajudá-los a atender a essas necessidades (Ibid, 2023, p. 07).

2.2 CONCEITOS FUNDAMENTAIS DA PREVISÃO DE DEMANDA

A previsão de demanda no planejamento e controle da produção (PCP) baseia-se no princípio de que os dados históricos influenciam direta ou parcialmente os

resultados futuros. A aplicação adequada da previsão de demanda é muito importante para as organizações porque permite aos gestores predizer a produção futura e tomar as medidas e ações necessárias para produzi-la (Consul; Werner, 2010).

As previsões de demanda de Tubino (2009) são utilizadas em duas situações no PCP: para delinear o sistema de produção e para delinear a utilização deste sistema. A previsão de demanda também é necessária para apoiar muitas atividades de gerenciamento de produção, como gerenciamento de estoque, capacitância, planejamento cumulativo e planejamento de produção (Pellegrini; Fogliatto, 2001).

2.2.1 Importância da previsão para a gestão de estoques

A previsão de demanda busca prever o estoque em um determinado período de tempo, definindo a quantidade e o momento em que determinado produto será demandado pelo cliente, para auxiliar na tomada de decisão, relacionada a quantidade de matéria prima no estoque, utilização de espaço físico, menos custos operacionais, etc. (Tubino, 2009).

Para Martins e Laugeni (2015), a escolha do melhor método a ser adotado para prever a demanda, depende de muitos fatores como a disponibilidade do histórico do item, horizonte de previsão a curto, médio e longo prazo, a precisão exigida, o orçamento disponível e o padrão dos dados existentes (horizontal, sazonal, cíclico ou tendência), além das características específicas da natureza de cada empresa.

2.2.2 Demanda sazonal, cíclica e variações irregulares

A demanda sazonal se refere às flutuações previsíveis e regulares ao longo de um período de tempo (Chase; Aquilano, 2006). Estão muitas vezes associadas a eventos como datas comemorativas, por exemplo, natal e páscoa, estações do ano ou outros padrões recorrentes que afetam o comportamento de consumo das pessoas.

A demanda cíclica é uma flutuação em forma de onda, como pode-se ver na Figura 02, centrada numa tendência e é geralmente influenciada por questões económicas. Os padrões cíclicos tendem a repetir-se a cada dois ou três anos (Andrade et al., 2016).

Figura 2 - Fatores que influenciam séries históricas

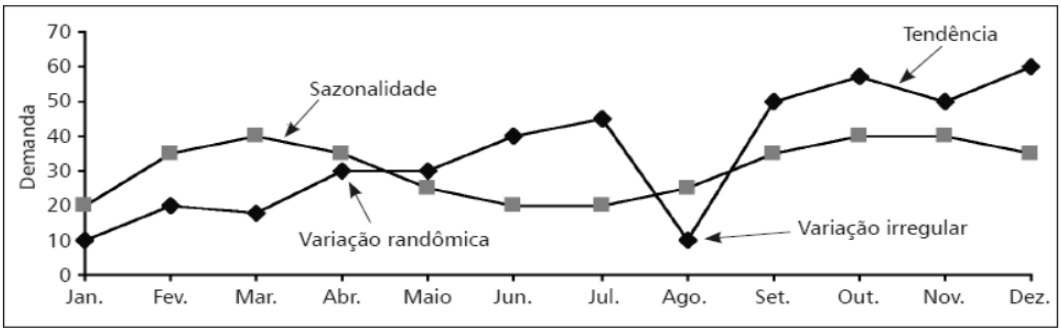

Fonte: Tubino (2009).

Conforme explica Tubino (2009) sobre a Figura 02, uma tendência é um movimento gradual e de longo prazo impulsionado por dados. As flutuações sazonais referem-se às alterações cíclicas de curto prazo ligadas a fatores temporais, por exemplo, o impacto das alterações climáticas ou das férias escolares. As flutuações irregulares, como o nome sugere, são alterações na procura passada resultantes de fatores excepcionais, como greves ou catástrofes climáticas, que não podem ser previstos e, portanto, não podem ser classificados no modelo. Esses dados, como já mencionado, devem ser retirados da série histórica e substituídos pelos valores mais prováveis. Finalmente, a remoção de tendências, sazonalidade e fatores anômalos deixa a variação aleatória ou normal, que é tratada pela média. Pode-se ver um exemplo na Figura 03.

Figura 3 - Variações irregulares

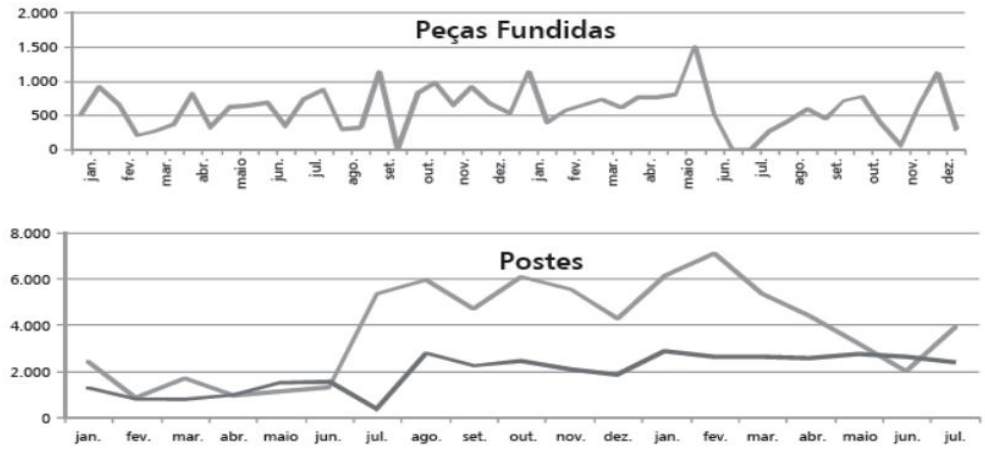

Fonte: Tubino (2009, p. 30).

> O que dizer da demanda por peças fundidas onde em setembro se atinge um patamar de 1.500 unidades e dois meses após não se vende nada? Ou em uma fábrica de artefatos de cimento na qual um de seus produtos pula do

> patamar de 1.500 para 6.000 postes em dois meses (e volta para 2.000 depois de um ano), enquanto o outro se comporta normalmente com pequeno aumento de vendas relativamente constante? (Tubino 2009, p. 31).

Dependendo dos fatores que afetam os dados, uma solicitação de previsão baseada em séries temporais pode ser dividida em diversas etapas, cada uma associada a uma dimensão de um desses fatores. O prognóstico final é resultado de uma combinação desses fatores. Existem técnicas para lidar com médias (flutuações aleatórias), tendências e sazonalidade. Uma vida como esta não é fácil para a maioria das empresas, por isso prever a procura para estes eventos imprevisíveis é mais uma habilidade desenvolvida pelos previsores do que uma habilidade específica em si (Ibid, 2009, p. 30)

2.3 MÉTODOS TRADICIONAIS DE PREVISÃO DE DEMANDA

Bonotto e Fogliatto (2015) destacam três métodos tradicionais de suavização exponencial: Suavização Exponencial Simples, Suavização Exponencial Dupla Holt e Suavização Exponencial Sazonal Holt-Winters. Esses métodos são essenciais na previsão de demanda e gerenciamento de estoque e são usados em diversas situações, dependendo das características da série temporal, como tendências, sazonalidade e padrões de demanda. Essas ferramentas auxiliam na tomada de decisões estratégicas em relação ao estoque e à cadeia de suprimentos.

2.3.1 Médias móveis

Segundo Tubino (2009), a média móvel usa dados de um número predeterminado de períodos, normalmente os mais recentes, para gerar sua previsão. A cada novo período de previsão se substitui o dado mais antigo pelo mais recente. A média móvel pode ser obtida a partir da equação 1:

$$Mm_n = \frac{\sum_{i=1}^{n} D_i}{n} \quad (1)$$

Onde:

Mmn = média móvel de n períodos;

Di = demanda ocorrida no período i;

n = número de períodos;

i = índice do período (i = 1, 2, 3, ...).

Sempre que se dispõe de um dado novo, se abandona o mais antigo e se introduz o dado mais recente na previsão. O número de períodos incluídos no cálculo da média móvel determina sua sensibilidade com relação aos dados mais recentes. Pequenos períodos permitem uma reação maior a mudanças da demanda, enquanto grandes períodos tratam a média de forma mais homogênea (Tubino 2009).

2.3.2 Suavização exponencial

Modelos de suavização exponencial são amplamente utilizados na previsão de séries temporais devido à sua simplicidade, precisão e adaptabilidade, conforme destacado por Samohyl et al. (2008). Uma de suas principais vantagens é a possibilidade de criar previsões rapidamente utilizando apenas dados das séries históricas internas da empresa, sem a necessidade de informações externas.

Estes modelos assumem que se algum evento externo afetar a procura, as suas consequências já estão incorporadas nos dados passados e, portanto, serão refletidas em valores futuros, como explica Mileski (2007). Eles analisam toda a série histórica, atribuindo pesos diferentes aos dados, sendo que pesos menores têm os dados mais antigos, conforme relatado por Samohyl et al. (2008) e Jacobs (2011). Como tal, os modelos de suavização exponencial valorizam especialmente os dados mais recentes.

2.4 MACHINE LEARNING

Segundo Nelli (apud Netto; Maciel, 2021, p. 117), o aprendizado de máquina é uma disciplina que utiliza uma variedade de procedimentos e algoritmos para identificar padrões, agrupamentos ou tendências e então obter informações úteis para análise de dados de forma totalmente automatizada. De maneira geral, são métodos matemáticos usados para treinar algoritmos que identificam padrões. A seguir apresenta-se os algoritmos de regressão, redes neurais e árvores de decisão.

2.4.1 Algoritmos de regressão

Segundo Neto e Maciel (2021), algoritmos de regressão são ferramentas fundamentais em ciência de dados e análise estatística. Eles são usados para modelar

e entender a relação entre variáveis, permitindo prever valores futuros com base em dados históricos. Cinco tipos de algoritmos de regressão são mais comumente: linear, polinomial, árvore de decisão e floresta aleatória (*Random Forest*).

Algoritmos de regressão linear são uma das abordagens mais básicas para aprendizagem supervisionada. Apesar de sua simplicidade, é muito eficaz e resolve bem problemas de baixo nível. A palavra linear sugere que a relação entre parâmetros dependentes e independentes pode ser descrita por uma linha reta ou algo muito semelhante, conforme equação mostrada na Figura 04 (Menon, 2017).

Figura 4 - Equação de regressão

$$y = ax + b \qquad a = \frac{\sum xy - n\bar{x}\bar{y}}{\sum x^2 - n(\bar{x})^2}$$

$$b = \bar{y} - a\bar{x}$$

Fonte: Menon (2017).

A imagem mostra um método para encontrar a melhor linha reta que se ajusta aos dados de duas variáveis. Ele tenta descrever como uma variável (por exemplo, preço de um produto) muda com outra variável (como a quantidade vendida). A equação da reta possui dois componentes: a inclinação, que mostra como a variável dependente muda para cada unidade da variável independente, e o intercepto, que é o valor da variável dependente quando a outra variável é zero. Usando essa técnica, é possível prever valores ou entender a relação entre as variáveis com base em observações anteriores (Menon, 2017).

2.4.2 Redes neurais

Redes Neurais Artificiais (RNAs) são técnicas de computação que dependem da estrutura neural de organismos inteligentes, como o cérebro humano, para adquirir conhecimento por meio da experiência. Neste método, são utilizadas unidades de processamento simples que formam sistemas paralelos distribuídos chamados “nós”. O objetivo desses nós é calcular funções matemáticas, geralmente não lineares. Estas unidades são organizadas em uma ou mais camadas e interligadas por um grande número de conexões, conforme descrito por Haykin (apud Ribeiro; De Oliveira, 2023).

As redes neurais tiveram desde o início motivação pelo reconhecimento de que o cérebro humano processa informações de uma forma totalmente diferente de um computador convencional. O cérebro é um computador muito complexo, nada linear e paralelo, que tem capacidade de organizar seus neurônios, realizando certos processamentos muito mais rápido do que um computador digital (Haykin, 2001).

Figura 5 - Rede neural

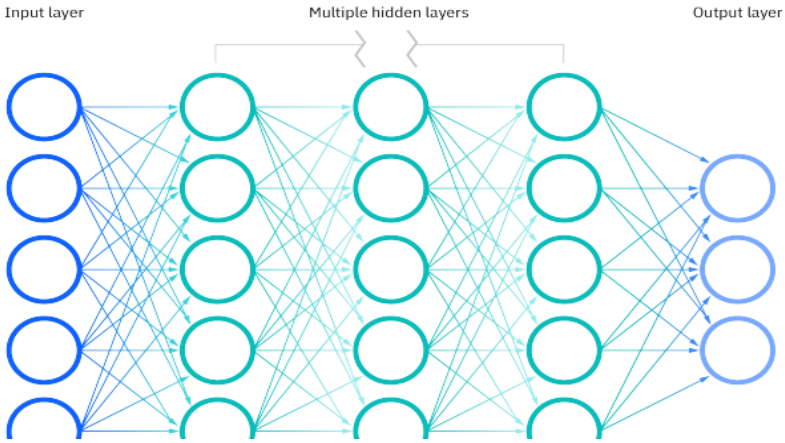

Fonte: IBM [s.d.]

Uma vez definida a camada de entrada (*input*), os pesos são atribuídos. Esses pesos ajudam a determinar a importância de uma variável específica, quanto maior o peso, mais ela contribui para o produto em comparação com outros insumos. Todas as entradas são então multiplicadas por seus respectivos pesos e depois somadas. Quando esta saída (*output*) ultrapassa um determinado valor, o nó é ativado e envia os dados para a próxima camada da rede. Isso faz com que a saída de um nó seja a entrada do próximo nó (IBM, [s.d.]).

2.4.3 Árvores de decisão

Uma árvore de decisão é um algoritmo de modelagem estatística que emprega uma estrutura hierárquica em forma de árvore composta por nós, a fim de representar e mapear múltiplos caminhos de decisão, cada um associado a um resultado específico. Essa representação é análoga a um diagrama de fluxo, frequentemente utilizado para visualizar procedimentos ou processos, como a montagem de móveis ou a navegação em um labirinto. Cada nó da árvore corresponde a uma decisão ou ponto de escolha, que direciona o fluxo para destinos distintos, refletindo, assim,

diferentes resultados ou desfechos. Geralmente são usados em problemas de difícil interpretação linear ou polinomial (Netto; Maciel, 2021).

As árvores de decisão constituem modelos estatísticos empregados no contexto de aprendizado supervisionado, com o propósito de classificar e prever dados. Em termos simples, esses modelos se baseiam em um conjunto de treinamento que engloba entradas e saídas, sendo estas últimas correspondentes às categorias ou classes desejadas. Conforme a Figura 06, a construção das árvores de decisão adota uma abordagem "dividir para conquistar", em que um problema complexo é decomposto em subproblemas mais simples, conforme elucidado por Gama (2004).

Figura 6 - Exemplo de árvore de decisão

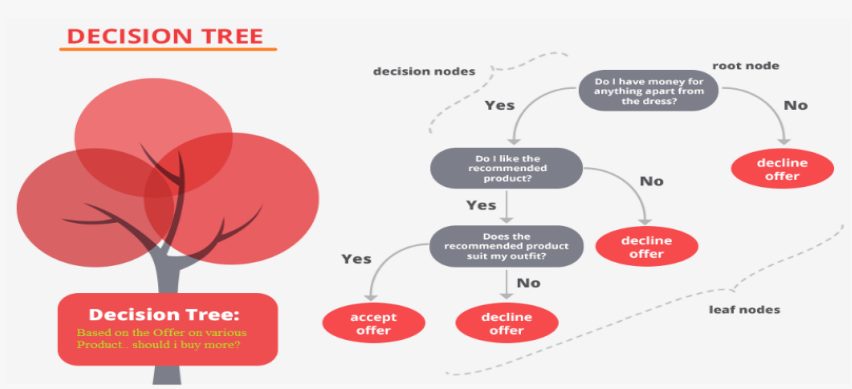

Fonte: Data Science Foundation (apud Sacramento, [s.d.].)

A imagem representa uma árvore de decisão, uma ferramenta visual utilizada para tomar decisões com base em uma série de escolhas. No topo, tem-se o nó raiz, que inicia a decisão com a pergunta: "Tenho dinheiro para algo além do vestido?". A resposta "Sim" leva a outra pergunta, enquanto a resposta "Não" resulta em "rejeitar a oferta". As perguntas seguintes, chamadas de nós de decisão, envolvem se o produto recomendado agrada e se combina com a roupa. Dependendo das respostas, o caminho leva a nós “folha”, que resultam em aceitar ou rejeitar a oferta. Esse exemplo ilustra como uma árvore de decisão ajuda a simplificar decisões complexas com base em condições sequenciais (Sacramento [s.d.]).

Assim como um fluxograma, uma árvore de decisão estabelece nós (nós de decisão) que se relacionam hierarquicamente entre si. Nesse contexto, há um nó-raiz de maior relevância e nós-folha que representam os resultados finais ou saídas. No contexto do aprendizado de máquina, o nó-raiz corresponde a um dos atributos

presentes no conjunto de dados, enquanto o nó-folha representa a classe ou valor que será gerado como resposta (Sacramento [s.d.]).

2.5 ANÁLISE DE SÉRIES TEMPORAIS

A análise de séries temporais, como o próprio nome indica, é a investigação de variáveis observadas ao longo do tempo, com a pretensão de realizar previsões para períodos futuros. Segundo Morettin e Toloi (2018, p. 3), quando tem-se uma série temporal, pode-se estar interessados em:

> 1. investigar o mecanismo gerador da série temporal — por exemplo, analisando uma série de alturas de ondas, podemos querer saber como essas ondas foram geradas;
> 2. fazer previsões de valores futuros da série — essas podem ser a curto prazo, como para séries de vendas, produção ou estoque, ou a longo prazo, como para séries populacionais, de produtividade etc.;
> 3. descrever apenas o comportamento da série — nesse caso, a construção do gráfico, a verificação da existência de tendências, ciclos e variações sazonais, a construção de histogramas e diagramas de dispersão etc. podem ser ferramentas úteis;
> 4. procurar periodicidades relevantes nos dados, com o auxílio de análise espectral (Morettin; Toloi 2018, p. 3).

Conforme Doane e Seward (apud Souza; Silva, 2021), as empresas de negócios utilizam dados de séries temporais para monitorar se um processo, em particular, se apresenta estável ou instável e para auxiliar a predizer o futuro, o que chama-se de previsão em séries temporais. Ao adotar metodologias de séries temporais, as empresas podem tomar decisões mais informadas, otimizar seus recursos e aumentar a eficiência operacional, resultando em vantagens competitivas significativas no mercado.

2.5.1 ARIMA (*Autoregressive Integrated Moving Average*)

O modelo ARIMA é um caso específico do modelo ARMA. ARMA é um modelo de média móvel auto regressiva e ARIMA é uma média móvel autorregressiva integrada. Antes disso, pode-se citar os modelos AR, que são modelos autorregressivos. Os modelos ARIMA são aplicados a modelos estacionários. Uma classe de modelos ARIMA será capaz de descrever satisfatoriamente séries estacionárias e não estacionárias, mas não exibem comportamento explosivo. Esse tipo de não estacionariedade é denominado homogêneo (Morettin; Toloi, 2018).

A metodologia ARIMA consiste em ajustar modelos integrados de média móvel auto regressiva, ARIMA, a um conjunto de dados. Na construção do modelo, segue-se um algoritmo em que a escolha da estrutura do modelo é baseada nos próprios

dados. Segundo Morettin (2011), há três fases a serem consideradas na construção de um modelo ARIMA para uma série temporal: identificação, estimativa, diagnóstico e aplicação.

Identificar o modelo ARIMA específico que se ajusta aos dados é provavelmente a etapa mais crítica das etapas descritas. Esta escolha é feita principalmente com base nas autocorrelações estimadas e nas autocorrelações parciais, que se espera representar adequadamente as quantidades teóricas relevantes que são desconhecidas. Primeiramente é criado um gráfico da série para identificação, depois sua estacionariedade é analisada por meio da função de autocorrelação. Se a série não for estacionária, é necessário torná-la moderna e sazonal. É necessário verificar o termo constante no modelo e determinar a ordem de p e q usando testes de hipóteses (Ibid, 2011).

2.5.2 Modelos Sazonais

Segundo Tubino (2017), a sazonalidade é caracterizada por flutuações ascendentes e descendentes que ocorrem em intervalos regulares nas séries temporais de demanda. Deve haver uma razão plausível para a ocorrência e posterior repetição de tais desvios. A sazonalidade pode ocorrer anualmente, mensal, semanalmente ou diariamente. A sazonalidade é expressa como o valor ou percentual de demanda que se desvia da média da série. Se houver uma tendência, ela deve ser levada em consideração. O valor aplicado à média ou tendência é denominado índice de sazonalidade.

A forma mais simples de contabilizar a sazonalidade na previsão da procura é obter os dados de procura mais recentes para o período sazonal relevante e utilizá-los como previsão. Por exemplo, a procura de casacos no mês de Julho será igual à procura de Julho do ano anterior. Se houver uma tendência, deve-se adicionar ou subtrair dos valores recuperados. Contudo, a forma mais comum de incorporar a sazonalidade na previsão da procura é utilizar uma média móvel centrada para determinar o índice de sazonalidade para vários períodos e aplicá-lo ao valor médio (ou tendência) esperado para esse período (Tubino, 2017).

2.5.3 *Gradient Boosting Machines* (GBM)

Segundo Sicsú et. al (2023), O *Gradient Boosting Machine* (GBM) é um algoritmo de aprendizado de máquina baseado em *boosting*, onde os modelos são treinados de forma sequencial, com o objetivo de corrigir os erros cometidos pelas iterações anteriores. O GBM minimiza uma função de perda ao longo das iterações, ajustando os parâmetros do modelo de forma incremental. Essa abordagem permite que o modelo aprenda com os erros de forma mais eficaz, fazendo com que cada nova árvore adicionada ao conjunto se concentre nos pontos de erro mais significativos.

Ainda segundo o mesmo autor, para calcular o GBM, inicialmente, uma árvore de decisão é criada para prever a variável de interesse. Depois disso, a função de perda é calculada com base nos erros de previsão. A próxima etapa envolve a criação de uma nova árvore para ajustar esses erros residuais, e esse processo se repete várias vezes. Cada nova árvore tenta minimizar o erro da anterior, ajustando seus pesos conforme a magnitude do erro em cada observação. O número de iterações e a profundidade das árvores são parâmetros importantes para controlar a complexidade do modelo e evitar o sobreajuste (*overfitting*).

2.6 ESTRATÉGIAS DE IMPLEMENTAÇÃO

Segundo Pellegrini e Fogliatto (2001), o desenvolvimento de um sistema de previsões requer conhecimentos e habilidades em quatro áreas principais: identificar e definir os problemas a serem abordados nas previsões; aplicação de métodos de previsão; procedimentos para seleção do método apropriado para situações específicas; e apoio organizacional para adaptação e utilização dos métodos de previsão necessários. Um sistema de previsão deve estabelecer relações entre as previsões feitas pelas diferentes áreas de gestão, uma compreensão completa da natureza das dependências determina o sucesso do uso de um sistema de previsão.

A aplicabilidade de um sistema de previsão depende de três condições (Makridakis et al., 1998): a disponibilidade de dados históricos; a possibilidade de conversão de dados traspassados em dados numéricos, e a suposição de repetibilidade futura de padrões observados a partir de dados traspassados. Esta última consideração é chamada de hipótese de continuidade. Este pré-requisito é um

pré-requisito fundamental para a utilização de métodos de previsão quantitativos, bem como de vários métodos qualitativos.

2.6.1 Processo de implementação

Uma parte fundamental do processo de implementação de um sistema de previsão de demanda é compreender o ambiente organizacional. Isto inclui identificar os objetivos estratégicos da organização, compreender os produtos ou serviços envolvidos e analisar os principais desafios na cadeia de abastecimento. Em seguida, devem ser definidos objetivos e indicadores claros para orientar o processo de implementação. As metas podem variar dependendo das necessidades da organização e podem incluir melhorar a precisão das previsões, reduzir o excesso de estoque ou melhorar o atendimento ao cliente (Armstong 2001).

Identificar e coletar fontes de dados relevantes, como histórico de vendas, informações de mercado e dados sazonais, são essenciais para a precisão das previsões. Garantir que os dados sejam precisos e atualizados é um requisito fundamental. Isso pode envolver a escolha de modelos estatísticos tradicionais, modelos avançados de aprendizado de máquina ou uma combinação de ambos, dependendo das necessidades e da complexidade dos dados da organização (Ibid 2001).

A limpeza e análise de dados são os próximos passos. A preparação de dados, incluindo a remoção de ruídos e valores discrepantes, é fundamental para garantir que os modelos preditivos funcionem corretamente. Além disso, a análise dos padrões históricos de demanda ajudará a identificar tendências e sazonalidades que impactam as previsões. O modelo selecionado deve ser treinado com dados históricos e validado com dados de teste (Ibid, 2001).

O monitoramento contínuo do desempenho é uma prática importante. Um processo de monitoramento permitirá avaliar até que ponto o seu sistema de previsão de demanda está atingindo os objetivos declarados. Assim como a documentação adequada e a comunicação eficaz são essenciais durante todo o processo. Documentar detalhadamente cada etapa do processo e compartilhar informações relevantes com as partes interessadas dentro da organização promove transparência e colaboração. E por fim, a melhoria contínua deve ser um princípio orientador, pois à medida que a organização cresce e as condições do mercado mudam, é fundamental

adaptar e melhorar o seu sistema de previsão de demanda para manter a sua eficácia (Ibid, 2001).

2.7 *VISUAL STUDIO CODE* (VS CODE) E BIBLIOTECAS UTILIZADAS

O Visual Studio Code, combinado com extensões como a do *Python*, é amplamente usado para ciência de dados. Ele permite configurar ambientes de desenvolvimento integrados, trabalhar com notebooks diretamente no editor, e realizar análises exploratórias e modelagem preditiva. Um tutorial no site da Microsoft mostra como integrar essas bibliotecas e criar modelos preditivos, como para o Titanic *Dataset*, usando *Pandas* para manipulação de dados, *matplotlib* para visualização e *sklearn* para aprendizado de máquina (Microsoft, 2018).

2.7.1 *Pandas*: Manipulação e Análise de Dados

O *Pandas* é uma biblioteca essencial para manipulação e análise de dados em *Python*, construída sobre a biblioteca *NumPy*. Suas principais estruturas de dados são o *DataFrame*, que permite manipular tabelas bidimensionais com rótulos em linhas e colunas, e o Series, uma estrutura unidimensional semelhante a um *array* com rótulos. Essas estruturas permitem realizar tarefas como leitura, escrita e processamento de dados em diversos formatos, como CSV, Excel e bancos de dados SQL (Saturn Cloud, 2023).

A biblioteca é amplamente utilizada para limpeza de dados, transformação e agregação. Oferece ferramentas para tratar valores ausentes, agrupar informações com base em critérios específicos e realizar cálculos estatísticos. Sua integração com bibliotecas como *matplotlib* e *scikit-learn* torna-a fundamental no fluxo de trabalho da ciência de dados. Em estudos como a análise do Titanic *Dataset*, *Pandas* demonstrou sua eficácia ao explorar dados e gerar insights importantes (Analytics Insight, 2023).

2.7.2 *NumPy*: Cálculo Numérico Avançado

A biblioteca *NumPy* fornece suporte para *arrays* multidimensionais e matrizes, permitindo cálculos matemáticos e numéricos eficientes. Projetada para lidar com grandes volumes de dados, ela realiza operações vetorizadas que oferecem desempenho superior em comparação aos loops convencionais em *Python* (Analytics Insight, 2023).

Entre suas funcionalidades estão operações de álgebra linear, transformações de Fourier e cálculos estatísticos. *NumPy* é a base para muitas outras bibliotecas em *Python*, como o próprio *Pandas*, e sua utilização é indispensável para manipulações numéricas em projetos científicos e de aprendizado de máquina (Dev Blogs Microsoft, 2019).

2.7.3 Matplotlib: Visualização de Dados

O *matplotlib* é a principal biblioteca de visualização de dados no *Python*. Através de seu módulo *pyplot*, ela permite a criação de gráficos básicos e avançados, como linhas, barras, dispersão, histogramas e mapas de calor. Essa flexibilidade é essencial para compreender padrões e comunicar insights de maneira eficiente (Analytics Insight, 2023).

Uma de suas maiores vantagens é a personalização total de gráficos, desde estilos e cores até rótulos e legendas. Além disso, sua integração com *Pandas* simplifica o processo de geração de gráficos a partir de *DataFrames*, reduzindo significativamente o tempo necessário para transições entre análise e visualização (Saturn Cloud, 2023).

2.7.4 Scikit-learn: Aprendizado de Máquina

O *scikit-learn* oferece uma ampla gama de ferramentas para aprendizado de máquina, incluindo algoritmos de classificação, regressão, clusterização e redução de dimensionalidade. Sua interface simples e consistente torna-o acessível tanto para iniciantes quanto para especialistas em ciência de dados (Saturn Cloud, 2023).

A biblioteca é frequentemente utilizada em conjunto com *Pandas* para preparação de dados e *matplotlib* para visualizações. Isso permite que fluxos de trabalho de aprendizado de máquina, desde o pré-processamento até a avaliação de modelos, sejam realizados de forma eficiente e integrada (Dev Blogs Microsoft, 2019).

2.7.5 Statsmodels: Modelagem Estatística

O *statsmodels* é especializado em análise estatística e econométrica, oferecendo ferramentas para regressão, séries temporais e testes de hipóteses. Um diferencial dessa biblioteca é o fornecimento de relatórios estatísticos detalhados, incluindo métricas como coeficientes, erros padrão e valores-p (Saturn Cloud, 2023).

Sua integração com *Pandas* facilita a preparação e manipulação de dados, tornando-a ideal para estudos que exigem rigor estatístico e validação de hipóteses. A biblioteca é amplamente utilizada em análises exploratórias e preditivas (Analytics Insight, 2023).

3 METODOLOGIA

Metodologia é vista como uma disciplina baseada no estudo, compreensão e avaliação dos métodos disponíveis para a realização de pesquisas acadêmicas. Portanto, para legitimar sua eficácia e aplicação nas diversas áreas da sociedade, a metodologia é a aplicação de procedimentos e técnicas que devem ser levados em consideração para a construção do conhecimento (Prodanov; Freitas, 2013).

3.1 MÉTODOS DE ABORDAGEM

Este trabalho conta com abordagem hipotético-dedutiva onde começa com a formulação de um problema e sua descrição clara e precisa para facilitar a aquisição de um modelo simplificado e a identificação de conhecimentos e ferramentas adicionais relevantes para o problema em questão para auxiliar o pesquisador em seu trabalho. Após esse estudo preparatório, o pesquisador passa para a fase de observação. Na verdade, esta é uma fase de teste de um modelo simplificado. É uma fase cuidadosa em que se observa determinado aspecto do universo, objeto de investigação (Prodanov; Freitas, 2013).

A próxima etapa é a formulação de hipóteses ou descrições provisórias de acordo com o que foi observado. Essas hipóteses foram usadas para fazer previsões que serão ou não comprovadas por meio de testes, experimentos ou observações mais detalhadas. Dependendo dos resultados destes testes, as hipóteses podem ser modificadas e um novo ciclo pode começar até que não haja mais contradições entre a teoria e os experimentos ou observações (Prodanov; Freitas, 2013).

Segundo Prodanov e Freitas (2013), o problema surge de lacunas ou conflitos dependendo do quadro teórico existente. Uma solução proposta é uma conjectura (uma nova ideia e/ou uma nova teoria) derivada de proposições (hipóteses ou premissas) que estão sujeitas a testes. Os testes de falsificação são tentativas de refutar hipóteses por meio de observação e/ou experimentação.

Este trabalho conta com uma forma de abordagem quali-quantitativa também conhecida como métodos mistos. De acordo com Creswell e Creswell (2021), os métodos mistos envolvem a combinação ou integração de pesquisas qualitativas e quantitativas e dados relevantes em um estudo. Os dados qualitativos tendem a ser

abertos, sem respostas pré-determinadas, enquanto os dados quantitativos envolvem frequentemente respostas fechadas, como as encontradas em questionários ou instrumentos psicológicos.

Nesse estudo, a pesquisa qualitativa foi aplicada para realizar uma análise exploratória e compreender os desafios intrínsecos. Paralelamente, a pesquisa quantitativa desempenha um papel crucial na aquisição de dados empíricos, aplicação de métodos estatísticos para modelagem de previsão de demanda e validação desses modelos. A sinergia entre ambas as abordagens possibilita a interpretação dos resultados baseados no contexto qualitativo, oferece fundamentos para recomendações embasadas e aborda de maneira abrangente a complexidade inerente à gestão de estoques, contribuindo de modo significativo para alicerçar decisões estratégicas informadas.

Em relação a abordagem com base nos objetivos, essa pesquisa utiliza os métodos descritivos e exploratórios. A pesquisa descritiva busca descrever as características de uma população ou fenômeno específico. Eles também são desenvolvidos para identificar possíveis relações entre variáveis, que é o caso deste trabalho. Existe um grande número de estudos que podem ser classificados como descritivos, e a maioria deles realizados para fins profissionais provavelmente se enquadra nesta categoria. Alguns estudos descritivos vão além da simples identificação da existência de uma relação entre variáveis, mas visam determinar a natureza dessa relação. Nesse caso, há estudos descritivos que se aproximam do explicativo (Gil, 2022).

Já a pesquisa exploratória é uma pesquisa empírica que visa levantar questões ou problemas e tem três propósitos: formular hipóteses; aumentar a familiaridade do pesquisador com o cenário, fatos ou fenômenos para pesquisas futuras mais precisas; revisar e esclarecer conceitos. Procedimentos sistemáticos são normalmente usados para obter observações empíricas ou analisar dados, como no caso deste trabalho de conclusão de curso. Geralmente são obtidas descrições quantitativas e qualitativas do objeto de estudo, cabendo ao pesquisador conceituar as inter-relações entre fenômenos, fatos ou atributos observados do ambiente. Para pesquisas relativamente aprofundadas em um pequeno número de unidades, uma variedade de procedimentos de coleta de dados, como entrevistas, observação participante e análise de conteúdo, podem ser utilizados, mas geralmente não são utilizadas técnicas de amostragem probabilística (Lakatos, 2021).

3.2 MÉTODO DE PROCEDIMENTO TÉCNICO

Segundo Parra Filho e Santos (2012), é importante que o pesquisador tenha uma compreensão abrangente da fase do assunto que está sendo estudado. A pesquisa bibliográfica desempenha um papel fundamental neste trabalho porque permite uma revisão e síntese do conhecimento existente sobre modelos de previsão de demanda, métodos estatísticos e melhores práticas de gestão de estoques. Esta etapa é importante para fundamentar teoricamente a pesquisa e identificar lacunas de conhecimento que este estudo pode preencher.

Segundo Gil (2022), a vantagem mais importante da pesquisa bibliográfica é que ela permite ao pesquisador abranger um espectro muito mais amplo de fenômenos do que poderia ser estudado diretamente. Contudo, esta vantagem tem uma contrapartida que pode reduzir significativamente a qualidade da investigação. Pode acontecer que a informação disponível nas fontes escritas tenha sido recolhida ou processada incorretamente. Consequentemente, trabalhos baseados nessas fontes tendem a reproduzir ou mesmo reforçar esses erros. Para reduzir esta possibilidade, os investigadores devem verificar as circunstâncias em que os dados foram obtidos, analisar minuciosamente cada conjunto de dados em busca de possíveis inconsistências ou contradições, e utilizar e comparar cuidadosamente diferentes fontes.

3.3 TÉCNICAS DE COLETA DE DADOS

Para obter informações importantes sobre o contexto e os requisitos anteriores da gestão de estoque, utilizou-se um banco de dados (Apêndice I) online chamado *Kaggle*, que fornece diversos conjuntos de dados relacionados a diferentes setores e práticas de gestão de estoque. Os dados são obtidos de forma ética e estruturada, sendo garantida a confidencialidade dos dados se necessário.

Também foi utilizada a pesquisa documental, que segundo Gil (2022), tem muitas semelhanças com a pesquisa bibliográfica porque ambos os métodos utilizam dados existentes. A principal diferença está na natureza das fontes. A pesquisa bibliográfica é baseada em material que os autores prepararam para leitura para um público específico. A pesquisa documental utiliza todos os tipos de documentos preparados para diversos fins, como pesquisa, autorização, comunicação, etc. Mas há fontes que ora são consideradas bibliográficas, ora documentais. Envolve

encontrar e analisar documentos, relatórios, políticas organizacionais e outros registros que possam fornecer informações valiosas para pesquisa. Documentos como manuais de procedimentos, relatórios de auditoria e registros financeiros são examinados para compreender as práticas de gestão de estoques das organizações estudadas.

3.4 TÉCNICAS DE ANÁLISE DE DADOS

A análise estatística é a etapa central desta pesquisa onde os dados coletados são processados e analisados. Foram utilizadas técnicas estatísticas avançadas, incluindo a construção de modelos de previsão de demanda como séries temporais, regressão linear e não linear. A análise estatística permite avaliar a eficácia dos modelos de previsão existentes, identificar tendências e padrões nos dados e fornecer informações para melhorar a gestão de inventário. Segundo Gil (2022), existem muitos testes de significância em estatística. A utilização de todos depende do conhecimento prévio da extensão, distribuição e qualidade dos dados. Portanto, todo o processo de análise estatística deve ser planejado antes da realização do experimento.

A análise dos dados processados no *VISUAL STUDIO CODE* envolveu a aplicação de técnicas estatísticas avançadas, incluindo a elaboração de modelos de previsão de demanda. Através desses modelos, foram realizadas projeções de demanda futura, identificação de sazonalidades e avaliação de tendências históricas. Os resultados foram apresentados em gráficos, tabelas e métricas relevantes, contribuindo para uma compreensão aprofundada dos dados coletados.

Uma parte significativa dos dados obtidos no *Kaggle* foi processada e analisada utilizando o ambiente de desenvolvimento Visual Studio Code, que é baseado em *Python*. O *VISUAL STUDIO CODE* proporciona uma plataforma poderosa e colaborativa para análise de dados, com acesso a bibliotecas amplamente utilizadas, como *Pandas*, *NumPy* e *Matplotlib*, que facilitam a organização, limpeza, análise estatística e visualização dos dados. As principais etapas realizadas no *VISUAL STUDIO CODE* incluíram a criação de gráficos, tabelas dinâmicas, cálculos estatísticos e visualizações que ajudarão a compreender padrões e tendências nos dados.

Além da análise quantitativa dos dados, foi realizada uma análise de conteúdo. Essa técnica foi aplicada para examinar documentos, relatórios e registros obtidos na pesquisa documental. A análise de conteúdo tem o objetivo de extrair informações

qualitativas e significativas, identificando temas, conceitos e padrões presentes nos documentos. Isso serviu para aprofundar a compreensão das práticas de gestão de estoques, identificar desafios e oportunidades, e complementar as informações quantitativas coletadas.

A análise dos dados processados envolveu a aplicação de técnicas estatísticas avançadas, incluindo a elaboração de modelos de previsão de demanda. Através desses modelos, foram realizadas projeções de demanda futura, identificação de sazonalidades e avaliação de tendências históricas. A efetividade desses modelos foram avaliadas com base em métricas de desempenho, como erro médio absoluto (MAE) e erro médio quadrático (RMSE), para determinar a precisão das previsões.

3.5 MATERIAIS E EQUIPAMENTOS

Durante a pesquisa, o autor utilizou uma série de fontes e ferramentas que tiveram papel fundamental na pesquisa. O acesso a um computador e à internet foram necessários para obter dados, realizar pesquisas bibliográficas e acessar fontes de informação relevantes. Além disso, o autor fez uso extensivo de ferramentas, como o *software* Visual Studio Code, para criar documentos, realizar análises de dados e colaborar.

Ferramentas da Microsoft como Word e Excel foram utilizadas para formatação de arquivos e análise estatística. A pesquisa foi enriquecida pelo acesso a bases de dados específicas e bibliografias aprofundadas relacionadas a modelos de previsão de demanda. Além disso, o acesso a bases de dados acadêmicas e bibliotecas online foi crucial para a coleta de informações e materiais de referência.

3.6 ETAPAS DA PESQUISA

Segundo Gil (2022), um fluxograma é um diagrama que representa, por meio de símbolos, as etapas de um processo ou de uma atividade. Em metodologia da pesquisa, os fluxogramas são frequentemente utilizados para representar o processo de pesquisa científica.

Um fluxograma de pesquisa científica é um diagrama que mostra as etapas do processo de pesquisa, desde a definição do tema até a apresentação e defesa dos resultados. Os fluxogramas são uma ferramenta útil para a organização e planejamento da pesquisa, pois permitem que o pesquisador visualize o processo

como um todo e identifique possíveis problemas ou lacunas, a seguir, na Figura 07 apresenta-se a condução desta pesquisa.

Figura 7 - Fluxograma das etapas realizadas

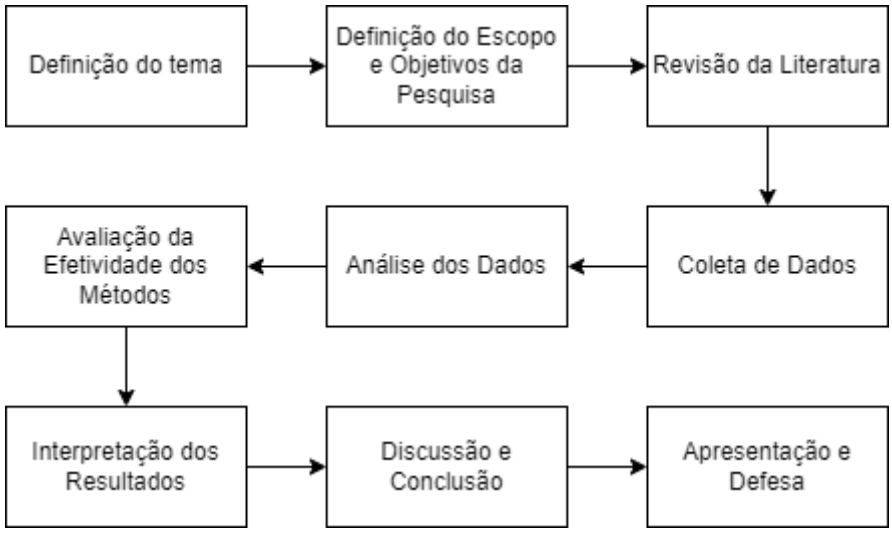

Fonte: Autor, 2023.

O fluxograma da Figura 07 ilustra as etapas do processo de pesquisa científica aplicadas neste trabalho final de curso. A primeira etapa consiste na definição do tema, em que se determina o assunto a ser investigado. Em seguida, realiza-se a revisão da literatura, com o objetivo de identificar e analisar o que já foi publicado sobre o tema em questão. A etapa de coleta de dados envolve reunir as informações necessárias para responder às hipóteses ou questões da pesquisa. Posteriormente, os dados coletados são analisados para identificar padrões, tendências e possíveis relações entre variáveis. A interpretação dos resultados busca atribuir significado aos achados da análise, elucidando sua relevância no contexto do estudo. Finalmente, ocorre a apresentação e defesa dos resultados, direcionada a um público acadêmico ou profissional. Em síntese, o processo de pesquisa científica engloba a escolha de um tema relevante, o estudo da literatura existente, a coleta e análise de dados, a interpretação dos resultados obtidos e a comunicação desses resultados de forma estruturada e fundamentada.

4 APRESENTAÇÃO E ANÁLISE DOS RESULTADOS

Na realização dos cálculos, foram utilizados dados de um banco de dados online chamado *Kaggle* referentes a demanda de produtos em um determinado setor (Apêndice I). Desse banco de dados foram escolhidos dados de um determinado produto, nesse caso denominado de Produto_0001, abrangendo o período de dezembro de 2011 até dezembro de 2016, num total de 599 unidades de dados. Destas, 495 foram utilizados como base para os testes e o restante dos valores (104) foram utilizados como meta dos cálculos, também para verificação do erro das previsões uma vez que os valores reais estavam disponíveis.

4.1 MÉDIA MÓVEL SIMPLES

Para realizar a análise da demanda de pedidos, utilizou-se o *VISUAL STUDIO CODE* (conforme o Apêndice A) com *Python* para implementar a técnica de Média Móvel Simples (MMS). A MMS foi calculada para suavizar os dados de demanda e revelar tendências subjacentes. No Visual Studio Code, começou-se carregando os dados em um "*DataFrame*" da biblioteca *Pandas* e convertendo a coluna de datas para o formato adequado. Aplicou-se a função "*rolling*" também da biblioteca *Pandas* para criar uma janela deslizante com tamanho definido (12 meses, neste caso), e calculou-se a média móvel usando a função "*mean*".

A seguir, na Figura 08, demonstra um gráfico de séries temporais mostrando a demanda de um determinado produto ao longo do tempo, junto com uma linha de tendência gerada pela técnica de Média Móvel Simples. Essa linha suaviza as flutuações nos dados e destaca as tendências subjacentes, facilitando a visualização dos padrões gerais na demanda histórica.

Figura 8 - Demanda de Pedidos e Média móvel simples

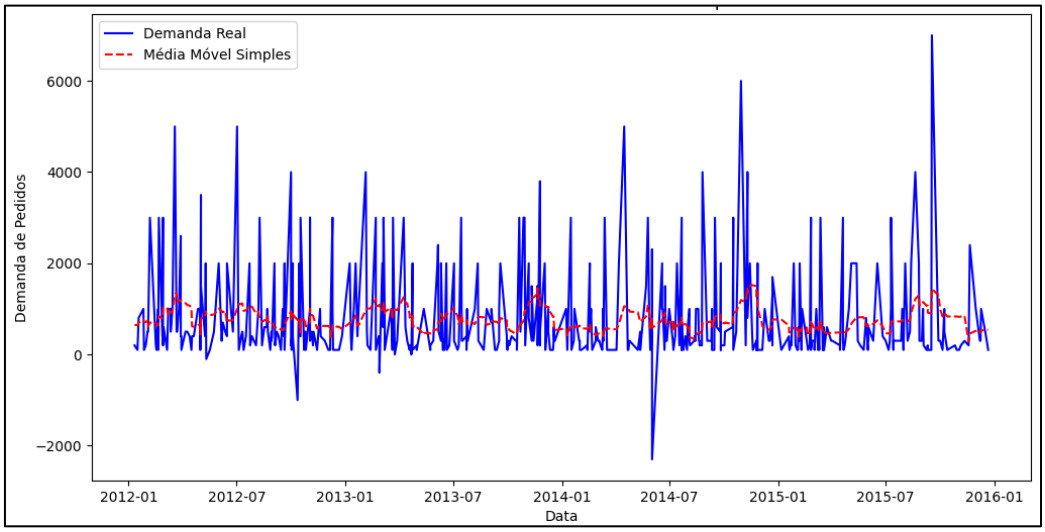

Fonte: Autor (2024)

Neste gráfico, os picos representam períodos em que a demanda atingiu níveis excepcionalmente altos, sugerindo eventos sazonais ou promoções que impulsionaram as vendas. Os vales, por outro lado, indicam quedas acentuadas na demanda, que podem estar associadas a fatores como baixa sazonalidade, falta de oferta ou mudanças nas preferências dos consumidores. A linha da média móvel simples suaviza essas variações extremas, oferecendo uma visão mais clara da tendência geral, mas pode ocultar oscilações significativas que impactam a gestão de estoques.

Para avaliar a precisão das previsões, foram calculadas duas métricas de erro: o Erro Médio Absoluto (MAE) e o Erro Quadrático Médio (RMSE). Os resultados obtidos foram um RMSE de 970.06 e um MAE de 684.02. Esses valores indicam que, apesar de a MMS ajudar a suavizar as flutuações nos dados, o modelo não foi capaz de prever com alta precisão a demanda de pedidos, sugerindo que técnicas mais avançadas podem ser necessárias para melhorar a acurácia das previsões.

4.2 SUAVIZAÇÃO EXPONENCIAL

Para analisar a demanda de pedidos e identificar tendências subjacentes, aplicou-se a técnica de Suavização Exponencial Simples (SES). Esta técnica é eficaz para suavizar séries temporais, atribuindo mais peso aos dados mais recentes e ajudando a destacar tendências recentes e padrões de longo prazo. Utilizou-se o

VISUAL STUDIO CODE com *Python* (conforme o Apêndice B) para implementar o modelo SES e calcular as previsões.

A precisão do modelo também foi avaliada utilizando pelas MAE e o RMSE. Essas métricas fornecem uma visão sobre a acurácia das previsões e ajudam a entender a eficácia do modelo na captura de padrões de demanda. Similar à figura anterior, o gráfico da Figura 09, exibe a demanda ao longo do tempo com a adição de uma linha que representa a previsão utilizando a técnica de Suavização Exponencial Simples. Essa técnica dá maior peso aos dados mais recentes, destacando tendências de curto prazo e permitindo uma análise mais precisa das variações recentes na demanda.

Figura 9 - Demanda de pedidos e suavização exponencial simples

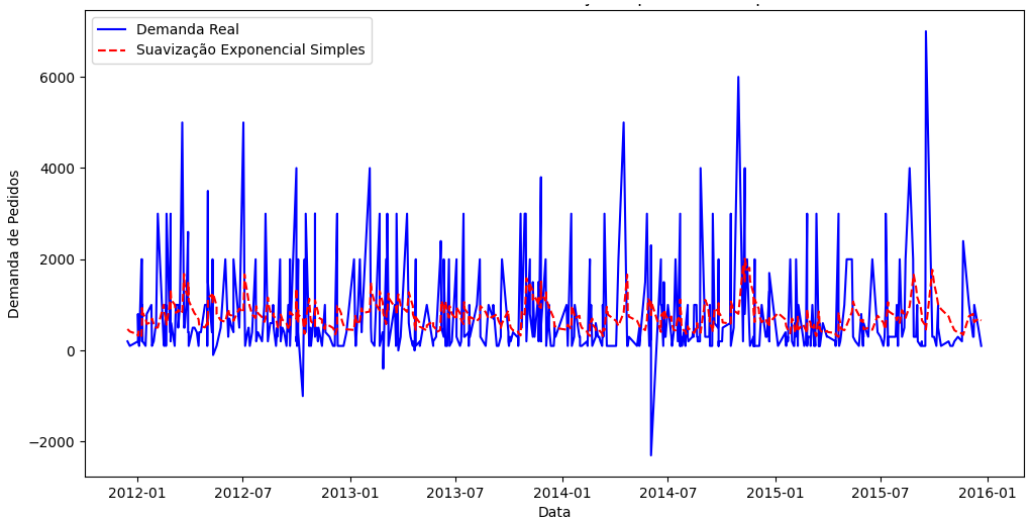

Fonte: Autor (2024)

Neste gráfico, a linha de suavização exponencial reage mais rapidamente às mudanças recentes na demanda devido ao maior peso atribuído aos dados mais recentes. Isso é evidente quando a linha se aproxima dos picos e vales, capturando melhor as tendências de curto prazo. Os picos próximos ao final do período analisado indicam um aumento recente na demanda, possivelmente devido a um evento sazonal específico. Já os vales refletem períodos de baixa atividade, sugerindo necessidade de ajustes no estoque para evitar excessos.

Os resultados da avaliação do modelo de Suavização Exponencial Simples foram os seguintes: RMSE: 1073.82 e MAE: 757.22. O RMSE de aproximadamente 1073.82 indica a magnitude média dos erros de previsão, considerando o quadrado das diferenças entre os valores reais e previstos. Esse valor relativamente alto sugere

que o modelo apresenta erros substanciais em suas previsões, com penalização para grandes discrepâncias. O MAE foi de 757.22, que representa a média das diferenças absolutas entre as previsões e os valores reais, e indica que, em média, as previsões estão distantes dos valores reais.

Essas métricas destacam que, embora a Suavização Exponencial Simples ajude a suavizar os dados e identificar tendências recentes, o modelo pode não ser suficientemente preciso para previsões detalhadas. O alto RMSE e MAE sugerem que há espaço para melhorias na precisão das previsões, possivelmente através da adoção de técnicas mais avançadas de modelagem de séries temporais.

4.3 ARIMA

Para realizar o cálculo do ARIMA, foi utilizado o *software* Visual Studio Code, que é um *software* usado para programação em diversas linguagens, nesse caso utilizando *Python* (conforme o Apêndice C). Tem-se duas formas de variáveis de calcular o ARIMA, utilizando *Stepwise* verdadeiro ou falso.

Stepwise=True: Esse método faz uma busca iterativa e mais rápida pelos melhores parâmetros, ajustando o modelo de maneira eficiente. O processo *Stepwise* tenta reduzir o tempo de execução e complexidade ao restringir a busca dos parâmetros a um conjunto menor e mais gerenciável.

Stepwise=False: Este método faz uma busca exaustiva, testando mais combinações de parâmetros, o que resulta em maior tempo de processamento, mas potencialmente pode encontrar um modelo mais adequado.

Neste estudo, foi realizado um processo de treinamento e teste para avaliar o desempenho do modelo ARIMA na previsão da demanda. Inicialmente, os dados foram separados em dois conjuntos: o conjunto de treino, que compreendeu os dados de janeiro de 2012 até dezembro de 2014, e o conjunto de teste, que incluiu os dados de janeiro a dezembro de 2015. O modelo foi ajustado (treinado) utilizando apenas o conjunto de treino, ou seja, ele aprendeu os padrões e a sazonalidade dos dados de demanda até o final de 2014.

Em seguida, o modelo foi testado no conjunto de teste, ou seja, utilizou-se o modelo treinado para prever os valores de demanda durante o ano de 2015, sem que esses dados tivessem sido vistos pelo modelo anteriormente. A comparação entre os valores previstos e os valores reais no conjunto de teste foi utilizada para calcular

métricas de erro, como o MSE e o MAE, permitindo avaliar a precisão e a eficácia do modelo na previsão de séries temporais.

Este gráfico na figura 10, mostra as previsões geradas pelo modelo ARIMA em comparação com os valores reais de demanda para o período de teste. A imagem ilustra como o modelo ARIMA captura padrões sazonais e tendências de longo prazo, comparando a previsão com a realidade e indicando a eficácia do modelo para projeções futuras.

Figura 10 - Aplicação do ARIMA

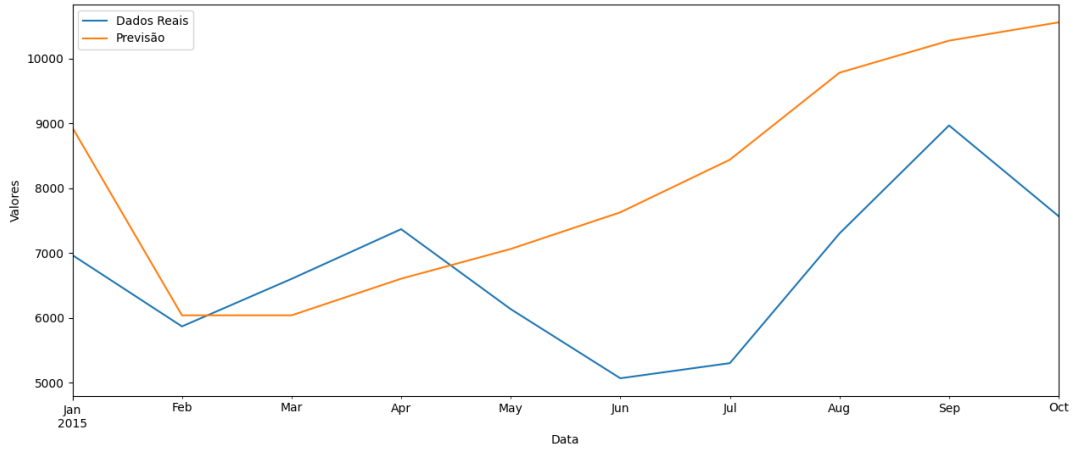

Fonte: Autor (2024)

O gráfico do modelo ARIMA destaca sua capacidade de capturar tanto picos quanto vales ao longo da série temporal. Os picos podem corresponder a altas sazonais ou eventos esporádicos que causam aumento na demanda, enquanto os vales mostram momentos de retração. As previsões do modelo ARIMA seguem bem essas variações, mas há momentos em que o modelo não acompanha totalmente a amplitude dos picos e vales, indicando a necessidade de um ajuste fino para lidar com variações mais extremas.

Nesse caso, foram utilizadas também algumas estratégias sugeridas para melhorar o desempenho do modelo ARIMA e reduzir o MSE. Essas mudanças incluem a aplicação de uma transformação logarítmica, o ajuste manual dos parâmetros do ARIMA, a utilização de média móvel para suavizar os dados, e a introdução de uma avaliação do erro.

Os resultados obtidos, com um MSE de 3.885.914,15 e um MAE de 1.686,75, indicam que o modelo de previsão ARIMA apresentou uma variação considerável entre os valores previstos e os valores reais da demanda. O MSE, que penaliza mais

fortemente os erros grandes por elevar ao quadrado as diferenças, revela que algumas previsões se desviaram significativamente dos valores observados.

Entretanto, o MAE, que calcula a média das diferenças absolutas entre as previsões e os valores reais, demonstra que, em média, o erro absoluto nas previsões foi de aproximadamente 1.686 unidades de demanda. O MAE é geralmente mais fácil de interpretar, pois não dá tanto peso a grandes outliers, sugerindo que o modelo teve um desempenho razoável para previsões gerais, mas pode ter cometido erros significativos em alguns pontos específicos da série temporal. Esses resultados sugerem que, apesar de o modelo capturar a tendência geral dos dados, há espaço para melhorias, seja no ajuste dos parâmetros ou na aplicação de técnicas que melhor lidem com as variações sazonais e o comportamento não-linear dos dados.

4.4 REGRESSÃO LINEAR

Para realizar o cálculo de Regressão Linear, também foi utilizado o *software Visual Studio Code*, com a linguagem de *Python* (conforme o Apêndice D). Na modelagem também foi utilizado um conjunto de valores para treino e teste. O conjunto de treino compreende os dados de demanda de pedidos até dezembro de 2014, sendo utilizado para ajustar o modelo de regressão linear. Este conjunto permite que o modelo aprenda os padrões e relações presentes nos dados históricos. Em contraste, o conjunto de teste inclui os dados de demanda de janeiro a dezembro de 2015. A divisão dos dados em treino e teste é crucial para garantir que o modelo não apenas se ajuste aos dados históricos, mas também tenha um desempenho eficaz na previsão de dados futuros.

A seguir, apresenta-se na Figura 11, resultante e a amostra do código utilizado para gerar essas métricas e avaliar o desempenho do modelo. A figura 11 apresenta a aplicação do modelo de Regressão Linear para prever a demanda de pedidos. O gráfico exibe a linha de regressão ajustada aos dados históricos, indicando a relação linear entre o tempo e a demanda. As previsões geradas pelo modelo são comparadas com os valores reais, ajudando a avaliar a precisão e adequação da regressão linear para esse tipo de série temporal.

Figura 11 - Demanda de pedidos e regressão linear

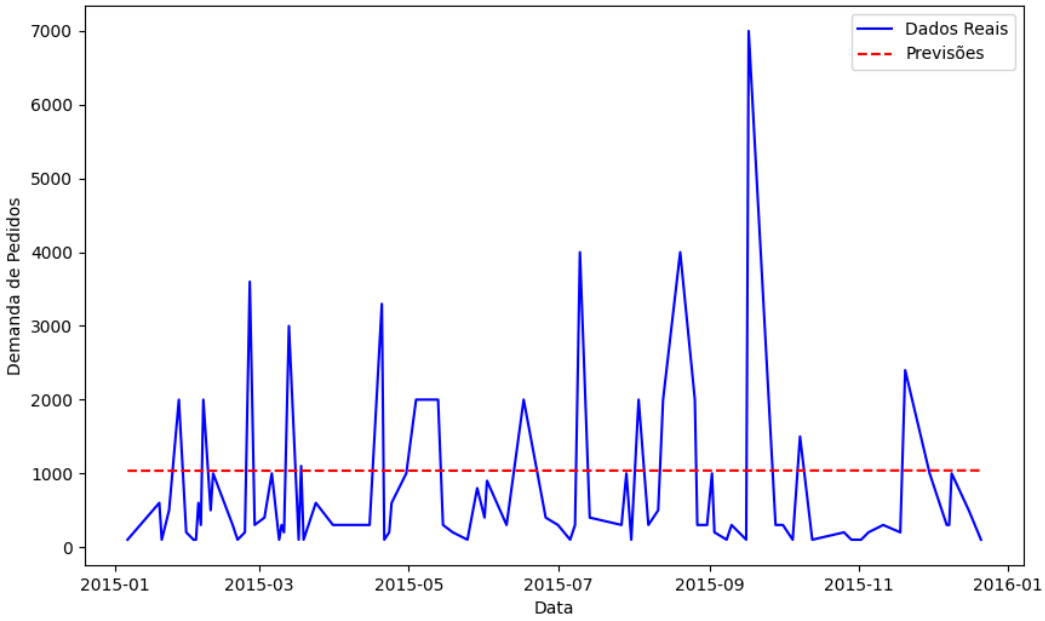

Fonte: Autor (2024)

Neste gráfico, a linha de regressão linear tende a simplificar demais a relação temporal, resultando em previsões que falham ao capturar adequadamente os picos e vales. Os picos representam subidas inesperadas na demanda que não são previstas pela linha linear, enquanto os vales mostram quedas que o modelo linear não antecipa corretamente. Isso sugere que a regressão linear, devido à sua natureza simplificadora, não é adequada para prever séries temporais com flutuações acentuadas.

Os resultados da análise de regressão linear mostram o desempenho do modelo em prever a demanda de pedidos. O MSE foi de aproximadamente 1.451.072,27, o que indica que, em média, o quadrado das diferenças entre as previsões e os valores reais é relativamente alto. Esse valor sugere que há variações significativas nas previsões, refletindo a dificuldade do modelo em capturar todos os padrões da série temporal. Por outro lado, o MAE foi de cerca de 901,14, representando a média das diferenças absolutas entre as previsões e os valores reais. Embora o MAE forneça uma visão mais intuitiva do erro médio em termos das unidades da variável dependente, ambos os indicadores revelam que o modelo tem limitações na previsão precisa dos valores. É importante notar que os erros padrão assumem que a matriz de covariância dos erros está corretamente especificada, o

que pode impactar a interpretação dos resultados e a robustez das estimativas do modelo.

4.5 ANÁLISE DE SAZONALIDADE E CICLOS

Para a análise da demanda de pedidos, também foi utilizado o *software VISUAL STUDIO CODE* com *Python* (conforme o Apêndice E), empregando bibliotecas e técnicas avançadas de análise de séries temporais. O primeiro passo foi a preparação dos dados, que envolveu a leitura do arquivo, a conversão das datas para o formato “datetime”, e a agregação dos dados para criar uma série temporal mensal. Após a preparação, a série temporal foi visualizada e decomposta para identificar padrões sazonais e cíclicos.

Para modelar a série temporal, foi aplicado um modelo SARIMA (*Seasonal AutoRegressive Integrated Moving Average*), que é adequado para séries temporais com componentes sazonais. O modelo foi treinado e testado, e os resultados das previsões foram comparados com os dados reais. Na Figura 12, é apresentada a decomposição da série temporal da demanda para identificar componentes sazonais e cíclicos. O gráfico mostra como os padrões sazonais e cíclicos influenciam a demanda ao longo do tempo, ajudando a entender melhor a periodicidade e as variações recorrentes nos dados.

Figura 12 - Demanda de pedidos e analise de sazonalidade e ciclos

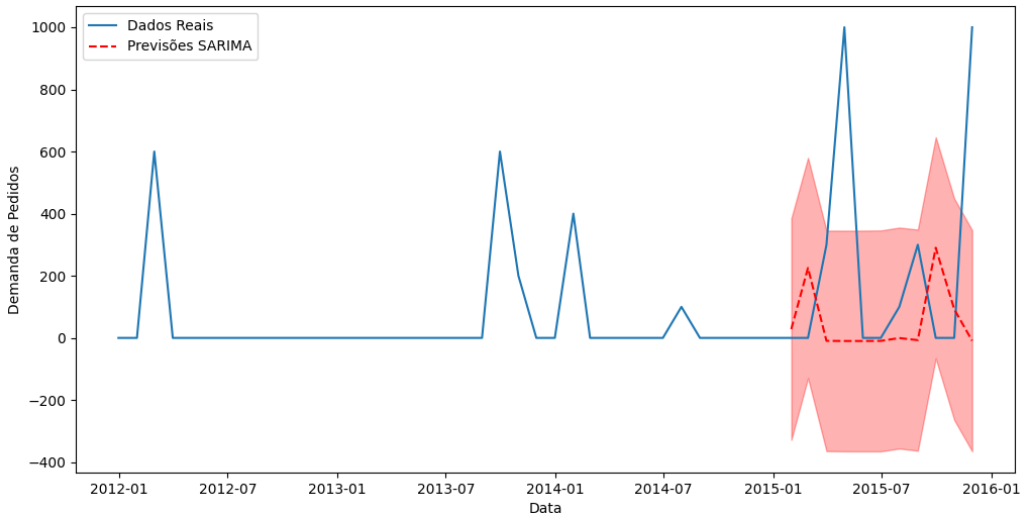

Fonte: Autor (2024)

Este gráfico mostra como a decomposição sazonal identifica claramente os picos e vales recorrentes, típicos de ciclos anuais ou mensais. Os picos indicam os

períodos de alta sazonalidade, como feriados ou eventos específicos que aumentam a demanda, enquanto os vales correspondem aos períodos de baixa sazonalidade. A modelagem SARIMA é eficaz para prever essas variações cíclicas, mas pode ter dificuldade em capturar eventos atípicos ou mudanças bruscas na tendência de longo prazo.

Os resultados da análise mostraram que o modelo SARIMA forneceu uma boa capacidade de previsão para a demanda de pedidos. A métrica de MSE foi de 216637.14, indicando a magnitude média dos erros de previsão ao quadrado. A métrica de Erro Absoluto Médio MAE foi de 308.34, refletindo o erro médio absoluto das previsões em termos de unidades. Esses resultados fornecem uma visão detalhada da precisão do modelo e ajudam a compreender o desempenho do modelo em prever a demanda de pedidos com base em dados históricos.

A faixa vermelha do gráfico é a faixa de confiança, uma área sombreada em torno das previsões, que indica a incerteza associada às previsões do modelo. Ela é calculada com base no intervalo de confiança, que fornece uma estimativa do intervalo dentro do qual os valores futuros da série temporal têm uma alta probabilidade de cair, dado o modelo e os dados históricos. O que demonstra certa incerteza nas previsões devido aos dados altamente sazonais.

4.6 REDES NEURAIS ARTIFICIAIS

Para melhorar a precisão na previsão da demanda de pedidos, foi implementado um modelo de rede neural recorrente (RNN), especificamente uma *Long Short-Term Memory* (LSTM, Memória de longo prazo), utilizando a biblioteca "*TensorFlow*" e "*Keras*" no ambiente de desenvolvimento *VISUAL STUDIO CODE* com *Python* (conforme o Apêndice F). Redes neurais LSTM são particularmente adequadas para lidar com dados de séries temporais devido à sua capacidade de capturar padrões de longo prazo e dependências temporais. O modelo foi treinado com dados históricos normalizados e, em seguida, foi avaliado com um conjunto de dados de teste separado para prever a demanda futura. As previsões geradas foram comparadas com os dados reais para medir a eficácia do modelo.

A Figura 13 ilustra o uso de redes neurais recorrentes, especificamente o modelo LSTM, para prever a demanda futura. O gráfico compara as previsões do modelo com os valores reais, destacando a capacidade da rede neural de capturar

padrões complexos e não lineares, proporcionando previsões mais precisas em relação aos métodos tradicionais.

Figura 13 - Demanda de pedidos e redes neurais artificiais

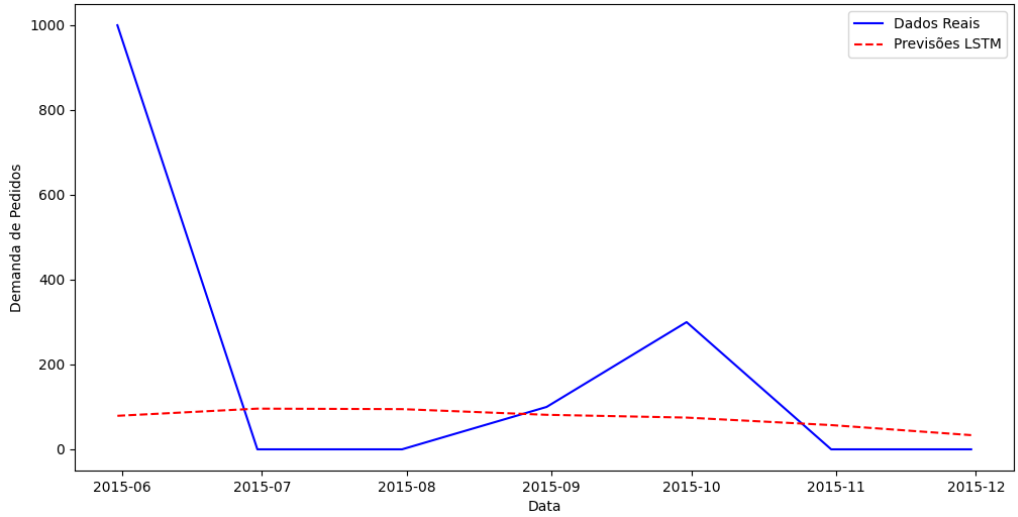

Fonte: Autor (2024)

No gráfico que utiliza LSTM, os picos e vales são identificados de maneira mais precisa, com a rede neural capturando a complexidade e a não linearidade dos dados. Os picos refletem aumentos inesperados na demanda, como em períodos de promoção ou lançamento de produtos, enquanto os vales mostram reduções que podem ser resultado de fatores econômicos ou mudanças de mercado. A LSTM se adapta melhor às variações de curto e longo prazo, mas ainda pode apresentar dificuldades com eventos totalmente inesperados ou mudanças abruptas.

Após o treinamento do modelo LSTM, foram calculadas o MSE e o MAE. O MSE obtido foi de 131.671,15, indicando que, em média, a diferença ao quadrado entre as previsões e os valores reais foi relativamente pequena. Este valor reflete o quão bem o modelo capturou as variações na demanda, mas é sensível a grandes discrepâncias. O MAE foi de 206,58, sugerindo que a média das diferenças absolutas entre as previsões e os valores reais foi de aproximadamente 207 unidades. Este valor proporciona uma medida direta do erro médio em termos das unidades da demanda e é útil para entender a precisão geral das previsões do modelo. Juntas, essas métricas indicam que o modelo LSTM foi eficaz em prever a demanda, com erros relativamente baixos, o que demonstra sua capacidade de capturar padrões temporais complexos nos dados.

4.7 FLORESTA ALEATÓRIA

Para melhorar a precisão na previsão da demanda de pedidos, foi utilizado um modelo de *Random Forest* (Floresta aleatória), uma técnica de aprendizado de máquina que combina múltiplas árvores de decisão para criar um modelo robusto e reduzir o risco de *overfitting* (sobreajuste). O processo foi realizado no ambiente de desenvolvimento *VISUAL STUDIO CODE* com *Python* (conforme o Apêndice G). O modelo foi treinado utilizando dados históricos de demanda e validado com um conjunto de dados separado para prever a demanda futura. Em seguida, as previsões obtidas foram comparadas com os dados reais para avaliar o desempenho do modelo e sua capacidade de previsão.

O gráfico da Figura 14, demonstra o desempenho do modelo de Floresta Aleatória na previsão da demanda. As previsões do modelo são apresentadas junto aos valores reais, permitindo uma análise da eficácia deste método de aprendizado de máquina para capturar as variações e padrões nos dados de demanda.

Figura 14 - Demanda de pedidos e floresta aleatória

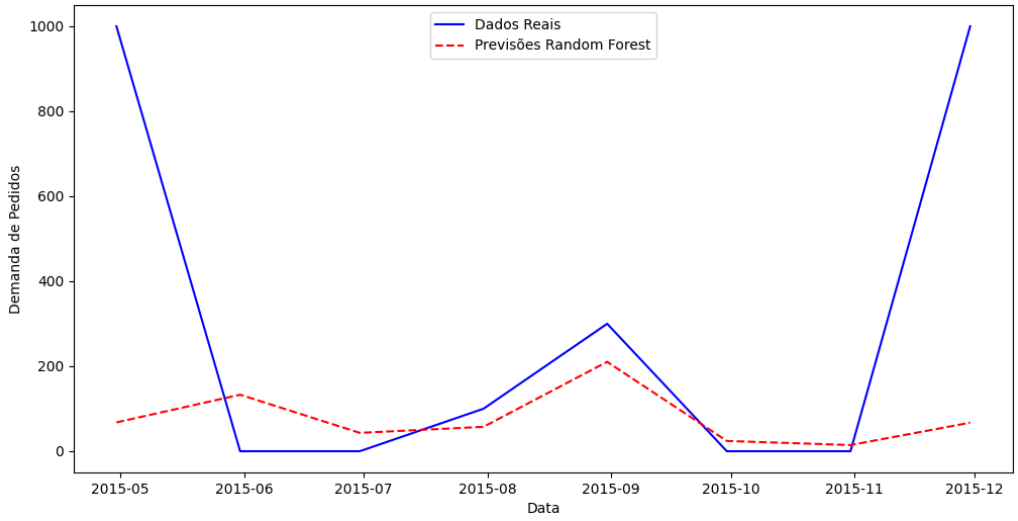

Fonte: Autor (2024)

Neste gráfico, o modelo de Floresta Aleatória tenta prever os picos e vales combinando múltiplas árvores de decisão. Os picos indicam eventos de alta demanda que o modelo capta parcialmente, sugerindo que ele consegue identificar padrões, mas pode perder detalhes importantes quando as variações são muito acentuadas. Os vales são mais previsíveis, mas o modelo pode apresentar sobreajuste, respondendo de maneira exagerada a oscilações menores.

Após a implementação do modelo *Random Forest*, foram calculados, o MSE que foi de 221.151,52, o que indica que a média dos quadrados dos erros de previsão foi relativamente alta, sugerindo que o modelo apresentou algumas variações significativas em suas previsões. O MAE foi de 276,49, indicando que, em média, as previsões estavam a cerca de 276 unidades dos valores reais. Esses resultados mostram que, apesar do *Random Forest* ter capturado alguns padrões da demanda, há espaço para melhorar a precisão das previsões, possivelmente ajustando os hiper parâmetros do modelo ou explorando outras técnicas de modelagem para obter melhores resultados.

4.8 GRADIENT BOOSTING MACHINES

Para a previsão da demanda de pedidos, foi aplicado um modelo de *Gradient Boosting Machines* (GBM, Máquinas de aumento de gradiente) utilizando a biblioteca "*Scikit-learn*" no ambiente de desenvolvimento *VISUAL STUDIO CODE* com *Python* (Conforme Apêndice H). O GBM é uma técnica de aprendizado de máquina que combina múltiplos modelos de árvores de decisão para melhorar a precisão das previsões e reduzir o risco de *overfitting* (sobreajuste). O modelo foi treinado com dados históricos de demanda e validado com um conjunto de dados separado para prever a demanda futura. As previsões obtidas foram comparadas com os dados reais para avaliar o desempenho do modelo.

A Figura 15, mostra as previsões feitas pelo modelo de *Gradient Boosting Machines* (GBM) em comparação com os valores reais de demanda. O gráfico destaca a capacidade do GBM de melhorar a precisão das previsões ao combinar múltiplos modelos de árvores de decisão, ajustando os erros de previsões anteriores para oferecer projeções mais confiáveis.

Figura 15 - Demanda de pedidos e *gradiente boosting machines*

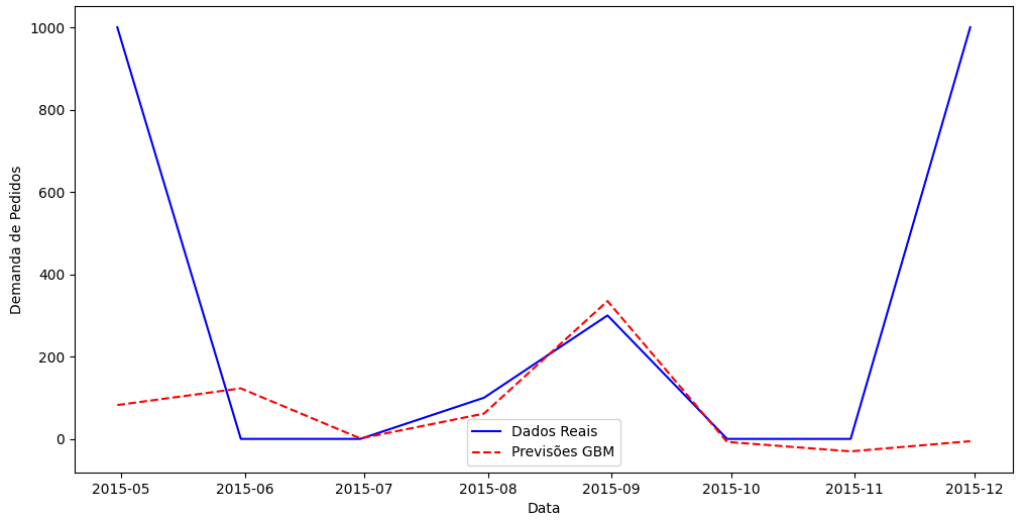

Fonte: Autor (2024)

O modelo GBM, ao combinar múltiplas árvores de decisão de forma sequencial, se esforça para reduzir o erro nas previsões, ajustando os parâmetros a cada iteração. Os picos indicam períodos de alta demanda que o modelo captura com certa precisão, mas ainda com algumas dificuldades em prever a magnitude exata, especialmente em casos de picos extremos. Os vales, por sua vez, mostram momentos de baixa demanda que o GBM consegue prever razoavelmente bem, mas com leve tendência a suavizar demais os pontos de inflexão bruscos.

Após a implementação do modelo GBM, foram calculadas as métricas de desempenho para avaliar a precisão das previsões. O MSE obtido foi de 234.020,56, indicando que a média dos quadrados dos erros de previsão foi relativamente alta, sugerindo que o modelo teve dificuldades em capturar todas as variações na demanda de forma precisa. O MAE foi de 269,77, o que indica que, em média, as previsões estavam a cerca de 270 unidades dos valores reais. Esses resultados mostram que, embora o modelo GBM tenha apresentado uma performance aceitável, ainda há espaço para melhorias, possivelmente ajustando os parâmetros do modelo ou explorando outras técnicas para obter previsões mais precisas.

4.9 ANÁLISE COMPARATIVA

A Figura 16 apresenta um quadro comparativo dos resultados obtidos com diferentes modelos de previsão de demanda utilizados na análise deste estudo. São considerados os principais indicadores de desempenho, como o Erro Médio Absoluto

(MAE) e o Erro Médio Quadrático (RMSE), além das características específicas, vantagens e desvantagens de cada modelo. O objetivo deste comparativo é fornecer uma visão clara e objetiva das capacidades de cada método, destacando as limitações e os pontos fortes em termos de captura de padrões sazonais, tendências de longo prazo e variações abruptas na demanda. Essa análise permite identificar o modelo mais adequado para a previsão de demanda no contexto industrial estudado, facilitando a tomada de decisões mais assertivas na gestão de estoques e no planejamento de produção.

Figura 16 - Comparativo dos Resultados dos Modelos de Previsão de Demanda

Modelo	Erro Médio Absoluto (MAE)	Erro Médio Quadrático (RMSE)	Principais Características	Vantagens	Desvantagens
Média Móvel Simples	684,02	970,06	Suaviza a série temporal considerando uma média dos períodos anteriores.	Simples de implementar e entender.	Dificuldade em capturar variações bruscas na demanda.
Suavização Exponencial Simples	757,22	1.073,82	Atribui maior peso aos dados mais recentes, ajustando rapidamente a novas tendências.	Reage mais rápido a mudanças recentes na demanda.	Sensível a oscilações aleatórias, alto RMSE.
ARIMA	1.686,75	3.885,91	Captura padrões sazonais e tendências de longo prazo através de modelos autoregressivos e médias móveis integradas.	Bom para séries com sazonalidade e tendências.	Complexo de ajustar e não lida bem com variações extremas.
Regressão Linear	901,14	1.451,07	Modela a relação linear entre o tempo e a demanda.	Fácil de interpretar e implementar.	Incapaz de capturar padrões não lineares complexos.
SARIMA (Sazonal)	308,34	216,64	Extensão do ARIMA que considera sazonalidade explícita na série temporal.	Eficaz em identificar e prever padrões sazonais.	Pode falhar com dados altamente voláteis.
Redes Neurais LSTM	206,58	131,67	Captura padrões complexos e dependências temporais usando redes neurais recorrentes.	Excelentes resultados em séries com padrões não lineares.	Requer muitos dados para treinamento e é computacionalmente intensivo.
Floresta Aleatória	276,49	221,15	Combina várias árvores de decisão para prever a demanda, reduzindo o risco de overfitting.	Boa capacidade de generalização e redução de overfitting.	Pode ser influenciado por variáveis irrelevantes.
Gradient Boosting Machines (GBM)	269,77	234,02	Constrói o modelo de forma iterativa, otimizando a função de perda a cada passo.	Alta precisão, bom para conjuntos de dados complexos.	Risco de sobreajuste se não configurado adequadamente.

Fonte: Autor (2024)

Melhor Desempenho Geral: As Redes Neurais LSTM apresentaram o menor erro absoluto (MAE = 206,58) e erro médio quadrático (RMSE = 131,67), indicando

que são mais eficazes em capturar padrões complexos e previsões precisas, especialmente em séries temporais não lineares e com variações significativas.

- Modelos Tradicionais: Tanto a Média Móvel Simples quanto a Suavização Exponencial apresentaram resultados moderados, adequados para suavizar as flutuações, mas com altos valores de erro quando comparados a técnicas mais avançadas. Esses métodos são mais indicados para séries temporais com poucos picos ou variações bruscas.
- Modelos Estatísticos: O ARIMA mostrou-se útil para séries com tendência e sazonalidade, mas com dificuldades em lidar com grandes variações e eventos inesperados. O SARIMA teve desempenho superior ao ARIMA em termos de captura de sazonalidade, mas ainda assim limitado para dados altamente voláteis.
- Modelos de Aprendizado de Máquina: Florestas Aleatórias e GBM apresentaram bons resultados com baixo risco de sobreajuste, sendo indicados para conjuntos de dados com múltiplas variáveis influenciando a demanda. No entanto, o GBM mostrou uma ligeira superioridade na precisão.

Com base nos resultados apresentados, o modelo de Redes Neurais LSTM é o mais indicado. Isso se deve ao fato de que ele conseguiu capturar de forma eficaz as complexidades e dependências temporais da série de demanda, apresentando os menores valores de erro (MAE e RMSE) entre todos os modelos testados. Essa capacidade de lidar com padrões não lineares e a flexibilidade na modelagem de dependências temporais complexas tornam o LSTM ideal para séries temporais de demanda com grandes flutuações e alta complexidade, como no contexto industrial analisado

4.10 RECOMENDAÇÕES

Com base nos resultados obtidos e na análise comparativa dos modelos de previsão de demanda, podem ser apresentadas as seguintes recomendações para a escolha e implementação de técnicas preditivas na gestão de estoques:

- Empresas que enfrentam alta variabilidade e padrões não lineares na demanda, recomenda-se o uso de modelos baseados em Redes Neurais LSTM. Esse modelo mostrou-se superior na captura de dependências temporais e padrões complexos, proporcionando previsões mais precisas. No entanto, devido ao alto custo computacional e à necessidade de um grande volume de dados históricos, é essencial avaliar a viabilidade técnica e operacional antes de sua implementação.
- A combinação de diferentes modelos, como SARIMA para sazonalidade e redes neurais para captura de padrões não lineares, pode aumentar a acurácia das previsões. Modelos híbridos permitem aproveitar as vantagens específicas de cada técnica, minimizando as limitações individuais e oferecendo uma visão mais robusta da demanda futura.
- A demanda pode ser influenciada por fatores externos imprevisíveis, como mudanças econômicas ou comportamentais. Assim, é crucial realizar ajustes periódicos nos modelos de previsão, revisando parâmetros e incorporando novos dados de forma contínua. A reavaliação constante dos modelos garante que eles permaneçam relevantes e eficazes em diferentes cenários.
- A incorporação de dados externos, como indicadores econômicos, tendências de mercado e informações climáticas, pode enriquecer os modelos de previsão. O uso de dados complementares melhora a capacidade preditiva e permite um planejamento mais estratégico, especialmente para setores que sofrem grandes impactos de fatores externos.
- Ao falar sobre a questão de treinamento e capacitação da equipe, pode-se implementar modelos avançados de previsão requer conhecimento técnico especializado. Investir no treinamento e na capacitação da equipe envolvida na análise de dados e na tomada de decisões é fundamental para garantir o sucesso na aplicação dessas técnicas. A equipe deve estar apta a interpretar os resultados e ajustar os modelos conforme necessário.
- A adoção de sistemas automatizados para monitoramento contínuo das previsões e ajuste dos modelos em tempo real pode reduzir

significativamente os erros e otimizar a gestão de estoques. Tecnologias como *machine learning* e inteligência artificial integradas a sistemas de gestão empresarial (ERP) possibilitam a atualização automática dos modelos conforme novos dados são gerados.

- Antes de implementar modelos complexos, é necessário realizar uma avaliação de custo-benefício. Para empresas com baixa variabilidade na demanda ou com dados limitados, modelos mais simples, como Média Móvel Simples ou Suavização Exponencial, podem ser suficientes e economicamente mais viáveis. A escolha do modelo deve sempre considerar o contexto operacional e as necessidades específicas da empresa.

Inicialmente, os modelos tradicionais como médias móveis e suavização exponencial demonstraram limitações significativas em termos de precisão, com altos valores de erro médio absoluto (MAE) e erro médio quadrático (RMSE). Embora tenham contribuído para suavizar flutuações, a sua capacidade de prever demanda com maior acurácia foi limitada, especialmente em contextos de alta sazonalidade e ciclos de demanda.

Entre os modelos mais avançados, o ARIMA mostrou-se eficaz em capturar padrões sazonais e tendências de longo prazo, mas ainda apresentou variações consideráveis quando aplicado a dados mais complexos, resultando em uma performance moderada. Por outro lado, o uso de técnicas de aprendizado de máquina, como redes neurais artificiais e florestas aleatórias, apresentou resultados mais promissores, com reduções significativas nos valores de erro. Especificamente, o modelo LSTM mostrou-se eficiente na captura de padrões temporais complexos, proporcionando previsões mais precisas em comparação aos modelos tradicionais e até mesmo ao ARIMA.

Além disso, o *Gradient Boosting Machines* (GBM) destacou-se por sua robustez e capacidade de ajuste fino, embora tenha apresentado desafios na modelagem de grandes variações na demanda. Entre os modelos testados, o GBM e as redes neurais demonstraram ser os mais promissores para a previsão de demanda no contexto industrial, proporcionando uma base sólida para a tomada de decisões mais precisas e eficientes na gestão de estoques.

Em conclusão, a aplicação de técnicas avançadas, especialmente as baseadas em aprendizado de máquina, mostrou-se superior às abordagens tradicionais, permitindo uma melhor adaptação às necessidades dinâmicas da indústria de manufatura. A adoção desses modelos pode proporcionar uma gestão de estoques mais eficiente, com redução de custos operacionais, melhoria no atendimento ao cliente e otimização do uso de recursos. Para empresas que buscam aprimorar suas operações, a integração dessas metodologias avançadas de previsão representa uma oportunidade valiosa de inovação e competitividade no mercado.

CONCLUSÃO

A gestão eficiente de estoques é um dos pilares fundamentais para a competitividade e sustentabilidade das empresas, especialmente no contexto industrial. Ela impacta diretamente a capacidade de atendimento ao cliente, a eficiência operacional e a saúde financeira da organização. Manter o equilíbrio ideal entre oferta e demanda, evitando tanto a falta quanto o excesso de produtos, é crucial para reduzir custos com armazenagem, minimizar desperdícios e otimizar o fluxo de caixa. Nesse sentido, a adoção de técnicas avançadas de previsão de demanda permite às empresas antever com maior precisão as flutuações do mercado, ajustar a produção e o abastecimento de forma proativa, garantindo uma gestão de estoques mais eficaz e estratégica.

O objetivo geral deste estudo foi analisar e comparar diferentes técnicas avançadas de previsão de demanda para aprimorar a gestão de estoques na indústria de manufatura. Para isso, foram avaliados modelos tradicionais e métodos baseados em aprendizado de máquina, como ARIMA, Redes Neurais LSTM, Florestas Aleatórias e *Gradient Boosting Machines* (GBM). Os resultados mostraram que, embora modelos tradicionais possam oferecer uma visão inicial sobre a demanda, são as técnicas avançadas, especialmente as redes neurais, que apresentam maior precisão em contextos de alta variabilidade e complexidade nos dados. Assim, o estudo atingiu seu objetivo ao identificar e validar a superioridade dos modelos avançados para melhorar a acurácia das previsões e, consequentemente, a gestão de estoques.

Em resposta à questão central do estudo, "Como a gestão de estoque pode ser melhorada aplicando técnicas avançadas de previsão de demanda na indústria?", conclui-se que a implementação de modelos como Redes Neurais LSTM, aliados a uma estratégia híbrida que integre diferentes técnicas preditivas, é a abordagem mais eficaz. Esses modelos são capazes de capturar padrões sazonais e comportamentos complexos dos consumidores, proporcionando uma base sólida para a tomada de decisões estratégicas e táticas na gestão de estoques.

A hipótese de que a aplicação de técnicas avançadas de previsão de demanda, como modelos estatísticos, algoritmos de aprendizado de máquina e análise de séries temporais, resultaria em benefícios significativos para a gestão de estoques na indústria foi aceita. O estudo demonstrou que modelos avançados, como LSTM e

GBM, apresentaram melhores resultados em termos de precisão das previsões e eficiência na gestão de estoques, em comparação aos métodos tradicionais.

A hipótese de que os modelos de aprendizado de máquina apresentariam valores mais assertivos na previsão de demanda em comparação aos modelos tradicionais da estatística também foi aceita. As redes neurais LSTM e o GBM superaram métodos tradicionais, como Média Móvel e ARIMA, na captura de padrões complexos e na previsão de demanda com maior acurácia.

Por fim, a hipótese de que a análise de séries temporais permitiria identificar padrões sazonais e tendências de demanda de forma mais eficaz, contribuindo para a gestão de estoque, foi confirmada. O modelo SARIMA mostrou-se eficaz na identificação de sazonalidade e ciclos, sendo valioso para prever padrões repetitivos e melhorar a gestão de estoques.

Uma das principais limitações deste estudo foi a falta de aplicação prática das técnicas de previsão de demanda em um case real de uma empresa. Embora os modelos tenham sido validados com dados históricos, a implementação em um ambiente real poderia fornecer insights adicionais sobre desafios operacionais, como a integração com sistemas de gestão e a aceitação das previsões pelos gestores.

Nesse sentido, para trabalhos futuros, recomenda-se a realização de um estudo de caso em uma empresa específica, aplicando as técnicas preditivas avaliadas neste trabalho. Isso permitiria validar a eficácia dos modelos em um contexto real, considerando as particularidades do negócio e os impactos financeiros na gestão de estoques. Além disso, a investigação de abordagens híbridas que combinem técnicas de aprendizado de máquina com fatores externos, como dados econômicos e de mercado, poderia enriquecer ainda mais a precisão das previsões e a tomada de decisões estratégicas.

Pesquisas futuras podem ainda explorar a integração de diferentes modelos preditivos para criar abordagens híbridas que combinem a robustez dos métodos estatísticos tradicionais com a flexibilidade dos algoritmos de aprendizado de máquina. Além disso, um estudo aprofundado sobre a personalização de modelos para diferentes setores da indústria pode oferecer insights valiosos sobre a adaptação dessas técnicas a diferentes padrões de demanda. Outra possibilidade seria investigar o impacto do uso de dados externos, como informações de mercado e macroeconômicas, na melhoria da acurácia dos modelos de previsão, bem como

avaliar a viabilidade de implementações em tempo real para a gestão de estoques dinâmicos.

REFERÊNCIAS

ANALYTICS INSIGHT. ***Data Analysis with Python: Using Pandas, NumPy, and Matplotlib***. Disponível em: https://www.analyticsinsight.net. Acesso em: 7 dez. 2024.

ANDRADE, W.; MIRANDA, L.; ACHIDA, T. **Tipos de Previsão de Demanda e a Aplicação em Indústria Automotiva Paulista**. *Revista FATEC*, [S.l.]., 2017.

ARMSTRONG, J. S. ***Principles of Forecasting: A Handbook for Researchers and Practitioners***. [S.l.]: Kluwer Academic Publishers, 2001.

BALLOU, R. H. ***Gerenciamento da Cadeia de Suprimentos: Planejamento, Organização e Logística Empresarial***. Tradução Elias Pereira. 5ª ed. Porto Alegre: Bookman, 2006.

BONOTTO, G.; FOGLIATTO, F. **Previsão de Demanda a partir de Métodos Quantitativos aplicada ao Setor Varejista**, UFRGS, (2015). Disponível em: https://lume.ufrgs.br/bitstream/handle/10183/147496/000999425.pdf?sequence=1#, Acesso em: 6 set. 2023.

CHASE, R. B.; AQUILANO, N. J. ***Administração da Produção para a Vantagem Competitiva***. Porto Alegre: Bookman, 2006.

CHOPRA, S.; MEINDL, P. ***Gerenciamento da Cadeia de Suprimentos: Estratégia, Planejamento e Operação***. São Paulo: Pearson, 2016.

CONSUL, F. B.; WERNER, L. **Avaliação de Técnicas de Previsão de Demanda Utilizadas por um *Software* de Gerenciamento de Estoques no Setor Farmacêutico**. In: XXX Encontro Nacional de Engenharia de Produção, São Carlos, out. 2010. Disponível em: http://www.abepro.org.br/biblioteca/enegep2010_tn_sto_113_740_15746.pdf. Acesso em: 06 set. 2023.

CRESWELL, John W.; CRESWELL, J D. ***Projeto de Pesquisa: Métodos Qualitativo, Quantitativo e Misto***. Porto Alegre. Grupo A, 2021. E-book. ISBN 9786581334192. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9786581334192/. Acesso em: 17 set. 2023.

DEV BLOGS MICROSOFT. ***Data Science with Python in Visual Studio Code***. Disponível em: https://devblogs.microsoft.com. Acesso em: 7 dez. 2024.

DIAS, M. A. P. **Administração de Materiais: Uma Abordagem Logística**. 5ª ed. São Paulo: Atlas, 2010.

HAYKIN, Simon. ***Redes Neurais: Princípios e Prática***. Porto Alegre Grupo A, 2001. E-book. ISBN 9788577800865. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788577800865/. Acesso em: 08 set. 2023.

HEIZER, Jay; RENDER, Barry. **Administração de Operações: Bens e Serviços.** 5ª ed. Rio de Janeiro: LTC, 2001.

LAKATOS, Eva M. **Fundamentos de Metodologia Científica**. Rio de Janeiro. Grupo GEN, 2021. E-book. ISBN 9788597026580. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788597026580/. Acesso em: 17 set. 2023.

LAUGENI, Fernando P.; Petrônio Garcia. **Administração da Produção**. Rio de Janeiro. Editora Saraiva, 2015. E-book. ISBN 9788502618367. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788502618367/. Acesso em: 02 set. 2023.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. ***Forecasting: Methods and Applications.*** John Wiley & Sons, 1998. Disponível em: https://www.researchgate.net/publication/52008212_Forecasting_Methods_and_Applications Acesso em 29 ago. 2024

MENTZER, J. T.; MOON, M. A.; SMITH, C. D**.** "***Managing Supply Chain Relationships***." *California Management Review*, 44(3), 24-42, 2001. Disponível em: https://edisciplinas.usp.br/pluginfile.php/5858988/mod_resource/content/1/CASE10_LEITURA%201.pdf Acesso em 29 ago. 2024.

MICHEL, Maria Helena. **Metodologia e Pesquisa Científica em Ciências Sociais: Um Guia Prático para Acompanhamento da Disciplina e Elaboração de Trabalhos Monográficos**. 3ª ed. São Paulo: Atlas, 2015.

MICROSOFT**. Data Science with *Python* in *VISUAL STUDIO CODE* | *Python***. Disponível em: <https://devblogs.microsoft.com/*Python*/data-science-with-*Python*-in-visual-studio-code/>. Acesso em: 25 abr. 2019.

MORETTIN, Pedro A. **Análise de Séries Temporais**. São Paulo. Editora Blucher, 2018. E-book. ISBN 9788521213529. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788521213529/. Acesso em: 08 set. 2023.

NETTO, Amilcar; MACIEL, Francisco. ***Python para Data Science e Machine learning* Descomplicado**. Rio de Janeiro. Editora Alta Books, 2021. E-book. ISBN 9786555203172. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9786555203172/. Acesso em: 07 set. 2023.

O que são Redes Neurais? | IBM. Ibm.com. Disponível em: https://www.ibm.com/br-pt/topics/neural-networks. Acesso em: 14 set. 2023.

PELLEGRINI, F. R.; FOGLIATTO, F. S. **Passos para Implantação de Sistemas de Previsão de Demanda - Técnicas e Estudo de Caso**. *Revista Produção*, v. 11, n. 1, p. 43-64, 2001.

PRODANOV, Cleber Cristiano; FREITAS, Ernani Cesar de. **Metodologia do Trabalho Científico: Métodos e Técnicas da Pesquisa e do Trabalho Acadêmico. 2ª ed**. [S. l.: s. n.], 2013. Disponível em:

https://www.feevale.br/institucional/editora-feevale/metodologia-do-trabalho-cientifico---2-edicao. Acesso em: 17 set. 2023.

RIBEIRO, Túlio Rodrigues; DE OLIVEIRA, Francisco Heber Lacerda. "**Desenvolvimento de Modelos de Previsão de Coeficiente de Atrito em Pistas de Pouso e Decolagem Brasileiras com Redes Neurais Artificiais**." *Transportes*, v. 31, n. 2, p. e2792, 2023.

SACRAMENTO, Gabriel. "**Árvore de Decisão: Entenda Esse Algoritmo de *Machine learning*.**" *Terra Blog*. Disponível em: https://blog.somostera.com/data-science/arvores-de-decisao. Acesso em: 8 set. 2023.

SANTOS, João A.; FILHO, Domingos P. **Metodologia Científica***.* São Paulo. Cengage Learning Brasil, 2012. E-book. ISBN 9788522112661. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788522112661/. Acesso em: 21 set. 2023.

SATURN CLOUD. ***How to Install Pandas into Visual Studio Code***. Disponível em: https://saturncloud.io. Acesso em: 7 dez. 2024.

SICSÚ, Abraham L.; SAMARTINI, André; BARTH, Nelson L. **Técnicas de *machine learning***. São Paulo: Editora Blucher, 2023. E-book. ISBN 9786555063974. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9786555063974/. Acesso em: 17 set. 2024.

SILVER, E. A.; PYKE, D. F.; PETERSON, R. ***Inventory Management and Production Planning and Scheduling****.* John Wiley & Sons, 1998.

SLACK, Nigel; BRANDON-JONES, Alistair; BURGESS, Nicola. **Administração da Produção***.* Rio de Janeiro. Grupo GEN, 2023. E-book. ISBN 9786559775187. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9786559775187/. Acesso em: 01 set. 2023.

SOUSA, Alex R S.; SILVA, Cristiane; SILVA, Juliane S F.; et al. **Análise de Séries Temporais***.* Porto Alegre. Grupo A, 2021. E-book. ISBN 9786556902876. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9786556902876/. Acesso em: 08 set. 2023.

TUBINO, Dalvio F**. Planejamento e Controle da Produção - Teoria e Prática, 3ª edição**. Rio de Janeiro. Grupo GEN, 2017. E-book. ISBN 9788597013726. Disponível em: https://integrada.minhabiblioteca.com.br/#/books/9788597013726/. Acesso em: 18 ago. 2023.

WERNER, L.; LEMOS, F. de O.; DAUDT, T**. Previsão de Demanda e Níveis de Estoque: uma Abordagem Conjunta Aplicada no Setor Siderúrgico**. In: XIII SIMPEP, Bauru, nov. 2006.

APENDICE A – Código ARIMA

```
import Pandas as pd
import matplotlib.pyplot as plt
import statsmodels.api as sm
from statsmodels.tsa.statespace.sarimax import SARIMAX
from sklearn.metrics import mean_squared_error
data = pd.read_csv('dadostfc.csv')
print(data.head())
print(data.columns)
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
print(data_grouped.head())
decomposicao = sm.tsa.seasonal_decompose(data_grouped['Order_Demand'], model='additive')
decomposicao.plot()
plt.show()
p, d, q = 1, 1, 1
P, D, Q, S = 1, 1, 1, 7
modelo = SARIMAX(data_grouped['Order_Demand'],
                 order=(p, d, q),
                 seasonal_order=(P, D, Q, S))
resultado = modelo.fit()
print(resultado.summary())
previsao = resultado.get_forecast(steps=12)
previsao_df = previsao.summary_frame()
plt.figure(figsize=(10, 6))
plt.plot(data_grouped.index, data_grouped['Order_Demand'], label='Dados Reais')

plt.plot(previsao_df.index, previsao_df['mean'], color='red', label='Previsão')
plt.fill_between(previsao_df.index, previsao_df['mean_ci_lower'], previsao_df['mean_ci_upper'], color='red', alpha=0.3)
plt.legend()
plt.show()
predicoes = resultado.fittedvalues
mse = mean_squared_error(data_grouped['Order_Demand'], predicoes)
print(f'MSE: {mse}')
```

APENDICE B - Código Média Móvel Simples

```
import Pandas as pd
import NumPy as np
import matplotlib.pyplot as plt
from sklearn.metrics import mean_squared_error, mean_absolute_error
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data.set_index('Date', inplace=True)
data = data.sort_index()
window_size = 12
data['MMS'] = data['Order_Demand'].rolling(window=window_size).mean()
data = data.dropna()
y_true = data['Order_Demand']
y_pred = data['MMS']
rmse = np.sqrt(mean_squared_error(y_true, y_pred))
mae = mean_absolute_error(y_true, y_pred)
print(f'RMSE: {rmse}')
print(f'MAE: {mae}')
plt.figure(figsize=(12, 6))
plt.plot(data.index, data['Order_Demand'], label='Demanda Real', color='blue')
plt.plot(data.index, data['MMS'], label='Média Móvel Simples', color='red', linestyle='--')
plt.xlabel('Data')
plt.ylabel('Demanda de Pedidos')
plt.title('Demanda de Pedidos e Média Móvel Simples')
plt.legend()
plt.show()
```

APENDICE C – Código Suavização Exponencial Simples

```
import Pandas as pd
import NumPy as np
import matplotlib.pyplot as plt
from statsmodels.tsa.api import ExponentialSmoothing
from sklearn.metrics import mean_squared_error, mean_absolute_error
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data.set_index('Date', inplace=True)
data = data.sort_index()
model = ExponentialSmoothing(data['Order_Demand'], trend=None, seasonal=None, initialization_method='estimated')
fit = model.fit(smoothing_level=0.2)
data['SES'] = fit.fittedvalues
data = data.dropna()
y_true = data['Order_Demand']
y_pred = data['SES']
rmse = np.sqrt(mean_squared_error(y_true, y_pred))
mae = mean_absolute_error(y_true, y_pred)
print(f'RMSE: {rmse}')
print(f'MAE: {mae}')
plt.figure(figsize=(12, 6))
plt.plot(data.index, data['Order_Demand'], label='Demanda Real', color='blue')
plt.plot(data.index, data['SES'], label='Suavização Exponencial Simples', color='red', linestyle='--')
plt.xlabel('Data')
plt.ylabel('Demanda de Pedidos')
plt.title('Demanda de Pedidos e Suavização Exponencial Simples')
plt.legend()
plt.show()
```

APENDICE D – Código Regressão Linear

```
import Pandas as pd
import matplotlib.pyplot as plt
import statsmodels.api as sm
from sklearn.metrics import mean_squared_error, mean_absolute_error
data = pd.read_csv('dadostfc.csv', delimiter=';')
print("Primeiras linhas do DataFrame:")
print(data.head())
print("\nNomes das colunas:")
print(data.columns)
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
data_grouped['Time'] = range(len(data_grouped))
train = data_grouped.loc[:'2014-12-31', 'Order_Demand']
test = data_grouped.loc['2015-01-01':, 'Order_Demand']
X_train = train.index.to_julian_date().to_series().reset_index(drop=True).rename('Time')
X_train = sm.add_constant(X_train)
y_train = train.values
modelo = sm.OLS(y_train, X_train).fit()
print(modelo.summary())
X_test = test.index.to_julian_date().to_series().reset_index(drop=True).rename('Time')
X_test = sm.add_constant(X_test)
previsoes = modelo.predict(X_test)
test_df = pd.DataFrame({
    'Date': test.index,
    'Order_Demand': test.values,
    'Previsao': previsoes
})

plt.figure(figsize=(10, 6))
plt.plot(test_df['Date'], test_df['Order_Demand'], label='Dados Reais', color='blue')
plt.plot(test_df['Date'], test_df['Previsao'], label='Previsões', color='red', linestyle='--')
plt.xlabel('Data')
plt.ylabel('Demanda de Pedidos')
plt.legend()
plt.show()
mse = mean_squared_error(test_df['Order_Demand'], test_df['Previsao'])
mae = mean_absolute_error(test_df['Order_Demand'], test_df['Previsao'])
print(f'MSE: {mse}')
print(f'MAE: {mae}')
```

APENDICE E – Código SARIMA

```
import Pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.seasonal import seasonal_decompose
from statsmodels.graphics.tsaplots import plot_acf, plot_pacf
from statsmodels.tsa.statespace.sarimax import SARIMAX
from sklearn.metrics import mean_squared_error, mean_absolute_error
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
data_grouped = data_grouped.asfreq('M', fill_value=0)
data_grouped = data_grouped.fillna(0)
data_grouped = data_grouped[['Order_Demand']]
plt.figure(figsize=(12, 6))
plt.plot(data_grouped.index, data_grouped['Order_Demand'], label='Demanda de Pedidos')
plt.xlabel('Data')
plt.ylabel('Demanda')
plt.title('Série Temporal da Demanda de Pedidos')
plt.legend()
plt.show()
decomposition = seasonal_decompose(data_grouped, model='additive')
decomposition.plot()
plt.show()
max_lags = len(data_grouped) // 2


plt.figure(figsize=(12, 6))
plot_acf(data_grouped['Order_Demand'], lags=min(40, max_lags), ax=plt.gca())
plt.title('Função de Autocorrelação (ACF)')
plt.show()
plt.figure(figsize=(12, 6))
plot_pacf(data_grouped['Order_Demand'], lags=min(40, max_lags), ax=plt.gca())
plt.title('Função de Autocorrelação Parcial (PACF)')
plt.show()
train = data_grouped.loc[:'2014-12-31', 'Order_Demand']
test = data_grouped.loc['2015-01-01':, 'Order_Demand']
sarima_model = SARIMAX(train,
                       order=(1, 1, 1)
                       seasonal_order=(1, 1, 1, 12)
                       ).fit()
print(sarima_model.summary())
forecast = sarima_model.get_forecast(steps=len(test))
forecast_index = test.index
forecast_values = forecast.predicted_mean
forecast_conf_int = forecast.conf_int()
test_df = pd.DataFrame({
    'Date': forecast_index,
    'Order_Demand': test.values,
    'Previsao': forecast_values
})
test_df = test_df.set_index('Date')
plt.figure(figsize=(12, 6))
```

```
        plt.plot(data_grouped.index, data_grouped['Order_Demand'], label='Dados Reais')
        plt.plot(forecast_index, forecast_values, color='red', linestyle='--', label='Previsões SARIMA')
        plt.fill_between(forecast_index, forecast_conf_int.iloc[:, 0], forecast_conf_int.iloc[:, 1], color='red', alpha=0.3)
        plt.xlabel('Data')
        plt.ylabel('Demanda de Pedidos')
        plt.title('Previsões SARIMA vs Dados Reais')
        plt.legend()
        plt.show()
        mse = mean_squared_error(test_df['Order_Demand'], test_df['Previsao'])
        mae = mean_absolute_error(test_df['Order_Demand'], test_df['Previsao'])
        print(f'MSE: {mse}')
        print(f'MAE: {mae}')
```

APENDICE F – Código Redes Neurais Artificiais

```
import NumPy as np
import Pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
import TensorFlow as tf
from TensorFlow.Keras.models import Sequential
from TensorFlow.Keras.layers import LSTM, Dense
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
data_grouped = data_grouped.asfreq('M', fill_value=0)
data_grouped = data_grouped.fillna(0)
data_grouped = data_grouped[['Order_Demand']]
scaler = MinMaxScaler(feature_range=(0, 1))
scaled_data = scaler.fit_transform(data_grouped)
def create_Dataset(data, time_step=1):
    X, y = [], []
    for i in range(len(data) - time_step - 1):
        X.append(data[i:(i + time_step), 0])
        y.append(data[i + time_step, 0])
    return np.array(X), np.array(y)
time_step = 12
X, y = create_Dataset(scaled_data, time_step)
X_train, y_train = X[:int(len(X) * 0.8)], y[:int(len(y) * 0.8)]
X_test, y_test = X[int(len(X) * 0.8):], y[int(len(y) * 0.8):]
X_train = X_train.reshape(X_train.shape[0], X_train.shape[1], 1)
X_test = X_test.reshape(X_test.shape[0], X_test.shape[1], 1)
model = Sequential()
model.add(LSTM(50, return_sequences=True, input_shape=(time_step, 1)))
model.add(LSTM(50, return_sequences=False))
model.add(Dense(1))
model.compile(optimizer='adam', loss='mean_squared_error')
history = model.fit(X_train, y_train, epochs=50, batch_size=32, validation_split=0.1, verbose=1)
predictions = model.predict(X_test)
predictions = scaler.inverse_transform(predictions)
y_test = scaler.inverse_transform([y_test])
mse = mean_squared_error(y_test[0], predictions)
mae = mean_absolute_error(y_test[0], predictions)
print(f'MSE: {mse}')
print(f'MAE: {mae}')
plt.figure(figsize=(12, 6))
```

```
        test_dates = data_grouped.index[-len(y_test[0]):]
        plt.plot(test_dates, y_test[0], label='Dados Reais', color='blue')
        plt.plot(test_dates, predictions, color='red', linestyle='--', label='Previsões LSTM')
        plt.xlabel('Data')
        plt.ylabel('Demanda de Pedidos')
        plt.title('Previsões LSTM vs Dados Reais')
        plt.legend()
        plt.show()
```

APENDICE G – Código Floresta Aleatória

```
import NumPy as np
import Pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from sklearn.ensemble import RandomForestRegressor
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
data_grouped = data_grouped.asfreq('M', fill_value=0)
data_grouped = data_grouped.fillna(0)
data_grouped = data_grouped[['Order_Demand']]
scaler = MinMaxScaler(feature_range=(0, 1))
scaled_data = scaler.fit_transform(data_grouped)
def create_Dataset(data, time_step=1):
    X, y = [], []
    for i in range(len(data) - time_step):
        X.append(data[i:(i + time_step), 0])
        y.append(data[i + time_step, 0])
    return np.array(X), np.array(y)
time_step = 12
X, y = create_Dataset(scaled_data, time_step)
X_train, y_train = X[:int(len(X) * 0.8)], y[:int(len(y) * 0.8)]
X_test, y_test = X[int(len(X) * 0.8):], y[int(len(y) * 0.8):]
X_train = X_train.reshape(X_train.shape[0], -1)
X_test = X_test.reshape(X_test.shape[0], -1)
model = RandomForestRegressor(n_estimators=100, random_state=42)
model.fit(X_train, y_train)
predictions = model.predict(X_test)
predictions = scaler.inverse_transform(predictions.reshape(-1, 1))
y_test = scaler.inverse_transform(y_test.reshape(-1, 1))
mse = mean_squared_error(y_test, predictions)
mae = mean_absolute_error(y_test, predictions)
print(f'MSE: {mse}')
print(f'MAE: {mae}')
plt.figure(figsize=(12, 6))
test_dates = data_grouped.index[-len(y_test):]
plt.plot(test_dates, y_test, label='Dados Reais', color='blue')
plt.plot(test_dates, predictions, color='red', linestyle='--', label='Previsões Random Forest')
plt.xlabel('Data')
plt.ylabel('Demanda de Pedidos')
plt.title('Previsões Random Forest vs Dados Reais')
plt.legend()
plt.show()
```

APENDICE H – Código *Gradient Boosting Machines*

```
import NumPy as np
import Pandas as pd
import matplotlib.pyplot as plt
from sklearn.preprocessing import MinMaxScaler
from sklearn.metrics import mean_squared_error, mean_absolute_error
from sklearn.ensemble import GradientBoostingRegressor
data = pd.read_csv('dadostfc.csv', delimiter=';')
data['Date'] = pd.to_datetime(data['Date'], dayfirst=True)
data_grouped = data.groupby('Date').sum()
data_grouped = data_grouped.asfreq('M', fill_value=0)
data_grouped = data_grouped.fillna(0)
data_grouped = data_grouped[['Order_Demand']]
scaler = MinMaxScaler(feature_range=(0, 1))
scaled_data = scaler.fit_transform(data_grouped)
def create_Dataset(data, time_step=1):
    X, y = [], []
    for i in range(len(data) - time_step):
        X.append(data[i:(i + time_step), 0])
        y.append(data[i + time_step, 0])
    return np.array(X), np.array(y)
time_step = 12
X, y = create_Dataset(scaled_data, time_step)
X_train, y_train = X[:int(len(X) * 0.8)], y[:int(len(y) * 0.8)]
X_test, y_test = X[int(len(X) * 0.8):], y[int(len(y) * 0.8):]
X_train = X_train.reshape(X_train.shape[0], -1)
X_test = X_test.reshape(X_test.shape[0], -1)
model = GradientBoostingRegressor(n_estimators=100, learning_rate=0.1, max_depth=3, random_state=42)
model.fit(X_train, y_train)
predictions = model.predict(X_test)
predictions = scaler.inverse_transform(predictions.reshape(-1, 1))
y_test = scaler.inverse_transform(y_test.reshape(-1, 1))
mse = mean_squared_error(y_test, predictions)
mae = mean_absolute_error(y_test, predictions)
print(f'MSE: {mse}')
print(f'MAE: {mae}')
plt.figure(figsize=(12, 6))
test_dates = data_grouped.index[-len(y_test):]
plt.plot(test_dates, y_test, label='Dados Reais', color='blue')
plt.plot(test_dates, predictions, color='red', linestyle='--', label='Previsões GBM')
plt.xlabel('Data')
plt.ylabel('Demanda de Pedidos')
plt.title('Previsões GBM vs Dados Reais')
plt.legend()
plt.show()
```

APENDICE I – Dados utilizados nas previsões

Date	Order_Demand	Date2	Order_Demand3	Date4	Order_Demand5	Date6	Order_Demand7	Date8	Order_Demand9
16/12/2011	200	20/09/2012	100	03/07/2013	300	13/05/2014	100	03/02/2015	100
20/12/2011	100	01/10/2012	4000	09/07/2013	100	23/05/2014	1500	04/02/2015	600
03/01/2012	200	01/10/2012	300	11/07/2013	200	26/05/2014	3000	05/02/2015	300
03/01/2012	800	01/10/2012	200	15/07/2013	3000	28/05/2014	1000	06/02/2015	2000
04/01/2012	200	01/10/2012	300	16/07/2013	300	30/05/2014	100	09/02/2015	100
05/01/2012	100	02/10/2012	300	17/07/2013	300	02/06/2014	300	09/02/2015	200
09/01/2012	2000	02/10/2012	100	24/07/2013	400	02/06/2014	2300	09/02/2015	200
10/01/2012	2000	04/10/2012	2000	24/07/2013	100	02/06/2014	-2300	10/02/2015	1000
10/01/2012	200	04/10/2012	400	25/07/2013	1000	19/06/2014	2000	18/02/2015	300
10/01/2012	800	04/10/2012	400	25/07/2013	1000	19/06/2014	1000	20/02/2015	100
10/01/2012	1000	12/10/2012	-1000	26/07/2013	300	20/06/2014	1000	23/02/2015	200
11/01/2012	200	15/10/2012	2000	07/08/2013	1000	23/06/2014	100	25/02/2015	3000
16/01/2012	100	15/10/2012	400	12/08/2013	2000	24/06/2014	1000	25/02/2015	500
18/01/2012	800	17/10/2012	400	13/08/2013	300	24/06/2014	1500	25/02/2015	100
26/01/2012	1000	17/10/2012	1000	22/08/2013	100	25/06/2014	300	27/02/2015	300
27/01/2012	100	17/10/2012	3000	27/08/2013	1000	27/06/2014	300	03/03/2015	300
30/01/2012	200	23/10/2012	100	04/09/2013	700	01/07/2014	1000	03/03/2015	100
02/02/2012	500	24/10/2012	200	04/09/2013	1000	07/07/2014	300	06/03/2015	1000
03/02/2012	500	25/10/2012	500	10/09/2013	100	07/07/2014	300	09/03/2015	100
06/02/2012	3000	25/10/2012	300	13/09/2013	100	08/07/2014	100	10/03/2015	300
16/02/2012	200	26/10/2012	100	17/09/2013	300	10/07/2014	300	11/03/2015	100
17/02/2012	100	02/11/2012	1000	17/09/2013	1000	11/07/2014	400	11/03/2015	100
20/02/2012	1000	02/11/2012	3000	19/09/2013	2000	14/07/2014	2000	13/03/2015	3000
20/02/2012	400	02/11/2012	300	30/09/2013	400	18/07/2014	200	17/03/2015	100
20/02/2012	100	05/11/2012	500	30/09/2013	200	22/07/2014	3000	18/03/2015	200
21/02/2012	3000	07/11/2012	200	01/10/2013	100	22/07/2014	100	18/03/2015	100
27/02/2012	400	08/11/2012	500	03/10/2013	300	22/07/2014	700	18/03/2015	600
28/02/2012	3000	14/11/2012	100	04/10/2013	200	23/07/2014	200	18/03/2015	200
28/02/2012	200	14/11/2012	100	08/10/2013	400	24/07/2014	300	19/03/2015	100
29/02/2012	600	19/11/2012	1000	15/10/2013	300	24/07/2014	300	24/03/2015	600
06/03/2012	100	20/11/2012	400	17/10/2013	300	24/07/2014	300	31/03/2015	300
08/03/2012	1000	27/11/2012	300	17/10/2013	100	25/07/2014	100	02/04/2015	300
12/03/2012	1000	03/12/2012	100	21/10/2013	3000	28/07/2014	400	15/04/2015	200
12/03/2012	500	06/12/2012	100	23/10/2013	500	31/07/2014	100	15/04/2015	100
15/03/2012	1000	07/12/2012	1000	28/10/2013	3000	01/08/2014	600	20/04/2015	3000
19/03/2012	5000	10/12/2012	3000	30/10/2013	3000	04/08/2014	1000	20/04/2015	300
22/03/2012	500	10/12/2012	1000	31/10/2013	200	04/08/2014	300	21/04/2015	100
23/03/2012	500	11/12/2012	100	06/11/2013	2000	05/08/2014	200	23/04/2015	200
26/03/2012	1000	17/12/2012	100	06/11/2013	800	12/08/2014	300	24/04/2015	300
29/03/2012	2600	18/12/2012	100	11/11/2013	300	13/08/2014	400	24/04/2015	300
29/03/2012	400	21/12/2012	100	11/11/2013	1500	14/08/2014	300	30/04/2015	1000
30/03/2012	400	26/12/2012	400	14/11/2013	300	15/08/2014	1000	04/05/2015	2000
30/03/2012	100	08/01/2013	2000	21/11/2013	1300	19/08/2014	1000	13/05/2015	2000
06/04/2012	500	10/01/2013	400	21/11/2013	1500	20/08/2014	300	15/05/2015	300
09/04/2012	500	11/01/2013	100	21/11/2013	200	21/08/2014	300	19/05/2015	200
13/04/2012	400	15/01/2013	1000	22/11/2013	800	21/08/2014	200	25/05/2015	100
16/04/2012	100	18/01/2013	2000	25/11/2013	3800	25/08/2014	200	29/05/2015	800
17/04/2012	400	21/01/2013	400	25/11/2013	200	26/08/2014	4000	01/06/2015	100
20/04/2012	400	23/01/2013	1000	25/11/2013	500	03/09/2014	300	01/06/2015	300
27/04/2012	1000	04/02/2013	4000	03/12/2013	2000	08/09/2014	300	02/06/2015	300
01/05/2012	1000	06/02/2013	500	04/12/2013	600	09/09/2014	300	02/06/2015	600
01/05/2012	100	07/02/2013	200	04/12/2013	100	10/09/2014	300	10/06/2015	300
02/05/2012	3500	12/02/2013	100	09/12/2013	1000	11/09/2014	1000	17/06/2015	2000
02/05/2012	1500	21/02/2013	3000	09/12/2013	500	11/09/2014	100	26/06/2015	400
09/05/2012	400	21/02/2013	100	12/12/2013	100	11/09/2014	100	01/07/2015	300
10/05/2012	2000	26/02/2013	400	17/12/2013	100	15/09/2014	100	06/07/2015	100
11/05/2012	-100	27/02/2013	400	18/12/2013	300	16/09/2014	3000	08/07/2015	300
17/05/2012	100	27/02/2013	-400	18/12/2013	600	19/09/2014	600	10/07/2015	1000
17/05/2012	100	04/03/2013	2000	19/12/2013	300	25/09/2014	500	10/07/2015	3000
24/05/2012	500	05/03/2013	600	20/12/2013	300	26/09/2014	2000	14/07/2015	100
01/06/2012	2000	06/03/2013	3000	08/01/2014	1000	26/09/2014	100	14/07/2015	300
06/06/2012	300	08/03/2013	900	10/01/2014	100	26/09/2014	200	27/07/2015	300
08/06/2012	700	08/03/2013	1100	16/01/2014	3000	02/10/2014	200	29/07/2015	1000
12/06/2012	500	08/03/2013	100	17/01/2014	100	03/10/2014	500	31/07/2015	100
15/06/2012	400	19/03/2013	1000	21/01/2014	300	16/10/2014	600	03/08/2015	2000
15/06/2012	2000	21/03/2013	100	22/01/2014	1000	17/10/2014	3000	07/08/2015	300
25/06/2012	500	22/03/2013	3000	30/01/2014	300	17/10/2014	100	11/08/2015	500
02/07/2012	5000	25/03/2013	0	31/01/2014	300	22/10/2014	500	13/08/2015	2000
04/07/2012	1000	29/03/2013	300	31/01/2014	100	30/10/2014	6000	20/08/2015	4000
05/07/2012	100	09/04/2013	3000	03/02/2014	100	07/11/2014	200	26/08/2015	2000
09/07/2012	400	12/04/2013	600	12/02/2014	200	10/11/2014	4000	27/08/2015	300
11/07/2012	500	15/04/2013	300	13/02/2014	100	10/11/2014	800	31/08/2015	300
13/07/2012	100	19/04/2013	100	17/02/2014	2000	14/11/2014	2000	02/09/2015	1000
17/07/2012	400	19/04/2013	200	17/02/2014	500	18/11/2014	400	03/09/2015	200
23/07/2012	2000	22/04/2013	100	19/02/2014	1000	19/11/2014	100	08/09/2015	100
24/07/2012	200	22/04/2013	0	21/02/2014	100	25/11/2014	300	10/09/2015	200
27/07/2012	400	24/04/2013	2000	21/02/2014	100	25/11/2014	100	10/09/2015	100
03/08/2012	200	24/04/2013	600	27/02/2014	300	25/11/2014	300	16/09/2015	100
07/08/2012	1000	24/04/2013	100	27/02/2014	600	26/11/2014	100	17/09/2015	7000
09/08/2012	3000	01/05/2013	200	03/03/2014	300	27/11/2014	2000	28/09/2015	300
13/08/2012	200	01/05/2013	100	05/03/2014	300	27/11/2014	2000	01/10/2015	300
15/08/2012	400	13/05/2013	1000	07/03/2014	200	27/11/2014	100	05/10/2015	100
17/08/2012	600	13/05/2013	1000	10/03/2014	100	04/12/2014	100	08/10/2015	1000
21/08/2012	600	24/05/2013	100	11/03/2014	500	05/12/2014	100	08/10/2015	500
22/08/2012	1000	24/05/2013	200	11/03/2014	1000	09/12/2014	1000	13/10/2015	100
23/08/2012	500	29/05/2013	300	12/03/2014	300	16/12/2014	300	26/10/2015	200
23/08/2012	500	29/05/2013	300	14/03/2014	3000	18/12/2014	300	29/10/2015	100
27/08/2012	100	30/05/2013	600	18/03/2014	100	22/12/2014	1300	02/11/2015	100
29/08/2012	500	05/06/2013	2000	20/03/2014	100	22/12/2014	200	05/11/2015	200
29/08/2012	300	06/06/2013	2400	03/04/2014	100	22/12/2014	1700	11/11/2015	300
30/08/2012	400	07/06/2013	500	07/04/2014	2000	06/01/2015	100	18/11/2015	200
03/09/2012	2000	11/06/2013	300	16/04/2014	5000	19/01/2015	400	20/11/2015	2400
04/09/2012	200	11/06/2013	2000	22/04/2014	100	19/01/2015	200	30/11/2015	1000
07/09/2012	500	14/06/2013	100	23/04/2014	100	20/01/2015	100	07/12/2015	300
10/09/2012	400	17/06/2013	100	23/04/2014	100	23/01/2015	300	08/12/2015	300
14/09/2012	100	20/06/2013	2000	23/04/2014	100	23/01/2015	200	09/12/2015	1000
17/09/2012	1000	21/06/2013	100	25/04/2014	300	27/01/2015	2000	16/12/2015	500
19/09/2012	400	25/06/2013	200	09/05/2014	100	30/01/2015	200	21/12/2015	100
20/09/2012	2000	03/07/2013	2000	13/05/2014	500	02/02/2015	100		