
1. Introdução

Alguns fatores como a globalização, o aumento da variedade de produtos, a maior exigência quanto ao nível de serviço prestado e a competitividade entre empresas, fez com que as atividades logísticas se tornassem cada vez mais complexas. Com isso, a demanda por cálculos sofisticados, ferramentas e análises mais aprofundadas cresceu significativamente nas últimas décadas (BOWERSOX, 1996).

Dentro da cadeia de suprimentos, é possível citar o controle de produção e de estoque como uma das principais preocupações presentes nas empresas. É indispensável para o sucesso de uma companhia a quantificação de demandas futuras e obtenção de projeções mais assertivas, para que assim, recursos sejam economizados e os custos relacionados a estoque sejam evitados. Além disso, os clientes não sofrerão com a falta de disponibilidade de produto ou descumprimento de prazos, resultando em todas as partes envolvidas satisfeitas.

Fundada na Alemanha em 1949 por Adolf Dassler, a Adidas foi criada com o objetivo de inovar o mercado de calçados esportivos, promovendo a alta performance de atletas. Desde então, é reconhecida mundialmente por sua qualidade, estando presente tanto na rotina de esportistas profissionais de elite, quanto de indivíduos amantes de esportes ou da marca.

Classificada pelo Instituto Nacional da Propriedade Industrial (INPI) como de alto renome, ou seja, que tem grande reconhecimento pelo público, a Adidas foi se reinventando com o passar do tempo e atualmente é referência não somente no mundo dos esportes, como também dentro de segmentos relacionados a moda, cultura, música e sustentabilidade. Suas fábricas também passaram por grande evolução, em 2016 foi inaugurada na Alemanha uma fábrica inteligente denominada de *Speedfactory*, onde calçados personalizados que demoravam meses para serem produzidos, eram feitos em poucos dias graças a máquinas automatizadas como impressoras 3D, malhas computadorizadas e braços mecânicos (FÁBRICAS, 2018). Em 2020, a *Speedfactory* foi fechada e a Adidas transferiu as tecnologias adquiridas de produção automatizada para Ásia, onde 90% dos produtos da marca são fabricados e onde estão presentes os fornecedores e o *know-how* (ADIDAS, 2019).

Com a pandemia causada pela Covid-19, em 2020 a Adidas obteve uma queda de 78% dos lucros líquidos anuais (PRESSE, 2021). Por conta do confinamento, a população diminuiu significativamente a frequência em se exercitar ou praticar esportes, além disso, jogos oficiais esportivos também foram interrompidos.

Diante desse cenário de incertezas e com as vendas decaindo, a justificativa desse artigo é a importância de um bom planejamento de produção alinhado à demanda, onde ao se utilizar modelos estatísticos, uma alta taxa de assertividade é adquirida nas projeções de vendas, aumentando a eficiência e a otimização produtiva de empresas, como a Adidas. O que se mostra ainda mais relevante em períodos de crises, como o ocorrido durante a pandemia.

Sendo assim, o objetivo deste artigo será realizar uma análise de projeção de demanda utilizando a metodologia Box e Jenkins com o modelo SARIMA, observando dados de séries temporais compostas por números de vendas de roupas e calçados da marca Adidas, otimizando dessa forma, os estudos realizados dentro do setor de planejamento e marketing de produtos.

2. Referencial teórico

2.1 Cadeia de suprimentos e previsão de demanda

Uma cadeia de suprimentos é composta por todas as etapas que envolve direta ou indiretamente o fornecimento de um produto a um cliente, incluindo todos os fornecedores de componentes do produto, o fabricante, transportadoras, depósitos, lojas distribuidoras e os próprios clientes (CHOPRA e MEINDL, 2003).

De acordo com Chopra e Meindl (2003, p. 52) “O estoque é o principal fator gerador de custos em uma cadeia de suprimento e exerce um forte impacto na responsividade”. Isto é, uma empresa pode atender imediatamente a necessidade de seus clientes mantendo seus estoques bem abastecidos, porém, haverá um aumento significativo de custos para manter esses produtos estocados e conseqüentemente uma diminuição da eficiência.

Sendo assim, é necessário que os líderes de uma empresa mantenham o equilíbrio adequado entre eficiência e responsividade. Isso pode ser realizado através de previsões de demandas, onde ao se realizar um estudo estimando a quantidade de itens que serão vendidos, os gerentes podem tomar melhores decisões e agir com um planejamento estratégico.

Segundo Ballou (2006) existem três categorias de métodos de previsão:

1. Métodos Qualitativos: É um método não científico composto de julgamentos, intuições, pesquisas ou técnicas de comparação. Apesar da carência de exatidão, há situações em que essas propriedades são tudo que se tem disponível. Dessa forma, é preferível que seja utilizado em períodos de médio a longo prazo (a partir de seis meses).
2. Métodos de Projeção Histórica: É de natureza quantitativa e se mostra adequado quando se há a disponibilidade de dados de séries históricas passadas, contendo tendências e sazonalidade estáveis e definidas. Partindo da premissa de que padrões passados se repetem no futuro, cálculos matemáticos e estatísticos são realizados, resultando na projeção de novos valores. É um método preferencialmente usado para períodos de curto prazo (menos de seis meses), já que quando ocorre uma mudança significativa, o modelo só irá captar depois do ocorrido.
3. Métodos Causais: São métodos de médio a longo prazo, os quais determinam a previsão a partir de variáveis independentes que irão ter uma influência direta no fenômeno a ser previsto, bem como entender como essas variáveis se relacionam causalmente com ele. Para isso, dados considerados relevantes são coletados e usados a fim de observar sua interação e o quanto o fenômeno é afetado, formando uma relação de causa e efeito. Um exemplo disso são os modelos de regressão e econométrico. A desvantagem desse método é a dificuldade em encontrar variáveis que são de fato causais.

2.2 Séries temporais

Uma série temporal é um conjunto de dados ordenados por tempo. São comumente usadas em análises estatísticas que tem como objetivo utilizar esses dados, após serem minerados,

organizados e trabalhados, para prever o futuro através da informação extraída. (MONTGOMERY, JENNINGS e KULAHCI, 2003).

Como as séries temporais possuem dependência entre observações adjacentes, é indispensável que ao realizar a análise de dados, haja o desenvolvimento de modelos estocásticos e dinâmicos, ou seja, incluindo variáveis aleatórias e com um sistema que muda ao longo do tempo (BOX, JENKINS e REINSEL, 2008).

Um equívoco cometido por algumas pessoas é o de presumir que a série que irá ser trabalhada é estacionária, isto é, que não apresenta variações ou tendências sistemáticas com o tempo, além de possuírem a média e a variância constante. No entanto, a maioria das séries temporais coletadas demonstram tendências, um exemplo comum é a denominada tendência linear, que é conhecida por apresentar uma série que flutua ao redor de uma reta. Dessa forma, um passo importante ao trabalhar com esses dados é tornar a série estacionária (BOX, JENKINS e REINSEL, 2008).

Para isso, um método utilizado é determinando diferenças sucessivas da série original. A primeira diferença é definida por:

$$\Delta Z_t = Z_t - Z_{t-1} \quad (1)$$

em que, Z_t representa a série e Δ um operador de diferença.

Já a segunda diferença, apresenta a seguinte fórmula:

$$\Delta^2 Z_t = Z_t - 2Z_{t-1} + Z_{t-2} \quad (2)$$

De maneira geral, a n-ésima diferença de Z_t é:

$$\Delta^n Z_t = \Delta[\Delta^{n-1} Z_t] \quad (3)$$

Geralmente, tomar uma ou duas diferenças é o bastante para que a série se torne estacionária.

Para realizar a análise de séries temporais, é imprescindível que um gráfico seja construído para tornar visível o que os números estão representando, facilitando a identificação de padrões. Dentro disso, existem alguns fatores que devem ser levados em conta durante tal estudo para auxiliar na interpretação de diferentes tipos de comportamentos.

De acordo com Fava (2000), existem quatro principais tipos de comportamentos de uma série temporal, listados a seguir:

1. **Tendência:** É um movimento evolutivo de longo prazo, podendo seguir para baixo ou para cima. Pode ser referido como mudança de direção quando a série deixa de tender um movimento de crescimento para um de decréscimo.
2. **Sazonalidade:** Comportamento específico que se repete de forma regular em subperíodos de um período fixo, que costuma ser de um ano.
3. **Ciclo:** São oscilações de longo prazo e padrões recorrentes de uma série temporal com duração maior que um ano. Não são regulares como a sazonalidade, que se repete em períodos fixos e costumam ser mais difíceis de identificar e modelar.

-
4. Componente Errático: Comportamento decorrente de fatores aleatórios, resultando em movimentos esporádicos e irregulares. Um exemplo disso é o ruído branco, que é conhecido por possuir uma série de observações aleatórias e independentes.

2.3 Modelo SARIMA de BOX & JENKINS

O modelo SARIMA (Seasonal Autoregressive Integrated Moving Average) é uma técnica estatística avançada que tem como objetivo modelar séries temporais com padrões sazonais e tendências. Ele é uma extensão do modelo ARIMA (Autoregressive Integrated Moving Average) e tem sido amplamente utilizado em estudos de previsão de demanda, análise financeira e econômica, entre outros (BROCKWELL e DAVIS, 2016)

O mesmo foi desenvolvido para lidar com as particularidades das séries temporais sazonais, que apresentam padrões cíclicos em um período determinado, como por exemplo, vendas em datas comemorativas, produção agrícola, consumo de energia, entre outros. Essas séries podem apresentar dificuldades para serem modeladas com modelos estatísticos tradicionais, como o ARIMA, pois possuem variações periódicas ao longo do tempo (MORETTIN E TOLOI, 2006).

O modelo SARIMA é composto de três componentes principais: o componente autorregressivo (AR), que considera a relação entre a série atual e os valores passados da mesma série; o componente de média móvel (MA), que considera a relação entre a série atual e os resíduos passados; e o componente de diferenciação (I), que busca remover a tendência e a sazonalidade da série.

Assim, pode ser utilizado para prever valores futuros da série, avaliar a precisão das previsões e identificar possíveis padrões e tendências na série. Além disso, ele também pode ser utilizado para analisar o impacto de eventos específicos na série, como por exemplo, o impacto de uma campanha de marketing nas vendas de um produto.

Para aplicar o modelo SARIMA em um estudo de caso, é necessário coletar e analisar os dados históricos da série temporal em questão, identificar possíveis padrões sazonais e tendências, e ajustar o modelo aos dados observados (FERREIRA, 2015). É importante também avaliar a adequação do modelo aos dados e a capacidade do modelo em prever valores futuros da série.

2.4 Etapas da metodologia Box & Jenkins

A metodologia Box-Jenkins é uma abordagem amplamente utilizada para modelagem e previsão de séries temporais (BOX e JENKINS, 1976). Que segue com as seguintes etapas:

2.4.1. Identificação

A primeira etapa da metodologia Box-Jenkins é a identificação do modelo, ou seja, determinar a ordem de diferenciação e os termos autorregressivos e de média móvel apropriados para a série temporal. Para isso, podem ser utilizados métodos gráficos e estatísticos, como a função de autocorrelação e a função de autocorrelação parcial (BROCKWELL E DAVIS, 2016).

2.4.2. Estimação

Na segunda etapa, é necessário estimar os parâmetros do modelo identificado. Existem várias técnicas de estimação disponíveis, incluindo o método dos mínimos quadrados e o método de máxima verossimilhanças (HUMBERT e STOFFER, 2017).

2.4.3. Diagnóstico

A terceira etapa da metodologia Box-Jenkins é o diagnóstico do modelo, que envolve verificar se os resíduos do modelo são ruídos brancos (TSAY, 2010). Se os resíduos não forem ruídos brancos, pode ser necessário refazer a identificação e a estimação do modelo.

2.4.4. Previsão

A última etapa da metodologia Box-Jenkins é a previsão, na qual o modelo é utilizado para gerar previsões futuras da série temporal (ENDERS, 2014).

3. Metodologia

3.1 Descrição da abordagem

Foi adotada nessa pesquisa uma abordagem quantitativa, utilizando um método de projeção histórica para analisar a demanda dos produtos da empresa Adidas nos Estados Unidos nos anos de 2020 e 2021. Foi utilizada a análise de séries temporais com o modelo SARIMA para prever a demanda futura com base nos dados históricos.

3.2 Procedimentos de análise

- a. Coleta de dados: Foram coletados os dados de demanda de roupas e sapatos da empresa Adidas nos Estados Unidos nos anos de 2020 e 2021. Esses dados foram obtidos por meio de relatórios financeiros da empresa, dados de vendas e informações disponíveis publicamente em uma comunidade para cientistas de dados denominada *Kaggle*.
- b. Preparação dos dados: Os dados foram tratados e organizados em uma estrutura de séries temporais utilizando a biblioteca *Pandas*. Foram verificadas e tratadas possíveis inconsistências, como valores ausentes e outliers.
- c. Modelagem com SARIMA: O modelo SARIMA (Seasonal Autoregressive Integrated Moving Average) foi implementado utilizando as bibliotecas *NumPy*, *Statsmodels*, *Matplotlib* e *Pandas* no Python. O modelo foi ajustado aos dados de demanda e utilizado para realizar a previsão da demanda futura.
- d. Comparação dos resultados: Os resultados obtidos com o modelo SARIMA foram comparados com os dados reais de demanda. Foram utilizadas métricas de desempenho, como erro médio absoluto (MAE), erro médio quadrático (MSE) e raiz quadrada do erro médio quadrático (RMSE), para avaliar a acurácia do modelo.
- e. Análise de fatores influenciadores: Foram realizadas análises estatísticas e gráficas para identificar possíveis fatores que influenciaram a demanda dos produtos da

Adidas nos Estados Unidos nos anos de 2020 e 2021. Incluindo análise de sazonalidade, tendências ou eventos específicos que impactaram a demanda.

3.3 Limitações

A disponibilidade e qualidade dos dados podem ser uma limitação, pois a série histórica foi retirada de fontes disponíveis publicamente.

As previsões obtidas com o modelo SARIMA estão sujeitas a erros e incertezas, uma vez que se baseiam em dados passados e suposições sobre padrões futuros.

O estudo se concentra apenas nos anos de 2020 e 2021, não levando em consideração períodos anteriores ou posteriores.

3.4 Ferramentas e bibliotecas utilizadas

Para a implementação da análise comparativa utilizando o modelo SARIMA, foram utilizadas as seguintes bibliotecas do Python:

1. Python: Linguagem de programação utilizada para implementar a análise.
2. NumPy: Biblioteca utilizada para realizar cálculos numéricos e manipulação de arrays.
3. Pandas: Biblioteca utilizada para manipulação e análise de dados, incluindo a criação de séries temporais.
4. Statsmodels: Biblioteca utilizada para a modelagem de séries temporais, incluindo a implementação do modelo SARIMA.
5. Matplotlib: Biblioteca que possui a funcionalidade de criar figuras e gráficos visualizadas em Python.

4. Análise e discussão dos resultados

A série temporal estudada é apresentada resumidamente na tabela 1 com os resultados mensais. Na análise realizada no artigo, foram examinadas 104 observações do registro de vendas dos produtos da Adidas nos Estados Unidos, ou seja, de forma semanal, escolhidas dentro do período de janeiro de 2020 a dezembro de 2021. Os dados dos últimos seis meses de 2021 foram utilizados para comparações com as previsões.

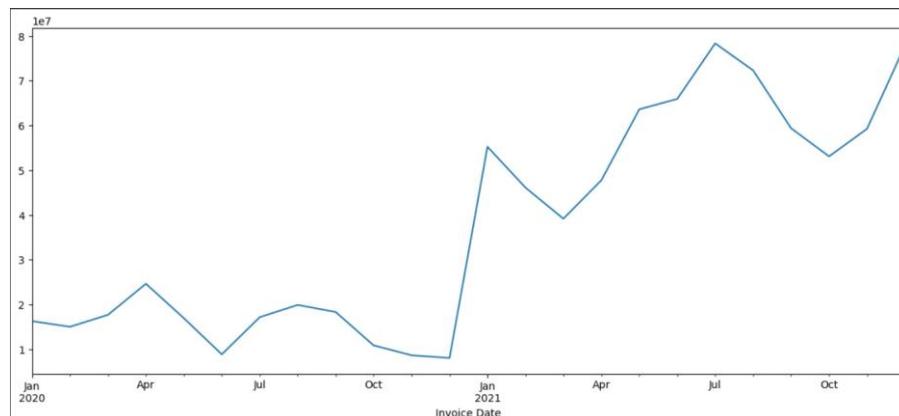
Tabela 1: Vendas mensais dos produtos Adidas nos Estados Unidos (em quantidade).

Mês/Ano	2020	2021
jan	48,333	179,299
fev	37,846	156,113
mar	46,972	143,988
abr	54,709	161,717
mai	35,705	178,900
jun	16,269	164,745
jul	38,219	180,481
ago	62,307	195,414
set	46,125	182,425
out	30,167	152,834
nov	25,152	149,350
dez	20,545	171,246
Total	462,349	2,016,512

Fonte: Adaptado de Chaudhari (2022)

Para a interpretação dos dados e identificação do modelo a ser aplicado, construiu-se inicialmente um gráfico da série original (Figura 1), possuindo uma média semanal estimada $Z = 103.285,88$.

Figura 1: Vendas de produtos Adidas entre o período de janeiro/2020 a dezembro/2021



Fonte: Autores (2023)

Diante do que é apresentado no gráfico, é possível observar que durante o ano de 2020, as vendas demonstraram um desempenho inferior ao ano seguinte, sendo a média de vendas de unidades em 2021 igual a 4,4 vezes maior que a do ano inferior. Esse acontecimento se deve a pandemia da COVID-19, causada pelo coronavírus que provocou 6.891.469 mortes ao redor do mundo (CORONAVÍRUS, 2023).

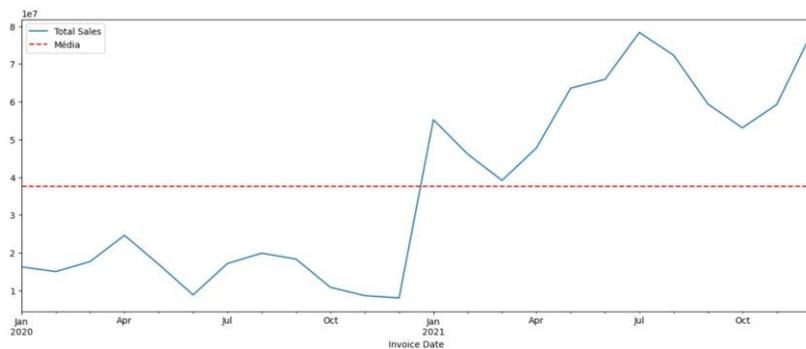
Como medida protetiva, no mês de março diversos estados nos Estados Unidos anunciaram confinamento afim de evitar que o vírus fosse espalhado. É possível observar no gráfico (Figura 1) uma queda gradual nos números a partir de abril, isso se deve ao fato de comércios como academias e jogos esportivos terem seu funcionamento suspenso. Um

exemplo disso, foi a NBA (National Basketball Association), que encerrou a temporada no dia 11 de março de 2020 (UM, 2021). Tudo isso desmotivou o consumo de artigos esportivos, além do fato de que como a economia sofreu negativamente e muitas pessoas tinham a possibilidade de perder seus empregos, a renda dos indivíduos acabava sendo destinada ao que fosse essencial no dia a dia.

Já o aumento de vendas observado a partir de dezembro de 2020, se deve a flexibilização do confinamento e a aparição da vacina, que aumentou o desempenho econômico da Adidas em 2021.

Antes de realizar a projeção, é necessário observar se a série histórica é estacionária. Ao analisar o gráfico da série em conjunto com a média (Figura 2), nota-se que os valores não evoluem em torno da média, apontando a existência de tendência, o que indica probabilidade da série não ser estacionária. Para obter certeza, foi aplicado o teste de Dickey-Fuller e estipulado um nível de significância de 0,05. O valor-p observado foi igual a 0.12738. Dessa forma, a série se demonstrou como não estacionária.

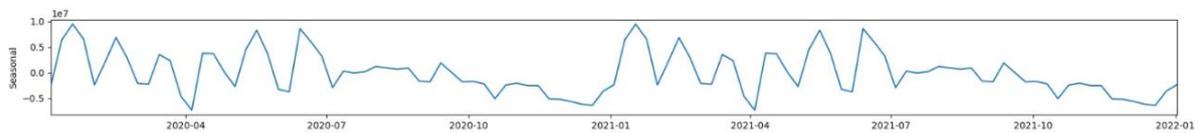
Figura 2: Gráfico de vendas com a média



Fonte: Autores (2023)

Com relação a sazonalidade, a partir da análise do gráfico da Figura 3, obtida em uma decomposição de série temporal, é possível observar que o comportamento da série se repete nos mesmos períodos dos dois anos, indicando que há a presença de sazonalidade.

Figura 3 - Sazonalidade



Fonte: Autores (2023)

Para tornar a série estacionária, foi realizada a separação dos valores de vendas mensais para semanais. Dessa forma, há uma segmentação da amostra feita em subgrupos analisados individualmente, tornando a média constante. Além disso, ao aplicar o componente de diferenciação (I), a tendência e a sazonalidade da série é eliminada.

O modelo SARIMA (7, 1, 1) (0, 1, 1)₇ foi selecionado após uma análise que considerou diferentes combinações de parâmetros e utilizou o critério AIC como medida de validação. Este modelo apresentou o menor valor de AIC, indicando um bom ajuste aos dados observados. Ele foi capaz de capturar os padrões de autocorrelação e sazonalidade presentes nos dados, tornando-se a escolha ideal para a análise.

Dentre os parâmetros do modelo, o coeficiente AR L6 foi considerado estatisticamente significativo, demonstrando que o valor passado da série temporal, com um atraso de 6 períodos influencia de forma significativa o valor atual. Com isso, o modelo SARIMA (7, 1, 1) (0, 1, 1)₇ se mostrou adequado para a análise, proporcionando um ajuste preciso aos dados e considerando tanto a autocorrelação quanto a sazonalidade na série temporal estudada.

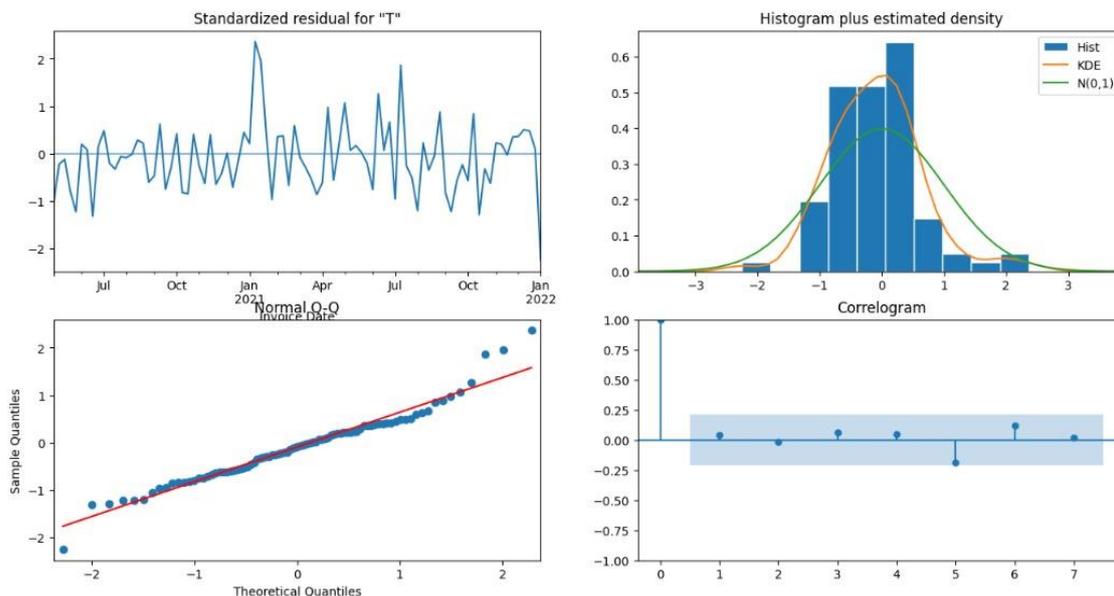
Figura 4 – Modelo ARIMA

	coef	std err	z	P> z	[0.025	0.975]
ar.L1	0.1461	1.364	0.107	0.915	-2.527	2.819
ar.L2	-0.1514	0.471	-0.321	0.748	-1.075	0.773
ar.L3	-0.5210	0.435	-1.197	0.231	-1.374	0.332
ar.L4	0.4940	1.005	0.491	0.623	-1.476	2.464
ar.L5	-0.1110	0.346	-0.320	0.749	-0.790	0.568
ar.L6	-0.3331	0.219	-1.524	0.127	-0.761	0.095
ar.L7	0.0027	0.534	0.005	0.996	-1.045	1.050
ma.L1	-0.4684	1.381	-0.339	0.734	-3.175	2.238
ma.S.L7	-0.9438	0.097	-9.740	0.000	-1.134	-0.754
sigma2	1.95e+13	2.44e-13	7.98e+25	0.000	1.95e+13	1.95e+13

Fonte: Autores (2023)

O diagnóstico do modelo apresentado na Figura 5 permite notar o resultado da série após o processo de estacionariedade, onde é possível observar que os resíduos, ou seja, as diferenças entre os valores observados e os valores previstos pelo modelo, estão próximos da distribuição normal, o que é um indicativo positivo da qualidade do ajuste do modelo aos dados.

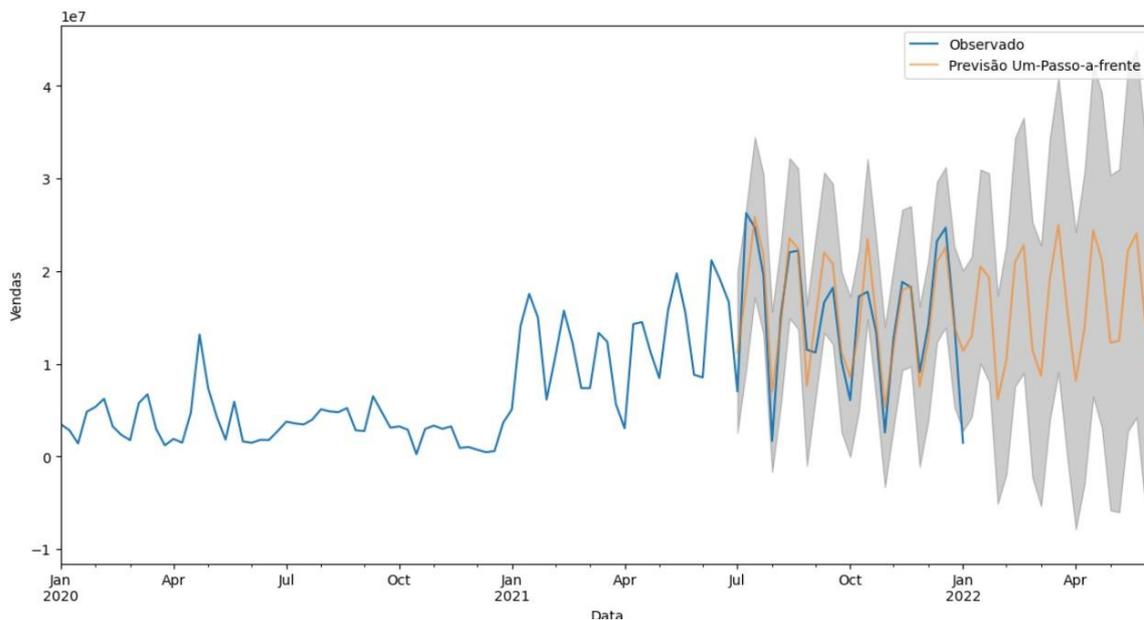
Figura 5: Diagnóstico do modelo



Fonte: Autores (2023)

Após a aplicação do modelo SARIMA, foi gerado o resultado a seguir de projeção de dados futuros.

Figura 6 – Previsão obtida



Fonte: Autores (2023)

O gráfico de previsão para os seis meses testados, dos quais já possuem valores reais, apresenta uma aderência significativa aos dados observados da série temporal. A linha de previsão acompanha de perto os valores observados, indicando um ajuste preciso do modelo aos padrões e tendências presentes nos dados.

Além disso, o gráfico de previsão mostra uma variação adequada nas magnitudes das flutuações. As quedas e picos observados nos dados históricos são refletidos de forma precisa na previsão, garantindo uma representação realista das variações esperadas.

O gráfico também fornece a previsão de valores dos próximos seis meses do ano de 2022, indicando a faixa provável de valores futuros. Esses intervalos ajudam a avaliar a incerteza associada à previsão e fornecem informações valiosas para tomadas de decisão.

5. Considerações finais

Levando em consideração os fatos apresentados, conclui-se que o objetivo proposto de realizar uma análise precisa de previsão das vendas da empresa Adidas, utilizando o modelo SARIMA, foi atingido. Ao longo do estudo, foi identificado padrões sazonais e tendências, permitindo a construção de um modelo preditivo robusto.

Foi identificado uma diferença significativa na quantidade de vendas em 2020 e 2021 por conta da pandemia. Isso demonstra como é importante um planejamento adequado para enfrentar grandes desafios que interfira no desempenho da companhia, antecipando possíveis resultados e garantindo uma estratégia bem embasada e verossímil.

As previsões de vendas estão sujeitas a incertezas do mercado, como mudanças nas preferências dos consumidores, concorrência e condições econômicas, afetando sua precisão. A disponibilidade e qualidade dos dados históricos são essenciais para construir um modelo preciso, e limitações nesses dados devem ser consideradas ao conduzir análises futuras.

Os resultados deste artigo contribuem para a engenharia de produção dentro da área da pesquisa operacional, especificamente na análise e previsão de séries temporais de vendas utilizando o modelo SARIMA. Como também para o setor de *supply chain*, uma vez que o torna mais eficaz nas atividades de gerenciamento de estoque e planejamento de produtos, levando a uma redução de custos, melhor atendimento ao cliente e aumento da lucratividade.

Os resultados obtidos forneceram insights valiosos, permitindo uma base sólida para a tomada de decisões estratégicas. No entanto, há oportunidades de aperfeiçoamento e expansão para pesquisas e trabalhos futuros. Algumas sugestões para investigações adicionais são: Explorar modelos de previsão mais avançados, como redes neurais artificiais e modelos de aprendizado de máquina, realizar análises mais detalhadas sobre os fatores que impactam as vendas da Adidas, incluindo estudos de mercado, análise de concorrência e segmentação de clientes e por fim, investigar a aplicação de estratégias de otimização de estoque e logística, levando em consideração as previsões de vendas e os custos associados, para melhorar a eficiência operacional da Adidas.

Explorar essas áreas de pesquisa possibilitará à Adidas aprimorar sua capacidade de prever com precisão as vendas, compreender o mercado em que atua e otimizar suas operações, fortalecendo assim sua posição competitiva no setor de artigos esportivos. Ao unir a expertise em análise de dados com as estratégias de negócios, a Adidas estará preparada para enfrentar os desafios e aproveitar as oportunidades em um mercado em constante evolução.

Agradecimentos

Agradecemos a nossa família por todo o apoio e suporte durante esses cinco anos de universidade.

Ao nosso orientador que dedicou tempo e esforço para nos aconselhar o melhor caminho e indicar as ferramentas adequadas para a realização do artigo.

Ao corpo docente pelos ensinamentos que levaremos por toda a nossa carreira.

A Universidade Anhembi Morumbi pelo apoio e incentivo a pesquisa.

E a todos os outros que fizeram parte dessa jornada e nos encorajou a essa conquista.

Referências

ADIDAS fecha fábricas automatizadas na Alemanha e nos EUA. **Época Negócios**. 13 de nov. de 2019. Disponível em: <<https://epocanegocios.globo.com/Empresa/noticia/2019/11/adidas-fecha-fabricas-automatizadas-na-alemanha-e-nos-eua.html>>. Acesso em: 03 de jun. de 2023.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5ª. ed. Bookman, Porto Alegre. 2006.

BOWERSOX, D.; CLOSS, D. **Logistics Management: The Integrated Supply Chain Process**. McGraw-Hill, Nova Iorque. 1996.

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. **Time Series Analysis: Forecasting and Control**. 4a. ed. Wiley, San Francisco. 2008.

BOX, G. E. P.; JENKINS, G. M. **Time Series Analysis: Forecasting And Control**. Holden-Day, San Francisco. 1976.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction To Time Series And Forecasting**. Springer, New York. 2016.

CHAUDHARI, Heemali. Adidas Sales Dataset. **Kaggle**. Dezembro de 2022. Disponível em: <<https://www.kaggle.com/datasets/heemalichaudhari/adidas-sales-dataset?datasetId=2756597>>. Acesso em: 25 Mai. 2023.

CHOPRA, S.; MEINDL, P. **Gerenciamento da Cadeia de Suprimentos**. 1ª. ed. Pearson, São Paulo. 2003.

CORONAVÍRUS última situação (Covid-19). **TRT**. Disponível em: <<https://www.trt.net.tr/portuguese/covid19>>. Acesso em: 15 de jun. de 2023.

ENDERS, W. **Applied econometric time series**. Hoboken, John Wiley & Sons, New Jersey. 2014.

FÁBRICAS supervelozes da Adidas derrubam tempo de produção e entrega. **Fashion Network**. 04 de out. de 2018. Disponível em: <<https://br.fashionnetwork.com/news/Fabricas-supervelozes-da-adidas-derrubam-tempo-de-producao-e-entrega,1021032.html>>. Acesso em: 03 de jun. de 2023.

FAVA, V. L. **Manual de econometria: nível intermediário**. In: VASCONCELOS, M. A. S.; ALVES, D. Editora Atlas, São Paulo. 2000.

HUMBERT, R. H.; STOFFER, D. S. **Time series analysis and its applications: with R examples**. 4^a. ed. Springer, New York. 2017.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. Wiley, New Jersey. 2008.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2^a. ed. Blucher, São Paulo. 2006.

PRESSE, F. Pandemia provoca queda de 78% do lucro da Adidas em 2020. **Globo**. 10 de mar. de 2021. Disponível em: <<https://g1.globo.com/economia/noticia/2021/03/10/pandemia-provoca-queda-de-78-do-lucro-da-adidas-em-2020.ghtml>>. Acesso em: 03 de jun. de 2023.

TSAY, R. S. **Analysis of financial time series**. Hoboken, John Wiley & Sons, New Jersey. 2010.

UM ano após fechamento por pandemia, esportes nos EUA caminham para a normalidade. **GZH Esportes**. 12 de mar. de 2021. Disponível em: <<https://gauchazh.clicrbs.com.br/esportes/noticia/2021/03/um-ano-apos-fechamento-por-pandemia-esportes-nos-eua-caminham-para-a-normalidade-ckm6ridz0008601f1uhg6jzh3.html>>. Acesso em: 15 de jun. de 2023.