

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E TRANSPORTES**

TRABALHO DE CONCLUSÃO DE CURSO DE GRADUAÇÃO

**APLICAÇÃO E ANÁLISE DE MÉTODOS DE PREVISÃO DE DEMANDA EM UMA
INDÚSTRIA DO RAMO DE TRANSPORTES VERTICAIS**

THALES DALLA POZZA MAHMUD

ORIENTADOR: MICHEL JOSÉ ANZANELLO

**PORTO ALEGRE
JANEIRO/2024**

RESUMO

A necessidade de evoluir em um mercado com competitividade crescente obriga as empresas a tomarem decisões embasadas e alinhadas com a realidade específica de cada uma delas. Nesse contexto, a capacidade em prever a demanda e possibilitar um planejamento bem estabelecido, bem como redução dos custos operacionais e níveis de estoque, torna-se crucial para as indústrias do ramo de transportes verticais. Ademais, a fabricação de produtos personalizados (característica marcante do setor em análise) soma-se às dificuldades mencionadas anteriormente, contribuindo assim para a relevância deste estudo. O artigo em questão propõe a aplicação de métodos de previsão de demanda para dados históricos de demanda de uma indústria de transportes verticais, com o objetivo final de selecionar o método que possui melhor capacidade preditiva para ser incorporado nos processos da empresa. Para tanto, previamente à modelagem de dados, é necessário realizar a coleta de dados e selecionar os componentes mais representativos por meio da integração da classificação ABC (que visa selecionar os componentes com maior valor de consumo) com a classificação XYZ, usada na seleção de componentes mais críticos para o processo de fabricação. Por fim, realiza-se a aplicação dos métodos de previsão aos dados dos componentes selecionados, identificando-se o método que apresenta menor erro percentual absoluto médio (MAPE) na porção de teste e, por consequência, a melhor capacidade preditiva em dados não utilizados na construção do modelo. As análises apontaram a necessidade de agrupar dados para reduzir ruídos durante a etapa de treino dos modelos.

PALAVRAS-CHAVE: Previsão de demanda, Estoques, Classificação de componentes, séries temporais, Curva ABC, MAPE.

1. INTRODUÇÃO

O setor industrial brasileiro apresenta grande competitividade entre as empresas em diferentes ramos. Evidenciando sua força, segundo uma pesquisa realizada em 2020 pela Confederação Nacional da Indústria (CNI), o setor é responsável por empregar 9,7 milhões de brasileiros e responde por 20,4% dos empregos formais do país. A recente globalização da informação e a disseminação de dados fazem com que as organizações invistam em aquisição de conhecimento técnico e inovações, visando o desenvolvimento econômico contínuo. As principais decisões organizacionais e operacionais, quando embasadas a partir de estudos e aplicações metodológicas, tornam-se mais alinhadas com a realidade e reduzem os riscos da obtenção de resultados pouco eficientes. O mercado competitivo exige

das empresas previsões assertivas que utilizem mais de um método e incorporem maior quantidade de informações relevantes para as tomadas de decisões (Werner, 2004).

Imersas neste cenário, torna-se imprescindível a necessidade das empresas em aprimorar seus processos decisórios e minimizar seus custos em todos os níveis organizacionais. As flutuações do mercado, resultado de um ambiente político imprevisível, não dão margem para empresas moldadas em processos gerenciais de constante urgência. Sem uma estimativa da demanda futura não é possível planejar efetivamente para futuros eventos, apenas reagir a eles (Slack et al., 2016). Assim, a previsão de demanda auxilia os planejamentos de longo e médio prazo e possibilita o preparo dos gestores para os resultados posteriores.

Exercendo papel fundamental como um dos pilares do Planejamento e Controle da Produção (PCP), a previsão de demanda fornece insumos importantes e cria laços de dependência entre áreas de magnitudes distintas dentro de uma organização. Proporcionar uma melhor compra de materiais, reduzir custos logísticos e operacionais, e otimizar estoques são alguns dos resultados obtidos a partir de uma previsão de demanda alinhada com a realidade e que fornecem dados pertinentes aos gestores. A previsão de demanda atende a objetivos específicos da empresa, como auxiliar no pedido de matéria-prima, além de analisar os recursos financeiros necessários para realizar determinadas operações para atendimento as demandas de mercado com prazos estipulados (Kotler, 1991).

Apesar da sabida importância do tema e dos resultados trazidos pela utilização do método preditivo em questão, é de conhecimento comum que parte significativa das empresas não conduzem esta análise de maneira estruturada. O setor de transportes verticais também é atingido pela fraca estruturação na escolha do modelo de previsão ideal. Uma das principais razões para tal dificuldade está na análise de dados que, idealmente, deveriam ser coletados tanto em setores gerenciais quanto no setor produtivo da organização. Segundo Ballou (2006), para a seleção do método de previsão mais adequado ao estudo, com uma prática racional, deve-se cuidar as etapas de coleta das informações e a escolha da técnica. Como consequência, a falta de padronização na coleta de dados, percebida na empresa em questão, resulta num desconhecimento da demanda real da empresa. Esta é uma das causas raiz para a recorrente falta de componentes em estoque ou excesso dos mesmos e, por consequência, aumento dos custos percebidos durante todo o processo produtivo do setor fabril.

O presente artigo objetiva realizar uma análise acerca dos distintos métodos quantitativos de previsão de demanda, como modelos de suavização exponencial, regressão linear múltipla e ARIMA e, a partir desta análise, propor uma abordagem para a definição do melhor modelo para a empresa de transportes verticais em questão. Devido à alta personalização de produtos acabados e utilização de diversos componentes distintos, o modelo de previsão selecionado irá atuar acerca de dados dos componentes utilizados na produção da empresa em estudo. Os componentes selecionados para o estudo fazem parte do grupo dos mais representativos em relação ao valor de consumo e criticidade da falta deste componente no processo de produção. Assim, para a aplicação desta ferramenta, de acordo com Pellegrini e Fogliatto (2001), será necessário conhecimento e habilidade em quatro áreas básicas: identificação e definição dos problemas a serem tratados na previsão; aplicação dos métodos de previsão de demanda; procedimentos para seleção do método apropriado a situações específicas; e suporte organizacional para adaptar e usar os métodos de previsão de demanda requeridos.

Os resultados deste estudo geram análises acerca dos diferentes modelos existentes de previsão de demanda e um comparativo entre técnicas para, a partir da análise de adaptação de cada uma das técnicas, selecionar a metodologia ideal para uso neste caso. Com a escolha feita, é possível apoiar tomadas de decisões gerenciais da empresa estudada e embasar premissas qualitativas realizadas na empresa. A partir dessa necessidade, o setor de compras possui a incumbência de, além de garantir que os componentes importados estejam disponíveis nas datas de fabricação, garantir um estoque ideal da maioria dos que estão ativos no sistema de controle de produtos. As quantidades e datas de aquisição destes insumos que são determinadas apenas a partir da experiência dos envolvidos no processo, geram resultados que não passam por uma análise histórica dos dados e acarretam faltas recorrentes de alguns componentes e estoques elevados de outros.

O artigo está estruturado em cinco seções, incluindo a presente introdução. Na seção 2, é apresentado o referencial teórico que conceitua e aprofunda os temas abordados a partir da literatura já existente. A seção 3 apresenta o método que explica a maneira com que a pesquisa foi conduzida e seus detalhes estruturais. Na seção 4 são apresentadas as análises dos resultados obtidos a partir dos dados gerados. Por fim, na seção 5, é apresentada a conclusão, que expõe os resultados gerados e encerra o presente trabalho.

2. REFERENCIAL TEÓRICO

Visando auxiliar na etapa prática do trabalho, a presente seção abordou conceitos e definições acerca do tema proposto. A literatura existente serviu de base para conceituar sistemáticas para seleção dos componentes mais representativos, métodos quantitativos de previsão de demanda, e indicadores de desempenho dos modelos preditivos.

2.1. SISTEMÁTICAS PARA PRIORIZAÇÃO DE COMPONENTES

Em uma análise de previsão de demanda de componentes, é comum a necessidade de trabalhar com dados de centenas de SKUs (código único de identificação de componente) distintos. Assim, objetivando a simplificação e eficiência das modelagens, sistemáticas voltadas à classificação e priorização dos componentes segundo critérios pré-estabelecidos auxiliam no agrupamento dos componentes com características semelhantes. Em qualquer ambiente produtivos com múltiplos itens, alguns serão mais importantes para a organização do que outros, demandando maior atenção nos processos a eles relacionados (Slack, Brandon-Jones e Johnston, 2016).

Visando realizar uma classificação de componentes alinhada com os objetivos de gestão e planejamento da empresa, uma maneira de selecionar os componentes mais importantes de acordo com sua relevância financeira e sua criticidade é utilizar o modelo ABC-XYZ. Para tal aplicação, a classificação XYZ, que quantifica a criticidade de falta de um determinado componente para realização dos processos, é combinada à tradicional regra de priorização ABC. Segundo Thomas et al. (2017), a análise ABC-XYZ consolida-se como o modo mais comum de diminuir custos e melhorar diferentes processos em estoques devido à sua simplicidade e acessibilidade.

A etapa de aplicação da análise ABC do método é baseada no Princípio de Pareto. Nesta classificação, Wisniewski (2006) afirma que todos os itens de estoque são categorizados em um dos três grupos – A, B e C – em termos de sua importância relativa para a organização. Os itens da categoria A representam os mais importantes e os da categoria C, os menos importantes. A importância pode ser definida de diferentes maneiras, sendo a principal delas estando relacionada com a contribuição financeira que cada componente faz para o faturamento da organização. Pellegrini (2000) afirma que as três classes podem ser subdivididas percentualmente em (i) Classe A, representando 80 % do faturamento e cerca de 20 % dos produtos vendidos pela empresa; (ii) Classe B, representando 15 % do

faturamento e cerca de 30 % dos produtos vendidos pela empresa; e (iii) Classe C, contemplando 5 % do faturamento e cerca de 50 % dos produtos vendidos pela empresa.

Complementar à classificação ABC, a análise XYZ busca, segundo Viana (2000), tratar os materiais que, independentemente de fraco consumo ou contribuição no faturamento, prejudicam seriamente a continuidade da produção da empresa caso venham a faltar. Desta forma, tornam o custo de falta mais oneroso que o custo de armazenamento. Assim, os componentes são subdivididos em: (i) Componentes X, com pouca importância e com possibilidade de uso similar existente na empresa; (ii) Componentes Y, com importância média, com ou sem produto componente similar na empresa; e (iii) Componentes Z, de suma importância e sem itens similares na empresa. Sua falta pode acarretar a paralisação de processos produtivos.

2.2. PREVISÃO DE DEMANDA

Segundo Ballou (2006), a previsão de demanda é vital para a empresa como um todo, na medida em que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais, dentre elas Logística, Marketing, Produção e Finanças. A partir desta previsão, as quantidades de componentes necessários em um futuro próximo podem ser estimadas e, baseado nestas estimativas, o cronograma de produção pode ser desenvolvido (KUMAR, 2015). Assim, torna-se clara a importância do estudo acerca dos diferentes tipos de demanda e diferentes modelos de previsão para componentes em indústrias de pequeno a grande porte. As atividades da previsão de demanda têm a função de controlar e orientar o decurso logístico e produtivo nas organizações da cadeia de suprimentos (Tomaselli, 2007).

A previsão é uma projeção futura da demanda esperada, dado um conjunto padrão de condições ambientais (Mentzer e Moon, 2005). Para sistemas Make-To-Order (MTO), onde há uma grande variedade de produtos, customização e não há um fluxo de produção contínuo, comumente trabalha-se com previsões de curto prazo. Segundo Peinado e Graeml (2007), as previsões que trabalham com horizontes de tempo curtos são mais precisas e possuem o maior índice de desagregação possível.

As previsões de demanda são elaboradas utilizando técnicas qualitativas e quantitativas ou, ainda, uma mistura de ambas (Pellegrini, 2000). Para selecionar a metodologia ideal para análise, é preciso avaliar os tipos de dados disponíveis. A abordagem qualitativa baseia-se na experiência dos gestores para construir uma previsão, a partir dos

conhecimentos de mercado, comportamento dos consumidores recorrentes e vendas em diferentes períodos do ano, por exemplo. Por outro lado, o método quantitativo é balizado por análises de dados, nas quais diversas variáveis podem ser abordadas, realizadas a partir de modelos matemáticos (Hyndman e Athanasopoulos, 2018).

Embora a previsão de demanda seja necessária e proporcione informações futuras para tomadas de decisões mais eficazes por parte dos gerentes, ela não é exata (Davis, Aquilano e Chase, 2001). Bowersox et al. (2006) citam que, por conta desta falta de exatidão, o processo de seleção da técnica de previsão que produz os melhores resultados configura-se mais como arte do que uma ciência.

Diferentemente do método quantitativo, a metodologia qualitativa é não científica e, por isso, possui uma difícil padronização. Em ambientes industriais onde há disponibilidade de dados para tal análise, torna-se preferível a escolha do método quantitativo. As previsões qualitativas são normalmente concluídas em reunião de consenso, são dispendiosas e consomem muito tempo. Por esta última razão, não são as mais apropriadas para a cadeia de suprimento (Bowersox et al., 2006).

Os métodos quantitativos dividem-se em dois principais grupos: métodos de análise de séries temporais e métodos causais (Ghiani, Laporte e Musmanno, 2004). O primeiro deles, grupo que será abordado no desenvolvimento deste trabalho, baseia-se em um modelo matemático desenvolvido para analisar a demanda futura a partir de dados históricos com foco na variável tempo. Nele, é realizada uma projeção histórica para obter resultados futuros. Ballou (2006) cita que a utilização deste modelo deve ser feita quando existe uma característica que permite a adaptação a mudanças nos padrões de tendência e sazonalidade. Os fundamentos de modelos focados em previsão temporal são agora detalhados.

2.2.1. MODELOS DE SUAVIZAÇÃO EXPONENCIAL

As técnicas de suavização exponencial são amplamente utilizadas quando se tem como objetivo atingir um resultado robusto baseado em métodos de séries temporais com uma base estatística sólida. Segundo Ballou (2006), estes modelos são simples, necessitam um mínimo de dados retidos para aplicação contínua e têm a capacidade de adaptação às mudanças fundamentais nos dados de previsão. Além disso, a suavização exponencial facilita a computação e reduz os requisitos de armazenamento de dados, que são de suma importância quando muitas séries estão sendo previstas (Segura e Vercher, 2001).

2.2.1.1. SUAVIZAÇÃO EXPONENCIAL SIMPLES

A suavização exponencial simples é uma das principais classes de modelos usados em previsão de séries temporais. Este método é utilizado quando o padrão de dados é aproximadamente horizontal, ou seja, não há um padrão de sazonalidade ou tendência clara na série analisada (Ostertagová e Ostertag, 2011). Segundo Armstrong (2005), a constante presente na equação é utilizada para suavizar as variações cíclicas para prever a tendência. Esta metodologia baseia-se no princípio de que os dados mais recentes devem ser mais ponderados, enquanto os dados mais antigos se tornam menos relevantes e devem receber menor peso. As previsões deste modelo podem ser obtidas através da equação (1) (Wisniewski, 2006).

$$F_{t+1} = \alpha_t Y_t + (1 - \alpha_t) F_t \quad (1)$$

Em que F_{t+1} = previsão da demanda para o período $t+1$, feita no período atual t ; α_t = constante de suavização, assumindo valores entre 0 e 1; Y_t = valor da demanda série temporal para o tempo t ; e F_t = valor da previsão feita para o tempo t .

A constante de suavização irá determinar o grau de suavidade da curva de projeção. Valores próximos de 0 irão implicar em menores correções da base e resultarão em uma curva mais suave. Já os valores próximos de 1 irão produzir maiores correções, resultando em uma série projetada mais irregular (Lustosa et al., 2008). Portanto, quanto mais próximo de 1 for o valor de α , maior será o ajuste do erro na previsão anterior, maior ênfase será dada a demandas recentes e o resultado será mais sensível a mudanças.

Segundo Pellegrini (2000), a determinação do melhor valor para a constante pode ser feita iterativamente utilizando a média do quadrado dos erros, MQE. Desta maneira, seleciona-se aleatoriamente um valor inicial para a constante, a partir do qual previsões são geradas. A partir disso, comparam-se os valores previstos com os reais e calcula-se a média do quadrado das diferenças entre eles. Como resultado, o parâmetro que minimiza essa média é utilizado no modelo final. Ademais, Pellegrini (2000) ainda destaca que, para medir a acurácia desse modelo, basta calcular o erro gerado por ela através da fórmula (2):

$$E_t = Y_t - F_t \quad (2)$$

Novaes et al. (2008) utilizaram a técnica de suavização exponencial simples para realizar uma previsão de demanda de vacinas para um serviço de imunização privado da cidade de Juiz de Fora, Minas Gerais. A metodologia consistiu na análise de quatro séries

históricas das demandas de vacinas e chegou em resultados que sustentaram a aplicabilidade do modelo nas séries de vacinas observadas. Além disso, é sinalizado que o método é de fácil implementação em planilhas eletrônicas clássicas e dispensam a aquisição de softwares ou hardwares sofisticados para sua implementação.

2.2.1.2. SUAVIZAÇÃO EXPONENCIAL DUPLA

Também conhecida como método de Holt, a suavização exponencial dupla é um método linear que introduz mais uma constante à modelagem. A suavização exponencial simples foi ampliada para dados de séries temporais que apresentam tendência linear, mas que não possuem sazonalidade (Lustosa et al., 2008). Segundo Morettin e Toloí (2018), esse método é similar à Suavização Exponencial Simples. A diferença entre eles é que, ao invés de suavizar só o nível, ele utiliza uma nova constante de suavização para “modelar” a tendência da série. Assim, para tal análise, a constante de suavização α é utilizada para a equação (4) que visa estimar o nível da série temporal e a constante de suavização β para o cálculo da tendência da série (5). Além das duas equações citadas anteriormente, o método possui uma equação para o cálculo da previsão (3) (Makridakis et al., 1998):

$$F_{t+m} = L_t + b_t m \quad (3)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (4)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (5)$$

Em que L_t = nível da série no tempo t ; e b_t = estimativa da inclinação da série no tempo t .

De acordo com Pellegrini e Fogliatto (2001), assim como na suavização exponencial simples, os valores das constantes de suavização no modelo de Holt podem ser determinados a partir de uma combinação de valores para α e β que minimize a MQE.

Em seu artigo, Li (2013) utiliza o método de Holt para analisar a precisão de seu modelo, na análise de previsão do volume de frete em Pequim nos modelos ferroviário, rodoviário e marítimo. Por meio de uma comparação com outros modelos de previsão, foi comprovado que a precisão da suavização exponencial de Holt era preferível naquelas circunstâncias. O autor propôs que, além de uma maior precisão, o modelo em questão apresenta grande facilidade de aplicação e entendimento.

Similarmente, Alves et al. (2019) realizou a aplicação do método de suavização exponencial dupla para obter, em curto prazo, previsões para o planejamento da

demanda do processo produtivo em uma indústria metalúrgica. Os resultados obtidos foram fundamentais para o analista do sistema de previsão de demanda direcionar especial atenção ao grau de acurácia que integrado a uma política de gerenciamento de estoques eficiente foi responsável por minimizar os efeitos de variabilidade e custos operacionais, além contribuir na melhoria dos níveis de serviço e no conseqüente aumento da rentabilidade da indústria envolvida.

2.2.1.3. SUAVIZAÇÃO EXPONENCIAL TRIPLA

A Suavização Exponencial Tripla, ou método de Holt-Winters, descreve apropriadamente dados de demanda em que se verifica a ocorrência de tendência linear, além de um componente de sazonalidade (Pellegrini e Fogliatto, 2001). A suavização exponencial de Holt-Winters, de acordo com Makridakis et al. (1998), possui abordagens distintas quando a sazonalidade é modelada: modelo sazonal multiplicativo e modelo sazonal aditivo.

2.2.1.3.1 MODELO SAZONAL MULTIPLICATIVO

De acordo com Pellegrini e Fogliatto (2001), o modelo multiplicativo deve ser utilizado em modelagens de dados sazonais, em que a amplitude do ciclo sazonal varia com o passar do tempo. Sua representação matemática pode ser dada por (Makridakis et al., 1998):

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta) b_{t-1} \quad (7)$$

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (8)$$

$$F_{t+m} = (L_t + mb_t)S_{t-s+m} \quad (9)$$

Em que s = período completo da sazonalidade (exemplo: números de meses dentro de um ano); L_t = nível da série; b_t = tendência da série; S_t = sazonalidade da série; F_{t+m} = previsão para m períodos a frente; e γ = constante de suavização que controla o peso relativo à sazonalidade (varia entre 0 e 1).

2.2.1.3.2 MODELO SAZONAL ADITIVO

Diferente do modelo multiplicativo, no modelo sazonal aditivo, a demanda apresenta uma pequena distinção entre seu valor máximo e mínimo ao longo do período analisado. Assim, a amplitude da variação sazonal é constante ao longo do tempo. Esta abordagem possui a equação de tendência (11) idêntica em relação a apresentada no modelo sazonal multiplicativo. Sua representação matemática pode ser dada por (Makridakis et al., 1998):

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (10)$$

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta) b_{t-1} \quad (11)$$

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (12)$$

$$F_{t+m} = (L_t + mb_t)S_{t-s+m} \quad (13)$$

Ainda segundo Makridakis et al. (1998), as únicas diferenças entre as equações (10) (12) dos diferentes modelos de suavização exponencial tripla são os índices sazonais. Nesse caso, são adicionados e subtraídos, ao invés de serem utilizados em multiplicações e divisões.

Tratar e Strmcnik (2016) utilizam-se da metodologia de Holt-Winters para enfrentar os desafios de sustentabilidade propostos pela União Europeia. No estudo, apresentaram uma abordagem de previsão de demanda de descarga de calor de curto e longo prazo em três níveis: diária, semanal e mensal. Os desempenhos apontaram que a suavização exponencial tripla garante os melhores valores de previsão com o propósito de análise a longo prazo, auxiliando, assim, o planejamento futuro da empresa eslovena que atende esta demanda.

Similarmente, Veríssimo et al. (2012) aplicou métodos estatísticos de suavização exponencial Holt-Winters para a previsão de demanda em uma empresa do setor metal mecânico. O estudo mostrou a eficácia da aplicação da metodologia, produzindo resultados eficientes na previsão de demanda dos produtos analisados. Para a empresa em questão, as previsões realizadas auxiliaram na definição da programação de produção, planejamento da capacidade de produção, controle de estoques, aquisição de matéria prima e contratação de mão de obra.

2.2.2. ARIMA

Quando um modelo é analisado, este pode ser classificado como estacionário ou não-estacionário. Segundo Werner e Ribeiro (2003), os modelos estacionários são denominados fracamente estacionários se suas médias e variâncias se mantêm constantes ao longo do tempo e fortemente estacionários se todos os momentos conjuntos são invariantes à translação no tempo. Já os modelos não-estacionários caracterizam uma série temporal que apresenta média e variância que dependem do tempo e seus dados não seguem uma constante.

O modelo autorregressivo integrado de média móvel (ARIMA), conhecido também como metodologia de Box-Jenkins, se diferencia do modelo autorregressivo conhecido como “ARMA” por, além de considerar o componente Autorregressivo (AR) e o componente de Médias Móveis (MA), incorporar diretamente a tendência determinística da série temporal através do filtro de integração (I) (Gujarati e Porter, 2011). Como resultado positivo, o modelo confere rapidez e conveniência na previsão de séries temporais.

Por outro lado, caso seja necessário diferenciar uma série temporal d vezes para torná-la estacionária e aplicar-lhe o modelo ARMA (p, q), diremos que a série temporal original é ARIMA (p, d, q), ou seja, ela é uma série temporal autorregressiva integrada de médias móveis, em que (p) denota os números dos termos autorregressivos, (d) o número de vezes que a série deve ser diferenciada antes de tornar-se estacionária e (q) o número de termos de média móvel (Hamilton, 1994; Gujarati e Porter, 2011).

Geralmente, o argumento representado pelo parâmetro “ d ” varia entre 1 e 2, demonstrando que é necessário tomar apenas uma ou duas diferenças para transformar a série não-estacionária em estacionária. Makridakis et al. (1998) sugerem que a notação geral do modelo ARIMA (14) pode ser representada por:

$$ARIMA(p, d, q)(P, D, Q)_s \quad (14)$$

Em que (p, d, q) = parte não-sazonal do modelo; e $(P, D, Q)_s$ = parte sazonal do modelo;

$$F'_t = \phi F_{t-1} + a_t \quad (15)$$

Neste caso, entretanto, a equação é construída com termos diferenciados (F'_t), podendo se tratar de qualquer nível de diferenciação.

Hien Do et al. (2021) aplicaram o modelo ARIMA para realizar uma previsão de demanda de produtos específicos em uma indústria de vestuário. Os resultados atingidos forneceram dados de entrada para um planejamento mais eficiente da produção, estoque e distribuição, possibilitando, assim, a empresa a reduzir os custos operacionais e melhorar a eficiência do abastecimento.

García, Peñate e Pérez (2022) realizaram uma previsão de vendas de gengibre no Equador a partir do uso do ARIMA. Quando comparados à outros métodos de previsão, o modelo ARIMA apresentou menores erros de previsão e, por sua vez, uma distribuição normal dos resíduos. Assim, foi possível prever com maior segurança o cenário de produção e exportação do gengibre para o período analisado, determinando o preço do alimento entre 1,34 e 2,16 dólares, a quantidade esperada de exportação de 8.930,94 e 52.746,62 quilos e as vendas em mil dólares oscilando entre 9.338,53 e 15.916,16 dólares.

2.2.3. SARIMA

O modelo autorregressivo com médias móveis integrado e componente sazonal (SARIMA) é uma extensão do ARIMA, com a adição da integração de componentes de sazonalidade às séries estocásticas dos dados. De acordo com Werner e Ribeiro (2003), os modelos SARIMA também contêm uma parte não sazonal, com parâmetros (p,d,q), e uma sazonal, com parâmetros (P,D,Q)s. Além disso, o parâmetro s representa o período sazonal analisado. A equação (16) que representa o modelo SARIMA é representada por (Kibunja et al., 2014):

$$\phi_p(B)\Phi_P(B^S)(1-B)^d(1-B^S)^D F_t = \phi_0 + \theta_q(B)\theta_Q(B^S)\varepsilon_t \quad (16)$$

Em que $\phi_p(B)$ = parte autorregressiva não-sazonal de ordem p ; $\Phi_P(B^S)$ = parte autorregressiva sazonal de ordem P e estação sazonal s ; $(1-B)^d$ = parte de integração não-sazonal de ordem d ; $(1-B^S)^D$ = parte de integração sazonal de ordem D e estação sazonal s ; $\theta_q(B)$ = parte não-sazonal de médias móveis de ordem q ; e $\theta_Q(B^S)$ = parte sazonal de médias móveis de ordem Q e estação sazonal s ;

2.2.4. REGRESSÃO LINEAR MÚLTIPLA

Makridakis et al. (1998), afirma que a regressão múltipla possui uma variável a ser prevista e duas ou mais variáveis explanatórias. A forma geral da regressão múltipla (17) é:

$$F_i = \beta_0 + \beta_1 x_{1i} + \beta_2 x_{2i} + \dots + \beta_k x_{ki} + \varepsilon_i \quad (17)$$

Em que F_i = valores da variável resposta, $i = 1, 2, \dots, n$ observações; x = valores das variáveis independentes, $k = 1, 2, \dots, K$ variáveis; β_k = parâmetros do modelo; e ε_i = erro aleatório.

Mesmo quando o foco recai exclusivamente em uma única variável independente, é recomendável incorporar outras variáveis com potencial para influenciar a variável dependente. Isso se deve ao fato de que, na análise de regressão linear múltipla, as variações que ocorrem em uma variável podem ser elucidadas fazendo referência a alterações em diversas outras variáveis. Frequentemente uma combinação de procedimentos é utilizada para obter a lista final de variáveis explanatórias (Makridakis et al., 1998)

Segundo Lemos (2006), a lista inicial de variáveis independentes é baseada na experiência de especialistas, na disponibilidade dos dados e em restrições de tempo e custo. Esta lista deve ser filtrada usando procedimentos formais como regressões de subconjuntos de variáveis, análise de componentes principais de todas as variáveis (incluindo a variável a ser prevista) para decidir quais são as variáveis importantes.

Lopes (2012) avalia a otimização do processo industrial de moagem de trigo através da utilização de regressão linear múltipla. No estudo, as variáveis independentes utilizadas foram dureza, peso de mil grãos, umidade e distribuição do tamanho do grão foram relacionadas com a variável dependente taxa de extração. Os resultados obtidos sinalizaram que a ferramenta pode auxiliar a otimização deste processo produtivo e determinou-se também o valor do R^2 que ficou satisfatório para uma análise inicial do processo, pois o valor encontrado 0,90 indica que em mais de 90% das situações a regressão linear múltipla pode ser aplicada dentro do diagrama de moagem pesquisado.

Garcia e Bordeaux-Rego (2015) utilizam-se da regressão linear múltipla para construir um modelo econométrico que auxilie no processo de tomada de decisão gerencial, através da análise do comportamento da demanda do produto. Neste estudo, os estimadores dos parâmetros de regressão se mostraram eficientes ao corrigir o problema da heterocedasticidade e contribuíram para um melhor ajuste do modelo em que se minimizou o erro médio entre a demanda real e a demanda estimada, aumentando a receita total.

Ainda, Bouzada e Saliby (2009) evidenciam um estudo de caso em que aplicam a regressão linear múltipla com variáveis *dummy* para combater o problema da previsão de demanda de chamadas para um determinado produto no *call center* de uma grande empresa brasileira do setor. Como resultados obtidos, foi constatado que a ferramenta de previsão contratada pela empresa estudada, não levava em conta algumas informações que poderiam refinar o processo de previsão. Assim, o estudo aponta uma acurácia superior do modelo de previsão baseado na regressão linear múltipla frente às previsões calculadas pela ferramenta.

3. PROCEDIMENTOS METODOLÓGICOS

3.1. DESCRIÇÃO DO CENÁRIO

A Engix Elevadores é uma empresa que presta serviços relacionados à fabricação, instalação e manutenção de elevadores. Fundada em 1997, já passou por diferentes reformulações e, com a entrada de novos sócios em 2019, uma visão diferente foi posta em pauta e mudanças estratégicas e operacionais foram implementadas. Desde então, a empresa cresceu substancialmente e hoje conta com um portfólio de produtos abrangente e mais de 850 elevadores instalados pela região sul do Brasil. A Engix Elevadores é reconhecida no mercado, principalmente por seu atendimento personalizado aos seus clientes e fabricação de elevadores customizados sob medida, fatores diferenciais que contribuíram para este crescimento citado e para o objeto do estudo em questão. Segundo classificação proposta pela Agência Nacional de Vigilância Sanitária – Anvisa, a Engix Elevadores é considerada uma empresa de médio porte.

A empresa é subdividida em diferentes setores: fabricação, administrativo, manutenção e instalação. As decisões gerenciais acerca do processo de compra de materiais são centralizadas no responsável pelo setor de compras da empresa e no sócio que trabalha mais próximo a operação. Além disso, o gerente do setor produtivo tem forte participação neste planejamento por ter vasta experiência com o produto e ter conhecimento acerca dos processos de recebimento e compra de componentes.

3.2. CLASSIFICAÇÃO DA PESQUISA

A presente pesquisa é classificada, quanto à natureza, como aplicada. Essa classificação é dada em função do estudo ter como objetivo imediato a resolução de um problema específico, relacionado à previsão de demanda em indústrias de alta

customização, envolvendo aplicação prática em uma organização real (Gerhardt e Silveira, 2009). Quanto à abordagem, classifica-se majoritariamente como quantitativa, visto que utiliza de métodos matemático e estatísticos para, com o envolvimento de variáveis, conduzir uma análise de previsão de demanda e construção dos resultados (Fonseca, 2002). Quanto aos objetivos, trata-se de pesquisa explicativa pois, a partir dos resultados oferecidos por cada análise, é desenvolvido um sistema de previsão de demanda cujo fim é explicar o comportamento da demanda em indústria de alta customização (Gil, 2002). Ainda segundo Gil (2002), quanto ao procedimento, classifica-se como uma pesquisa-ação, em virtude de necessitar o envolvimento ativo do pesquisador e a ação por parte dos colaboradores da empresa que estão envolvidos no setor em estudo.

3.3. ETAPAS DO TRABALHO

O método proposto neste estudo foi desenvolvido em quatro etapas: (i) coleta de dados para caracterização e seleção dos componentes mais representativos, (ii) implementação de sistemática de classificação dos componentes mais representativos, (iii) modelagem dos dados históricos de demanda dos componentes mais representativos e seleção do método mais adequado, e (iv) análise e discussão dos resultados gerados pelos métodos analisados.

3.3.1. COLETA DE DADOS E SELEÇÃO DOS COMPONENTES MAIS REPRESENTATIVOS

A primeira etapa do método contemplou a coleta de dados para caracterização e seleção dos componentes mais representativos utilizados nos processos que envolvem compra e transformação dos componentes envolvidos. Tais dados foram reunidos a partir de consultas aos bancos de dados armazenados nos sistemas dos setores de engenharia, produção e comercial da empresa. Estas informações contêm dados sobre os componentes, sua demanda em distintos períodos e diferentes informações utilizadas como critérios de agrupamento na modelagem matemática da previsão de demanda.

Quanto ao armazenamento dos dados citados, eles são alimentados a partir de apontamentos em processos, os quais incluem recebimento de ordens de compras, identificação de não-conformidades no processo produtivo, apontamentos de ordens de produção e checklists distintos. Todos estes marcos dos processos estão evidenciados e registrados em procedimentos operacionais padrão (POP) e fluxogramas desenvolvidos e validados pelo setor administrativo ligado à operação.

3.3.2. IMPLEMENTAÇÃO DE SISTEMÁTICA DE CLASSIFICAÇÃO DOS COMPONENTES MAIS REPRESENTATIVOS

Com a etapa de coleta e tratamento de dados concluída, procedeu-se à classificação dos componentes mais representativos. Tendo em vista a elevada variedade de SKUs identificados, e com o objetivo de simplificar a modelagem para um resultado replicável e eficiente, foi realizado o agrupamento dos componentes a partir da abordagem ABC-XYZ para a classificação dos componentes mais representativos desta indústria.

Para tanto, a classificação ABC foi aplicada por meio da relação de valor de consumo. Este valor foi determinado a partir do produto entre custo unitário e volume de cada um dos componentes analisados por meio do histórico de demanda. Já o método de segmentação XYZ foi utilizado para dividir os componentes em grupos que representavam a criticidade da falta do componente para a realização dos processos fabris. Como resultado desta combinação de classificações, foi possível trabalhar com uma matriz *Nine Box* representada pela Figura 1, método de avaliação em que cada componente foi alocado em uma das nove classificações existentes.

	A	B	C
X	Itens com alto valor de consumo e baixa criticidade	Itens com valor de consumo considerável e baixa criticidade	Itens com baixo valor de consumo e baixa criticidade
Y	Itens com alto valor de consumo e média criticidade	Itens com valor de consumo considerável e média criticidade	Itens com baixo valor de consumo e média criticidade
Z	Itens com alto valor de consumo e alta criticidade	Itens com valor de consumo considerável e alta criticidade	Itens com baixo valor de consumo e alta criticidade

Figura 1 – Matrix Nine Box representando a classificação ABC-XYZ

3.3.3. MODELAGEM DOS DADOS HISTÓRICOS DE DEMANDA E SELEÇÃO DO MÉTODO MAIS ADEQUADO

A partir da classificação dos componentes em cada um dos grupos possíveis da matriz, foram selecionados para o estudo, primeiramente, todos aqueles que foram alocados no grupo “AZ”, representando os componentes com alto valor de consumo e alta criticidade.

Para limitar os componentes que teriam suas séries históricas modeladas, dividiu-se o grupo “AZ” em três famílias:

- Componentes importados: Os componentes importados foram retirados do estudo pois há uma necessidade de realizar seu pedido assim que o equipamento é vendido. O tempo de importação elevado totaliza mais de 3 meses, período modelado de previsão da demanda;
- Componentes nacionais: Componentes nacionais que necessitam de uma compra periódica por parte da empresa, podem ser estocados e são utilizados em diversos produtos;
- Componentes endereçados: São aqueles desenvolvidos especialmente para o elevador em questão, normalmente compondo a chaparia do produto final ou a parte mecânica. Estes componentes foram retirados do estudo por não haver possibilidade de estocar a matéria-prima dos que necessitam corte à *laser* por limitações técnicas e de maquinário. Assim, quando é elaborado o projeto por parte da engenharia e componentes específicos para a venda em questão são desenvolvidos, estes são solicitados aos respectivos fornecedores.

Assim, foram selecionados os componentes contemplados pela família dos nacionais para as modelagens dos dados históricos de demanda. Em seguida, aplicou-se o teste ADF (*Augmented Dickey Fuller*), usado na determinação da presença de raiz unitária nas séries, verificando se a série é estacionária ou não. Baseado neste teste, apenas as séries estacionárias seguiram para a etapa de modelagem.

As séries temporais de demanda dos componentes selecionados foram separadas em duas porções (treino e teste) para posterior avaliação da qualidade das previsões realizadas. Tal divisão cumpre papel fundamental na aplicação das modelagens matemáticas, pois há necessidade de gerar o modelo (com os dados de treino), antes de analisar seu desempenho preditivo (dados de teste). O conjunto de treino costuma abranger cerca de 70% dos dados (geralmente os mais antigos), sendo utilizado para a construção do modelo preditivo. Já o conjunto de teste representa cerca de 30% do total e é usado para validação da capacidade preditiva do modelo.

A partir da separação dos dados nos dois conjuntos retratados, os modelos quantitativos de previsão de demanda referenciados na seção de revisão foram ajustados aos dados da porção de treino. Cada modelagem matemática gerou um MAPE (*Mean Absolute*

Percentage Error, que estima a média das diferenças absolutas entre o valor real e o valor previsto), para a porção de treino (possibilitando avaliar a adequação de cada modelo avaliado aos dados históricos) e um MAPE para a porção de teste (possibilitando avaliar a capacidade preditiva de cada modelo). Com a análise dos resultados de MAPE e o conhecido poder de previsão dos modelos, exemplificados na Tabela 1, foi identificada a necessidade de agrupar os dados em períodos maiores que o mensal. Este agrupamento teve como objetivo minimizar o impacto de demandas fora do comum e obter uma diminuição do percentual do erro absoluto em cada um dos modelos. O modelo com o menor MAPE na porção de teste para cada componente avaliado é selecionado para previsões futuras.

Tabela 1 – Poder de previsão de modelos a partir do MAPE

VALOR DE MAPE	PODER DE PREVISÃO
<10%	PREVISÃO MUITO PRECISA
10% ~ 20%	BOA PREVISÃO
20% ~ 50%	PREVISÃO RAZOÁVEL
>50%	PREVISÃO FRACA E IMPRECISA

Fonte: Adaptado de Lewis (1982)

3.3.4. ANÁLISE E DISCUSSÃO DOS RESULTADOS GERADOS PELOS MÉTODOS ANALISADOS

A última etapa do trabalho teve como objetivo analisar os resultados gerados pelos métodos de previsão de demanda propostos. Nela, foram expostos os parâmetros evidenciados na etapa de modelagem dos dados históricos de demanda e houve uma comparação da demanda real no período analisado com a demanda utilizada como resultado do *forecasting*.

Assim, foi possível utilizar o modelo sinalizado como mais apropriado para o estudo em questão para realizar previsões de demandas futuras dos diferentes tipos de componentes e evidenciar o impacto deste dimensionamento quantitativo de demanda nos custos operacionais da empresa.

4. RESULTADOS E DISCUSSÃO

O presente estudo foi aplicado em uma indústria com foco na produção de elevadores personalizados que possui um portfólio de 4 produtos base distintos com medidas variadas de acordo com as especificações do cliente. Existe uma demanda média de 15 elevadores no mês e, com isso, é preciso disponibilizar todos os insumos necessários para não cessar o ritmo do setor.

Com a sabida demanda média de elevadores, se faz necessária a atuação do setor de compras para garantir níveis de estoques adequados de cada componente ativo, com uma análise embasada e condizente aos dados históricos, sem gerar excesso em estoque. Visando facilitar tais tomadas de decisão, o presente estudo atua na definição do método mais adequado para prever a demanda de componentes do processo fabril para 3 meses. Esta definição passa não só pela escolha do melhor modelo preditivo, mas pela determinação dos componentes mais representativos do processo.

Para os componentes disponíveis para análise, convencionou-se a extração de dados dos elevadores comercializados e produzidos entre novembro de 2020 e julho de 2023. As informações coletadas são resultado do apontamento de operações dos setores de engenharia, compras e produção, sendo compiladas em bancos de dados MSAccess. Os dados adquiridos englobam informações de componentes de cada elevador e de custos despendidos na compra de seus componentes, totalizando 293 instalações, mais de 80.000 componentes utilizados ao longo do período (4.000 componentes distintos).

Mediante ao levantamento e tratamento inicial dos dados e buscando realizar a seleção dos componentes mais representativos para o estudo, foram compiladas as quantidades de cada componente utilizadas nas 293 obras. Inicialmente, visando quantificar a criticidade de falta de um determinado componente para realização dos processos com a classificação XYZ, foi repassado ao responsável pela área produtiva da empresa uma listagem com todos os componentes inclusos na análise para determinar o grupo adequado para cada um deles. Os componentes foram divididos entre as categorias X (componentes que possuem baixa criticidade), Y (componentes que possuem média criticidade) e Z (componentes que possuem alta criticidade). Como resultado, chegou-se à distribuição da Figura 2. Percebe-se uma grande disparidade na distribuição dos componentes: cerca de 75% dos componentes utilizados nas obras analisadas são de suma importância e não possuem componentes similares na empresa para a substituição.

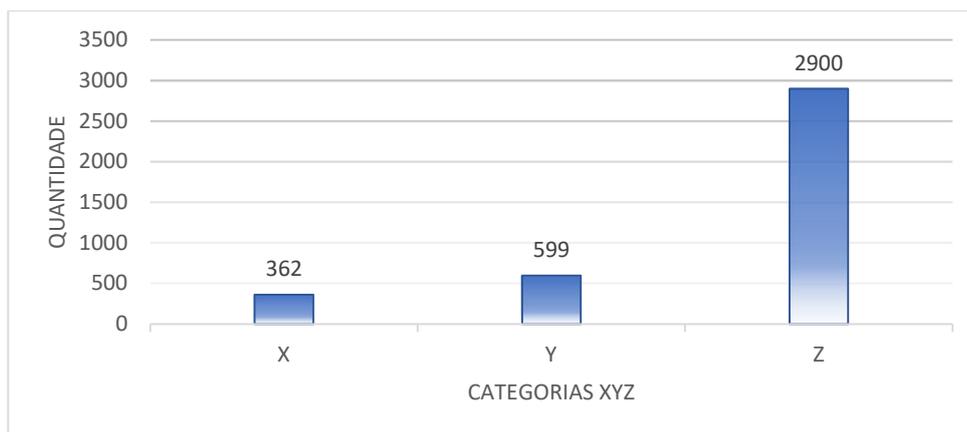


Figura 2 - Gráfico da classificação XYZ dos componentes

Buscando restringir a escolha dos componentes a serem analisados e concentrar esforços naqueles que devem de fato ser controlados e estocados, realizou-se uma classificação em ordem decrescente dos componentes em relação ao produto do volume utilizado ao longo do período total e seus custos unitários médios por meio da técnica ABC.

Com esta disposição dos dados, as quantidades totais de utilização de cada um dos insumos foram unificadas e utilizadas para o cálculo do custo total de cada um deles. Assim, foi possível classificar os componentes entre as três classes disponíveis. A classe A resultou em 242 componentes dos 3860 contemplados. A classe B abrange 790 componentes e a classe C possui a maior quantidade de componentes em sua categoria, com 2828 componentes. Com os resultados da classificação ABC, percebe-se que a empresa possui poucos componentes que concentram a maior parte do valor acumulado em estoque. Este fato reflete o alto nível de personalização dos produtos fabricados e a alta quantidade de SKUs distintos utilizados no processo produtivo.

A combinação das classificações propostas resultou na classificação ABC-XYZ que se baseia na alocação de cada um dos componentes em uma matriz *Nine Box* apresentada na Figura 1. Para o estudo em questão, foram selecionados apenas os componentes classificados como AZ, considerados itens com alto valor de consumo e alta criticidade, e que faziam parte da família dos componentes nacionais, desconsiderando, assim, os importados e endereçados em função das suas especificidades já apresentadas anteriormente.

Com esta redução na quantidade de componentes a serem analisados, restaram 81 componentes na categoria AZ e, destes, foram selecionados como mais importantes para a aplicação dos métodos de previsão os que possuíam o apontamento médio de ao menos 10

unidades por mês (métrica de período utilizada no estudo). Além disso, com o teste ADF, realizou-se a remoção dos componentes que possuíam séries temporais não estacionárias. A Tabela 2 contempla os 11 componentes a serem modelados. Complementarmente, a Tabela 3 fornece a descrição dos componentes selecionados.

Tabela 2 – Resumo dos componentes selecionados para a aplicação do estudo

CÓDIGO	VALOR MÉDIO	QTD	VALOR TOTAL	ABC	XYZ	FAMÍLIA
M4.0001	R\$ 17,86	3920	R\$ 70.011,20	A	Z	NACIONAL
M1.0001	R\$ 23,85	2973	R\$ 70.906,05	A	Z	NACIONAL
M2.0001	R\$ 28,95	1086	R\$ 31.439,70	A	Z	NACIONAL
M17.0022	R\$ 26,60	953	R\$ 25.349,80	A	Z	NACIONAL
M2.0009	R\$ 19,24	852	R\$ 16.392,48	A	Z	NACIONAL
M2.0002	R\$ 59,75	846	R\$ 50.548,50	A	Z	NACIONAL
U7.0027	R\$ 17,05	781	R\$ 13.316,05	A	Z	NACIONAL
U7.0019	R\$ 13,21	703	R\$ 9.286,63	A	Z	NACIONAL
M2.0004	R\$ 23,24	551	R\$ 12.805,24	A	Z	NACIONAL
M18.0002	R\$ 16,07	489	R\$ 7.858,23	A	Z	NACIONAL
M19.0003	R\$ 16,39	480	R\$ 7.867,20	A	Z	NACIONAL

Tabela 3 – Código e descrição dos componentes selecionados para a aplicação do estudo

CÓDIGO	DESCRIÇÃO
M4.0001	CADEIRA
M1.0001	BASE 240mm
M2.0001	BRAÇO 295mm
M17.0022	Suporte do piso
M2.0009	Braço do Bracket 250mm
M2.0002	Braço do Bracket 335mm
U7.0027	SUPORTE FIXAÇÃO PORTA ALVENARIA
U7.0019	Sapata para Marco Largo
M2.0004	Braço do Bracket 210mm
M18.0002	BASE SUPORTE DA CORREDIÇA CHAPA RETA 3/8" 38 X 200mm
M19.0003	CHAPA BASE DO BLOCO DO FREIO - SAE 1020

Selecionados os componentes, foi necessário dividir seus dados mensais de demanda em porções de treino e teste. Como o objetivo da modelagem é realizar a previsão de 3 meses futuros, foram selecionados 28 períodos para geração dos modelos (dados de treino), e 5 períodos para validação da capacidade preditiva (dados de teste). Assim, em termos percentuais, 85% da totalidade dos dados foram voltados para treino e 15% para teste. Na Figura 3 pode-se observar estas partições durante o período.

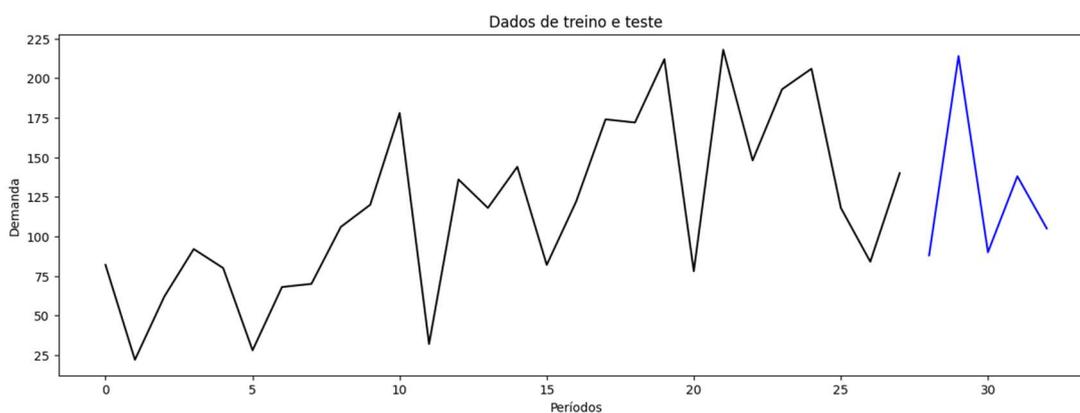


Figura 3 – Porções treino e teste dos dados históricos do componente M4.0001

Com os conjuntos de dados de treino e teste selecionados para cada um dos componentes a serem analisados, foi, inicialmente, realizado o cálculo do MAPE para cada uma das porções de treino nas modelagens matemáticas escolhidas (Suavização Exponencial Simples, Holt, Holt-Winters Aditivo, Holt-Winters Multiplicativo, Arima, Sarima e Regressão Linear Múltipla). Para os modelos Arima e Sarima, utilizou-se a análise da autocorrelação (ACF) e da autocorrelação parcial (PACF) para a determinação dos parâmetros (p, d, q) e (P, D, Q) que melhor descreviam a série temporal de cada um dos componentes analisados.

Os resultados da Tabela 4 demonstram um alto percentual de erro para cada porção de treino dos modelos. Isso evidencia a baixa qualidade do ajuste dos modelos aos dados para a maior parte dos resultados, o que pode ser justificada pela elevada dispersão dos dados e falta de padrão de repetição de algumas séries.

Tabela 4 – Resultado do MAPE gerado para cada modelo na porção treino

MAPE - PORÇÕES DE TREINO - DADOS MENSAIS							
CÓDIGO	SES	HOLT	HW-ADD	HW-MUL	ARIMA	SARIMA	REG. MÚLTIPLA
M4.0001	48,34	48,72	38,75	36,83	42,53	41,95	31,76
M1.0001	40,98	40,80	31,72	29,19	39,74	56,32	28,88
M2.0001	199,46	233,64	194,04	183,24	45,17	120,24	190,39
M17.0022	42,14	42,41	37,792	33,60	28,49	25,78	36,76
M2.0009	191,13	145,63	107,96	117,43	80,64	93,26	138,19
M2.0002	412,43	414,53	289,66	310,35	72,79	47,63	332,05
U7.0027	80,45	98,10	353,17	180,44	102,41	118,63	358,79
U7.0019	327,07	360,69	246,36	239,26	107,28	156,37	242,7
M2.0004	506,64	559,39	413,69	353,91	888,63	669,41	391,55
M18.0002	70,47	58,08	50,02	47,20	43,45	54,91	42,05
M19.0003	71,31	59,17	51,17	48,24	35,78	45,72	42,18

Na sequência, validou-se a capacidade preditiva dos modelos em dados não utilizados na construção do modelo (ou seja, porções de teste), calculando-se o MAPE para cada modelagem (ver Tabela 5). Valores reduzidos de MAPE são desejados, pois revelam menores erros na predição.

Tabela 5 – Resultados de MAPE para os modelos analisados em dados mensais

MAPE - PORÇÕES DE TESTE - DADOS MENSAIS							
CÓDIGO	SES	HOLT	HW-ADD	HW-MUL	ARIMA	SARIMA	REG. MÚLTIPLA
M4.0001	37,53	42,93	70,65	77,06	28,03	38,35	29,89
M1.0001	46,71	35,44	70,85	75,88	38,82	49,52	43,93
M2.0001	92,50	92,51	164,52	210,83	36,17	113,64	62,45
M17.0022	31,25	34,24	56,44	83,42	18,49	22,22	30,29
M2.0009	112,96	121,73	212,97	394,41	52,64	85,54	188,44
M2.0002	54,06	255,79	44,28	39,33	48,79	42,92	66,56
U7.0027	140,25	140,25	195,96	219,95	81,81	113,42	98,82
U7.0019	119,94	167,36	140,50	111,97	81,27	140,25	68,06
M2.0004	927,37	624,75	1227,84	1336,21	871,00	647,42	850,16
M18.0002	50,88	70,64	89,08	96,03	35,98	50,23	36,99
M19.0003	43,66	76,17	78,63	86,17	31,41	42,63	32,72

Complementarmente, as Figuras 4 e 5 exemplificam, respectivamente, a comparação entre os dados reais e a previsão fornecida pelo método ARIMA e pelo método de Holt-Winters Multiplicativo para o componente M2.0001.

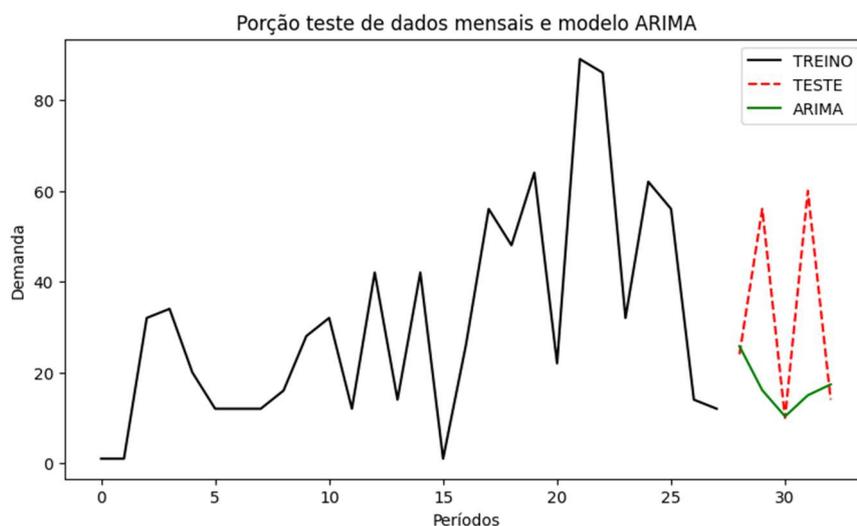


Figura 4 - Gráfico comparativo entre dados reais e modelo ARIMA para o componente M2.0001

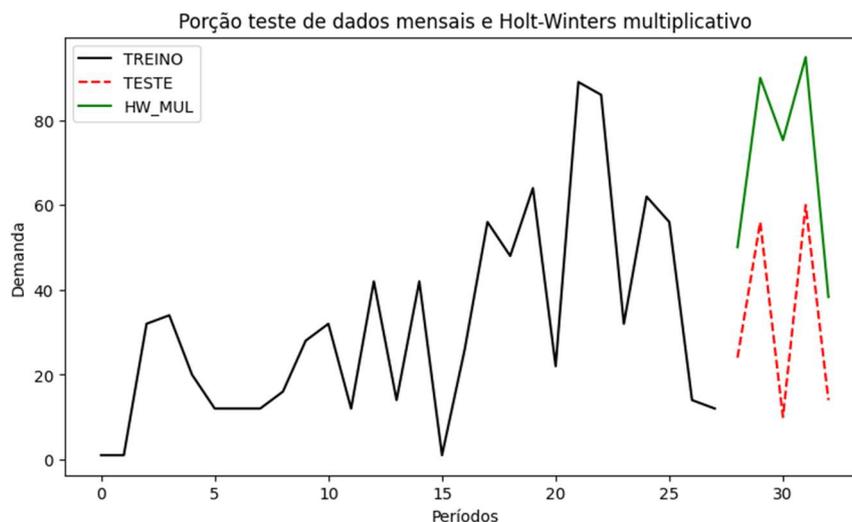


Figura 5 – Gráfico comparativo entre dados reais e Holt-Winters Multiplicativo para o componente M2.0001

Os resultados representados na Tabela 5 evidenciam um alto percentual de erro em relação aos dados reais na maioria dos modelos propostos. Em cerca de 64% dos componentes analisados, o modelo ARIMA foi o que obteve melhores resultados quando comparado aos demais. Entretanto, pelos elevados MAPEs, estes resultados não se tornam satisfatórios para realizar uma previsão em contexto prático. Assim, se faz recomendável agregar os dados históricos em trimestres, visando reduzir a oscilação da série e melhorar a aderência dos modelos aos dados. A agregação dos períodos originais é uma importante estratégia para buscar resultados melhores em relação ao ajuste do modelo aos dados e consequente melhora na capacidade preditiva. Dentre outros benefícios, a agregação faz com que a dados atípicos impactem menos no MAPE.

Antes de obter a base de dados trimestral dos componentes, é preciso mapear, além da quantidade de demanda acumulada, a média do percentual de participação de cada um dos três meses na soma da demanda trimestral para concretizar a desagregação. A Tabela 6 compila a proporção de demanda de cada um dos meses dentro do trimestre em questão. Como resultado desta compilação, a Tabela 7 mostra a contribuição média de cada mês para a demanda histórica do trimestre.

Tabela 6 – Compilado da demanda a proporção de cada mês para o componente M1.0001

Período	Demanda	Mês 1	Mês 2	Mês 3
nov/2020 - jan/2021	133	48,87%	16,54%	34,58%
fev/2021 - abr/2021	152	36,84%	43,42%	19,73%
mai/2021 - jul/2021	194	28,86%	40,20%	30,92%
ago/2021 - out/2021	218	37,61%	47,70%	14,67%
nov/2021 - jan/2022	316	27,21%	34,17%	38,60%
fev/2022 - abr/2022	292	13,69%	31,50%	54,79%
mai/2022 - jul/2022	332	35,54%	45,78%	18,67%
ago/2022 - out/2022	381	36,48%	29,92%	33,59%
nov/2022 - jan/2023	328	51,82%	25,61%	22,56%
fev/2023 - abr/2023	346	35,26%	15,60%	49,13%
mai/2023 - jul/2023	281	27,75%	44,12%	28,11%

Tabela 7 – Contribuição média de cada mês para o componente M1.0001

Período	Mês 1	Mês 2	Mês 3
nov - jan	42,63%	25,44%	31,91%
fev - abr	28,60%	30,17%	41,22%
mai - jul	30,72%	43,37%	25,90%
ago- out	37,04%	38,81%	24,13%

Com os dados percentuais definidos, os dados históricos de demanda foram divididos novamente entre duas porções, treino e teste. Neste caso, visando permitir uma melhor avaliação quanto à relação entre os dados reais de teste e os dados previstos pelos modelos, foram selecionados 9 períodos para treino (totalizando 27 meses) e 2 períodos para teste (totalizando 6 meses). As previsões para os 2 períodos da porção de teste (em base trimestral) são então desagregados em base mensal. Tal processo é exemplificado na Tabela 8 para o componente M1.0001. Um sumário desses resultados para todos os componentes em análise é trazido na Tabela 9.

Tabela 8 – Exemplo de análise para obtenção do MAPE – análise trimestral

PERÍODO MENSAL	DEMANDA REAL	DEMANDA REAL ACUMULADA	PERCENTUAL DA DEMANDA REAL	PREVISÃO ARIMA	ERRO PERCENTUAL	VALOR PREVISTO fev - abr	VALOR PREVISTO mai - jul
28	122	346	35,26%	89,72	26,46%	313,72	276,98
29	54		15,61%	94,68	75,32%		
30	170		49,13%	129,32	23,93%		
31	78	281	27,76%	85,09	9,09%		
32	124		44,13%	120,13	3,12%		
33	79		28,11%	71,75	9,17%		
MAPE - ARIMA					24,52%		

Além da melhora significativa na maioria dos resultados de MAPE, a Tabela 9 sugere o método ARIMA como o melhor método para análise dos dados em questão, tendo em vista que se mostrou soberano na obtenção dos menores erros.

Tabela 9 – Resultados de MAPE para os modelos analisados em dados trimestrais desagregados

MAPE - PORÇÕES DE TESTE - DADOS TRIMESTRAIS DESAGREGADOS							
CÓDIGO	SES	SED	SET_ADD	SET_MUL	ARIMA	SARIMA	REG. MÚLTIPLA
M4.0001	24,92	45,18	59,80	179,20	17,35	27,96	21,45
M1.0001	29,73	41,41	50,90	160,16	24,52	28,64	36,16
M2.0001	121,93	187,31	166,72	343,98	53,25	154,23	56,73
M17.0022	24,83	30,43	64,66	227,07	21,36	23,06	25,27
M2.0009	126,74	180,65	179,29	181,58	125,39	252,49	145,44
M2.0002	47,06	60,68	38,63	67,35	34,36	41,58	38,71
U7.0027	167,19	256,48	152,18	163,24	118,48	264,80	128,43
U7.0019	97,40	131,51	119,91	43,82	33,01	66,27	65,37
M2.0004	273,29	319,70	721,25	423,37	188,34	448,39	563,64
M18.0002	51,73	73,65	78,16	90,03	23,35	82,97	31,44
M19.0003	49,53	70,78	74,16	84,75	23,51	76,71	27,96

As figuras 6 e 7 comparam os dados reais de demanda com os dados previstos pelo modelo ARIMA para as duas bases de dados mensais e trimestrais do componente

M1.0001. Visualmente, também é possível perceber uma maior confiabilidade na previsão concedida pelo modelo em comparação aos dados desagregados.

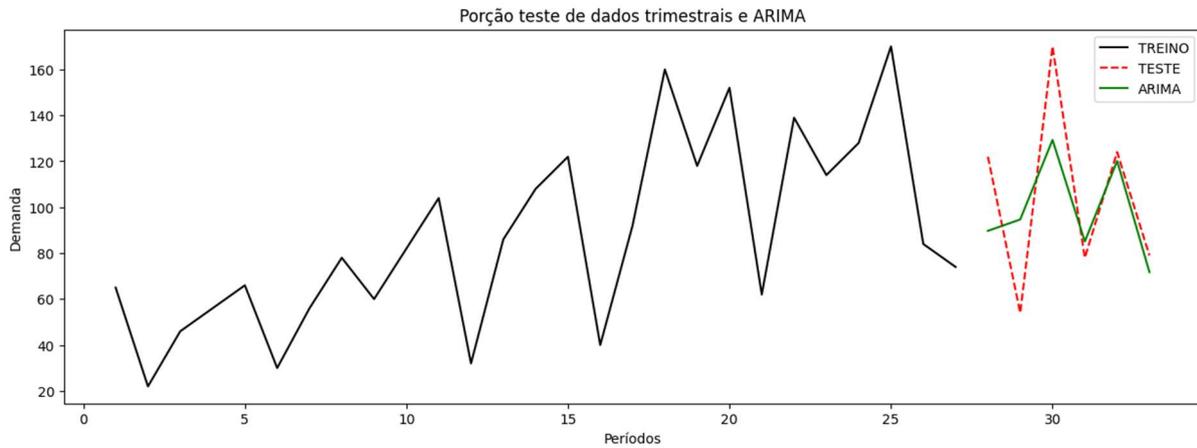


Figura 6 – Gráfico comparativo entre dados reais e modelo ARIMA para o componente M1.0001 em dados trimestrais desagregados



Figura 7 – Gráfico comparativo entre dados reais e modelo ARIMA para o componente M1.0001 em dados mensais

Buscando solucionar o problema exposto pela empresa e apresentar o resultado adequado, a Figura 8 exibe o gráfico de previsão de demanda para o componente M1.0001 nos 3 meses posteriores aos dados inicialmente coletados. Assim, é possível expandir o modelo para todos os componentes selecionados e obter os resultados desejados.

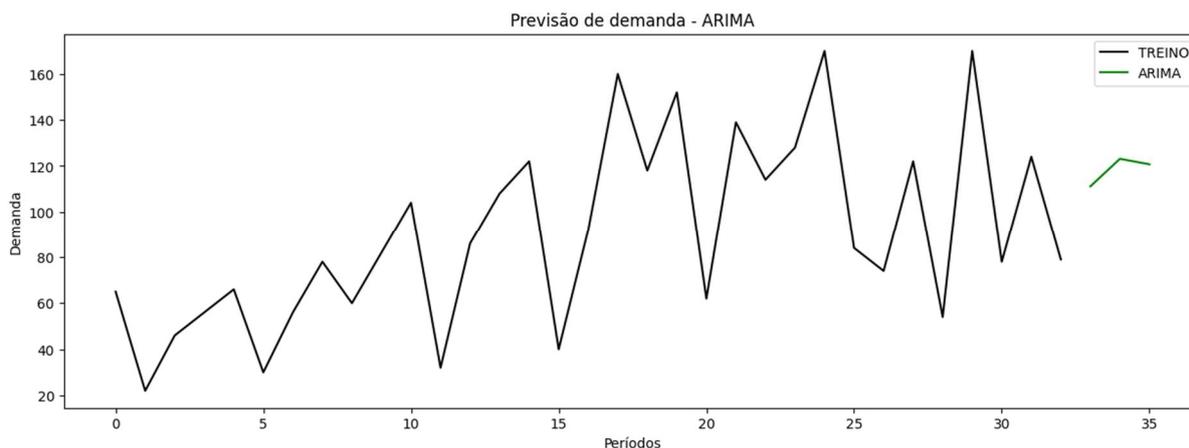


Figura 8 – Gráfico de previsão de demanda com modelo ARIMA para o componente M1.0001

5. CONCLUSÕES

O presente estudo analisou diferentes métodos quantitativos de previsão de demanda, identificando aquele que proporcionou os melhores resultados para a empresa em estudo e previsões mais precisas para os componentes analisados. Resultados satisfatórios de previsão de demanda proporcionam a otimização dos processos de decisão, minimização de custos operacionais e níveis de estoques controlados, por exemplo.

Inicialmente, a coleta de dados e seleção dos componentes mais significativos permitiu restringir o objeto de estudo, focando nos componentes mais importantes para a empresa em aspectos financeiros e operacionais. Os componentes classificados na porção “AZ” da matriz *Nine Box*, representada pela Figura 1, totalizaram cerca de 60% do valor total, em componentes, no período analisado. Com os cortes necessários e a seleção daqueles componentes que teriam sua análise viabilizada, permaneceram 11 componentes para o presente estudo.

A aplicação inicial dos modelos de previsão nas porções de treino e teste não conduziram a resultados satisfatórios de MAPE. Assim, foi realizada a agregação dos dados mensais em dados trimestrais para, posteriormente, desagregá-los e obter o resultado do erro para cada previsão em relação aos dados de teste.

Os resultados de MAPE obtidos a partir da nova análise realizada demonstram uma grande melhora em relação ao experimento anterior. Após a agregação, modelagem e desagregação, entendeu-se que os resultados do modelo preditivo selecionado foram satisfatórios e cumpriram os objetivos de prever a demanda de 3 meses à frente da análise realizada. As conclusões obtidas no estudo têm o poder de auxiliar a empresa em novas

tomadas de decisões e podem ter papel de facilitador no processo, concedendo maior confiabilidade ao mesmo.

6. REFERÊNCIAS

Ballou, R. H. (2006). Gerenciamento da Cadeia de Suprimentos/Logística Empresarial (5ª. Ed.). Porto Alegre: Bookman Editora.

Bouzada, M. A. C., & Saliby, E. (2009). Prevendo a demanda de ligações em um call center por meio de um modelo de Regressão Múltipla. *Gestão & Produção*, 16, 382-397.

Fonseca, J. J. S. (2002). Metodologia da pesquisa científica. Fortaleza: UEC. Apostila.

García, Á. R. S., Peñate, M. U., & Pérez, V. E. M. (2022). Regressão linear e modelo Arima na previsão de vendas de gengibre no Equador Linear regression and Arima Model in sales forecasts of Ginger in Ecuador. *Brazilian Journal of Development*, 8(4), 30432-30458.

Garcia, B. B. M., & Rego, R. B. (2015). MODELO DE REGRESSÃO NA PREVISÃO DA DEMANDA. *Relatórios de Pesquisa em Engenharia de Produção*, 15(1), A2-A2.

Gerhardt, T. E., & Silveira, D. T. (2009). Métodos de pesquisa. Porto Alegre: Editora da UFRGS, 31-32.

Gil, A. C. (2002). Como elaborar projetos de pesquisa (Vol. 4, p. 175). São Paulo: Atlas.

Gujarati, D. N., & Porter, D. C. (2011). Econometria básica (Vol. 5). Amgh Editora.

Hoepers, E., da Cunha Alves, C., Corazza, E. J., dos Santos, G. J., Cristofolini, R., & da Cruz, A. C. (2019). Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. *Revista Produção Online*, 19(3), 1001-1026.

Kibunja, H. W., Kihoro, J. M., Orwa, G. O., & Yodah, W. O. (2014). Forecasting precipitation using SARIMA Model: A case study of Mt. Kenya Region.

Kumar, P. (2015). *Industrial Engineering and Management*. Pearson Education India.

Lemos, F. D. O. (2006). Metodologia para seleção de métodos de previsão de demanda. Porto Alegre: UFRGS.

- LEWIS, C. D. (1982). *Industrial and business forecasting methods : a practical guide to exponential smoothing and curve fitting*. London: Butterworths Scientific.
- Li, X. (2013). Comparison and analysis between holt exponential smoothing and brown exponential smoothing used for freight turnover forecasts. *Third International Conference on Intelligent System Design and Engineering Applications* (p. 453-456). IEEE.
- Lodetti, L. & Teixeira, L. L. (2017). Aplicação da metodologia box & jenkins na previsão das vendas de leite de um laticínio em Guaíra-PR. *R. Eletr. Cient. Inov. Tecnol, Medianeira, Edição Especial Cadernos Matemática*, E – 5108.
- Lopes, R. B. (2012). Utilização da regressão linear múltipla como ferramenta de otimização em processos industriais de moagem de trigo.
- Lustosa, L., Mesquita, M. A., Oliveira, R. J. & Quelhas, O. (2008). *Planejamento e controle da produção*. Elsevier Brasil.
- Makridakis, S., Wheelwright, S., & Hyndman, R. (1998). *Forecasting: Methods and Applications*. 3. ed., New York: John Wiley & Sons.
- Meneghini, M., Anzanello, M., Kahmann, A., & Tortorella, G. L. (2018). Ajuste de previsão de demanda quantitativa com base em fatores qualitativos: estudo de caso em um restaurante fast food. *Sistemas & Gestão*, 13(1).
- Novaes, M. L. O., Gonçalves, A. A., Gouvêa, D. S. A., & Simonetti, V. M. M. (2008). Utilização dos métodos de suavização exponencial e da média móvel aritmética para a previsão de demandas na área de saúde. Rio de Janeiro: ENEGEP.
- Ostertagova, E., & Ostertag, O. (2011). The simple exponential smoothing model. In *The 4th International Conference on modelling of mechanical and mechatronic systems*, Technical University of Košice, Slovak Republic, *Proceedings of Conference* (pp. 380-384).
- Peinado, J., & Graeml, A. R. (2007). *Administração da produção. Operações industriais e de serviços*. Unicenp, p. 332.
- Pellegrini, F. R. (2000). *Metodologia para implementação de sistemas de previsão de demanda*. Porto Alegre: UFRGS.

- Pellegrini, F. R., & Fogliatto, F. S. (2001). Passos para implantação de sistemas de previsão de demanda: técnicas e estudo de caso. *Revista PRODUÇÃO*, v. 11.
- Segura, J. V., & Vercher, E. (2001). A spreadsheet modeling approach to the Holt–Winters optimal forecasting. *European Journal of Operational Research*, 131(2), 375-388.
- Slack, N., Chambers, S., & Johnston, R. (2018). *Administração da produção* (Vol. 8). São Paulo: Atlas.
- Tratar, L. F., & Strmčnik, E. (2016). The comparison of Holt–Winters method and Multiple regression method: A case study. *Energy*, 109, p. 266-276.
- Veríssimo, A. J., da Cunha Alves, C., Henning, E., do Amaral, C. E., & da Cruz, A. C. (2013). Métodos estatísticos de suavização exponencial Holt-Winters para previsão de demanda em uma empresa do setor metal mecânico. *Revista Gestão Industrial*, 8(4).
- Viana, J. J. (2006). *Administração de materiais: um enfoque prático*. São Paulo: Atlas.
- Vo, T. T. B. C., Le, P. H., Nguyen, N. T., Nguyen, T. L. T., & Do, N. H. (2021). Demand Forecasting and Inventory Prediction for Apparel Product using the ARIMA and Fuzzy EPQ Model. *Journal of Engineering Science & Technology Review*, 14(2).
- Werner, L. (2005). Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião.
- Werner, L., & Ribeiro, J. L. D. (2003). Previsão de demanda: uma aplicação dos modelos Box-Jenkins na área de assistência técnica de computadores pessoais. *Gestão & Produção*, 10, 47-67.
- Wisniewski, M. (2006). *Quantitative methods for decision makers*. Pearson Education.