

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
COMISSÃO DE GRADUAÇÃO DO CURSO DE ENGENHARIA CIVIL**

Raquel Wolter Martell

**CONSUMO DE CIMENTOS ASFÁLTICOS NO BRASIL:
ESTIMATIVA DE DEMANDA PARA UM QUINQUÊNIO
UTILIZANDO MÉTODOS QUANTITATIVOS**

**Porto Alegre,
Novembro de 2021**

RAQUEL WOLTER MARTELL

**CONSUMO DE CIMENTOS ASFÁLTICOS NO BRASIL:
ESTIMATIVA DE DEMANDA PARA UM QUINQUÊNIO
UTILIZANDO MÉTODOS QUANTITATIVOS**

Trabalho de Conclusão de Curso apresentado à Comissão de
Graduação do Curso de Engenharia Civil da Escola de Engenharia da
Universidade Federal do Rio Grande do Sul, como parte dos requisitos
para obtenção do título de Engenheira Civil

Orientador: Lélío Antônio Teixeira Brito

Porto Alegre,
Novembro de 2021

RAQUEL WOLTER MARTELL

**CONSUMO DE CIMENTOS ASFÁLTICOS NO BRASIL:
ESTIMATIVA DE DEMANDA PARA UM QUINQUÊNIO
UTILIZANDO MÉTODOS QUANTITATIVOS**

Este Trabalho de Diplomação foi julgado adequado como pré-requisito para a obtenção do título de ENGENHEIRA CIVIL e aprovado em sua forma final pela Banca Examinadora, pelo Professor Orientador e pela Comissão de Graduação do Curso de Engenharia Civil da Universidade Federal do Rio Grande do Sul.

Porto Alegre, 06 de dezembro de 2021.

BANCA EXAMINADORA

Prof. Lélío Antônio Teixeira Brito (UFRGS)
PhD pela Universidade de Nottingham
Orientador

Profª. Graciele Bordin Colpo (PUCRS)
Dra. pela Universidade Federal do Rio Grande do Sul

Viviane e Silva Wickboldt
Mestra pela Universidade Federal do Rio Grande do Sul

Dedico este trabalho a meus pais, Francisco Carlos e Gislaine, à minha avó, Melina (*in memoriam*), e aos meus irmãos, Daniel, Gabriel e Rafael, pelo apoio, cuidado e amor a mim dedicados ao longo dos anos.

AGRADECIMENTOS

Agradeço aos meus pais, Francisco Carlos Barcelos Martell e Gislaine Quintana Wolter Martell, por sempre terem apoiado os meus estudos e servido de suporte durante esses longos anos de graduação. À minha mãe Gislaine, agradeço especialmente por ser uma fonte inesgotável de amor e compreensão, servindo de colo em momentos difíceis e me impulsionando em todos os outros. Se sou o que sou hoje, é porque tu me permitisses ser. Agradeço também aos meus tios, Odete e Mario Luís, por serem meus segundos pais. Grande parte do amor que recebi na vida, sei que veio de vocês.

Agradeço aos meus irmãos, Daniel, Gabriel e Rafael, por serem exemplo e incentivo ao longo da minha trajetória, mas também calmaram nos momentos em que minha ansiedade se faz intolerável. Ao meu irmão Gabriel, agradeço também por todos os momentos dedicados à minha formação, tanto acadêmica quanto pessoal. Nossas longas conversas me tornam uma pessoa melhor, ano após ano.

Agradeço ao Rodrigo Haas e Thiago Nitschke por serem a minha família escolhida. Independente dos rumos que as nossas vidas tomarem, minha casa sempre será também a de vocês. Ao Lucas Gestaro, agradeço por aguentar sempre com bom humor minhas crises existenciais em relação a engenharia civil. Obrigada por conversar comigo em momentos em que nem eu me aguento.

Agradeço as minhas amigas Caroline e Thais, pelos longos anos de amizade, por tantos bons momentos vividos e pela compreensão pelos meus sumiços. Sei que temos muitos anos de amizade pela frente!

Agradeço as minhas amigas Gabriela, Giovana, Júlia, Jéssica, Luciana, Yasmin e Tais por todos os momentos compartilhados (sejam eles bons ou ruins, mas especialmente os bons). Não consigo definir minha trajetória pela universidade sem a presença de vocês. Espero ansiosa para ver as engenheiras brilhantes que vocês se tornarão!

Ao Helton e ao Fernando, agradeço por todos os cafés e sonhos divididos entre aulas. São essas pequenas coisas que realmente importam no final do dia.

Aos demais amigos, agradeço o apoio, compreensão e tolerância com as minhas reclamações (constantes) sobre tudo que está errado no mundo. É devido a pessoas como vocês que acredito em um futuro melhor.

Por último, agradeço a todos os professores que contribuíram para a minha formação como Engenheira Civil, esforçando-se para oferecer o melhor ensino possível mesmo que em situações adversas. Um agradecimento especial é dedicado ao prof. Lélcio Antônio Teixeira Brito, não apenas pela orientação neste trabalho de conclusão de curso, mas também pelo exemplo durante a graduação. Espero algum dia poder me tornar uma profissional tão competente e admirada quanto tu és.

Se a educação sozinha não transforma a sociedade,
sem ela tampouco a sociedade muda.

Paulo Freire

RESUMO

O presente artigo se propõe a encontrar o modelo de previsão de demanda quantitativo que possui maior acurácia para estimar o consumo de cimentos asfálticos no Brasil para o próximo quinquênio. A metodologia proposta inclui a pesquisa e validação de dados sobre consumo de cimentos asfálticos no país, modelagem da série histórica e seleção do método quantitativo de extrapolação que melhor se ajusta a série temporal. A escolha do modelo de previsão utilizado foi realizada com base no coeficiente de determinação R^2 e o *Mean Absolute Percentage Error* (MAPE). Após, foi realizada a estimativa de demanda para os próximos 64 meses. O método proposto foi aplicado para dados da Agência Nacional de Petróleo sobre comercialização de cimentos asfálticos. O modelo gerou uma previsão com tendência e sazonalidade, desconsiderando o comportamento cíclico da série histórica. Por esse motivo, o modelo, ainda que satisfatório, foi considerado excessivamente otimista para predição da demanda.

Palavras-chave: demanda, previsão de demanda, modelos quantitativos, séries temporais, asfalto, cimentos asfálticos.

LISTA DE FIGURAS

Figura 1: Comparativo entre o volume de asfalto comercializado para distribuidoras por tipo de produto.....	12
Figura 2: Componentes de uma série temporal.	14
Figura 3: Metodologia do trabalho.	18
Figura 4: Consumo de cimento asfáltico entre 2019 e 2021.	21
Figura 5: Série histórica de demanda de cimentos asfálticos entre janeiro de 2019 e agosto de 2021.	22
Figura 6: Comparação entre os diferentes modelos testados para previsão de demanda da série histórica.	23
Figura 7: Previsão de demanda de cimento asfáltico para o período de setembro de 2021 a dezembro de 2026.	24
Figura 8: Demanda anual de cimento asfáltico no Brasil para o quinquênio 2022-2026.	25
Figura 9: Volume de asfalto adquirido por distribuidoras em refinarias entre os anos de 2008 e 2020.	27

LISTA DE TABELAS

Tabela 1: Resultado do Teste de Grubbs para intervalo de confiança de 95%.	22
Tabela 2: Medidas de acurácia dos modelos de previsão testados.	23
Tabela 3: Coeficientes de Suavização do Método de Holt-Winters Aditivo.....	24
Tabela 4: Medidas de acurácia dos modelos de previsão testados.	24
Tabela 5: Estimativa de demanda de cimento asfáltico para os anos de 2022 a 2026. ..	25

LISTA DE SIGLAS

ABEDA – Associação Brasileira das Empresas Distribuidoras de Asfalto

ADP – Asfalto Diluído de Petróleo

ANP – Agência Nacional de Petróleo

CAP – Cimento Asfáltico de Petróleo

CNT – Confederação Nacional do Transporte

DIEESE – Departamento Intersindical de Estatística e Estudos Socioeconômicos

PETROBRAS – Petróleo Brasileiro S.A.

MAPE – *Mean Absolute Percentage Error*

CONSUMO DE CIMENTOS ASFÁLTICOS NO BRASIL: ESTIMATIVA DE DEMANDA PARA UM QUINQUÊNIO UTILIZANDO MÉTODOS QUANTITATIVOS

Raquel Wolter Martell

Lélio Antônio Brito Teixeira

Universidade Federal do Rio Grande do Sul

Departamento de Engenharia Civil

RESUMO

O presente artigo se propõe a encontrar o modelo de previsão de demanda quantitativo que possui maior acurácia para estimar o consumo de cimentos asfálticos no Brasil para o próximo quinquênio. A metodologia proposta inclui a pesquisa e validação de dados sobre consumo de cimentos asfálticos no país, modelagem da série histórica e seleção do método quantitativo de extrapolação que melhor se ajusta a série temporal. A escolha do modelo de previsão utilizado foi realizada com base no coeficiente de determinação R^2 e o *Mean Absolute Percentage Error* (MAPE). Após, foi realizada a estimativa de demanda para os próximos 64 meses. O método proposto foi aplicado para dados da Agência Nacional de Petróleo sobre comercialização de cimentos asfálticos. O modelo gerou uma previsão com tendência e sazonalidade, desconsiderando o comportamento cíclico da série histórica. Por esse motivo, o modelo, ainda que satisfatório, foi considerado excessivamente otimista para predição da demanda.

ABSTRACT

This article has the objective to determine the best quantitative forecasting model generated by extrapolation of historical series which has greater accuracy in predicting future demand for asphalt cements in Brazil for the next five years. To achieve this objective, the proposed methodology includes the research and validation of data on the consumption of asphalt cements and selection of the quantitative extrapolation model that best fits the time series, using the coefficient of determination R^2 and the Mean Absolute Percentage Error (MAPE) for decision making. Next, the demand forecast for the next 64 months was made. The proposed method was applied to data from Agência Nacional do Petróleo on the commercialization of asphalt cements. The proposed model generated a forecast with trend and seasonality, disregarding the cyclical behavior of the historical series. For this reason, the model, although satisfactory, was considered excessively optimistic for predicting demand.

1. INTRODUÇÃO

O transporte rodoviário é o principal sistema logístico utilizado no Brasil, sendo responsável pela movimentação de aproximadamente 60% das mercadorias e 90% dos passageiros (Anuário CNT do Transporte, 2020). Apesar da importância social e econômica que a malha rodoviária possui, pouco tem sido feito para melhorar a sua qualidade. No período entre 2009 e 2019, a quilometragem de rodovias pavimentadas cresceu apenas 0,5%, frente a um crescimento de 59,5% da frota de veículos. Dos 1.720.700,0 quilômetros de estradas existentes, apenas 12,4% são pavimentados, sendo a maioria em pista simples e em mau estado de conservação (Anuário CNT do Transporte, 2020). Tais informações corroboram com a urgência na realização de investimentos no modal de transporte rodoviário, o que tem levado governos estaduais e federal a concessionar maiores e mais importantes lotes de rodovias.

A utilização de pavimentos flexíveis é a forma mais comum de pavimentação utilizada na construção e recuperação de vias mundialmente, sendo comumente associados a misturas asfálticas, compostas por agregados e ligantes asfálticos. De acordo com Araújo *et al.* (2016), o Brasil possui 95% de suas estradas pavimentadas com revestimentos asfálticos, que são derivados do processo de refino petróleo. Para Milani Júnior *et al.* (2016), a indústria petrolífera pode ser descrita como um processo complexo composto por seis atividades: exploração, desenvolvimento, produção, refino, transporte e

distribuição, sendo o asfalto um resíduo obtido na etapa de refino do petróleo, produzido através do processo de destilação fracionada do petróleo.

A indústria da construção civil é o único consumidor de materiais asfálticos no país, empregando-os em quatro tipos de produtos: (i) Cimentos Asfálticos de Petróleo (CAP); (ii) Asfaltos Diluídos de Petróleo (ADP); (iii) Emulsões Asfálticas e; (iv) Produtos impermeabilizantes. Dentre os setores da construção civil que utilizam de materiais asfálticos, o ramo de engenharia rodoviária destaca-se como seu maior dependente. Segundo dados da Agência Nacional de Petróleo (ANP) relacionados à produção e comercialização de asfaltos, em 2019 a venda de cimentos asfálticos de petróleo, emulsões asfálticas e asfaltos diluídos de petróleo para as diferentes distribuidoras do país foi responsável pela utilização de 98% do volume de asfalto produzido. Para o ano de 2020 e até agosto de 2021, o volume de asfalto destinado à fabricação destes produtos foi respectivamente de 97% e 96%.

Ainda segundo dados da Agência Nacional de Petróleo, apresentados na Figura 1, anualmente cimentos asfálticos de petróleo são responsáveis pela utilização de 70 a 75% do volume de asfalto produzido nas refinarias. Na produção de emulsões asfálticas, são empregados de 20 a 25% do asfalto total disponível. Produtos impermeabilizantes consomem, em média, 3% do volume anual de asfalto, e os asfaltos diluídos de petróleo são responsáveis pela utilização do 1% restante.

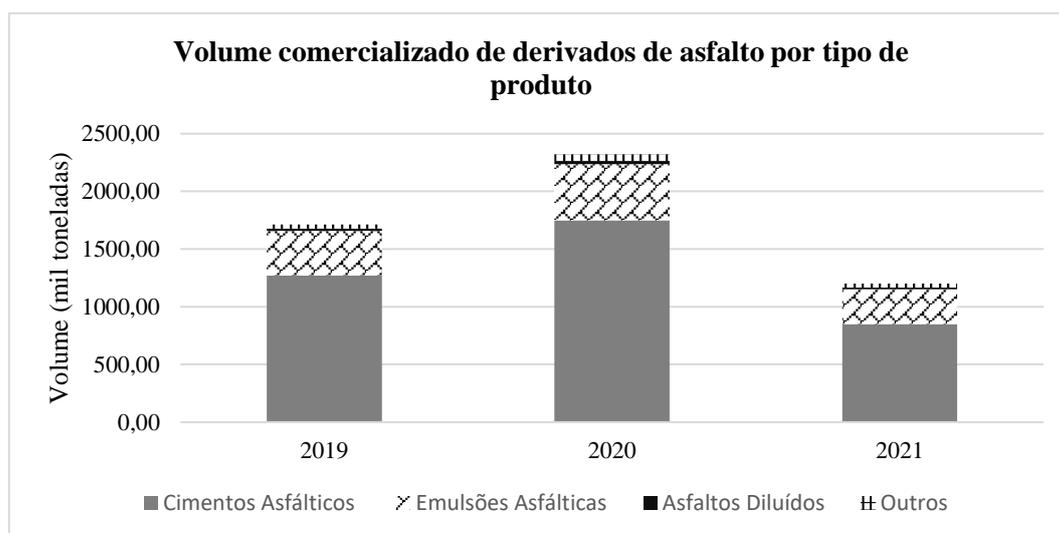


Figura 1: Comparativo entre o volume de asfalto comercializado para distribuidoras por tipo de produto. Fonte: Elaborado pelos autores (2021).

Visto que a aplicação de produtos asfálticos na construção e manutenção da malha rodoviária brasileira é responsável pelo consumo de mais de 95% do volume de asfalto produzido anualmente no país, estimar a demanda para anos futuros é de extrema importância para que se possa compreender se as refinarias brasileiras serão capazes de atender o volume solicitado por compradores de produtos derivados de asfalto nos próximos anos. Caso a capacidade de produção das refinarias não seja suficiente para atender o mercado interno, a estimativa de demanda torna-se então necessária para o desenvolvimento de estratégias de negócio que possibilitem o abastecimento do mercado interno de asfaltos.

De acordo com Senna *et al.* (2015), toda empresa desenvolve um modelo de previsão de

demanda ao longo da sua trajetória, com o objetivo de embasar as tomadas de decisões de negócios em avaliações realistas do contexto em que a empresa se encontra inserida. A previsão de demanda também é diretamente conectada com a produção. Previsões de demanda inferiores à necessidade do mercado podem ocasionar falta de produtos e redução de lucros pela não realização das vendas, enquanto estimativas superestimadas geram custos desnecessários de produção e estoque (WERNER, 2004).

Este artigo tem como objetivo encontrar o modelo de previsão de demanda quantitativo que possui acurácia satisfatória para estimar o consumo de cimentos asfálticos no Brasil para o quinquênio 2022-2026. Para tanto, é necessário realizar a pesquisa e validação de dados sobre consumo de cimentos asfálticos no país em bases de dados de fontes confiáveis, modelar a série histórica para os n modelos pré-selecionados e selecionar o que possui maior acurácia utilizando o coeficiente de determinação R^2 e o *Mean Absolute Percentage Error* (MAPE).

O presente artigo encontra-se organizado em cinco seções. A primeira seção apresenta a contextualização e problemática sobre o tema abordado, assim como o objetivo do trabalho. A seção 2 é composta pela revisão bibliográfica, onde são abordados os conteúdos sobre previsão de demanda quantitativa (*forecasting*) necessários para realização do estudo. A terceira seção discorre sobre os procedimentos metodológicos que compõem a execução do trabalho. Na seção 4 são apresentados e discutidos os resultados do estudo. Por fim, a seção 5 expõe considerações finais sobre o estudo realizado e sugestões para trabalhos futuros abordando o tema.

2. REVISÃO BIBLIOGRÁFICA

Kotler (1991) define demanda de um produto como “o volume total que seria comprado por um grupo definido de consumidores em uma área geográfica definida, em um período de tempo definido”. Nesta lógica, previsão de demanda é uma estimativa do que pode vir a ser a demanda de acordo com as premissas adotadas (MOON *et al.*, 1998). Para Armstrong (1983), métodos de previsão de demanda são procedimentos explícitos realizados para traduzir informações sobre o ambiente e a estratégia proposta pela companhia em afirmações sobre resultados futuros. Para Makridakis (1988), a previsão de demanda é uma atividade indispensável para o planejamento, estratégia e outras formas de tomada de decisões futuras, tanto em níveis individuais quanto organizacionais. Ainda segundo Armstrong (1983), existem distinções entre planejamento empresarial e previsão de demanda: o planejamento está relacionado ao que a empresa deve fazer em determinada situação, enquanto a previsão está relacionada com o que acontecerá caso a empresa implemente certa estratégia em um ambiente existente. Em um mercado industrial cada vez mais competitivo, executar previsões de demanda com a maior acurácia possível é essencial para facilitar o planejamento necessário para atender à demanda esperada, garantindo assim um bom desempenho da unidade de negócios.

Existem duas abordagens principais para a realização de previsões de demanda: métodos qualitativos e métodos quantitativos. Métodos qualitativos são aqueles em que os processos utilizados para a análise de dados não foram devidamente especificados (ARMSTRONG, 2006) e envolvem estimações subjetivas através da opinião de especialistas ou consumidores (MONTGOMERY *et al.*, 1990). Métodos quantitativos, por sua vez, possuem processos bem definidos para a análise de dados. Eles podem ser replicados por demais especialistas, gerando previsões idênticas para uma mesma base de

dados (ARMSTRONG, 1983). Nos últimos anos, inúmeras técnicas de previsão de demanda quantitativas foram desenvolvidas com o objetivo de reduzir a incerteza das estimativas encontradas. As técnicas aplicadas variam em relação ao seu objetivo, exatidão, horizonte de tempo e custos de aplicação (MAKRIDAKIS et al., 1998; ABRAHAM; LEDOLTER, 2005). Para Axsäter (2015), modelos de previsão de demanda generalistas aparentam ser mais vantajosos, já que englobam um número maior de classes de demanda. No entanto, isto não é verdade, uma vez que estes modelos fazem uso de mais parâmetros na sua construção, que se tornam cada vez mais complexos de serem estimados com acurácia. Desta forma, modelos generalistas só devem ser aplicados quando houver evidências de que sua utilização será vantajosa para aumentar a precisão das estimativas.

Para Thomas (1996), previsões de demanda quantitativas podem ser feitas por meio de análises de séries temporais e extrapolação ou métodos causais. Séries temporais fazem uso da análise estatística de dados passados da variável de interesse para projeção futura. Métodos causais fazem uso da análise de dados de variáveis relacionadas à variável de interesse para projeção de valores futuros (ARCHER, 1980). Os métodos de extrapolação mais utilizados para análise de séries temporais são médias móveis e suavizações exponenciais (MENEHINI; ANZANELLO, 2013).

Toda previsão a ser realizada por métodos quantitativos faz uso de diferentes modelos matemáticos, e a escolha do modelo matemático a ser empregado está sujeita ao comportamento da série temporal analisada (PELLEGRINI; FOGLIATTO, 2001). De acordo com Makridakis *et al.* (1998), séries temporais podem ser decompostas em cinco componentes: (i) nível (média para o período); (ii) tendência; (iii) sazonalidade; (iv) fatores cíclicos e (v) erro aleatório. Makridakis *et al.* (1998) recomendam a análise gráfica dos dados coletados para a identificação de comportamentos e simplificação da escolha do método de séries temporais a ser empregado. A Figura 2 apresenta os componentes que podem ser observados em séries temporais.

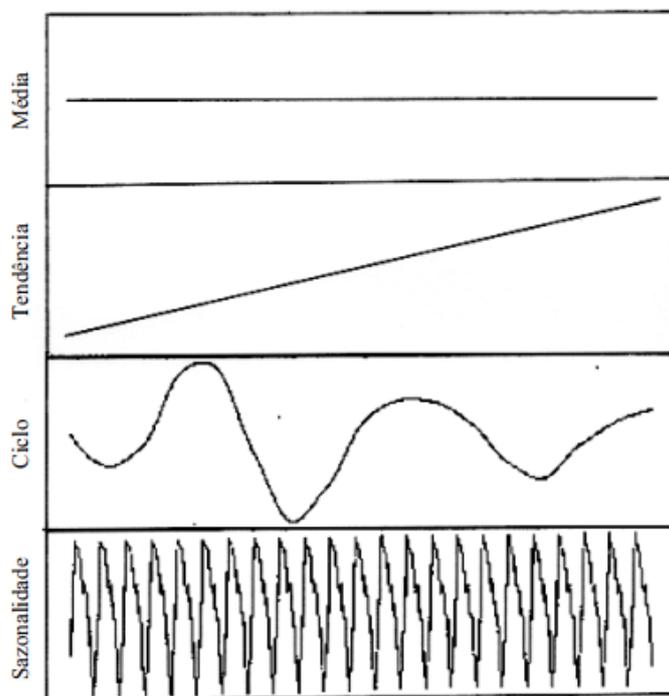


Figura 2: Componentes de uma série temporal.
Fonte: Adaptado de Makridakis *et al.* (1998).

Para Lemos (2006) “técnicas de extrapolação são baseadas na consideração que o padrão existente na série histórica irá continuar no futuro”. Assim, a extrapolação é utilizada para um conjunto de dados sobre uma população onde os pontos existentes são extrapolados para se obter resultados e referências sobre esta população (ARMSTRONG, 2001). O restante desta revisão bibliográfica será focado em métodos de análise de séries temporais, que serão utilizados para aplicação do estudo.

2.1. Média Móvel Simples

O método de média móvel simples é um dos mais utilizados para previsão de demanda, pois necessita de poucos dados para ser utilizado, além de ser um método de fácil aplicação e manutenção. A quantidade de dados necessária para aplicação do método depende do período de interesse para realização da previsão, tornando-o um método apropriado para previsões de curto prazo para séries que apresentam dados irregulares, sem padrão definido de tendência e sazonalidade (MAKRIDAKIS *et al.*, 1998).

A previsão de demanda utilizando média móvel simples de ordem n é dada pela equação (1) (MAKRIDAKIS *et al.*, 1998):

$$F_{t+1} = \frac{1}{n} \sum_{i=t-n+1}^t Y_i \quad (1)$$

Onde F_{t+1} é a previsão para o período $t+1$, n é o número de períodos que compõem a média móvel e Y_i é o valor da demanda para o período i .

As médias móveis simples movem-se pela série temporal até que a componente média tenha sido calculada para todos os períodos da série temporal. As previsões para períodos posteriores à última observação da série temporal serão constantes, possuindo o valor da última média calculada. Dentre as desvantagens na utilização deste método, encontra-se a dificuldade que ele possui em trabalhar com séries que possuam tendência e sazonalidade. Isso ocorre porque, para a previsão de cada novo período, ocorre a adição de novos dados e a desconsideração de dados anteriores, apagando o histórico de dados que carregam as informações de tendência e sazonalidade (MAKRIDAKIS *et al.*, 1998).

2.2. Suavização Exponencial

Os modelos de suavização exponencial são os mais utilizados para previsão de demanda, uma vez que apresentam o melhor custo/benefício entre os métodos de extrapolação de séries temporais (ARMSTRONG; BRODIE, 1999 *apud* LEMOS, 2006). Tais métodos aplicam uma ponderação distinta para cada ponto presente na série temporal, determinada em progressão geométrica. Desta forma, dados mais recentes recebem pesos maiores, enquanto aos dados antigos são atribuídos pesos menores. Esta dinâmica torna os dados atuais exponencialmente mais importantes para a previsão futura em relação aos dados antigos (MAKRIDAKIS *et al.*, 1998).

2.2.1. Suavização Exponencial Simples

O modelo de suavização exponencial simples é utilizado para séries históricas que se mantêm constantes sobre um nível médio, ou seja, possuem um padrão de demanda com

um ruído aleatório que oscila em torno de um valor médio. De acordo com Lemos (2006), o método de suavização exponencial simples ajusta a previsão para o período futuro utilizando a previsão da estação atual e o seu erro de previsão ($Y_t - F_t$). Sua formulação matemática é dada pela equação (2) (MAKRIDAKIS *et al.*, 1998).

$$F_{t+1} = F_t + \alpha(Y_t - F_t) \quad (2)$$

Onde F_{t+1} é a previsão de demanda para o período $t+1$, F_t é a previsão para o período t , Y_t é a demanda observada para o período t e α é a constante de suavização do modelo, com valores entre 0 e 1.

A constante de suavização α possui um valor arbitrário, e a determinação do seu melhor valor pode ser realizada iterativamente através da minimização dos erros da previsão (MAKRIDAKIS *et al.*, 1998). Uma das medidas de erro mais utilizadas para a determinação do coeficiente é a média quadrática dos erros (MQE).

O coeficiente α também é responsável por determinar a resposta do modelo adotado em relação as mudanças observadas na série temporal. Grandes valores de α indicam uma rápida resposta do modelo em relação a alterações observadas nos dados, que faz ajustes maiores do erro da previsão anterior (MAKRIDAKIS *et al.*, 1998).

A inicialização do modelo de suavização linear simples exige uma estimativa para F_t . Na existência de dados históricos, pode-se considerar como valor inicial F_1 a média simples dos primeiros valores observados na série temporal. Como alternativa, F_1 pode ser igualado ao Y_1 , o primeiro valor de demanda registrado na série (LEMOS, 2006).

2.2.2. Suavização Exponencial Dupla

O método de suavização exponencial dupla também é conhecido como suavização exponencial de Holt. Este método é utilizado para séries temporais que apresentam tendência, ou seja, um aumento ou diminuição sistemática da média da série ao decorrer do tempo (MAKRIDAKIS *et al.*, 1998). As equações (3), (4) e (5) descrevem o modelo.

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

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

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

Onde F_{t+m} é a previsão para o período $t+m$, L_t é a estimativa para o nível da série no período t , m é o horizonte de previsão, b_t é a estimativa de tendência da série para o período t e α e β são constantes de suavização do modelo, com valores entre 0 e 1 não relacionados.

A equação (3) é utilizada para obter a previsão de demanda para m períodos posteriores. A equação (4) faz uma estimativa para o nível da série, e a equação (5) para a tendência que a série apresenta. As constantes de suavização α e β possuem valores arbitrários, e a sua determinação pode ser feita assim como no modelo de suavização exponencial simples, através da minimização dos erros da previsão.

O cálculo inicial do modelo de suavização linear dupla requer a estimativa inicial de L_1 e b_1 . Uma forma para obtenção dos valores iniciais é considerar L_1 como sendo igual a Y_1

e b_1 como sendo igual a zero ou à diferença entre os dois primeiros valores da série temporal ($Y_2 - Y_1$) (MAKRIDAKIS *et al.*, 1998).

2.2.3. Método de Holt-Winters

O modelo de Holt-Winters é utilizado para séries temporais que apresentam tendência e sazonalidade, que são alterações repetidas regularmente na demanda, provocando a alta ou baixa dos valores. Para isso, o método estima o nível, a tendência e a sazonalidade da série temporal a partir de equações de suavização, possibilitando a construção da previsão de demanda (MAKRIDAKIS *et al.*, 1998).

A depender da sazonalidade apresentada pela série temporal, dois modelos de Holt-Winters podem ser aplicados: aditivo e multiplicativo. O modelo multiplicativo é utilizado em séries onde a amplitude da sazonalidade varia com o nível da demanda. A forma aditiva do modelo, por sua vez, é dedicada a séries temporais cuja amplitude da sazonalidade mantém-se constante em relação ao nível da demanda (WINTERS, 1960).

A representação matemática do modelo multiplicativo de Holt-Winters é dada pelas equações (6), (7), (8) e (9) (MAKRIDAKIS *et al.*, 1998).

$$\text{Previsão: } F_{t+m} = (L_t + b_t m) S_{t-s+m} \quad (6)$$

$$\text{Nível: } L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (7)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (8)$$

$$\text{Sazonalidade: } S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (9)$$

Onde s é o número de períodos que compõem um ciclo sazonal, L_t e b_t são estimativas para o nível e a tendência da série, respectivamente, S_t é a estimativa para o componente sazonal da série no período t e α , β e γ são constantes de suavização do modelo, com valores entre 0 e 1 não relacionados.

O método de suavização exponencial de Holt-Winters necessita, assim como os demais modelos de suavização exponencial, de valores iniciais para L_1 , b_1 e S_1 . A estimativa do componente sazonal exige uma estação completa de observações, ou seja, s períodos. O cálculo inicial para as componentes de nível e tendência é feito, conseqüentemente, para o intervalo s definido pela componente sazonal (MAKRIDAKIS *et al.*, 1998). As equações que determinam as estimativas iniciais para o nível, tendência e sazonalidade são apresentadas em Makridakis *et al.* (1998).

O modelo aditivo de Holt-Winters difere-se do modelo multiplicativo em relação ao impacto da componente sazonal. No modelo multiplicativo, a componente sazonal efetua operações de multiplicação e divisão nas equações de nível e previsão. Já no modelo aditivo, a sazonalidade é tratada como um termo a ser adicionado ou subtraído das equações de nível e previsão. As equações (10), (11), (12) e (13) representam o modelo aditivo de Holt-Winters (MAKRIDAKIS *et al.*, 1998).

$$\text{Previsão: } F_{t+m} = L_t + b_t m + S_{t-s+m} \quad (10)$$

$$\text{Nível: } L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (11)$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (12)$$

$$\text{Sazonalidade: } S_t = \gamma(Y_t - S_{t-s}) + (1 - \gamma)S_{t-s} \quad (13)$$

Os primeiros valores de L_s e b_s são calculados da mesma forma especificada para o modelo multiplicativo. Os valores iniciais da componente sazonal podem ser obtidos pela equação (14) (PELLEGRINI, 2000).

$$S_s = F_s - L_s \quad (14)$$

Onde F_s é a demanda estimada para o período s e L_s é a componente de nível estimada para o período s .

3. PROCEDIMENTOS METODOLÓGICOS

De acordo com Silva e Menezes (2005), do ponto de vista de sua natureza, a presente pesquisa pode ser classificada como aplicada, pois tem como objetivo gerar conhecimento para aplicação prática direcionada à solução de problemas pré-estabelecidos. Possui abordagem quantitativa, uma vez que utiliza técnicas estatísticas para traduzir em números opiniões e informações relativas ao tema estudado. Do ponto de vista de seus objetivos, trata-se de uma pesquisa exploratória, uma vez que visa proporcionar maior familiaridade com o tema abordado (GIL, 1991). Quanto aos procedimentos técnicos, é classificada como pesquisa-ação, pois os pesquisadores e participantes estão envolvidos com o intuito de encontrar alternativas para o problema levantado (GIL, 1991).

O método proposto para este trabalho é composto por cinco etapas, sendo elas: (i) Coleta de dados históricos; (ii) Verificação de pontos espúrios (*outliers*); (iii) Modelagem quantitativa; (iv) *Forecasting* e (v) Análise dos resultados. A sequência das etapas é apresentada na Figura 3 e detalhada nos itens subsequentes.

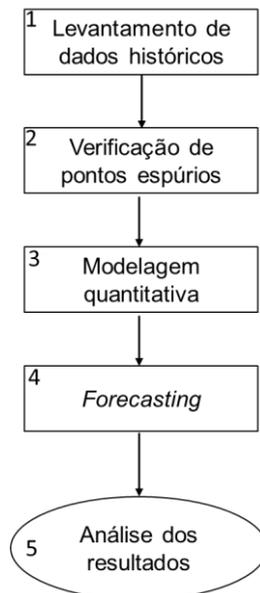


Figura 3: Metodologia do trabalho.
Fonte: Elaborado pelos autores (2021).

3.1. Coleta de dados históricos

A primeira etapa tem como objetivo verificar a disponibilidade de dados para que a

metodologia proposta possa ser aplicada. Nesta etapa, analisa-se o histórico de dados de demanda existentes e a qualidade deles, com o intuito de escolher o produto a ser incorporado no trabalho e validar a sua utilização no estudo.

3.2. Verificação de pontos espúrios

A segunda etapa visa identificar a existência de dados espúrios na base de dados coletada. Dados espúrios (*outliers*) são pontos que fogem da normalidade de valores observados na série histórica e podem causar anomalias nos resultados objetivos pela análise. Nesta fase a série histórica gerada será analisada através do Teste de Grubbs com 95% de confiança, para que os dados discrepantes possam ser identificados e substituídos. Na ocorrência de dados discrepantes, a série será suavizada sem que o perfil da demanda seja descaracterizado.

3.3. Modelagem quantitativa da série

A modelagem quantitativa da série tem por objetivo realizar a previsão puramente quantitativa da demanda, com a utilização de séries históricas. Para tal, deve-se definir o método de previsão de demanda quantitativo que melhor se ajusta aos dados históricos existentes.

A determinação do modelo é feita segundo a metodologia definida por Meneghini e Anzanello (2013). Os dados da série histórica utilizada são divididos em dois grupos: treino e teste. O grupo treino utiliza 80% dos dados para a construção do modelo, e o grupo teste os 20% restantes para validação da modelagem. São testados n modelos de previsão de demanda utilizando apenas os dados do grupo treino, que então são ajustados para prever os níveis de demanda observados no grupo teste. Exemplificando, se existem 20 dados disponíveis na série histórica, o ajuste dos métodos é baseado nas primeiras 16 observações (grupo treino, 80% dos dados), realizando a predição para os quatro períodos restantes (grupo teste, 20% dos dados).

Para cada um dos N modelos testados é gerado um coeficiente de determinação R^2 , que representa o ajuste do modelo testado aos dados de treino da série histórica. São procurados modelos que possuem um alto valor de R^2 , uma vez que denotam boa aderência dos dados históricos aos modelos utilizados.

Para avaliar a capacidade preditiva de cada modelo, é feita a comparação das previsões realizadas por cada modelo estatístico com a série histórica. A medida de acurácia utilizada para a comparação entre modelos é o MAPE (*Mean Absolute Percentual Error*), indicada para a comparação entre métodos por não depender da unidade dos dados utilizados, ser menos afetada por valores discrepantes do que medidas quadráticas e ser apresentada como um percentual de erro (ARMSTRONG; COLLOPY, 1992; KAHN, 1998). Baixos valores de MAPE são procurados, uma vez que denotam boa capacidade preditiva dos modelos estatísticos utilizados. O MAPE pode ser calculado através da seguinte equação:

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{Y_t - \hat{Z}_t}{Y_t} \right| \quad (15)$$

Onde n é o número de períodos considerados para cálculo da medida de acurácia, Y_t é o

valor real da demanda no período t e \hat{Z}_t é a previsão de demanda para o período t .

O modelo quantitativo que apresentar melhor aderência e capacidade preditiva em relação aos dados será selecionado para compor o estudo. O desempenho dos modelos será avaliado pelo índice I , de acordo com a equação (16). O modelo que apresentar o maior valor de I será escolhido para prosseguimento do estudo.

$$I_n = \frac{R^2_n}{MAPE_n} \quad (16)$$

3.4. Forecasting

A quarta etapa consiste em realizar a previsão de demanda (*forecasting*) para os períodos desejados a partir do modelo selecionado na etapa anterior, utilizando todos os dados da série histórica como base para extrapolação do modelo.

3.5. Análise dos resultados

Na quinta e última etapa são apresentados os resultados obtidos pelo estudo, com o intuito de contextualizar e avaliar os valores obtidos através para a previsão de demanda. Também objetiva-se avaliar possíveis fatores que possam influir nos ciclos de baixa e alta de demanda, assim como analisar se as refinarias de petróleo existentes no país possuem capacidade para abastecer o mercado interno de asfalto nos próximos anos.

4. RESULTADOS

Nesta seção serão abordados os resultados encontrados para a estimativa de demanda de cimentos asfálticos para o próximo quinquênio, utilizando os dados obtidos da Agência Nacional de Petróleo (ANP) e a metodologia descrita na seção 3. Os modelos matemáticos de previsão de demanda aplicados na série temporal foram o de Suavização Exponencial Simples, Suavização Exponencial Dupla, Método de Holt-Winters Aditivo, Método de Holt-Winters Multiplicativo e Média Móvel para três e quatro períodos anteriores, descritos na revisão bibliográfica.

4.1. Coleta de dados históricos

Para a realização do estudo, foi necessário obter uma série histórica sobre consumo de asfalto no Brasil. Para tal, foram realizadas pesquisas em bases de dados da Associação Brasileira das Empresas Distribuidoras de Asfaltos (ABEDA), Departamento Intersindical de Estatística e Estudos Socioeconômicos (DIEESE), Agência Nacional de Petróleo (ANP) e Petróleo Brasileiro S.A. (PETROBRAS). Não foram encontrados dados abertos fornecidos pela PETROBRAS, uma vez que a empresa não possui obrigação legal de fornecer tais dados. Os dados obtidos nos registros ABEDA e DIEESE tratavam de valores anuais para o volume de asfaltos adquirido por distribuidores nas refinarias entre os anos de 2008 e 2020. Tais valores formavam uma série histórica com apenas 13 pontos, considerados insuficientes para realização da previsão de demanda. Séries temporais com poucas observações tendem a gerar modelos de previsão de demanda pouco confiáveis, visto que a base de treino utilizada é insuficiente para se obter modelos com acurácia satisfatória.

Desta forma, a aplicação da metodologia proposta no trabalho foi realizada para os dados da Agência Nacional de Petróleo (ANP) sobre a comercialização de asfaltos pelas distribuidoras brasileiras, disponível em [Dados abertos - Movimentação de derivados de petróleo — Português \(Brasil\) \(www.gov.br\)](http://www.gov.br). As informações disponíveis sobre cada ordem de venda compreendem mês e ano da venda, agente regulatório responsável, produto comercializado, região de origem e destino do produto, além da quantidade comercializada em mil toneladas. Ao todo, quatro produtos asfálticos formam a base de dados coletada: Cimentos Asfálticos, Emulsões Asfálticas, Asfaltos Diluídos e Outros Asfaltos. Para escolha do produto a ser analisado, foram utilizados dois critérios de escolha, sendo eles: (i) Volume comercializado; (ii) Aplicação em obras rodoviárias. Desta forma, o produto utilizado no estudo foi o Cimento Asfáltico de Petróleo (CAP).

Os dados obtidos sobre comercialização de CAP apresentam valores mensais do volume adquirido por distribuidoras para período de janeiro de 2007 a agosto de 2021. Durante a etapa de validação dos dados, não foi possível verificar a veracidade dos valores obtidos entre janeiro de 2007 e junho de 2018, que possuíam muitos pontos espúrios e não correspondiam ao montante registrado nas bases de dados da ABEDA e DIEESE. Dessa forma, foram utilizados apenas os dados compreendidos entre janeiro de 2019 e agosto de 2021 para realização do estudo.

A série histórica resultante possui 32 pontos, apresentando quatro dos cinco componentes que compõem uma série, sendo eles: (i) nível; (ii) tendência; (iii) comportamento cíclico; (iv) ruído. A Figura 4 apresenta os dados de comercialização de cimento asfáltico de petróleo para os meses de janeiro de 2019 a agosto de 2021, assim como os componentes que determinam o comportamento da série.

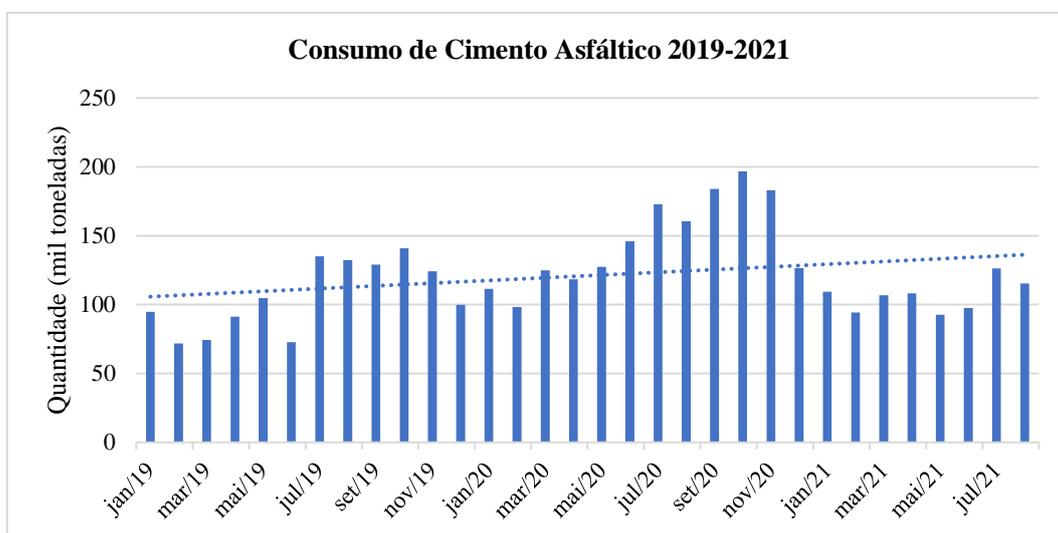


Figura 4: Consumo de cimento asfáltico entre 2019 e 2021.
Fonte: Elaborado pelos autores (2021).

4.2. Verificação de pontos espúrios

A série histórica definida na seção 4.1. foi analisada para que os pontos espúrios, que poderiam comprometer a previsão ao adicionar algum comportamento anômalo, fossem localizados e substituídos pela média dos dados anteriores e posteriores. A identificação foi feita pelo Teste de Grubbs (Teste G) com intervalo de confiança de 95%, para os

valores máximos e mínimos da série. A série possui média de 121,02 mil toneladas e desvio padrão de 32,01, com o valor máximo observado de 196,77 mil toneladas e valor mínimo 71,73 mil toneladas. Os valores encontrados no Teste de Grubbs são mostrados na Tabela 1. Uma vez que os valores comparados (G máximo e G mínimo) são menores que o valor crítico (G crítico) da série, a hipótese nula não pode ser rejeitada, considerando-se que todos os valores da amostra foram obtidos de uma única população que segue a mesma distribuição normal.

Tabela 1: Resultado do Teste de Grubbs para intervalo de confiança de 95%.

Variável	Valor
G máximo	196,77
G mínimo	71,73
T crítico	3,21
G crítico	70,16

Fonte: Elaborado pelos autores (2021).

Como não foram encontrados valores de demanda fora do padrão para a série histórica analisada, nenhum valor foi substituído. A série histórica final é apresentada na Figura 5, já separada entre os dados que serão utilizados para treino e para teste dos modelos.

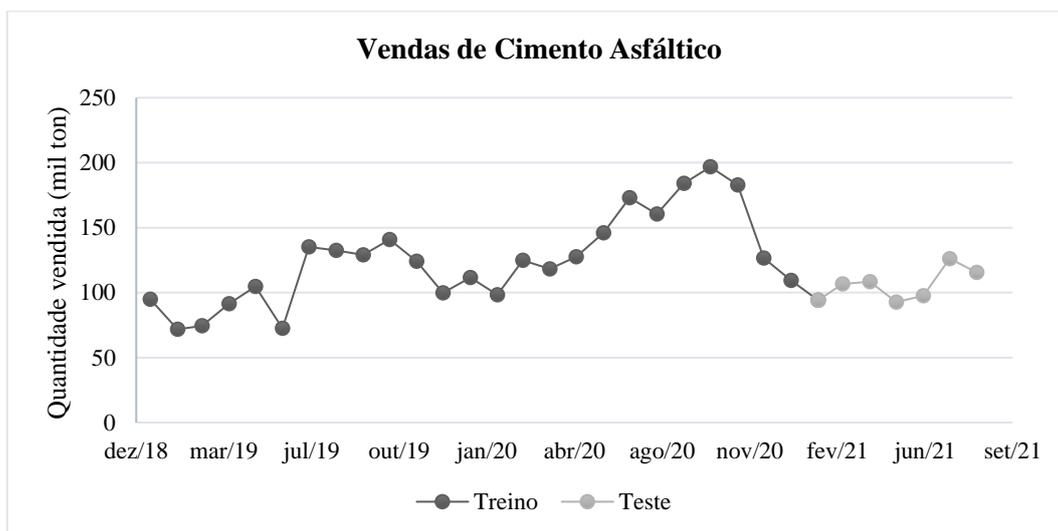


Figura 5: Série histórica de demanda de cimentos asfálticos entre janeiro de 2019 e agosto de 2021.

Fonte: Elaborado pelos autores (2021).

4.3. Modelagem quantitativa da série

A série histórica a ser moldada apresenta tendência crescente e comportamento cíclico. Para a modelagem quantitativa dos dados foram pré-selecionados seis modelos distintos: Suavização Exponencial Simples, Suavização Exponencial Dupla, Método de Holt-Winters Multiplicativo, Método de Holt-Winters Aditivo e Média Móvel para três e quatro períodos anteriores (MM3 e MM4). O modelo de Suavização Exponencial Dupla foi escolhido devido a tendência crescente que a série histórica apresenta. Já os modelos de Holt-Winters Aditivo e Multiplicativo foram escolhidos uma vez que a série histórica, além de possuir tendência crescente também apresenta um comportamento cíclico, que pode ser mais bem representado por métodos que consideram a existência de tendência e sazonalidade nas séries históricas. Os modelos de Suavização Exponencial Simples e Média Móvel para três e quatro períodos (MM3 e MM4) anteriores foram testados devido a sua larga utilização na indústria e facilidade de aplicação, ainda que sejam modelos que

não trabalham bem em séries temporais com presença de tendência e sazonalidade.

Os métodos de Suavização Exponencial Simples, Suavização Exponencial Dupla e Holt-Winters foram modelados com o uso do *software* estatístico NCSS 2021, e os modelos de Média Móvel (MM3 e MM4) foram obtidos por planilha eletrônica. De acordo com a metodologia proposta para este trabalho, 80% dos dados foram utilizados para treino do modelo e 20% para teste. Dos 32 pontos disponíveis na série histórica, 26 foram utilizados para treino dos algoritmos e cálculo do coeficiente de determinação R^2 , e os 6 pontos mais recentes foram utilizadas para teste dos modelos e determinação do MAPE e índice I. Para aplicação dos modelos de Média Móvel de três e quatro períodos anteriores, foi necessário utilizar os dados disponíveis de setembro, outubro, novembro e dezembro de 2018 para cálculo da demanda esperada. A Figura 6 apresenta as previsões realizadas pelos diferentes modelos de previsão de demanda testados.

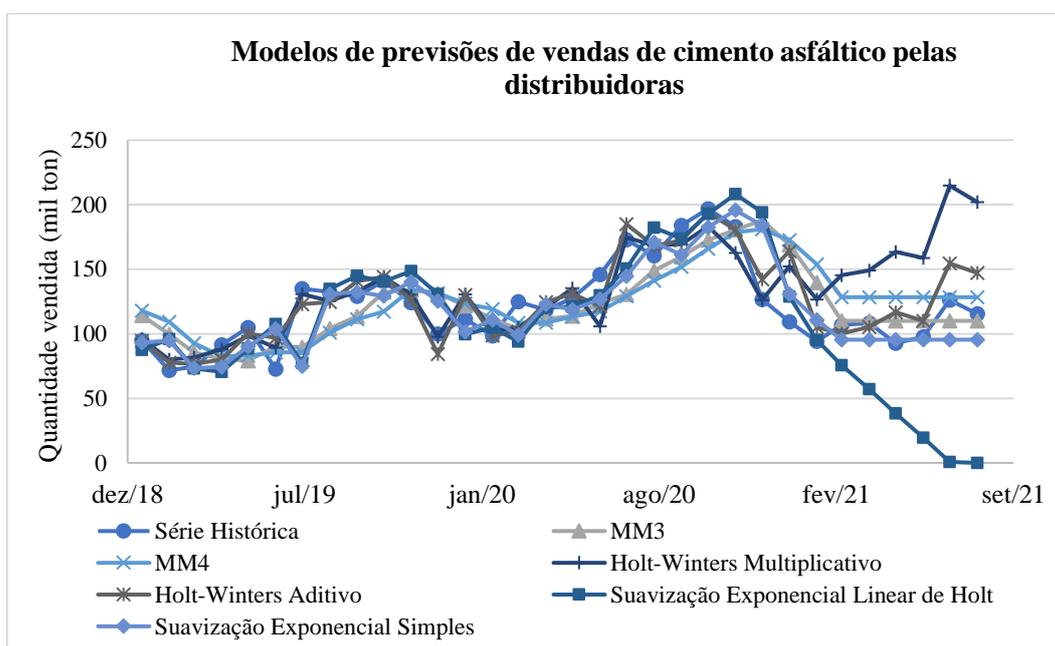


Figura 6: Comparação entre os diferentes modelos testados para previsão de demanda da série histórica.
Fonte: Elaborado pelos autores (2021).

A Tabela 2 expõe os valores de R^2 , MAPE e coeficiente I obtidos para cada um dos modelos testados. O modelo que possui o maior valor encontrado para I é aquele recomendado para os passos subsequentes do trabalho. Conforme pode ser identificado na Tabela 2, o modelo que apresenta o melhor ajuste aos dados da série histórica e possui a melhor acurácia para a previsão realizada para o grupo teste é o Método de Holt-Winters Aditivo. Por isto, este foi o modelo escolhido para a realização da previsão de demanda.

Tabela 2: Medidas de acurácia dos modelos de previsão testados.

Modelo	R^2	MAPE	I
MM3	0,68	0,18	3,74
MM4	0,69	0,23	3,05
Suavização Exponencial Simples	0,53	0,15	3,61
Suavização Exponencial Dupla	0,47	0,26	1,80
Holt-Winters Multiplicativo	0,78	0,19	4,03
Holt-Winters Aditivo	0,78	0,11	6,98

Fonte: Elaborado pelos autores (2021).

4.4. Forecasting

A previsão de demanda de cimento asfáltico foi realizada utilizando todos os pontos disponíveis na série histórica (grupos treino e teste) para calibração do modelo de Holt-Winters Aditivo. O modelo foi extrapolado para os 64 meses subsequentes, contemplando o período de setembro de 2021 a 2026. O modelo empregado é descrito pelas equações (10), (11), (12) e (13), utilizando como critério de parada a minimização da média dos erros quadráticos. As constantes de suavização empregadas no modelo são apresentadas na Tabela 3. O modelo utilizado apresenta um valor elevado para a constante α , justificando a sua rápida reação às variações que ocorrem nos dados de demanda da série temporal.

Tabela 3: Coeficientes de Suavização do Método de Holt-Winters Aditivo.

Constante	Valor
α	0,7439932
β	5,825602E-10
γ	2,284444E-10

Fonte: Elaborado pelos autores (2021).

Para a extrapolação do modelo foram utilizados os 32 pontos da série histórica, ocasionando em uma maior aderência aos valores reais de consumo de cimento asfáltico em relação ao obtido apenas com os dados do grupo teste. O coeficiente de determinação R^2 , o MAPE e o índice I obtidos para o modelo de previsão de demanda são mostrados na Tabela 4.

Tabela 4: Medidas de acurácia dos modelos de previsão testados.

Modelo	R^2	MAPE	I
Holt-Winters Aditivo	0,85	0,09	9,45

Fonte: Elaborado pelos autores (2021).

A previsão de demanda gerada para o período de setembro de 2021 a dezembro de 2026 pode ser vista na Figura 7, e na Tabela 5 são apresentados os valores obtidos para o quinquênio 2022-2026.

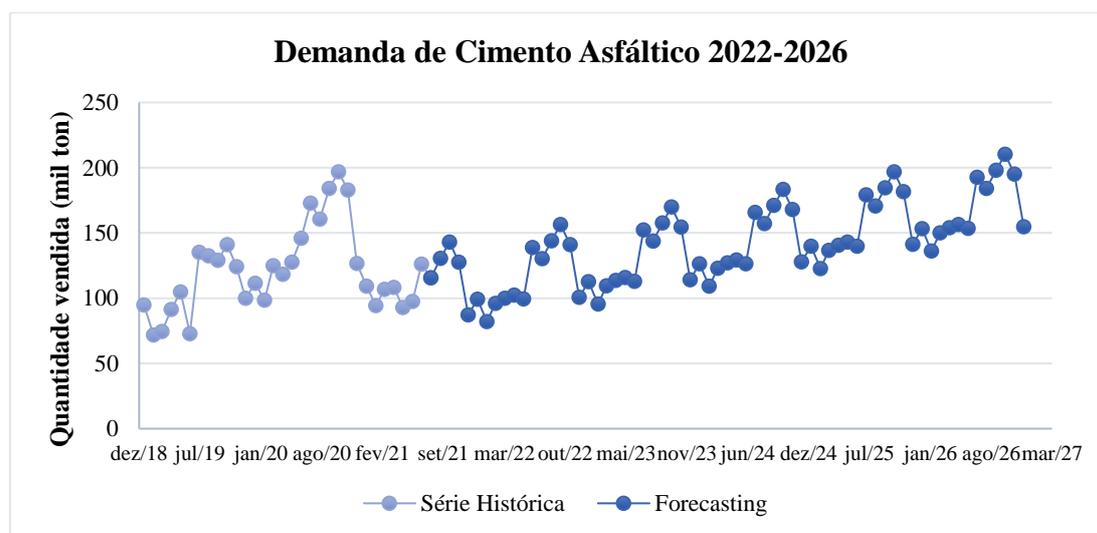


Figura 7: Previsão de demanda de cimento asfáltico para o período de setembro de 2021 a dezembro de 2026.

Fonte: Elaborado pelos autores (2021).

Tabela 5: Estimativa de demanda de cimento asfáltico para os anos de 2022 a 2026.

Data	Demanda (mil toneladas)	Data	Demanda (mil toneladas)	Data	Demanda (mil toneladas)
Jan/2022	99,28	Set/2023	157,60	Mai/2025	142,88
Fev/2022	82,15	Out/2023	169,85	Jun/2025	139,91
Mar/2022	96,07	Nov/2023	154,56	Jul/2025	179,25
Abr/2022	100,05	Dez/2023	114,22	Ago/2025	170,63
Mai/2022	102,43	Jan/2024	126,25	Set/2025	184,54
Jun/2022	99,45	Fev/2024	109,12	Out/2025	196,82
Jul/2022	138,80	Mar/2024	123,04	Nov/2025	181,52
Ago/2022	130,18	Abr/2024	127,02	Dez/2025	141,19
Set/2022	144,09	Mai/2024	129,40	Jan/2026	153,22
Out/2022	156,36	Jun/2024	126,42	Fev/2026	136,09
Nov/2022	141,07	Jul/2024	165,77	Mar/2026	150,01
Dez/2022	100,74	Ago/2024	157,15	Abr/2026	153,98
Jan/2023	112,76	Set/2024	171,05	Mai/2026	156,37
Fev/2023	95,64	Out/2024	183,33	Jun/2026	153,39
Mar/2023	109,55	Nov/2024	168,04	Jul/2026	192,74
Abr/2023	113,53	Dez/2024	127,71	Ago/2026	184,12
Mai/2023	115,91	Jan/2025	139,73	Set/2026	198,02
Jun/2023	112,94	Fev/2025	122,61	Out/2026	210,30
Jul/2023	152,28	Mar/2025	136,52	Nov/2026	195,01
Ago/2023	143,66	Abr/2025	140,50	Dez/2026	154,67

Fonte: Elaborado pelos autores (2021).

4.5. Análise dos Resultados

A previsão de demanda obtida pelo Modelo de Holt-Winters Aditivo possui comportamento com tendência de crescimento e sazonalidade de amplitude constante no volume de cimento asfáltico comercializado. A estimativa prevê um crescimento da demanda para os anos de 2022 a 2026, cujo valor inicial é de 1390 mil toneladas em 2022, atingindo o máximo de 2037 mil toneladas em 2026. O consumo médio estimado para o próximo quinquênio é de 1714 mil toneladas por ano, com uma taxa de crescimento anual composta de 7,9%. O modelo obtido corrobora com as expectativas do mercado de que o consumo de cimento asfáltico aumente nos próximos anos, devido a evolução das concessões rodoviárias realizadas nos últimos meses, tanto em âmbito estadual quanto federal. A Figura 8 mostra a demanda anual de cimentos asfálticos para os anos de 2022 a 2026.

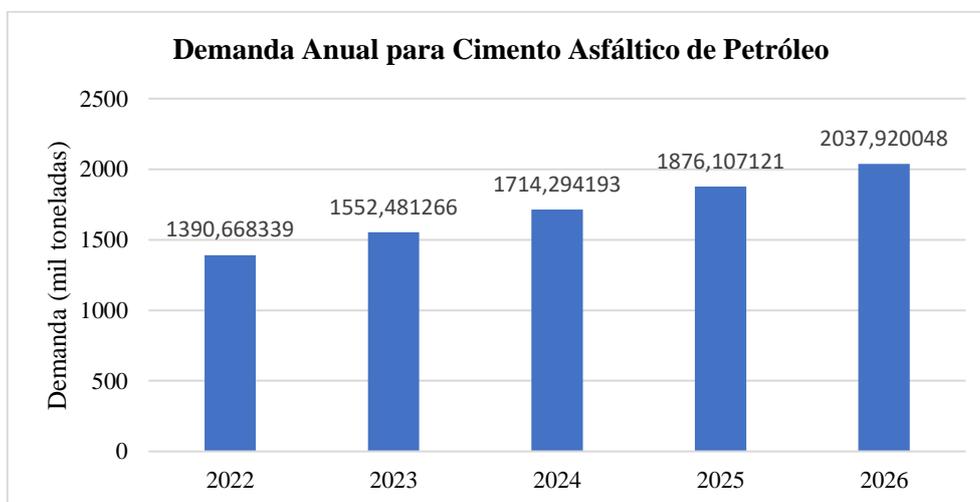


Figura 8: Demanda anual de cimento asfáltico no Brasil para o quinquênio 2022-2026.

Fonte: Elaborado pelos autores (2021).

A sazonalidade prevista pelo modelo é anual e encontra-se dividida em períodos de alta e baixa demanda. Os períodos de baixa demanda ocorrem nos meses de dezembro a junho, durante o primeiro semestre do ano, enquanto períodos de alta demanda ocorrem entre julho e novembro, no segundo semestre. Este comportamento pode ser explicado, em parte, pela dinâmica de financiamento e execução de obras rodoviárias, especialmente as que contemplam os serviços de construção e manutenção.

A ocorrência do início do período de baixa demanda para consumo de cimentos asfálticos de petróleo em dezembro pode ser atribuída as festividades de final de ano. Neste contexto, diversas obras são paralisadas ou executadas em um ritmo abaixo do normal, visando diminuir os impactos que a realização de obras na pista de rolamento provoca nos motoristas em um período em que o trânsito já é conturbado, uma vez que apresenta um volume de tráfego acima da média anual que muitas vezes não é suportado pela infraestrutura existente. O restante do período de baixa demanda pode ser explicado pela demora na aprovação dos orçamentos destinados aos órgãos de infraestrutura. Dado que o orçamento a ser aplicado em obras viárias e de saneamento costuma ser aprovado durante o primeiro trimestre de cada novo ano fiscal, o volume de obras contratadas e licitadas começa a crescer após este período, atingindo níveis maiores no segundo semestre do ano. Também é no segundo semestre do ano, entre os meses de setembro e dezembro, em que é possível definir se todos os recursos destinados a execução de projetos de infraestrutura já foram aplicados até o final do ano. Nos casos em que uma parte do orçamento ainda não foi destinada, há um aceleração no ritmo das obras que estão sendo executadas para garantir o cumprimento das leis orçamentárias até o término do ano fiscal vigente.

Comparando os valores de demanda estimados pelo modelo de Holt-Winters Aditivo aos dados disponibilizados pela ABEDA, apresentados na Figura 9, sobre o volume de asfalto adquirido por distribuidoras em refinarias entre os anos de 2008 e 2020, pode-se observar que desde 2008 não foi verificada a ocorrência quinquênio consecutivo de crescimento para a demanda de asfalto no país. O maior crescimento observado para o período ocorreu entre os anos de 2011 e 2014, onde o consumo médio de asfalto para o período foi de 2825 mil toneladas por ano e a taxa de crescimento anual composta de 6,4%. Tais valores não correspondem ao comportamento geral da série, e podem ser justificados pelos grandes investimentos realizados em obras de infraestrutura neste período para permitir a realização da Copa do Mundo FIFA de Futebol 2014 no Brasil.

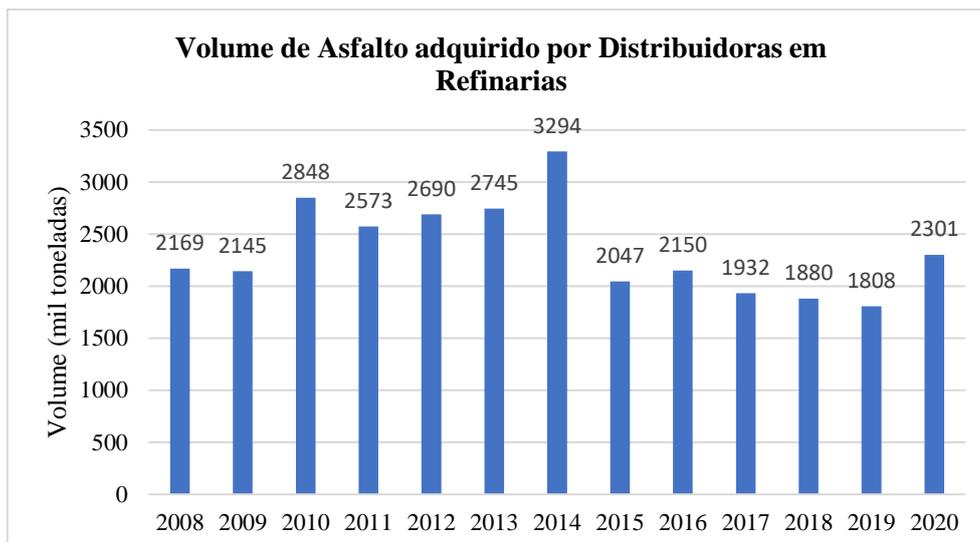


Figura 9: Volume de asfalto adquirido por distribuidoras em refinarias entre os anos de 2008 e 2020.
Fonte: Associação Brasileira das Empresas Distribuidoras de Asfaltos (2021).

Entre os anos de 2008 e 2020, o volume de asfalto adquirido por distribuidoras apresentou uma taxa de crescimento anual composta de apenas 0,5%. Esta taxa reflete a expansão da malha rodoviária brasileira, que apresentou um crescimento de apenas 0,5% entre os anos de 2009 e 2019. Neste mesmo período, pode-se observar que o comportamento cíclico atribuído a comercialização de asfaltos acompanha o desempenho econômico do país. Nos anos de expansão do PIB, os volumes adquiridos apresentam um crescimento considerável, e nos anos de contração da economia (2015 a 2018) os valores comercializados são aquém do esperado. O ano de 2019, inclusive, foi o ano de menor consumo de asfalto no país na última década, refletindo a crise econômica e viária que o país enfrentou nos seus anos anteriores.

Assim, é possível inferir que a previsão gerada para o quinquênio 2022 – 2026 é excessivamente positiva ao prever 5 anos consecutivos de crescimento, dado que este comportamento não foi observado em períodos anteriores desde 2008, quando a economia do país apresentava níveis de crescimento muito acima dos observados atualmente. Ainda que o *forecasting* gerado corrobore com as expectativas de especialistas em relação ao crescimento da demanda para o próximo quinquênio, a taxa de crescimento média anual estimada para a demanda de cimento asfáltico não parece corresponder à realidade observada. Um crescimento médio anual de 7,9% na demanda por cimento asfáltico representa valores maiores que os encontrados no período que precedeu a realização da Copa do Mundo, onde os investimentos em infraestrutura eram prioridade no país e o montante de recursos destinados a estas obras eram maiores para garantir a finalização das obras a tempo.

Dentre as limitações de modelos de previsão de demanda criados a partir da extrapolação de dados encontram-se a realização de previsões com acurácia decrescente para um horizonte de tempo maior que 24 meses (médio prazo) e a incapacidade de gerar alterações na demanda a partir de fatores externos, como o desempenho econômico do país, o número de concessões de trechos de rodovias e o orçamento destinado a obras de infraestrutura. Posto que são exatamente os fatores externos que provocam o comportamento cíclico da série temporal de consumo de asfaltos, a ausência de métodos de extrapolação que sejam capazes de modelar este comportamento podem colocar em xeque os resultados obtidos para a previsão realizada.

5. CONSIDERAÇÕES FINAIS

O presente estudo teve como objetivo encontrar um método que possibilite a previsão de demanda para o consumo de cimento asfáltico em um horizonte de 5 anos no Brasil. Para tal, diferentes modelos foram aplicados na série histórica de consumo de cimento asfáltico no Brasil disponibilizada pela ANP. O modelo escolhido como o mais adequado à série histórica foi o de Holt-Winters aditivo, que é indicado para séries que possuem tendência e sazonalidade. A utilização de todos os dados da série histórica para a extrapolação do modelo aumentou a sua acurácia em relação ao modelo utilizado apenas com os dados do grupo de treino, confirmando a importância de uma série histórica com diversos pontos para calibração do modelo.

De acordo com a metodologia proposta no trabalho, a série histórica foi modelada para os 6 modelos pré-selecionados: Suavização Exponencial Simples, Suavização Exponencial Dupla, Método de Holt-Winters Multiplicativo, Método de Holt-Winters Aditivo e Média Móvel para três e quatro períodos anteriores (MM3 e MM4). O modelo escolhido para a previsão de demanda foi aquele que apresentou o maior coeficiente I, uma vez que apresentava maior acurácia em relação aos dados da série histórica. Após, realizou-se a previsão de demanda para os 64 períodos posteriores, correspondendo aos meses de setembro de 2021 a dezembro de 2026. O modelo obtido apresentou tendência crescente e sazonalidade a cada 12 meses, com uma taxa de crescimento anual composta de 7,9%. Tais valores foram comparados com o volume de asfaltos comprados pelas distribuidoras nas refinarias brasileiras entre os anos de 2008 e 2020. Em comparação aos volumes comercializados em anos passados, a previsão obtida parece excessivamente otimista, especialmente para períodos maiores que 24 meses.

Estudos futuros incluem o acompanhamento da série histórica de consumo de cimento asfáltico no país, que deve ser utilizada para recalibração do modelo e revisão da previsão de demanda obtida. Ainda, recomenda-se realizar o levantamento com especialistas da área de engenharia rodoviária sobre fatores contextuais que podem influenciar na demanda de cimento asfáltico, com o intuito de entender se a previsão realizada pode ser considerada efetiva ou necessita de ajustes qualitativos para ter a sua acurácia melhorada.

A abordagem deste trabalho também pode ser melhorada com a inclusão de outros modelos de previsão de demanda entre os pré-selecionados, como os de Box-Jenkins e os causais, que levam em consideração fatores externos que podem provocar alterações da demanda por determinado produto.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abraham, B. e J Ledolter (2005) *Statistical Methods for Forecasting*. Jhon Wiley & Sons, New York.
- Araújo, M. A.; M. J. P. Santos; H. P. Pinheiro e Z. V. Cruz (2016) Análise Comparativa de Métodos de Pavimentação – Pavimento Rígido (concreto) x Flexível (asfalto). *Revista Científica Multidisciplinar Núcleo Do Conhecimento*, v. 10, n. 11, p. 187-196.
- Archer, B. (1980) Forecasting Demand: Quantitative and Intuitive Techniques. *International Journal of Tourism Management*, v. 1, n.1, p. 5-12.
- Armstrong, J. S. (1983) Strategic Planning and Forecast Fundamentals. In: Albert, K. (eds.) *The Strategic Management Handbook*. McGraw Hill, New York.
- Armstrong, J. S. (2001) Extrapolation for Time-series and Cross-sectional data. In: Armstrong, J (eds.) *Principles of Forecasting: a Handbook for Researchers and Practitioners*. Kluwer Academic Publishers, Boston.
- Armstrong, J. S. (2006) Findings from Evidence-Based Forecasting: Methods for Reducing Forecast Error.

- International Journal of Forecasting*, v. 22, n. 3, p. 583-598.
- Armstrong, J. S. e F. Collopy (1992) Error Measures for Generalizing about Forecasting Methods: Empirical Comparisons. *International Journal of Forecasting*, v. 8, n. 1, p. 69-80.
- Axsäter, S (2015) *Inventory Control*. 3ª ed., Springer, Switzerland.
- CNT (2020) – *Anuário CNT de Transportes – 2020*. Confederação Nacional do Transporte, Brasília, DF.
- Silva; E. D. da e E. M. Menezes (2005) *Metodologia da Pesquisa e Elaboração de Dissertação*. Universidade Federal de Santa Catarina, Florianópolis, Santa Catarina.
- GIL, A. C. (1991) *Como Elaborar Projetos de Pesquisa*. Atlas, São Paulo.
- Kahn, K. (1998) Benchmarking Sales Forecasting Performance Measures. *The Journal of Business Forecasting*, Winter, p. 19-23.
- Kotler, P. (1991) *Marketing Management: Analysis, Planning, Implementation, and Control*. Prentice-Hall, New York.
- Lemos, F. O. (2006) *Metodologia para seleção de métodos de previsão de demanda*. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Makridakis, S. (1988) Metaforecasting: Ways of Improving Forecast Accuracy and Usefulness. *International Journal of Forecasting*, v. 4, n. 3, p. 467-491.
- Makridakis, S.; S. C. Wheelwright e R. J. Hyndman (1998) *Forecasting Methods and Applications*. John Wiley & Sons, New York.
- Meneghini, M.; M. J. Anzanello (2013). *Ajuste de previsão de demanda quantitativa com base em fatores qualitativos: estudo de caso em um restaurante fast food*. Trabalho de Conclusão (Graduação em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Milani Júnior, A.; H. Q. P. Júnior e J. V. Bomtempo (2007) A indústria do petróleo como uma organização complexa: modelagem de negócios e processo decisório. *Revista Produção*, v. 17, n. 1, p. 008-032.
- Moon, M; J. Mentzer; C. Smith e M Garver (1998) Seven Keys to Better Forecasting. *Business Horizons*, v. 41, n. 5, p. 44-52.
- Montgomery, D.; L. Johnson e J. Gardiner (1990) *Forecasting and Time Series Analysis*. McGraw Hill, New York.
- Pellegrini, F. R. (2000) *Metodologia para implementação de sistemas de previsão de demanda*. Dissertação (Mestrado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Pellegrini, F. R. e F. S. Fogliatto (2001) Passos para Implantação de Sistemas de Previsão de Demanda – Técnicas e Estudo de Caso. *Revista Produção*, v. 11, n.1, p. 43-64.
- Senna, P.; R. Tanscheit e A. M. Gomes (2015) Planejando o processo de previsão de demanda com auxílio da lógica fuzzy. *Revista Produção e Desenvolvimento*, v. 1, n. 2, p. 90-103.
- Thomas, R. J. (1996) Estimating Demand for Services: Issues in Combining Sales Forecasts. *Journal of Forecasting*, v. 3, n. 4, p. 241-250.
- Werner, L. (2004) *Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião*. Tese (Doutorado em Engenharia de Produção) – Universidade Federal do Rio Grande do Sul, Porto Alegre.
- Winters, P. R. (1960) Forecasting Sales by Exponentially Weighted Moving Average. *Management Science*, v. 6, p. 324-342.