

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS SOCIAIS APLICADAS – GOVERNADOR VALADARES
DEPARTAMENTO DE ADMINISTRAÇÃO

Caleb Alves Gonçalves

Previsão da demanda por aulas práticas em Centros de Formação de Condutores:

Aplicação de modelos quantitativos de séries temporais

Governador Valadares

2025

Caleb Alves Gonçalves

Previsão da demanda por aulas práticas em Centros de Formação de Condutores:

Aplicação de modelos quantitativos de séries temporais

Trabalho de conclusão de curso apresentado ao Departamento de Administração na Universidade Federal de Juiz de Fora – Campus Governador Valadares como requisito parcial à obtenção do título de Bacharel em Administração.

Orientador: Dr. Leonardo Lemos da Silveira Santos

Governador Valadares

2025

Ficha catalográfica elaborada através do programa de geração automática da Biblioteca Universitária da UFJF, com os dados fornecidos pelo(a) autor(a)

Gonçalves, Caleb Alves.

Previsão da demanda por aulas práticas nas categorias A, B e D em Centros de Formação de Condutores: : Aplicação de modelos quantitativos de séries temporais / Caleb Alves Gonçalves. -- 2025. 103 p.

Orientador: Leonardo Lemos da Silveira Santos
Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Juiz de Fora, Campus Avançado de Governador Valadares, Instituto de Ciências Sociais Aplicadas - ICSA, 2025.

1. Previsão de demanda. 2. Séries temporais. 3. Autoescola. I. Santos, Leonardo Lemos da Silveira , orient. II. Título.

Caleb Alves Gonçalves

Previsão da demanda por aulas práticas em Centros de Formação de Condutores:

Aplicação de modelos quantitativos de séries temporais

Trabalho de conclusão de curso apresentado ao Departamento de Administração na Universidade Federal de Juiz de Fora – Campus Governador Valadares como requisito parcial à obtenção do título de Bacharel em Administração.

Aprovado em: 21 de Agosto de 2025.

BANCA EXAMINADORA:

Prof. Dr. Leonardo Lemos da Silveira Santos - Orientador
Universidade Federal de Juiz de Fora – Campus Governador Valadares

Prof(a).Dr. Alcielis de Paula Neto
Universidade Federal de Juiz de Fora – Campus Governador Valadares

Prof(a). Dr. Rodolfo Vieira Nunes
Universidade Federal de Juiz de Fora – Campus Governador Valadares

Termo de Declaração de Autenticidade de Autoria

Declaro, sob as penas da lei e para os devidos fins, junto à Universidade Federal de Juiz de Fora – Campus Avançado Governador Valadares, que meu Trabalho de Conclusão de Curso é original, de minha única e exclusiva autoria e não se trata de cópia integral ou parcial de textos e trabalhos de autoria de outrem, seja em formato de papel, eletrônico, digital, audiovisual ou qualquer outro meio.

Declaro ainda ter total conhecimento e compreensão do que é considerado plágio, não apenas a cópia integral do trabalho, mas também parte dele, inclusive de artigos e/ou parágrafos, sem citação do autor ou de sua fonte. Declaro por fim, ter total conhecimento e compreensão das punições decorrentes da prática de plágio, através das sanções civis previstas na lei do direito autoral¹ e criminais previstas no Código Penal², além das cominações administrativas e acadêmicas que poderão resultar em reprovação no Trabalho de Conclusão de Curso.

Governador Valadares, 21 de Agosto de 2025.

Caleb Alves Gonçalves

201701077GV

¹ LEI Nº 9.610, DE 19 DE FEVEREIRO DE 1998. Altera, atualiza e consolida a legislação sobre direitos autorais e dá outras providências.

² Art. 184. Violar direitos de autor e os que lhe são conexos: Pena - detenção, de 3 (três) meses a 1 (um) ano ou multa

À Deus, que me abençoa todos os dias. Aos meus pais, pela base que me deram e pelo apoio constante em todos os sentidos. Aos meus irmãos, Israel, pelo incentivo aos estudos, e Misael, pelo companheirismo. À minha família, por todo suporte ao longo da caminhada.

E, à minha esposa, por ser pilar nesta jornada, com amor, paciência e presença em cada etapa.

AGRADECIMENTOS

Agradeço primeiramente a Deus, por ter me sustentado nos momentos mais difíceis e me dado sabedoria e força para vencer cada etapa da vida acadêmica e pessoal. Aos meus pais, pelo amor, pela base que me deram e por todo apoio material e emocional ao longo de minha formação. A educação, os valores e os princípios que me transmitiram foram essenciais para minha trajetória. Aos meus irmãos: Israel, por me incentivar continuamente a crescer e buscar conhecimento, e Misael, por seu companheirismo e apoio direto e indireto, inclusive nos momentos em que sua ajuda veio de forma discreta, mas indispensável. À minha esposa, pelo suporte incansável durante todo o curso. Sua compreensão, parceria, incentivo e ajuda nas responsabilidades do cotidiano foram fundamentais para a conquista deste diploma.

Agradeço também aos professores do curso de Administração da UFJF – Campus Governador Valadares, por contribuírem com sua dedicação, conhecimento e experiências ao longo da minha formação. Em especial, expresso minha gratidão ao Professor Leonardo Lemos da Silveira Santos, meu orientador, por sua paciência, disponibilidade e orientação segura nos momentos em que encontrei dificuldades. Sua atenção e apoio foram fundamentais para que este trabalho fosse concretizado.

Estendo minha gratidão a todos que, de alguma forma, contribuíram para a realização deste trabalho e para minha caminhada universitária. A todos vocês, meu sincero obrigado.

RESUMO

O presente Trabalho de Conclusão de Curso tem como objetivo identificar o método mais eficiente de previsão da demanda por aulas práticas nas categorias A, B e D, em duas unidades de Centros de Formação de Condutores (CFCs) localizados em Governador Valadares – MG. A pesquisa utiliza abordagem quantitativa, com aplicação de métodos baseados em séries temporais. Os dados foram extraídos do sistema interno CFC PRODUTIVO, abrangendo o período de 2018 a 2024, e foram consideradas apenas aulas efetivamente realizadas, por representarem a demanda concretizada. Os métodos aplicados incluem Média Móvel Simples, Média Móvel Ponderada, Suavização Exponencial Simples, Holt, Holt-Winters Aditivo e Holt-Winters Multiplicativo. A comparação entre os modelos foi realizada com base no Erro Quadrático Médio (EQM) e na Raiz do Erro Quadrático Médio (RMSE). Os resultados permitiram identificar o modelo mais adequado para cada categoria e unidade, contribuindo para decisões estratégicas relacionadas à capacidade produtiva, planejamento operacional e gestão da oferta de serviços nos CFCs. A análise detalhada demonstrou a importância de uma previsão de demanda precisa para otimizar a alocação de recursos e reduzir desperdícios, fornecendo um valioso suporte à gestão estratégica do negócio.

Palavras-chave: previsão de demanda; séries temporais; autoescola; aulas práticas; gestão de operações.

ABSTRACT

This Final Paper aims to identify the most efficient method for forecasting the demand for practical driving lessons in categories A, B, and D, in two Driving School Centers (CFCs) located in Governador Valadares – MG. The research uses a quantitative approach, applying methods based on time series. Data were extracted from the internal system CFC PRODUTIVO, covering the period from 2018 to 2024, and only effectively conducted classes were considered, as they represent the materialized demand. The applied methods include Simple Moving Average, Weighted Moving Average, Simple Exponential Smoothing, Holt, Holt-Winters Additive, and Holt-Winters Multiplicative. The comparison between the models was based on the Mean Squared Error (MSE) and the Root Mean Squared Error (RMSE). The results allowed for the identification of the most suitable model for each category and unit, contributing to strategic decisions related to productive capacity, operational planning, and the management of service offerings at the CFCs. The detailed analysis demonstrated the importance of accurate demand forecasting to optimize resource allocation and reduce waste, providing valuable support for the business's strategic management.

Keywords: demand forecasting; time series; driving school; practical lessons; operations management.

LISTA DE ILUSTRAÇÕES

Figura 1 - Processo de previsão de KRESS; SNYDER (1994).....	25
Figura 2 – Cabeçalho da base de dados brutos extraídos do sistema CFC PRODUTIVO.....	41
Figura 3 – Cabeçalho da base de dados tratados extraídos do sistema CFC PRODUTIVO.....	43
Gráfico 1 – Composição Geral da Demanda - Autoescola A.....	44
Gráfico 2 – Composição Geral da Demanda - Autoescola B.....	45
Gráfico 3 – Total de aulas realizadas por categoria (2018 a 2024) – Autoescola A.....	45
Gráfico 4 – Total de aulas realizadas por categoria (2022 a 2024) – Autoescola B.....	46
Gráfico 5 – Série temporal semanal da quantidade de aulas por categoria – Autoescola A e Autoescola B.....	48
Gráfico 6 - Média Móvel Simples - CAT A - Autoescola A.....	51
Gráfico 7 - Média Móvel Simples - CAT B - Autoescola A.....	52
Gráfico 8 - Média Móvel Simples - CAT D - Autoescola A.....	53
Gráfico 9 - Média Móvel Simples - CAT A - Autoescola B.....	54
Gráfico 10 - Média Móvel Simples - CAT B - Autoescola B.....	55
Gráfico 11 - Média Móvel Ponderada - CAT A - Autoescola A.....	58
Gráfico 12 - Média Móvel Ponderada - CAT A - Autoescola A.....	59
Gráfico 13 - Média Móvel Ponderada - CAT D - Autoescola A.....	60
Gráfico 14 - Média Móvel Ponderada - CAT A - Autoescola B.....	61
Gráfico 15 - Média Móvel Ponderada - CAT B - Autoescola B.....	62
Gráfico 16 - Suavização Exponencial Simples - CAT A - Autoescola A.....	66
Gráfico 17 - Suavização Exponencial Simples - CAT B - Autoescola A.....	67
Gráfico 18 - Suavização Exponencial Simples - CAT D - Autoescola A.....	68
Gráfico 19 - Suavização Exponencial Simples - CAT A - Autoescola B.....	69
Gráfico 20 - Suavização Exponencial Simples - CAT B - Autoescola B.....	70
Gráfico 21 - Método Holt - CAT A - Autoescola A.....	73

Gráfico 22 - Método Holt - CAT B - Autoescola A.....	74
Gráfico 23 - Método Holt - CAT D - Autoescola A.....	75
Gráfico 24 - Método Holt - CAT A - Autoescola B.....	76
Gráfico 25 - Método Holt - CAT B - Autoescola B.....	77
Gráfico 26 - Método Holt - Winter Aditivo - CAT A - Autoescola A.....	80
Gráfico 27 - Método Holt - Winter Aditivo - CAT B - Autoescola A.....	81
Gráfico 28 - Método Holt - Winter Aditivo - CAT D - Autoescola A.....	82
Gráfico 29 - Método Holt - Winter Aditivo - CAT A - Autoescola B.....	83
Gráfico 30 - Método Holt - Winter Aditivo - CAT B - Autoescola B.....	84
Gráfico 31 - Método Holt - Winter Multiplicativo - CAT A - Autoescola A.....	87
Gráfico 32 - Método Holt - Winter Multiplicativo - CAT B - Autoescola A.....	88
Gráfico 33 - Método Holt - Winter Multiplicativo - CAT D - Autoescola A.....	89
Gráfico 34 - Método Holt - Winter Multiplicativo - CAT A - Autoescola B.....	90

LISTA DE TABELAS

Tabela 1 - Comparativo de EQM e RMSE dos períodos da MMS	54
Tabela 2 - Comparativo de EQM e RMSE das autoescolas e pesos da MMP	62
Tabela 3 - Comparativo de EQM e RMSE das autoescolas e pesos da SES.....	69
Tabela 4 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt.....	76
Tabela 5 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt-Winters Aditivo	83
Tabela 6 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt-Winters Multiplicativo.....	91
Tabela 7 - Comparativo de RMSE dos Métodos de Previsão	92

SUMÁRIO

1	INTRODUÇÃO	12
2	DEMANDA	15
3	PREVISÃO DA DEMANDA.....	18
4	PREVISÃO DE DEMANDA E SÉRIES TEMPORAIS.....	20
5	PROCESSO DE PREVISÃO DE DEMANDA.....	22
6	MÉTODOS DE PREVISÃO USANDO SÉRIES TEMPORAIS	24
6.1	MÉDIA MÓVEL SIMPLES	24
6.2	MÉDIA MÓVEL PONDERADA	24
6.3	SUAVIZAÇÃO EXPONENCIAL SIMPLES.....	25
6.4	MODELO HOLT	26
6.5	MODELOS DE HOLT-WINTER.....	27
6.5.1	Multiplicativo:	28
6.5.2	Aditivo	29
7	ERROS DE PREVISÃO	31
8	O SETOR DE FORMAÇÃO DE CONDUTORES NO BRASIL	33
9	METODOLOGIA.....	37
10	ANÁLISES DOS DADOS.....	41
10.1	ANÁLISE DESCRITIVA DOS DADOS.....	41
10.2	APLICAÇÃO DOS MÉTODOS DE PREVISÃO	47
10.2.1	Aplicação e análise do método de Média Móvel Simples.....	47
10.2.2	Aplicação e Análise do Método de Média Móvel Ponderada	54
10.2.3	Aplicação e análise do método de Suavização Exponencial Simples	61
10.2.4	Aplicação e análise do método de Holt	68
10.2.5	Aplicação e Análise do Método De Holt-Winters Aditivo.....	75
10.2.6	Aplicação e Análise do Método De Holt-Winters Multiplicativo.....	82
10.3	ANÁLISE COMPARATIVA ENTRE OS MÉTODOS	90

11	DISCUSSÃO DOS RESULTADOS	93
12	CONCLUSÃO.....	98
	REFERÊNCIAS.....	100

1 INTRODUÇÃO

Muitas pessoas sonham em conquistar a Carteira Nacional de Habilitação (CNH), mas poucas sabem quais são os agentes e organizações que fazem parte do processo de realização deste sonho antes de iniciá-lo. A primeira instituição que o ajudará a se tornar habilitado é o Estado que, através de seus órgãos reguladores, estabelece quais são as regras de trânsito e quais os critérios que o tornarão aptos para dirigir um veículo. Já a segunda instituição é a clínica credenciada pelo Departamento de Trânsito (Detran), que atesta a aptidão física e mental dos futuros motoristas. Por fim, os Centros de Formação de Condutores (CFCs). Conforme estabelece o artigo 145 do Código de Trânsito Brasileiro (Lei nº 9.503/1997), os CFC's têm como principal finalidade capacitar candidatos à obtenção da Carteira Nacional de Habilitação, oferecendo cursos teóricos e práticos.

Os Centros de Formação de Condutores (CFCs), popularmente conhecidos como auto escolas, desempenham papel central na capacitação de candidatos, oferecendo aulas teóricas sobre legislação, direção defensiva, primeiros socorros e cidadania, e aulas práticas de direção veicular. As aulas teóricas são, geralmente, realizadas por turmas, tendo em sua maior parte horários já pré-definidos e a possibilidade de ocorrerem de maneira remota e on-line, o que facilita a gestão de recursos e a otimização dos processos. Já a gestão de aulas práticas é determinada a partir da demanda por parte dos alunos, tendo a carga horária obrigatória determinada pelo Código de Trânsito Brasileiro (CTB) a ser cumprida e podendo estender-se com aulas extras solicitadas pelo próprio aluno.

Nesse sentido, a gestão operacional dos CFCs apresenta desafios particulares, principalmente na coordenação das aulas práticas, que dependem da disponibilidade de alunos, instrutores e veículos. A demanda por aulas é influenciada por fatores sazonais, econômicos, comportamento do consumidor e mudanças na legislação, tornando a previsão de demanda complexa e essencial para otimização de recursos e redução de custos. Frequentemente o que se observa no cotidiano desse tipo de empresa é um desequilíbrio entre o comportamento “real” da demanda e a oferta de recursos, como instrutores, veículos e horários. Um planejamento cuidadoso, baseado em previsões confiáveis de demanda futura, é, portanto, crucial para o desempenho operacional e financeiro das autoescolas. Uma previsão imprecisa pode causar sobrecarga ou ociosidade, impactando negativamente a satisfação do aluno e a eficiência do serviço (GOBE et al., 2000; BALLOU, 2006). No caso dos CFC's uma “boa” previsão de demanda poderia ser

convertida em planejamento e ações gerenciais capazes de reduzir o tempo de prestação de serviço, de otimizar a frota de veículos, de regular o quadro de horários dos instrutores e, conseqüentemente, de ampliar a possibilidade de maior faturamento, margem de contribuição e lucro.

Diante desse cenário, os administradores dos Centros de Formação de Condutores precisam de ferramentas e métodos eficientes na previsão de demanda das aulas práticas, com vistas a aprimorar a sua eficiência operacional, reduzindo desperdícios e otimizando recursos. No entanto, a literatura aponta que a previsão de demanda, apesar de amplamente aplicada para setores de serviços, industriais e comerciais, ainda é pouco explorada para o ramo da educação do trânsito, especificamente para os CFC's. Miller (2010), declara que a previsão de demanda na área da educação pode ser mais complexa, considerando a variedade de procura, motivada por variáveis externas, como alterações na legislação e modos de se comportar do consumidor. Essa lacuna evidencia a necessidade de aprofundar pesquisas nessa área para oferecer soluções práticas e inovadoras.

Neste contexto, a questão que norteia o presente estudo é: qual seria o método mais acurado para prever a demanda por aulas práticas em um Centro de Formação de Condutores? A partir dessa pergunta estabeleceu-se como objetivo geral da pesquisa definir - dentro de um conjunto pré-determinado de métodos baseados em séries temporais (média móvel simples, média móvel ponderada, suavização exponencial simples, método de Holt, Holt-Winters Aditivo e Holt-Winters Multiplicativo) - qual é o que melhor se ajusta à demanda por aulas práticas em um CFC's em Governador Valadares (MG).

Para alcançar esse objetivo e responder ao problema da pesquisa, foram traçados os seguintes objetivos específicos: (a) analisar os dados históricos da demanda por aulas práticas em cada categoria A, B e D, nas duas unidades do CFC's estudado; (b) avaliar o comportamento (nível, sazonalidade e tendência) dessa demanda; (c) aplicar diferentes métodos de previsão de demanda (média móvel simples, média móvel ponderada, suavização exponencial simples, método de Holt, Holt-Winters Aditivo e Holt-Winters Multiplicativo) aos dados históricos disponíveis e (d) verificar qual deles melhor se ajusta, ou seja, que apresenta o menor erro de previsão.

De maneira geral, o trabalho foi desenvolvido tal como um processo de previsão de demanda, ou seja, de acordo com uma sequência estruturada de etapas, essenciais para garantir a precisão e a aplicabilidade das estimativas. Inicialmente, definiu-se o objetivo da previsão e o horizonte temporal de interesse (Autoescola A entre 2018-2024, Autoescola B entre 2022-2024),

determinando os produtos ou serviços a serem analisados (aulas práticas categorias A, B e D). Na sequência, procedeu-se à coleta sistemática de dados históricos de vendas (aulas práticas realizadas). Os dados coletados foram então analisados para identificar padrões, sazonalidades, tendências e potenciais anomalias que pudessem ter influenciado a demanda. Com base nessa análise, selecionou-se a metodologia de previsão mais adequada (nesse caso, de natureza quantitativa). A etapa subsequente consistiu na geração das estimativas de demanda, aplicando-se os métodos selecionados e ajustando-se parâmetros aos dados históricos da empresa (médias móveis, médias móveis ponderadas, suavização exponencial ou modelos de Holt e de Holt-Winters). Posteriormente, a acurácia das previsões foi avaliada por meio de métricas como Erro Quadrático Médio (EQMt) e Raiz do Erro Quadrático Médio (RMSE).

2 DEMANDA

De acordo com Nogami & Passos (2016), a demanda, também chamada de procura, corresponde à quantidade de um produto ou serviço que os consumidores desejam adquirir em um determinado período, levando em consideração seus gastos e o preço de mercado. No entanto, a demanda representa apenas a intenção de compra, não necessariamente sua concretização por meio da aquisição do bem ou serviço. Segundo Crocco (2013), as empresas precisam compreender e antecipar as demandas do mercado para desenvolver estratégias de vendas mais eficazes, garantindo que seus produtos e serviços atendam às necessidades dos consumidores e possam influenciar seus padrões de consumo.

A demanda por produtos ou serviços pode apresentar diferentes características que influenciam a gestão e o planejamento operacional das empresas. A demanda pode ser excessiva, quando a procura supera a capacidade de atendimento ou plena quando demanda e capacidade se igualam. A demanda pode ser decrescente, ou seja tende a cair ao longo do tempo ou crescente quando aumenta progressivamente. A demanda pode ser negativa refletindo a rejeição ao produto/serviço. Pode ser latente envolvendo necessidades ainda não manifestadas. A demanda pode ser irregular quando variações imprevisíveis. Pode ser sazonal seguindo padrões e variações temporais previsíveis. Por fim, a demanda pode ser independente quando se refere à procura por produtos finais ou dependente quando está relacionada à demanda por componentes necessários à produção de itens finais. Compreender essas variações é essencial para otimizar recursos, planejar a produção e atender clientes de forma eficiente (KOTLER; KELLER, 2012; BALLOU, 2015; KRAJEWSKI, RITZMAN; MALHOTRA, 2009; DIAS, 1993; MARTINS; LAUGENI, 2005; MENTZER; MOON, 2005; SLACK; CHAMBERS; JOHNSTON, 2002).

A demanda excessiva, segundo Kotler e Keller (2012), ocorre quando a capacidade de produção ou fornecimento da empresa é ultrapassada pela procura de algum produto ou serviço, resultando na falta ou escassez deste. Como consequência das ações publicitárias, novidades tecnológicas ou tendências da moda, pode ocorrer o aumento extraordinário do desejo do consumidor resultando neste tipo de demanda. É necessário gerir de maneira cautelosa essa falta ou escassez, ajustando a produção à quantidade demandada, tomando decisões de onde colocar os seus produtos com a finalidade de satisfazer da melhor maneira possível aos consumidores. A demanda excessiva também é abordada por Ballou (2015), ele evidencia que esse tipo de demanda

requer políticas de priorização, controle de estoque e provável aumento da oferta de produtos ou serviços para evitar perda de cliente ou danos à imagem da empresa.

De acordo com Kotler e Keller (2012), a demanda plena acontece quando a demanda pelo produto ou serviço está perfeitamente balanceada com a capacidade produtiva da empresa. Assim, há consonância entre a quantidade demandada e a capacidade produtiva, evitando o excesso ou escassez do produto. Considerando este contexto, todas as necessidades dos consumidores são supridas pela empresa sem a sobrecarga operacional ou custo além do previsto. A finalidade de boa parte das empresas é alcançar este tipo de demanda, considerando que essa harmonia contribui para o planejamento e a previsão da produção e distribuição. Ballou (2015) argumenta que este tipo de demanda ocorre quando a procura é igual à capacidade produtiva, ou seja, a capacidade da empresa atender a demanda totalmente, ocasionando no equilíbrio entre a oferta e demanda, não gerando excesso ou escassez de produtos ou serviços.

Kotler e Keller (2012), esclarecem que a demanda decrescente ocorre quando a procura por um produto ou serviço cai ao decorrer do tempo, ocasionada normalmente por alterações nos hábitos de consumo, troca por novos produtos e tecnologias, ou quando esse produto torna-se obsoleto. Quando a demanda começa a cair é necessário que as empresas tomem decisões de como gerir essa redução, como campanhas promocionais, descontos e até a suspensão deste produto. Na gestão de estoques e na estratégia de marketing, produtos com demanda decrescente requerem maior atenção, considerando que a empresa pode exigir a mudança de direção de seus recursos para produtos mais vantajosos. De acordo com Krajewski, Ritzman e Malhotra (2009), a demanda decrescente ocorre quando há uma queda contínua na procura por um produto, geralmente consequente da obsolescência ou avanço tecnológico, resultando na substituição deste produto.

Segundo Kotler e Keller (2012), a demanda negativa refere-se àquelas necessidades de produtos ou serviços que são evitadas pelos consumidores, ou seja, os consumidores não estimam o produto, podendo até evitar comprá-lo. Já a demanda inexistente, segundo os próprios autores, refere-se quando não há conhecimento sobre o produto ou serviço, quando não há interesse ou não há percepção de necessidade por parte do consumidor. Ballou (2015) argumenta que a demanda negativa requer ações de marketing como reestruturação do produto, redução de preço ou campanhas educativas, enquanto é necessário que a organização crie ou desperte o desejo e necessidade através da comunicação e identificação de benefícios desconhecidos para lidar com a demanda inexistente.

Kotler e Keller (2012) descrevem que a demanda latente ocorre quando há um compartilhamento entre os consumidores de uma forte necessidade que não pode ser satisfeita por nenhum produto que já existe. Já a demanda indesejada é explicada, segundo os mesmos autores, por a atração de consumidores por produtos que possuem resultados sociais negativos.

A demanda irregular, de acordo com Kotler e Keller (2012), ocorre quando as compras dos consumidores variam em certos períodos ao decorrer do ano (como sazonalmente), ou de acordo com o mês, a semana, o dia ou o horário. Essas variações são resultantes de fatores externos como temperatura, recessos de feriados ou datas comemorativas, e também por comportamentos de acordo com alguns ciclos de consumo. Um exemplo disso, é o aumento de demanda nos meses frios do ano por roupas de inverno, em contrapartida devido ao feriado de Natal aumentar a demanda por brinquedos. Estrategicamente, as empresas devem considerar essas flutuações, adequando a gestão de estoques e utilizando de estratégias de marketing, para evitar excessos ou a escassez de produtos e serviços durante esses períodos.

Dias (1993) evidencia que a demanda sazonal caracteriza-se por variações periódicas de consumo abaixo da média ou acima, com regularidade de intervalos, como as estações do ano e ou recessos, impactando diretamente no planejamento produtivo. Martins e Laugeni (2005) também afirmam que a demanda sazonal é classificada como padrões de demanda repetitivos regularmente ao decorrer do tempo, geralmente ligados a fatores como clima, datas festivas e ciclos comportamentais de consumo.

De acordo com Mentzer e Moon (2005), a demanda independente é traduzida pela procura de produtos finais, onde a demanda não depende diretamente ou indiretamente da demanda de outros produtos da cadeia de produção, sendo influenciadas por variáveis externas, ou seja, de mercado. Slack, Chambers & Johnston (2002), definem também a demanda independente sendo aquela que tem origem externamente ao sistema de produção, não sendo originada de padrões produtivos internos ou dependente do consumo de outros produtos.

Ainda em consonância com Mentzer e Moon (2005), a demanda dependente é originada pela procura por produtos acabados, traduzindo-se que a demanda de componentes e matérias-primas é diretamente ligada à produção esperada desses produtos. Slack, Chambers e Johnston (2002), complementam que a demanda dependente acontece quando a procura de itens específicos depende da quantidade planejada de produção de produtos finais, como peças ou componentes para

montagem, ou seja, o contrário da demanda independente que não tem relação direta com a produção.

3 PREVISÃO DA DEMANDA

A partir do estudo apresentado por Melo e Alcântara (2011), que reúne diferentes abordagens sobre a gestão da demanda, observa-se que esse conceito é definido por Croxton et al. (2008) como o processo de gerenciamento da cadeia de suprimentos, composto por subprocessos operacionais e estratégicos, com o objetivo de estabelecer previsões de vendas alinhadas à capacidade produtiva da cadeia de suprimentos e da empresa. Para Walters & Rainbird (2004), a gestão da demanda envolve a compreensão das demandas atuais e futuras dos clientes, dos aspectos do mercado e das possibilidades disponíveis para atender a essas demandas por meio de processos operacionais. Nesse sentido, a gestão da demanda pode ser compreendida como a integração entre os processos de geração e atendimento da demanda, tanto internamente na empresa quanto ao longo da cadeia de suprimentos. Esse alinhamento permite potencializar a relação entre marketing e a gestão da cadeia de suprimentos (SCM), contribuindo para a obtenção de vantagens competitivas, conforme a perspectiva de Hilletofth, Ericsson e Christopher (2009).

No que se refere à previsão de demanda, Cavalheiro (2003) a define como o processo para calcular a quantidade de futura demanda de bens e serviços através de dados históricos e de métodos de análises. De maneira semelhante, MAKRIDAKIS, WHEELWRIGHT E HYNDMAN (2008), elucidam que a previsão é a utilização de dados históricos para a predição de comportamentos que ainda acontecerão, fazendo a identificação de padrões nos dados que são repetitivos ao decorrer do tempo, como tendências e sazonalidades. Eles destacam a importância de modelos matemáticos para as projeções mais acuradas.

A previsão de demanda consiste na estimativa quantitativa ou qualitativa da quantidade de produtos ou serviços que os consumidores vão requisitar em um determinado período futuro no tempo. Esse processo é essencial para que as empresas possam planejar suas operações, alocar recursos de forma eficiente e atender ao mercado de maneira adequada, minimizando excessos ou faltas de produtos/serviços. A previsão de demanda fornece informações críticas para a tomada de decisão em áreas como produção, estoques, logística, compras e gestão financeira, influenciando diretamente a eficiência operacional e a competitividade empresarial (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; BALLOU, 2006). Quando realizada de forma adequada, permite que empresas evitem tanto a ociosidade de capacidade quanto a incapacidade de atender à demanda crescente, garantindo um equilíbrio entre eficiência produtiva e atendimento ao mercado.

Por outro lado, previsões imprecisas podem gerar impactos negativos significativos, como perda de vendas, aumento de custos com estoques, desperdício de insumos e comprometimento da confiabilidade organizacional (CAVALHEIRO, 2003).

Os principais métodos de previsão de demanda podem ser classificados em técnicas qualitativas e quantitativas. As técnicas qualitativas envolvem julgamentos de especialistas, pesquisa de mercado e análise Delphi, sendo especialmente úteis quando há escassez de dados históricos ou mudanças abruptas no comportamento do mercado (MOREIRA, 2001). Entre as técnicas quantitativas – tal como serão utilizadas no presente trabalho - destacam-se a média móvel simples, média móvel ponderada, suavização exponencial simples, e os métodos de Holt e de Holt-Winters, que podem ser aditivos ou multiplicativos, dependendo da presença de tendência e sazonalidade nos dados históricos. Moreira (2001), destaca ainda o método causal, que deve ser utilizado quando a demanda está associada a variáveis externas e internas. Estes fatores, se seguirem um padrão de recorrência, é identificado como causal e destinado a um agrupamento de itens com o objetivo de ter-se uma previsão. A escolha do método adequado depende da natureza do produto, da disponibilidade e qualidade dos dados, da complexidade da série histórica e do horizonte de previsão desejado (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008). Embora os métodos qualitativos de previsão sejam úteis em situações onde há limitação de dados ou quando é essencial o julgamento de especialistas, este estudo opta por utilizar exclusivamente métodos quantitativos.

4 PREVISÃO DE DEMANDA E SÉRIES TEMPORAIS

A série temporal, segundo Hyndman & Athanasopoulos (2018), é um conjunto de observações de um fator catalogadas em um determinado período de tempo. Quando se pretende fazer previsões com base em dados passados, a análise de séries temporais é primordial para isso, podendo incluir padrões como tendência, sazonalidade e ciclicidade. A partir da identificação desses padrões, podem ser utilizados modelos matemáticos para previsão de valores futuros da série temporal.

Chatfield (2004), deixa ainda mais evidente que série temporal é uma sequência de dados organizados de acordo com o tempo e que para prever, é necessário classificar fatores como tendência e sazonalidade, o que se torna fundamental para prever a demanda por aulas práticas em CFC's. Para direcionarmos o estudo é importante definir os conceitos de tendência, sazonalidade e ciclicidade, a fim de tornar aplicável os métodos de previsão e conceitos aqui abordados.

Portanto, a tendência, de acordo com Makridakis, Wheelwright & Hyndman (2008), em uma série temporal, é um fator de longo prazo, refletindo um movimento repetitivo e contínuo, para mais ou para menos de acordo com o tempo, podendo ser influenciada por diversas variáveis, como mudança de tecnologias, regras sociais ou econômicas. Hyndman & Athanasopoulos (2018) ainda complementam, nos evidenciando que representa uma modificação na média de uma série temporal num longo período, aumentando ou diminuindo, a depender de fatores citados anteriormente.

Já a sazonalidade, seguindo os mesmos autores Makridakis, Wheelwright & Hyndman (2008) e Hyndman, & Athanasopoulos (2018), caracteriza-se com flutuações capazes de serem previsíveis em períodos fixos ao decorrer do tempo, podendo ser diárias, semanais, mensais ou anuais, incluindo outros eventos que interferem no comportamento de todas as variáveis. Já a ciclicidade, segundo eles, caracteriza-se por flutuações no longo prazo, que não possuem um modelo regular, podendo ser causados por variáveis macroeconômicas e políticas, sendo fatores imprevisíveis.


Perini e Bertolde (2016), definem também um quarto componente das séries temporais, no caso, irregularidade, sendo como aquele que há mudanças aleatórias e sem regularidade derivadas de variáveis divergentes.

É importante entender também os conceitos de série temporal estacionária e não estacionária, pois esse é um pressuposto importante para diversos modelos preditivos (HYNDMAN; ATHANASOPOULOS, 2018; MORETTIN; TOLOI, 2006). Apesar de existirem outros pressupostos como homocedasticidade e normalidade dos resíduos, estes são cruciais para a validação dos modelos (MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008). Uma série temporal estacionária ocorre quando a média, a variância e a estrutura de autocorrelação, são constantes ao decorrer do tempo (HYNDMAN; ATHANASOPOULOS, 2018; MORETTIN; TOLOI, 2006). Em outros termos, o desempenho da demanda é independente de em qual parte do tempo ela está sendo observada. Significando assim, que não há tendências nítidas, sazonalidade permanente ou alterações significativas na variabilidade ao decorrer do tempo. Ao contrário, uma série não estacionária ocorre quando suas propriedades estatísticas alteram ao decorrer do tempo. Exemplos claros de não estacionariedade é quando ocorre tendência e/ou sazonalidade.

5 PROCESSO DE PREVISÃO DE DEMANDA

Kress Snyder (1994), sugere que o processo de previsão siga os seguintes passos, o que está estruturado na figura 1 que será apresentada logo abaixo:

Figura 1 - Processo de previsão de KRESS; SNYDER (1994)



Fonte: KRESS; SNYDER (1994, p. 115)

Inicialmente é necessário definir o propósito da previsão, em seguida identificar quais são as características chaves da previsão estabelecendo o período da previsão (dia, semana, mês, ano) e seu nível de detalhamento (produto, serviço, região e afins). Posteriormente é necessário identificar as forças internas e externas, determinando fatores internos como por exemplo, lançamento de novos produtos, dados passados de vendas e etc; e externos (como fatores econômicos e atividades de concorrentes). Após isso, é necessário estabelecer o modelo de previsão mais adequado, baseando-se no horizonte de previsão, acurácia, custos, disponibilidade de informações e dados, bem como a complexidade dos modelos. É necessário, portanto, fazer uma primeira previsão para logo depois revisar esta previsão utilizando como base o retorno dos usuários com a finalidade de ajustar a previsão. Finalmente, após efetivar o ajuste da previsão inicial, é necessário que seja feita a previsão formal e monitorar o erro, acompanhando e ajustando

os erros para que esteja o mais próximo possível da realidade, encerrando assim, a última etapa do processo. O monitoramento dos erros é o momento onde há uma análise de comportamento da demanda, identificando as falhas no método de previsão, ajustando-o continuamente, para que decisões sejam baseadas em dados cada vez mais precisos para minimizar a possibilidade de erros que impactam diretamente na lucratividade da empresa.

Fazer previsões de maneira mais eficaz e com maior precisão exige um planejamento, análise e contínuo aprendizado, não sendo mera sugestão de um número, sendo preciso considerar os fatores pertinentes e a seleção de um melhor modelo ou ferramenta apropriada para cada ambiente e momento empresarial. (KRESS; SNYDER, 1994).

6 MÉTODOS DE PREVISÃO USANDO SÉRIES TEMPORAIS

6.1 MÉDIA MÓVEL SIMPLES

Para prever a demanda futura, a média móvel simples usa a média dos últimos n períodos dos dados passados, onde a suavização das variações aumenta de acordo com o tamanho da amostra, ou seja, do período selecionado (MARTINS; LAUGENI, 2005). A média móvel simples é um método de previsão de demanda baseado no cálculo da média aritmética das observações históricas mais recentes, dentro de uma janela temporal de tamanho fixo “ n ”. Para o período seguinte, a previsão é obtida pela soma dos valores passados, dividida pelo número de períodos considerados (MARTINS; LAUGENI, 2005). Esse método atribui o mesmo peso a todos os valores, desconsiderando a possível maior relevância de dados mais recentes. É apropriado para séries temporais com comportamento relativamente estável, sem tendência ou sazonalidade (MORETTIN; TOLOI, 2006; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; RAGSDALE, 2014; HILLIER; HILLIER, 2014).

$$MMS_t = \frac{1}{n} \sum_{i=1}^n D_{t-i} \quad (1)$$

Onde: **MMS_t** : Média Móvel no período t ; **D_{t-i}** : Demanda no período $t-i$; **n** : Número de períodos (períodos da média).

6.2 MÉDIA MÓVEL PONDERADA

Para prever a demanda futura, a média móvel ponderada distribui diferentes pesos aos dados passados, utilizando o maior peso para dados históricos mais atuais, com finalidade de obter maior precisão nas previsões (CORRÊA et al. 2010). A média móvel ponderada é uma variação do método de média móvel simples que atribui pesos diferentes às observações, de modo que valores mais recentes tendam a receber maior importância no cálculo da previsão. A previsão é obtida pela soma ponderada dos valores históricos, dividida pela soma dos pesos. A flexibilidade na atribuição dos pesos permite maior sensibilidade a mudanças recentes no padrão da série, sem perder a

suavização de ruídos. Assim como a média móvel simples, a média móvel ponderada não considera explicitamente componentes de tendência ou sazonalidade, sendo indicada para séries estacionárias (MORETTIN; TOLOI, 2006; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; RAGSDALE, 2014; HILLIER; HILLIER, 2014).

$$MMP_t = \sum_{i=1}^n w_i \times D_{t-i} \quad (2)$$

Onde: **MMP_t**: Média Móvel Ponderada no período **t**; **w_i**: Peso para o período **i**; **D_{t-i}**: Demanda no período **t-i**; **n**: Número de períodos.

Sendo crucial que a soma dos pesos seja igual a 1:

$$\sum_{i=1}^n P_i = 1 \quad (3)$$

6.3 SUAUIZAÇÃO EXPONENCIAL SIMPLES

Segundo Wheelwright e Makridakis (1985), devido a sua simplicidade, eficiência e capacidade de adaptação a mudanças nos padrões históricos de demanda, a suavização exponencial é uma das técnicas mais utilizadas para previsão. Ela faz a atribuição de pesos decrescentes aos valores mais antigos da série temporal, com maior foco nos dados mais recentes. Essa característica a torna especificamente adequada para séries temporais que apresentam flutuações que possuem sazonalidades ou tendências leves. A suavização exponencial simples é um método de previsão que aplica um fator de suavização α (entre 0 e 1) para atribuir maior peso às observações mais recentes e pesos decrescentes, de forma exponencial, às mais antigas. Essa abordagem exige apenas o valor observado mais recente e a previsão anterior, sendo computacionalmente simples. É recomendada para séries estacionárias, sem tendência ou sazonalidade, permitindo ajustar a sensibilidade do modelo por meio da calibração de α . No entanto, sua aplicação em séries com tendência ou sazonalidade tende a produzir erros sistemáticos (MORETTIN; TOLOI, 2006; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; RAGSDALE, 2014; HILLIER; HILLIER, 2014). Matematicamente, a equação que define a suavização exponencial é:

$$F_{t+1} = \alpha X_t + (1 - \alpha)F_t \quad (4)$$

Onde: **F_{t+1}**: É a previsão para o próximo período; **α (alfa)**: É o fator de suavização, um valor entre 0 e 1; **X_t**: É a demanda real do período atual; **F_t**: É a previsão feita para o período atual.

Como explicitado por Wheelwright e Makridakis (1985), o parâmetro de α realiza um papel fundamental no desempenho do modelo. Valores mais baixos de α geram previsões mais estáveis, dando prioridade a suavização de variações aleatórias, já valores altos de α eleva a responsividade do modelo às mudanças mais atuais na série. A suavização exponencial é largamente utilizada em questões de previsão, considerando a sua flexibilidade e pouca necessidade de grandes dados históricos.

6.4 MODELO HOLT

O método de Suavização Exponencial Dupla, ou método de Holt, segundo Moreira (2011) é um modelo considerado como de segunda ordem, sendo utilizado sobre as previsões de primeira ordem, produzidas a partir do modelo de Suavização Exponencial Simples. Após isso, o modelo tem como resultado previsões mais suaves, considerando que as variações serão menos bruscas. Este modelo amplificou o modelo de Suavização Exponencial Simples para os dados de série temporal que contém tendência linear, de acordo com Veríssimo et al. (2012). Seguindo o mesmo aspecto, os autores sustentam que o método de Holt, ao implementar constantes de suavização específicas, oferece aprimoramentos adicionais que influenciam diretamente a tendência da série temporal. O método de Holt é uma extensão da suavização exponencial simples que incorpora uma componente de tendência na série temporal, permitindo modelar dados que apresentam crescimento ou declínio ao longo do tempo (RAGSDALE, 2014; HILLIER; HILLIER, 2014). Utiliza dois parâmetros de suavização: α para o nível e β para a tendência. As equações de atualização ajustam separadamente o nível e a inclinação da série, produzindo previsões que extrapolam a tendência estimada para períodos futuros. Esse método é adequado para séries com tendência linear estável, mas sem sazonalidade significativa. Sua principal limitação é a incapacidade de capturar padrões sazonais, o que pode reduzir sua acurácia quando tais padrões estão presentes (MORETTIN; TOLOI, 2006; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008; RAGSDALE, 2014; HILLIER; HILLIER, 2014)..

Matematicamente, a equação que define o método de Holt, segundo Makridakis, Wheelwright e Hyndman (2008), é:

$$\hat{Y}_{t+k} = E_t + kT_t \quad (5)$$

Onde: **E_t** : componente de nível; **T_t** : componente de tendência; **$k=1,2,\dots,h$** : índice para o horizonte de previsão; **h** : horizonte de previsão; **y_{t+k}** : valor previsto para o período futuro (**$t+k$**).

A seguir a equação que define o nível do método:

$$L_t = \alpha x_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (6)$$

Onde: **L_t** : Novo nível no período t ; **α** : Fator de suavização do nível; **x_t** : Demanda real no período t ; **E_{t-1}** : Nível do período anterior; **T_{t-1}** : Tendência do período anterior.

A seguir a equação que define o fator tendência do método:

$$T_t = \beta(L_{t-1} - E_{t-1}) + (1 - \beta)T_{t-1} \quad (7)$$

Onde: **T_t** : Nova tendência no período t ; **β** : Fator de suavização da tendência; **$(L_{t-1} - E_{t-1})$** : A nova tendência observada entre os dois últimos níveis; **T_{t-1}** : Tendência do período anterior.

6.5 MODELOS DE HOLT-WINTER

O modelo de Suavização Exponencial Tripla, ou modelo de Holt-Winter, é utilizado para prever séries temporais que possuem como componentes a sazonalidade e tendência, segundo Morettin e Toloi (2006). O modelo foi desenvolvido por Winter (1960), ampliando o modelo de Holt a fim de contemplar modelos de séries temporais com sazonalidade e tendência. Há 3 (três) componentes principais que estruturam o modelo em questão, segundo Samohyl, Rocha e Mattos (2001), um para representar o nível, outro para a tendência e o último para a sazonalidade, podendo ser modelado de forma aditiva ou multiplicativa.

O método de Holt-Winters aditivo inclui sazonalidade aditiva, adequada para séries em que a amplitude da variação sazonal é aproximadamente constante ao longo do tempo, independentemente do nível da série. O modelo decompõe a série em três componentes: nível, tendência e sazonalidade, cada um atualizado por sua respectiva equação de suavização com parâmetros α , β e γ . A previsão para cada período futuro é obtida pela soma do nível ajustado, da tendência projetada e do fator sazonal correspondente. Esse método é eficaz para séries com

padrões sazonais fixos e tendência bem definida, mas pode apresentar desempenho insatisfatório quando a sazonalidade é proporcional ao nível da série, cenário em que o modelo multiplicativo se mostra mais adequado (BERTOLO, 2013; RAGSDALE, 2014; HILLIER; HILLIER, 2014).

O método de Holt-Winters multiplicativo é indicado para séries temporais que apresentam sazonalidade proporcional ao nível, ou seja, cuja amplitude das variações sazonais aumenta ou diminui em função do valor médio da série. Assim como no modelo aditivo, a série é decomposta em componentes de nível, tendência e sazonalidade, mas a combinação entre nível e sazonalidade é feita por multiplicação, permitindo ajustar variações sazonais relativas. Os parâmetros de suavização α , β e γ controlam a atualização das componentes. Esse método é mais flexível para séries com crescimento ou declínio acentuados acompanhados de flutuações sazonais proporcionais (BERTOLO, 2013; RAGSDALE, 2014; HILLIER; HILLIER, 2014).

Segundo Samohyl, Rocha e Mattos (2001), matematicamente, as equações que são usadas no desenvolvimento do método representam-se da seguinte maneira:

6.5.1 Multiplicativo

Nível:

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (8)$$

Onde: **L_t** : Nível no período t ; **α** : Fator de suavização do nível; **Y_t** : Demanda real no período t ; **S_{t-s}** : Fator de sazonalidade do mesmo período na última estação completa (por exemplo, a sazonalidade de janeiro do ano passado se a estação for anual); **L_{t-1}** : Nível do período anterior.

Tendência:

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (9)$$

Onde: **b_t** : Tendência no período t ; **β** : Fator de suavização da tendência; **$(L_t - L_{t-1})$** : A variação do nível entre os dois últimos períodos.

Sazonalidade:

$$S_t = \gamma \frac{Y_t}{L_t} + (1 - \gamma)S_{t-s} \quad (10)$$

Onde: **St**: Fator de sazonalidade no período t ; γ : Fator de suavização da sazonalidade; s : O número de períodos em uma estação (por exemplo, $s=12$ para dados mensais com sazonalidade anual).

Previsão:

$$F_{t+m} = (L_t + m \cdot b_t)S_{t-s+m} \quad (11)$$

Onde: **Ft+m**: É a previsão para m períodos à frente; **Lt**: É o último **nível** calculado no período t ; **bt**: É a última **tendência** calculada no período t . Multiplicamos por m para projetar essa tendência por m períodos no futuro; **m**: É o número de períodos que você quer prever no futuro (ex.: 1, 2, 3...); **St-s+m**: É o fator de sazonalidade do período correspondente na última estação completa.

6.5.2 Aditivo

Nível:

$$L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_t) \quad (12)$$

Onde: **Lt**: Nível no período t ; α : Fator de suavização do nível; **Yt**: Demanda real no período t ; **St-s**: Fator de sazonalidade do mesmo período na última estação completa; **Lt-1**: Nível do período anterior; **bt-1**: Tendência do período anterior.

Tendência:

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (13)$$

Onde: **bt**: Tendência no período t ; β : Fator de suavização da tendência; **(Lt-Lt-1)**: A variação do nível entre os dois últimos períodos.

Sazonalidade:

$$S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (14)$$

Onde: **St**: Fator de sazonalidade no período t ; γ : Fator de suavização da sazonalidade; s : O número de períodos em uma estação (por exemplo, 12 para dados mensais).

Previsão:

$$F_{t+m} = L_t + b_{t-m} + S_{t-s+m} \quad (15)$$

Onde: **$Ft+m$** : Previsão para **m** períodos à frente; **m** : Número de períodos no futuro; **Lt** : Último nível calculado; **bt** : Última tendência calculada; **$St-s+m$** : O fator de sazonalidade do mesmo período da última estação completa.

7 ERROS DE PREVISÃO

Normalmente, as previsões são inexatas, ocasionando erros que podem ser utilizados como critério de comparação entre diferentes modelos, possibilitando determinar qual o modelo que apresenta maior similaridade com a demanda real, ou seja, o modelo mais acurado. Entre as principais métricas de avaliação dos modelos quantitativos de previsão de demanda, o Erro Quadrático Médio (EQMt) destaca-se, pois mede a dispersão das previsões em comparação aos valores analisados. Segundo Krajewski, Ritzman e Malhotra (2009), o EQMt é utilizado para reprimir grandes erros, calculando-se a média dos quadrados das diferenças dos valores previstos e os valores analisados. O Erro Quadrático Médio (EQMt) é uma medida estatística amplamente utilizada para avaliar a acurácia de modelos de previsão, obtida pela média aritmética dos quadrados das diferenças entre os valores previstos e os valores observados. Essa métrica penaliza erros proporcionalmente ao seu quadrado, o que significa que grandes desvios entre previsão e realidade têm impacto mais significativo no resultado final. Como desvantagem, o EQMt apresenta resultados em unidades ao quadrado, dificultando a interpretação intuitiva em termos da variável original (RAGSDALE, 2014; HILLIER; HILLIER, 2014). Matematicamente, o EQMt é representado da seguinte maneira:

$$EQMt = \frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2 \quad (16)$$

Onde: Y_t : valor real analisado no período t ; $\hat{Y}_t$: valor previsto no período t ; n : número total de períodos avaliados.

Outra métrica de erro bastante usual é a Raiz do Erro Quadrático Médio (RMSE). A RMSE é uma medida derivada do Erro Quadrático Médio (EQMt) obtida pela extração de sua raiz quadrada, de modo que o resultado seja expresso nas mesmas unidades da variável prevista (HYNDMAN; ATHANASOPOULOS, 2018). Essa característica confere ao indicador maior interpretabilidade prática, pois permite que o analista compreenda diretamente a magnitude média dos erros no contexto do problema. A principal vantagem da RMSE em relação ao EQMt é que ela corrige a limitação de apresentar valores em unidades ao quadrado, o que facilita a comunicação e a comparação entre modelos. Em aplicações de previsão de demanda e séries temporais, a RMSE é amplamente utilizada como critério de seleção de modelos, especialmente quando é importante

traduzir a qualidade preditiva em unidades físicas da variável de interesse, como unidades vendidas, litros, reais ou aulas dadas (RAGSDALE, 2014; HILLIER; HILLIER, 2014). Matematicamente, o RMSE é representado da seguinte maneira:

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - \hat{Y}_t)^2} \quad (17)$$

Onde: Y_t : valor real analisado no período t ; $\hat{Y}_t$: valor previsto no período t ; n : número total de períodos avaliados.

Com base nessas métricas, a comparação do desempenho dos métodos aplicados torna-se possível, selecionando aquele que é mais adaptável às variações de comportamento da demanda analisada.

8 O SETOR DE FORMAÇÃO DE CONDUTORES NO BRASIL

O processo de adquirir a Carteira Nacional de Habilitação (CNH) no Brasil é rigorosamente regulamentado por uma série de normas, sendo o Código de Trânsito Brasileiro (CTB - Lei nº 9.503/1997) a sua base legal fundamental. Este código estabelece além das normas de conduta no trânsito, os critérios para a formação e habilitação de condutores. Concomitantemente, o Conselho Nacional de Trânsito (CONTRAN), por intermédio de suas resoluções, como a Resolução nº 789/2020, detalha os procedimentos, requisitos e estrutura do processo de formação. Já a fiscalização e a execução dessas normas são de estrita responsabilidade dos Departamentos Estaduais de Trânsito (DETRANs) em cada unidade federativa. Essas instituições agem em conjunto para assegurar o padrão e a qualidade na formação de novos condutores em todo o território nacional. (BRASIL, 1997; CONTRAN, 2020).

Considerando essa estrutura legal, os Centros De Formação de Condutores (CFCs), popularmente conhecidos como auto escolas, cumprem um papel fundamental. Credenciados pelos DETRANs, o principal objetivo dos CFCs é capacitar os candidatos a adquirir a CNH. Essa capacitação não é somente o mero ensino técnico de como dirigir ou pilotar um veículo, ela abarca a formação de condutores responsáveis, conscientes e aptos para interagir de forma segura no trânsito. (PORTAL DO TRÂNSITO, 2014). O processo de ensino-aprendizagem nos Centros é separado em duas fases: as aulas teórico-técnicas e as aulas práticas de direção veicular. Enquanto as aulas teórico-técnicas tratam sobre temas de legislação de trânsito, direção defensiva, primeiros socorros, meio ambiente e cidadania, as aulas práticas concentram no desenvolvimento das habilidades de direção sob a supervisão de instrutores práticos credenciados. Os profissionais dos Centros e os CFCs são credenciados a partir de um processo rigoroso, a fim de garantir que o ensino esteja de acordo com as exigências da lei e também das exigências pedagógicas. (PORTAL DO TRÂNSITO, 2014).

A legislação brasileira de trânsito, especificamente o ART. 143 do Código de Trânsito Brasileiro e a Resolução nº 789/2020 do CONTRAN, define diferentes categorias de habilitação para a condução de veículos automotores e elétricos. Categorizar esses tipos de categorias é essencial para definir os tipos de veículos que o condutor está legalmente capacitado para dirigir, certificando que ele detém a experiência e a capacidade adequada para cada modalidade

(CONTRAN,2020). As principais categorias de CNH são:

- **ACC (Autorização para Conduzir Ciclomotor):** Permite a condução de ciclomotores (veículos de duas ou três rodas com motor de até 50 cm³ e velocidade máxima de 50 km/h) (CONTRAN, 2020).
- **Categoria A:** Habilita o condutor a dirigir veículos motorizados de duas ou três rodas, como motocicletas, motonetas e triciclos (CONTRAN, 2020).
- **Categoria B:** Autoriza a condução de veículos automotores e elétricos, não abrangidos pela Categoria A, cujo Peso Bruto Total (PBT) não exceda 3.500 kg e que não exceda oito lugares, excluído o do motorista (ex: carros de passeio, picapes, vans de uso particular) (CONTRAN, 2020).
- **Categoria C:** Permite a condução de veículos motorizados utilizados no transporte de carga, cujo PBT exceda 3.500 kg (ex: caminhões, caminhonetes de carga). Exige que o condutor esteja habilitado na categoria B há pelo menos um ano (CONTRAN, 2020).
- **Categoria D:** Habilita a condução de veículos motorizados utilizados no transporte de passageiros, cuja lotação exceda a oito lugares, excluído o do condutor (ex: ônibus, micro-ônibus, vans de passageiros). Requer idade mínima de 21 anos e habilitação há pelo menos dois anos na categoria B ou um ano na categoria C (CONTRAN, 2020).
- **Categoria E:** Permite a condução de combinação de veículos em que a unidade tratora se enquadre nas categorias B, C ou D e cuja unidade acoplada (reboque, semirreboque, trailer ou articulada) tenha 6.000 kg ou mais de PBT, ou cuja lotação exceda 8 lugares (ex: caminhão com reboque grande, ônibus articulado). Exige idade mínima de 21 anos e habilitação há pelo menos um ano nas categorias C ou D (CONTRAN, 2020).

A diversificação dessas categorias e os requisitos específicos para cada tipo de veículo evidenciam a complexidade do setor e a importância do ofício dos CFC 's em capacitar os candidatos para as diferentes categorias. (Sebrae, [s.d.]).

A gestão de operações de um Centro de Formação de Condutores apresenta singularidades que a tornam mais complexa em relação a outros setores de serviço. Embora as aulas teóricas possam ser geridas em turmas com horários pré-determinados e, às vezes, em formato remoto, tornando mais eficientes os recursos e processos, a gestão de aulas práticas diferencia-se

consideravelmente. A demanda por aulas práticas é definida por cada aluno, que obrigatoriamente precisa cumprir a carga horária mínima exigida pelo Código de Trânsito Brasileiro (CTB), havendo ainda a possibilidade de aulas complementares solicitadas pelo candidato. Essa dinâmica requer uma maior flexibilidade e disponibilidades de recursos como: instrutores, veículos e horários, que precisam ser compatíveis com a rotina dos alunos e disponibilidade deles, gerando um desafio na logística da empresa para maximizar a otimização da agenda evitando a ociosidade ou sobrecarga na capacidade produtiva das autoescolas.

A demanda por aulas práticas nos CFCs não é linear, podendo variar consideravelmente ao decorrer do tempo, sendo influenciada por diversos fatores externos. Entre os principais fatores, sobressaem os fatores sazonais, como o período de férias escolares ou feriados prolongados, podendo gerar picos ou quedas na demanda. Fatores econômicos possuem uma atuação importante; o custo total da habilitação e a renda disponível dos consumidores também podem interferir no volume de matrículas. Além disso, o comportamento do consumidor e tendências na mobilidade urbana (como o aumento do uso de aplicativos de transporte ou interesse por veículos elétricos) podem inferir no interesse em obter certos tipos de categorias de CNH. Finalmente, alterações nas leis de trânsito ou em processos burocráticos também podem gerar variações repentinas na demanda. Prever a demanda na área da educação é regularmente indicada como mais complexa devido à multivariabilidade das variáveis externas que interferem na procura (MILLER, 2010; MAKRIDAKIS; WHEELWRIGHT; HYNDMAN, 2008).

A inexistência de um planejamento eficaz de recursos e de uma previsão de demanda assertiva desencadeia custos adicionais e prejudica a eficiência operacional (GOBE et al., 2000). Quando a previsão da demanda é imprecisa, a empresa pode encarar desequilíbrios relevantes: a falta de instrutores e veículos para atender uma demanda crescente pode resultar em atrasos no atendimento e andamento do processo de habilitação, insatisfação dos alunos e até perdas de matrículas, ocasionando inclusive reembolso. Ao contrário, superestimar a demanda leva à ociosidade dos recursos, aumentando custos operacionais desnecessários e até inviabilizando a operacionalização. Realizar uma previsão da demanda de maneira assertiva e um planejamento adequado e robusto são fatores essenciais para a tomada de decisão em qualquer organização, possibilitando o controle de entradas e otimizando todas as áreas operacionais (BALLOU, 2006). A otimização de estoques, redução de custos e maior satisfação do cliente é resultado da capacidade de planejamento da produção e dos serviços com antecedência, embasado em informações de

demanda futura (CAVALHEIRO, 2003). Para os CFC 's, isso é traduzido em menor tempo de prestação de serviço, melhor gestão na escala dos instrutores, otimização da frota de veículos e, conseqüentemente, aumento da margem de contribuição e lucratividade.

No estado de Minas Gerais, a relação entre os Centros de Formação de Condutores e o Departamento de Trânsito acontece, em sua maioria, por meios das Circunscrições Regionais de Trânsito (CIRETRANs). AS CIRETRANs são as unidades locais do DETRAN-MG, espalhadas entre os municípios, e têm o compromisso de gerir e fiscalizar uma variedade de serviços de trânsitos em suas respectivas jurisdições. Sua atividade é essencial para o sistema de habilitação, afinal, incluem o credenciamento e a fiscalização contínua dos Centros, o agendamento de exames teóricos e práticos de direção, e a emissão dos documentos de habilitação, como a PPD (Permissão para Dirigir) e a CNH (Carteira Nacional de Habilitação) definitiva. (Detran-MG, [s.d]).

As autoescolas objeto deste estudo, localizam-se em Governador Valadares, operando sob a jurisdição direta da CIRETRAN de Governador Valadares. Isso significa que todas a sua operação, desde o início do processo de habilitação dos candidatos até a realização dos exames teóricos e práticos e emissão dos certificados e CNH, estão subordinadas às normas, procedimentos e à capacidade operacional desta unidade específica do DETRAN-MG (Detran-MG,[s.d]). A eficiência da CIRETRAN de Governador Valadares no agendamento de exames, processamento de documentos e condução a fiscalização são fatores que interferem diretamente no fluxo de alunos e na capacidade dos CFCs locais e regionais de atenderem à demanda de forma eficiente. Nesse sentido, entender o funcionamento e as possíveis limitações da CIRETRAN é imprescindível para trazer o contexto da dinâmica da demanda por aulas práticas e recursos nas autoescolas estudadas, revelando que fatores externos podem influenciar a previsibilidade do processo.

9 METODOLOGIA

Segundo Do Nascimento (2016), a classificação da pesquisa pode ser feita quanto à sua natureza, métodos, objetivos e procedimentos. No que se refere à natureza, seguindo o que Nascimento (2016) precedeu, ela pode ser categorizada como básica ou aplicada. Em relação às pesquisas básicas, a finalidade é o avanço da ciência através da produção de novos conhecimentos, e por outro lado, os novos conhecimentos tem como objetivo resolver problemas específicos. Portanto, com base no que Do Nascimento (2016) evidencia, esta pesquisa classifica-se como aplicada.

Quanto aos métodos de pesquisa, Do Nascimento (2016) elucida que a pesquisa pode ser classificada como qualitativa, com utilização nas áreas das ciências sociais devido ao foco na interpretação de um conjunto de eventos e variáveis observadas considerando a particularidade deles; ou quantitativa, quanto refere-se à análise estatística de dados. Considerando essas interpretações, a pesquisa é quantitativa, visto que será feita a análise estatística de dados, tanto para efetuar a previsão da demanda quanto para comparação dos métodos de previsão.

Tratando-se de objetivos, existem pesquisas exploratórias, descritivas e explicativas. Gil (1991) cita que pesquisas exploratórias têm como finalidade contribuir no entendimento do pesquisador na elaboração de hipóteses e no processo decisório. Já as pesquisas descritivas, englobam o conceito da descrição das características das variáveis e sua correlação. Finalmente, as pesquisas explicativas são usadas na identificação de fatores que definem o acontecimento dos fenômenos. A pesquisa descritiva é a que define o presente estudo.

O presente estudo concentra-se na análise da demanda por aulas práticas em Centros de Formação de Condutores (CFCs) localizados na cidade de Governador Valadares, Minas Gerais, operando sob a jurisdição da CIRETRAN local. Foram selecionadas duas autoescolas pertencentes ao mesmo grupo econômico, ambas de pequeno porte, mas com grande relevância no mercado local de Governador Valadares. A escolha dessas autoescolas se deu pela sua relevância regional, permitindo obter uma amostra representativa da dinâmica do mercado. Adicionalmente, a seleção foi realizada por conveniência, visto que o autor do presente estudo teve acesso direto ao contexto operacional e aos bancos de dados disponibilizados pela gestão dessas autoescolas.

As organizações objeto deste estudo, pertencentes ao mesmo grupo econômico, apresentam perfis distintos, embora relevantes para a região. A **Autoescola A** destaca-se por possuir a maior estrutura física de Minas Gerais, contando com 12 veículos no período de estudo e oferecendo serviços de formação para as categorias A, B e D. Esta autoescola opera desde 2009, o que confere uma longa trajetória e histórico de dados.

A “**Autoescola B**”, por sua vez, dispunha de 7 veículos e atuava exclusivamente com aulas para as categorias A e B. Os dados coletados para a Autoescola B abrangem o período de 01 de julho de 2022 a 31 de dezembro de 2024, desde a sua inauguração em julho de 2022 e a consequente implementação do sistema.

Atualmente, as autoescolas objeto de estudo não utilizam um método formal e sistemático de previsão da demanda por aulas práticas. A gestão de recursos e o planejamento das agendas são baseados predominantemente na experiência dos gestores e na observação reativa do fluxo de alunos, o que frequentemente resulta em desafios de ociosidade ou sobrecarga, conforme detalhado anteriormente.

Os dados brutos para o presente estudo foram coletados diretamente do CFC PRODUTIVO, sistema de gestão interna utilizado por ambas as autoescolas. A coleta foi realizada no dia 06 de janeiro de 2025, com a extração de todos os registros relacionados às aulas práticas, conforme a estrutura apresentada na Figura 2, que representa o cabeçalho da base de dados analisada.

Figura 2 – Cabeçalho da base de dados brutos extraídos do sistema CFC PRODUTIVO

	id_aul	id_instru	id_vei		categoria	clientes_			observac			
id	a	tor	culo	id_alun	s_id	locais	tipo	ordem	oes	Data	data_e_hora	status
1553159	0	2034	2016	1312698	1	0	pratico	0		16/03/2018	16/03/2018 08:00	Desmarcadas
1553160	0	2034	2016	1312698	1	0	pratico	0		16/03/2018	16/03/2018 10:00	Desmarcadas

Fonte: Elaborado pelo autor (2025)

A base de dados original continha registros de diversos tipos de aulas, incluindo agendadas, desmarcadas, canceladas e realizadas. No entanto, para fins desta pesquisa, foram consideradas exclusivamente as aulas efetivamente realizadas, por representarem a demanda concreta e atendida por serviços de prática veicular. Aulas agendadas, canceladas, desmarcadas ou classificadas como faltas foram excluídas, pois representam apenas intenção de consumo, remanejamento ou ausência, e não caracterizam demanda efetiva. A escolha exclusiva pelas aulas dadas (efetuadas) justifica-se

pela compreensão de que este dado representa a demanda efetiva e concretizada por aulas práticas. Entende-se que todos os fatores operacionais e contextuais das autoescolas interferem diretamente na realização da prática veicular, sendo este um dos únicos processos obrigatórios e presenciais na obtenção da Carteira Nacional de Habilitação (CNH), diferentemente das aulas teóricas, que são necessárias somente para quem vai se habilitar pela primeira vez e podem ter formatos mais flexíveis. Aulas que foram canceladas, marcadas e posteriormente remarcadas, ou declaradas como faltas, não foram incluídas na base de dados, pois não representam uma demanda efetiva de serviço, mas sim questões de remanejamento ou não comparecimento, que não refletem a necessidade de capacidade produtiva das autoescolas.

Para a “**Autoescola A**”, o período dos dados analisados abrange de 13 de março de 2018 a 31 de dezembro de 2024, correspondendo ao tempo de implementação do sistema de gestão nesta unidade. A Autoescola A está em operação desde 2009.

Para a “**Autoescola B**”, os dados foram coletados desde a sua inauguração e implementação do sistema, cobrindo o período de 01 de julho de 2022 a 31 de dezembro de 2024.

Para a organização e o pré-processamento inicial dos dados, bem como a implementação dos métodos de previsão de demanda foram realizadas utilizando o Microsoft Excel. As fórmulas de cada método de previsão serão aplicadas diretamente na ferramenta, com o auxílio da função **Solver** para a otimização de cada modelo. A escolha pelo Microsoft Excel justifica-se pela sua facilidade de acesso e disponibilidade generalizada, o que torna a metodologia replicável e de fácil manuseio por diversos usuários. Além disso, o software possui funcionalidades robustas para tratamento de dados, geração de gráficos, tabelas dinâmicas e funções estatísticas, que viabilizam a análise proposta no presente estudo. Outro fator relevante é a sua acessibilidade em termos de custos de aquisição e utilização, que são significativamente menores em comparação com a maioria dos softwares estatísticos mais complexos, o que se alinha à proposta de oferecer uma solução prática e viável para as autoescolas. A versão Microsoft 365, em particular, permite o acesso aos dados e ao desenvolvimento do estudo de qualquer aparelho e em qualquer localidade, gerando maior liberdade e flexibilidade operacional.

Para a análise e fins de identificação do comportamento e previsão semanal da demanda, os dados foram organizados por semanas do ano. No software Excel, as informações foram segmentadas por categorias de aulas efetuadas, permitindo identificar a quantidade total de aulas

dadas por unidade de tempo (semanas do ano, por ano), por categoria (A, B e D) e por autoescola (“Autoescola A” e “Autoescola B”), visando compreender a composição e a representatividade geral das aulas em bases semanais e por categoria. Finalmente os dados tratados ficaram da seguinte maneira:

Figura 3 – Cabeçalho da base de dados tratados extraídos do sistema CFC PRODUTIVO

Ano	Semana do ano	Semana (N)	Quantidade total de aulas realizadas	CAT 1 (A)	CAT 2 (B)	CAT 4 (D)
2018	12	1	29	11	18	0
2018	13	2	55	16	39	0

Fonte: Elaborado pelo autor (2025)

É importante ressaltar que os dados foram analisados separadamente para cada autoescola, dada a diferença de porte e o contexto operacional particular de cada uma, mesmo estando na mesma localidade.

A análise subsequente envolverá a aplicação e comparação de diversos métodos de previsão de demanda baseados em séries temporais. Serão avaliados os seguintes métodos:

- Média Móvel Simples
- Média Móvel Ponderada
- Suavização Exponencial Simples
- Método de Holt (Suavização Exponencial Dupla)
- Método de Holt-Winters Aditivo
- Método de Holt-Winters Multiplicativo

O objetivo foi identificar qual desses modelos apresenta a maior acurácia na previsão, com o menor erro possível. A comparação da acurácia dos modelos foi realizada por meio de métricas de erro padrão. Serão utilizadas as seguintes métricas:

- Erro Médio Quadrático (EQM): métrica principal para definir qual método de previsão apresenta menor erro.
- Raiz do Erro Quadrático Médio (RMSE): utilizada como métrica complementar, por indicar os erros na mesma unidade dos dados analisados.


10 ANÁLISES DOS DADOS

10.1 ANÁLISE DESCRITIVA DOS DADOS

A análise descritiva a seguir apresenta o comportamento histórico da demanda por aulas práticas na Autoescola A, considerando o período de março de 2018 a dezembro de 2024, conforme registros extraídos do sistema CFC PRODUTIVO. Foram analisadas exclusivamente as aulas efetivamente realizadas, categorizadas conforme o tipo de habilitação: Categoria A (moto), Categoria B (carro) e Categoria D (ônibus/micro-ônibus).

A Autoescola B teve seu início de operação no segundo semestre de 2022, com dados disponíveis desde julho daquele ano até dezembro de 2024. Por se tratar de uma unidade mais recente, sua evolução demanda deve ser compreendida dentro do contexto de crescimento estrutural e consolidação no mercado.


Gráfico 1 – Composição Geral da Demanda - Autoescola A



Fonte: Elaborado pelo autor (2025)

O gráfico 1 apresenta a distribuição percentual do total de aulas realizadas por categoria no período analisado da **Autoescola A**. Observa-se que a Categoria B representa a maior parcela da demanda da Autoescola A, com aproximadamente **63%** do total de aulas ministradas. Em seguida, tem-se a Categoria A com **31%**, e a Categoria D, com **6%**, evidenciando sua menor representatividade no mix de serviços da unidade.


Gráfico 2 – Composição Geral da Demanda - Autoescola B



Fonte: Elaborado pelo autor (2025)

Na **Autoescola B** o gráfico 2 mostra a distribuição percentual da demanda por categoria ao longo de todo o período analisado. Assim como observado na Autoescola A, a **Categoria B** também representa a maior parte das aulas realizadas, com aproximadamente **63%** do total, enquanto a **Categoria A** responde por **37%**. A ausência de aulas da **Categoria D** está relacionada à não oferta dessa categoria na Autoescola B durante o período analisado.

Gráfico 3 – Total de aulas realizadas por categoria (2018 a 2024) – Autoescola A




Fonte: Elaborado pelo autor (2025)

O gráfico 3 ilustra o total de aulas realizadas por categoria ao longo dos anos na **Autoescola A**. É possível observar uma trajetória de crescimento entre 2018 e 2022, seguida por uma leve redução nos anos subsequentes. A **Categoria B** manteve-se como a mais demandada em todos os anos, com picos de crescimento expressivos em 2021 e 2022. Já a **Categoria A** apresentou

crescimento gradual até 2022, enquanto a **Categoria D** manteve comportamento relativamente estável e baixo volume ao longo de todo o período.

Gráfico 4 – Total de aulas realizadas por categoria (2022 a 2024) – Autoescola B



Fonte: Elaborado pelo autor (2025)

O gráfico 4 apresenta o total de aulas realizadas por categoria, por ano, na Autoescola B. Nota-se um crescimento expressivo da demanda entre 2022 e 2024, com destaque para o avanço tanto na **Categoria B** quanto na **Categoria A**. Esse crescimento pode ser atribuído ao processo natural de consolidação da unidade, com ampliação da base de alunos, frota e estrutura. O gráfico 4 apresenta a série histórica semanal de aulas realizadas por categoria. A **Categoria B** exibe maior volume e variabilidade ao longo do tempo, com oscilações visíveis entre os anos, mas mantendo uma média superior às demais. A **Categoria A** também demonstra comportamento sazonal, com picos e quedas em períodos específicos. A **Categoria D**, por sua vez, apresenta baixa variação e um padrão mais linear.


A tendência positiva é visível nas duas categorias, com crescimento contínuo e progressivo ano a ano. Esse comportamento fortalece a possibilidade de aplicação de métodos de previsão baseados em séries temporais, especialmente com tendência crescente.

O gráfico 5 apresenta a série histórica semanal de aulas realizadas por categoria na **Autoescola A e na Autoescola B**. A **Categoria B** exibe maior volume e variabilidade ao longo do tempo, com oscilações visíveis entre os anos, mas mantendo uma média superior às demais. A **Categoria A** também demonstra comportamento relativamente sazonal, com picos e quedas em alguns períodos. A **Categoria D**, por sua vez, apresenta baixa variação e um padrão mais linear.

Observa-se uma tendência de crescimento ao longo do tempo para a **Autoescola B**, com **picos mais altos na Categoria B**, que mantém volume maior e maior estabilidade. A **Categoria A**, embora com menor volume, apresenta também crescimento e comportamento relativamente estável, ainda que com maior variação semanal e alguns períodos de queda ou oscilação.

Os dados semanais sugerem uma certa sazonalidade e o comportamento crescente da unidade, reforçando a adequação da modelagem por séries temporais para projeções futuras da demanda.

Gráfico 5 – Série temporal semanal da quantidade de aulas por categoria – Autoescola A e Autoescola B



Fonte: Elaborado pelo autor (2025)

A análise da série temporal semanal da demanda por aulas práticas revela padrões distintos ao longo do período de estudo. Observa-se uma dinâmica que combina elementos de sazonalidade e tendência, mas que foi fortemente influenciada por fatores exógenos e decisões de gestão interna, conforme detalhado a seguir.

Ainda que a pandemia da COVID-19 tenha gerado um impacto mundial significativo na demanda de diversos setores, na **Autoescola A** observou-se uma paralisação total das aulas em todas as categorias por aproximadamente 10 semanas. Este período de aulas zeradas, visível no Gráfico 5 da série temporal semanal entre as semanas 13 e 23 do ano de 2020 (correspondentes às semanas 106 e 116 da série temporal geral), foi particularmente crítico entre março e maio de 2020. Contudo, em virtude do caráter agendado e individual das aulas práticas, que minimiza consideravelmente o risco de aglomeração, as atividades foram restabelecidas rapidamente.

Um fator relevante para a análise é a reestruturação da **Autoescola A**. Pouco antes do fechamento dos comércios da região, em fevereiro de 2020, a empresa foi reinaugurada com o dobro de veículos e uma estrutura física ampliada. Ao analisar a demanda, percebe-se uma estabilidade até o retorno das atividades pós-pandemia, seguida por uma notável tendência de crescimento no cenário subsequente. Essa ascensão pode ser diretamente atribuída à reinauguração e à reestruturação da empresa, com o maior número de veículos e o pronto restabelecimento das operações impactando positivamente a efetivação das aulas.

Adicionalmente, foram identificados períodos de "vales" na demanda, decorrentes de questões de gerenciamento interno. Durante períodos de férias e datas comemorativas de final de ano, esses vales se repetem, uma vez que as atividades da CIRETRAN e os exames práticos das categorias são paralisados, seguindo o cronograma do próprio DETRAN. Consequentemente, por decisões internas, os instrutores práticos recebiam férias. Até meados de 2021, os instrutores, ao terem seu período aquisitivo adquirido, podiam gozar desses dias de folga concomitantemente aos períodos de menor demanda. No entanto, a partir de 2022, essa prática não se repete. Com a mudança no quadro de colaboradores e a inauguração da Autoescola B, houve uma implementação de gestão interna que priorizou o revezamento das férias dos instrutores. Assim, apesar de ainda haver uma redução na quantidade de aulas dadas nesses períodos específicos, a disponibilidade de instrutores manteve um fluxo mais constante de atividades.


10.2 APLICAÇÃO DOS MÉTODOS DE PREVISÃO

Após a análise descritiva das séries históricas semanais de aulas realizadas em cada categoria e unidade de autoescola, esta seção tem como objetivo aplicar e avaliar diferentes métodos de previsão de demanda com base em modelos quantitativos. Serão analisadas as categorias A, B e D da Autoescola A e as categorias A e B da Autoescola B, totalizando cinco séries distintas. A aplicação dos métodos foi organizada por técnica de previsão, permitindo uma comparação transversal entre as categorias dentro de cada modelo. Para cada método, serão apresentados os resultados gráficos e as respectivas métricas de erro estatístico: o Erro Quadrático Médio (EQM) e a Raiz do Erro Quadrático Médio (RMSE), possibilitando identificar o modelo com maior precisão para cada série.

10.2.1 Aplicação e análise do método de Média Móvel Simples

A seguir, apresenta-se a análise da aplicação da Média Móvel Simples, considerando diferentes horizontes de suavização (2, 3 e 4 períodos), como forma inicial de avaliação do desempenho preditivo em séries com comportamento sazonal e tendência.

Gráfico 6 - Média Móvel Simples - CAT A - Autoescola A




Fonte: Elaborado pelo autor (2025)

A série da “**Categoria A - Autoescola A**” apresenta comportamento relativamente regular, com picos visíveis de crescimento e posterior queda. O volume é menor do que o da categoria B, mas há um padrão cíclico aparente. O método de Média Móvel Simples captura bem os movimentos de curto prazo, mas há maior defasagem nos ciclos mais amplos.

Ao observar os resultados que encontram-se na tabela 1 que contém a tabela de erros, verifica-se que, para a demanda da **Categoria A na Autoescola A**, a Média Móvel Simples de 2 períodos apresenta os menores erros de previsão (EQM de 1404.25 e RMSE de 37.47) quando comparada às configurações de 3 e 4 períodos. Isso sugere que a demanda por aulas práticas desta categoria reage de forma mais pronunciada a variações recentes, e a inclusão de um histórico mais longo (3 ou 4 períodos) tende a diluir a influência dos dados mais atuais, resultando em previsões menos precisas. O aumento progressivo dos valores de EQM e RMSE à medida que o número

de períodos da média móvel é ampliado (de 2 para 3 e para 4) indica que o modelo de 2 períodos é o que melhor se adapta à volatilidade ou aos padrões de curto prazo presentes na série histórica da Categoria A.


Gráfico 7 - Média Móvel Simples - CAT B - Autoescola A



Fonte: Elaborado pelo autor (2025)

A série da “**Categoria B - Autoescola A**” é extensa, com grandes variações ao longo do tempo e picos agudos. O volume de aulas é alto, mas apresenta sazonalidade e períodos de estabilidade. O modelo de média móvel simples é limitado em acompanhar essas oscilações abruptas, com desempenho decrescente à medida que o número de períodos aumenta. Similar à Categoria A, na **Categoria B da Autoescola A**, o menor erro é obtido com a Média Móvel Simples de 2 períodos. Há um aumento consistente nos valores de EQM e RMSE à medida que o número de períodos da média móvel é ampliado. Os valores de erro são significativamente mais altos em comparação com a Categoria A, o que pode indicar uma maior variabilidade na demanda da Categoria B ou que a MMS, de forma geral, é menos eficaz para esta categoria. No entanto, dentro da MMS, 2 períodos é a melhor configuração.


Gráfico 8 - Média Móvel Simples - CAT D - Autoescola A



Fonte: Elaborado pelo autor (2025)

A série da “**Categoria D - Autoescola A**” é caracterizada por baixos volumes e crescimento mais lento. A volatilidade é menor, o que favorece a aplicação de métodos simples como a média móvel. Para a **Categoria D na Autoescola A**, o padrão se repete: a Média Móvel Simples de 2 períodos apresenta os menores erros. O aumento do número de períodos resulta em um aumento dos erros, embora a magnitude do aumento seja menor em comparação com a Categoria B. Os valores de erro para a Categoria D são os menores entre as categorias da Autoescola A, sugerindo que a demanda por aulas da Categoria D pode ser mais estável ou menos volátil, facilitando a previsão com a MMS.


Gráfico 9 - Média Móvel Simples - CAT A - Autoescola B



Fonte: Elaborado pelo autor (2025)

A série da “**Categoria A - Autoescola B**” demonstra padrão cíclico e tendência de crescimento com certa estabilidade. O método de média móvel acompanha bem o comportamento, com desempenho equilibrado entre os três modelos testados, embora com leve perda de precisão nos modelos com mais períodos. Similarmente à **Autoescola A**, para a **Categoria A na Autoescola B**, a Média Móvel Simples com 2 períodos também apresentou os menores valores de erro (EQM de 399.05 e RMSE de 19.98). O padrão de aumento dos erros com a elevação do número de períodos (3 e 4) é consistente, sugerindo que, também nesta autoescola, a demanda da Categoria A é melhor prevista com base em um histórico mais recente. Comparativamente, os erros para a Categoria A na Autoescola B são significativamente menores do que os observados na Autoescola A, indicando uma demanda potencialmente mais estável ou previsível para esta categoria na Autoescola B, ou uma maior adequação da MMS para esta série específica.

Gráfico 10 - Média Móvel Simples - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

A série da “**Categoria B - Autoescola B**” apresenta um comportamento mais robusto e volumoso, com variações semanais expressivas e tendência de crescimento. Todas as configurações do modelo apresentaram RMSE acima de 30, sendo o modelo de 2 períodos o mais adequado para respostas rápidas às variações. Na **Categoria B da Autoescola B**, a Média Móvel Simples de 2 períodos novamente demonstra ser a melhor opção, com os menores valores de EQM e RMSE. Os erros aumentam gradualmente com o aumento do número de períodos. Comparando com a Categoria B da Autoescola A, os erros são consideravelmente menores, o que sugere que a demanda por aulas da Categoria B na Autoescola B pode ter uma variabilidade menor ou um comportamento mais previsível que na Autoescola A.

Com base nos dados fornecidos para todas as categorias e autoescolas, algumas observações gerais sobre a aplicação da Média Móvel Simples podem ser feitas: Em todas as categorias analisadas, a Média Móvel Simples com 2 períodos consistentemente apresentou os menores erros (EQM e RMSE). Isso indica que, para os seus dados, a demanda é mais sensível a mudanças recentes, e a inclusão de dados mais antigos na média (maior número de períodos) tende a diluir a informação mais relevante e aumentar o erro de previsão.

Tabela 1 - Comparativo de EQM e RMSE dos períodos da MMS

Métrica	Períodos	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
EQM	2	1404,25	4735,42	156,28	399,05	926,87
RMSE		37,47	68,80	12,50	19,98	30,44
EQM	3	1504,10	5213,51	168,80	409,85	933,60
RMSE		38,80	72,20	13,00	20,20	30,60
EQM	4	1550,16	5757,56	175,10	422,42	953,64
RMSE		39,40	75,90	13,20	20,60	30,90

Fonte: Elaborada pelo autor (2025)

Ao comparar as cinco séries analisadas, observa-se que o modelo de Média Móvel com 2 períodos foi o mais eficaz em todas as categorias, apresentando os menores valores de RMSE. A Categoria D da Autoescola A se destacou com o menor erro geral (RMSE = 12,5), devido ao seu comportamento mais estável. Em contrapartida, as Categorias B de ambas as unidades apresentaram os maiores RMSEs, revelando a limitação desse modelo frente a séries mais volumosas e com maior volatilidade. Os resultados indicam que o modelo de Média Móvel Simples é útil para projeções de curto prazo, mas pode necessitar de ajustes ou substituições por métodos mais robustos quando aplicado a séries com grande variabilidade e crescimento irregular.

Portanto, os valores absolutos dos erros (especialmente para Categoria B - Autoescola A) indicam que a MMS, em geral, pode não ser o método mais preciso para todas as séries, e que a


comparação com os outros métodos (Média Móvel Ponderada, Suavização Exponencial, Holt, Holt-Winters Aditivo e Holt - Winters Multiplicativo) será crucial para identificar a melhor técnica de previsão para cada cenário.

10.2.2 Aplicação e Análise do Método de Média Móvel Ponderada

Após a avaliação do método de Média Móvel Simples (MMS), que demonstrou a importância da volatilidade de curto prazo nas séries de demanda, o presente capítulo avança para a análise da Média Móvel Ponderada (MMP). Para a determinação desses pesos, utilizou-se a ferramenta **Solver do Excel**, otimizando o modelo para as séries analisadas.

Dadas as conclusões obtidas na seção anterior, optou-se por aplicar a Média Móvel Ponderada com 2 períodos em todas as categorias de aulas práticas (A, B e D para Autoescola A; A e B para Autoescola B). O objetivo é verificar se a ponderação dos dados mais recentes pode resultar em uma redução dos erros de previsão, oferecendo um ajuste mais preciso às dinâmicas observadas e, conseqüentemente, uma ferramenta mais eficaz para a gestão da demanda em Centros de Formação de Condutores.


Gráfico 11 - Média Móvel Ponderada - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

No gráfico 11, podemos observar que a série histórica da **Categoria A na Autoescola A** demonstra crescimento progressivo até determinado ponto, seguido de oscilações semanais. A curva da MMP suaviza essas oscilações, acompanhando bem a tendência geral da série. Nota-se que nos períodos com picos ou quedas abruptas, a MMP tende a reagir com menos intensidade, o que é esperado dada sua natureza suavizadora. Para a **Categoria A na Autoescola A**, a Média Móvel Ponderada de 2 períodos, com pesos otimizados (82% para o dado mais recente e 18% para o mais antigo), apresentou um EQM de 1270,86 e um RMSE de 35,65. A atribuição de um peso significativamente maior às observações mais recentes demonstra a importância da informação de curto prazo para a precisão da previsão nesta série.


Gráfico 12 - Média Móvel Ponderada - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

Já no gráfico 12, podemos observar que a série histórica da **Categoria B na Autoescola A** apresenta maior volume de aulas e uma maior estabilidade ao longo do tempo. A MMP acompanha com precisão o comportamento da série, com pouca defasagem em relação aos dados reais. Em períodos de grande variação, a MMP mantém a fluidez e absorve bem as oscilações, demonstrando boa capacidade de previsão para essa categoria. Na **Categoria B da Autoescola A**, a Média Móvel Ponderada de 2 períodos, com pesos de 83% para o dado mais recente e 17% para o mais antigo, resultou em um EQM de 4266,13 e um RMSE de 65,32. Os valores de erro, embora presentes, refletem a complexidade e a alta variabilidade inerente a esta série, e a otimização dos pesos buscou mitigar essa volatilidade.


Gráfico 13 - Média Móvel Ponderada - CAT D - Autoescola A



Fonte: Elaborado pelo autor (2025)

O gráfico 13 da **Categoria D na Autoescola A** apresenta uma série com maior variabilidade e volume reduzido em alguns trechos, inclusive com períodos sem aulas. A MMP 2 períodos suaviza significativamente as flutuações e apresenta comportamento semelhante ao da série, mas tende a ser impactada nos momentos em que há ausência de dados (aulas zeradas). Ainda assim, consegue capturar tendências locais de crescimento e queda com relativa eficiência. Para a **Categoria D na Autoescola A**, a Média Móvel Ponderada de 2 períodos, com pesos de 73% para o dado mais recente e 27% para o mais antigo, obteve um EQM de 148,04 e um RMSE de 12,17. Estes são os menores erros absolutos entre todas as categorias analisadas com a MMP até o momento, o que indica que esta série possui um comportamento mais estável e previsível, sendo bem capturado pelo método com os pesos otimizados.


Gráfico 14 - Média Móvel Ponderada - CAT A - Autoescola B



Fonte: Elaborado pelo autor (2025)

No gráfico 14 mostra que a série da **Categoria A da Autoescola B** com padrão mais linear e menos oscilatório que a Autoescola A. A MMP acompanha fielmente os movimentos da série, reforçando a coerência da tendência geral da demanda semanal, com resposta rápida às alterações, mesmo nos momentos de baixa demanda. Na **Categoria A da Autoescola B**, a Média Móvel Ponderada de 2 períodos, utilizando pesos de 69% para o dado mais recente e 31% para o mais antigo, apresentou um EQM de 385,84 e um RMSE de 19,64. Os resultados indicam que o modelo conseguiu um bom ajuste para a demanda desta categoria, com erros controlados, e a ponderação auxiliou na captura das informações mais relevantes para a previsão.

Gráfico 15 - Média Móvel Ponderada - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

A série de dados da **Categoria B da Autoescola B** é a mais robusta em volume e estabilidade. A MMP se ajusta muito bem aos dados reais, sendo eficiente na representação da tendência e sazonalidade local. Pequenas defasagens são perceptíveis em picos de aumento ou queda, mas não comprometem a qualidade da suavização. Para a **Categoria B da Autoescola B**, a Média Móvel Ponderada de 2 períodos, com pesos de 67% para o dado mais recente e 33% para o mais antigo, resultou em um EQM de 902 e um RMSE de

30.03. A aplicação da ponderação contribuiu para um desempenho adequado, com erros que refletem a natureza da série, mas que são consistentes com a busca por maior precisão ao dar prioridade a dados mais recentes.

Tabela 2 - Comparativo de EQM e RMSE das autoescolas e pesos da MMP

Métrica	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
Peso Mais Recente (%)	82	83	73	69	67
Peso Mais Antigo (%)	18	17	27	31	33
EQM	1270,86	4266,13	148,04	385,84	902,00
RMSE	35,65	65,32	12,17	19,64	30,03

Fonte: Elaborada pelo autor (2025)


A análise da Média Móvel Ponderada (MMP), com a otimização dos pesos realizada via Solver do Excel, demonstrou ser uma abordagem flexível e eficaz na previsão da demanda. Para todas as categorias analisadas, a capacidade de atribuir pesos diferenciados às observações históricas, dando maior relevância aos dados mais recentes, reflete a adequação do método em capturar as dinâmicas de curto prazo de cada série. A variação nos pesos otimizados entre as categorias (de 67% a 83% para o dado mais recente) ressalta que o comportamento da demanda é único para cada tipo de aula e autoescola, e a MMP permite essa personalização para aprimorar a precisão das estimativas. Este método se configura como uma ferramenta robusta para as séries em questão, especialmente ao considerar a influência mais imediata dos dados passados.

10.2.3 Aplicação e análise do método de Suavização Exponencial Simples

Após a aplicação dos métodos de Média Móvel Simples (MMS) e Média Móvel Ponderada (MMP), este capítulo avança para a análise da Suavização Exponencial Simples (SES). Para a aplicação da SES, foi utilizada a ferramenta de otimização do **Excel (Solver)** a fim de determinar o valor de α (alfa) que minimizasse o erro médio quadrático (EQM) para cada série.

Considerando a estrutura das séries temporais analisadas, a Suavização Exponencial foi aplicada a todas as categorias de aulas práticas: A, B e D para a Autoescola A, e A e B para a Autoescola B. O objetivo é avaliar a capacidade deste método em capturar flutuações e tendências de curto prazo, contribuindo para previsões mais precisas e, por consequência, um planejamento operacional mais eficiente nos Centros de Formação de Condutores.


Gráfico 16 - Suavização Exponencial Simples - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

Observa-se no gráfico 16 uma forte aderência da linha da SES à série real da **Categoria A da Autoescola A**, com capacidade de reagir rapidamente às mudanças de padrão, sem comprometer a suavidade. A presença de oscilações abruptas é atenuada pelo modelo, mas sem perder o traçado geral da evolução da demanda. Para a **Categoria A na Autoescola A**, o Método de Suavização Exponencial Simples com um α de 0,68 obteve um EQM de 1240,17 e um RMSE de 35,22. O valor de α relativamente alto indica que o modelo atribuiu uma grande importância aos dados mais recentes da série para a formação da previsão, sugerindo que a demanda desta categoria é bastante influenciada pelas observações mais recentes.


Gráfico 17 - Suavização Exponencial Simples - CAT B - Autoescola A



Fonte: Elaborado pelo autor (2025)

Devido ao maior volume e à relativa estabilidade da série **Categoria B da Autoescola A**, de acordo com o gráfico 17 a SES mostrou desempenho robusto, ajustando-se de forma eficiente à tendência central. Embora picos agudos não sejam completamente capturados, o modelo consegue representar fielmente os padrões médios da série. Na **Categoria B da Autoescola A**, a Suavização Exponencial Simples, utilizando um α de 0,77, resultou em um EQM de 4215,95 e um RMSE de 64,93. O alto valor de α reforça a sensibilidade do modelo aos dados mais recentes, o que é frequentemente necessário para séries com maior volatilidade, buscando acompanhar suas oscilações de forma mais ágil. Os erros ainda são significativos, refletindo a complexidade da série.


Gráfico 18 - Suavização Exponencial Simples - CAT D - Autoescola A



Fonte: Elaborado pelo autor (2025)

A **Categoria D da Autoescola A**, por apresentar menor volume e alta variabilidade, no gráfico 18 exigiu maior sensibilidade do modelo. A SES, nesse caso, acompanhou bem o comportamento geral da série, ainda que com pequenas defasagens nas viradas mais bruscas. Para a **Categoria D na Autoescola A**, o SES com um α de 0,60 apresentou um EQM de 143,54 e um RMSE de 11,98. Este é o menor RMSE absoluto obtido até agora para as categorias da Autoescola A, indicando que a demanda da Categoria D é relativamente estável e bem previsível com este método, mesmo com um α um pouco mais moderado, que ainda dá boa consideração ao histórico recente.


Gráfico 19 - Suavização Exponencial Simples - CAT A - Autoescola B



Fonte: Elaborado pelo autor (2025)

O modelo foi eficaz em suavizar os altos e baixos frequentes da série da **Categoria A da Autoescola B** de acordo com o gráfico 19, mantendo proximidade com os valores reais. A SES demonstrou boa capacidade de previsão em períodos de estabilidade, ainda que algumas variações rápidas não tenham sido plenamente captadas. Na **Categoria A da Autoescola B**, o Método de Suavização Exponencial Simples, com α de 0,34, obteve um EQM de 348,29 e um RMSE de 18,66. O baixo valor de α indica que a previsão é pouco responsiva às flutuações recentes da demanda. É importante notar que os erros para esta categoria na Autoescola B são maiores com o SES em comparação com os erros obtidos pela Média Móvel Ponderada (RMSE de 19.6).

Gráfico 20 - Suavização Exponencial Simples - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

Apesar da maior amplitude da série da **Categoria B da Autoescola B**, a SES apresentou no gráfico 20 desempenho satisfatório, com bom alinhamento às oscilações principais da demanda. Em momentos de quedas abruptas, como ao final da série, o modelo demonstrou alguma defasagem, mas sem comprometer a tendência geral. **Para a Categoria B da Autoescola B**, o SES com um α de 0,30 resultou em um EQM de 806,57 e um RMSE de 28,40. O valor de α significativamente mais baixo do que nas outras categorias sugere que, para esta série em particular, o modelo se beneficia de uma maior suavização, dando mais peso à média histórica geral do que às flutuações mais recentes. Isso pode indicar uma série com menos irregularidades de curto prazo ou uma tendência que se beneficia de uma visão mais ampla.

Tabela 3 - Comparativo de EQM e RMSE das autoescolas e pesos da SES

Métrica	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
Alfa (α)	0,68	0,77	0,60	0,34	0,30
EQM	1240,17	4215,95	143,54	348,29	806,57
RMSE	35,22	64,93	11,98	18,66	28,40

Fonte: Elaborada pelo autor (2025)

A aplicação do Método de Suavização Exponencial Simples (SES) com α otimizado revelou que a sensibilidade aos dados mais recentes (com α s predominantemente altos) é uma característica comum para a previsão da demanda das aulas práticas, exceto para a **Categoria B da Autoescola B**, onde um α menor indicou a necessidade de maior suavização. Os resultados de EQM e RMSE fornecem uma base para avaliar a precisão do SES para cada categoria, mostrando que, para algumas séries (como **Categoria D - Autoescola A**), o método alcança um desempenho notável. A performance geral do SES agora poderá ser comparada com os métodos de Média Móvel Simples e Ponderada para identificar o modelo mais adequado para cada cenário.


10.2.4 Aplicação e análise do método de Holt

Após a aplicação da Suavização Exponencial Simples (SES), que se mostrou eficaz para acompanhar séries com relativa estabilidade ou sem tendência evidente, este capítulo avança para a aplicação do método de Holt, também conhecido como suavização exponencial dupla.

Dadas as conclusões extraídas na etapa anterior, o método de Holt foi aplicado às cinco categorias de aulas práticas (Categorias A, B e D da Autoescola A; Categorias A e B da Autoescola B), mantendo a estrutura metodológica anterior e realizando o ajuste fino dos parâmetros α e β por meio do recurso **Solver do Excel**, com o intuito de minimizar os erros de previsão. O objetivo central desta etapa é verificar se a incorporação da tendência por meio da suavização dupla contribui para a redução do erro quadrático médio e proporciona um modelo mais responsivo às

variações estruturais nas séries de demanda. Dessa forma, pretende-se avaliar se o modelo de Holt oferece ganhos significativos de precisão e utilidade para a tomada de decisão nos Centros de Formação de Condutores analisados.


Gráfico 21 - Método Holt - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

Para a **Categoria A na Autoescola A**, com uma tendência igual a 0, o Método de Holt (operando como SES neste caso) com α de 0,68 resultou em um EQM de 1240,17 e um RMSE de 35,22. O α relativamente alto sugere que o modelo se ajusta bem às informações mais recentes para determinar o nível da série.


Gráfico 22 - Método Holt - CAT B - Autoescola A



Fonte: Elaborado pelo autor (2025)

Na **Categoria B da Autoescola A**, também sem tendência, o Método de Holt com α de 0,77 obteve um EQM de 4215,95 e um RMSE de 64,93. O elevado valor de α indica que a previsão é bastante reativa aos últimos dados observados, capturando bem as mudanças no nível da série, mesmo sem um componente de tendência ativo.


Gráfico 23 - Método Holt - CAT D - Autoescola A



Fonte: Elaborado pelo autor (2025)

Para a **Categoria D na Autoescola A**, com tendência nula, o Método de Holt com α de 0,60 apresentou um EQM de 143,54 e um RMSE de 11,98. Este é um dos menores erros, indicando que a demanda desta categoria é bastante estável e bem previsível pelo método, com um α que equilibra a sensibilidade aos dados recentes e a suavização do histórico.


Gráfico 24 - Método Holt - CAT A - Autoescola B



Fonte: Elaborado pelo autor (2025)

Na **Categoria A da Autoescola B**, também sem tendência, o Método de Holt com α de 0,34 resultou em um EQM de 351,01 e um RMSE de 18,74. O α moderado sugere uma boa adaptação do nível da previsão às variações mais recentes, sendo eficaz para uma série que não demonstra um movimento direcional claro.

Gráfico 25 - Método Holt - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

Para a **Categoria B da Autoescola B**, com tendência nula, o Método de Holt com α de 0,30 obteve um EQM de 806,57 e um RMSE de 28,40. O α mais baixo em comparação com as outras séries indica que, para esta série em particular, o modelo se beneficia de uma maior suavização do nível, dando mais peso à média histórica geral e menos às flutuações de curto prazo.

Tabela 4 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt

Métrica	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
Alfa (α) - Nível	0,68	0,77	0,60	0,71	0,30
Beta (β) - Tendência	0,00	0,00	0,00	0,00	0,00
EQM	1240,17	4215,95	143,54	351,01	806,57
RMSE	35,22	64,93	11,98	18,74	28,47

Fonte: Elaborada pelo autor (2025)


A aplicação do Método de Holt com a condição de tendência zero resulta, na prática, em um comportamento semelhante ao da Suavização Exponencial Simples (SES). Isso sugere que, para as séries analisadas, o componente de tendência linear pode não ser proeminente ou foi otimizado para ser insignificante pelo modelo. Os valores de α continuam sendo cruciais para a forma como o nível da série é suavizado, influenciando diretamente a precisão da previsão medida por EQM e RMSE.

10.2.5 Aplicação e Análise do Método De Holt-Winters Aditivo

Dando continuidade às análises de previsão de demanda, este capítulo apresenta a aplicação do método de Holt-Winters Aditivo, sobre as séries históricas de aulas práticas nas categorias A, B e D da Autoescola A e nas categorias A e B da Autoescola B. Essa abordagem visa incorporar ao modelo a componente sazonal e de tendência, permitindo que o modelo ajuste automaticamente os parâmetros para otimizar a previsão. As análises anteriores, especialmente a aplicação do método de Holt, serviram como base para a inclusão da tendência nos modelos de Holt-Winters para verificar se essa combinação proporciona uma melhoria no desempenho da previsão. A modelagem foi realizada por meio do Excel, com uso da ferramenta Solver para calibragem dos

parâmetros de suavização (*alpha* e *beta*), buscando a minimização do Erro Quadrático Médio (EQM). Para essa aplicação, adotou-se como base um fator sazonal de 4 semanas, considerando que a soma de 4 semanas equivale aproximadamente a um mês, unidade de tempo relevante na gestão operacional de Centros de Formação de Condutores. A aplicação uniforme do modelo nas cinco categorias tem por objetivo verificar o desempenho da suavização sazonal na previsão de curto prazo da demanda, especialmente em períodos com oscilações regulares. Ao final da análise individual de cada categoria, será realizada uma comparação entre os resultados obtidos, permitindo identificar quais séries se beneficiaram mais da incorporação da sazonalidade, e em que medida o modelo contribui para uma previsão mais estável e aderente à realidade operacional dos Centros de Formação de Condutores.


Gráfico 26 - Método Holt - Winter Aditivo - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

Apesar da elevada volatilidade na série de dados da **Categoria A da Autoescola A**, o modelo Holt-Winters Aditivo apresentou desempenho consistente, acompanhando bem as variações sazonais ao longo do tempo. Houve boa aderência às oscilações principais, especialmente nas fases de estabilidade e tendência decrescente. Pequenas defasagens foram observadas em pontos de transição brusca, mas sem comprometer a qualidade da previsão. Para a **Categoria A na Autoescola A**, o modelo Holt-Winters Aditivo (sem tendência) apresentou um EQM de 1233,99 e um RMSE de 35,13. O α de 0,68 indica uma forte ponderação nos dados mais recentes para estimar o nível. O valor de β igual a 0,00 para o fator sazonal é um achado interessante; sugere que, ou não há um componente sazonal significativo a ser capturado por este modelo, ou a otimização não encontrou um valor para o β que melhorasse a previsão, o que pode indicar a ausência de um padrão sazonal aditivo claro para esta série específica, ou que a média da série já captura a maior parte da informação.


Gráfico 27 - Método Holt - Winter Aditivo - CAT B - Autoescola A



Fonte: Elaborado pelo autor (2025)

A série da **Categoria B da Autoescola A** apresentou forte sazonalidade e picos acentuados, o que pode representar desafio para modelos de previsão. Ainda assim, o Holt-Winters Aditivo demonstrou boa capacidade de ajuste, com alinhamento satisfatório à tendência geral da série. O modelo foi ligeiramente conservador na resposta a variações extremas, o que é esperado em modelos suavizadores, mas capturou bem o comportamento cíclico da demanda. Na **Categoria B da Autoescola A**, o modelo resultou em um EQM de 4597,78 e um RMSE de 67,81. O α de 0,70 mostra que o nível é bastante responsivo aos dados recentes. O β de 0,24 para o fator sazonal indica que o modelo está suavizando o componente sazonal, dando um peso moderado às novas observações sazonais. Os erros permanecem elevados, sugerindo que a série ainda possui uma variabilidade considerável ou outros fatores não capturados pelo modelo.


Gráfico 28 - Método Holt - Winter Aditivo - CAT D - Autoescola A



Fonte: Elaborado pelo autor (2025)

Apesar da menor magnitude dos valores observados na **Categoria D da Autoescola A**, o modelo conseguiu captar com precisão o padrão de sazonalidade presente na série. As previsões acompanharam adequadamente os picos e vales recorrentes, mantendo coerência com a variação real dos dados. O desempenho gráfico do Holt-Winters Aditivo, nesse caso, foi bastante satisfatório. Para a **Categoria D na Autoescola A**, o Holt-Winters Aditivo sem tendência obteve um EQM de 144,41 e um RMSE de 12,02. O α de 0,60 sugere um bom equilíbrio na suavização do nível. O β de 0,02 para o fator sazonal é um valor muito baixo, próximo a zero, indicando que o modelo atribui pouquíssimo peso às novas observações sazonais para atualizar o componente sazonal. Isso pode significar que o componente sazonal é muito estável ou quase inexistente para esta categoria com este modelo.


Gráfico 29 - Método Holt - Winter Aditivo - CAT A - Autoescola B



Fonte: Elaborado pelo autor (2025)

A série da **Categoria A da Autoescola B** demonstrou crescimento gradual seguido de estabilização, com oscilações mais suaves. O modelo Holt-Winters Aditivo acompanhou essa evolução com previsões que mantiveram boa proximidade com a linha real. Em momentos de maior dispersão, observou-se certa suavização excessiva, mas sem perdas significativas na representação da tendência principal. Na **Categoria A da Autoescola B**, o modelo resultou em um EQM de 363,98 e um RMSE de 19,08. O α de 0,33 é relativamente baixo, indicando que o modelo atribui mais peso à média histórica para suavizar o nível, tornando a previsão mais estável. O β de 0,01 para o fator sazonal é muito baixo, semelhante ao da Categoria D, o que sugere que o componente sazonal aditivo é mínimo ou quase inalterado por novas informações.

Gráfico 30 - Método Holt - Winter Aditivo - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

Apesar da maior amplitude da série da **Categoria B da Autoescola B**, o modelo Holt-Winters Aditivo apresentou desempenho satisfatório, com bom alinhamento às oscilações principais da demanda. Em momentos de quedas abruptas, como ao final da série, o modelo demonstrou alguma defasagem, mas sem comprometer a tendência geral. Para a **Categoria B da Autoescola B**, o Holt-Winters Aditivo sem tendência apresentou um EQM de 881,86 e um RMSE de 29,70. O α de 0,25, o mais baixo entre as categorias, indica uma forte suavização do nível, com grande peso para a média histórica. O β de 0,07 para o fator sazonal também é baixo, sugerindo que a contribuição da nova informação sazonal para o componente é pequena, talvez refletindo uma sazonalidade menos acentuada ou mais estável.

Tabela 5 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt-Winters

Aditivo					
Métrica	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
Alfa (α)	0,68	0,70	0,60	0,33	0,25
Beta (β) - Fator Sazonal	0,00	0,24	0,02	0,01	0,07
EQM	1233,99	4597,78	144,41	363,98	881,86
RMSE	35,13	67,81	12,02	19,08	29,70

Fonte: Elaborada pelo autor (2025)

A aplicação do Método de Holt-Winters Aditivo, configurado para desconsiderar a tendência e focar no nível e na sazonalidade, demonstrou capacidades variadas de previsão entre as categorias. Os valores de α (nível) variam, indicando diferentes graus de responsividade aos dados recentes. O baixo valor, e em um caso, nulo, do parâmetro β (fator sazonal) para diversas séries levanta a questão da força ou da forma aditiva da sazonalidade nessas categorias, ou se o modelo encontrou pouca necessidade de atualizar ativamente o componente sazonal a partir de novas observações. Os resultados de EQM e RMSE fornecerão a base para a comparação final do desempenho deste método com os anteriores.


10.2.6 Aplicação e Análise do Método De Holt-Winters Multiplicativo

Com base nas análises anteriores, que abordaram métodos com e sem tendência (como Holt) e com sazonalidade aditiva (como Holt-Winters Aditivo), este capítulo dedica-se à aplicação do modelo de Holt-Winters Multiplicativo, o qual também considera um componente de tendência para otimizar a precisão da previsão.. Esse modelo é particularmente indicado para séries temporais que apresentam sazonalidade proporcional à tendência, ou seja, quando as variações sazonais aumentam ou diminuem em escala com o nível da série. A aplicação foi conduzida sobre as cinco

categorias analisadas (Categorias A, B e D da Autoescola A; Categorias A e B da Autoescola B), com o objetivo de verificar se a combinação simultânea de tendência e sazonalidade multiplicativa proporciona ganhos de acurácia nas previsões, sobretudo em séries com comportamento oscilante e crescimento progressivo. O procedimento de modelagem foi realizado por meio do Microsoft Excel, utilizando a ferramenta **Solver** para otimização dos parâmetros de suavização (*alpha*, *beta* e *gamma*), ajustados de forma a minimizar o Erro Quadrático Médio (EQM). Para o componente sazonal, foi mantido o fator de periodicidade de 4 semanas, equivalente a um mês de operação, garantindo coerência com as análises anteriores.

Assim como nos modelos anteriores, ao final da aplicação individual em cada categoria será realizada uma análise comparativa entre as séries, a fim de identificar padrões de desempenho, variações nos erros e a aderência do modelo Holt-Winters Multiplicativo à realidade de cada unidade e categoria. A expectativa é que este modelo proporcione um ajuste mais sensível às séries com padrões sazonais em escala, oferecendo uma ferramenta robusta para previsão e planejamento operacional nos Centros de Formação de Condutores.


Gráfico 31 - Método Holt - Winter Multiplicativo - CAT A - Autoescola A



Fonte: Elaborado pelo autor (2025)

No gráfico 31, observa-se que a série da **Categoria A da Autoescola A** apresenta picos significativos ao longo do tempo, com oscilações relativamente acentuadas. O modelo Holt-Winter Multiplicativo conseguiu captar a tendência crescente no início da série, bem como os ciclos sazonais que marcam o comportamento da demanda. Em momentos de alta volatilidade, nota-se alguma defasagem entre os valores previstos e os valores reais, principalmente nos picos mais agudos. Apesar disso, o modelo manteve boa aderência à trajetória geral da série, fornecendo previsões coerentes com o padrão histórico. Para a **Categoria A na Autoescola A**, o modelo Holt-Winters Multiplicativo apresentou um EQM de 1527,3 e um RMSE de 39,08. O valor de α de 0,172, relativamente baixo, indica que o modelo confere maior peso aos dados históricos mais antigos para suavizar o nível da série, resultando em uma previsão mais estável e menos responsiva a flutuações recentes. O β de 0,00 para a tendência confirma que, para esta série, o componente de tendência não foi considerado ativo. O γ de 0,098 (baixo) sugere que o componente sazonal multiplicativo é suavizado de forma conservadora, indicando uma sazonalidade relativamente estável ou de menor impacto proporcional.


Gráfico 32 - Método Holt - Winter Multiplicativo - CAT B - Autoescola A



Fonte: Elaborado pelo autor (2025)

O gráfico 32 revela uma série com alta variabilidade e muitos picos abruptos, o que representa um desafio para os modelos de suavização. Ainda assim, o método Holt-Winter Multiplicativo mostrou desempenho consistente ao captar a tendência geral da série. Os períodos de sazonalidade foram bem representados na curva de previsão, embora a magnitude das variações reais tenha superado a sensibilidade do modelo em diversos momentos. A defasagem é mais visível nos momentos de queda súbita. Mesmo com essas limitações, o modelo conseguiu manter uma linha de previsão que acompanha razoavelmente o padrão da série. Na **Categoria B da Autoescola A**, o modelo obteve um EQM de 5909,5 e um RMSE de 76,87. Com um α muito baixo (0,087) e β de 0,000, a previsão do nível é altamente suavizada e a tendência é desconsiderada. O γ de 0,182 para a sazonalidade, embora ainda baixo, é maior do que na Categoria A, indicando que o modelo atribui um pouco mais de peso às observações sazonais recentes para atualizar o fator sazonal. Os erros elevados sugerem que, mesmo com a modelagem sazonal, a série pode ter alta variabilidade ou outros padrões não capturados.

Gráfico 33 - Método Holt - Winter Multiplicativo - CAT D - Autoescola A




Fonte: Elaborado pelo autor (2025)

A série da **Categoria D** no gráfico 33 se destaca por apresentar grande irregularidade e várias interrupções nos dados realizados, refletindo uma forte sazonalidade e comportamentos instáveis. O modelo Holt-Winter Multiplicativo conseguiu suavizar essa instabilidade, representando uma tendência crescente com variações sazonais. Apesar das falhas frequentes na série observada, a linha de previsão demonstrou resiliência, conseguindo seguir a direção geral da série sem ser excessivamente afetada pelos ruídos. Isso demonstra a robustez do modelo diante de séries com baixa regularidade. Para a **Categoria D na Autoescola A**, os parâmetros apresentaram um comportamento peculiar. Um α de 0,00 significa que o nível da série não é atualizado por novas observações, permanecendo fixo em seu valor inicial (ou baseado em uma estimativa inicial). Contraditoriamente à instrução de desconsiderar a tendência, o β de 1 indica que a tendência é totalmente influenciada pela observação mais recente, o que é altamente reativo e pode gerar previsões instáveis se a tendência for volátil. O γ de 0,149 (moderado) permite alguma atualização do componente sazonal. Os erros de EQM (233,6) e RMSE (15,28) são um pouco maiores do que os obtidos com métodos mais simples para esta categoria (como SES). Isso

pode indicar que a complexidade de um modelo com tendência (mesmo que com $\beta=1$) e sazonalidade não se ajustou tão bem quanto esperado, ou que a série não se beneficia de uma modelagem de tendência tão agressiva.

Gráfico 34 - Método Holt - Winter Multiplicativo - CAT A - Autoescola B




Fonte: Elaborado pelo autor (2025)

No gráfico 34, a série da **Categoria A da Autoescola B** apresenta comportamento mais suave em comparação com as anteriores, com oscilações moderadas e tendência crescente até cerca da metade da série. O modelo Holt-Winter Multiplicativo teve desempenho satisfatório, com bom alinhamento entre os dados observados e previstos. Embora pequenas defasagens apareçam nos extremos da série, o modelo conseguiu captar bem os movimentos cíclicos e a tendência geral, oferecendo previsões consistentes e bem ajustadas ao histórico da demanda. Na **Categoria A da Autoescola B**, o modelo obteve um EQM de 355,9 e um RMSE de 18,87. O α de 0,242 sugere uma suavização moderada do nível. O β de 0,033, embora pequeno e contraditório à instrução de desconsiderar a tendência, indica que um componente de tendência foi, de fato, ajustado, mas de forma muito suavizada. O γ de 0,087, semelhante a outras categorias, mostra

uma suavização conservadora do componente sazonal. Os erros são relativamente baixos, sugerindo uma boa performance do modelo para esta série.

Gráfico 35 - Método Holt - Winter Multiplicativo - CAT B - Autoescola B



Fonte: Elaborado pelo autor (2025)

O gráfico 35 revela uma série com maior amplitude e picos mais pronunciados. O modelo Holt-Winter Multiplicativo apresentou desempenho satisfatório, ajustando-se bem às oscilações principais da demanda. Nos pontos de maior queda, como ao final da série, há uma defasagem perceptível, mas o comportamento da previsão permanece alinhado à tendência estrutural. Esse resultado indica que o modelo é eficiente para séries com flutuações mais intensas, desde que mantenham um padrão sazonal consistente. A aderência geral da previsão reforça a utilidade do modelo para apoio em decisões operacionais e estratégicas. Para a **Categoria B da Autoescola B**, o Holt-Winters Multiplicativo apresentou um EQM de 810,80 e um RMSE de 28,47. Com α de 0,254, o nível é moderadamente suavizado. O β de 0,00 confirma que a tendência foi desconsiderada para esta série. O γ de 0,039 é um valor muito baixo, indicando uma suavização

extrema do componente sazonal. Isso pode significar que o modelo atribuiu pouquíssimo peso a novas observações sazonais, sugerindo uma sazonalidade muito estável ou de pouca relevância proporcional para a previsão.

Tabela 6 - Comparativo de EQM e RMSE das autoescolas e pesos do Método Holt-Winters

Multiplicativo					
Métrica	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
Alfa (α) - Nível	0,17	0,08	0,00	0,24	0,25
Beta (β) - Fator Tendência	0,00	0,00	1,00	0,03	0,00
Gama (γ) - Sazonalidade e	0,09	0,18	0,14	0,08	0,03
EQM	1527,30	5909,50	233,60	355,90	810,80
RMSE	39,08	76,87	15,28	18,87	28,47

Fonte: Elaborada pelo autor (2025)

A aplicação do Método de Holt-Winters Multiplicativo revela uma complexidade nos resultados dos parâmetros. Enquanto para algumas séries (α s mais baixos), o modelo tende a uma maior suavização do nível, a presença de valores de β (tendência) diferentes de zero para algumas categorias, apesar da instrução de desconsiderá-la, indica que a otimização pode ter identificado uma leve influência de tendência ou que o modelo foi configurado para testar essa possibilidade. O γ (sazonalidade) geralmente baixo sugere que o componente sazonal multiplicativo é tratado de forma conservadora. A performance geral, medida por EQM e RMSE, deve ser comparada cuidadosamente com os métodos anteriores para determinar o modelo mais robusto para cada cenário de demanda.

10.3 ANÁLISE COMPARATIVA ENTRE OS MÉTODOS

A “Tabela 7 - Comparativa dos valores de Raiz do Erro Quadrático Médio (RMSE)” para cada um dos métodos de previsão aplicados (Média Móvel Simples - MMS, Média Móvel Ponderada - MMP, Suavização Exponencial Simples - SES, Método de Holt, Holt-Winters Aditivo

sem tendência e Holt-Winters Multiplicativo) nas diferentes categorias de aulas práticas para as autoescolas A e B. A análise desses resultados permite identificar o desempenho relativo de cada modelo e, conseqüentemente, determinar a abordagem mais eficaz para a previsão da demanda em cada cenário.

Tabela 7 - Comparativo de RMSE dos Métodos de Previsão

Método	Cat. A – Aut. A	Cat. B – Aut. A	Cat. D – Aut. A	Cat. A – Aut. B	Cat. B – Aut. B
MMS	37,47	68,80	12,50	19,98	30,44
MMP	35,65	65,32	12,17	19,64	30,03
SES	35,22	64,93	11,98	18,66	28,40
HOLT	35,22	64,93	11,98	18,74	28,51
HW ADITIVO (S/TENDÊNCIA)	35,13	67,81	12,02	19,08	29,70
HW MULTIPLICATIVO	39,08	76,87	15,28	18,87	28,47

Fonte: Elaborada pelo autor (2025)

Observa-se que, para a **Categoria A na Autoescola A**, o método Holt-Winters Aditivo (sem tendência) demonstrou o menor RMSE (35,13). Contudo, o SES e o Método de Holt apresentaram resultados muito próximos (35,22). A performance superior desses modelos mais diretos sugere que a demanda para esta categoria é mais estável e que a inclusão de um componente sazonal aditivo, mesmo que de forma simples, contribui ligeiramente para a acurácia, enquanto a complexidade de modelagem de tendência ou sazonalidade multiplicativa não se mostrou vantajosa.

Na **Categoria B na Autoescola A**, o SES e o Método de Holt obtiveram o menor RMSE (64,93). Esse resultado indica que, apesar da variabilidade inerente à série, esses modelos foram os mais eficientes em capturar os padrões subjacentes. A ausência de um benefício significativo dos modelos Holt-Winters (aditivo ou multiplicativo) em termos de redução do erro aponta para a não

predominância de uma sazonalidade complexa ou para a suficiência da suavização do nível e de uma tendência nula (no caso de Holt) para a previsão.

Para a **Categoria D na Autoescola A**, o SES e o Método de Holt novamente se destacaram com o menor RMSE (11,98). Este é um erro particularmente baixo, refletindo uma demanda bastante consistente e previsível. A simplicidade desses modelos provou ser a mais eficaz, evidenciando que a adição de parâmetros para tendência ou sazonalidade não é apenas desnecessária, mas pode até introduzir ruído, como visto no RMSE maior do Holt-Winters Multiplicativo (15,28).

Conjuntamente às categorias da **Autoescola A**, para a **Categoria A na Autoescola B**, o SES apresentou o menor RMSE (18,66), sendo o mais preciso. O Holt (18,74) e o Holt-Winters (18,87) também performaram muito bem. A simplicidade desses modelos provou ser a mais eficaz, evidenciando que a adição de parâmetros para tendência ou sazonalidade não é apenas desnecessária, mas pode até introduzir ruído, como visto no RMSE maior do Holt-Winters Multiplicativo.

Na **Categoria B da Autoescola B**, o SES foi o método com o menor RMSE (28,40), seguido de perto pelo Holt-Winters Multiplicativo (28,47) e pelo Método de Holt (28,51). A eficácia do SES novamente reforça a ideia de que, para esta série, um modelo que foca na suavização do nível é suficiente. A proximidade dos resultados do Holt-Winters Multiplicativo também merece destaque, indicando uma potencial adequação desse modelo em cenários onde a sazonalidade multiplicativa pode ter alguma influência.

A análise da tabela 7 revela que não existe um único método de previsão universalmente superior para todas as categorias de demanda. A Suavização Exponencial Simples (SES) e o Método de Holt destacam-se como os mais robustos e precisos na maioria dos cenários da **Autoescola A**, e também para a **Categoria B da Autoescola B**, o que sublinha a eficácia de modelos que priorizam a suavização do nível em séries com tendência nula ou pouca complexidade. Para a **Categoria A da Autoescola B**, o Método de Holt e o Holt-Winters Multiplicativo foram os mais acurados, sugerindo que, para esta série, a modelagem de padrões pode demandar abordagens ligeiramente mais sofisticadas ou uma sensibilidade particular desses modelos. Essa variabilidade reforça a importância de testar múltiplos métodos para identificar a melhor ferramenta preditiva para cada contexto específico de demanda.

11 DISCUSSÃO DOS RESULTADOS

A análise comparativa dos diversos modelos de previsão de séries temporais aplicados à demanda por aulas práticas nas categorias A, B e D das autoescolas A e B revelou padrões de desempenho distintos, mas com algumas tendências claras. Conforme detalhado na Tabela 7 - Comparativo de RMSE dos Métodos de Previsão, a acurácia dos modelos variou significativamente entre as diferentes categorias de demanda, evidenciando que não existe um modelo universalmente superior.

De forma geral, observou-se que os métodos de Suavização Exponencial Simples (SES) e o Método de Holt foram os que consistentemente apresentaram os menores erros de previsão (RMSE) na maioria dos cenários estudados. Especificamente para as categorias da Autoescola A (A, B e D), esses modelos, ou em conjunto com o Holt-Winters Aditivo (sem tendência) para a **Categoria A da Autoescola A**, demonstraram uma notável capacidade de se ajustar aos padrões de demanda. Isso sugere que, para essas séries, a demanda é predominantemente influenciada por um nível suavizado, com pouca ou nenhuma evidência de tendência linear significativa ou de uma sazonalidade multiplicativa complexa que justificasse a aplicação de modelos mais elaborados.

A diversidade nos métodos de melhor desempenho reforça a importância da etapa de comparação de modelos. O processo permitiu identificar, para cada categoria de aula prática, o método mais adequado, resultando em previsões com menor erro e, conseqüentemente, com maior confiabilidade para o planejamento e a gestão das operações das autoescolas. A seguir, será aprofundada a discussão desses resultados, categoria por categoria, com suas respectivas implicações práticas.

Durante o processo de aplicação e comparação dos modelos de previsão, alguns resultados se destacaram por apresentarem características menos usuais ou por contrariarem expectativas iniciais, merecendo uma análise mais aprofundada.

Um dos pontos mais notáveis ocorreu na aplicação do Método Holt-Winters Multiplicativo para a **Autoescola A, Categoria D**. Para esta série, os parâmetros ótimos encontrados pelo modelo apresentaram um alfa (α) de 0,00 e um beta (β) de 1,00. Um α igual a zero implica que o componente de nível da série não é atualizado por novas observações, permanecendo fixo em seu

valor inicial. Concomitantemente, um β igual a 1,00 significa que o componente de tendência é excessivamente reativo às mudanças mais recentes, sendo totalmente determinado pela última observação. Tal combinação de parâmetros é altamente incomum em modelos de suavização exponencial, sugerindo que o algoritmo de otimização encontrou um cenário onde essa configuração, apesar de agressiva, minimizava o erro de forma matemática, ainda que o resultado final (RMSE de 15,28) tenha sido inferior ao dos modelos SES e Holt (RMSE de 11,98). Essa performance inferior, apesar dos parâmetros extremos, ressalta que uma modelagem de complexidade desnecessária ou excessivamente reativa pode prejudicar a acurácia.

Adicionalmente, observou-se que o Método Holt-Winters Multiplicativo, embora robusto para séries com sazonalidade de amplitude crescente, consistentemente apresentou RMSEs mais elevados em comparação com modelos mais simples, como SES e Holt, para a maioria das categorias da **Autoescola A (Categorias A, B e D)**. Embora tenha sido desconsiderada a tendência, a otimização em alguns casos (ex: Autoescola B - Categoria A com $\beta=0,033$) indicou a relevância de um fator de tendência, por menor que fosse, refletindo a adaptação do modelo aos dados. No entanto, a superioridade dos modelos mais simples para estas séries específicas sugere que a demanda não exibe uma sazonalidade de natureza multiplicativa que justifique a complexidade adicional desse método, ou que a variabilidade não sazonal foi mais dominante. Esse achado corrobora a premissa de que a simplicidade do modelo, quando adequada à complexidade intrínseca da série, é frequentemente preferível.

Para a **Categoria A da Autoescola A**, o Método Holt-Winters Aditivo (sem tendência) (RMSE: 35,13) destacou-se por sua capacidade em capturar a demanda estável com variações sazonais aditivas, sendo o mais preciso. Na **Categoria B da Autoescola A**, os métodos SES e Holt (RMSE: 64,93 para ambos) provaram ser os mais eficazes. Sua simplicidade foi ideal para suavizar a demanda sem tendência ou sazonalidade complexa, otimizando as projeções. A **Categoria D da Autoescola A** apresentou uma demanda extremamente previsível, onde SES e Holt (RMSE: 11,98) foram novamente os mais acurados. A simplicidade desses modelos alinhou-se perfeitamente à estabilidade da série, gerando previsões de alta precisão.

Para a **Categoria A da Autoescola B**, o SES (RMSE: 18,66) demonstrou a melhor performance. Este modelo conseguiu adaptar-se bem às nuances da demanda, que também foi bem

capturada pelo Holt, indicando pouca necessidade de uma estrutura que vá além da simples suavização de nível para esta série.

Finalmente, na **Categoria B da Autoescola B**, o Método SES (RMSE: 28,40) foi o mais preciso. Sua capacidade de suavizar o nível da série de forma eficaz foi suficiente para modelar a demanda relativamente estável, mostrando que a simplicidade pode ser o caminho mais eficiente.

Os resultados deste estudo transcendem a análise individual de cada autoescola, oferecendo implicações significativas para o setor de formação de condutores como um todo. A demonstração da viabilidade e da acurácia de modelos de previsão de séries temporais, como a Suavização Exponencial Simples (SES), o Método de Holt e as variações de Holt-Winters, ressalta o potencial inexplorado desses métodos no planejamento operacional das autoescolas. A análise comparativa mostra que SES e o Método de Holt se destacaram como os mais precisos em quase todos os cenários da Autoescola A e na Categoria B da Autoescola B, o que sublinha a eficácia de modelos que priorizam a suavização do nível em séries com tendência nula ou pouca complexidade.

Tradicionalmente, a gestão da demanda em Centros de Formação de Condutores (CFCs) pode depender de métodos intuitivos ou da simples observação de padrões históricos sem uma análise quantitativa rigorosa. Contudo, a aplicação de modelos preditivos comprovadamente eficazes pode transformar essa realidade. Ao empregar as previsões de demanda, as autoescolas podem otimizar a alocação de seus recursos mais críticos:

- **Gestão de Instrutores:** Previsões precisas permitem dimensionar adequadamente o quadro de instrutores, evitando a ociosidade ou a sobrecarga, o que impacta diretamente os custos operacionais e a qualidade do ensino.
- **Utilização de Frota:** A demanda futura por aulas de cada categoria direciona o uso eficiente dos veículos (motos, carros, etc.), minimizando tempos de inatividade e necessidade de manutenção corretiva.
- **Planejamento de Cursos e Agendamentos:** Com uma visão clara da demanda esperada, as autoescolas podem estruturar as turmas, os pacotes de aulas e os agendamentos de forma mais estratégica, reduzindo filas e otimizando o fluxo de alunos.
- **Tomada de Decisão Estratégica:** As previsões fornecem subsídio para decisões de investimento (expansão da frota, contratação de novos profissionais) e para a formulação

de estratégias de marketing mais assertivas, direcionando esforços para as categorias de maior ou menor demanda esperada.

Em suma, a implementação de uma cultura de previsão da demanda baseada em métodos quantitativos robustos, como os explorados neste trabalho, capacita as autoescolas a se tornarem mais eficientes, competitivas e responsivas às necessidades do mercado, contribuindo para uma gestão mais proativa e menos reativa.

Todo estudo científico, por mais rigoroso que seja, possui inerentemente suas limitações, e este trabalho não é uma exceção. O reconhecimento dessas restrições é fundamental para a correta interpretação dos resultados e para o delineamento de futuras pesquisas.

Uma das principais limitações reside no escopo da amostra, que se restringiu a dados de apenas duas autoescolas em um contexto geográfico específico. Embora essas instituições ofereçam um panorama valioso, os resultados podem não ser totalmente generalizáveis para a totalidade do setor de formação de condutores no Brasil, que é vasto e diversificado em termos de porte, localização e dinâmica de mercado.

Adicionalmente, a **disponibilidade dos dados históricos** para cada categoria de aula prática variou em extensão, o que pode ter impactado a capacidade de alguns modelos de capturar padrões de longo prazo ou sazonalidades complexas que demandam séries mais longas para identificação robusta. A natureza dos dados utilizados, focada em volume de aulas, não permitiu a inclusão de outras variáveis exógenas que poderiam influenciar a demanda, como sazonalidades macroeconômicas, feriados prolongados, mudanças regulatórias no trânsito, campanhas de marketing ou eventos sociais específicos. Tais fatores, embora relevantes, não foram incorporados nos modelos quantitativos de séries temporais utilizados, que operam primariamente com base nos padrões históricos da própria variável de demanda.

Por fim, a metodologia adotada concentrou-se exclusivamente em modelos quantitativos de suavização exponencial. Embora esses métodos sejam eficazes e amplamente utilizados para previsão de séries temporais, eles podem não ser a única abordagem ideal em todos os contextos, e a integração com métodos qualitativos ou modelos causais poderia oferecer uma perspectiva ainda mais rica e abrangente.

12 CONCLUSÃO

O presente Trabalho de Conclusão de Curso teve como objetivo principal analisar a aplicação de modelos quantitativos de séries temporais para a previsão da demanda por aulas práticas nas categorias A, B e D em Centros de Formação de Condutores. Buscou-se identificar os métodos mais adequados para cada categoria de aula, visando fornecer subsídios para um planejamento mais eficiente por parte das autoescolas.

Ao longo da pesquisa, foram aplicados e comparados diversos modelos de suavização exponencial, tais como: Média Móvel Simples (MMS), Média Móvel Ponderada (MMP), Suavização Exponencial Simples (SES), Método de Holt e as variações Aditiva e Multiplicativa de Holt-Winters. Os resultados demonstraram que a eficácia dos modelos de previsão varia significativamente entre as diferentes categorias de demanda. Em geral, os métodos mais parcimoniosos, como o SES e o Método de Holt, destacaram-se como os mais precisos para a maioria das categorias estudadas, especialmente onde a demanda se mostrou mais estável ou com padrões menos complexos. Para a Categoria A da Autoescola A, o Holt-Winters Aditivo (sem tendência) revelou-se o mais adequado, enquanto para a Categoria A da Autoescola B, o SES foi o de melhor desempenho.

A principal contribuição deste estudo reside em evidenciar a viabilidade e o valor da aplicação de técnicas de previsão quantitativa em um setor que frequentemente opera com base em estimativas menos formais. A identificação de modelos específicos para cada tipo de demanda permite que as autoescolas otimizem a gestão de seus recursos, como instrutores e veículos, melhorem o planejamento de agendamentos e tomem decisões mais informadas sobre investimentos e estratégias de mercado. A capacidade de antecipar a demanda futura confere às autoescolas uma vantagem competitiva, resultando em maior eficiência operacional e potencial melhoria na satisfação dos clientes.

Para pesquisas futuras, sugere-se a expansão da amostra para incluir um número maior de autoescolas em diferentes regiões, o que permitiria uma generalização mais robusta dos

resultados. Outras direções incluem a incorporação de variáveis externas (como fatores macroeconômicos, períodos de férias ou mudanças legislativas) nos modelos preditivos, a exploração de outros métodos de previsão mais avançados (como modelos ARIMA ou redes neurais) e a realização de estudos de caso que acompanhem a implementação prática das previsões e seus impactos na gestão das autoescolas.

REFERÊNCIAS

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos: planejamento, organização e logística empresarial**. 5. ed. Porto Alegre: Bookman, 2006.

BALLOU, R. H. **Logística empresarial: transporte, administração de materiais e distribuição física**. São Paulo: Atlas, 2015.

BERTOLO, L. J. **Modelagem de séries temporais: aplicações em previsão de demanda**. São Paulo: Atlas, 2013.

BRANDÃO, C. R. **Paulo Freire, educar para transformar: fotobiografia**. São Paulo: Mercado Cultural, 2005.

BRASIL. **Lei nº 9.503, de 23 de setembro de 1997. Institui o Código de Trânsito Brasileiro**. Diário Oficial da União, Brasília, 1997.

CAVALHEIRO, A. A. **Previsão de demanda: teoria e prática**. Rio de Janeiro: Ciência Moderna, 2003.

CHATFIELD, C. **The analysis of time series: An introduction**. 6th edition. CRC Press, 2004.

CONTRAN. **Resolução nº 789, de 18 de junho de 2020. Consolida normas sobre o processo de formação de condutores de veículos automotores**. Diário Oficial da União, Brasília, 2020.

CORRÊA, H. L.; CORRÊA, C. A. **Administração de produção e operações: manufatura e serviços: uma abordagem estratégica**. São Paulo: Atlas, 2010.

CROCCO, L. et al. **Fundamentos de marketing**. 3. ed. São Paulo: SaraivaUni, 2013.

CROXTON, K. L. et al. The Demand Management Process. In: LAMBERT, D. M. **Supply Chain Management: Processes, Partnerships, Performance**. Florida: Supply Chain Management Institute, 2008. p. 87-104.

DO NASCIMENTO, F. P. **Classificação da Pesquisa**. Natureza, método ou abordagem metodológica, objetivos e procedimentos. Brasília: Thesaurus, 2016.

DIAS, M. A. P. **Administração de materiais: princípios, conceitos e gestão**. São Paulo: Atlas, 1993.

GIL, A. C. **Métodos e técnicas de pesquisa social**. São Paulo: Atlas, 1991.

GOBE, L. et al. **Forecasting demand in education**. New York: McGraw-Hill, 2000.

HILLETOFTH, P.; ERICSSON, D.; CHRISTOPHER, M. Demand chain management: a Swedish industrial case study. **Industrial Management & Data Systems**, v. 109, n. 9, 2009. Disponível em: <http://dx.doi.org/10.1108/02635570911002261>. Acesso em: 2 jun. 2025.

HILLIER, F. S.; HILLIER, M. S. **Introduction to management science**. New York: McGraw-Hill, 2014.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 2. ed. Melbourne: OTexts, 2018.

KOTLER, P.; KELLER, K. L. **Administração de marketing**. 14. ed. São Paulo: Pearson, 2012.

KRESS, G.J.; SNYDER, J. **Forecasting and Market Analysis Techniques: A Practical Approach**. Connecticut: Quorum, 1994.

KRAJEWSKI, L. J.; RITZMAN, L. P.; MALHOTRA, M. K. **Gestão de operações: processos e cadeias de suprimentos**. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

MAKRIDAKIS, S.; WHEELWRIGHT, S. C.; HYNDMAN, R. J. **Forecasting: methods and applications**. 3. ed. New York: Wiley, 2008.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. São Paulo: Saraiva, 2005.

MELO, D. de C.; ALCÂNTARA, R. L. C. A gestão da demanda em cadeias de suprimentos: uma abordagem além da previsão de vendas. **Gestão & Produção**, v. 18, p. 809-824, 2011.

MENTZER, J. T.; MOON, M. A. **Sales forecasting management**. 2. ed. Thousand Oaks: Sage, 2005.

MILLER, J. **Forecasting demand in higher education**. New York: Routledge, 2010.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Pioneira Thomson Learning, 2001.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Pioneira Thomson Learning, 2011.

MORETTIN, P. A.; TOLOI, C. M. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blücher, 2006.

NOGAMI, O.; PASSOS, R. **Administração da produção**. São Paulo: Cengage Learning, 2016.

PERINI, J.; BERTOLDE, R. **Introdução à análise de séries temporais**. São Paulo: Atlas, 2016.

PORTAL DO TRÂNSITO. **Histórico e evolução da legislação de trânsito no Brasil**. 2014. Disponível em: <https://portaldotransito.com.br/>. Acesso em: 15 jul. 2025.

RAGSDALE, C. T. **Spreadsheet modeling and decision analysis: a practical introduction to business analytics**. 7. ed. Mason: Cengage Learning, 2014.

SAMOHYL, R.; ROCHA, R.; MATTOS, J. **Previsão de séries temporais**. São Paulo: Atlas, 2001.

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

VERÍSSIMO, F. J. et al. **Modelos de previsão de demanda**. Rio de Janeiro: Elsevier, 2012.

WALTERS, D., RAINBIRD, M. **The Demand Chain as an Integral Component of the Value Chain**. *Journal of Consumer Marketing*, v. 21, n. 7, 2004.

<http://dx.doi.org/10.1108/07363760410568680>

WHEELWRIGHT, S. C.; MAKRIDAKIS, S. **Forecasting methods for management**. New York: Wiley, 1985.