

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

LUCAS TOMMASINI

**PREVISÃO DO INDICADOR GERAL DE SATISFAÇÃO POR DEFASAGENS
TEMPORAIS: ESTUDO DE CASO EM UMA CONCESSIONÁRIA DO SETOR
AUTOMOTIVO PESADO**

CURITIBA

2026

LUCAS TOMMASINI

**PREVISÃO DO INDICADOR GERAL DE SATISFAÇÃO POR DEFASAGENS
TEMPORAIS: ESTUDO DE CASO EM UMA CONCESSIONÁRIA DO SETOR
AUTOMOTIVO PESADO**

**FORECASTING THE GENERAL SATISFACTION INDICATOR THROUGH TIME
LAGS: A CASE STUDY IN A HEAVY AUTOMOTIVE INDUSTRY DEALERSHIP**

Trabalho de conclusão de curso de graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica do curso de
Engenharia Elétrica da Universidade Tecnológica
Federal do Paraná (UTFPR).
Orientador(a): Carlos Henrique Mariano.

CURITIBA

2026



Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

LUCAS TOMMASINI

**PREVISÃO DO INDICADOR GERAL DE SATISFAÇÃO POR DEFASAGENS
TEMPORAIS: ESTUDO DE CASO EM UMA CONCESSIONÁRIA DO SETOR
AUTOMOTIVO PESADO**

Trabalho de conclusão de curso de graduação
apresentado como requisito para obtenção do título
de Bacharel em Engenharia Elétrica do curso de
Engenharia Elétrica da Universidade Tecnológica
Federal do Paraná (UTFPR).

Data de aprovação: 24/junho/2026

Carlos Henrique Mariano
Doutorado
Universidade Tecnológica Federal do Paraná

Emerson Rigoni
Doutorado
Universidade Tecnológica Federal do Paraná

Narco Afonso Ravazzoli Maciejewski
Doutorado
Universidade Tecnológica Federal do Paraná

CURITIBA

2026

Dedico este trabalho à minha família, que sempre esteve ao meu lado em cada etapa desta jornada.
Àqueles que, com amor, paciência e palavras de incentivo, fortaleceram minha caminhada e acreditaram no meu potencial.

AGRADECIMENTOS

Gostaria de dedicar esta página para agradecer a todos que estiveram comigo neste período único da minha vida, que foi cursar Engenharia Elétrica na UTFPR. Sou grato pelo apoio, incentivo e, principalmente, pela compreensão diante do tempo e da dedicação exigidos ao longo dessa trajetória acadêmica.

Agradeço de forma especial à minha mãe, à minha irmã e ao meu pai, que estiveram ao meu lado em todos os momentos. Sem o apoio, a confiança e o incentivo de vocês, eu não teria conseguido concluir esse desafio.

Ao meu orientador, Prof. Dr. Carlos Henrique Mariano, expresso minha profunda gratidão pela sabedoria, orientação e paciência com que conduziu este trabalho, contribuindo de maneira fundamental para o seu desenvolvimento.

Aos meus colegas de sala, deixo meu agradecimento pela parceria ao longo do curso, em especial ao João, que esteve comigo em diversos desafios desta jornada.

Agradeço à Secretaria do Curso, pela cooperação e suporte prestados durante toda a graduação.

RESUMO

A gestão da experiência do cliente (CX) no setor automotivo de transportes pesados depende do monitoramento contínuo de indicadores capazes de subsidiar a tomada de decisão e orientar ações de melhoria. No contexto analisado, o Indicador Geral de Satisfação (IGS) é utilizado para avaliar o desempenho das concessionárias por meio de pesquisas transacionais aplicadas em diferentes momentos da jornada do cliente. Entretanto, por ser calculado a partir de uma composição ponderada e de uma média móvel de doze meses, o indicador apresenta comportamento suavizado e predominantemente retrospectivo, dificultando a identificação antecipada de tendências de variação. Diante desse contexto, este trabalho teve como objetivo desenvolver um modelo empírico de previsão do IGS, baseado em defasagens temporais dos momentos da jornada do cliente, para apoiar a detecção antecipada dessas tendências. A pesquisa caracteriza-se como aplicada, de abordagem quantitativa, exploratória e desenvolvida por meio de estudo de caso. A metodologia envolveu a preparação de uma base histórica de pesquisas transacionais, referente ao período de outubro de 2023 a março de 2025, seguida da análise de estacionariedade das séries dos momentos da jornada e da média mensal do IGS. Em seguida, foram desenvolvidas e comparadas três alternativas de modelagem, submetidas à validação temporal e avaliadas pelo Erro Percentual Absoluto Médio (MAPE). Posteriormente, o modelo de melhor desempenho foi comparado aos modelos de referência ingênuo e de média móvel. Os resultados demonstraram que a estrutura multivariável inicialmente proposta apresentou instabilidade devido às limitações da base histórica. Em contrapartida, um modelo simplificado, baseado na média dos dois últimos períodos de cada momento da jornada, apresentou melhor desempenho preditivo, obtendo MAPE de 0,07%, inferior ao modelo ingênuo (0,19%) e ao modelo de média móvel (0,27%). Os testes de estacionariedade indicaram que parte das séries atendeu aos pressupostos da modelagem baseada em defasagens, enquanto outras apresentaram resultados inconclusivos em razão do reduzido número de observações. Esses resultados demonstram que a utilização da estrutura interna do indicador proporcionou ganho preditivo em relação aos modelos de referência. Conclui-se que foi possível desenvolver um modelo empírico capaz de antecipar tendências de variação do IGS com desempenho superior aos modelos simples de referência, atingindo os objetivos da pesquisa. Contudo, os resultados devem ser interpretados considerando as limitações da base histórica, a análise restrita a uma única concessionária e o comportamento naturalmente suavizado do indicador. Assim, antes de sua aplicação em ambiente gerencial, recomenda-se sua validação em bases mais extensas, envolvendo diferentes concessionárias e análises estatísticas mais robustas.

Palavras-chave: experiência do cliente; Indicador Geral de Satisfação; séries temporais; defasagens temporais; modelo preditivo.

ABSTRACT

Customer Experience (CX) management in the heavy-duty automotive sector relies on the continuous monitoring of performance indicators capable of supporting managerial decision-making and guiding improvement actions. In the context analyzed, the General Satisfaction Indicator (IGS) is used to evaluate dealership performance through transactional surveys conducted at different stages of the customer journey. However, because it is calculated from a weighted composition and a 12-month moving average, the indicator exhibits a smoothed and predominantly retrospective behavior, making it difficult to identify emerging trends in a timely manner. In this context, the objective of this study was to develop an empirical forecasting model for the IGS, based on temporal lags of the customer journey stages, to support the early detection of such trends. This research is characterized as applied, quantitative, exploratory, and conducted through a case study. The methodology involved preparing a historical database of transactional surveys collected between October 2023 and March 2025, followed by stationarity analysis of the customer journey stage series and the monthly IGS series. Subsequently, three alternative forecasting models were developed and compared using temporal validation and the Mean Absolute Percentage Error (MAPE) as the performance metric. The best-performing model was then compared with benchmark models, namely the naïve model and the moving average model. The results showed that the initially proposed multivariate structure presented instability due to the limitations of the available historical dataset. In contrast, a simplified model based on the average of the two previous periods for each customer journey stage achieved the best predictive performance, obtaining a MAPE of 0.07%, outperforming both the naïve model (0.19%) and the moving average model (0.27%). The stationarity tests indicated that some series satisfied the assumptions required for lag-based modeling, whereas others produced inconclusive results due to the limited number of observations. These findings demonstrate that incorporating the internal structure of the indicator provided greater predictive capability than the benchmark models. It is concluded that an empirical model capable of anticipating variation trends in the IGS, while outperforming the benchmark models, was successfully developed, achieving the objectives established for this research. Nevertheless, the results should be interpreted considering the limitations of the historical dataset, the analysis restricted to a single dealership, and the naturally smoothed behavior of the indicator. Therefore, before being adopted as a managerial support tool, the proposed methodology should be validated using larger datasets, multiple dealerships, and more robust statistical analyses.

Keywords: customer experience; General Satisfaction Indicator; time series; temporal lags; forecasting model.

LISTA DE FIGURAS

Figura 1 - Linha de Tempo dos Lags	45
Figura 2 – Fluxograma com etapas metodológicas	49

LISTA DE GRÁFICOS

Gráfico 1 – Evolução Genérica do IGS	27
Gráfico 2 – Comparação entre uma série estacionária (AR(1)) e um passeio aleatório	37
Gráfico 3 - Crescimento da variância do erro de previsão para séries estacionárias e não estacionárias	38
Gráfico 4 - O passeio aleatório (B) e sua primeira diferença (Delta B)	39
Gráfico 5 - Distribuição volumétrica de pesquisas (out23-mar25).....	44
Gráfico 6 - Evolução do IGS da Concessionária M (out23-mar25).....	44
Gráfico 7 – Comparativo entre IGS previsto e Real, Modelo 3	59
Gráfico 8 - Análise Estacionária.....	60

LISTA DE QUADROS

Quadro 1 - Análise ADF e KPSS.....	39
Quadro 2 - Variáveis para Modelagem	45
Quadro 3 - Seleção de Dados Concessionária M	52
Quadro 4 - Análise Estacionária	60

LISTA DE TABELAS

Tabela 1 – Distribuição ponderada do IGS.....	23
Tabela 2 - Comparativo Real X Previsto Modelo 1	53
Tabela 3 – Comparativo Real X Previsto Modelo 2.....	54
Tabela 4 – Comparativo Real X Previsto Modelo 3.....	55
Tabela 5 – Comparação de Desempenho entre Modelos.....	56
Tabela 6 - Comparação entre valores reais e previstos por momento (Modelo 3)	57
Tabela 7 – Previsão do IGS (validação recursiva)	58
Tabela 8 – Previsão do IGS (modelo ingênuo).....	61
Tabela 9 – Previsão do IGS (modelo média móvel).....	61
Tabela 10 – Comparação com modelos de referência	62

LISTA DE ABREVIATURAS E SIGLAS

ADF	Dickey-Fuller Aumentado
ARIMA	<i>AutoRegressive Integrated Moving Average</i>
ARDL	<i>AutoRegressive Distributed Lag</i>
BI	<i>Business Intelligence</i>
CSV	<i>Comma Separated Values</i>
CX	<i>Customer Experience</i>
DAX	<i>Data Analysis Expressions</i>
IGS	Indicador Geral de Satisfação
KPSS	Kwiatkowski-Phillips-Schmidt-Shin
LGPD	Lei Geral de Proteção de Dados
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
NPS	<i>Net Promoter Score</i>
RMSE	<i>Root Mean Squared Error</i>
SARIMA	<i>Seasonal AutoRegressive Integrated Moving Average</i>
UTFPR	Universidade Tecnológica Federal do Paraná

LISTA DE SÍMBOLOS

β_0	Intercepto da regressão
β_i	Coefficiente associado à variável i
ϵ_t	Erro aleatório no período t
i	Momento da jornada do cliente
IGSt	Indicador Geral de Satisfação no período t
k	Ordem da defasagem
$M_{i,t}$	Nota do momento i no período t
$M_{i,t-1}$	Primeira defasagem do momento i
$M_{i,t-2}$	Segunda defasagem do momento i
n	Número de observações
t	Período de tempo (mês)

SUMÁRIO

1	GESTÃO E MONITORAMENTO DA EXPERIÊNCIA DO CLIENTE NO SETOR AUTOMOTIVO DE TRANSPORTES PESADOS	15
1.1	Delimitação do tema	16
1.2	Descrição do problema	17
1.2.1	Pergunta de pesquisa.....	17
1.3	Objetivo geral	17
1.4	Objetivos específicos	18
1.5	Justificativa	18
1.6	Enquadramento metodológico	19
1.7	Mapa de desenvolvimento do trabalho	20
2	CARACTERIZAÇÃO DO OBJETO DE ESTUDO: IGS E JORNADA DO CLIENTE	21
2.1	Pesquisa transacional de satisfação	21
2.2	Indicador Geral de Satisfação	22
2.3	Momentos de aplicação da pesquisa transacional	24
2.3.1	Momento 1 — Vendas.....	24
2.3.2	Momento 2 — Um Ano e Meio de Uso.....	25
2.3.3	Momento 3 — <i>Pitstop</i>	25
2.3.4	Momento 4 — Revisão	26
2.3.5	Momento 5 — Outros Serviços.....	26
2.3.6	Momento 6 — Atendimento Emergencial	26
2.4	Limitações gerenciais do acompanhamento atual	27
2.5	Síntese e conclusão do capítulo	28
3	FUNDAMENTAÇÃO TEÓRICA	30
3.1	Séries temporais e dependência temporal	30
3.2	Defasagens temporais — <i>lags</i>	31
3.3	Modelos autorregressivos simples e modelos empíricos com defasagens	32
3.4	Modelos multivariáveis e limitação em bases curtas	33
3.5	Modelos de referência para validação	34
3.6	Métricas de avaliação dos modelos preditivos	34
3.7	Análise estacionária	36
3.8	Considerações sobre ARDL	40
3.9	Síntese e conclusão do capítulo	41

4	METODOLOGIA PARA DESENVOLVIMENTO DO MODELO PREDITIVO	43
4.1	Fonte e seleção de dados	43
4.2	Seleção da unidade para análise	43
4.3	Estruturação das variáveis	44
4.4	Alternativas de modelagem testadas	46
4.4.1	Modelo 1 – Estrutura multivariável inicial	46
4.4.2	Modelo 2 – Estrutura autorregressiva por momento.....	46
4.4.3	Modelo 3 – Estrutura simplificada com média dos dois últimos períodos	47
4.4.4	Modelos de referência	47
4.5	Critério de comparação	48
4.6	Procedimento de validação	48
4.7	Limitação metodológica	50
4.8	Síntese e conclusão do capítulo	51
5	DESENVOLVIMENTO E EXECUÇÃO DOS MODELOS	52
5.1	Preparação dos dados	52
5.2	Primeiro modelo	53
5.3	Segundo modelo	54
5.4	Terceiro modelo	55
5.5	Validação dos modelos e comparação de desempenho	56
5.6	Projeção do IGS e validação do modelo escolhido	57
5.7	Comparação com modelos de referência	61
5.8	Interpretação dos resultados	62
5.9	Síntese e conclusão do capítulo	63
6	DISCUSSÃO	65
6.1	Coerência entre modelo proposto e solução final	65
6.2	Utilidade gerencial	65
6.3	Limitações da abordagem	66
6.4	Síntese e conclusão do capítulo	67
7	CONCLUSÃO	69
7.1	Trabalhos futuros	70
	REFERÊNCIAS	72

1 GESTÃO E MONITORAMENTO DA EXPERIÊNCIA DO CLIENTE NO SETOR AUTOMOTIVO DE TRANSPORTES PESADOS

A empresa utilizada como objeto de estudo nesta pesquisa é uma multinacional do setor automotivo pesado, localizada em Curitiba, Paraná. A unidade analisada possui a particularidade de concentrar em um mesmo complexo tanto as operações fabris quanto as atividades comerciais da organização para a América Latina. Enquanto a estrutura industrial é responsável pela fabricação e desenvolvimento dos veículos e componentes, o polo comercial atua na gestão estratégica da rede de concessionárias da região, coordenando atividades relacionadas à comercialização de produtos, serviços e pós-venda.

A rede de concessionárias desempenha papel fundamental na relação entre a empresa e seus clientes, sendo responsável pela venda dos veículos, atendimento pós-venda, fornecimento de peças, execução de serviços de manutenção e acompanhamento contínuo das necessidades dos transportadores. Dessa forma, grande parte da percepção do cliente em relação à marca é construída por meio das experiências vivenciadas nesses pontos de contato.

Nesse contexto, destaca-se a área de Experiência do Cliente (*Customer Experience – CX*), responsável pela definição, aplicação e análise das pesquisas de satisfação utilizadas para monitorar a percepção dos clientes ao longo de sua jornada. Além da gestão dos indicadores de satisfação, a área atua de forma transversal junto às concessionárias e às áreas internas da fábrica, conduzindo análises e projetos de melhoria sempre que os dados identificam oportunidades de aprimoramento na experiência oferecida ao cliente.

A atuação da área de CX possui elevada relevância estratégica dentro da organização, uma vez que os resultados das pesquisas influenciam decisões relacionadas a processos comerciais, pós-venda, qualidade de produtos, treinamento de equipes e definição de ações corretivas e preventivas. Dessa forma, os indicadores de satisfação tornam-se instrumentos importantes para direcionar iniciativas de melhoria contínua em diferentes áreas da empresa.

A importância desse acompanhamento é potencializada pelo posicionamento da marca no mercado. Reconhecida por atuar em um segmento de veículos pesados de alto valor agregado, a empresa comercializa produtos entre os mais custosos de sua categoria. Em razão desse posicionamento premium, a percepção de valor entregue ao cliente torna-se um fator crítico para a manutenção da competitividade e

da fidelização. Assim, compreender, monitorar e antecipar tendências relacionadas à satisfação dos clientes constitui uma atividade estratégica para a sustentação dos resultados da organização e para o fortalecimento de sua imagem perante o mercado.

1.1 Delimitação do tema

Este estudo tem como foco a análise e previsão do Indicador Geral de Satisfação (IGS) a partir de dados históricos de pesquisas transacionais de uma concessionária selecionada.

O IGS constitui o principal indicador utilizado pela organização para monitorar e avaliar a experiência dos clientes ao longo de sua jornada de relacionamento com a marca. Sua função é consolidar, em uma única métrica, a percepção dos clientes sobre os diferentes pontos de contato considerados estratégicos para o negócio, permitindo uma visão abrangente do desempenho das concessionárias sob a ótica da satisfação.

A construção do IGS tem como base os resultados da pesquisa transacional de satisfação. As respostas coletadas são agrupadas de acordo com momentos específicos da jornada do cliente, definidos pela organização como os pontos mais críticos e representativos da experiência vivenciada. Cada um desses momentos possui uma nota média própria, calculada a partir das avaliações obtidas nas pesquisas realizadas junto aos clientes.

O trabalho limita-se ao contexto da concessionária analisada, não contemplando a avaliação de toda a rede de concessionárias, nem a proposição de um novo indicador corporativo ou o redesenho do sistema de CX adotado pela organização. Também não busca estabelecer relações causais entre fatores operacionais e os resultados de satisfação, desenvolver uma solução completa de *Business Intelligence* ou validar formalmente um modelo econométrico *Autoregressive Distributed Lag* (ARDL). Dessa forma, o estudo restringe-se à construção e avaliação de um modelo preditivo aplicado ao IGS como ferramenta de apoio à tomada de decisão.

Embora os dados estejam organizados mensalmente, este estudo não incorporou explicitamente componentes de sazonalidade à modelagem. Essa decisão está associada à extensão reduzida da série histórica disponível, que compreende aproximadamente dezoito meses, período insuficiente para identificar com robustez padrões sazonais anuais. Além disso, o IGS é calculado por meio de uma média móvel

de doze meses, característica que suaviza oscilações mensais e dificulta a separação entre variações sazonais e flutuações pontuais. Assim, possíveis efeitos sazonais foram considerados uma limitação da abordagem e devem ser investigados em estudos futuros com séries históricas mais longas.

1.2 Descrição do problema

A gestão de CX depende cada vez mais de indicadores de satisfação para apoiar a tomada de decisão. No contexto estudado, o IGS é utilizado para acompanhar a percepção dos clientes, porém sua análise ocorre de forma predominantemente retrospectiva, dificultando a identificação antecipada de tendências de queda ou melhoria.

Diante dessa necessidade, este trabalho propõe o desenvolvimento de um modelo preditivo baseado em dados históricos já disponíveis, buscando uma solução de baixo custo, simples de implementar e facilmente interpretável pelos gestores. A escolha por uma abordagem baseada em defasagens temporais também se justifica pela quantidade limitada de dados disponíveis e pela possibilidade de aplicação prática sem a necessidade de grande infraestrutura tecnológica adicional.

O IGS, por ser calculado a partir de uma composição ponderada e suavizada temporalmente, pode retardar a percepção de quedas recentes em momentos específicos da jornada do cliente. Isso dificulta a atuação preventiva das concessionárias e reduz a capacidade de resposta gerencial diante de deteriorações emergentes na satisfação.

1.2.1 Pergunta de pesquisa

Uma abordagem empírica baseada em defasagens temporais dos momentos da jornada do cliente seria capaz de prever tendências de variação do IGS com desempenho superior a modelos simples de referência e com utilidade prática para a gestão da satisfação?

1.3 Objetivo geral

Desenvolver um modelo empírico de previsão do IGS, baseado em defasagens temporais dos momentos da jornada do cliente, para apoiar a detecção

antecipada de tendências de variação em uma concessionária do setor automotivo pesado.

1.4 Objetivos específicos

Para materializar o objetivo geral, definem-se os seguintes objetivos específicos:

- Caracterizar o IGS, sua composição, seus momentos de aplicação e sua relevância para a gestão de CX.
- Selecionar e preparar a base histórica de dados da pesquisa transacional, consolidando as médias mensais dos momentos da jornada do cliente utilizados no cálculo do IGS.
- Construir alternativas de modelos empíricos de previsão baseadas em defasagens temporais dos momentos da jornada do cliente.
- Comparar o desempenho das alternativas testadas por meio de métricas de erro e validação temporal fora da amostra.
- Comparar o modelo selecionado com modelos simples de referência, como manutenção do último valor observado e média móvel, a fim de verificar se a abordagem proposta agrega ganho preditivo.
- Avaliar a utilidade prática da previsão do IGS para apoiar a identificação antecipada de tendências de queda e subsidiar ações gerenciais preventivas.

1.5 Justificativa

Devido ao comportamento retroativo do IGS e sua grande importância gerencial, torna-se relevante o desenvolvimento de um modelo capaz de antecipar suas possíveis variações, oferecendo suporte adicional ao processo de tomada de decisão.

A escolha por uma abordagem simples, interpretável e operacional justifica-se pela necessidade de construir uma solução compatível com a realidade organizacional, em que a ferramenta é utilizada pelos mais diversos setores e funcionários. Modelos excessivamente complexos, além de exigirem grande volume de dados e maior capacidade computacional, podem dificultar a compreensão dos resultados e limitar sua utilização prática pelos usuários. Por outro lado, uma estrutura simplificada apresenta baixo custo de implementação, utiliza dados já disponíveis na organização e possibilita a aplicação mesmo em cenários com base histórica limitada, característica presente no contexto deste estudo.

Dessa forma, o presente trabalho busca oferecer uma solução prática e acessível para o monitoramento antecipado do IGS, contribuindo para uma gestão mais proativa da satisfação e da experiência dos clientes.

Além da relevância gerencial, o estudo também se justifica do ponto de vista acadêmico e metodológico, pois aborda a aplicação de técnicas de previsão em uma base histórica limitada e em um indicador corporativo naturalmente suavizado por média móvel. Esse contexto impõe desafios à modelagem preditiva, uma vez que exige o desenvolvimento de uma solução capaz de equilibrar simplicidade, interpretabilidade e desempenho. Assim, a investigação contribui para demonstrar como abordagens empíricas baseadas em defasagens temporais podem ser utilizadas em problemas reais de apoio à decisão, especialmente quando há restrições quanto ao volume de dados disponível e à necessidade de aplicação prática em ambiente gerencial.

1.6 Enquadramento metodológico

Este estudo caracteriza-se como uma pesquisa **aplicada**, uma vez que busca solucionar um problema prático relacionado à previsão do IGS em uma concessionária do setor automotivo pesado. Quanto à abordagem, a pesquisa é quantitativa, pois utiliza dados numéricos provenientes das pesquisas transacionais de satisfação para construção e avaliação dos modelos de previsão.

Sob a ótica dos objetivos, o trabalho possui caráter descritivo e exploratório, visto que busca compreender o comportamento histórico do indicador, identificar padrões temporais e investigar a viabilidade de técnicas preditivas aplicadas ao contexto estudado. Em relação aos procedimentos técnicos, a pesquisa é desenvolvida por meio de um estudo de caso, concentrando-se na análise de uma concessionária específica e em seus dados históricos de satisfação.

A modelagem adotada baseia-se em uma abordagem adaptada de séries temporais, utilizando defasagens temporais dos momentos da jornada do cliente para construção dos modelos preditivos. A avaliação dos resultados é realizada por meio de uma validação temporal preliminar, comparando previsões geradas para períodos futuros com os valores efetivamente observados, utilizando métricas de erro para análise de desempenho.

No contexto da engenharia, o trabalho se insere no uso de métodos quantitativos, análise de dados e modelagem aplicada para apoiar a melhoria de

processos, o monitoramento de indicadores de desempenho e a tomada de decisão baseada em evidências.

Para operacionalização da pesquisa, foram utilizadas ferramentas como *Excel*, *Power Business Intelligence (BI)*, *Python* e *Visual Studio Code*, empregadas nas etapas de tratamento dos dados, modelagem, validação e análise dos resultados. Dessa forma, busca-se desenvolver uma solução prática, interpretável e aplicável à rotina gerencial da organização estudada.

1.7 Mapa de desenvolvimento do trabalho

Este trabalho está estruturado em sete capítulos, organizados de forma a conduzir o leitor desde a contextualização do problema até as conclusões obtidas. O Capítulo 1, *Gestão e Monitoramento da Experiência do Cliente no Setor Automotivo de Transportes Pesados*, apresenta a contextualização da empresa e do setor, a definição do problema de pesquisa, bem como os objetivos geral e específicos do estudo. O Capítulo 2, *Caracterização do Objeto de Estudo: IGS e Jornada do Cliente*, descreve o IGS, sua composição, seus componentes e sua importância para o monitoramento da experiência do cliente. O Capítulo 3, *Fundamentação Teórica*, reúne os principais conceitos e referenciais utilizados para embasar o desenvolvimento da pesquisa. O Capítulo 4, *Metodologia para Desenvolvimento do Modelo Preditivo*, apresenta os procedimentos metodológicos adotados, a caracterização da pesquisa e as etapas empregadas na construção e validação dos modelos de previsão. O Capítulo 5, *Desenvolvimento e Execução dos Modelos*, descreve a implementação das alternativas de modelagem, bem como os resultados obtidos em cada etapa de validação. O Capítulo 6, *Discussão*, analisa criticamente os resultados alcançados, destacando suas contribuições, limitações e aplicações práticas. Por fim, o Capítulo 7, *Conclusão*, retoma os objetivos propostos, sintetiza os principais resultados obtidos e apresenta as considerações finais e recomendações para trabalhos futuros.

2 CARACTERIZAÇÃO DO OBJETO DE ESTUDO: IGS E JORNADA DO CLIENTE

Neste capítulo, aprofunda-se o contexto no qual o estudo está inserido, apresentando de forma clara o setor analisado e suas particularidades. Após a delimitação da proposta, descrevem-se o funcionamento a fundo do indicador de satisfação adotado no projeto e os elementos que o compõem. Além disso, são detalhadas as variáveis essenciais que servirão de base para o modelo preditivo, com destaque para os momentos críticos da jornada do cliente com a marca, que influenciam diretamente a percepção de qualidade e o comportamento futuro de satisfação.

2.1 Pesquisa transacional de satisfação

Para compreender a satisfação dos clientes, a empresa utiliza diferentes fontes de captação da voz do cliente. Entre elas, destacam-se um canal público de relacionamento com consumidores, semelhante ao “Reclame Aqui”, e uma pesquisa anual de mercado conduzida por entidade independente para fins de benchmarking competitivo. Embora ambas forneçam informações relevantes para o monitoramento da percepção da marca, não constituem o foco deste estudo devido às suas limitações quanto à representatividade estatística, periodicidade e capacidade de acompanhamento contínuo da satisfação.

O principal instrumento de mensuração utilizado pela organização é a pesquisa transacional de satisfação, que representa a base de dados empregada neste trabalho. Essa pesquisa é realizada de forma proativa por um *call center* terceirizado e ocorre diariamente após interações relevantes da jornada do cliente, como aquisição de veículos, realização de serviços de manutenção, revisões programadas ou atendimentos emergenciais.

Devido à sua abrangência operacional, o processo gera uma base amostral representativa do território das concessionárias. Essa característica confere representatividade estatística aos resultados obtidos, permitindo análises tanto em nível nacional quanto por concessionária, segmento ou etapa da jornada do cliente.

As entrevistas possuem curta duração e são compostas por perguntas estruturadas voltadas à avaliação da experiência do cliente. As respostas são registradas em uma escala de 0 a 10, amplamente utilizada em programas de CX e derivada dos conceitos do *Net Promoter Score* (NPS), proposto por Reichheld (2003).

Segundo o autor, a utilização dessa escala permite mensurar de forma objetiva a propensão do cliente em recomendar uma empresa, produto ou serviço, constituindo um importante indicador de lealdade e percepção de valor.

A padronização da escala de 0 a 10 possibilita comparações entre períodos, concessionárias e mercados, além de servir como base para a construção dos indicadores corporativos de satisfação. Conforme destacado por Reichheld (2003), métricas derivadas do NPS contribuem para a compreensão da experiência do cliente e para o direcionamento de ações voltadas à melhoria contínua dos serviços prestados.

A utilização da escala de 0 a 10 justifica-se por sua ampla adoção em pesquisas de experiência do cliente e por sua compatibilidade com a lógica do Net Promoter Score (NPS), que classifica os respondentes em detratores, passivos e promotores. Tendo esta medida calculada pela diferença entre a porcentagem de promotores (nota 9 ou 10) e a porcentagem de detratores (nota 0 a 6).

No presente estudo, entretanto, a escala é utilizada para compor médias de satisfação dos momentos da jornada e o IGS, não correspondendo ao cálculo formal do NPS.

Dessa forma, a pesquisa transacional configura-se como a principal fonte de monitoramento da satisfação dentro da organização, fornecendo dados contínuos, padronizados e de elevada representatividade. Em função de sua abrangência, periodicidade e disponibilidade histórica, essa base foi selecionada como fundamento para o desenvolvimento do modelo preditivo proposto neste estudo.

2.2 Indicador Geral de Satisfação

Como citado no subitem 1.1 o IGS constitui o principal indicador utilizado pela organização para monitorar e avaliar a experiência dos clientes ao longo de sua jornada de relacionamento com a marca. Sua função é consolidar, em uma única métrica, a percepção dos clientes sobre os diferentes pontos de contato considerados estratégicos para o negócio, permitindo uma visão abrangente do desempenho das concessionárias sob a ótica da satisfação.

A construção do IGS tem como base os resultados da pesquisa transacional de satisfação apresentada anteriormente. As respostas coletadas são agrupadas de acordo com momentos específicos da jornada do cliente, definidos pela organização como os pontos mais críticos e representativos da experiência vivenciada. Cada um

desses momentos possui uma nota média própria, calculada a partir das avaliações obtidas nas pesquisas realizadas junto aos clientes.

Posteriormente, as médias de cada momento são combinadas por meio de uma ponderação previamente estabelecida pela empresa, refletindo a importância relativa de cada etapa da jornada na composição do indicador final. Dessa forma, momentos considerados mais relevantes para a percepção do cliente exercem maior influência sobre o resultado consolidado do IGS, conforme a tabela (1):

Tabela 1 – Distribuição ponderada do IGS

Indicador Geral de Satisfação	
Momento	Ponderação
M1 - Vendas	20%
M2 - Uso	20%
M3 - Pitstop	15%
M4 – Revisão	15%
M5 – Outros Serviços	15%
M6 – Atendimento Emergencial	15%

Fonte: Autoria própria (2026)

Além da ponderação entre os momentos, o indicador adota uma lógica de média móvel de doze meses. Isso significa que o valor do IGS em determinado período é calculado considerando todas as pesquisas realizadas nos doze meses anteriores à data de referência. Essa metodologia reduz a influência de oscilações pontuais e proporciona maior estabilidade ao indicador, permitindo uma avaliação mais consistente do desempenho ao longo do tempo.

A utilização de uma janela móvel anual também garante que o indicador reflita continuamente o comportamento recente da satisfação dos clientes. De maneira exemplificada, o IGS referente ao mês de dezembro de 2025 é calculado a partir das médias ponderadas das pesquisas realizadas entre janeiro e dezembro de 2025. Da mesma forma, o indicador de junho de 2025 considera os resultados obtidos entre julho de 2024 e junho de 2025 seguindo o cálculo do valor da nota de satisfação mensal na equação (1) e posteriormente do IGS como na equação (2):

$$\begin{aligned}
 \text{Nota}^{\{\text{mensal}\}} = & 0,20M_{\{1,t\}} + 0,20M_{\{2,t\}} + 0,15M_{\{3,t\}} + 0,15M_{\{4,t\}} + 0,15M_{\{5,t\}} \\
 & + 0,15M_{\{6,t\}}
 \end{aligned}
 \tag{1}$$

Este cálculo gera um valor referente a nota das entrevistas daquele mês isolado, a mesma métrica se aplica aos 11 meses anteriores e posteriormente é feita uma média entre essas notas mensais, gerando assim o IGS conforme a equação (2):

$$IGS_t = (1/12) \sum_{\{k=0\}}^{\{11\}} Nota_{\{t-k\}}^{\{mensal\}} \quad (2)$$

Em razão de sua abrangência e representatividade, o IGS é amplamente utilizado como instrumento de gestão pelas lideranças da empresa e pela rede de concessionárias. O acompanhamento periódico desse indicador subsidia análises de desempenho, definição de prioridades e direcionamento de ações de melhoria relacionadas à CX.

Além de sua utilização gerencial, o IGS possui impacto direto em programas corporativos de reconhecimento e remuneração variável das concessionárias. Parte das bonificações concedidas pela organização é vinculada ao atingimento de metas associadas ao indicador, sendo as avaliações realizadas em ciclos semestrais. Dessa forma, o desempenho em satisfação do cliente torna-se um fator estratégico não apenas para a percepção da marca no mercado, mas também para os resultados financeiros das concessionárias, reforçando a importância do monitoramento contínuo e da capacidade de antecipação das tendências futuras do indicador.

2.3 Momentos de aplicação da pesquisa transacional

A pesquisa transacional utilizada pela empresa é estruturada com base em seis momentos considerados críticos da jornada do cliente, definidos estrategicamente pela alta direção da organização como os principais pontos de interação entre o cliente e a marca. Esses momentos abrangem desde o processo de aquisição do veículo até os diferentes atendimentos de pós-venda, permitindo acompanhar a percepção do cliente ao longo de toda sua experiência.

2.3.1 Momento 1 — Vendas

O primeiro momento analisado corresponde à etapa de Vendas, que abrange todo o processo de interação inicial entre cliente e marca. Esse momento engloba desde a busca pelo produto e o primeiro atendimento comercial até o fechamento da compra e o recebimento do veículo.

A pesquisa é acionada pelo gatilho da data de faturamento, o que significa que, muitas vezes, o cliente ainda sequer utilizou o veículo quando é entrevistado. Esse detalhe torna o momento especialmente estratégico, pois permite mensurar não

apenas a qualidade dos atendimentos iniciais, mas também as expectativas formadas em relação ao produto e à marca.

Assim, o objetivo desse momento é captar a percepção inicial do cliente, que costuma ser influenciada por fatores como clareza na negociação, confiança no vendedor, condições de compra, prazo de entrega e experiência geral de aquisição.

2.3.2 Momento 2 — Um Ano e Meio de Uso

O segundo momento também utiliza como gatilho a data de faturamento, porém a pesquisa ocorre após um intervalo de um ano e meio de uso do veículo. Diferentemente do primeiro contato, aqui o cliente já vivenciou de maneira mais aprofundada as características do produto e a rotina de serviços oferecidos pela rede.

Nesse período, o cliente costuma ter acumulado experiências suficientes para formar uma percepção consolidada sobre pontos positivos e negativos do caminhão, incluindo desempenho, conforto, consumo, disponibilidade, comportamento em operação e ocorrências de manutenção.

Essa etapa também desempenha um papel comparativo importante: permite verificar o alinhamento — ou discrepância — entre a expectativa criada no momento inicial (vendas) e a experiência real após um período significativo de uso. Trata-se, portanto, de um momento fundamental para avaliar fidelização, confiabilidade percebida e satisfação sustentada ao longo do ciclo de propriedade.

2.3.3 Momento 3 — *Pitstop*

O *Pitstop* constitui um dos serviços de maior relevância dentro da rede de concessionárias, sobretudo por ser o tipo de atendimento mais frequente ao longo da jornada de uso do veículo. Por essa razão, representa um ponto de contato estratégico para a fidelização do cliente, funcionando como porta de entrada para a contratação de outros serviços de maior complexidade. A avaliação desse momento é feita com gatilho de cerca de 15 dias pós serviço assim como os demais serviços e permite mensurar tanto a eficiência operacional da concessionária quanto a qualidade da interação cotidiana com o cliente, elementos fundamentais para o fortalecimento do relacionamento e para a consolidação da confiança na marca.

2.3.4 Momento 4 — Revisão

A revisão periódica destaca-se como outro ponto crítico da jornada do cliente, pois combina percepções relacionadas ao atendimento com aspectos diretamente ligados ao produto. Nesse momento, é possível avaliar a qualidade técnica dos serviços, a agilidade do processo, a clareza das orientações e a capacidade da equipe em transmitir confiança. Além disso, esse contato fornece insumos valiosos tanto para a concessionária quanto para a fábrica, já que eventuais falhas, reclamações recorrentes ou elogios ao desempenho do veículo contribuem para melhorias contínuas no produto e nos processos internos.

2.3.5 Momento 5 — Outros Serviços

A categoria denominada “Outros Serviços” engloba todos os atendimentos que não se enquadram como revisão ou *Pitstop*, tais como pequenos reparos, serviços de funilaria, ajustes pontuais e manutenções corretivas pontuais. Além de permitir a mensuração da satisfação em serviços de menor complexidade, esse momento possibilita identificar padrões de demanda e potenciais oportunidades de criação de novos momentos específicos no futuro, conforme a relevância operacional e estratégica desses atendimentos evolua. Assim, esse grupo funciona como termômetro para serviços complementares que influenciam a percepção geral de suporte técnico oferecido pela marca.

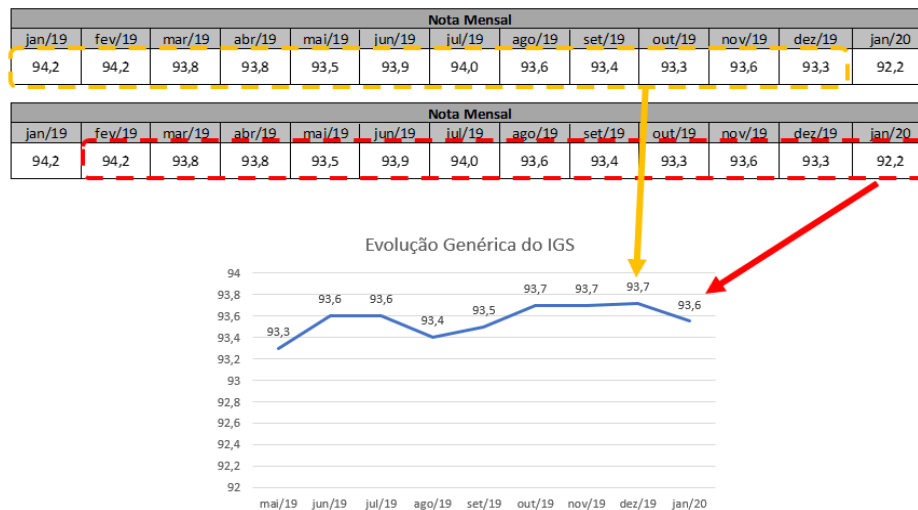
2.3.6 Momento 6 — Atendimento Emergencial

O Atendimento Emergencial encerra a gama de serviços avaliados e representa um dos pacotes mais robustos e estratégicos oferecidos pela empresa. Prestado em regime 24 horas, esse serviço envolve a atuação integrada entre uma central especializada e a concessionária mais próxima, sendo acionado em situações críticas que exigem resposta imediata. Por tratar-se de um atendimento premium e de alto valor para o cliente — tanto em confiabilidade quanto em impacto operacional —, seu monitoramento é essencial. A avaliação desse momento busca assegurar padrões elevados de agilidade, qualidade técnica e suporte, além de manter a percepção de valor associada a um dos serviços que mais geram receita dentro da estrutura de pós-venda da marca.

2.4 Limitações gerenciais do acompanhamento atual

Embora o IGS seja amplamente utilizado pela organização como principal métrica de CX, sua metodologia de cálculo baseada em uma média móvel de doze meses apresenta algumas limitações para o monitoramento gerencial. Por considerar um longo período histórico, o indicador tende a suavizar oscilações recentes, reduzindo a sensibilidade a mudanças mais abruptas na percepção dos clientes. Como mostrado no exemplo fictício do gráfico (1), é possível visualizar a média móvel na primeira tabela representada em amarelo agregando as notas mensais para a composição do IGS de dezembro de 2019 e logo em sequência ela de vermelho compondo as notas para o IGS de janeiro de 2020.

Gráfico 1 – Evolução Genérica do IGS



Fonte: Autoria própria (2026)

Neste caso fica nítido como ocorre a suavização das oscilações, onde mesmo caindo 1,1 pontos na nota entre dezembro de 2019 e janeiro de 2020 (visível nas tabelas), o monitoramento padrão do IGS apenas apontou queda de 0,1 como representado em sua *timeline* (IGS de 93,7 em dezembro de 2019 e 93,6 em janeiro de 2020). Essa queda mostrada nas notas mensais foi onze vezes maior que a representada no IGS.

Na prática, isso significa que quedas ou melhorias ocorridas nos meses mais recentes podem demorar a se refletir de forma significativa no valor final do IGS. Como consequência, problemas emergentes podem ser identificados apenas quando já produziram impacto relevante nos resultados da concessionária, reduzindo o tempo disponível para a implementação de ações corretivas.

Essa característica é especialmente relevante considerando que o indicador influencia avaliações de desempenho e programas de bonificação das concessionárias. Dessa forma, a capacidade de antecipar tendências futuras torna-se um importante diferencial para apoiar o planejamento gerencial e a tomada de decisão.

Nesse contexto, surge a motivação para o desenvolvimento de um modelo preditivo capaz de estimar o comportamento futuro do IGS a partir dos dados históricos disponíveis. A proposta não busca substituir o indicador atualmente utilizado pela organização, mas complementar sua análise, fornecendo uma visão prospectiva que auxilie na identificação antecipada de tendências e no direcionamento de ações preventivas sem consideração de sazonalidade, para se manter condizente a estrutura do indicador. Dessa forma, a previsão do IGS passa a atuar como uma ferramenta adicional de monitoramento, ampliando o potencial de utilização estratégica das informações de satisfação dos clientes.

2.5 Síntese e conclusão do capítulo

Neste capítulo foi realizada a caracterização do objeto de estudo desta pesquisa, apresentando o contexto da gestão da experiência do cliente na empresa analisada e detalhando a estrutura do IGS. Foram descritos os seis momentos da jornada do cliente utilizados na pesquisa transacional, a composição matemática do indicador, sua forma de cálculo por média móvel e sua relevância como ferramenta de acompanhamento da satisfação dos clientes e do desempenho das concessionárias.

A compreensão da composição do IGS mostrou-se essencial para o desenvolvimento desta pesquisa, pois permitiu identificar que o indicador não representa uma medida isolada, mas sim o resultado da agregação de diferentes etapas da jornada do cliente. Esse entendimento justificou a escolha que será vista em capítulos futuros de modelar inicialmente os momentos de forma individual, preservando a contribuição específica de cada etapa antes da obtenção da previsão do indicador agregado.

Além disso, a análise realizada neste capítulo evidenciou que o próprio método de cálculo do IGS, baseado em média móvel de doze meses, confere elevada estabilidade ao indicador, suavizando oscilações recentes. Essa característica influenciou diretamente as decisões metodológicas adotadas ao longo do trabalho,

tanto na construção dos modelos de previsão quanto na interpretação dos resultados obtidos, reforçando a necessidade de comparar o desempenho da abordagem proposta com modelos simples de referência.

Compreendido o funcionamento do indicador e sua importância para a gestão da experiência do cliente, torna-se necessário estabelecer os fundamentos teóricos que sustentam a metodologia empregada nesta pesquisa. Assim, o capítulo seguinte apresenta os principais conceitos relacionados à experiência do cliente, séries temporais, modelos de previsão, métricas de avaliação, estacionariedade e modelos baseados em defasagens, fornecendo o embasamento conceitual que orienta o desenvolvimento do modelo preditivo proposto.

3 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são apresentados os fundamentos teóricos que sustentam a modelagem utilizada para prever o IGS. Como o IGS apresenta comportamento dependente do tempo e é influenciado por resultados anteriores, torna-se necessário empregar modelos capazes de representar essas relações dinâmicas. Assim, discute-se o uso de estruturas com defasagens temporais, destacando sua adequação, propriedades e limitações, com finalidade de contextualizar a aplicação prática descrita nos capítulos seguintes.

3.1 Séries temporais e dependência temporal

Séries temporais são conjuntos de observações registradas sequencialmente ao longo do tempo, permitindo analisar a evolução de determinado fenômeno em diferentes períodos. Em diversos contextos, especialmente em indicadores de desempenho, os valores observados em um período tendem a apresentar relação com os valores registrados anteriormente. Segundo Box, Jenkins, Reinsel e Ljung (2015), essa dependência entre observações consecutivas constitui uma das principais características das séries temporais e representa a base para a construção de modelos de previsão.

Essa característica é conhecida como dependência temporal e indica que observações passadas podem conter informações relevantes para explicar ou estimar comportamentos futuros. Em outras palavras, o desempenho observado em um determinado mês pode ser influenciado pelos resultados obtidos nos meses anteriores, refletindo tendências, padrões ou persistências presentes na série histórica (BOX; JENKINS; REINSEL; LJUNG, 2015).

No contexto deste estudo, as médias mensais dos momentos da jornada do cliente constituem séries temporais que podem apresentar esse comportamento. Dessa forma, a utilização de informações de períodos anteriores torna-se uma alternativa viável para a construção de modelos capazes de antecipar tendências futuras do IGS.

Uma série temporal pode apresentar componentes como nível, tendência, sazonalidade e variações aleatórias. No presente estudo, devido ao tamanho reduzido da base histórica disponível e ao comportamento suavizado do IGS por média móvel de doze meses, a modelagem concentrou-se na dependência temporal de curto prazo,

representada por defasagens dos períodos imediatamente anteriores, sem incorporar explicitamente componentes sazonais e de ruídos aleatórios.

3.2 Defasagens temporais — *lags*

Uma das formas mais utilizadas para representar a dependência temporal de uma série é por meio das chamadas defasagens temporais, também conhecidas como *lags*, conforme descrito por Box, Jenkins, Reinsel e Ljung (2015). Uma defasagem corresponde ao valor observado da variável em períodos anteriores, permitindo que informações históricas sejam utilizadas para explicar ou prever comportamentos futuros.

Matematicamente, as defasagens utilizadas de um dado momento $\{M\}_{\{i,t\}}$ neste estudo podem ser representadas pela equação (3):

$$\{M\}_{\{i,t\}} = f(M_{\{i,t-1\}}, M_{\{i,t-2\}}, M_{\{i,t-3\}}) \quad (3)$$

Onde i representa um determinado momento da jornada do cliente, t corresponde ao período atual, já os valores com índices negativos, como $M_{i,t-1}$, $M_{i,t-2}$ e $M_{i,t-3}$, indicam defasagens temporais, ou seja, quantos períodos anteriores ao período t estão sendo considerados. Dessa forma, de maneira exemplificada, para estimar o comportamento do momento M_i em determinado mês t , pode-se criar uma modelagem baseada na média simples dos valores observados nos dois períodos imediatamente anteriores. Nesse caso, utilizam-se os *lags* correspondentes a $t-1$ e $t-2$, conforme expresso na equação (4):

$$\{M\}_{\{i,t\}} = \frac{\{M_{\{t-1\}} + M_{\{t-2\}}\}}{2} \quad (4)$$

A utilização de *lags* permite incorporar ao modelo a chamada memória recente da série, ou seja, a influência que os resultados mais próximos exercem sobre os valores futuros. Em indicadores de satisfação, essa abordagem é particularmente relevante, pois a percepção dos clientes tende a apresentar continuidade ao longo do tempo, fazendo com que desempenhos recentes sejam bons indicativos do comportamento esperado nos períodos subsequentes.

Assim, ao utilizar as defasagens $M_{i,t-1}$ e $M_{i,t-2}$, o modelo passa a considerar explicitamente o histórico recente de cada momento da jornada, capturando tendências e reduzindo a dependência de informações externas mais complexas.

Essa característica contribui para a construção de um modelo simples, interpretável e adequado ao volume de dados disponível para a pesquisa.

3.3 Modelos autorregressivos simples e modelos empíricos com defasagens

Uma das abordagens mais tradicionais para previsão de séries temporais consiste na utilização de modelos autorregressivos, nos quais os valores futuros de uma variável são estimados a partir de seus próprios valores observados em períodos anteriores. A premissa fundamental desses modelos é que o comportamento passado da série contém informações relevantes para explicar sua evolução futura, especialmente quando existe dependência temporal entre as observações.

De forma geral, um modelo autorregressivo pode ser representado pela utilização de defasagens da própria variável de interesse como variáveis explicativas. Assim, o valor observado em um determinado período é estimado a partir dos valores registrados em períodos anteriores, permitindo capturar tendências e padrões de persistência existentes na série temporal.

Segundo Box, Jenkins, Reinsel e Ljung (2015), a utilização de observações passadas para explicar valores futuros constitui um dos fundamentos da modelagem de séries temporais, sendo amplamente empregada em aplicações de previsão devido à sua simplicidade conceitual e capacidade de representar a dinâmica temporal dos dados. Os autores destacam que a dependência entre observações consecutivas frequentemente fornece informação suficiente para gerar previsões úteis em diversos contextos organizacionais.

Neste trabalho, os conceitos de séries temporais são utilizados de forma empírica e aplicada, com foco na exploração da dependência entre observações mensais consecutivas. Não se pretende realizar uma modelagem estatística formal completa, como ARIMA (*Autoregressive Integrated Moving Average*), SARIMA (*Seasonal ARIMA*) ou ARDL (*Autoregressive Distributed Lag*), mas sim utilizar a lógica de defasagens temporais para construir modelos simples, interpretáveis e compatíveis com a quantidade limitada de dados disponível.

Essa abordagem apresenta vantagens importantes para o contexto da pesquisa, como simplicidade de implementação, facilidade de interpretação e adequação ao volume de dados disponível. Além disso, permite a construção de modelos transparentes e facilmente reproduzíveis em ferramentas de uso corporativo, favorecendo sua aplicação prática no acompanhamento e na previsão do IGS.

3.4 Modelos multivariáveis e limitação em bases curtas

Em problemas de previsão, é comum considerar modelos multivariáveis, nos quais diferentes variáveis são utilizadas simultaneamente para explicar o comportamento da variável de interesse. No contexto deste estudo, essa abordagem poderia ser representada pela utilização conjunta dos diversos momentos da jornada do cliente e de suas respectivas defasagens temporais como variáveis explicativas para a previsão das notas futuras de satisfação.

Embora modelos multivariáveis tenham potencial para capturar relações mais complexas entre os dados, sua aplicação exige cuidados quando a quantidade de observações disponíveis é limitada. Segundo Gujarati e Porter (2011), a utilização de muitas variáveis explicativas em amostras reduzidas pode aumentar significativamente a ocorrência de problemas estatísticos, especialmente a multicolinearidade, caracterizada pela elevada correlação entre variáveis independentes.

Em situações nas quais diferentes variáveis apresentam comportamentos semelhantes ao longo do tempo, torna-se difícil para o modelo identificar a contribuição individual de cada uma delas. Como consequência, os coeficientes estimados podem apresentar elevada instabilidade, tornando as previsões mais sensíveis a pequenas variações na base de dados. Além disso, o excesso de parâmetros em relação ao número de observações disponíveis pode levar ao fenômeno conhecido como sobreajuste (*overfitting*) conforme descrito na literatura de aprendizado estatístico (James, Witten, Hastie e Tibshirani, 2021), situação em que o modelo se adapta excessivamente aos dados históricos utilizados no treinamento, mas perde capacidade de generalização para períodos futuros.

Segundo James, Witten, Hastie e Tibshirani (2021), modelos excessivamente complexos nem sempre resultam em melhores previsões, especialmente quando a quantidade de dados disponível é limitada. Nesses casos, abordagens mais simples frequentemente apresentam desempenho semelhante ou superior, além de proporcionarem maior interpretabilidade e robustez.

Dessa forma, embora uma estrutura multivariável tenha sido considerada durante o desenvolvimento desta pesquisa, as características da base histórica disponível indicaram a necessidade de avaliar alternativas mais simples e parcimoniosas. Essa decisão metodológica buscou reduzir riscos de

multicolinearidade e sobreajuste, priorizando modelos com maior estabilidade, facilidade de interpretação e melhor capacidade de aplicação prática no contexto estudado. Quanto menor o número de observações, maior deve ser o cuidado com modelos que utilizam muitas variáveis explicativas. Em séries curtas, modelos com muitos parâmetros podem apresentar bom ajuste aos dados históricos, mas desempenho ruim em dados futuros. Por esse motivo que no subitem 5.5 o modelo mais simples seguiu a diante com menor erro médio em relação ao modelo mais robusto.

3.5 Modelos de referência para validação

A avaliação de um modelo preditivo torna-se mais consistente quando seus resultados são comparados com métodos simples de previsão, conhecidos como modelos de referência (*benchmarks*) conforme descrito por Hyndman e Athanasopoulos (2021). Essa comparação permite verificar se a modelagem proposta realmente agrega capacidade preditiva em relação a abordagens básicas.

Entre os principais modelos de referência destacam-se o último valor observado, que considera a próxima observação igual ao valor mais recente disponível; a média dos dois últimos períodos, utilizada para reduzir oscilações pontuais; a média móvel, que suaviza variações de curto prazo por meio da média de observações anteriores; e a tendência linear simples, que projeta valores futuros a partir do comportamento histórico da série.

A comparação entre o modelo desenvolvido e esses métodos de referência permite avaliar se a abordagem proposta oferece ganhos reais de precisão, justificando sua utilização no contexto da previsão do IGS.

3.6 Métricas de avaliação dos modelos preditivos

A avaliação de modelos preditivos requer a utilização de métricas que permitam quantificar a diferença entre os valores previstos e os valores efetivamente observados, conforme descrito por Hyndman e Athanasopoulos (2021). Entre as métricas mais utilizadas na literatura destacam-se o Erro Absoluto Médio (*Mean Absolute Error – MAE*), o Erro Quadrático Médio (*Root Mean Square Error – RMSE*) e o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error – MAPE*).

O MAE representa a média dos erros absolutos entre os valores reais e previstos, sendo expresso na mesma unidade da variável analisada. Sua formulação é dada pela equação (3):

$$MAE = \left(\frac{1}{n}\right) \sum_{t=1}^n |Y_t - (Yp)_t| \quad (3)$$

Em que (Y_t) representa o valor real observado, (Yp) corresponde ao valor previsto e (n) ao número de observações avaliadas. Essa métrica permite interpretar diretamente o erro médio em pontos da variável analisada.

Já o RMSE representa a raiz quadrada da média dos erros quadráticos entre os valores reais e previstos. Diferentemente do MAE, essa métrica penaliza mais fortemente erros maiores, já que os desvios são elevados ao quadrado antes da média. Sua formulação é dada pela equação (4):

$$RMSE = \sqrt{\left\{ \frac{1}{n} \sum_{t=1}^n (Y_t - \widehat{Y}_t)^2 \right\}} \quad (4)$$

Em que (Y_t) representa o valor real observado, \widehat{Y}_t corresponde ao valor previsto pelo modelo e n ao número total de observações avaliadas. Essa métrica fornece uma medida da magnitude média dos erros, expressa na mesma unidade da variável analisada, permitindo avaliar a precisão do modelo de forma mais sensível a grandes discrepâncias.

Por sua vez, o MAPE expressa o erro em termos percentuais, permitindo avaliar a precisão do modelo independentemente da escala dos dados. Sua formulação é apresentada pela equação (5):

$$MAPE = \left(\frac{100}{n}\right) \sum_{t=1}^n \left| \frac{Y_t - (Y)_p}{Y_t} \right| \quad (5)$$

O resultado é apresentado em percentual, indicando quanto, em média, a previsão se distancia do valor real observado.

Embora estas três métricas sejam amplamente utilizadas na avaliação de modelos de previsão, neste estudo optaremos pela utilização do MAPE como principal critério de comparação entre os modelos testados. Essa escolha foi motivada pela maior facilidade de interpretação dos resultados sob a ótica gerencial, uma vez que o

erro percentual permite comparar o desempenho das previsões entre diferentes momentos da jornada do cliente e do próprio IGS de forma padronizada.

Dessa forma, o MAE e o RMSE foram considerados como métrica complementar no referencial teórico, enquanto o MAPE foi adotado como principal indicador de desempenho durante a etapa de validação dos modelos desenvolvidos, servindo como base para a seleção da alternativa com melhor capacidade preditiva. Porém como o IGS apresenta valores elevados e baixa amplitude de variação, o MAPE tende a gerar percentuais reduzidos. Por essa razão, sua interpretação deve ser acompanhada da análise dos erros absolutos e da comparação com modelos de referência, evitando conclusões baseadas apenas no valor percentual do erro.

3.7 Análise estacionária

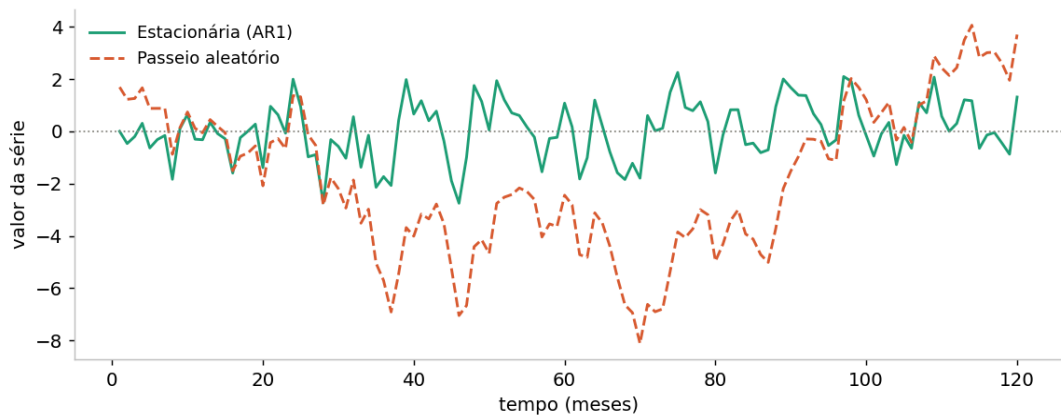
A estacionariedade é uma das propriedades fundamentais no estudo de séries temporais e está diretamente relacionada à estabilidade estatística dos dados ao longo do tempo. De forma geral, uma série temporal é considerada estacionária quando suas principais características, como média, variância e estrutura de autocorrelação, permanecem aproximadamente constantes durante todo o período de observação. Em outras palavras, o comportamento estatístico da série não depende do instante em que ela é observada, permitindo que padrões identificados no passado possam ser utilizados para explicar ou estimar valores futuros (BOX; JENKINS; REINSEL; LJUNG, 2015).

A importância dessa propriedade está no fato de que grande parte dos modelos de previsão baseados em séries temporais pressupõe que o comportamento observado no passado permanece relativamente estável ao longo do tempo. Quando essa condição é satisfeita, torna-se possível utilizar observações históricas como fonte de informação para estimar valores futuros. Em contrapartida, séries não estacionárias apresentam alterações em suas propriedades estatísticas, dificultando a identificação de padrões consistentes e reduzindo a confiabilidade das previsões (GUJARATI; PORTER, 2011).

Um exemplo clássico de série estacionária é o processo autorregressivo de primeira ordem (AR(1)), no qual os valores oscilam continuamente em torno de uma média constante e apresentam variabilidade aproximadamente estável. Em oposição, o passeio aleatório (*random walk*) representa um processo não estacionário, caracterizado pelo acúmulo sucessivo de choques aleatórios, fazendo com que sua

trajetória se afaste progressivamente da média e apresente crescimento contínuo da variância ao longo do tempo.

Gráfico 2 – Comparação entre uma série estacionária (AR(1)) e um passeio aleatório



Fonte: Autoria própria (2026)

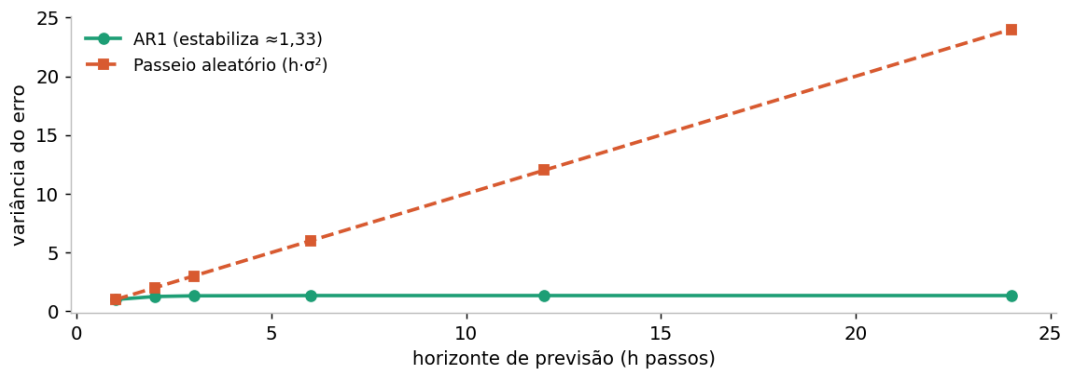
Conforme ilustrado no gráfico (2), observa-se que a série estacionária mantém média e variância aproximadamente constantes durante todo o período analisado, enquanto o passeio aleatório apresenta mudanças graduais nessas propriedades estatísticas, caracterizando um comportamento não estacionário. Essa diferença pode ser percebida tanto visualmente quanto por meio da comparação entre as duas séries, evidenciando que apenas a série estacionária preserva um comportamento consistente ao longo do tempo.

Além da análise gráfica, a verificação da estacionariedade pode ser realizada por meio de testes estatísticos específicos. Entre os mais utilizados destacam-se o teste Dickey-Fuller Aumentado (ADF) e o teste Kwiatkowski-Phillips-Schmidt-Shin (KPSS). O teste ADF possui como hipótese nula a existência de raiz unitária, indicando que a série não é estacionária. Assim, valores de *p-value* inferiores ao nível de significância adotado permitem rejeitar essa hipótese e concluir pela estacionariedade da série. Por outro lado, o teste KPSS utiliza hipótese nula oposta, assumindo inicialmente que a série é estacionária. Dessa forma, valores elevados de *p-value* indicam que não existem evidências suficientes para rejeitar essa hipótese (GUJARATI; PORTER, 2011).

A utilização conjunta desses dois testes proporciona uma avaliação mais robusta da estacionariedade, uma vez que suas hipóteses nulas são complementares. Dessa forma, os resultados podem ser interpretados de maneira integrada, reduzindo a possibilidade de conclusões equivocadas decorrentes da utilização isolada de apenas um dos testes.

A estacionariedade também exerce influência direta sobre a qualidade das previsões. Em séries estacionárias, a variância do erro de previsão tende a crescer apenas nos primeiros horizontes e posteriormente estabiliza-se em um limite máximo. Em séries não estacionárias, entretanto, essa variância cresce continuamente conforme aumenta o horizonte de previsão, tornando estimativas de longo prazo progressivamente menos confiáveis (Hyndman e Athanasopoulos, 2021).

Gráfico 3 - Crescimento da variância do erro de previsão para séries estacionárias e não estacionárias



Fonte: Autoria própria (2026)

O gráfico (3) demonstra esse comportamento. Enquanto séries estacionárias apresentam erro limitado ao longo do horizonte de previsão, séries não estacionárias acumulam incerteza continuamente, dificultando a obtenção de previsões confiáveis para períodos mais distantes.

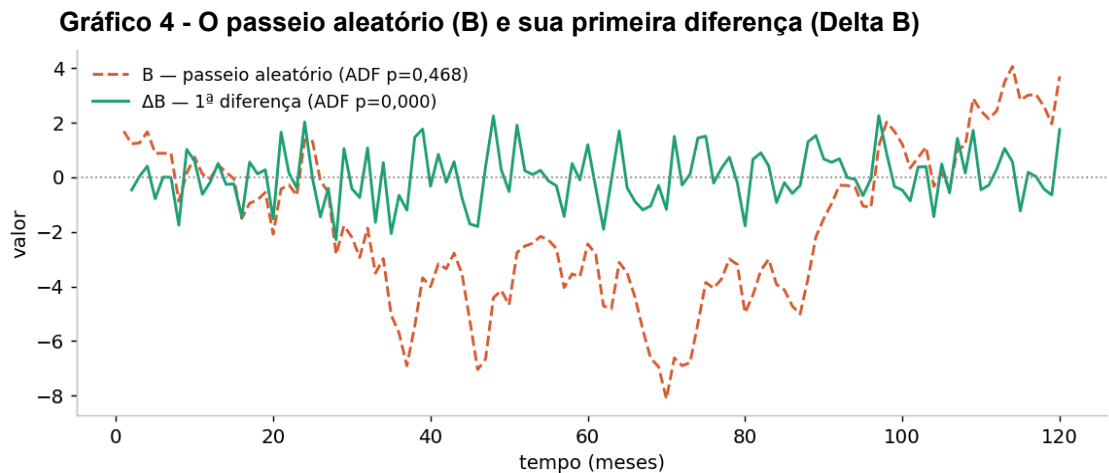
Quando uma série apresenta comportamento não estacionário, é comum aplicar transformações antes da etapa de modelagem. Dentre essas transformações, a diferenciação constitui uma das técnicas mais utilizadas, consistindo na substituição dos valores originais pelas diferenças entre observações consecutivas. Esse procedimento reduz tendências acumuladas e estabiliza as propriedades estatísticas da série, tornando-a mais adequada para modelagem (BOX; JENKINS; REINSEL; LJUNG, 2015).

A primeira diferença pode ser representada pela equação (5):

$$\Delta X_{\{t\}} = X_{\{t\}} - X_{\{t-1\}} \quad (5)$$

Após a aplicação da diferenciação, uma série originalmente não estacionária pode passar a apresentar comportamento aproximadamente estacionário, tornando possível a utilização de modelos de previsão que pressupõem estabilidade temporal. Esse procedimento constitui a base do componente de integração presente nos modelos ARIMA, em que o parâmetro d representa exatamente o número de

diferenciações necessárias para tornar a série estacionária (BOX; JENKINS; REINSEL; LJUNG, 2015).



Fonte: Autoria própria (2026)

O gráfico (4) ilustra esse efeito, evidenciando que a primeira diferença elimina o comportamento acumulativo presente no passeio aleatório e produz uma série que oscila em torno de uma média aproximadamente constante, característica compatível com a estacionariedade.

Após compreender os conceitos de estacionariedade e as principais formas de tratamento das séries temporais, torna-se importante interpretar corretamente os resultados obtidos pelos testes estatísticos. Como o teste ADF e o teste KPSS possuem hipóteses nulas distintas, sua utilização conjunta fornece um diagnóstico mais consistente sobre as propriedades da série temporal e auxilia na definição da estratégia de modelagem mais adequada.

Quadro 1 - Análise ADF e KPSS

Resultado dos testes	Diagnóstico	Ação recomendada
ADF $p < 0,05$ e KPSS $p > 0,05$	Estacionária	Modelar a série em nível. Podem ser empregados modelos baseados em defasagens diretamente sobre a série.
ADF $p > 0,05$ e KPSS $p < 0,05$	Não estacionária (raiz unitária)	Aplicar a primeira diferença da série e realizar nova avaliação da estacionariedade.
ADF $p < 0,05$ e KPSS $p < 0,05$	Estacionária com tendência	Remover a tendência (<i>detrending</i>) e, em seguida, modelar a série residual.
ADF $p > 0,05$ e KPSS $p > 0,05$	Inconclusivo	Podem ocorrer em séries curtas, devendo os resultados ser interpretados com cautela e complementados por comparação com modelos de referência.

Fonte: Aatoria própria (2026)

O quadro (1) apresenta as principais combinações possíveis entre os resultados dos testes ADF e KPSS, bem como suas respectivas interpretações e implicações para a construção de modelos de previsão. Em situações em que ambos os testes indicam estacionariedade, a série pode ser utilizada diretamente em modelos baseados em defasagens. Quando os resultados apontam para a presença de raiz unitária, recomenda-se inicialmente aplicar a primeira diferença da série e realizar nova avaliação da estacionariedade. Também podem ocorrer situações em que a série apresenta estacionariedade em torno de uma tendência determinística ou resultados inconclusivos, especialmente em bases históricas reduzidas, devendo nesses casos a interpretação ser realizada com cautela e recomenda-se análises adicionais.

3.8 Considerações sobre ARDL

Os modelos *Autoregressive Distributed Lag* (ARDL) constituem uma classe de modelos amplamente utilizada na análise de séries temporais, caracterizando-se pela utilização simultânea de defasagens da variável dependente e de variáveis explicativas para descrever a dinâmica temporal de um fenômeno, conforme proposto por Pesaran, Shin e Smith (2001). Sua principal característica consiste em representar tanto os efeitos passados da própria variável de interesse quanto a influência de outras variáveis ao longo do tempo. O modelo ARDL geral pode ser expresso como na equação (5):

$$Y_t = \alpha_0 + \sum_{i=1}^p \phi_i Y_{t-i} + \sum_{j=1}^k \sum_{r=0}^{q_j} \beta_{jr} X_{j,t-r} + \varepsilon_t \quad (5)$$

onde:

- Y_t : variável dependente no tempo t ;
- ϕ_i : coeficientes das defasagens autoregressivas;
- $X_{j,t-r}$: defasagens das variáveis explicativas;
- β_{jr} : coeficientes das defasagens distribuídas;

- p : ordem autoregressiva;
- q_j : número de defasagens para cada variável explicativa;
- ε_t : termo de erro aleatório.

A literatura destaca que os modelos ARDL apresentam vantagens como flexibilidade de especificação, interpretação relativamente simples dos coeficientes e capacidade de capturar relações temporais entre variáveis em diferentes horizontes de tempo (Pesaran, Shin e Smith, 2001). Entretanto, sua aplicação formal exige cuidados relacionados ao tamanho da amostra, à seleção adequada das defasagens e à estabilidade estatística dos parâmetros estimados.

No presente estudo, a lógica de utilização de defasagens serviu como inspiração metodológica para a construção inicial dos modelos de previsão. Em um primeiro momento, foram consideradas estruturas multivariáveis contendo diferentes *lags* dos momentos da jornada do cliente, buscando reproduzir a ideia central dos modelos com defasagens distribuídas.

Contudo, devido à quantidade limitada de observações históricas disponíveis e aos problemas de instabilidade observados nos resultados iniciais, optou-se por uma abordagem empírica simplificada. Essa decisão permitiu reduzir a complexidade da modelagem, minimizar efeitos de multicolinearidade e aumentar a robustez das previsões obtidas.

Dessa forma, o modelo final desenvolvido não deve ser interpretado como uma aplicação formal da metodologia ARDL, mas sim como uma solução empírica baseada em defasagens temporais, inspirada nos princípios desses modelos e adaptada às características e limitações da base de dados utilizada. Tal escolha mostrou-se mais compatível com o caráter aplicado do trabalho e com o objetivo de desenvolver uma ferramenta simples, interpretável e passível de implementação em ambiente gerencial.

3.9 Síntese e conclusão do capítulo

Neste capítulo foram apresentados os principais fundamentos teóricos que sustentam o desenvolvimento desta pesquisa. Inicialmente, discutiu-se a importância da gestão da experiência do cliente e dos indicadores de satisfação como instrumentos de apoio à tomada de decisão. Em seguida, foram abordados os conceitos relacionados às séries temporais, dependência temporal, modelos

multivariáveis, estacionariedade, testes estatísticos, métricas de avaliação de desempenho e modelos baseados em defasagens, fornecendo a base conceitual necessária para a construção e avaliação dos modelos de previsão propostos.

A fundamentação teórica permitiu compreender que a previsão de indicadores temporais depende tanto das características da série histórica quanto da escolha de uma metodologia compatível com a disponibilidade e a qualidade dos dados. Os conceitos apresentados evidenciaram que modelos excessivamente complexos nem sempre produzem melhores resultados, especialmente em bases históricas reduzidas, reforçando a importância da parcimônia, da interpretabilidade e da validação por meio de métricas objetivas de desempenho.

Além disso, os referenciais estudados forneceram suporte para as principais decisões metodológicas adotadas ao longo da pesquisa. A utilização de defasagens temporais, a aplicação dos testes de estacionariedade, a escolha do MAPE como principal métrica de comparação entre modelos e a avaliação frente a modelos simples de referência foram diretamente fundamentadas pelos conceitos discutidos neste capítulo, garantindo coerência entre a literatura e o desenvolvimento prático do trabalho.

Com os fundamentos teóricos estabelecidos, o capítulo seguinte apresenta a metodologia empregada na pesquisa. Nele são descritos o delineamento metodológico, a caracterização da pesquisa, a seleção e preparação da base de dados, as alternativas de modelagem desenvolvidas, os procedimentos de validação e as limitações metodológicas consideradas, estabelecendo a estrutura que orienta toda a etapa de desenvolvimento e avaliação dos modelos preditivos.

4 METODOLOGIA PARA DESENVOLVIMENTO DO MODELO PREDITIVO

Esta seção apresenta os procedimentos metodológicos adotados para o desenvolvimento e avaliação preliminar do modelo preditivo do IGS, contemplando a fonte de dados, os critérios de seleção da unidade analisada, o tratamento da base, a estruturação das variáveis, as alternativas de modelagem, o procedimento de validação temporal e os critérios de comparação dos resultados.

4.1 Fonte e seleção de dados

Os dados utilizados neste estudo foram extraídos das pesquisas transacionais de satisfação realizadas pela empresa por meio de um *call center* terceirizado. Cada entrevista contém:

- nota atribuída pelo cliente em escala de 0 a 10;
- momento da jornada associado (Vendas, Um Ano e Meio, *Pitstop*, Revisão, Outros Serviços, Atendimento Emergencial);
- data da interação;
- concessionária responsável.

Em conformidade com a Lei Geral de Proteção de Dados (Lei nº 13.709/2018), os registros qualitativos de justificativas abertas não foram incluídos na modelagem, restringindo a análise aos valores numéricos.

Após a coleta, procedeu-se à limpeza dos dados, removendo:

- entrevistas fora do prazo do gatilho;
- registros inconsistentes;
- contatos incorretos ou duplicados;
- respostas que violavam critérios mínimos de qualidade.

Os dados válidos foram então consolidados em uma única base contendo médias mensais de satisfação para cada um dos seis momentos avaliados, devidamente formatada para importação para softwares para análise de dados. Um resumo a respeito da quantidade de dados de entrevista que passaram por esta seleção e descarte está no subitem 5.1.

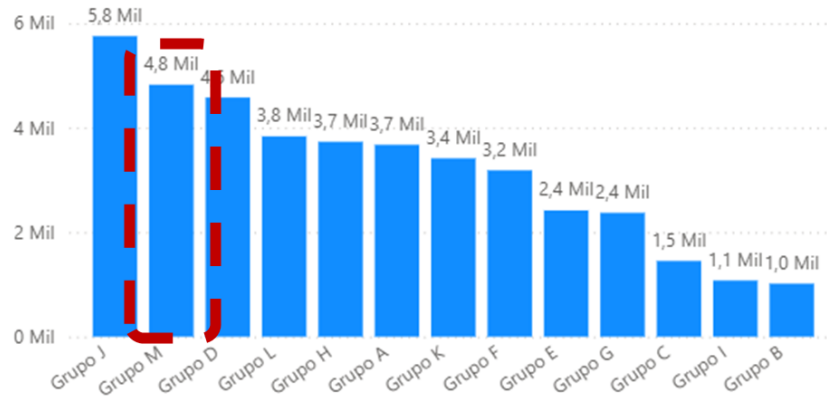
4.2 Seleção da unidade para análise

Entre as 13 concessionárias avaliadas, selecionou-se a Concessionária M como unidade de estudo, considerando:

- volume expressivo de entrevistas (4.822 no período analisado);
- série histórica completa entre outubro de 2023 e março de 2025;
- desempenho oscilando próximo à meta corporativa;
- variabilidade suficiente para calibrar o modelo.


Essa seleção, que foi norteadada pela distribuição volumétrica de pesquisas e pela evolução do IGS representadas nos gráficos (5) e (6), segue os critérios para escolha de um exemplo que agregue ao estudo.

Gráfico 5 - Distribuição volumétrica de pesquisas (out23-mar25)



Fonte: Autoria própria (2026)

Gráfico 6 - Evolução do IGS da Concessionária M (out23-mar25)



Fonte: Autoria própria (2026)

Conforme os critérios de seleção de concessionária, o grupo M se destaca por conter a segunda maior volumetria de pesquisas no período analisado, além disto observando o comportamento de sua *timeline* do IGS, nota-se um cenário de interesse para o estudo por estar em queda e próximo a meta de 93 de bonificação.

4.3 Estruturação das variáveis

A modelagem considerou:

Variável resposta

- IGS mensal, calculado pela média ponderada dos seis momentos,

Variáveis explicativas

- Médias mensais de cada momento da jornada do cliente (M1 – Vendas, M2 – Um ano e Meio, M3 – *Pitstop*, M4 – Revisão, M5 – Outros Serviços e M6 – Atendimento Emergencial),

Componentes temporais com períodos mensais (defasagens calculadas para cada momento seguindo a divisão feita pela figura (1) – Linha de Tempo dos *Lags*)

- defasagem (*lag*) do próprio momento (*lags* 1, 2 e 3);
- defasagem (*lag*) cruzada dos demais momentos (*lag* 1).



Fonte: Autoria própria (2026)

Essa estrutura permite capturar simultaneamente a memória temporal do próprio momento, a influência entre etapas da jornada e os efeitos de curto e médio prazo sobre o IGS a depender da modelagem.

Quadro 2 - Variáveis para Modelagem

Variável	Descrição	Tipo	Uso no modelo
$M_{\{1,t\}}$	Nota média mensal de Vendas	Explicativa	Composição do IGS e previsão
$M_{\{2,t\}}$	Nota média mensal de Um Ano e Meio de Uso	Explicativa	Composição do IGS e previsão
$M_{\{3,t\}}$	Nota média mensal de Pitstop	Explicativa	Composição do IGS e previsão
$M_{\{4,t\}}$	Nota média mensal de Revisão	Explicativa	Composição do IGS e previsão
$M_{\{5,t\}}$	Nota média mensal de Outros Serviços	Explicativa	Composição do IGS e previsão
$M_{\{6,t\}}$	Nota média mensal de Atendimento Emergencial	Explicativa	Composição do IGS e previsão
IGS _t	Indicador Geral de Satisfação no mês t	Resposta	Indicador final previsto

Fonte: Autoria própria (2026)

O quadro (2) resume quais são as variáveis, seu tipo e finalidade na utilização na modelagem, tendo uma variável resposta e outras seis explicativas originárias dos momentos de pesquisa.

4.4 Alternativas de modelagem testadas

Com o objetivo de identificar a abordagem mais adequada para a previsão das notas dos momentos da jornada do cliente e, conseqüentemente, do IGS, foram avaliadas diferentes estruturas de modelagem. As alternativas foram desenvolvidas de forma incremental, permitindo comparar seus desempenhos e selecionar a solução mais adequada para as características da base de dados disponível.

4.4.1 Modelo 1 – Estrutura multivariável inicial

A primeira abordagem testada foi baseada em uma estrutura multivariável inspirada na lógica de modelos com defasagens distribuídas. Nessa configuração, cada momento da jornada era explicado simultaneamente por seus próprios *lags* e por *lags* provenientes dos demais momentos avaliados na pesquisa transactional conforme apresentado na equação (6):

$$M_{i,t} = \alpha_i + \beta_{i1}M_{i,t-1} + \beta_{i2}M_{i,t-2} + \beta_{i3}M_{i,t-3} + \sum_{j \neq i} \gamma_{ij}M_{j,t-1} + \varepsilon_{i,t} \quad (6)$$

onde:

- $M_{i,t-k}$: valores defasados do próprio momento;
- $M_{j,t-1}$: valores dos demais momentos no mês anterior;
- α_i : intercepto;
- β e γ : coeficientes estimados;
- $\varepsilon_{i,t}$: termo de erro aleatório.

Essa alternativa representou a hipótese inicial do estudo, buscando capturar possíveis relações temporais entre diferentes etapas da jornada do cliente. Entretanto, a elevada quantidade de variáveis e *lags* em relação ao tamanho da amostra traz o risco de instabilidade dos coeficientes por conta de multicolinearidade, tendo assim a possibilidade de ter erros médios maiores que o esperado. Assim, é motivado a simplificação da modelagem.

4.4.2 Modelo 2 – Estrutura autorregressiva por momento

A segunda alternativa consistiu na construção de um modelo preditivo para para o momento da jornada, utilizando exclusivamente suas próprias defasagens temporais como variáveis explicativas, conforme mostrado na equação (7):

$$M_t = \beta_0 + \beta_1 M_{\{t-1\}} + \beta_2 M_{\{t-2\}} \quad (7)$$

Nessa abordagem, cada nota mensal passou a ser prevista a partir dos seus valores observados em períodos anteriores, reduzindo a complexidade da estrutura e eliminando os efeitos decorrentes da multicolinearidade entre diferentes momentos da pesquisa. Os resultados apresentaram melhora em relação ao modelo inicial.

4.4.3 Modelo 3 – Estrutura simplificada com média dos dois últimos períodos

A terceira alternativa consistiu em uma simplificação adicional da estrutura autorregressiva. Em vez de utilizar múltiplas defasagens como variáveis independentes, cada previsão passou a ser realizada a partir da média dos dois períodos imediatamente anteriores, sendo representado na equação (8):

$$M_t = \beta_0 + \beta_1 * \frac{\{M_{\{t-1\}} + M_{\{t-2\}}\}}{2} \quad (8)$$

Essa abordagem introduz um efeito de suavização sobre as oscilações de curto prazo, reduzindo a sensibilidade do modelo a variações pontuais e contribuindo para maior estabilidade das previsões. Os resultados obtidos tendem a possuir menor erro médio entre as alternativas testadas, motivo pelo qual essa estrutura foi selecionada como modelo final para a previsão das notas dos momentos e do IGS.

4.4.4 Modelos de referência

Além dos modelos desenvolvidos, foram considerados dois métodos simples de previsão utilizados como referência para avaliação dos resultados obtidos como recomendado por Hyndman e Athanasopoulos (2021).

O primeiro deles foi o modelo ingênuo (*naïve forecast*), no qual o valor previsto para o próximo período é igual ao último valor observado do indicador.

Também foi considerada a média móvel simples, que utiliza a média dos dois períodos anteriores para gerar a previsão seguinte, reduzindo oscilações de curto prazo.

A comparação entre as alternativas desenvolvidas e os modelos de referência constituiu a base para a seleção do modelo final adotado neste estudo.

4.5 Critério de comparação

Para comparar o desempenho das diferentes alternativas de modelagem desenvolvidas neste estudo, adotou-se como métrica de avaliação o Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error – MAPE*) sendo essa uma das recomendações segundo Hyndman e Athanasopoulos (2021). A escolha dessa métrica foi motivada pela necessidade de avaliar os erros de previsão de forma padronizada e facilmente interpretável no contexto gerencial da organização.

Diferentemente de métricas expressas na unidade original da variável, o MAPE apresenta o erro em termos percentuais, permitindo comparar diretamente previsões realizadas para diferentes momentos da jornada do cliente, independentemente de pequenas variações em suas magnitudes. Além disso, a interpretação dos resultados torna-se mais intuitiva para os usuários do modelo, uma vez que o percentual de erro representa diretamente o quanto a previsão se afastou do valor real observado.

No presente estudo, o cálculo do MAPE foi realizado por meio da comparação entre os valores previstos pelos modelos e os valores reais observados nos períodos utilizados para validação temporal. Dessa forma, foi possível mensurar a capacidade de cada abordagem em reproduzir o comportamento efetivamente registrado nas pesquisas de satisfação.

A utilização do MAPE também se mostrou adequada devido à natureza dos dados analisados, cujas notas apresentam valores positivos e relativamente estáveis ao longo do tempo. Assim, o erro percentual médio constituiu o principal critério para seleção do modelo final, permitindo identificar a alternativa que apresentou maior precisão preditiva em relação aos dados reais da concessionária estudada.

4.6 Procedimento de validação

A validação dos modelos foi realizada por meio de uma abordagem temporal, preservando a ordem cronológica dos dados observados, conforme recomendado por Hyndman e Athanasopoulos (2021). Diferentemente de técnicas que embaralham as observações para formação dos conjuntos de treino e teste, optou-se por manter a sequência temporal da série, uma vez que o objetivo do estudo consiste justamente em prever valores futuros a partir de informações históricas.

Inicialmente, a validação foi conduzida utilizando apenas um dos momentos da jornada do cliente, permitindo avaliar o comportamento das diferentes estruturas de modelagem (1,2 e 3) em um cenário controlado. Na sequência foi feita a identificação da modelagem com melhor desempenho (menor erro médio se comparado aos valores reais), o modelo eleito, por fim, gerou as previsões dos demais momentos, das Notas Mensais futuras e o IGS a partir destas previsões. Além disso, os resultados obtidos pelo modelo escolhido foram comparados com modelos de referência, permitindo verificar se a abordagem desenvolvida apresentava ganho preditivo em relação a métodos básicos de previsão.

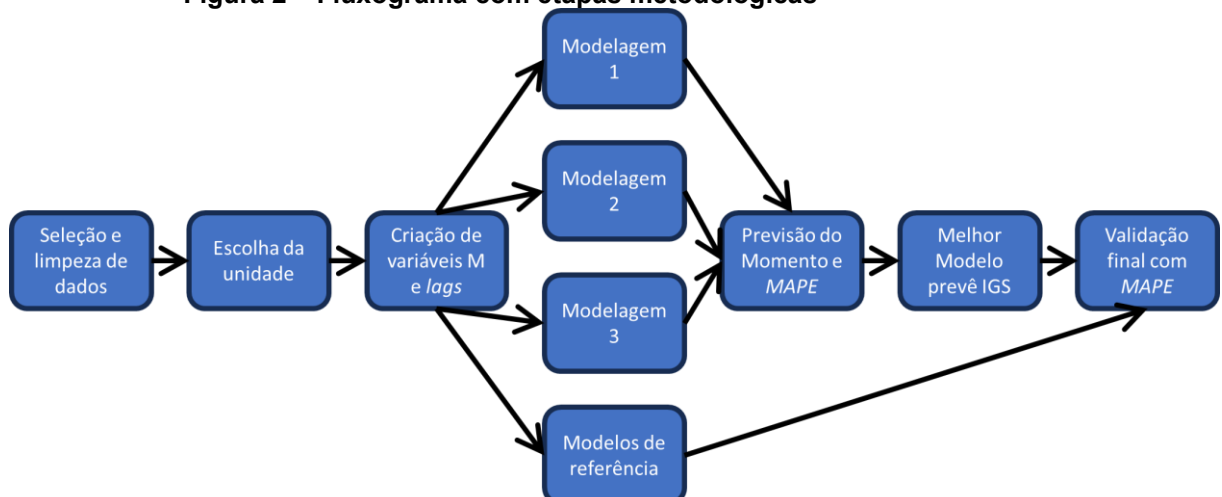
Para a construção dos modelos, os dados históricos de outubro de 2023 até janeiro de 2025 foram utilizados para treinamento, enquanto os dois meses subsequentes foram reservados para teste. Dessa forma, as previsões geradas para fevereiro e março de 2025 puderam ser comparadas diretamente com os valores reais observados, simulando uma situação prática de utilização do modelo.

A avaliação concentrou-se em previsões de curto horizonte, adequadas às características da base disponível e ao objetivo de antecipar tendências de satisfação com antecedência suficiente para apoiar ações gerenciais.

Cabe destacar que a quantidade limitada de observações históricas impõe restrições à generalização dos resultados. Por esse motivo, os testes realizados devem ser interpretados como uma validação preliminar da metodologia proposta, fornecendo evidências iniciais de sua aplicabilidade prática, mas não caracterizando uma validação estatística exaustiva ou definitiva do modelo.

Em resumo, as etapas metodológicas se resumem nestes blocos presentes na figura (2):

Figura 2 – Fluxograma com etapas metodológicas



Fonte: Aatoria própria (2026)

4.7 Limitação metodológica

Os resultados obtidos neste estudo devem ser interpretados considerando algumas limitações inerentes à base de dados e à abordagem adotada. A primeira delas refere-se à extensão da série histórica disponível, composta por um número relativamente reduzido de observações mensais. Embora a base contenha 4.822 entrevistas válidas, a modelagem preditiva foi realizada a partir de médias mensais dos momentos da jornada do cliente. Portanto, a unidade temporal efetivamente utilizada no modelo corresponde ao mês, resultando em uma série histórica com aproximadamente 18 observações mensais no período analisado.

Outra limitação está relacionada ao escopo do estudo, que foi desenvolvido a partir de dados de uma única concessionária da rede analisada. Dessa forma, os resultados obtidos refletem as características específicas desse caso e não devem ser generalizados automaticamente para outras concessionárias sem avaliações complementares.

Também deve ser considerado que o IGS é calculado por meio de uma média móvel de doze meses. Essa característica promove maior estabilidade ao indicador, porém reduz sua sensibilidade a oscilações recentes, influenciando tanto o comportamento da série quanto os resultados das previsões realizadas.

Além disso, os modelos desenvolvidos utilizaram exclusivamente informações históricas das próprias notas de satisfação, não incorporando variáveis externas que eventualmente possam influenciar a percepção dos clientes, como condições econômicas, mudanças operacionais, campanhas comerciais ou fatores de mercado.

Consequentemente, as previsões geradas devem ser interpretadas como projeções de tendência baseadas em padrões observados no histórico dos dados, não constituindo evidências de relações de causa e efeito entre variáveis. O objetivo do modelo é antecipar possíveis comportamentos futuros do indicador, e não explicar causalmente os fatores que originam tais comportamentos.

Por fim, destaca-se que o processo de validação realizado possui caráter preliminar. Embora os resultados tenham demonstrado desempenho satisfatório para os períodos analisados, a consolidação da metodologia demandaria novas aplicações em horizontes temporais maiores, diferentes concessionárias e ciclos adicionais de validação para ampliar a confiança e a generalização dos resultados obtidos.

Em razão da extensão reduzida da série histórica, não foram aplicados procedimentos formais de identificação de sazonalidade ou diagnóstico estatístico completo dos resíduos. Assim, a abordagem deve ser interpretada como uma modelagem empírica preliminar, voltada à previsão operacional de curto prazo, e não como uma modelagem formal exaustiva de séries temporais.

4.8 Síntese e conclusão do capítulo

Neste capítulo foram apresentados os procedimentos metodológicos adotados para o desenvolvimento da pesquisa. Inicialmente, caracterizou-se o estudo quanto à sua natureza, abordagem e estratégia de investigação, sendo definido como uma pesquisa aplicada, quantitativa, exploratória e desenvolvida por meio de um estudo de caso. Em seguida, foram descritas a origem e a preparação da base de dados, as alternativas de modelagem propostas, os critérios de validação empregados e as limitações metodológicas consideradas durante o desenvolvimento do trabalho.

A metodologia estabelecida neste capítulo foi fundamental para garantir que o desenvolvimento dos modelos de previsão ocorresse de forma estruturada e alinhada aos objetivos da pesquisa. A definição de uma validação temporal, a utilização de métricas objetivas de desempenho e a comparação com modelos simples de referência proporcionaram critérios consistentes para avaliar as diferentes alternativas de modelagem, permitindo que a escolha do modelo final fosse baseada em evidências quantitativas e não apenas em sua complexidade.

Além disso, o detalhamento das limitações metodológicas permitiu contextualizar os resultados obtidos, evidenciando as restrições impostas pela reduzida base histórica disponível e pela própria natureza do IGS. Dessa forma, a metodologia estabeleceu não apenas os procedimentos de execução da pesquisa, mas também os limites dentro dos quais os resultados deveriam ser interpretados, conferindo maior transparência e rigor científico ao estudo.

Definida a metodologia de pesquisa, o capítulo seguinte apresenta sua aplicação prática por meio do desenvolvimento, implementação e comparação dos modelos preditivos. Nele são descritas as etapas de construção dos modelos, a avaliação de seu desempenho, a comparação com modelos de referência e a seleção da alternativa que apresentou os melhores resultados para a previsão do IGS.

5 DESENVOLVIMENTO E EXECUÇÃO DOS MODELOS

Este capítulo apresenta, de forma sequencial e estruturada, a condução da construção do modelo preditivo proposto, descrevendo as etapas práticas de desenvolvimento, desde a preparação inicial dos dados até a obtenção da versão final, seguindo os passos definidos na metodologia. Ao longo do capítulo, são detalhadas as principais tentativas realizadas, bem como os ajustes e aprimoramentos adotados em cada fase, evidenciando o processo iterativo de evolução do modelo até se alcançar uma solução mais refinada, estável e aderente aos objetivos do estudo.

5.1 Preparação dos dados

A execução do projeto teve início com a consolidação e preparação da base de dados proveniente das pesquisas de satisfação. Inicialmente, já considerando a concessionária M para análise, os dados foram estruturados no ambiente do *Power BI*, onde foram feitas as seleções e descartes seguindo os critérios apresentados no subitem 4.1, resultando no quadro (3):

Quadro 3 - Seleção de Dados Concessionária M

Etapas	Quantidade de registros
Registros brutos extraídos	5.070
Registros removidos por duplicidade	3
Registros removidos por inconsistência	214
Registros removidos por fora do prazo do gatilho	31
Registros válidos finais	4.822

Fonte: Autoria própria (2026)

E logo após foram calculadas as médias mensais de cada um dos momentos da jornada do cliente (M1, M2, M3, M4, M5 e M6) considerando as notas destas 4822 entrevistas qualificadas. Essa agregação mensal foi necessária para padronizar a granularidade da análise e permitir a construção de um modelo preditivo baseado em séries temporais.

Após a organização dos dados, a base foi exportada no formato *Comma Separated Values* (CSV) e importada no ambiente de desenvolvimento *Visual Studio Code*, utilizando a linguagem *Python* para tratamento e modelagem. Durante essa etapa, foram realizados ajustes essenciais, como a padronização do formato de datas, ordenação cronológica dos registros e tratamento de inconsistências, incluindo a conversão de separadores decimais e remoção de valores ausentes.

Com a base devidamente estruturada, iniciou-se a etapa de engenharia de atributos (*feature engineering*), com foco na incorporação de defasagens temporais (*lags*). A utilização de *lags* consiste em empregar valores passados das variáveis como preditores para estimar valores futuros, sendo uma abordagem amplamente utilizada em problemas de séries temporais. Dessa forma, para cada momento da jornada, foram criadas variáveis correspondentes aos três períodos anteriores (*lag 1*, *lag 2* e *lag 3*), representando, respectivamente, os valores observados nos meses imediatamente anteriores.

5.2 Primeiro modelo

Na primeira abordagem de modelagem, optou-se por um modelo de regressão linear multivariada que utilizava, simultaneamente, os três *lags* de cada variável, além de incluir também *lags* provenientes de outros momentos da jornada como variáveis explicativas, seguindo de maneira fidedigna a modelagem prevista na etapa metodológica pela equação (6). Seguindo a metodologia do subitem 4.6, essa estrutura foi aplicada ao momento M1, com o objetivo de validar o comportamento do modelo e compreender, de forma controlada, o impacto das variáveis explicativas no erro de previsão. Gerando a seguinte previsão da tabela (2):

Tabela 2 - Comparativo Real X Previsto Modelo 1

Mês	Real	Previsto	Erro absoluto	Erro (%)	MAPE (%)
Fevereiro 2025	95	89,27	5,73	6,03	
Março 2025	88,1	105,1	16,97	19,27	12,65

Fonte: Autoria própria (2026)

Entretanto, os resultados obtidos com essa abordagem inicial não foram satisfatórios. Observou-se um valor de erro considerável, com *MAPE* de 12,65% e erro de 19,27% em março de 2025. Tal comportamento pode ser atribuído principalmente à alta correlação entre as variáveis explicativas, uma vez que os diferentes momentos da jornada apresentam dinâmicas semelhantes ao longo do tempo. Essa multicolinearidade compromete a capacidade do modelo em identificar relações claras entre as variáveis, resultando em sobreajuste (*overfitting*) e baixa capacidade de generalização para períodos futuros.

Além disso, a inclusão de múltiplos *lags* e variáveis simultaneamente aumentou a complexidade do modelo sem necessariamente agregar ganho preditivo, evidenciando que a estrutura inicial estava superparametrizada para o volume de dados disponível. Diante desse cenário, tornou-se necessário simplificar a

abordagem, buscando um modelo mais simples, estável e interpretável, o que motivou a evolução metodológica apresentada nas seções seguintes.

5.3 Segundo modelo

Diante das limitações observadas na primeira abordagem, optou-se por uma reformulação do modelo com foco na redução do número de variáveis explicativas. Essa etapa teve como objetivo principal mitigar os efeitos da multicolinearidade e melhorar a capacidade de generalização do modelo.

Na segunda abordagem, o modelo de regressão linear passou a considerar exclusivamente os valores defasados do próprio momento a ser previsto, eliminando a influência dos demais momentos da jornada. Assim, para cada variável, foram utilizados apenas dois períodos anteriores (*lag 1 e lag 2*), resultando em uma estrutura mais simplificada, conforme a formulação na equação (7) presente no subitem 4.4.2

Essa mudança reduziu significativamente a dimensionalidade do problema, permitindo que o modelo se concentrasse na dinâmica temporal intrínseca de cada variável. Tal abordagem é particularmente adequada em séries com dependência temporal, nas quais os valores passados do próprio indicador tendem a ser bons preditores de seu comportamento futuro (Hyndman e Athanasopoulos, 2021). A nova previsão gerou a tabela (3):

Tabela 3 – Comparativo Real X Previsto Modelo 2

Mês	Real	Previsto	Erro absoluto	Erro (%)	MAPE (%)
Fevereiro 2025	95	96	1	1,06	
Março 2025	88,1	95,96	7,86	8,92	4,99

Fonte: Autoria própria (2026)

Os resultados obtidos com essa segunda versão apresentaram melhora em relação ao modelo anterior, com redução do erro médio de previsão. Isso indica que a simplificação da estrutura atende de maneira mais apropriada este caso, sem interferência de variáveis cruzadas de outros momentos.

Apesar do avanço, com uma diminuição do erro médio se comparado ao modelo 1, ainda havia espaço para aprimoramento, especialmente no que diz respeito à suavização das variações de curto prazo. Dessa forma, essa etapa serviu como base para o desenvolvimento da abordagem final, apresentada na sequência, na qual se buscou maior estabilidade por meio de uma nova transformação das variáveis explicativas.

5.4 Terceiro modelo

A partir dos resultados obtidos na segunda abordagem, observou-se que, embora a simplificação do modelo tenha proporcionado ganhos relevantes em termos de estabilidade e redução de erro, ainda persistiam oscilações nas previsões, especialmente em períodos com maior variação nos dados. Diante disso, foi proposta uma terceira abordagem com o objetivo de aprimorar o modelo por meio da suavização das variáveis explicativas.

Nesta etapa, optou-se por substituir os *lags* individuais (*lag 1 e lag 2*) por uma única variável representando a média destes dois períodos. Dessa forma, o modelo passou a considerar não os valores isolados de cada defasagem, mas sim uma medida agregada que captura a tendência recente da série. A formulação adotada pode ser representada pela equação (8) presente no subitem 4.4.3.

Essa transformação teve como principal objetivo reduzir a influência de variações pontuais entre períodos consecutivos, promovendo uma suavização natural da série de entrada. Em termos estatísticos, essa abordagem contribui para a diminuição da variância do modelo, ao mesmo tempo em que preserva a informação de tendência contida nos dados históricos. A simulação do modelo 3 gerou a tabela (4):

Tabela 4 – Comparativo Real X Previsto Modelo 3

Mês	Real	Previsto	Erro absoluto	Erro (%)	MAPE (%)
Fevereiro 2025	95	95,48	0,48	0,51	
Março 2025	88,1	95,65	7,55	8,57	4,54

Fonte: Autoria própria (2026)

Os resultados obtidos com essa terceira versão demonstraram melhora em relação ao modelo 2 se tratando de erro médio da predição. Observou-se que o modelo passou a apresentar comportamento mais estável, especialmente em cenários onde os valores dos períodos anteriores apresentavam pequenas discrepâncias entre si.

Além disso, a nova estrutura por possuir um número menor de parâmetros a serem estimados, melhora o desempenho preditivo para este trabalho. Tal característica é especialmente relevante para aplicações práticas, como a implementação do modelo em ferramentas de *Business Intelligence*, onde modelos mais simples tendem a ser mais facilmente operacionalizados.

Dessa forma, a utilização da média dos *lags* se mostrou uma solução mais simples se comparado ao modelo 1 por conter menos coeficientes e mais suavizada

para oscilações se comparado ao modelo 2 por conta da média dos *lags*, consolidando-se como a base para a etapa final do projeto, na qual o modelo foi aplicado à projeção dos demais momentos, da Nota Mensal e do IGS.

5.5 Validação dos modelos e comparação de desempenho

Com o objetivo de avaliar o desempenho das diferentes abordagens de modelagem propostas, foi adotada uma estratégia de validação baseada na separação temporal dos dados. Para isso, utilizou-se o histórico disponível de outubro de 2023 até janeiro de 2025 como base de treinamento dos modelos, sendo os meses de fevereiro e março de 2025 reservados exclusivamente para teste. Essa abordagem permitiu simular um cenário real de previsão, no qual o modelo projeta valores futuros sem acesso aos dados efetivamente observados nesses períodos.

A partir deste cenário, obteve-se conforme os subitens 5.2, 5.3 e 5.4 uma melhora quanto ao cálculo do *MAPE*, devido ao refinamento na modelagem, conforme indica a tabela (5):

Tabela 5 – Comparação de Desempenho entre Modelos

Modelo	Estrutura	Erro médio
Modelo 1	<i>Lags</i> (1,2 e 3) + múltiplas variáveis	12,65%
Modelo 2	<i>Lags</i> (1 e 2) do próprio momento	4,99%
Modelo 3	Média de <i>lags</i> (1 e 2) do próprio momento	4,54%

Fonte: Autoria própria (2026)

O Modelo 1, caracterizado por elevada complexidade e grande número de variáveis, apresentou o erro mais acentuado, reforçando a hipótese de que a multicolinearidade e o excesso de parâmetros comprometeram sua capacidade de generalização.

O Modelo 2, ao restringir-se aos *lags* do próprio momento, apresentou melhora significativa, indicando que a dinâmica temporal individual de cada variável possui maior relevância preditiva do que a interação entre diferentes momentos da jornada.

Por fim, o Modelo 3, baseado na média dos dois últimos períodos, apresentou o melhor desempenho geral, com o menor erro médio entre as abordagens testadas. Esse resultado confirma que a suavização das variáveis de entrada (a partir da média entre *lag* 1 e *lag* 2) contribui para maior acurácia do modelo.

Entretanto, observa-se que, mesmo no modelo de menor erro médio, é possível ocorrerem desvios mais acentuados, como exemplificado no mês de março de 2025 no momento M1 conforme a tabela (6). Esse comportamento indica a presença de uma variação atípica nos dados reais, que não foi completamente capturada pelo modelo, podendo ser originária de sazonalidade ou um dos outros fatores enunciados no subitem 3.1. Tal ocorrência é esperada em aplicações reais, uma vez que eventos pontuais ou mudanças abruptas no comportamento dos dados podem não ser plenamente antecipados por modelos baseados em tendências históricas. A tabela (6) apresenta a comparação entre os valores reais e previstos agora para todos os momentos da jornada do cliente, considerando o Modelo 3 (que foi escolhido com base na tabela (5)). Observa-se que, de forma geral, o modelo apresentou certa precisão, com erros percentuais reduzidos na maioria dos casos, evidenciando sua capacidade de capturar adequadamente a dinâmica das séries temporais analisadas.

Tabela 6 - Comparação entre valores reais e previstos por momento (Modelo 3)

Momento	Data	Real	Previsto	Erro médio (%)
M1	Fev/25	95.0	95.1	0.51
M1	Mar/25	88.1	97,38	8,57
M2	Fev/25	98.3	89.56	8.89
M2	Mar/25	87.6	92.21	5.26
M3	Fev/25	93.6	93.00	0.64
M3	Mar/25	92.0	92.99	1.08
M4	Fev/25	95.0	96.05	1.11
M4	Mar/25	95.7	95.49	0.22
M5	Fev/25	94.8	93.52	1.35
M5	Mar/25	89.3	93.41	4.61
M6	Fev/25	94.0	92.80	1.27
M6	Mar/25	94.7	92.73	2.08

Fonte: Autoria própria (2026)

Apesar dessa ocorrência pontual, verifica-se que os demais momentos mantiveram níveis de erro majoritariamente abaixo de 5%, indicando que o modelo, de maneira geral, apresenta boa capacidade preditiva. Esse resultado reforça que o desvio identificado não compromete a validade da abordagem, sendo mais adequado interpretá-lo como um evento isolado, típico de séries reais sujeitas a variações imprevistas.

5.6 Projeção do IGS e validação do modelo escolhido

Após a definição do Modelo 3 como a abordagem mais adequada, procedeu-se à sua aplicação na projeção do IGS. Diferentemente das etapas anteriores, nas

quais o foco estava na previsão individual dos momentos da jornada, esta fase concentrou-se na avaliação do impacto dessas previsões no indicador consolidado, que representa a métrica final de interesse do negócio.

Cabe lembrar que notas mensais são calculadas com base em uma média ponderada dos diferentes momentos da jornada, sendo posteriormente suavizado por meio de uma média móvel de 12 meses para compor o IGS. Essa característica confere ao indicador um comportamento naturalmente menos volátil, reduzindo a influência de variações pontuais e tornando sua trajetória mais estável ao longo do tempo. Como consequência, espera-se que erros nas previsões mensais individuais sejam parcialmente diluídos no cálculo final do indicador.

Para validação do modelo, optou-se por realizar previsões recursivas a partir de outubro de 2024, utilizando exclusivamente dados históricos até esse período. A partir desse ponto, os meses subsequentes (novembro de 2024 a março de 2025) foram projetados iterativamente, sendo cada nova previsão utilizada como base para a seguinte. Essa estratégia permitiu simular um cenário real de aplicação do modelo, no qual múltiplos períodos futuros são estimados sem acesso a dados observados.

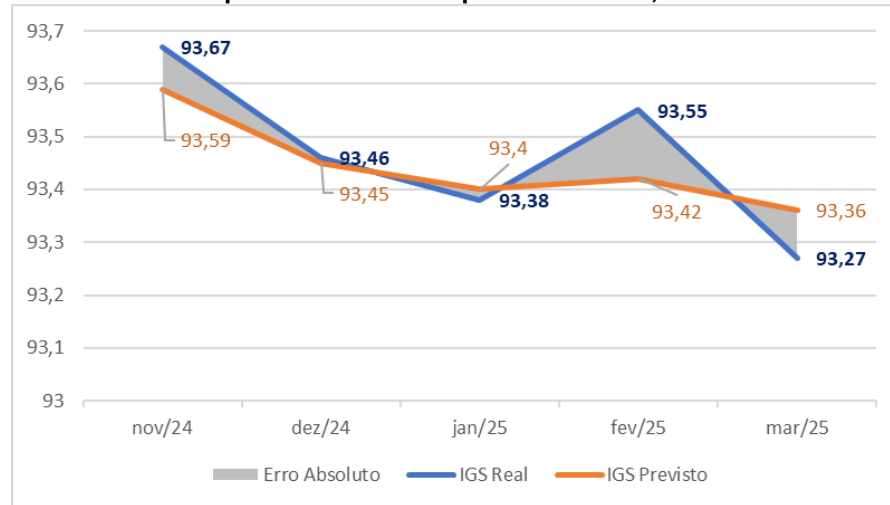
A escolha desse intervalo de validação está diretamente alinhada ao contexto de negócio, no qual a bonificação associada, de acordo com o subitem 2.2, ao indicador ocorre de forma semestral. Dessa forma, a avaliação da capacidade preditiva ao longo de um horizonte de até cinco meses fornece uma aproximação da aplicabilidade prática do modelo.

Os resultados obtidos são apresentados na tabela (7) e são representados no gráfico (7) de *timeline* fazendo o comparativo entre a projeção, feita até março de 2025 com reais de outubro de 24, com o IGS verdadeiro:

Data	IGS Real	IGS Previsto	Erro (%)	Erro médio (%)
Nov/24	93,67	93,59	0,09	
Dez/24	93,46	93,45	0,01	
Jan/25	93,38	93,4	0,02	
Fev/25	93,55	93,42	0,14	
Mar/25	93,27	93,36	0,09	0,07

Fonte: Autoria própria (2026)

Gráfico 7 – Comparativo entre IGS previsto e Real, Modelo 3



Fonte: Autoria própria (2026)

A análise dos resultados na tabela (7), evidencia que o modelo apresentou certo nível de precisão na projeção do indicador, com erro médio inferior a 0,1% ao longo de todo o período avaliado. Apesar do risco de propagação de erros (por se tratar de um modelo recursivo utilizando previsões anteriores como entrada para estimar períodos subsequentes) discutido na literatura de séries temporais (Hyndman e Athanasopoulos, 2021), os resultados mostraram desempenho satisfatório, com erros médios reduzidos e sem crescimento expressivo ao longo dos meses como mostrado no gráfico (7). Isso indica que a metodologia manteve estabilidade preditiva mesmo sob estratégia recursiva, reforçando sua adequação para aplicações de curto prazo no contexto do IGS.

Esse comportamento pode ser explicado, em grande parte, pela própria estrutura do IGS, que incorpora um efeito de suavização por meio da média móvel de 12 meses. Tal característica reduz a sensibilidade do indicador a oscilações de curto prazo, tornando-o mais previsível e menos suscetível a variações abruptas.

Considerando isso realizou-se uma análise de estacionariedade dos momentos M1-M6 e do IGS mensal, pois, é plausível que o IGS seja não estacionário e que vários momentos M1–M6 sejam estacionários. O diagnóstico do IGS serve para qualificar a interpretação do erro baixo e o diagnóstico dos momentos é o que valida tecnicamente a modelagem do Modelo 3. Se o IGS for não estacionário, modelar a variação (Δ IGS) é tanto o caminho estatístico correto quanto o mais aderente ao objetivo de antecipar quedas. Seguindo as fundamentações do subitem 3.7 e

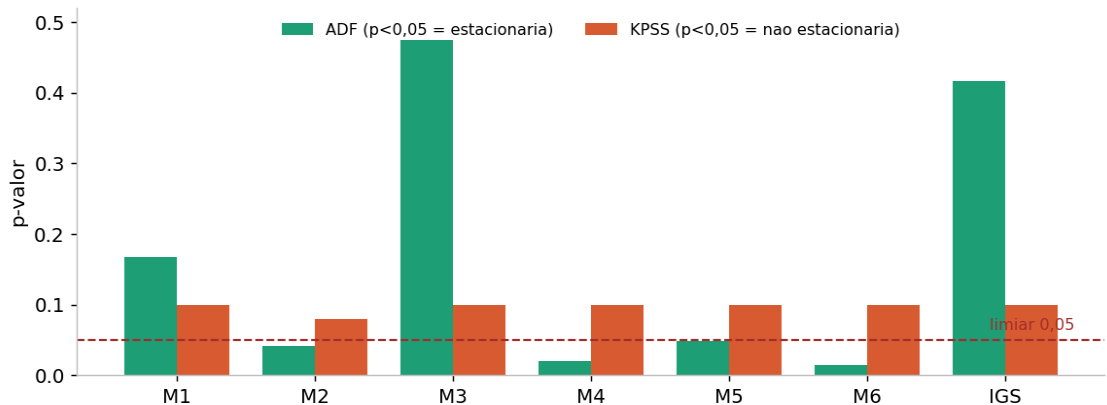
realizando as adaptações para o modelo 3, foi obtido os seguintes resultados do quadro (4) e gráfico (8) pós análise estacionária:

Quadro 4 - Análise Estacionária

Série	ADF (p)	KPSS (p)	Conclusão	Encaminhamento
M1	0,168	0,10	Inconclusivo	Preliminar (ver nota)
M2	0,041	0,08	Estacionária	Modelar em nível
M3	0,474	0,10	Inconclusivo	Preliminar (ver nota)
M4	0,021	0,10	Estacionária	Modelar em nível
M5	0,048	0,10	Estacionária	Modelar em nível
M6	0,014	0,10	Estacionária	Modelar em nível
Média mensal	0,416	0,099	Inconclusivo (tende a não estac.)	Apoiar-se nos benchmarks

Fonte: Autoria própria (2026)

Gráfico 8 - Análise Estacionária



Fonte: Autoria própria (2026)

Em momentos considerados estacionários (M2, M4, M5 e M6), o ADF rejeita a raiz unitária a 5% e o KPSS não rejeita a estacionariedade. Como esses momentos são as entradas efetivas do Modelo 3, o resultado dá suporte técnico à modelagem por defasagens para a maior parte das séries.

Nos casos inconclusivos (M1, M3 e média mensal), o ADF não rejeitou a raiz unitária, enquanto o KPSS não acusou não estacionariedade. Esse padrão é típico de amostras pequenas: com apenas 18 observações, o ADF tem baixo poder estatístico e tende a não rejeitar a hipótese nula mesmo quando a série é estacionária. Ao diferenciar M1, M3 e a média mensal, o ADF continuou sem rejeitar (p entre 0,37 e 0,50), o que reforça tratar-se de limitação de poder, e não de evidência forte de não estacionariedade.

A média mensal é o caso em que o ADF está mais distante de rejeitar a raiz unitária e o KPSS está no limite de acusar não estacionariedade — ambos apontando

persistência. Isso é coerente com a construção do indicador por média móvel e sustenta que o erro reduzido na previsão do IGS reflete, em parte, essa persistência; por isso a avaliação do ganho preditivo deve apoiar-se na comparação com os modelos de referência, e não apenas no erro absoluto.

5.7 Comparação com modelos de referência

Antes de seguir a diante, tornou-se necessário verificar se o Modelo 3, já identificado como a alternativa de menor erro entre as estruturas propostas neste estudo, também apresentava vantagens em relação a métodos de previsão mais simples amplamente utilizados em séries temporais de acordo com o subitem 4.4.4.

Essa comparação é importante porque o Modelo 3 realiza um processo de previsão em múltiplas etapas. Inicialmente, são estimadas as notas futuras de cada momento da jornada do cliente por meio das defasagens temporais identificadas na modelagem. Em seguida, essas previsões são utilizadas para recompor o IGS mensal e, posteriormente, o indicador acumulado de 12 meses. Trata-se, portanto, de uma abordagem mais elaborada do que simplesmente projetar diretamente o valor futuro do indicador final.

Com o objetivo de avaliar se esse esforço adicional de modelagem efetivamente agrega capacidade preditiva, foram considerados modelos de referência aplicados diretamente à série histórica do IGS. Entre eles, destacam-se o modelo ingênuo, que assume que o próximo valor do indicador será igual ao último valor observado e a média móvel simples dos dois períodos anteriores. Tais projeções tiveram o resultado das tabelas (8) e (9):

Tabela 8 – Previsão do IGS (modelo ingênuo)

Data	IGS Real	IGS Previsto	Erro (%)	Erro médio (%)
Nov/24	93,67	93,79	0,13	
Dez/24	93,46	93,67	0,23	
Jan/25	93,38	93,46	0,09	
Fev/25	93,55	93,38	0,18	
Mar/25	93,27	93,55	0,30	0,19

Fonte: Autoria própria (2026)

Tabela 9 – Previsão do IGS (modelo média móvel)

Data	IGS Real	IGS Previsto	Erro (%)	Erro médio (%)
Nov/24	93,67	93,73	0,06	
Dez/24	93,46	93,71	0,27	
Jan/25	93,38	93,72	0,36	
Fev/25	93,55	93,71	0,17	
Mar/25	93,27	93,72	0,48	0,27

Fonte: Aatoria própria (2026)

A comparação foi realizada utilizando o mesmo tempo amostral adotado anteriormente, mantendo a separação cronológica entre dados de treinamento e teste e avaliando o desempenho por meio do Erro Percentual Absoluto Médio (MAPE).

Tabela 10 – Comparação com modelos de referência

Modelo	MAPE (%)
Ingênuo	0,19
Média Móvel	0,27
Modelo 3	0,07

Fonte: Aatoria própria (2026)

Conforme apresentado na tabela (10), o Modelo 3 apresentou desempenho superior aos modelos de referência avaliados, registrando o menor erro percentual médio entre as abordagens comparadas, embora muito próximos. Esse resultado indica que a utilização das informações contidas nos momentos individuais da jornada do cliente fornece sinais adicionais relevantes para a previsão do comportamento futuro do indicador, permitindo uma maior capacidade preditiva em relação a métodos simplificados que utilizam apenas o histórico do próprio indicador.

5.8 Interpretação dos resultados

Os resultados obtidos indicam que o Modelo 3 apresentou os menores níveis de erro entre as alternativas avaliadas durante o processo de validação temporal. A utilização das defasagens dos momentos da jornada do cliente permitiu antecipar o comportamento futuro do indicador por até cinco meses, com precisão adequada aos objetivos do estudo (erro médio de 0,07%). Cabe destacar que essa estrutura preditiva apoia-se nas séries dos momentos individuais, e não diretamente no IGS: os testes de estacionariedade (ADF e KPSS) indicaram que quatro dos seis momentos (M2, M4, M5 e M6) são estacionários, o que confere suporte técnico à aplicação da modelagem por defasagens a essas séries.

A interpretação desses resultados, contudo, deve considerar uma característica importante do IGS: por ser calculado a partir de uma média móvel de 12 meses, o indicador apresenta comportamento naturalmente suavizado e elevada persistência. Essa característica foi corroborada pelos testes de estacionariedade, nos quais o ADF não rejeitou a hipótese de raiz unitária para o IGS, sinalizando tendência à não estacionariedade. Como consequência, oscilações abruptas tendem a ser

amortecidas, e parte do baixo erro obtido em previsões de curto prazo decorre da própria inércia do indicador, e não exclusivamente da capacidade preditiva do modelo.

Por esse motivo, a avaliação do modelo não deve se basear apenas no valor absoluto do erro, mas sobretudo em seu desempenho relativo quando comparado aos modelos de referência — critério especialmente pertinente quando a série analisada apresenta forte persistência. A comparação realizada, de acordo com a Tabela (10), demonstrou que a modelagem preditiva específica para cada momento que compõe o IGS proporcionou erro médio ligeiramente inferior ao das abordagens simplificadas, baseadas exclusivamente no histórico do próprio IGS. Ainda que a diferença seja pequena, ela indica que as informações contidas nos momentos individuais agregam ganho preditivo em relação aos métodos de referência.

Também deve ser ressaltado o caráter preliminar dessas conclusões. Com apenas 18 observações mensais, os testes de estacionariedade possuem baixo poder estatístico — o que explica os resultados inconclusivos obtidos para os momentos M1 e M3 — e a validação temporal abrange um horizonte curto. Dessa forma, os achados fornecem evidências iniciais de aplicabilidade, mas não constituem uma validação estatística definitiva.

Por fim, destaca-se que a proposta desenvolvida deve ser compreendida como uma ferramenta de apoio à tomada de decisão. O modelo não elimina a necessidade de análises complementares nem substitui a avaliação gerencial das causas das variações observadas, mas fornece uma visão antecipada das tendências do indicador, permitindo maior agilidade na identificação de riscos e na definição de ações preventivas.

5.9 Síntese e conclusão do capítulo

Neste capítulo foi apresentada a execução da metodologia proposta, contemplando o desenvolvimento, implementação e avaliação das alternativas de modelagem para previsão do IGS. Foram construídos três modelos baseados em defasagens temporais dos momentos da jornada do cliente, os quais foram submetidos à validação temporal e comparados por meio de métricas de erro. Posteriormente, o modelo de melhor desempenho foi confrontado com modelos simples de referência, permitindo avaliar se a abordagem proposta agregava capacidade preditiva em relação a métodos tradicionalmente empregados em séries temporais.

Os resultados obtidos demonstraram que a estrutura inicialmente proposta, baseada em múltiplas variáveis e defasagens cruzadas, não apresentou desempenho satisfatório diante das características da base disponível. Em contrapartida, o processo de refinamento metodológico conduziu à obtenção de um modelo mais simples, baseado na média dos dois períodos anteriores de cada momento da jornada, que apresentou maior estabilidade e melhor desempenho preditivo. A comparação com os modelos de referência confirmou que a utilização da estrutura interna do IGS proporcionou ganho preditivo em relação às abordagens mais simplificadas, justificando a adoção do modelo final.

Além de permitir a seleção da alternativa mais adequada para o contexto estudado, a execução descrita neste capítulo evidenciou a importância da validação temporal, da utilização de métricas objetivas de desempenho e da comparação com modelos de referência como critérios para avaliação de modelos preditivos. Dessa forma, os resultados obtidos forneceram evidências de que uma abordagem empírica baseada em defasagens temporais pode constituir uma alternativa viável para apoiar a previsão do IGS, desde que interpretada considerando as limitações da base histórica utilizada.

Com a execução da metodologia concluída e os resultados obtidos, o capítulo seguinte apresenta a discussão dos principais achados da pesquisa. São analisadas a coerência entre a proposta inicial e a solução final desenvolvida, a utilidade gerencial da abordagem, suas limitações e as recomendações para sua aplicação prática, relacionando os resultados alcançados aos objetivos estabelecidos para o trabalho.

6 DISCUSSÃO

Este capítulo apresenta uma análise crítica dos resultados obtidos ao longo do desenvolvimento do modelo de previsão do IGS. Inicialmente, discute-se a coerência entre a proposta metodológica originalmente concebida e a solução final adotada, destacando os fatores que motivaram a simplificação da modelagem. Em seguida, são abordadas as contribuições gerenciais da ferramenta desenvolvida e suas principais limitações. Dessa forma, busca-se interpretar os resultados alcançados à luz dos objetivos do trabalho, evidenciando tanto o potencial quanto as restrições da abordagem proposta.

6.1 Coerência entre modelo proposto e solução final

A proposta inicial deste trabalho, modelo 1, considerou a utilização de uma estrutura multivariável baseada em defasagens próprias e cruzadas dos momentos da jornada do cliente, inspirada na lógica de modelos com defasagens distribuídas. Entretanto, durante a etapa de testes, observou-se que a combinação de diversas variáveis em uma base histórica relativamente curta resultava em instabilidade dos coeficientes e aumento dos erros de previsão, em grande parte devido à multicolinearidade existente entre os momentos analisados.

Diante desses resultados, optou-se por uma abordagem mais simples, baseada na utilização da média dos dois períodos anteriores para cada momento da jornada, modelo 3. Essa adaptação manteve a lógica de dependência temporal proposta inicialmente, mas proporcionou maior estabilidade e desempenho preditivo, tornando a solução final mais adequada ao contexto aplicado deste estudo.

6.2 Utilidade gerencial

O modelo desenvolvido apresentou desempenho satisfatório dentro dos objetivos estabelecidos para esta pesquisa, demonstrando ser capaz de antecipar tendências de variação do IGS com desempenho superior aos modelos simples de referência avaliados. Entretanto, antes de sua utilização como ferramenta de apoio à gestão, recomenda-se a realização de validações adicionais envolvendo bases históricas mais extensas, diferentes concessionárias e análises estatísticas mais robustas, de forma a ampliar a confiabilidade e a capacidade de generalização dos resultados obtidos.

Uma vez submetida a essas etapas de validação e confirmada sua robustez, a metodologia apresenta potencial para atuar como um mecanismo de apoio à gestão da satisfação dos clientes. Como o IGS é calculado a partir de uma média móvel de 12 meses, oscilações recentes tendem a ser suavizadas, dificultando a identificação precoce de tendências de queda no desempenho. Nesse contexto, a previsão proposta poderá complementar o monitoramento tradicional do indicador, permitindo a geração de alertas antecipados e subsidiando a adoção de ações preventivas antes que seus impactos sejam refletidos integralmente no indicador oficial.

Além disso, o baixo MAPE obtido durante a validação preliminar do horizonte semestral, apresentado na tabela (7), indica que a abordagem possui potencial para apoiar os ciclos de acompanhamento das metas de satisfação e das bonificações associadas ao desempenho das concessionárias. Contudo, esse resultado deve ser interpretado considerando as limitações da base utilizada, reforçando que sua aplicação prática depende da confirmação do desempenho do modelo em cenários mais amplos e representativos.

6.3 Limitações da abordagem

Embora os resultados obtidos tenham sido satisfatórios, algumas limitações devem ser consideradas na interpretação dos achados. Em primeiro lugar, a validação realizada possui caráter preliminar, uma vez que foi conduzida a partir de uma base histórica relativamente curta e restrita a uma única concessionária. Além disso, o próprio IGS apresenta baixa volatilidade devido à sua composição baseada em uma média móvel de 12 meses, característica que suaviza oscilações recentes e tende a favorecer previsões de curto prazo, conforme discutido anteriormente.

Sob o ponto de vista operacional, também existem limitações para a implementação integral da lógica de previsão em ferramentas de *Business Intelligence*. No Power BI, por exemplo, a linguagem DAX não oferece suporte nativo para cálculos recursivos, dificultando a reprodução completa do modelo diretamente nos *dashboards*. Como alternativa, adotou-se uma abordagem prática na qual as previsões são geradas externamente por meio de scripts desenvolvidos em *Python* e posteriormente exportadas em formato CSV para integração ao ambiente analítico, permitindo sua utilização sem modificações significativas na infraestrutura já existente.

Como forma de verificar a adequação da modelagem baseada em defasagens, foram aplicados os testes de ADF e KPSS às séries mensais

correspondentes aos seis momentos da jornada do cliente (M1 a M6) e ao próprio IGS. Enquanto o teste ADF possui como hipótese nula a existência de raiz unitária, indicando não estacionariedade, o teste KPSS adota hipótese nula oposta, assumindo a estacionariedade da série. A utilização conjunta desses testes proporciona um diagnóstico sobre o comportamento estatístico das séries temporais.

Os resultados mostraram que os momentos M2, M4, M5 e M6 podem ser considerados estacionários, uma vez que o teste ADF rejeitou a hipótese de raiz unitária ao nível de significância de 5% e o teste KPSS não rejeitou a hipótese de estacionariedade. Para os momentos M1, M3 e para as notas mensais do IGS, entretanto, os testes apresentaram resultados inconclusivos: o ADF não rejeitou a hipótese de raiz unitária, enquanto o KPSS também não forneceu evidências suficientes para indicar não estacionariedade.

Esse comportamento é compatível com o reduzido número de observações disponíveis, limitado a aproximadamente 18 meses de dados. Em séries curtas, o teste ADF apresenta menor poder estatístico, podendo não rejeitar a hipótese nula mesmo quando a série apresenta comportamento estacionário. No caso específico do IGS, essa dificuldade é ainda mais compreensível devido à própria natureza do indicador, calculado a partir de uma média móvel de 12 meses, o que lhe confere elevada persistência temporal. Dessa forma, o desempenho do modelo não deve ser interpretado exclusivamente pelo baixo erro obtido na previsão do IGS, mas principalmente pelo ganho observado em relação aos modelos de referência, evidenciando que a utilização da estrutura interna do indicador agregou capacidade preditiva mesmo diante das limitações impostas pela base histórica e pelas características do próprio indicador.

6.4 Síntese e conclusão do capítulo

Neste capítulo foram discutidos os principais resultados obtidos ao longo da pesquisa, relacionando-os aos objetivos propostos e às características da base de dados utilizada. Foram analisadas a coerência entre a proposta metodológica inicial e a solução final desenvolvida, a utilidade gerencial do modelo e suas limitações, considerando tanto o desempenho preditivo alcançado quanto as restrições inerentes ao estudo.

A discussão realizada permitiu compreender que o desenvolvimento do modelo não se restringe à obtenção de baixos erros de previsão, mas envolve também

aspectos relacionados à interpretabilidade, estabilidade e viabilidade de aplicação no ambiente organizacional. Da mesma forma, evidenciou-se que o desempenho observado deve ser interpretado considerando as características do próprio IGS, a reduzida base histórica disponível e a necessidade de validações adicionais antes da utilização do modelo como ferramenta de apoio à gestão.

Além disso, este capítulo reforçou que a contribuição da pesquisa está na proposição de uma abordagem empírica simples, operacional e fundamentada, capaz de auxiliar a identificação antecipada de tendências de variação do IGS. Embora os resultados obtidos sejam promissores e superiores aos modelos de referência avaliados, sua aplicação em ambiente gerencial depende da realização de estudos complementares que ampliem a base de validação e confirmem a robustez da metodologia em diferentes contextos operacionais.

Com a análise crítica dos resultados concluída, o capítulo seguinte apresenta as conclusões da pesquisa, retomando o problema investigado, verificando o atendimento dos objetivos estabelecidos e sintetizando as principais contribuições, limitações e perspectivas para trabalhos futuros.

7 CONCLUSÃO

O presente trabalho teve como objetivo geral desenvolver um modelo empírico de previsão do IGS, baseado em defasagens temporais dos momentos da jornada do cliente, com o propósito de apoiar a detecção antecipada de tendências de variação em uma concessionária do setor automotivo de transportes pesados. A partir dos resultados obtidos, considera-se que esse objetivo foi alcançado, uma vez que foi possível construir, testar e comparar diferentes alternativas de modelagem, culminando na seleção de uma abordagem simplificada capaz de apresentar desempenho superior aos modelos de referência adotados na validação.

Em resposta ao problema de pesquisa apresentado no item 1.2.1 — "Uma abordagem empírica baseada em defasagens temporais dos momentos da jornada do cliente seria capaz de prever tendências de variação do IGS com desempenho superior a modelos simples de referência e com utilidade prática para a gestão da satisfação?" — os resultados obtidos indicam que a resposta é positiva. Foi possível desenvolver uma modelagem capaz de antecipar tendências de variação do IGS, apresentando desempenho superior aos modelos simples de referência utilizados neste estudo. Entretanto, essa conclusão deve ser interpretada com cautela, uma vez que a validação foi realizada sobre uma base histórica reduzida. Dessa forma, embora os resultados demonstrem o potencial da abordagem proposta, sua consolidação demanda validações adicionais em bases mais extensas e diversificadas, constituindo uma importante oportunidade para trabalhos futuros envolvendo uma análise estatística mais rigorosa.

Para atingir esse objetivo geral, houve logro dos objetivos específicos expostos no subitem 1.4. Inicialmente foi realizada a caracterização do IGS, de sua composição e dos momentos que integram a jornada do cliente. Essa etapa permitiu compreender como as pesquisas transacionais são conduzidas pela empresa, de que forma os diferentes momentos contribuem para a formação do indicador e qual a relevância do IGS para o acompanhamento da experiência do cliente e para as atividades desempenhadas pela área de CX em suporte às concessionárias.

Em seguida, foi realizada a seleção e preparação da base histórica de dados proveniente das pesquisas transacionais. Após alinhamento com o setor jurídico da empresa, foi disponibilizada uma base contendo as entrevistas dos momentos da jornada do cliente utilizadas no cálculo do IGS. A principal limitação do trabalho esteve

relacionada à esta etapa por possuir reduzida quantidade de informações disponíveis para utilização na pesquisa, fator que influenciou diretamente as decisões metodológicas adotadas ao longo do desenvolvimento do trabalho.

Com a base devidamente estruturada e fundamentando-se nos conceitos apresentados na literatura sobre séries temporais e modelos com defasagens, foram desenvolvidas diferentes alternativas de modelagem. A proposta inicial baseou-se em uma estrutura multivariável contendo defasagens próprias e cruzadas dos momentos da jornada. Entretanto, os resultados evidenciaram elevado erro de previsão. Diante desse cenário, o modelo foi sucessivamente refinado até a obtenção de uma estrutura mais simples, baseada na média dos dois períodos anteriores de cada momento da jornada, que apresentou desempenho preditivo superior.

Posteriormente, as alternativas desenvolvidas foram comparadas por meio de validação temporal fora da amostra e da utilização de métricas de erro, permitindo selecionar objetivamente o modelo com melhor desempenho para a etapa de projeção do IGS. Em complemento, realizou-se a comparação do modelo selecionado com modelos simples de referência, verificando que a utilização da estrutura interna do indicador proporcionou ganho preditivo em relação a essas abordagens simplificadas. Essa etapa mostrou-se fundamental para demonstrar que o esforço adicional empregado na modelagem efetivamente agregou capacidade preditiva em comparação às alternativas mais simples.

Por fim, avaliou-se a utilidade prática da abordagem proposta para o apoio à gestão da satisfação dos clientes. As discussões realizadas demonstraram que, embora existam limitações decorrentes da reduzida base histórica, da ausência de variáveis externas e da própria característica suavizada do IGS, o modelo apresenta desempenho satisfatório em relação as demais modelagens testadas, porém seria interessante maiores validações para verificar a possibilidade de ser utilizado como ferramenta auxiliar da gestão da satisfação.

7.1 Trabalhos futuros

Embora os resultados obtidos tenham atingido o objetivo proposto, algumas limitações da base de dados impediram a realização de análises estatísticas mais abrangentes. Dessa forma, recomenda-se que trabalhos futuros utilizem bases históricas mais extensas, permitindo ampliar o horizonte de validação temporal e aumentar a confiabilidade estatística dos resultados obtidos. Da mesma forma, a

incorporação de dados provenientes de diferentes concessionárias poderá contribuir para verificar a capacidade de generalização do modelo em distintos contextos operacionais.

Outra possibilidade consiste na inclusão de variáveis externas potencialmente relacionadas à satisfação dos clientes, como indicadores operacionais, comerciais, financeiros ou econômicos. A utilização dessas informações pode ampliar a capacidade dos modelos e possibilitar o desenvolvimento de abordagens que considerem não apenas a dependência temporal dos dados, mas também fatores que influenciam diretamente a percepção dos clientes ao longo da jornada.

Com uma base histórica mais robusta, também se recomenda a realização de validações estatísticas mais rigorosas, contemplando diferentes horizontes de previsão, testes adicionais de diagnóstico e comparação com modelos estatísticos clássicos e técnicas de aprendizado de máquina. Essas análises poderão confirmar a robustez da metodologia proposta e identificar oportunidades de melhoria em seu desempenho preditivo.

Por fim, identifica-se como uma importante oportunidade de pesquisa a reavaliação da própria estrutura do IGS. Estudos futuros podem investigar a composição dos momentos da jornada do cliente, os pesos atualmente atribuídos a cada um deles e sua efetividade na representação da satisfação dos clientes e do desempenho dos diferentes setores da concessionária. Além disso, análises estatísticas mais aprofundadas, envolvendo técnicas de correlação, consistência interna, análise fatorial ou modelos de equações estruturais, podem verificar se a estrutura atualmente utilizada apresenta fundamentação estatística adequada ou se existem alternativas capazes de representar o indicador de forma mais precisa e consistente. Dessa forma, além de aprimorar os modelos de previsão, futuras pesquisas poderão contribuir para a evolução do próprio indicador utilizado pela organização.

REFERÊNCIAS

BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2015.

BRASIL. **Lei nº 13.709, de 14 de agosto de 2018**. Lei Geral de Proteção de Dados Pessoais (LGPD). Diário Oficial da União: seção 1, Brasília, DF, ano 155, n. 157, p. 1-7, 15 ago. 2018.

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. 5. ed. Porto Alegre: AMGH, 2011.

HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: principles and practice**. 3. ed. Melbourne: OTexts, 2021.

JAMES, G.; WITTEN, D.; HASTIE, T.; TIBSHIRANI, R. **An introduction to statistical learning: with applications in R**. 2. ed. New York: Springer, 2021.

PESARAN, M. H.; SHIN, Y.; SMITH, R. J. Bounds testing approaches to the analysis of level relationships. **Journal of Applied Econometrics**, v. 16, n. 3, p. 289–326, 2001.

REICHHELD, F. F. The one number you need to grow. **Harvard Business Review**, Boston, v. 81, n. 12, p. 46-54, Dec. 2003.