

Previsão da Demanda de URA e CHATBOT: Estudo de Caso em Contact Center

João Paulo Ferreira Dias – jpfd@ufu.br

Universidade Federal de Uberlândia

Jean Carlos Domingos – jdomingos@ufu.br

Universidade Federal de Uberlândia

Leonardo Caixeta de Castro Maia – leonardocaixeta@ufu.br

Universidade Federal de Uberlândia

Carla Bonato Marcolin – carla@ufu.br

Universidade Federal de Uberlândia

Resumo

Este artigo avalia a previsão de demanda de atendimentos recebidos em Unidades de Resposta Audível (URA) e *chatbots* em uma empresa de *Contact Center* que atua no ramo de telecomunicações. A previsão da demanda é uma atividade essencial para a alocação eficiente de recursos e a sustentabilidade organizacional, especialmente em um setor competitivo como o de *Contact Centers*. Foram testados 16 cenários, abrangendo métodos sugeridos na literatura, uma adaptação proposta pelo autor e o método atualmente empregado pela empresa. A avaliação foi realizada por meio de métricas de erro como o Erro Percentual Absoluto Médio (MAPE), a Soma Cumulativa de Erros de Previsão (CFE) e o Desvio Absoluto Médio (MAD). O método que apresentou o menor MAPE foi o método com a média móvel, com 4,69%, utilizando um histórico dos últimos três meses em relação ao mês planejado para a URA. O melhor CFE foi de -2.453, obtido com a média móvel adaptada pelo autor com histórico dos últimos 2 meses para o *chatbot*. O melhor MAD, de 1.170, foi alcançado com a média móvel utilizada pela empresa, considerando um histórico dos últimos 12 meses para o *chatbot*. Os resultados indicam que, para a demanda específica analisada, a utilização de períodos históricos mais curtos pode resultar em maior acurácia.

Palavras-chave: Previsão de demanda; Contact center; URA; Chatbot; Séries temporais.

1 Introdução

O planejamento da demanda de produtos ou serviços é reconhecido como um fator crítico para o sucesso organizacional, pois está intrinsecamente ligado à eficiência, abrangendo desde as operações até as decisões estratégicas de longo prazo. Em um cenário de intensa competitividade global, o controle otimizado e a alocação eficaz de recursos tornaram-se requisitos mínimos para a manutenção da sustentabilidade financeira das empresas (Fildes; Ma; Kolassa, 2019).

No setor de serviços, que detém uma participação significativa no Produto Interno Bruto (PIB) de diversas economias, incluindo o Brasil, Estados Unidos e França, a acurácia no planejamento é fundamental (Bouzada; Saliby, 2009). Segundo dados da Folha de São Paulo (2025) o setor de serviços no Brasil representou 68,8% do PIB em 2024, apresentando um crescimento de 3,7% em relação ao ano anterior. Para o futuro, o mercado projeta uma movimentação de R\$ 87,7 bilhões de reais, até o ano de 2027. Estes resultados são projetados sobre o aumento na oferta de serviços integrados com *chatbots*, inteligência artificial e analytics (Juniper Research, 2022).

Os *Contact Centers*, inseridos no setor terciário, desempenham um papel vital na terceirização do atendimento ao cliente para diversas empresas. Dada a natureza da sua atividade principal, uma parcela substancial dos custos de uma empresa neste ramo está atrelada à mão de obra dedicada ao atendimento (Barbosa; Gomes; Chaves, 2015).

Nesse contexto, o controle de custos é uma prioridade, impulsionando a automação de demandas por meio de ferramentas como *Interactive Voice Response* (IVRs), ou Unidades de Resposta Audíveis (URAs), e *chatbots*. Tais ferramentas permitem o autoatendimento ágil e resolutivo, liberando atendentes humanos para interações mais complexas e personalizadas. Segundo Sá e Sá (2014), os *Contact Centers* prezam pelo padrão e controle, pois o objetivo central comumente está atrelado à redução de custos. Uma das vias disponíveis é a automatização de demandas, que cumprem um papel ágil e resolutivo atendendo o cliente sem a necessidade de um atendente humano, enquanto este, assume como protagonista de atendimentos mais complexos, flexibilizados e personalizados.

Diante disso, a previsão precisa da demanda de atendimentos — tanto os resolvidos manualmente quanto os automatizados — é essencial para que as estratégias organizacionais sejam desdobradas em todos os níveis. É comum que neste setor, a receita seja variável e relacionada com o volume de atendimentos recebidos, e com indicadores e níveis de serviço alinhados em contrato. Caso não sejam atingidos, penaliza-se o faturamento. Portanto, uma previsão inadequada pode resultar em superdimensionamento da estrutura e ociosidade da capacidade de trabalho, gerando custos desnecessários e impactando a rentabilidade.

A capacidade de prever o volume de chamadas e interações possibilita um aumento direto nos lucros e uma melhoria indireta na satisfação do cliente, devido à redução do tempo de espera. Conforme Carvalho, Guazzelli e Gaspar (2018, p.349), variações negativas nos volumes de chamadas implicam diretamente em reduções na rentabilidade dos prestadores de serviço, que não são capazes de reduzir os quadros de funcionários com a mesma velocidade.

Martins e Strambi (2021) destacam que a previsão de demanda é um pilar essencial para qualquer estratégia, pois é a partir da demanda que a receita, os custos e investimentos da empresa serão traçados. Cambuí *et al.* (2023) concluem que utilizar a previsão de demanda aumenta a competitividade da organização através da otimização dos recursos, e afirmam que a utilização de séries temporais auxilia na tomada de decisão e citam o uso das técnicas de média móvel simples, média móvel ponderada, suavização exponencial, suavização com tendência, e *Box-Jenkins*.

Fildes, Ma e Kolassa (2022) declararam que provisionar a demanda tem influência direta no desempenho de uma organização, pois melhora vários processos ao longo da cadeia de suprimentos e que os métodos de séries temporais são técnicas de previsão comumente utilizadas por varejistas online e apontam que os métodos com aprendizagem de machine learning não geraram evidências suficientes.

Apesar da relevância do tema, assevera-se que os estudos sobre previsão de demanda na área de serviços e *contact centers* ainda são escassos. Fildes; Ma; Kolassa (2019) avaliam a previsão de demanda no setor de varejista em países desenvolvidos. Arunraj, Ahrens, Fernandes (2016) destacam a previsão de demanda na indústria de alimentos, mediante variáveis de sazonalidade e perecibilidade. Na área de serviços, tem-se manuscritos sobre a previsão de demanda em e-commerce, tais como Viana et al. (2024).

Assim, a partir da importância do tema e da experiência profissional do pesquisador colaborador em uma empresa de *Contact Center*, na área de análise de dados, este trabalho tem como objetivo principal avaliar os métodos de previsão da demanda de atendimentos entrantes nas URAs (canal de voz) e *chatbots* (canal digital no WhatsApp) de uma operação específica do *Contact Center* que atende clientes do ramo de telecomunicações, buscando identificar a técnica mais adequada para apoiar a tomada de decisão da empresa.

Adicionalmente, este estudo busca contribuir com a equipe de planejamento da empresa, oferecendo uma técnica de previsão otimizada, e com a literatura acadêmica, por meio da aplicação prática da teoria em um cenário real. A pesquisa se insere em uma abordagem descritiva e quantitativa, com características de estudo de caso e pesquisa-ação.

2 Referencial teórico

A previsão de demanda é um dos pilares da gestão de operações e do planejamento estratégico de qualquer organização. Embora algumas previsões, como o nascer do sol, sejam exatas, o ambiente empresarial é dinâmico e muitas variáveis estão fora do controle direto da empresa. No entanto, a importância de realizar previsões rigorosas permanece inquestionável. Bugor e Lucca Filho (2021) destacam que na alta competitividade existente entre as empresas, praticar com excelências as atividades de planejamento, programação e controle da produção é fator de diferenciação para que uma delas seja bem-sucedida, proporcionando eficiência, ou seja, produzindo mais com os mesmos recursos.

A previsão de demanda é base inicial de qualquer análise, pois permitirá conhecer a demanda futura e assim desdobrar os cálculos de receita e dimensionar todos os requisitos necessários para a entrega do serviço ou produto (Martins; Strambi, 2021). Ackermann e Sellitto (2022) descrevem a previsão de demanda como um método administrativo para estimar o estado futuro de uma dimensão de interesse organizacional. Este processo envolve a análise e o reconhecimento de padrões históricos para projetar cenários futuros, identificando causas para possíveis superações. Tubino (2007) detalha o processo de previsão da demanda em cinco etapas fundamentais: (1) definição do objetivo do modelo (produtos e horizonte de planejamento), (2) coleta e análise dos dados (insumos para a técnica de previsão), (3) seleção da técnica de previsão (qualitativa ou quantitativa), (4) obtenção das previsões e (5) monitoramento do modelo.

A etapa de coleta e análise de dados tem papel importante na previsão da demanda, pois a disponibilidade de um histórico confiável é um desafio comum em muitas empresas. A escolha da técnica de previsão também é influenciada pelo histórico de dados, objetivos do plano e recursos disponíveis, destacando uma relação positiva entre acurácia e custo.

Após a obtenção das previsões, o monitoramento contínuo do modelo é essencial para medir a taxa de erro e permitir o aperfeiçoamento ou a substituição da técnica, dado o dinamismo da

demanda por fatores como promoções, avanços tecnológicos ou mudanças sazonais. Fatores como a má utilização ou interpretação das técnicas, a perda de validade por alterações no comportamento das variáveis, variações irregulares na demanda e ações não previstas de concorrentes podem influenciar negativamente a acurácia de uma previsão.

2.1 Previsão de demanda em Contact Center

Os avanços tecnológicos e a crescente popularidade dos atendimentos remotos, intensificados pela pandemia de COVID-19, transformaram os *Contact Centers* em pontos de contato multicanais, não mais limitados apenas a interações telefônicas (Roque et al.; 2021). Essas empresas especializadas terceirizam o atendimento ao cliente, e os principais motivos para essa terceirização incluem a especialização do prestador de serviços, a redução e o controle dos custos operacionais, e o aumento do foco da empresa contratante em sua atividade principal. A otimização dos custos, em particular, é um fator determinante na escolha de um parceiro de *Contact Center* (Ferruzzi et al., 2011).

O *Contact Center* é uma evolução do *Call Center* que abrange não apenas as chamadas telefônicas, mas também todos os outros canais de comunicação digitais e multicanais que os clientes utilizam para interagir com uma empresa. Oliveira e Moraes (2019) apontam que *call centers* estão organizados como uma central de atendimento, centralizando as mais diversas faces da comunicação entre uma empresa e seu cliente, tais como: vendas, cobranças, suporte técnico, fornecimento de informações, que normalmente são viabilizadas através de uma linha de produção amarrada a informatização com processos extremamente controlados e padronizados. Mello (2021) também destaca as três principais áreas de atuação de um *Contact Center*, onde 47% do mercado está atendendo a serviços de atendimento ao consumidor (SAC), 23% dedicados a vendas e 22% relacionados com processos de cobranças de dívidas, os 8% restantes são diversificados e não foram categorizados.

Internamente, os *Contact Centers* operam com processos altamente controlados e padronizados, buscando a redução de custos como objetivo central. Isso é alcançado, em parte, pela automatização de processos simples e repetitivos por meio de ferramentas de autoatendimento, como URAs e *chatbots*. A URA (Unidade de Resposta Audível), segundo Costa, Felipe e Rodrigues (2008), é uma aplicação com opções pré-definidas ou que interage com a fala do cliente para o pré-atendimento de chamadas receptivas, podendo reter a chamada ou transferi-la para um atendente humano. *Chatbots*, por sua vez, simulam a interação humana, comunicando-se em linguagem natural e seguindo regras de negócio para atendimento em tempo real (Chandel et al., 2018).

Devido a competitividade do setor, os gestores têm voltado sua atenção para o planejamento da demanda e seus desdobramentos sobre as estruturas de pessoas e ferramentas. Para Roque, Gomes, Santos e Ferreira (2021) a previsão do volume de atendimentos nessas centrais é importante para o dimensionamento ótimo das equipes e da infraestrutura, impactando diretamente a rentabilidade e o cumprimento de Níveis de Serviço (NS) contratados. Isso ressalta a importância de informações e previsões precisas como um diferencial competitivo, permitindo que os fornecedores alinhem as expectativas de custo e serviço desde o início do contrato.

2.2 Técnicas de previsão de demanda

Na literatura, as técnicas de previsão de demanda são classificadas em dois tipos principais: qualitativas e quantitativas. Os métodos qualitativos baseiam-se em opiniões, experiências e suposições para fundamentar a demanda futura, incluindo o consenso do comitê executivo, o método Delphi, pesquisas com equipes de vendas ou clientes, analogia histórica e pesquisa de mercado.

Em contraste, os métodos quantitativos utilizam dados históricos em modelos matemáticos para realizar a previsão, tais como regressão linear, média móvel, suavização exponencial, entre outros (Gaither; Frazier, 2005; Krajewski, Ritzman; Malhotra, 2009). Este estudo foca na aplicação de técnicas quantitativas, que, considerando as práticas da empresa estudada, analisou-se em detalhes as seguintes técnicas:

- Previsão por Média Móvel: Este método utiliza a média aritmética da demanda real de um passado histórico de 'n' períodos para gerar a demanda futura. Pode ser calculada a partir da equação 1.

$$P_j = \frac{\sum_{i=1}^n D_i}{n} \quad (1)$$

Fonte: Peinado e Graeml, 2007, p. 338.

Onde: i = número de ordem de cada período mais recente; n = número de períodos utilizados para apurar a média móvel; D_i = demanda ocorrida no período i . P_j = previsão de demanda para o período j .

- Previsão por Média Móvel Ponderada: Similar à média móvel simples, porém, as demandas dos períodos passados podem ter pesos diferentes, comumente atribuindo pesos maiores aos períodos mais recentes. Pode ser calculada a partir da equação 2.

$$P_j = (D_1 \times PE_1) + (D_2 \times PE_2) + \dots + (D_n \times PE_n) \quad (2)$$

sendo $PE_1 + PE_2 + PE_3 + \dots + PE_n = 1$

Fonte: Peinado e Graeml, 2007, p. 345.

Onde: PE_i = peso atribuído para o período i ; n = número de períodos utilizados; D_i = demanda ocorrida no período i . P_j = previsão de demanda para o período j .

- Previsão por modelo do ajuste sazonal: Este método é aplicado para demandas que exibem tanto tendência quanto sazonalidade. Pode ser calculada a partir da equação 3.

$$D_i = (a + b \times P_i) \times S_i \quad (3)$$

Fonte: Peinado e Graeml, 2007, p. 358.

Onde: D_i = demanda ocorrida no período i ; a = coeficiente de nível da demanda; b = coeficiente de tendência da demanda; P_i = período i ; S_i = fator de sazonalidade do período i ;

Todas as previsões estão sujeitas a erros, que podem ser classificados como sistemáticos (superestimação ou subestimação, por omissão ou desatenção) ou aleatórios (causados por fatores não previstos) (Krajewski, Ritzman; Malhotra, 2009). A definição básica de um erro de previsão E_t é a diferença entre a demanda real D_t e a demanda prevista F_t para um período t : $E_t = D_t - F_t$

Neste trabalho, foram utilizados os seguintes indicadores de erro:

- Erro Percentual Absoluto Médio (MAPE - *Mean Absolute Percent Error*): É uma medida de erro em unidade percentual, o que a torna imune ao impacto das escalas de diferentes tipos de demanda, facilitando a comparação. A fórmula de cálculo é apresentada na equação 4, conforme Romão et al. (2020).

$$MAPE(\%) = \frac{1}{T} \sum_{t=1}^T \left| \frac{y_t - \hat{Y}_t}{Y_t} \right| \times 100 \quad (4)$$

- Soma Cumulativa de Erros de Previsão (CFE - *Cumulative Sum of Forecast Errors*): Calcula o erro de previsão total. Se o CFE cresce continuamente, indica uma oportunidade de melhoria na previsão, frequentemente relacionada à presença de tendência ou sazonalidade não capturada. A fórmula de cálculo é apresentada na equação (5), conforme Krajewski, Ritzman e Malhotra (2009).

$$CFE = \sum E_t \quad (5)$$

- Desvio Absoluto Médio (MAD - *Mean Absolute Deviation*): Mede a dispersão dos erros de previsão. Um MAD menor indica maior proximidade da demanda real. A fórmula de cálculo é apresentada na equação (6), conforme Krajewski, Ritzman e Malhotra (2009).

$$MAD = \frac{\sum |E_t|}{n} \quad (6)$$

3 Procedimentos metodológicos

Este estudo caracteriza-se como uma pesquisa-ação, cujo objetivo é atender a uma necessidade identificada no ambiente organizacional, onde o próprio pesquisador está inserido (Vergara, 2005). A abordagem é quantitativa, buscando traduzir os dados em números para classificação e análise, o que confere maior margem de segurança e evita distorções na interpretação. De acordo com Malhotra (2012), esta pesquisa classifica-se como descritiva, adequada para descrever aspectos de grupos relevantes e realizar previsões específicas.

O problema investigado concentra-se na avaliação de métodos de previsão de demanda para os atendimentos recebidos pela operação "J" do *Contact Center* "T" em seus canais de URA e *chatbot*. A empresa tem como prática realizar duas previsões de demanda distintas, uma mensal com horizonte de 12 meses, utilizada para o planejamento anual e negociação de contratos com clientes, e outra diária com horizonte de 30 dias, empregada para o planejamento da capacidade operacional do mês subsequente.

Os dados de demanda, tanto planejada quanto real, foram cedidos pela empresa. Foram utilizados registros diários abrangendo o período de 01/01/2019 a 31/12/2023, garantindo o anonimato das informações.

Para a análise, foram aplicados três métodos para a previsão de demanda mensal: média móvel, média móvel ponderada e ajuste sazonal. Foram gerados 12 cenários de planejamento considerando o horizonte de planejamento anual, 6 para cada canal, URA e *chatbot*. Nesses cenários, variou-se o histórico de dados utilizado para a previsão, optando por janelas de 3 ou 12 meses. Adicionalmente, foi incluído 2 cenários que utiliza o método aplicado pela empresa em seu planejamento anual aos 2 canais, totalizando 14 cenários.

Para avaliação da previsão de demanda diária com horizonte de 30 dias, foi proposto uma adaptação da média móvel utilizando o histórico de 2 meses, o qual foi comparada com método aplicado pela empresa para o mesmo horizonte. Ambos os métodos foram avaliados para cada

canal, URA e *chatbot*, totalizando mais 4 cenários. As previsões obtidas foram avaliadas utilizando os índices de erro MAPE, CFE e MAD.

4 Resultados

Neste trabalho foram aplicados os três métodos de previsão da demanda média móvel, média móvel ponderada e ajuste sazonal para os canais de URA e *chatbot* do *Contact Center*. De acordo com os múltiplos contextos testados, gerou-se 18 cenários de planejamento de demanda, sendo 9 para cada canal, o que permitiu comparar a acurácia dos métodos propostos e das abordagens já utilizadas pela empresa. Dentre os 9 cenários realizados para cada canal, têm-se:

- Dois cenários de previsão mensal com uso da média móvel: um que se utiliza o histórico dos últimos 12 meses e outro que utiliza um histórico dos últimos 3 meses em relação ao mês avaliado;
- Dois cenários de previsão mensal que utilizaram a média móvel ponderada: também com alternância do histórico entre 3 e 12 meses em relação ao mês planejado;
- Dois cenários de previsão mensal que se basearam no modelo de ajuste sazonal, considerando 3 e 12 meses de histórico;
- Um cenário de previsão mensal baseado na média móvel que é aplicado pela empresa, e que utiliza um histórico dos 12 meses mais recentes em relação ao mês avaliado;
- Um cenário de previsão diária baseado na adaptação da média móvel adaptada e em que se utilizou o histórico dos últimos 2 meses em relação ao mês planejado;
- Um cenário de previsão diária baseado no método aplicado pela empresa, e que utiliza um histórico dos 12 meses mais recentes.

Na tabela 1 é sintetizado os resultados das métricas de erros MAPE, CFE e MAD para cada canal e método testado.

Tabela 1 – MAPEs, CFEs e MADs (consolidado do período planejado) de cada canal e método. Fonte: Os autores.

OBJETIVO	MÉTODO	URA			CHATBOT		
		MAPE	CFE	MAD	MAPE	CFE	MAD
Previsão Mensal	Média móvel - 12 meses	8,37	-512325	76756	16,12	675385	56282
	Média móvel - 3 meses	4,69	92950	43764	7,33	242462	25200
	Média móvel ponderada - 12 meses	5,93	-227644	54655	11,92	498766	41564
	Média móvel ponderada - 3 meses	5,11	72389	47665	6,06	178409	20892
	Ajuste sazonal - 12 meses	10,33	1135188	99471	9,74	383743	35961
	Ajuste sazonal - 3 meses	8,05	692058	77455	7,24	182371	25840
	Método aplicado pela empresa	13,25	1290072	120217	21,15	888724	74060
Previsão Diária	Método aplicado pela empresa	27,61	176220	7580	22,37	41070	2292
	Método adaptado pelo autor	32,27	-31663	7304	31,48	-4804	2822

Os 18 modelos de previsões foram gerados a partir de mudanças no histórico avaliado por cada método e canal. A empresa avaliada tem por padrão a utilização de históricos recentes com os últimos 12 meses em seus processos de planejamento. Todavia, verificou-se o uso dos métodos com períodos menores para analisar o reflexo do histórico e das mudanças de comportamento na demanda planejada.

Os resultados demonstram que o menor MAPE encontrado para previsão mensal foi de 4,69%, obtido com o método de média móvel e utilizando um histórico dos últimos 3 meses dos atendimentos da URA. Em contraste, o maior MAPE para previsão mensal atingiu 21,15%, gerado a partir da técnica aplicada pela empresa com histórico dos últimos 12 meses para os

atendimentos por meio do *chatbot*. Observando os resultados da previsão mensal, apresentados na tabela 1, pode ser sugerido que a utilização de um período menor no histórico afeta positivamente a acurácia da previsão.

Em relação ao CFE, o melhor resultado (menor viés cumulativo) para a previsão mensal foi obtido com o uso da técnica da média móvel ponderada com o histórico dos últimos 3 meses para os atendimentos da URA, resultando em um CFE de 72389. Quanto ao MAD, o melhor resultado (menor dispersão dos erros) foi de 20892, obtido com a técnica da média móvel ponderada, com histórico dos últimos 3 meses para os atendimentos do *chatbot*.

Na comparação dos resultados das previsões diárias, verificou-se que o método aplicado pela empresa apresentou os menores MAPE em ambos os canais, sendo 27,61% para URA e 22,37% para *chatbot*. Em relação ao CFE, os melhores resultados foram obtidos pelo método proposto neste trabalho, sendo -31663 para URA e 7304 para o *chatbot*. Para o caso da medida MAD, o método aplicado pela empresa apresentou o menor resultado de 2292 para os atendimentos do *chatbot*.

As figuras 1 e 2 apresenta uma análise comparativa do desempenho dos métodos de previsão aplicados à demanda da URA. São detalhados os valores da demanda real observada em 2023 em contraste com as demandas planejadas previstas utilizando duas abordagens distintas da média móvel: uma considerando o histórico dos últimos doze meses e outra baseada nos últimos três meses. Esta comparação visa ilustrar a acurácia e a adequação de cada método para o contexto operacional estudado.

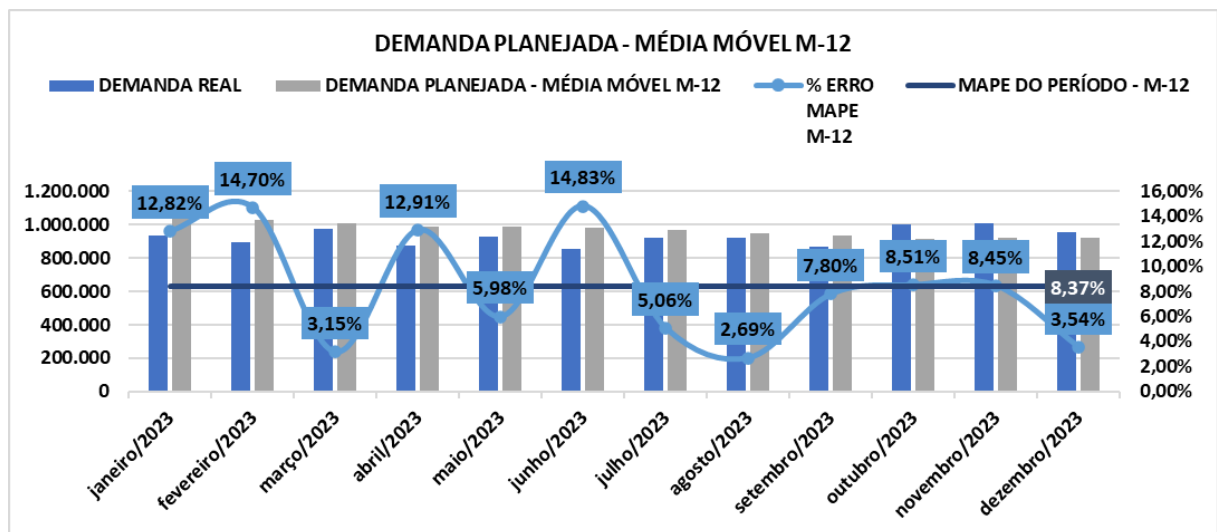


FIGURA 1 – Previsão de demanda para URA utilizando a média móvel com o histórico dos últimos 12 meses.
Fonte: Os autores.




FIGURA 2 – Previsão de demanda para URA utilizando a média móvel com o histórico dos últimos 3 meses. Fonte: Os autores.

As figuras 3 e 4 subsequente apresenta os resultados da previsão de demanda da URA obtidos por meio do método da média móvel ponderada. Foram aplicadas duas configurações distintas: uma utilizando o histórico dos últimos doze meses e outra considerando os últimos três meses. A ponderação empregada atribuiu os seguintes pesos: 0,6 para os períodos mais recentes, 0,3 para os períodos intermediários e 0,1 para os períodos mais antigos, visando refletir a maior influência de dados mais recentes na estimativa da demanda futura.




FIGURA 3 – Previsão de demanda para URA utilizando a média móvel ponderada com o histórico dos últimos 12 meses. Fonte: Os autores.




FIGURA 4 – Previsão de demanda para URA utilizando a média móvel ponderada com o histórico dos últimos 3 meses. Fonte: Os autores.

As figuras 5 e 6 apresenta, na sequência, os resultados da previsão de demanda da URA obtidos pelo método de ajuste sazonal. Foram empregadas duas séries históricas distintas para a aplicação deste método: uma com dados dos últimos doze meses e outra com os últimos três meses. Os parâmetros de suavização, alfa (α) e beta (β), foram determinados por meio da aplicação de regressão linear sobre a média móvel centrada.




FIGURA 5 – Previsão de demanda para URA utilizando o método de ajuste sazonal com o histórico dos últimos 12 meses. Fonte: Os autores.

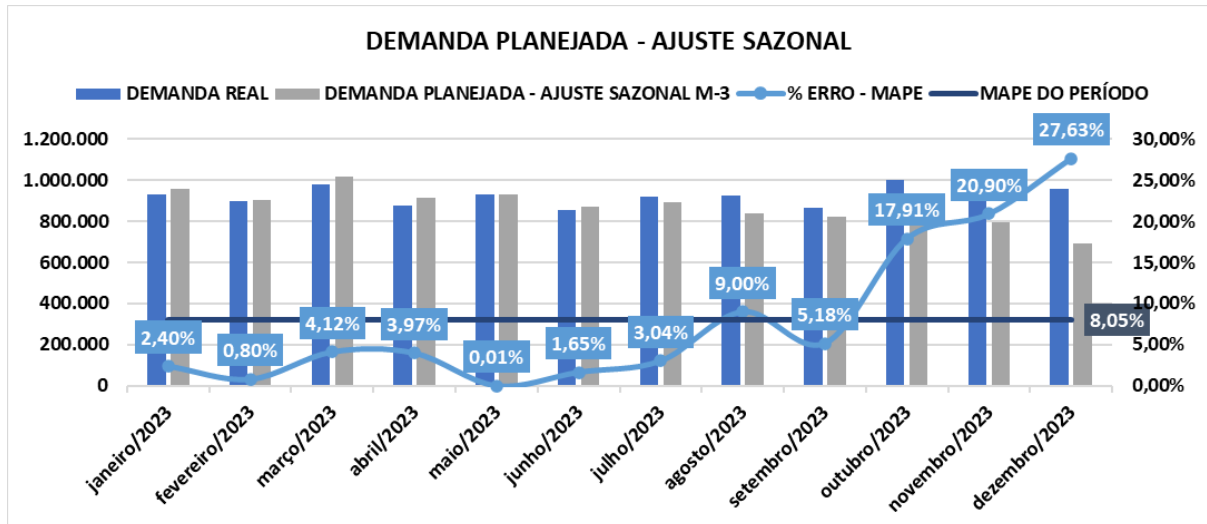


FIGURA 6 – Previsão de demanda para URA utilizando o método de ajuste sazonal com o histórico dos últimos 3 meses. Fonte: Os autores.

A metodologia de previsão de demanda empregada para a URA foi replicada para o canal de atendimento por *chatbot*, utilizando as mesmas técnicas e parâmetros previamente descritos. A tabela 2 e 3 sumariza o desempenho comparativo, apresentando as medidas de erro e os valores da demanda real em contraste com a demanda planejada, obtidos por meio de cada técnica aplicada à demanda do canal por *chatbot*.

Tabela 2 – Previsão de demanda do canal por *chatbot* a partir das técnicas de média móvel, média móvel ponderada e ajuste sazonal utilizando o histórico dos **últimos 12 meses**. Fonte: Os autores.

CHATBOT		Média Móvel M-12				M. Móvel Ponderada M-12				Ajuste Sazonal M-12			
Mês	Dem. real	Planej.	% MAPE	CFE	MAD	Planej.	% MAPE	CFE	MAD	Planej.	% MAPE	CFE	MAD
jan-23	279232	250968	10,12%	28264	28264	255673	8,44%	23559	23559	278917	0,11%	315	315
fev-23	265875	253332	4,72%	40807	20403	260194	2,14%	29241	14620	275217	3,51%	-9026	4828
mar-23	305177	255453	16,29%	90531	30177	263018	13,81%	71400	23800	313419	2,70%	-17268	5966
abr-23	290341	260633	10,23%	120239	30060	269235	7,27%	92506	23127	296655	2,17%	-23581	6053
mai-23	327655	265063	19,10%	182830	36566	274348	16,27%	145813	29163	305925	6,63%	-1852	9188
jun-23	357880	271445	24,15%	269265	44878	283918	20,67%	219775	36629	316962	11,43%	39066	14476
jul-23	357463	280366	21,57%	346362	49480	299051	16,34%	278186	39741	303762	15,02%	92767	20080
ago-23	358903	289818	19,25%	415447	51931	309494	13,77%	327595	40949	319811	10,89%	131858	22456
set-23	339011	298962	11,81%	455496	50611	321957	5,03%	344649	38294	337537	0,43%	133332	20125
out-23	386795	306614	20,73%	535677	53568	328094	15,18%	403350	40335	321925	16,77%	198202	24600
nov-23	401401	318285	20,71%	618793	56254	339810	15,34%	464942	42267	304015	24,26%	295588	31216
dez-23	384681	328089	14,71%	675385	56282	350857	8,79%	498766	41564	296526	22,92%	383743	35961
Erro no período de 12 meses	-	-	16,12%	675385	56282	-	11,92%	498766	41564	-	9,74%	383743	35961

Cabe ressaltar que, apesar de a literatura indicar o método de ajuste sazonal como mais adequado para demandas com sazonalidade (Krajewski, Ritzman; Malhotra, 2009), neste estudo ele não apresentou os melhores índices de erro. Isso pode ser atribuído à natureza específica da demanda observada, onde a sazonalidade pode não ser tão regular ou pronunciada quanto em outros contextos, ou devido aos parâmetros específicos utilizados no modelo de ajuste sazonal para este conjunto de dados.

A adaptação do método da média móvel, proposta neste estudo, incorporou a ordem e o dia da semana dos atendimentos recebidos em ambos os canais para o planejamento da demanda do

mês de dezembro de 2023. Para tanto, utilizou-se o histórico dos últimos dois meses precedentes (outubro e novembro de 2023). A granularidade temporal dessa abordagem baseou-se na análise individualizada de cada dia da semana em sua respectiva ordem mensal (ex: 1ª segunda-feira, 1ª terça-feira, ..., 2ª segunda-feira, etc.), buscando uma compreensão mais aprofundada do comportamento diário da demanda ao longo do mês. As Figuras 4 e 5 ilustram as demandas planejadas para a URA e o *chatbot*, respectivamente, utilizando esta metodologia. Um ponto relevante de observação foi a imprecisão na previsão para 25 de dezembro de 2023, quando o modelo não considerou o status de feriado nacional, tratando a data como um dia útil comum.

Tabela 3 – Previsão de demanda do canal por *chatbot* a partir das técnicas de média móvel, média móvel ponderada e ajuste sazonal utilizando o histórico dos últimos 3 meses. Fonte: Os autores.

CHATBOT		Média Móvel M-3				Média Móvel Ponderada M-3				Ajuste Sazonal M-3			
Mês	Dem. Real	Planej.	% MAPE	CFE	MAD	Planej.	% MAPE	CFE	MAD	Planej.	% MAPE	CFE	MAD
jan-23	279232	265943	4,76%	13289	13289	270202	3,23%	9030	9030	286169	2,48%	-6937	6937
fev-23	265875	276774	4,10%	2390	12094	276115	3,85%	-1210	9635	282416	6,22%	-23477	11739
mar-23	305177	270814	11,26%	36753	19517	270028	11,52%	33939	18140	321706	5,42%	-40006	13336
abr-23	290341	283428	2,38%	43666	16366	290792	0,16%	33488	13717	304137	4,75%	-53801	13451
mai-23	327655	287131	12,37%	84189	21197	292345	10,78%	68797	18036	312852	4,52%	-38998	13721
jun-23	357880	307724	14,01%	134345	26024	314213	12,20%	112464	22308	323728	9,54%	-4846	17126
jul-23	357463	325292	9,00%	166516	26902	342058	4,31%	127868	21321	352087	1,50%	530	15448
ago-23	358903	347666	3,13%	177753	24944	354607	1,20%	132163	19193	345751	3,66%	13682	15161
set-23	339011	358082	5,63%	158682	24291	358368	5,71%	112806	19211	349065	2,97%	3628	14593
out-23	386795	351792	9,05%	193685	25362	346824	10,33%	152777	21287	341583	11,69%	48840	17655
nov-23	401401	361569	9,92%	233517	26678	369670	7,90%	184508	22237	342844	14,59%	107397	21373
dez-23	384681	375736	2,33%	242462	25200	390780	1,59%	178409	20892	309707	19,49%	182371	25840
Erro no período de 12 meses	-	-	7,33%	242462	25200	-	6,06%	178409	20892	-	7,24%	182371	25840




FIGURA 4 – Previsão da demanda da URA a partir da média móvel adaptada. Fonte: Os autores.




FIGURA 5 – Previsão da demanda para o canal do *chatbot* a partir da média móvel adaptada. Fonte: Os autores.

A fim de complementar a análise comparativa, o método de previsão atualmente empregado pela empresa também foi aplicado para o planejamento diário do mês dezembro de 2023. Esta técnica consiste em uma avaliação da média móvel que considera a ordem do dia no mês e o

dia da semana. Por exemplo, são analisados separadamente os dados históricos para o primeiro dia de cada mês, categorizados por ser uma segunda-feira, uma terça-feira, uma quarta-feira, e assim sucessivamente. As figuras 6 e 7 subsequente ilustram os resultados da demanda prevista para a URA e *chatbot* utilizando este método atualmente em uso pela organização.




FIGURA 6 – Previsão da demanda da URA a partir da média móvel utilizada pela empresa. Fonte: Os autores.




FIGURA 7 – Previsão da demanda do *chatbot* a partir da média móvel utilizada pela empresa. Fonte: Os autores.

O modelo de previsão de demanda utilizado pela empresa demonstra boa aderência em condições normais de operação. No entanto, também apresenta fragilidade para lidar com anomalias ou sazonalidades específicas, como feriados nacionais. O MAPE de 22,37% e 27,61% para o período total indicam que há espaços significativos para otimização do modelo, especialmente pela incorporação de fatores exógenos (como feriados, eventos) que influenciam diretamente o volume dos atendimentos recebidos em ambos os canais.

5 Conclusão

A capacidade de prever a demanda é uma ferramenta estratégica indispensável para as organizações e seus gestores. Permite não apenas estimar o volume futuro de atendimentos, mas também dimensionar de forma precisa os recursos necessários para a prestação de serviços, impactando diretamente a receita, os custos e os investimentos.

Este artigo, de caráter descritivo e com abordagem quantitativa, analisou e previu a demanda mensal e diária de atendimentos de URA e *chatbot* em um *Contact Center* que atua no setor de telecomunicações. Por meio da aplicação de técnicas de séries temporais, incluindo métodos amplamente citados na literatura e adaptações desenvolvidas no âmbito do próprio estudo, as previsões foram comparadas com os volumes reais de atendimentos para determinar a acurácia por meio das métricas de erro MAPE, CFE e MAD.

Os resultados para o horizonte de planejamento de doze meses indicam que a média móvel com um histórico de três meses se mostrou a mais acurada para a URA (MAPE de 4,69%). Para o *chatbot*, a média móvel ponderada apresentou o menor MAPE de 6,06%, com um histórico de três meses. Estes dois cenários apresentaram resultado superior ao método aplicado pela organização, os quais apresentaram o MAPE de 13,25% e 21,15%, respectivamente para os canais da URA e *chatbot*.

O melhor CFE foi obtido também com o uso do método da média móvel ponderada com o histórico de três meses para ambos os canais, enquanto o método da média móvel, com três meses de histórico, obteve o menor MAD. Estes resultados reforçam a percepção de que, para a demanda analisada, períodos históricos mais curtos tendem a gerar previsões mais precisas, possivelmente devido à volatilidade ou rápidas mudanças no comportamento da demanda dos canais automatizados.

Em relação aos resultados para o horizonte de planejamento diário, foi realizado a comparação entre o método aplicado pela empresa e o método proposto neste trabalho. Quatro cenários foram avaliados com a realização da previsão de demanda para os dias do mês de dezembro de 2023.

Nestes cenários, o método aplicado pela empresa apresentou o menor MAPE para ambos os canais, sendo estes de 27,61% e 22,37%, respectivamente para os atendimentos da URA e *chatbot*. Com relação ao CFE, os menores desvios foram apresentados pelo método proposto para os dois canais. Em relação ao MAD, o método aplicado pela empresa apresentou o menor erro para o canal do *chatbot* e para o caso da URA, o método proposto teve melhor desempenho.

Uma contribuição prática deste estudo é a identificação de técnicas de previsão que podem otimizar o planejamento da empresa, auxiliando na alocação de recursos e na gestão de custos. A aplicação da teoria em um cenário real também contribui para a literatura acadêmica.

Para futuras pesquisas, sugere-se a exploração de métodos de previsão mais avançados, como aqueles que utilizam inteligência artificial e machine learning. Tais abordagens inovadoras podem oferecer uma compreensão ainda mais profunda e acurada do comportamento da demanda em *Contact Centers*, especialmente em cenários com padrões complexos ou em constante evolução.

Referências

ACKERMANN, Andres E. F.; SELLITTO, Miguel A. Métodos de previsão de demanda: uma revisão da literatura. **Innovar**, Bogotá, v. 32, n. 85, p. 83-99, set. 2022.

ARUNRAJ, N.; AHRENS, D.; FERNANDES, M. Application of SARIMAX model to forecast daily sales in food retail industry. **International Journal of Operations Research and Information Systems**, v.7, p.1-21. 2016.

BARBOSA, Luiz Henrique Santana; GOMES, Carlos Francisco Simões; CHAVES, Maria Cecília C. Uso de programação inteira para escalonamento de agentes em call centers receptivos multilíngues. **Revista Eletrônica Pesquisa Operacional Para O Desenvolvimento**, Rio de Janeiro, v. 7, n. 2, p. 147-172, mai-nov 2015.

BOUZADA, Marco Aurélio Carino; SALIBY, Eduardo. Prevendo a demanda de ligações em um call center por meio de um modelo de Regressão Múltipla. **Gestão & Planejamento**, São Carlos, v. 16, n. 3, p. 382-397, jul.-set. 2009.

BUGOR, F. B.; LUCCA FILHO, J. de. A importância do planejamento, programação e controle da produção (ppcp) para o desenvolvimento das indústrias atuais. **Revista Interface Tecnológica**, [S. l.], v. 18, n. 1, p. 461-473, 2021.

CAMBUÍ, Caio Matheus Comar et al. Aplicações de previsão de demanda por meio de séries temporais. **Revista de Gestão e Secretariado - GESEC**, São Paulo, v. 14, n. 2, p. 1477-1490, 2023.

CARVALHO, Daniel Estima de; GUAZZELLI, Rinaldo Luiz; GASPAS, Marcos Antônio. Uma Análise do Uso da Internet e Redes Sociais no Segmento de Call Centers: os telefones vão

parar de tocar?. **International Journal Of Professional Business Review**, São Paulo, v. 3, n. 2, p. 340-359, jul./dez. 2018.

CHANDEL, Sonali; YUYING, Y.; YUJIE, G., RAZAQUE, A.; YANG, G. Chatbot: efficient and utility-based platform. **Advances In Intelligent Systems And Computing**, [S.L.], p. 109-122, 2 nov. 2018.

COSTA, José Fabiano da Serra; FELIPE, Ada Priscila Machado; RODRIGUES, Monique de Menezes. Avaliação da escolha de unidade de resposta audível (URA) através do Método de Análise Hierárquica (AHP). **Revista Gestão da Produção Operações e Sistemas - GEPROS**, São Paulo, v. 3, n. 3, p. 147-161, dez. 2008.

FERRUZZI, Marcos Antonio; SACOMANO NETO, Mário; SPERS, Eduardo Eugênio; PONCHIO, Mateus Canniatti. Razões da terceirização de serviços em empresas de médio e grande porte. **BBR - Brazilian Business Review**, Vitória, v. 8, n. 4, p.46-69, out. 2011.

FILDES, Robert; MA, Shaohui; KOLASSA, Stephan. Retail forecasting: research and practice. **International Journal Of Forecasting**, [S.L.], v. 38, n. 4, p. 1283-1318, out. 2022. <https://doi.org/10.1016/j.ijforecast.2019.06.004>

FOLHA DE SÃO PAULO. Serviços e indústria puxam PIB de 2024 no Brasil; agro cai. **Folha de S.Paulo**, São Paulo, 5 mar. 2025. Disponível em: <https://www1.folha.uol.com.br/mercado/2025/03/servicos-e-industria-puxam-pib-de-2024-no-brasil-agro-cai.shtml#:~:text=O%20setor%20de%20servi%C3%A7os%20%C3%A9,da%20oferta%20no%20ano%20passado.>

JUNIPER RESEARCH (Hampshire - Uk). CCaaS Market Value to Near \$16 Billion in Global Revenue by 2027. 2022.

KRAJEWSKI, Lee; RITZMAN, Larry; MALHOTRA, Manoj. **Administração de Produção e Operações**. 8. ed. São Paulo: Pearson Prentice Hall, 2009.

MALHOTRA, Naresh. **Pesquisa de Marketing**: uma orientação aplicada. 6. ed. Porto Alegre: Bookman, 2012.

MARTINS, Diogo Barreto; STRAMBI, Orlando. Forecasting upon a star: forecasting or wishful thinking?. **Journal Of Air Transport Management**, Orlando, v. 91, p. 1-17, mar. 2021.

MELLO, Alvaro. **O uso de teletrabalho nas empresas de call center e contact center**: um estudo das forças propulsoras, restritivas e contribuições. São Paulo: Laços, 2021.

OLIVEIRA, R. V. de; MORAES, A. C. N. de. A reconfiguração espacial do segmento de call center no Brasil vista a partir da instalação de centrais de teleatividades na Paraíba|The space reconfiguration of the call center segment in Brazil seen from the implementation of the teleactivity centers in Paraíba. **Revista Brasileira de Estudos Urbanos e Regionais**, [S. l.], v. 21, n. 2, p. 371, 2019.

PEINADO, Jurandir; GRAEML, Alexandre Reis. **Administração da Produção** (Operações industriais e de serviços). Curitiba: Unicenp, 2007.

ROMÃO, Estevão Luiz et al. Estudo Comparativo entre Modelos Autoregressivos Integrados de Médias Móveis e Redes Neurais Artificiais na Modelagem e Previsão de Séries Econométricas. In: **XL ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO**, 40, 2020, Foz do Iguaçu. Anais eletrônicos. Foz do Iguaçu: Enegep, 2020. p. 1-12.

ROQUE, Pedro Henrique da Silva; GOMES, Rogério Martins; SANTOS, Bruno André; FERREIRA, Marcela Richele. Modelagem da previsão do volume de chamadas recebidas por um Call Center. **Sociedade Brasileira de Automática**, [S. l.], v. 1, n. 1, p. 83-88, out. 2021.

SÁ, Ana Cristina dos Anjos Grilo Pinto de; SÁ, Patrícia Helena Ferreira Lopes de Moura e. As Características da Função e seu Impacto nos Níveis de Satisfação do Funcionário de Contato: um estudo em uma grande empresa de telecomunicações. **Revista Brasileira de Gestão de Negócios**, São Paulo, v. 16, n. 53, p. 658-676, out./dez. 2014.

TUBINO, Dalvio Ferrari. **Planejamento e Controle da Produção**: teoria e prática. São Paulo: Atlas, 2007.

VERGARA, Sylvia Constant. **Métodos de pesquisa em Administração**. 5. ed. São Paulo: Atlas, 2005.

VIANA, L. D. A. L.; GRECCO, V. E. A.; MORETTO, G. S.; RAMOS, N. B.; KALILI, R. M. Aplicação De Machine Learning Na Previsão De Demandas: Otimização De Recursos No Setor De E-Commerce. **Revista Contemporânea**, v.4, n.11, 2024.