

PREVISÃO DE DEMANDA EM UM CONTACT CENTER

Resumo

Este artigo avalia a previsão de demanda de atendimentos recebidos em Unidades de Resposta Audível (URA) 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 13 cenários, abrangendo métodos sugeridos na literatura, uma adaptação proposta pelos autores, o método atualmente empregado pela empresa e os modelos de redes neurais LSTM combinados com camadas convolucionais. 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 melhor desempenho para previsão mensal foi o método com a média móvel utilizando o histórico dos últimos três meses em relação ao mês planejado para a URA. Este método obteve o menor MAPE de 4,69% e o menor MAD de 43764. Na previsão diária para um horizonte de 1 mês, o método que utilizou o modelo de rede neural Conv1-LSTM apresentou o melhor desempenho, obtendo o menor MAPE 15,53% e menor MAD de 4544. Estes métodos superaram a metodologia empregada pela empresa que se baseia na média móvel e considera o histórico dos últimos 12 meses. Os resultados indicam que, para a demanda específica analisada, a utilização de períodos históricos mais curtos pode resultar em maior acurácia e destacam que os modelos de redes neurais têm potencial de aplicação prática para organização.

Palavras-chave: Previsão de demanda; Serviços; URA; Séries Temporais; Redes Neurais.

36° ENANGRAD

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 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).

Neste contexto, os *Contact Centers*, inseridos no setor terciário, desempenham um papel estratégico na terceirização do atendimento ao cliente para diversas empresas. Dada a natureza da sua atividade principal, uma parcela substancial dos custos destas empresas está atrelada à mão de obra dedicada ao atendimento (Barbosa; Gomes; Chaves, 2015). Com este cenário, 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.

Com objetivos orientados à redução de custo, estas organizações buscam melhorar a eficiência de seus processos, principalmente aqueles relacionados ao planejamento de seus recursos e ao planejamento da demanda de atendimentos. Para estes planejamentos, a previsão precisa do volume de chamadas e interações é essencial para que as estratégias organizacionais sejam desdobradas em todos os níveis, impactando diretamente a rentabilidade e a satisfação do cliente. É comum que, neste setor, a receita seja variável e relacionada com o volume de atendimentos recebidos e com indicadores e níveis de serviço acordados em contrato. Caso não sejam atingidos, penaliza-se o faturamento. 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*. Tradicionalmente, a previsão de demanda tem se apoiado em métodos estatísticos de séries temporais, como média móvel simples, média móvel ponderada, suavização exponencial e Box-Jenkins. No entanto, esses métodos frequentemente enfrentam dificuldades com relações complexas, não lineares e dinâmicas de alta dimensionalidade presentes nos dados de demanda.

Com o advento do Aprendizado de Máquina (*Machine Learning* - ML), observa-se uma transformação na abordagem de previsão da demanda (Fukai, 2024). O ML, como uma técnica da IA, permite que os sistemas de computador aprendam com a experiência em forma de dados, identificando padrões complexos e relações ocultas que os seres humanos não conseguiriam, e gerando previsões mais precisas e confiáveis (Ni xiao Lim 2019). Esses modelos são capazes de manipular grandes volumes de dados e lidar com variáveis adicionais, como sazonalidade, campanhas promocionais e tendências de consumo, ajustando-se a variações inesperadas e à volatilidade dos mercados (Viana, 2024). Exemplos de modelos com Redes Neurais Recorrentes (RNNs) e suas variações, como as Redes Long Short-Term Memory (LSTM), têm se mostrado eficazes na modelagem de séries temporais (Rahimi, 2024; Fukai, 2024). Adicionalmente, variantes como Conv1D-LSTM, uma variação que utiliza convoluções unidimensionais combinadas com a arquitetura LSTM, tem se mostrado capaz de capturar características locais e temporais, superando outros modelos LSTM em diversas métricas de desempenho.

Apesar da relevância do tema, estudos sobre previsão de demanda na área de serviços e *contact centers* carecem de investigações empíricas (Fildes; Ma; Kolassa, 2019; Arunraj, Ahrens, Fernandes, 2016; Viana et al., 2024). Este trabalho busca contribuir com essa lacuna ao focar em um cenário real de operação de um *contact center*.

Assim, a partir da importância do tema e da experiência profissional de um dos pesquisadores como colaborador em uma empresa de *Contact Center*, na área de análise de dados, este trabalho tem como objetivo principal avaliar e comparar a eficácia de diferentes métodos de previsão da demanda de atendimentos entrantes nas URAs (canal de voz) de uma operação específica de *Contact Center* que atende clientes do ramo de telecomunicações. Em particular, o estudo analisará modelos de previsão de séries temporais baseados na média móvel, uma vez que são métodos conhecidos pela organização, um modelo proprietário da empresa, e modelos de aprendizado profundo, especificamente a rede LSTM e sua variante Conv1D-LSTM. A comparação visa identificar a técnica mais adequada para apoiar a tomada de decisão da empresa e otimizar o controle de custos e a alocação de recursos.

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 pesquisa-ação.

2. Fundamentação Teórica

A previsão de demanda é um dos pilares da gestão de operações e do planejamento estratégico de qualquer organização. Bugor e Lucca Filho (2021) destacam que na alta competitividade existente entre as empresas, praticar com excelência as atividades de planejamento, programação e controle da produção é fator de diferenciação para que uma delas seja bem-sucedida, proporcionando eficiência. 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) destaca que 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 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 da demanda em Contact Center

Impulsionados pelos avanços tecnológicos e pela expansão dos atendimentos remotos durante a pandemia de COVID-19, os *Contact Centers* evoluíram para estruturas multicanais, superando o modelo tradicional baseado em chamadas telefônicas (Roque et al., 2021). A terceirização desse serviço por empresas especializadas visa, sobretudo, a qualificação técnica dos prestadores, a racionalização dos custos operacionais e o redirecionamento estratégico do foco empresarial. Entre esses fatores, a otimização de custos se destaca como critério decisivo na escolha de parceiros (Ferruzzi et al., 2011).

O *Contact Center* representa uma evolução do *Call Center*, incorporando múltiplos canais digitais de comunicação além das chamadas telefônicas tradicionais. Estruturados como centrais de atendimento, esses serviços englobam funções como vendas, cobranças, suporte técnico e fornecimento de informações, operando sob processos informatizados, rigorosamente controlados e padronizados (Oliveira; Moraes, 2019). Segundo Mello (2021), o setor se distribui majoritariamente entre atendimento ao consumidor (47%), vendas (23%) e cobranças (22%), com os 8% restantes em atividades não categorizadas.

A busca pela eficiência operacional leva os *Contact Centers* a automatizar tarefas repetitivas por meio de ferramentas como URAs e chatbots. As URAs (Unidades de Resposta Audível) realizam o pré-atendimento de chamadas receptivas com opções interativas ou pré-definidas (Costa, Felipe & Rodrigues, 2008), enquanto os *chatbots* simulam diálogos em linguagem natural, seguindo regras de negócio para atendimento em tempo real (Chandel et al., 2018).

Diante da alta competitividade do setor, o planejamento da demanda tornou-se estratégico. Para Roque, Gomes, Santos e Ferreira (2021), a previsão do volume de atendimentos é essencial para o dimensionamento adequado de equipes e infraestrutura, impactando diretamente a rentabilidade e o cumprimento dos Níveis de Serviço (NS) contratados. Informações e previsões precisas, portanto, configuram-se como diferenciais competitivos relevantes, permitindo que fornecedores alinhem as expectativas de custo e serviço em contratos.

2.2. Métodos tradicionais versus técnicas contemporâneas

É evidente que o volume de dados disponíveis para as organizações no dia a dia está cada vez maior. Tanto as empresas de grande porte, tais como, Amazon, Mercado Livre e Alibaba, como empresas de médio porte, buscam modelos para prever o comportamento do consumidor em tempo real, ajustando automaticamente seus estoques, cadeias de suprimentos e estratégias de marketing com base nas previsões geradas (Seyedan, Mafakheri, 2020). Nesse preâmbulo, os métodos tradicionais de previsão, baseados em séries temporais, asseveram que a demanda passada pode estimar estatisticamente a demanda futura (Fatima, Rahimi, 2024; Marchese, Sozzo, 2024).

Assim, envolvem a análise de padrões de comportamento de séries temporais. Contudo, a identificação de componentes como tendência, sazonalidade, variação aleatória e outros fatores podem influenciar a qualidade dos resultados (Ni; Xiao; Lim, 2019). Entre as abordagens iniciais e mais diretas, destacam-se a Média Móvel (MA), que oferece uma estrutura fundamental para a análise temporal de dados, e a Suavização Exponencial (ES). Conforme Rahimi (2024), estes modelos clássicos, juntamente com suas variantes como a média móvel ponderada e a suavização com tendência, são amplamente utilizados devido à sua simplicidade e interpretabilidade, facilitando a identificação de padrões e tendências em conjuntos de dados temporais.

Viana et al. (2024) destacam que a regressão linear é uma técnica simples e amplamente utilizada para previsão de demanda, que busca identificar uma relação linear entre variáveis independentes (como preço ou sazonalidade) e a demanda. Apesar de ser eficaz em cenários com baixa complexidade e padrões estáveis, ela pode falhar em capturar relações mais complexas, especialmente em ambientes de e-commerce com variações rápidas e não lineares. Nesse interim, o aprendizado de máquina (em inglês, *machine learning*) viabiliza um diferencial competitivo para as organizações, avaliando oportunidades de maior acurácia (menor erro) e precisão (garantia de repetibilidade). Consequentemente, proporcionam uma melhor gestão dos recursos, menores custos e aumento da margem de lucro das operações (Tirkolaei et al., 2021).

O aprendizado de máquina é um campo de pesquisa que está na interseção de Inteligência Artificial, Ciência da Computação e Estatística e também conhecido como análise preditiva ou aprendizado estatístico (Sousa, 2024). Segundo Tirkolaei et al. (2021), essa abordagem aprimora o desempenho de sistemas ao permitir que algoritmos aprendam padrões a partir de dados, por meio de métodos computacionais. Viana et al. (2024) destacam que o objetivo central do aprendizado de máquina é desenvolver modelos preditivos robustos, utilizando algoritmos como *Random Forest*, *Extreme Gradient Boosting* (XGBoost) e *LightGBM*, amplamente aplicados em tarefas de classificação e regressão.

A adoção dessas técnicas possibilita a detecção de padrões complexos e a geração de previsões em tempo real, promovendo maior controle sobre estoques e flexibilidade na gestão operacional (Viana et al., 2024). No contexto da previsão de demanda, o uso de modelos de aprendizado profundo (deep learning), como Convolutional Neural Networks (CNNs) e Long Short-Term Memory networks (LSTMs), tem se mostrado particularmente eficaz. As CNNs, embora originalmente desenvolvidas para processamento de imagens, têm sido adaptadas para capturar padrões espaciais em séries temporais, enquanto as LSTMs são projetadas para lidar com dependências de

longo prazo, sendo altamente adequadas para dados sequenciais e temporais (Fukai, 2024).

Choi et al. (2021) ressaltam que modelos baseados em redes neurais e árvores de decisão são capazes de identificar relações não lineares e dinâmicas, ajustando-se com eficiência a flutuações inesperadas e à volatilidade dos mercados. Apesar dos avanços e do crescente interesse acadêmico e industrial, ainda persistem lacunas na literatura, especialmente no que diz respeito à comparação sistemática entre diferentes arquiteturas de redes neurais aplicadas à previsão de demanda no varejo (Fan et al., 2020; Fukai, 2024).

2.2.1. Modelos de Aprendizado Profundo

O Aprendizado Profundo (Deep Learning), uma subárea de Aprendizado de Máquina (Machine Learning - ML), tem se mostrado particularmente eficaz na modelagem de dependências de longo prazo e no manuseio de dados de alta dimensionalidade, características comuns em séries temporais complexas (Fatima, Rahimi, 2024). Nesse contexto, as Redes Neurais Recorrentes (RNNs) surgem como uma classe de redes neurais desenvolvidas especificamente para processar dados sequenciais, capturando dinâmicas temporais e dependências de longo prazo através de suas conexões de retroalimentação, que funcionam como uma "memória" para informações de cálculos anteriores (Fatima, Rahimi, 2024). As Redes Long Short-Term Memory (LSTM) representam uma extensão das RNNs, pois foram projetadas para superar problemas como o desaparecimento ou explosão de gradientes, que limitam as RNNs tradicionais na aprendizagem de dependências de longo prazo. As LSTMs são capazes de modelar sequências com dependências temporais complexas e capturar sazonalidades de curto e longo prazo, mantendo essa informação por longos períodos (Fukai, 2024).

A arquitetura de uma rede LSTM, ilustrada na Figura 1, é composta por células de memória com uma estrutura interna bem definida, incluindo um estado de célula (C_t), que retém a memória de longo prazo, e um estado oculto (h_t), que representa a memória de curto prazo. As modificações e o fluxo de informação dentro da célula são controlados por três portas ou *gates*: a porta de esquecimento que decide quais informações devem ser descartadas; a porta de entrada que controla quais informações serão armazenadas; e a porta de saída que determina quais partes do estado da célula serão utilizadas como saída do modelo e para atualização do estado oculto no próximo passo.




FIGURA 1 – Arquitetura da célula LSTM. Fonte: Fan (2020).

Outra arquitetura de rede considerada uma variação da LSTM é a ConvLSTM (Convolutional LSTM). Esta rede combina operações de convolução de Redes Neurais Convolucionais (CNNs) com a arquitetura LSTM. Essa fusão permite à

ConvLSTM capturar tanto dependências temporais quanto características espaço-espectrais dos dados, sendo especialmente adequada para análise espaço-temporal detalhada em séries temporais complexas (Shi et al., 2022). No contexto de séries temporais unidimensionais, a Conv1D-LSTM (uma variação da ConvLSTM) utiliza convoluções unidimensionais (Conv1D) para extrair características locais e temporais dos dados antes de processá-los com a LSTM. A Conv1D é conhecida por sua menor complexidade computacional e eficácia na extração de características locais em sinais e séries temporais. A estrutura interna da ConvLSTM, que se aplica à Conv1D-LSTM, é visualmente representada na figura 2.




FIGURA 2 – Estrutura interna da rede ConvLSTM. Fonte: Shi et al. (2022).

Segundo Fukai (2024), essa abordagem se mostrou mais eficaz que redes LSTM tradicionais na previsão de demanda no varejo. Ela permite que o modelo aprenda relações dinâmicas e complexas com maior precisão e estabilidade.

Este estudo analisa a aplicação de modelos clássicos de séries temporais, fundamentados em métodos estatísticos alinhados às práticas operacionais da empresa investigada, bem como a implementação de redes neurais LSTM e Conv1D-LSTM para a previsão dos volumes de chamadas entrantes no canal de URA. O objetivo é comparar o desempenho preditivo desses modelos baseados em aprendizado profundo com os resultados obtidos pelos métodos estatísticos tradicionais.

2.2.2. Avaliação da qualidade preditiva

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 Y_t e a demanda prevista $\hat{Y}_t$ para um período t : $E_t = Y_t - \hat{Y}_t$. 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 1, conforme Romão et al. (2020).

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

- 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 (2), conforme Krajewski, Ritzman e Malhotra (2009).

(2)

$$CFE = \sum E_t$$

- 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 (3), conforme Krajewski, Ritzman e Malhotra (2009).

(3)

$$MAD = \frac{\sum |E_t|}{n}$$

3. Metodologia

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 seu canal da URA. 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 estatísticos, um método utilizado pela empresa, um modelo de rede LSTM e um modelo de rede Conv1D-LSTM. A previsão de demanda mensal para o horizonte de planejamento anual foi avaliada com 6 métodos, sendo que para os métodos estatísticos foram considerados a média móvel, a média móvel ponderada e ajuste sazonal. Nos métodos estatísticos ainda se utilizou uma variação do histórico de dados utilizado para a previsão, optando por janelas de 3 ou 12 meses. Estas combinações totalizaram 9 cenários de planejamento para o horizonte de planejamento anual.

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 e com os modelos de rede LSTM e Conv1D-LSTM. Ambos os métodos foram avaliados para o canal URA, totalizando 4 cenários.

A arquitetura da rede neural foi projetada com o uso da biblioteca Keras (TensorFlow) e consiste em modelos sequenciais. O primeiro modelo é composto por duas camadas de LSTM empilhadas, seguidas por uma camada de *dropout* e uma camada de saída densa conforme apresentado na figura 1.

Layer (type)	Output Shape	Param #
lstm (LSTM)	(None, 90, 100)	42,400
lstm_1 (LSTM)	(None, 100)	80,400
dropout (Dropout)	(None, 100)	0
dense (Dense)	(None, 1)	101

Figura 1. Arquitetura da rede LSTM

O segundo modelo consiste em uma rede Conv1-LSTM que é composta por duas camadas convolucionais empilhadas, duas camadas de LSTM empilhadas, uma camada densa seguida por uma camada de *dropout* e uma camada de saída densa conforme apresentado na figura 2.

Layer (type)	Output Shape	Param #
conv1d_76 (Conv1D)	(None, 88, 128)	2,048
conv1d_77 (Conv1D)	(None, 86, 64)	24,640
lstm_84 (LSTM)	(None, 86, 100)	66,000
lstm_85 (LSTM)	(None, 100)	80,400
dense_80 (Dense)	(None, 100)	10,100
dropout_42 (Dropout)	(None, 100)	0
dense_81 (Dense)	(None, 1)	101

Figura 2. Arquitetura da rede LSTM

A base de dados foi segmentada em conjuntos de treinamento e teste para a validação do modelo. A separação foi feita de forma temporal, com 80% dos dados para treinamento e 20% para teste, mantendo a ordem cronológica e assegurando uma avaliação realista da capacidade preditiva do modelo em dados não vistos. A busca por hiper parâmetros também foi realizada considerando a combinação dos seguintes valores e parâmetros: 'units': [30, 50, 100], 'dropout': [0.1, 0.2], 'optimizer', ['adam', 'rmsprop'], 'batch_size': [32, 64] e 'epochs': [100, 150]. As previsões obtidas foram avaliadas utilizando os índices de erro MAPE, CFE e MAD.

4. Análise e Discussão dos Resultados

Neste trabalho foram aplicados os métodos estatísticos de previsão baseado em séries temporais e os modelos de aprendizado de máquina para o canal de URA do *Contact Center*. De acordo com os múltiplos contextos testados, gerou-se 13 cenários de planejamento de demanda, o que permitiu comparar a acurácia dos métodos propostos e das abordagens já utilizadas pela empresa. Na tabela 1 a seguir apresenta-se a configuração dos cenários gerados e os respectivos resultados dos índices de erro considerados para avaliação.

Os 13 modelos de previsões foram gerados a partir de mudanças no histórico avaliado por cada método. 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 estatísticos com períodos menores para analisar o reflexo do histórico e das mudanças de comportamento na demanda planejada. Por outro lado, nos modelos de rede LSTM e Conv1D-LSTM foram considerados a inclusão de algumas variáveis categóricas com o objetivo de capturar padrões comportamentais e sazonais que influenciem diretamente no volume de chamadas. Após uma análise exploratória dos dados realizada com o uso de histogramas, correlações, gráficos de dispersão e regressão, definiu-se como variáveis de entrada de ambos os modelos de rede: o volume de chamadas do canal, o dia da semana

categorizada com valores de 1 a 7, o dia do mês categorizado de 1 a 31, a identificação de feriado categorizado com valores 0 ou 1, e a média móvel dos últimos 90 dias.

O método proposto neste estudo considerou uma adaptação da média móvel, o qual incorporou a ordem e o dia da semana dos atendimentos recebidos no canal da URA para o planejamento da demanda diária do mês de dezembro de 2023. 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. O método de previsão atualmente empregado pela empresa, aplicado para o planejamento mensal e diário, consiste em uma avaliação da média móvel que considera a ordem do dia no mês e o dia da semana. Por exemplo, neste método 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.

Tabela 1 – Cenários de planejamento da demanda para o canal de URA do Contact Center. Fonte: Os autores

OBJETIVO	MÉTODO	Histórico	MAPE	CFE	MAD
Previsão Mensal - Horizonte 12 meses	Média móvel	12 meses	8,37	-512325	76756
		3 meses	4,69	92950	43764
	Média móvel ponderada	12 meses	5,93	-227644	54655
		3 meses	5,11	72389	47665
	Ajuste sazonal	12 meses	10,33	1135188	99471
		3 meses	8,05	692058	77455
	Rede LSTM	3 meses	6,66	-330157	62259
	Rede Conv1D-LSTM	3 meses	5,39	525667	51516
Previsão Diária - Horizonte 30 dias	Método aplicado pela empresa	12 meses	13,25	1290072	120217
	Rede LSTM	3 meses	20,83	-330155	5677
	Rede Conv1D-LSTM	3 meses	15,53	525663	4544
	Método aplicado pela empresa	12 meses	27,61	176220	7580
	Método adaptado pelo autor	2 meses	32,27	-31663	7304

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 13,25%, gerado a partir da técnica aplicada pela empresa com histórico dos últimos 12 meses. 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 aos modelos de redes LSTM, ambos apresentaram bons resultados para a previsão mensal, considerando que o conjunto de dados disponível de 4 anos é relativamente pequeno para o treinamento de redes profundas. Entre os dois modelos, a rede LSTM combinada com camadas convolucionais apresentou melhor MAPE com o valor de 5,39%, no entanto, não superou o método da média móvel para a previsão mensal. 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 43764, obtido com a técnica da média móvel, com histórico dos últimos 3 meses dos atendimentos da URA.

Nas figuras 3 e 4 é apresentada uma análise comparativa do desempenho dos 2 métodos que obtiveram o menor MAPE aplicados à previsão da demanda mensal da URA. São detalhados os valores da demanda real observada em 2023 em contraste com as demandas planejadas previstas utilizando a abordagem da média móvel com histórico dos últimos três meses e o modelo de rede Conv1D-LSTM. Esta comparação visa ilustrar a acurácia e a adequação de cada método para o contexto operacional estudado.




FIGURA 3 – Previsão de demanda para URA utilizando o modelo de rede Conv1D-LSTM. Fonte: Os autores.




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

No método da média móvel ponderada também foram considerados os dois períodos históricos dos últimos doze meses e dos últimos três meses. A ponderação empregada considerou os 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. Para o método de ajuste sazonal, também se utilizou os dois períodos históricos, e os parâmetros de suavização, alfa (α) e beta (β), foram determinados por meio da aplicação de regressão linear sobre a média móvel centrada. Cabe ressaltar que, apesar da 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, em que 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.

Na comparação dos resultados das previsões diárias, verificou-se que o modelo de rede LSTM combinado com camadas convolucionais apresentou o menor MAPE de 15,53% e o menor MAD no valor de 4544. Em relação ao CFE, o melhor resultado foi obtido pelo método proposto neste trabalho, sendo -31663 para os atendimentos da URA. O método atualmente utilizado pela empresa não apresentou um bom desempenho para os índices de erro utilizados na avaliação e o método proposto neste estudo somente apresentou melhor resultado para o índice de erro CFE, superando neste indicador os modelos de rede LSTM e o método da empresa. As Figuras 5 e 6 ilustram as demandas diárias previstas para o volume de entradas na URA do mês de dezembro de 2023. 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.




FIGURA 5 – Previsão da demanda da URA a partir da média móvel adaptada. Fonte: Os autores.




FIGURA 6 – Previsão da demanda da URA utilizando o modelo de rede Conv1D-LSTM. 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 27,61% para o período total indica que há espaços significativos para otimização do modelo.

5. Conclusão e contribuições

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 em um Contact Center que atua no setor de telecomunicações. Por meio da aplicação de técnicas de

séries temporais e aprendizado de máquina, 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%). Os modelos de redes neurais LSTM combinados com camadas convolucionais também apresentaram bons resultados, obtendo para o mesmo horizonte de planejamento o MAPE de 5,39%. Estes dois cenários apresentaram resultados superiores ao método aplicado pela organização, o qual apresentou o MAPE de 13,25%. O melhor CFE foi obtido com o uso do método da média móvel ponderada com o histórico de três meses, 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 do canal automatizado.

Em relação aos resultados para o horizonte de planejamento diário, foi realizada a comparação entre o método aplicado pela empresa, um método proposto neste trabalho e os modelos de redes neurais LSTM e Conv1D-LSTM. Quatro cenários foram avaliados com a realização da previsão de demanda para os dias do mês de dezembro de 2023. Nestes cenários, o método que utilizou a rede neural Conv1D-LSTM apresentou o menor MAPE, sendo este de 15,53% para os atendimentos da URA. Com relação ao CFE, o menor desvio foi apresentado pelo método proposto neste estudo. Em relação ao MAD, o modelo de rede neural Conv1D-LSTM apresentou o menor erro para o canal da URA.

Os modelos de redes neurais recorrentes do tipo LSTM empregados neste estudo incorporaram variáveis categóricas com o propósito de capturar nuances comportamentais e padrões sazonais que impactam diretamente o volume de chamadas. Os resultados obtidos revelaram desempenho promissor, indicando potencial significativo de aprimoramento. Tais avanços podem ser alcançados mediante a ampliação da base de dados utilizada para treinamento, bem como pela inclusão de variáveis adicionais que contribuam para a modelagem dos fatores sazonais e comportamentais subjacentes. 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 sobre a gestão de operações de Contact Centers.

Referências Bibliográficas

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 Cecilia 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; GASPARG, 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.

FAN, Hongxiang; MINGLIANG, Jiang; LIGANG, Xu; HUA, Zhu; JUNXIANG, Cheng; JIAHU, Jiang. Comparison of Long Short-Term Memory Networks and the Hydrological Model in Runoff Simulation. **Water**, v. 12, n. 1, 2020. 175. <https://doi.org/10.3390/w12010175>.

FATIMA, S. S. W.; RAHIMI, A. A review of time-series forecasting algorithms for industrial manufacturing systems. **Machines**, v.12, n.6, 2024. <https://doi.org/10.3390/machines12060380>

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.>

FUKAI, F. M. **Redes neurais do tipo long short-term memory aplicadas em Previsões de demanda no mercado varejista**. Dissertação. Programa de Pós-graduação em Engenharia de Controle e Automação. Instituto Federal de Educação, Ciência e Tecnologia do Espírito Santo, Serra, ES. 2024.

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.

MARCHESE, B. G.; SOZZO, B. Análise comparativa de modelos de machine learning na predição de demanda para instalação de varais. **Revista Terra & Cultura: Cadernos de Ensino e Pesquisa**, v.40 (especial), p.209-228, 2024.

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.

NI, D.; XIAO, Z.; LIM, M. K. A systematic review of the research trends of machine learning in supply chain management. **International Journal of Machine Learning and Cybernetics**, p. 1–20, 2019. <https://doi.org/10.1007/s13042-019-01050-0>

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.

SEYEDAN, M.; MAFAKHERI, F. Predictive big data analytics for supply chain demand forecasting: methods, applications, and research opportunities. **Journal of Big Data**, v.7, n.1, p.1–22. 2020, <https://doi.org/10.1186/s40537-020-00329-2>.

SOUSA, A. C. C. Previsão de demanda de cosméticos no varejo utilizando aprendizagem de máquina. 2024. Dissertação. Programa de Pós-Graduação em Informática da Universidade Federal da Paraíba. João Pessoa, PB, 2024.

TIRKOLAEI, E. B.; SADEGHI, S.; MOOSELOO, F. M.; VANDCHALI, H. R.; AEINI, S. Application of machine learning in supply chain management: a comprehensive overview of the main areas. **Mathematical problems in engineering**, v.2021, n.1, 2021.

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.