



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DOUTORADO EM MEIO AMBIENTE E
DESENVOLVIMENTO REGIONAL**

MARCO AURÉLIO APARECIDO LÚCIO

**MODELAGEM DE SÉRIES TEMPORAIS PARA AVALIAR SERVIÇOS DE SAÚDE
PRÉ E PÓS-PANDEMIA DE COVID-19 NO MUNICÍPIO DE PRESIDENTE
PRUDENTE - SP**

Presidente Prudente - SP
2025



**PRÓ-REITORIA DE PESQUISA E PÓS-GRADUAÇÃO
DOUTORADO EM MEIO AMBIENTE E
DESENVOLVIMENTO REGIONAL**

MARCO AURÉLIO APARECIDO LÚCIO

**MODELAGEM DE SÉRIES TEMPORAIS PARA AVALIAR SERVIÇOS DE SAÚDE
PRÉ E PÓS-PANDEMIA DE COVID-19 NO MUNICÍPIO DE PRESIDENTE
PRUDENTE - SP**

Tese apresentada à Pró-Reitoria de Pesquisa e Pós-Graduação, Universidade do Oeste Paulista, como parte dos requisitos para obtenção do título de Doutor.

Área de concentração: Meio Ambiente e Desenvolvimento Regional

Orientador: Dr. Rogerio Giuffrida

<p>362.17 L938m</p>	<p>Lúcio, Marco Aurélio Aparecido. Modelagem de séries temporais para avaliar serviços de saúde pré e pós-pandemia de COVID-19 no município de Presidente Prudente – SP. / Marco Aurélio Aparecido Lúcio. – Presidente Prudente, 2025. 102 f.: il.</p> <p>Tese (Doutorado em Meio Ambiente e Desenvolvimento Regional) - Universidade do Oeste Paulista – Unoeste, Presidente Prudente, SP, 2025. Bibliografia.</p> <p>Orientador: Dr. Rogerio Giuffrida</p> <p>1. SARS-CoV-2. 2. Estudo epidemiológico. 3. Impactos de saúde. 4. Atenção básica. I. Título.</p>
-------------------------	--

Catálogo na Fonte: Maria Leticia Silva Vila Real – CRB 8/10699

MARCO AURÉLIO APARECIDO LÚCIO

**MODELAGEM DE SÉRIES TEMPORAIS PARA AVALIAR SERVIÇOS DE SAÚDE
PRÉ E PÓS-PANDEMIA DE COVID-19 NO MUNICÍPIO DE PRESIDENTE
PRUDENTE - SP**

Tese apresentada à Pró-Reitoria de Pesquisa e Pós-Graduação, Universidade do Oeste Paulista, como parte dos requisitos para obtenção do título de Doutor.

Área de Concentração: Meio Ambiente e Desenvolvimento Regional

Presidente Prudente, 22 de janeiro de 2025

BANCA EXAMINADORA

Prof. Dr. Rogerio Giuffrida
Universidade do Oeste Paulista – Unoeste
Presidente Prudente-SP

Prof. Dra. Marcos Natal Rufino
Universidade do Oeste Paulista – Unoeste
Presidente Prudente-SP

Prof. Dra. Elaine Cristina Negri
Universidade do Oeste Paulista – Unoeste
Presidente Prudente-SP

Dra. Lourdes Aparecida Zampieri D'Andrea
Instituto Adolfo Lutz - IAL
Presidente Prudente-SP

Prof. Dr. Elivelton da Silva Fonseca
Universidade Federal do Sul e Sudeste do Pará- UNIFESSP
Marabá-PA

DEDICATÓRIA

À minha esposa Letícia Valentim Aquoti Lúcio (*in memoriam*), amor da minha vida, minha guerreira e inspiração, parceira dedicada, excelente esposa e mãe, que está sempre junto a mim em todas as situações, esta vitória é nossa. Minha eterna gratidão.

Quis o destino que você não estivesse mais presente fisicamente nas nossas vidas, mas sinto você em todo lugar e a todo tempo comigo.

Gratidão minha querida por todo o incentivo e ajuda, você será sempre a minha maior inspiração e exemplo de persistência, fé e amor, te amarei por toda vida, até breve.

À minha linda filha Sofia Valentim Aquoti Lúcio melhor presente de Deus em minha vida, maior riqueza e inspiração que um ser humano pode ter, amor infinito.

À minha mãe, Zuleide Macedo de Oliveira Lúcio (*in memoriam*), obrigado pelos ensinamentos de uma vida. Quanta falta a senhora me faz, te amo!

Aos meus irmãos Mauro Lúcio Júnior, Adriani Luisa e meu filho do coração Marco Antônio, muito obrigado por tudo que tem feito na nossa vida e por todo apoio.

AGRADECIMENTOS

A Deus, pois Ele é o princípio de tudo, que me deu forças para vencer todas as dificuldades.

À coordenação do programa de pós-graduação meio ambiente e desenvolvimento regional, por todo o apoio logístico, pessoal e estrutural.

Ao professor Dr. Rogério Giuffrida pela orientação, confiança, conselhos, ajuda, pelas palavras de sabedoria e alento durante essa caminhada e, principalmente, por ter me aceitado como seu orientando, foi uma honra poder compartilhar de seus ensinamentos. No momento mais difícil da vida de minha família me incentivou a prosseguir, minha gratidão.

Aos professores do programa de pós-graduação pela contribuição intelectual que forneceram à minha formação profissional, em especial as Professoras Maira Uliana e Alba Arana.

Ao amigo Flávio Colaço do Nascimento, pela importante colaboração.

Aos Amigos Helder Furlan, Meire Tolosa, Ney, Renata e Carlos Brochini, Aniely Oliveira, pelo apoio e ajuda de sempre.

Ao Professor Dr. Marcus Vinicius, pelo apoio no ingresso do Doutorado.

Aos colegas do Doutorado e aos amigos que conquistei nesta caminhada, que se tornaram parte importante da minha vida.

Faça o teu melhor na condição que você tem, enquanto você não tem condições melhores de fazer melhor ainda!”. (Mario Sérgio Cortella).

RESUMO

Modelagem de séries temporais para avaliar serviços de saúde pré e pós-pandemia de COVID-19 no município de Presidente Prudente – SP

A atenção primária à saúde desempenha um papel crucial na promoção da saúde e prevenção de doenças, especialmente em contextos como o Brasil, com suas grandes disparidades socioeconômicas. A pandemia de COVID-19 teve um impacto significativo nos serviços de saúde primários, resultando em quedas na procura por exames preventivos e na participação em campanhas de saúde. A presente pesquisa teve como objetivo principal avaliar o impacto da pandemia de COVID-19 sobre o número de atendimentos dos serviços de atenção básica no município de Presidente Prudente – SP. Utilizando métodos como Séries Temporais Interrompidas (STI) e Análise de Pontos de Mudança, busca-se entender como as intervenções de saúde pública e as medidas de isolamento afetaram o acesso e a utilização dos serviços de saúde na região durante e após a pandemia. Foram utilizados dados da Secretaria Municipal de Saúde de Presidente Prudente, referentes aos anos de 2017 a 2022. Foram calculados os totais de atendimentos e procedimentos padronizados em taxas anuais para cada 10 mil habitantes. Para avaliar a sazonalidade, foram analisadas séries temporais mensais de 2017 a 2022, considerando períodos pré, durante e pós-pandemia. Foi realizada uma análise da estabilidade da variância, especificação dos parâmetros utilizando modelos ARIMA e SARIMA, análise dos resíduos, avaliação gráfica do modelo segmentado e estimativas de desempenho. Os resultados revelam variações significativas nos atendimentos e procedimentos de atenção primária em Presidente Prudente entre 2017 e 2021. Antes da pandemia de COVID-19, houve um aumento geral nas taxas anuais de atendimentos e procedimentos, seguido por uma redução notável durante o ano de 2020, especialmente em procedimentos como mamografias e exames preventivos específicos. A pandemia de COVID-19 impactou significativamente a Atenção Básica em Presidente Prudente - SP, com redução nos atendimentos e procedimentos de saúde em 2020 devido às medidas de distanciamento social. É fundamental aprender com esses desafios para fortalecer a resposta a futuras crises, investindo em tecnologia, infraestrutura e campanhas preventivas, garantindo a acessibilidade e qualidade dos serviços de saúde primária.

Palavras-chave: SARS-CoV-2; Estudo epidemiológico; Impactos de saúde; Atenção básica.

ABSTRACT

Time series modeling to evaluate health services before and after the COVID-19 pandemic in the municipality of Presidente Prudente – SP

Primary health care plays a crucial role in promoting health and preventing diseases, especially in contexts like Brazil, with its large socioeconomic disparities. The COVID-19 pandemic had a significant impact on primary health services, resulting in a decrease in the demand for preventive exams and participation in health campaigns. The main objective of this research was to evaluate the impact of the COVID-19 pandemic on the number of services provided by primary health care in the city of Presidente Prudente – SP. Using methods such as Interrupted Time Series (ITS) and Change Point Analysis, the study aims to understand how public health interventions and isolation measures affected access to and use of health services in the region during and after the pandemic. Data from the Municipal Health Department of Presidente Prudente, covering the years 2017 to 2022, were used. The total number of services and procedures was standardized into annual rates per 10,000 inhabitants. To evaluate seasonality, monthly time series from 2017 to 2022 were analyzed, considering pre-, during, and post-pandemic periods. An analysis of variance stability was conducted, as well as parameter specification using ARIMA and SARIMA models, residual analysis, graphical evaluation of the segmented model, and performance estimates. The results reveal significant variations in primary care services and procedures in Presidente Prudente between 2017 and 2021. Before the COVID-19 pandemic, there was a general increase in annual service and procedure rates, followed by a notable reduction in 2020, particularly in procedures such as mammograms and specific preventive exams. The COVID-19 pandemic significantly impacted primary care in Presidente Prudente – SP, with a reduction in health services and procedures in 2020 due to social distancing measures. It is essential to learn from these challenges to strengthen the response to future crises by investing in technology, infrastructure, and preventive campaigns, ensuring accessibility and quality of primary health care services.

Keywords: SARS-CoV-2; Epidemiological study; Health impacts; Primary care.

LISTA DE SIGLAS

AIC	— Akaike Information Criterion
ar	— Termo Autorregressivo (AutoRegressive)
ARIMA	— AutoRegressive Integrated Moving Average
BIC	— Bayesian Information Criterion
drift	— Tendência Linear Residual
ITS	— Interrupted Time Series (Séries Temporais Interrompidas)
ma	— Média Móvel (Moving Average)
PSA	— Antígeno Prostático Específico (Prostate-Specific Antigen)
ramp	— Efeito Progressivo ao Longo do Tempo
RRAS	— Região de Saúde
sar	— Termo Autorregressivo Sazonal (Seasonal AutoRegressive)
SARIMA	— Seasonal AutoRegressive Integrated Moving Average
sma	— Média Móvel Sazonal (Seasonal Moving Average)
SP	— São Paulo
step	— Efeito Imediato do Decreto de Pandemia
STI	— Séries Temporais Interrompidas
SUS	— Sistema Único de Saúde

LISTA DE FIGURAS

4. ARTIGO CIENTÍFICO A SER ENVIADO PARA O PERIÓDICO “REVISTA BRASILEIRA DE ENFERMAGEM”, ISBN 0950-2688, WEB-QUALIS A4

Figura 1— Séries temporais para atendimentos totais e procedimentos totais no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-2022.....46

Figura 2— Série temporal para procedimentos cobertos pela atenção básica: Dosagens de Antígeno Prostático (PSA), Antedimentos a Idosos, Diabéticos e Hipertensos no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-202246

Figura 3— Série temporal para atendimentos cobertos pela atenção básica: mamografias gerais e de rastreamento, colposcopias e citologias no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-202247

Figura 4— Série temporal para atendimentos cobertos pela atenção básica: atendimentos odontológicos, atendimentos à crianças e exames pré-natais no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-202248

5. ARTIGO CIENTÍFICO A SER ENVIADO PARA A REVISTA BRASILEIRA DE EPIDEMIOLOGIA, QUALIS A3 NO SISTEMA WEB-QUALIS

Figura 1— Séries temporais reais (azul) e preditas pelos modelos testados (vermelho) para taxas de internamentos mensais de câncer de útero para cada 100 mil mulheres com mais de 40 anos idade na RRAS 11. As linhas verticais pontilhadas na cor preta correspondem ao início e final da pandemia, de acordo com os decretos oficiais no Brasil.69

Figura 2— Séries temporais reais (azul) e preditas pelos modelos testados (vermelho) para taxas de internamentos mensais de câncer de próstata para cada 100 mil homens com mais de 40 anos idade na RRAS 11. As linhas verticais pontilhadas correspondem ao início e final da pandemia, de acordo com os decretos oficiais no Brasil e as linhas

pontilhadas em vermelho, pontos de mudança significativos nos
modelos de partição segmentada.70

LISTA DE TABELAS

4. ARTIGO CIENTÍFICO A SER ENVIADO PARA O PERIÓDICO “REVISTA BRASILEIRA DE ENFERMAGEM”, ISBN 0950-2688, WEB-QUALIS A4

Tabela 1— Total de atendimentos e procedimentos de atenção primária realizados no município de Presidente Prudente entre os anos de 2017 e 2021, segundo modalidade de atendimento ou procedimento.....44

Tabela 2— Parâmetros dos modelos ARIMA para modelagem temporal do número de procedimentos e exames de atenção básica, Presidente Prudente, SP, 2017-202244

5. ARTIGO CIENTÍFICO A SER ENVIADO PARA A REVISTA BRASILEIRA DE EPIDEMIOLOGIA, QUALIS A3 NO SISTEMA WEB-QUALIS

Tabela 1— Métricas utilizadas para avaliar o desempenho de modelos preditivos nas séries temporais para predição das taxas mensais de internamentos por neoplasias rastreáveis na RRAS-11.....68

SUMÁRIO

1.	INTRODUÇÃO	15
1.1	Problema de pesquisa e Hipótese.....	15
1.1.1	Contextualização do problema	15
1.1.2	Inserção no Programa de Pós-Graduação em Meio ambiente e Desenvolvimento Regional.....	20
1.1.3	Hipóteses de pesquisa	21
1.2	Objetivos	22
1.2.1	Objetivo Geral.....	22
1.2.2	Objetivos Específicos	22
1.3	Metodologia	23
1.3.1	Metodologia da Pesquisa	23
1.3.2	Procedimentos Metodológicos.....	24
1.4	Estrutura Da Dissertação.....	25
2.	FUNDAMENTAÇÃO TEÓRICA RELACIONADA A ATENÇÃO BÁSICA A SAÚDE E SEUS ASPECTOS RELATIVOS À PANDEMIA DE COVID-19..	26
2.1	Sistema único de Saúde e atenção básica.....	26
2.2	Vigilância epidemiológica e atenção básica	28
3.	ESTADO DA ARTE SOBRE SÉRIES TEMPORAIS.....	30
3.1	ARIMA e séries temporais interrompidas.....	30
3.2	Uso de inteligência artificial e detecção de pontos de mudança em séries temporais	34
4.	ARTIGO CIENTÍFICO A SER ENVIADO PARA O PERIÓDICO “REVISTA BRASILEIRA DE ENFERMAGEM”, ISBN 0950-2688, WEB-QUALIS A4 ..	37
5.	ARTIGO CIENTÍFICO A SER ENVIADO PARA A REVISTA BRASILEIRA DE EPIDEMIOLOGIA, QUALIS A3 NO SISTEMA WEB-QUALIS.....	61
6.	CONSIDERAÇÕES FINAIS	79
	REFERÊNCIAS.....	81
	ANEXO A— SCRIPTS DO PROGRAMA R PARA CONSECUÇÃO DAS ANÁLISES DO ARTIGO 1	94
	ANEXO B— SCRIPTS DO PROGRAMA R PARA CONSECUÇÃO DAS ANÁLISES DO ARTIGO 2	100

PRÓLOGO

A pandemia de COVID-19 provocou mudanças significativas nos sistemas de saúde globais, afetando especialmente os serviços de atenção básica, que desempenham um papel crucial na promoção da saúde. Neste sentido, pesquisas sobre os impactos da COVID-19 nesse nível de atenção são relevantes por diversas razões, incluindo a atenção à grupos em situação de vulnerabilidade socioeconômica, que foram desproporcionalmente afetados pela interrupção de serviços de atenção básica, agravando desigualdades em saúde (Haileamlak, 2021).

Neste sentido, a concepção desta pesquisa foi motivada pela necessidade de compreender como o sistema de saúde, no caso, a atenção básica foi afetada pela pandemia, de forma a preencher uma lacuna significativa sobre o impacto direto e indireto da COVID-19 na prestação de serviços. Há necessidade real de entender como a gestão pode ser organizada de serviços oferecidos à comunidade e melhoras nas decisões tomadas durante a crise para garantir que futuras ações sejam mais eficazes e humanizadas.

Os dados gerados podem identificar gargalos e implementar melhorias nos serviços de saúde, visto que a pandemia foi uma oportunidade de aprendizado, e investigar seus impactos pode motivar a busca por inovação e eficiência nos processos gerenciais (Koh, 2020; Rodrigues; Carpes; Raffagnato, 2020). Ademais, a pandemia foi catalizadora de problemas de sobrecarga e esgotamento dos profissionais de saúde. Pesquisar o tema é uma maneira de honrar o esforço dessas equipes, propondo soluções que melhorem as condições de trabalho e reduzam o impacto de crises futuras sobre esses trabalhadores, além de combater desinformação sobre o tema (Recuero; Soares; Zago, 2020).

Gestores de saúde são frequentemente motivados pela missão de reduzir desigualdades no acesso e na qualidade dos serviços. A COVID-19 evidenciou disparidades importantes na prestação de cuidados, e compreender essas questões pode inspirar ações que promovam maior justiça social e saúde universal.

1. INTRODUÇÃO

1.1 Problema de pesquisa e Hipótese

1.1.1 Contextualização do problema

A atenção básica à saúde desempenha um papel fundamental na promoção da saúde, na prevenção de doenças e na prestação de serviços de saúde abrangentes para indivíduos e comunidades. No Brasil, um país caracterizado por grandes disparidades socioeconômicas e por uma população diversificada, esses serviços são essenciais para garantir o acesso equitativo à saúde (Hone *et al.*, 2021) e prevenir doenças, principalmente porque reduzem a carga de enfermidades crônicas e melhoram os resultados de saúde da população. Estratégias como programas comunitários de educação em saúde, campanhas de imunização e iniciativas de detecção precoce demonstraram impactos positivos (Césare *et al.*, 2020; Torres *et al.*, 2021; Zabih *et al.*, 2020).

A pandemia de COVID-19, declarada pela Organização Mundial da Saúde (OMS) em março de 2020, rapidamente se espalhou pelo mundo, impactando profundamente todos os aspectos da vida global (Malik *et al.*, 2020). Com o rápido avanço do SARS-CoV-2, países enfrentaram crises sem precedentes nos sistemas de saúde, que ficaram sobrecarregados pela alta demanda de cuidados intensivos, falta de equipamentos de proteção e ventiladores, além da escassez de vacinas no início da crise (Haileamlak, 2021). Governos implementaram medidas drásticas, como lockdowns, quarentenas e restrições de viagens, na tentativa de conter a disseminação do vírus, resultando em graves consequências econômicas e sociais (Koh, 2020). A pandemia também evidenciou desigualdades entre países, com nações mais pobres tendo menos acesso a vacinas e tratamentos. A colaboração internacional, em especial para o desenvolvimento e distribuição de vacinas, como as plataformas de mRNA, tornou-se essencial para o enfrentamento global da crise. Mesmo com o avanço da vacinação, a pandemia deixou marcas duradouras e mudou para sempre a forma como o mundo lida com emergências sanitárias e a saúde pública (Aung; Koyanagi; Yuasa, 2021).

Os serviços de atenção básica à saúde foram fortemente impactados pela pandemia de COVID-19, que resultou em uma redução na procura por exames preventivos e na adesão às campanhas de conscientização promovidas pelos

gestores de saúde. Muitos programas foram afetados, incluindo as campanhas de combate e prevenção à diabetes e à obesidade, condições que, além de terem se agravado durante a pandemia, em razão das restrições de circulação durante a quarentena, também representam comorbidades que podem agravar a condição clínica do indivíduo infectado pelo novo coronavírus (Xu *et al.*, 2021). No Brasil teve um impacto profundo, expondo e agravando desigualdades estruturais no sistema de saúde e na sociedade. Com um dos maiores números de casos e mortes no mundo, o país enfrentou desafios como a sobrecarga dos hospitais, falta de insumos médicos, e dificuldades na implementação de medidas de isolamento social, especialmente em regiões mais vulneráveis (Souza *et al.*, 2020). Além disso, a desinformação e a hesitação vacinal também dificultaram o controle da pandemia (Recuero; Soares; Zago, 2020). A resposta do Brasil envolveu uma série de ações de saúde pública, como campanhas de vacinação em massa e o fortalecimento da telemedicina para manter o atendimento em meio às restrições (Rodrigues; Carpes; Raffagnato, 2020).

Um dos componentes mais importantes da atenção primária afetados pela pandemia foram os programas de rastreamento de enfermidades crônicas, incluindo câncer, diabetes e hipertensão arterial, entre outros, que, em geral, compõem parte de um programa global de vigilância epidemiológica (Vicente, 2020). Muitos testes de rastreamento foram cancelados ou adiados em razão da pandemia, deixando muitos pacientes sem acesso aos serviços de saúde (Cancino *et al.*, 2020). O diagnóstico tardio de câncer possivelmente implicará em um maior número de casos em estágio mais avançado nos anos futuros, com aumento dos gastos governamentais com diagnóstico e tratamento (Del Vecchio Blanco *et al.*, 2020). Além do rastreamento, cirurgias para câncer foram adiadas, com impacto significativo na sobrevivência de muitos pacientes (Sud *et al.*, 2020). Na Espanha, por exemplo, de 67 unidades, 79,1% cessaram alguma atividade relativa aos procedimentos cirúrgicos para câncer colorretal, estimando-se que pelo menos um mês de intensa atividade cirúrgica seria necessário para recuperar o atraso (De La Portilla De Juan; Reyes Díaz; Ramallo Solía, 2021).

O município de Presidente Prudente situa-se na região oeste do estado de São Paulo, sendo a capital regional da Alta Sorocabana e o município-sede da 11ª Rede Regional de Atenção à Saúde (RRAS 11). A população residente é estimada em 225.668 habitantes, com densidade demográfica de 402,52 hab/km² e Índice de

Desenvolvimento Humano Municipal de 0,806 (IBGE, 2024). Por ser um polo regional para os municípios circunvizinhos, Presidente Prudente centraliza muitos serviços de atenção básica, com gastos de aproximadamente 160 milhões em serviços de saúde somente no segundo bimestre de 2022 (Presidente Prudente, 2023). Durante a pandemia de COVID-19, o município foi um dos polos de disseminação do coronavírus no estado, principalmente por sediar diversos hospitais, incluindo o maior da região, o Hospital Regional de Presidente Prudente (HRPP). Além disso, o elevado número de indivíduos pertencentes aos grupos de risco impactou diretamente a propagação da doença (Rex; Borges; Käfer, 2020). Em Presidente Prudente, a pandemia progrediu especialmente entre populações vulneráveis (De Lima; Borges Guimarães, 2022).

Uma redução nos serviços de atenção básica decorrente da pandemia de COVID-19 pode acarretar problemas na detecção precoce de várias enfermidades rastreáveis, com consequências potencialmente severas no futuro, incluindo aumentos nas taxas de detecção de câncer e outras enfermidades. Uma das formas de avaliar retrospectivamente o impacto das quedas no número de rastreamentos de enfermidades e atendimentos primários decorrentes da pandemia de COVID-19 é o uso de séries temporais interrompidas (STI) (Ballard *et al.*, 2022; Shah *et al.*, 2021; Shah *et al.*, 2022). Este método permite modelar o comportamento temporal de ocorrências epidemiológicas após intervenções ou eventos drásticos ao longo de intervalos de tempo regulares. Neste caso, a variável dependente é o evento de interesse e a independente é o tempo (Bhaskaran *et al.*, 2013). A partir dessas séries, é possível observar tendências, ocorrência de picos, sazonalidade e repercussões de intervenções ou eventos impactantes ao longo do tempo (Heesterbeek *et al.*, 2015).

Muitos modelos estatísticos podem ser aplicados às STIs, sendo o que emprega médias móveis autorregressivas (ARIMA) uma das opções mais interessantes (Schaffer; Dobbins; Pearson, 2021). A ARIMA é uma técnica amplamente utilizada e versátil, que pode ser aplicada para estudar eventos epidemiológicos e que combina componentes autorregressivos (AR), diferenciais (I) e de média móvel (MA) para analisar e prever dados de séries temporais (Sato, 2013). Na ARIMA, o componente autorregressivo captura a relação entre observações passadas e valores atuais, o componente de média móvel modela a influência de erros anteriores, e o componente de diferenciação trata da não

estacionariedade nos dados. Ao selecionar os parâmetros AR, I e MA apropriados, os modelos ARIMA podem capturar padrões temporais complexos na incidência de doenças e problemas ambientais (Kaur; Parmar; Singh, 2023).

Para construir a ARIMA baseada em STI, preliminarmente se estabelece o modelo no período pré-evento, capturando os componentes autorregressivos (AR) e de média móvel (MA), e incorporando diferenças, se necessário, para alcançar a estacionariedade. Uma vez estabelecida a tendência pré-intervenção, o modelo ARIMA é estendido para incorporar o período pós-evento. Ao comparar os dados observados no período pós-evento com os valores esperados com base na tendência pré-evento, o modelo ARIMA permite estimar o efeito do evento (Schaffer; Dobbins; Pearson, 2021).

As STIs podem ser utilizadas tanto para dados contínuos, como taxas de incidência, quanto para contagens e variáveis binárias, funcionando melhor para resultados de curto prazo, quando se espera que as intervenções provoquem mudanças relativamente rápidas (Lopez Bernal; Cummins; Gasparrini, 2018). Para aplicar STI, as medidas sequenciais do resultado devem estar disponíveis antes e depois da intervenção, sem limites fixos relativos ao número de pontos no tempo, apesar de recomendar-se cautela para estudos com poucos pontos temporais ou com tamanhos de efeito esperados pequenos (Wagner *et al.*, 2002).

O desenho STI é frequentemente utilizado na avaliação de eventos não programados que ocorrem em ambientes do mundo real, sendo uma técnica emergente devido à disponibilidade e qualidade dos dados de rotina que abrangem períodos antes e após os eventos (Lopez Bernal; Cummins; Gasparrini, 2018). Seus pontos fortes incluem a capacidade de modelar tendências de longo prazo nos dados e avaliar resultados utilizando dados populacionais, a apresentação gráfica dos resultados para facilitar a compreensão, a facilidade de realização de análises estratificadas, e a capacidade de avaliar as consequências intencionais e não intencionais das intervenções. As limitações das STIs incluem a necessidade de um mínimo de períodos de tempo antes e depois de uma intervenção para prover poder estatístico, além da dificuldade em analisar o impacto independente de componentes separados de um programa complexo, entre outros (Penfold; Zhang, 2013).

As STIs, apesar de apresentarem resultados inferiores aos Ensaio Clínicos Randomizados (ECR), podem ser utilizadas para modelar efeitos de intervenções em dados longitudinais. Em um estudo que avaliou o tratamento sobre sintomas

depressivos medidos com o Patient Health Questionnaire, o modelo final baseado em STI mostrou um coeficiente de regressão similar ao ECR (Maas *et al.*, 2017). Outro estudo reforçou que as análises de STI podem ser menos custosas que os ECR e, se cuidadosamente conduzidas, podem complementar a evidência de ensaios ou mesmo gerar hipóteses, embora apresentem limitações relacionadas a problemas de autocorrelação, efeitos externos, não linearidade dos dados e fatores de confusão não medidos (Kontopantelis *et al.*, 2015).

As STIs são mais vantajosas do que testes estatísticos mais simples para a comparação das médias de registros de eventos, antes e após uma intervenção. As STI são capazes de capturar tendências de longo prazo, ao contrário de um teste t ou de Friedman, usados para comparação de eventos antes e depois (Penfold; Zhang, 2013). Desta forma, esses métodos apresentam resultados inferiores às séries temporais e são desencorajados por alguns autores (Ewusie *et al.*, 2020).

As STIs foram utilizadas para avaliar os efeitos do decreto de quarentena devido à pandemia de COVID-19 sobre a atenção primária à saúde em países que disponibilizam esses serviços. Na Inglaterra, foi possível detectar uma queda na taxa geral de procura por esses serviços de cerca de 30% no início do primeiro bloqueio, com retorno gradual aos níveis pré-pandêmicos ao longo de um período de seis meses (Walter *et al.*, 2023). Outro estudo, também realizado na Inglaterra, utilizou a STI modelada como uma regressão binomial negativa para comparar as taxas de atendimentos de atenção primária para imigrantes antes e durante a pandemia, detectando uma queda no número de atendimentos em relação aos não migrantes antes da pandemia (Zhang, 2022). Os efeitos negativos do lockdown também foram detectados via STI para taxas semanais de internação hospitalar por câncer, doenças cardiovasculares e respiratórias (excluindo COVID-19), estimadas como reduções de 26,2, 23,8 e 30,2 admissões por 100.000 pessoas na Inglaterra, Escócia e País de Gales, respectivamente (Shah *et al.*, 2022).

Na África do Sul, um estudo que envolveu 11 clínicas de cuidados de saúde primários e 89.476 consultas clínicas utilizou STI para modelar os impactos do decreto de quarentena da COVID-19 sobre a saúde infantil, cuidados perinatais, planejamento familiar, serviços de HIV, doenças não transmissíveis e por estratos de idade e sexo. Os pesquisadores detectaram uma redução de mais de 50% nas consultas de saúde infantil no início do bloqueio, com um retorno gradual aos níveis pré-bloqueio dentro de 3 meses (Siedner *et al.*, 2020). Um estudo mais amplo,

também neste país, avaliou os cuidados primários para pessoas que fizeram testes para HIV ou iniciaram terapia antirretroviral antes e depois da quarentena via regressão segmentada de Poisson. Os pesquisadores estimaram uma redução de 47,6% nos testes de HIV, sem contudo detectar uma mudança acentuada no número de visitas para testagem (Dorward *et al.*, 2021).

Um estudo amplo envolvendo 27 distritos de quatro países da África Subsaariana utilizou STI para avaliar a magnitude da interrupção na utilização dos cuidados primários após o registro dos primeiros casos de COVID-19, no qual não foram observadas reduções significativas nos registros de cuidados prestados à comunidade durante o período pandêmico (Ballard *et al.*, 2022).

No Brasil, observou-se uma queda generalizada em diversos serviços, incluindo procedimentos diagnósticos (-28,9%), consultas médicas (-42,5%), cirurgias de baixa e média complexidade (-59,7%), cirurgias de alta complexidade (-27,9%), transplantes (-44,7%), tratamentos e procedimentos clínicos por lesões de causas externas (-19,1%) e partos (-12,6%) (Bigoni *et al.*, 2022).

1.1.2 Inserção no Programa de Pós-Graduação em Meio ambiente e Desenvolvimento Regional

O estudo desenvolvido é de caráter multidisciplinar porque integra ciências da saúde ao proceder a avaliação de serviços de atenção primária à saúde e impacto da pandemia em exames preventivos e atendimentos por métodos quantitativos. Além disso, também integra ciências sociais e políticas públicas ao proceder a análise das disparidades socioeconômicas e do impacto das políticas de saúde pública, como medidas de isolamento social. Também integra tecnologia e Infraestrutura porque pode resultar em sugestões de investimento em tecnologia e infraestrutura para melhorar os sistemas de saúde no futuro.

Dentro do corpo de projetos do Programa de Pós-Graduação em Meio Ambiente e Desenvolvimento Regional, o presente estudo está inserido no PROINTER-Saúde, projeto criado em 2017, focado na saúde pública na região do Pontal do Paranapanema. O estudo está diretamente alinhado com diversos Objetivos de Desenvolvimento Sustentável (ODS), incluindo:

- a.) **ODS 3 - Saúde e Bem-Estar:** O trabalho avalia o impacto da pandemia na saúde primária, promovendo a busca por soluções para garantir o acesso

equitativo a serviços de saúde de qualidade e fortalecer os sistemas de saúde;

- b.) **ODS 10 - Redução das Desigualdades:** Ao destacar as disparidades socioeconômicas no acesso à saúde, o estudo contribui para a compreensão e redução das desigualdades no atendimento em saúde;
- c.) **ODS 9 - Indústria, Inovação e Infraestrutura:** A ênfase no fortalecimento da infraestrutura de saúde e no investimento em tecnologia para melhorar a resposta a crises está alinhada com o objetivo de construir infraestrutura resiliente e promover a inovação;
- d.) **ODS 17 - Parcerias e Meios de Implementação:** O uso de dados da Secretaria Municipal de Saúde reflete a necessidade de colaboração entre diferentes setores (governo, academia e sociedade) para enfrentar desafios de saúde pública.

1.1.3 Hipóteses de pesquisa

Diante do exposto, a presente pesquisa pretende responder questões relevantes para a saúde pública do município de Presidente Prudente, considerando-se que se trata de uma cidade-polo para o desenvolvimento regional, que incluem:

- a.) Quais serviços de atenção básica foram reduzidos durante a pandemia de COVID-19?
- b.) A redução se prolongou nos meses que sucederam o decreto de quarentena?
- c.) A sazonalidade dos serviços prestados durante as campanhas de prevenção promovidas pelo serviço de atenção básica foi afetada?

Para responder às questões levantadas, serão verificadas as seguintes hipóteses de pesquisa:

- a.) As taxas de prestação de serviços ligadas aos atendimentos e agendamentos de exames relativos aos serviços de atenção básica no município de Presidente Prudente reduziram-se logo após o decreto de quarentena?
- b.) Existem mudanças significativas nas tendências temporais de atendimentos e agendamentos de exames e serviços de atenção básica no município de Presidente Prudente, logo após o decreto de quarentena?
- c.) Existe sazonalidade nos serviços prestados de atenção básica no município, e se sim, como foram afetados pela pandemia?

Dentro deste contexto, este trabalho pretende fazer uma contribuição na área de epidemiologia para gerar indicadores que podem ser aproveitados durante crises sanitárias futuras. Espera-se contribuir para a compreensão dos impactos da pandemia e seus reflexos na saúde pública.

Entre os diferenciais apresentados, a pesquisa utiliza séries temporais interrompidas (STI) e modelos avançados baseados em ARIMA e SARIMA, que são ferramentas robustas para captar tendências e padrões antes, durante e após a pandemia. Isso permite uma análise detalhada da evolução dos atendimentos ao longo de seis anos (2017 a 2022), incluindo sazonalidade e variações de longo prazo. Ademais, o foco na Atenção Básica de Presidente Prudente - SP traz uma contribuição regional específica, ajudando a entender os impactos da pandemia em um município brasileiro, diferentemente de estudos nacionais ou globais que podem generalizar os resultados. A segmentação dos dados em categorias específicas (como mamografias e exames preventivos), permite identificar os serviços mais afetados e oferecer recomendações direcionadas. Finalmente, os resultados têm implicações práticas para o fortalecimento do sistema de saúde primário, visto que pode fomentar sugestões de investimentos em tecnologia, infraestrutura e campanhas preventivas, tomando-o relevante para gestores e planejadores em saúde pública.

1.2 Objetivos

1.2.1 Objetivo Geral

Analisar o impacto da pandemia de COVID-19 sobre os serviços de atenção básica à saúde no município de Presidente Prudente.

1.2.2 Objetivos Específicos

- a.) Estimar numericamente as taxas de redução nos serviços municipais de atenção à saúde logo após o decreto de quarentena da pandemia de COVID-19 para gerar indicadores objetivos do impacto da pandemia sobre a saúde da população;
- b.) Analisar se o impacto nas taxas de redução nos serviços municipais de atenção à saúde logo após o decreto de quarentena da pandemia de COVID-19 se prolongou ao longo dos meses subsequentes;

- c.) Avaliar se a sazonalidade na prestação dos serviços de atenção básica (campanhas de prevenção) foi afetada pela pandemia de COVID-19.

1.3 Metodologia

1.3.1 Metodologia da Pesquisa

O método utilizado é o hipotético-dedutivo, visto que a pesquisa parte de uma questão específica: como a pandemia de COVID-19 impactou os atendimentos na atenção básica à saúde em Presidente Prudente? Além disso, há uma suposição implícita de que as medidas de isolamento social e a pandemia influenciaram negativamente os atendimentos e procedimentos na atenção básica à saúde que será respondida pela coleta e análise de dados para testar hipóteses com métodos dados quantitativos (séries temporais). Os resultados podem confirmar se as variações esperadas nos atendimentos estão relacionadas com a pandemia de COVID-19. Os resultados foram interpretados e usados para propor estratégias de melhoria na resposta à futuras crises.

Trata-se de uma pesquisa quantitativa aplicada, visto que busca resolver problemas concretos, como entender o impacto da pandemia nos serviços de atenção básica para fornecer informações úteis ao planejamento de políticas públicas e melhorias no sistema de saúde, utilizando métodos estatísticos, como séries temporais (modelos ARIMA e SARIMA), para analisar dados numéricos referentes a atendimentos e procedimentos padronizados.

Sob o ponto de vista dos objetivos propostos, trata-se de uma pesquisa descritiva, posto que o estudo descreve o impacto da pandemia de COVID-19 nos atendimentos de atenção básica, apresentando tendências, variações e comportamentos ao longo do tempo. Embora os resultados possam ajudar a explicar fenômenos, o foco principal está em descrever as alterações nos serviços de saúde.

Esta pesquisa é orientada pela necessidade de gerar conhecimento aplicável, logo sua epistemologia é Interpretativista, visto que o foco é a compreensão das experiências humanas com base em indicadores numéricos. No caso, estimou-se como o impacto da quarentena afetou a percepção dos usuários dos serviços de atenção básica.

1.3.2 Procedimentos Metodológicos

Trata-se de uma pesquisa com dados secundários fornecidos pela Secretaria Municipal de Saúde de Presidente Prudente, referentes ao período de 2017 a 2022, registros administrativos, que incluem o número de atendimentos e procedimentos realizados, o que caracteriza o uso de fontes documentais. Não foi realizada coleta direta de dados primários ou interação com sujeitos da pesquisa.

As etapas cumpridas no desenvolvimento da pesquisa foram:

- a.) Levantamento das publicações relevantes na área, incluindo dados de pesquisas quantitativas e qualitativas, no Brasil e no mundo. Neste contexto, foram utilizadas as palavras-chave que incluíram: “Atenção primária à saúde”, “Serviços de saúde”, “Pandemia de COVID-19”, “Impacto da pandemia”, “Séries temporais interrompidas”, “Modelos ARIMA”, “Análise de pontos de mudança”, “Atendimentos em saúde”, “Saúde pública”, “Presidente Prudente”, “Isolamento social”, “Campanhas preventivas de saúde”, “Indicadores de saúde”, “Redução de atendimentos” e “Serviços de atenção básica”;
- b.) Elaboração de um texto introdutório com base nos artigos levantadas;
- c.) Captação das informações junto a secretaria de saúde do município de Presidente Prudente, SP;
- d.) Análise estatística baseada em séries temporais interrompidas para estimar numericamente as taxas de redução nos serviços municipais de atenção à saúde logo após o decreto de quarentena da pandemia de COVID-19 para gerar indicadores objetivos do impacto da pandemia sobre a saúde da população, determinar se o impacto nas taxas de redução nos serviços municipais de atenção à saúde logo após o decreto de quarentena da pandemia de COVID-19 se prolongou ao longo dos meses subsequentes; e avaliar se a sazonalidade na prestação dos serviços de atenção básica (campanhas de prevenção) foi afetada pela pandemia de COVID-19.
- e.) Avaliação dos resultados do contexto de saúde do município;
- f.) Elaboração da discussão.

Os dados obtidos na pesquisa descrita no resumo podem trazer vários benefícios para diversos setores da sociedade, incluindo a identificação de lacunas e vulnerabilidades no Sistema de Saúde ao revelar quais serviços foram mais afetados, como mamografias e exames preventivos. Essa informação permite priorizar esforços e recursos para áreas mais críticas, especialmente aquelas que

podem impactar a saúde da população no longo prazo. Ademais contribui para melhoria no planejamento e gestão de crises de saúde pública ao orientar a criação de estratégias mais robustas para lidar com futuras pandemias ou emergências sanitárias. O trabalho também foca na identificação de falhas, como redução no acesso durante o isolamento social, direcionando os gestores em investir em Infraestrutura tecnológica (telemedicina) e fortalecimento de sistemas que permitam acesso remoto a serviços de saúde.

Ao destacar os impactos da pandemia nos serviços de saúde, a pesquisa pode sensibilizar gestores e a sociedade para a importância de fortalecer a atenção básica e promover campanhas educativas baseadas nos dados coletados para incentivar a busca por exames e procedimentos preventivos. Finalmente, os resultados podem servir de base para outros estudos e comparações regionais, nacionais e internacionais, ajudando a construir um panorama mais abrangente do impacto da pandemia nos sistemas de saúde.

1.4 Estrutura Da Dissertação

A Sessão 1 apresenta a Introdução contextualizando o tema proposto neste trabalho, assim como os resultados esperados por meio da definição de seus objetivos e hipóteses testadas.

A Sessão 2 apresenta a fundamentação teórica relacionada a atenção básica a saúde e seus aspectos relativos à pandemia de COVID-19.

A Sessão 3 apresenta o estado da arte sobre séries temporais, detalhando o método utilizado neste estudo.

A Sessão 4 apresenta o primeiro artigo científico a ser enviado para a revista brasileira de enfermagem e aborda o uso de séries temporais interrompidas para avaliar os impactos da pandemia sobre os serviços de atenção básica.

A Sessão 5 apresenta o segundo artigo científico a ser enviado para a revista brasileira de epidemiologia.

A Sessão 6 apresenta as considerações finais do estudo e propostas de continuidade da pesquisa desenvolvida a partir das experiências adquiridas com a execução do trabalho.

2. FUNDAMENTAÇÃO TEÓRICA RELACIONADA A ATENÇÃO BÁSICA A SAÚDE E SEUS ASPECTOS RELATIVOS À PANDEMIA DE COVID-19

2.1 Sistema único de Saúde e atenção básica

O Sistema Único de Saúde (SUS) tem sido fundamental para o desenvolvimento e expansão dos serviços de atenção primária à saúde. Com a criação da Estratégia Saúde da Família (ESF) no final da década de 1990, o Brasil mudou seu foco para um modelo de atenção primária integral que enfatiza o cuidado preventivo, a promoção da saúde e o envolvimento da comunidade (Arantes; Shimizu; Merchán-Hamann, 2016). A ESF tem feito progressos significativos na melhoria do acesso aos cuidados de saúde, especialmente em áreas carentes (Lemos Macedo *et al.*, 2021).

Apesar dos avanços, os serviços de atenção primária à saúde no Brasil enfrentam vários desafios. Financiamento insuficiente, infraestrutura inadequada e escassez de mão de obra impedem a prestação de cuidados de qualidade (Scherer *et al.*, 2018). Além disso, as disparidades geográficas e as desigualdades socioeconômicas representam barreiras ao acesso, principalmente em comunidades remotas e marginalizadas. A integração limitada entre a atenção primária e outros níveis de atenção à saúde, como serviços especializados e hospitais, dificulta ainda mais a continuidade do cuidado e o manejo integral dos pacientes (Houweling *et al.*, 2016).

Os serviços de atenção primária à saúde no Brasil têm se concentrado cada vez mais na promoção da saúde e na prevenção de doenças. Fundamentalmente, se objetiva reduzir a carga de doenças crônicas e melhorar os resultados de saúde da população. Estratégias como programas comunitários de educação em saúde, campanhas de imunização e iniciativas de detecção precoce demonstraram impactos positivos (Césare *et al.*, 2020; Torres *et al.*, 2021; Zabih *et al.*, 2020). As colaborações com organizações comunitárias e líderes locais têm se mostrado eficazes no engajamento de indivíduos e na promoção de práticas de saúde sustentáveis (Madia Lourenço *et al.*, 2021).

No Brasil, programas de atenção primária têm sido desenvolvidos para nichos específicos. Na saúde materno-infantil no Brasil, destaca-se o programas “Rede Cegonha” têm como objetivo melhorar o acesso ao pré-natal, parto e puerpério, priorizando uma abordagem humanizada e integral (Leal *et al.*, 2021).

Apesar dos avanços, persistem variações regionais, com disparidades na cobertura e na qualidade dos serviços. Fortalecer os cuidados primários de saúde para a saúde materno-infantil requer investimentos sustentados, treinamento aprimorado para profissionais de saúde e melhor coordenação entre os diferentes níveis de atenção (Zveiter *et al.*, 2022).

Uma das formas de promover avanços na atenção primária é uso de tecnologias inovadoras. Soluções digitais de saúde, telemedicina e registros eletrônicos de saúde têm se mostrado promissores para melhorar o acesso, a continuidade do atendimento e a eficiência (Barbosa; de A Novaes; de Vasconcelos, 2003). No entanto, os desafios relacionados à infraestrutura, conectividade e alfabetização digital precisam ser enfrentados para garantir a implementação equitativa dessas inovações (Celuppi *et al.*, 2021). Além disso, as considerações éticas relativas à privacidade e segurança dos dados devem ser cuidadosamente abordadas (Carvalho *et al.*, 2021).

O envolvimento da comunidade e as abordagens participativas são essenciais para a eficácia dos serviços de atenção primária à saúde no Brasil. Foi demonstrado que capacitar indivíduos e comunidades para participar ativamente nos processos de tomada de decisão e nas iniciativas de promoção da saúde melhora os resultados de saúde e promove a apropriação dos programas de saúde. As iniciativas bem-sucedidas de envolvimento da comunidade envolvem parcerias com organizações locais, envolvimento significativo dos membros da comunidade e sensibilidade cultural (Haricharan; Stuttford; London, 2021; Heumann; Röhsch; Hämel, 2022).

O sucesso dos serviços de atenção primária à saúde no Brasil depende da colaboração interprofissional efetiva e de uma força de trabalho de saúde bem treinada. Fortalecer a educação e o treinamento de profissionais de saúde, promover a colaboração entre diferentes disciplinas e criar ambientes de trabalho de apoio são estratégicos para garantir a prestação de cuidados abrangentes e centrados no paciente. Abordagens inovadoras, como educação interprofissional e modelos de cuidado em equipe, mostrou-se promissora para melhorar os serviços de atenção primária à saúde e atender às necessidades complexas dos pacientes (Barreto; Guimarães Campos; Dal Poz, 2019).

Para aprimorar ainda mais os serviços de atenção primária à saúde no Brasil, várias áreas prioritárias requerem atenção. Em primeiro lugar, aumentar os

investimentos em infraestrutura de atenção primária, incluindo instalações e equipamentos, é essencial para melhorar a prestação de serviços e garantir o acesso equitativo (Kashiwakura *et al.*, 2021). Em segundo lugar, abordar a escassez de força de trabalho e promover oportunidades de desenvolvimento profissional são essenciais para manter uma força de trabalho de saúde competente e motivada (Macinko; Harris; Rocha, 2017; Santos *et al.*, 2017). Em terceiro lugar, fortalecer a coordenação e a integração entre a atenção primária e outros níveis de atenção à saúde, bem como implementar sistemas de referência robustos, é essencial para transições de cuidados perfeitas (Benzer *et al.*, 2015). Por fim, alavancar a tecnologia e a inovação pode melhorar significativamente os serviços de atenção primária à saúde (Islam, 2021).

2.2 Vigilância epidemiológica e atenção básica

A vigilância epidemiológica é um componente fundamental dos serviços de atenção primária à saúde, proporcionando uma abordagem sistemática para a vigilância, monitoramento e controle de doenças e eventos relacionados à saúde. No Brasil, onde doenças infecciosas e emergências de saúde pública representam desafios significativos, o papel da vigilância epidemiológica na atenção primária à saúde é de suma importância (Teixeira *et al.*, 2018).

A vigilância epidemiológica nos serviços de atenção primária à saúde no Brasil utiliza diversas metodologias para detectar, monitorar e responder a surtos de doenças e emergências de saúde pública. Essas metodologias incluem vigilância ativa, vigilância sindrômica, sistemas de notificação e técnicas de análise de dados (Vicente, 2020). A vigilância ativa envolve a detecção e monitoramento proativos de casos, garantindo a identificação oportuna dos padrões da doença (Leal-Neto *et al.*, 2016). A vigilância sindrômica utiliza dados em tempo real de várias fontes, como departamentos de emergência e clínicas de cuidados primários, para detectar e rastrear surtos ou eventos de saúde incomuns (Boaventura *et al.*, 2023).

Contudo, apesar dos avanços, a vigilância epidemiológica nos serviços de atenção primária à saúde no Brasil enfrenta diversos desafios. Recursos limitados, incluindo financiamento, escassez de pessoal treinado e de infraestrutura dificultam a implementação e eficácia dos sistemas de vigilância. A coleta fragmentada de dados e os mecanismos de tratamento estatístico dos dados em diferentes instituições de saúde representam desafios na integração e análise de dados

(Machado; Martins; Leite, 2016). O treinamento e a conscientização inadequados dos profissionais de saúde sobre a importância da vigilância epidemiológica podem levar à subnotificação e atraso na resposta. Além disso, o vasto tamanho geográfico do Brasil, com diversas populações e regiões, apresenta desafios para garantir cobertura e resposta de vigilância uniformes (Ross *et al.*, 2018).

Para fortalecer a vigilância epidemiológica nos serviços de atenção primária à saúde no Brasil, existem várias oportunidades de melhoria. Aprimorar programas de treinamento e capacitação de profissionais de saúde em metodologias de vigilância e análise de dados é essencial. Melhorar a integração dos sistemas de vigilância em diferentes níveis de atenção, incluindo atenção primária à saúde, hospitais e serviços especializados, pode aprimorar o compartilhamento e a coordenação de dados (Bradley; Curry; Devers, 2007). O fortalecimento da qualidade, padronização e interoperabilidade dos dados pode facilitar a análise e a interpretação precisas dos dados de vigilância, alavancando os avanços tecnológicos, como soluções digitais de saúde e transmissão de dados em tempo real (Chretien *et al.*, 2009; Faria *et al.*, 2016; Lowe *et al.*, 2014).

Ao priorizar o fortalecimento da vigilância epidemiológica na atenção primária à saúde, o Brasil pode aumentar sua capacidade de detectar, responder e prevenir surtos de doenças e ameaças à saúde pública. Formuladores de políticas, profissionais de saúde e pesquisadores devem colaborar para implementar estratégias baseadas em evidências que melhorem os sistemas de vigilância e promovam uma vigilância epidemiológica eficaz nos serviços de atenção primária à saúde no Brasil (Garritty *et al.*, 2023).

3. ESTADO DA ARTE SOBRE SÉRIES TEMPORAIS

3.1 ARIMA e séries temporais interrompidas

Sistemas de vigilância epidemiológica são concebidos para monitorar eventos epidemiológicos ao longo do tempo, em intervalos regulares. A forma como estes eventos evoluem ao longo do tempo pode ser modelada estatisticamente por meio de séries temporais nas quais a variável dependente é o evento e a independente o tempo (Bhaskaran *et al.*, 2013). A partir destas séries é possível determinar como o evento se comporta ao longo do tempo, incluindo tendências (crescimento e decrescimento), ocorrência de picos (epidemias) e intervenções (medidas de controle) (Heesterbeek *et al.*, 2015).

Os modelos temporais apresentam três componentes básicos: tendência, sazonalidade e ruído branco, ou aleatório. A tendência é uma característica relacionada a evolução dos dados ao longo do tempo. Ela pode ser crescente, decrescente ou estacionária. Se a série for estacionária, a média, variância e covariância do número de registros do evento devem permanecer constantes em intervalos de tempo regulares. Neste caso, embora ocorram flutuações nos valores, a série tende a regredir para uma média constante sendo, desta forma, mais fácil de prever (Zeger; Irizarry; Peng, 2006). Séries totalmente estacionárias são eventos raros para variáveis de caráter biológico, sendo, desta forma, comum assumir-se que o evento apresenta “estacionaridade fraca” (Schaffer; Dobbins; Pearson, 2021). Existem muitas causas para uma série temporal não apresentar estacionaridade. Se o fenômeno biológico é a prevalência de uma enfermidade, por exemplo, os registros tendem a crescer em populações primo-expostas no início de uma epidemia e a decrescer quando são implantadas medidas de controle (Lopez Bernal; Cummins; Gasparrini, 2018; Zeger; Irizarry; Peng, 2006; Zhang *et al.*, 2014).

Em contraste, a sazonalidade é o componente temporal relacionado a variações das ocorrências registradas em função de determinadas épocas do ano. Doenças vetoriadas por artrópodes, por exemplo, tendem a ser sazonais, com casos concentrados nas épocas de calor e chuvas intensas e doenças respiratórias, nos períodos mais frios do ano (Caini *et al.*, 2017; Lima; Laporta, 2020; Paz *et al.*, 2022). Finalmente, o ruído aleatório, ou irregularidade, está relacionado às flutuações das ocorrências ao longo dos períodos de registro em torno de um valor médio. Estas

flutuações não apresentam padrão de regularidade detectável, o que as diferencia das flutuações sazonais (Zeger; Irizarry; Peng, 2006).

Séries não estacionárias, em geral são heterocedásticas, ou seja, a variância dos dados não é constante ao longo do tempo, e ocorrem mudanças sistemáticas na dispersão dos resíduos ao longo do intervalo de valores medidos. A heterocedasticidade é um problema na regressão temporal porque a regressão dos mínimos quadrados ordinários (OLS) assume que todos os resíduos são extraídos de uma população que tem uma variância constante (homocedasticidade). O problema da heterocedasticidade pode ser resolvido com a transformação logarítmica dos dados (Nascimento *et al.*, 2008).

Séries temporais podem ser utilizadas para avaliar o impacto de intervenções de saúde em populações. Estas séries estimam mudanças em tendências temporais de uma variável de interesse, antes e após uma intervenção. Caso a intervenção não apresente impacto significativo, espera-se que a tendência não apresente mudanças de direção nas sequências temporais (Taljaard *et al.*, 2014). O uso desta abordagem representa uma alternativa viável aos ensaios clínicos randomizados que não podem ser executados por que implicam problemas éticos (Lopez Bernal; Cummins; Gasparrini, 2018).

Uma metodologia amplamente empregada para séries temporais é modelo baseado em médias móveis autorregressivas (ARIMA). A ARIMA é uma técnica de análise de séries temporais amplamente utilizada e versátil que pode ser aplicada para estudar a incidência de doenças e que combina componentes autorregressivos (AR), diferenciais (I) e média móvel (MA) para analisar e prever dados de séries temporais (Sato, 2013).

Na ARIMA, o componente autorregressivo captura a relação entre observações passadas e valores atuais, o componente de média móvel modela a influência de erros anteriores e o componente de diferenciação trata da não estacionariedade nos dados. Ao selecionar os parâmetros AR, I e MA apropriados, os modelos ARIMA podem capturar padrões temporais complexos na incidência de doenças e problemas ambientais (Kaur; Parmar; Singh, 2023).

Antes de aplicar a metodologia ARIMA, os dados de séries temporais de incidência da doença devem ser preparados adequadamente. Isso inclui a verificação da estacionariedade dos dados, que é um pré-requisito para a modelagem ARIMA. A estacionariedade implica que as propriedades estatísticas dos dados, como

média e variância, permanecem constantes ao longo do tempo. Se os dados não forem estacionários, a diferenciação matemática pode ser aplicada para obter a estacionaridade. Além disso, valores discrepantes e ausentes devem ser tratados por meio de imputação ou exclusão para garantir a precisão e a confiabilidade da análise (Cardinal; Roy; Lambert, 1999).

Determinar a ordem apropriada do modelo ARIMA é crucial para capturar a dinâmica temporal da incidência da doença. Isso envolve selecionar os valores dos parâmetros AR, I e MA. A seleção da ordem do modelo pode ser obtida usando técnicas como inspeção visual de autocorrelação e gráficos de autocorrelação parcial, *Akaike Information Criterion* (AIC), *Bayesian Information Criterion* (BIC) ou validação cruzada. A ordem do modelo selecionado deve fornecer um equilíbrio entre a complexidade do modelo e a qualidade do ajuste (Beard *et al.*, 2019).

Após determinar a ordem do modelo, os parâmetros do modelo ARIMA precisam ser estimados. Isso pode ser feito usando estimativa de máxima verossimilhança ou métodos de estimativa de mínimos quadrados. Os parâmetros estimados refletem a força e significância dos componentes autorregressivos e de média móvel, permitindo a identificação de padrões temporais significativos e o cálculo de valores previstos (Box; Jenkins; Reinsel, 2008).

A adequação do modelo ARIMA pode ser avaliada após verificar-se como se ajusta aos dados de incidência das enfermidades observadas. Isso pode envolver a comparação visual dos valores previstos pelo modelo com os dados reais ou o uso de medidas estatísticas, como o erro médio absoluto ou a raiz quadrada do erro médio. Além disso, a realização da análise residual ajuda a validar as suposições do modelo, como a ausência de correlação serial e resíduos normalmente distribuídos (Chatfield, 2004).

Uma das principais vantagens da metodologia ARIMA é sua capacidade de prever a incidência futura de doenças com base em padrões de dados históricos. Depois que o modelo ARIMA é ajustado e validado, ele pode ser usado para gerar previsões para pontos de tempo futuros. Essas previsões podem ajudar os profissionais de saúde pública a antecipar tendências de doenças, identificar possíveis surtos e tomar decisões informadas sobre alocação de recursos, estratégias de prevenção e planejamento de intervenção (Permanasari; Hidayah; Bustoni, 2013; Yanchun Pan *et al.*, 2016; Zheng *et al.*, 2015).

Embora a metodologia ARIMA seja uma ferramenta valiosa para análise de séries temporais de incidência de doenças, é importante considerar suas limitações. A ARIMA assume que o processo de geração de dados subjacente é estacionário e linear, o que nem sempre é válido para a incidência de doenças. Além disso, os modelos ARIMA podem não capturar dinâmicas complexas, como sazonalidade ou tendências de longo prazo, sem modificações adicionais ou o uso de técnicas mais avançadas. Deve-se ter cuidado também na interpretação e comunicação dos resultados do modelo ARIMA, pois fornecem associações estatísticas em vez de relações causais. Finalmente, a precisão das previsões ARIMA pode ser influenciada pela qualidade dos dados, suposições do modelo e mudanças na dinâmica da doença subjacente (Wagner *et al.*, 2002).

Uma alternativa aos problemas mencionados é o uso de séries temporais interrompidas para a ARIMA, capazes de lidar com a estrutura de autocorrelação dos dados (Schaffer; Dobbins; Pearson, 2021). Neste caso, é construído um modelo com período pré-intervenção para estabelecer a tendência subjacente. Isso envolve o ajuste de um modelo ARIMA aos dados pré-intervenção, capturando os componentes autorregressivos (AR) e de média móvel (MA) e incorporando diferenças, se necessário, para alcançar a estacionaridade. Uma vez estabelecida a tendência pré-intervenção, o modelo ARIMA é estendido para incorporar o período pós-intervenção. Ao comparar os dados observados no período pós-intervenção com os valores esperados com base na tendência pré-intervenção, o modelo ARIMA permite estimar o efeito da intervenção.

É crucial selecionar cuidadosamente a ordem do modelo apropriado (termos AR, I e MA) usando técnicas estatísticas como critérios de informação (por exemplo, AIC, BIC) e testes de diagnóstico para garantir que o modelo capture adequadamente os padrões temporais nos dados. A presença de potenciais fatores de confusão ou covariáveis também deve ser considerada, e variáveis adicionais podem ser incorporadas ao modelo ARIMA para explicar sua influência na incidência da doença. Além disso, é importante realizar análises de sensibilidade e avaliar a robustez dos resultados em relação a possíveis valores discrepantes ou inconsistências de dados para garantir a confiabilidade das descobertas (Schaffer; Dobbins; Pearson, 2021).

3.2 Uso de inteligência artificial e detecção de pontos de mudança em séries temporais

A técnica de detecção de pontos de mudança em séries temporais é amplamente utilizada para identificar alterações significativas no comportamento de uma variável ao longo do tempo (Aminikhanghahi; Cook, 2017). Em estudos sobre a ocorrência de doenças transmissíveis, essa abordagem se torna especialmente valiosa para monitorar surtos, avaliar a efetividade de intervenções de saúde pública e compreender padrões epidemiológicos. Esses pontos podem indicar o início de um surto, mudanças na dinâmica de transmissão, ou até mesmo o impacto de intervenções, como campanhas de vacinação ou medidas de distanciamento social (Coughlin *et al.*, 2021; You *et al.*, 2021).

Do ponto de vista técnico, a detecção de pontos de mudança baseia-se na identificação de momentos em que as propriedades estatísticas de uma série temporal, como média ou variância, sofrem alterações significativas. Métodos como a Análise de Pontos de Mudança (*Change Point Analysis*) e técnicas de segmentação baseadas em máxima verossimilhança ou penalizações, como o algoritmo PELT (*Pruned Exact Linear Time*), são amplamente aplicados (Aminikhanghahi; Cook, 2017; Dorcas Wambui, 2015). Em estudos epidemiológicos, essas ferramentas permitem detectar variações em séries de casos notificados ou hospitalizações, possibilitando a rápida resposta a eventos anômalos (Struchen; Vial; Andersson, 2017).

Um exemplo prático de aplicação dessa técnica é a análise do impacto da pandemia de COVID-19 sobre a ocorrência de outras doenças transmissíveis. Durante a pandemia, muitos países registraram quedas abruptas em notificações de doenças como dengue ou tuberculose, possivelmente relacionadas a mudanças no comportamento populacional, redução do acesso a serviços de saúde, ou sobrecarga do sistema de vigilância. Utilizando métodos de detecção de pontos de mudança, é possível determinar com relativa precisão os períodos em que essas alterações ocorreram, fornecendo informações valiosas para planejar estratégias de mitigação e recuperação (Dehning *et al.*, 2020; Jegede; Szajowski, 2022).

Além de sua aplicabilidade em vigilância de doenças, a técnica também desempenha um papel importante na avaliação de políticas públicas. Por exemplo, pode-se medir o efeito de intervenções, como o início de campanhas de vacinação ou medidas de controle vetorial, identificando mudanças na tendência ou

sazonalidade das séries de casos (Dings *et al.*, 2024; Texier *et al.*, 2016). Esta abordagem permite avaliar a eficácia das ações realizadas, mas também contribui para o planejamento de estratégias futuras, otimizando os recursos disponíveis para o controle de doenças transmissíveis (Texier *et al.*, 2016).

Com a crescente disponibilidade de dados em tempo real e o avanço de ferramentas analíticas, essa técnica continua a evoluir, sendo integrada a sistemas de vigilância automatizados e modelos preditivos (Hilas; Rekanos; Mastorocostas, 2013). Sua aplicação na área de saúde pública fortalece a capacidade de resposta a ameaças emergentes, ajudando a proteger populações e minimizar os impactos de doenças transmissíveis (Brookmeyer; Stroup, 2003).

Métodos baseados em inteligência artificial (IA) têm se mostrado eficazes para detecção de mudanças em séries temporais, especialmente em aplicações que requerem a identificação de padrões anômalos ou transições estruturais (Olawade *et al.*, 2024). Este método tem capacidade de modelar relações complexas em dados de alta dimensionalidade e de lidar com diferentes escalas temporais. As principais ferramentas incluem as redes neurais recorrentes (RNNs), transformadores temporais e modelos híbridos, que têm sido amplamente empregados para analisar e prever alterações em séries temporais em campos como economia, saúde e monitoramento ambiental (Hajirahimi; Khashei, 2019; Mienye; Swart; Obaido, 2024).

As redes neurais recorrentes, incluindo suas variantes como LSTM (Long Short-Term Memory) e GRU (Gated Recurrent Unit), são particularmente úteis para a detecção de mudanças em séries temporais. Elas capturam dependências temporais ao longo de períodos estendidos, permitindo identificar variações sutis nos padrões de dados (Waqas; Humphries, 2024). Recentemente, arquiteturas baseadas em transformadores, como o Transformer Temporal, têm desafiado o domínio das RNNs, oferecendo maior eficiência no processamento de longas sequências devido ao mecanismo de atenção que prioriza padrões de interesse (Nayak *et al.*, 2024).

Outro avanço significativo é a integração de métodos de aprendizado profundo com técnicas estatísticas, como o uso de modelos probabilísticos e Bayesianos. Esses modelos híbridos combinam a robustez da inferência estatística com a flexibilidade do aprendizado profundo para detectar alterações em séries temporais que podem ser mascaradas por ruídos ou variações sazonais (Lim; Zohren, 2021). Por exemplo, o uso de filtros de Kalman com redes neurais

profundas tem demonstrado alto desempenho na detecção de mudanças abruptas em alguns tipos de dados (Bai *et al.*, 2023).

Em síntese, o uso de inteligência artificial na detecção de mudanças em séries temporais combina técnicas avançadas de aprendizado profundo, estatísticas e aprendizado não supervisionado, proporcionando soluções robustas para identificar alterações em uma ampla gama de aplicações. Contudo, desafios como a explicabilidade dos modelos e a necessidade de grande volume de dados rotulados ainda limitam a aplicação em certos contextos. Pesquisas futuras devem explorar abordagens mais interpretáveis e eficientes para abordar esses desafios, promovendo maior confiabilidade na detecção de mudanças em cenários reais (Saeed; Omlin, 2023).

4. ARTIGO CIENTÍFICO A SER ENVIADO PARA O PERIÓDICO “REVISTA BRASILEIRA DE ENFERMAGEM”, ISBN 0950-2688, WEB-QUALIS A4

Acesso: <https://reben.com.br/revista/instrucoes-aos-autores-2023/>

Séries temporais interrompidas para avaliar os efeitos da pandemia de COVID-19 nos serviços de atenção primária no município de Presidente Prudente, SP, Brasil

MARCO AURÉLIO APARECIDO LÚCIO¹

ROGERIO GIUFFRIDA¹

MARCOS VINICIUS PIMENTA RODRIGUES¹

1. Programa de pós-graduação em meio ambiente e desenvolvimento regional Universidade do Oeste Paulista – Unoeste, Presidente Prudente São Paulo.

Resumo

A pandemia de COVID-19 afetou significativamente os programas de atenção básica a saúde em todo o mundo. Este estudo ecológico retrospectivo avaliou os impactos da pandemia de COVID-19 em atendimentos e procedimentos preventivos no sistema de saúde de Presidente Prudente – SP, com dados de 2017 a 2022. Dados de atendimentos realizados pelo serviço municipal de saúde para crianças, adultos e idosos, e de procedimentos diagnósticos para rastreamento de câncer foram padronizados em taxas por 1.000 habitantes, conforme diferentes estratos populacionais. Modelos ARIMA foram construídos para identificar padrões temporais, nos quais foram incluídos termos de controle para avaliar efeitos imediatos ("step") e progressivos ("ramp") do decreto de Pandemia de COVID-19, além de ajustar tendências sazonais e residuais quando necessário. Gráficos compararam dados reais e previstos após o decreto de quarentena (março de 2020), avaliando diferenças entre valores observados e comportamentos esperados. Quedas abruptas foram observadas nos atendimentos a crianças, idosos, exames de PSA e odontológicos, evidenciando mudanças estruturais temporais nos dados. Efeitos de longo prazo mostraram recuperações graduais para citologias, mamografias, exames de PSA e atendimentos odontológicos e infantis, mas tendência de queda persistente para atendimentos a idosos. As maiores quedas no número de atendimentos foram

observadas para idosos e crianças. Conclui-se que a pandemia de COVID-19 impactou profundamente a Atenção Básica à Saúde em Presidente Prudente - SP, destacando a necessidade de investimentos em tecnologia, infraestrutura e campanhas preventivas para garantir a acessibilidade e qualidade dos serviços, especialmente em crises de saúde pública.

Palavras-chaves: saúde pública; atenção primária; SARS-COV-2; Oeste Paulista; políticas públicas

Introdução

A atenção básica desempenha um papel fundamental na promoção, prevenção de doenças e prestação de serviços de saúde abrangentes para indivíduos e comunidades. No Brasil, um país caracterizado por grandes disparidades socioeconômicas e uma população diversificada, esses serviços são essenciais para garantir o acesso equitativo à saúde e prevenir doenças, principalmente porque reduzem a carga de enfermidades crônicas e melhoram o estado de saúde da população (Hone *et al.*, 2021).

Os serviços de atenção básica foram fortemente impactados pela pandemia do novo coronavírus (COVID-19), que resultou em uma redução na procura por exames preventivos e na adesão às campanhas de conscientização promovidas pelos gestores. Muitos programas de atenção básica foram afetados, incluindo as campanhas de combate e prevenção à diabetes e obesidade, condições que, além de terem se agravado durante a pandemia em função das restrições de circulação, também representam comorbidades que podem agravar a condição clínica de indivíduos infectados pelo novo coronavírus (Xu *et al.*, 2021).

Um dos componentes mais importantes da atenção básica afetados pela pandemia foram os programas de rastreio de enfermidades de natureza crônica, como câncer, diabetes e hipertensão arterial, que, em geral, compõem parte de um programa global de vigilância epidemiológica (Vicente, 2020). Muitos testes de rastreio foram cancelados ou adiados em razão do risco de infecção, deixando pacientes sem acesso adequado aos serviços de saúde (Cancino *et al.*, 2020). O diagnóstico tardio do câncer pode implicar no aumento de casos em estágios mais avançados nos anos futuros, elevando os gastos governamentais com diagnóstico e tratamento (Del Vecchio Blanco *et al.*, 2020). Além do rastreio, cirurgias para câncer

também foram adiadas, com impacto significativo na sobrevida de muitos pacientes (Sud *et al.*, 2020).

Um dos municípios afetados pela pandemia foi Presidente Prudente, situado na região oeste do estado de São Paulo, com população estimada em 225.668 habitantes, densidade demográfica de 402,52 hab/km² e Índice de Desenvolvimento Humano Municipal de 0,806 (IBGE, 2024). Por ser um polo regional, o município centraliza muitos serviços de atenção básica, com gastos de aproximadamente 160 milhões de reais em saúde no segundo bimestre de 2022 (Presidente Prudente, 2023). Durante a pandemia, destacou-se como polo de disseminação da COVID-19 no estado, por sediar hospitais de referência como o HRPP e a Santa Casa, além de hospitais particulares (Rex; Borges; Käfer, 2020).

Uma das formas mais eficazes de avaliar retrospectivamente o impacto da pandemia sobre os atendimentos e rastreios de enfermidades é por meio da aplicação de séries temporais interrompidas (STI) (Ballard *et al.*, 2022; Shah *et al.*, 2021; Shah *et al.*, 2022). Esse método permite modelar o comportamento de variáveis ao longo do tempo e após eventos ou intervenções específicas, utilizando o tempo como variável independente (Bhaskaran *et al.*, 2013). A partir dessas séries, é possível detectar tendências, picos, sazonalidades e impactos de intervenções sobre a saúde pública (Heesterbeek *et al.*, 2015). Assim, este estudo teve como objetivo avaliar os impactos da pandemia de COVID-19 sobre a utilização dos serviços de saúde em Presidente Prudente – SP, especialmente na atenção básica, por meio de séries temporais interrompidas.

Metodologia

Tipo de estudo

Trata-se de um estudo epidemiológico do tipo ecológico com dados populacionais retrospectivos para avaliar os impactos da pandemia de COVID-19 no município de Presidente Prudente – SP sobre os atendimentos e procedimentos preventivos.

População investigada

A população sob investigação foi composta por munícipes da cidade de Presidente Prudente que utilizam o Serviço Municipal de Saúde, incluindo crianças, adultos e idosos nos anos de 2017 a 2022.

Fonte dos dados e padronização

Os dados foram coletados junto à Secretaria Municipal de Saúde de Presidente Prudente. Os dados referentes aos atendimentos mensais no município, nos anos de 2017, 2018, 2019, 2020, 2021 e 2022 foram padronizados como taxas para cada 1.000 habitantes, com base na população projetada para o município pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2024). Para procedimentos específicos, os dados foram padronizados conforme o estrato populacional: exames citopatológicos para cada 1.000 mulheres na idade entre 25 e 64 anos, exames de mamografia para cada 1.000 mulheres com a idade acima de 40 anos, exames pré-natais e exames de colposcopia para cada 1.000 mulheres em idade fértil (15 a 49 anos), atendimento a idosos cada 1.000 indivíduos acima de 60 anos, atendimentos a crianças cada 1.000 crianças com idade inferior a 14 anos, exames de PSA para cada 1.000 homens com idade acima de 40 anos e exames de rastreamento de câncer de mama para cada 1.000 mulheres com idade entre 50 e 70 anos. Os dados processados foram compostos apenas pelo total de atendimentos de cada especialidade para cada mês do período considerado, não sendo possível a identificação dos participantes, ou bairros atendidos. Consideramos, diante da natureza dos dados, que essas informações são públicas e não rastreáveis, portanto, não necessitaram de aprovação por comitê de ética.

Séries temporais

Os dados padronizados foram utilizados para a construção de modelos de médias móveis autorregressivas (ARIMA), especificados mediante a determinação dos termos p , d , q (componentes não sazonais) e P , D e Q (componentes sazonais). O termo “ p ” representou o número de defasagens autorregressivas (relação entre o valor atual da série e seus valores passados), o termo d , a ordem de diferenciação (número de vezes que os dados precisaram ser diferenciados matematicamente para atingir a estacionalidade), e q o número de defasagens de média móvel. Os termos sazonais “ P ”, “ D ” e “ Q ” foram especificados de forma análoga aos termos não sazonais (Ljung; Box, 1978). Considerando-se que os modelos ARIMA sazonais

podem ser especificados com múltiplas combinações dos termos mencionados, recorreremos ao processo de seleção de modelos baseado no algoritmo “auto.arima” disponível no pacote “forecast” do Programa R (Hyndman; Khandakar, 2008), especificado com o comando “seasonal=TRUE” para capturar a tendência sazonal dos dados, caso existisse. Este algoritmo testa diferentes parâmetros até encontrar uma combinação que minimize o AIC (Akaike Information Criterion) ou BIC (Bayesian Information Criterion). Nos modelos gerados pelo algoritmo foram adicionados dois regressores de controle: um para avaliar o efeito imediato do decreto de pandemia, designando como “step” e outro para designar o efeito progressivo ao longo do tempo, designado como “ramp”. Um termo para controlar a tendência residual linear dos dados (“drift”) foi adicionado automaticamente pelo algoritmo quando necessário. Os coeficientes dos modelos foram testados para a hipótese de que diferem estatisticamente de zero, adotando-se 5% de nível de significância. Todas as análises foram conduzidas no Programa R (R Core Team, 2025).

O modelo ARIMA construído nas etapas anteriores com os dados foi utilizado para prever o comportamento dos dados, imediatamente após o decreto de quarentena (oficialmente proclamado no Brasil em 20 de março de 2020). Os dados previstos pelo modelo para esta janela de tempo foram inseridos em gráficos temporais conjuntamente com os dados reais, para permitir uma comparação entre o comportamento temporal esperado (previsões reais) e os valores observados (Schaffer; Dobbins; Pearson, 2021).

Resultados

As taxas anuais médias de atendimentos para as diferentes modalidades de atenção básica, padronizadas para cada 1.000 habitantes, estão sumarizadas na tabela 1. A tabela 2 apresenta os resultados das séries temporais interrompidas baseadas em ARIMA modeladas para o ponto de inflexão correspondente a pandemia de COVID-19. As figuras 1 a 4 apresentam os gráficos com as séries temporais dos dados reais e dos modelos previstos pela análise de STI.

As especificações dos modelos ARIMA permitem observar a diversidade de comportamentos temporais dos parâmetros estudados. O método não conseguiu capturar a tendência temporal para exames de colposcopia e pré-natais, que retornaram modelos denotados como “ARIMA (0,0,0)”, nos quais não há

dependência temporal, nem tendências ou sazonalidades. Estas séries são puramente aleatórias, sem padrão temporal.

Modelos que apresentaram apenas três termos na ARIMA diferentes de zero foram considerados não sazonais, o que foi observado para o total de procedimentos, mamografias gerais e de rastreio. Em contraste, os modelos que apresentaram seis termos na ARIMA (três termos não sazonais, seguidos de três termos sazonais e o número "12" para indicar que a sazonalidade foi modelada mensalmente) foram considerados sazonais, o que foi observado para o total de atendimentos, citologias, atendimento à idosos, hipertensos, diabéticos e crianças, atendimentos odontológicos e exames de PSA.

Consideramos que os coeficientes internos das séries, designados como médias móveis (ma) e termos autorregressivos (ar), sazonais ou não, descrevem como a série temporal é influenciada por suas observações passadas, desvios e tendências. Valores positivos dos coeficientes autorregressivos não sazonais (ar) indicaram que, se o valor passado foi alto, o valor atual também tende a ser alto, sugerindo uma relação direta. Este fenômeno foi observado para citologias ($ar_1=1,402$, $p < 0,001$), atendimento à hipertensos ($ar_1 = 0,885$; $p < 0,001$) e atendimento à diabéticos ($ar_1 = 0,837$; $p < 0,001$).

Quando o coeficiente autorregressivo sazonal (sar) foi positivo indicou que padrões sazonais anteriores influenciam de forma direta os valores presentes, o que foi observado para Total de atendimentos ($sar_1=0,307$; $p=0,020$), Atendimento à idosos ($sar_1=0,350$; $p=0,006$) e Atendimento à hipertensos ($sar_1=0,347$, $p=0,016$). Atendimento à diabéticos apresentou coeficiente não significativo ($sar_1=0,297$, $p=0,053$)

Por outro lado, coeficiente autorregressivos negativos indicam que, se o valor passado foi alto, o valor atual tende a ser baixo, sugerindo uma relação inversa. Este fenômeno foi observado para Citologias ($ar_2=-0,776$, $p < 0,001$), considerando os termos não sazonais e para mamografias ($sar_1=-0,492$, $p < 0,001$, Exames de PSA ($sar_1=-0,529$, $p < 0,001$) e atendimentos odontológicos ($sar_1=-0,616$, $p < 0,001$), considerando-se os termos sazonais.

Médias móveis positivas (ma) indicam que os erros passados têm um efeito corretivo ou ampliador positivo sobre o valor atual da série temporal, enquanto médias móveis negativas indicam uma correção, ou um efeito inverso, dos erros passados sobre o valor da série temporal. Quando significativas, indicam que as

séries temporais têm uma dinâmica de ajuste de seus valores a partir de um impacto negativo dos períodos anteriores. Foram significativas as médias móveis para total de procedimentos ($ma1=-0,542$; $p<0,001$ e $ma2=0,916$; $p<0,001$), mamografias gerais ($ma1=0,365$; $p=0,019$, e $ma3=0,464$; $p=0,003$) e atendimento à hipertensos ($ma1=-0,513$, $p=0,005$). Apresentaram média móveis sazonais significativas e negativas, citologias ($sma1=-0,504$, $p=0,036$) e atendimentos à crianças ($sma1=-0,645$; $p=0,004$), o que sugere que um aumento no valor da série temporal no período sazonal anterior é acompanhado por uma diminuição no valor atual, com um efeito estatisticamente significativo.

Consideramos que a pandemia teve efeitos significativos no comportamento dos dados quando os valores de “step” e “ramp” foram estatisticamente significativos. Foram observados efeitos imediatos sobre o comportamento temporal dos dados com quedas significativas após o decreto de pandemia, para o total de atendimentos (step = $-1,729$; $p = 0,023$), citologias (step: $-0,374$; $p=0,027$), mamografias gerais (step= $-0,575$; $p<0,001$), atendimento a idosos (step= $-5,306$; $p<0,001$), exames de PSA (step= $-0,632$; $p < 0,001$), atendimentos a crianças (step= $-5,500$; $p<0,001$) e atendimentos odontológicos (step= $-1,354$; $p < 0,001$). Estes resultados sugerem mudanças estruturais abruptas e significativas no comportamento temporal dos dados com efeitos de maior magnitude para atendimento a crianças e idosos.

Em relação aos coeficientes “ramp”, que denotam o efeito de longo prazo nos meses subsequentes ao decreto, observou-se efeito positivo e significativo para citologias (ramp = $0,021$; $p=0,027$), mamografias gerais (ramp = $0,025$; $p=0,006$), exames de PSA (ramp = $0,031$; $p=0,001$), atendimentos a crianças (ramp = $0,130$; $p=0,003$) e atendimentos odontológicos (ramp = $0,039$; $p<0,001$). efeito longo prazo negativo e significativo foi observado apenas atendimento a idosos (ramp = $-0,209$; $p=0,018$). Estes resultados sugerem que todos os procedimentos e atendimentos apresentaram recuperações tênues e graduais após o decreto de pandemia, com exceção dos atendimentos a idosos, que apresentaram tendência a queda.

Nos gráficos temporais os modelos ARIMA foram capazes de prever linhas retas indicando dados predominantemente estacionários, ou com tendência linear para algumas variáveis, o que implica que as flutuações dos dados são mínimas e que, em geral, o valor futuro esperado será próximo ao valor passado, sem grandes

variações. Em contraste, para outras variáveis, observou-se linhas sinuosas, o que sugere que o modelo capturou algum tipo de sazonalidade ou ciclicidade nos dados.

Tabela 1— Total de atendimentos e procedimentos de atenção primária realizados no município de Presidente Prudente entre os anos de 2017 e 2021, segundo modalidade de atendimento ou procedimento

Contagens/ cada 1.000 indivíduos	Ano*				
	2017	2018	2019	2020	2021
Total de atendimentos/ mil hab.	168,47	179,31	193,02	163,28	166,74
Total de procedimentos/ mil hab.	278,42	376,29	407,95	336,41	404,95
Procedimentos					
Citopatológicos/mil hab.	10,88	10,47	11,70	8,16	10,47
Mamografia geral/mil mulheres > 40 anos	14,31	13,89	15,97	10,53	13,36
Mamografia de rastreamento/ mil mulheres de 40-70 anos	1,09	11,61	16,15	11,93	10,37
PSA/ mil homens > 40 anos	21,62	18,55	21,49	15,05	18,36
Colposcopia/ mil mulheres em idade fértil	0,19	0,17	0,22	0,14	0,26
Atendimentos					
Odontológicos/ mil hab.	20,72	20,57	22,80	10,78	15,40
Crianças / mil crianças < 14 anos	122,75	122,98	130,90	74,43	82,40
Diabéticos/mil hab. **	4,96	9,54	11,41	10,28	9,48
Pré-natal/mil mulheres em idade reprodutiva **	16,86	31,43	30,27	29,65	29,82
Idosos /mil hab. > 60 anos	381,38	412,39	423,57	335,92	296,10
Hipertensos para cada mil hab.**	16,28	34,39	38,84	29,61	23,99

* suprimiu-se o ano de 2022 em razão de informação incompleta; **– dados anuais incompletos para os meses de janeiro a maio.

Fonte: Autoria própria

Tabela 2— Parâmetros dos modelos ARIMA para modelagem temporal do número de procedimentos e exames de atenção básica, Presidente Prudente, SP, 2017-2022

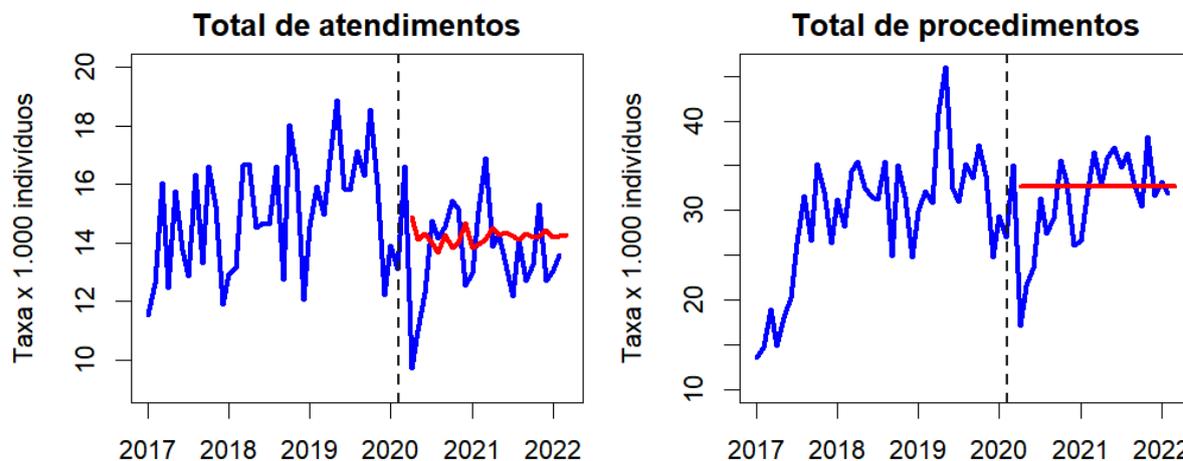
Variável	Modelo	Coefficiente	Estimativa	p
Total de atendimentos	ARIMA(0,0,0)(1,0,0)[12]	intercepto	14,931	< 0,001
		sar1	0,307	0,020
		step	-1,729	0,023
		ramp	0,029	0,546
		ma1	-0,542	< 0,001
Total de procedimentos	ARIMA(0,1,1)	step	-1,533	0,747
		ramp	0,250	0,624
		ar1	1,402	< 0,001
Citologias	ARIMA(2,0,2)(0,1,1)[12]	ar2	-0,776	< 0,001

		ma1	-1,245	< 0,001
		ma2	0,916	< 0,001
		sma1	-0,504	0,036
		step	-0,374	0,027
		ramp	0,021	0,027
Colposcopias	ARIMA(0,0,0)	intercepto	0,016	< 0,001
		step	-0,004	0,360
		ramp	0,001	0,097
Mamografias gerais	ARIMA(0,1,2)	ma1	0,365	0,019
		ma2	0,065	0,671
		ma3	0,464	0,003
		sar1	-0,492	< 0,001
		step	-0,575	< 0,001
		ramp	0,025	0,006
Mamografias de rastreio	ARIMA(0,1,1)	ma1	-0,109	0,398
		ma2	-0,291	0,017
		step	-0,207	0,452
		ramp	0,001	0,970
Atendimento a idosos	ARIMA(0,0,0)(1,0,0)[12]	intercepto	33,435	< 0,001
		sar1	0,350	0,006
		step	-5,306	< 0,001
		ramp	-0,209	0,018
Atendimento à hipertensos	ARIMA(1,0,1)(1,0,0)[12]	intercepto	2,535	< 0,001
		ar1	0,885	< 0,001
		ma1	-0,513	0,005
		sar1	0,347	0,016
		step	-0,281	0,422
		ramp	-0,009	0,780
Atendimento à diabéticos	ARIMA (1,0,1)(1,0,0)[12]	intercepto	0,800	< 0,001
		ar1	0,837	< 0,001
		ma1	-0,571	0,009
		sar1	0,297	0,053
		step	-0,051	0,627
		ramp	0,008	0,356
Exames de PSA	ARIMA(0,0,0)(1,1,0)[12]	sar1	-0,529	< 0,001
		step	-0,632	< 0,001
		ramp	0,031	0,001
Atendimentos a crianças	ARIMA(0,0,0)(0,1,1)[12]	sma1	-0,645	0,004
		step	-5,500	< 0,001
		ramp	0,130	0,003
Exames pré-natais	ARIMA(0,0,0)	intercepto	2,515	< 0,001
		step	0,091	0,504
		ramp	-0,014	0,225
Atendimentos odontológicos	ARIMA(0,0,0)(1,1,0)[12]	sar1	-0,616	< 0,001
		drift	0,006	0,066
		step	-1,354	< 0,001
		ramp	0,039	< 0,001

ma1, ma2 e ma3 = coeficientes de médias móveis; ar1, ar2 e ar3 = coeficientes autorregressivos; sma1= coeficiente de média móvel sazonal; sar1 = coeficiente autorregressivo sazonal; step = regressor para designar o efeito imediato; ramp = regressor para designar o efeito progressivo ao longo do tempo; drift = tendência linear; p = significância estatística para o teste de hipótese de que o coeficiente difere significativamente de zero.

Fonte: Autoria própria

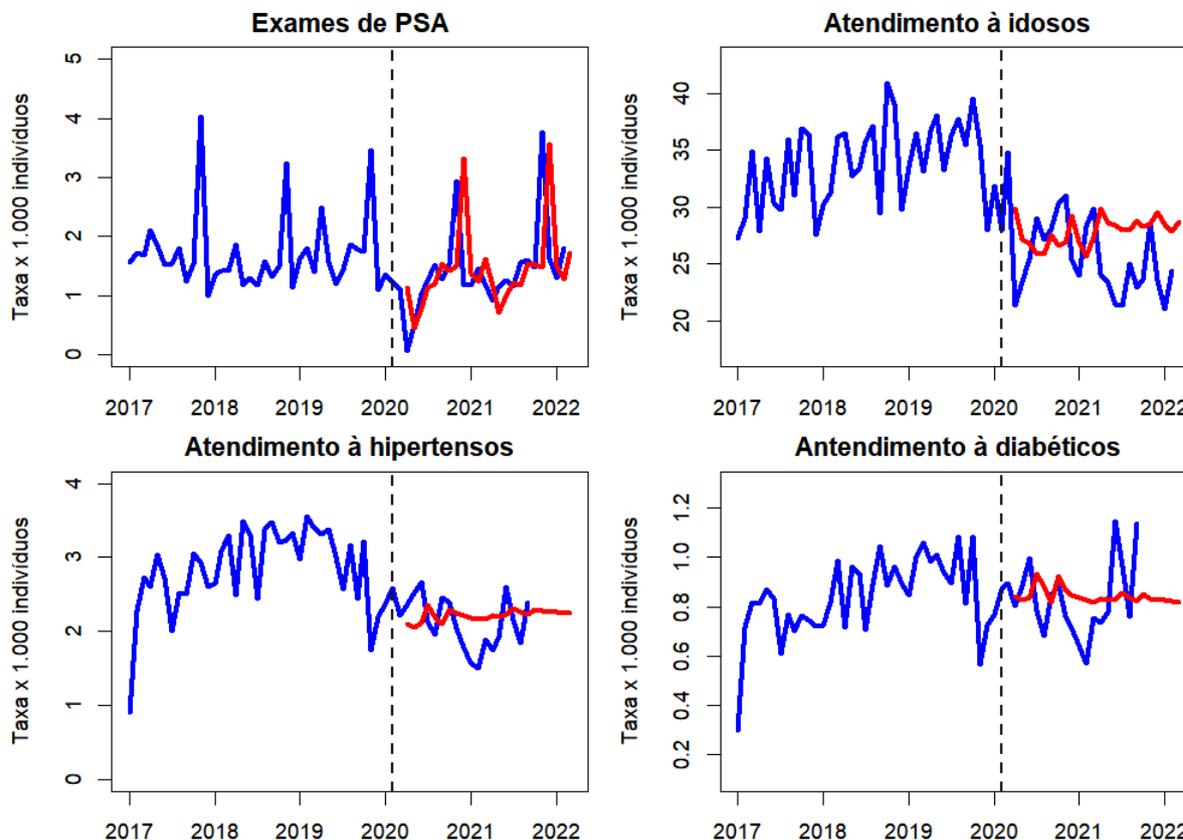
Figura 1— Séries temporais para atendimentos totais e procedimentos totais no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-2022



Legenda: As linhas azuis indicam a série temporal original (total de atendimentos para cada 1.000 habitantes e as linhas vermelhas, os valores esperados caso não ocorresse a pandemia de COVID-19. A linha pontilhada em cada gráfico indica o dia do decreto de quarentena.

Fonte: Autoria própria

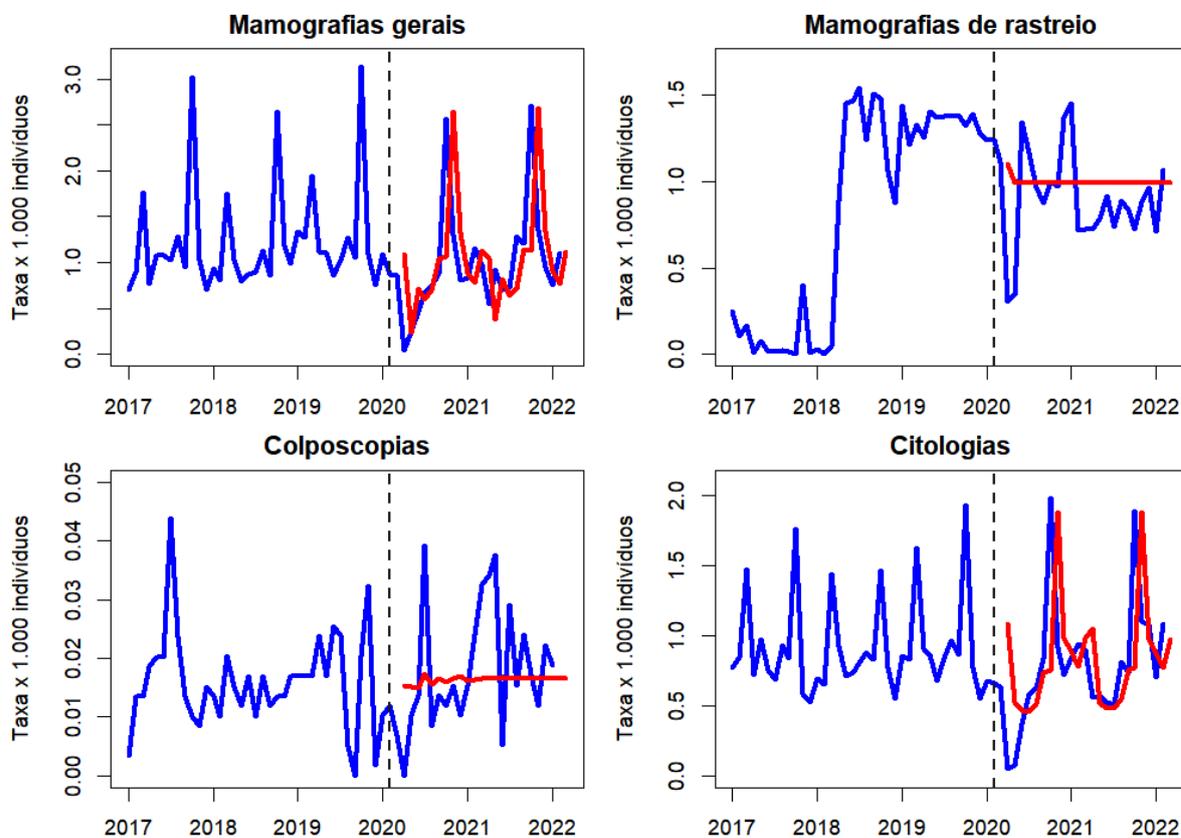
Figura 2— Série temporal para procedimentos cobertos pela atenção básica: Dosagens de Antígeno Prostático (PSA), Antedimentos a Idosos, Diabéticos e Hipertensos no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-2022



Legenda: As linhas azuis indicam a série temporal original (total de atendimentos para cada 1.000 habitantes e as linhas vermelhas, os valores esperados caso não ocorresse a pandemia de COVID-19. A linha pontilhada indica o dia do decreto de quarentena.

Fonte: Autoria própria

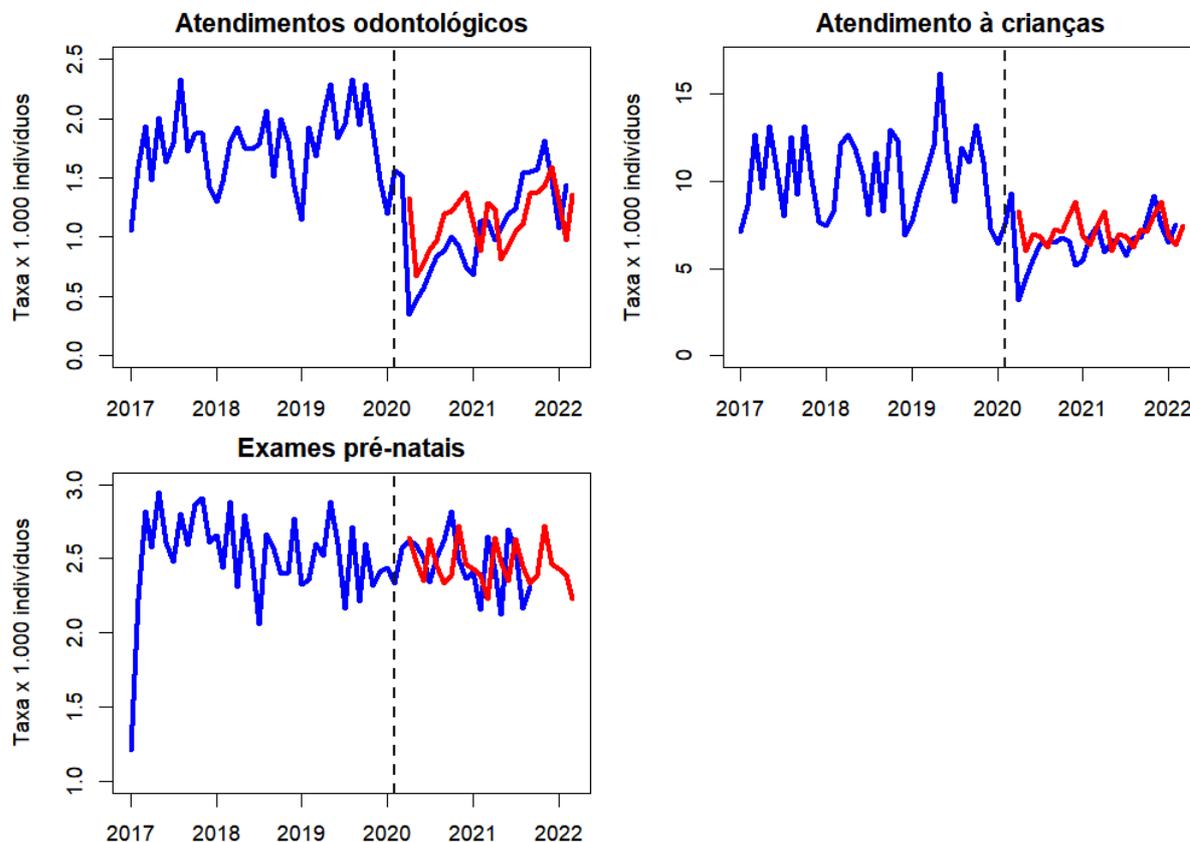
Figura 3— Série temporal para atendimentos cobertos pela atenção básica: mamografias gerais e de rastreo, colposcopias e citologias no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-2022



Legenda: As linhas azuis indicam a série temporal original (total de atendimentos para cada 1.000 habitantes e as linhas vermelhas, os valores esperados caso não ocorresse a pandemia de COVID-19. A linha pontilhada indica o dia do decreto de quarentena.

Fonte: Autoria própria

Figura 4— Série temporal para atendimentos cobertos pela atenção básica: atendimentos odontológicos, atendimentos à crianças e exames pré-natais no período pré e pós-pandemia de COVID-19, Presidente Prudente entre 2017-2022



Legenda: As linhas azuis indicam a série temporal original (total de atendimentos para cada 1.000 habitantes e as linhas vermelhas, os valores esperados caso não ocorresse a pandemia de COVID-19. A linha pontilhada indica o dia do decreto de quarentena.

Fonte: Autoria própria

Discussão

O presente estudo representa a primeira investigação utilizando ARIMA e STI realizada no Brasil sobre os impactos da pandemia na Atenção Básica, evidenciando como os eventos pandêmicos desestruturam e comprometem a saúde pública. O ano de 2019 registrou o maior número de atendimentos e procedimentos na atenção primária à saúde, enquanto 2020 apresentou os menores valores. Esse declínio significativo em 2020 sugere uma influência direta da pandemia na procura por serviços de saúde primários. A pandemia possivelmente contribuiu para a redução dos atendimentos e procedimentos devido a fatores como o medo de contágio, as restrições de mobilidade e a priorização de recursos para o combate à COVID-19. Essas mudanças ressaltam a vulnerabilidade do sistema de saúde em situações de crise sanitária, evidenciando a necessidade de estratégias de

resiliência para manter a continuidade dos cuidados essenciais à população (Tureck *et al.*, 2024).

A tabela 1 fornece um panorama das atividades de saúde pública em termos de atendimentos e procedimentos realizados a cada 10.000 indivíduos entre os anos de 2017 e 2021. O número total de atendimentos aumentou de 2017 para 2019, seguido por uma queda em 2020, com leve recuperação em 2021. Conforme o padrão observado, a pandemia de COVID-19 teve impactos significativos na atenção básica à saúde em Presidente Prudente, afetando diretamente a oferta e a procura por serviços essenciais com redução nos atendimentos e procedimentos de rotina, visto que consultas médicas de acompanhamento, exames preventivos, como mamografias, citopatológicos e consultas odontológicas foram adiados ou cancelados devido às medidas de distanciamento social e às restrições impostas às clínicas e unidades de saúde. Muitas regiões registraram diminuição nos serviços preventivos e, portanto, mudanças na dinâmica dos cuidados primários, visto que os pacientes, temendo a exposição ao vírus, evitaram procurar assistência médica para condições crônicas, como diabetes, hipertensão e cuidados pré-natais. Isso pode ter consequências sérias a longo prazo, pois a interrupção no manejo dessas condições pode levar a complicações de saúde significativas (Barros *et al.*, 2021).

Os dados da Tabela 2 refletem os impactos da pandemia nos atendimentos e procedimentos. Conforme observado, o impacto imediato do decreto de pandemia propiciou a redução de vários serviços e procedimentos de atenção básica, denotado pelos coeficientes “step” significativos. Nota-se também que para alguns procedimentos e exames, estes coeficientes não foram significativos, incluindo total de procedimentos, colposcopias, mamografias de rastreamento, atendimentos a hipertensos e diabéticos e exames pré-natais. Contudo, fica claro nos gráficos temporais que ocorreram quedas nestes serviços no período próximo ao decreto de pandemia, com exceção dos exames pré-natais. Estes resultados sugerem que os modelos ARIMA não foram sensíveis o suficiente para lidar com os dados. Neste caso, metodologias temporais alternativas podem ser adotadas, incluindo métodos baseados em inteligência artificial como o Extreme Gradient Boosting e as redes neurais (Paliari; Karanikola; Kotsiantis, 2021).

As quedas observadas nos gráficos e nos modelos podem ser atribuídas aos impactos da pandemia de COVID-19, mantendo um padrão semelhante ao observado em nível mundial (Chhabra *et al.*, 2023). Medidas de distanciamento

social, quarentenas e outras restrições implementadas para conter a propagação do vírus resultaram em mudanças significativas no comportamento de busca por cuidados médicos. Muitos pacientes adiaram consultas e procedimentos não urgentes por receio de exposição ao vírus em ambientes de saúde. Além disso, a realocação de recursos para lidar com o aumento de casos de COVID-19 também pode ter reduzido a capacidade dos serviços de saúde de realizar atendimentos e procedimentos não emergenciais (McArthur *et al.*, 2021).

Destaca-se que, ao contrário do esperado, os atendimentos a hipertensos e diabéticos apresentaram reduções não significativas, conforme observa-se pelos coeficientes “step”, contudo, nos gráficos temporais, as quedas são notáveis pouco antes do decreto de pandemia, sugerindo que estes exames foram afetados antes do país implementar a quarentena. Uma possível razão para este fenômeno é que são condições crônicas que afetam principalmente idosos, a população mais vulnerável à pandemia. Essas condições crônicas de saúde foram significativamente afetadas pela pandemia de COVID-19 devido a múltiplos fatores (Kim *et al.*, 2023). Durante os períodos de maior intensidade da pandemia, as medidas de distanciamento social e as restrições de mobilidade reduziram o acesso aos serviços de saúde. A interrupção temporária de consultas e exames de rotina pode ter contribuído para flutuações nos indicadores de saúde desses grupos, especialmente entre aqueles dependentes de cuidados contínuos para gerenciar suas condições (Khunti; Valabhji; Misra, 2023).

Exames citopatológicos apresentaram uma leve variação, com uma queda em 2020 seguida por um aumento em 2021, conforme observado na tabela 1. O modelo temporal indicou que, após a queda significativa no início da pandemia, houve uma recuperação com tendência ao crescimento. A citopatologia é um exame essencial para detecção do câncer de colo de útero, assim como o PSA e as mamografias, sendo parte das políticas de rastreamento implementadas no país (Carter *et al.*, 2015). Neste sentido, o Instituto Nacional de Câncer (INCA) estabeleceu diretrizes rigorosas a serem seguidas durante o período pandêmico para garantir a continuidade dos cuidados oncológicos essenciais, mesmo diante das restrições impostas pela COVID-19 (Santos; Corrêa, 2020). No entanto, estratégias estão sendo implementadas para reverter esse cenário, como a intensificação de campanhas de conscientização em massa, voltadas para a população geral, com o

objetivo de mitigar o impacto futuro causado pela ausência de diagnóstico precoce e pela interrupção dos cuidados preventivos (Kumar; Saini; Ganguly, 2023).

O exame de PSA (Antígeno Prostático Específico), utilizado para a detecção do câncer de próstata, apresentou um comportamento semelhante ao de outros procedimentos, com um aumento até 2019, seguido por uma queda em 2020 e uma recuperação parcial em 2021. Os resultados indicam uma influência negativa dos fatores sazonais passados, o que pode refletir mudanças nas diretrizes de triagem ou na conscientização pública sobre a importância do exame, como observado em outros países (Epstein *et al.*, 2022). Embora o benefício desse procedimento ainda seja discutido (Roobol, 2018), a redução no número de exames em Presidente Prudente parece ter sido temporária, com uma retomada aos níveis anteriormente observados nos meses seguintes. Um dos fatores que podem explicar esse padrão são as campanhas recorrentes do Novembro Azul, que claramente contribuem para a sazonalidade no número de exames realizados, chegando a dobrar durante esse mês.

A mamografia é um exame crucial para o diagnóstico precoce do câncer de mama. Segundo dados do Instituto Nacional de Câncer (INCA), a cobertura desse exame no Brasil ainda enfrenta desafios, especialmente em regiões remotas e desfavorecidas (Santos; Corrêa, 2020). Os coeficientes observados sugerem que os exames de mamografia geral foram mais afetados do que as mamografias de rastreamento. Com efeito, as mamografias gerais são exames agendados, por vezes para o controle de pacientes oncológicos, enquanto que as mamografias de rastreamento são exames usados como método de varredura em busca de novos casos de câncer na população e sujeitos às variações sazonais das campanhas (Carter *et al.*, 2015). Desta forma, a segunda modalidade é mais propensa a adiamentos. As campanhas de conscientização têm sido as principais aliadas para a recuperação desse procedimento, sendo fundamentais para ampliar a oferta de mamografias e garantir que o exame chegue a regiões estratégicas, minimizando os impactos causados pelo período pandêmico (Fiorillo, 2023).

Durante e após a pandemia, observou-se uma redução significativa na oferta de mamografias de rastreamento, um cenário amplamente atribuído aos impactos das medidas de distanciamento social e restrições operacionais nos serviços de saúde. Durante o auge da pandemia, muitos centros de saúde e hospitais concentraram seus recursos na resposta à COVID-19, reduzindo ou suspendendo

temporariamente serviços não emergenciais, como mamografias de rastreamento. Esse cenário foi agravado pelo receio dos pacientes de frequentar ambientes de saúde devido ao risco de exposição ao vírus (Fritsch *et al.*, 2024). O Programa Nacional de Controle do Câncer de Mama (PNCCM), conforme recomendações do Ministério da Saúde do Brasil, orienta o rastreamento para mulheres entre 50 e 69 anos, mas a implementação efetiva e a equidade no acesso continuam sendo desafios. Estratégias emergenciais, como a telemedicina e unidades móveis de saúde, têm sido exploradas para mitigar esses desafios e garantir que as mulheres continuem a ter acesso à mamografia (Assis; Santos; Migowski, 2020).

As colposcopias não apresentaram coeficientes significativos. Contudo, observa-se nos gráficos uma queda acentuada no número de exames nos gráficos temporais. O padrão de queda parece ser bimodal, com queda acentuada antes mesmo do decreto de pandemia. A colposcopia é de extrema importância para o diagnóstico precoce do câncer de colo do útero. Este exame permite visualizar com maior precisão áreas suspeitas identificadas em exames como o Papanicolau, possibilitando a identificação de lesões pré-cancerígenas ou cancerígenas no colo do útero, vagina e vulva (Qin *et al.*, 2023). O rastreamento do câncer de colo de útero, por meio da colposcopia, permaneceu relativamente estável, com ligeiras variações e um aumento em 2021. Os coeficientes sugerem uma estabilidade ao longo do tempo, com influência significativa apenas do momento (Elemes *et al.*, 2023). Isso pode indicar consistência nas políticas de triagem ou uma demanda estável por esse serviço, possivelmente relacionada ao período de campanhas de prevenção, como a realizada no mês de março (Bernuci *et al.*, 2023).

Os atendimentos odontológicos sofreram uma queda significativa em 2020, seguida por uma recuperação parcial em 2021 (coeficiente “step” negativo e significativo), e continuaram a se recuperar gradativamente, conforme coeficiente “ramp” positivo e significativo. Detectou-se também influência positiva dos fatores sazonais, com o comportamento possivelmente associado às inseguranças relacionadas à contaminação pelo vírus SARS-CoV-2. Embora as recomendações de segurança fossem seguidas, os atendimentos caíram em âmbito mundial durante o pico da pandemia (Eggmann *et al.*, 2021). Em Presidente Prudente, apenas um atendimento por hora foi realizado, além do cancelamento dos atendimentos previamente agendados. A retomada dos atendimentos em 2021 está alinhada com

estudos que destacam a importância da saúde bucal e a necessidade de acesso a serviços odontológicos em diferentes faixas etárias.

Para crianças menores de 12 anos, assim como idosos, a análise das variações nos atendimentos ao longo do tempo revela a complexidade trazida pela pandemia de COVID-19. Durante períodos de crise sanitária, observou-se as maiores quedas na demanda por estes atendimentos para ambas as categorias, possivelmente influenciada diretamente por medidas como o distanciamento social, restrições de mobilidade e mudanças no comportamento da população em relação à busca por serviços médicos (Evensen *et al.*, 2023). Em ambos os casos, estes são os usuários mais comuns dos sistemas de assistência à saúde. As crianças necessitam de acompanhamento para fases críticas, onde o foco é a vacinação, controle do crescimento e desenvolvimento (peso, altura, nutrição), tratamento de doenças comuns na infância, como infecções respiratórias e gastrointestinais e alta incidência de doenças evitáveis (Cabral *et al.*, 2021). Em contraste, o envelhecimento é acompanhado por um aumento da prevalência de doenças crônicas e degenerativas, como hipertensão, diabetes e artrite, além da necessidade de tratamento de múltiplas comorbidades e cuidados preventivos para evitar complicações, como quedas e infecções (Alves *et al.*, 2007). Estes dois extratos populacionais, muitas vezes, têm maior dificuldade em acessar níveis mais complexos de cuidado (por questões econômicas, mobilidade ou dependência de terceiros), o que os torna dependentes de cuidados primários. Portanto, justamente a população mais vulnerável foi a mais prejudicada pela pandemia.

Destaca-se que, enquanto os atendimentos às crianças se recuperaram nos meses subsequentes, denotado pelo coeficiente “ramp” positivo e significativo, os atendimentos a idosos foram os únicos entre todas as modalidades que apresentaram redução significativa no número de atendimentos, denotado pelo coeficiente “ramp” negativo e significativo. Políticas de saúde voltadas para as condições crônicas típicas dessa faixa etária são essenciais em países que passam por uma transição demográfica, como é o caso do Brasil (Miranda; Mendes; Silva, 2016). Essas políticas devem abranger várias dimensões de cuidados, incluindo acesso a ambulatórios clínicos, serviços de atendimento geriátrico domiciliar, emergencial, cuidados paliativos e tratamentos de longa duração, como reabilitação e instituições de permanência para idosos (Veras; Oliveira, 2018). No cenário observado, a situação é preocupante e reforça a necessidade de estratégias

adaptativas para a saúde durante crises, como a pandemia. Sistemas de saúde flexíveis e resilientes, capazes de se adaptar rapidamente às novas circunstâncias sem comprometer os serviços médicos, serão essenciais no futuro. Nesse sentido, sistemas de agendamento simplificados e protocolos de triagem modificados são estratégias potenciais para aderir às diretrizes de saúde do idoso, além de campanhas proativas de saúde pública para informar sobre a importância contínua dos exames de rotina e a disponibilidade de ambientes de saúde seguros (Akintunde *et al.*, 2021).

O único serviço que parece não ter sido afetado de forma imediata pela pandemia foram os atendimentos de pré-natal, tanto na avaliação gráfica como na modelagem. Estes resultados podem ser reflexo dos autocuidados das gestantes em relação à gravidez. Durante períodos de crise sanitária, como a pandemia, houve uma necessidade urgente de adaptação nos serviços de pré-natal para garantir a continuidade dos cuidados essenciais às gestantes. Inicialmente, as medidas de distanciamento social e as quarentenas levaram a ajustes nos protocolos de atendimento, com possíveis impactos na acessibilidade aos serviços de saúde materna (Kajdy *et al.*, 2023). A flexibilização gradual dessas restrições, ao longo do tempo, possibilitou uma recuperação parcial dos níveis de atendimento pré-natal. Isso reflete não apenas uma resposta adaptativa das instituições de saúde, mas também a importância de políticas públicas eficazes para mitigar os efeitos adversos sobre os cuidados pré-natais durante crises de saúde pública (Williams; Berkowitz; Rackin, 2023).

Conclusão

É evidente que a pandemia de COVID-19 teve um impacto profundo e multifacetado na Atenção Básica à Saúde em Presidente Prudente - SP. A análise dos dados revelou uma redução significativa nos atendimentos e procedimentos de saúde em 2020, reflexo das medidas de distanciamento social e das prioridades emergenciais voltadas para o combate à COVID-19. Essa diminuição afetou especialmente os serviços preventivos e de acompanhamento, essenciais para o manejo de condições crônicas e o diagnóstico precoce de cânceres.

É imperativo que lições sejam aprendidas desses desafios para fortalecer a preparação e a resposta futuras a crises de saúde pública. Investimentos contínuos em tecnologia e infraestrutura de saúde, juntamente com campanhas educativas e

preventivas, são fundamentais para mitigar os impactos de futuras emergências. A manutenção da acessibilidade e qualidade dos serviços de saúde primária é essencial para garantir o bem-estar contínuo da população, especialmente em tempos de adversidade global como os vivenciados durante a pandemia de COVID-19.

Agradecimentos

Agradecemos à coordenação de saúde do município de Presidente Prudente por facilitar a obtenção dos dados utilizados nesta pesquisa.

O Presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior -Brasil (CAPES) -Código de financiamento 001.

REFERÊNCIAS

AKINTUNDE, Tolu Yakubu *et al.* Expanding telemedicine to reduce the burden on the healthcare systems and poverty in Africa for a post-coronavirus disease 2019 (COVID-19) pandemic reformation. **Global Health Journal**, v. 5, p. 128–134, 2021.

ALVES, Luciana Conceição *et al.* A influência das doenças crônicas na capacidade funcional dos idosos do Município de São Paulo, Brasil. **Cadernos de Saúde Pública**, v. 23, p. 1924–1930, 2007.

ASSIS, Mayara Dias de; SANTOS, Rafael Oliveira Moreira dos; MIGOWSKI, Ana. Detecção precoce do câncer de mama na mídia brasileira no Outubro Rosa. **Physis**, v. 30, p. e300119, 2020.

BALLARD, Megan *et al.* Continuity of community-based healthcare provision during COVID-19: a multicountry interrupted time series analysis. **BMJ Open**, v. 12, p. e052407, 2022.

BARROS, Gilberto *et al.* Decrease in search to hospitals and health services and the interruption of therapeutics and treatments during pandemic. **Brazilian Journal of Global Health**, v. 1, p. 35–39, 2021.

BERNUCI, Marcelo Pereira *et al.* Cervical Cancer Prevention on Instagram: Content and Social Interaction Analysis of Brazilian Accounts. **Asian Pacific Journal of Cancer Biology**, v. 8, p. 13–19, 2023.

BHASKARAN, Krishnan *et al.* Time series regression studies in environmental epidemiology. **International Journal of Epidemiology**, v. 42, p. 1187–1195, 2013.

BRASIL. Informações de Saúde (TABNET) – DATASUS. Ministério da Saúde, 2024. Disponível em: <https://datasus.saude.gov.br/informacoes-de-saude-tabnet/>. Acesso em: 14 nov. 2024

CABRAL, Isabel Eleutério *et al.* Child health vulnerabilities during the COVID-19 pandemic in Brazil and Portugal. **Revista Latino-Americana de Enfermagem**, v. 29, p. e3422, 2021.

CANCINO, Rocio S. *et al.* The Impact of COVID-19 on Cancer Screening: Challenges and Opportunities. **JMIR Cancer**, v. 6, p. e21697, 2020.

CARTER, Stacy M. *et al.* Screening for Cervical, Prostate, and Breast Cancer. **American Journal of Preventive Medicine**, v. 49, p. 274–285, 2015.

CHHABRA, Shagun T. *et al.* Outpatient Attendance in COVID Pandemic Lockdown: An Observational Study. **International Journal of Chronic Diseases and Wellness**, v. 8, p. 18–24, 2023.

DEL VECCHIO BLANCO, Giovanni *et al.* The impact of COVID-19 pandemic in the colorectal cancer prevention. **International Journal of Colorectal Disease**, v. 35, p. 1951–1954, 2020.

EGGMANN, Florian *et al.* Impact of the COVID-19 pandemic on urgent dental care delivery in a Swiss university center for dental medicine. **Clinical Oral Investigations**, v. 25, p. 5711–5721, 2021.

ELEMES, Spyridon *et al.* The Impact of the COVID-19 Pandemic on Breast and Cervical Cancer Screening: A Systematic Review. **In Vivo**, v. 37, p. 1455–1476, 2023.

EPSTEIN, Michael M. *et al.* Trends in breast and prostate cancer screening and diagnostic procedures during the COVID-19 pandemic in central Massachusetts. **Cancer Causes & Control**, v. 33, p. 1313–1323, 2022.

EVENSEN, Marianne *et al.* Impact of the COVID-19 pandemic on mental healthcare consultations among children and adolescents in Norway: a nationwide registry study. **European Child & Adolescent Psychiatry**, v. 32, p. 1025–1035, 2023.

FIORILLO, Sarah. Breast Cancer Awareness Month: The History and Impact. **Clinical Advisor**, 2023. [S.l.: s.n.]. [Sem paginação]

FRITSCH, Talita Zanetti *et al.* Impact of COVID-19 on the clinical staging of breast cancer: A cross-sectional study. **Advances in Cancer Biology – Metastasis**, v. 10, p. 100116, 2024.

HEESTERBEEK, Hans *et al.* Modeling infectious disease dynamics in the complex landscape of global health. **Science**, v. 347, p. aaa4339, 2015.

HONE, Thomas *et al.* Racial and socioeconomic disparities in multimorbidity and associated healthcare utilisation and outcomes in Brazil: a cross-sectional analysis of three million individuals. **BMC Public Health**, v. 21, p. 1287, 2021.

HYNDMAN, Rob J.; KHANDAKAR, Yeasmin. Automatic Time Series Forecasting: The forecast Package for R. **Journal of Statistical Software**, v. 27, p. 1–22, 2008.

IBGE. IBGE-cidades. **Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística**. Rio de Janeiro: IBGE, 2024.

KAJDY, Anna *et al.* Risk factors for anxiety and depression among pregnant women during the COVID-19 pandemic: Results of a web-based multinational cross-

sectional study. **International Journal of Gynecology & Obstetrics**, v. 160, p. 167–186, 2023.

KIM, Youngho *et al.* Changes in the management of hypertension, diabetes mellitus, and hypercholesterolemia in Korean adults before and during the COVID-19 pandemic: data from the 2010–2020 Korea National Health and Nutrition Examination Survey. **Epidemiology and Health**, v. 45, p. e2023014, 2023.

KHUNTI, Kamlesh; VALABHJI, Jonathan; MISRA, Sanjay. Diabetes and the COVID-19 pandemic. **Diabetologia**, v. 66, p. 255–266, 2023.

KUMAR, Rajeev; SAINI, Sakshi; GANGULY, Nirmal Kumar. Year-round breast cancer awareness: Empowering young women in the fight against breast cancer. **Indian Journal of Medical Research**, v. 158, p. 347, 2023.

LJUNG, Greta M.; BOX, George E. P. On a measure of lack of fit in time series models. **Biometrika**, v. 65, n. 2, p. 297–303, 1978.

McARTHUR, Carolyn *et al.* Evaluating the Effect of COVID-19 Pandemic Lockdown on Long-Term Care Residents' Mental Health: A Data-Driven Approach in New Brunswick. **Journal of the American Medical Directors Association**, v. 22, p. 187–192, 2021.

MIRANDA, Gabriela Maria Duarte; MENDES, Andréa Dâmaso Cortes Gonçalves; SILVA, Ana Luiza Amaral da. Population aging in Brazil: current and future social challenges and consequences. **Revista Brasileira de Geriatria e Gerontologia**, v. 19, p. 507–519, 2016.

PALIARI, Isabella; KARANIKOLA, Angeliki; KOTSIANTIS, Sotiris. A comparison of the optimized LSTM, XGBOOST and ARIMA in Time Series forecasting. In: **2021 12th International Conference on Information, Intelligence, Systems & Applications (IISA)**. Chania Crete, Greece: IEEE, 2021. p. 1–7.

PRESIDENTE PRUDENTE. Secretaria Municipal de Saúde. **Relatório Anual de Gestão 2022**. Presidente Prudente: Prefeitura Municipal, 2023.

QIN, Dong *et al.* Colposcopic accuracy in diagnosing squamous intraepithelial lesions: a systematic review and meta-analysis of the International Federation of Cervical Pathology and Colposcopy 2011 terminology. **BMC Cancer**, v. 23, p. 187, 2023.

R CORE TEAM. R: A Language and Environment for Statistical Computing. Vienna: R Foundation for Statistical Computing, 2025

REX, Fernanda Elizabete; BORGES, Caio Augusto Dalla Santa; KÄFER, Patrícia Silva. Spatial analysis of the COVID-19 distribution pattern in São Paulo State, Brazil. **Ciência & Saúde Coletiva**, v. 25, p. 3377–3384, 2020.

ROOBOL, Monique J. Screening for prostate cancer: are organized screening programs necessary? **Translational Andrology and Urology**, v. 7, p. 4–11, 2018.

SANTOS, Ana Maria Ribeiro dos; CORRÊA, Francisco de Moraes. **Recomendações para detecção precoce de câncer durante a pandemia de covid-19 em 2021**. Rio de Janeiro: Instituto Nacional de Câncer, 2020

SCHAFFER, Andrea Louise; DOBBINS, Timothy Andrew; PEARSON, Sallie-Anne. Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. **BMC Medical Research Methodology**, v. 21, p. 58, 2021.

SHAH, Syed A. *et al.* Impact of COVID-19 national lockdown on asthma exacerbations: interrupted time-series analysis of English primary care data. **Thorax**, v. 76, p. 860–866, 2021.

SHAH, Syed A. *et al.* Impact of first UK COVID-19 lockdown on hospital admissions: Interrupted time series study of 32 million people. **eClinicalMedicine**, v. 49, p. 101462, 2022.

SUD, Amit *et al.* Collateral damage: the impact on outcomes from cancer surgery of the COVID-19 pandemic. **Annals of Oncology**, v. 31, p. 1065–1074, 2020.

TURECK, Fernanda *et al.* Innovations produced in Primary Health Care during the COVID-19 pandemic: an integrative literature review. **Ciência & Saúde Coletiva**, v. 29, p. e07022023, 2024.

VERAS, Renato Peixoto; OLIVEIRA, Mariana. Envelhecer no Brasil: a construção de um modelo de cuidado. **Ciência & Saúde Coletiva**, v. 23, p. 1929–1936, 2018.

VICENTE, Carlos Roberto. Is Brazil prepared for the new era of infectious disease epidemics? **Revista da Sociedade Brasileira de Medicina Tropical**, v. 53, p. e20200218, 2020.

WILLIAMS, Christine E.; BERKOWITZ, Deborah; RACKIN, Heather M. Exploring the experiences of pregnant women in the U.S. during the first year of the Covid-19 pandemic. **Journal of Social Issues**, v. 79, p. 617–645, 2023.

XU, Zhiwei *et al.* The Impact of COVID-19 on Primary Care General Practice Consultations in a Teaching Hospital in Shanghai, China. **Frontiers in Medicine**, v. 8, p. 642496, 2021.

5. ARTIGO CIENTÍFICO A SER ENVIADO PARA A REVISTA BRASILEIRA DE EPIDEMIOLOGIA, QUALIS A3 NO SISTEMA WEB-QUALIS

Normas de publicação disponíveis em: <https://abrasco.org.br/revistas-e-publicacoes/epidemiologia/epidemiologia-submissao-de-artigos/>

Uso de séries temporais e aprendizado de máquina para avaliar as internações por câncer rastreável na RRAS 11 durante a pandemia de COVID-19.

Use of time series and machine learning to assess hospitalizations for cancer screening in RRAS 11 during the COVID-19 pandemic

Marco Aurélio aparecido Lúcio¹

Rogério Giuffrida¹

Marcus Vinicius Pimenta Rodrigues¹

1- Programa de Pós-graduação e Meio ambiente e desenvolvimento regional, Universidade do Oeste Paulista, Presidente Prudente, SP

AUTOR CORRESPONDENTE: Rogério Giuffrida. Rod. Raposo Tavares, km 572, Campus II da Unoeste, CEP: 19.067-175, Presidente Prudente (SP), Brasil. E-mail: rgiuffrida@unoeste.br

CONFLITO DE INTERESSES: nada a declarar

Resumo

A pandemia de COVID-19 impactou profundamente os serviços de rastreio de câncer em todo o mundo, com graves consequências para a saúde da população. O presente estudo utilizou modelos temporais baseados em inteligência artificial para prever o comportamento das taxas de internamento de câncer uterino e de próstata nos períodos pandêmico e pós-pandêmico e compará-los com os dados reais observados no mesmo período. Dados mensais de internações hospitalares por neoplasias prostáticas, uterinos e cervicais na região de Presidente Prudente, entre 2014 e 2024, foram obtidos do SINAN e padronizados como taxas por 100.000 homens ou mulheres acima de 40 anos, utilizando dados populacionais do IBGE.

Séries temporais foram modeladas com *Prophet*, ARIMA-XGBoost e Redes Neurais Autorregressivas (NNAR), aplicando divisões pré e pós-pandemia. Os modelos foram treinados com 70% dos dados e testados com os 30% restantes, avaliando-se métricas de erros para comparação entre os modelos. O modelo Prophet apresentou os menores erros de previsão, seguido pelo ARIMA-XGBoost para câncer de útero e NNAR para câncer de próstata. As diferenças gráficas evidenciaram variações nos padrões de predição entre os modelos. Os modelos temporais sugerem que durante a pandemia, ocorreu uma queda nas taxas de internamento com um aumento compensatório no período pós-pandemia. Conclui-se que os modelos temporais baseados em inteligência artificial podem ser utilizados para prever o comportamento temporal das internações devido ao câncer de útero e próstata em diferentes cenários durante a pandemia de COVID-19.

Palavras-chaves: COVID-19; inteligência artificial; séries temporais; câncer de próstata; câncer cervical

Abstract

The COVID-19 pandemic has profoundly impacted cancer screening services worldwide, with serious consequences for the health of the population. The present study used temporal models based on artificial intelligence to predict the behavior of hospitalization rates for uterine and prostate cancer in the pandemic and post-pandemic periods and compare them with the actual data observed in the same period. Monthly data on hospitalizations for prostate, uterine and cervical neoplasms in the Presidente Prudente region, between 2014 and 2024, were obtained from SINAN and standardized as rates per 100,000 men or women over 40 years old, using population data from IBGE. Time series were modeled with Prophet, ARIMA-XGBoost and Autoregressive Neural Networks (NNAR), applying pre- and post-pandemic divisions. The models were trained with 70% of the data and tested with the remaining 30%, evaluating error metrics for comparison between the models. The Prophet model presented the lowest prediction errors, followed by ARIMA-XGBoost for uterine cancer and NNAR for prostate cancer. The graphical differences highlighted variations in the prediction patterns between the models. The temporal models suggest that during the pandemic, there was a decrease in hospitalization rates with a compensatory increase in the post-pandemic period. It is concluded that temporal models based on artificial intelligence can be used to predict the temporal

behavior of hospitalizations due to uterine and prostate cancer in different scenarios during the COVID-19 pandemic.

Keywords: COVID-19, artificial intelligence, time series, prostate cancer, cervical cancer

Introdução

Os programas de rastreamento do câncer são estratégias essenciais de saúde pública que possibilitam a detecção precoce de neoplasias malignas, melhorando, assim, os desfechos do tratamento, reduzindo a mortalidade específica por câncer e promovendo melhores resultados em termos de qualidade de vida (Kalager; Bretthauer, 2020). Esses programas envolvem a aplicação sistemática de testes diagnósticos em indivíduos assintomáticos dentro de uma população definida, com o objetivo de identificar o câncer em estágios iniciais e mais tratáveis. As modalidades mais amplamente implementadas incluem a mamografia para o câncer de mama, o exame de Papanicolau (Pap) para o câncer de colo do útero e o teste do antígeno prostático específico (PSA) para o câncer de próstata (Chou; Bing; Ding, 2024; Murillo *et al.*, 2008; Roobol, 2018). O sucesso desses programas depende da disponibilidade de tecnologias de rastreamento precisas e validadas, bem como da integração de políticas públicas abrangentes, educação populacional e uma infraestrutura de saúde robusta (Bergerot *et al.*, 2024). Apesar dos benefícios bem estabelecidos do rastreamento na redução do impacto do câncer, desafios significativos persistem, incluindo desigualdades no acesso aos serviços, baixa adesão entre as populações-alvo e possíveis consequências indesejadas do rastreamento excessivo, como resultados falso-positivos, estresse psicológico e sobrediagnóstico (Spear *et al.*, 2024).

As neoplasias mais frequentemente contempladas em programas organizados de rastreamento incluem próstata, mama e colo do útero, que são rotineiramente incorporados às políticas de saúde preventiva em diversos países (Carter *et al.*, 2015). Esses rastreamentos preventivos são particularmente importantes no contexto do envelhecimento populacional global, uma mudança demográfica que contribui para o aumento da incidência de câncer, atualmente reconhecido como uma das principais causas de morbidade e mortalidade em todo o mundo (Bray *et al.*, 2024).

A análise de séries temporais representa uma abordagem metodológica valiosa para monitorar e prever tendências na epidemiologia do câncer. Essa técnica envolve a análise de dados coletados em intervalos regulares, a fim de detectar padrões temporais, flutuações sazonais e tendências de longo prazo, o que pode subsidiar estratégias de prevenção e rastreamento mais direcionadas (Bouzon Nagem Assad *et al.*, 2024). Na pesquisa em epidemiologia do câncer, os modelos de séries temporais são ferramentas analíticas valiosas para prever a incidência de câncer, monitorar os resultados de intervenções de saúde pública e quantificar os efeitos de eventos externos — como pandemias — sobre a oferta e o acesso aos serviços de saúde (Li, 2022).

A modelagem preditiva de cânceres detectáveis por rastreamento — como mama, colo do útero, próstata e colorretal — frequentemente emprega estruturas estatísticas como o modelo de Médias Móveis Integradas Auto-Regressivas (ARIMA), que é adequado para capturar dependências lineares em dados temporais (Altuhaifa, 2023; Earnest *et al.*, 2019). Essas abordagens clássicas podem ser aprimoradas pela integração de técnicas de inteligência artificial (IA), incluindo algoritmos de aprendizado de máquina e aprendizado profundo, que oferecem maior capacidade para lidar com conjuntos de dados em larga escala, não lineares e multivariados (Chae *et al.*, 2024; Maipan-Uku; Cavus, 2024; Saito *et al.*, 2023).

Entre 2019 e 2023, a pandemia de COVID-19 emergiu como um fator disruptivo importante, reduzindo significativamente a adesão aos rastreamentos preventivos de câncer (Ballard *et al.*, 2022; Cancino *et al.*, 2020). A consequência esperada desse evento é o aumento no diagnóstico de câncer em estágios avançados nos anos subsequentes, com potenciais implicações negativas para o prognóstico dos pacientes e para a mortalidade geral por câncer (Burus *et al.*, 2024; Howlader *et al.*, 2024). Presidente Prudente, um polo estratégico para o desenvolvimento econômico e regional na região oeste do estado de São Paulo, Brasil, é um dos municípios que pode ter sido impactado por esse evento. O município desempenhou um papel importante como epicentro regional na disseminação do SARS-CoV-2 (Rex; Borges; Käfer, 2020). Na condição de epicentro regional para estratégias de saúde pública no âmbito da RRAS 11 (Rede Regional de Atenção à Saúde 11), Presidente Prudente pode ter experimentado um aumento expressivo nos casos rastreáveis de câncer nos anos pós-pandemia, particularmente para câncer de colo do útero e próstata. Este estudo tem como

objetivo avaliar o impacto da pandemia de COVID-19 nas taxas de internação hospitalar para esses dois tipos de câncer detectáveis por rastreamento na macrorregião de saúde de Presidente Prudente, com o objetivo de identificar possíveis mudanças epidemiológicas que possam orientar o planejamento futuro dos serviços de saúde.

2. Metodologia

2.1 Banco de dados

Dados relativos ao número de internações mensais (morbidade hospitalar do SUS) na rede regional de atenção a saúde 11 (Regional de Presidente Prudente) decorrentes de neoplasias benignas e malignas de próstata e neoplasias malignas de colo de útero e carcinomas *in situ* de colo de útero, registradas entre janeiro de 2014 e setembro de 2024, foram captados na base de dados pública do SINAN (Sistema de Informação de Agravos de Notificação) do Ministério da saúde do Brasil. Os dados foram padronizados como taxas mensais para representar o número de internações para cada 100.000 homens (câncer de próstata) e 100,000 mulheres (câncer de útero) com idade > 40 anos. Os dados populacionais utilizados para padronização foram captados no banco de dados do instituto brasileiro de Geografia e Estatística (IBGE, 2022).

2.3 Modelos de aprendizado de máquina para séries temporais

Para avaliar a evolução temporal das taxas de internamento para cada tipo de câncer, foram construídas séries temporais baseadas em aprendizado de máquina com três métodos diferentes: uso do algoritmo desenvolvido pelo Facebook (PROPHET), modelos autorregressivos de média móvel impulsionado por extreme gradiente boosting (XGBOOST) redes neurais autorregressivas (NNAR).

Antes de proceder as análises, os dados foram divididos em dois segmentos temporais: o primeiro correspondeu ao período pré-pandêmico (janeiro de 2014 a março de 2020) e outro ao período pandêmico + pós-pandêmico (abril de 2020 a setembro de 2024). Os dados do período pré-pandêmico foram utilizados para a construção dos modelos de séries temporais baseados nos métodos supracitados.

Inicialmente, o conjunto de dados foi dividido em uma amostra de treino representada por 70% e uma amostra de teste, correspondente à 30% dos dados. A

amostra de treino foi utilizada para construção dos modelos e a de teste para avaliar o poder preditivo dos algoritmos com dados não vistos pelo modelo gerado.

O modelo PROPHET é uma ferramenta de previsão desenvolvida pela plataforma Facebook, para tarefas comerciais, sendo posteriormente otimizado para outros propósitos (Papastefanopoulos; Linardatos; Kotsiantis, 2020). O modelo utilizado foi baseado em algoritmo de previsão de séries temporais de regressão aditiva, considerando a tendência, sazonalidade. O efeito sazonalidade foi modelado como uma série de Fourier para capturar efeitos periódicos (Saini; Abhinav; Parida, 2023). O algoritmo foi implementado com o pacote *modeltime* do Programa R (Dancho, 2024).

O segundo modelo foi construído com a fusão da técnica Extreme Gradient Boosting (XGBoost) e a ARIMA. O algoritmo XGBoost é uma técnica de aprendizado de máquina que melhora iterativamente o desempenho de modelos simples (fracos) para criar um modelo final forte, sendo amplamente utilizado em problemas de regressão e classificação (Chen; Guestrin, 2016). O *Boosting* começa com um modelo base (geralmente um modelo simples, como uma árvore de decisão rasa) que faz previsões iniciais nos dados. Sequencialmente, outros modelos são gerados, de forma que os novos tentam corrigir os erros dos anteriores, ajustando-se aos exemplos mal previstos. Os modelos individuais (fracos) são combinados em um modelo final. A função de perda é baseada no método de gradiente a partir de derivadas (Bentéjac; Csörgő; Martínez-Muñoz, 2019). Para o presente estudo, combinou-se o método linear da ARIMA com o método não lineares do XGBoost (Rahman; Chowdhury; Amrin, 2022) para gerar os parâmetros da ARIMA. O algoritmo foi implementado no pacote *modeltime* do Programa R (Dancho, 2024).

O terceiro modelo aplicou o princípio das redes neurais autorregressivas (NNAR), composto por três camadas: dados de entrada (valores passados da série), camadas ocultas (neurônios com funções de ativação para aprender padrões não lineares) e camada de saída (fornece a previsão da série temporal). A NNAR substitui a relação linear do AR da ARIMA tradicional por uma rede neural capaz de capturar dependências não lineares nos valores passados. O número de nós ocultos da rede de neurônios foi determinado automaticamente com base no número de *lags*. O algoritmo utilizado otimiza os pesos da rede neural para minimizar a diferença entre os valores previstos e os valores reais da série, utilizando a função `nnetar_reg()` do pacote *modeltime* (Dancho, 2024).

Para os três modelos foram calculadas métricas de desempenho baseada em resíduos (erros) de predição para a amostra de treino (Almalaq; Edwards, 2017). As métricas utilizadas foram:

- a.) MAE - Mean Absolute Error (Erro Médio Absoluto) que representa a média dos valores absolutos das diferenças entre as previsões do modelo;
- b.) MAPE - Mean Absolute Percentage Error (Erro Médio Absoluto Percentual), que mede o erro médio absoluto relativo, expresso como uma porcentagem;
- c.) MASE - Mean Absolute Scaled Error (Erro Absoluto Médio Escalonado), obtido após normalizar o MAE em relação ao erro médio de um modelo de referência, como a média dos erros absolutos;
- d.) SMAPE - Symmetric Mean Absolute Percentage Error (Erro Percentual Médio Absoluto Simétrico), uma modificação do MAPE para que seja simétrico em relação a previsões acima ou abaixo dos valores reais;
- e.) RMSE - Root Mean Squared Error (Raiz do Erro Médio Quadrático), resultado da raiz quadrada da média dos quadrados dos erros

2.5 Avaliação gráfica e diferença percentual nas áreas sobre a curva

Para verificar a discrepância entre as previsões dos modelos pré-pandêmicos e os valores reais observados nos períodos pandêmico e pos-pandêmicos, foram construídos gráficos de linhas para representar as duas series temporais. Nos gráficos temporais, foram inseridas linhas verticais para representar as datas dos decretos oficiais de início da quarentena pandemia e do término da emergência sanitária no Brasil (respectivamente 22 de março de 2020 e 22 de abril de 2022).

Resultados

Na tabela 1 estão sumarizadas as métricas de desempenho dos modelos propostos. De acordo com os resultados, os menores erros de previsão foram observados para o modelo PROPHET. Para o câncer de útero, o segundo melhor modelo foi a ARIMA XGBoost e para câncer de próstata, NNAR.

Nas figuras 1 e 2 são mostradas as séries temporais reais e previstas pelos modelos propostos, respectivamente para câncer de útero e próstata. Para o câncer de útero, os modelos apresentaram diferentes padrões de previsões. O modelo PROPHET apresentou tendência a proporcionar linhas de predição com valores mais baixos comparativamente aos demais. O modelo ARIMA XGBoost, por outro

lado, apresentou linhas de predição que aparentemente mais altas, enquanto o modelo NNAR apresentou um padrão intermediário.

Quando observados os gráficos de linhas temporais para o câncer de próstata, as diferenças entre modelos não ficam tão claras. Contudo, ao observar-se as janelas de tempo da pandemia, observa-se que registros de internamento ficaram abaixo do esperado no período pandêmico e acima do esperado no período pós-pandêmico.

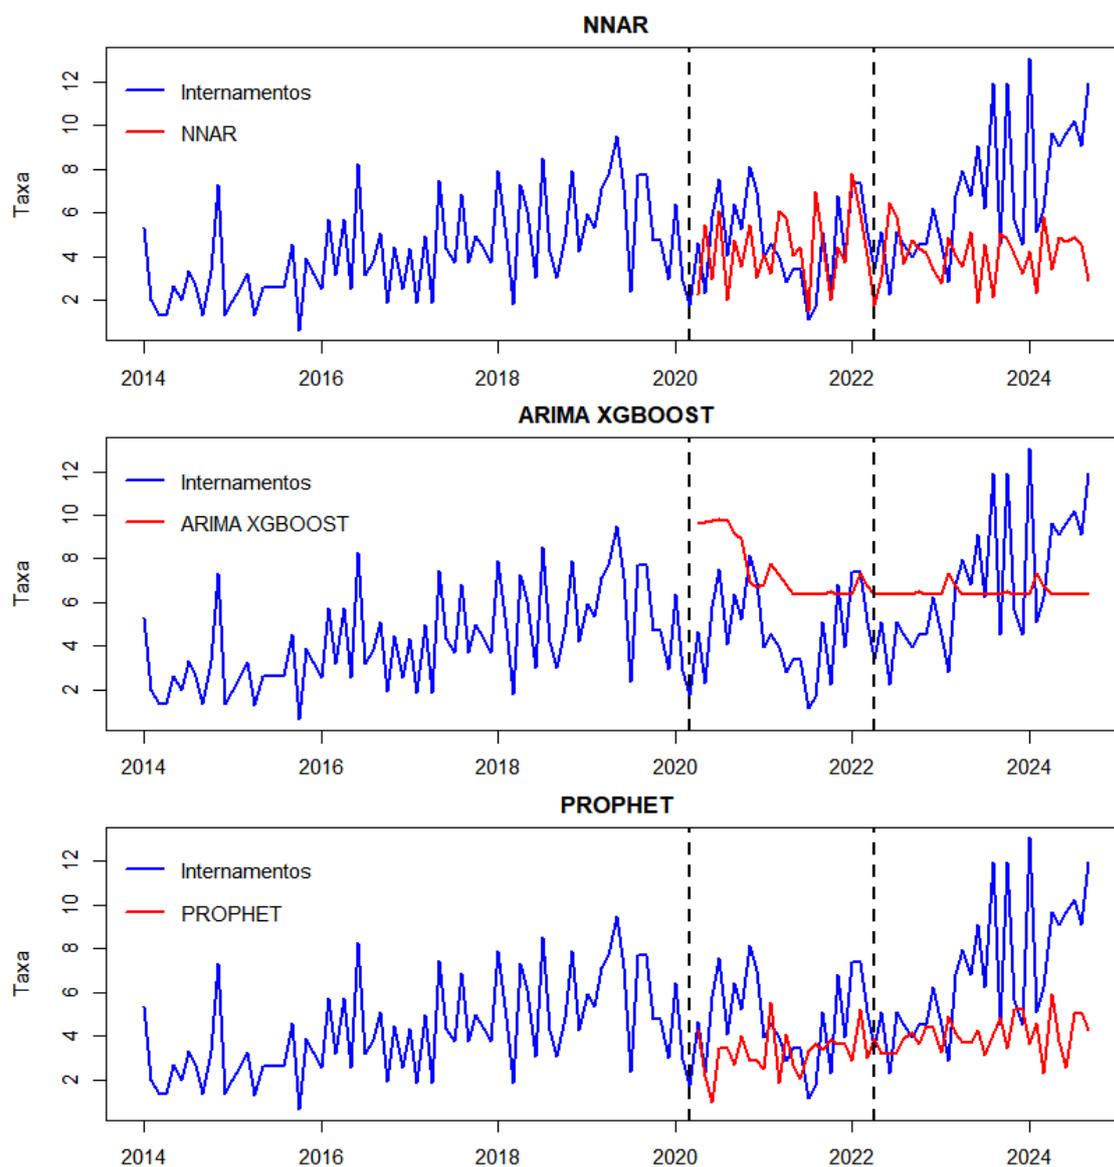
Tabela 1— Métricas utilizadas para avaliar o desempenho de modelos preditivos nas séries temporais para predição das taxas mensais de internamentos por neoplasias rastreáveis na RRAS-11

Neoplasia	Modelo	MAE	MAPE	MASE	SMAPE	RMSE
Útero	NNAR	3,20	53,78	1,19	57,73	4,18
	PROPHET	2,36	54,87	0,88	39,02	2,81
	ARIMAXGB	2,99	47,03	1,12	52,61	3,90
Próstata	NNAR	4,46	35,91	1,54	40,88	5,33
	PROPHET	3,77	33,08	1,31	34,03	4,50
	ARIMAXGB	5,64	43,12	1,95	56,37	6,55

MAE = Mean Absolute Error (Erro Médio Absoluto); MAPE - Mean Absolute Percentage Error (Erro Médio Absoluto Percentual); MASE - Mean Absolute Scaled Error (Erro Absoluto Médio Escalado); SMAPE = Symmetric Mean Absolute Percentage Error (Erro Percentual Médio Absoluto Simétrico); RMSE - Root Mean Squared Error (Raiz do Erro Médio Quadrático).

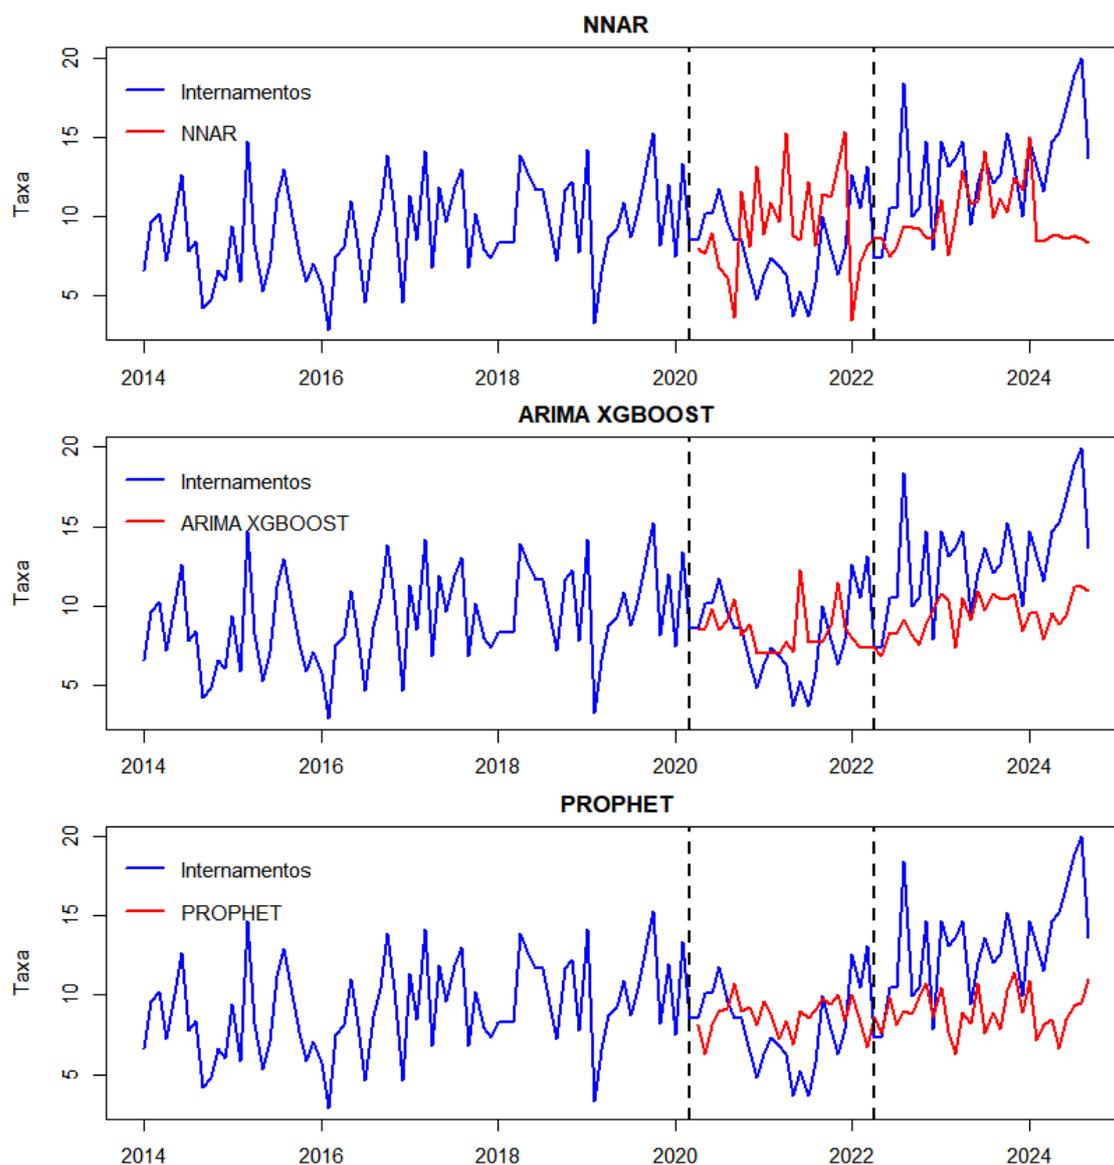
Fonte: Autoria própria

Figura 1— Séries temporais reais (azul) e preditas pelos modelos testados (vermelho) para taxas de internamentos mensais de câncer de útero para cada 100 mil mulheres com mais de 40 anos idade na RRAS 11. As linhas verticais pontilhadas na cor preta correspondem ao início e final da pandemia, de acordo com os decretos oficiais no Brasil.



Fonte: Autoria própria

Figura 2— Séries temporais reais (azul) e previstas pelos modelos testados (vermelho) para taxas de internamentos mensais de câncer de próstata para cada 100 mil homens com mais de 40 anos idade na RRAS 11. As linhas verticais pontilhadas correspondem ao início e final da pandemia, de acordo com os decretos oficiais no Brasil e as linhas pontilhadas em vermelho, pontos de mudança significativos nos modelos de partição segmentada.



Fonte: Autoria própria

Discussão

Utilizamos modelos treinados com algoritmos de inteligência artificial para prever as internações decorrentes de câncer de útero e próstata em Presidente Prudente-SP. Comparamos os dados previstos pelos modelos com os dados reais, visando observar se os dados reais ficaram abaixo ou acima do esperado para o

período. Nossos resultados indicam que a família de modelos de PROPHET, teve melhor ajuste (erros de previsão mais baixos) do que outros modelos. Algoritmos de IA, híbridos ou não, em geral exibem melhor desempenho de previsão na maioria dos modelos tradicionais, como a ARIMA, com algumas exceções (Kontopoulou *et al.*, 2023).

Ao contrário do que esperávamos, o algoritmo misto ARIMA XGBoost não superou os demais, apesar de ser considerado um dos mais poderosos modelos para aprendizado supervisionado (Bentéjac; Csörgő; Martínez-Muñoz, 2019; Chen; Guestrin, 2016). Um das razões para este resultado pode estar relacionado ao conjunto de dados relativamente pequeno para treinar o algoritmo, no caso 70% dos dados que corresponde à 90 observações (Rajput; Wang; Chen, 2023). Uma forma de melhorar a previsibilidade dos modelos é modular as informações para dados semanais, ao invés de mensais. Contudo, este procedimento é limitado pela base de dados do IBGE, que informa apenas a incidência mensal.

Os modelos baseados em NNAR também se mostraram adequados. Estes modelos são considerados superiores ao modelo tradicional baseado em ARIMA (Triebe; Laptev; Rajagopal, 2019). Deve-se ressaltar que outras técnicas de aprendizado de máquina para dados de séries temporais podem ser consideradas e usadas de maneira semelhante (Taskaya-Temizel; Casey, 2005).

Nos gráficos de linhas, fica claro que no período pandêmico, as internações devido à câncer de próstata e útero ficaram abaixo do esperado no período pandêmico. Para o câncer de próstata este resultado ficou mais evidente. A hipótese mais provável para este achado é que a queda no número de internações reflete a queda no número de rastreios efetivados no município. Os impactos futuros incluem diagnóstico tardio e incrementos no número de mortes evitáveis por câncer no município, o que reforça a necessidade de intervenções políticas urgentes para lidar com o acúmulo de serviços de diagnóstico de rotina e minimizar os efeitos nocivos da pandemia de COVID-19 em pacientes com câncer (Alkatout *et al.*, 2021). Incrementos nas taxas de internação, acima do esperado para o período pós-pandêmico observados em nossos dados corroboram com este fenômeno.

Nos EUA, uma avaliação em um banco de dados sobre faturamento para procedimentos comuns de câncer de março a julho de 2020 detectou declínios significativos para os exames de mama, cólon, pulmão e próstata que reduziram-se em 85%, 75%, 56% e 74%, respectivamente,, corroborando com nossos

achados(Mitchell, 2020). Em alguns países o adiamento dos exames foi mais comum para pessoas que residem em comunidades pobres (Miller *et al.*, 2021).

No Brasil em 2020, durante o período pandêmico, os testes de citopatologia reduziram em 44,6%, mamografias em 42,6%, biópsias em 35,3%, cirurgias de câncer em 15,7% e procedimentos de radioterapia em, 0,7%, quando comparados à 2019 (Ribeiro; Correa; Migowski, 2022). Estes resultados reforçam nossos achados e alertam para uma eventual crise de saúde pública relacionada a um aumento expressivo nos casos de câncer previstos para os próximos anos.

Observamos que a recuperação nas taxas de internamento iniciou-se antes do final do período pandêmico, possivelmente como reflexo da disseminação de informações sobre estratégias preventivas e de proteção individual, que se tornaram acessíveis as instituições de saúde (Mitchell, 2020). Os incrementos nas taxas de internação continuaram a recuperar-se no período pós-pandêmico e superaram os valores previstos pelos modelos, o que sugere que os sistemas de rastreio de câncer voltaram a detectar os casos em uma taxa superior ao período pré-pandêmico. Este incremento pode ser reflexo de um maior número de pacientes com quadros graves destas enfermidades, que foram diagnosticadas tardiamente. Este fenômeno foi observado em outros estudos conduzidos no país, corroborando com nossos achados (Bonadio *et al.*, 2021; Tachibana *et al.*, 2021).

No Brasil, as restrições relativas à quarentena reduziram o impacto da doença nas comunidades afetadas (Silva; Figueiredo Filho; Fernandes, 2020). Contudo, mesmo após o fim do período pandêmico, as consequências futuras ainda são sentidas, principalmente sobre a população mais vulnerável atendida pelos sistemas públicos, visto que foram as principais vítimas da enfermidade e das suas consequências econômicas (Akintunde *et al.*, 2021; Fedewa *et al.*, 2022).

Conclusão

Os modelos temporais baseados em inteligência artificial podem ser utilizados para prever o comportamento temporal das internações devido ao câncer de útero e próstata em diferentes cenários durante a pandemia de COVID-19. Os modelos sugerem que durante a pandemia, ocorreu uma queda nas taxas de internamento com um aumento compensatório no período pós-pandemia.

Agradecimentos

O Presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior -Brasil (CAPES) -Código de financiamento 001.

REFERÊNCIAS

AKINTUNDE, Tosin Yinka *et al.* Expanding telemedicine to reduce the burden on the healthcare systems and poverty in Africa for a post-coronavirus disease 2019 (COVID-19) pandemic reformation. **Global Health Journal**, [s. l.], v. 5, n. 3, p. 128–134, 2021.

ALKATOUT, Ibrahim *et al.* Has COVID-19 Affected Cancer Screening Programs? A Systematic Review. **Frontiers in Oncology**, [s. l.], v. 11, p. 675038, 2021.

ALMALAQ, Abdulaziz; EDWARDS, George. A Review of Deep Learning Methods Applied on Load Forecasting. *In: 2017 16TH IEEE INTERNATIONAL CONFERENCE ON MACHINE LEARNING AND APPLICATIONS (ICMLA), 2017, Cancun, Mexico. 2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)*. Cancun, Mexico: IEEE, 2017. p. 511–516. Disponível em: <http://ieeexplore.ieee.org/document/8260682/>. Acesso em: 8 dez. 2024.

ALTUHAIFA, Fatimah. Time Series Prediction of Lung Cancer Death Rates on the Basis of SEER Data. **JCO Clinical Cancer Informatics**, [s. l.], n. 7, p. e2300011, 2023.

BALLARD, Madeleine *et al.* Continuity of community-based healthcare provision during COVID-19: a multicountry interrupted time series analysis. **BMJ Open**, [s. l.], v. 12, n. 5, p. e052407, 2022.

BENTÉJAC, Candice; CSÖRGŐ, Anna; MARTÍNEZ-MUÑOZ, Gonzalo. A Comparative Analysis of XGBoost. [s. l.], 2019. Disponível em: <https://arxiv.org/abs/1911.01914>. Acesso em: 8 dez. 2024.

BERGEROT, Cristiane *et al.* Global unmet psychosocial needs in cancer care: health policy. **eClinicalMedicine**, [s. l.], v. 78, p. 102942, 2024.

BONADIO, Renata Colombo *et al.* Impact of the COVID-19 pandemic on breast and cervical cancer stage at diagnosis in Brazil. **Ecancermedicalsecience**, [s. l.], v. 15, p. 1299, 2021.

BOUZON NAGEM ASSAD, Daniel *et al.* Comparing the current short-term cancer incidence prediction models in Brazil with state-of-the-art time-series models. **Scientific Reports**, [s. l.], v. 14, n. 1, p. 4566, 2024.

BRAY, Freddie *et al.* Global cancer statistics 2022: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. **CA: A Cancer Journal for Clinicians**, [s. l.], v. 74, n. 3, p. 229–263, 2024.

BURUS, Todd *et al.* Undiagnosed Cancer Cases in the US During the First 10 Months of the COVID-19 Pandemic. **JAMA Oncology**, [s. l.], v. 10, n. 4, p. 500, 2024.

CANCINO, Ramon S *et al.* The Impact of COVID-19 on Cancer Screening: Challenges and Opportunities. **JMIR Cancer**, [s. l.], v. 6, n. 2, p. e21697, 2020.

CARTER, Stacy M. *et al.* Screening for Cervical, Prostate, and Breast Cancer. **American Journal of Preventive Medicine**, [s. l.], v. 49, n. 2, p. 274–285, 2015.

CHAE, Sena *et al.* Prediction of Cancer Symptom Trajectory Using Longitudinal Electronic Health Record Data and Long Short-Term Memory Neural Network. **JCO Clinical Cancer Informatics**, [s. l.], n. 8, p. e2300039, 2024.

CHEN, Tianqi; GUESTRIN, Carlos. XGBoost: A Scalable Tree Boosting System. *In*: KDD '16: THE 22ND ACM SIGKDD INTERNATIONAL CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING, 2016, San Francisco California USA. **Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining**. San Francisco California USA: ACM, 2016. p. 785–794. Disponível em: <https://dl.acm.org/doi/10.1145/2939672.2939785>. Acesso em: 27 ago. 2024.

CHOU, An-Ju; BING, Ruo-Shi; DING, Dah-Ching. Endometrial Atypical Hyperplasia and Risk of Endometrial Cancer. **Diagnostics**, [s. l.], v. 14, n. 22, p. 2471, 2024.

DANCHO, M. **Modeltime: The Tidymodels Extension for Time Series Modeling**. [S. l.], 2024. Disponível em: <https://github.com/business-science/modeltime>. Acesso em: 8 nov. 2024.

EARNEST, Arul *et al.* Forecasting annual incidence and mortality rate for prostate cancer in Australia until 2022 using autoregressive integrated moving average (ARIMA) models. **BMJ Open**, [s. l.], v. 9, n. 8, p. e031331, 2019.

FEDEWA, Stacey A. *et al.* Unemployment and cancer screening: Baseline estimates to inform health care delivery in the context of COVID-19 economic distress. **Cancer**, [s. l.], v. 128, n. 4, p. 737–745, 2022.

HOWLADER, Nadia *et al.* Impact of COVID-19 on 2021 cancer incidence rates and potential rebound from 2020 decline. **JNCI: Journal of the National Cancer Institute**, [s. l.], p. djae180, 2024.

IBGE. **Censo 2022**. [S. l.], 2022. Disponível em: <https://censo2022.ibge.gov.br/panorama/>. Acesso em: 1 fev. 2024.

KALAGER, Mette; BRETTHAUER, Michael. Improving cancer screening programs. **Science**, [s. l.], v. 367, n. 6474, p. 143–144, 2020.

KONTOPOULOU, Vaia I. *et al.* A Review of ARIMA vs. Machine Learning Approaches for Time Series Forecasting in Data Driven Networks. **Future Internet**, [s. l.], v. 15, n. 8, p. 255, 2023.

LI, Qiao. Mechanisms for the Invasion and Dissemination of Salmonella. **Canadian Journal of Infectious Diseases and Medical Microbiology**, [s. l.], v. 2022, p. 1–12, 2022.

LI, Jinhui *et al.* Time series models show comparable projection performance with joinpoint regression: A comparison using historical cancer data from World Health Organization. **Frontiers in Public Health**, [s. l.], v. 10, p. 1003162, 2022.

MAIPAN-UKU, Jamilu Yahaya; CAVUS, Nadire. Forecasting tuberculosis incidence: a review of time series and machine learning models for prediction and eradication strategies. **International Journal of Environmental Health Research**, [s. l.], p. 1–16, 2024.

MILLER, Matthew M. *et al.* Impact of the COVID-19 pandemic on breast cancer screening volumes and patient screening behaviors. **Breast Cancer Research and Treatment**, [s. l.], v. 189, n. 1, p. 237–246, 2021.

MITCHELL, Edith P. Declines in Cancer Screening During COVID-19 Pandemic. **Journal of the National Medical Association**, [s. l.], v. 112, n. 6, p. 563–564, 2020.

MURILLO, Raul *et al.* Cervical Cancer Screening Programs in Latin America and the Caribbean. **Vaccine**, [s. l.], v. 26, p. L37–L48, 2008.

PAPASTEFANOPOULOS, Vasilis; LINARDATOS, Pantelis; KOTSIANTIS, Sotiris. COVID-19: A Comparison of Time Series Methods to Forecast Percentage of Active Cases per Population. **Applied Sciences**, [s. l.], v. 10, n. 11, p. 3880, 2020.

RAHMAN, Md. Siddikur; CHOWDHURY, Arman Hossain; AMRIN, Miftahuzzannat. Accuracy comparison of ARIMA and XGBoost forecasting models in predicting the incidence of COVID-19 in Bangladesh. **PLOS Global Public Health**, [s. l.], v. 2, n. 5, p. e0000495, 2022.

RAJPUT, Daniyal; WANG, Wei-Jen; CHEN, Chun-Chuan. Evaluation of a decided sample size in machine learning applications. **BMC Bioinformatics**, [s. l.], v. 24, n. 1, p. 48, 2023.

REX, Franciel Eduardo; BORGES, Cléber Augusto De Souza; KÄFER, Pâmela Suélen. Spatial analysis of the COVID-19 distribution pattern in São Paulo State, Brazil. **Ciência & Saúde Coletiva**, [s. l.], v. 25, n. 9, p. 3377–3384, 2020.

RIBEIRO, Caroline Madalena; CORREA, Flávia De Miranda; MIGOWSKI, Arn. Efeitos de curto prazo da pandemia de COVID-19 na realização de procedimentos de rastreamento, investigação diagnóstica e tratamento do câncer no Brasil: estudo descritivo, 2019-2020. **Epidemiologia e Serviços de Saúde**, [s. l.], v. 31, n. 1, p. e2021405, 2022.

ROOBOL, Monique J. Screening for prostate cancer: are organized screening programs necessary?. **Translational Andrology and Urology**, [s. l.], v. 7, n. 1, p. 4–11, 2018.

SAINI, Priyesh; ABHINAV, Kumar; PARIDA, S. K. Improved Facebook Prophet Model Using Singular Spectrum Analysis for Short-Term Load Forecasting. *In: 2023 IEEE INTERNATIONAL CONFERENCE ON ENERGY TECHNOLOGIES FOR FUTURE GRIDS (ETFG)*, 2023, Wollongong, Australia. **2023 IEEE International Conference on Energy Technologies for Future Grids (ETFG)**. Wollongong, Australia: IEEE, 2023. p. 1–6. Disponível em: <https://ieeexplore.ieee.org/document/10408507/>. Acesso em: 8 dez. 2024.

SAITO, Shinpei *et al.* Machine-learning predicts time-series prognosis factors in metastatic prostate cancer patients treated with androgen deprivation therapy. **Scientific Reports**, [s. l.], v. 13, n. 1, p. 6325, 2023.

SILVA, Lucas; FIGUEIREDO FILHO, Dalson; FERNANDES, Antônio. The effect of lockdown on the COVID-19 epidemic in Brazil: evidence from an interrupted time series design. **Cadernos de Saúde Pública**, [s. l.], v. 36, n. 10, p. e00213920, 2020.

SPEAR, Georgia *et al.* Updates in Breast Cancer Screening and Diagnosis. **Current Treatment Options in Oncology**, [s. l.], v. 25, n. 11, p. 1451–1460, 2024.

TACHIBANA, Bruna Mayumi Takaki *et al.* The delay of breast cancer diagnosis during the COVID-19 pandemic in São Paulo, Brazil. **Einstein (São Paulo)**, [s. l.], v. 19, p. eAO6721, 2021.

TASKAYA-TEMIZEL, Tugba; CASEY, Matthew C. A comparative study of autoregressive neural network hybrids. **Neural Networks**, [s. l.], v. 18, n. 5–6, p. 781–789, 2005.

TRIEBE, Oskar; LAPTEV, Nikolay; RAJAGOPAL, Ram. **AR-Net: A simple Auto-Regressive Neural Network for time-series**. [S. l.]: arXiv, 2019. Disponível em: <https://arxiv.org/abs/1911.12436>. Acesso em: 9 dez. 2024.

6. CONSIDERAÇÕES FINAIS

É evidente que a pandemia de COVID-19 teve um impacto profundo e multifacetado na Atenção Básica à Saúde em Presidente Prudente - SP. A análise dos dados revelou uma redução significativa nos atendimentos e procedimentos de saúde em 2020, reflexo das medidas de distanciamento social e das prioridades emergenciais voltadas para o combate à COVID-19. Essa diminuição afetou especialmente os serviços preventivos e de acompanhamento, essenciais para o manejo de condições crônicas e o diagnóstico precoce de cânceres.

A presente pesquisa atende às seguintes ODS:

- a.) **ODS 3 - Saúde e Bem-Estar:** este trabalho atendeu a esta ODS ao fornecer indicadores que podem auxiliar os gestores na busca por soluções para garantir o acesso equitativo a serviços de saúde de qualidade e fortalecer os sistemas de saúde;
- b.) **ODS 9 - Indústria, Inovação e Infraestrutura:** este trabalho atendeu a esta ODS ao utilizar ferramentas de inteligência artificial para predição de dados com séries temporais que podem ser utilizadas para fortalecimento da infraestrutura de vigilância em saúde para melhorar a resposta a crises está alinhada com o objetivo de construir infraestrutura resiliente e promover a inovação;
- e.) **ODS 10 - Redução das Desigualdades:** este trabalho atendeu à esta ODS ao chamar a atenção para fragilidades do sistema de atenção básica que normalmente atende à usuários de baixa renda e que vivem em áreas com vulnerabilidade social;
- f.) **ODS 17 - Parcerias e Meios de Implementação:** este trabalho atendeu à esta ODS ao focar na parceria com a Secretaria Municipal de Saúde, visto que o autor da tese está envolvido na gestão da saúde no município de Presidente Prudente, o que fortalece ações conjuntas para enfrentar desafios de saúde pública.

É imperativo que lições sejam aprendidas com esses desafios para fortalecer a preparação e a resposta futuras a crises de saúde pública. Investimentos contínuos em tecnologia e infraestrutura de saúde, juntamente com campanhas educativas e preventivas, são fundamentais para mitigar os impactos de futuras emergências. A manutenção da acessibilidade e da qualidade dos serviços de saúde

primária é essencial para garantir o bem-estar contínuo da população, especialmente em tempos de adversidade global, como os vivenciados durante a pandemia de COVID-19.

REFERÊNCIAS

AMINIKHANGHAHI, Samaneh; COOK, Diane J. A survey of methods for time series change point detection. **Knowledge and Information Systems**, v. 51, n. 2, p. 339–367, maio 2017.

ARANTES, Luciano José; SHIMIZU, Helena Eri; MERCHÁN-HAMANN, Edgar. Contribuições e desafios da Estratégia Saúde da Família na Atenção Primária à Saúde no Brasil: revisão da literatura. **Ciência & Saúde Coletiva**, v. 21, n. 5, p. 1499–1510, maio 2016.

AUNG, Myo Nyein; KOYANAGI, Yuka; YUASA, Motoyuki. Health inequality among different economies during early phase of COVID-19 pandemic. **Journal of the Egyptian Public Health Association**, v. 96, n. 1, p. 3, 17 fev. 2021.

BAI, Yuting *et al.* State of art on state estimation: Kalman filter driven by machine learning. **Annual Reviews in Control**, v. 56, p. 100909, 2023.

BALLARD, Madeleine *et al.* Continuity of community-based healthcare provision during COVID-19: a multicountry interrupted time series analysis. **BMJ Open**, v. 12, n. 5, p. e052407, maio 2022.

BARBOSA, Ana Karina P.; DE A NOVAES, Magdala; DE VASCONCELOS, Alexandre M. L. A web application to support telemedicine services in Brazil. *In*: ANNUAL SYMPOSIUM PROCEEDINGS. 2003. **Anais** [...]. AMIA Symposium, 2003. p. 56–60.

BARRETO, Liliádia Da Silva Oliveira; GUIMARÃES CAMPOS, Vanessa D.; DAL POZ, Mario Roberto. Interprofessional education in healthcare and health workforce (HRH) planning in Brazil: experiences and good practices. **Journal of Interprofessional Care**, v. 33, n. 4, p. 369–381, 4 jul. 2019.

BEARD, Emma *et al.* Understanding and using time series analyses in addiction research. **Addiction**, v. 114, n. 10, p. 1866–1884, out. 2019.

BENZER, Justin K. *et al.* How personal and standardized coordination impact implementation of integrated care. **BMC Health Services Research**, v. 15, n. 1, p. 448, jun. 2015.

BHASKARAN, Krishnan *et al.* Time series regression studies in environmental epidemiology. **International journal of epidemiology**, v. 42, n. 4, p. 1187–95, ago. 2013.

BIGONI, Alessandro *et al.* Brazil's health system functionality amidst of the COVID-19 pandemic: An analysis of resilience. **The Lancet Regional Health - Americas**, v. 10, p. 100222, jun. 2022.

BOAVENTURA, Viviane S. *et al.* Syndromic Surveillance Using Structured Telehealth Data: Case Study of the First Wave of COVID-19 in Brazil. **JMIR Public Health and Surveillance**, v. 9, p. e40036, 24 jan. 2023.

BOX, George E. P.; JENKINS, Gwilym M.; REINSEL, Gregory C. **Time Series Analysis**. 1. ed. [S.l.]: Wiley, 2008.

BRADLEY, Elizabeth H.; CURRY, Leslie A.; DEVERS, Kelly J. Qualitative Data Analysis for Health Services Research: Developing Taxonomy, Themes, and Theory. **Health Services Research**, v. 42, n. 4, p. 1758–1772, ago. 2007.

BROOKMEYER, Ron; STROUP, Donna F. **Monitoring the Health of Populations**. [S.l.]: Oxford University Press, 2003.

CAINI, Saverio *et al.* Characteristics of seasonal influenza A and B in Latin America: Influenza surveillance data from ten countries. **PLOS ONE**, v. 12, n. 3, p. e0174592, 27 mar. 2017.

CANCINO, Ramon S. *et al.* The Impact of COVID-19 on Cancer Screening: Challenges and Opportunities. **JMIR Cancer**, v. 6, n. 2, p. e21697, 29 out. 2020.

CARDINAL, Mitsi; ROY, Roch; LAMBERT, Jean. On the application of integer-valued time series models for the analysis of disease incidence. **Statistics in Medicine**, v. 18, n. 15, p. 2025–2039, 15 ago. 1999.

CARVALHO, Luiz Paulo *et al.* Social Network Analysis, Ethics and LGPD, considerations in research. **iSys - Brazilian Journal of Information Systems**, v. 14, n. 2, p. 28–52, 20 ago. 2021.

CELUPPI, Ianka Cristina *et al.* Uma análise sobre o desenvolvimento de tecnologias digitais em saúde para o enfrentamento da COVID-19 no Brasil e no mundo. **Cadernos de Saúde Pública**, v. 37, n. 3, p. e00243220, 2021.

CÉSARE, Náthaly *et al.* Longitudinal profiling of the vaccination coverage in Brazil reveals a recent change in the patterns hallmarked by differential reduction across regions. **International Journal of Infectious Diseases**, v. 98, p. 275–280, set. 2020.

CHATFIELD, Christopher. **The analysis of time series: an introduction**. 6. ed. Boca Raton, Fla.: Chapman & Hall/CRC, 2004.

CHRETIEN, Jean-Paul *et al.* Real-Time Public Health Surveillance for Emergency Preparedness. **American Journal of Public Health**, v. 99, n. 8, p. 1360–1363, ago. 2009.

COUGHLIN, Steven S. *et al.* Early detection of change patterns in COVID-19 incidence and the implementation of public health policies: A multi-national study. **Public Health in Practice**, v. 2, p. 100064, nov. 2021.

DE LA PORTILLA DE JUAN, Fernando; REYES DÍAZ, María Luisa; RAMALLO SOLÍA, Irene. Impact of the pandemic on surgical activity in colorectal cancer in Spain. Results of a national survey. **Cirugía Española (English Edition)**, v. 99, n. 7, p. 500–505, ago. 2021.

DE LIMA, João Pedro Pereira; BORGES GUIMARÃES, Raul. Análise Espacial da COVID-19 em Presidente Prudente e Botucatu - São Paulo. **Estrabão**, v. 3, p. 130–141, 1 jan. 2022.

DEHNING, Jonas *et al.* Inferring change points in the spread of COVID-19 reveals the effectiveness of interventions. **Science**, v. 369, n. 6500, p. eabb9789, 10 jul. 2020.

DEL VECCHIO BLANCO, Giovanna *et al.* The impact of COVID-19 pandemic in the colorectal cancer prevention. **International Journal of Colorectal Disease**, v. 35, n. 10, p. 1951–1954, out. 2020.

DINGS, Christiane *et al.* Effect of vaccinations and school restrictions on the spread of COVID-19 in different age groups in Germany. **Infectious Disease Modelling**, v. 9, n. 4, p. 1250–1264, dez. 2024.

DORCAS WAMBUI, Gachomo. The Power of the Pruned Exact Linear Time(PELT) Test in Multiple Change-point Detection. **American Journal of Theoretical and Applied Statistics**, v. 4, n. 6, p. 581, 2015.

DORWARD, Jienchi *et al.* The impact of the COVID-19 lockdown on HIV care in 65 South African primary care clinics: an interrupted time series analysis. **The Lancet HIV**, v. 8, n. 3, p. e158–e165, mar. 2021.

EWUSIE, Joycelyne E. *et al.* Methods, Applications and Challenges in the Analysis of Interrupted Time Series Data: A Scoping Review. **Journal of Multidisciplinary Healthcare**, v. 13, p. 411–423, maio 2020.

FARIA, Nuno Rodrigues *et al.* Mobile real-time surveillance of Zika virus in Brazil. **Genome Medicine**, v. 8, n. 1, p. 97, dez. 2016.

GARRITTY, Chantelle *et al.* Rapid Reviews Methods Series: Involving patient and public partners, healthcare providers and policymakers as knowledge users. **BMJ Evidence-Based Medicine**, p. bmjebm-2022-112070, 19 abr. 2023.

HAILEAMLAK, Abraham. The impact of COVID-19 on health and health systems. **Ethiopian Journal of Health Sciences**, v. 31, n. 6, p. 1073–1074, nov. 2021.

HAJIRAHIMI, Zahra; KHASHEI, Mehdi. Hybrid structures in time series modeling and forecasting: A review. **Engineering Applications of Artificial Intelligence**, v. 86, p. 83–106, nov. 2019.

HARICHARAN, Hanne Jensen; STUTTAFORD, Maria; LONDON, Leslie. The role of community participation in primary health care: practices of South African health committees. **Primary Health Care Research & Development**, v. 22, p. e31, 2021.

HEESTERBEEK, H. *et al.* Modeling infectious disease dynamics in the complex landscape of global health. **Science**, v. 347, n. 6227, p. aaa4339–aaa4339, 12 mar. 2015.

HEUMANN, Marcus; RÖHNSCH, Gundula; HÄMEL, Kerstin. Primary healthcare nurses' involvement in patient and community participation in the context of chronic diseases: An integrative review. **Journal of Advanced Nursing**, v. 78, n. 1, p. 26–47, jan. 2022.

HILAS, Constantinos S.; REKANOS, Ioannis T.; MASTOROCOSTAS, Paris Ast. Change Point Detection in Time Series Using Higher-Order Statistics: A Heuristic Approach. **Mathematical Problems in Engineering**, v. 2013, p. 1–10, 2013.

HONE, Thomas *et al.* Racial and socioeconomic disparities in multimorbidity and associated healthcare utilisation and outcomes in Brazil: a cross-sectional analysis of three million individuals. **BMC Public Health**, v. 21, n. 1, p. 1287, dez. 2021.

HOUWELING, Tanja A. J. *et al.* Socioeconomic Inequalities in Neglected Tropical Diseases: A Systematic Review. **PLOS Neglected Tropical Diseases**, v. 10, n. 5, p. e0004546, 12 maio 2016.

IBGE. IBGE-cidades. **Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística**. Rio de Janeiro: IBGE, 2024.

ISLAM, Q. M. Innovation in Primary Healthcare in the Twenty-first Century. **Journal of Health Management**, v. 23, n. 1, p. 129–142, mar. 2021.

JEGEDE, Segun Light; SZAJOWSKI, Krzysztof J. Change-Point Detection in Homogeneous Segments of COVID-19 Daily Infection. **Axioms**, v. 11, n. 5, p. 213, 4 maio 2022.

KASHIWAKURA, Helder Kiyoshi *et al.* Retrato da atenção básica no Brasil: gastos e infraestrutura em municípios brasileiros. **Ciência & Saúde Coletiva**, v. 26, n. suppl 2, p. 3397–3408, 2021.

KAUR, Jatinder; PARMAR, Kulwinder Singh; SINGH, Sarbjit. Autoregressive models in environmental forecasting time series: a theoretical and application review. **Environmental Science and Pollution Research**, v. 30, n. 8, p. 19617–19641, 17 jan. 2023.

KOH, David. COVID-19 lockdowns throughout the world. **Occupational Medicine**, v. 70, n. 5, p. 322, 17 jul. 2020.

KONTOPANTELIS, E. *et al.* Regression based quasi-experimental approach when randomisation is not an option: interrupted time series analysis. **BMJ**, v. 350, n. jun09 5, p. h2750–h2750, 9 jun. 2015.

LEAL, Maria Do Carmo *et al.* Redução das iniquidades sociais no acesso às tecnologias apropriadas ao parto na Rede Cegonha. **Ciência & Saúde Coletiva**, v. 26, n. 3, p. 823–835, mar. 2021.

LEAL-NETO, Onicio B. *et al.* Digital disease detection and participatory surveillance: overview and perspectives for Brazil. **Revista de Saúde Pública**, v. 50, n. 0, 2016.

LEMOS MACEDO, Jéssica Caline *et al.* Community-Based Interventions to Improve the Control of Non-Communicable Diseases in Underserved Rural Areas in Brazil: A Before-and-After Study. **Frontiers in Pharmacology**, v. 12, p. 644599, 14 abr. 2021.

LIM, Bryan; ZOHREN, Stefan. Time-series forecasting with deep learning: a survey. **Philosophical Transactions of the Royal Society A: Mathematical, Physical and Engineering Sciences**, v. 379, n. 2194, p. 20200209, 5 abr. 2021.

LIMA, Marcos Venícius Malveira De; LAPORTA, Gabriel Zorello. Evaluation of the Models for Forecasting Dengue in Brazil from 2000 to 2017: An Ecological Time-Series Study. **Insects**, v. 11, n. 11, p. 794, 12 nov. 2020.

LOPEZ BERNAL, James; CUMMINS, Steven; GASPARRINI, Antonio. The use of controls in interrupted time series studies of public health interventions. **International Journal of Epidemiology**, v. 47, n. 6, p. 2082–2093, 1 dez. 2018.

LOWE, Rachel *et al.* Dengue outlook for the World Cup in Brazil: an early warning model framework driven by real-time seasonal climate forecasts. **The Lancet Infectious Diseases**, v. 14, n. 7, p. 619–626, jul. 2014.

MAAS, Iris L. *et al.* The regression discontinuity design showed to be a valid alternative to a randomized controlled trial for estimating treatment effects. **Journal of Clinical Epidemiology**, v. 82, p. 94–102, fev. 2017.

MACHADO, Juliana Pires; MARTINS, Mônica; LEITE, Iuri Da Costa. Qualidade das bases de dados hospitalares no Brasil: alguns elementos. **Revista Brasileira de Epidemiologia**, v. 19, n. 3, p. 567–581, set. 2016.

MACINKO, James; HARRIS, Matthew J.; ROCHA, Marcia Gomes. Brazil's National Program for Improving Primary Care Access and Quality (PMAQ): Fulfilling the

Potential of the World's Largest Payment for Performance System in Primary Care. **Journal of Ambulatory Care Management**, v. 40, p. S4–S11, abr. 2017.

MADIA LOURENÇO, Luiza Helena *et al.* Engaging local health research communities to enhance long-term capacity building in Brazil. **BMJ Global Health**, v. 6, n. 10, p. e007131, out. 2021.

MALIK, Yashpal Singh *et al.* Coronavirus Disease Pandemic (COVID-19): Challenges and a Global Perspective. **Pathogens**, v. 9, n. 7, p. 519, jul. 2020.

MIENYE, Ibomoiye Domor; SWART, Theo G.; OBAIDO, George. Recurrent Neural Networks: A Comprehensive Review of Architectures, Variants, and Applications. **Information**, v. 15, n. 9, p. 517, 25 ago. 2024.

NASCIMENTO, C. M. *et al.* Multifractality and heteroscedastic dynamics: An application to time series analysis. **EPL (Europhysics Letters)**, v. 81, n. 1, p. 18002, jan. 2008.

NAYAK, G. H. Harish *et al.* Transformer-based deep learning architecture for time series forecasting. **Software Impacts**, v. 22, p. 100716, nov. 2024.

OLAWADE, David B. *et al.* Artificial intelligence in environmental monitoring: Advancements, challenges, and future directions. **Hygiene and Environmental Health Advances**, v. 12, p. 100114, dez. 2024.

PAZ, Leidijany Costa *et al.* Análise da sazonalidade da tuberculose nas capitais brasileiras e Distrito Federal, Brasil, no período de 2001 a 2019. **Cadernos de Saúde Pública**, v. 38, n. 7, p. e00291321, 2022.

PENFOLD, Robert B.; ZHANG, Fang. Use of Interrupted Time Series Analysis in Evaluating Health Care Quality Improvements. **Academic Pediatrics**, v. 13, n. 6, p. S38–S44, nov. 2013.

PERMANASARI, Adhistya Erna; HIDAYAH, Indriana; BUSTONI, Isna Alfi. SARIMA (Seasonal ARIMA) implementation on time series to forecast the number of Malaria incidence. *In: INTERNATIONAL CONFERENCE ON INFORMATION TECHNOLOGY AND ELECTRICAL ENGINEERING (ICITEE)*. 2013. **Anais** [...]. Yogyakarta, Indonesia: IEEE, out. 2013. Disponível em: <http://ieeexplore.ieee.org/document/6676239/>. Acesso em: 15 jun. 2023

RECUERO, Raquel; SOARES, Felipe; ZAGO, Gabriela. **Polarização, Hiperpartidarismo e Câmaras de Eco: Como circula a Desinformação sobre Covid-19 no Twitter**. SciELO Preprints, 28 ago. 2020. Disponível em: <https://preprints.scielo.org/index.php/scielo/preprint/view/1154>. Acesso em: 8 out. 2024

REX, Franciel Eduardo; BORGES, Cléber Augusto De Souza; KÄFER, Pâmela Suélen. Spatial analysis of the COVID-19 distribution pattern in São Paulo State, Brazil. **Ciência & Saúde Coletiva**, v. 25, n. 9, p. 3377–3384, set. 2020.

RODRIGUES, Karina Furtado; CARPES, Mariana Montez; RAFFAGNATO, Carolina Gomes. Preparação e resposta a desastres do Brasil na pandemia da COVID-19. **Revista de Administração Pública**, v. 54, p. 614–634, 28 ago. 2020.

ROSS, Jennifer M. *et al.* Progress toward eliminating TB and HIV deaths in Brazil, 2001–2015: a spatial assessment. **BMC Medicine**, v. 16, n. 1, p. 144, dez. 2018.

SAEED, Waddah; OMLIN, Christian. Explainable AI (XAI): A systematic meta-survey of current challenges and future opportunities. **Knowledge-Based Systems**, v. 263, p. 110273, mar. 2023.

SANTOS, Leonor Maria Pacheco *et al.* Implementation research: towards universal health coverage with more doctors in Brazil. **Bulletin of the World Health Organization**, v. 95, n. 2, p. 103–112, 1 fev. 2017.

SATO, Renato Cesar. Gerenciamento de doenças utilizando séries temporais com o modelo ARIMA. **Einstein (São Paulo)**, v. 11, n. 1, p. 128–131, mar. 2013.

SCHAFFER, Andrea L.; DOBBINS, Timothy A.; PEARSON, Sallie-Anne. Interrupted time series analysis using autoregressive integrated moving average (ARIMA) models: a guide for evaluating large-scale health interventions. **BMC Medical Research Methodology**, v. 21, n. 1, p. 58, dez. 2021.

SCHERER, Magda Duarte Dos Anjos *et al.* Desafios para o trabalho em saúde: um estudo comparado de Hospitais Universitários na Argélia, Brasil e França. **Ciência & Saúde Coletiva**, v. 23, n. 7, p. 2265–2276, jul. 2018.

SUD, A. *et al.* Collateral damage: the impact on outcomes from cancer surgery of the COVID-19 pandemic. **Annals of Oncology**, v. 31, n. 8, p. 1065–1074, 2020.

PRESIDENTE PRUDENTE (município). Secretaria de Saúde. **RELATÓRIO ANUAL DE GESTÃO 2022 SECRETARIA DE SAÚDE - Presidente Prudente 2023**. Presidente Prudente, 2023. Disponível em: <https://www.presidenteprudente.sp.gov.br>. Acesso em: 30 ago. 2024

SHAH, Syed A. *et al.* Impact of COVID-19 national lockdown on asthma exacerbations: interrupted time-series analysis of English primary care data. **Thorax**, v. 76, n. 9, p. 860–866, set. 2021.

SHAH, Syed Ahmar *et al.* Impact of first UK COVID-19 lockdown on hospital admissions: Interrupted time series study of 32 million people. **eClinicalMedicine**, v. 49, p. 101462, jul. 2022.

SIEDNER, Mark J. *et al.* Access to primary healthcare during lockdown measures for COVID-19 in rural South Africa: an interrupted time series analysis. **BMJ Open**, v. 10, n. 10, p. e043763, out. 2020.

SOUZA, Carlos Dornels Freire de *et al.* Spatiotemporal evolution of case fatality rates of COVID-19 in Brazil, 2020. **J. bras. pneumol.**, v. 46, n. 4, p. e20200208–e20200208, 2020.

STRUCHEN, R.; VIAL, F.; ANDERSSON, M. G. Value of evidence from syndromic surveillance with cumulative evidence from multiple data streams with delayed reporting. **Scientific Reports**, v. 7, n. 1, p. 1191, 26 abr. 2017.

TALJAARD, Monica *et al.* The use of segmented regression in analysing interrupted time series studies: an example in pre-hospital ambulance care. **Implementation Science**, v. 9, n. 1, p. 77, 19 dez. 2014.

TEIXEIRA, Maria Glória *et al.* Vigilância em Saúde no SUS - construção, efeitos e perspectivas. **Ciência & Saúde Coletiva**, v. 23, n. 6, p. 1811–1818, jun. 2018.

TEXIER, Gaëtan *et al.* Outbreak definition by change point analysis: a tool for public health decision? **BMC medical informatics and decision making**, v. 16, p. 33, 12 mar. 2016.

TORRES, Kátia Luz *et al.* Moving towards a strategy to accelerate cervical cancer elimination in a high-burden city—Lessons learned from the Amazon city of Manaus, Brazil. **PLOS ONE**, v. 16, n. 10, p. e0258539, 18 out. 2021.

VICENTE, Creuza Rachel. Is Brazil prepared for the new era of infectious disease epidemics? **Revista da Sociedade Brasileira de Medicina Tropical**, v. 53, p. e20200218, 2020.

WAGNER, A. K. *et al.* Segmented regression analysis of interrupted time series studies in medication use research. **Journal of Clinical Pharmacy and Therapeutics**, v. 27, n. 4, p. 299–309, ago. 2002.

WALTER, Scott *et al.* OP03 The impact of COVID-19 lockdowns on primary care contact among vulnerable populations in England: A controlled interrupted time series study*. *In*: SOCIETY FOR SOCIAL MEDICINE ANNUAL SCIENTIFIC MEETING ABSTRACTS. 2023. **Anais** [...]. BMJ Publishing Group, ago. 2023. Disponível em: <https://jech.bmj.com/lookup/doi/10.1136/jech-2023-SSMabstracts.3>. Acesso em: 18 dez. 2023

WAQAS, Muhammad; HUMPHRIES, Usa Wannasingha. A critical review of RNN and LSTM variants in hydrological time series predictions. **MethodsX**, v. 13, p. 102946, dez. 2024.

XU, Zhongqing *et al.* The Impact of COVID-19 on Primary Care General Practice Consultations in a Teaching Hospital in Shanghai, China. **Frontiers in Medicine**, v. 8, p. 642496, 26 mar. 2021.

YANCHUN PAN *et al.* An ARIMA based model for forecasting the patient number of epidemic disease. *In*: INTERNATIONAL CONFERENCE ON SERVICE SYSTEMS AND SERVICE MANAGEMENT (ICSSSM). 13., 2016. **Anais [...]**. Kunming, China: IEEE, jun. 2016. Disponível em: <http://ieeexplore.ieee.org/document/7538560/>. Acesso em: 15 jun. 2023

YOU, Seung-Hun *et al.* Change Point Analysis for Detecting Vaccine Safety Signals. **Vaccines**, v. 9, n. 3, p. 206, 2 mar. 2021.

ZABIH, Weeda *et al.* Interventions to improve early detection of childhood cancer in low- and middle-income countries: A systematic review. **Pediatric Blood & Cancer**, v. 67, n. 12, p. e28761, dez. 2020.

ZEGER, Scott L.; IRIZARRY, Rafael; PENG, Roger D. On time series analysis of public health and biomedical data. **Annual Review of Public Health**, v. 27, n. 1, p. 57–79, abr. 2006.

ZHANG, Louis. Machine learning for enumeration of cell colony forming units. **Visual Computing for Industry, Biomedicine, and Art**, v. 5, n. 1, p. 26, 5 nov. 2022.

ZHANG, Xingyu *et al.* Applications and Comparisons of Four Time Series Models in Epidemiological Surveillance Data. **PLoS ONE**, v. 9, n. 2, p. e88075, 5 fev. 2014.

ZHENG, Yan-Ling *et al.* Forecast Model Analysis for the Morbidity of Tuberculosis in Xinjiang, China. **PLOS ONE**, v. 10, n. 3, p. e0116832, 11 mar. 2015.

ZVEITER, Marcele *et al.* O fim anunciado da Rede Cegonha – que decisões tomaremos para o nosso futuro? **Revista Enfermagem UERJ**, v. 30, n. 1, p. e66736, 21 set. 2022.

ANEXO A— SCRIPTS DO PROGRAMA R PARA CONSECUÇÃO DAS ANÁLISES DO ARTIGO 1

Scripts do Programa R para consecução das análises do artigo 1

```

library(tidyverse)
library(lubridate)
library(readxl)
library(forecast)
library(fpp2)
library(patchwork)
library(ggplot2)
library(xts)
library(directlabels)
library(tseries)
library(fUnitRoots)
library(strucchange)
library(reshape)
library(Rmisc)
library(fBasics)

# Inserção dos dados
Ate <- (read.table("clipboard", header=TRUE, dec="."))
str(Ate)
names(Ate)

# Criação das séries temporais
TotAt = Ate$Total_atendimentos
TotProc = Ate$totoa_procedimentos
Citop = Ate$Citopatológicos
MamoGeral = Ate$Mamografia_geral
hipert = Ate$hipertensos
Diab = Ate$Diabéticos
Pre_natal = Ate$Pre.natal
Idosos = Ate$Idosos_60anos
PSA = Ate$PSA
Odonto = Ate$Odonto
Crianças = Ate$Crianças_12anos
Colpo = Ate$Colposcopia
Mamorastr = Ate$Mamorastr

# Plotagem geral
autoplot(TSTot)
autoplot(TSTotProc)
autoplot(TSCitop)
autoplot(TSMamoGeral)
autoplot(TShipert)
autoplot(TSDiab)
autoplot(TSPre_natal)
autoplot(TSIdosos)
autoplot(TSPSA)
autoplot(TSOdonto)
autoplot(TSCrianças)
autoplot(TSColpo)
autoplot(TSMamorastr)

# Criação das series temporais
TSTot = ts(TotAt, start = 2017, frequency=12)
TSTotProc = ts(TotProc, start = 2017, frequency=12)
TSCitop = ts(Citop, start = 2017, frequency=12)
TSMamoGeral = ts(MamoGeral, start = 2017, frequency=12)
TShipert = ts(hipert, start = c(2017, 6), frequency=12)
TSDiab = ts(Diab, start = c(2017, 6), frequency=12)
TSPre_natal = ts(Pre_natal, start = c(2017, 6), frequency=12)
TSIdosos = ts(Idosos, start = 2017, frequency=12)
TSPSA = ts(PSA, start = 2017, frequency=12)
TSOdonto = ts(Odonto, start = 2017, frequency=12)
TSCrianças = ts(Crianças, start = 2017, frequency=12)
TSColpo = ts(Colpo, start = 2017, frequency=12)
TSMamorastr = ts(Mamorastr, start = 2017, frequency=12)

# Avaliação de médias mensais
ggsubseriesplot(TSMamorastr)
ggsubseriesplot(TSTot)

```

```

ggsubseriesplot(TSTotProc)
ggsubseriesplot(TSCitop)
ggsubseriesplot(TSMamoGeral)
ggsubseriesplot(TShipert)
ggsubseriesplot(TSDiab)
ggsubseriesplot(TSPre_natal)
ggsubseriesplot(TSIidosos)
ggsubseriesplot(TSPSA)
ggsubseriesplot(TSOdonto)
ggsubseriesplot(TSCrianças)
ggsubseriesplot(TSColpo)
ggsubseriesplot(TSMamorastr)

# Gráficos de sazonalidade
ggseasonplot(TSTot, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSTotProc, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSCitop, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSMamoGeral, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TShipert, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSDiab, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSPre_natal, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSIidosos, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSPSA, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSOdonto, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSCrianças, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSColpo, year.labels=FALSE, continuous=TRUE)
ggseasonplot(TSMamorastr, year.labels=FALSE, continuous=TRUE)

# Médias anuais
TSTotMed=aggregate(TSTot)/12
TSTotProcMed=aggregate(TSTotProc)/12
TSCitopMed=aggregate(TSCitop)/12
TSMamoGeralMed=aggregate(TSMamoGeral)/12
TShipertMed=aggregate(TShipert)/12
TSDiabMed=aggregate(TSDiab)/12
TSPre_natalMed=aggregate(TSPre_natal)/12
TSIidososMed=aggregate(TSIidosos)/12
TSPSAMed=aggregate(TSPSA)/12
TSOodontoMed=aggregate(TSOodonto)/12
TSCriançasMed=aggregate(TSCrianças)/12
TSColpoMed=aggregate(TSColpo)/12
TSMamorastrMed=aggregate(TSMamorastr)/12

# Criação de uma variável para designar o início da pandemia
step <- as.numeric(as.yearmon(time(TSMamorastr)))>='Fev 2020')
step
table(step)

# Criação de uma variável para designar a evolução da pandemia
ramp <- append(rep(0,37), seq(1,25,1))
length(ramp)

# Criação das series temporais, significância estatística dos coeficientes
# Checagem de resíduos
# Plotagem de gráficos de linhas

TSITot <- auto.arima(TSTot, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSITot)
coefstest(TSITot)
confint(TSITot)
checkresiduals(STITot)
Box.test(STITot$residuals, lag = 24, type = "Ljung-Box")
STITot2<- Arima(window(TSTot, end=c(2020,1)),
order=c(0,0,0),
seasonal=list(order=c(1,0,0), period=12))
Totfc <- forecast(STITot2, h=24)
Totfc.ts <- ts(as.numeric(Totfc$mean), start=c(2020,2), frequency=12)
Tot.ts.2 <- ts.union(TSTot, Totfc.ts)
Tot.ts.2
plot(Tot.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
xlab="Ano", ylab="Total de atendimentos",
linetype=c("solid","dashed"), ylim=c(9,20))
abline(v = 2020.09589041, col = "red", lty = 2)
TotAtPM=cpt.mean(TotAt,method="BinSeg")
plot(TotAtPM, xlab= "Ano", ylab = "Número de atendimentos")
cpts(TotAtPM)

```

```

TSITotProc<- auto.arima(TSTotProc, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSITotProc)
coeftest(TSITotProc)
confint(TSITotProc)
checkresiduals(TSITotProc)
Box.test(TSITotProc$residuals, lag = 24, type = "Ljung-Box")
STITotProc2<- Arima(window(TSTotProc, end=c(2020,1)),
                    order=c(0,1,1),
                    seasonal=list(order=c(0,0,0), period=12))
STITotProc2
Procfc <- forecast(STITotProc2, h=24)
Procfc
Procfc.ts <- ts(as.numeric(Procfc$mean), start=c(2020,2), frequency=12)
Procfc.ts
Procfc.ts.2 <- ts.union(TSTotProc, Procfc.ts)
Procfc.ts.2
plot(Procfc.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(10,47))
abline(v = 2020.09589041, col = "red", lty = 2)
TotProcPM=cpt.mean(TotProc,method="BinSeg")
plot(TotProcPM, xlab= "Ano", ylab = "Número de atendimentos")
cpts(TotProcPM)

TSICitop<- auto.arima(TSCitop, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSICitop)
coeftest(TSICitop)
confint(TSICitop)
checkresiduals(TSICitop)
Box.test(TSICitop$residuals, lag = 24, type = "Ljung-Box")
TSICitop2<- Arima(window(TSCitop, end=c(2020,1)),
                  order=c(1,0,0),
                  seasonal=list(order=c(0,1,1), period=12))
TSICitop2
Citopfc <- forecast(TSICitop2, h=24)
Citopfc
Citopfc.ts <- ts(as.numeric(Citopfc$mean), start=c(2020,2), frequency=12)
plot(Citopfc.ts)
Citopfc.ts.2 <- ts.union(TSCitop, Citopfc.ts)
Citopfc.ts.2
plot(Citopfc.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,3.2))
abline(v = 2020.09589041, col = "red", lty = 2)
CitopPM=cpt.mean(Citop,method="BinSeg")
plot(CitopPM, xlab= "Ano", ylab = "Número de atendimentos")
cpts(CitopPM)

TSMamoGeral<- auto.arima(TSMamoGeral, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSMamoGeral)
coeftest(TSMamoGeral)
confint(TSMamoGeral)
checkresiduals(TSMamoGeral)
Box.test(TSMamoGeral$residuals, lag = 24, type = "Ljung-Box")
TSMamoGeral2<- Arima(window(TSMamoGeral, end=c(2020,1)),
                    order=c(0,0,1),
                    seasonal=list(order=c(1,1,0), period=12))
TSMamoGeral2
MamoGeralfc <- forecast(TSMamoGeral2, h=24)
MamoGeralfc
MamoGeralfc.ts <- ts(as.numeric(MamoGeralfc$mean), start=c(2020,2), frequency=12)
plot(MamoGeralfc.ts)
MamoGeralfc.ts.2 <- ts.union(TSMamoGeral, MamoGeralfc.ts)
MamoGeralfc.ts.2
plot(MamoGeralfc.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,3.2))
abline(v = 2020.09589041, col = "red", lty = 2)
MamoGeralpPM=cpt.mean(MamoGeral,method="BinSeg")
plot(MamoGeralpPM, xlab= "Ano", ylab = "Número de atendimentos")

```

```

cpts (MamoGeralpPM)

TSIhipert<- auto.arima(TShipert, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIhipert)
coefstest(TSIhipert)
confint(TSIhipert)
checkresiduals(TSIhipert)
Box.test(TSIhipert$residuals, lag = 24, type = "Ljung-Box")
TSIhipert2<- Arima(window(TShipert, end=c(2020,1)),
                  order=c(1,0,1),
                  seasonal=list(order=c(1,0,0), period=12))

TSIhipert2
hipertfc <- forecast(TSIhipert2, h=24)
hipertfc
hipertfc.ts <- ts(as.numeric(hipertfc$mean), start=c(2020,2), frequency=12)
plot(hipertfc.ts)
hipertfc.ts.2 <- ts.union(TShipert, hipertfc.ts)
hipertfc.ts.2
plot(hipertfc.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,4))
abline(v = 2020.09589041, col = "red", lty = 2)
hipertPM=cpt.mean(na.omit(hipert),method="BinSeg")
plot(hipertPM, xlab= "Ano", ylab = "Número de atendimentos")
cpts(hipertPM)

TSIDIab<- auto.arima(TSDiab, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIDIab)
coefstest(TSIDIab)
confint(TSIDIab)
checkresiduals(TSIDIab)
Box.test(TSIDIab$residuals, lag = 24, type = "Ljung-Box")
TSIDIab2<- Arima(window(TSDiab, end=c(2020,1)),
                 order=c(1,0,1),
                 seasonal=list(order=c(1,0,0), period=12))

TSIDIab2
TSIDIabfc <- forecast(TSIDIab2, h=24)
TSIDIabfc
Diab.ts <- ts(as.numeric(TSIDIabfc$mean), start=c(2020,2), frequency=12)
plot(Diab.ts)
Diab.ts.2 <- ts.union(TSDiab, Diab.ts)
Diab.ts.2
plot(Diab.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0.2,1.3))
abline(v = 2020.09589041, col = "red", lty = 2)
DiabPM=cpt.mean(na.omit(Diab),method="BinSeg")
plot(DiabPM, xlab= "Ano", ylab = "Número de atendimentos")
cpts(DiabPM)

TSIPre_natal<- auto.arima(TSPre_natal, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIPre_natal)
coefstest(TSIPre_natal)
confint(TSIPre_natal)
checkresiduals(TSIPre_natal)
Box.test(TSIPre_natal$residuals, lag = 24, type = "Ljung-Box")
TSIPre_natal2<- Arima(window(TSPre_natal, end=c(2020,1)),
                    order=c(0,0,0),
                    seasonal=list(order=c(0,0,0), period=12))

TSIPre_natal2
TSIPre_natalfc <- forecast(TSIPre_natal2, h=24)
TSIPre_natalfc
Pre_natal.ts <- ts(as.numeric(TSIPre_natalfc$mean), start=c(2020,2), frequency=12)
plot(Pre_natal.ts)
Pre_natal.ts.2 <- ts.union(TSPre_natal, Pre_natal.ts)
Pre_natal.ts.2
plot(Pre_natal.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(1,3.5))
abline(v = 2020.09589041, col = "red", lty = 2)
Pre_natalPM=cpt.mean(na.omit(Pre_natal),method="BinSeg")
plot(Pre_natalPM, xlab= "Ano", ylab = "Número de atendimentos")

```

```
cpts(Pre_natalPM)
```

```
TSIIDosos<- auto.arima(TSIDosos, seasonal=TRUE,
http://127.0.0.1:46779/graphics/plot_zoom_png?width=398&height=275
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIIDosos)
coeftest(TSIIDosos)
confint(TSIIDosos)
checkresiduals(TSIIDosos)
Box.test(TSIIDosos$residuals, lag = 24, type = "Ljung-Box")
TSIIDosos2<- Arima(window(TSIDosos, end=c(2020,1)),
order=c(0,0,0),
seasonal=list(order=c(1,0,0), period=12))

TSIIDosos2
TSIIDososfc <- forecast(TSIIDosos2, h=24)
TSIIDososfc
Idosos.ts <- ts(as.numeric(TSIIDososfc$mean), start=c(2020,2), frequency=12)
plot(Idosos.ts)
Idosos.ts.2 <- ts.union(TSIDosos, Idosos.ts)
Idosos.ts.2
plot(Idosos.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
xlab="Ano", ylab="Total de atendimentos",
linetype=c("solid","dashed"), ylim=c(15,42))
abline(v = 2020.09589041, col = "red", lty = 2)

TSIPSA<- auto.arima(TSPSA, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIPSA)
coeftest(TSIPSA)
confint(TSIPSA)
checkresiduals(TSIPSA)
Box.test(TSIPSA$residuals, lag = 24, type = "Ljung-Box")
TSIPSA2<- Arima(window(TSPSA, end=c(2020,1)),
order=c(0,0,0),
seasonal=list(order=c(1,0,0), period=12))

TSIPSA2
TSIPSAfc <- forecast(TSIPSA2, h=24)
TSIPSAfc
PSA.ts <- ts(as.numeric(TSIPSAfc$mean), start=c(2020,2), frequency=12)
plot(PSA.ts)
PSA.ts.2 <- ts.union(TSPSA, PSA.ts)
PSA.ts.2
plot(PSA.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
xlab="Ano", ylab="Total de atendimentos",
linetype=c("solid","dashed"), ylim=c(0,5))
abline(v = 2020.09589041, col = "red", lty = 2)

TSIOdonto<- auto.arima(TSOdonto, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIOdonto)
coeftest(TSIOdonto)
confint(TSIOdonto)
checkresiduals(TSIOdonto)
Box.test(TSIOdonto$residuals, lag = 24, type = "Ljung-Box")
TSIOdonto2<- Arima(window(TSOdonto, end=c(2020,1)),
order=c(0,0,1),
seasonal=list(order=c(1,0,0), period=12))

TSIOdonto2
TSIOdonto2fc <- forecast(TSIOdonto2, h=24)
TSIOdonto2fc
Odonto.ts <- ts(as.numeric(TSIOdonto2fc$mean), start=c(2020,2), frequency=12)
plot(Odonto.ts)
Odonto.ts.2 <- ts.union(TSOdonto, Odonto.ts)
Odonto.ts.2
plot(Odonto.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
xlab="Ano", ylab="Total de atendimentos",
linetype=c("solid","dashed"), ylim=c(0,2.3))
abline(v = 2020.09589041, col = "red", lty = 2)

TSICrianças<- auto.arima(TSCrianças, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSICrianças)
coeftest(TSICrianças)
```

```

confint(TSICrianças)
checkresiduals(TSICrianças)
Box.test(TSICrianças$residuals, lag = 24, type = "Ljung-Box")
TSICrianças2<- Arima(window(TSCrianças, end=c(2020,1)),
                    order=c(0,0,2),
                    seasonal=list(order=c(1,0,0), period=12))
TSICrianças2
TSICriançasfc <- forecast(TSICrianças2, h=24)
TSICriançasfc
Crianças.ts <- ts(as.numeric(TSICriançasfc$mean), start=c(2020,2), frequency=12)
plot(Crianças.ts)
Crianças.ts.2 <- ts.union(TSCrianças, Crianças.ts)
Crianças.ts.2
plot(Crianças.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,17))
abline(v = 2020.09589041, col = "red", lty = 2)

TSIColpo<- auto.arima(TSColpo, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSIColpo)
coefstest(TSIColpo)
confint(TSIColpo)
checkresiduals(TSIColpo)
Box.test(TSIColpo$residuals, lag = 24, type = "Ljung-Box")
TSIColpo2<- Arima(window(TSColpo, end=c(2020,1)),
                 order=c(0,0,0),
                 seasonal=list(order=c(0,0,0), period=12))
TSIColpo2
TSIColpofc <- forecast(TSIColpo2, h=24)
TSIColpofc
Colpo.ts <- ts(as.numeric(TSIColpofc$mean), start=c(2020,2), frequency=12)
plot(Colpo.ts)
Colpo.ts.2 <- ts.union(TSColpo, Colpo.ts)
Colpo.ts.2
plot(Colpo.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,0.05))
abline(v = 2020.09589041, col = "red", lty = 2)

TSMamorastr<- auto.arima(TSMamorastr, seasonal=TRUE,
xreg=cbind(step,ramp), stepwise=FALSE, trace=TRUE)
summary(TSMamorastr)
coefstest(TSMamorastr)
confint(TSMamorastr)
checkresiduals(TSMamorastr)
Box.test(TSMamorastr$residuals, lag = 24, type = "Ljung-Box")
TSMamorastr2<- Arima(window(TSMamorastr, end=c(2020,1)),
                    order=c(0,1,2),
                    seasonal=list(order=c(0,0,0), period=12))
TSMamorastr2
TSMamorastrfc <- forecast(TSMamorastr2, h=24)
TSMamorastrfc
Mamorastr.ts <- ts(as.numeric(TSMamorastrfc$mean), start=c(2020,2), frequency=12)
plot(Mamorastr.ts)
Mamorastr.ts.2 <- ts.union(TSMamorastr, Mamorastr.ts)
Mamorastr.ts.2
plot(Mamorastr.ts.2, type="l", plot.type="s", col=c('blue','red'), lwd=2,
     xlab="Ano", ylab="Total de atendimentos",
     linetype=c("solid","dashed"), ylim=c(0,2))
abline(v = 2020.09589041, col = "red", lty = 2)

```

ANEXO B— SCRIPTS DO PROGRAMA R PARA CONSECUÇÃO DAS ANÁLISES DO ARTIGO 2

Scripts do Programa R para consecução das análises do artigo 2

```
# Pacotes utiizados

library(xgboost)
library(tidymodels)
library(modeltime)
library(modeltime.ensemble)
library(tidyverse)
library(lubridate)
library(timetk)
library(zoo)
library(generics)
library(yardstick)

# Dados relacionados à câncer de próstata
# Inserção dos dados gerais
Cancer<-(read.table("clipboard", header=TRUE, dec=".")
str(Cancer)
Prost= Cancer$Prost
str(Prost)

# Criação das series temporais
ProstCAC= ts(Prost, start = 2014, frequency = 12)
plot(ProstCAC)
TSProst = ts(Prost, start = c(2020, 4), frequency = 12)

# Padronização e plotagem
dfP<-data.frame(date = as.Date(as.yearmon(time(TSProst))),
value=as.matrix(TSProst))
dfP
dfP %>%
plot_time_series(date, value, .interactive = interactive)

# Separação em dados de treino e teste
# 80/20
splitsP <- initial_time_split(dfP, prop = 0.7)

# Modelo ARIMA XGBoost
model_spec <- arima_boost(
  tree_depth = 6,
  learn_rate = 0.1
) %>%
  set_engine(engine = "arima_xgboost")
ARIMABOOSTP <- model_spec %>%
fit(value ~ date + as.numeric(date) + month(date, label = TRUE),
data = training(splitsP))
ARIMABOOSTP

## Modelo PROPHET
PROPHETP <- prophet_reg() %>%
  set_engine(engine = "prophet") %>%
  fit(value ~ date, data = training(splitsP))
PROPHETP

# Modelo NNETAR
model_spec <- nnetar_reg() %>%
  set_engine("nnetar")
NNARP <- model_spec %>%
  fit(value ~ date, data = training(splitsP))
NNARP

# Tabela com modelos
models_tblP <- modeltime_table(
  NNARP,
  PROPHETP,
  ARIMABOOSTP)

models_tblP

# Calibração
```

```

calibration_tblP <- models_tblP %>%
  modeltime_calibrate(new_data = testing(splitsP))
calibration_tblP

calibration_tblP %>%
  modeltime_forecast(
    new_data = testing(splitsP),
    actual_data = dfP) %>%
  plot_modeltime_forecast(
    .legend_max_width = 25, # For mobile screens
    .interactive = interactive)

TABP = calibration_tblP %>%
  modeltime_accuracy() %>%
  table_modeltime_accuracy()
TABP = calibration_tblP %>%
  modeltime_accuracy() %>%
  table_modeltime_accuracy(
    .interactive = FALSE)

TABP

future_dates <- tibble(
  date = seq.Date(
    from = as.Date("2020-04-01"),
    to = as.Date("2024-09-01"),
    by = "month"))

# Valores preditos
forecastNNARP <- modeltime_table(NNARP) %>%
  modeltime_forecast(
    new_data = future_dates,
    actual_data = NULL)

forecastPROPHETP <- modeltime_table(PROPHETP) %>%
  modeltime_forecast(
    new_data = future_dates,
    actual_data = NULL)

forecastARIMA_boostP <- modeltime_table(ARIMABOOSTP) %>%
  modeltime_forecast(
    new_data = future_dates,
    actual_data = NULL)

# Séries temporais dos valores preditos
TSNNARP = ts(forecastNNARP$.value, frequency=12,
  start = c(2020, 4))
plot(TSNNARP)

PROPHETTSP = ts(forecastPROPHETP$.value, frequency=12,
  start = c(2020, 4))
plot(PROPHETTSP)

TSARIMAXGBBOSTP = ts(forecastARIMA_boostP$.value, frequency=12,
  start = c(2020, 4))
plot(TSARIMAXGBBOSTP)

# Plotagem das séries temporais
plot(TSNNARP)
plot(PROPHETTSP)
plot(TSARIMAXGBBOSTP)

# Plotagem dos das séries
par(mfrow = c(3, 1), mar = c(2, 4, 2, 1))

# NNAR
plot(ProstCAC,
  type = "l", col = "blue",
  lwd = 2,
  ylim=range(c(ProstCAC, TSNNARP)),
  xlab = "Ano",
  ylab = "Taxa",
  main = "NNAR")

# Adicionando a segunda série ao gráfico
lines(TSNNARP, col = "red", lwd = 2)
abline(v = c(2020.1667, 2022.25),

```

```

col = "black", lty = 2, lwd = 2)

# Adicionando uma legenda
legend("topleft",
legend = c("Internamentos", "NNAR"),
col = c("blue", "red"),
lwd = 2,
bty = "n")

# ARIMAXGBBOST
plot(ProstCAC,
type = "l", col = "blue",
lwd = 2,
ylim=range (c(ProstCAC, TSARIMAXGBBOSTM)),
xlab = "Ano",
ylab = "Taxa",
main = "ARIMA XGBOOST")

# Adicionando a segunda série ao gráfico
lines(TSARIMAXGBBOSTP, col = "red",lwd = 2)
abline(v = c(2020.1667, 2022.25),
col = "black", lty = 2, lwd = 2)

# Adicionando uma legenda
legend(
"topleft",
legend = c("Internamentos", "ARIMA XGBOOST"),
col = c("blue", "red"),
lwd = 2,
bty = "n")

# PROPHET
plot(ProstCAC,
type = "l", col = "blue",
lwd = 2,
ylim=range (c(ProstCAC, PROPHETTSP)),
xlab = "Ano",
ylab = "Taxa",
main = "PROPHET")

# Adicionando a segunda série ao gráfico
lines(PROPHETTSP, col = "red",lwd = 2)
abline(v = c(2020.1667, 2022.25),
col = "black", lty = 2, lwd = 2)

# Adicionando uma legenda
legend(
"topleft",
legend = c("Internamentos", "PROPHET"),
col = c("blue", "red"),
lwd = 2,
bty = "n")

```