

Modelo Autorregressivo Integrado de Médias Móveis (ARIMA): aspectos conceituais e metodológicos e sua aplicabilidade na mortalidade infantil

Aline Beatriz dos Santos Silva ¹

 <https://orcid.org/0000-0001-9559-8524>

Ana Catarina de Melo Araújo ²

 <https://orcid.org/0000-0003-1558-9789>

Paulo Germano de Frias ³

 <https://orcid.org/0000-0003-4497-8898>

Mirella Bezerra Rodrigues Vilela ⁴

 <https://orcid.org/0000-0001-5113-7144>

Cristine Vieira do Bonfim ⁵

 <https://orcid.org/0000-0002-4495-9673>

¹ Programa de Pós-Graduação em Saúde Coletiva. Universidade Federal de Pernambuco. Av. Prof. Moraes Rego, 1235. Recife, PE, Brasil. CEP: 50.670-901. E-mail: alinebeatriz92@gmail.com

² Secretaria Estadual de Saúde de Pernambuco. Recife, PE, Brasil.

³ Instituto de Medicina Integral Prof. Fernando Figueira. Recife, PE, Brasil.

⁴ Universidade Federal de Pernambuco. Recife, PE, Brasil.

⁵ Fundação Joaquim Nabuco. Recife, PE, Brasil.

Resumo

Este artigo, de cunho teórico-reflexivo, objetiva discutir os aspectos conceituais e metodológicos sobre as aplicações da modelagem de série temporal, em especial, o Modelo Autorregressivo Integrado de Médias Móveis e sua aplicabilidade na mortalidade infantil. Essa modelagem possibilita prever os valores futuros utilizando os dados passados, delineando e estimando os cenários possíveis do evento em saúde, evidenciando a sua magnitude. Devido à persistência da mortalidade infantil como um problema de saúde pública, a aplicabilidade desse método é útil no gerenciamento oportuno e sistemático dos indicadores da saúde infantil, além de ser um método que apresenta baixo custo operacional, que, em contextos de redução de gastos em saúde, se torna uma ferramenta de gestão em potencial. No entanto, ainda há lacunas na utilização de métodos estatísticos no processo decisório e formulador de políticas em saúde, a exemplo da modelagem em questão. São obstáculos de natureza metodológica (estatística robusta), institucional (sistemas de informações defasados) e cultural (desvalorização dos dados produzidos, principalmente em nível local).

Palavras-chave *Estudos de séries temporais, Mortalidade infantil, Políticas públicas de saúde*



Introdução

A análise da situação de saúde, o monitoramento de indicadores prioritários e a previsão de cenários são desafios em todos os países, em especial, naqueles que têm dificuldades para o alcance de ações internacionalmente pactuadas.¹ A mortalidade infantil é particularmente estudada pela sua expressão como um problema de saúde pública e pela disponibilidade de tecnologia para o seu enfrentamento.^{1,2} Para esse evento, a utilização da metodologia de séries temporais é favorável na construção de cenários futuros, monitoramento e análise da situação de saúde.^{3,4} Essa modelagem permite diagnosticar e compreender os padrões de comportamento temporal de eventos que acometem uma determinada população e avaliar os impactos de intervenções em saúde.⁵

Diversas técnicas de análise de séries temporais são capazes de prever valores futuros, utilizando os dados passados, por meio de conclusões estatísticas. A finalidade é modelar o evento, construindo uma função matemática que representa a correlação da variável com o tempo.⁶

Nenhum modelo proposto assume integralmente as previsões exatas devido a ocorrências de variações aleatórias às quais o processo de observação dos eventos está sujeito. Porém, constituem ferramentas valiosas para avaliar rapidamente a gravidade de uma situação e auxiliam as autoridades públicas de saúde na definição ou nos ajustes das estratégias de controle.⁷ Dentre os tipos de modelos, destacam-se: a análise de tendência (média móvel e suavização exponencial); os modelos de regressão, que lidam com diferentes padrões presentes na série, como os pontos de inflexão (*joinpoint regression analysis*); a rede neural artificial, que foi pensada para funcionar de forma matematicamente semelhante ao cérebro humano e poder realizar generalizações por meio de dados passados e não lineares e o Modelo Autorregressivo Integrado de Médias Móveis (ARIMA), ou Modelo Box-Jenkins, bastante utilizado na área econômica.^{9,10} Na área da saúde, na década de 1980, o Centro de Controle de Doenças (CDC) adotou essa modelagem como referência nas análises em saúde e, desde então, ele foi difundido em estudos na área.^{7,8}

Este artigo objetiva discutir os aspectos conceituais e metodológicos acerca da série temporal utilizando a modelagem ARIMA e a sua aplicabilidade na mortalidade infantil. A proposta de construir o manuscrito tem a finalidade de contribuir com a prática em saúde na redução das iniquidades persistentes na saúde infantil, utilizando uma modelagem

estatística robusta. Ao propor antever cenários futuros, a incorporação sistemática do método abordado fortalecerá o planejamento de ações direcionadas nos diversos níveis do sistema de saúde.

O apoio referencial para estruturar conceitos e métodos foi proveniente de livros e artigos científicos publicados em periódicos indexados nas bases de dados da LILACS e US *National Library of Medicine* (PubMed), além da biblioteca virtual da SciELO. As explicações e ponderações foram organizadas nos seguintes tópicos: Séries temporais: aspectos teóricos e metodológicos e a modelagem ARIMA; Aplicações da análise de séries temporais na mortalidade infantil: possibilidades e limitações metodológicas. Foram utilizadas as taxas de mortalidade infantil no Brasil distribuídas em uma série temporal para exemplificar a aplicabilidade da modelagem ARIMA por meio de gráfico linear e os gráficos de autocorrelações. Os dados para o cálculo da taxa de mortalidade infantil foram extraídos dos Sistemas de Informação sobre Mortalidade (SIM) e do Sistema de Informação sobre Nascidos Vivos (Sinasc) e obtidos no site do DATASUS por meio do link de acesso aberto ao público: <https://datasus.saude.gov.br/>.

Séries temporais: aspectos teóricos e metodológicos e a modelagem ARIMA

As séries temporais são uma sequência de valores observados de determinado fenômeno e distribuídos sobre uma base de tempo. A expressão matemática que descreve uma série temporal é dada por $\{Y(t), t \in T\}$, em que Y representa a variável de interesse e T representa o conjunto de índices relacionados aos tempos de medição. A análise de série temporal objetiva construir modelos explicativos, ou determinísticos, para o fenômeno estudado e, com isso, realizar as respectivas previsões.⁶

A natureza dos valores observados caracteriza a série temporal em contínua ou discreta. Com base na função geral, uma série discreta $T = t_1, t_2, \dots, t_n$, as observações são feitas em intervalos de tempo fixos e enumeráveis, podendo ser equiespaçados ou não. Na série contínua, os dados referentes à determinada variável são evidenciados de forma sequencial em um intervalo de tempo $T = t : t_1 < t < t_2$, por exemplo, a mensuração contínua de determinado sinal biológico como a pressão arterial.⁸

Na análise da série, alguns aspectos básicos devem ser considerados para poder compreender melhor o comportamento da variável observada. O primeiro refere-se à periodicidade, a qual depende da natureza da variável em análise, se contínua ou

discreta, e do objetivo de estudo proposto. No caso da taxa de mortalidade infantil, sua periodicidade está relacionada com a disponibilidade dos dados nos sistemas oficiais de informações e de investigadores em saúde que realizem as análises críticas constantes para mensurar a magnitude do evento em questão.⁸ Outro aspecto importante refere-se à comparabilidade entre séries temporais de diferentes contextos, em que, nessa situação, é necessário respeitar determinadas circunstâncias que permitam contrastar as séries.⁸

A não estacionariedade é uma característica considerada importante no tratamento da série temporal e deve ser evitada, pois dificulta as previsões. Uma série não estacionária é resultante da frequência dos dados estudados e esta pode ser instável referente à sua média, variância e autocovariância. Referente à taxa de mortalidade infantil, valores muito altos ou baixos de óbitos dentro de um período causam grandes variações na série. Dessa maneira, o tratamento da série, quanto à sua estacionariedade, é uma condição necessária na modelagem de séries temporais. Uma série não estacionária pressupõe que o modelo é determinado pela aleatoriedade das observações, pelo acaso.⁵

Para estimar o modelo, deve-se primeiramente certificar se não é uma sequência puramente aleatória, também chamada de variação aleatória, ruído branco ou resíduo aleatório. Caso não seja, a função do modelo pode ser constituída por componentes que representam padrões ou regularidades parciais da série estudada, sendo: tendência, sazonalidade e a estimação da variabilidade do resíduo aleatório para constituir os intervalos de confiança para as previsões provenientes do modelo.⁶

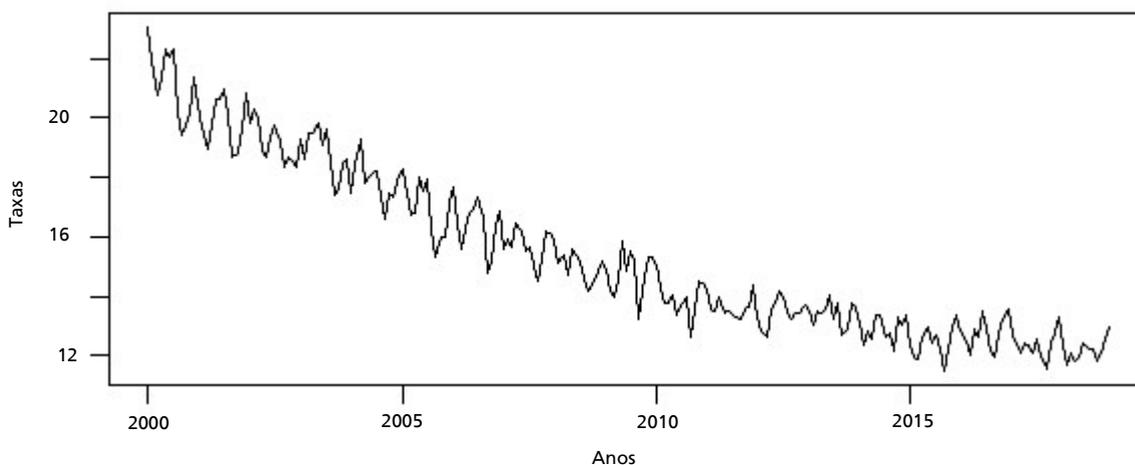
O gráfico temporal, ou gráfico de linha, é fundamental para visualizar os componentes e identificar valores atípicos (*outliers*). A Figura 1 evidencia a série temporal da taxa de mortalidade infantil no Brasil durante o período de 2000 a 2018. O comportamento temporal da taxa por meio do gráfico evidencia a presença de tendência. A estacionariedade pode ser identificada por meio de testes estatísticos, como, por exemplo, o teste de Dickey-Fuller Aumentado, o qual testa a hipótese alternativa de estacionariedade.

O autocorrelograma permite visualizar e identificar a dependência das regularidades encontradas. A autocorrelação, como o nome remete, é a correlação entre uma série temporal e ela mesma. No autocorrelograma, os períodos em que houver correlação são representados pela nomenclatura lag. A autocorrelação temporal é identificada por meio dos gráficos de autocorrelação simples (ACF) e parcial (PACF), que são testes que apontam a significância estatística da autocorrelação, ou seja, quando os lags extrapolam (para cima ou para baixo) os limites do intervalo de confiança traçados no gráfico (Figura 2).^{6,11}

Na análise de modelos ARIMA, a presença da autocorrelação só pode ser útil se a série temporal em questão não apresentar tendência ou esta for removida, o que é classificado como padrão estacionário. Nesse padrão, os valores desenvolvem-se no tempo ao redor de uma média e variância

Figura 1

Taxa de mortalidade infantil no Brasil, 2000-2018 (n= 228 observações).



*Teste de estacionariedade (Dickey-Fuller Aumentado): p -valor 0,38. Isso indica que a série não é estacionária.

Fonte: Sistema de Informação de Mortalidade e Sistema de Informação sobre Nascidos Vivos- DATASUS, Ministério da Saúde.

constantes, tornando possível a técnica de predição.⁶ O primeiro componente a ser identificado é a tendência por meio do gráfico temporal e de alguns métodos que suavizam as flutuações da série original, como as médias móveis ou transformações lineares. As médias móveis, ou filtros lineares, são utilizadas quando uma série se mostra marcadamente irregular, com muitas flutuações, dificultando a visualização da tendência. Quanto mais sinuosa a tendência, maior o suavizamento necessário para identificar a real tendência da série.⁸

A remoção da tendência é feita por técnica de diferenciação da própria série no intuito de torná-la estacionária (Figura 3). Uma diferença elimina uma tendência linear e duas diferenças eliminam uma tendência exponencial. A quantidade de diferenças está relacionada ao grau do polinômio estimado para a tendência.⁶

O componente sazonalidade é um fenômeno que ocorre regularmente no tempo.¹² As relações das observações em séries que apresentam sazonalidade ocorrem com frequência em séries temporais anuais e mensais, podendo também ocorrer em séries mensuradas em outras dimensões temporais. Padrões sazonais são identificados no gráfico original (Figura 1) e no correlograma por meio de oscilações em mesma frequência (Figura 3). A análise é feita por meio dos coeficientes de autocorrelação nos períodos sazonais.⁶

O Modelo Autorregressivo Integrado de Médias Móveis (ARIMA), ou Modelo Box-Jenkins, é bastante utilizado para predição, ou forecasting. Essa técnica utiliza dados passados para estimar valores

futuros e a instabilidade com suas flutuações é um empecilho para a aplicabilidade da técnica.^{13,14} A identificação da estabilidade serial, ou estacionariedade, é a primeira etapa da modelagem. Devido à possibilidade de existir períodos sazonais na série, a modelagem ARIMA apresenta uma extensão, a Modelagem Sazonal Autorregressiva Integrada de Médias Móveis (SARIMA) ou ARIMA sazonal.⁶ Nas séries que não apresentam estacionariedade devido às flutuações (tendência, sazonalidade) inerentes das mesmas, o modelo ARIMA possibilita obter resultados satisfatórios.⁸

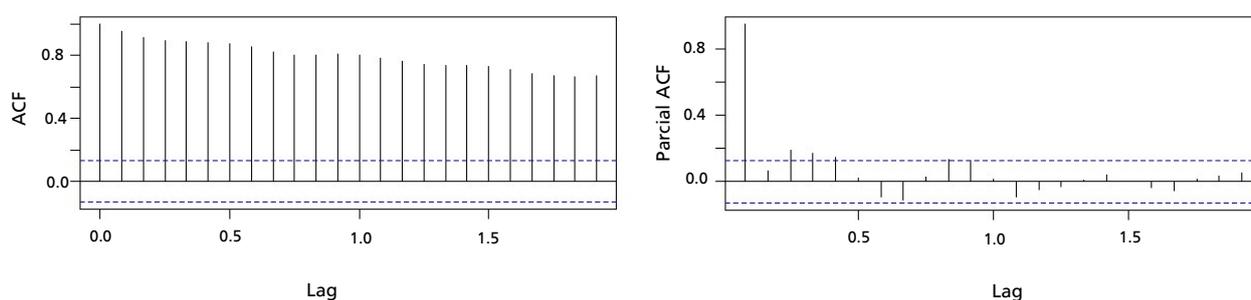
A indução à estacionariedade segue uma ordem que parte do pressuposto de conservação das flutuações da série original. Primeiro, avalia-se a não estacionariedade da variância, seguida das autocorrelações e, por último, da média. A depender do grau da tendência apresentada na série, ao corrigir a não estacionariedade da variância, conseqüentemente, estabilizam-se a média e as autocorrelações. Por isso, deve ser respeitada a ordem de ajuste da série citada anteriormente, fazendo com que não seja necessário induzir estacionariedade a respeito das autocorrelações e média.⁸

Em geral, a metodologia ARIMA, proposta por George Box e Gwilym Jenkins, consegue diagnosticar a série quanto à condição de estacionariedade e identificar o modelo adequado por meio de um ciclo iterativo, com os próprios dados da série, com as seguintes fases: identificação, especificação, estimação e diagnóstico.⁶

Ao desmembrar a sigla ARIMA na fase de identificação dos possíveis modelos, o AR, ou ordem p,

Figura 2

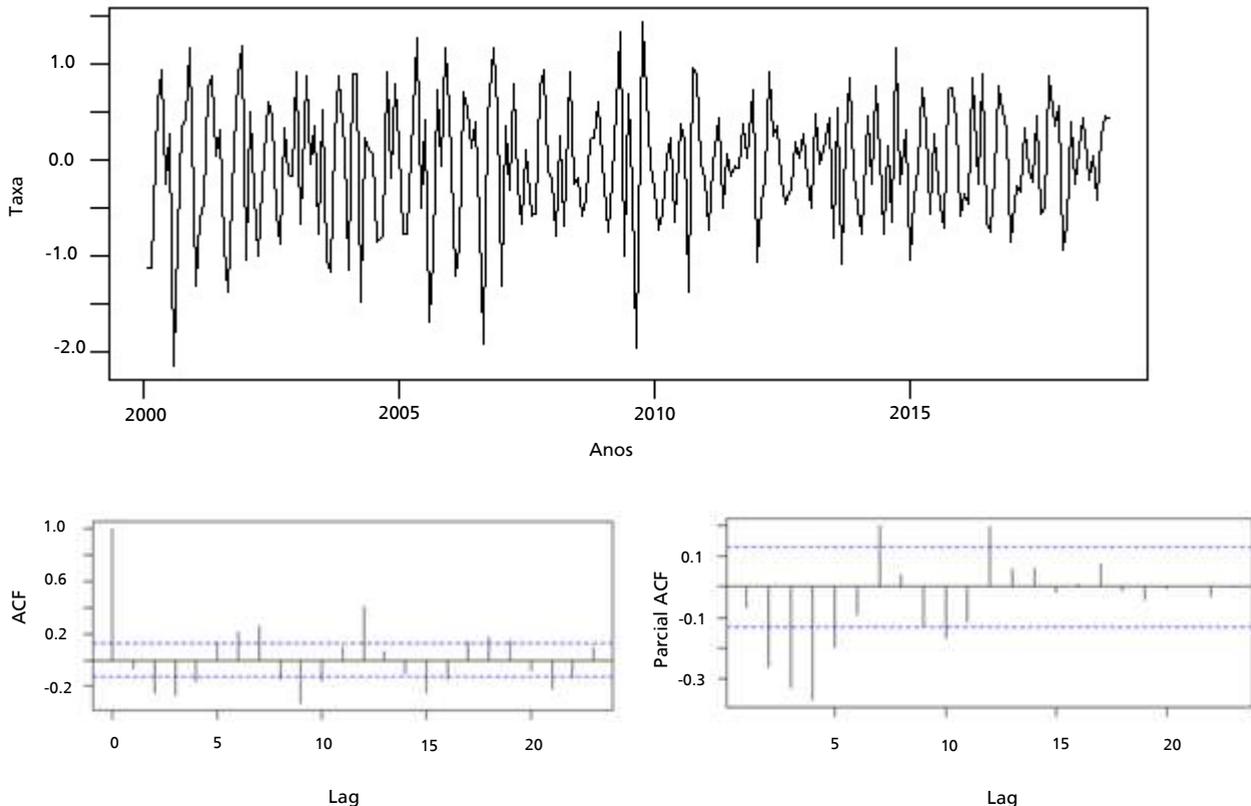
Função de autocorrelação (ACF) e função de autocorrelação parcial (PACF) da taxa mensal da mortalidade infantil no Brasil, 2000-2018.



Fonte: Sistema de Informação de Mortalidade e Sistema de Informação sobre Nascidos Vivos- DATASUS, Ministério da Saúde.

Figura 3

Taxa mensal da mortalidade infantil e função de autocorrelação (ACF) e autocorrelação parcial (PACF) após o processo de diferenciação ($d=1$), Brasil, 2000-2018.



*Teste de estacionariedade (Dickey-Fuller Aumentado): p -valor 0,01. Isso indica que a hipótese nula de não estacionariedade foi rejeitada. Fonte: Sistema de Informação de Mortalidade e Sistema de Informação sobre Nascidos Vivos- DATASUS, Ministério da Saúde.

representa o processo autorregressivo, ou seja, a influência do valor anterior da variável sobre o valor considerado; o I, ou ordem d , está relacionado ao número de diferenciações para induzir à estacionariedade, e o MA, ou ordem q , está relacionado à influência do ruído produzido no valor anterior.^{5,14,15} As ordens dos modelos ARIMA e SARIMA são estimadas pelo gráfico da função de autocorrelação (ACF) e pelo correlograma de autocorrelação parcial (PACF), sendo o ACF sugestivo de ordem MA e o PACF da ordem AR. O número da ordem está relacionado à quantidade de lags que ultrapassem o intervalo de confiança do gráfico.^{13,14} Observar a ACF e PACF é útil para se ter uma ideia do modelo a ser testado, objetivando escolher aquele que apresente a menor quantidade de parâmetros (mais parcimonioso).

Os modelos SARIMA apresentam ordem não sazonal (p, d, q) e sazonal (P, D, Q) e, por isso, é também chamado de modelo multiplicativo. A estimação dos parâmetros (ou coeficientes) é realizada por meio dos seguintes métodos: mínimos quadrados, máxima verossimilhança ou método dos momentos.⁶

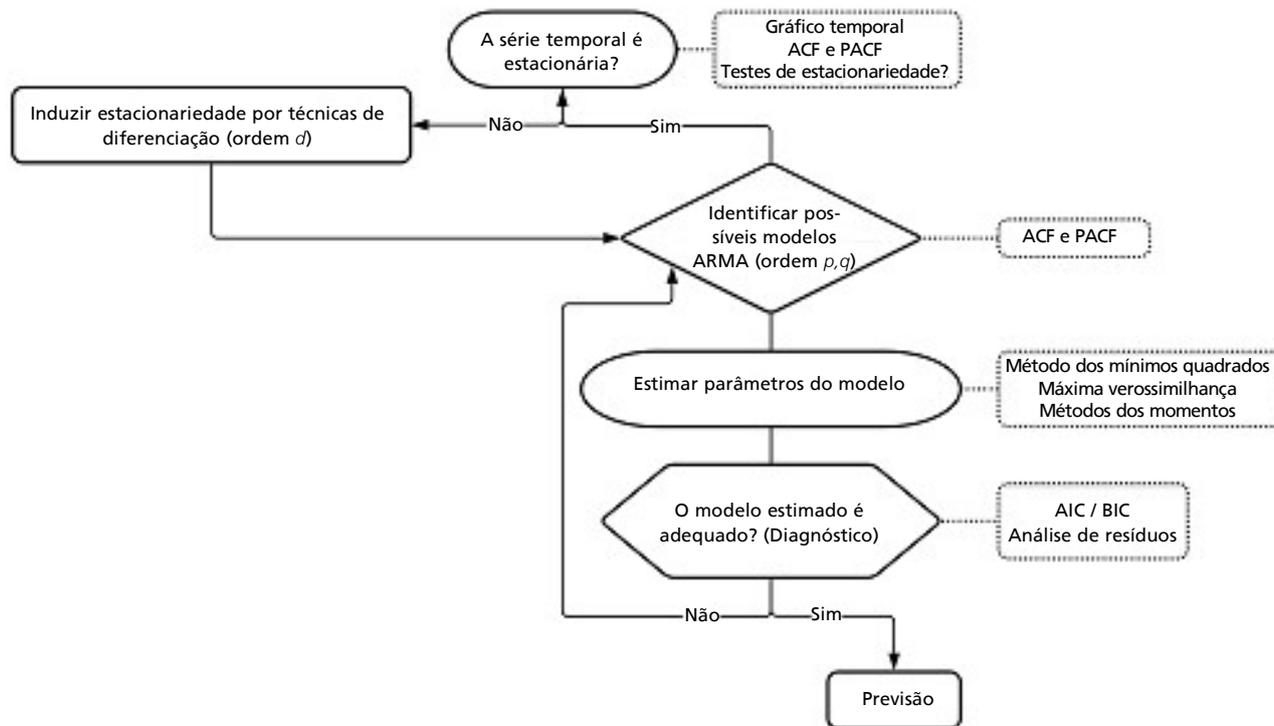
O processo de modelagem da série temporal pode ser sistematizado a partir do seguinte fluxograma (Figura 4).

Aplicações da análise de séries temporais na mortalidade infantil: possibilidades e limitações metodológicas

Atuar nos principais determinantes e condicionantes dos agravos em saúde requer estudos que apresentem modelagem robusta, como os de séries

Figura 4

Etapas da modelagem ARIMA (Box-Jenkins).



ACF = Função de Autocorrelação; PACF = Função de Autocorrelação Parcial; AIC = Critério de Informação de Akaike; BIC = Critério Bayesiano de Schwarz.

temporais, os quais permitem trazer evidências científicas que subsidiem a tomada de decisão em saúde.¹⁶

A incorporação de estudos de séries temporais na área da saúde surge da necessidade de planejar onde alocar os investimentos, objetivando impactar os principais indicadores epidemiológicos, como a mortalidade infantil e materna.⁴ Além disso, trata-se de uma modelagem prática ao permitir utilizar dados demográficos, epidemiológicos, ambientais e socioeconômicos de fontes oficiais.¹⁷

Por meio desse tipo de estudo, pode-se compreender o comportamento de variáveis durante um período, descobrir padrões atípicos na morbimortalidade e compreender a determinação das causas, além de ser útil para a avaliação do impacto produzido por intervenções em saúde.¹⁸

Prever cenários requer o uso de técnicas diversificadas, incluindo aquelas que avaliam as caracterís-

ticas do dado estudado. A modelagem ARIMA apresenta essa versatilidade frente às variáveis epidemiológicas, que são dinâmicas por natureza, por isso, é útil em séries estacionárias ou não.^{12,19} Outra vantagem metodológica, em detrimento de outras técnicas de predição, é a de construir modelos parcimoniosos por conterem uma quantidade reduzida de parâmetros (fase da estimação do ciclo iterativo) e as previsões obtidas podem ser bem precisas em diversos contextos.⁶

Apesar das potencialidades expostas, há algumas limitações, que podem surgir ao utilizar a modelagem de séries temporais. Uma delas, inerente a esse tipo de estudo, considera que exista relação linear entre os dados observados e dados passados, fato não visto com os dados reais, os quais apresentam relação complexa e não linear.⁷ A mortalidade infantil, por exemplo, possui determinação multifatorial resultante da interação de variáveis

biológicas, sociais, econômicas e assistenciais.²⁰

Outra limitação relaciona-se à qualidade dos dados disponíveis, pois esses interferem diretamente na modelagem.¹⁵ Dados disponíveis e confiáveis são fundamentais para fornecer informações necessárias para determinar políticas e delimitar os grupos vulneráveis. Por isso, é imprescindível a alimentação adequada dos sistemas de informação em saúde.²¹

Os estudos de série temporal, ainda que clássicos e imprescindíveis para a compreensão sobre a situação de um dado problema de saúde, por vezes, são considerados complexos e de difícil operacionalização, não sendo utilizados em toda sua potencialidade. Em especial à modelagem ARIMA, ainda existem dificuldades no manuseio e na aplicabilidade no campo da saúde devido à sua natureza matemática oriunda da área econômica. Trata-se de um modelo sofisticado, que requer uma aproximação com os aspectos teóricos e treinamentos em análise estatística para realizar todo o ciclo iterativo e a predição.⁶

A persistência como problema de saúde pública mundial torna as mortes infantis uma agenda consensual na saúde, sendo a modelagem ARIMA uma possibilidade metodológica para a gestão.^{4,20,22} Por meio dela, é possível delinear e analisar tendências em saúde mais prováveis, caracterizando-as como importantes dispositivos de planejamento de intervenções.^{4,22}

A utilização de modelos ARIMA na saúde infantil funcionaria como uma ferramenta que antecede e subsidia a prática assistencial. Sua incorporação no planejamento de ações estratégicas de impacto pode contribuir na redução de desfechos desfavoráveis no processo saúde-doença materno e infantil.⁴ Recentemente, alguns estudos utilizaram a modelagem ARIMA para expressar diferentes dimensões sobre a questão. A Tabela 1 apresenta alguns exemplos.

Apesar disso, há uma lacuna significativa na utilização de métodos estatísticos no processo decisório e formulador de políticas em saúde.^{1,23} Um exemplo é a incorporação dos estudos de séries temporais como ferramenta para a prática de gestão em saúde.^{1,23} Realizar as predições exige a superação de uma limitação já mencionada: dados coletados sistematicamente (oportunos e de qualidade) e acesso aos dados epidemiológicos, não só pelos tomadores de decisão. Essa é uma realidade na maioria dos países mais pobres, principalmente aqueles com dificuldades em consolidar os sistemas de informações de qualidade e instituir uma cultura de utilização de dados.²¹

Construir e fortalecer os sistemas de informações em saúde robustos permanece como um desafio. Em 2015, como desdobramento das discussões sobre os objetivos e as metas da Agenda 2030, foram propostos princípios-chave (foco, relevância, inovação, equidade, liderança e propriedade do país) para se alcançar e transpor modelagens robustas de monitoramento mundial dos indicadores em saúde materna e infantil, incluindo a modelagem ARIMA, para as realidades nacionais e locais.¹

O foco refere-se à definição de indicadores de saúde materna e infantil padronizados globalmente para tornar possível medi-los, monitorá-los e estimá-los em todos os subníveis nacionais de saúde.²⁴ O propósito é valorizar a produção de dados nacionais e locais, corresponsabilizando os atores nesses espaços na tomada de decisão. Para tanto, é necessário muni-los de capacidade técnica e fomentar tecnologias para superar a complexidade no manejo dos dados. Adicionalmente, requerem-se incentivos subjetivos, como o estímulo e as motivações para o uso dos dados, ao identificarem a potencialidade que a modelagem representa. Somada a esses princípios, agrega-se a perspectiva da inovação.¹ O modelo ARIMA, entre outros abordados, trata-se de uma ferramenta promissora na interpretação dos dados.

As predições que a modelagem ARIMA proporciona podem anteceder as ações estratégicas e atenuar a carga de morbimortalidade, fazendo das previsões um meio para aumentar as alternativas para a tomada de decisões. Mesmo diante das limitações inerentes e externas ao método discutido, suas potencialidades, aplicações e versatilidade sobressaem-se, configurando um método viável na prática em saúde.

Contribuição dos autores

Silva ABS, Frias PG, Vilela MBR, Bonfim CV e Araújo ACM contribuíram em todas as etapas de elaboração artigo: concepção, delineamento, redação do artigo e aprovação da versão final do artigo.

Tabela 1

Estudos de séries temporais utilizando a modelagem ARIMA na aplicabilidade de estudos sobre a mortalidade infantil.

Título	Autores (Ano de publicação)	Aplicabilidade do método
Change of Outcomes in Pediatric Intestinal Failure: Use of Time-Series Analysis to assess the evolution of an Intestinal Rehabilitation Program	Oliveira <i>et al.</i> ²⁵ (2016)	O estudo evidenciou a versatilidade do método ARIMA, expandindo seu campo de aplicação à clínica. Foi avaliada a eficácia das opções de tratamento na melhoria do quadro clínico da insuficiência intestinal neonatal e infantil, mostrando a tendência decrescente no desfecho primário (mortalidade).
Post Millennium Development Goals Prospect on Child Mortality in India: An Analysis Using Autoregressive Integrated Moving Averages (ARIMA) Model	De <i>et al.</i> ¹⁵ (2016)	A modelagem ARIMA foi utilizada para subsidiar o monitoramento dos Objetivos de Desenvolvimento Sustentável na Índia e antever as ações em saúde que devem ser priorizadas para se atingir as respectivas metas, bem como uma ferramenta crucial para a formulação de um planejamento geral de saúde nacional.
Predicting infant mortality in India using time series models	Singh e Singh ²⁶ (2018)	O método foi aplicado para prever a taxa de mortalidade infantil em alguns Estados da Índia. Permitiu comparar as respectivas séries históricas e as previsões.
Trend of Neonatal Mortality in Nigeria from 1990 to 2017 using Time Series Analysis	Usman <i>et al.</i> ¹⁴ (2019)	A modelagem ARIMA foi utilizada para investigar a tendência da incidência da mortalidade neonatal, realizando a previsão de 20 anos. Evidenciam-se um declínio consistente da taxa de mortalidade neonatal e que a política local de saúde neonatal está atuante e comprometida em reduzir as mortes neonatais.
Trends and future of maternal and child health in Bangladesh	Rajia <i>et al.</i> ²² (2019)	O método permitiu analisar a tendência dos indicadores de saúde materno-infantil. Com o cenário previsto das taxas, configura-se como uma potencial ferramenta para subsidiar a tomada de decisão da gestão local no monitoramento e as implicações de políticas públicas para atingir as metas propostas na Agenda 2030.
A mortalidade infantil no estado de São Paulo: uma previsão da taxa por meio da modelagem SARIMA	Chaib ²⁷ (2019)	A série histórica foi utilizada para descrever a evolução temporal da taxa de mortalidade infantil (1996-2016). A metodologia ARIMA aplicada permitiu evidenciar o comportamento sazonal da mortalidade infantil, uma vez que apresenta quedas em períodos específicos, com isso, identificando um modelo SARIMA. A previsão realizada evidencia a tendência de queda da taxa.
Forecasting Indian infant mortality rate: An application of autoregressive integrated moving average model	Mishra <i>et al.</i> ³ (2019)	A modelagem ARIMA permitiu traçar um panorama de cenário futuro a respeito da mortalidade infantil. A previsão foi referente ao período de nove anos (2017-2025), com tendência decrescente. O estudo traz uma potencialidade do método: a confiabilidade da predição ao estimar o período da amostra utilizando dados disponíveis. Depreende-se que é uma ferramenta estatística de grande utilidade na saúde, auxiliando no planejamento adequado de intervenções.
Modeling and Forecasting Infant Deaths in Zimbabwe using ARIMA Models	Nyoni e Nyoni ⁵ (2020)	O modelo foi aplicado para prever o número de mortes infantis em um país de capitalismo periférico que apresenta taxa de mortalidade elevada. Disponibilizar essas informações traria ganhos nos programas de intervenção em saúde locais de uma maneira mais eficaz.

Referências

- Marchant T, Boerma T, Diaz T, Huicho L, Kyobutungi C, Mershon CH, Schellenberg J, Somers K, Waiswa P. Measurement and accountability for maternal, newborn and child health: fit for 2030?. *BMJ Global Health*. 2020; 5: e002697.
- Szwarcwald CL, Leal MC, Almeida WS, Barreto ML, Frias PG, Theme Filha MM, Domingues RMSM, Franca EB, Gama SGN, Boccolini CS, Victora C. *Child Health in Latin America*. *Glob Public Health*. 2019; 1: 1-49.
- Mishra AK, Sahana C, Manikandan M. Forecasting Indian infant mortality rate: An application of autoregressive integrated moving average model. *J Family Community Med*. 2019; 26 (2): 123-6.
- Foreman KJ, Marquez N, Dolgert A, Fukutaki K, Fullman N, McGaughey M, Pletcher MA, Smith AE, Tang K, Yuan CW, Brown JC, Friedman J, He J, Heuton KR, Holmberg M, Patel DJ, Reidy P, Carter A, Cercy K, Chapin A, Douwes-Schultz D, Frank T, Goettsch F, Liu PY, Nandakumar V, Reitsma MB, Reuter V, Sadat N, Sorensen RJD, Srinivasan V, Updike RL, York H, Lopez AD, Lozano R, Lim SS, Mokdad AH, Vollset SE, Murray CJL. Forecasting life expectancy, years of life lost, and all cause and cause-specific mortality for 250 causes of death: reference and alternative scenarios for 2016–40 for 195 countries and territories. *Lancet*. 2018; 392: 2052-90.
- Nyoni SP, Nyoni T. Modeling and forecasting Infant deaths in Zimbabwe using ARIMA Models. *JournalNX - A Multidisciplinary Peer Reviewed Journal*. 2020; 6 (7): 142-51.
- Moretlin PA, Toloï CM. *Análise de Séries Temporais*. 3 ed. São Paulo: Blucher; 2018.
- Wang YW, Shen ZZ, Jiang Y. Comparison of ARIMA and GM (1,1) models for prediction of hepatitis B in China. *PLoS One*. 2018; 13(9): e0201987.
- Jaime AG. *Introducción al tratamiento de series temporales: Aplicación a las Ciencias de la Salud*. Madrid: Díaz de Santos, S.A.; 1994.
- Lima LMM, Vianna RPT, Moraes RM. Identificação das anomalias congênitas baseado em um modelo de decisão a partir de redes neurais artificiais. *J Health Inform*. 2019; 11 (1): 8-12.
- Ramalho AA, Andrade AM, Martins FA, Koifman RJ. Infant mortality trend in the city of Rio Branco, AC, 1999 to 2015. *Rev Saúde Pública*. 2018; 52: 33.
- Zheng A, Fang Q, Zhu Y, Jiang C, Jin F, Wang X. An application of ARIMA model for predicting total health expenditure in China from 1978-2022. *J Glob Health*. 2020; 10 (1): 010803.
- Liu Q, Li Z, Ji Y, Zia UH, Javaid A, Lu W, Wang J. Forecasting the seasonality and trend of pulmonary tuberculosis in Jiangsu Province of China using advanced statistical time-series analyses. *Infect Drug Resist*. 2019; 26 (12): 2311-22.
- Singh RK, Rani M, Bhagavathula AS, Sah R, Rodriguez-Morales AJ, Kalita H, Nanda C, Sharma S, Sharma YD, Rabban AA, Rahmani J, Kumar P. Prediction of the COVID-19 Pandemic for the Top 15 Affected Countries: Advanced Autoregressive Integrated Moving Average (ARIMA) Model. *JMIR Public Health Surveill*. 2020; 6(2).
- Usman A, Sulaiman MA, Abubakar I. Trend of Neonatal Mortality in Nigeria from 1990 to 2017 using Time Series Analysis. *J. Appl. Sci. Environ. Manage*. 2019; 23 (5): 865-9.
- De P, Sahu D, Pandey A, Gulati BK, Chandhiok N, Shukla AK, Mohan P, Mitra RG. Post Millennium Development Goals Prospect on Child Mortality in India: An Analysis Using Autoregressive Integrated Moving Averages (ARIMA) Model. *Health*. 2016; 8 (15): 1845-72.
- GBD 2015 Mortality and Causes of Death Collaborators. Global, regional, and national life expectancy, all-cause mortality, and cause-specific mortality for 249 causes of death, 1980-2015: a systematic analysis for the Global Burden of Disease Study 2015. *Lancet*. 2016; 388: 1459-1544.
- Slama A, Śliwczynski A, Woźnica J, Zdrolik M, Wiśnicki B, Kubajek J, Turzańska-Wieczorek O, Gozdowski D, Wierzbna W, Franek E. Impact of air pollution on hospital admissions with a focus on respiratory diseases: a time-series multi-city analysis. *Environ Sci Pollut Res*. 2019 26 (17) 16998–17009.
- Naderimaghani S, Jamshidi H, Khajavi A, Pishgar F, Ardani A, Larijani B, Mahmoudi Z, Jeddian A, Bahrami-Taghanaki HR, Farzadfar F. Impact of rural family physician program on child mortality rates in Iran: a time-series study. *Popul Health Metrics*. 2017; 15: 21.
- Li Y, Chen SF, Dong XJ, Zhao XJ. Prediction of cause-specific disability-adjusted life years in China from 2018 through 2021: a systematic analysis. *Public Health*. 2020; 180: 90-9.
- Maia LTS, Souza WV, Mendes ACG. Determinantes individuais e contextuais associados à mortalidade infantil nas capitais brasileiras: uma abordagem multinível. *Cad Saúde Pública*. 2020; 36 (2): e00057519.
- Frias PG, Szwarcwald CL, Moraes Neto OL, Leal MC, Cortez-Escalante JJ, Souza Junior PRB, Almeida WS, Silva Junior JB. Utilização das informações vitais para a estimação de indicadores de mortalidade no Brasil: da busca ativa de eventos ao desenvolvimento de métodos. *Cad Saúde Pública*. 2017; 33 (3): e00206015.
- Rajia S, Sabiruzzaman M, Islam MK, Hossain MG, Lestrel PE. Trends and future of maternal and child health in Bangladesh. *PLoS One*. 2019; 14 (3): e0211875.
- Oelke ND; Lima MADS; Acosta AM. Translação do conhecimento: traduzindo pesquisa para uso na prática e na formulação de políticas. *Rev Gaúcha Enferm*. 2015; 36 (3): 113-7.
- Allik M, Leyland A, Ichihara MYT, Dundas R. Creating small-area deprivation indices: a guide for stages and options. *J Epidemiol Community Health*. 2019; 74 (1): 20-5.
- Oliveira C, Silva NT, Stanojevic S, Avitzur Y, Bayoumi AM, Ungar WJ, Hoch JS, Wales PW. Change of Outcomes in Pediatric Intestinal Failure: Use of Time-Series Analysis

- to assess the evolution of an Intestinal Rehabilitation Program. *J Am Coll Surg*. 2016; 222 (6): 1180-8.
26. Singh MP, Singh RD. Predicting infant mortality in India using time series models. *Int J Statistics Appl Mathematics*. 2018; 3(5): 33-42.
27. Chaib DC. A mortalidade infantil no estado de São Paulo: uma previsão da taxa por meio da modelagem SARIMA. *Rev Econ UEGJ*. 2019; 15 (1): 43-52.

Recebido em 1 de Setembro de 2020

Versão final apresentada em 18 de Janeiro de 2021

Aprovado em 24 de Março de 2021