
QUAL A INFLUÊNCIA DO PROGRAMA MAIS MÉDICOS NAS TAXAS DE MORTALIDADE DOS BRASILEIROS? UMA ANÁLISE EM PAINEL ESPACIAL (2012 A 2022)

WHAT IS THE INFLUENCE OF THE MAIS MÉDICOS PROGRAM ON THE MORTALITY RATES OF BRAZILIANS? A SPATIAL PANEL ANALYSIS (2012 TO 2022)

Bruno Silva de Moraes Gomes (Prof. do IFRJ Campus Niterói e do PPGER/UFRRJ)

Rachel Alves da Silva (Mestre em economia PPGER/UFRRJ)

Área 11 – Mercado de trabalho, Demografia e Migração

Resumo

Este estudo analisa os impactos do Programa Mais Médicos (PMM) nas taxas de mortalidade em municípios brasileiros entre 2012 e 2022, utilizando modelos de painel espacial SAR, SEM e SDM. Considerando efeitos espaciais e a influência da pandemia de COVID-19, foram avaliadas mudanças nas taxas de mortalidade geral, infantil, de idosos, por causas evitáveis e por condições sensíveis à atenção primária. A pandemia elevou as taxas de mortalidade, exceto para mortalidade infantil e na primeira infância. Os resultados destacam a importância de considerar efeitos espaciais, revelando influência da pandemia no aumento da taxa de mortalidade total. O PMM impactou na redução da mortalidade infantil, na primeira infância e por causas evitáveis, reforçando seu papel na prevenção e controle de doenças por meio da presença médica e da Estratégia Saúde da Família.

Palavras-Chave: Programa Mais Médicos, distribuição de médicos, atenção primária, painel espacial.

Abstract

This study examines the impacts of the More Doctors Program (Programa Mais Médicos - PMM) on mortality rates in Brazilian municipalities between 2012 and 2022, using spatial panel models SAR, SEM, and SDM. Taking into account spatial effects and the influence of the COVID-19 pandemic, changes in overall mortality rates, as well as infant, elderly, preventable causes, and primary care-sensitive conditions were evaluated. The pandemic increased mortality rates, except for infant and early childhood mortality. The results underscore the importance of considering spatial effects, revealing the pandemic's influence on the rise in overall mortality rates. The PMM contributed to reducing infant, early childhood, and preventable mortality, reinforcing its role in disease prevention and control through the presence of physicians and the Family Health Strategy. The study provides robust evidence to guide public policies and program adjustments, considering the unequal distribution of health resources in Brazil.

Keywords: More Doctors Program, distribution of doctors, primary care, spatial panel.

Classificação JEL: I19, R23.

1. Introdução

A saúde pública no Brasil enfrenta desafios históricos e estruturais, particularmente na distribuição equitativa de profissionais de saúde entre as diferentes regiões do país. Regiões mais remotas e menos desenvolvidas frequentemente sofrem com a escassez de médicos, o que agrava as desigualdades no acesso aos cuidados de saúde e resulta em piores indicadores de saúde pública (Scheffer *et al.*, 2023). O Programa Mais Médicos (PMM), instituído em 2013, foi uma resposta governamental significativa para mitigar essas disparidades, promovendo a alocação de médicos em áreas com carência de profissionais de saúde (Girardi *et al.*, 2016).

Apesar da relevância do programa, existem lacunas na literatura que abordam sistematicamente seu impacto a longo prazo sobre as taxas de mortalidade nos municípios brasileiros. Dentre essas lacunas podemos citar: a precariedade de estudos quantitativos que analisem os impactos do PMM em diferentes taxas de mortalidade e, se existe espraiamento na presença dos médicos do PMM de um município nos municípios vizinhos.

Esta pesquisa visa preencher essas lacunas, proporcionando uma análise abrangente ao investigar se houve mudanças significativas nas taxas de mortalidade geral, infantil, de idosos, por causas evitáveis e por condições sensíveis à atenção primária entre 2012 e 2022 em função da presença dos médicos do PMM.

A metodologia adotada envolve a aplicação de técnicas de análise em painel espacial, que são particularmente adequadas para lidar com dados que possuem dependência espacial e heterogeneidade (Anselin, 1988). Este enfoque metodológico é justificado pela necessidade de se compreender os efeitos do PMM em um contexto espacialmente diferenciado, considerando a distribuição desigual dos recursos de saúde no Brasil.

As contribuições esperadas deste estudo são múltiplas. Primeiramente, espera-se fornecer evidências empíricas robustas sobre os impactos do PMM, oferecendo evidências para formuladores de políticas públicas. Em segundo lugar, nossos achados podem informar futuras intervenções e ajustes no programa, garantindo que ele continue a cumprir seus objetivos de maneira eficaz. Terceiramente, responde ao questionamento se considerar o espaço se faz importante nesse tipo de análise, e em caso de positivo, como o impacto pode influenciar na forma que o PMM de um município impacta os vizinhos. Por fim, ao explorar os efeitos a longo prazo do PMM, este estudo também contribuirá para a literatura existente sobre políticas de saúde pública e a distribuição de médicos em países em desenvolvimento.

Além dessa introdução, esse artigo conta com cinco seções. São elas: segunda seção, composta do referencial teórico; na terceira seção, apresenta-se a metodologia, a origem e composição da base de dados; enquanto na quarta seção visualiza-se os resultados; na última e derradeira seção demonstra-se as considerações finais; e por fim, relata-se as referências bibliográficas.

2. Referencial teórico

As políticas públicas de saúde no Brasil têm passado por expressivas transformações nas últimas décadas, com o Sistema Único de Saúde (SUS) desempenhando um papel fundamental na promoção da equidade e do acesso universal aos serviços de saúde. Criado pela Constituição Federal de 1988, o SUS representa um marco na consolidação do direito à saúde no país. Desde então, diversas iniciativas foram desenvolvidas para reduzir as desigualdades regionais na oferta de recursos e serviços de saúde (Paim *et al.*, 2011).

Uma dessas iniciativas é o Programa Mais Médicos (PMM), instituído em 2013, como resposta à escassez de médicos em áreas vulneráveis e regiões remotas do Brasil. O programa foi estruturado em três eixos estratégicos: provimento emergencial, investimento em infraestrutura da rede de serviços básicos de saúde e formação médica no Brasil. Esses eixos visam, respectivamente, suprir a falta de médicos em curto prazo, melhorar a infraestrutura das

unidades básicas de saúde (UBS) e ampliar a formação e qualificação de profissionais médicos de acordo com as necessidades sociais (Brasil, 2015).

O PMM se destacou por incluir médicos brasileiros e estrangeiros em sua composição, com significativa participação de médicos cubanos, que chegaram ao país por meio de um acordo de cooperação técnica firmado com a Organização Pan-Americana da Saúde (OPAS) (Brasil, 2017). Esse acordo contribuiu para a inserção de médicos em locais historicamente negligenciados, promovendo maior equidade e acesso à atenção básica. Até 2017, os médicos cubanos representavam mais de 60% dos profissionais do programa, reforçando o papel do PMM no enfrentamento das desigualdades na distribuição de recursos humanos em saúde (Brasil, 2017).

Com o objetivo central de fortalecer a atenção primária à saúde, o PMM buscou reduzir barreiras ao acesso aos serviços de saúde e elevar a qualidade do atendimento. Entre seus resultados iniciais, destacam-se a ampliação da cobertura em áreas carentes, o aumento no número de consultas médicas realizadas e a promoção da justiça social por meio de uma distribuição mais equitativa dos profissionais de saúde (Macinko; Harris, 2015; Brasil, 2015).

Contudo, o programa enfrentou desafios ao longo de sua implementação, incluindo a saída dos médicos cubanos em 2018, o que evidenciou, naquele momento, a dependência do programa em relação a essa força de trabalho. Mesmo assim, o PMM permanece como um marco na política pública de saúde brasileira, sendo adaptado e reformulado para atender às demandas emergentes e de longo prazo do sistema de saúde do país. A mais recente legislação, representada pela Lei nº 14.621/2023, reforçou o compromisso com a qualificação da formação médica e com a continuidade do programa, evidenciando sua relevância na construção de um sistema de saúde mais inclusivo e eficiente (Brasil, 2024c).

O relatório "*Primary care: an increasingly important contributor to effectiveness, equity, and efficiency of health services*" da Spanish Association of Public Health and Healthcare (SESPAS) de 2012 oferece evidências adicionais sobre a importância da atenção primária na melhoria dos indicadores de saúde. Segundo o relatório, sistemas de saúde orientados para a atenção primária são mais eficazes, equitativos e eficientes. A universalidade do acesso financeiro, a distribuição equitativa de recursos, a abrangência dos serviços e a coordenação dos cuidados são características chave que contribuem para melhores resultados de saúde (Starfield, 2012).

O relatório também enfatiza que a presença de médicos de atenção primária está associada à redução das taxas de mortalidade infantil e à melhoria geral dos indicadores de saúde. Isso reforça a importância de políticas de saúde que aumentem a disponibilidade e a qualidade dos serviços de atenção primária (Starfield, 2012).

Programas de distribuição de médicos podem ter impactos significativos não apenas na saúde da população, mas também em aspectos socioeconômicos. A presença de médicos em comunidades carentes tem sido associada a melhorias na saúde pública, redução das taxas de mortalidade e aumento da qualidade de vida (Dussault; Franceschini, 2006). Além disso, tais programas podem contribuir para o desenvolvimento local, ao promover a fixação de profissionais qualificados e estimular a economia local (Remes; Wilson; Ramdorai, 2020).

O impacto do Programa Mais Médicos (PMM) também tem sido investigado com relação a diferentes indicadores de saúde, fornecendo uma base robusta para a análise de sua eficácia. Fontes *et al.* (2018) avaliaram o impacto do PMM na provisão de médicos e suas consequências na hospitalização por condições sensíveis à atenção primária, utilizando métodos de diferenças-em-diferenças combinados com pareamento por escore de propensão. Seus resultados indicam uma redução significativa nas admissões hospitalares em municípios tratados, especialmente a partir do segundo ano do programa.

Mattos e Mazetto (2019), por sua vez, exploraram os efeitos de curto prazo do PMM em indicadores de saúde, demonstrando um aumento no atendimento dos serviços de saúde e

uma redução nas hospitalizações gerais. No entanto, eles não observaram um impacto significativo nas taxas de mortalidade, sugerindo que melhorias na qualidade do atendimento podem não se traduzir imediatamente em reduções na mortalidade.

Francesconi *et al.* (2020) utilizaram modelos de regressão com efeitos fixos longitudinais para prever o impacto de diferentes cenários de cobertura do PMM e da Estratégia Saúde da Família (ESF) nas taxas de mortalidade infantil e de menores de 70 anos por condições sensíveis à atenção primária. Eles concluíram que a redução da cobertura do PMM, especialmente devido à retirada dos médicos cubanos, poderia resultar em aumentos significativos nas taxas de mortalidade evitável.

Özçelik *et al.* (2020) analisaram o impacto do PMM nas hospitalizações por condições cardiovasculares sensíveis à atenção primária, utilizando métodos de pareamento exato e diferenças-em-diferenças. Eles descobriram uma relação inversa entre o PMM e as hospitalizações por doenças cerebrovasculares, com efeitos mais pronunciados a partir do quarto ano de implementação do programa, embora não tenham encontrado evidências de reduções nas hospitalizações por hipertensão.

Os impactos do programa também foram estudados por Dos Santos *et al.* (2020), que os examinou em várias medidas de saúde, incluindo mortalidade infantil e mortalidade geral. Utilizando pareamento por escore de propensão com diferenças-em-diferenças, eles observaram melhorias significativas na mortalidade infantil e uma redução menor, mas significativa, na mortalidade geral, destacando a importância da presença de médicos em áreas remotas.

Hone *et al.* (2020) investigaram a relação entre a expansão da Estratégia Saúde da Família (ESF) e a mortalidade evitável no Brasil, destacando a importância da governança local de saúde. Utilizando modelos de regressão longitudinal com efeitos fixos, eles identificaram que a expansão da cobertura da eSF estava associada a uma redução de 6,8% nas taxas de mortalidade evitável. Além disso, encontraram que os municípios com melhores índices de governança em saúde apresentaram reduções mais acentuadas na mortalidade evitável, sugerindo que o fortalecimento da governança local é crucial para melhorar a efetividade dos serviços de saúde e os resultados de saúde em sistemas de saúde descentralizados.

Malta *et al.* (2024) analisaram as tendências de mortalidade evitável no Brasil de 1990 a 2019, utilizando dados do Global Burden of Disease Study. Eles encontraram uma redução significativa nas taxas de mortalidade evitável em todo o país, de 343,90 por 100.000 habitantes em 1990 para 155,80 por 100.000 habitantes em 2019. As maiores reduções foram observadas em doenças infecciosas, condições maternas e neonatais, e doenças crônicas não transmissíveis. A análise também revelou que as taxas de mortalidade evitável diminuíram em todos os estados brasileiros, com uma correlação alta entre as mortes evitáveis e os índices sociodemográficos (SDI), sugerindo que melhorias na infraestrutura de saúde e saneamento básico foram fundamentais para esses avanços.

Barufi, Haddad e Paez (2020) realizaram uma análise espacial em painel sobre a mortalidade infantil no Brasil entre 1980 e 2000, identificando os fatores que influenciam a distribuição da referida mortalidade. Utilizando um modelo de painel espacial com efeitos fixos e uma estrutura de autocorrelação de erros espaciais, os autores observaram que a infraestrutura de saúde e medidas de política social, como a melhoria na educação, estão associadas à redução das taxas de mortalidade infantil. Além disso, efeitos de transbordamento relacionados à infraestrutura de saúde e às instalações de água e saneamento implicam benefícios regionais além da unidade de análise, destacando a importância de abordagens espaciais na formulação de políticas públicas.

A mortalidade é amplamente utilizada como um indicador chave de saúde pública, refletindo tanto a eficácia dos serviços de saúde quanto as condições socioeconômicas de uma população (Murray e Lopez, 1997). Este estudo foca em diversas taxas de mortalidade, incluindo mortalidade geral, infantil, de idosos, por causas evitáveis e por condições sensíveis

à atenção primária. Cada uma dessas taxas oferece uma perspectiva única sobre o impacto das intervenções de saúde e a efetividade do PMM em particular.

A aplicação de métodos econométricos para analisar dados de saúde pública permite uma compreensão mais precisa dos efeitos das políticas de saúde. Técnicas como a análise em painel espacial são particularmente adequadas para estudos que envolvem dados com dependência espacial e temporal (Anselin, 1988). Estas técnicas permitem controlar por variáveis não observadas que podem influenciar os resultados, proporcionando estimativas mais robustas dos efeitos das intervenções de saúde (Elhorst, 2014).

A pandemia de COVID-19 (2020-2022) introduziu desafios adicionais para o sistema de saúde brasileiro, influenciando potencialmente os resultados das políticas de saúde em análise (Aquino *et al.*, 2020). Ademais, segundo Macedo *et al.* (2023), a pandemia funcionou como uma catástrofe sanitária e traumática, redimensionando o processo de trabalho e contribuindo para a sobrecarga, conflitos, medo, sentimento de desamparo e sofrimento psíquico entre os profissionais. Os médicos relataram problemas estruturais nas unidades de saúde, falta de recursos, burocracia e interferências políticas como fatores agravantes. Diante disso, este estudo controlará possíveis vieses gerados pela pandemia para assegurar que os resultados reflitam com mais precisão o impacto do PMM.

É importante destacar que, além do pequeno número de artigos publicados que investigam a relação entre o Programa Mais Médicos (PMM) e taxas de mortalidade, não foram encontrados registros de artigos que utilizem a metodologia de análise de painel espacial para essa finalidade. Essa abordagem metodológica diferencia o presente estudo, assim como o período no qual está debruçado, permitindo uma análise mais robusta e precisa dos efeitos do PMM sobre as diversas taxas de mortalidade nos municípios brasileiros ao longo de 10 anos do programa

3. Metodologia

A base de dados utilizada é formada por dados provenientes de diversas fontes oficiais como Instituto Brasileiro de Geografia e Estatística (IBGE), Ministério da Saúde, Agência Nacional de Saúde Suplementar (ANS), Sistema Nacional de Informações sobre Saneamento (SNIS), DATASUS e Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP) e fornecem informações sobre economia, estrutura de saúde, infraestrutura de saneamento básico e educação dos municípios brasileiros.

A Tabela 1 apresenta a descrição das variáveis utilizadas, estatísticas descritivas, bem como suas fontes correspondentes. Todas as variáveis foram obtidas para o período de 2012 a 2022. Ademais, após o tratamento dos dados e adequação aos dados espaciais disponíveis, foram mantidos 5035 municípios (unidades espaciais), totalizando 55385 observações. O software utilizado para a análise dos dados foi o Stata.

A base de dados consiste em um conjunto de observações coletadas ao longo do tempo e através do espaço. Dada essa característica, é necessário utilizar um método de análise econométrica que seja apropriado para este contexto, uma vez que eventos externos ocorreram no período analisado, como a Pandemia da COVID-19 e a saída dos médicos cubanos do PMM em 2018. Assim, verificada autocorrelação espacial, justifica-se a escolha por modelos de painel espacial em detrimento de outros modelos econométricos.

Os dados em painel, também conhecidos como dados longitudinais, representam uma forma robusta de análise estatística que combina as dimensões temporal e espacial ao acompanhar as mesmas unidades em corte transversal, como famílias, empresas ou estados, ao longo do tempo. Esses dados permitem uma observação detalhada das mudanças e tendências que ocorrem dentro de uma unidade específica, permitindo análises mais profundas sobre a dinâmica de seu comportamento.

A importância dos dados em painel reside em sua capacidade de tratar a heterogeneidade das unidades observadas de maneira explícita, permitindo que variáveis específicas ao sujeito sejam consideradas nas análises. Essa abordagem é vantajosa por proporcionar um conjunto de dados mais informativo, com maior variabilidade e menos colinearidade entre as variáveis, resultando em mais graus de liberdade e maior eficiência estatística (Gujarati; Porter, 2011; Almeida, 2012).

A econometria espacial é uma subárea da econometria que lida com a interação espacial (autocorrelação espacial) e a estrutura espacial (heterogeneidade espacial) em modelos de regressão para dados em seção cruzada e painel (Paelinck e Klaassen, 1979; Anselin, 1988). Essa abordagem é particularmente útil quando a localização geográfica das observações é relevante, como em estudos de ciência regional, economia urbana, economia imobiliária e geografia econômica (Anselin, 2001).

Para entender a econometria espacial, é essencial compreender dois conceitos fundamentais: dependência espacial e heterogeneidade espacial. A dependência espacial refere-se à correlação entre as variáveis observadas em diferentes locais geográficos. Essa correlação pode ser expressa formalmente pela condição de momento:

$$\text{cov}(y_i, y_j) = E[y_i y_j] - E[y_i] \cdot E[y_j] \neq 0, \quad \text{para } i \neq j \quad (2.1)$$

Onde i, j são as observações em diferentes locais e y_i é o valor da variável aleatória de interesse nessa localização (Anselin, 2001). A dependência espacial pode ser modelada de três maneiras principais: especificando uma forma funcional para um processo estocástico espacial, modelando diretamente a estrutura de covariância ou estimando-a de forma não paramétrica.

Os modelos de regressão espacial podem incorporar dependência espacial de duas maneiras distintas: como uma variável adicional na forma de uma variável dependente defasada espacialmente (Wy) ou na estrutura do erro. O primeiro é conhecido como modelo de defasagem espacial, apropriado quando o interesse está na avaliação da interação espacial. O segundo, o modelo de erro espacial, é utilizado para corrigir a influência potencialmente tendenciosa da autocorrelação espacial nos dados (Anselin, 1988).

A heterogeneidade espacial, por sua vez, refere-se às variações nas relações econômicas entre diferentes unidades espaciais que não podem ser explicadas apenas pela dependência espacial. Elhorst (2014) menciona que uma forma de lidar com a heterogeneidade espacial é incluir efeitos fixos ou aleatórios que capturam essas variações específicas de cada unidade espacial.

A extensão do modelo geral para dados *cross section* (2.2), para dados em painel resulta em modelos que capturam tanto efeitos espaciais quanto temporais:

$$Y_t = \rho WY_t + \alpha i_N + X_t \beta + WX_t \theta + u_t \quad (2.3a)$$

$$u_t = \lambda W u_t + \epsilon_t \quad (2.3b)$$

onde Y_t é o vetor das variáveis dependentes no tempo t . ρ é o coeficiente autorregressivo espacial que captura os efeitos de interação endógena entre as variáveis dependentes, enquanto W é a matriz de pesos espaciais que define a estrutura de vizinhança entre as unidades espaciais. α é um vetor de constantes, e i_N é um vetor com dimensão N , representando os efeitos fixos. X_t é a matriz das variáveis independentes no tempo t , com β sendo o vetor dos coeficientes associados a essas variáveis. $WX_t \theta$ captura os efeitos de interação exógena entre as variáveis independentes, com θ sendo o vetor de coeficientes desses efeitos. u_t representa os termos de erro no tempo t , que são modelados como um processo autorregressivo espacial com coeficiente λ , e ϵ_t é o termo de erro idiossincrático. Essas equações fornecem uma estrutura abrangente para modelar dependências espaciais em dados de painel (Elhorst, 2014).

Tabela 1 - Descrição das variáveis utilizadas

Variável	Descrição	Média	Desvio Padrão	Mín.	Máx.	Fonte
PIB	Produto Interno Bruto per capita municipal	23233.14	26575.82	301.6	920834	IBGE
d_pmm	<i>Dummy</i> que indica os municípios que receberam médicos do PMM (1 para municípios que receberam o PMM e 0 caso contrário)	-	-	-	-	Ministério da Saúde
postpol	<i>Dummy</i> que indica o período de mudança na política do PMM (1 para ano >=2018 e 0 caso contrário)	-	-	-	-	-
pandemia	<i>Dummy</i> que indica os anos de enfrentamento da Pandemia da COVID-19 (1 para ano >=2020 & ano <=2022 e 0 caso contrário)	-	-	-	-	-
plano	Percentual da população coberto por plano de saúde suplementar	8.362	12.313	0	97.31	ANS
água	Percentual da população atendida por água encanada	73.249	27.176	0	100	SNIS
esgoto	Percentual da população atendida por rede de esgoto sanitário	23.703	32.834	0	100	SNIS
rh_sus	Número de profissionais (exceto médicos) que atuam no SUS por 100 mil habitantes	1082.49	453.853	0	11111.11	DATASUS
med_sus	Número de médicos que atuam no SUS por 100 mil habitantes	71.124	69.883	0	3256.791	DATASUS
esf	Número de equipes de saúde da família por 100 mil habitantes	5.224	9.106	0	93.41429	DATASUS
educ_f	Taxa de Distorção Idade-Série Total no ensino fundamental	18.371	10.438	0	64.4	INEP
educ_m	Taxa de Distorção Idade-Série Total no ensino médio	29.064	14.097	0	84.8	INEP
Mort_geral	Taxa de mortalidade geral por 100 mil habitantes	430.186	275.789	0	5890.361	DATASUS
Mort_idosos	Taxa de mortalidade de idosos por 100 mil habitantes (faixa etária a partir de 60 anos)	267.029	189.610	0	3005.394	DATASUS
Mort_inf	Taxa de mortalidade infantil por 100 mil habitantes (faixa etária 0 a 1 ano)	5.516	12.197	0	273.3027	DATASUS
Mort_prim_inf	Taxa de mortalidade na primeira infância por 100 mil habitantes (faixa etária 1 a 6 anos)	7.048	14.135	0	321.3326	DATASUS
Mort_ca_evit	Taxa de mortalidade por causas evitáveis por 100 mil habitantes (causas definidas por Malta <i>et al</i> , 2010)	232.237	154.621	0	4388.27	DATASUS
Mort_csap	Taxa de mortalidade por condições sensíveis à atenção primária por 100 mil habitantes (causas definidas em Portaria N° 221 de 17/04/2008 do MS)	68.851	61.285	0	1171.89	DATASUS

Fonte: Elaboração própria.

A partir da imposição de restrições em um ou mais parâmetros no modelo espacial geral, é possível obter diferentes modelos espaciais. Os principais modelos econométricos espaciais trabalhados na literatura são os modelos de defasagem espacial que possuem apenas um tipo de efeito de interação, conhecidos como Modelo Espacial Autorregressivo (*Spatial Autoregressive Model* - SAR) e o Modelo de Erro Espacial (*Spatial Error Model* – SEM). Enquanto o modelo SAR capta efeitos de interação endógena, ou seja, incorpora a dependência espacial através de uma variável dependente espacialmente defasada, o SEM considera a autocorrelação espacial nos termos de erro (efeitos de interação exógena) (Anselin, 2011; Elhorst, 2014).

O Modelo de Durbin Espacial (*Spatial Durbin Model* – SDM), exclui o termo de erro com autocorrelação espacial e incorpora ambos os efeitos de interação, endógeno e exógeno (Elhorst, 2011). O modelo SDM pode ser obtido igualando a zero o coeficiente de correlação espacial λ presente no modelo geral (2.3), ficando da seguinte forma:

$$Y_t = \rho WY_t + \alpha i_N + X_t\beta + WX_t\theta + \epsilon_t \quad (2.4)$$

O modelo SAR (*Spatial Autoregressive Model*) incorpora a dependência espacial através de uma variável dependente defasada espacialmente e é obtida ao igualar a zero o vetor dos coeficientes que mede os efeitos de interação exógena entre as variáveis independentes θ do modelo SDM (Elhorst, 2014). Dessa forma, a especificação do modelo é:

$$Y_t = \rho WY_t + \alpha i_N + X_t\beta + \epsilon_t \quad (2.5)$$

O modelo SEM (*Spatial Error Model*), por sua vez, considera a autocorrelação espacial nos termos de erro. O modelo pode ser obtido ao igualar a $-\delta\beta$ o vetor dos coeficientes que mede os efeitos de interação exógena entre as variáveis independentes θ do modelo SDM. A especificação do modelo SEM é:

$$Y_t = \alpha i_N + X_t\beta + u \quad (2.6a)$$

$$u = \lambda Wu_t + \epsilon_t \quad (2.6b)$$

(se $\theta = -\rho\beta$, então $\lambda = \rho$)

A estimação de modelos espaciais utiliza métodos como Máxima Verossimilhança (ML), Máxima Verossimilhança Quase-Máxima (QML), Variáveis Instrumentais (IV) / Método dos Momentos Generalizados (GMM) e abordagens Bayesiana de Monte Carlo via Cadeia de Markov (MCMC). A escolha do método adequado depende das características dos dados e das suposições do modelo. A ML é amplamente utilizada devido à sua capacidade assintótica e será utilizado neste estudo.

No âmbito da análise de painel espacial, a escolha dos modelos econométricos adequados é crucial para obter resultados robustos e significativos. Conforme indicado na literatura de Elhorst (2014), os modelos espaciais SAR (*Spatial Autoregressive Model*), SEM (*Spatial Error Model*) e SDM (*Spatial Durbin Model*) e SAC (*Spatial Autoregressive Combined Model*) são comumente aplicados por economistas. No entanto, a escolha dos modelos a serem utilizados em uma análise empírica deve considerar não apenas a robustez teórica, mas também a viabilidade prática de sua aplicação.

Este estudo seguirá as estratégias de LeSage; Pace (2009) e Elhorst (2010) para a seleção de modelos cujos procedimentos iniciam-se a partir do ajustamento do modelo SDM e posterior aplicação de testes para verificar qual dentre as especificações SAR, SEM ou SDM é a mais adequada.

Antes da aplicação dos modelos espaciais, adotou-se uma formulação que inclui as variáveis descritas na Tabela 1, desconsiderando a possibilidade de dependência espacial. Neste caso, o modelo de regressão tem a seguinte especificação:

$$\text{Mort}_{it} = \beta_0 + \beta_1.\text{Pandemia}_{it} + \beta_2.d_pmm_{it} + \beta_3.\text{Postpol}_{it} + \beta_4.\text{PIB}_{it} + \beta_5.\text{plano}_{it} + \beta_6.\text{água}_{it} + \beta_7.\text{esgoto}_{it} + \beta_8.\text{rh_sus}_{it} + \beta_9.\text{med_sus}_{it} + \beta_{10}.\text{esfi}_{it} + \beta_{11}.\text{educ_fi}_{it} + \beta_{12}.\text{educ_mi}_{it} + \alpha_i + u_{it} \quad (2.7)$$

onde cada observação representa a informação relativa à variável considerada para o município i , no ano t . Desta forma, a base de dados é formada por observações dos municípios brasileiros entre os anos de 2012 e 2022, perfazendo um total de nT observações.

Este modelo foi aplicado separadamente para as diferentes variáveis dependentes, a saber: mortalidade geral, mortalidade de idosos, mortalidade infantil, mortalidade na primeira infância, mortalidade por causas evitáveis e mortalidade por condições sensíveis à atenção primária. As análises foram realizadas utilizando modelos *pooled*, efeitos fixos e efeitos aleatórios para captar as variações específicas de cada município ao longo do tempo. Em seguida, foram aplicados o teste Multiplicador de Lagrange de Breusch e Pagan (Teste LM), que compara os resultados do modelo *pooled* aos de efeitos aleatórios, e o teste de Hausman, que compara os resultados do modelo de efeitos fixos aos de efeitos aleatórios, para determinar o modelo mais adequado para cada caso.

4. Resultados e discussão

A Tabela 2 apresenta os resultados da estimação sem efeitos espaciais, conforme especificação (2.7). Os erros padrão encontram-se entre parênteses.

Para todas as variáveis de mortalidade analisadas com relação ao modelo de efeitos aleatórios, os testes de Multiplicador Lagrangiano de Breusch-Pagan resultaram em valores p muito baixos (0.0000), indicando que o modelo de efeitos aleatórios é preferível ao modelo *pooled*. Portanto, a variância dos efeitos aleatórios não é zero, e a inclusão desses efeitos é significativa em cada um dos modelos. No entanto, ao aplicar o teste de Hausman após a estimação por efeitos fixos e efeitos aleatórios para todas as taxas de mortalidade os resultados indicaram que se deve rejeitar a hipótese nula ($\text{Prob} > \chi^2 = 0.0000$), indicando que o modelo de efeitos fixos é mais adequado para todas as análises se comparado com o modelo de efeitos aleatórios.

Os resultados do modelo de efeitos fixos destacaram que a pandemia da COVID-19 teve um impacto positivo e estatisticamente significativo sobre as taxas de mortalidade geral, de idosos, por causas evitáveis e por causas sensíveis à atenção primária, indicando um aumento na mortalidade durante esse período. A variável *postpol*, que captura mudanças nas políticas do Programa Mais Médicos (PMM), também apresentou efeitos significativos. Para a mortalidade geral e de idosos, o impacto foi positivo, sugerindo que alterações nas políticas do PMM podem ter contribuído para o aumento dessas taxas. No caso da mortalidade infantil e na primeira infância, *postpol* teve um efeito negativo e significativo, indicando que mudanças nas políticas do programa podem estar associadas à redução desses tipos de mortalidade. Para a mortalidade por causas evitáveis e sensíveis à atenção primária, *postpol* também apresentou impactos positivos, reforçando a influência das mudanças políticas na dinâmica da mortalidade.

A presença de médicos do PMM (*d_pmm*) mostrou efeitos variados. Para a mortalidade geral e de idosos, o impacto foi positivo e significativo, possivelmente refletindo uma maior detecção de casos ou outros fatores não controlados. Já para a mortalidade infantil, na primeira infância e por causas sensíveis à atenção primária, *d_pmm* apresentou efeitos negativos e significativos, sugerindo que a atuação desses profissionais pode ter contribuído para a redução desses tipos de mortalidade. No caso da mortalidade por causas evitáveis, *d_pmm* foi associada a um aumento, possivelmente indicando desafios específicos em municípios atendidos pelo programa.

A variável *esf* (equipes de Saúde da Família) mostrou um efeito negativo e significativo em quase todas as análises, incluindo mortalidade geral, de idosos, por causas evitáveis e por causas sensíveis à atenção primária. Isso reforça a importância da atuação das equipes de Saúde da Família na redução das taxas de mortalidade, destacando seu papel crucial na melhoria dos indicadores de saúde.

Em seguida, os testes de Moran I foram aplicados para avaliar a existência de autocorrelação espacial das taxas de mortalidade em diferentes categorias ao longo dos anos de 2012 a 2022, conforme resultados apresentados na Tabela 3.

Utiliza-se, neste estudo, a matriz de contiguidade do tipo *rainha*, a qual considera como vizinhos todos os municípios que compartilham qualquer tipo de fronteira — seja ela linear ou apenas em um ponto — com o município em análise, caracterizando, assim, os vizinhos limítrofes diretos. Em diversos contextos relacionados à saúde pública, as condições sanitárias de uma localidade podem não ser independentes das condições observadas nos municípios adjacentes. Um exemplo ilustrativo é o caso de municípios com altas taxas de doenças transmissíveis, os quais podem influenciar diretamente as regiões vizinhas em função da mobilidade populacional, de fatores ambientais compartilhados, de políticas públicas comuns ou da integração dos serviços de saúde.

A adoção da matriz de contiguidade *rainha* permite capturar, de forma mais abrangente, essa dependência espacial entre as unidades geográficas. Tal abordagem é especialmente relevante em análises de saúde pública, uma vez que a alocação de recursos e a formulação de políticas de intervenção frequentemente demandam uma compreensão regionalizada dos padrões de saúde. Nesse sentido, o uso dessa matriz pode subsidiar decisões mais eficazes, como a distribuição otimizada de vacinas, medicamentos ou estratégias preventivas, cujos efeitos podem se estender além das fronteiras administrativas dos municípios (Pinto e Andrade, 2021; Souza e Silva, 2020).

Os resultados dos testes de I de Moran para todas as variáveis dependentes analisadas mostram uma autocorrelação espacial positiva significativa ao longo dos anos de 2012 a 2022. Os erros padrão encontram-se entre parênteses na tabela. Isso indica que as taxas de mortalidade em diferentes categorias estão espacialmente correlacionadas, com áreas geográficas próximas exibindo padrões semelhantes de mortalidade. Os resultados ressaltam a importância de considerar a dimensão espacial neste tipo de análise, pois fatores geográficos e regionais desempenham um papel crucial na distribuição das taxas de mortalidade.

Verificada a autocorrelação espacial, foram aplicados modelos espaciais SAR, SEM e SDM. Após a estimação dos modelos, foram aplicados testes descritos em LeSage e Pace (2009), Elhorst (2010) e Belloti, Hughes e Mortaria (2017) para comparar o modelo SDM (Spatial Durbin Model) com os modelos SAR (Spatial Autoregressive Model) e SEM (Spatial Error Model). Os testes verificaram se as defasagens espaciais das variáveis explicativas no SDM eram iguais a zero (comparando SDM com SAR) ou proporcionais aos coeficientes das variáveis principais (comparando SDM com SEM). Para todas as análises de mortalidade, os resultados rejeitaram as hipóteses nulas, indicando que pelo menos uma defasagem espacial não é zero e que as defasagens não são proporcionais aos coeficientes principais. Isso sugere que o modelo SAR, que não inclui defasagens espaciais nas variáveis explicativas, e o SEM, que assume proporcionalidade, podem não ser adequados. Portanto, os testes apontaram o modelo SDM como o mais indicado para analisar os dados entre os três modelos avaliados.

A Tabela 4 apresenta os resultados do modelo SDM.

Tabela 2 - Resultados das estimações por MQO dos modelos *pooled*, efeitos fixos e efeitos aleatórios

Variáveis	Mortalidade geral			Mortalidade de idosos			Mortalidade infantil			Mortalidade na primeira infância			Mortalidade por causas evitáveis			Mortalidade por condições sensíveis à atenção primária		
	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios	<i>Pooled</i>	Efeitos fixos	Efeitos aleatórios
pandemia	60.845 *** (1.500)	62.510 *** (1.495)	60.845 *** (1.500)	42.514 *** (1.085)	43.477 *** (1.083)	42.514 *** (1.085)	-0.657 *** (0.095)	-0.501 *** (0.095)	-0.657 *** (0.095)	-0.725 *** (0.114)	-0.549 *** (0.114)	-0.725 *** (0.114)	31.129 *** (0.998)	32.624 *** (0.996)	31.129 *** (0.998)	2.625 *** (0.452)	3.238 *** (0.453)	2.625 *** (0.452)
postpol	14.194 *** (1.611)	12.728 *** (1.606)	14.194 *** (1.611)	19.748 *** (1.165)	18.700 *** (1.164)	19.748 *** (1.165)	-1.516 *** (0.102)	-1.511 *** (0.102)	-1.516 *** (0.102)	-1.891 *** (0.123)	-1.881 *** (0.122)	-1.891 *** (0.122)	4.351 *** (1.071)	3.200 ** (1.071)	4.351 *** (1.071)	0.910 * (0.485)	0.290 (0.486)	0.910 * (0.485)
d_pmm	6.297 *** (1.155)	5.429 *** (1.151)	6.297 *** (1.155)	6.753 *** (0.835)	6.360 *** (0.834)	6.753 *** (0.835)	-0.699 *** (0.073)	-0.882 *** (0.073)	-0.699 *** (0.073)	-0.811 *** (0.088)	-1.053 *** (0.088)	-0.811 *** (0.088)	2.494 ** (0.767)	1.612 ** (0.767)	2.494 ** (0.767)	-0.263 (0.347)	-0.628 * (0.349)	-0.263 (0.347)
PIB	0.000 *** (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 *** (0.000)	0.000 (0.000)	0.000 (0.000)	0.000 (0.000)
plano	0.429 *** (0.079)	0.010 (0.081)	0.429 *** (0.079)	0.231 *** (0.057)	-0.039 (0.059)	0.231 *** (0.057)	0.032 *** (0.005)	0.012 ** (0.005)	0.032 *** (0.005)	0.037 *** (0.006)	0.014 ** (0.006)	0.037 *** (0.006)	0.367 *** (0.052)	0.002 (0.054)	0.367 *** (0.052)	0.171 *** (0.023)	0.028 (0.025)	0.171 *** (0.023)
água	0.415 *** (0.029)	0.330 *** (0.029)	0.415 *** (0.029)	0.310 *** (0.021)	0.250 *** (0.021)	0.310 *** (0.021)	-0.003 (0.002)	-0.005 ** (0.002)	-0.003 (0.002)	-0.002 (0.002)	-0.004 * (0.003)	-0.002 (0.003)	0.310 *** (0.019)	0.243 *** (0.019)	0.310 *** (0.019)	0.040 *** (0.009)	0.006 (0.009)	0.040 *** (0.009)
esgoto	0.108 ** (0.035)	-0.099 ** (0.037)	0.108 ** (0.035)	0.082 ** (0.025)	-0.058 ** (0.027)	0.082 ** (0.025)	0.005 ** (0.002)	-0.002 (0.002)	0.005 ** (0.002)	0.004 (0.003)	-0.004 (0.003)	0.004 (0.003)	0.110 *** (0.023)	-0.060 ** (0.024)	0.110 *** (0.023)	0.052 *** (0.010)	-0.026 ** (0.011)	0.052 *** (0.010)
rh_sus	0.112 *** (0.002)	0.106 *** (0.002)	0.112 *** (0.002)	0.071 *** (0.002)	0.067 *** (0.002)	0.071 *** (0.002)	0.002 *** (0.000)	0.001 *** (0.000)	0.002 *** (0.000)	0.003 *** (0.000)	0.002 *** (0.000)	0.003 *** (0.000)	0.063 *** (0.001)	0.058 *** (0.001)	0.063 *** (0.001)	0.019 *** (0.001)	0.016 *** (0.001)	0.019 *** (0.001)
medsus	0.018 (0.013)	0.005 (0.013)	0.018 (0.013)	0.014 (0.009)	0.002 (0.010)	0.014 (0.009)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	-0.001 (0.001)	0.016 * (0.009)	0.006 (0.009)	0.016 * (0.009)	0.004 (0.004)	0.000 (0.004)	0.004 (0.004)
esf	-0.215 ** (0.074)	-0.251 *** (0.074)	-0.215 ** (0.074)	-0.141 ** (0.054)	-0.173 ** (0.054)	-0.141 ** (0.054)	0.000 (0.005)	0.000 (0.005)	0.000 (0.005)	0.003 (0.006)	0.003 (0.006)	0.003 (0.006)	-0.102 ** (0.049)	-0.128 ** (0.050)	-0.102 ** (0.049)	-0.058 ** (0.022)	-0.075 *** (0.023)	-0.058 ** (0.022)
educ_f	-0.209 * (0.111)	-0.131 (0.113)	-0.209 * (0.111)	-0.098 (0.080)	-0.026 (0.082)	-0.098 (0.080)	0.018 ** (0.007)	0.004 (0.007)	0.018 ** (0.007)	0.025 ** (0.008)	0.005 (0.009)	0.025 ** (0.008)	-0.188 ** (0.073)	-0.129 * (0.075)	-0.188 ** (0.073)	-0.106 ** (0.033)	-0.087 ** (0.034)	-0.106 ** (0.033)
educ_m	0.005 (0.085)	0.180 ** (0.086)	0.005 (0.085)	-0.128 ** (0.061)	0.039 (0.062)	-0.128 ** (0.061)	0.015 ** (0.005)	-0.001 (0.006)	0.015 ** (0.005)	0.017 ** (0.006)	-0.005 (0.007)	0.017 ** (0.006)	0.065 (0.056)	0.173 ** (0.057)	0.065 (0.056)	-0.004 (0.025)	0.049 * (0.026)	-0.004 (0.025)
Intercept	244.551 *** (5.342)	261.235 *** (4.440)	244.551 *** (5.342)	140.960 *** (3.807)	150.464 *** (3.218)	140.960 *** (3.807)	3.564 *** (0.302)	5.457 *** (0.283)	3.564 *** (0.302)	4.204 *** (0.358)	6.510 *** (0.340)	4.204 *** (0.358)	122.435 *** (3.319)	137.173 *** (2.958)	122.435 *** (3.319)	43.519 *** (1.452)	50.456 *** (1.345)	43.519 *** (1.452)
Teste LM	180000 ***	-	-	170000 ***	-	-	120000 ***	-	-	120000 ***	-	-	150000 ***	-	-	130000 ***	-	-
Teste de Hausman	-	1597.52 ***	-	-	1282.52 ***	-	-	3597.64 ***	-	-	2355.94 ***	-	-	728.42 ***	-	-	2748.51 ***	-
I de Moran	-	0,000 ***	-	0,000 ***	-	-	0,000 ***	-	-	0,000 ***	-	-	0,000 ***	-	-	0,000 ***	-	-

*** p<0.001, ** p<0.05, * p<0.1

Fonte: Elaboração própria.

Tabela 3 - Resultados da estatística I de Moran

Ano	Mortalidade geral	Mortalidade de idosos	Mortalidade infantil	Mortalidade na primeira infância	Mortalidade por causas evitáveis	Mortalidade por condições sensíveis à atenção primária
2012	0.057*** (0.009)	0.119*** (0.009)	0.103*** (0.009)	0.134*** (0.009)	0.068*** (0.009)	0.049*** (0.009)
2013	0.051*** (0.009)	0.123*** (0.009)	0.086*** (0.009)	0.115*** (0.009)	0.053*** (0.009)	0.066*** (0.009)
2014	0.045*** (0.009)	0.104*** (0.009)	0.084*** (0.009)	0.114*** (0.009)	0.058*** (0.009)	0.052*** (0.009)
2015	0.036*** (0.009)	0.093*** (0.009)	0.090*** (0.009)	0.109*** (0.009)	0.043*** (0.009)	0.040*** (0.009)
2016	0.037*** (0.009)	0.092*** (0.009)	0.081*** (0.009)	0.102*** (0.009)	0.041*** (0.009)	0.037*** (0.009)
2017	0.031*** (0.009)	0.083*** (0.009)	0.092*** (0.009)	0.118*** (0.009)	0.040*** (0.009)	0.035*** (0.009)
2018	0.047*** (0.009)	0.091*** (0.009)	0.094*** (0.009)	0.114*** (0.009)	0.052*** (0.009)	0.037*** (0.009)
2019	0.043*** (0.009)	0.089*** (0.009)	0.104*** (0.009)	0.130*** (0.009)	0.045*** (0.009)	0.030*** (0.009)
2020	0.031*** (0.009)	0.065*** (0.009)	0.097*** (0.009)	0.111*** (0.009)	0.038*** (0.009)	0.047*** (0.009)
2021	0.039*** (0.009)	0.084*** (0.009)	0.139*** (0.009)	0.185*** (0.009)	0.045*** (0.009)	0.058*** (0.009)
2022	0.049*** (0.009)	0.104*** (0.009)	0.114*** (0.009)	0.161*** (0.009)	0.037*** (0.009)	0.054*** (0.009)

*** p<0.001, ** p<0.05, * p<0.1

Fonte: Elaboração própria.

Tabela 4 - Resultados do Modelo Durbin Espacial (*Spatial Durbin Model – SDM*)

Variável	Mortalidade geral	Mortalidade de idosos	Mortalidade infantil	Mortalidade na primeira infância	Mortalidade por causas evitáveis	Mortalidade por causas sensíveis à atenção primária
SDM						
pandemia	25.601 (35.397)	20.432 (25.696)	-1.298 (2.275)	-4.592 * (2.729)	12.454 (23.620)	-3.498 (10.802)
d_pmm	6.733 *** (1.289)	4.800 *** (0.936)	-0.438 *** (0.083)	-0.511 *** (0.099)	4.120 *** (0.860)	-0.523 (0.393)
postpol	24.659 (31.720)	40.811 * (23.026)	-3.636 * (2.039)	-2.200 (2.445)	-11.479 (21.166)	-5.729 (9.680)
PIB	0.000 *** (0.000)	0.000 *** (0.000)	0.000 (0.000)	0.000 * (0.000)	0.000 ** (0.000)	0.000 (0.000)
plano	0.015 (0.077)	-0.042 (0.056)	0.012 ** (0.005)	0.014 ** (0.006)	0.014 (0.051)	0.032 (0.023)
água	0.531 *** (0.033)	0.410 *** (0.024)	-0.012 *** (0.002)	-0.012 *** (0.003)	0.299 *** (0.022)	0.021 ** (0.010)
esgoto	-0.136 *** (0.035)	-0.092 *** (0.025)	0.000 (0.002)	-0.002 (0.003)	-0.070 ** (0.023)	-0.028 ** (0.011)
rh_sus	0.104 *** (0.002)	0.063 *** (0.002)	0.002 *** (0.000)	0.002 *** (0.000)	0.060 *** (0.002)	0.016 *** (0.001)
medsus	0.008 (0.013)	0.005 (0.009)	-0.001 (0.001)	-0.001 (0.001)	0.007 (0.008)	0.000 (0.004)
esf	-0.159 ** (0.072)	-0.111 ** (0.052)	0.003 (0.005)	0.006 (0.006)	-0.080 * (0.048)	-0.077 *** (0.022)
educ_f	-0.128 (0.107)	-0.027 (0.077)	0.004 (0.007)	0.006 (0.008)	-0.115 (0.071)	-0.096 ** (0.033)
educ_m	0.177 ** (0.082)	0.042 (0.059)	-0.001 (0.005)	-0.005 (0.006)	0.178 *** (0.054)	0.044 * (0.025)
ρ	0.143 *** (0.006)	0.123 *** (0.006)	0.025 *** (0.007)	0.033 *** (0.007)	0.134 *** (0.006)	0.052 *** (0.007)
λ	-	-	-	-	-	-
$\sigma^2\varepsilon$	9015.476 *** (54.265)	4750.814 *** (28.585)	37.241 *** (0.224)	53.583 *** (0.322)	4027.290 *** (24.160)	842.329 *** (5.047)
Wx						
pandemia	21.865	11.580	0.920	4.233	14.035	5.703

d_pmm	(35.442) -5.898 ** (1.816)	(25.728) 0.845 (1.319)	(2.278) -0.958 *** (0.117)	(2.732) -1.132 *** (0.140)	(23.650) -5.553 *** (1.211)	(10.815) -1.142 ** (0.554)
postpol	-25.628 (31.766)	-32.890 (23.060)	2.314 (2.042)	0.517 (2.449)	10.605 (21.198)	4.569 (9.694)
PIB	0.000 *** (0.000)	0.000 *** (0.000)	0.000 (0.000)	0.000 ** (0.000)	0.000 *** (0.000)	0.000 (0.000)
plano	-0.444 ** (0.143)	-0.234 ** (0.104)	-0.015 * (0.009)	-0.010 (0.011)	-0.330 *** (0.095)	-0.183 *** (0.044)
água	-0.540 *** (0.047)	-0.408 *** (0.034)	0.017 *** (0.003)	0.018 *** (0.004)	-0.198 *** (0.031)	-0.026 * (0.014)
esgoto	0.149 ** (0.072)	0.137 ** (0.053)	-0.009 * (0.005)	-0.010 * (0.006)	0.057 (0.048)	0.007 (0.022)
rh_sus	-0.011 ** (0.004)	0.001 (0.003)	-0.001 ** (0.000)	-0.001 ** (0.000)	-0.015 *** (0.003)	0.004 ** (0.001)
medsus	-0.036 (0.024)	-0.036 ** (0.017)	-0.002 (0.002)	-0.004 ** (0.002)	0.005 (0.016)	0.004 (0.007)
esf	-0.496 *** (0.140)	-0.459 *** (0.102)	-0.002 (0.009)	-0.001 (0.011)	-0.236 ** (0.093)	-0.041 (0.043)
educ_f	-0.014 (0.234)	-0.084 (0.170)	-0.002 (0.015)	-0.002 (0.018)	-0.006 (0.042)	-0.115 (0.006)
educ_m	-0.051	-0.085	0.008	0.021	0.022 (0.122)	0.075 (0.049)
R ²	0.2120	0.2190	0.0124	0.0125	0.1299	0.0308
Log-likelihood	-341646.92	-323404.24	-184008.74	-194499.46	-318303.16	-273529.1

*** p<0.001, ** p<0.05, * p<0.1

Fonte: Elaboração própria

A variável que busca captar os efeitos das mudanças na política do PMM a partir de 2018 apresentou impactos variados sobre diferentes tipos de mortalidade. Para a mortalidade geral os modelos SAR e SEM indicam um aumento significativo, assim como para mortalidade de idosos que apresentou coeficiente positivo e significativo em todos os modelos, o que sugere que a retirada dos médicos cubanos e outras alterações políticas podem ter reduzido a disponibilidade de cuidados médicos em áreas vulneráveis, levando a piores resultados de saúde. Em contraste, para a mortalidade infantil nos três modelos e na primeira infância, os modelos SAR e SEM sugerem uma redução significativa, o que pode indicar que outras políticas ou fatores compensaram a perda dos médicos cubanos nestas faixas etárias específicas. Para a mortalidade por causas evitáveis, os modelos SAR e SEM indicam um aumento significativo, sugerindo que a falta de médicos do PMM pode ter reduzido a eficácia da atenção primária na prevenção de mortes evitáveis. Finalmente, para a mortalidade por causas sensíveis à atenção primária, nenhum modelo indicou coeficiente significativo para a variável postpol.

Não há muitos estudos que se debruçam sobre os possíveis efeitos da saída dos cubanos do PMM em 2018 e consequentes mudanças no programa. No entanto, Francesconi *et al.* (2020) utilizando um modelo de micro simulação verificou que a extinção do PMM levaria a um aumento de 4,3% nas taxas de mortalidade de menores de 5 anos e de 2,8% nas taxas de mortalidade em pessoas com menos que 70 anos. Ademais, a saída dos médicos cubanos contribuiria para um aumento de 3,2% nas taxas de mortalidade de menores de 5 anos e de 2,0% nas taxas de mortalidade em pessoas menos que 70 anos até 2030. O estudo conclui que a redução na cobertura de atenção primária à saúde, decorrente dessas mudanças políticas, poderia resultar em um número considerável de mortes evitáveis entre crianças e adultos no Brasil nos anos seguintes. Rasella *et al.* (2019) também encontrou resultados relevantes, mostrando que se a cobertura da Estratégia da Saúde da Família diminuir e o Programa Mais Médicos terminar, a taxa de mortalidade por condições sensíveis à atenção ambulatorial seria 8,60% maior em 2030, resultando em 48.546 mortes prematuras adicionais entre 2017 e 2030.

Com relação à variável pandemia, incluída no modelo para captar os efeitos da pandemia da COVID-19 nas taxas de mortalidade, verificou-se pelos modelos SAR e SEM um

aumento substancial na mortalidade geral, de idosos, por causas evitáveis e por causas sensíveis à atenção primária. Isso é consistente com a expectativa de que a pandemia afetaria gravemente a saúde das populações mais vulneráveis, especialmente os idosos, que são mais suscetíveis a complicações graves de doenças. Além disso, a pandemia pode ter comprometido a eficácia da atenção primária e a prevenção de doenças. A sobrecarga dos sistemas de saúde e a interrupção dos serviços regulares de saúde provavelmente contribuíram para aumentar a incapacidade dos serviços de saúde primária de diagnosticar, tratar e prevenir condições que normalmente seriam manejáveis (Dinmohamed *et al.*, 2020; Schwarz *et al.*, 2020; Zubiri *et al.*, 2021). Tais resultados eram esperados visto que estudos como o COVID-19 Excess Mortality Collaborators (2022), apresentam resultados que sugerem que a pandemia teve um impacto muito mais devastador na mortalidade do que indicado pelas estatísticas oficiais, especialmente em regiões com capacidade limitada de testes e infraestrutura de saúde.

Com relação à variável que representa a densidade de recursos humanos atuantes no SUS (rh_sus), os resultados apresentaram coeficientes positivos e significativos em todos os modelos e para todas as taxas de mortalidade. O resultado pode indicar que a presença de mais recursos humanos está associada ao aumento da mortalidade, que pode refletir uma maior capacidade de diagnóstico e registro de óbitos. No entanto, sugere-se mais estudos relacionados ao tema devido a limitada literatura existente que relacione tais informações.

Em todos os modelos a variável que representa a densidade de equipes de saúde da família (esf) mostrou-se significativa e com relevante impacto negativo sobre diferentes taxas de mortalidade, exceto na avaliação das mortalidades infantil e na primeira infância, as quais não apresentaram significância estatística. Tal resultado conversa com os achados de Hone *et al.* (2017), o qual associou a cobertura completa da eSF a uma redução de 15,4% na mortalidade por CSAP na população preta/parda, em comparação com uma redução de 6,8% na população branca. As reduções nas desigualdades raciais foram impulsionadas por quedas nas mortes por doenças infecciosas, deficiências nutricionais, anemias, diabetes e doenças cardiovasculares. Ademais, Rasella *et al.* (2019) verificou que a redução na cobertura da Estratégia de Saúde da Família sem a terminação do PMM, resultaria em um aumento de 5,80% na taxa de mortalidade por condições sensíveis à atenção ambulatorial, com 27.685 mortes prematuras adicionais, com um impacto mais significativo nos municípios mais pobres, exacerbando as desigualdades de saúde.

Finalmente, a variável d_pmm , cuja finalidade é captar os possíveis efeitos da presença de médicos do PMM nos municípios brasileiros, apresentou impactos mistos nas diferentes taxas de mortalidade. Destaca-se, porém, redução significativa nas mortalidades infantil e na primeira infância (resultado significativo em todos os modelos) e nas taxas de mortalidade por condições sensíveis à atenção primária (coeficiente estatisticamente significativo nos modelos SAR e SEM).

Adicionalmente, a variável d_pmm defasada espacialmente ($Wx.d_pmm$) mostrou efeitos espaciais positivos nos municípios vizinhos (exceto com relação à mortalidade de idosos), apresentando coeficientes negativos e estatisticamente significativos. Tais resultados sugerem que a presença de médicos do PMM em um município pode beneficiar áreas adjacentes, possivelmente devido à melhor infraestrutura de saúde ou à mobilidade dos pacientes. No entanto, sugere-se a realização de estudos adicionais.

Os resultados encontrados alinham-se à literatura existente. O estudo de Bexson *et al.* (2021) mostrou que o PMM teve eficácia limitada na redução da mortalidade infantil e neonatal em geral, mas foi eficaz em áreas de maior necessidade, como municípios com as maiores taxas de mortalidade infantil. Carneiro *et al.* (2018), por sua vez, verificou uma melhoria significativa em todos os indicadores após a implementação do PMM em 2013, como o crescimento significativo na proporção de nascidos vivos de mães com sete ou mais consultas de pré-natal, enquanto a taxa de mortalidade infantil e as taxas de internação por condições sensíveis à

atenção primária apresentaram tendência de queda. Adicionalmente, o estudo de Hone *et al.* (2020) revelou uma redução na mortalidade evitável de 1,06 mortes por 100.000 habitantes por ano, com maiores benefícios observados em municípios prioritários para alocação de médicos.

5. Considerações finais

Este estudo avaliou os impactos do Programa Mais Médicos (PMM) sobre as taxas de mortalidade nos municípios brasileiros no período de 2012 a 2022, com ênfase na análise de sua influência na redução da mortalidade geral, infantil, de idosos, por causas evitáveis e por condições sensíveis à atenção primária (CSAP). A investigação evidenciou a importância de incorporar a dimensão espacial nas análises, razão pela qual foram utilizadas técnicas de painel espacial, com destaque para o modelo Spatial Durbin Model (SDM), apropriado para lidar com dependência e heterogeneidade espaciais. O estudo contribui para o avanço do conhecimento ao abordar desigualdades regionais na distribuição dos recursos em saúde e ao suprir lacunas existentes na literatura quanto aos efeitos de longo prazo do PMM.

A adoção da matriz de contiguidade do tipo rainha justifica-se pela relevância das interações regionais entre municípios, especialmente em um sistema de saúde como o brasileiro, pautado por ações integradas e regionalizadas no âmbito do Sistema Único de Saúde (SUS). A consideração de vizinhos limítrofes possibilita captar de maneira mais acurada os efeitos indiretos das políticas públicas de saúde, como a alocação de recursos e a atuação de profissionais, que frequentemente ultrapassam os limites administrativos municipais.

Os resultados revelam que a pandemia de COVID-19 elevou significativamente as taxas de mortalidade geral, com exceção das mortalidades infantil e na primeira infância, cujos índices não apresentaram crescimento no período. Ademais, o PMM demonstrou efeitos positivos na redução da mortalidade infantil, na primeira infância e por causas evitáveis, evidenciando sua efetividade no fortalecimento da Atenção Primária à Saúde (APS), sobretudo em áreas mais vulneráveis.

Entretanto, as descontinuidades observadas no programa a partir de 2018, incluindo a saída dos profissionais cubanos, indicam efeitos adversos, comprometendo a continuidade da cobertura médica e os avanços previamente alcançados. Tais interrupções sugerem a necessidade de maior estabilidade institucional e política para garantir a efetividade de programas dessa natureza.

Em suma, os achados deste trabalho fornecem evidências empíricas consistentes sobre o impacto positivo do PMM nas taxas de mortalidade, reforçando a importância da dimensão espacial na formulação e avaliação de políticas públicas em saúde. Ao abordar os desafios e avanços relacionados ao programa, o estudo contribui para o aprimoramento de estratégias voltadas à promoção da equidade em saúde, oferecendo subsídios relevantes para o debate sobre políticas de saúde pública em países em desenvolvimento.

Referências

- ALMEIDA, E. **Econometria espacial aplicada**. Campinas, SP: Alínea, 2012.
- ANSELIN, L. **Spatial Econometrics: Methods and Models**. Kluwer Academic Publishers, 1988.
- ANSELIN, L. **Chapter fourteen: Spatial Econometrics**. A Companion to Theoretical Econometrics Edited by Badi H. Baltagi Copyright © 2001, 2003 by Blackwell Publishing Ltd. Disponível em: https://web.pdx.edu/~crkl/WISE/SEAUG/papers/anselin01_CTE14.pdf
- AQUINO, E. M. L.; SILVEIRA, I. H.; PESCARINI, J. M.; AQUINO, R.; SOUZA-FILHO, J. A.; ROCHA, A. S.; BARRETO, M. L. Social distancing measures to control the COVID-19

pandemic: potential impacts and challenges in Brazil. **Ciência & Saúde Coletiva**, 2020. Disponível em: <https://doi.org/10.1590/1413-81232020256.1.10502020>. Acesso em 10 jul. 2024.

BARUFI, A. M.; HADDAD, E.; PAEZ, A. Infant mortality in Brazil, 1980-2000: A spatial panel data analysis. **BMC Public Health**, 2020. Disponível em: <http://www.biomedcentral.com/1471-2458/12/181>. Acesso em 10 jul. 2024.

BELOTTI F.; HUGHES G.; MORTARI S. P. Spatial panel-data models using Stata. **The Stata Journal**, 17, nº 1, 2017, pp 139-180. Disponível em: <https://journals.sagepub.com/doi/pdf/10.1177/1536867X1701700109>. Acesso em: 25 ago. 2024.

BEXSON, C. *et al.* Brazil's more doctors programme and infant health outcomes: a longitudinal analysis. **Human Resources for Health**, 2021. DOI: <https://doi.org/10.1186/s12960-021-00639-3>.

BRASIL. **Lei nº 14.621, de 14 de julho de 2023**. Institui a Estratégia Nacional de Formação de Especialistas para a Saúde no âmbito do Programa Mais Médicos; e altera as Leis nºs 12.871, de 22 de outubro de 2013, 13.959, de 18 de dezembro de 2019, e 13.958, de 18 de dezembro de 2019, para criar novos incentivos e regras no âmbito do Projeto Mais Médicos para o Brasil e do Exame Nacional de Revalidação de Diplomas Médicos Expedidos por Instituição de Educação Superior Estrangeira (Revalida) e para transformar a Agência para o Desenvolvimento da Atenção Primária à Saúde (Adaps) em Agência Brasileira de Apoio à Gestão do SUS (AGSUS). **Diário Oficial da União**: edição extra. Brasília, DF: Presidência da República, [2023a].

_____. Ministério da Saúde. **Programa mais médicos – dois anos: mais saúde para os brasileiros**. Brasília, DF: Ministério da Saúde, [2015], 128p.

_____. Ministério da Saúde. **Programa Mais Médicos**. Brasília, DF: Ministério da Saúde, [2017]. Disponível em: <http://maismedicos.gov.br/images/PDF/Cartilha-Mais-Medicos-Versao-Eletronica.pdf>. Acesso em 20 jun. 2024.

_____. **Portaria nº 221, de 17 de abril de 2008**. Brasília, DF: Ministério da Saúde, [2008]. Disponível em: https://bvsmms.saude.gov.br/bvs/saudelegis/sas/2008/prt0221_17_04_2008.html

CARNEIRO V.; MAIA C.; RAMOS E.; CASTELO-BRANCO S. Tecobé In Marajó Trend of Indicators for the Monitoring of Primary Care Before and During the More Physicians for Brazil Program. **Ciencia e Saude Coletiva**, v. 23, n. 7, 2018, p. 2413-2422. DOI 10.1590/1413-81232018237.19052016

CHENG J. J.; SCHUSTER-WALLACE C. J.; WATT S.; NEWBOLD B. K.; MENTE A. An Ecological Quantification Of The Relationships Between Water, Sanitation And Infant, Child, And Maternal Mortality. **Environmental Health**, v. 11, Article number: 4, 2012. Disponível em: <https://ehjournal.biomedcentral.com/articles/10.1186/1476-069X-11-4>. Acesso em: 12 jul. 2024.

COVID-19 Excess Mortality Collaborators. Estimating excess mortality due to the COVID-19 pandemic: a systematic analysis of COVID-19-related mortality. **Lancet**: 2022. Disponível em: [https://doi.org/10.1016/S0140-6736\(21\)02796-3](https://doi.org/10.1016/S0140-6736(21)02796-3). Acesso em: 12 jul. 2024.

DINMOHAMED, A. G. *et al.* Fewer cancer diagnoses during the COVID-19 epidemic in the Netherlands. **Lancet Oncology**, v. 21, mai. 2020, p. 750-751. Disponível em: <https://www.thelancet.com/action/showPdf?pii=S1470-2045%2820%2930265-5>. Acesso em: 29 jan. 2025.

- DOS SANTOS, J. R. R.; DOS SANTOS, H. G.; DIAS, C. M. M.; CHIAVEGATTO, A. D. P. Assessing the impact of a doctor in remote areas of Brazil. **International Journal of Public Health**, 2020. DOI: <http://dx.doi.org/10.1007/s00038-020-01360-z>.
- DUSSAULT, G.; FRANCESCHINI, M. C. Not enough there, too many here: understanding geographical imbalances in the distribution of the health workforce. **Human Resources for Health**, 2006. Disponível em: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC1481612/>. Acesso em 11 jul. 2024.
- ELHORST, J. P. Specification and estimation of spatial panel data models. **Int Reg Sci Ver**, 26(3), 2003, p. 244–268. DOI: <https://doi.org/10.1177/0160017603253791>
- ELHORST, P. G. Applied Spatial Econometrics: Raising the Bar. Spatial Economic Analysis, Vol. 5, No. 1. **Taylor and Francis Group**, 2010. DOI: <https://doi.org/10.1080/17421770903541772>
- ELHORST, J. P. Spatial Econometrics: From Cross-Sectional Data to Spatial Panels. **Springer**, 2014. Disponível em: <https://arm.ssuv.uz/frontend/web/books/643105596a3dd.pdf>. Acesso em: 23 ago. 2024
- ELHORST, J. P. Spatial panel models. Groningen, Países Baixos: **University of Groningen**, 2011. Disponível em: https://www.york.ac.uk/media/economics/documents/seminars/2011-12/Elhorst_November2011.pdf. Acesso em: ago. 2024.
- ELHORST P., VEGA S H. On spatial econometric models, spillover effects. *In: 53rd Congress of the European Regional Science Association: "Regional Integration: Europe, the Mediterranean and the World Economy"*, ago. 2013, Palermo, Italy. **Conference Paper**. Disponível em: https://www.econstor.eu/bitstream/10419/123888/1/ERSA2013_00222.pdf. Acesso em 12 set. 2024.
- FONTES, L. F. C.; CONCEIÇÃO, O. C.; JACINTO, P. D. Evaluating the impact of physicians' provision on primary healthcare: Evidence from Brazil's More Doctors Program. **Health Economics**, 2018. DOI: <http://dx.doi.org/10.1002/hec.3775>..
- FRANCESCONI, G. V.; TASCA, R.; BASU, S.; ROCHA, T. A. H.; RASELLA, D. Mortality associated with alternative policy options for primary care and the Mais Médicos (More Doctors) Program in Brazil: forecasting future scenarios. **Revista Panamericana de Salud Pública**, 2020. Disponível em: <http://dx.doi.org/10.26633/RPSP.2020.31>. Acesso em: 11 jul. 2024.
- FRANCO, C. M.; ALMEIDA, P. F. DE; GIOVANELLA, L. A integralidade das práticas dos médicos cubanos no Programa Mais Médicos na cidade do Rio de Janeiro, Brasil. **Cadernos de Saúde Pública**, 34(9), 2018. DOI:10.1590/0102-311x00102917
- GIOVANELLA, L.; BOUSQUAT, A.; ALMEIDA, P. F. DE; MELO E.A.; MEDINA, M.G.; AQUINO, R.; MENDONÇA, M. H. M. Médicos pelo Brasil: caminho para a privatização da atenção primária à saúde no Sistema Único de Saúde? **Cad. Saúde Pública**, 2019. DOI: 10.1590/0102-311X00178619.
- GIRARDI, S. N.; STRALEN, A. C. S.; CELLA, J. N.; WAN DER MAAS, L.; CARVALHO, C. L.; FARIA, E. J. Impacto do Programa Mais Médicos na redução da escassez de médicos em regiões vulneráveis. **Ciência & Saúde Coletiva**, v. 21, n. 9, 2016, p. 2677-2685. Disponível em: <https://www.scielo.br/j/csc/a/qTyKQT9CDdZ3ctg67njlLqj/abstract/?lang=pt>. Acesso em: 10 jun 2024.
- GUJARATI D. N.; PORTER D. C. **Econometria básica**. 5ª edição, AMGH, 2011.

HONE, T.; RASELLA, D.; BARRETO, M.; ATUN, R.; MAJEED, A.; MILLETT, C. Large reductions in amenable mortality associated with Brazil's primary care expansion and strong health governance. **Health Affairs**, v. 36, n. 1, 2017, p. 149-158. Disponível em: <https://www.healthaffairs.org/doi/10.1377/hlthaff.2016.0966>. Acesso em 11 jul 2024.

HONE, T. *et al.* Impact of the Programa Mais médicos (more doctors Programme) on primary care doctor supply and amenable mortality: quasi-experimental study of 5565 Brazilian municipalities. **BMC Health Services Research**, 2020. Disponível em: <https://doi.org/10.1186/s12913-020-05716-2>. Acesso em 30 mar 2024.

INEP – Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. **Indicador apresenta distorção idade-série para ensino fundamental e médio**. Brasília, DF: Ministério da Educação, 2020. Disponível em: <https://www.gov.br/inep/pt-br/assuntos/noticias/censo-escolar/indicador-apresenta-distorcao-idade-serie-para-ensino-fundamental-e-medio>. Acesso em: 22 ago. 2024.

LESAGE, J.; R. K. PACE. **Introduction to Spatial Econometrics**. Boca Raton, FL: Chapman & Hall/CRC, 2009.

MACEDO, A. S.; FERREIRA, M. A. M. Efeitos do Programa Mais Médicos (PMM) nos Resultados da Atenção Básica à Saúde. **Revista Brasileira de Políticas Públicas**, 2020. DOI: <https://doi.org/10.5102/rbpp.v10i1.6534>

MACEDO M. R. C. *et al.* Work process and psychic suffering of primary care physicians in the COVID-19 pandemic. **Saúde Soc. São Paulo**, v. 32, supl. 2, e220825pt, 2023.

MACINKO, J.; HARRIS, M. J. Brazil's Family Health Strategy — Delivering Community-Based Primary Care in a Universal Health System. **New England Journal of Medicine**, v. 372, n. 23, p. 2177-2181, 2015. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/26039598/>. Acesso em 11 jul 2024.

MAFFIOLI M. E.; HERNANDES ROCHA T.; VIVAS G.; ROSALES C.; STATON C.; VISSOCI J. R. N. Addressing inequalities in medical workforce distribution: evidence from a quasi-experimental study in Brazil. **BMJ Global Health**, 2019. DOI:10.1136/bmjgh-2019-001827

MALTA, D. C.; SALTARELLI, R. M. F.; VELOSO, G. A.; GOMES, C. S.; SOARES FILHO, A. M.; VIEIRA, E. W. R.; FELISBINO-MENDES, M. S.; NAGHAVI, M.; RIBEIRO, A. L. P. Mortality by avoidable causes in Brazil from 1990 to 2019: data from the Global Burden of Disease Study. **Public Health**, v. 227, fev. 2024, p. 194-201. Disponível em: <https://doi.org/10.1016/j.puhe.2023.12.012>. Acesso em 11 jul 2024.

MALTA D. C., SARDINHA L. M. V., MOURA L., LANSKY S., LEAL M. C., SZARCWALD C. L., FRANÇA E. Atualização da lista de causas de mortes evitáveis por intervenções do Sistema Único de Saúde do Brasil. **Epidemiologia e Serviços de Saúde**, 19(2), p.173-176, 2010. DOI: <http://dx.doi.org/10.5123/S1679-49742010000200010>

MARQUES DA COSTA G.; SANCHEZ M. N.; SHIMIZU H. E. Fatores associados à mortalidade de idosos por condições sensíveis à atenção primária, entre 2008 e 2018, no Distrito Federal, Brasil. **Plos One**, 2022. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0272650>. Acesso em 11 jul 2024.

MATTOS, E.; MAZETTO, D. Assessing the impact of more doctors' program on healthcare indicators in Brazil. **World Development**, 2019. Disponível em: <https://doi.org/10.1016/j.worlddev.2019.104617>. Acesso em: 11 jul. 2024.

MURRAY, C. J.; LOPEZ, A. D. Mortality by cause for eight regions of the world: Global Burden of Disease Study. **The Lancet**, v. 349, n. 9061, p. 1269-1276, 1997. Disponível em: [https://doi.org/10.1016/S0140-6736\(96\)07493-4](https://doi.org/10.1016/S0140-6736(96)07493-4). Acesso em 11 jul 2024.

NIKOLOSKI Z.; ALBALA S.; MADRIZ MONTERO A.; MOSSIALOS E. The impact of primary health care and specialist physician supply on amenable mortality in Mexico (2000-2015): Panel data analysis using system-Generalized Method of Moments. **Social Science & Medicine**, 2021. Disponível em: https://www.sciencedirect.com/science/article/pii/S0277953621002690?ref=pdf_download&r=RR-2&r=8a1a624deee8264c. Acesso em 11 jul 2024.

NOGUEIRA, P.T.A.; BEZERRA A.F.B.; LEITE, A.F.B.; CARVALHO, I.M.S.; GONÇALVES, R.F.; BRITO-SILVA, K.S. Características da distribuição de profissionais do Programa Mais Médicos nos estados do Nordeste, Brasil. **Ciência e Saúde Coletiva**, 2016. DOI: 10.1590/1413-81232015219.17022016

OLIVEIRA J. P. A.; SANCHEZ M. N.; PACHECO SANTOS L. M. O Programa Mais Médicos: provimento de médicos em municípios brasileiros prioritários entre 2013 e 2014. **Ciência e Saúde Coletiva**, 2016. DOI: 10.1590/1413-81232015219.17702016

ÖZÇELİK, E. A.; MASSUDA, A.; MCCONNELL, M.; CASTRO, M. C. Impact of Brazil's More Doctors Program on hospitalizations for primary care sensitive cardiovascular conditions. **SSM-Population Health**, 2020. Disponível em: <https://doi.org/10.1016/j.ssmph.2020.100695>. Acesso em: 11 jul. 2024.

PEREIRA L. K. M.; SILVA JAD; VALENTIM RADM; LIMA TGFMS; GUSMÃO CMG; ROCHA MAD; SANTOS MMD; CAITANO AR; BARROS RMBD; ROSENDO TS. Interventions of Brazil's more doctors program through continuing education for Primary Health Care. **Front. Public Health**, 2024. DOI: 10.3389/fpubh.2023.1289280

PAELINCK, J. H. P; KLAASSEN, L. H. **Spatial Econometrics**. Studies in spatial analysis. Universidade de Michigan, Saxon House, v.1, 1979.

PAIM, J.; TRAVASSOS, C.; ALMEIDA, C.; BAHIA, L.; MACINKO, J. The Brazilian health system: history, advances, and challenges. **The Lancet**, v. 377, n. 9779, p. 1778-1797, 2011. Disponível em: [https://doi.org/10.1016/S0140-6736\(11\)60054-8](https://doi.org/10.1016/S0140-6736(11)60054-8). Acesso em 11 jul 2024.

RASELLA, Davide *et al*. Mortality associated with alternative primary healthcare policies: a nationwide microsimulation modelling study in Brazil. **BMC Medicine**, v. 17, n. 82, 2019. Disponível em: <https://doi.org/10.1186/s12916-019-1316-7>. Acesso em: 16 jul. 2024.

REMES. J.; WILSON A.; RAMDORAI A. How investing in health has a significant economic payoff for developing economies. **The Brookings Institution**. 2020. Disponível em: <https://www.brookings.edu/articles/how-investing-in-health-has-a-significant-economic-payoff-for-developing-economies/>. Acesso em 11 jul 2024.

SCHEFFER, M. *et al*. Demografia Médica no Brasil 2023. São Paulo, SP: **FMUSP, AMB**, 2023. 344p. ISBN 978-65-00-60986-8. Disponível em: https://amb.org.br/wp-content/uploads/2023/02/DemografiaMedica2023_8fev-1.pdf. Acesso em: 10 jan. 2024.

SCHWARZ, V.; MAHFOUD F.; LAUDER L.; REITH W.; BEHNKE S.; SMOLA S.; RISSLAND J.; PFUHL T.; SCHELLER B.; BÖHM M.; EWEN S. Decline of emergency admissions for cardiovascular and cerebrovascular events after the outbreak of COVID-19. **Clinical Research in Cardiology**, v. 109, p. 1500-1506, 2020. DOI: 10.1007/s00392-020-01688-9

STARFIELD B. Primary care: an increasingly important contributor to effectiveness, equity, and efficiency of health services. SESPAS report 2012. **Gaceta Sanitaria**, v. 26, Supplement 1, mar. 2012, p. 20-26. DOI: 10.1016/j.gaceta.2011.10.009

TADDEO, M. M.; AMORIM L. D.; AQUINO, R. Causal measures using generalized difference-in-difference approach with nonlinear models. **Statistics and Its Interface**, v. 15, 2022, p. 399–413. DOI: <https://dx.doi.org/10.4310/21-SII704>.

TANGCHAROENSATHIEN, V.; FARAMNUAYPHOL P.; TEOKUL W.; BUNDHAMCHAROEN K.; WIBULPHOLPRASERT S. A critical assessment of mortality statistics in Thailand: potential for improvements. **Bulletin of the World Health Organization**, 2006. Disponível em: <https://www.scielo.org/pdf/bwho/2006.v84n3/233-238/en>. Acesso em: jul. 2024.

UNICEF – FUNDO DAS NAÇÕES UNIDAS PARA A INFÂNCIA. **Panorama da Distorção Idade-Série no Brasil**. UNICEF, 2018. Disponível em: https://www.unicef.org/brazil/media/461/file/Panorama_da_distorcao_idade-serie_no_Brasil.pdf. Acesso em 07 ago 2024.

ZUBIRI, L. *et al.* Temporal trends in inpatient oncology census before and during the COVID-19 pandemic and rates of nosocomial COVID-19 among patients with cancer at a large academic center. **Oncologist**, v. 26, p. e1427-e1433, 2021.