

**UNIVERSIDADE FEDERAL DE MATO GROSSO**  
**CAMPUS UNIVERSITÁRIO DE SINOP**  
**Programa de Pós-Graduação em Ciências em Saúde**

**ANÁLISE DA COBERTURA VACINAL E DA  
MORBIMORTALIDADE POR COVID-19 NO ESTADO  
DE MATO GROSSO**

**LUANNE KAROLYNE LEAL DOS SANTOS**

**Sinop, Mato Grosso**  
**Fevereiro de 2025**

**LUANNE KAROLYNE LEAL DOS SANTOS**

**ANÁLISE DA COBERTURA VACINAL E DA  
MORBIMORTALIDADE POR COVID-19 NO ESTADO  
DE MATO GROSSO**

Orientadora: Profa. Dra. Ludmila Barbosa Bandeira Rodrigues Emerick

Dissertação apresentada ao Programa de Pós-Graduação em Ciências em Saúde da Universidade Federal de Mato Grosso, *Campus* Universitário de Sinop, como requisito para a obtenção de título de Mestre em Ciências em Saúde.

**Sinop, Mato Grosso  
Fevereiro de 2025**

### **Dados Internacionais de Catalogação na Fonte.**

S237a Santos, Luanne Karolyne Leal dos.

Análise da cobertura vacinal e da morbimortalidade por COVID-19 no estado de Mato Grosso [recurso eletrônico] / Luanne Karolyne Leal dos Santos. -- Dados eletrônicos (1 arquivo : 119 f., il. color., pdf). -- 2025.

Orientadora: Ludmila Barbosa Bandeira Rodrigues Emerick.  
Dissertação (mestrado) – Universidade Federal de Mato Grosso, Instituto de Ciências da Saúde, Programa de Pós-Graduação em Ciências em Saúde, Sinop, 2025.

Modo de acesso: World Wide Web: <https://ri.ufmt.br>.

Inclui bibliografia.

1. COVID-19. 2. epidemiologia. 3. indicadores de morbimortalidade.  
I. Emerick, Ludmila Barbosa Bandeira Rodrigues, *orientador*. II. Título.

Ficha catalográfica elaborada automaticamente de acordo com os dados fornecidos pelo(a) autor(a).

Permitida a reprodução parcial ou total, desde que citada a fonte.



**MINISTÉRIO DA EDUCAÇÃO**  
**UNIVERSIDADE FEDERAL DE MATO GROSSO**  
**PRÓ-REITORIA DE ENSINO DE PÓS-GRADUAÇÃO**  
**PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS EM SAÚDE**  
**FOLHA DE APROVAÇÃO**

**TÍTULO:** “Análise da cobertura vacinal e da morbimortalidade por COVID-19 no estado de Mato Grosso”

**AUTOR (A):** MESTRANDO (A) **Luanne Karolyne Leal dos Santos**

Dissertação defendida e aprovada em **27 de fevereiro de 2025**.

**COMPOSIÇÃO DA BANCA EXAMINADORA**

Doutor(a) Ludmila Barbosa Bandeira Rodrigues Emerick (Presidente Banca/Orientadora)

Instituição: Universidade Federal de Mato Grosso

Doutor(a) Ricardo Alexandre Arcêncio (Examinador(a) Externo(a))

Instituição: Universidade de São Paulo

Doutor(a) Murilo César do Nascimento (Examinador(a) Externo(a))

Instituição: Universidade Federal de Alfenas

Doutor(a) Mellina Yamamura Calori (Examinador(a) Suplente)

Instituição: Universidade Federal de São Carlos

Doutor(a) Cláudio Vieira de Araújo (Examinador(a) Suplente)

Instituição: Universidade Federal de Mato Grosso

**SINOP, 27/02/2025.**



Documento assinado eletronicamente por **Murilo César do Nascimento, Usuário Externo**, em 01/04/2025, às 09:47, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **RICARDO ALEXANDRE ARCENCIO, Usuário Externo**, em 01/04/2025, às 10:25, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



Documento assinado eletronicamente por **LUDMILA BARBOSA BANDEIRA RODRIGUES EMERICK, Docente da Universidade Federal de Mato Grosso**, em 01/04/2025, às 15:43, conforme horário oficial de Brasília, com fundamento no § 3º do art. 4º do [Decreto nº 10.543, de 13 de novembro de 2020](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufmt.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufmt.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **7776567** e o código CRC **7662ECAC**.

Dedico este trabalho aos meus pais, cujo amor, incentivo e apoio foram fundamentais em cada etapa da minha vida.

## AGRADECIMENTOS

Primeiramente, agradeço à Deus, que me guiou, iluminou meu caminho e trouxe pessoas maravilhosas à minha vida para me apoiar durante esta jornada.

Aos meus pais, Altamir dos Santos e Rosângela da Silva Leal, meu mais profundo agradecimento por todo amor, suporte e por sempre acreditarem em mim, permitindo que eu chegasse até aqui.

À Profa. Dra. Ludmila Barbosa Bandeira Rodrigues Emerick e ao Prof. Dr. Ricardo Alexandre Arcêncio, pela oportunidade de integrar o Projeto Termômetro Social COVID-19.

Novamente à minha querida orientadora, Profa. Dra. Ludmila B. B. R. Emerick, pela excelente orientação, por todo apoio e suporte que me forneceu, pelas oportunidades que me proporcionou e por todo ensinamento ao longo dessa trajetória.

Ao meu companheiro de vida, Mauricio Roberto Pagliarini Filho, pelo apoio, carinho, companheirismo, amor e suporte que me proporcionou durante todos esses anos juntos.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pela concessão de bolsa e suporte financeiro, essenciais para a realização desta pesquisa.

À Universidade Federal de Mato Grosso, pelo excelente curso de pós-graduação e pelo corpo docente altamente qualificado.

Ao Programa de Pós-graduação em Ciências em Saúde, pelas pessoas que conheci, pelas oportunidades que me proporcionou e pela experiência que adquiri como representante discente do colegiado.

A todos os professores que participaram da minha trajetória acadêmica na pós-graduação, pelo valioso conhecimento e ensinamentos que me transmitiram.

À Profa. Dra. Larissa Fortunato Araújo, pela generosidade em compartilhar seu conhecimento, pelos ensinamentos, conselhos e pelo incentivo que me motivou a seguir na carreira acadêmica.

À Profa. Dra. Marina Mariko Sugui e Prof. Dr. Danilo Henrique Aguiar, pela oportunidade de atuar como professora substituta no curso de Farmácia e Enfermagem da UFMT, retirando todas as minhas dúvidas sobre a trajetória acadêmica.

A todos os colegas de pós-graduação, em especial à Natasha Siega, Maira Liliane e Isabelle Zanata, pela troca de experiência, de conhecimento e companheirismo que tivemos durante esses anos.

## RESUMO

Desde o início da pandemia de COVID-19, a implementação de estratégias para conter sua disseminação tem sido um grande desafio para as políticas públicas e serviços de saúde. A vacinação, uma das principais medidas adotadas, contribuiu para reduzir a gravidade da doença e a transmissão do vírus. No entanto, a falta de coordenação e as desigualdades nas políticas de proteção durante o período pandêmico agravaram os desafios enfrentados pelas populações vulneráveis, que, expostas a condições insalubres e com dificuldades de acesso a serviços de saúde, sofreram com desinformação, medo, negacionismo científico e desigualdade na distribuição de recursos, aumentando sua suscetibilidade à pandemia e o risco de disseminação do vírus. Este estudo teve como objetivo analisar a variação das taxas de morbimortalidade por COVID-19 em relação à cobertura vacinal e aos determinantes sociais de saúde entre 2020 e 2023 no estado de Mato Grosso, considerando aspectos epidemiológicos, socioeconômicos e espaciais. Trata-se de um estudo ecológico de séries temporais e espacial, utilizando dados de casos e óbitos de COVID-19 do Sistema de Informação de Vigilância da Gripe (SIVEP-Gripe) e do e-SUS Notifica, e dados de vacinação do Sistema de Informação do Programa Nacional de Imunizações (SI-PNI). As taxas populacionais foram obtidas do Instituto Brasileiro de Geografia e Estatística (IBGE), padronizadas por idade pelo método direto, com base na população do Censo Demográfico de 2022. Foram estimadas taxas de incidência, mortalidade, letalidade e cobertura vacinal por sexo, idade, raça/cor da pele e município. A tendência temporal dessas taxas foi analisada por meio da regressão de Prais-Winsten para correção das variações ao longo do tempo. Também foram realizadas análises descritivas e espaciais, incluindo séries temporais e estatísticas de Índice de Moran Global e Local univariado e bivariado para identificar padrões de autocorrelação espacial. Os resultados indicam que a COVID-19 teve um impacto desproporcional nas populações vulneráveis de Mato Grosso. Crianças e adolescentes apresentaram as menores taxas de incidência e mortalidade, enquanto os idosos, especialmente aqueles com mais de 80 anos, foram os mais afetados, apresentando alta letalidade. Observou-se que as mulheres tiveram uma maior taxa de incidência, mas os homens registraram maiores taxas de mortalidade e letalidade. A correlação das taxas ao longo do tempo demonstrou uma tendência decrescente da morbimortalidade após a ampliação da cobertura vacinal, ainda que com variações regionais expressivas. Enquanto algumas localidades, como Acorizal e Nova Brasilândia, atingiram 100% de cobertura, outras, como Santa Terezinha e Confresa, registraram menos de 50%. As análises espaciais identificaram padrões de autocorrelação, com *hot spots* de alta incidência e mortalidade concentrados nas regiões Norte e Nordeste do estado, enquanto os *cold spots* estavam nas regiões Sul e Sudeste. Além disso, foi observada uma correlação espacial negativa entre a incidência da COVID-19 e a cobertura vacinal, assim como entre a incidência e o Índice de Progresso Social (IPS), indicando que áreas com menor desenvolvimento socioeconômico apresentaram maior disseminação do vírus. Os achados reforçam que, embora a vacinação tenha sido um elemento essencial para reduzir a morbimortalidade, a hesitação vacinal, a desigualdade na cobertura e o acesso limitado aos serviços de saúde revelam desafios persistentes. Estratégias de comunicação eficazes e políticas públicas equitativas e coordenadas são fundamentais para mitigar essas disparidades, garantindo maior equidade no enfrentamento de crises sanitárias futuras.

**Palavras-chave:** COVID-19; epidemiologia; indicadores de morbimortalidade.

## ABSTRACT

Since the beginning of the COVID-19 pandemic, implementing strategies to contain its spread has been a major challenge for public policies and health services. Vaccination, one of the main measures adopted, contributed to reducing the severity of the disease and the transmission of the virus. However, the lack of coordination and inequalities in protection policies during the pandemic period aggravated the challenges faced by vulnerable populations, who, exposed to unsanitary conditions and with difficulties in accessing health services, suffered from misinformation, fear, scientific denialism and inequality in the distribution of resources, increasing their susceptibility to the pandemic and the risk of spreading the virus. This study aimed to analyze the variation in COVID-19 morbidity and mortality rates in relation to vaccination coverage and social determinants of health between 2020 and 2023 in the state of Mato Grosso, considering epidemiological, socioeconomic and spatial aspects. This is an ecological time-series and spatial study using data on COVID-19 cases and deaths from the *Sistema de Informação de Vigilância da Gripe* (SIVEP-Gripe) and e-SUS Notifica, and vaccination data from the *Sistema de Informação do Programa Nacional de Imunizações* (SI-PNI). Population rates were obtained from the *Instituto Brasileiro de Geografia e Estatística* (IBGE), standardized by age using the direct method, based on the population of the 2022 demographic census. Incidence, mortality, case fatality, and vaccination coverage rates were estimated by sex, age, race/skin color, and municipality. The temporal trend of these rates was analyzed using Prais-Winsten regression to correct for variations over time. Descriptive and spatial analyses were also performed, including time series and univariate and bivariate Global and Local Moran's Index statistics to identify spatial autocorrelation patterns. The results indicate that COVID-19 had a disproportionate impact on vulnerable populations in Mato Grosso. Children and adolescents had the lowest incidence and mortality rates, while the elderly, especially those over 80 years old, were the most affected, with high lethality rates. It was observed that women had a higher incidence rate, but men recorded higher mortality and lethality rates. The correlation of rates over time demonstrated a decreasing trend in morbidity and mortality after the expansion of vaccination coverage, although with significant regional variations. While some locations, such as Acorizal and Nova Brasilândia, reached 100% coverage, others, such as Santa Terezinha and Confresa, recorded less than 50%. Spatial analyses identified patterns of autocorrelation, with hot spots of high incidence and mortality concentrated in the North and Northeast regions of the state, while cold spots were in the South and Southeast regions. Furthermore, a negative spatial correlation was observed between COVID-19 incidence and vaccination coverage, as well as between incidence and the Social Progress Index (SPI), indicating that areas with lower socioeconomic development had a greater spread of the virus. The findings reinforce that, although vaccination has been an essential element in reducing morbidity and mortality, vaccine hesitancy, inequality in coverage and limited access to health services reveal persistent challenges. Effective communication strategies and equitable and coordinated public policies are essential to mitigate these disparities, ensuring greater equity in facing future health crises.

**Keywords:** COVID-19; epidemiology; morbimortality indicator.

## LISTA DE FIGURAS

Figura 1.	Determinantes sociais da saúde: modelo de Dahlgren e Whitehead .....	19
Figura 2.	Mapa representativo do local de estudo.....	36
Figura 3.	Representação ilustrativa das diferenças entre as matrizes do tipo “ <i>Queen</i> ” e “ <i>Rook</i> ”, respectivamente.....	48
Figura 4.	Ilustração dos quadrantes do diagrama de dispersão de Moran .....	51
Figura 5.	Distribuição das taxas de incidência acumuladas padronizadas por idade, por 100 mil habitantes, nos municípios do estado de Mato Grosso, 2020 a 2023 .....	55
Figura 6.	Distribuição das taxas de mortalidade acumuladas padronizadas por idade, por 100 mil habitantes, nos municípios do estado de Mato Grosso, 2020 a 2023 .....	55
Figura 7.	Taxa de incidência de COVID-19 padronizada por idade, por 100 mil habitantes, em cada município do Mato Grosso, nos anos de 2020 (A), 2021 (B), 2022 (C) e 2023 (D).....	56
Figura 8.	Taxa de mortalidade por COVID-19 padronizada por idade, por 100 mil habitantes, em cada município do Mato Grosso, nos anos de 2020 (A), 2021 (B), 2022 (C) e 2023 (D).....	57
Figura 9.	Série temporal da incidência (A) e mortalidade (B) por COVID-19, específica por faixa etária, por 100 mil habitantes, no Mato Grosso, entre os anos de 2020 a 2023 .....	58
Figura 10.	Série temporal da incidência (A) e mortalidade (B) por COVID-19 padronizada por idade por 100 mil habitantes, no Mato Grosso, entre os anos de 2020 a 2023 .....	59
Figura 11.	Decomposição da série temporal da taxa de incidência de COVID-19 no Mato Grosso, 2020 a 2023 .....	60
Figura 12.	Decomposição da série temporal da taxa de mortalidade de COVID-19 no Mato Grosso, 2020 a 2023 .....	60
Figura 13.	Cobertura vacinal contra a COVID-19 de acordo com o esquema vacinal completo (A) e reforço (B), nos municípios do estado de Mato Grosso, 2021 a 2023 .....	63
Figura 14.	Série temporal da cobertura vacinal (%) contra a COVID-19 de acordo com a faixa etária, considerando o esquema vacinal completo (A) e reforço (B), no Mato Grosso, entre os anos de 2021 a 2023.....	65
Figura 15.	Correlação entre a cobertura vacinal e taxas de incidência (A) e mortalidade (B) por COVID-19 no Mato Grosso, 2021 a 2023.....	66
Figura 16.	Diagrama de dispersão do <i>I</i> de Moran Global univariado para as variáveis de taxa de incidência (A), mortalidade (B), cobertura vacinal (C) e IPS (D).....	68
Figura 17.	Diagrama de dispersão do <i>I</i> de Moran Global bivariado para as variáveis de Incidência x CV (A), Incidência x IPS (B) e CV x IPS (C) .....	70
Figura 18.	<i>Clusters</i> dos municípios para a análise de LISA univariado, nas taxas de incidência (A), mortalidade (B), cobertura vacinal (C) e IPS (D) .....	71
Figura 19.	<i>Clusters</i> dos municípios para a análise de LISA bivariado, para as variáveis de Incidência x CV (A), Incidência x IPS (B) e CV x IPS (C) .....	73
Figura 20.	Distribuição e organização das rodovias federais no estado de Mato Grosso .....	82

## LISTA DE TABELAS

Tabela 1.	Classificação dos vinte e cinco municípios do Mato Grosso com os maiores e menores valores de IPS, 2024.....	26
Tabela 2.	Especificações das vacinas oferecidas de acordo com os diferentes fabricantes durante a Campanha Nacional de vacinação contra a COVID-19 .....	32
Tabela 3.	Características populacional e socioeconômica dos 141 municípios do estado de Mato Grosso, 2020.....	36
Tabela 4.	Divisão das regiões de saúde do estado de Mato Grosso, 2024 .....	40
Tabela 5.	Características da cobertura da saúde nas regiões de saúde do estado de Mato Grosso .....	41
Tabela 6.	Fonte de dados das variáveis abordadas no estudo.....	42
Tabela 7.	Distribuição taxas de morbimortalidade da COVID-19 por faixa etária, sexo e raça/cor de pele, no estado de Mato Grosso, 2020 a 2023 .....	53
Tabela 8.	Estatística descritiva das taxas de incidência, mortalidade e letalidade, nos municípios do estado de Mato Grosso, entre os anos de 2020 a 2023 .....	54
Tabela 9.	Análise da tendência das taxas de incidência e mortalidade por 100 mil habitantes e padronizadas por idade no Mato Grosso, 2020 a 2023 .....	61
Tabela 10.	Cobertura vacinal contra a COVID-19 de acordo com o esquema vacinal completo e reforço, no estado de Mato Grosso, 2021 a 2023 .....	62
Tabela 11.	<i>I</i> de Moran Global univariado, média, desvio padrão e pseudo-significância das variáveis incidência, mortalidade, letalidade, cobertura vacinal e IPS, no Mato Grosso .....	67
Tabela 12.	<i>I</i> de Moran Global bivariado, média, desvio padrão e pseudo-significância da correlação espacial das variáveis, no Mato Grosso .....	69

## LISTA DE ABREVIATURAS E SIGLAS

AEDE	Análise Exploratória de Dados Espaciais
APC	Mudança Percentual Anual
BI	Bronquite Infecciosa
CDC	Centro de Controle de Doenças
CNDSS	Comissão de Determinantes Sociais da Saúde
COVID-19	<i>Coronavirus Disease 2019</i>
CV	Cobertura Vacinal
DataSUS	Departamento de Informática do Sistema Único de Saúde
DSS	Determinantes Sociais da Saúde
EPIs	Equipamentos de Proteção Individual
EUA	Estados Unidos da América
HCoV	Coronavírus Humano
IBGE	Instituto Brasileiro de Geografia e Estatística
IBP	Índice Brasileiro de Privação
IDH	Índice de Desenvolvimento Humano
IDHM	Índice de Desenvolvimento Humano Municipal
IEPS	Instituto de Estudos para Políticas de Saúde
IFDM	Índice Firjan de Desenvolvimento Municipal
IPS	Índice de Progresso Social
IVS	Índice de Vulnerabilidade Social
LISA	Índice Local de Associação Espacial
MERS	Síndrome Respiratória do Oriente Médio
MMD	Malha Municipal Digital
OMS	Organização Mundial da Saúde
ONU	Organização das Nações Unidas
PCR	Reação em Cadeia da Polimerase
PED	Diarreia Epidêmica Suína
PNUD	Programa das Nações Unidas para o Desenvolvimento
SARS	Síndrome Respiratória Aguda Grave
SI-PNI	Sistema de Informação do Programa Nacional de Imunizações
SIVEP-Gripe	Sistema de Informação de Vigilância da Gripe
Sm. <sup>a</sup>	Santíssima
STL	<i>Seasonal-Trend Decomposition Using Loess</i>
SUS	Sistema Único de Saúde
SVI	<i>Social Vulnerability Index</i>
SVSA	Secretaria de Vigilância em Saúde e Ambiente
TES	Teoria da Escolha Social
UTI	Unidade de Terapia Intensiva

## SUMÁRIO

1.	<b>INTRODUÇÃO</b> .....	12
1.1.	<b>Epidemiologia da COVID-19: mundo, Brasil e Mato Grosso</b> .....	12
1.2.	<b>Determinantes sociais da saúde</b> .....	15
1.2.1.	Indicadores sociais e de saúde .....	20
1.3.	<b>Envelhecimento populacional e vulnerabilidade social</b> .....	26
1.3.1.	Padronização de taxas em epidemiologia .....	28
1.4.	<b>Medidas de prevenção e controle</b> .....	29
1.4.1.	Implementação e disponibilização da vacinação no estado de Mato Grosso .....	31
1.5.	<b>Justificativa</b> .....	32
2.	<b>OBJETIVOS</b> .....	34
2.1.	<b>Objetivo geral</b> .....	34
2.2.	<b>Objetivos específicos</b> .....	34
3.	<b>MATERIAL E MÉTODOS</b> .....	35
3.1.	<b>Tipo de estudo</b> .....	35
3.2.	<b>Local de estudo</b> .....	35
3.3.	<b>Critérios de inclusão e exclusão</b> .....	41
3.4.	<b>Coleta de dados</b> .....	41
3.4.	<b>Análises estatísticas descritivas</b> .....	42
3.4.1.	Taxas de incidência, mortalidade e letalidade .....	42
3.4.2.	Análise da cobertura vacinal.....	43
3.4.3.	Análise de tendência e sazonalidade.....	44
3.5.	<b>Análise de correlação de Spearman</b> .....	45
3.6.	<b>Análise exploratória de dados espaciais (AEDE)</b> .....	46
3.6.1.	Matriz de ponderação espacial e teste de permutação aleatória .....	47
3.6.2.	Estatística de <i>I</i> de Moran Global .....	49
3.6.3.	Índice local de associação espacial (LISA) .....	50
3.7.	<b>Aspectos éticos</b> .....	51
4.	<b>RESULTADOS</b> .....	53
4.1.	<b>Análise descritiva dos dados: taxas de incidência, mortalidade e letalidade</b> .	53
4.2.	<b>Análise descritiva dos dados: cobertura vacinal</b> .....	62
4.3.	<b>Correlação de Spearman: incidência, mortalidade e cobertura vacinal</b> .....	65
4.4.	<b>Autocorrelação espacial global: <i>I</i> de Moran univariado</b> .....	66
4.5.	<b>Autocorrelação espacial global: <i>I</i> de Moran bivariado</b> .....	68
4.6.	<b>Autocorrelação espacial local univariada: LISA</b> .....	70
4.7.	<b>Autocorrelação espacial local bivariada: LISA</b> .....	72
5.	<b>DISCUSSÃO</b> .....	74
6.	<b>CONCLUSÃO</b> .....	87
7.	<b>REFERÊNCIAS BIBLIOGRÁFICAS</b> .....	88

## 1. INTRODUÇÃO

### 1.1. Epidemiologia da COVID-19: mundo, Brasil e Mato Grosso

Os coronavírus são vírus que pertencem à família *Coronaviridae*, da ordem *Nidovirales* e subfamília *Coronavirinae*. Ao todo, sua subfamília apresenta quatro gêneros ( $\alpha$ -coronavírus,  $\beta$ -coronavírus,  $\gamma$ -coronavírus e  $\delta$ -coronavírus), porém, apenas os  $\alpha$ -coronavírus e  $\beta$ -coronavírus são capazes de infectar seres humanos (CORMAN; MUTH; NIEMEYER; DROSTEN, 2018; CSG, 2020; SIDDELL; WALKER; LEFKOWITZ; MUSHEGIAN *et al.*, 2019). Estudados desde os anos 1930, os coronavírus afetam animais de importância veterinária, podendo levar ao surgimento de doenças virais como a bronquite infecciosa (BI) em aves e a diarreia epidêmica suína (PED), causando perdas econômicas no setor agropecuário (BARRALNETTO; BARRETO; PINTO JUNIOR; ARAGÃO, 2020). Em 1965, o primeiro coronavírus humano (HCoV) foi isolado e associado a um resfriado comum (TYRRELL; BYNOE, 1965).

Até o ano de 2002, haviam sido relatados apenas quatro subespécies de coronavírus capazes de infectar o ser humano: os  $\alpha$ -coronavírus denominados 229E e NL63, e os  $\beta$ -coronavírus OC43 e HKU1 (GELLER; VARBANOV; DUVAL, 2012). Contudo, em novembro do mesmo ano, na província de Guangdong, China, surgiu o primeiro subtipo viral com capacidade letal: o SARS-CoV, responsável por causar a Síndrome Respiratória Aguda Grave (SARS, do inglês *Severe Acute Respiratory Syndrome*, ou SRAG, do português) (ZHONG; ZHENG; LI; POON *et al.*, 2003). Esse vírus se espalhou por 29 países da América do Norte, América do Sul, Europa e Ásia, ocasionando a epidemia de SARS, que foi controlada em julho de 2003, após infectar mais de 8.000 pessoas e causar cerca de 774 óbitos (WHO, 2015).

Em 2012, um novo  $\beta$ -coronavírus da família *Coronaviridae* foi identificado como o responsável pelo surgimento de casos de pneumonia na Arábia Saudita. Denominado de MERS-CoV, foi responsável por levar ao surgimento de casos de Síndrome Respiratória do Oriente Médio (MERS), onde cerca de 35% dos casos evoluíram para o óbito (WHO, 2022).

Em dezembro de 2019, um grupo de casos de pneumonia de causa desconhecida surgiu em Wuhan, na província de Hubei, China. Em janeiro de 2020, foi identificado um novo  $\beta$ -coronavírus, sendo este nomeado de SARS-CoV-2. Inicialmente, os primeiros casos foram associados a um mercado de frutos do mar de Wuhan, sugerindo uma origem zoonótica. Nos meses subsequentes, a disseminação do vírus responsável por ocasionar a COVID-19 (*Coronavirus Disease 2019*) levou ao aparecimento de milhões de casos confirmados e milhares de óbitos em todo o mundo impactando profundamente a sociedade e a economia global,

caracterizando assim uma pandemia (MARTIN; GONÇALVES; GOULARTE; DIAS *et al.*, 2020; WHO, 2020a).

A COVID-19 é uma doença infecciosa causada pelo vírus SARS-CoV-2, que pertence à família *Coronaviridae*. A transmissão do vírus ocorre principalmente por meio de partículas respiratórias que são liberadas quando uma pessoa infectada tosse, espirra, fala ou canta. Além disso, a transmissão também pode ocorrer por meio de superfícies contaminadas pelo vírus (PRATHER; WANG; SCHOOLEY, 2020).

Desde o surgimento da COVID-19, uma das maiores preocupações dos órgãos de saúde era o surgimento de casos de SRAG, uma complicação grave da doença que pode levar à internação em Unidade de Terapia Intensiva (UTI) e até mesmo ao óbito. Estudos têm mostrado que a SRAG é uma das principais causas de morte entre pacientes com COVID-19 (CEVIK; KUPPALLI; KINDRACHUK; PEIRIS, 2020; NICOLETI TURAZZA DA SILVA; PRADO ROSA; SARAMAGO MENDONÇA; DE ASSIS QUEIROZ *et al.*, 2021; WANG; HU; HU; ZHU *et al.*, 2020).

A SRAG também é associada a um aumento considerável na demanda por recursos de saúde, como ventiladores mecânicos e equipamentos de proteção individual (EPIs), colocando uma pressão ainda maior nos sistemas de saúde que se encontravam sobrecarregados durante a pandemia (GUAN; NI; HU; LIANG *et al.*, 2020).

A rota de entrada do SARS-CoV-2 no Brasil foi fortemente influenciada pelo tráfego aéreo internacional. O primeiro caso de COVID-19 no Brasil e na América Latina foi confirmado em 26 de fevereiro de 2020, em São Paulo, e foi importado do norte da Itália (JESUS; SACCHI; CLARO; SALLES *et al.*, 2020). Até 10 de março de 2020, 34 casos foram confirmados, sendo 85,3% deles importados, onde 54,8% vieram da Itália, 9,3% da China e 8,3% da França (CANDIDO; WATTS; ABADE; KRAEMER *et al.*, 2020).

O Brasil foi um dos países mais afetados pela pandemia, apresentando uma alta taxa de morbidade e mortalidade em comparação com outros países do mundo (CHIORO; CALIFE; BARROS; MARTINS *et al.*, 2020). Isto devido a ações e políticas desiguais e descoordenadas entre os diferentes estados e municípios, levando a uma resposta complexa e desafiadora à pandemia no Brasil, o que pode ter contribuído para o aumento da disseminação do vírus e o agravamento da crise sanitária (BACH; WEGRICH, 2019; MOURA; CORTEZ-ESCALANTE; CAVALCANTE; BARRETO *et al.*, 2022; SILVA; JARDIM; SANTOS, 2020).

A disseminação da doença no Brasil atingiu de forma particularmente grave as populações vulneráveis, especialmente as que vivem em áreas rurais, remotas e com pouco acesso aos serviços de saúde, sendo que a maior parte das mortes ocorreu entre indivíduos com

60 anos ou mais, e/ou que apresentassem comorbidades como cardiopatias, diabetes, pneumopatias e doenças neurológicas (PIRES, 2020; SATHLER; LEIVA, 2021; SILVA; OLIVEIRA, 2020). O estado de Mato Grosso, por exemplo, é uma região marcada por desigualdades socioeconômicas e geográficas, onde as áreas que possuem os serviços de saúde necessários são, principalmente, as regiões urbanas já consolidadas ou em crescimento acelerado e consolidação, relacionadas principalmente aos centros do agronegócio (ALBUQUERQUE; RIBEIRO, 2021).

Um estudo realizado em abril de 2020, demonstrou que a maioria dos casos confirmados se concentrou na região Sudeste do Brasil. Até o dia 26 de abril de 2020, o Brasil registrou 61.888 casos confirmados de COVID-19, com 4.205 óbitos, representando uma taxa de letalidade de 6,8% (SILVA; OLIVEIRA, 2020).

A primeira onda de COVID-19 no Brasil apresentou um pico de óbitos entre julho e setembro de 2020, com o país registrando até 1.590 mortes em um único dia. Nesse período, a média móvel em 14 dias foi aproximadamente de 1.000 mortes diárias. A segunda onda começou em novembro de 2020, com valores semelhantes de médias móveis de mortes diárias. Até dezembro de 2021, o número total de casos acumulados ultrapassou 22 milhões no Brasil e 270 milhões no mundo, com óbitos acumulados ultrapassando 617 mil e 5,3 milhões, respectivamente. Após essas ondas iniciais, o Brasil enfrentou novas variantes, incluindo a variante Ômicron, que resultaram em novas ondas de infecção no segundo semestre de 2022 (GOMES, 2022; WHO, 2024).

Ao término de 2023, o total de casos e óbitos acumulados no Brasil foi de 38.210.864 e 708.638, respectivamente. Atualmente, o país está posicionado no sexto lugar dentre os países com mais casos do mundo e é o segundo com maior total de óbitos acumulados, ficando atrás apenas dos Estados Unidos da América (EUA). Em relação à percentagem de população vacinada, o Brasil apresenta uma cobertura vacinal de 87% para pelo menos uma dose aplicada e 81% para o esquema vacinal completo (WHO, 2024).

Até maio de 2024, as regiões do Brasil que apresentaram os maiores números totais de casos e óbitos estão a região Sudeste (15.497.414 casos e 343.286 óbitos), Nordeste (7.559.088 e 136.849) e Sul (8.239.177 e 112.994). Entretanto, a região que apresentou maior taxa de incidência e mortalidade acumulada foi o Centro-Oeste, com 27.817,6 de incidência e 411,5 de mortalidade por 100 mil habitantes. Ao comparar os estados que compõem o Centro-Oeste, o Distrito Federal se destaca com uma maior taxa de incidência acumulada em comparação aos outros três estados, de 31.367,6 por 100 mil habitantes. Enquanto o estado que apresenta maior

taxa de mortalidade acumulada é o Mato Grosso, com 437,1 por 100 mil habitantes (BRASIL, 2024).

## 1.2. Determinantes sociais da saúde

A atenção à saúde da população no Brasil evoluiu consideravelmente ao longo do tempo. Essas transformações vão além do progresso na tecnologia e na medicina, envolvendo especialmente a ampliação dos serviços oferecidos e o aprimoramento do acesso da população a esses cuidados (SILVA, 2023).

Inicialmente, os serviços de saúde eram limitados e acessíveis a poucos. Com o passar dos anos, políticas públicas e reformas estruturais, como a criação do Sistema Único de Saúde (SUS) em 1988, foram implementadas para garantir que todos os cidadãos tivessem direito a atendimento médico gratuito e de qualidade (SILVA, 2023). Assim, a saúde do Brasil foi impulsionada por iniciativas de promoção da saúde e prevenção de doenças, que incluem campanhas de vacinação, educação em saúde e pelo aumento no número de unidades de saúde, hospitais e programas de saúde da família, visando cobrir áreas antes negligenciadas, como regiões rurais e periferias urbanas (PALMEIRA; MORO; GETULINO; VIEIRA *et al.*, 2022; VIACAVA; OLIVEIRA; CARVALHO; LAGUARDIA *et al.*, 2018).

Contudo, o acesso às ações de promoção da saúde ainda apresenta desigualdades. (CARAM; MENDONÇA; MARQUES; BRITO *et al.*, 2021). As desigualdades na saúde resultam em diferentes probabilidades de exposição aos fatores que influenciam a saúde e a doença em indivíduos, além de ocasionar diferenças mensuráveis e perceptíveis nas condições de saúde da população. Essas disparidades estão diretamente ligadas às diferenças no acesso aos serviços de promoção, prevenção e tratamento, provocando variações nas taxas de adoecimento e mortalidade da população (BARRETO, 2017). A desigualdade é ainda mais evidente em áreas vulneráveis, onde há escassez de ambientes propícios para a promoção da saúde dessa população (CARAM; MENDONÇA; MARQUES; BRITO *et al.*, 2021).

A desigualdade vai além da dimensão econômica, abrangendo diversas expressões da questão social, envolvendo gênero, aspectos étnicos/raciais, acesso à educação, condições de trabalho, distribuição de serviços de saúde e exposição a riscos de saúde específicos (SILVA, 2023).

As condições de saúde de uma população são fortemente influenciadas pelo contexto social e ambiental em que vivem. Fatores como pobreza, habitações inadequadas, ambiente urbano precário e condições de trabalho insalubres impactam negativamente a saúde das pessoas. Geralmente, doenças e problemas de saúde são mais frequentes entre grupos sociais

desfavorecidos, incluindo os mais pobres, minorias étnicas e grupos discriminados. Isso demonstra o porquê países pobres apresentam condições de saúde inferiores em comparação com países ricos. Da mesma forma, dentro de qualquer país, seja ele rico ou pobre, as regiões menos prósperas ou as populações que compõem grupos étnicos marginalizados tendem a ter piores condições de saúde (BARRETO, 2017).

Evidências mostram que políticas que melhoram as condições econômicas ou fortalecem a proteção social têm efeitos positivos na saúde das populações. Além disso, intervenções que visam melhorar o ambiente de trabalho, combater a discriminação e promover a inclusão social, demonstraram sucesso na melhoria da saúde pública e também são importantes para a redução das desigualdades em saúde (BARRETO, 2017; MENDONÇA; LATGÉ; SILVA JUNIOR; CUNHA, 2020).

Durante a pandemia da COVID-19, a percepção de risco e os comportamentos adotados frente a ela foram influenciados por diversos fatores, incluindo características individuais, socioeconômicas e culturais (PIRES, 2020). Estudos têm mostrado que a percepção de risco está associada a um maior engajamento em comportamentos preventivos, como lavagem das mãos e uso de máscaras, e a uma maior adesão às medidas de distanciamento social e vacinação. Além disso, indivíduos que percebem o risco de contrair a COVID-19 tendem a adotar comportamentos mais protetivos em relação à doença (PRATHER; WANG; SCHOOLEY, 2020).

É válido dizer que a percepção de risco pode ser afetada por diversos fatores, como a mídia e as informações divulgadas, a confiança nas autoridades de saúde e a crença na eficácia das medidas de prevenção. Além disso, a percepção de risco também pode ser influenciada pela posição social e econômica do indivíduo na sociedade (BEZERRA; SILVA; SOARES; SILVA, 2020; SPOSATI, 2020).

As desigualdades sociais e econômicas presentes na sociedade brasileira foram um dos principais agravantes da pandemia da COVID-19 no país (BEZERRA; SILVA; SOARES; SILVA, 2020; CHIORO; CALIFE; BARROS; MARTINS *et al.*, 2020). Estudos realizados no Brasil, indicam que as regiões com menor índice de desenvolvimento humano foram as mais afetadas pela pandemia, com maiores taxas de mortalidade em comparação com as regiões mais desenvolvidas (ALBUQUERQUE; RIBEIRO, 2021; BEZERRA; SILVA; SOARES; SILVA, 2020; CHIORO; CALIFE; BARROS; MARTINS *et al.*, 2020).

Entre os grupos mais afetados pela pandemia no Brasil estão as pessoas de baixa renda, idosos, moradores de rua, comunidades indígenas e quilombolas, assentados, entre outros. Esses grupos enfrentam desafios adicionais, incluindo barreiras de acesso aos serviços de saúde,

maiores taxas de morbimortalidade, condições insalubres de moradias e maior exposição ao vírus devido a condições socioeconômicas precárias (CARVALHO, 2022; MENDONÇA; LATGÉ; SILVA JUNIOR; CUNHA, 2020; PIRES, 2020). Dados mostram que durante o ano de 2022, o país possuía cerca de 281 mil moradores de rua, aproximadamente 1.693.535 indígenas (correspondendo a 0,83% da população brasileira) e 22.169.101 idosos (10,9% da população brasileira) vulneráveis frente a uma pandemia (CHIORO; CALIFE; BARROS; MARTINS *et al.*, 2020; CRUZ; ANDRADE; MOSCON; MICHELETTO *et al.*, 2020; IBGE, 2022a; IPEA, 2022).

Dessa forma, a falta de acesso a recursos básicos, como água e saneamento adequados, bem como a condições de habitação inadequadas, aumenta a exposição à infecção e agravam os efeitos da doença (MOURA; CORTEZ-ESCALANTE; CAVALCANTE; BARRETO *et al.*, 2022). Além disso, as condições de trabalho precárias e a dificuldade de acesso a serviços de saúde contribuem para a propagação da doença nessas populações (CRUZ; ANDRADE; MOSCON; MICHELETTO *et al.*, 2020; SILVA, 2021; SPOSATI, 2020).

Nesta perspectiva, a falta de acesso a informações precisas e confiáveis, dificuldades financeiras, moradia e condições de trabalho precárias, podem corroborar para o aumento da chance de populações vulneráveis contrair a COVID-19, devido aos comportamentos que elevam o risco de infecção, como a falta de uso de máscaras, o não cumprimento do distanciamento social, a inadequada higiene pessoal e a não adesão a vacinação (CARVALHO, 2022; SILVA, 2021).

A vulnerabilidade social na pandemia não está restrita apenas às condições materiais, mas também está relacionada a fatores político-sociais e culturais. A desinformação, o medo, o negacionismo científico, a falta de liderança política, a desigualdade na distribuição de recursos e a discriminação são fatores que contribuem para a perpetuação das desigualdades na pandemia (BIEHL, 2021; VENTURA; REIS, 2021).

Como forma de definição, o comportamento de risco consiste em um conjunto de ações, atitudes ou práticas que aumentam a probabilidade de um indivíduo contrair uma doença ou sofrer lesões. Na epidemiologia, é frequentemente associado a comportamentos relacionados à saúde, como uso de drogas, consumo excessivo de álcool, inatividade física, tabagismo, comportamentos sexuais de risco, entre outros (FIGUEIREDO, 2015).

Em populações vulneráveis, o comportamento de risco pode ser praticado por diversos motivos, como falta de acesso à informação sobre cuidados de saúde adequados, falta de recursos financeiros para adquirir alimentos saudáveis ou serviços de saúde, desemprego e instabilidade financeira, discriminação e estigma social, entre outros fatores. Esses fatores

podem levar a uma maior exposição aos riscos à saúde, reduzir a capacidade de aderir a medidas preventivas, aumentar a prevalência de comorbidades e, conseqüentemente, aumentar a vulnerabilidade dessas populações à COVID-19 e outras doenças (CARVALHO, 2022; SPOSATI, 2020).

No cenário nacional, a criação da Comissão Nacional de Determinantes Sociais da Saúde (CNDSS) em 2006, destacou a importância da implementação de políticas públicas para redução das desigualdades sociais, promovendo a missão de organizar as evidências sobre as ações necessárias para promover a equidade em saúde globalmente (BARRETO, 2017). A partir da comissão, em 2008, foi determinado três princípios de ação para que os governos de todos os países aplicassem para reduzir as desigualdades sociais, sendo eles: melhorar o cenário cotidiano das pessoas, tratar fatores que levem a distribuição desigual de poder, dinheiro e recursos, e analisar o problema e possíveis ações a serem tomadas (WHO, 2008).

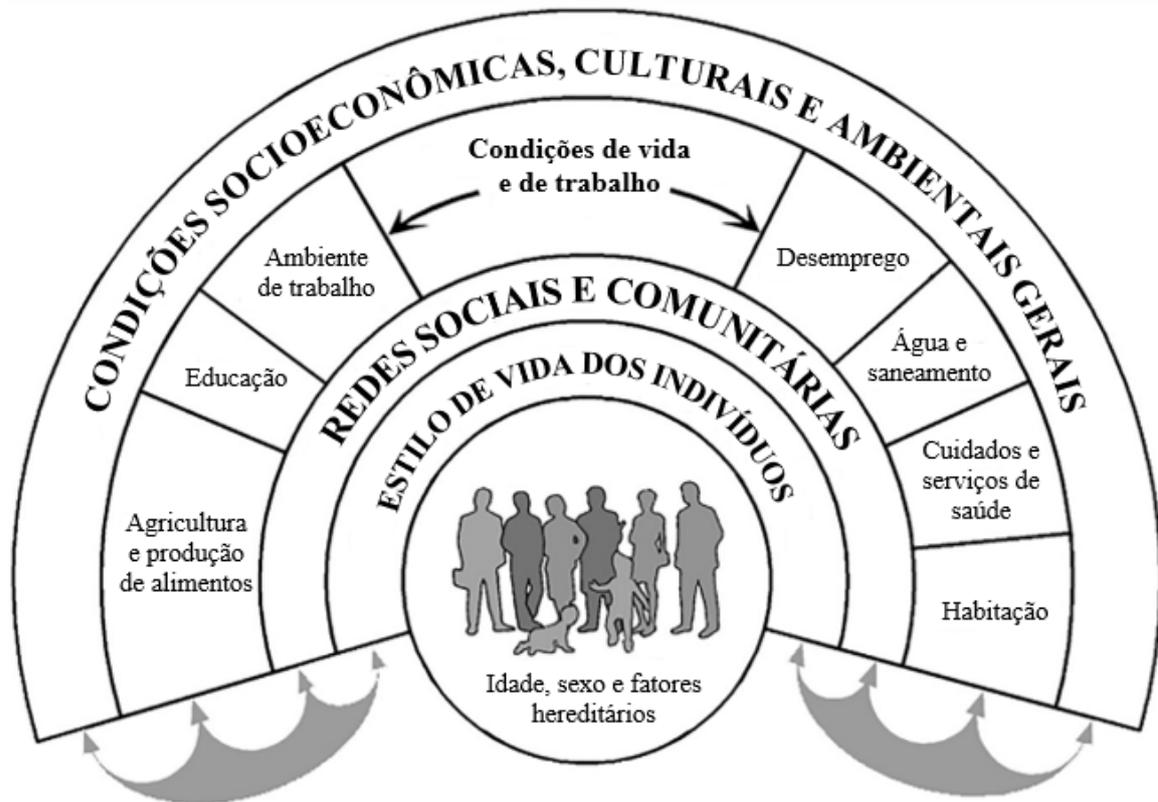
Para a CNDSS, os determinantes sociais da saúde (DSS) referem-se aos fatores socioeconômicos, culturais, étnicos/raciais, psicológicos, comportamentais e ambientais de uma sociedade que influenciam as condições de vida e trabalho de seus integrantes. Entre os exemplos de determinantes sociais estão a qualidade da habitação, a disponibilidade de saneamento básico, as condições do ambiente de trabalho, o acesso a serviços de saúde e a educação, além das redes sociais e comunitárias que proporcionam suporte social (BUSS; PELLEGRINI FILHO, 2007).

O modelo de Dahlgren e Whitehead é uma abordagem conceitual amplamente utilizada para compreender os DSS (Figura 1). Ele apresenta um diagrama de camadas que ilustram como diferentes fatores influenciam a saúde dos indivíduos e das populações. Esse modelo facilita a visualização gráfica dos DSS e sua distribuição conforme o nível de abrangência. No entanto, ele não se propõe a explicar detalhadamente as relações e mediações entre os diversos níveis, nem a origem das iniquidades (BUSS; PELLEGRINI FILHO, 2007; DAHLGREN; WHITEHEAD, 1991; 2021).

De acordo com o modelo, os indivíduos estão na base, com suas características biológicas básicas como idade, sexo e fatores genéticos, que influenciam diretamente seu potencial e suas condições de saúde. A próxima camada representa o comportamento e os estilos de vida individuais. Esta camada está situada no limiar entre os fatores individuais e os DSS, uma vez que os comportamentos, muitas vezes vistos como de responsabilidade individual e dependentes de escolhas pessoais, são, na verdade, fortemente influenciados por determinantes sociais. Esses comportamentos estão condicionados por diversos fatores sociais, como informações disponíveis, propaganda, pressão dos pares, e as possibilidades de acesso a

alimentos saudáveis e espaços de lazer. O modelo de Dahlgren e Whitehead destaca que as escolhas individuais são moldadas por um contexto social mais amplo, ilustrando como os DSS operam em diferentes níveis para influenciar a saúde dos indivíduos e das populações (BUSS; PELLEGRINI FILHO, 2007; DAHLGREN; WHITEHEAD, 1991; 2021).

Figura 1. Determinantes sociais da saúde: modelo de Dahlgren e Whitehead



Fonte: Adaptado de Dahlgren e Whitehead (2021).

Desta forma, a saúde é moldada por uma interação complexa de componentes biológicos, comportamentos individuais relacionados ao estilo de vida e fatores coletivos que dependem das condições políticas, econômicas, sociais, culturais e ambientais. O estilo de vida individuais, como o hábito de fumar, a prática regular de exercícios físicos e a adoção de uma dieta equilibrada, são significativamente influenciados por determinantes sociais da saúde, tais como o nível de renda, os padrões culturais e as mensagens veiculadas pela publicidade (SIMÃO FILHO, 2020).

A análise dos DSS permite a implementação de intervenções que ampliem as políticas públicas para reduzir as iniquidades e promover maior equidade na saúde. Identificar e abordar os fatores socioeconômicos e ambientais que afetam a saúde, facilita a criação de estratégias

que favorecem a justiça social e melhoram o acesso universal aos cuidados de saúde (VIANNA, 2012). Isso é essencial para que, entre suas ações coordenadas, possam atender de forma eficaz e prioritária aqueles indivíduos que estão em maior risco, com menor visibilidade e proteção (MASCARELLO; VIEIRA; SOUZA; MARCARINI *et al.*, 2021).

### 1.2.1. Indicadores sociais e de saúde

A origem dos indicadores sociais se dá nos anos 1960, uma década de grandes transformações sociais e políticas. Nos Estados Unidos, onde esses indicadores começaram a ser formalmente utilizados, o contexto era de intenso conflito social e busca por respostas às desigualdades evidentes, que foram exacerbadas por eventos como o assassinato do presidente Kennedy, a Guerra do Vietnã e os movimentos de protesto por direitos civis. Sociólogos norte-americanos foram chamados a explicar as disfunções sociais que a economia não conseguia justificar, resultando na construção de indicadores que pudessem refletir as realidades sociais de maneira quantificável (SANTAGADA, 2007).

Durante a década de 1980, ocorreu uma estagnação no interesse pelos indicadores sociais, especialmente em países industrializados, retomando o interesse a partir dos anos 1990. Este renascimento foi impulsionado por uma série de conferências e acordos internacionais promovidos pelas Nações Unidas, abordando temas desde educação e meio ambiente até direitos humanos e desenvolvimento sustentável. Os indicadores passaram a ser essenciais para monitorar o cumprimento dos objetivos estabelecidos nesses encontros, refletindo uma preocupação renovada com o bem-estar social em um contexto de globalização crescente (ROMERO; MARQUES; MUZY, 2021; SANTAGADA, 2007).

Os indicadores são ferramentas essenciais para a análise da situação de saúde de uma população, acompanhamento de políticas públicas e estratégias de intervenção. Eles são categorizados em indicadores sociais e de saúde e desempenham um papel fundamental no monitoramento de diversos aspectos da saúde pública. Indicadores de saúde são medidas que revelam o estado de saúde de uma população, permitindo avaliar aspectos como mortalidade, morbidade, acessibilidade aos serviços de saúde e efetividade das intervenções de saúde pública. Já os indicadores sociais medem condições sociais que impactam a saúde, como nível de educação, condições de moradia e renda, auxiliando no entendimento dos determinantes sociais da saúde (ROMERO; MARQUES; MUZY, 2021).

Os indicadores podem ser classificados como objetivos ou subjetivos. Os indicadores objetivos correspondem a ocorrências concretas ou elementos da realidade social, construídos a partir de dados públicos disponíveis, como a taxa de mortalidade infantil ou a prevalência de

doenças crônicas. Já os indicadores subjetivos correspondem a medidas construídas a partir da avaliação dos indivíduos ou especialistas com relação a diferentes aspectos da realidade, como a satisfação com os serviços de saúde (FIGUEIREDO FILHO; PARANHOS; ROCHA; DA SILVA JUNIOR *et al.*, 2013)

Dentre os aspectos dos determinantes sociais da saúde, a vulnerabilidade social pode ser analisada por meio do: *Social Vulnerability Index* (SVI) e o Índice de Vulnerabilidade Social (IVS). O SVI é utilizado para descrever a sensibilidade da comunidade aos desafios de saúde e os recursos disponíveis para mitigar os impactos negativos à saúde causados por riscos ambientais. Este índice leva em consideração variáveis como a proximidade das unidades de saúde, os níveis de pobreza, a educação, o isolamento linguístico, as características raciais/étnicas e a faixa etária das populações. Esse índice é amplamente utilizado para identificar áreas vulneráveis e direcionar suporte e recursos para comunidades que precisam melhorar suas condições de saúde (SCHUMANN; MOURA, 2015).

Já o IVS é uma ferramenta essencial para analisar as condições sociais nos municípios brasileiros, oferecendo uma abordagem mais abrangente do que as métricas tradicionais de pobreza, que se concentram apenas na falta de renda. Este índice é estruturado em três dimensões principais: infraestrutura urbana, capital humano, renda e inserção no mercado de trabalho. A relevância deste índice está em sua capacidade de proporcionar uma visão detalhada e multidimensional da vulnerabilidade social. Isso permite que gestores públicos, pesquisadores e formuladores de políticas direcionem seus esforços e recursos de maneira mais eficaz para as áreas que mais necessitam de intervenção (IPEA, 2015; SCHUMANN; MOURA, 2015).

Outro tipo de indicador social, utilizado para representar uma medida geral e sintética do desenvolvimento econômico de um território é o Índice de Desenvolvimento Humano (IDH) (PNUD, 2024). A institucionalização do IDH no Brasil começou com a Lei 9.995 de 26 de julho de 2000, que incluiu o IDH nas diretrizes orçamentárias dos programas sociais. Esse movimento foi impulsionado pela territorialização da agenda econômica e social da Organização das Nações Unidas (ONU) no Brasil, com destaque para a atuação do Programa das Nações Unidas para o Desenvolvimento (PNUD). A adoção do IDH no marco legal brasileiro reforçou sua importância e evidenciou a influência das comunidades epistêmicas que colaboram com a agenda do PNUD e a Teoria da Escolha Social (TES) (GODOY; SOARES, 2020).

No Brasil, a implementação do IDH foi fundamental para orientar a distribuição de recursos e avaliar o impacto das políticas públicas. No entanto, o uso do IDH também suscitou críticas. Especialistas argumentam que o índice, ao focar em médias, pode mascarar desigualdades significativas dentro dos países, como é o caso do Brasil, onde a concentração

de renda e as disparidades regionais são grandes desafios (SANTAGADA, 2007). Para enfrentar essas limitações, o Brasil adotou o Índice de Desenvolvimento Humano Municipal (IDHM), que permite uma análise mais granular e detalhada das condições de vida nos municípios, contribuindo para um planejamento mais eficaz e equitativo das políticas públicas (GODOY; SOARES, 2020).

O IDH utiliza três variáveis principais para avaliar o desenvolvimento de um país: a expectativa de vida ao nascer, que reflete a saúde da população; a educação, medida pela taxa de alfabetização de adultos e pelos anos de escolaridade; e a renda per capita, ajustada ao poder de compra em dólares. Segundo o PNUD, essas variáveis são resumidas em longevidade (sobrevivência), escolaridade (educação para a cidadania) e capacidade de consumo (participação no mercado) (WILKE, 2017).

Outro exemplo de indicador social é o Índice FIRJAN de Desenvolvimento Municipal (IFDM), criado em 2008 pela Federação das Indústrias do Estado do Rio de Janeiro, monitora anualmente o desenvolvimento socioeconômico dos municípios brasileiros, focando em três áreas principais: Emprego e Renda, Educação e Saúde. Este índice permite comparações anuais, facilitando a análise do progresso de municípios ou regiões e avaliando a eficácia das políticas públicas implementadas. Similar ao IDH, o IFDM varia de 0 a 1 e utiliza dados de fontes oficiais para medir renda, educação e saúde (BARBOSA, 2017; BARROSO; PEREIRA; SILVA; BRESCIANI *et al.*, 2022; ERVILHA; ALVES; GOMES, 2013; FIRJAN, 2018).

No entanto, uma problemática observada entre os índices apresentados, consiste no fato de que nenhum deles são capazes de analisar a desigualdade a nível nacional nas menores áreas, como os setores censitários. Dessa forma, foi criado o Índice Brasileiro de Privação (IBP), desenvolvido pelo Centro de Integração de Dados e Conhecimentos para Saúde (Cidacs/Fiocruz Bahia) e se baseia em dados do Censo Demográfico do IBGE (2010). Este índice é calculado a partir de setores censitários, que são as menores áreas geográficas utilizadas para a coleta de dados, permitindo uma análise detalhada e precisa das desigualdades dentro de pequenas áreas. O IBP torna possível analisar subpopulações em situação de privação material, acompanhar a implementação de programas sociais, explorar a privação material como fator causal ou associado a resultados de saúde, e informar políticas públicas direcionadas em nível intramunicipal (ICHIHARA; RAMOS; REBOUCAS; OLIVEIRA *et al.*, 2018; PORTELLA; JOSÉ MANUEL; PEDRO; MALÚ *et al.*, 2021).

Indicadores de saúde são essenciais para a gestão eficiente dos sistemas de saúde pública, permitindo monitorar, avaliar e planejar ações que visam melhorar a saúde da população. Eles fornecem dados quantitativos e qualitativos que permitem avaliar a qualidade de vida, o

desenvolvimento humano e as desigualdades sociais. Eles são definidos como medidas usadas para operacionalizar conceitos abstratos ou demandas programáticas específicas de saúde pública, permitindo uma análise objetiva e comparável das condições de saúde de diferentes populações (FIGUEIREDO FILHO; PARANHOS; ROCHA; DA SILVA JUNIOR *et al.*, 2013).

A definição de indicadores de saúde envolve medidas que sintetizam informações relevantes sobre determinados aspectos do estado de saúde de uma população ou sobre o desempenho de sistemas de saúde. Eles são dados quantitativos que refletem uma situação de saúde específica, permitindo comparações entre diferentes períodos e populações. Porém, é importante fazer a distinção entre dados e indicadores: dados são unidades primárias que, ao serem trabalhadas e analisadas, geram indicadores que produzem informações úteis para a tomada de decisão (OPAS, 2018).

Para serem eficazes, os indicadores de saúde devem possuir certas propriedades desejáveis. Entre essas propriedades estão a confiabilidade, que se refere à repetibilidade da mensuração, e a validade, que se refere ao grau de correspondência entre o que se mediu e o que se queria medir. Além disso, os indicadores devem ser relevantes para a agenda política, ter uma cobertura populacional ampla, ser sensíveis às ações previstas e específicos ao programa de saúde, entre outras características (FIGUEIREDO FILHO; PARANHOS; ROCHA; DA SILVA JUNIOR *et al.*, 2013).

Os indicadores de saúde têm várias aplicações na saúde pública. Eles são usados para descrever a carga de doença ou necessidades de atenção de saúde de uma população, orientando decisões sobre intervenções necessárias. Além disso, auxiliam na previsão de desfechos de saúde de populações, permitindo a antecipação de surtos de doenças e a adoção de medidas preventivas. Os indicadores de saúde ajudam também a entender porque alguns indivíduos são saudáveis e outros não, analisando determinantes sociais da saúde como gênero, etnia e renda (OPAS, 2018).

Os indicadores podem ser classificados como positivos ou negativos, dependendo de sua relação com o estado de saúde. Indicadores positivos, como a expectativa de vida ao nascer, refletem um bom estado de saúde; quanto maior a expectativa de vida, melhor o estado de saúde da população. Outros exemplos incluem a proporção de casos de tuberculose curados e a cobertura de vacinação. Por outro lado, indicadores negativos, como a taxa de mortalidade infantil e a taxa de incidência de AIDS, refletem problemas de saúde; quanto maiores esses indicadores, pior é o estado de saúde da população (OPAS, 2018).

Outro indicador amplamente utilizado é o Índice de Gini, que consiste em uma medida de desigualdade de renda dentro de uma população, desenvolvida pelo estatístico italiano Corrado Gini em 1914. Este índice é utilizado em estudos econômicos e sociais para avaliar a distribuição de renda e riqueza entre os habitantes de um país ou região. O valor do Índice de Gini pode variar de 0 a 1 (ou 0 a 100%, dependendo de sua apresentação), onde 0 representa a perfeita igualdade, ou seja, todos os indivíduos de uma população possuem a mesma renda e 1 indica a máxima desigualdade, onde uma única pessoa possui toda a renda. A principal vantagem do Índice de Gini é sua capacidade de fornecer uma medida de desigualdade baseada em razões, o que facilita a análise da concentração de renda sem a necessidade de informações detalhadas sobre a distribuição específica dos rendimentos (BARBOSA; DA COSTA; RAMOS; BERRA *et al.*, 2022; RODRÍGUEZ ESPARZA; ORTIZ LAZCANO; MACÍAS PONCE; MAZA DÍAZ CORTÉS, 2020).

Quando se trata da análise de fatores socioambientais, o Índice de Progresso Social (IPS) é considerado o mais completo na atualidade. O IPS foi desenvolvido por meio de uma colaboração entre diversas organizações e pesquisadores, incluindo o Instituto do Homem e do Meio Ambiente da Amazônia (Imazon), a Fundação Avina, o Centro de Empreendedorismo da Amazônia, a iniciativa Amazônia 2030, a Anattá e o *Social Progress Imperative*. Este índice consiste em uma medida que avalia diferentes dimensões, fornecendo um panorama multidimensional dos municípios. As dimensões avaliadas pelo IPS são: Necessidades Humanas Básicas, Fundamentos de Bem-Estar e Oportunidades, cada uma composta por componentes específicos avaliados por 53 indicadores. O índice é calculado a partir da média das três dimensões, e seus valores variam de 0 a 100, sendo que 0 indica um baixo desempenho e 100 um alto desempenho (MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.*, 2024).

Na dimensão de Necessidades Humanas Básicas, o IPS avalia a nutrição e cuidados médicos básicos, água e saneamento, moradia e segurança pessoal. Nutrição e cuidados médicos básicos avaliam o acesso a alimentos suficientes e serviços de saúde essenciais, usando indicadores como taxas de desnutrição infantil, mortalidade infantil e mortalidade materna. Água e saneamento medem a disponibilidade e qualidade da água potável e dos serviços de saneamento, considerando acesso a água tratada e sistemas de esgoto. A moradia analisa a adequação das moradias e a segurança do ambiente residencial, com indicadores como qualidade das moradias, eletricidade e segurança estrutural. Já a segurança pessoal examina a proteção contra crimes e violência, utilizando taxas de homicídio e crimes violentos como

indicadores (MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.*, 2024).

Nos Fundamentos de Bem-Estar, o IPS avalia o acesso ao conhecimento básico, informação e comunicação, saúde e bem-estar geral e a qualidade do meio ambiente. O componente de acesso ao conhecimento básico inclui a alfabetização e educação primária, medidas por taxas de alfabetização e matrículas escolares. Informação e comunicação verifica a disponibilidade de internet e outros meios de comunicação, considerando o número de usuários de internet e acesso a dispositivos de comunicação. Saúde e bem-estar examinam a saúde geral da população, incluindo expectativa de vida e prevalência de doenças. Enquanto que a qualidade do meio ambiente avalia a sustentabilidade ambiental e a exposição a riscos ambientais, com indicadores como poluição do ar e acesso a espaços verdes (MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.*, 2024).

Na dimensão de Oportunidades, o IPS considera direitos individuais, liberdade individual e de escolha, tolerância e inclusão e acesso à educação superior. Em relação aos direitos individuais, é avaliado a proteção dos direitos humanos e das liberdades civis, utilizando indicadores como liberdade de expressão e direitos políticos. Liberdade individual e de escolha mede a autonomia individual em tomar decisões e seguir caminhos desejados na vida, com indicadores como liberdade de movimento e autonomia pessoal. Tolerância e inclusão consideram a aceitação de grupos diversos e a ausência de discriminação, com indicadores como atitudes em relação a minorias e igualdade de gênero. Já o acesso à educação superior verifica a disponibilidade e acessibilidade de educação superior e técnica, considerando taxas de matrícula em ensino superior e acesso a programas de treinamento técnico (MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.*, 2024).

Em 2024, o Brasil obteve uma pontuação de 68,90 no IPS Global, ficando na 67ª colocação entre 170 países. Ao comparar com outros países da América do Sul, Chile (78,43), Argentina (77,19) e Equador (69,56) apresentam melhores pontuações (MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.*, 2024; STERN; HARMACEK; KRYLOVA; HTITICH, 2024). No Mato Grosso, todos os municípios permaneceram abaixo da média nacional, sendo que o município com o maior valor de IPS foi a capital do estado, Cuiabá, com índice de 68,47, e o município de menor índice foi Nova Nazaré, com IPS de 42,78 (Tabela 1).

Tabela 1. Classificação dos vinte e cinco municípios do Mato Grosso com os maiores e menores valores de IPS, 2024

Maiores valores		Menores valores	
Município	IPS	Município	IPS
Cuiabá	68,47	Nova Nazaré	42,78
Primavera do Leste	67,64	Gaúcha do Norte	43,53
Rondonópolis	64,15	Santa Terezinha	44,10
Sapezal	64,05	Campinápolis	44,53
Alto Taquari	63,76	Colniza	44,96
Sinop	63,15	Cotriguaçu	45,00
Campo Verde	62,56	Canabrava do Norte	45,13
Várzea Grande	62,55	Vila Bela da Santíssima Trindade	45,54
Ponte Branca	62,22	Nova Monte Verde	46,10
Barra do Garças	62,06	União do Sul	47,66
Denise	61,71	Ribeirão Cascalheira	48,15
Indiavaí	61,61	Castanheira	48,20
Dom Aquino	61,50	Porto Alegre do Norte	48,71
Alto Garças	61,23	Juruena	48,85
Guiratinga	61,06	General Carneiro	49,19
Santa Rita do Trivelato	60,83	Nova Bandeirantes	49,25
Sorriso	60,73	Apiacás	49,46
Tangará da Serra	60,43	Peixoto de Azevedo	49,53
Nova Guarita	60,43	Serra Nova Dourada	49,66
Lambari D'Oeste	60,38	Bom Jesus do Araguaia	50,32
Pontal do Araguaia	60,29	Tabaporã	50,38
Araputanga	60,23	Novo Mundo	50,62
Nova Mutum	60,18	São Félix do Araguaia	50,71
Alto Araguaia	60,14	Novo Santo Antônio	50,83
Jauru	60,05	Cocalinho	50,96

Fonte: Índice de Progresso Social, 2024.

### 1.3. Envelhecimento populacional e vulnerabilidade social

O envelhecimento populacional é um fenômeno que se iniciou a partir da evolução das condições de saúde e dos avanços científicos ao longo da história. Até o início do século XX, a maioria das pessoas vivia em extrema pobreza, o conhecimento médico era limitado e a expectativa de vida era consideravelmente baixa. Nossos antepassados frequentemente enfrentavam a morte em idades que hoje consideramos prematuras (DATTANI; RODÉS-GUIRAO; RITCHIE; ORTIZ-OSPINA *et al.*, 2023; RILEY, 2005; ROMERO; MAIA, 2022).

Durante séculos, a expectativa de vida média global não ultrapassava os trinta anos. No entanto, com os avanços da medicina ocorridos no século XX, foi possível observar uma grande

melhoria nas condições de vida, resultando em uma expectativa de vida média global de 66 anos no final do século. Esse aumento, porém, ocorreu de maneira desigual entre os países. Em 2000, enquanto o Japão tinha uma expectativa de vida de 81 anos, países na África tinham uma média de 55 anos, e o Brasil registrava 70 anos, sendo este um valor inferior a outros países latino-americanos como Equador, Argentina, Colômbia e México (DATTANI; RODÉS-GUIRAO; RITCHIE; ORTIZ-OSPINA *et al.*, 2023; ROMERO; MAIA, 2022; ZIJDEMAN; RIBEIRA DA SILVA, 2015).

Nas últimas décadas, o Brasil tem experimentado uma significativa redução na mortalidade e fecundidade, com variações regionais importantes. Estudos indicam que a mortalidade e a fecundidade continuarão a diminuir, acentuando o envelhecimento populacional. As regiões Norte e Nordeste, tradicionalmente mais jovens, enfrentarão um processo de envelhecimento menos acentuado comparado às regiões Sul e Sudeste, onde a mediana da idade deverá se aproximar dos 50 anos até 2030 (GUIMARÃES; VILLARDI; SAMPAIO; ELEUTERIO *et al.*, 2021).

Esse processo de transição demográfica também tem sido observado em outros países da América Latina, como a Argentina e México que estão passando por mudanças similares em suas estruturas etárias, podendo alterar o consumo das famílias e a estrutura produtiva do país (SANTIAGO; PEROBELLI; OLIVEIRA; SALGUEIRO, 2017). No Brasil, a população idosa de 60 anos ou mais cresceu de 4% em 1940 para 11% em 2010, com projeções indicando que esse grupo etário alcançará 20% até 2033. Em 2016, um em cada dez brasileiros tinha 60 anos ou mais, e espera-se que, em 2060, essa proporção aumente para um em cada três (SILVA; FASSARELLA; FARIA; NABBOUT *et al.*, 2022).

O envelhecimento da população impõe desafios para o sistema de saúde, incluindo o aumento da demanda por cuidados de longo prazo, tratamento de doenças crônicas e reabilitação. Além disso, as mudanças demográficas exigem uma reorganização dos serviços de saúde para atender de maneira eficiente às necessidades de uma população envelhecida. (CARVALHO; GARCIA, 2003; SANTIAGO; PEROBELLI; OLIVEIRA; SALGUEIRO, 2017).

Essa dinâmica demográfica exige uma reestruturação das políticas públicas e econômicas para acomodar a nova realidade populacional. A adoção de políticas voltadas para a saúde, incluindo o desenvolvimento de infraestrutura adequada, formação de profissionais de saúde especializados, criação de programas de prevenção e promoção da saúde voltados para a população idosa, previdência e inclusão social dos idosos é fundamental para garantir que o envelhecimento não resulte em desafios insustentáveis para o Estado. A criação de políticas que

promovam a autonomia e a qualidade de vida dos idosos é essencial para enfrentar os impactos econômicos e sociais decorrentes dessas mudanças demográficas (OPAS, 2023; SILVA; FASSARELLA; FARIA; NABBOUT *et al.*, 2022).

A vulnerabilidade da população idosa possui aspectos além dos fatores físicos, emocionais e mentais. Ela ocorre a partir do resultado de uma construção social e todo o contexto histórico do indivíduo idoso, sendo necessário também levar em consideração fatores sociais, políticos, sexuais, espirituais e étnicos (BROCKLEHURST; LAURENSEN, 2008; MAIA, 2011). A interação desses fatores pode refletir a desigualdade do envelhecimento em uma região, influenciando os aspectos de saúde, fatores de risco, susceptibilidade a doenças, lesões e síndromes geriátricas nos indivíduos idosos (ROMERO; MAIA, 2022).

A vulnerabilidade física observada no envelhecimento populacional é uma das principais preocupações, pois com o avanço da idade há uma redução na reserva funcional, aumentando a probabilidade de desenvolvimento de doenças crônicas, declínio funcional, perda de autonomia e independência, e ocorrência de óbitos prematuros. A fragilidade física pode aumentar a chance de óbito em 179% em relação a indivíduos não frágeis, além de aumentar a probabilidade de desenvolver incapacidades e outras vulnerabilidades sociais (MAIA, 2011).

Evidências científicas demonstram que os idosos são o grupo mais vulnerável ao desenvolvimento da SRAG (NUNES; MACHADO; MORAIS; COSTA *et al.*, 2020). Isso ocorre não apenas devido à idade avançada, mas também porque muitos apresentam comorbidades pré-existentes, uma vez que a prevalência de doenças crônicas aumenta com o envelhecimento da população (YANG; YU; XU; SHU *et al.*, 2020). Essas condições incluem hipertensão, diabetes, doenças cardiovasculares e pulmonares, que estão frequentemente associadas a um sistema imunológico comprometido e a uma maior prevalência de doenças crônico-degenerativas (MAFRA; STOBBE; RABELLO; LINDEMANN *et al.*, 2023; ROTHAN; BYRAREDDY, 2020).

Uma revisão feita por Zhang *et al.* (2022), evidenciou que o risco de morte por COVID-19 aumenta exponencialmente com a idade, dobrando aproximadamente a cada cinco anos desde a infância até a velhice. De acordo com o estudo, crianças de 5 a 9 anos apresentam uma taxa de mortalidade de 0,001%, enquanto indivíduos com mais de 80 anos chegam a 8,29%. Sendo assim, indivíduos que estão na primeira década de vida apresentaram um risco de óbito cerca de 10.000 vezes menor quando comparado a indivíduos com 80 anos ou mais.

### 1.3.1. Padronização de taxas em epidemiologia

Avaliar as taxas de mortalidade e morbidade em diferentes regiões geográficas é fundamental para entender o estado de saúde das comunidades. No entanto, as comparações diretas entre as taxas brutas podem ser enganosas devido às variações nas distribuições etárias e outras características demográficas entre as populações. As taxas brutas, que são calculadas com base na população total estudada, não levam em conta essas diferenças, podendo assim não refletir com precisão o verdadeiro estado de saúde de uma população (NAING, 2000).

Para garantir uma comparação justa e precisa, é necessário padronizar as taxas, ajustando-as para características específicas como a idade e sexo. Essa padronização resulta em taxas padronizadas, que permitem uma avaliação mais adequada das condições de saúde, eliminando o impacto das diferenças estruturais entre as populações. Ao ajustar as taxas de mortalidade para a idade, podemos obter uma visão mais clara das taxas específicas de mortalidade por idade, que são mais informativas sobre o risco real enfrentado por diferentes grupos etários (NAING, 2000).

Basicamente, existem dois métodos principais de padronização: direto e indireto. Na padronização direta, utiliza-se uma população padrão com uma estrutura etária conhecida. Esta população pode ser real, como a população brasileira, ou fictícia, podendo ser uma combinação de várias populações. Normalmente o método direto é utilizado para analisar populações grandes ou quando ambas as populações apresentam as taxas específicas por idade. Já a padronização indireta é utilizada quando as taxas específicas por idade da população de estudo não são conhecidas ou são muito pequenas para fornecer estimativas precisas (AHMAD; BOSCHI-PINTO; LOPEZ; MURRAY *et al.*, 2001; NAING, 2000).

#### **1.4. Medidas de prevenção e controle**

Para controlar a disseminação do vírus, é importante adotar medidas preventivas, como usar máscaras faciais adequadas, cobrindo boca e nariz, lavar as mãos com frequência com água e sabão ou álcool em gel, manter o distanciamento físico de pelo menos 1 metro de outras pessoas, evitar aglomerações, abraços, apertos de mão e beijos (WHO, 2020b). As campanhas de conscientização sobre essas medidas preventivas foram disseminadas amplamente, porém, a adesão da população variou conforme a confiança nas autoridades e a clareza das informações transmitidas (SOARES; OLIVEIRA; DA SILVA; SILVA *et al.*, 2021).

A influência das mídias digitais e as ações de gestão sanitária nas medidas de prevenção e controle da COVID-19 foram observadas em um estudo realizado a partir da análise de vídeos coletados da plataforma YouTube. A análise dos 100 vídeos mais assistidos contendo a palavra-chave "coronavírus" revelou que menos de um terço deles abordava os principais

comportamentos preventivos definidos pelo Centro de Controle de Doenças (CDC) dos Estados Unidos, como higienização das mãos, evitar contato com pessoas enfermas, ficar em casa quando doente, cobrir a tosse ou espirro com lenço de papel, usar máscara facial ao cuidar de alguém doente e limpar e desinfetar objetos e superfícies. Além disso, a exposição prolongada às mídias sociais foi associada a maior vulnerabilidade a conteúdos que sugerem medo, ansiedade e morte, dificultando a adesão às medidas preventivas (BASCH; HILLYER; MELEO-ERWIN; JAIME *et al.*, 2020; SOARES; OLIVEIRA; DA SILVA; SILVA *et al.*, 2021).

Além das medidas preventivas individuais, a vacinação é outra importante estratégia para combater a COVID-19. As vacinas foram desenvolvidas para prevenir a manifestação e reduzir a gravidade da doença, além de diminuir a transmissão do vírus. É importante ressaltar que a vacinação também pode ajudar a evitar a propagação de novas variantes do vírus (CARDOSO; OLIVEIRA; CASANOVA; TOLEDO *et al.*, 2019; CHIORO; CALIFE; BARROS; MARTINS *et al.*, 2020; FREITAS; SANTOS; SANTOS, 2021).

O desenvolvimento de vacinas contra a COVID-19 foi um dos pontos mais positivos no combate ao vírus. Desde o início da pandemia, muitas empresas e instituições de pesquisa em todo o mundo se dedicaram intensamente ao desenvolvimento de vacinas eficazes e seguras (AYRES; TRAVASSOS; SAMPAIO, 2023; OLIVEIRA; SANTOS; CARVALHO; COSME *et al.*, 2022). Esses esforços culminaram na aprovação de várias vacinas, incluindo as desenvolvidas pelas empresas Pfizer-BioNTech, Moderna, AstraZeneca, Janssen e Sinovac (BADEN; EL-SAHLY; ESSINK; KOTLOFF *et al.*, 2021; POLACK; THOMAS; KITCHIN; ABSALON *et al.*, 2020; SADOFF; GRAY; VANDEBOSCH; CARDENAS *et al.*, 2021; TARTOF; SLEZAK; FISCHER; HONG *et al.*, 2021; VOYSEY; CLEMENS; MADHI; WECKX *et al.*, 2021).

Um estudo analisou dados de mais de 2 milhões de pessoas vacinadas na Escócia e mostrou que a vacina da Pfizer-BioNTech reduziu em 85% as hospitalizações relacionadas à COVID-19 em pessoas com mais de 80 anos (SHEIKH; MCMENAMIN; TAYLOR; ROBERTSON *et al.*, 2021).

Outros estudos também publicados durante o período pandêmico, demonstraram que a vacina CoronaVac da Sinovac BioNTech com parceria com o Instituto Butantan apresentou uma eficácia de mais de 95% na prevenção de hospitalizações a partir de 14 dias após a administração (TANRIOVER; DOGANAY; AKOVA; GUNER *et al.*, 2021), já a vacina Pfizer-BioNTech apresentou uma eficácia superior a 95,3% na prevenção de casos graves da doença e não houve queda na imunogenicidade após um mês da aplicação da dose de reforço

(BERNAL; ANDREWS; GOWER; GALLAGHER *et al.*, 2021), enquanto que a vacina Janssen demonstrou uma eficácia contra casos graves da doença de 85,4% após a primeira dose e atingiu 100% de eficácia após 14 dias da aplicação da dose de reforço (SADOFF; GRAY; VANDEBOSCH; CARDENAS *et al.*, 2021). Entretanto, cabe salientar que a eficácia observada em estudos clínicos controlados pode diferir da eficácia real observada na população. Além disso, os estudos supracitados apresentam diferenças metodológicas importantes e isso deve ser considerado ao realizar uma comparação de eficácia entre os imunizantes.

Uma revisão analisou 92 publicações sobre a eficácia das vacinas Pfizer, Moderna e AstraZeneca, categorizadas por tipo de vacina e diferentes variantes do vírus. Os principais resultados mostram que a eficácia das vacinas de mRNA (Pfizer e Moderna) para infecções positivas por PCR após uma dose é de 64,5%, enquanto após duas doses é de 89%. A eficácia para infecções assintomáticas, sintomáticas e severas após duas doses foi de 85,5%, 93,2% e 92,2%, respectivamente. Para a vacina AstraZeneca, a eficácia para infecções positivas por PCR após uma dose foi de 53,4% e, após duas doses, 69,6%. A eficácia para infecções assintomáticas, sintomáticas e severas após duas doses correspondeu a 69,7%, 71% e 90,2%, respectivamente (REYNOLDS; DEWEY; ASFOUR; LITTLE, 2023).

#### 1.4.1. Implementação e disponibilização da vacinação no estado de Mato Grosso

O primeiro caso confirmado da COVID-19 no Mato Grosso foi registrado no dia 20 de março de 2020, na capital, Cuiabá. Nesse mesmo período, já estavam sendo monitorados outros 58 casos suspeitos de COVID-19. Após quase um ano, em 18 de janeiro de 2021, a vacinação contra a COVID-19 começou no Mato Grosso. Nesta mesma data, o estado acumulava 199.035 casos e 4.743 óbitos por COVID-19, apresentando as piores taxas de incidência (10.737,60 por 100 mil habitantes) e de mortalidade (267,76 por 100 mil habitantes) do país (BRASIL, 2024). Inicialmente, o estado recebeu 126 mil doses do imunizante, priorizando a vacinação de pessoas idosas com 60 anos ou mais, pessoas com deficiências, indígenas aldeados e trabalhadores da saúde que atuavam na linha de frente do combate ao coronavírus. A escolha desses grupos foi fundamentada na maior vulnerabilidade dessas populações ao vírus e na necessidade de proteger os profissionais de saúde (CRISTALDO; BRANDÃO, 2021; SECOM-MT, 2021b).

Durante o período da vacinação, foram lançadas campanhas de comunicação visando informar a população sobre a importância da vacinação contra a COVID-19, quais os locais de vacinação e os grupos prioritários. Essas campanhas utilizaram diversas plataformas de mídia, incluindo redes sociais, rádio e televisão, visando alcançar o maior número possível de pessoas (BRASIL, 2022).

No Brasil, assim como no Mato Grosso, a vacinação contra a COVID-19 ocorreu a partir da utilização de diferentes vacinas, cada uma com diferentes tecnologias e regimes de doses (Tabela 2). Durante a Campanha Nacional, foi oferecido a vacina adsorvida de vírus inativado do Instituto Butantan, em colaboração com a Sinovac. A Fundação Oswaldo Cruz (Fiocruz/Bio-Manguinhos) distribuiu a vacina recombinante em parceria com a AstraZeneca, com versões fabricadas pela Fiocruz, pelo *Serum Institute of India* e através do consórcio *Covax Facility*. O laboratório Pfizer/BioNTech, forneceu a vacina de mRNA (RNA mensageiro), conhecida como Comirnaty. Por fim, a Janssen disponibilizou uma vacina recombinante, também vinda do consórcio *Covax Facility* (BRASIL, 2022).

Tabela 2. Especificações das vacinas oferecidas de acordo com os diferentes fabricantes durante a Campanha Nacional de vacinação contra a COVID-19

<b>Fabricante</b>	<b>Plataforma</b>	<b>Indicação de uso</b>	<b>Esquema vacinal</b>
<b>Sinovac/Butantan</b>	Vírus inativado	Idade maior ou igual a 6 anos	2 doses de 0,5 ml, com intervalo de 4 semanas
<b>AstraZeneca/ Fiocruz</b>	Vetor adenovírus recombinante	A partir de 18 anos de idade	2 doses de 0,5 ml, com intervalo de 4 a 12 semanas
<b>Pfizer/BioNTech</b>	RNA mensageiro	Idade maior ou igual a 12 anos	2 doses de 0,3 ml, com intervalo de 3 a 12 semanas
<b>Janssen</b>	Vetor viral (não replicante)	A partir de 18 anos de idade	Dose única de 0,5 mL

Fonte: Bula dos fabricantes e Secretaria Extraordinária de Enfrentamento à COVID-19 (Secovid), 2022.

Para garantir uma distribuição adequada e a administração eficaz das vacinas, foi efetuado um plano operacional, que envolveu a logística de distribuição, a capacitação dos profissionais de saúde e a articulação com diversas esferas de gestão pública. A estratégia de vacinação incluiu a microprogramação local, que foi essencial para mapear a população-alvo e implementar as melhores práticas para alcançar os grupos prioritários. Além disso, as unidades de saúde se adaptaram para realizar a vacinação em horários estendidos e finais de semana. Parcerias com instituições públicas e privadas foram formadas para descentralizar os pontos de vacinação, evitando aglomerações e garantindo a acessibilidade (BRASIL, 2022).

### 1.5. Justificativa

Durante a pandemia de COVID-19 foi possível observar desafios no enfrentamento da doença. A resistência ao uso de máscaras e ao distanciamento social, combinada com a falta de

políticas claras e consistentes, refletiu uma complexa interação de fatores socioeconômicos e culturais. A disseminação de desinformação e o negacionismo científico também contribuem para essa percepção distorcida, dificultando a adesão a medidas preventivas. Como consequência, houve uma maior dificuldade em controlar a disseminação da COVID-19, perpetuando a crise sanitária e aumentando a pressão sobre os sistemas de saúde (MALINVERNI; BRIGAGÃO; CARDOSO; VILLELA *et al.*, 2023; SODRÉ, 2020).

Adicionalmente, a percepção equivocada sobre a imunidade conferida pelas vacinas também impactou negativamente o comportamento das pessoas, resultando em uma falsa sensação de segurança. Muitas pessoas acreditavam estar completamente protegidas após a vacinação, o que levou à adoção/manutenção em grande frequência de comportamentos de risco, como o abandono do uso de máscaras e a participação em aglomerações. Este problema é agravado pela baixa cobertura vacinal, especialmente entre as populações mais vulneráveis, devido a iniquidade no acesso e baixa compreensão acerca da efetividade do completo ciclo vacinal e doses de reforço (LU, 2021).

Investigar os fatores que influenciam na morbimortalidade e vacinação por COVID-19, em populações vulneráveis é fundamental para compreender e mitigar as consequências da pandemia. Uma variedade de fatores sociais, econômicos e estruturais coloca alguns grupos populacionais, incluindo idosos, pessoas com doenças médicas pré-existentes e de baixa renda, trabalhadores de atividades essenciais, e minorias étnicas, em maior risco de infecção e sequelas graves.

É fundamental estudar a respeito dos desdobramentos da pandemia como forma de buscar promover a equidade em saúde e elaborar estratégias de prevenção e controle adaptados às necessidades de cada comunidade. Isso envolve campanhas de imunização direcionadas, melhor acesso a testes e tratamento, campanhas educativas culturalmente sensíveis e leis eficazes de distanciamento social.

Até o momento, não há estudos abrangentes que analisam a relação entre cobertura vacinal, morbimortalidade e determinantes sociais no estado de Mato Grosso. Esta pesquisa busca preencher essa lacuna ao fornecer uma compreensão detalhada dos desdobramentos da pandemia no estado, bem como a evolução da adesão vacinal e aspectos sociais relacionados. É essencial investir em estudos epidemiológicos que possam fornecer uma base sólida para políticas públicas que visem reduzir as desigualdades em saúde e melhorar a resposta a futuras crises sanitárias.

## **2. OBJETIVOS**

### **2.1. Objetivo geral**

Analisar a cobertura vacinal e morbimortalidade por COVID-19, no período de 2020 a 2023, no estado de Mato Grosso, considerando aspectos epidemiológicos, socioeconômicos e espaciais.

### **2.2. Objetivos específicos**

- ✓ Descrever as taxas de incidência, letalidade, mortalidade e cobertura vacinal contra a COVID-19, estratificadas por sexo, idade, raça/cor da pele, município e período mensal, de 2020 a 2023;
- ✓ Investigar a tendência temporal das taxas de incidência e mortalidade da COVID-19 e a relação com a cobertura vacinal no período de 2020 a 2023;
- ✓ Avaliar o padrão de distribuição espacial das taxas de incidência, mortalidade e cobertura vacinal, por ano e por período;
- ✓ Analisar a autocorrelação espacial das taxas de incidência, letalidade, mortalidade, cobertura vacinal e Índice de Progresso Social;
- ✓ Estimar a relação da distribuição espacial do Índice de Progresso Social com as taxas de incidência, mortalidade e cobertura vacinal contra a COVID-19.

### **3. MATERIAL E MÉTODOS**

#### **3.1. Tipo de estudo**

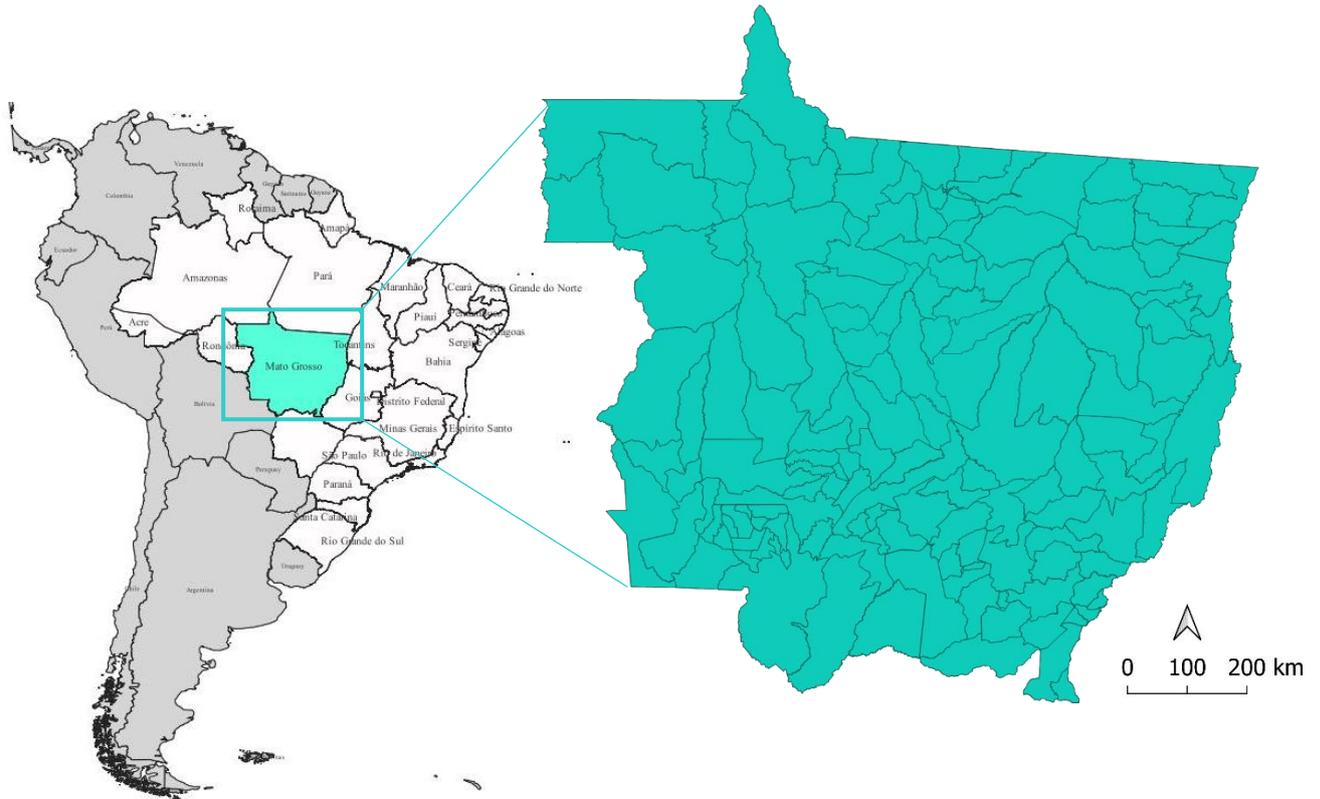
Trata-se de um estudo ecológico, combinando análises temporais e espaciais para analisar a evolução da cobertura vacinal e morbimortalidade por COVID-19 em Mato Grosso (2020-2023). Este tipo de estudo consiste em uma pesquisa que descreve a distribuição espacial e a evolução ou mudança de uma variável ao longo do tempo. Tal método é frequentemente utilizado em epidemiologia, onde os dados são coletados anualmente e analisados para determinar se os indicadores de ocorrência (morbidade/mortalidade) estão aumentando ou diminuindo, e quais fatores podem estar contribuindo para essa tendência. O objetivo é apresentar informações sobre a disseminação da COVID-19, levando em conta aspectos relacionados à população vulnerável que podem ou não ser afetados pela doença, identificando também a localidade geográfica em que é mais comum e a variação da frequência ao longo do tempo (ROMANOWSKI; CASTRO; NERIS, 2019).

#### **3.2. Local de estudo**

O estudo foi realizado no estado de Mato Grosso, Brasil (Figura 2), abrangendo todos os 141 municípios (Tabela 2), divididos por meio de suas 16 regiões de saúde (Tabela 3). Ao abordar todos os municípios do estado, a pesquisa visa fornecer uma visão abrangente da situação de saúde em Mato Grosso durante o período pandêmico, identificando áreas de vulnerabilidade e necessidades específicas de intervenção. De acordo com o último censo demográfico, o estado apresenta uma população estimada de 3.658.649 habitantes e Índice de Desenvolvimento Humano (IDH) de 0,736, ocupando o décimo primeiro lugar no ranking nacional em comparação com os estados brasileiros. Apresenta uma área de extensão territorial de 903.208,361 km<sup>2</sup>, sendo o terceiro maior estado do país em extensão, com 4,05 habitantes por km<sup>2</sup> (IBGE, 2022a).

A cobertura de serviços de saúde no estado é heterogênea, variando consideravelmente entre as diferentes regiões de saúde. Por exemplo, regiões como o Médio Araguaia e Centro Norte apresentam uma cobertura de atenção básica superior a 94%, enquanto outras, como o Oeste Matogrossense, têm uma cobertura de aproximadamente 73,5% (Tabela 4).

Figura 2. Mapa representativo do local de estudo



Fonte: Elaboração própria.

Tabela 3. Características populacional e socioeconômica dos 141 municípios do estado de Mato Grosso, 2020

(Continua)

Município	Área Territorial - Km <sup>2</sup> (2022)	População estimada (2022)	Escolarização 6 a 14 anos (2010)	IDHM (2010)	PIB per capita - R\$ (2021)
Acorizal	850,763	5.014	96,6	0,628	20.561,61
Água Boa	7.549,308	29.219	99,2	0,729	74.990,39
Alta Floresta	8.955,41	58.613	98,0	0,714	40.531,28
Alto Araguaia	5.402,308	17.193	96,7	0,704	59.497,11
Alto Boa Vista	2.248,414	5.715	96,8	0,651	37.231,59
Alto Garças	3.858,153	13.052	98,0	0,701	97.187,86
Alto Paraguai	1.847,354	8.009	95,4	0,638	14.382,3
Alto Taquari	1.436,582	10.904	98,3	0,705	113.538,74
Apiacás	20.489,024	8.590	95,0	0,675	22.418,58
Araguaiana	6.380,7	3.795	98,3	0,687	41.316,47
Araguainha	675,231	1.010	98,1	0,701	30.845,7
Araputanga	1.639,733	14.786	97,5	0,725	38.361,43
Arenópolis	417,337	10.576	98,4	0,704	24.711,43
Aripuanã	24.678,135	24.626	92,7	0,675	62.691,39

Barão de Melgaço	11.374,872	7.253	86,3	0,6	15.262,65
Barra do Bugres	5.976,864	29.403	96,9	0,693	44.018,43
Barra do Garças	8.363,149	69.210	96,3	0,748	41.607,18
Bom Jesus do Araguaia	4.266,636	7.280	97,2	0,661	112.613,63
Brasnorte	15.968,355	17.004	96,0	0,696	101.462,2
Cáceres	24.495,51	89.681	97,8	0,708	23.753,91
Campinápolis	5.978,985	15.347	81,9	0,538	26.958,25
Campo Novo do Parecis	9.428,586	45.899	97,8	0,734	187.188,91
Campo Verde	4.770,631	44.585	98,1	0,75	113.394,08
Campos de Júlio	6.792,808	8.822	97,9	0,744	455.838,1
Canabrava do Norte	3.449,037	4.485	98,1	0,667	56.716,7
Canarana	10.855,181	25.858	94,3	0,693	132.641,17
Carlinda	2.421,788	10.332	98,7	0,665	29.658,71
Castanheira	3.713,466	7.506	96,8	0,665	24.494,82
Chapada dos Guimarães	6.603,252	18.990	95,7	0,688	53.931,12
Cláudia	3.843,561	9.593	97,5	0,699	86.593,96
Cocalinho	16.563,136	6.220	90,4	0,66	52.079,24
Colíder	3.112,091	31.370	97,2	0,713	37.495,61
Colniza	27.960,237	25.766	95,4	0,611	20.651,18
Comodoro	21.485,018	18.238	96,1	0,689	59.213,23
Confresa	5.802,314	35.075	97,2	0,668	47.721,27
Conquista D'Oeste	2.684,676	3.760	98,6	0,718	34.399,39
Cotriguaçu	9.469,957	11.011	87,9	0,601	15.773,04
Cuiabá	4.327,448	650.877	95,8	0,785	47.700,88
Curvelândia	357,128	4.903	99,7	0,69	23.513,3
Denise	1.273,178	7.014	97,6	0,683	55.018,49
Diamantino	8.263,397	21.941	98,1	0,718	257.582,45
Dom Aquino	2.183,603	7.872	99,2	0,69	83.260,65
Feliz Natal	11.661,514	10.521	96,6	0,692	70.377,74
Figueirópolis D'Oeste	891,448	3.187	98,3	0,679	24.516,56
Gaúcha do Norte	16.908,375	8.642	81,5	0,615	163.138,13
General Carneiro	4.514,917	6.037	97,2	0,67	84.131,44
Glória D'Oeste	833,13	2.905	98,0	0,71	29.844,05
Guarantã do Norte	4.725,281	31.024	97,8	0,703	30.166,45
Guiratinga	5.043,899	10.966	99,2	0,705	46.198,67
Indiavaí	592,495	2.213	95,4	0,661	36.921,25
Ipiranga do Norte	3.422,016	7.815	99,3	0,727	235.258,71
Itanhangá	2.909,745	7.539	97,1	0,71	102.626,15
Itaúba	4.521,79	5.020	98,3	0,69	116.106,91
Itiquira	8.698,814	12.236	96,6	0,693	156.247,05
Jaciara	2.429,678	28.569	98,2	0,735	43.250,68
Jangada	1.114,302	7.426	96,1	0,63	22.421,04
Jauru	1.345,411	8.367	97,7	0,673	41.639,89
Juara	22.632,713	34.906	96,0	0,682	38.713,76
Juína	26.397,173	45.869	96,4	0,716	32.361,19
Juruena	3.207,837	10.213	96,6	0,662	17.721,06

Juscimeira	2.291,307	11.480	99,3	0,714	47.524,61
Lambari D'Oeste	1.810,547	4.790	95,4	0,627	39.221,83
Lucas do Rio Verde	3.674,596	83.798	97,5	0,768	98.915,82
Luciara	4.282,733	2.509	98,0	0,676	20.224,35
Vila Bela da Sm. <sup>a</sup> Trindade	13.484,71	16.774	93,9	0,645	38.942,45
Marcelândia	12.285,486	11.396	98,3	0,701	66.743,72
Matupá	5.228,272	20.091	98,6	0,716	75.388,99
Mirassol d'Oeste	1.085,486	26.785	96,6	0,704	29.702,61
Nobres	3.908,739	15.492	97,8	0,699	72.718,09
Nortelândia	1.336,754	5.956	96,9	0,702	55.592,83
Nossa Senhora do Livramento	5.537,413	12.940	95,5	0,638	29.622,31
Nova Bandeirantes	9.556,661	13.635	93,8	0,65	21.391,37
Nova Nazaré	4.034,539	4.200	66,3	0,595	35.035,46
Nova Lacerda	4.780,426	6.670	93,0	0,636	64.948,2
Nova Santa Helena	2.385,611	4.239	97,9	0,714	88.750,48
Nova Brasilândia	3.290,032	3.932	95,4	0,651	29.851,26
Nova Canaã do Norte	5.953,099	11.707	97,9	0,686	70.608,91
Nova Mutum	9.536,814	55.839	97,2	0,758	125.187,35
Nova Olímpia	1.327,266	16.352	95,7	0,682	35.164,43
Nova Ubitatã	12.460,736	11.530	96,6	0,669	261.783,61
Nova Xavantina	5.491,972	24.345	97,6	0,704	47.627,46
Novo Mundo	5.800,759	6.520	99,2	0,674	50.945,76
Novo Horizonte do Norte	920,048	3.349	98,3	0,664	24.944,48
Novo São Joaquim	5.225,595	6.919	93,9	0,649	178.424,27
Paranaíta	4.814,149	11.671	97,4	0,672	70.518,15
Paranatinga	24.166,632	26.423	94,9	0,667	91.867,26
Novo Santo Antônio	4.394,78	2.015	96,9	0,653	20.458,85
Pedra Preta	3.841,672	18.066	98,2	0,679	89.805,8
Peixoto de Azevedo	14.433,775	32.714	90,6	0,649	25.734,2
Planalto da Serra	2.437,59	3.166	98,5	0,656	87.939,09
Poconé	17.156,759	31.217	94,3	0,652	21.252,49
Pontal do Araguaia	2.742,482	6.932	97,7	0,734	17.674,65
Ponte Branca	701,138	2.008	98,0	0,686	20.481,87
Pontes e Lacerda	8.545,292	52.018	96,8	0,703	52.840,74
Porto Alegre do Norte	3.971,721	12.127	97,4	0,673	44.260,34
Porto dos Gaúchos	6.846,668	5.593	97,1	0,685	246.782,25
Porto Esperidião	5.835,278	10.204	98,5	0,652	25.346,89
Porto Estrela	2.045,467	3.224	93,1	0,599	29.907,24
Poxoréu	6.915,298	23.283	94,3	0,678	67.630,15
Primavera do Leste	5.470,383	85.146	94,7	0,752	109.043,17
Querência	17.799,989	26.769	91,1	0,692	231.667,59
São José dos Quatro Marcos	1.282,763	17.849	98,5	0,719	23.873,07
Reserva do Cabaçal	1.331,677	2.122	99,2	0,676	17.235,37
Ribeirão Cascalheira	11.354,555	10.089	94,3	0,67	72.424,03
Ribeirãozinho	624,997	2.593	95,9	0,692	77.486,61
Rio Branco	539,287	4.535	97,8	0,707	20.830,42

Santa Carmem	3.812,09	5.374	98,7	0,715	224.418,59
Santo Afonso	1.166,382	2.519	94,2	0,689	51.063,2
São José do Povo	489,737	2.875	96,6	0,661	14.374,39
São José do Rio Claro	4.525,304	14.911	95,9	0,682	68.644,21
São José do Xingu	7.465,563	5.964	93,7	0,657	165.549,74
São Pedro da Cipa	344,33	4.191	97,5	0,66	14.366,2
Rondolândia	12.658,341	3.505	96,8	0,64	28.110,57
Rondonópolis	4.824,02	244.911	98,4	0,755	72.181,58
Rosário Oeste	7.339,443	15.453	96,5	0,65	31.476,72
Santa Cruz do Xingu	5.623,39	2.661	98,8	0,684	118.731,1
Salto do Céu	1.753,378	3.679	99,2	0,666	29.237,92
Santa Rita do Trivelato	4.747,042	3.276	97,3	0,735	343.161,27
Santa Terezinha	6.466,223	7.596	95,4	0,609	35.169,16
Santo Antônio do Leste	3.403,593	4.099	85,3	0,655	186.843,37
Santo Antônio de Leverger	9.469,139	15.246	96,4	0,656	47.655,17
São Félix do Araguaia	16.682,473	13.621	95,6	0,668	135.991,34
Sapezal	13.614,552	28.944	98,1	0,732	253.910,54
Serra Nova Dourada	1.490,793	1.800	97,4	0,664	43.686,5
Sinop	3.990,87	196.312	98,0	0,754	64.607,12
Sorriso	9.293,629	110.635	96,5	0,744	131.899,11
Tabaporã	8.439,05	9.818	98,7	0,695	141.052,69
Tangará da Serra	11.636,825	106.434	93,3	0,729	51.892,66
Tapurah	4.492,539	14.370	96,6	0,714	139.617,54
Terra Nova do Norte	2.399,736	10.616	98,8	0,698	54.104,74
Tesouro	4.244,073	3.025	96,7	0,655	83.165,07
Torixoréu	2.398,383	4.164	98,3	0,716	60.613,76
União do Sul	4.590,628	3.838	95,5	0,665	145.942,7
Vale de São Domingos	1.901,545	2.904	99,4	0,656	24.697,43
Várzea Grande	724,279	300.078	95,9	0,734	34.151,42
Vera	3.058,364	12.800	97,2	0,68	110.130,08
Vila Rica	7.436,383	19.888	94,3	0,688	32.627,85
Nova Guarita	1.121,928	4.590	99,1	0,688	37.993,87
Nova Marilândia	1.905,744	3.529	99,0	0,704	126.907,27
Nova Maringá	11.553,479	5.846	95,9	0,663	133.034,17
Nova Monte Verde	5.139,307	8.313	99,1	0,691	39.171,89

Fonte: Instituto Brasileiro de Geografia e Estatística (IBGE).

Tabela 4. Divisão das regiões de saúde do estado de Mato Grosso, 2024

<b>Região de Saúde</b>	<b>Municípios</b>
Baixada Cuiabana	Cuiabá, Acorizal, Barão de Melgaço, Chapada dos Guimarães, Jangada, Nova Brasilândia, Nossa Senhora do Livramento, Planalto da Serra, Poconé, Santo Antônio do Leverger, Várzea Grande
Médio Araguaia	Água Boa, Bom Jesus do Araguaia, Canarana, Cocalinho, Nova Nazaré, Gaúcha do Norte, Querência, Ribeirão Cascalheira
Alto Tapajós	Alta Floresta, Apiacás, Carlinda, Nova Bandeirantes, Nova Monte Verde, Paranaíta
Sul Matogrossense	Rondonópolis, Alto Araguaia, Alto Garças, Alto Taquari, Araguainha, Campo Verde, Dom Aquino, Guiratinga, Itiquira, Jaciara, Juscimeira, Paranatinga, Pedra Preta, Poxoróe, Primavera do Leste, Santo Antônio do Leste, São José do Povo, São Pedro da Cipa, Tesouro
Norte Araguaia Karajá	São Felix do Araguaia, Alto Boa Vista, Luciara, Novo Santo Antônio, Serra Nova Dourada
Centro Norte	Diamantino, Alto Paraguai, Nobres, Nortelândia, Nova Maringá, Rosário Oeste, São Jose do Rio Claro
Garças Araguaia	Barra Do Garças, Araguaiana, Campinápolis, General Carneiro, Nova Xavantina, Novo São Joaquim, Pontal do Araguaia, Ponte Branca, Ribeirãozinho, Torixoreu
Oeste Matogrossense	Cáceres, Araputanga, Curvelândia, Gloria D' oeste, Indiavaí, Lambari D' oeste, Mirassol D' oeste, Porto Esperidião, Reserva do Cabaçal, Rio Branco, Salto do Céu, São José dos Quatro Marcos
Médio Norte Matogrossense	Tangará da Serra, Barra do Bugres, Campo Novo do Parecis, Denise, Nova Marilândia, Nova Olímpia, Porto Estrela, Santo Afonso, Sapezal, Arenópolis
Noroeste Matogrossense	Juína, Aripuanã, Castanheira, Colniza, Cotriguaçu, Juruena, Brasnorte
Sudoeste Matogrossense	Pontes e Lacerda, Campos de Júlio, Comodoro, Conquista D' oeste, Figueirópolis D' oeste, Jauru, Nova Lacerda, Rondolândia, Vale de São Domingos, Vila Bela da Santíssima Trindade
Araguaia Xingu	Porto Alegre do Norte, Canabrava do Norte, Confresa, Santa Cruz do Xingu, Santa Terezinha, São José do Xingu, Vila Rica
Teles Pires	Sinop, Cláudia, Feliz Natal, Ipiranga do Norte, Itanhangá, Lucas do Rio Verde, Nova Mutum, Nova Ubiratã, Santa Carmem, Santa Rita do Trivelato, Sorriso, Tapurah, União do Sul, Vera
Norte Matogrossense	Colíder, Nova Canaã do Norte, Nova Guarita, Marcelândia, Nova Santa Helena, Itaúba
Vale do Peixoto	Peixoto de Azevedo, Guarantã do Norte, Matupá, Novo Mundo, Terra Nova do Norte
Vale dos Arinos	Juara, Novo Horizonte do Norte, Porto dos Gaúchos, Tabaporã

Fonte: Instituto Brasileiro de Geografia e Estatística (IBGE).

Tabela 5. Características da cobertura da saúde nas regiões de saúde do estado de Mato Grosso

Região de Saúde	Cobertura da Atenção Básica (%)	Cobertura de Agentes Comunitários de Saúde (%)	Cobertura de Estratégia de Saúde da Família (%)	Médicos (por 1.000 Hab.)	Enfermeiros (por 1.000 Hab.)
Baixada Cuiabana	64,74	49,05	48,86	2,58	2,02
Médio Araguaia	94,60	91,59	91,43	1,07	1,31
Alto Tapajós	86,96	82,87	80,54	1,10	1,10
Sul Matogrossense	80,54	88,53	71,69	1,43	1,30
Norte Araguaia Karajá	100,00	100,00	100,00	0,67	1,51
Centro Norte	95,60	94,49	95,60	0,63	1,14
Garças Araguaia	87,90	84,80	87,90	1,48	1,75
Oeste Matogrossense	73,48	51,65	58,84	1,23	1,09
Médio Norte Matogrossense	84,29	51,79	75,61	1,20	0,95
Noroeste Matogrossense	71,78	75,60	71,78	0,61	0,94
Sudoeste Matogrossense	98,41	100,00	87,85	0,75	1,10
Araguaia Xingu	84,53	100,00	81,22	0,49	0,90
Teles Pires	92,35	69,59	82,60	1,75	1,60
Norte Matogrossense	80,75	99,04	80,75	1,38	1,56
Vale do Peixoto	88,57	100	88,57	0,75	0,83
Vale dos Arinos	92,72	91,65	92,72	0,78	0,96

Fonte: Instituto de Estudos para Políticas de Saúde (IEPS) (2022).

### 3.3. Critérios de inclusão e exclusão

Foram incluídos no estudo dados de morbimortalidade por COVID-19 ocorrida nos 141 municípios do estado de Mato Grosso, durante o período de 01 de janeiro de 2020 a 31 de dezembro de 2023. Para a vacinação, considerou-se o período de 01 de janeiro de 2021 a 31 de dezembro de 2023. A coleta de dados foi realizada em janeiro de 2024.

Foram excluídos dados que não apresentavam confirmação laboratorial, clínico-epidemiológica, clínico-imagem ou por critério clínico. Dados de outros períodos, de outras localidades e em branco não foram considerados.

### 3.4. Coleta de dados

O banco de dados dos casos incidentes e óbitos pela COVID-19 foi obtido por meio do Departamento de Informática do Sistema Único de Saúde (openDataSUS), que disponibiliza dados do Sistema de Informação de Vigilância da Gripe (SIVEP-Gripe) para notificação dos casos de SRAG e do Sistema e-SUS Notifica, implementado por meio da Secretaria de Vigilância em Saúde e Ambiente (SVSA), para notificação dos casos leves e moderados de COVID-19 (Tabela 6).

Os registros de vacinação contra a COVID-19 foram obtidos por meio do Sistema de Informação do Programa Nacional de Imunizações (SI-PNI), disponibilizado pelo Departamento de Informática do Sistema Único de Saúde (openDataSUS) (Tabela 6). O banco de dados bruto apresentava 7.334.746 registros de vacinação, foram excluídos os dados cujo endereço de residência do indivíduo correspondia ao de outro estado e que apresentavam linhas em branco. Assim, foi possível obter um banco de dados com o total de 6.882.055 registros de vacinação. Após a limpeza dos dados, houve uma redução de 6,17% (452.691 registros).

Os dados populacionais foram retirados do Instituto Brasileiro de Geografia e Estatística (IBGE), sendo que para os dados à nível estadual foi utilizado como base o Censo Demográfico de 2022. Já a nível municipal, foi utilizado banco de dados referente à projeção populacional por sexo e faixa etária, para os anos de 2020 a 2023. Para a investigação dos determinantes de saúde dos municípios de Mato Grosso, foram coletados dados a partir do Índice de Progresso Social (IPS) disponibilizado no ano de 2024 (Tabela 6). Para obtenção dos dados geográficos e confecções dos mapas das análises espaciais, foi utilizado as malhas municipais do estado de Mato Grosso, coletados a partir dos arquivos da Malha Municipal Digital (MMD), fornecido pelo IBGE, no ano de 2022 (IBGE, 2022b).

Tabela 6. Fonte de dados das variáveis abordadas no estudo

<b>Variáveis</b>	<b>Fonte</b>
Data de notificação (vacinação e morbimortalidade)	SI-PNI / SIVEP-Gripe / e-SUS Notifica
Faixa etária, sexo e raça (vacinação e morbimortalidade)	SI-PNI / SIVEP-Gripe / e-SUS Notifica
Casos e óbitos por COVID-19	SIVEP-Gripe/ e-SUS Notifica
Doses de vacinas (1º e 2º dose, dose única e reforço)	SI-PNI
Município de residência	SI-PNI / SIVEP-Gripe/ e-SUS Notifica
População municipal por sexo, raça/cor e faixa etária	IBGE
População padrão	IBGE
Índice de Progresso Social	IPS Brasil

Fonte: Elaboração própria.

### 3.4. Análises estatísticas descritivas

#### 3.4.1. Taxas de incidência, mortalidade e letalidade

Para a análise das tendências temporais, inicialmente foi realizado o cálculo das taxas específicas de morbimortalidade da COVID-19. Para determinação das taxas de incidência, mortalidade e letalidade específica por faixa etária, utilizou-se as seguintes fórmulas:

$$\text{Taxa de incidência específica} = \frac{\text{Total de casos confirmados de COVID-19, por faixa etária}}{\text{Total da população no município, no meio do período, por faixa etária}} \times 100.000$$

$$\text{Taxa de mortalidade específica} = \frac{\text{Total de óbitos por COVID-19, por faixa etária}}{\text{Total da população no município, no meio do período, por faixa etária}} \times 100.000$$

$$\text{Letalidade específica} = \frac{\text{Total de óbitos por COVID-19, por faixa etária}}{\text{Total de casos confirmados, por faixa etária}} \times 100$$

Para corrigir o efeito da estrutura etária na comparação entre localidades, as taxas foram padronizadas pelo método direto, utilizando como população padrão os dados do Brasil (para análises estaduais) e de Mato Grosso (para análises municipais). Desta forma, prosseguiu para os cálculos da taxa de incidência e mortalidade esperadas. Inicialmente, fez-se a multiplicação das respectivas taxas por faixa etária de cada município pela população por faixa etária da população padrão e dividiu pela constante utilizada em cada indicador para estimar o número absoluto de casos incidentes e óbitos por faixa etária. Posteriormente, fez-se o somatório de todos os casos incidentes e óbitos ajustados por idade e recalculou os indicadores esperados padronizados, conforme descrição a seguir:

$$\text{Taxa de incidência padronizada} = \frac{\sum \text{de casos incidentes esperados}}{\sum \text{população padrão}} \times 100.000$$

$$\text{Taxa de mortalidade padronizada} = \frac{\sum \text{de óbitos esperados}}{\sum \text{população padrão}} \times 100.000$$

#### 3.4.2. Análise da cobertura vacinal

Para analisar a cobertura vacinal, os registros de vacinação foram estratificados por idade, e assim calculou a proporção da população presente em cada faixa etária que recebeu a vacina, considerando como base o esquema vacinal completo e reforço de cada vacina contra a COVID-19. O esquema vacinal da Sinovac/Butantan consiste em duas doses de 0,5 ml cada, administradas com um intervalo de 4 semanas. A vacina da AstraZeneca/Fiocruz inclui duas doses de 0,5 ml, com um intervalo de 4 a 12 semanas entre as doses. A vacina fornecida pela Pfizer/BioNTech, consiste em duas doses de 0,3 ml cada, administradas com um intervalo de 3 a 12 semanas. Por fim, a vacina Janssen, apresenta uma única dose de 0,5 ml. Conforme as diretrizes do Plano Nacional de Operacionalização da Vacinação contra a COVID-19,

considera-se esquema vacinal completo as pessoas que receberam a primeira e segunda dose das vacinas Sinovac, Pfizer ou AstraZeneca, ou a dose única da vacina Janssen (BRASIL, 2022). O cálculo da cobertura vacinal é realizado a partir da seguinte fórmula:

$$\text{Cobertura Vacinal} = \frac{\text{Número de indivíduos vacinados, por faixa etária}}{\text{Número total da população no município, no meio do período, por faixa etária}} \times 100$$

### 3.4.3. Análise de tendência e sazonalidade

A análise de séries temporais é uma ferramenta utilizada para estudar a dinâmica temporal de variáveis, permitindo identificar tendência e sazonalidade. A tendência é estimada para identificar a direção geral do desenvolvimento das variáveis, de acordo com um intervalo de tempo, ou seja, a tendência de uma série temporal é definida como um padrão de crescimento/decrescimento e estacionariedade da variável em um determinado período. A sazonalidade é responsável por capturar os padrões periódicos e repetitivos que ocorrem em determinados períodos de tempo, como sazonalidades mensais, trimestrais ou anuais (ANTUNES; CARDOSO, 2015).

A decomposição desses componentes baseia-se em uma regressão localmente ponderada, conhecida como *Loess*, que é amplamente utilizada para estimar relações não-lineares entre variáveis. Quando associado à decomposição de séries temporais, o método STL (*Seasonal-Trend Decomposition using Loess*) é empregado para dividir a série temporal em três componentes principais: tendência, sazonalidade e resíduos. Isso facilita uma análise mais aprofundada e uma interpretação clara dos padrões de longo prazo, além de identificar irregularidades nos dados, evidenciando tendências e padrões nos dados (BROCKWELL; DAVIS, 2016; CLEVELAND; CLEVELAND; MCRAE; TERPENNING, 1990).

Para analisar o comportamento da morbimortalidade ao longo do tempo, foram construídos gráficos para as taxas de incidência e mortalidade. As séries temporais foram construídas e analisadas utilizando o *software* RStudio® versão 6.1.524, utilizando as bibliotecas *forecast*, *ggplot2* e *tidyverse* (HYNDMAN; ATHANASOPOULOS; BERGMEIR; CACERES *et al.*, 2024; HYNDMAN; KHANDAKAR, 2008; WICKHAM, 2016; WICKHAM; AVERICK; BRYAN; CHANG *et al.*, 2019). Complementando essa análise, foi aplicado o método de *Prais-Winsten*, para avaliar o crescimento, decréscimo e estacionariedade das tendências, utilizando a biblioteca *prais* (MOHR, 2021; PRAIS; WINSTEN, 1954). Na análise, a série temporal  $Y_t$  é considerada, onde os tempos  $t$  pertencem ao conjunto dos períodos

analisados. A linha de melhor ajuste para estimar a tendência temporal é definida pela equação de regressão linear (ANTUNES; CARDOSO, 2015):

$$Y_t = \beta_0 + \beta_1 t + \varepsilon t$$

Onde:

- $\beta_0$  = intercepto;
- $\beta_1$  = coeficiente de inclinação (taxa de mudança ao longo do tempo);
- $\varepsilon t$  = erro aleatório.

A regressão linear permite estimar o coeficiente  $\beta_1$ , e aplicar o intervalo de confiança desse coeficiente para calcular a tendência ou mudança percentual mensal (MPC) e seu intervalo de confiança, conforme a seguinte fórmula (ANTUNES; CARDOSO, 2015):

$$\begin{aligned} \text{MPC} &= [10^{\beta_1} - 1] * 100\% \\ \text{IC95\%} &= [10^{\beta_1 \text{mín.}} - 1] * 100\%; [10^{\beta_1 \text{máx.}} - 1] * 100\% \end{aligned}$$

Sendo:

- MPC = *mensal percent change* (tendência ou mudança percentual mensal);
- IC = intervalo de confiança de 95%.

Uma taxa positiva e significativa ( $p < 0,05$ ) indica uma tendência de aumento na série temporal, enquanto uma taxa negativa e significativa ( $p < 0,05$ ) sugere uma tendência de diminuição. Já uma taxa próxima de zero ou não significativa ( $p \geq 0,05$ ) indica que a série temporal está estacionária, ou seja, não apresenta diferenças significativas entre seu valor e zero (ANTUNES; CARDOSO, 2015).

### 3.5. Análise de correlação de Spearman

A correlação de *Spearman*, também conhecida como coeficiente de correlação ordinal de *Spearman*, é uma medida estatística não paramétrica que avalia a força e a direção da associação monotônica entre duas variáveis (SCHÖBER; BOER; SCHWARTE, 2018). Ao contrário do coeficiente de correlação de *Pearson*, que presume uma relação linear entre as variáveis e requer que os dados sejam normalmente distribuídos, a correlação de *Spearman* é adequada

para dados que não atendem a esses pressupostos, incluindo dados ordinais ou aqueles que contêm *outliers* (WINTER; GOSLING; POTTER, 2016).

O coeficiente de *Spearman*, representado pela letra grega  $\rho$  (rho), é calculado com base nos postos (ranks) dos dados. Inicialmente, cada observação de ambas as variáveis é substituída por sua posição ordinal dentro do conjunto de dados (SCHOBER; BOER; SCHWARTE, 2018; SEDGWICK, 2014).

O coeficiente de correlação de *Spearman* é calculado utilizando a seguinte fórmula:

$$\rho = 1 - \frac{6 \sum d_i^2}{n(n^2 - 1)}$$

Onde:

- $d_i$  é a diferença entre os postos das duas variáveis para cada par de observações;
- $n$  é o número total de pares de dados.

A fórmula é baseada na soma das diferenças ao quadrado dos postos ( $\sum d_i^2$ ), que é ajustada pelo número de observações para gerar um valor entre -1 e +1. Um coeficiente de +1 indica uma correlação positiva perfeita (ambas as variáveis aumentam ou diminuem juntas), enquanto um coeficiente de -1 indica uma correlação negativa perfeita (uma variável aumenta enquanto a outra diminui). Um valor próximo a zero sugere a ausência de uma correlação significativa entre as variáveis. Para uma melhor interpretação dos resultados, os coeficientes de correlação de *Spearman* estatisticamente significativos ( $p < 0,05$ ) foram classificados como muito fraca (0,00-0,19), fraca (0,20-0,39), moderada (0,40-0,59), forte (0,60-0,79) e muito forte (0,80-1,00) (MARTINS-FILHO; QUINTANS-JUNIOR; DE SOUZA ARAUJO; SPOSATO *et al.*, 2021; SCHOBER; BOER; SCHWARTE, 2018; SILVA; PACHECO; CARDOSO; LIMA *et al.*, 2022).

Antes de realizar a correlação de *Spearman*, foi conduzido um teste de normalidade de *Shapiro-Wilk* para avaliar a distribuição dos dados, confirmando a distribuição não paramétrica. Para a análise e confecção dos gráficos de correlação de *Spearman*, utilizou o *software GraphPad Prism*, versão 8.0.1.

### 3.6. Análise exploratória de dados espaciais (AEDE)

A Análise Exploratória de Dados Espaciais (AEDE) é uma abordagem metodológica que

auxilia na compreensão de acontecimentos de associação espacial, por meio de um conjunto de técnicas que descrevem as distribuições e permitem a visualização espacial de variáveis, identificam padrões de associação espacial (*clusters*) e identificam dados atípicos (*outliers*). Para identificar essas associações, a AEDE utiliza medidas globais e locais de autocorrelação espacial, que podem ser verificadas por testes estatísticos como a análise de *I* de Moran Global e Local (ALMEIDA, 2012; TEIXEIRA, 2020).

Para identificar os municípios em risco pela baixa adesão à vacina (esquema completo e reforço), e ainda, suas consequências, expressas por seus indicadores de morbimortalidade, foi utilizado a AEDE. Para tal, foi realizada a geocodificação mediante obtenção das coordenadas geográficas dos municípios do estado de Mato Grosso. Na sequência, foi realizada uma análise denominada *I* de Moran Global. Essa análise consiste em um índice global para avaliar a associação espacial de uma variável, baseada em distâncias estatísticas e calculadas a partir de um somatório de valores para uma dada distância. De forma complementar à análise de *I* de Moran Global, foi realizada as análises de Índice Local de Associação Espacial univariada e bivariada nas variáveis de incidência, mortalidade, letalidade, cobertura vacinal e IPS. Para a execução da AEDE, foi utilizado o *software* GeoDa, versão 1.22.

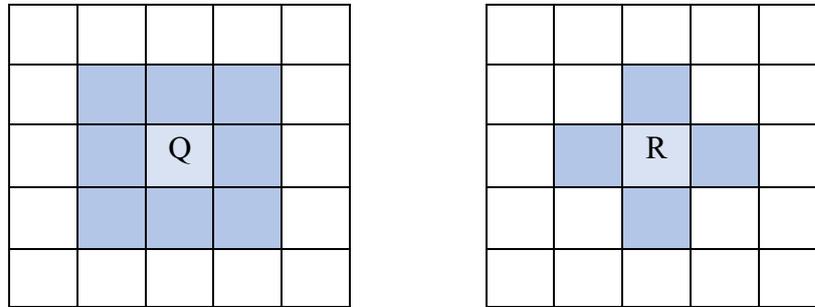
### 3.6.1. Matriz de ponderação espacial e teste de permutação aleatória

A matriz de ponderação espacial ( $W$ ) é uma ferramenta utilizada na análise espacial para representar as estruturas entre diferentes regiões em um espaço geográfico. Ela é estruturada como uma matriz de dimensão  $n$  por  $n$ , onde  $n$  consiste no número de regiões ou unidades espaciais em estudo, como no caso do presente estudo que utilizou como  $n$  os 141 municípios do Mato Grosso. Nessa matriz, cada elemento denotado como  $w_{ij}$  indica o grau de conexão ou proximidade entre os municípios  $i$  e  $j$ . Essa conexão pode ser baseada em diferentes critérios, como proximidade geográfica, econômica, cultural, social, entre outros (ALMEIDA, 2012; ANSELIN; BERA, 1998).

Normalmente, as matrizes de ponderação espacial baseiam-se na contiguidade, que consiste em uma matriz binária baseada nas conexões entre  $i$  e  $j$ . Sendo assim,  $w_{ij}$  corresponde a 1 se  $i$  e  $j$  forem contíguos, e corresponde a 0 se  $i$  e  $j$  não forem contíguos. Normalmente, para a hipótese nula assume-se que  $w_{ij}$  não possuem contiguidades, ou seja, são iguais a 0. Como exemplo de matrizes contíguas, têm-se as do tipo “*Queen*” (Rainha) e do tipo “*Rook*” (Torre), que são inspiradas nos movimentos feitos pelas peças de xadrez com os mesmos nomes. A diferença entre as matrizes (Figura 3), se dá pelo fato de que as do tipo “*Queen*” consideram todo seu entorno como uma região de conexão, enquanto a do tipo “*Rook*” considera como

vizinhos apenas os municípios que estiverem em contato adjacente, seja horizontalmente ou verticalmente, desconsiderando os vértices (ALMEIDA, 2012; ANSELIN; BERA, 1998).

Figura 3. Representação ilustrativa das diferenças entre as matrizes do tipo “*Queen*” e “*Rook*”, respectivamente



Fonte: Elaboração própria.

Para que uma AEDE seja realizada adequadamente, evitando possíveis vieses, é fundamental que a escolha da matriz de ponderação espacial seja bem definida e modelada da maneira adequada, visto que os resultados das análises espaciais variam de acordo com as matrizes de ponderação espacial escolhidas (ANSELIN; BERA, 1998). Dessa maneira, ambas as matrizes foram testadas para a realização deste estudo, para verificar qual se adequaria melhor para as análises, sendo então escolhida a matriz de ponderação do tipo “*Queen*”. A significância das estatísticas foram dadas por meio de testes de permutação aleatória, utilizando 999 permutações (LOBO, 2017).

O teste de permutação aleatória é uma técnica estatística utilizada para avaliar se a distribuição espacial de uma variável é aleatória ou se apresenta algum padrão. Nesse método, os valores observados de uma variável são aleatoriamente redistribuídos entre as diferentes regiões várias vezes, criando diferentes configurações possíveis dos dados (ALMEIDA, 2012).

Para cada uma dessas permutações, calcula-se uma estatística de teste, como o índice *I* de Moran. Esse processo gera uma distribuição de referência empírica com base nas várias permutações aleatórias realizadas. A estatística obtida dos dados observados é comparada com essa distribuição de referência. Se a estatística dos dados observados se desviar da distribuição de referência, isso indica a presença de um padrão espacial não aleatório. Em outras palavras, sugere que os valores da variável de interesse possuem autocorrelação, ou seja, que há dependência espacial entre as observações (ALMEIDA, 2012).

### 3.6.2. Estatística de $I$ de Moran Global

A estatística  $I$  de Moran, proposta por Moran em 1948, é uma medida de autocorrelação espacial que quantifica a similaridade entre valores de uma variável de interesse em diferentes localidades geográficas (ALMEIDA, 2012; MORAN, 1948).

Matematicamente, a estatística  $I$  de Moran é representada por:

$$I = \frac{n}{S_0} \frac{\sum_i \sum_j w_{ij} z_i z_j}{\sum_{i=1}^n z_i^2}$$

Ou, de forma matricial:

$$I = \frac{n}{S_0} \frac{z'Wz}{z'z}$$

Onde:

- $n$  é o número de municípios;
- $z$  corresponde aos valores da variável de interesse, padronizados;
- $Wz$  representa as médias dos valores da variável de interesse dos vizinhos padronizadas, definidos segundo uma matriz de ponderação espacial  $W$ ;
- $w_{ij}$  é um elemento da matriz de ponderação espacial  $W$ , que corresponde à interação entre as regiões  $i$  e  $j$ ;
- $S_0$  é a soma de todos os elementos da matriz de pesos espaciais  $W$ .

O índice  $I$  de Moran testa a hipótese nula de que não há dependência espacial, ou seja, os valores da variável de interesse em um município são independentes dos valores em municípios vizinhos ( $H_0: I=0$ ). A hipótese alternativa é que existe dependência espacial ( $H_1: I \neq 0$ ). Valores próximos de zero ou não significativos indicam ausência de autocorrelação espacial, sugerindo que os valores da variável de interesse estão distribuídos de forma aleatória. De outro modo que, valores positivos e significativos de  $I$  de Moran indicam autocorrelação espacial positiva, o que significa que municípios com valores altos (ou baixos) de uma variável tendem a ser vizinhos de outros municípios com valores igualmente altos (ou baixos). Em contrapartida, valores negativos e significativos apontam para autocorrelação espacial negativa, onde municípios com valores altos estão próximos de municípios com valores baixos (ALMEIDA, 2012; MORAN, 1948; TEIXEIRA, 2020).

Para investigar as relações espaciais entre diferentes variáveis de saúde relacionadas à COVID-19, como incidência, mortalidade, letalidade, cobertura vacinal e o IPS, foi realizada uma análise univariada e bivariada utilizando o *I* de Moran. Essa abordagem permite detectar padrões de autocorrelação espacial entre uma e duas variáveis, respectivamente, ajudando a entender como essas variáveis estão relacionadas geograficamente. Foram considerados significantes, as variáveis que apresentaram pseudo-valor- $p < 0,05$ , sendo que a significância estatística foi um critério de inclusão para avançar nas análises espaciais.

### 3.6.3. Índice local de associação espacial (LISA)

O Índice Local de Associação Espacial (LISA) é um método desenvolvido para identificar padrões de dependência espacial local, complementando a análise de autocorrelação espacial global. Este índice é uma variação do *I* de Moran, sendo também conhecido como Índice de Moran Local, que permite detectar áreas onde os valores de uma variável apresentam uma autocorrelação espacial significativa, identificando clusters de alta ou baixa concentração, bem como *outliers* (ALMEIDA, 2012; ANSELIN, 1995; TEIXEIRA, 2020).

Ao aplicar o LISA, cada município recebe um valor que indica a força e o tipo de associação espacial com seus vizinhos. Esse valor pode ser positivo, indicando *clusters* de valores semelhantes, ou negativo, indicando valores diferentes entre a os municípios e seus vizinhos. A interpretação dos resultados do LISA é de extrema importância para entender como diferentes áreas se relacionam espacialmente em termos de variáveis como renda, incidência de doenças, ou outras métricas socioeconômicas (ALMEIDA, 2012; ANSELIN, 1995; TEIXEIRA, 2020).

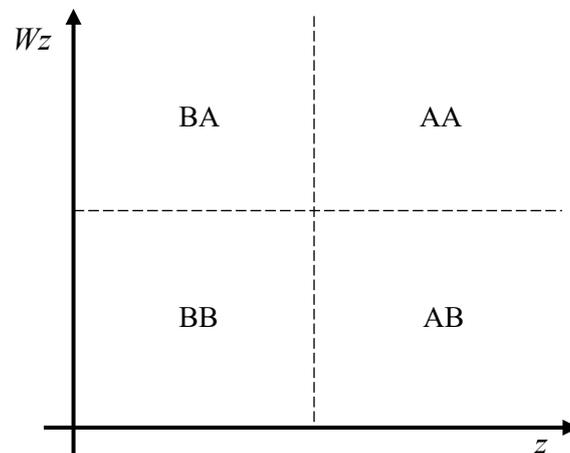
De acordo com Anselin (1995), a análise do LISA resulta na identificação de diferentes padrões de autocorrelação espacial, que podem ser classificados em quatro categorias principais, sendo que cada uma corresponde a um quadrante do diagrama de dispersão de Moran (Figura 4):

- *Clusters* Alto-Alto (AA): Municípios onde altos valores da variável estão cercados por municípios com altos valores.
- *Clusters* Baixo-Baixo (BB): Municípios onde baixos valores da variável estão cercados por municípios com baixos valores.
- *Clusters* Alto-Baixo (AB): Municípios com altos valores da variável cercadas por municípios com baixos valores.

- *Clusters* Baixo-Alto (BA): Municípios com baixos valores da variável cercados por municípios com altos valores.

Caso os valores analisados se encontrem completamente dispersos, sem uma orientação bem definida, pode ser resultado de uma inexistência de autocorrelação espacial. Em contrapartida, caso os valores estejam concentrados nos quadrantes identificados como BB e AA, têm-se que os valores apresentam forte autocorrelação espacial positiva. Enquanto que, caso os valores se concentrem nos quadrantes BA e AB, indica forte autocorrelação espacial negativa (LOBO, 2017).

Figura 4. Ilustração dos quadrantes do diagrama de dispersão de Moran



Fonte: Adaptado de Lima, Caldarelli e Camara (2014).

Após a verificação da significância estatística do LISA, é gerado um mapa chamado “LISA Map”, que evidencia apenas as áreas que são significativas. São significativos os municípios que apresentarem valores de  $p = 0,05$ ,  $p = 0,01$  ou  $p = 0,001$ , sendo estes identificados com diferentes colorações. Quando não há significância nos dados, os municípios são apresentados sem coloração (LOBO, 2017).

### 3.7. Aspectos éticos

O presente trabalho não foi submetido ao Comitê de Ética em Pesquisa (CEP) devido à natureza dos dados utilizados. De acordo com a Resolução nº 510/2016, do Conselho Nacional de Saúde (CNS), pesquisas que utilizam informações de domínio público e que não identificam os participantes não precisam ser registradas ou avaliadas pelo sistema CEP/CONEP. Isso inclui pesquisa com dados secundários que são agregados e anonimizados, sem a possibilidade de identificação individual dos participantes (CNS, 2016).

Os dados utilizados no presente estudo estão em conformidade com a Lei Geral de Proteção de Dados (LGPD – Lei nº 13.709/2018), uma vez que são anonimizados e públicos, não apresentando informações que possibilite a identificação direta ou indireta dos indivíduos.

## 4. RESULTADOS

### 4.1. Análise descritiva dos dados: taxas de incidência, mortalidade e letalidade

De janeiro de 2020 até dezembro de 2023, o estado de Mato Grosso registrou 890.279 casos e 15.123 óbitos por COVID-19. A Tabela 7 apresenta dados descritivos sobre a morbimortalidade da COVID-19 no Mato Grosso entre os anos de 2020 a 2023, levando em consideração a faixa etária, sexo e raça/cor de pele da população. Observa-se que as crianças e adolescentes (0-19 anos) apresentam as menores taxas de incidência, mortalidade e letalidade. A letalidade da COVID-19 aumenta progressivamente com a idade, atingindo 17,84% entre os indivíduos com 80 anos ou mais, sendo a mais elevada entre todas as faixas etárias analisadas.

Quando se considera o sexo (Tabela 7), a população feminina apresenta uma taxa de incidência de COVID-19 cerca de 16,4% maior que a população masculina. Porém, homens apresentam uma taxa de mortalidade 37% maior se comparada às mulheres. A letalidade entre os homens é aproximadamente 69% maior que entre as mulheres, com uma razão de letalidade masculina/feminina de 1,69.

Tabela 7. Distribuição taxas de morbimortalidade da COVID-19 por faixa etária, sexo e raça/cor de pele, no estado de Mato Grosso, 2020 a 2023

Variável	População		Incidência /100 mil hab.	Mortalidade /100 mil hab.	Letalidade %
	N	%			
<b>Faixa Etária</b>					
0 a 9	560.578	15,3	6.692,7	9,3	0,14
10 a 19	535.475	14,6	13.175,4	6,2	0,05
20 a 29	593.267	16,2	28.495,8	41,3	0,14
30 a 39	603.862	16,5	33.215,2	145,1	0,44
40 a 49	530.710	14,5	32.273,9	323,9	1,00
50 a 59	399.845	10,9	30.661,6	694,0	2,26
60 a 69	258.407	7,1	27.379,7	1.342,8	4,90
70 a 79	122.119	3,4	26.850,0	2.690,0	10,02
≥ 80	53.894	1,5	27.756,3	4.950,5	17,84
<b>Sexo</b>					
Feminino	1.817.114	49,7	26.528,0	349,9	1,3
Masculino	1.841.043	50,3	22.174,1	478,3	2,2
<b>Raça/Cor</b>					
Amarela	10.813	0,3	11.556,6	184,9	1,60
Branca	1.181.423	32,3	16.630,0	287,7	1,73
Indígena	56.621	1,5	7.273,3	254,0	3,49
Parda	2.048.649	56	21.909,9	399,7	1,82
Preta	360.651	9,9	8.268,7	257,6	3,11

Fonte: Elaboração própria a partir dos dados do SIVEP-Gripe, e-SUS Notifica e IBGE.

A taxa de incidência de COVID-19 no estado de Mato Grosso demonstrou variações entre os municípios, onde foi possível observar municípios que apresentaram uma taxa mínima de 7.705,1 e máxima de 47.865,3 a cada 100 mil habitantes (Tabela 8). O valor mínimo indica municípios que apresentaram baixa incidência quando comparado com os demais, enquanto o valor máximo reflete os picos de infecção que ocorreram em alguns municípios do Mato Grosso. A mediana de 25.411,3/100.000 habitantes indica que metade dos valores está abaixo desse ponto, enquanto a média é ligeiramente maior, sugerindo a presença de valores altos que elevam a média. Quando analisado o primeiro quartil (Q1) e terceiro quartil (Q3), é possível observar que 50% das taxas estão concentradas entre os valores de 19.935,6 e 31.660,0/100.000 habitantes. O desvio padrão de 8.451,0/100.000 habitantes reflete uma variação considerável na incidência, sendo que deve ser levado em consideração que tais resultados foram obtidos a partir das taxas acumuladas entre os períodos de 2020 a 2023 para a incidência e mortalidade, e entre 2021 a 2023 para a cobertura vacinal.

A letalidade máxima nos municípios avaliados foi de 1,26%, indicando a proporção de óbitos entre os casos confirmados, com uma média de mortalidade de 327,3/100.000 habitantes (Tabela 8).

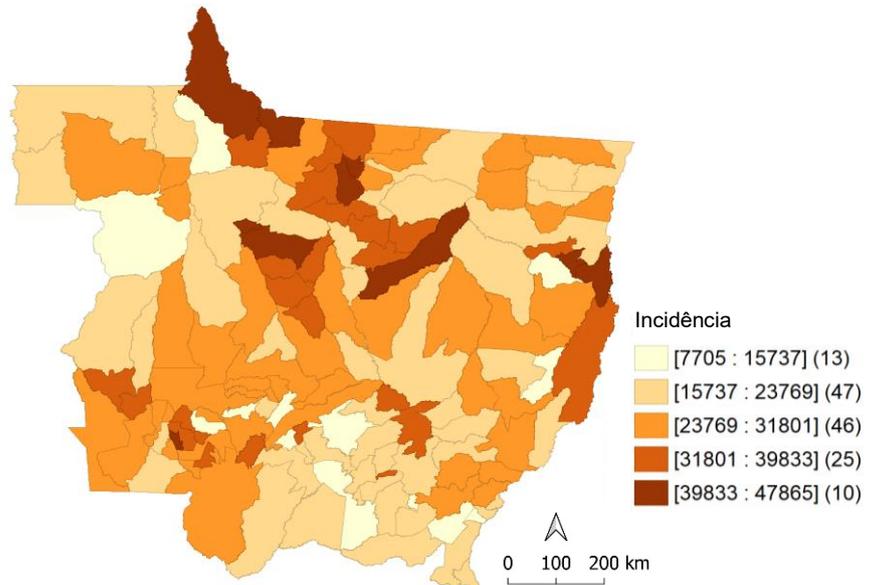
Tabela 8. Estatística descritiva das taxas de incidência, mortalidade e letalidade, nos municípios do estado de Mato Grosso, entre os anos de 2020 a 2023

<b>Variáveis</b>	<b>Mínimo</b>	<b>Máximo</b>	<b>Q1</b>	<b>Mediana</b>	<b>Q3</b>	<b>Média</b>	<b>Desvio Padrão</b>
Incidência	7.705,1	47.865,3	19.935,6	25.411,3	31.660,0	25.809,0	8.451,0
Mortalidade	72,3	604,0	259,1	317,4	384,9	327,3	99,3
Letalidade	27,4	932,1	238,0	324,5	477,7	357,1	169,1

Fonte: Elaboração própria. Nota: As taxas de incidência e mortalidade são demonstradas por 100 mil habitantes e padronizadas pela população por faixa etária do Mato Grosso. A letalidade corresponde a proporção de óbitos entre os casos incidentes, expressa em percentual.

Dentre os municípios que apresentaram as maiores taxas acumuladas de incidência por 100 mil habitantes (Figura 5), encontram-se Paranaíta (47.865), Novo Santo Antônio (46.543), Novo Horizonte do Norte (45.525), Porto dos Gaúchos (43.852), Apiacás (42.990), Indiavaí (42.238), Nova Guarita (40.994), Colíder (40.904), Feliz Natal (40.310) e Serra Nova Dourada (39.848), sendo a maioria localizada na mesorregião Norte Mato-Grossense, com exceção de Indiavaí que se localiza no Sudoeste Mato-Grossense e Novo Santo Antônio e Serra Nova Dourada no Nordeste Mato-Grossense.

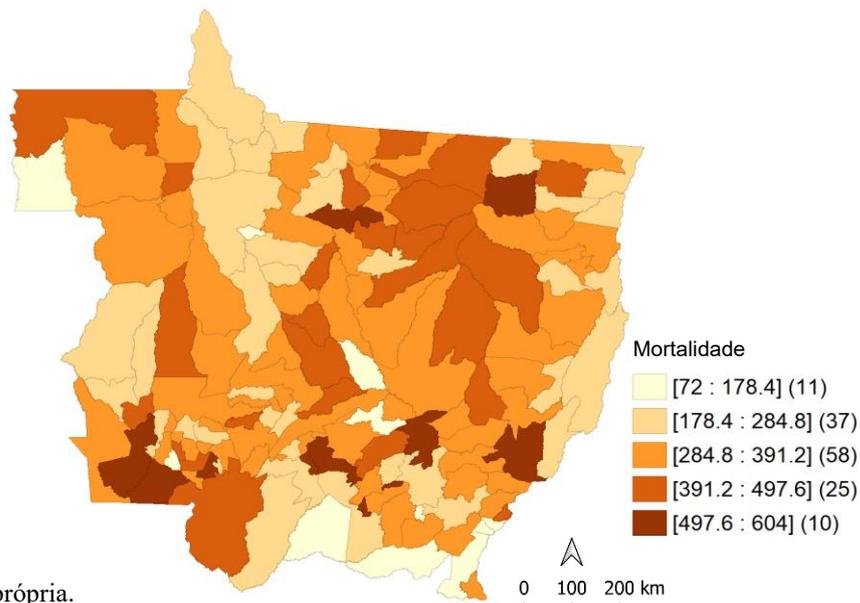
Figura 5. Distribuição das taxas de incidência acumuladas padronizadas por idade, por 100 mil habitantes, nos municípios do estado de Mato Grosso, 2020 a 2023



Fonte: Elaboração própria.

Em relação às taxas de mortalidade acumuladas padronizadas por idade (Figura 6), observou-se que houve uma distribuição mais heterogênea entre as diferentes regiões do Mato Grosso, onde os municípios que apresentaram as maiores taxas foram: Itaúba (604), Porto Esperidião (539), São Pedro da Cipa (539), Primavera do Leste (536), Pontes e Lacerda (514), São José do Xingu (510), Cuiabá (508), Várzea Grande (507), Mirassol d'Oeste (504) e Barra do Garças (503).

Figura 6. Distribuição das taxas de mortalidade acumuladas padronizadas por idade, por 100 mil habitantes, nos municípios do estado de Mato Grosso, 2020 a 2023

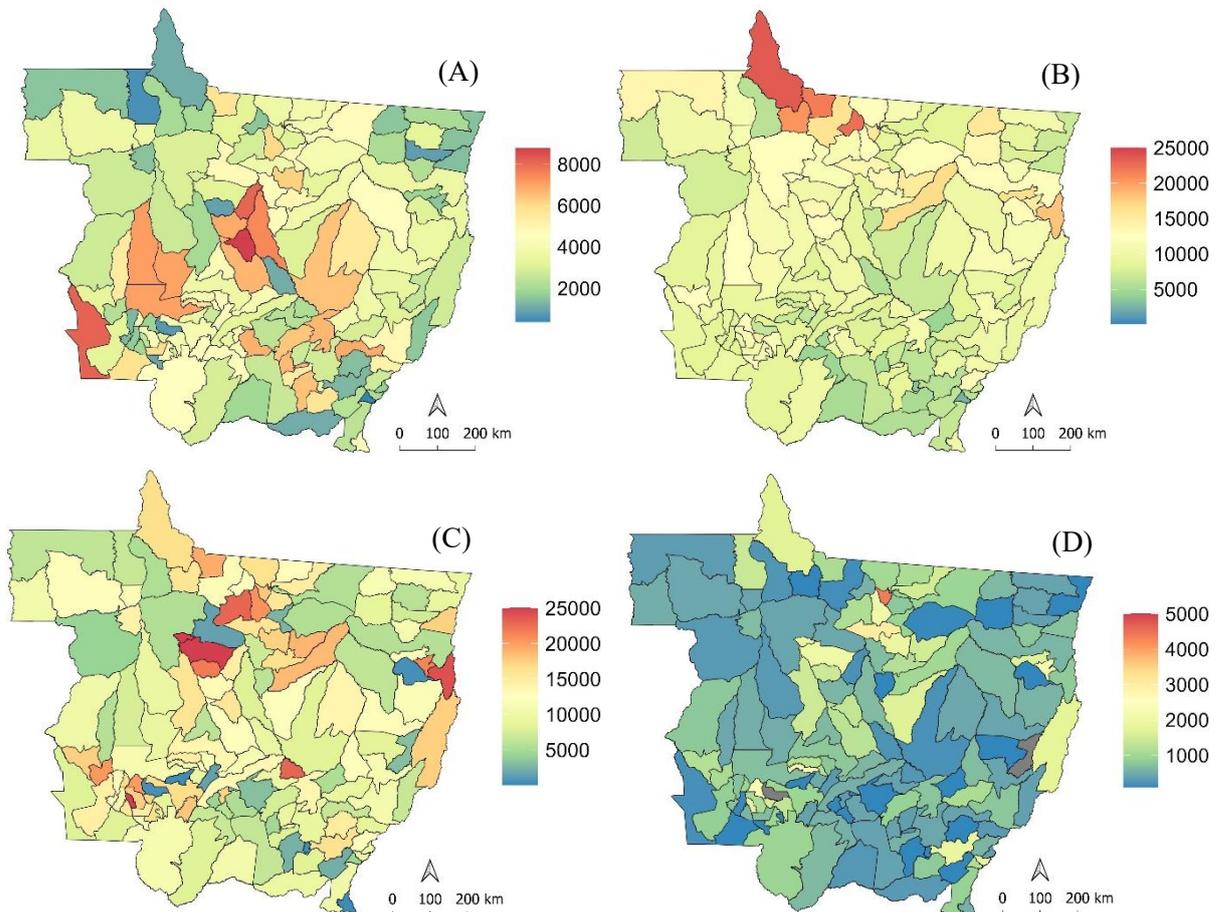


Fonte: Elaboração própria.

A Figura 7 e 8 apresenta a distribuição geográfica das taxas de incidência e mortalidade por COVID-19, padronizadas por idade, para cada município do Mato Grosso ao longo dos anos de 2020 a 2023. Cada subfigura (A, B, C e D) corresponde a um ano específico, permitindo uma análise detalhada da evolução temporal da pandemia em relação as mudanças e impacto da incidência e mortalidade.

O ano inicial da pandemia mostra uma distribuição heterogênea das taxas de incidência e mortalidade entre os municípios. Na Figura 7B, é possível notar um aumento considerável nas taxas de incidência, com o município de Apiacás destacando-se com taxas superiores a 25.000 casos por 100 mil habitantes. Já na Figura 7C, há uma redução aparente na incidência, com muitos municípios apresentando uma taxa de incidência inferior a 5.000 por 100 mil habitantes, embora ainda se observe altas taxas em vários municípios como em Novo Horizonte do Norte, Porto dos Gaúchos, Planalto da Serra, Nova Canaã do Norte, Itanhangá e Novo Santo Antônio. No ano de 2023 (Figura 7D), a incidência em quase todos os municípios diminuiu drasticamente, com a maioria apresentando taxas abaixo de 4.000 casos por 100 mil habitantes, com exceção do município de Nova Guarita, que notificou casos acima da média do restante do estado.

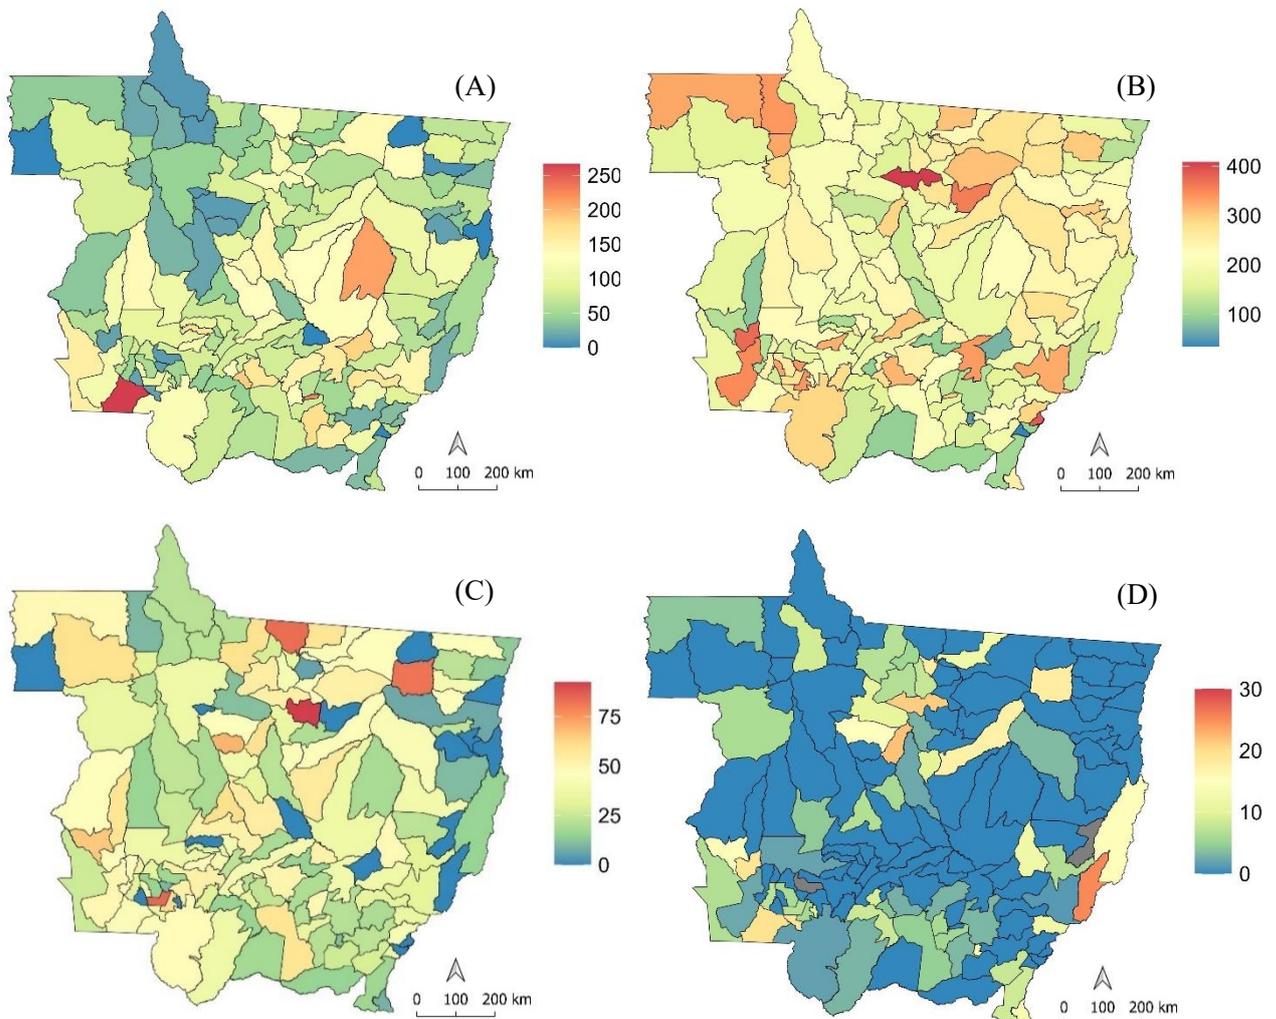
Figura 7. Taxa de incidência de COVID-19 padronizada por idade, por 100 mil habitantes, em cada município do Mato Grosso, nos anos de 2020 (A), 2021 (B), 2022 (C) e 2023 (D)



Fonte: Elaboração própria.

Em relação as taxas de mortalidade no Mato Grosso, os municípios mais afetados apresentam taxas superiores a 250 óbitos por 100 mil habitantes, como em Porto Esperidião (Figura 8A). Na Figura 8B observa-se uma escalada das taxas de mortalidade, onde os municípios de Itaúba, União do Sul, Conquista D'Oeste, Pontes e Lacerda, Ribeirãozinho, Colniza, Cotriguaçu, Juruena excederam 350 óbitos por 100 mil habitantes. Já no ano seguinte (Figura 8C), há uma regressão acentuada nas taxas de mortalidade em vários municípios, embora os municípios de Cláudia, Novo Mundo, São José dos Quatro Marcos e São José do Xingu ainda mantenham taxas elevadas. No ano de 2023 (Figura 8D), a taxa de mortalidade reduz consideravelmente em todo o estado, com a maioria dos municípios apresentando taxas inferiores a 30 óbitos por 100 mil habitantes, com exceção do município de Araguaiana.

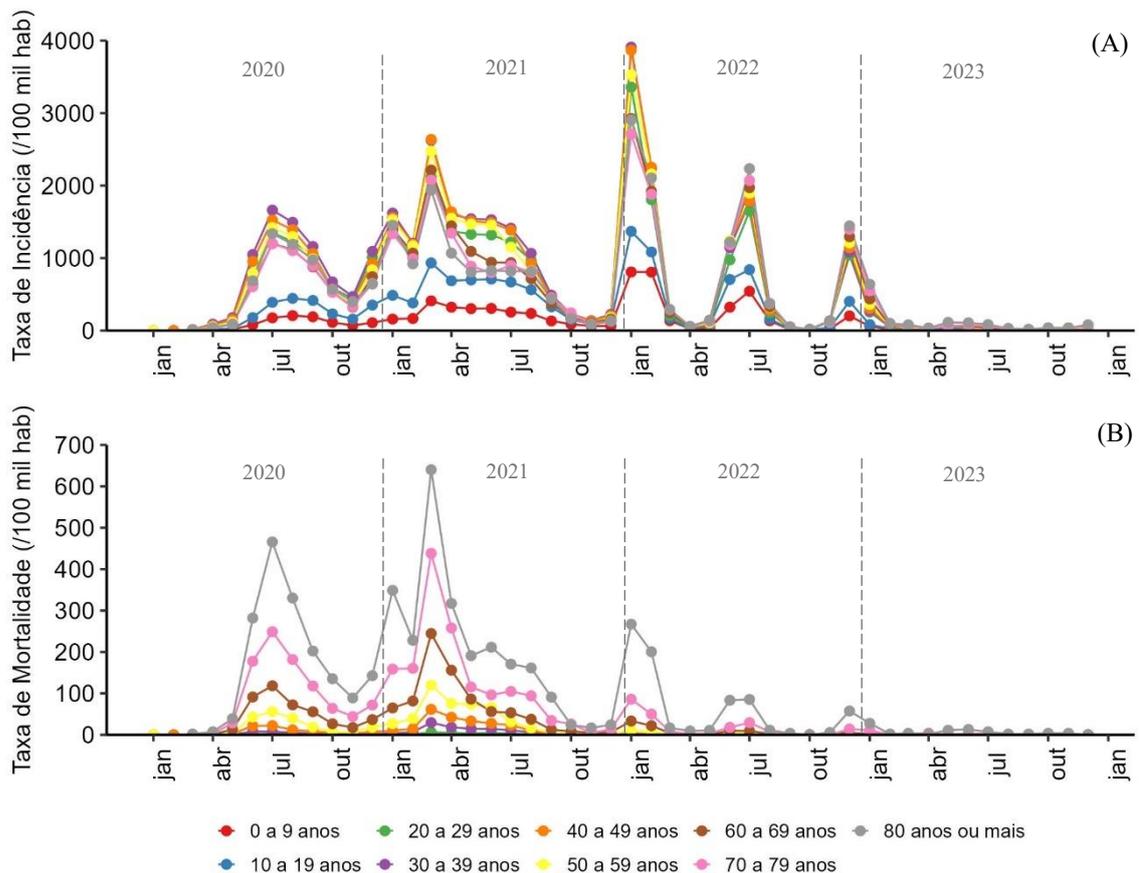
Figura 8. Taxa de mortalidade por COVID-19 padronizada por idade, por 100 mil habitantes, em cada município do Mato Grosso, nos anos de 2020 (A), 2021 (B), 2022 (C) e 2023 (D)



Fonte: Elaboração própria.

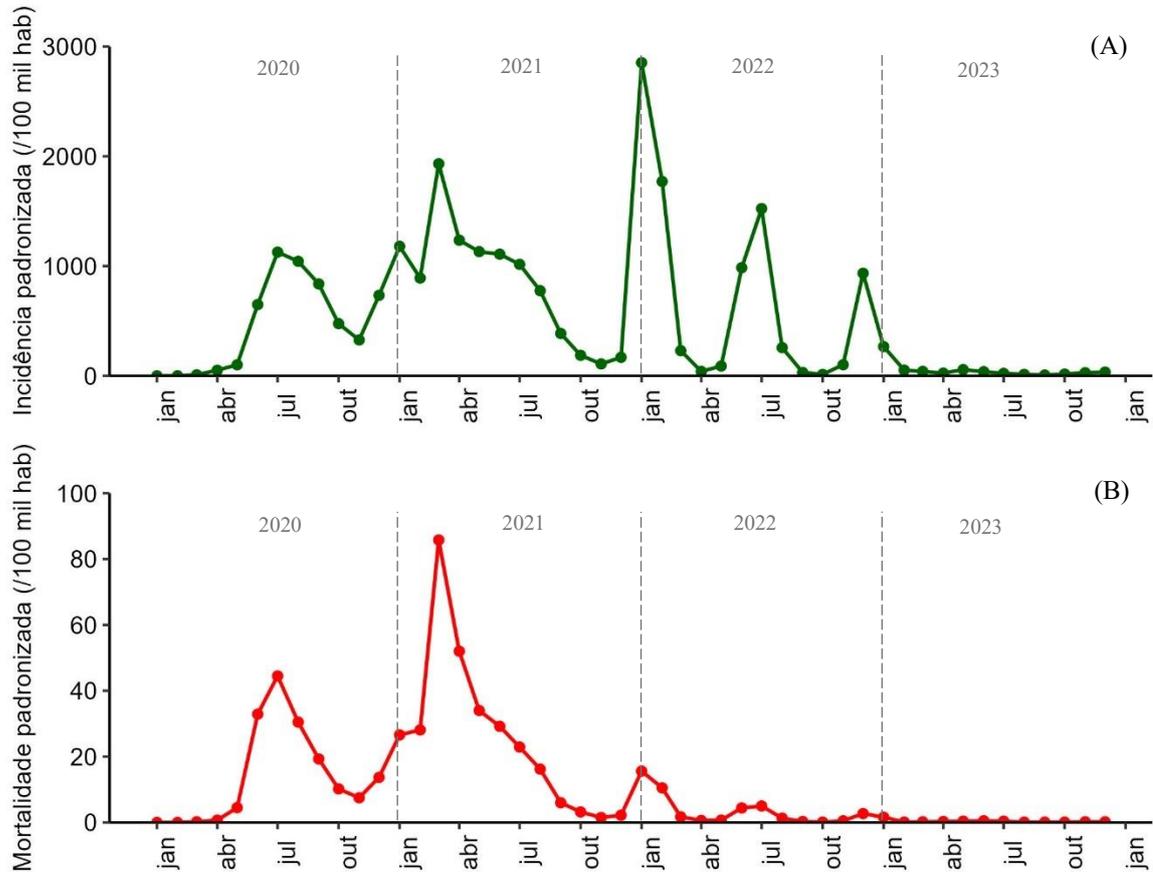
A Figura 9 e 10 apresenta as séries temporais das taxas de incidência e mortalidade por COVID-19 no estado de Mato Grosso, específica por faixa etária (Figura 9) e padronizado pela população por faixa etária do Brasil (Figura 10), por 100 mil habitantes, ao longo dos anos de 2020 a 2023, onde é possível observar a presença de picos, principalmente nos meses de janeiro e julho. Nos períodos que compreendem os anos de 2020 e 2021, é possível notar que ambas as séries temporais apresentam características de picos semelhantes, perfil este que se altera após a vacinação que se iniciou em 2021. Esta mudança na característica dos picos entre as duas séries temporais fica mais evidente a partir de janeiro de 2022, onde a série temporal da incidência apresenta o maior pico observado dentre todos os anos, enquanto a série temporal da mortalidade revela uma diminuição na mortalidade da população.

Figura 9. Série temporal da incidência (A) e mortalidade (B) por COVID-19, específica por faixa etária, por 100 mil habitantes, no Mato Grosso, entre os anos de 2020 a 2023



Fonte: Elaboração própria.

Figura 10. Série temporal da incidência (A) e mortalidade (B) por COVID-19 padronizada por idade por 100 mil habitantes, no Mato Grosso, entre os anos de 2020 a 2023



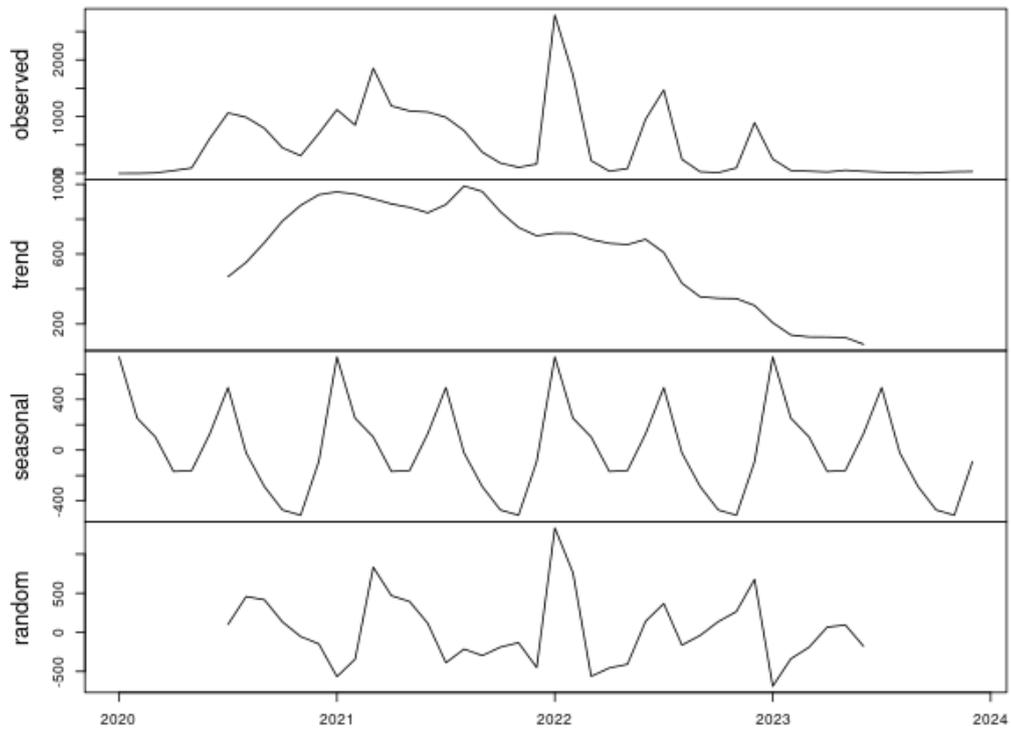
Fonte: Elaboração própria.

A decomposição da série temporal da incidência e mortalidade de COVID-19 no Mato Grosso entre 2020 e 2023 revelou diferentes componentes da série: tendência, sazonalidade e aleatoriedade.

A tendência da taxa de incidência (Figura 11), demonstrou um aumento acentuado até o início de 2021. A partir desse ano, a tendência começou a declinar, ficando mais estabilizado no final de 2022, mantendo níveis constantes até o final de 2023. A sazonalidade evidenciou um padrão de flutuações regulares, com picos nos meses de janeiro, março e julho.

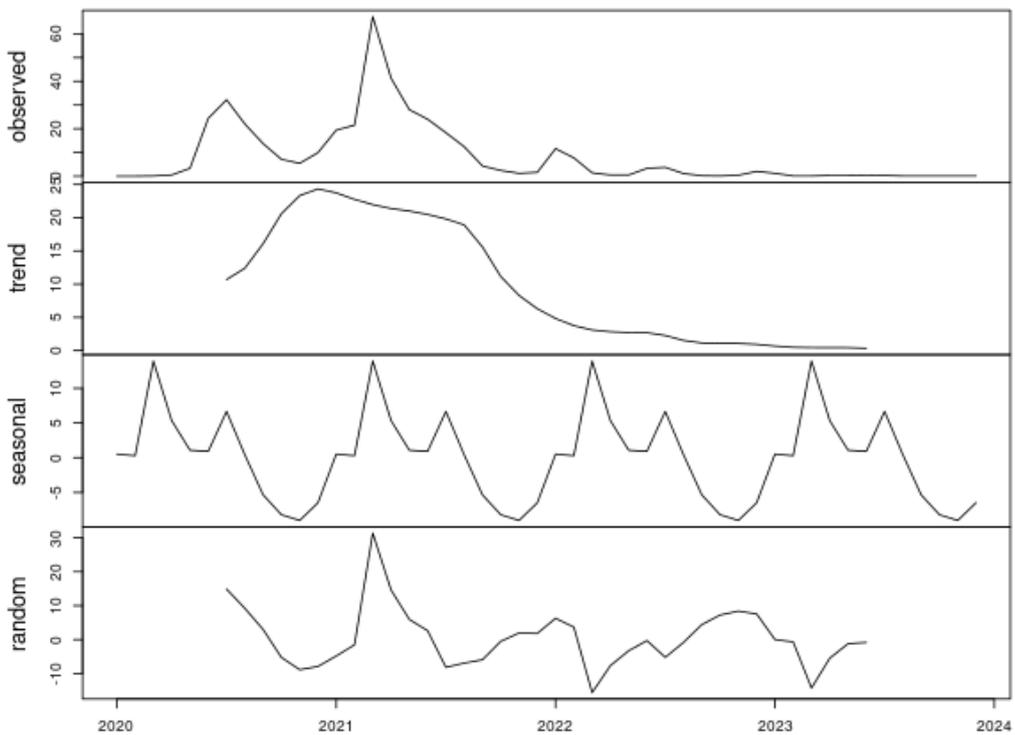
Enquanto que, a tendência da taxa de mortalidade (Figura 12) destacou um aumento acentuado da taxa de mortalidade em 2020, com um ponto máximo no início de 2021, seguido de uma redução até 2022, quando a taxa de mortalidade se estabilizou. A sazonalidade evidenciou flutuações regulares na taxa de mortalidade, com picos nos meses de janeiro, março e junho. O componente aleatório revelou flutuações não explicadas pela tendência ou sazonalidade, representando fatores imprevisíveis que podem ter afetado a taxa de incidência e mortalidade.

Figura 11. Decomposição da série temporal da taxa de incidência de COVID-19 no Mato Grosso, 2020 a 2023



Fonte: Elaboração própria.

Figura 12. Decomposição da série temporal da taxa de mortalidade de COVID-19 no Mato Grosso, 2020 a 2023



Fonte: Elaboração própria.

Os resultados da regressão de *Prais-Winsten* indicaram que, em 2020, a taxa de incidência apresentou uma tendência crescente na incidência de COVID-19 (MPC = 2,63; IC95% = 0,9; 4,38; p = 0,0133), indicando um aumento estatisticamente significativo. Em 2021, a tendência se mostrou decrescente (MPC = -0,66; IC95% = -1,05; -0,27; p = 0,0080). Em 2022, a tendência se torna estacionária (MPC = -0,55; IC95% = -1,81; 0,73; p = 0,4167), indicando ausência de significância estatística, sugerindo uma estabilização na incidência dos casos. Em 2023, a tendência permanece estacionária (MPC = -0,54; IC95% = -1,04; -0,04; p = 0,0601), também sem significância estatística, confirmando a estabilidade observada nos casos de COVID-19 (Tabela 9).

Já a análise da taxa de mortalidade de COVID-19, evidenciou uma tendência estacionária (MPC = 1,43; IC95% = 0,17; 2,71; p = 0,0505) em 2020, demonstrando um aumento na mudança percentual mensal, porém, sem ser estatisticamente significativo. Em 2021, houve uma inversão da tendência para decrescente (MPC = -0,89; IC95% = -1,45; -0,33; p = 0,0110), indicando uma redução estatisticamente significativa na mortalidade. Em 2022, a tendência se mostrou estacionária, sem significância estatística (MPC = -0,69; IC95% = -1,59; 0,23; p = 0,1710), sugerindo uma estabilização na mortalidade. No ano de 2023, a tendência permaneceu estacionária (MPC = -0,43; IC95% = -0,83; -0,03; p = 0,0630), indicando pouca variação na taxa de mortalidade neste ano (Tabela 9).

Tabela 9. Análise da tendência das taxas de incidência e mortalidade por 100 mil habitantes e padronizadas por idade no Mato Grosso, 2020 a 2023

	Ano	Total	DP <sup>a</sup>	MPC <sup>b</sup>	IC95% <sup>c</sup>	p-valor <sup>d</sup>	Tendência
Incidência	2020	5084,2	401,683	2,63	0,9; 4,38	0,0133	Crescente
	2021	9766,6	523,791	-0,66	-1,05; -0,27	0,0080	Decrescente
	2022	8574,3	886,966	-0,55	-1,81; 0,73	0,4167	Estacionária
	2023	572,8	66,201	-0,54	-1,04; -0,04	0,0601	Estacionária
Mortalidade	2020	118,8	10,94	1,43	0,17; 2,71	0,0505	Estacionária
	2021	241,6	19,242	-0,89	-1,45; -0,33	0,0110	Decrescente
	2022	32,5	3,546	-0,69	-1,59; 0,23	0,1710	Estacionária
	2023	3,2	0,314	-0,43	-0,83; -0,03	0,0630	Estacionária

Fonte: Elaboração própria. a) DP: Desvio Padrão; b) MPC: Mudança percentual mensal; c) IC95%: Intervalo de confiança da MPC d) p-valor calculado pelo método de *Prais-Winsten*, considerado estatisticamente significativo quando  $p < 0,05$ .

#### 4.2. Análise descritiva dos dados: cobertura vacinal

Os dados para cobertura vacinal são apresentados para um recorte temporal de 2021 a 2023, em decorrência do calendário vacinal. A partir da análise da cobertura vacinal, observa-se que a adesão à vacinação aumentou com a idade, atingindo os maiores percentuais de cobertura entre os idosos. A Tabela 10 mostra que as faixas etárias mais avançadas, especialmente aquelas acima de 60 anos, apresentam uma cobertura vacinal acima de 80% no esquema completo e doses de reforço. Ao considerar o sexo, as mulheres demonstram uma maior adesão à vacinação em comparação aos homens, tanto na cobertura vacinal completa quanto na taxa de reforço, apesar de ambos apresentarem uma cobertura vacinal abaixo do recomendado pela OMS.

Em relação à raça/cor da pele, percebe-se que a população branca e indígena apresenta uma adesão consideravelmente maior à vacinação completa e ao reforço em comparação com a população preta, que registra os menores percentuais de vacinação. A população parda também apresenta taxas de vacinação menores, embora não tão baixas quanto a população preta.

Tabela 10. Cobertura vacinal contra a COVID-19 de acordo com o esquema vacinal completo e reforço, no estado de Mato Grosso, 2021 a 2023

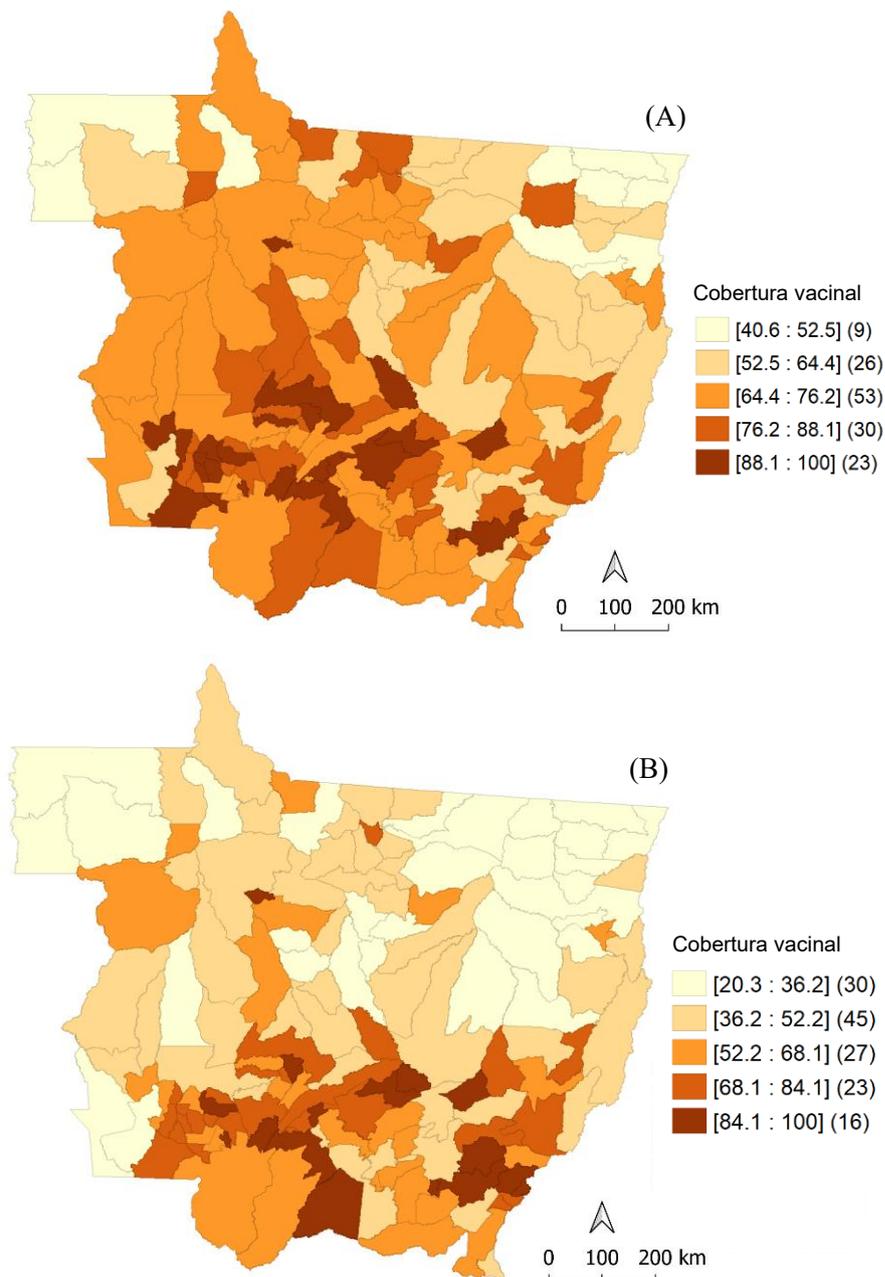
Variável	População		CV esquema completo	CV Reforço
	N	%	%	%
<b>Faixa Etária</b>				
0 a 9	560.578	15,3	20,2	1,7
10 a 19	535.475	14,6	67,1	18,5
20 a 29	593.267	16,2	77,6	35,3
30 a 39	603.862	16,5	79,1	46,0
40 a 49	530.710	14,5	79,6	63,4
50 a 59	399.845	10,9	84,6	81,5
60 a 69	258.407	7,1	88,1	100
70 a 79	122.119	3,4	87,5	100
≥ 80	53.894	1,5	80,6	100
<b>Sexo</b>				
Feminino	1.817.114	49,7	71,9	53,4
Masculino	1.841.043	50,3	67,5	44,0
<b>Raça/Cor</b>				
Branca	1.181.423	32,3	62,1	44,9
Indígena	56.621	1,5	51,6	45,0
Parda	2.048.649	56,0	45,8	31,1
Preta	360.651	9,9	33,3	26,0

Fonte: Elaboração própria a partir dos dados do SI-PNI e IBGE.

De acordo com a análise da distribuição espacial da cobertura vacinal considerando o

esquema completo (Figura 13A), 20 municípios apresentaram cobertura acima de 90%, sendo Acorizal (100%), Nova Brasilândia (100%), Santo Antônio de Leverger (100%), Indiavaí (100%), Glória D'Oeste (100%), Chapada dos Guimarães (98,6%), Nossa Senhora do Livramento (98,0%), Santa Rita do Trivelato (97,7%), Porto Estrela (96,5%), Curvelândia (96,1%), Santo Afonso (95,3%), Porto Esperidião (95,2%), Guiratinga (94,5%), Nortelândia (93,7%), Diamantino (93,5%), Vale de São Domingos (92,2%), Jangada (92,2%), Reserva do Cabaçal (92,1%), São José do Povo (90,9%), Salto do Céu (90,2%).

Figura 13. Cobertura vacinal contra a COVID-19 de acordo com o esquema vacinal completo (A) e reforço (B), nos municípios do estado de Mato Grosso, 2021 a 2023



Fonte: Elaboração própria.

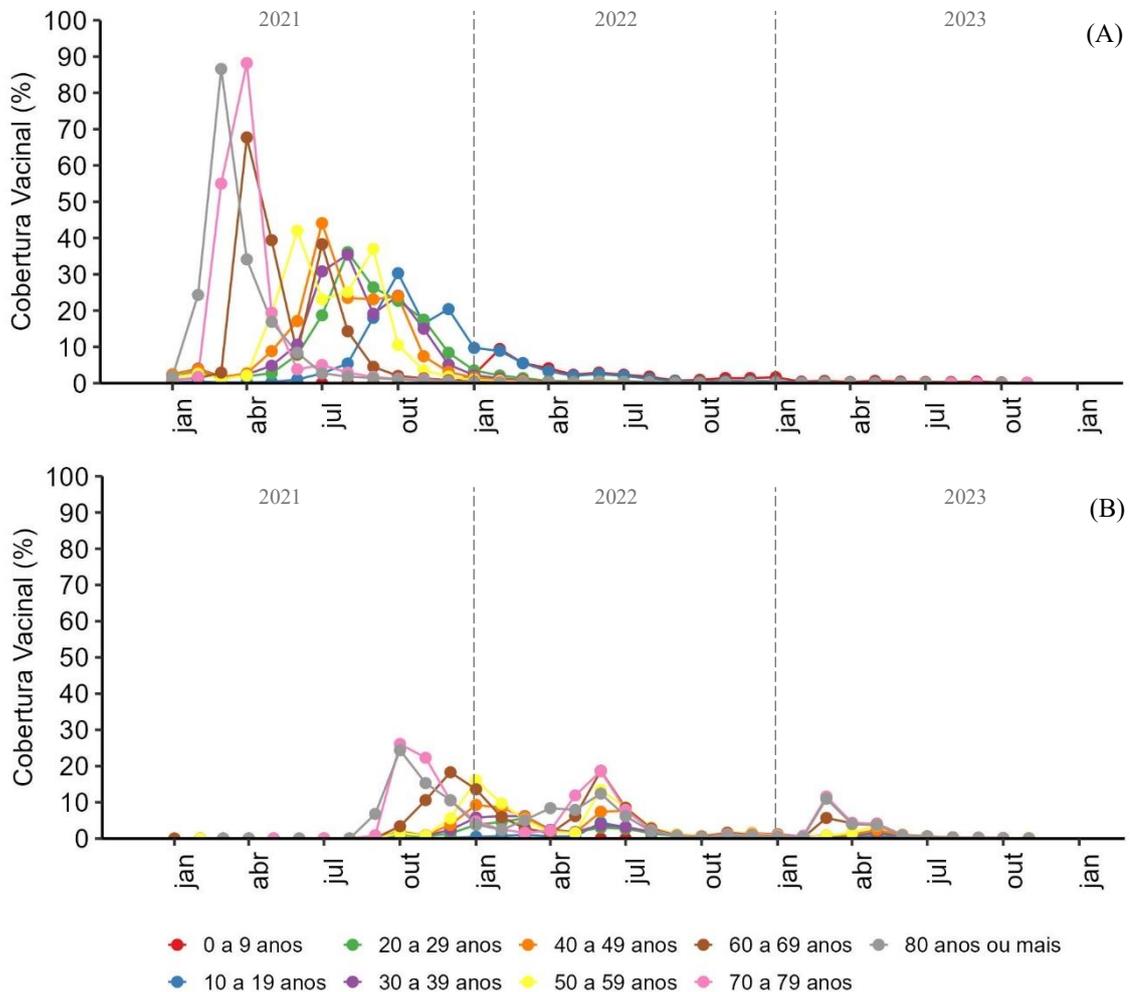
Dentre os municípios com menores taxas de cobertura vacinal referente ao esquema vacinal completo (Figura 13A), houveram 4 municípios que apresentaram cobertura abaixo de 50%, sendo Santa Terezinha (48,8%), Rondolândia (45,6%), Santa Cruz do Xingu (44,1%) e Confresa (40,6%).

Em relação a cobertura vacinal das doses de reforço (Figura 13B), 7 municípios apresentam 100% de cobertura vacinal, sendo Acorizal, Porto Estrela, Nossa Senhora do Livramento, Guiratinga, Barão de Melgaço, Torixoréu e São José do Povo. Entretanto, 68 municípios apresentaram cobertura vacinal das doses de reforço abaixo de 50%, correspondendo a 51,8% do total de municípios no estado.

Quanto a temporalidade da cobertura vacinal, em janeiro de 2021 ocorreu o início da vacinação contra a COVID-19 nos grupos etários de 80 anos ou mais. A partir de fevereiro, outros grupos etários começaram a ser incluídos na prioridade vacinal à medida que ocorreu a disponibilização das doses vacinais. Até abril de 2021, os grupos etários acima de 70 anos alcançaram taxas de cobertura acima de 80%, quando considerado o esquema vacinal completo. A partir de maio de 2021, a população abaixo de 59 anos se tornou mais presente na cobertura vacinal (Figura 14A).

Embora a cobertura vacinal tenha se estabilizado nas faixas etárias mais elevadas, observa-se uma redução na adesão ao reforço entre os mais jovens (Figura 14B). Os picos esporádicos observados durante estes dois anos foram menos intensos. As faixas etárias de crianças e adolescentes (0 a 19 anos) exibiram variações em seus níveis de cobertura vacinal, sem alcançar os altos picos vistos nos outros grupos etários (Figura 14).

Figura 14. Série temporal da cobertura vacinal (%) contra a COVID-19 de acordo com a faixa etária, considerando o esquema vacinal completo (A) e reforço (B), no Mato Grosso, entre os anos de 2021 a 2023

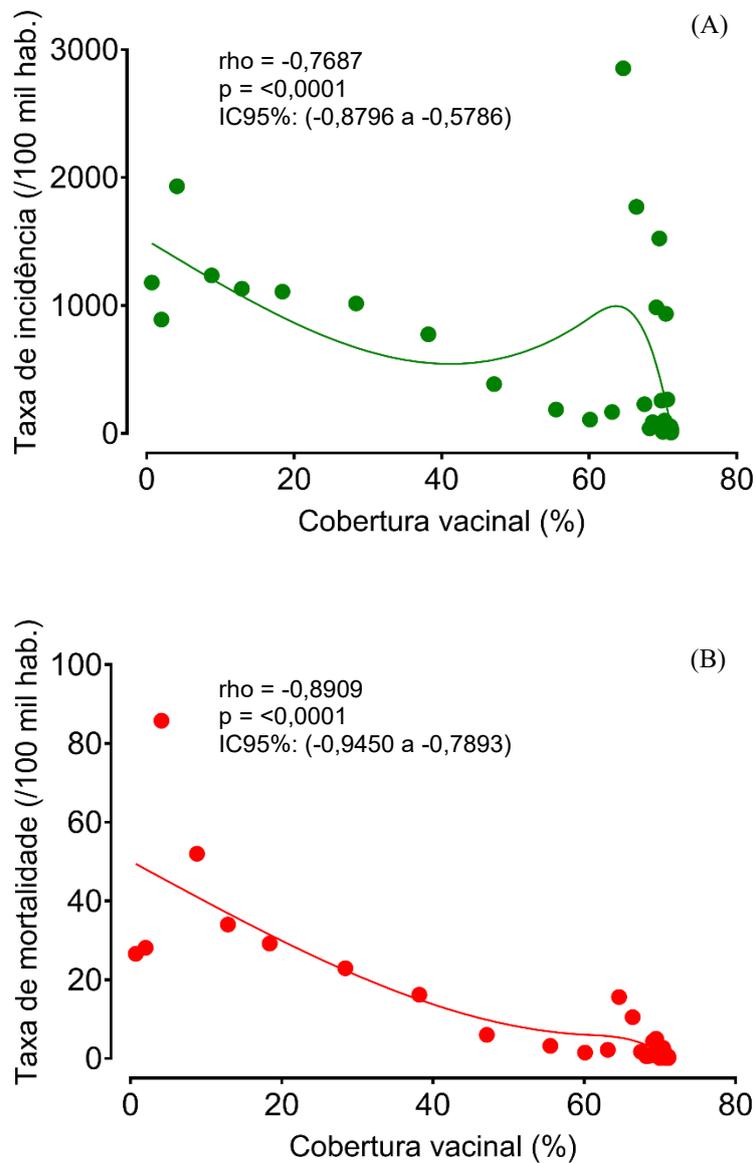


Fonte: Elaboração própria.

#### 4.3. Correlação de Spearman: incidência, mortalidade e cobertura vacinal

A correlação entre a cobertura vacinal e taxa de incidência de COVID-19 evidenciou um coeficiente de correlação de *Spearman* ( $\rho$ ) de  $-0,7687$ , indicando uma correlação negativa forte entre as variáveis (Figura 15A). O coeficiente de correlação de *Spearman* obtido na análise entre a cobertura vacinal e mortalidade foi de  $\rho = -0,8909$ , indicando uma correlação negativa muito forte entre a cobertura vacinal e a taxa de mortalidade por COVID-19 (Figura 15B). Esses resultados sugerem que, à medida que a cobertura vacinal aumenta, a taxa de incidência e mortalidade tendem a diminuir. O valor de  $p < 0,0001$  mostra que essa correlação é estatisticamente significativa, permitindo rejeitar a hipótese nula de que não há associação entre a cobertura vacinal e as taxas de morbimortalidade.

Figura 15. Correlação entre a cobertura vacinal e taxas de incidência (A) e mortalidade (B) por COVID-19 no Mato Grosso, 2021 a 2023



Fonte: Elaboração própria.

#### 4.4. Autocorrelação espacial global: *I* de Moran univariado

Para iniciar a análise de autocorrelação espacial nos dados, foi realizado o *I* de Moran univariado para as variáveis de incidência, mortalidade, letalidade, cobertura vacinal e IPS. Valores diferentes de zero e positivos indicam uma autocorrelação espacial nas variáveis, ou seja, municípios com altas taxas em relação às variáveis de interesse estão próximos a municípios com taxas semelhantes. Na análise do padrão espacial, a letalidade não se mostrou significativa (pseudo-valor-p = 0,479) (Tabela 11), demonstrando que a distribuição da letalidade da COVID-19 no estado de Mato Grosso não apresentou autocorrelação espacial.

Na Tabela 11, foi observado uma forte autocorrelação espacial positiva para a taxa de incidência, indicando que há uma tendência em municípios apresentarem vizinhos com taxas de incidência semelhantes. Os valores de *I* de Moran para mortalidade e cobertura vacinal indicam fraca autocorrelação espacial, sugerindo a presença de pequenas aglomerações locais, mas sem um padrão espacial forte. Já o IPS, apresenta uma forte autocorrelação espacial, indicando que áreas com melhores condições sociais tendem a estar perto umas das outras.

Tabela 11. *I* de Moran Global univariado, média, desvio padrão e pseudo-significância das variáveis incidência, mortalidade, letalidade, cobertura vacinal e IPS, no Mato Grosso

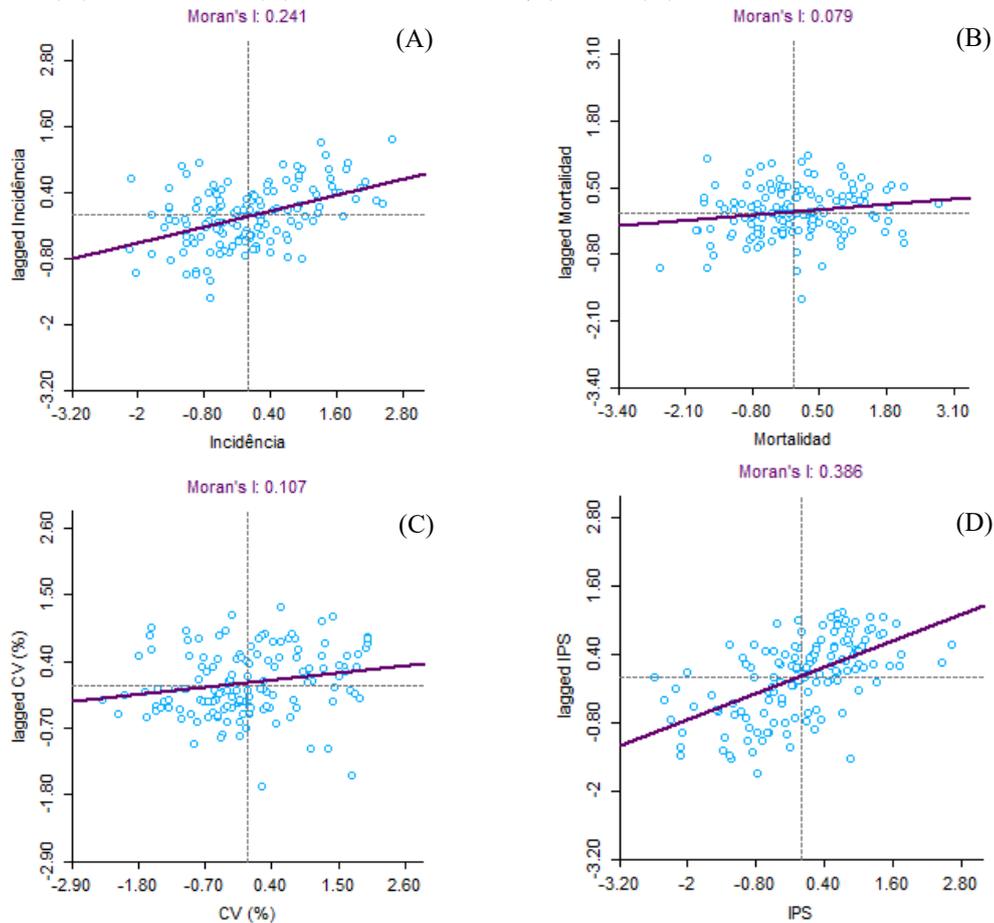
Variáveis	<i>I</i> de Moran	Média	Desvio Padrão	Pseudo-valor-p*
Incidência	0,241	-0,0089	0,0509	0,001
Mortalidade	0,079	-0,0074	0,0503	0,047
Letalidade	-0,006	-0,0056	0,0523	0,479
CV	0,107	-0,0080	0,0498	0,014
IPS	0,386	-0,0096	0,0505	0,001

Fonte: Elaboração própria. \*A pseudo-significância da análise é baseada em 999 permutações aleatórias. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para as taxas de incidência, mortalidade e letalidade, e os anos de 2021 a 2023 para a cobertura vacinal.

Após a análise da autocorrelação espacial para as variáveis, prosseguiu-se para as análises dos diagramas de dispersão do *I* de Moran Global univariado. Nos diagramas de dispersão da incidência e IPS (Figura 16, A e D), é possível observar visualmente que a maior parte dos municípios se concentram nos quadrantes alto-alto (AA) e baixo-baixo (BB). Enquanto que, em relação a mortalidade e a cobertura vacinal (Figura 16, B e C), os valores se mostram mais dispersos, com leve predominância nos quadrantes AA e BB.

A partir da verificação percentual da disposição de cada município no diagrama de dispersão (Figura 16), é confirmado que a maior concentração ocorre nos quadrantes alto-alto (AA) e baixo-baixo (BB). Na análise da dispersão da variável de incidência, cerca de 62,4% (n = 88) dos municípios estavam nos quadrantes alto-alto (AA) e baixo-baixo (BB). Para a variável mortalidade, cerca de 56,02% (n = 79) dos municípios se mostravam nos mesmos quadrantes. O mesmo padrão de disposição se repete para as variáveis de CV e IPS, onde apresentaram os respectivos percentuais: 64,54% (n = 91) e 75,18% (n = 106).

Figura 16. Diagrama de dispersão do  $I$  de Moran Global univariado para as variáveis de taxa de incidência (A), mortalidade (B), cobertura vacinal (C) e IPS (D)



Fonte: Elaboração própria. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para as taxas de incidência e mortalidade, e os anos de 2021 a 2023 para a cobertura vacinal.

#### 4.5. Autocorrelação espacial global: $I$ de Moran bivariado

Para testar a hipótese de padrões de distribuição espacial entre as taxas de cobertura vacinal, IPS, incidência, e mortalidade, foi utilizado o  $I$  de Moran Global. Para essa avaliação, foi comparado a autocorrelação espacial entre: incidência e mortalidade; incidência e cobertura vacinal; incidência e IPS; mortalidade e cobertura vacinal; mortalidade e IPS; e cobertura vacinal e IPS (Tabela 12).

Segundo os resultados obtidos da análise do  $I$  de Moran Global bivariado, na variável Incidência x CV, observa-se uma correlação espacial negativa ( $I$  de Moran = -0,074, pseudo-valor-p = 0,023), indicando que municípios com alta incidência tendem a estar próximos de municípios com baixa cobertura vacinal e vice-versa; Incidência x IPS, também com uma correlação espacial negativa evidente ( $I$  de Moran = -0,150, pseudo-valor-p = 0,001), sugerindo que municípios com alta incidência tendem a estar próximos de municípios com baixo IPS; e CV x IPS, com uma correlação espacial positiva ( $I$  de Moran = 0,218, pseudo-valor-p = 0,001),

indicando que municípios com alta cobertura vacinal tendem a estar próximos de municípios com alto IPS. Os pares de variáveis Incidência x Mortalidade, Mortalidade x CV, e Mortalidade x IPS não apresentaram significância estatística ( $p < 0,05$ ) e, portanto, não foi descartado a hipótese nula para a correlação espacial entre essas variáveis. Sendo assim, não serão realizadas análises de LISA entre essas variáveis (Tabela 12).

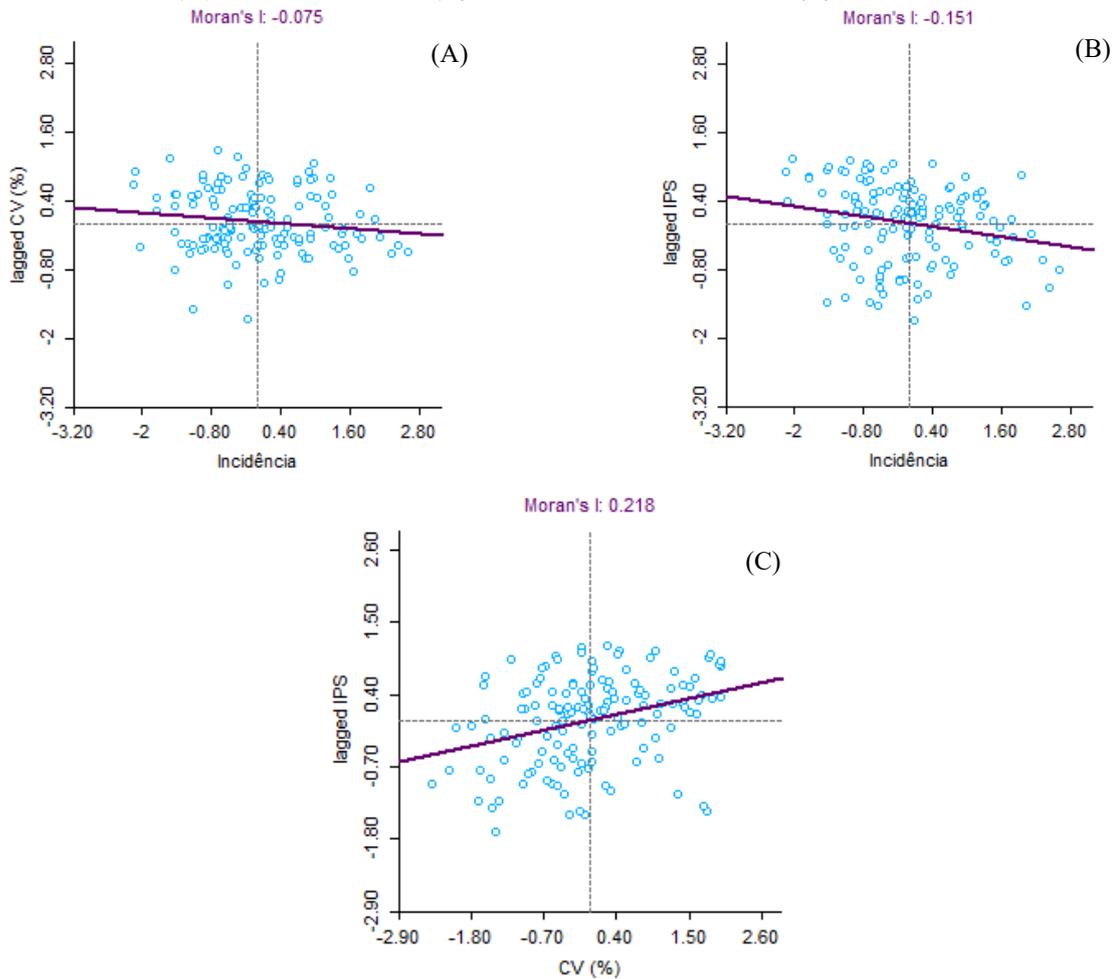
Tabela 12. *I* de Moran Global bivariado, média, desvio padrão e pseudo-significância da correlação espacial das variáveis, no Mato Grosso

Variáveis	<i>I</i> de Moran	Média	Desvio Padrão	Pseudo valor-p*
Incidência x Mortalidade	0,034	-0,0004	0,0385	0,187
Incidência x CV	-0,075	0,0004	0,0367	0,023
Incidência x IPS	-0,151	-0,0002	0,0377	0,001
Mortalidade x CV	0,041	0,0002	0,0376	0,136
Mortalidade x IPS	-0,009	0,0007	0,0383	0,390
CV x IPS	0,218	-0,0027	0,0385	0,001

Fonte: Elaboração própria. \*A pseudo-significância da análise é baseada em 999 permutações aleatórias. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para as taxas de incidência e mortalidade, e os anos de 2021 a 2023 para a cobertura vacinal.

Após a confirmação dos grupos que apresentavam significância estatística, prosseguiu para a confecção e análise dos diagramas de dispersão. Na Figura 17A, foi observado que cerca de 55,32% ( $n = 78$ ) dos municípios encontram-se nos quadrantes alto-baixo (AB) e baixo-alto (BA), confirmando a correlação espacial negativa demonstrada na Tabela 12. Quanto a correlação entre incidência e IPS (Figura 17B), 54,6% ( $n = 77$ ) dos municípios estão localizados nos quadrantes alto-baixo (AB) e baixo-alto (BA). Enquanto que, a análise da dispersão das variáveis CV e IPS (Figura 17C), revelou que 61,7% ( $n = 87$ ) dos municípios se concentraram nos quadrantes alto-alto (AA) e baixo-baixo (BB), confirmando a correlação positiva entre as variáveis.

Figura 17. Diagrama de dispersão do  $I$  de Moran Global bivariado para as variáveis de Incidência x Cobertura Vacinal (A), Incidência x IPS (B) e Cobertura Vacinal x IPS (C)



Fonte: Elaboração própria. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para a taxa de incidência, e os anos de 2021 a 2023 para a cobertura vacinal.

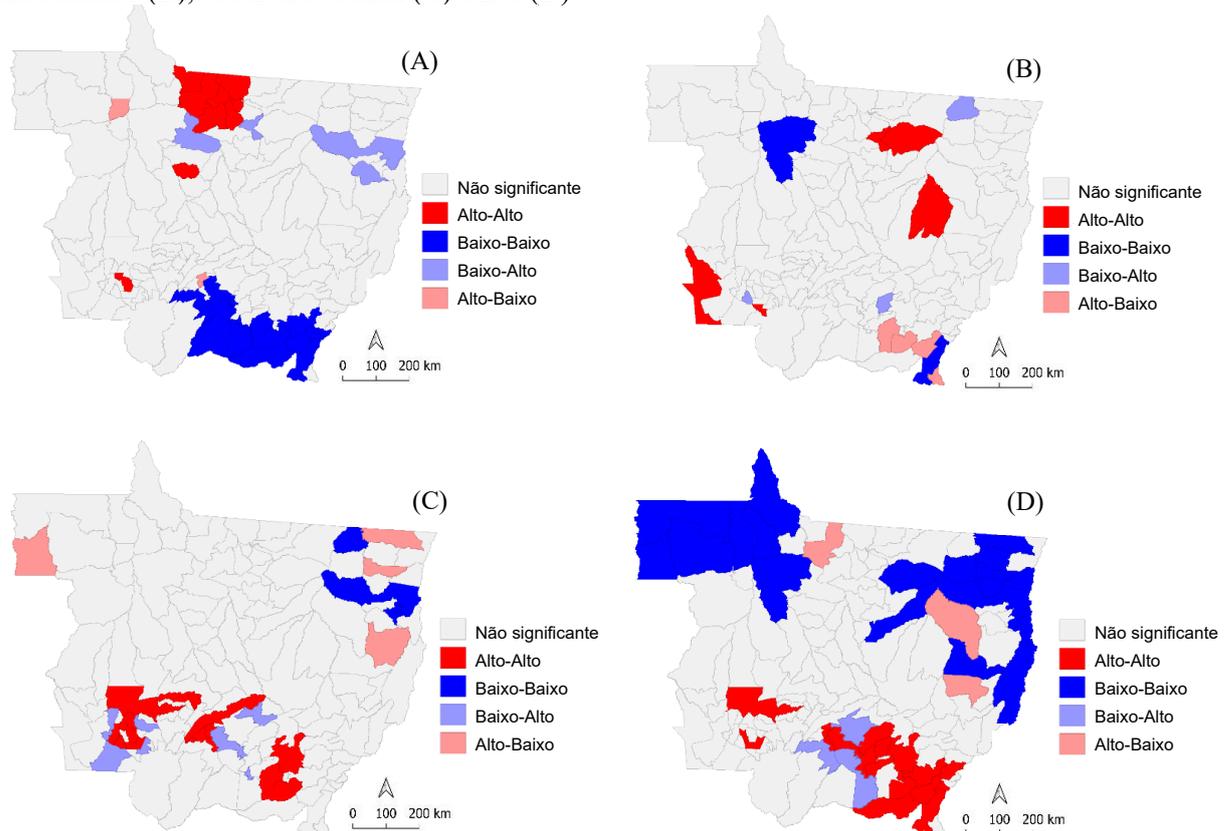
#### 4.6. Autocorrelação espacial local univariada: LISA

Na Figura 18, é possível confirmar a existência de uma autocorrelação espacial global positiva, visto que ocorre uma maior predominância de classificações AA (alto-alto) e BB (baixo-baixo) em todas as variáveis analisadas, quando referido aos resultados com significância espacial.

Quanto às regiões atípicas que apresentam variações do padrão de autocorrelação global para a taxa de incidência (Figura 18A), verificou que 4 municípios apresentaram correlação baixo-alto (BA), onde municípios de baixa taxa de incidência estavam cercados por municípios com alta taxa, e 2 apresentaram correlação alto-baixo (AB), ou seja, municípios com alta taxa de incidência estavam cercados por municípios com taxas baixas, sendo eles: Bom Jesus do Araguaia, Nova Santa Helena, São Félix do Araguaia e Tabaporã para a correlação baixo-alto (BA); e Acorizal e Juruena para a correlação alto-baixo (AB). Quanto as regiões atípicas da

taxa de mortalidade (Figura 18B), os municípios de Dom Aquino, Figueirópolis D'Oeste e Santa Cruz do Xingu apresentaram correlação baixo-alto (BA), enquanto os municípios de Alto Garças, Alto Taquari, Pedra Preta e Rondonópolis demonstraram correlação alto-baixo (AB). Na variável de cobertura vacinal (Figura 18C), os municípios que apresentaram correlação baixo-alto (BA) foram: Cuiabá, Mirassol D'Oeste, Nova Brasilândia, Porto Esperidião, Salto do Céu e Vale de São Domingos. E para a correlação alto-baixo (AB): Porto Alegre do Norte, Ribeirão Cascalheira, Rondolândia e Vila Rica. Por fim, 3 municípios da variável IPS demonstraram correlação baixo-alta (BA) e 3 apresentaram correlação alto-baixa (AB) (Figura 18D), sendo, respectivamente: Chapada dos Guimarães, Nossa Senhora do Livramento e Santo Antônio do Leverger para o primeiro grupo e, Água Boa, Alta Floresta e Querência para o alto-baixa (AB).

Figura 18. *Clusters* dos municípios para a análise de LISA univariado, nas taxas de incidência (A), mortalidade (B), cobertura vacinal (C) e IPS (D)



Fonte: Elaboração própria. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para as taxas de incidência e mortalidade, e os anos de 2021 a 2023 para a cobertura vacinal.

#### 4.7. Autocorrelação espacial local bivariada: LISA

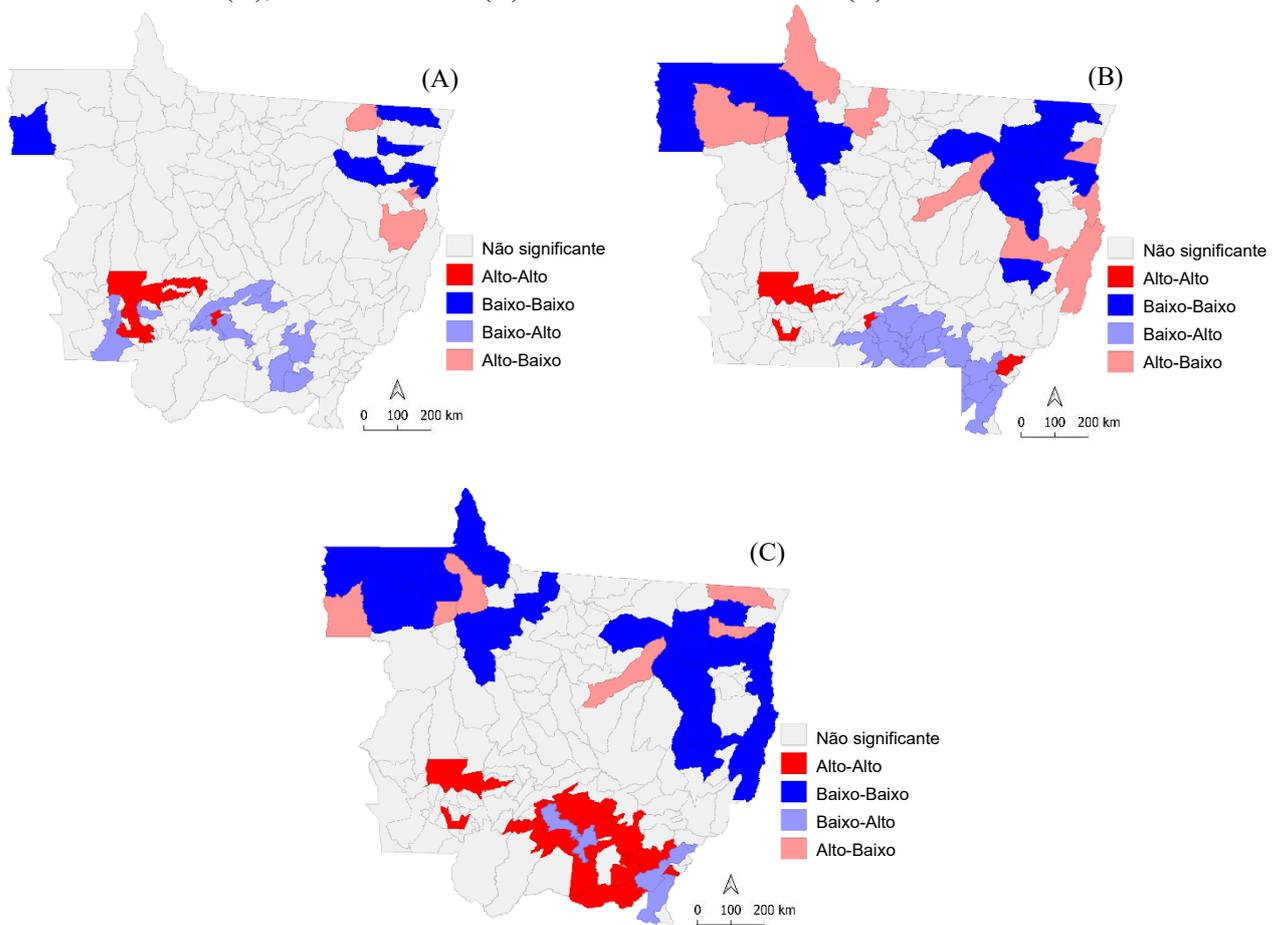
Complementando a análise de autocorrelação espacial global, foi realizada a análise bivariada de LISA para as variáveis que foram estatisticamente significativas no *I* de Moran bivariado, sendo elas: Incidência x Cobertura Vacinal; Incidência x IPS; e Cobertura Vacinal x IPS.

A análise do LISA *map* bivariado da Incidência x Cobertura Vacinal (Figura 19A), revela que 53,6% dos municípios enquadrados como significativos apresentaram correlação espacial baixo-alto (BA), com maior concentração na região Sul e Centro-Sul Mato-Grossense, e alto-baixo (AB) na região do Nordeste Mato-Grossense. Dentre os municípios estão: Cuiabá, Jangada, Jauru, Nova Brasilândia, Pedra Preta, Porto Esperidião, Poxoréu, Rondonópolis, Rosário Oeste, Salto do Céu, Vale de São Domingos, Várzea Grande, Ribeirão Cascalheira, Santa Cruz do Xingu e Serra Nova Dourada.

Nas taxas de Incidência x IPS (Figura 19B), observou-se que 57,8% dos municípios obtiveram correlação espacial baixo-alto (BA), revelando *clusters* na região Centro-Sul e Sudeste Mato-Grossense, e alto-baixo (AB) com *spots* espalhados entre as regiões do Norte e Nordeste Mato-Grossense, sendo eles: Alto Araguaia, Alto Garças, Araguainha, Campo Verde, Chapada dos Guimarães, Cuiabá, Dom Aquino, Guiratinga, Itiquira, Jaciara, Juscimeira, Nossa Senhora do Livramento, Pedra Preta, Poxoréu, São José do Povo, Santo Antônio de Leverger, Várzea Grande, Alta Floresta, Apiacás, Aripuanã, Canarana, Cocalinho, Feliz Natal, Juruena, Luciara e Novo Santo Antônio.

Em contrapartida, nas variáveis de Cobertura Vacinal x IPS (Figura 19C), 75,5% dos municípios demonstraram correlação espacial alto-alto (AA) e baixo-baixo (BB), ou seja, municípios com altas taxas de cobertura vacinal estavam cercados por municípios com altas taxas de IPS, e vice versa. Os municípios que detinham correlação alto-alto (AA), se concentraram na região Sul, Centro-Sul e Sudeste Mato-Grossense, sendo eles: Acorizal, Araguainha, Campo Verde, Chapada dos Guimarães, Dom Aquino, Guiratinga, Indavaí, Itiquira, Juscimeira, Nossa Senhora do Livramento, Pedra Preta, Poxoréu, São José dos Quatro Marcos, São José do Povo, Santo Antônio de Leverger, Tangará da Serra e Várzea Grande. Enquanto que, os municípios que apresentaram correlação baixo-baixo (BB) se encontravam no Norte e Nordeste Mato-Grossense, sendo: Água Boa, Alta Floresta, Apiacás, Aripuanã, Canabrava do Norte, Canarana, Cocalinho, Colniza, Confresa, Cotriguaçu, Juara, Luciara, Marcelândia, Novo Santo Antônio, Querência, São José do Xingu e São Félix do Araguaia.

Figura 19. *Clusters* dos municípios para a análise de LISA bivariado, para as variáveis de Incidência x Cobertura Vacinal (A), Incidência x IPS (B) e Cobertura Vacinal x IPS (C)



Fonte: Elaboração própria. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para a taxa de incidência, e os anos de 2021 a 2023 para a cobertura vacinal.

## 5. DISCUSSÃO

Os principais resultados da presente pesquisa mostram que, ao longo do período de 2020 a 2023, as taxas de incidência, letalidade e mortalidade da COVID-19 variaram significativamente conforme fatores demográficos e regionais. Crianças e adolescentes tiveram as menores taxas de incidência e mortalidade, enquanto os idosos, especialmente aqueles acima de 80 anos, apresentaram alta letalidade. Homens tiveram maiores taxas de mortalidade e letalidade, apesar de uma incidência mais baixa entre eles. Já em relação a cobertura vacinal contra a COVID-19, inicialmente houve uma alta adesão à primeira dose, mas houve uma redução notável na adesão à segunda dose, sobretudo entre os jovens. A correlação entre a cobertura vacinal e os indicadores de morbimortalidade indicaram que, à medida que a cobertura vacinal aumentava, as taxas de incidência e mortalidade diminuíram. Padrões de autocorrelação espacial revelaram que regiões do Norte e Nordeste Mato-grossense apresentaram *hot spots* de alta incidência e mortalidade, enquanto *cold spots* estavam concentrados nas regiões do Sul e Sudeste Mato-grossense. Regiões com melhor infraestrutura social e econômica mostraram menores taxas de morbimortalidade e maior cobertura vacinal, destacando a influência dos determinantes sociais na saúde pública.

Ao analisar os resultados, apesar da taxa de mortalidade parecer representar uma pequena parte da incidência a nível intermunicipal, o Mato Grosso ainda permanece como o estado brasileiro com maior taxa de mortalidade por habitantes. De acordo com Brasil (2024), enquanto o país apresentava uma média de taxa de mortalidade bruta em 339,1 por 100 mil habitantes, onde o valor mínimo apresentado era do Nordeste com uma mortalidade de 239,8 por 100 mil habitantes, o Centro-Oeste detinha da maior taxa, sendo 411,6 por 100 mil habitantes. Dentre os estados do Centro-Oeste, as taxas de mortalidade bruta variavam de: 398,3 para o Distrito Federal; 404,8 para o Mato Grosso do Sul; 407,3 para Goiás; e 437,1 para o estado de Mato Grosso, apresentando a maior taxa dentre todos os estados brasileiros.

A análise das taxas de morbimortalidade nos municípios do estado de Mato Grosso revela desigualdades com relação as características sociodemográficas. Maior taxa de incidência na população economicamente ativa (30 a 49 anos) foi observada no presente estudo. Isso pode ser explicado pelo fato de que essa faixa etária está mais exposta ao vírus devido às suas atividades profissionais e sociais. É observado isso desde o início do surto de COVID-19, onde os trabalhadores e clientes de um mercado de peixes de Wuhan, se mostraram como os primeiros casos da doença (LI; GUAN; WU; WANG *et al.*, 2020).

Resultados semelhantes também foram observados no estudo feito por Schneider, Passos

e Pereira (2022), onde foi analisado dados do Brasil, durante o período de início da pandemia até 14 de agosto de 2020. Os autores demonstraram que os trabalhadores da faixa etária de 30 a 49 anos exerciam a maior parte das atividades trabalhistas e também as de maior risco para contágio pela doença. Os resultados ainda revelaram que, ao todo, aproximadamente 5,7 milhões de trabalhadores estavam envolvidos em atividades de alto risco de contágio, enquanto cerca de 16 milhões estavam em atividades de médio risco e mais de 58 milhões em atividades de baixo risco de contágio durante a pandemia (SCHNEIDER; PASSOS; PEREIRA, 2022).

Ao avaliar as taxas de mortalidade e letalidade, a população idosa ( $\geq 60$  anos) apresentam as taxas mais elevadas, quando comparado aos outros grupos. Ainda foi possível observar maiores taxas com o incremento da idade, indicando uma maior vulnerabilidade para a população idosa. Uma possível explicação seria a presença de comorbidades e redução da eficácia do sistema imunológico com o avanço da idade, tornando-os mais susceptíveis ao contágio e manifestações mais graves da doença (MAFRA; STOBBE; RABELLO; LINDEMANN *et al.*, 2023; ROTHAN; BYRAREDDY, 2020).

De acordo com uma revisão sistemática que analisou doze estudos envolvendo 3064 pacientes hospitalizados com COVID-19, para cada incremento de um ano na média de idade populacional, a incidência de condições graves da COVID-19 pode aumentar em até 2,9 vezes (TIRUNEH; TESEMA; AZANAW; ANGAW, 2021). Além disso, estima-se que a probabilidade de morte é inferior a 1% para indivíduos com menos de 40 anos, porém, pode ultrapassar 51% para pessoas com mais de 90 anos (LI; WANG; ZHONG; BAO *et al.*, 2020).

Com o avançar da idade, o sistema imunológico dos idosos passa a enfrentar uma série de mudanças que reduzem sua eficácia, um fenômeno conhecido como imunossenescência (NIKOLICH-ZUGICH, 2018). Este processo envolve alterações tanto nos componentes celulares quanto moleculares dos sistemas imunológicos (GORONZY; WEYAND, 2013). Além disso, a capacidade do sistema imunológico de coordenar respostas eficazes ao longo do tempo e entre diferentes partes do corpo também diminui (NIKOLICH-ZUGICH, 2018). Enquanto essas funções são geralmente eficientes em pessoas mais jovens, elas se deterioram com o envelhecimento, tornando os idosos mais suscetíveis a infecções por novos patógenos, como o vírus SARS-CoV-2 (NIKOLICH-ZUGICH; KNOX; RIOS; NATT *et al.*, 2020).

Além da maior susceptibilidade fisiológica dos idosos à infecção, o isolamento social adotado como forma de redução da transmissão do vírus, aumentou drasticamente os relatos de sentimento de solidão, ansiedade, tristeza e depressão, fatores estes que podem acarretar no declínio funcional e aumentar a vulnerabilidade dessa população (ROMERO; MUZY; DAMACENA; SOUZA *et al.*, 2021; VALTORTA; KANAAN; GILBODY; HANRATTY,

2018).

Em casos onde o isolamento social é fundamental, o uso da tecnologia pode ser destacado como uma ferramenta vital para manter os idosos conectados com suas redes de apoio e facilitar o acesso a serviços de saúde e apoio psicológico (COSTA; SILVA; OLIVEIRA; COSTA *et al.*, 2020). No entanto, é necessário garantir que os idosos tenham o conhecimento e o acesso para utilizar essas tecnologias de maneira eficaz. Programas de educação e treinamento podem ser implementados para aumentar a alfabetização digital entre os idosos, facilitando assim o uso de ferramentas digitais para comunicação e apoio (GRANDA; CUNHA; SILVA; CAMPOS, 2021). Adicionalmente, é necessário que os meios de comunicação sejam mais sensíveis às necessidades dos idosos, fornecendo informações precisas e evitando alarmismos que possam aumentar a ansiedade (MEHRA; RANI; SAHOO; PARVEEN *et al.*, 2020).

Em relação ao sexo, os dados revelam que os homens têm taxas de mortalidade e letalidade mais altas do que as mulheres. Também foi possível evidenciar, que a taxa de letalidade entre os homens é quase 70% maior do que entre as mulheres. Esses resultados corroboram com estudos que indicam que os homens são mais suscetíveis a complicações graves da COVID-19. Uma revisão crítica demonstrou que 71,7% das infecções na Malásia, e 61% na Espanha ocorreram em homens (BERENQUER; RYAN; RODRIGUEZ-BANO; JARRIN *et al.*, 2020; HAN; YIN; WU; WANG *et al.*, 2023; SIM; CHIDAMBARAM; WONG; PATHMANATHAN *et al.*, 2020). Um estudo transversal conduzido por Baqui *et al* (2020), analisou as taxas de mortalidade em diferentes regiões do Brasil, durante o período de 27 de fevereiro a 4 de maio de 2020; os resultados demonstraram que os homens apresentaram taxas maiores de mortalidade em ambas as regiões analisadas.

A vulnerabilidade dos homens à COVID-19 pode ser atribuída a uma combinação de fatores, incluindo condições de saúde preexistentes, comportamentos de risco e acesso limitado aos serviços de saúde (GAZONI; RUI; MORAES; ZANOTTI *et al.*, 2022). Além disso, a maior taxa de incidência de casos graves em homens pode ser explicada pela elevada expressão do receptor da enzima conversora de angiotensina 2 (ECA2) nesse grupo, o que facilitaria a entrada do SARS-CoV-2 nas células, aumentando a patogenicidade do vírus (BEYERSTEDT; CASARO; RANGEL, 2021).

Adicionalmente, Takahashi *et al.* (2020) conduziram um estudo para avaliar as diferenças imunológicas entre homens e mulheres infectadas pelo SARS-CoV-2, entre 18 de março e 9 de maio de 2020, no *Yale-New Haven Hospital*, EUA. Os pesquisadores descobriram que os homens apresentavam níveis mais altos de substâncias inflamatórias chamadas citocinas, como IL-8 e IL-18, que podem aumentar as respostas inflamatórias, contribuindo para a gravidade da

doença. Em contraste, as mulheres apresentaram uma resposta mais forte das células T, especialmente as células T CD8+, que são importantes para destruir células infectadas pelo vírus.

A população negra (pretos e pardos) e indígena também compuseram um grupo de risco, apresentando taxas de letalidade mais altas e menor cobertura vacinal comparado a população branca. Algo que contribui para a taxa elevada na população negra consiste no fato de que esse grupo enfrenta uma maior vulnerabilidade socioeconômica, sendo mais representada em trabalhos informais e de menor remuneração. Esse cenário leva à um menor acesso a serviços de saúde de qualidade e aumenta a exposição a condições de vida que promovem a transmissão do vírus, como a falta de saneamento básico, moradias inadequadas e uso frequente do transporte público (BARRETO; RIOS; RIBEIRO; TORREÃO *et al.*, 2021; PEREIRA; CASTRO; FIGUEIRA; NOVAS, 2020). De acordo os resultados de um estudo fornecido pelo Ipea utilizando dados de 2019, foi evidenciado que a população negra enfrenta maiores dificuldades de acesso a serviços de alta complexidade em comparação com a população branca (IPEA, 2023).

Um estudo do Reino Unido realizado entre 16 de março de 2020 e 14 de abril de 2020, encontrou que indivíduos pretos apresentavam maior probabilidade de serem infectados pela COVID-19 (HASTIE; MACKAY; HO; CELIS-MORALES *et al.*, 2020). Quando comparado ao estudo realizado nas diferentes regiões do Brasil, no período de 27 de fevereiro a 4 de maio de 2020, observa-se que a população negra enfrentou um risco consideravelmente maior de desenvolver as formas graves da COVID-19 em comparação com a população branca (BAQUI; BICA; MARRA; ERCOLE *et al.*, 2020).

Outros estudos também demonstram a vulnerabilidade das populações indígenas à COVID-19, onde essa população apresentou altas taxas de incidência e mortalidade, que podem ter sido exacerbados por condições sociais e sanitárias precárias. A ausência de infraestrutura adequada, como leitos de UTI e ventiladores mecânicos nas proximidades das aldeias, combinada com a distância dos centros urbanos, pode ter prejudicado ainda mais a resposta à pandemia nas comunidades indígenas (DAMASCO; ANTUNES; AZEVEDO, 2020; SILVA; ROSA; MENDONÇA; QUEIROZ *et al.*, 2021). A subnotificação de casos e mortes pela Secretaria Especial de Saúde Indígena (SESAI) e a falta de ações governamentais eficazes também contribuíram para agravar a situação. Segundo dados da Articulação dos Povos Indígenas do Brasil (APIB), coletados entre março e junho de 2020, a taxa de letalidade entre indígenas atingiu 9,6%, em comparação com 5,6% na população geral (AMADO; RIBEIRO, 2020).

Também notou-se no presente estudo, que a cobertura vacinal contra a COVID-19 no estado do Mato Grosso revelou padrões distintos de adesão vacinal, conforme detalhado por faixa etária, sexo e raça/cor de pele. A cobertura vacinal entre as crianças e adolescentes (0 a 19 anos) mostrou-se relativamente baixa, especialmente no que se refere à administração de doses de reforço. Este fenômeno pode ser atribuído a uma combinação de hesitação vacinal por parte dos pais, a percepção de menor risco de complicações graves da COVID-19 nesses grupos etários, opiniões políticas, fatores psicológicos e a uma implementação mais tardia de políticas de vacinação para jovens em comparação com adultos e idosos (LEITE; MARTINS; MARTINS, 2023; LIMA; FARIA; KFOURI, 2021).

Por outro lado, a população idosa (60 anos ou mais) exibiu níveis elevados de cobertura vacinal. Esse alto índice de vacinação pode ser explicado pela maior conscientização sobre os riscos da COVID-19 para a saúde nesta faixa etária e pelo esforço concentrado das autoridades de saúde para imunizar este grupo populacional, considerado de alto risco. Um estudo transversal conduzido por Lima-Costa *et al.* (2022) em março de 2021, destacou que os idosos (60 anos ou mais) foram priorizados nas campanhas de vacinação, o que aumentou consideravelmente a cobertura vacinal. Além disso, a maior conscientização sobre as complicações graves associadas à infecção pelo SARS-CoV-2 impulsionou uma resposta mais positiva à vacinação nesse grupo.

Em relação ao gênero, as mulheres tiveram uma taxa ligeiramente superior de cobertura vacinal em comparação aos homens. A literatura aponta que mulheres geralmente apresentam uma maior propensão a buscar serviços de saúde, incluindo a vacinação, do que homens. Essa tendência pode ser parcialmente explicada por fatores sociais e culturais que incentivam as mulheres a serem mais proativas em relação à saúde e ao bem-estar (GEBHARD; REGITZ-ZAGROSEK; NEUHAUSER; MORGAN *et al.*, 2020).

Uma revisão sistemática que abrangeu estudos publicados entre janeiro de 2020 e maio de 2022 no Brasil, demonstrou que os fatores socioeconômicos tiveram grande influência na adesão à vacinação, com pessoas de menor renda demonstrando maiores níveis de hesitação. De acordo com o estudo, a precariedade econômica pode limitar o acesso a informações precisas e de qualidade sobre vacinas, tornando-as mais suscetíveis a fontes menos confiáveis. Além disso, o menor acesso à educação está associado a uma maior hesitação, pois indivíduos com menor escolaridade podem ter dificuldades em compreender informações técnicas sobre vacinas, aumentando sua vulnerabilidade à desinformação (LEITE; MARTINS; MARTINS, 2023).

Para comprovar a importância e eficácia da implementação de medidas que envolvem a

vacinação, um estudo simulou uma campanha de vacinação de duas doses, com 95% de eficácia, focando em profissionais de saúde e indivíduos de alto risco, demonstrando que a vacinação reduziu a taxa de incidência global de COVID-19 de 9,0% para 4,6% em 300 dias. A redução foi mais significativa entre pessoas com 65 anos ou mais, diminuindo a taxa de incidência em 54 a 62%. Além disso, a vacinação resultou em reduções consideráveis nas hospitalizações e óbitos, com diminuições de cerca de 65% para ambas as variáveis (MOGHADAS; VILCHES; ZHANG; WELLS *et al.*, 2021). Comparando com a literatura científica, a vacinação contra a COVID-19 foi altamente eficaz na prevenção de hospitalizações e casos graves, além de diminuir a transmissão do vírus. Estudos indicam que vacinados infectados têm carga viral menor, resultando em menor probabilidade de transmissão do vírus (CUNHA; CESCINETTO; VARGAS; SILVEIRA *et al.*, 2024).

Esses dados corroboram com os resultados encontrados no presente estudo. Ao fazer a comparação entre a Figura 10 e 14, percebe-se que após o início da campanha vacinal, houve uma diminuição drástica nas taxas de mortalidade ao longo do tempo, mesmo com o aparecimento de elevações nas taxas de incidência. Semelhantemente, no Pará, antes da implementação das campanhas de vacinação, o estado apresentava picos elevados de incidência e mortalidade, que diminuíram significativamente com o aumento da cobertura vacinal (FEIO; QUEIROZ; MORAES; SOUSA JÚNIOR *et al.*, 2023).

A análise de tendência mostrou um aumento inicial nas taxas de incidência e mortalidade por COVID-19 em Mato Grosso até o início de 2021, seguido por um declínio notável e posterior estabilização. Este padrão corrobora com estudos realizados em outras regiões do Brasil e do mundo. Um estudo ecológico realizado no Piauí por Silva *et al.* (2021) entre os anos de 2020 e 2021, identificou padrões semelhantes de incidência crescente na maioria dos municípios do estado, com uma tendência estacionária para a taxa de mortalidade em quase todos os municípios. No Brasil, dados de diferentes estados indicam que, após a introdução e ampliação da cobertura vacinal, houve uma redução consistente nas taxas de hospitalização e mortalidade (ORELLANA; CUNHA; MARRERO; LEITE *et al.*, 2022; SALES-MOIOLI; GALVAO-LIMA; PINTO; CARDOSO *et al.*, 2022).

A estabilização das taxas de incidência e mortalidade após 2022 pode ser atribuída ao efeito cumulativo da vacinação, que, ao aumentar a imunidade coletiva, reduziu o número de casos graves e óbitos. Os resultados do presente estudo, referente a correlação de *Spearman* entre a cobertura vacinal e as taxas de morbimortalidade, indicaram que o aumento da vacinação está diretamente relacionado a uma queda acentuada na incidência e mortalidade por COVID-19. Esses achados são consistentes com uma revisão sistemática conduzida por Rahmani *et al.*

(2022), que avaliou a eficácia das vacinas contra a COVID-19 na redução da incidência, hospitalizações e mortalidade associadas à doença, utilizando dados de 54 pesquisas observacionais de diferentes países. De acordo com os autores, a eficácia das vacinas contra a COVID-19 foi de 71% após a primeira dose e aumentou para 87% após a segunda dose. Em termos de prevenção de hospitalizações, a eficácia foi de 73% após a primeira dose e 89% após a segunda. Quanto à prevenção de mortes, a vacinação reduziu o risco de mortalidade em 68% após a primeira dose e em 92% após a segunda dose (RAHMANI; SHAVALEH; FOROUHI; DISFANI *et al.*, 2022). Um estudo realizado no Brasil por Victora *et al.* (2021), demonstrou que a vacinação contra a COVID-19, foi associada a uma redução acentuada na mortalidade entre os idosos, especialmente nas faixas etárias de 70 anos ou mais.

Entretanto, vários fatores podem influenciar a relação observada entre vacinação e a morbimortalidade da COVID-19. Primeiramente, a eficácia das vacinas pode ser afetada pelo surgimento de novas variantes do vírus, que podem alterar a dinâmica de transmissão e a gravidade dos casos, como demonstrado no estudo de caso-controle realizado no Reino Unido por Bernal *et al.* (2021). Além disso, a cobertura vacinal não é o único fator que afeta a taxa de mortalidade e incidência de doenças. Medidas de saúde pública, como o distanciamento social, o uso de máscaras e políticas de mobilidade, também desempenharam papéis fundamentais na redução do impacto da pandemia (BARBERIA; CANTARELLI; OLIVEIRA; MOREIRA *et al.*, 2021; RICHMOND; BIG-CANOE; ABRAM; MANDAWÉ *et al.*, 2022). A combinação desses fatores, juntamente com a vacinação, pode contribuir para o controle de futuros surtos de doenças.

Apesar da influência positiva da vacinação acerca da diminuição das taxas de mortalidade pela COVID-19, foi observado que houve variações extremas na cobertura vacinal entre os municípios do Mato Grosso. Houve municípios que apresentaram cobertura vacinal abaixo de 50%, sendo Santa Terezinha, Rondolândia, Santa Cruz do Xingu e Confresa. Enquanto outros municípios apresentaram até 100% de cobertura vacinal, sendo Acorizal, Nova Brasilândia e Santo Antônio de Leverger. Quando observado a localização de cada um desses municípios, notou-se que os municípios que apresentaram menor cobertura vacinal estavam nas regiões Norte e Nordeste Mato-Grossense e os de melhor cobertura nas regiões Sul, Centro-Sul e Sudeste Mato-Grossense.

A desigualdade na cobertura vacinal pode ser explicada por uma combinação de fatores socioeconômicos, logísticos e culturais. A desinformação sobre a vacina, dificuldades de acesso a serviços de saúde, bem como questões religiosas e políticas, foram fatores que contribuíram para o aumento da hesitação vacinal. Além disso, regiões com menor acesso a informações e

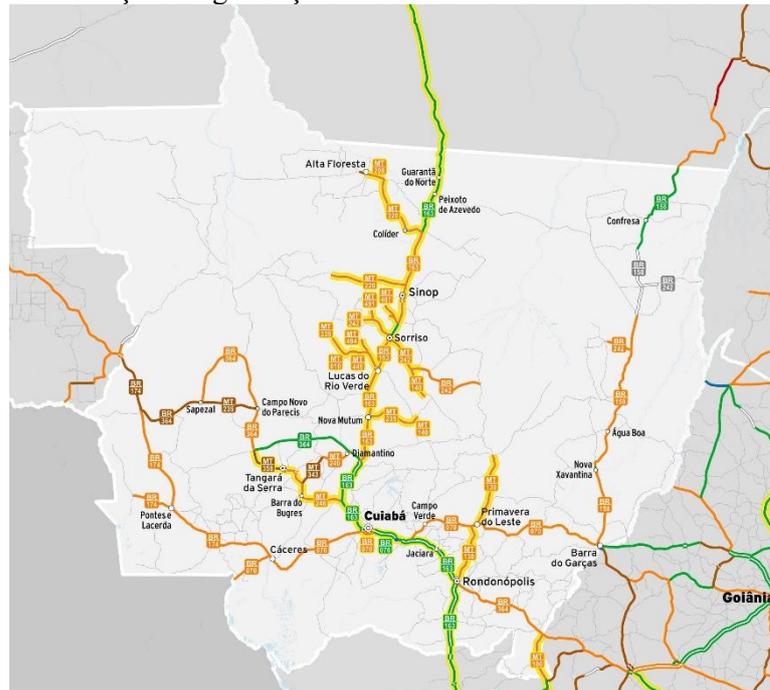
serviços de saúde enfrentaram mais dificuldades em alcançar altas taxas de vacinação (FEIO; QUEIROZ; MORAES; SOUSA JÚNIOR *et al.*, 2023).

A partir do estudo realizado por Moura *et al.* (2022), com dados coletados do Brasil, entre os anos de 2020 a 2022, foi possível observar desigualdades na cobertura vacinal, onde as regiões Sudeste e o Sul apresentaram uma evolução rápida na vacinação, atingindo uma cobertura vacinal de 50% já na 38ª semana de 2021, enquanto que a região Norte alcançou essa marca apenas na 48ª semana. Já a região Centro-Oeste alcançou a marca de 50% de cobertura vacinal por volta da 42ª semana de 2021. Ao final do período analisado pelos autores, as regiões Sudeste e Sul apresentaram cobertura vacinal acima de 80%, enquanto que as regiões Nordeste e Centro-Oeste permaneceram com a cobertura vacinal abaixo de 70% e a região Norte com aproximadamente 60%, caracterizando assim as consequências do desfavorecimento socioeconômico na saúde da população (MOURA; CORTEZ-ESCALANTE; CAVALCANTE; BARRETO *et al.*, 2022).

Um dos fatores que também pode contribuir para a distribuição da vacinação, e até nas diferenças entre as taxas de mortalidade e incidência, é a presença de rodovias federais, que conectam as diferentes regiões, desempenhando um papel importante na mobilidade e acesso a serviços de saúde. Uma análise histórica realizada no Tocantins, demonstrou que a construção da BR-153, uma rodovia federal que conecta desde o Pará até o Rio Grande do Sul, contribuiu para melhorias no Índice de Desenvolvimento Humano (IDH) dos municípios ao longo da rodovia. As melhorias em infraestrutura, combinadas com a melhor acessibilidade proporcionada pela rodovia, resultaram em avanços na qualidade de vida, educação, saúde e renda para os habitantes dessas regiões (NUNES; MELO; BRACARENSE, 2020).

Este estudo não avaliou efetivamente a associação entre a distribuição das rodovias e as taxas de cobertura vacinal, morbimortalidade e IPS. Entretanto, ao observar o mapa das rodovias federais fornecido pela Pesquisa da Confederação Nacional dos Transportes (CNT) em 2023 (Figura 20), é notável que as regiões Sul, Centro-Sul e Sudeste Mato-Grossense apresentam grande concentração de rodovias que interligam as regiões entre si e entre outros estados, como Goiânia e Mato Grosso do Sul. As regiões Norte e Nordeste Mato-Grossense detêm de apenas duas rodovias federais, caracterizando em possíveis desafios logísticos para a distribuição e acesso à saúde. Estudos futuros sobre a influência da mobilidade e distribuição logística de transporte no estado são fundamentais para aprofundar a compreensão de como esses fatores podem impactar a saúde pública.

Figura 20. Distribuição e organização das rodovias federais no estado de Mato Grosso



Fonte: Pesquisa da Confederação Nacional dos Transportes, 2023.

Quando levado em consideração a temporalidade das taxas de morbimortalidade por COVID-19 no Mato Grosso, percebe-se um padrão temporal onde as taxas de incidência e mortalidade apresentaram elevações durante os meses de julho de 2020, janeiro e março de 2021, e janeiro, julho e dezembro de 2022. Esses dados temporais apresentam certa consonância com um estudo ecológico conduzido por Maia *et al.* (2024) no Rio Grande do Norte, durante o período de 2020 a 2022, que revelou picos nas taxas de incidência e mortalidade durante os meses de junho e julho 2020, junho de 2021, e fevereiro, julho e dezembro de 2022. Em um estudo realizado no estado de Roraima, no período de março de 2020 a julho de 2021, os autores observaram picos nas taxas de incidência e mortalidade em junho e julho de 2020, e no período de março e junho de 2021 (VALENZUELA; MORAIS; DABOIN; CAVALCANTI *et al.*, 2021).

Algo que se deve levar em consideração para a análise dos picos das taxas de morbimortalidade, é referente à diferentes fatores que podem influenciar nesse aumento ou diminuição. Um desses fatores consiste na falta de adesão às medidas de distanciamento social por parte da população. De acordo com dados da Secom-MT, com o início das restrições para conter a disseminação do coronavírus em 2020, a Polícia Militar do Mato Grosso realizou 5.709 intervenções onde milhares de pessoas foram abordadas, para a dispersão de aglomerações, fechamento de festas e outros eventos ilegais. Nesse mesmo ano, 400 estabelecimentos foram fechados por não cumprirem as medidas de prevenção impostas e 2.153 comércios foram

notificados por permitirem a circulação de pessoas sem a utilização de máscara facial (SECOM-MT, 2021a).

É importante ressaltar que, em março de 2020, o estado de Mato Grosso implementou medidas que incluíram a suspensão de eventos e a quarentena de grupos de risco, que foram rapidamente seguidas por paralisações econômicas parciais à medida que o número de casos confirmados aumentava. O estado também adotou medidas de restrição de transporte intermunicipal e interestadual, embora não tenha implementado uma quarentena obrigatória para toda a população. Essas ações demonstraram a tentativa adotada para equilibrar a contenção da propagação do vírus com a manutenção de certas atividades econômicas. Quando comparado a outros estados do Brasil, a implementação à essas medidas pelo Mato Grosso ocorreram de forma relativamente rápida (SILVA; LIMA; POLLI; RAZIA *et al.*, 2020).

Outro fator a se levar em consideração, é o surgimento de novas variantes do vírus ao longo dos anos de pandemia. Em meados de novembro de 2020 em Manaus, foi identificada uma nova linhagem do SARS-CoV-2, denominada P.1 ou variante Gama. Essa variante foi caracterizada por possuir 17 mutações, das quais três foram associadas a um aumento da afinidade pelo receptor ACE2 (FARIA; MELLAN; WHITTAKER; CLARO *et al.*, 2021). Essa variante, se tornou a responsável pela maior onda de taxas de incidência e mortalidade no Brasil. Por conta desse surto, em 2021 ocorreu a maior crise de escassez de oxigênio hospitalar, onde o epicentro da crise foi Manaus, no estado de Amazonas (BBC, 2021).

No ano de 2022, uma nova variante do vírus denominada Ômicron apresentou rápida disseminação em comparação com variantes anteriores, devido a curtos intervalos de transmissão da cepa, fazendo com que a taxa de incidência aumentasse de forma súbita em diferentes períodos (MEFSIN; CHEN; BOND; LIN *et al.*, 2022). Apesar disso, populações com alta taxa de cobertura vacinal não apresentaram um aumento proporcional nas taxas de mortalidade e letalidade pela nova variante do vírus (ALTARAWNEH; CHEMAITELLY; HASAN; AYOUB *et al.*, 2022; FONAGER; BENNEDBAEK; BAGER; WOHLFAHRT *et al.*, 2022). Dados estes que corroboram com o presente estudo, que identificou altos picos da taxa de incidência no ano de 2022 e baixos picos para a taxa de mortalidade.

A análise de autocorrelação espacial realizada para entender a distribuição da incidência, mortalidade, letalidade e cobertura vacinal da COVID-19 nos municípios do estado de Mato Grosso revelou padrões de agrupamento e correlações espaciais. Foi possível identificar que as maiores taxas de incidência e mortalidade apresentaram uma tendência a se concentrarem nas regiões do Norte e Nordeste Mato Grossense, regiões estas marcadas pelos menores valores para IPS. Ao comparar os mapas de *clusters* da incidência e mortalidade com o mapa da

cobertura vacinal, observa-se que as regiões do Sul, Centro-Sul e Sudeste Mato-Grossense evidenciaram uma maior adesão à vacinação pela população, refletindo em menores taxas de incidência e mortalidade por COVID-19.

A influência dos fatores sociais e demográficos também é notável ao analisar a autocorrelação espacial bivariada. Observou-se uma correlação negativa entre a taxa de incidência e a cobertura vacinal, indicando que municípios com altas taxas de incidência estão próximos de regiões com baixa cobertura vacinal. Da mesma forma, houve uma correlação negativa entre a taxa de incidência da COVID-19 e o IPS, sugerindo que áreas com condições socioeconômicas desfavoráveis apresentaram maior disseminação do vírus. Em contrapartida, foi encontrada uma correlação positiva entre a cobertura vacinal e o IPS, mostrando que municípios com melhores condições sociais tendem a ter maior adesão à vacinação. Esses resultados destacam a necessidade de políticas públicas que promovam a equidade no acesso à vacinação, especialmente em áreas mais vulneráveis, para reduzir a morbimortalidade associada à COVID-19.

Esses achados corroboram com um estudo realizado a nível nacional, durante o período dos meses de abril a outubro de 2021, que identificou que a cobertura vacinal foi maior nas regiões Centro-Sul do Brasil, onde os indicadores socioeconômicos são melhores, em comparação com as regiões Norte e Nordeste. Este resultado sugere que maiores recursos em saúde e campanhas informativas eficazes estão diretamente relacionadas à maiores taxa de cobertura vacinal (BAUMGRATZ; TERRE; ALVES, 2023). Fatores associados às desigualdades sociais também foram observadas em um estudo feito no Tocantins, no período de março de 2020 a abril de 2021, que demonstrou que regiões com menor acesso a serviços de saúde e maior vulnerabilidade social apresentaram uma carga elevada de casos e óbitos (CESAR; DABOIN; MORAIS; PORTUGAL *et al.*, 2021).

Um estudo realizado na Espanha, indicou que as taxas de infecção por COVID-19 são de seis a sete vezes maiores nas áreas mais desfavorecidas em comparação com as menos desfavorecidas (BAMBRA; RIORDAN; FORD; MATTHEWS, 2020). Em consonância, Chen e Krieger (2021), demonstraram que os residentes dos condados menos favorecidos nos Estados Unidos apresentaram um maior risco de desenvolverem as formas mais graves da COVID-19, podendo assim apresentar mais casos de óbitos.

Quando considerado a quantidade de recursos relacionados à saúde, como o número de médicos e leitos hospitalares por população, um estudo que utilizou dados de 79 países, coletados desde o início da pandemia até abril de 2021, revelou correlações positivas com as taxas de incidência e correlações negativas com as taxas de letalidade, sugerindo que recursos

médicos adequados são importantes tanto para a detecção de casos de COVID-19 quanto para a prevenção de mortes relacionadas à doença (HONG; LEE; CHOI; MOON *et al.*, 2021). Dessa forma, pode ser que a distribuição dos recursos de saúde para os diferentes municípios e regiões de saúde do Mato Grosso pode influenciar nas taxas de morbimortalidade e cobertura vacinal observadas no presente estudo.

Sendo assim, é fundamental desenvolver estratégias que vão além da resposta imediata à pandemia, englobando a prevenção, o diagnóstico, o tratamento e a recuperação. Essas estratégias precisam ser sustentáveis e bem equilibradas, especialmente em regiões vulneráveis, que apresentam desigualdades econômicas e sociais. A pandemia evidenciou a necessidade de um sistema de saúde robusto e adaptável que possa responder não apenas às crises de saúde, mas também às desigualdades socioeconômicas existentes que vão além dessas crises.

Políticas voltadas para a equidade na saúde são essenciais para melhorar a qualidade de vida das populações. A pandemia de COVID-19 revelou ainda mais as vulnerabilidades sociais enfrentadas pela população, especialmente em regiões com acesso limitado aos serviços de saúde. Portanto, a implementação de políticas que assegurem recursos adequados, profissionais de saúde qualificados e infraestrutura de saúde é vital para atender às necessidades de todas as comunidades, particularmente aquelas que historicamente foram marginalizadas. Além disso, a criação de sistemas de monitoramento e avaliação contínua dos indicadores de saúde pública, especialmente em áreas que foram detectadas como vulneráveis no presente estudo, pode ajudar a identificar rapidamente problemas emergentes e adaptar as intervenções conforme necessário.

O estudo apresentado possui algumas limitações que devem ser consideradas ao interpretar os resultados. Primeiramente, por se tratar de um estudo ecológico, ele está sujeito à falácia ecológica, onde associações observadas em grupos podem não refletir as mesmas associações em indivíduos. Isso pode limitar a capacidade de inferir causalidades a nível individual.

Outra limitação se dá devido ao presente estudo não analisar todas as variáveis confundidoras presentes no banco de dados, podendo assim influenciar os resultados. Estudos futuros que envolvam variáveis como comorbidades, mobilidade, níveis de renda, acesso a cuidados de saúde, escolaridade e condições de moradia são necessários para garantir uma compreensão mais abrangente do impacto da COVID-19 no Mato Grosso.

A utilização de dados secundários, coletados de bases públicas, também podem ocasionar em limitações relacionadas à qualidade, precisão e veracidade das informações. Essa limitação deixa o estudo sujeito a um viés de informação, devido à possíveis inconsistências nos registros ou subnotificações que podem impactar a análise e a interpretação dos resultados. Para amenizar

este viés, utilizamos dados oficiais de órgãos de saúde pública, combinados com informações adicionais de pesquisas locais, o que fortaleceu a validade das conclusões. Além disso, toda a coleta, limpeza e análise dos dados foi realizada de forma minuciosa e sistemática, garantindo que possíveis erros nos dados fossem retirados.

Outro viés que o estudo pode apresentar é o viés espacial que pode surgir devido à desigualdade na qualidade dos dados entre diferentes regiões analisadas. Para evitar esse viés, foi considerado as variações regionais e temporais, e empregado técnicas de análise espacial e temporal robustas, que ajudaram a identificar padrões consistentes nos resultados.

Contudo, o estudo apresenta pontos fortes relevantes. A utilização de métodos estatísticos, como a análise de tendência e correlação, permitiu uma análise mais detalhada das tendências das taxas de incidência e mortalidade da COVID-19 e a relação com a adesão à vacinação. Além disso, a estratificação dos resultados para uma análise espacial e temporal pode demonstrar sobre como a pandemia afetou diferentes regiões e grupos, evidenciando desigualdades que podem ajudar a direcionar futuras políticas públicas para a região. A padronização dos dados também foi de extrema relevância, garantindo comparações mais precisas e confiáveis entre as diferentes populações analisadas, o que fortalece as conclusões do estudo.

A inclusão dos indicadores socioambientais e demográficos também foi eficaz em fornecer uma visão mais completa das condições que contribuem para as diferenças nos resultados referentes a eficácia das medidas de saúde tomadas por cada município. Essa abordagem mais ampla é essencial para criar estratégias de saúde pública que sejam mais justas e eficazes, garantindo a identificação de regiões e grupos que foram mais afetados pela pandemia, podendo orientar a alocação de recursos de forma mais eficaz, garantindo que áreas com maior vulnerabilidade recebam apoio adequado. Investimentos contínuos na infraestrutura de saúde e em programas de educação em saúde são essenciais para preparar as comunidades para enfrentar futuras crises sanitárias.

Sendo assim, o presente estudo detalhou a dinâmica espacial e temporal da pandemia de COVID-19 no Mato Grosso, destacando como as desigualdades sociais e a cobertura vacinal impactaram a morbimortalidade. Essas informações são fundamentais para a formulação de políticas públicas mais equitativas e eficazes. A identificação de *hot spots* das taxas de incidência e mortalidade, assim como a análise da cobertura vacinal, pode fornecer uma base para que os gestores de saúde planejem melhor as intervenções em futuras crises de saúde pública, focando nas regiões e populações mais vulneráveis.

## 6. CONCLUSÃO

Este estudo visou analisar a dinâmica espacial e temporal da pandemia de COVID-19 no estado de Mato Grosso, com foco na relação entre a cobertura vacinal e os determinantes sociais de saúde. Para alcançar esse objetivo, uma série de análises foi realizada, abrangendo tanto aspectos descritivos quanto espaciais.

Os resultados demonstraram variação nas taxas de morbimortalidade ao longo do período de 2020 a 2023. Os idosos, especialmente aqueles com mais de 80 anos, foram os mais afetados, apresentando as maiores taxas de mortalidade e letalidade. Em contrapartida, crianças e adolescentes tiveram as menores taxas. Além disso, as análises revelaram que, embora as mulheres apresentassem uma maior taxa de incidência, os homens tiveram maiores taxas de mortalidade e letalidade, indicando uma disparidade de gênero nos resultados da doença.

As análises temporais mostraram que, após a introdução das campanhas de vacinação em 2021, houve uma redução acentuada nas taxas de incidência e mortalidade. No entanto, essa redução não foi uniforme em todo o estado, com regiões apresentando uma adesão vacinal desigual. A influência da vacinação sobre as taxas de morbimortalidade foi confirmada pela análise de correlação, demonstrando que à medida que a cobertura vacinal aumenta, as taxas de incidência e mortalidade diminuem.

A análise espacial das taxas de morbimortalidade e cobertura vacinal, identificou padrões claros de autocorrelação espacial. Os *hot spots* de incidência e mortalidade foram predominantemente localizados nas regiões Norte e Nordeste do estado, que também apresentaram os menores Índices de Progresso Social (IPS). Em contraste, as regiões Sul, Centro-Sul e Sudeste, que apresentaram maiores taxas de IPS, indicaram uma menor taxa de incidência e uma melhor cobertura vacinal. Essa análise confirma que a vulnerabilidade social e econômica pode estar diretamente associada a piores resultados de saúde, reforçando a necessidade de políticas públicas equitativas que abordem essas desigualdades.

Ressalta-se que presente o estudo destaca que a cobertura vacinal foi um fator que teve grande influência na redução da morbimortalidade, mas as desigualdades no acesso à vacinação e aos serviços de saúde demonstram a necessidade de uma abordagem mais coordenada e inclusiva nas políticas de saúde pública. Os resultados obtidos fornecem uma compreensão detalhada das dinâmicas espaciais e temporais da pandemia no Mato Grosso e pode indicar caminhos para melhorar a equidade no acesso à saúde no estado, especialmente em contextos de crise sanitária.

## 7. REFERÊNCIAS BIBLIOGRÁFICAS

- AHMAD, O. B.; BOSCHI-PINTO, C.; LOPEZ, A. D.; MURRAY, C. J. *et al.* Age standardization of rates: a new WHO standard. **GPE Discussion Paper Series**, 9, n. 31, p. 1-14, 2001.
- ALBUQUERQUE, M. V.; RIBEIRO, L. H. L. Inequality, geographic situation, and meanings of action in the COVID-19 pandemic in Brazil. **Cad Saúde Pública**, 36, n. 12, p. e00208720, 2021.
- ALMEIDA, E. **Econometria Espacial Aplicada**. 1 ed. Campinas, São Paulo: Alínea, 2012. 498 p.
- ALTARAWNEH, H. N.; CHEMAITELLY, H.; HASAN, M. R.; AYOUB, H. H. *et al.* Protection against the Omicron Variant from Previous SARS-CoV-2 Infection. **N Engl J Med**, 386, n. 13, p. 1288-1290, Mar 31 2022.
- AMADO, L. H. E.; RIBEIRO, A. M. M. Panorama e desafios dos povos indígenas no contexto de pandemia do covid-19 no brasil. **Revista Interdisciplinar de Sociologia e Direito**, 22, n. 2, p. 335-360, 2020.
- ANSELIN, L. Local indicators of spatial association—LISA. **Geographical analysis**, 27, n. 2, p. 93-115, 1995.
- ANSELIN, L.; BERA, A. K. **Spatial Dependence in Linear Regression Models with an Introduction to Spatial Econometrics**. CRC Press, 1998. (Handbook of Applied Economic Statistics).
- ANTUNES, J. L. F.; CARDOSO, M. R. A. Uso da análise de séries temporais em estudos epidemiológicos. **Epidemiol Serv Saúde**, 24, n. 3, p. 565-576, 2015.
- AYRES, A. B. N.; TRAVASSOS, X. L.; SAMPAIO, R. R. Strategies used to enable the vaccine for Covid-19 in Brazil and the pandemic paradigma. **Clium**, 23, n. 5, p. 173-187, 2023.
- BACH, T.; WEGRICH, K. Blind Spots, Biased Attention, and the Politics of Non-coordination. *In*: MCMILLAN, P. (Ed.). **The Blind Spots of Public Bureaucracy and the Politics of Non-Coordination**. Switzerland: Springer International Publishing, 2019. p. 3-28.
- BADEN, L. R.; EL-SAHLY, H. M.; ESSINK, B.; KOTLOFF, K. *et al.* Efficacy and Safety of the mRNA-1273 SARS-CoV-2 Vaccine. **N Engl J Med**, 384, n. 5, p. 403-416, 2021.
- BAMBRA, C.; RIORDAN, R.; FORD, J.; MATTHEWS, F. The COVID-19 pandemic and health inequalities. **J Epidemiol Community Health**, 74, n. 11, p. 964-968, Nov 2020.
- BAQUI, P.; BICA, I.; MARRA, V.; ERCOLE, A. *et al.* Ethnic and regional variations in hospital mortality from COVID-19 in Brazil: a cross-sectional observational study. **Lancet Glob Health**, 8, n. 8, p. e1018-e1026, Aug 2020.
- BARBERIA, L. G.; CANTARELLI, L. G. R.; OLIVEIRA, M. L. C. d. F.; MOREIRA, N. d. P.

*et al.* The effect of state-level social distancing policy stringency on mobility in the states of Brazil. **Revista de Administração Pública**, 55, n. 1, p. 27-49, 2021.

BARBOSA, F. R. G. M. Índice de Desenvolvimento Relativo, IDH-M e IFDM: em busca da operacionalização das liberdades instrumentais de Amartya Sen. **Ensaio FEE**, 38, n. 2, p. 295-328, 2017.

BARBOSA, T. P.; DA COSTA, F. B. P.; RAMOS, A. C. V.; BERRA, T. Z. *et al.* COVID-19 morbidity and mortality associated with chronic disorders, healthcare services, and inequity: evidence for a syndemic. **Morbimortalidad por COVID-19 asociada a los problemas cronicos de salud, los servicios de salud y las inequidades: evidencia de sindemia. Rev Panam Salud Publica**, 46, 2022.

BARRAL-NETTO, M.; BARRETO, M. L.; PINTO JUNIOR, E. P.; ARAGÃO, É. **Construção de conhecimento no curso da pandemia de COVID-19: aspectos biomédicos, clínico-assistenciais, epidemiológicos e sociais**. Salvador: EDUFBA, 2020. 9786556300443.

BARRETO, M. L. Health inequalities: a global perspective. **Cien Saude Colet**, 22, n. 7, p. 2097-2108, Jul 2017.

BARRETO, N. M. P. V.; RIOS, J. D. C.; RIBEIRO, E. B.; TORREÃO, P. L. *et al.* Vulnerabilidades sociais relacionadas à infecção e mortalidade por covid-19: uma revisão sistemática. **Revista de Saúde Coletiva da UFS**, 11, n. 2, 2021.

BARROSO, J. A.; PEREIRA, A. W. R.; SILVA, R. E. G. d.; BRESCIANI, L. P. *et al.* Os efeitos dos gastos públicos em educação, saúde e trabalho no desempenho do índice FIRJAN de Desenvolvimento Municipal em Cidades do Estado de São Paulo. **Research, Society and Development**, 11, n. 1, 2022.

BASCH, C. H.; HILLYER, G. C.; MELEO-ERWIN, Z. C.; JAIME, C. *et al.* Preventive Behaviors Conveyed on YouTube to Mitigate Transmission of COVID-19: Cross-Sectional Study. **JMIR Public Health Surveill**, 6, n. 2, p. e18807, Apr 2 2020.

BAUMGRATZ, D.; TERRE, B. R. B. F.; ALVES, L. R. Análise da correlação espacial da COVID-19 nos municípios brasileiros de fronteira. **Revista Tecnologia e Sociedade**, 19, n. 56, 2023.

BBC. **Covid em Manaus: sem oxigênio, pacientes dependem de ventilação manual para sobreviver em Manaus**. 2021. Disponível em: <https://www.bbc.com/portuguese/brasil-55674229>. Acesso em: 12 ago 2024.

BERENGUER, J.; RYAN, P.; RODRIGUEZ-BANO, J.; JARRIN, I. *et al.* Characteristics and predictors of death among 4035 consecutively hospitalized patients with COVID-19 in Spain. **Clin Microbiol Infect**, 26, n. 11, p. 1525-1536, Nov 2020.

BERNAL, J. L.; ANDREWS, N.; GOWER, C.; GALLAGHER, E. *et al.* Effectiveness of Covid-19 Vaccines against the B.1.617.2 (Delta) Variant. **N Engl J Med**, 385, n. 7, p. 585-594, Aug 12 2021.

BEYERSTEDT, S.; CASARO, E. B.; RANGEL, E. B. COVID-19: angiotensin-converting

enzyme 2 (ACE2) expression and tissue susceptibility to SARS-CoV-2 infection. **Eur J Clin Microbiol Infect Dis**, 40, n. 5, p. 905-919, May 2021.

BEZERRA, A. C. V.; SILVA, C.; SOARES, F. R. G.; SILVA, J. Factors associated with people's behavior in social isolation during the COVID-19 pandemic. **Ciênc Saúde Coletiva**, 25, p. 2411-2421, 2020.

BIEHL, J. Descolonizando a saúde planetária. **Horiz Antropol**, 27, n. 59, p. 337-359, 2021.

BRASIL. **Ministério da Saúde. Secretaria Extraordinária de Enfrentamento à COVID-19. Plano nacional de operacionalização da vacinação contra a covid-19.** Brasília, DF, 2022.

BRASIL. **Ministério da Saúde. Secretaria de Vigilância à Saúde (SVS). Situação epidemiológica da COVID-19 no Brasil. Painel Coronavírus.**, 2024. Disponível em: <https://covid.saude.gov.br>. Acesso em: 03 jun 2024.

BROCKLEHURST, H.; LAURENSEN, M. A concept analysis examining the vulnerability of older people. **British Journal of Nursing**, 17, n. 21, p. 1354-1357, 2008.

BROCKWELL, P. J.; DAVIS, R. A. **Introduction to Time Series and Forecasting.** Cham, Switzerland: Springer International Publishing, 2016.

BUSS, P. M.; PELLEGRINI FILHO, A. A saúde e seus determinantes sociais. **Physis: Revista de Saúde Coletiva**, 17, n. 1, p. 77-93, 2007.

CANDIDO, D. D. S.; WATTS, A.; ABADE, L.; KRAEMER, M. U. G. *et al.* Routes for COVID-19 importation in Brazil. **J Travel Med**, 27, n. 3, May 18 2020.

CARAM, C. D. S.; MENDONÇA, R. D. D.; MARQUES, R. J. R.; BRITO, M. J. M. *et al.* Redução da desigualdade de acesso às ações de promoção da saúde na Atenção Primária brasileira: Programa Academia da Saúde. **DEMETRA: Alimentação, Nutrição & Saúde**, 16, 2021.

CARDOSO, G. C. P.; OLIVEIRA, E. A. d.; CASANOVA, A. O.; TOLEDO, P. P. d. S. *et al.* Participação dos atores na avaliação do Projeto QualiSUS-Rede: reflexões sobre uma experiência de abordagem colaborativa. **Saúde Debate**, 43, n. 120, p. 54-68, 2019.

CARVALHO, B. C. C. **Fique em casa? Estudo antropológico sobre os desdobramentos da pandemia da COVID-19 nos encontros entre o Consultório na Rua e as pessoas em situação de rua no município de João Pessoa/PB.** 2022. 130 f. Dissertação (Pós-Graduação em Antropologia) - Centro de Ciências Humanas, Letras e Artes, Universidade Federal da Paraíba, João Pessoa.

CARVALHO, J. A. M. d.; GARCIA, R. A. O envelhecimento da população brasileira: um enfoque demográfico. **Cadernos de Saúde Pública**, 19, p. 725-733, 2003.

CESAR, A. E. M.; DABOIN, B. E. G.; MORAIS, T. C.; PORTUGAL, I. *et al.* Analysis of COVID-19 mortality and case-fatality in a low- income region: an ecological time-series study in Tocantins, Brazilian Amazon. **Journal of Human Growth and Development**, 31, n. 3, p.

496-506, 2021.

CEVIK, M.; KUPPALLI, K.; KINDRACHUK, J.; PEIRIS, M. Virology, transmission, and pathogenesis of SARS-CoV-2. **Br Med J**, 371, p. m3862, 2020.

CHEN, J. T.; KRIEGER, N. Revealing the Unequal Burden of COVID-19 by Income, Race/Ethnicity, and Household Crowding: US County Versus Zip Code Analyses. **J Public Health Manag Pract**, 27 Suppl 1, COVID-19 and Public Health: Looking Back, Moving Forward, p. S43-S56, Jan/Feb 2021.

CHIORO, A.; CALIFE, K.; BARROS, C. R. D. S.; MARTINS, L. C. *et al.* Covid-19 em uma Região Metropolitana: vulnerabilidade social e políticas públicas em contextos de desigualdades. **Saúde Debate**, 44, p. 219-231, 2020.

CLEVELAND, R. B.; CLEVELAND, W. S.; MCRAE, J. E.; TERPENNING, I. STL: A seasonal-trend decomposition procedure based on loess. **J Off Stat**, 6, p. 3-73, 1990.

CNS. **Ministério da Saúde. Conselho Nacional de Saúde. Resolução nº 510, de 07 de abril de 2016.** 2016.

CORMAN, V. M.; MUTH, D.; NIEMEYER, D.; DROSTEN, C. Hosts and Sources of Endemic Human Coronaviruses. **Adv Virus Res**, 100, p. 163-188, 2018.

COSTA, F. d. A.; SILVA, A. d. S.; OLIVEIRA, C. B. S. d.; COSTA, L. C. S. d. *et al.* COVID-19: seus impactos clínicos e psicológicos na população idosa. **Brazilian Journal of Development**, 6, n. 7, p. 49811-44982, 2020.

CRISTALDO, H.; BRANDÃO, M. F., F. **Vacinação contra a covid-19 começa em todo o país.** Brasília, 2021. Disponível em: <https://agenciabrasil.ebc.com.br/saude/noticia/2021-01/vacinacao-contracovid-19-comeca-em-todo-o-pais>. Acesso em: 16 jun 2024.

CRUZ, R. M.; ANDRADE, J. E. B.; MOSCON, D. C. B.; MICHELETTO, M. R. D. *et al.* COVID-19: Emergência e Impactos na Saúde e no Trabalho. **Rev Psicol Organ Trab**, 20, p. 1-2, 2020.

CSG. Coronaviridae Study Group of the International Committee on Taxonomy of Viruses. The species Severe acute respiratory syndrome-related coronavirus: classifying 2019-nCoV and naming it SARS-CoV-2. **Nat Microbiol**, 5, n. 4, p. 536-544, Apr 2020.

CUNHA, E. C. F.; CESCINETTO, J.; VARGAS, E. J. C.; SILVEIRA, I. V. *et al.* A Influência Das Vacinas Na Luta Contra a Covid-19: Uma Revisão Narrativa. **Brazilian Journal of Implantology and Health Sciences**, 6, n. 6, p. 651-666, 2024.

DAHLGREN, G.; WHITEHEAD, M. Policies and strategies to promote social equity. **Health Institute of Future Studies, Stockholm**, 1991.

DAHLGREN, G.; WHITEHEAD, M. The Dahlgren-Whitehead model of health determinants: 30 years on and still chasing rainbows. **Public Health**, 199, p. 20-24, 2021.

DAMASCO, F.; ANTUNES, M.; AZEVEDO, M. Deslocamentos da população indígena para

acesso aos serviços de saúde: elementos para ações emergenciais de enfrentamento à Covid-19. **Revista Geographia**, 22, n. 48, p. 1-32, 2020.

DATTANI, S.; RODÉS-GUIRAO, L.; RITCHIE, H.; ORTIZ-OSPINA, E. *et al.* Life Expectancy. **Our World In Data**, 2023.

ERVILHA, G. T.; ALVES, F. F.; GOMES, A. P. Desenvolvimento municipal e eficiência dos gastos públicos na Bahia: uma análise do IFDM a partir da metodologia DEA. **Bahia Análise e Dados**, 23, n. 3, p. 553-566, 2013.

FARIA, N. R.; MELLAN, T. A.; WHITTAKER, C.; CLARO, I. M. *et al.* Genomics and epidemiology of the P.1 SARS-CoV-2 lineage in Manaus, Brazil. **Science**, 372, n. 6544, p. 815-821, May 21 2021.

FEIO, E. C. G.; QUEIROZ, L. A.; MORAES, T. M.; SOUSA JÚNIOR, A. S. *et al.* Impacto da cobertura vacinal sobre o COVID-19 no estado do Pará: uma análise espacial (2020 - 2022). **Amazônia Science and Health**, 11, n. 3, 2023.

FIGUEIREDO FILHO, D. B.; PARANHOS, R.; ROCHA, E. C.; DA SILVA JUNIOR, J. A. *et al.* Análise de componentes principais para construção de indicadores sociais. **Rev Bras Biom**, 31, n. 1, p. 61-78, 2013.

FIGUEIREDO, J. P. **Comportamentos de saúde, costumes e estilos de vida: indicadores de risco epidemiológico: avaliação de estados de saúde e doença**. 2015. 24 f. Dissertação (Doutorado em Ciências da Saúde) - Faculdade de Medicina, Universidade de Coimbra, Portugal.

FIRJAN. Federação das Indústrias do Estado do Rio de Janeiro. Índice FIRJAN de desenvolvimento municipal. **Anexo metodológico – IFDM**, 2018.

FONAGER, J.; BENNEBAEK, M.; BAGER, P.; WOHLFAHRT, J. *et al.* Molecular epidemiology of the SARS-CoV-2 variant Omicron BA.2 sub-lineage in Denmark, 29 November 2021 to 2 January 2022. **Euro Surveill**, 27, n. 10, Mar 2022.

FREITAS, A. L. G. C.; SANTOS, M. S.; SANTOS, J. A. B. Vascular complications after Covid-19. **Braz J Hea Rev**, 4, n. 3, p. 13090-13105, 2021.

GAZONI, V. G.; RUI, M. I. d. C.; MORAES, M. M.; ZANOTTI, M. R. *et al.* Identification of socioeconomic predictors for hospitalization, intensive care admission and mortality by Covid-19. **Brazilian Journal of Development**, 8, n. 5, p. 41492-41508, 2022.

GEBHARD, C.; REGITZ-ZAGROSEK, V.; NEUHAUSER, H. K.; MORGAN, R. *et al.* Impact of sex and gender on COVID-19 outcomes in Europe. **Biol Sex Differ**, 11, n. 1, p. 29, May 25 2020.

GELLER, C.; VARBANOV, M.; DUVAL, R. E. Human coronaviruses: insights into environmental resistance and its influence on the development of new antiseptic strategies. **Viruses**, 4, n. 11, p. 3044-3068, Nov 12 2012.

GODOY, D.; SOARES, P. R. R. Gestão Territorial e Indicadores Sociais: o caso do IDH. **Ponta**

**de Lança: Revista Eletrônica de História, Memória & Cultura**, 14, n. 26, p. 105 - 125, 07/20 2020.

GOMES, D. C. K. **Obesidade e COVID-19: estudo de base populacional da mortalidade por SRAG no Brasil**. 2022. 87 f. (Doutorado em Saúde Coletiva) - Instituto de Medicina Social Hesio Cordeiro, Universidade do Estado do Rio de Janeiro, Rio de Janeiro.

GORONZY, J. J.; WEYAND, C. M. Understanding immunosenescence to improve responses to vaccines. **Nat Immunol**, 14, n. 5, p. 428-436, May 2013.

GRANDA, E. C.; CUNHA, S. G. S.; SILVA, M. F. d.; CAMPOS, K. F. C. COVID-19 in elderly: why are they more vulnerable to the new coronavirus? **Brazilian Journal of Development**, 7, n. 4, p. 42572-42581, 2021.

GUAN, W. J.; NI, Z. Y.; HU, Y.; LIANG, W. H. *et al.* Clinical Characteristics of Coronavirus Disease 2019 in China. **N Engl J Med**, 382, n. 18, p. 1708-1720, 2020.

GUIMARÃES, R. M.; VILLARDI, J. W. R.; SAMPAIO, J. R. C.; ELEUTERIO, T. A. *et al.* Questões demográficas atuais e implicações para o modelo de atenção à saúde no Brasil. **Cadernos Saúde Coletiva**, 29, n. spe, p. 3-15, 2021.

HAN, J.; YIN, J.; WU, X.; WANG, D. *et al.* Environment and COVID-19 incidence: A critical review. **J Environ Sci (China)**, 124, p. 933-951, Feb 2023.

HASTIE, C. E.; MACKAY, D. F.; HO, F.; CELIS-MORALES, C. A. *et al.* Vitamin D concentrations and COVID-19 infection in UK Biobank. **Diabetes Metab Syndr**, 14, n. 4, p. 561-565, Jul-Aug 2020.

HONG, D.; LEE, S.; CHOI, Y. J.; MOON, S. *et al.* The age-standardized incidence, mortality, and case fatality rates of COVID-19 in 79 countries: a cross-sectional comparison and their correlations with associated factors. **Epidemiol Health**, 43, p. e2021061, 2021.

HYNDMAN, R.; ATHANASOPOULOS, G.; BERGMEIR, C.; CACERES, G. *et al.* **Forecast: Forecasting functions for time series and linear models**. R package version 8.22.0 ed. 2024.

HYNDMAN, R. J.; KHANDAKAR, Y. Automatic time series forecasting: the forecast package for R. **Journal of Statistical Software**, 27, n. 3, p. 1-22, 2008.

IBGE. Instituto Brasileiro de Geografia e Estatística. Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais. Censo Brasileiro de 2022. Rio de Janeiro: IBGE 2022a.

IBGE. **Malha Municipal Digital e Áreas Territoriais 2022. Nota metodológica n. 01**. Instituto Brasileiro de Geografia e Estatística. 2022b.

ICHIHARA, M. Y. T.; RAMOS, D.; REBOUCAS, P.; OLIVEIRA, F. J. *et al.* Area deprivation measures used in Brazil: a scoping review. **Rev Saude Publica**, 52, p. 83, 2018.

IPEA. Instituto de Pesquisa Econômica Aplicada. Atlas da vulnerabilidade social nos municípios brasileiros. REPÚBLICA, S. d. A. E. d. P. d. Brasília 2015.

IPEA. **Instituto de Pesquisa Econômica Aplicada. População em situação de rua supera 281,4 mil pessoas no Brasil.** 2022. Disponível em: <https://www.ipea.gov.br/portal/categorias/45-todas-as-noticias/noticias/13457-populacao-em-situacaoderuasupera2814milpessoasnobrasil>. Acesso em: 03 jun 2024.

IPEA. **Desigualdades raciais e de renda no acesso à saúde nas cidades brasileiras.** Rio de Janeiro, 2023.

JESUS, J. G. d.; SACCHI, C.; CLARO, I.; SALLES, F. *et al.* **First cases of coronavirus disease (COVID-19) in Brazil, South America (2 genomes, 3rd March 2020).** 2020. Disponível em: <https://virological.org/t/first-cases-of-coronavirus-disease-covid-19-in-brazil-south-america-2-genomes-3rd-march-2020/409/2>. Acesso em: 04 jun 2024.

LEITE, E. S. F.; MARTINS, M. G.; MARTINS, C. M. d. C. R. Hesitação Vacinal e seus Fatores Associados no Contexto da Pandemia de COVID-19 no Brasil. **Cadernos de Prospecção**, 16, n. 2, p. 484-502, 2023.

LI, H.; WANG, S.; ZHONG, F.; BAO, W. *et al.* Age-Dependent Risks of Incidence and Mortality of COVID-19 in Hubei Province and Other Parts of China. **Front Med (Lausanne)**, 7, p. 190, 2020.

LI, Q.; GUAN, X.; WU, P.; WANG, X. *et al.* Early Transmission Dynamics in Wuhan, China, of Novel Coronavirus-Infected Pneumonia. **N Engl J Med**, 382, n. 13, p. 1199-1207, Mar 26 2020.

LIMA-COSTA, M. F.; MACINKO, J.; MAMBRINI, J. V. M. COVID-19 vaccine hesitancy in a national sample of older Brazilians: the ELSI-COVID Initiative, March 2021. **Epidemiol Serv Saude**, 31, n. 1, p. e2021469, 2022.

LIMA, E.; FARIA, S. M.; KFOURI, R. A. Reflections on the use of COVID-19 vaccines in children and adolescents. **Epidemiol Serv Saude**, 30, n. 4, p. e2021957, Dec 15 2021.

LIMA, V. M. A.; CALDARELLI, C. E.; CAMARA, M. R. G. Análise do desenvolvimento municipal paranaense: uma abordagem espacial para a década de 2000. **Economia e Desenvolvimento**, 26, n. 1, 2014.

LOBO, B. J. M. **Análise espacial do desenvolvimento humano educacional dos municípios do estado do ceará nos anos 2000 e 2010.** 2017. 49 f. Dissertação (Mestrado em Economia) - Programa de pós-graduação em Economia – CAEN, Universidade Federal do Ceará, Fortaleza, 2017.

LU, R. **Vacinação de público de áreas vulneráveis em debate na Saúde.** 2021. Disponível em: <https://www.agenciabrasilia.df.gov.br/2021/07/02/vacinacao-de-publico-de-areas-vulneraveis-em-debate-na-saude/>.

MAFRA, T. K. A.; STOBBE, J. C.; RABELLO, R. d. S.; LINDEMANN, I. L. *et al.* A Síndrome Respiratória Aguda Grave na pessoa idosa no contexto da pandemia da covid-19 e seus fatores associados. **Revista Brasileira de Geriatria e Gerontologia**, 26, 2023.

MAIA, F. d. O. M. **Vulnerabilidade e envelhecimento: panorama dos idosos residentes no**

**município de São Paulo.** 2011. 193 f. Tese (Doutorado em Ciências) - Escola de Enfermagem, Universidade de São Paulo, São Paulo, 2011.

MAIA, P. C. G. G. S.; CAVALCANTI, M. P. E.; FIGUEIRA, F. A. M. S.; PEREIRA, G. A. V. *et al.* Space-temporal analysis of the incidence, mortality and case fatality of COVID-19 in the State of Rio Grande do Norte, in the period from 2020 to 2022, in the Northeast of Brazil. **Journal of Human Growth and Development**, 34, n. 1, p. 119-131, 2024.

MALINVERNI, C.; BRIGAGÃO, J. I. M.; CARDOSO, J.; VILLELA, E. F. M. *et al.* **Desinformação e covid-19: desafios contemporâneos na comunicação e saúde.** São Paulo: Instituto de Saúde, 2023. 318 p.

MARTIN, P. d. S.; GONÇALVES, S. L.; GOULARTE, P. d. S.; DIAS, E. P. *et al.* História e Epidemiologia da COVID-19. **ULAKES Journal of Medicine**, 1, p. 11-22, 2020.

MARTINS-FILHO, P. R.; QUINTANS-JUNIOR, L. J.; DE SOUZA ARAUJO, A. A.; SPOSATO, K. B. *et al.* Socio-economic inequalities and COVID-19 incidence and mortality in Brazilian children: a nationwide register-based study. **Public Health**, 190, p. 4-6, Jan 2021.

MARTINS, F. **Mato Grosso se mantém como maior produtor de grãos do país em 2024.** 2024. Disponível em: <https://www.secom.mt.gov.br/w/mato-grosso-se-mantem-como-maior-produtor-de-graos-do-pais-em-2024#:~:text=Mato%20Grosso%20se%20mantem%20como,mt.gov.br%20-%20Site>. Acesso em: 01 jun 2024.

MASCARELLO, K. C.; VIEIRA, A.; SOUZA, A. S. S.; MARCARINI, W. D. *et al.* COVID-19 hospitalization and death and relationship with social determinants of health and morbidities in Espírito Santo State, Brazil: a cross-sectional study. **Epidemiol Serv Saude**, 30, n. 3, p. e2020919, 2021.

MEFSIN, Y. M.; CHEN, D.; BOND, H. S.; LIN, Y. *et al.* Epidemiology of Infections with SARS-CoV-2 Omicron BA.2 Variant, Hong Kong, January-March 2022. **Emerg Infect Dis**, 28, n. 9, p. 1856-1858, Sep 2022.

MEHRA, A.; RANI, S.; SAHOO, S.; PARVEEN, S. *et al.* A crisis for elderly with mental disorders: Relapse of symptoms due to heightened anxiety due to COVID-19. **Asian J Psychiatr**, 51, p. 102114, Jun 2020.

MELISSA WILM; DANIEL SANTOS; BETO VERÍSSIMO; MARCELO MOSANER *et al.* Índice de Progresso Social Brasil 2024: Qualidade de vida nos 5.570 municípios do Brasil. **Resumo Executivo**, p. 1-50, 2024.

MENDONÇA, M. H. M.; LATGÉ, P. K.; SILVA JUNIOR, A. G.; CUNHA, C. L. F. A pandemia COVID-19 no Brasil: ecos e reflexos nas comunidades periféricas. **Aps Em Revista**, 2, n. 2, p. 162-168, 2020.

MOGHADAS, S. M.; VILCHES, T. N.; ZHANG, K.; WELLS, C. R. *et al.* The impact of vaccination on COVID-19 outbreaks in the United States. **medRxiv**, Jan 2 2021.

MOHR, F. X. **Prais: Prais-Winsten Estimator for AR(1) Serial Correlation.** Versão R

package version 1.1.2. 2021.

MORAN, P. A. P. The Interpretation of Statistical Maps. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, 10, n. 2, p. 243-251, 1948.

MOURA, E. C.; CORTEZ-ESCALANTE, J.; CAVALCANTE, F. V.; BARRETO, I. *et al.* Covid-19: temporal evolution and immunization in the three epidemiological waves, Brazil, 2020-2022. **Rev Saúde Pública**, 56, p. 105, 2022.

NAING, N. N. Easy way to learn standardization: direct and indirect methods. **Malays J Med Sci**, 7, n. 1, p. 10-15, 2000.

NICOLETI TURAZZA DA SILVA, W.; PRADO ROSA, M. F.; SARAMAGO MENDONÇA, K.; DE ASSIS QUEIROZ, G. *et al.* Síndrome respiratória aguda grave em indígenas no contexto da pandemia da COVID-19 no Brasil: uma análise sob a perspectiva da vigilância epidemiológica. **Vigilância Sanitária em Debate: Sociedade, Ciência & Tecnologia**, 9, n. 1, p. 2-11, 2021.

NIKOLICH-ZUGICH, J. The twilight of immunity: emerging concepts in aging of the immune system. **Nat Immunol**, 19, n. 1, p. 10-19, Jan 2018.

NIKOLICH-ZUGICH, J.; KNOX, K. S.; RIOS, C. T.; NATT, B. *et al.* SARS-CoV-2 and COVID-19 in older adults: what we may expect regarding pathogenesis, immune responses, and outcomes. **Geroscience**, 42, n. 2, p. 505-514, Apr 2020.

NUNES, D. S.; MELO, W. F.; BRACARENSE, L. d. S. F. P. Implicações socioeconômicas da rodovia BR-153 e os reflexos no desenvolvimento urbano no Tocantins. **Revista Humanidades e Inovação**, 7, n. 14, p. 1-15, 2020.

NUNES, V. M. A.; MACHADO, F. C. A.; MORAIS, M. M.; COSTA, L. A. *et al.* **COVID-19 e o cuidado de idosos: recomendações para instituições de longa permanência**. Natal, RN: EDUFRN, 2020.

OLIVEIRA, L. N.; SANTOS, A. K. F. S.; CARVALHO, R. M. C.; COSME, F. H. d. S. *et al.* Evaluation of the efficacy and safety of the main vaccines used against COVID-19 in Brazil. **Braz J Dev**, 8, n. 4, p. 31753-31767, 2022.

OPAS. **Organização Pan-Americana da Saúde. Indicadores de saúde: elementos conceituais e práticos**. Washington, D.C: OPAS, 2018. 978-92-75-72005-9

OPAS. **Organização Pan-Americana da Saúde. Organização Mundial da Saúde. Perspectivas demográficas do envelhecimento populacional na Região das Américas**. Washington, DC, 2023. Disponível em: <https://doi.org/10.37774/9789275726792>.

ORELLANA, J. D. Y.; CUNHA, G. M. D.; MARRERO, L.; LEITE, I. D. C. *et al.* Changes in the pattern of COVID-19 hospitalizations and deaths after substantial vaccination of the elderly in Manaus, Amazonas State, Brazil. **Cad Saude Publica**, 38, n. 5, p. PT192321, 2022.

PALMEIRA, N. C.; MORO, J. P.; GETULINO, F. A.; VIEIRA, Y. P. *et al.* Analysis of access to health services in Brazil according to sociodemographic profile: National Health Survey,

2019. **Epidemiol Serv Saude**, 31, n. 3, p. e2022966, Dec 19 2022.

PEREIRA, N. D.; CASTRO, M. D.; FIGUEIRA, H. M.; NOVAS, K. R. Saúde da população negra frente à covid-19: desafios e vulnerabilidades. **Revista Transformar**, 14, n. 2, p. 145-162, 2020.

PIRES, R. R. C. Diretoria de Estudos e Políticas do Estado, das Instituições e da Democracia. Os Efeitos sobre grupos sociais e territórios vulnerabilizados das medidas de enfrentamento à crise sanitária da Covid-19: propostas para o aperfeiçoamento da ação pública. Brasília: Instituto de Pesquisa Econômica Aplicada. 33: 18 p. 2020.

PNUD. **Programa das Nações Unidas para o Desenvolvimento. O que é o IDH.** 2024. Disponível em: <https://www.undp.org/pt/brazil/o-que-e-o-idh>. Acesso em: 03 jun 2024.

POLACK, F. P.; THOMAS, S. J.; KITCHIN, N.; ABSALON, J. *et al.* Safety and Efficacy of the BNT162b2 mRNA Covid-19 Vaccine. **N Engl J Med**, 383, n. 27, p. 2603-2615, 2020.

PORTELLA, S. I. d.; JOSÉ MANUEL, M.; PEDRO, S.; MALÚ, G. *et al.* Metodologias para Índices de Vulnerabilidades Socioambientais, Dinâmicas de contágio da COVID 19 e Índice Brasileiro de Privação em Saúde. **Ciência & Trópico**, 45, n. 2, 2021.

PRAIS, G. J.; WINSTEN, C. B. Trend Estimates and Serial Correlation. *In: Cowles Commission Discussion Paper*, 1954, Chicago. University of Chicago.

PRATHER, K. A.; WANG, C. C.; SCHOOLEY, R. T. Reducing transmission of SARS-CoV-2. **Science**, 368, n. 6498, p. 1422-1424, 2020.

RAHMANI, K.; SHAVALEH, R.; FOROUHI, M.; DISFANI, H. F. *et al.* The effectiveness of COVID-19 vaccines in reducing the incidence, hospitalization, and mortality from COVID-19: A systematic review and meta-analysis. **Frontiers in Public Health**, 10, 2022.

REYNOLDS, L.; DEWEY, C.; ASFOUR, G.; LITTLE, M. Vaccine efficacy against SARS-CoV-2 for Pfizer BioNTech, Moderna, and AstraZeneca vaccines: a systematic review. **Front Public Health**, 11, p. 1229716, 2023.

RICHMOND, C.; BIG-CANOE, K.; ABRAM, H.; MANDAWAWE, E. *et al.* The Health Impacts of Social Distancing Among Indigenous People in Ontario During the First Wave of COVID-19. **International Journal of Indigenous Health**, 17, n. 1, 2022.

RILEY, J. C. Estimates of regional and global life expectancy, 1800-2001. **Population and Development Review**, 31, n. 3, p. 537-543, 2005.

RODRÍGUEZ ESPARZA, L. J.; ORTIZ LAZCANO, D. A.; MACÍAS PONCE, J. C.; MAZA DÍAZ CORTÉS, O. M. Bilateral Gini Index. **RBEST: Revista Brasileira de Economia Social e do Trabalho**, 2, 2020.

ROMANOWSKI, F. N. A.; CASTRO, M. B.; NERIS, N. W. Manual de tipos de estudo. Anápolis: Centro Universitário de Anápolis: 39 p. 2019.

ROMERO, D.; MAIA, L. **A epidemiologia do envelhecimento: novos paradigmas?** Rio de

Janeiro: Fundação Oswaldo Cruz, 2022.

ROMERO, D.; MARQUES, A.; MUZY, J. **Informação e indicadores: conceitos, fontes e aplicações para a saúde do idoso e envelhecimento**. Rio de Janeiro: Edições Livres, 2021. 978-65-87663-08-1.

ROMERO, D. E.; MUZY, J.; DAMACENA, G. N.; SOUZA, N. A. *et al.* Older adults in the context of the COVID-19 pandemic in Brazil: effects on health, income and work. **Cad Saude Publica**, 37, n. 3, p. e00216620, 2021.

ROTHAN, H. A.; BYRAREDDY, S. N. The epidemiology and pathogenesis of coronavirus disease (COVID-19) outbreak. **Journal of Autoimmunity**, 109, 2020.

SADOFF, J.; GRAY, G.; VANDEBOSCH, A.; CARDENAS, V. *et al.* Safety and Efficacy of Single-Dose Ad26.COV2.S Vaccine against Covid-19. **N Engl J Med**, 384, n. 23, p. 2187-2201, 2021.

SALES-MOIOLI, A. I. L.; GALVAO-LIMA, L. J.; PINTO, T. K. B.; CARDOSO, P. H. *et al.* Effectiveness of COVID-19 Vaccination on Reduction of Hospitalizations and Deaths in Elderly Patients in Rio Grande do Norte, Brazil. **Int J Environ Res Public Health**, 19, n. 21, Oct 26 2022.

SANTAGADA, S. Indicadores sociais: uma primeira abordagem social e histórica. **Pensamento Plural**, 1, p. 113-142, 2007.

SANTIAGO, F. S.; PEROBELLI, F. S.; OLIVEIRA, E. C. P. d.; SALGUEIRO, G. P. OS IMPACTOS ECONÔMICOS DO ENVELHECIMENTO POPULACIONAL NA ARGENTINA, BRASIL E MÉXICO. **BRSA**, 2017.

SATHLER, D.; LEIVA, G. Prioridade para futuras vacinações contra a Covid-19 no Brasil: os usuários de transporte público devem ser um grupo-alvo? **Rev Bras Estud Popul**, 38, p. 1-12, 2021.

SCHNEIDER, R. A.; PASSOS, L.; PEREIRA, W. M. Uma nota sobre o risco de contágio, perfil dos trabalhadores e a pandemia de COVID-19 no Brasil. **Revista Brasileira de Economia**, 76, n. 3, 2022.

SCHOBER, P.; BOER, C.; SCHWARTE, L. A. Correlation Coefficients: Appropriate Use and Interpretation. **Anesth Analg**, 126, n. 5, p. 1763-1768, May 2018.

SCHUMANN, L. R.; MOURA, L. B. Vulnerability synthetic indices: a literature integrative review. **Cien Saude Colet**, 20, n. 7, p. 2105-2120, Jul 2015.

SECOM-MT. **A ação visa coibir eventos em meio ao carnaval cancelado por conta da pandemia**. 2021a. Disponível em: <https://www.pm.mt.gov.br/-/16515525-pm-dispersa-2-1-mil-pessoas-e-fecha-60-festas-clandestinas-em-mt>. Acesso em: 10 ago 2024.

SECOM-MT. **Mato Grosso inicia vacinação contra a Covid-19 e imuniza 10 trabalhadores da Saúde**. 2021b. Disponível em: <https://www.indea.mt.gov.br/web/mt/w/16297239-mato-grosso-inicia-vacinacao-contra-a-covid-19-e-imuniza-10-trabalhadores-da-saude>. Acesso em:

18 jun 2024.

SEDGWICK, P. Spearman's rank correlation coefficient. **BMJ**, 349, 2014.

SHEIKH, A.; MCMENAMIN, J.; TAYLOR, B.; ROBERTSON, C. *et al.* SARS-CoV-2 Delta VOC in Scotland: demographics, risk of hospital admission, and vaccine effectiveness. **Lancet**, 397, n. 10293, p. 2461-2462, 2021.

SIDDELL, S. G.; WALKER, P. J.; LEFKOWITZ, E. J.; MUSHEGIAN, A. R. *et al.* Additional changes to taxonomy ratified in a special vote by the International Committee on Taxonomy of Viruses (October 2018). **Arch Virol**, 164, n. 3, p. 943-946, Mar 2019.

SILVA, A. d. S.; FASSARELLA, B. P. A.; FARIA, B. d. S.; NABBOUT, T. G. M. E. *et al.* Envelhecimento populacional: realidade atual e desafios. **Global Academic Nursing Journal**, 2022.

SILVA, D. F.; OLIVEIRA, M. L. C. Epidemiologia da COVID-19: comparação entre boletins epidemiológicos. **Comunicação em Ciências da Saúde**, 31, n. Suppl1, p. 61-74, 05/08 2020.

SILVA, G. A. E.; JARDIM, B. C.; SANTOS, C. Excess mortality in Brazil in times of Covid-19. **Ciênc Saúde Coletiva**, 25, n. 9, p. 3345-3354, 2020.

SILVA, J. C. **Trabalho precarizado: trajetórias, crises e vínculos dos entregadores de aplicativos**. 2021. Dissertação (Mestrado em Administração) - Faculdade de Economia, Administração e Contabilidade, Universidade de São Paulo, São Paulo.

SILVA, L.; LIMA, A. F. R.; POLLI, D. A.; RAZIA, P. F. S. *et al.* Social distancing measures in the fight against COVID-19 in Brazil: description and epidemiological analysis by state. **Cad Saude Publica**, 36, n. 9, p. e00185020, 2020.

SILVA, R. d. C. P. d. **Resistência em tempos de crise: o sistema de saúde no semiárido potiguar durante a pandemia da Covid-19**. 2023. 98 f. (Bacharelado em Serviço Social) - Centro Ciências Sociais Aplicadas, Universidade Federal do Rio Grande do Norte, Natal/RN.

SILVA, V. R. D.; PACHECO, E. S.; CARDOSO, O. O.; LIMA, L. H. O. *et al.* Temporal trend of COVID-19 incidence and mortality rates and their relationship with socioeconomic indicators in the state of Piauí, Brazil: an ecological study, 2020-2021. **Epidemiol Serv Saude**, 31, n. 2, p. e20211150, 2022.

SILVA, W. N. T.; ROSA, M. F. P.; MENDONÇA, K. S.; QUEIROZ, G. A. *et al.* Síndrome respiratória aguda grave em indígenas no contexto da pandemia da COVID-19 no Brasil: uma análise sob a perspectiva da vigilância epidemiológica. **Vigilância Sanitária em Debate: Sociedade, Ciência & Tecnologia**, 9, n. 1, p. 2-11, 2021.

SIM, B. L. H.; CHIDAMBARAM, S. K.; WONG, X. C.; PATHMANATHAN, M. D. *et al.* Clinical characteristics and risk factors for severe COVID-19 infections in Malaysia: A nationwide observational study. **Lancet Reg Health West Pac**, 4, p. 100055, Nov 2020.

SIMÃO FILHO, P. M. **Iniquidades no acesso à justiça e determinantes sociais da saúde: estratégias para garantir o direito à saúde**. 2020. 63f f. (Mestrado em Saúde Pública) - Escola

Nacional de Saúde Pública Sergio Arouca, Fundação Oswaldo Cruz, Rio de Janeiro.

SOARES, K. H. D.; OLIVEIRA, L. d. S.; DA SILVA, R. K. F.; SILVA, D. C. d. A. *et al.* Medidas de prevenção e controle da covid-19: revisão integrativa. **Revista Eletrônica Acervo Saúde**, 13, n. 2, 2021.

SODRÉ, F. Epidemia de Covid-19: questões críticas para a gestão da saúde pública no Brasil. **Trabalho, Educação e Saúde**, 18, n. 3, 2020.

SPOSATI, A. D. O. COVID-19 revela a desigualdade de condições da vida dos brasileiros. **NAU Social**, 11, n. 20, p. 101, 2020.

STERN, S.; HARMACEK, J.; KRYLOVA, P.; HTITICH, M. **The 2024 Social Progress Index results**. Washington, DC, 2024. Disponível em: <https://www.socialprogress.org>. Acesso em: 20 jul 2024.

TAKAHASHI, T.; ELLINGSON, M. K.; WONG, P.; ISRAELOW, B. *et al.* Sex differences in immune responses that underlie COVID-19 disease outcomes. **Nature**, 588, n. 7837, p. 315-320, Dec 2020.

TANRIOVER, M. D.; DOGANAY, H. L.; AKOVA, M.; GUNER, H. R. *et al.* Efficacy and safety of an inactivated whole-virion SARS-CoV-2 vaccine (CoronaVac): interim results of a double-blind, randomised, placebo-controlled, phase 3 trial in Turkey. **Lancet**, 398, n. 10296, p. 213-222, 2021.

TARTOF, S. Y.; SLEZAK, J. M.; FISCHER, H.; HONG, V. *et al.* Effectiveness of mRNA BNT162b2 COVID-19 vaccine up to 6 months in a large integrated health system in the USA: a retrospective cohort study. **Lancet**, 398, n. 10309, p. 1407-1416, 2021.

TEIXEIRA, K. H. Uma análise espacial da pobreza no Estado de Alagoas. **Redes**, 25, p. 2668-2692, 2020.

TIRUNEH, S. A.; TESEMA, Z. T.; AZANAW, M. M.; ANGAW, D. A. The effect of age on the incidence of COVID-19 complications: a systematic review and meta-analysis. **Syst Rev**, 10, n. 1, p. 80, Mar 20 2021.

TYRRELL, D. A.; BYNOE, M. L. Cultivation of a Novel Type of Common-Cold Virus in Organ Cultures. **Br Med J**, 1, n. 5448, p. 1467-1470, Jun 5 1965.

VALENZUELA, E. V.; MORAIS, T. C.; DABOIN, B. G.; CAVALCANTI, M. P. E. *et al.* Evolution of mortality and lethality due to covid-19 in the state of Roraima, Brazil, from march 2020 to july 2021. **Journal of Human Growth and Development**, 31, n. 3, p. 447-457, 2021.

VALTORTA, N. K.; KANAAN, M.; GILBODY, S.; HANRATTY, B. Loneliness, social isolation and risk of cardiovascular disease in the English Longitudinal Study of Ageing. **Eur J Prev Cardiol**, 25, n. 13, p. 1387-1396, Sep 2018.

VENTURA, D. F. L.; REIS, R. A linha do tempo da estratégia federal de disseminação da Covid-19. . *In: Direitos na pandemia: mapeamento e análise das normas jurídicas de resposta à Covid-19 no Brasil*. 10 ed. São Paulo: Conectas, 2021. p. 6–31.

VIACAVA, F.; OLIVEIRA, R. A. D.; CARVALHO, C. C.; LAGUARDIA, J. *et al.* SUS: supply, access to and use of health services over the last 30 years. **Cien Saude Colet**, 23, n. 6, p. 1751-1762, Jun 2018.

VIANNA, L. A. C. **Determinantes Sociais de Saúde: processo saúde doença**. 2012.

VICTORA, P. C.; CASTRO, P. M. C.; GURZENDA, S.; MEDEIROS, A. C. *et al.* Estimating the early impact of vaccination against COVID-19 on deaths among elderly people in Brazil: Analyses of routinely-collected data on vaccine coverage and mortality. **EClinicalMedicine**, 38, p. 101036, Aug 2021.

VOYSEY, M.; CLEMENS, S. A. C.; MADHI, S. A.; WECKX, L. Y. *et al.* Safety and efficacy of the ChAdOx1 nCoV-19 vaccine (AZD1222) against SARS-CoV-2: an interim analysis of four randomised controlled trials in Brazil, South Africa, and the UK. **Lancet**, 397, n. 10269, p. 99-111, 2021.

WANG, D.; HU, B.; HU, C.; ZHU, F. *et al.* Clinical Characteristics of 138 Hospitalized Patients With 2019 Novel Coronavirus-Infected Pneumonia in Wuhan, China. **J Am Med Assoc**, 323, n. 11, p. 1061-1069, 2020.

WHO. Commission on Social Determinants of Health. **Closing the Gap in a Generation: Health Equity Through Action on the Social Determinants of Health: Commission on Social Determinants of Health Final Report**. WHO, Geneva, Switzerland, 2008.

WHO. World Health Organization. **Summary of probable SARS cases with onset of illness from 1 November 2002 to 31 July 2003**. Geneva, Switzerland, 2015. Disponível em: <https://www.who.int/publications/m/item/summary-of-probable-sars-cases-with-onset-of-illness-from-1-november-2002-to-31-july-2003>. Acesso em: 31 mai 2024.

WHO. **Director-General's opening remarks at the media briefing on COVID-19**. 2020a. Disponível em: <https://www.who.int/director-general/speeches/detail/who-director-general-s-opening-remarks-at-the-media-briefing-on-covid-19---11-march-2020>. Acesso em: 13 jun 2024.

WHO. World Health Organization. **World Health Report. Mask use in the context of COVID-19: Interim guidance**. Geneva, Switzerland, 2020b. Disponível em: [https://www.who.int/publications/i/item/advice-on-the-use-of-masks-in-the-community-during-home-care-and-in-healthcare-settings-in-the-context-of-the-novel-coronavirus-\(2019-ncov\)-outbreak](https://www.who.int/publications/i/item/advice-on-the-use-of-masks-in-the-community-during-home-care-and-in-healthcare-settings-in-the-context-of-the-novel-coronavirus-(2019-ncov)-outbreak). Acesso em: 31 mar. 2023.

WHO. World Health Organization. **Middle East respiratory syndrome coronavirus (MERS-CoV)**. Geneva, Switzerland, 2022. Disponível em: [https://www.who.int/news-room/fact-sheets/detail/middle-east-respiratory-syndrome-coronavirus-\(mers-cov\)](https://www.who.int/news-room/fact-sheets/detail/middle-east-respiratory-syndrome-coronavirus-(mers-cov)). Acesso em: 31 mai 2024.

WHO. World Health Organization. **COVID-19 vaccination, World data**. Geneva, Switzerland, 2024. Disponível em: <https://data.who.int/dashboards/covid19/>. Acesso em: 03 jun 2024.

WICKHAM, H. **Ggplot2: Elegant Graphics for Data Analysis**. Springer-Verlag New York, 2016.

WICKHAM, H.; AVERICK, M.; BRYAN, J.; CHANG, W. *et al.* Welcome to the tidyverse. **Journal of Open Source Software**, 4, n. 43, 2019.

WILKE, H. C. B. B. **Política e PNUD: resiliência, desenvolvimento humano e vulnerabilidades**. 2017. 317 f. Dissertação (Mestrado em Ciências Sociais) - Programa de Estudos Pós-Graduados em Ciências Sociais, Pontifícia Universidade Católica de São Paulo, São Paulo.

WINTER, J. C. F.; GOSLING, S. D.; POTTER, J. Comparing the Pearson and Spearman correlation coefficients across distributions and sample sizes: A tutorial using simulations and empirical data. **Psychological Methods**, 21, n. 3, p. 273-290, 2016.

YANG, X.; YU, Y.; XU, J.; SHU, H. *et al.* Clinical course and outcomes of critically ill patients with SARS-CoV-2 pneumonia in Wuhan, China: a single-centered, retrospective, observational study. **The Lancet Respiratory Medicine**, 8, n. 5, p. 475-481, 2020.

ZHANG, Q.; BASTARD, P.; EFFORT, C. H. G.; COBAT, A. *et al.* Human genetic and immunological determinants of critical COVID-19 pneumonia. **Nature**, 603, p. 587-598, 2022.

ZHONG, N. S.; ZHENG, B. J.; LI, Y. M.; POON *et al.* Epidemiology and cause of severe acute respiratory syndrome (SARS) in Guangdong, People's Republic of China, in February, 2003. **Lancet**, 362, n. 9393, p. 1353-1358, Oct 25 2003.

ZIJDEMAN, R.; RIBEIRA DA SILVA, F. Life Expectancy at Birth. IISH Data Collection 2015.

## 8. ARTIGO

### **Influência dos determinantes sociais da saúde na morbimortalidade e adesão à vacinação contra a COVID-19, no Mato Grosso, 2020 a 2023**

Influence of social determinants of health on morbidity and mortality and adherence to vaccination against COVID-19, in Mato Grosso, 2020 to 2023

Influencia de los determinantes sociales de la salud en la morbilidad, la mortalidad y la adherencia a la vacunación contra COVID-19, en Mato Grosso, 2020 a 2023

**Resumo** Analisou-se a influência dos determinantes sociais da saúde na adesão à vacinação e na morbimortalidade por COVID-19, entre 2020 a 2023, no estado de Mato Grosso. Estudo ecológico com abordagem geoespacial, utilizando dados de casos e óbitos de COVID-19 do Sistema de Informação de Vigilância da Gripe e dados de vacinação do Sistema de Informação do Programa Nacional de Imunizações. As taxas populacionais foram obtidas do Instituto Brasileiro de Geografia e Estatística (IBGE). Foram realizadas análises descritivas espaciais e estatísticas de Índice de Moran Global e Local bivariado. Os resultados evidenciaram que as menores taxas de incidência, maior Índice de Progresso Social e melhor cobertura vacinal concentraram-se nas regiões Sul, Centro-Sul e Sudeste do estado. Em contrapartida, as regiões Norte e Nordeste apresentaram menor Índice de Progresso Social, associando-se a maiores taxas de incidência e menor cobertura vacinal. Regiões com melhor infraestrutura social e econômica mostraram menores taxas de morbimortalidade e maior cobertura vacinal, destacando a influência dos determinantes sociais na saúde pública.

**Palavras-chave** COVID-19, Indicadores de Morbimortalidade, Cobertura Vacinal

**Abstract** The influence of social determinants of health on vaccination adherence and COVID-19 morbidity and mortality in the state of Mato Grosso was analyzed, between 2020 and 2023. This ecological study employed a geospatial approach, utilizing COVID-19 case and death data from the Influenza Surveillance Information System and vaccination data from the National Immunization Program Information System. Population rates were obtained from the Brazilian Institute of Geography and Statistics (IBGE). Descriptive spatial analyses and statistical assessments, including the Global and Local Bivariate Moran's Index, were conducted. The results showed that lower incidence rates, a higher Social Progress Index, and better vaccination coverage were concentrated in the South, Central-South, and Southeast regions of the state. In contrast, the North and Northeast regions exhibited a lower Social Progress Index, higher incidence rates, and lower vaccination coverage. Areas with better social and economic infrastructure had lower morbidity and mortality rates and higher vaccination coverage, highlighting the influence of social determinants on public health.

**Keywords** COVID-19, Morbidity and Mortality Indicators, Vaccination Coverage

**Resumen** Se analizó la influencia de los determinantes sociales de la salud en la adhesión a la vacunación y en la morbilidad y mortalidad por COVID-19 entre 2020 y 2023 en el estado de Mato Grosso. Se trata de un estudio ecológico con un enfoque geoespacial, utilizando datos de

casos y muertes por COVID-19 del Sistema de Información de Vigilancia de la Gripe y datos de vacunación del Sistema de Información del Programa Nacional de Inmunizaciones. Las tasas poblacionales se obtuvieron del Instituto Brasileño de Geografía y Estadística (IBGE). Se realizaron análisis espaciales descriptivos y evaluaciones estadísticas, incluyendo el Índice de Moran Global y Local bivariado. Los resultados evidenciaron que las menores tasas de incidencia, un mayor Índice de Progreso Social y una mejor cobertura de vacunación se concentraron en las regiones Sur, Centro-Sur y Sudeste del estado. En contraste, las regiones Norte y Noreste presentaron un menor Índice de Progreso Social, asociado con mayores tasas de incidencia y menor cobertura de vacunación. Las regiones con mejor infraestructura social y económica mostraron menores tasas de morbilidad y mortalidad y una mayor cobertura de vacunación, resaltando la influencia de los determinantes sociales en la salud pública.

**Palabras clave** COVID-19, Indicadores de Morbilidad y Mortalidad, Coberturas de Vacunación

## Introdução

O Brasil é considerado um dos países mais afetados pela pandemia, apresentando uma alta taxa de morbidade e mortalidade em comparação com outros países do mundo<sup>1</sup>. Isto devido a ações e políticas desiguais e descoordenadas entre os diferentes estados e municípios, levando a uma resposta complexa e desafiadora à pandemia no Brasil, o que pode ter contribuído para o aumento da disseminação do vírus e o agravamento da crise sanitária<sup>2-4</sup>.

A disseminação da doença no Brasil atingiu de forma particularmente grave as populações vulneráveis, especialmente as que vivem em áreas rurais, remotas e com pouco acesso aos serviços de saúde, sendo que a maior parte das mortes ocorreu entre indivíduos com 60 anos ou mais, e/ou que apresentassem comorbidades como cardiopatias, diabetes, pneumopatias e doenças neurológicas<sup>5-7</sup>. O estado de Mato Grosso, por exemplo, é uma região marcada por desigualdades socioeconômicas e geográficas, onde as áreas que possuem os serviços de saúde necessários são, principalmente, as regiões urbanas já consolidadas ou em crescimento acelerado e consolidação, relacionadas principalmente aos centros do agronegócio<sup>8</sup>.

Nesse ínterim, sabe-se que as desigualdades sociais e econômicas presentes na sociedade brasileira foram um dos principais agravantes da pandemia da COVID-19 no país<sup>1,9</sup>. Estudos realizados no Brasil, indicam que as regiões com menor índice de desenvolvimento humano foram as mais afetadas pela pandemia, com maiores taxas de mortalidade em comparação com as regiões mais desenvolvidas<sup>1,8,9</sup>.

Entre os grupos mais afetados pela pandemia no Brasil estão as pessoas de baixa renda, idosos, moradores de rua, comunidades indígenas e quilombolas, assentados, entre outros. Esses grupos enfrentam desafios adicionais, incluindo barreiras de acesso aos serviços de saúde,

maiores taxas de morbimortalidade, condições insalubres de moradias e maior exposição ao vírus devido a condições socioeconômicas precárias<sup>6,10,11</sup>. Dados mostram que durante o ano de 2022, o país possuía cerca de 281 mil moradores de rua, aproximadamente 1.693.535 indígenas (correspondendo a 0,83% da população brasileira) e 22.169.101 idosos (10,9% da população brasileira) vulneráveis frente a uma pandemia<sup>1,12-14</sup>.

Essas desigualdades sociais afetam diretamente a saúde devido as diferentes probabilidades de exposição aos fatores que influenciam a saúde e a doença em indivíduos, além de ocasionar diferenças mensuráveis e perceptíveis nas condições de saúde da população. Essas disparidades estão diretamente ligadas às diferenças no acesso aos serviços de promoção, prevenção e tratamento, provocando variações nas taxas de adoecimento e mortalidade da população<sup>15</sup>. A desigualdade é ainda mais evidente em áreas vulneráveis, onde há escassez de ambientes propícios para a promoção da saúde dessa população<sup>16</sup>.

As condições de saúde de uma população são fortemente influenciadas pelo contexto social e ambiental em que vivem. Fatores como pobreza, habitações inadequadas, ambiente urbano precário e condições de trabalho insalubres impactam negativamente a saúde das pessoas. Geralmente, doenças e problemas de saúde são mais frequentes entre grupos sociais desfavorecidos, incluindo os mais pobres, minorias étnicas e grupos discriminados. Isso demonstra o porquê países pobres apresentam condições de saúde inferiores em comparação com países ricos. Da mesma forma, dentro de qualquer país, seja ele rico ou pobre, as regiões menos prósperas ou as populações que compõem grupos étnicos marginalizados tendem a ter piores condições de saúde<sup>15</sup>.

Evidências mostram que políticas que melhoram as condições econômicas ou fortalecem a proteção social têm efeitos positivos na saúde das populações. Além disso, intervenções que visam melhorar o ambiente de trabalho, combater a discriminação e promover a inclusão social, demonstraram sucesso na melhoria da saúde pública e também são importantes para a redução das desigualdades em saúde<sup>11,15</sup>.

No cenário internacional, a criação da Comissão de Determinantes Sociais da Saúde (CNDSS) da Organização Mundial da Saúde (OMS) em 2005, destacou a importância da implementação de políticas públicas para redução das desigualdades sociais, promovendo a missão de organizar as evidências sobre as ações necessárias para promover a equidade em saúde globalmente<sup>15</sup>. A partir da comissão, em 2008, foi determinado três princípios de ação para que os governos de todos os países aplicassem para reduzir as desigualdades sociais, sendo eles: melhorar o cenário cotidiano das pessoas, tratar fatores que levem a distribuição desigual de poder, dinheiro e recursos, e analisar o problema e possíveis ações a serem tomadas<sup>17</sup>.

Para a CNDSS, os determinantes sociais da saúde (DSS) referem-se aos fatores socioeconômicos, culturais, étnicos/raciais, psicológicos, comportamentais e ambientais de uma sociedade que influenciam as condições de vida e trabalho de seus integrantes. Entre os exemplos de determinantes sociais estão a qualidade da habitação, a disponibilidade de saneamento básico, as condições do ambiente de trabalho, o acesso a serviços de saúde e a educação, além das redes sociais e comunitárias que proporcionam suporte social<sup>18</sup>.

Quando se trata da análise de fatores socioambientais, o Índice de Progresso Social (IPS) é considerado o mais completo na atualidade. O IPS foi desenvolvido por meio de uma colaboração entre diversas organizações e pesquisadores, incluindo o Instituto do Homem e do Meio Ambiente da Amazônia (Imazon), a Fundação Avina, o Centro de Empreendedorismo da Amazônia, a iniciativa Amazônia 2030, a Anattá e o *Social Progress Imperative*. Este índice consiste em uma medida que avalia diferentes dimensões, fornecendo um panorama multidimensional dos municípios<sup>19</sup>.

As dimensões avaliadas pelo IPS são: Necessidades Humanas Básicas, Fundamentos de Bem-Estar e Oportunidades, cada uma composta por componentes específicos avaliados por 53 indicadores. O índice é calculado a partir da média das três dimensões, e seus valores variam de 0 a 100, sendo que 0 indica um baixo desempenho e 100 um alto desempenho<sup>19</sup>.

Em 2024, o Brasil obteve uma pontuação de 68,90 no IPS Global, ficando na 67ª colocação entre 170 países. Ao comparar com outros países da América do Sul, Chile (78,43), Argentina (77,19) e Equador (69,56) apresentam melhores pontuações<sup>19,20</sup>. No Mato Grosso, todos os municípios permaneceram abaixo da média nacional, sendo que o município com o maior valor de IPS foi a capital do estado, Cuiabá, com índice de 68,47, e o município de menor índice foi Nova Nazaré, com IPS de 42,78.

Dessa forma, a falta de acesso a recursos básicos, como água e saneamento adequados, bem como a condições de habitação inadequadas, aumenta a exposição à infecção e agravam os efeitos da doença<sup>3</sup>. Além disso, as condições de trabalho precárias e a dificuldade de acesso a serviços de saúde contribuem para a propagação da doença nessas populações<sup>12,21,22</sup>.

Nesta perspectiva, a dificuldade de acesso a informações precisas e confiáveis, problemas financeiros, moradia e condições de trabalho precárias, podem corroborar para o aumento da chance de populações vulneráveis contrair a COVID-19, devido aos comportamentos que elevam o risco de infecção, como a falta de uso de máscaras, o não cumprimento do distanciamento social, a inadequada higiene pessoal e a não adesão a vacinação<sup>10,21</sup>.

## **Metodologia**

### *Delineamento de estudo*

Trata-se de um estudo ecológico de desenho misto, realizado entre os anos de 2020 e 2023. Este tipo de estudo consiste em uma pesquisa que descreve a distribuição espacial e a evolução ou mudança de uma variável ao longo do tempo.

### *Critérios de inclusão e exclusão*

Foram incluídos no estudo dados de morbimortalidade por COVID-19 ocorrida nos 141 municípios do estado de Mato Grosso, durante o período de 01 de janeiro de 2020 a 31 de dezembro de 2023. Para a vacinação, considerou-se o período de 01 de janeiro de 2021 a 31 de dezembro de 2023. A coleta de dados foi realizada em janeiro de 2024.

Foram excluídos dados que não apresentavam confirmação laboratorial, clínico-epidemiológica, clínico-imagem ou por critério clínico. Dados de outros períodos, de outras localidades e em branco não foram considerados.

### *Coleta de dados*

O banco de dados dos casos incidentes e óbitos pela COVID-19 foi obtido por meio do Departamento de Informática do Sistema Único de Saúde (openDataSUS), que disponibiliza dados do Sistema de Informação de Vigilância da Gripe (SIVEP-Gripe) para notificação dos casos de SRAG e do Sistema e-SUS Notifica, implementado por meio da Secretaria de Vigilância em Saúde e Ambiente (SVSA), para notificação dos casos leves e moderados de COVID-19.

Os registros de vacinação contra a COVID-19 foram obtidos por meio do Sistema de Informação do Programa Nacional de Imunizações (SI-PNI), disponibilizado pelo Departamento de Informática do Sistema Único de Saúde (openDataSUS). O banco de dados bruto apresentava 7.334.746 registros de vacinação, foram excluídos os dados cujo endereço de residência do indivíduo correspondia ao de outro estado e que apresentavam linhas em branco. Assim, foi possível obter um banco de dados com o total de 6.882.055 registros de vacinação, ocasionando em uma redução de 6,17% (452.691) dos registros totais.

Os dados populacionais foram retirados do Instituto Brasileiro de Geografia e Estatística (IBGE), sendo que para os dados à nível estadual foi utilizado como base o Censo Demográfico de 2022. Já a nível municipal, foi utilizado banco de dados referente à projeção populacional por sexo e faixa etária, para os anos de 2020 a 2023. Para a investigação dos determinantes de saúde dos municípios de Mato Grosso, foram coletados dados a partir do Índice de Progresso

Social (IPS) disponibilizado no ano de 2024. Para obtenção dos dados geográficos e confecções dos mapas das análises espaciais, foi utilizado as malhas municipais do estado de Mato Grosso, coletados a partir dos arquivos da Malha Municipal Digital (MMD), fornecido pelo IBGE, no ano de 2022<sup>23</sup>.

## **Análises estatísticas descritivas**

### *Taxas de incidência e mortalidade*

Inicialmente foi realizado o cálculo das taxas específicas de morbimortalidade da COVID-19. Posteriormente, para remover o efeito de confusão da idade pela diferença na estrutura etária entre localidades fez-se a padronização das taxas de incidência e mortalidade pelo método direto. Para as análises espaciais a nível municipal, foi utilizada como população padrão a população por faixa etária de Mato Grosso. Desta forma, prosseguiu para os cálculos da taxa de incidência e mortalidade esperadas. Inicialmente, fez-se a multiplicação das respectivas taxas por faixa etária de cada município pela população por faixa etária da população padrão e dividiu pela constante utilizada em cada indicador para estimar o número absoluto de casos incidentes e óbitos por faixa etária. Posteriormente, fez-se o somatório de todos os casos incidentes e óbitos ajustados por idade e recalculou os indicadores esperados padronizados.

### *Análise da cobertura vacinal*

Para analisar a cobertura vacinal, os registros de vacinação foram estratificados por idade, e assim calculou a proporção da população presente em cada faixa etária que recebeu a vacina, considerando como base o esquema vacinal completo e reforço de cada vacina contra a COVID-19. O esquema vacinal da Sinovac/Butantan consiste em duas doses de 0,5 ml cada, administradas com um intervalo de 4 semanas. A vacina da AstraZeneca/Fiocruz inclui duas doses de 0,5 ml, com um intervalo de 4 a 12 semanas entre as doses. A vacina fornecida pela Pfizer/BioNTech, consiste em duas doses de 0,3 ml cada, administradas com um intervalo de 3 a 12 semanas. Por fim, a vacina Janssen, apresenta uma única dose de 0,5 ml. Conforme as diretrizes do Plano Nacional de Operacionalização da Vacinação contra a COVID-19, considera-se esquema vacinal completo as pessoas que receberam a primeira e segunda dose das vacinas Sinovac, Pfizer ou AstraZeneca, ou a dose única da vacina Janssen<sup>24</sup>.

### *Estatística de I de Moran Global e Local*

Para investigar as relações espaciais entre diferentes variáveis de saúde relacionadas à COVID-19 no Mato Grosso, como incidência, mortalidade, cobertura vacinal e o Índice de Progresso Social (IPS), foi realizado uma análise bivariada utilizando o *I* de Moran Global e Local. Essa abordagem permite detectar padrões de autocorrelação espacial entre duas variáveis, ajudando a entender como essas variáveis estão relacionadas geograficamente. Foram considerados significantes, as variáveis que apresentaram pseudo-valor- $p < 0,05$ , sendo que a significância estatística foi um critério de inclusão para avançar nas análises espaciais.

### **Resultados**

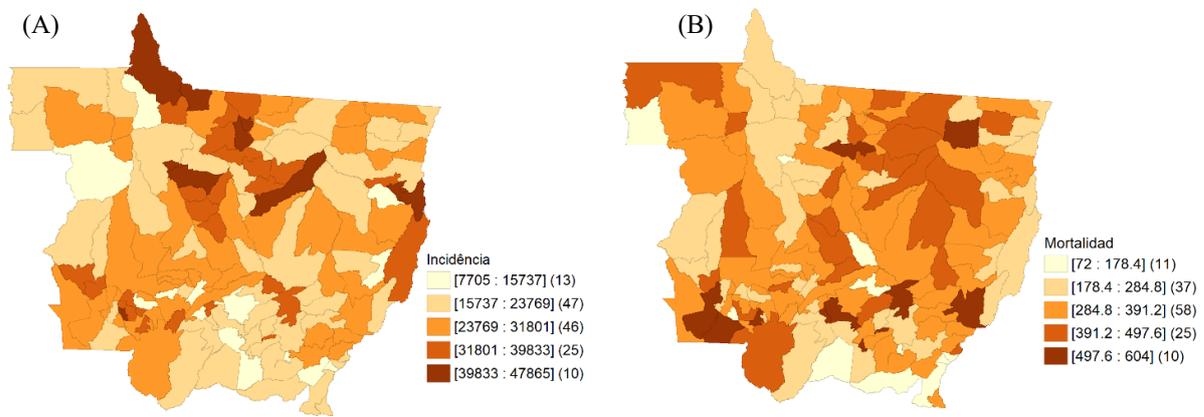
De janeiro de 2020 até dezembro de 2023, o estado de Mato Grosso registrou 890.279 casos e 15.123 óbitos por COVID-19, que foram confirmados por meio de análise laboratorial, clínico-epidemiológica, clínico-imagem ou por critério clínico.

A taxa de incidência de COVID-19 no estado de Mato Grosso demonstrou variações entre os municípios, onde foi possível observar municípios que apresentaram uma taxa mínima de 7.705,1 e máxima de 47.865,3 a cada 100 mil habitantes. A mediana foi estimada em 25.411,3/100.000 habitantes, indicando que metade dos valores permaneceu abaixo desse ponto, enquanto a média foi ligeiramente maior, sugerindo a presença de valores altos que elevam a média. Quando analisado o primeiro quartil (Q1) e terceiro quartil (Q3), foi possível observar que 50% das taxas estavam concentradas entre os valores de 19.935,6 e 31.660,0/100.000 habitantes. O desvio padrão correspondeu a 8.451,0/100.000 habitantes refletindo uma variação considerável na incidência, sendo que deve ser levado em consideração que tais resultados foram obtidos a partir das taxas acumuladas entre os períodos de 2020 a 2023 para a incidência e mortalidade, e entre 2021 a 2023 para a cobertura vacinal. Quando analisado a taxa de mortalidade por COVID-19, percebeu-se que a taxa máxima de mortalidade dos municípios correspondeu a 1,26% da taxa de incidência máxima, com uma média de mortalidade de 327,3/100.000 habitantes.

Dentre os municípios que apresentaram as maiores taxas acumuladas de incidência por 100 mil habitantes (Figura 1A), estavam Paranaíta (47.865), Novo Santo Antônio (46.543), Novo Horizonte do Norte (45.525), Porto dos Gaúchos (43.852), Apiacás (42.990), Indivaí (42.238), Nova Guarita (40.994), Colíder (40.904), Feliz Natal (40.310) e Serra Nova Dourada (39.848), sendo a maioria localizada na mesorregião Norte Mato-Grossense, com exceção de Indivaí que se localiza no Sudoeste Mato-Grossense e Novo Santo Antônio e Serra Nova Dourada no Nordeste Mato-Grossense.

Em relação às taxas de mortalidade acumuladas padronizadas por idade (Figura 1B), observou-se que houve uma distribuição mais heterogênea entre as diferentes regiões do Mato Grosso, onde os municípios que apresentaram as maiores taxas foram: Itaúba (604), Porto Esperidião (539), São Pedro da Cipa (539), Primavera do Leste (536), Pontes e Lacerda (514), São José do Xingu (510), Cuiabá (508), Várzea Grande (507), Mirassol d'Oeste (504) e Barra do Garças (503).

**Figura 1.** Distribuição das taxas de incidência (A) e mortalidade (B) acumuladas padronizadas por idade, por 100 mil habitantes, nos municípios do estado de Mato Grosso, 2020 a 2023.



Fonte: Autores.

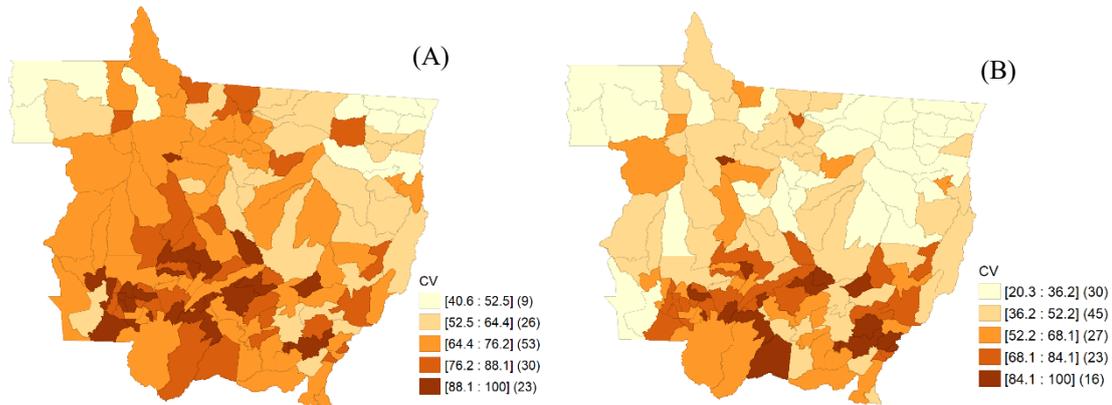
De acordo com a análise da distribuição espacial da cobertura vacinal considerando o esquema completo (Figura 2A), 20 municípios apresentaram cobertura acima de 90%, sendo Acorizal (100%), Nova Brasilândia (100%), Santo Antônio de Leverger (100%), Indaiavá (100%), Glória D'Oeste (100%), Chapada dos Guimarães (98,6%), Nossa Senhora do Livramento (98,0%), Santa Rita do Trivelato (97,7%), Porto Estrela (96,5%), Curvelândia (96,1%), Santo Afonso (95,3%), Porto Esperidião (95,2%), Guiratinga (94,5%), Nortelândia (93,7%), Diamantino (93,5%), Vale de São Domingos (92,2%), Jangada (92,2%), Reserva do Cabaçal (92,1%), São José do Povo (90,9%), Salto do Céu (90,2%).

Dentre os municípios com menores taxas de cobertura vacinal referente ao esquema vacinal completo (Figura 2A), houveram 4 municípios que apresentaram cobertura abaixo de 50%, sendo Santa Terezinha (48,8%), Rondolândia (45,6%), Santa Cruz do Xingu (44,1%) e Confresa (40,6%).

Em relação a cobertura vacinal das doses de reforço (Figura 2B), 7 municípios apresentam 100% de cobertura vacinal, sendo Acorizal, Porto Estrela, Nossa Senhora do Livramento, Guiratinga, Barão de Melgaço, Torixoréu e São José do Povo. Entretanto, 68 municípios apresentaram cobertura vacinal das doses de reforço abaixo de 50%, correspondendo a 51,8%

do total de municípios no estado.

**Figura 2.** Cobertura vacinal contra a COVID-19 de acordo com o esquema vacinal completo (A) e reforço (B), nos municípios do estado de Mato Grosso, 2021 a 2023.



Fonte: Autores.

Para testar a hipótese de padrões de distribuição espacial entre as taxas de cobertura vacinal (CV), Índice de Progresso Social (IPS), incidência, e mortalidade, foi utilizado o *I* de Moran Global. Para essa avaliação, foi comparado a autocorrelação espacial entre: incidência e mortalidade; incidência e cobertura vacinal; incidência e IPS; mortalidade e cobertura vacinal; mortalidade e IPS; e cobertura vacinal e IPS.

Segundo os resultados obtidos da análise do *I* de Moran Global bivariado (Tabela 1), na variável Incidência x CV, observou-se uma correlação espacial negativa (*I* de Moran = -0,074, pseudo-valor-p = 0,023), indicando que municípios com alta incidência tendem a estar próximos de municípios com baixa cobertura vacinal e vice-versa; Incidência x IPS, também com uma correlação espacial negativa evidente (*I* de Moran = -0,150, pseudo-valor-p = 0,001), sugerindo que municípios com alta incidência tendem a estar próximos de municípios com baixo IPS; e CV x IPS, com uma correlação espacial positiva (*I* de Moran = 0,218, pseudo-valor-p = 0,001), indicando que municípios com alta cobertura vacinal tendem a estar próximos de municípios com alto IPS. Os pares de variáveis Incidência x Mortalidade, Mortalidade x CV, e Mortalidade x IPS não apresentaram significância estatística ( $p < 0,05$ ) e, portanto, não foi descartado a hipótese nula para a correlação espacial entre essas variáveis. Sendo assim, não serão realizadas análises de LISA entre essas variáveis.

Tabela 1. *I* de Moran Global bivariado, média, desvio padrão e pseudo-significância da correlação espacial das variáveis, no Mato Grosso

Variáveis	<i>I</i> de Moran	Média	Desvio Padrão	Pseudo valor-p*
Incidência x Mortalidade	0,034	-0,0004	0,0385	0,187
Incidência x CV	-0,075	0,0004	0,0367	0,023
Incidência x IPS	-0,151	-0,0002	0,0377	0,001
Mortalidade x CV	0,041	0,0002	0,0376	0,136
Mortalidade x IPS	-0,009	0,0007	0,0383	0,390
CV x IPS	0,218	-0,0027	0,0385	0,001

Fonte: Autores. \*A pseudo-significância da análise é baseada em 999 permutações aleatórias. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para as taxas de incidência e mortalidade, e os anos de 2021 a 2023 para a cobertura vacinal.

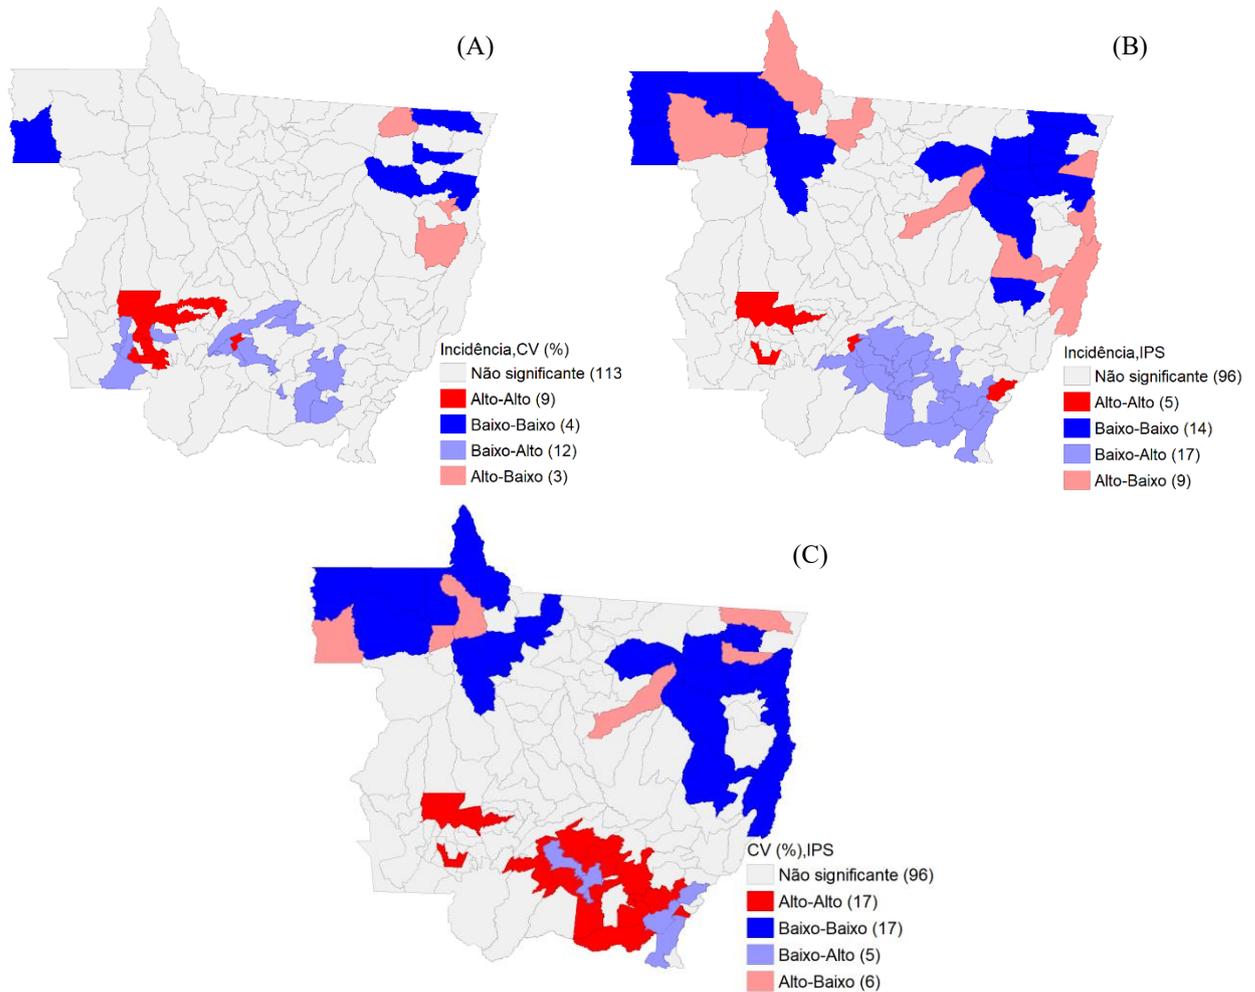
Quando analisado o LISA *map* bivariado da Incidência x CV (Figura 3A), observou que 53,6% dos municípios enquadrados como significativos apresentaram correlação espacial baixo-alto (BA), com maior concentração na região Sul e Centro-Sul Mato-Grossense, e alto-baixo (AB) na região do Nordeste Mato-Grossense. Dentre os municípios estão: Cuiabá, Jangada, Jauru, Nova Brasilândia, Pedra Preta, Porto Esperidião, Poxoréu, Rondonópolis, Rosário Oeste, Salto do Céu, Vale de São Domingos, Várzea Grande, Ribeirão Cascalheira, Santa Cruz do Xingu e Serra Nova Dourada.

Nas taxas de Incidência x IPS (Figura 3B), observou-se que 57,8% dos municípios obtiveram correlação espacial baixo-alto (BA), revelando *clusters* na região Centro-Sul e Sudeste Mato-Grossense, e alto-baixo (AB) com *spots* espalhados entre as regiões do Norte e Nordeste Mato-Grossense, sendo eles: Alto Araguaia, Alto Garças, Araguainha, Campo Verde, Chapada dos Guimarães, Cuiabá, Dom Aquino, Guiratinga, Itiquira, Jaciara, Juscimeira, Nossa Senhora do Livramento, Pedra Preta, Poxoréu, São José do Povo, Santo Antônio de Leverger, Várzea Grande, Alta Floresta, Apiacás, Aripuanã, Canarana, Cocalinho, Feliz Natal, Juruena, Luciara e Novo Santo Antônio.

Em contrapartida, nas variáveis de CV x IPS (Figura 3C), 75,5% dos municípios demonstraram correlação espacial alto-alto (AA) e baixo-baixo (BB), ou seja, municípios com altas taxas de cobertura vacinal estavam cercados por municípios com altas taxas de IPS, e vice versa. Os municípios que detinham correlação alto-alto (AA), se concentraram na região Sul, Centro-Sul e Sudeste Mato-Grossense, sendo eles: Acorizal, Araguainha, Campo Verde, Chapada dos Guimarães, Dom Aquino, Guiratinga, Indiavaí, Itiquira, Juscimeira, Nossa Senhora do Livramento, Pedra Preta, Poxoréu, São José dos Quatro Marcos, São José do Povo, Santo Antônio de Leverger, Tangará da Serra e Várzea Grande. Enquanto que, os municípios que apresentaram correlação baixo-baixo (BB) se encontravam no Norte e Nordeste Mato-

Grossense, sendo: Água Boa, Alta Floresta, Apiacás, Aripuanã, Canabrava do Norte, Canarana, Cocalinho, Colniza, Confresa, Cotriguaçu, Juara, Luciara, Marcelândia, Novo Santo Antônio, Querência, São José do Xingu e São Félix do Araguaia.

**Figura 3.** Clusters dos municípios para a análise de LISA bivariado, para as variáveis de Incidência x CV (A), Incidência x IPS (B) e CV x IPS (C)



Fonte: Autores. Nota: Foi considerado os dados entre os anos de 2020 e 2023 para a taxa de incidência, e os anos de 2021 a 2023 para a cobertura vacinal.

## Discussão

Ao analisar os resultados, apesar da taxa de mortalidade parecer representar uma pequena parte da incidência a nível intermunicipal, o Mato Grosso ainda permanece como o estado brasileiro com maior taxa de mortalidade por habitantes. De acordo com Brasil (2024), enquanto o país apresentava uma média de taxa de mortalidade bruta em 339,1 por 100 mil habitantes, onde o valor mínimo apresentado era do Nordeste com uma mortalidade de 239,8 por 100 mil habitantes, o Centro-Oeste detinha da maior taxa, sendo 411,6 por 100 mil habitantes. Dentre os estados do Centro-Oeste, as taxas de mortalidade bruta variavam de: 398,3

para o Distrito Federal; 404,8 para o Mato Grosso do Sul; 407,3 para Goiás; e 437,1 para o estado de Mato Grosso, apresentando a maior taxa dentre todos os estados brasileiros.

Os resultados evidenciaram que houve variações extremas na cobertura vacinal entre os municípios do Mato Grosso. Houve municípios que apresentaram cobertura vacinal abaixo de 50%, sendo Santa Terezinha, Rondolândia, Santa Cruz do Xingu e Confresa. Enquanto outros municípios apresentaram até 100% de cobertura vacinal, sendo Acorizal, Nova Brasilândia e Santo Antônio de Leverger. Quando observado a localização de cada um desses municípios, notou-se que os municípios que apresentaram menor cobertura vacinal estavam nas regiões Norte e Nordeste Mato-Grossense e os de melhor cobertura nas regiões Sul, Centro-Sul e Sudeste Mato-Grossense.

A desigualdade na cobertura vacinal pode ser explicada por uma combinação de fatores socioeconômicos, logísticos e culturais. A desinformação sobre a vacina, dificuldades de acesso a serviços de saúde, bem como questões religiosas e políticas, foram fatores que contribuíram para o aumento da hesitação vacinal. Além disso, regiões com menor acesso a informações e serviços de saúde enfrentaram mais dificuldades em alcançar altas taxas de vacinação<sup>25</sup>.

A partir do estudo realizado por Moura *et al.* (2022), com dados coletados do Brasil, entre os anos de 2020 a 2022, foi possível observar desigualdades na cobertura vacinal, onde as regiões Sudeste e o Sul apresentaram uma evolução rápida na vacinação, atingindo uma cobertura vacinal de 50% já na 38ª semana de 2021, enquanto que a região Norte alcançou essa marca apenas na 48ª semana. Já a região Centro-Oeste alcançou a marca de 50% de cobertura vacinal por volta da 42ª semana de 2021. Ao final do período analisado pelos autores, as regiões Sudeste e Sul apresentaram cobertura vacinal acima de 80%, enquanto que as regiões Nordeste e Centro-Oeste permaneceram com a cobertura vacinal abaixo de 70% e a região Norte com aproximadamente 60%, caracterizando assim as consequências do desfavorecimento socioeconômico na saúde da população<sup>3</sup>.

Quanto a análise do *I* de Moral Global bivariado, observou-se uma correlação negativa entre a taxa de incidência e a cobertura vacinal, indicando que municípios com altas taxas de incidência estão próximos de regiões com baixa cobertura vacinal. Da mesma forma, houve uma correlação negativa entre a taxa de incidência da COVID-19 e o IPS, sugerindo que áreas com condições socioeconômicas desfavoráveis apresentaram maior disseminação do vírus. Em contrapartida, foi encontrada uma correlação positiva entre a cobertura vacinal e o IPS, mostrando que municípios com melhores condições sociais tendem a ter maior adesão à vacinação. Esses resultados destacam a necessidade de políticas públicas que promovam a equidade no acesso à vacinação, especialmente em áreas mais vulneráveis, para reduzir a

morbimortalidade associada à COVID-19.

Esses achados corroboram com um estudo realizado a nível nacional, durante o período dos meses de abril a outubro de 2021, que identificou que a cobertura vacinal foi maior nas regiões Centro-Sul do Brasil, onde os indicadores socioeconômicos são melhores, em comparação com as regiões Norte e Nordeste. Este resultado sugere que maiores recursos em saúde e campanhas informativas eficazes estão diretamente relacionadas à maiores taxa de cobertura vacinal<sup>26</sup>. Fatores associados às desigualdades sociais também foram observadas em um estudo feito no Tocantins, no período de março de 2020 a abril de 2021, que demonstrou que regiões com menor acesso a serviços de saúde e maior vulnerabilidade social apresentaram uma carga elevada de casos e óbitos<sup>27</sup>.

Um estudo realizado na Espanha, indicou que as taxas de infecção por COVID-19 são de seis a sete vezes maiores nas áreas mais desfavorecidas em comparação com as menos desfavorecidas<sup>28</sup>. Em consonância, Chen e Krieger (2021), demonstraram que os residentes dos condados menos favorecidos nos Estados Unidos apresentaram um maior risco de desenvolverem as formas mais graves da COVID-19, podendo assim apresentar mais casos de óbitos<sup>29</sup>.

Quando considerado a quantidade de recursos relacionados à saúde, como o número de médicos e leitos hospitalares por população, um estudo que utilizou dados de 79 países, coletados desde o início da pandemia até abril de 2021, revelou correlações positivas com as taxas de incidência e correlações negativas com as taxas de letalidade, sugerindo que recursos médicos adequados são importantes tanto para a detecção de casos de COVID-19 quanto para a prevenção de mortes relacionadas à doença<sup>30</sup>. Dessa forma, pode ser que a distribuição dos recursos de saúde para os diferentes municípios e regiões de saúde do Mato Grosso pode influenciar nas taxas de morbimortalidade e cobertura vacinal observadas no presente estudo.

Sendo assim, é fundamental desenvolver estratégias que vão além de uma resposta imediata à uma possível futura pandemia, sendo necessário englobar a prevenção, o diagnóstico, o tratamento e a recuperação. Essas estratégias precisam ser sustentáveis e bem equilibradas, especialmente em regiões vulneráveis, que apresentam desigualdades econômicas e sociais. A pandemia evidenciou a necessidade de um sistema de saúde robusto e adaptável que possa responder não apenas às crises de saúde, mas também às desigualdades socioeconômicas existentes que vão além dessas crises.

Políticas voltadas para a equidade na saúde são essenciais para melhorar a qualidade de vida das populações. A pandemia de COVID-19 revelou ainda mais as vulnerabilidades sociais enfrentadas pela população, especialmente em regiões com acesso limitado aos serviços de

saúde. Portanto, a implementação de políticas que assegurem recursos adequados, profissionais de saúde qualificados e infraestrutura de saúde é vital para atender às necessidades de todas as comunidades, particularmente aquelas que historicamente foram marginalizadas. Além disso, a criação de sistemas de monitoramento e avaliação contínua dos indicadores de saúde pública, especialmente em áreas que foram detectadas como vulneráveis no presente estudo, pode ajudar a identificar rapidamente problemas emergentes e adaptar as intervenções conforme necessário.

O estudo apresentado possui algumas limitações que devem ser consideradas ao interpretar os resultados. Primeiramente, por se tratar de um estudo ecológico, ele está sujeito à falácia ecológica, onde associações observadas em grupos podem não refletir as mesmas associações em indivíduos. Isso pode limitar a capacidade de inferir causalidades a nível individual.

Outra limitação se dá devido ao presente estudo não analisar todas as variáveis confundidoras presentes no banco de dados, podendo assim influenciar os resultados. Estudos futuros que envolvam variáveis como comorbidades, mobilidade, níveis de renda, acesso a cuidados de saúde, escolaridade e condições de moradia são necessários para garantir uma compreensão mais abrangente do impacto da COVID-19 no Mato Grosso.

A utilização de dados secundários, coletados de bases públicas, também podem ocasionar em limitações relacionadas à qualidade, precisão e veracidade das informações. Essa limitação deixa o estudo sujeito a um viés de informação, devido à possíveis inconsistências nos registros ou subnotificações que podem impactar a análise e a interpretação dos resultados. Para amenizar este viés, utilizou-se dados oficiais de órgãos de saúde pública, combinados com informações adicionais de pesquisas locais, o que fortaleceu a validade das conclusões. Além disso, toda a coleta, limpeza e análise dos dados foi realizada de forma minuciosa e sistemática, garantindo que possíveis erros nos dados fossem retirados.

Outro viés que o estudo pode apresentar é o viés espacial que pode surgir devido à desigualdade na qualidade dos dados entre diferentes regiões analisadas. Para evitar esse viés, foi considerado as variações regionais, e empregado técnicas de análise espacial robustas, que ajudaram a identificar padrões consistentes nos resultados.

## **Conclusão**

A análise espacial das taxas de incidência e cobertura vacinal, identificou padrões claros de autocorrelação espacial. *Clusters* de altas taxas de incidência foram predominantemente localizados nas regiões Norte e Nordeste do estado, que também apresentaram os menores Índices de Progresso Social (IPS). Em contraste, as regiões Sul, Centro-Sul e Sudeste, que

apresentaram maiores taxas de IPS, indicaram uma menor taxa de incidência e uma melhor cobertura vacinal. Essa análise confirma que a vulnerabilidade social e econômica pode estar diretamente associada a piores resultados de saúde, reforçando a necessidade de políticas públicas equitativas que abordem essas desigualdades.

As desigualdades sociais presentes nos diferentes municípios demonstram a necessidade de uma abordagem mais coordenada e inclusiva nas políticas de saúde pública. Os resultados obtidos fornecem uma compreensão das dinâmicas espaciais da pandemia no Mato Grosso e pode indicar caminhos para melhorar a equidade no acesso à saúde, especialmente em contextos de crise sanitária.

## Referências

1. Chioro, A., et al., Covid-19 em uma Região Metropolitana: vulnerabilidade social e políticas públicas em contextos de desigualdades. *Saúde Debate*, 2020. 44: p. 219-231.
2. Bach, T. and K. Wegrich, *Blind Spots, Biased Attention, and the Politics of Non-coordination*, in *The Blind Spots of Public Bureaucracy and the Politics of Non-Coordination*, P. McMillan, Editor. 2019, Springer International Publishing: Switzerland. p. 3-28.
3. Moura, E.C., et al., Covid-19: temporal evolution and immunization in the three epidemiological waves, Brazil, 2020-2022. *Rev Saúde Pública*, 2022. 56: p. 105.
4. Silva, G.A.E., B.C. Jardim, and C. Santos, Excess mortality in Brazil in times of Covid-19. *Ciênc Saúde Coletiva*, 2020. 25(9): p. 3345-3354.
5. Silva, D.F. and M.L.C. Oliveira, Epidemiologia da COVID-19: comparação entre boletins epidemiológicos. *Comunicação em Ciências da Saúde*, 2020. 31(Suppl1): p. 61-74.
6. Pires, R.R.C., Diretoria de Estudos e Políticas do Estado, das Instituições e da Democracia. *Os Efeitos sobre grupos sociais e territórios vulnerabilizados das medidas de enfrentamento à crise sanitária da Covid-19: propostas para o aperfeiçoamento da ação pública*. 2020, Instituto de Pesquisa Econômica Aplicada: Brasília. p. 18.
7. Sathler, D. and G. Leiva, Prioridade para futuras vacinações contra a Covid-19 no Brasil: os usuários de transporte público devem ser um grupo-alvo? *Rev Bras Estud Popul*, 2021. 38: p. 1-12.
8. Albuquerque, M.V. and L.H.L. Ribeiro, Inequality, geographic situation, and meanings of action in the COVID-19 pandemic in Brazil. *Cad Saúde Pública*, 2021. 36(12): p. e00208720.
9. Bezerra, A.C.V., et al., Factors associated with people's behavior in social isolation during the COVID-19 pandemic. *Ciênc Saúde Coletiva*, 2020. 25: p. 2411-2421.
10. CARVALHO, B.C.C., Fique em casa? Estudo antropológico sobre os desdobramentos da pandemia da COVID-19 nos encontros entre o Consultório na Rua e as pessoas em situação de rua no município de João Pessoa/PB, in *Centro de Ciências Humanas, Letras e Artes*. 2022, Universidade Federal da Paraíba: João Pessoa. p. 130.

11. Mendonça, M.H.M., et al., A pandemia COVID-19 no Brasil: ecos e reflexos nas comunidades periféricas. *Aps Em Revista*, 2020. 2(2): p. 162-168.
12. Cruz, R.M., et al., COVID-19: Emergência e Impactos na Saúde e no Trabalho. *Rev Psicol Organ Trab*, 2020. 20: p. 1-2.
13. IBGE, Instituto Brasileiro de Geografia e Estatística. Diretoria de Pesquisas, Coordenação de População e Indicadores Sociais. Censo Brasileiro de 2022. 2022, IBGE: Rio de Janeiro.
14. IPEA. Instituto de Pesquisa Econômica Aplicada. População em situação de rua supera 281,4 mil pessoas no Brasil. 2022 [cited 2024 03 jun 2024]; Available from: <https://www.ipea.gov.br/portal/categorias/45-todas-as-noticias/noticias/13457-populacao-em-situacao-deruasupera2814milpessoasnobrasil>.
15. Barreto, M.L., Health inequalities: a global perspective. *Cien Saude Colet*, 2017. 22(7): p. 2097-2108.
16. Caram, C.D.S., et al., Redução da desigualdade de acesso às ações de promoção da saúde na Atenção Primária brasileira: Programa Academia da Saúde. *DEMETERA: Alimentação, Nutrição & Saúde*, 2021. 16.
17. WHO. Commission on Social Determinants of Health. Closing the Gap in a Generation: Health Equity Through Action on the Social Determinants of Health: Commission on Social Determinants of Health Final Report. 2008.
18. Buss, P.M., A. Pellegrini Filho, A saúde e seus determinantes sociais. *Physis: Revista de Saúde Coletiva*, 2007. 17(1): p. 77-93.
19. Melissa Wilm, et al., Índice de Progresso Social Brasil 2024: Qualidade de vida nos 5.570 municípios do Brasil. *Resumo Executivo*, 2024: p. 1-50.
20. Stern, S., et al. The 2024 Social Progress Index results. 2024 20 jul 2024; Available from: <https://www.socialprogress.org>.
21. Silva, J.C., Trabalho precarizado: trajetórias, crises e vínculos dos entregadores de aplicativos, in *Faculdade de Economia, Administração e Contabilidade*. 2021, Universidade de São Paulo: São Paulo.
22. Sposati, A.D.O., COVID-19 revela a desigualdade de condições da vida dos brasileiros. *NAU Social*, 2020. 11(20): p. 101.
23. IBGE, Malha Municipal Digital e Áreas Territoriais 2022. Nota metodológica n. 01, in *Informações Técnicas e Legais para a Utilização dos Dados Publicados*. 2022, Instituto Brasileiro de Geografia e Estatística.
24. BRASIL. Ministério da Saúde. Secretaria Extraordinária de Enfrentamento à COVID-19. Plano nacional de operacionalização da vacinação contra a covid-19. 2022.
25. Feio, E.C.G., et al., Impacto da cobertura vacinal sobre o COVID-19 no estado do Pará: uma análise espacial (2020 - 2022). *Amazônia Science and Health*, 2023. 11(3).
26. Baumgratz, D., B.R.B.F. Terre, and L.R. Alves, Análise da correlação espacial da COVID-19 nos municípios brasileiros de fronteira. *Revista Tecnologia e Sociedade*, 2023. 19(56).
27. Cesar, A.E.M., et al., Analysis of COVID-19 mortality and case-fatality in a low-income region: an ecological time-series study in Tocantins, Brazilian Amazon. *Journal of Human Growth and Development*, 2021. 31(3): p. 496-506.

28. Bambra, C., et al., The COVID-19 pandemic and health inequalities. *J Epidemiol Community Health*, 2020. 74(11): p. 964-968.
29. Chen, J.T. and N. Krieger, Revealing the Unequal Burden of COVID-19 by Income, Race/Ethnicity, and Household Crowding: US County Versus Zip Code Analyses. *J Public Health Manag Pract*, 2021. 27 Suppl 1, COVID-19 and Public Health: Looking Back, Moving Forward: p. S43-S56.
30. Hong, D., et al., The age-standardized incidence, mortality, and case fatality rates of COVID-19 in 79 countries: a cross-sectional comparison and their correlations with associated factors. *Epidemiol Health*, 2021. 43: p. e2021061.