UNIVERSIDADE FEDERAL DE PERNAMBUCO

CENTRO ACADÊMICO DO AGRESTE

PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA

LUIZ FERNANDO LOURENÇO DE SOUSA

ESTRUTURA URBANA E ACESSO A OPORTUNIDADES: Implicações Para a Disseminação da Covid-19 no Brasil

Caruaru

2023

LUIZ FERNANDO LOURENÇO DE SOUSA

ESTRUTURA URBANA E ACESSO A OPORTUNIDADES: Implicações Para a Disseminação da Covid-19 no Brasil

Dissertação apresentada ao Programa de Pós-Graduação em Economia da Universidade Federal de Pernambuco, como requisito parcial à obtenção do título de mestre em Economia.
Área de concentração: Economia Regional

Orientadora: Profa. Dra. Danyella Juliana Martins de Brito

Caruaru
2023

Catalogação na fonte:
Bibliotecária – Paula Silva - CRB/4 - 1223

S725e Sousa, Luiz Fernando Lourenço de.
Estrutura urbana e acesso a oportunidades: implicações para a disseminação da Covid-19 no Brasil. / Luiz Fernando Lourenço de Sousa. – 2023.
67 f.; il.: 30 cm.

Orientadora: Danyella Juliana Martins de Brito.

Dissertação (Mestrado) – Universidade Federal de Pernambuco, CAA, Programa de Pós- Graduação em Economia, 2023.
Inclui Referências.

1. COVID-19 (Doença) - Brasil. 2. Crescimento urbano – Brasil. 3. Acesso aos serviços de saúde – Brasil. 4. Infraestrutura (Economia) – Brasil. 5. Espraiamento urbano. I. Brito, Danyella Juliana Martins de (Orientadora). II. Título.

CDD 330 (23. ed.) UFPE (CAA 2023-013)

LUIZ FERNANDO LOURENÇO DE SOUSA

ESTRUTURA URBANA E ACESSO A OPORTUNIDADES: Implicações Para a Disseminação da Covid-19 no Brasil

Dissertação apresentada ao Programa de Pós Graduação em Economia da Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, como requisito para a obtenção do título de Mestre em Economia. Área de concentração: Economia Regional

.

Aprovada em: 03/03/2023.

BANCA EXAMINADORA

_____

Profa. Dra. Danyella Juliana Martins de Brito (Orientadora)
Universidade Federal de Pernambuco - UFPE

_____

Prof. Dr. Klebson Humberto de Lucena Moura (Examinador Interno)
Universidade Federal de Pernambuco - UFPE

_____

Profa. Dra. Andreza Daniela Pontes Lucas (Examinadora Externa)
Universidade Federal de Pernambuco - UFPE

RESUMO

Com a expansão mundial da pandemia da Covid-19, a disseminação e mortalidade do vírus trouxe impactos no modo de organização da economia. Um dos fatores determinantes para este processo é a estrutura das localidades. O objetivo deste estudo é analisar como as infecções e óbitos por Covid-19 estão relacionados com a estrutura urbana das cidades brasileiras. Este tipo de análise se faz importante para compreender as diferenças das localidades e sua relevância no momento da adoção e calibragem de estratégias de contenção para a Covid-19 e outras doenças. Para examinar esse fenômeno, busca-se, primeiro, compreender a relação direta de variáveis demográficas, de mobilidade, vulnerabilidade social e de estrutura urbana com as taxas de infecção e de mortalidade da Covid-19, através de uma abordagem de modelos de equações estruturais (*structural equation modeling* – SEM). Na sequência, investiga-se a relação entre as infecções e óbitos por Covid-19 e nível de espraiamento urbano, analisando o nível de compacidade urbana desde uma perspectiva multidimensional, considerando características demográficas, de vulnerabilidade social e de acesso a oportunidades, por meio do modelo de múltiplos indicadores e múltiplas causas (MIMIC). Os resultados mostram que as cidades menos espraiadas, isto é, localidades mais compactas, possuem uma maior taxa de disseminação e óbitos pelo novo coronavírus. Sendo a relação entre nível de compacidade e mortalidade significativamente menor, comparativamente a infecção, o que certamente está relacionado a fatores como acesso rápido aos sistemas de saúde e qualidade de atendimento nas localidades mais compactas. Adicionalmente, os resultados evidenciam que, dentre outros aspectos, acesso a oportunidades e mobilidade pendular são variáveis com influência sobre o nível de compacidade urbana.

Palavras-chave: Covid-19; espraiamento urbano; acesso a oportunidades; Brasil.

ABSTRACT

With the worldwide expansion of the Covid-19 pandemic, the spread and mortality of the virus has brought impacts on the organization of the economy. One of the determining factors for this process is the structure of localities. The objective of this study is to analyze how Covid-19 infections and deaths are related to the urban structure of Brazilian cities. This type of analysis is important to understand the differences between localities and their relevance in the adoption and calibration of containment strategies for Covid-19 and other diseases. To examine this phenomenon, the direct relationship between demographic, mobility, social vulnerability, and urban structure variables with Covid-19 infection and mortality rates is first understood through a structural equation modeling (SEM) approach. Subsequently, the relationship between Covid-19 infections and deaths and the level of urban sprawl is investigated, analyzing the level of urban compactness from a multidimensional perspective, considering demographic characteristics, social vulnerability, and access to opportunities through the multiple indicator multiple causes model (MIMIC). The results show that less sprawling cities, i.e., more compact localities, have a higher rate of spread and deaths from the new coronavirus. Since the relationship between compactness level and mortality is significantly smaller than that of infection, this is certainly related to factors such as quick access to health systems and quality of care in more compact localities. Additionally, the results show that, among other factors, access to opportunities and commuting mobility are variables that influence the level of urban compactness.

Keywords: Covid-19; urban sprawl; access to opportunities; Brazil.

LISTA DE ILUSTRAÇÕES

Diagrama 1 - Diagrama de caminho relacional entre as variáveis endógenas e exógenas 32

Diagrama 2 - Modelo MIMIC para análise da relação entre a compacidade urbana e as taxas de infecção e mortalidade por Covid-19 35

Mapa 1 - Distribuição espacial do número acumulado de infectados pela Covid-19 e densidade populacional 39

Gráfico 1 - Ranking dos impactos dos determinantes significativos do índice de compacidade urbana 49

LISTA DE TABELAS

Tabela 1 - Descrição das variáveis analisadas 24

Tabela 2 - Estatísticas descritivas das variáveis do modelo 40

Tabela 3 - Média de infecções e óbitos por Covid-19 por classes de hierarquia urbana 41

Tabela 4 - Resultado do modelo de equações estruturais 42

Tabela 5 - Resultados do modelo estrutural – modelo de múltiplos indicadores e múltiplas causas (MIMIC) 47

Tabela 6 - Resultados do modelo de mensuração – modelo de múltiplos indicadores e múltiplas causas (MIMIC) 51

Tabela 7 - Resultado do modelo de equações estruturais para taxa de infecções 64

Tabela 8 - Resultado do modelo de equações estruturais para taxa de óbitos 65

Tabela 9 - Resultados do modelo estrutural para as três datas – modelo de múltiplos indicadores e múltiplas causas (MIMIC) 66

Tabela 10 - Resultados do modelo de mensuração para as três datas – modelo de múltiplos indicadores e múltiplas causas (MIMIC) 67

SUMÁRIO

1 INTRODUÇÃO …….. 9

2 FUNDAMENTAÇÃO TEÓRICA …… 13

2.1 Cidades compactas e cidades espraiadas 13

2.2 Expansão urbana e os modelos de cidades 15

2.3 A pandemia da Covid-19 e os modelos de cidades 18

2.4 Acesso a oportunidades e os modelos de cidades 21

3 ESTRATÉGIA EMPÍRICA 23

3.1 Dados e definição de variáveis 23

3.2 Metodologia 29

4 RESULTADOS 38

4.1 Análise Descritiva 38

4.2 Modelos Empíricos 41

4.2.1 *Modelo de Equações Estruturais 42*

4.2.2 *Modelo de Múltiplos Indicadores e Múltiplas Causas 47*

5 CONSIDERAÇÕES FINAIS 52

REFERÊNCIAS 54

APÊNDICE A - ROBUSTEZ DOS MODELOS ATESTADA PARA OUTRAS DATAS 64

1 INTRODUÇÃO

No ano de 2019, surge na China o primeiro caso de Covid-19[1] (*Corona Virus Disease* do ano de 2019), um vírus altamente transmissível que ataca principalmente o sistema respiratório dos indivíduos, e, em 2020, o vírus chega ao Brasil. Na tentativa de controlar a propagação da doença, políticas foram adotadas para minimizar o ritmo de contágio e o número de óbitos. Dentre as ações governamentais, é cita-se o isolamento social, que foi o principal mecanismo de contenção do espalhamento do vírus, antes da vacinação tornar-se amplamente acessível à população[2] (MACEDO JÚNIOR, 2020).

Para Chauvin (2021), na análise de 2.500 municípios brasileiros, o número de infectados pela Covid-19 no país varia de acordo com a organização das localidades. Dessa maneira, locais que apresentam maior densidade e mobilidade mais intensa tendem a apresentar um maior número de infectados, comparativamente às demais localidades. Leiva *et al.* (2020), ao investigarem Nova York e Los Angeles, evidenciam que locais com maior desigualdade e segregação socioespacial tendem a possuir, em um primeiro momento, menos pessoas afetadas pela doença, visto que locais mais ricos possuem mais canais de aglomeração populacional.

A estrutura horizontal de organização espacial das cidades, ou os modelos teóricos de cidades, podem apresentar duas formas, sendo elas compactas ou espraiadas (NEWTON, 2000; ECHENIQUE, 2001; ARBURY, 2005). Nessa linha, estudos como os de Burton *et al.* (2003), OECD (2012), Sebbenn e Ruschel (2019), Leiva *et al.* (2020), Nascimento Júnior (2017) e Mesquita *et al.* (2021) afirmam que cidades compactas tendem a apresentar maior densidade populacional, menores espaços verdes e melhor sistema de transportes; enquanto nas cidades espraiadas, além de existir um maior distanciamento dos centros comerciais, o uso de transporte individual tende a ser mais intenso, aumentando o nível de poluição.

Nesse contexto, as análises que investigam como que a difusão de doenças está associada à organização das cidades ganham destaque na literatura. Hassell *et al.* (2017)

---

[1] Doença infecciosa causada pelo vírus SARS-CoV-2 (BRITO *et al.*, 2020).

[2] No Brasil a vacinação começou a partir de janeiro de 2021 (MINISTÉRIO DA SAÚDE, 2022). O isolamento social, por sua vez, regulamentado pela lei 13.979/2020, foi adotado como principal medida de contenção do vírus, juntamente com a quarentena, onde essas medidas poderiam ser determinadas por médico ou agente de vigilância epidemiológica (MACEDO JÚNIOR, 2020).

analisaram como a urbanização estava associada à propagação de zoonoses emergentes, como a gripe aviária, tuberculose, hepatite, entre outros[3]; Soares *et al.* (2014) avaliam a disseminação de doenças como a leptospirose atrelada a forma de organização das localidades; Tauil (2001) aborda aspectos urbanos que estão relacionados com a disseminação de casos de dengue no país; Sathler e Leiva (2022), Hamidi *et al.* (2020), Aguilar *et al.* (2022) e Yücel et al. (2023) investigam como variáveis de densidade, infraestrutura urbana, restrições de mobilidade, pobreza e desigualdade podem estar relacionadas com o número de infecções e óbitos por Covid-19.

A maneira como as localidades estão organizadas pode interferir no processo de contágio da Covid-19. Assim, municípios que possuem maior densidade, melhor infraestrutura de transportes, melhor acesso a oportunidades de trabalho, saúde e educação, menor poluição e menores espaços verdes, podem apresentar um grau mais elevado de infecções por Covid-19 (GENTIL, 2015; LEIVA *et al*., 2020). O mecanismo que explica o fato de que melhor acesso a oportunidades e melhor infraestrutura urbana e de transportes estão correlacionados com uma maior propagação do vírus é o maior grau de exposição dos indivíduos, devido a uma maior aglomeração em localidades com tais características. Hamidi *et al.* (2020), por sua vez, verificam que a densidade populacional está, de fato, positivamente relacionada com as infecções, porém, está negativamente associada com a mortalidade pelo vírus, para a realidade norte-americana.

De acordo com dados do Instituto Brasileiro de Geografia e Estatística (IBGE), no ano de 2012, o Brasil possuía aproximadamente 194 milhões de habitantes, já em 2022 existiam cerca de 214 milhões. No período de 10 anos houve um aumento de 20 milhões de habitantes, o que evidencia uma vasta expansão populacional. Esse maior aglomerado de pessoas, aliado a aspectos como a continentalidade e as diferenças regionais entre as localidades, contribui para que a disseminação do vírus se dê de maneira assimétrica no Brasil, apresentando, portanto, padrões diferentes de infecções entre as localidades (BEGA; SOUZA, 2021).

Nesse sentido, este estudo tem como objetivo geral analisar como as infecções e óbitos por Covid-19 estão relacionados com a estrutura urbana das cidades, ponderando os fatores sociais, demográficos, econômicos e espaciais. Para compreender esse processo, é fundamental se aprofundar no exame das principais características dos dois

[3] Zoonoses emergentes são definidas pelos autores como doenças transmitidas entre animais e pessoas que aumentaram sua incidência nas últimas duas décadas, ou ameaçam aumentar em breve.

modelos teóricos de cidades – a citar, cidade compacta e cidade espraiada. Para tanto, seguindo Bollen (1989), Kline (2011), Macana e Comim (2016), Hamidi *et al*. (2020) e Pereira *et al.* (2020a), inicialmente é realizada uma análise, através do uso do ferramental da modelagem de equações estruturais para investigar a relação entre variáveis espaciais, demográficas, sociais e econômicas com as infecções e óbitos por Covid-19. Na sequência, investiga-se a relação entre a contaminação e mortalidade pelo vírus e nível de espraiamento urbano, a partir da análise do índice de compacidade urbana desde uma perspectiva multidimensional, considerando características demográficas, de vulnerabilidade social e de acesso à oportunidades, por meio do modelo de múltiplos indicadores e múltiplas causas do inglês, *Multiple Indicator Multiple Causes* (MIMIC), (MIMIC). Vale ressaltar que, a despeito da relevância empírica da caracterização das cidades brasileiras, existe uma lacuna na literatura em termos de relação entre as tipologias de cidades e infecções e óbitos por Covid-19.

Dessa forma, com base em Pereira *et al.* (2020a), Pereira *et al.* (2020b), Hamidi *et al.* (2020) e Leiva *et al.* (2020), a hipótese subjacente da presente pesquisa é a de que locais compactos, com maiores indicadores de densidade e melhores condições de acessibilidade, possuam uma maior taxa de infecção e uma menor taxa de mortalidade por Covid-19. Assim, as unidades territoriais de análise são os municípios brasileiros e os dados utilizados são extraídos das Estimativas da População e do Censo Demográfico de 2010 do Instituto Brasileiro de Geografia e Estatística (IBGE), do Programa das Nações Unidas para o Desenvolvimento (PNUD), do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa do Observatório do Clima (OC), da Relação Anual de Informações Sociais (RAIS), da pesquisa Regiões de Influência das Cidades (REGIC), do Cadastro Nacional de Estabelecimentos de Saúde (CNES), do Censo Escolar do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) e do Portal Covid do Ministério da Saúde (MS).

Hamidi *et al.* (2020) estudam os impactos diretos e indiretos das densidades sobre o número de infectados e óbitos em 913 municípios nos EUA. Leiva *et al.* (2020) conduzem uma análise descritiva comparativa de Nova York (cidade compacta) e Los Angeles (cidade espraiada), para obter as principais diferenças entre as duas no processo de contaminação pelo novo coronavírus. Pereira *et al.* (2020a) analisam o acesso a oportunidades de trabalho, saúde e educação a partir de dois indicadores – a citar, tempo

mínimo e medida cumulativa ativa de acesso a oportunidades – para compreender o acesso à saúde, educação e trabalho nos municípios das principais regiões metropolitanas brasileiras. Dieleman e Wegener (2004) exploram a relação entre a estrutura urbana e o sistema de transportes, além de analisarem as políticas para a contenção da expansão urbana nas localidades.

Diferente dos estudos citados, na presente pesquisa é realizada uma análise conjunta dos indicadores acima. Esse tipo de estudo é importante para a obtenção de informações que servem como guia para a elaboração de políticas públicas no mundo pós-pandemia. Este estudo avança em relação à literatura existente, pois traz novas evidências acerca do espraiamento urbano, através do índice de compacidade urbana, e sua relação com as infeções e óbitos não só para Covid-19, mas também para outras doenças virais altamente contagiosas.

Assim, este estudo está dividido em cinco seções, incluindo esta introdução. Na seção dois é apresentada a fundamentação teórica obtida de uma revisão sistemática na literatura. Na seção três, é desenvolvida a estratégia empírica. A seção quatro contém os resultados. A seção cinco compreende as considerações finais da dissertação.

2 FUNDAMENTAÇÃO TEÓRICA

Nesta seção são abordadas as principais discussões teóricas existentes na literatura nacional e internacional. Assim, são apresentados alguns estudos que debatem acerca da estrutura urbana, da expansão urbana, da pandemia da Covid-19, e do mecanismo de acesso a oportunidades de trabalho, saúde e educação.

2.1 Cidades compactas e cidades espraiadas

A maneira de organização das cidades é um fenômeno amplamente estudado pelos pesquisadores, pois elas ditam não só o crescimento, mas o desenvolvimento econômico, político e social de uma localidade. Assim, o desenvolvimento econômico não está relacionado apenas à aquisição de capital e de conhecimento, mas também à estrutura das localidades, pois ela determina se este será dado de maneira mais acelerada ou mais lenta (EATON; ECKSTEIN, 1997).

As cidades são locais que podem assumir não apenas um formato. Esses locais podem ser moldados de acordo com sua densidade, representantes políticos, dimensão, distribuição da população, infraestrutura do sistema de transportes e modelo econômico. Essas estruturas urbanas são resilientes e mudam de maneira lenta e gradual com o passar do tempo (BERTAUD, 2004).

No modelo de crescimento horizontal, observa-se dois tipos de cidades: compactas e espraiadas (dispersas). As cidades compactas evidenciam um modelo urbano que está relacionado a um mecanismo mais densificado de ocupação. Neste tipo de cidade o uso de transportes coletivos é maior, levando ao desenvolvimento mais acelerado do mesmo, e permitindo que o acesso a oportunidades, como trabalho, educação e saúde, seja realizado com mais facilidade (BURTON *et al.*, 2003).

As cidades compactas possuem um potencial de sustentabilidade maior, devido ao fato de que a incidência do uso de transportes coletivos é grande, colocando o transporte individual em segundo plano. Dessa maneira, a emissão de gases poluentes é reduzida, além disso, devido a menor extensão territorial, as distâncias percorridas são relativamente menores nas cidades compactas (OECD, 2012). De acordo com Leiva *et al.* (2020), um exemplo desta tipologia de cidade é Nova York, nos Estados Unidos.

Sebbenn e Ruschel (2019) afirmam que a compacidade das cidades traz benefícios, devido a sua extensão territorial, pois assim, as políticas conseguem ser mais

direcionadas e eficazes na resolução de problemas específicos. Isso melhora aspectos como a qualidade de vida e maior adequação dos indivíduos às políticas propostas.

O fenômeno do espraiamento urbano foi analisado por Glaeser e Kahn (2004) para os Estados Unidos, e por Nadalin (2010) para a Região Metropolitana de São Paulo. As evidências indicam que, em São Paulo, este processo se iniciou na década de 80 e que ele pode não ser benéfico para os locais, pois traz consigo externalidades negativas, a exemplo, a extensão desnecessária da infraestrutura urbana, pois quanto maior a extensão da localidade, mais difícil é a implementação de políticas específicas eficientes e eficazes nestes locais.

As cidades espraiadas ou dispersas são locais com menor densidade populacional e nelas existe uma maior distância entre o centro e as periferias. Neste tipo de cidade, no geral, os sistemas de transportes coletivos não funcionam de maneira eficiente, dado que funcionam com baixa capacidade de passageiros, rotatividade limitada, qualidade de serviço precário e podem exercer altos valores de tarifas. Assim, o uso de transportes individuais, como automóveis e motocicletas, passa a ser preferível. Um exemplo deste tipo de cidade é Los Angeles (LEIVA *et al.*, 2020).

Nesses locais dispersos, em geral, as emissões de gases poluentes como o CO_2 passam a ser maiores, devido a maiores distâncias percorridas e o uso mais intenso de meios individuais de transporte. O espraiamento das cidades pode se apresentar de maneira diferente em locais distintos, pois cada localidade possui um grau maior ou menor desse fenômeno (NASCIMENTO JÚNIOR, 2017).

Segundo Mesquita *et al.* (2021) e Leiva *et al.* (2020), a predominância de cidades espraiadas é mais esperada no território brasileiro, pois a realidade do Brasil no planejamento de políticas de infraestrutura de transportes não é eficiente tanto do ponto de vista econômico-social, quanto ambiental, pois existem uma série de questões como a alta desigualdade social e de renda e uso intensivo de transportes individuais que dificultam o processo de elaboração destas políticas. Contudo, vale ressaltar que não existe uma classificação precisa, em termos de compacidade urbana, para os municípios brasileiros.

Além de todas as diferenças em questões de mobilidade, a diferença entre as cidades também traz reflexos na saúde. É possível perceber que, devido aos aspectos de mobilidade, as cidades integradas emitem menos gases poluentes na atmosfera e apresentam um sistema de saúde melhor, tanto no quesito de condições de acesso, quanto

no tocante a oferta de serviços médicos. Isto acontece, porque em cidades compactas, há uma maior difusão do conhecimento e, como consequência disto, existem mais profissionais qualificados para exercerem seus cargos de forma mais eficiente, entre eles, os médicos, enfermeiros, fisioterapeutas, entre outros (OECD, 2012; SEBBENN; RUSCHEL, 2019).

A partir do que foi exposto, é possível relacionar a expansão das cidades (espraiamento urbano) e a compacidade destas à disseminação da Covid-19. Nesse contexto, Leiva *et al.* (2020), a partir do estudo de caso de Los Angeles e Nova York, evidenciam que a estrutura urbana e a forma de organização das cidades acabam interferindo no processo de isolamento social e, consequentemente, no processo de infecção da Covid-19. Assim, as diferentes formas de cidades apresentaram, tanto desafios, como oportunidades distintas, para o enfrentamento da pandemia da Covid-19.

Sathler e Leiva (2022) argumentam que a cidade deve estar no cerne dos debates acerca da contaminação por Covid-19. Nesse contexto, é crucial o entendimento de fatores sociais, espaciais, econômicos e demográficos, pois eles ditam as vulnerabilidades das cidades. Dessa forma, compreender o mecanismo da expansão urbana se faz importante para o debate sobre a relação entre a organização espacial das localidades e a disseminação e mortalidade por Covid-19.

2.2 Expansão urbana e os modelos de cidades

Os modelos de cidades não são estáticos, eles se alteram de acordo com mudanças estruturais nas localidades. O retrato local monocêntrico é o tradicional, nele existe apenas um distrito comercial central (DCC), ou Central Business District (CBD) e a localidade se desenvolve em seu entorno. Dessa maneira, locais mais próximos destes centros, tendem a apresentar uma melhor acessibilidade, maior captação de investimentos, melhores condições e maior densidade populacional (BRUECKNER, 2011).

Para retratar a característica monocêntrica das localidades o modelo amplamente utilizado na literatura é o Alonso-Mills-Murth (AMM) que apresenta a tomada de decisão das famílias levando em consideração o espaço de moradia, o acesso a oportunidade de trabalho e as amenidades locais. Nele é evidenciado que quanto mais próximo do CBD, melhor o nível de acessibilidade e maiores as amenidades locais, porém os espaços de moradia são reduzidos (BRUECKNER, 2011). No Brasil, o modelo monocêntrico de

cidade se faz consistente com o tamanho de sua área urbana nos últimos anos (NOVA, 2014).

Porém, ao longo do tempo, as cidades passaram a se espalhar e assumirem um caráter mais policêntrico, com mais centros de emprego, o que gerou uma mudança no padrão de distribuição populacional nas cidades. Com essa expansão, alguns novos centros urbanos passaram a ser incorporados à área urbana expandida, dado a proximidade com o distrito comercial central (CBD), e outros possuem maior distanciamento, necessitando de melhores condições de transporte (ANAS *et al.*, 1998).

Com esse maior crescimento urbano, existem três fenômenos que começam a ser evidenciados na dinâmica espacial da localidade, sendo eles: o declínio das cidades centrais, reduzindo estruturas monocêntricas e aumentando as policêntricas; o surgimento de cidades de ponta que competem e complementam as funções do núcleo, suprindo melhor as necessidades da demanda e a suburbanização das cidades, dada uma maior migração para o entorno, seja por motivos de estudo, trabalho, entre outros (BATTY *et al*., 1999).

Grostein (2001) afirma que o crescimento destes locais levou a formação das regiões metropolitanas, nestas regiões existe a presença de um município central somado a outras cidades que estão ao seu entorno que sofrem influências da sua expansão. Estes municípios, que estão inseridos nesta zona espacial, segundo a autora, possuem funções de caráter complementar, com gestões diferentes e independentes e níveis diferentes de recursos financeiros.

Características destas regiões metropolitanas, como maior renda, maiores oportunidades de empregos e menor custo de transporte, em países em desenvolvimento, como é o caso do Brasil, faz com que a localidade seja alvo de constantes migrações. Como consequência disso, começa a haver a formação de um local com maior densidade populacional, característica primordial de uma cidade com estrutura compacta (BRUECKNER, 2011).

No Brasil, este processo de expansão urbana que apresenta, até a atualidade, uma tendência crescente, começou a ganhar força na década de 30. Porém, apenas na década de 70, a população urbana superou a rural. Assim, grandes mudanças estruturais foram realizadas no território brasileiro, levando-o a chegar na realidade atual, em que predominam grandes aglomerados urbanos (BRITO; SOUZA, 2005).

O desenvolvimento urbano permite uma redução de custos logísticos, um maior

desenvolvimento do sistema de transportes, facilidade de crédito para a compra de imóveis. Porém, pontos negativos desse processo também são evidentes no maior uso de transportes privados individuais, na emissão mais gases poluentes (por mais que o transporte público se desenvolva) e no aumento da demanda por serviços (diminuindo o bem-estar do indivíduo, devido a uma provável superlotação) (THISSE, 2000; TINOCO, 2003; NEUMAN, 2005; DALBERTO; STADUTO, 2013).

Estes fatores de ganhos de aglomeração, em consonância com Fujita *et al.* (2002), são benéficos para o desenvolvimento econômico, principalmente no campo industrial, pois leva para o lugar mão de obra especializada, acomoda os fornecedores e dispersa as informações no meio concentrado. Logo, eles funcionam como uma força centrípeta, atraindo para o centro as demandas de interesse.

Devido ao fato de concentrarem um maior contingente populacional, os municípios metropolitanos concentram uma maior força de trabalho para que possa suprir um maior mercado consumidor. Dessa maneira, a maior demanda pela produção local, leva estas cidades a possuírem uma maior infraestrutura de produção e, consequentemente, um elevado grau de desenvolvimento, atraindo ainda mais indivíduos para estes locais (NASCIMENTO; MATIAS, 2011).

Devido a necessidade de compreender o cerne deste processo, Galster *et al.* (2001) utilizam o Censo de 1990 para caracterizar a expansão urbana em treze municípios dos EUA através do uso de indicadores que explicam o espraiamento urbano[4]. Os autores percebem que Atlanta, Miami e Denver possuem um maior nível de espraiamento urbano se comparados com os menores níveis apresentados por Nova York, Filadélfia, Chicago e Boston. Frenkel e Ashkenazi (2008) procuraram medir a expansão urbana em 78 assentamentos urbanos de Israel ao longo de 15 anos, de 1993 a 2008, utilizando indicadores de densidade, forma, fragmentação e de composição do uso das terras.

Os estudos vistos nesta seção, evidenciam as mudanças locacionais advindas do processo de expansão urbana, levando as cidades a possuírem diferentes tipos de características e organizações. Assim, a partir desses textos, percebe-se que a expansão urbana está relacionada ao nível de espraiamento local, pois, quanto mais ocorre esse processo, mais interligado e denso tende a se tornar a localidade, em outras palavras, mais compacto ele fica. A partir do exposto, é necessário compreender a pandemia,

[4] Os indicadores utilizados por Galster *et al.* (2001) foram: densidade, continuidade, concentração, agrupamento, centralidade, nuclearidade, uso misto do solo e proximidade.

principalmente nos países emergentes e subdesenvolvidos e sua relação com a estrutura urbana.

2.3 A pandemia da Covid-19 e os modelos de cidades

A estrutura urbana das localidades pode afetar a disseminação de doenças infecciosas. Fatores como o uso de transporte públicos, emissões per capita de gases poluentes, indicadores de saúde, tamanho das localidades e distribuição populacional estão relacionados com os níveis de infectados (AGUILAR *et al.*, 2022).

No início do ano de 2020, chega ao Brasil o vírus chamado de Covid-19 que tomou grandes proporções pela sua facilidade de transmissão e foi reconhecido como um dos grandes desafios de enfrentamento do século XXI. Os problemas causados por esta doença não são meramente sanitários, mas sim, de caráter político, socioeconômico e cultural que podem ter reflexos distintos a depender da região em que se apresentam (MATTA *et al.*, 2021).

Brito *et al.* (2020) afirmam que a Covid-19 se apresenta através de uma infecção respiratória aguda que tem alto grau de transmissibilidade, principalmente através de gotículas, secreções e contato físico. Falhas no olfato e paladar, tosse, febre e cansaço são sintomas que podem ocorrer devido ao fato de se tratar de uma infecção viral.

No Brasil, de acordo com Cavalcante *et al.* (2020), até a vigésima semana epidemiológica (tempo padrão para agrupar mortes e outros eventos epidemiológicos) de 2020, a região Norte apresentou o maior número relativo de infectados. Além disso, segundo Moraes *et al.* (2020), a região Nordeste foi a mais afetada pelo novo coronavírus. Esses fatos evidenciam que algumas localidades acabaram sendo mais atingidas do que outras, seja por conta da estrutura hospitalar precária, pela sua estrutura de organização espacial ou por outros tipos de sistemas ineficientes que atuam de forma negativa para a contenção do vírus.

Mesmo com um grande número de infectados, percebe-se que, no cenário brasileiro, em um primeiro momento, existiu uma subnotificação dos casos, gerada, principalmente, por escassez de testes, em que os pacientes com sintomas mais graves eram priorizados em detrimento aos outros. Além disso, indivíduos assintomáticos passaram despercebidos pela contabilização oficial dos casos (OLIVEIRA; ARAÚJO, 2020).

Segundo Oliveira *et al.* (2020), para tentar conter o avanço da doença, a maior parte dos países do mundo decidiu restringir as atividades usuais, através de um isolamento que visou limitar o acesso a escolas, universidades, transporte público, locais de trabalho e outros diversos locais. Kosfeld *et al.* (2021) estudaram os efeitos das principais tentativas de contenção do vírus na Alemanha e concluíram que as restrições de contato foram as maiores responsáveis pela minimização da taxa de incidência de casos de Covid-19 no país, seguidas do uso de máscaras e do fechamento de escolas e creches.

Esse isolamento social fez com que os diversos setores se adaptassem à nova realidade, através do desenvolvimento de atividades de maneira remota. Efeitos positivos foram advindos dessa restrição de mobilidade, mas eles não foram suficientes para controlar totalmente os casos, além de trazer consigo consequências como a demissão em massa, aumento de casos depressivos e fechamento de alguns estabelecimentos menores, devido à falta de recursos para se manterem operantes. O grupo que foi o principal alvo da restrição foi o dos idosos, dado que são os mais vulneráveis ao vírus (MENDES *et al.*, 2020; MORAES, 2020; OLIVEIRA *et al.*, 2020).

Além de todo o contexto de gravidade da doença, segundo Sousa (2021), alguns discursos negacionistas acerca do vírus, no Brasil, acabaram influenciando uma parte dos indivíduos a recusar certas medidas preventivas. Isso pode ter levado ao aumento ainda mais drástico de casos de infecção e óbitos por Covid-19.

Esforços para conter o vírus e suas variantes, como a alfa e a delta, foram realizados, onde é possível observar a criação de vacinas como a Comirnaty, AZD1222 e Coronavac. A indicação é o uso de duas doses somadas a uma dose de reforço (3ª dose), que são capazes de reduzir em mais de 90% as infecções por Covid-19 (BERNAL *et al.*, 2021; SILVA *et al.*, 2022).

No período de pandemia, um dos ambientes considerados de maior risco de propagação do vírus é o transporte coletivo, devido a fatores como falta de higienização constante e aglomerações. Em 2020, houve uma redução na taxa de utilização desse modal de mais de 75% dos passageiros, devido a sensação de insegurança dos indivíduos com a doença e a redução da frota de veículos nas estradas (LIMA *et al.*, 2020).

As cidades espraiadas, por terem um quantitativo menor de indivíduos por Km^2, e por possuir um sistema de transporte público relativamente ineficiente ou até mesmo inexistente, levando os moradores a utilizar transportes individuais, apresenta a tendência de obter menores números de infectados por esse vírus. Leiva *et al.* (2020) constata que

cidades espraiadas, como o caso de Los Angeles, tiveram ritmos de contaminação mais desacelerados, comparativamente com as cidades compactas, como Nova York.

Mesquita *et al.* (2021) ressaltam que aspectos socioeconômicos dos domicílios também estão associados com a maneira de propagação da Covid-19. Dessa forma, mesmo que se tenha uma densidade populacional baixa, o modelo espraiado de cidade apresenta problemas de maior desigualdade social e precariedade econômica. Logo, os indivíduos em famílias de menores rendimentos são os mais expostos ao vírus, nestes locais, pois, de maneira geral, não possuem transporte individual para locomoção, as condições de moradias são precárias e existe uma prevalência de domicílios com mais de uma família.

As cidades compactas, por possuírem um maior número de habitantes por Km^2, enfrentaram dificuldades no uso das medidas preventivas ao vírus da Covid-19. Isso acontece, pois nestas localidades as residências são mais próximas e o uso do transporte coletivo é mais intenso, levando a uma maior aglomeração de indivíduos em um mesmo local, o que facilita a disseminação do vírus (OECD, 2020).

Yücel et al. (2023), em seu estudo conduzido na região metropolitana de São Paulo, evidenciam que locais que possuem uma maior centralidade apresentam uma menor resposta a políticas governamentais que visem atrasar as infecções por Covid-19, visto que estes locais são ou estão mais próximos das regiões mais acometidas pelo vírus. Assim, os efeitos da centralidade da rede urbana conseguem superar efeitos de influência de fatores socioeconômicos e de desigualdade de isolamento dos indivíduos.

Não obstante, a qualidade de vida, nestes locais, mesmo em tempos de pandemia, acaba sendo maior devido a sistemas mais eficientes de saúde e a capacidade de integração entre as regiões metropolitanas e periféricas, ganhos de aglomeração que ocorrem através de um processo de difusão de novas ideias e da redução nos custos de transportes destes locais. Dessa maneira, ainda que haja uma tendência maior de infecção, os indivíduos têm maiores chances de se curar da Covid-19 com menores ou até mesmo sem sequelas (SALES, 2020; MARSHALL, 1985).

Logo, regiões economicamente grandes, ricas, acessíveis e densas possuem maior predisposição a uma maior incidência de Covid-19, além disso, locais que possuem uma boa eficácia governamental tendem a reagir mais rápido às ondas da Covid. Por outro lado, em locais com sistemas de saúde mais defasados e uma gestão governamental fraca

a taxa de mortalidade tende a ser mais alta (RODRÍGUEZ-POSE; BURLINA, 2021; MATAMOROS *et al.*, 2021).

Dessa maneira, Hamidi *et al.* (2020) evidenciam que, em cidades compactas, a taxa de infectados por Covid-19 tende a ser maior, e a taxa de mortalidade menor, devido a uma melhor infraestrutura nos serviços de saúde. Isso se dá pelo fato de a cidade compacta possuir mais infraestrutura, como mencionado anteriormente.

2.4 Acesso a oportunidades e os modelos de cidades

O acesso a oportunidades é um importante mecanismo para análise, quando se estuda, por exemplo, a exclusão social. Indivíduos que residem mais próximos de seu trabalho, hospitais e escolas, tendem a possuir um maior nível de acessibilidade local, seja por proximidade ou pela facilidade de acesso aos sistemas de transporte existentes na localidade (SCOTT; HORNER, 2008). Assim, o nível de acesso aos locais é um indicador para a organização de uma cidade, visto que uma maior interligação do sistema de transportes, maior densidade de oportunidades no local e menor tempo de deslocamento são características intrínsecas ao modelo compacto de cidades (PEREIRA *et al.*, 2020a; SATHLER; LEIVA *et al.*, 2022).

A necessidade de realizar deslocamentos diários está presente na vida da maior parte dos indivíduos. A maneira como esse movimento é realizado depende de características individuais, familiares e urbanas. Desse modo, a mobilidade urbana é caracterizada como a capacidade de deslocamento das pessoas dentro de um espaço urbano (RODRIGUES, 2016).

No Brasil é notado um forte crescimento do uso de transportes individuais em detrimento ao transporte coletivo rodoviário (ônibus). Este aumento do quantitativo de veículos automotores traz consigo externalidades negativas, como engarrafamento, emissão de poluentes e uma piora no mecanismo de mobilidade urbana (CARVALHO, 2016). O maior uso de automóveis está relacionado à dispersas atividades na localidade, principalmente na estrutura urbana espraiada, visto que existe uma maior distância a ser percorrida para o alcance do destino final. Esta questão piora a dinâmica de acessibilidade urbana, principalmente, para quem depende de transporte coletivo, em geral, a parcela da população mais vulnerável economicamente (GOMIDE, 2006).

Assim, o acesso à saúde, educação e trabalho são influenciados diretamente pelo padrão de mobilidade local. No Brasil a condição deste acesso a oportunidades é limitada

e segregada por fatores como raça e renda. Indivíduos mais ricos e de cor branca possuem, em média, um melhor acesso a oportunidades que indivíduos pobres e de cor negra, independentemente do transporte utilizado por eles (PEREIRA *et al.*, 2020a).

A intensificação do uso de automóveis e motocicletas, além de levar a um maior tempo de deslocamento casa-trabalho, faz com que haja uma redução de demanda pelo sistema de transporte público coletivo. Isso leva a uma pressão nos preços deste modal para cima e prejudica, ainda mais, a situação dos indivíduos de menor renda. Políticas de transporte que visem aumento da capacidade de frota para redução do tempo para o acesso as oportunidades não são tão eficazes e não podem ser utilizadas a longo prazo, pois seus efeitos positivos possuem uma duração limitada, ou seja, se dissipam com o tempo (PEREIRA *et al.*, 2021; PEREIRA; SCHWANEN, 2013).

Há uma visível lacuna na literatura sobre a discussão de como o acesso a oportunidades está relacionado aos modelos teóricos de cidades. Nesse contexto, este estudo avança em relação ao que foi exposto, trazendo novos dados para o Brasil em um nível de desagregação territorial menor, utilizando os municípios, bem como incorporando variáveis que ainda não foram analisadas de maneira conjunta para o país.

3 ESTRATÉGIA EMPÍRICA

A estratégia empírica compreende duas etapas. Primeiro, é realizada uma análise, utilizando um modelo de equações estruturais (MEE), para investigar a relação direta e indireta entre variáveis econômicas, demográficas, sociais, espaciais e número de infectados e óbitos por Covid-19. No referido procedimento a tipologia de cidades é captada através de uma *proxy*, especificamente a variável *dummy* de hierarquia urbana. Avançando em relação à primeira abordagem, é utilizado o modelo de múltiplos indicadores e múltiplas causas (MIMIC) para compreender a relação entre um indicador latente de compacidade urbana e o número de infectados e óbitos por Covid-19. Nesta seção são apresentadas as bases de dados utilizadas, bem como a estratégia de tratamento destes dados, e a metodologia empregada.

3.1 Dados e definição de variáveis

As informações utilizadas são extraídas das Estimativas da População e do Censo Demográfico de 2010 do Instituto Brasileiro de Geografia e Estatística (IBGE), do Programa das Nações Unidas para o Desenvolvimento (PNUD), do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa do Observatório do Clima (OC), da Relação Anual de Informações Sociais (RAIS), da pesquisa Regiões de Influência das Cidades (REGIC), do Cadastro Nacional de Estabelecimentos de Saúde (CNES), do Censo Escolar do Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira (INEP), da Empresa Brasileira de Pesquisa Agropecuária (EMBRAPA) e do Portal Covid do Ministério da Saúde (MS).

O recorte geográfico de análise é o Brasil urbano, e as unidades territoriais examinadas são os municípios, visto que este é o nível mais desagregado para as informações de densidade e infecções por Covid-19. Vale ressaltar que dos 5.570 municípios brasileiros são utilizados 4.855, devido a existência de informações faltantes[5] na base de dados da REGIC e do Portal Covid (MS). A Tabela 1 apresenta um resumo das variáveis utilizadas no presente estudo, bem como a fundamentação teórica para o uso de cada variável.

[5] Informações faltantes para municípios aleatórios, não caracterizando a existência de um padrão de *missings*.

Tabela 1 - Descrição das variáveis analisadas

Variáveis de resultado				
Variável	**Descrição da variável**	**Ano**	**Base de dados**	**Fonte**
ln_txinfec	Logaritmo natural da taxa de infectados por 100 mil habitantes	2020	Ministério da Saúde (2020)	Hamidi *et al.* (2020)
ln_txobito	Logaritmo natural da taxa de óbitos por 100 mil habitantes	2020		
Variáveis explicativas				
Variável	**Descrição da variável**	**Ano**	**Base de dados**	**Fonte**
ln_popurb	Logaritmo natural da população urbana	2010	PNUD (2010)	Barbosa *et al*. (2022)
densR	Densidade Residencial: $densR = \frac{nº\ de\ Dom.Particular\ Perm.}{Área\ Urbana}$	2020	IBGE (2020)	Santos *et al.* (2022)
densA	Densidade de Atividade: $densA = \frac{Qtd.de\ Vínculos\ Ativos}{Área\ Urbana}$	2020	RAIS (2020)	Hamidi *et al.* (2020)
densES	Densidade de Estabelecimentos de Saúde: $densES = \frac{nº\ de\ Estab.Saúde}{Área\ Urbana}$	2022	CNES (2022)	Pereira *et al.* (2020a)

densEE	Densidade de Estabelecimentos de Educação: $densEE = \frac{nº\ de\ Estab.\ Educ.}{Área\ Urbana}$	2021	Censo Escolar (2021)	Pereira *et al.* (2020a)
mob_pend	Fluxo de Mobilidade Pendular Intermunicipal (fluxo de saída)	2010	IBGE (2010)	Ciriaco e Lima (2021).
hierarquia_simpl	*Dummy* de hierarquia urbana, que capta a centralidade do local: 1 – se é metrópole ou capital regional; 0 – se é centro sub-regional, centro de zona ou centro local	2018	REGIC (2018)	Loureiro *et al.* (2016)
emissão_pcp	Emissão Municipal Per Capita de CO_2: $emissao_pcp = \frac{emissao\ total\ de\ CO_2}{População\ Urbana}$	2019	SEEG-OC (2019)	Massuga *et. al.* (2022)
gini	Coeficiente de Gini	2010		Sathler e Leiva (2022)
prop_pob	Proporção de indivíduos que recebiam até R$140,00 em 2010	2010	PNUD (2010)	Anunciato e Franco (2017)
prop_idosos	Proporção da população acima de 60 anos	2010		Hamidi *et al.* (2020)

Fonte: Elaboração própria. Nota: Para construção dos indicadores de densidade são utilizadas as a áreas urbanas dos municípios em 2015, tal informação é extraída no portal da EMBRAPA.

Especificamente, como variáveis de resultado são utilizados o logaritmo natural da taxa de infecção (casos confirmados por 100 mil habitantes até a data de referência) e da taxa de óbitos (casos confirmados por 100 mil habitantes até a data de referência), ambas retiradas do Portal Covid do Ministério da Saúde. É importante salientar que nestes dados de casos acumulados, existe uma subnotificação no número de infectados por Covid-19, devido à escassez de testes de diagnóstico e ausência de sintomas por parte de alguns indivíduos.

A confirmação da infecção se dá quando o indivíduo testa positivo, utilizando um teste que passa por um profissional de saúde. O número de óbitos reflete o número de mortes reportadas pelas secretarias de saúde na data em que tiveram a confirmação laboratorial ou clínico epidemiológica (MINISTÉRIO DA SAÚDE, 2020). Ambas as variáveis foram transformadas em logaritmo para torná-las mais próximas de distribuições normais, dado que variam exponencialmente com histogramas altamente assimétricos (HAMIDI, 2020).

A data de referência para captar os casos acumulados de infecção e de mortalidade da Covid-19 é 16/01/2021. A despeito de não haver uma justificativa específica para tal seleção, optou-se por uma data que antecede o início da vacinação no Brasil (MINISTÉRIO DA SAÚDE, 2020). Tal procedimento tem o propósito de evitar os efeitos das heterogeneidades territoriais na distribuição da vacina, e captar os reais desdobramentos do vírus sem o devido controle vacinal.

As variáveis socioeconômicas de proporção de indivíduos pobres[6], coeficiente de Gini, população urbana[7] e a proporção de indivíduos idosos (maiores de 60 anos de idade) são extraídas da base de dados municipal do Programa das Nações Unidas para o Desenvolvimento (PNUD). Através das informações municipais do nível total de emissão bruta de CO_2 em toneladas, retiradas do Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG) do Observatório do Clima (OC), foi criado um indicador de emissão per capita de CO_2, *emissão*_pcp, levando em consideração a população urbana dos municípios. A variável é normalizada, ficando em uma escala de 0 a 1, onde 0 é o menor valor e 1 é o maior. Esta variável é utilizada para captar o nível de sustentabilidade municipal.

[6] Proporção de indivíduos com renda domiciliar *per capita* igual ou inferior a R$ 140,00 mensais.
[7] Quantitativo de indivíduos que residem em área urbana. Neste estudo a referida variável é utilizada em logaritmo natural.

A variável de mobilidade, *mob_pend*, construída com os microdados do Censo Demográfico de 2010, capta os movimentos pendulares intermunicipais por motivo de trabalho, identificando precisamente o fluxo de indivíduos que residem em um município e fazem o deslocamento por motivo de trabalho para outro município (fluxo de saída). Toda análise é conduzida com o indicador normalizado, em uma escala entre 0 e 1.

Da pesquisa REGIC mais recente, de 2018, é retirada a variável de hierarquia urbana (VAR09). Simões e Amaral (2011) mostram que a definição utilizada na pesquisa REGIC para caracterizar os níveis de hierarquia urbana leva em consideração, não apenas a classificação dos centros de gestão de territórios, mas também a dimensão da região e sua influência. Dessa maneira, as hierarquias urbanas compreendem cinco grandes níveis: (1) metrópoles, (2) capital regional, (3) centro sub-regional, (4) centro de zona, e (5) centro local.

As metrópoles são compostas pelos 15 principais centros que exercem influência sobre todos os municípios brasileiros. As capitais regionais são os 97 centros que possuem atividades de gestão altamente concentradas, mas com menor alcance que as metrópoles. Os centros sub-regionais são formados por 352 localidades com sistemas de gestão com menor complexidade, menor área de influência e menor porte populacional que as capitais regionais. Os centros de zona são compostos por 398 cidades que apresentam média populacional de 30 mil habitantes e possuem poucas cidades vizinhas, em relação às anteriores, devido a uma baixa atividade de gestão. Por fim, os centros locais, compostos por 4.037 municípios, não são o destino principal de nenhuma outra cidade e sua influência é exercida apenas nos limites de seus territórios, apresentando fraca centralidade de gestão pública e de atividades empresariais (IBGE, 2020).

Segundo os dados do IBGE (2020), os arranjos populacionais[8] de São Paulo/SP, Rio de Janeiro/RJ e Recife/PE são exemplos de metrópoles. Dentre as capitais regionais encontram-se os arranjos populacionais de João Pessoa/PB, Londrina/PR e Macapá/AP. Fazem parte dos centros sub-regionais os municípios de Três Lagoas/MS e Goiana/PE e o arranjo populacional de Catalão/GO. Quanto aos centros de zona, pode-se exemplificar os municípios de Campos do Jordão/SP, Petrolândia/PE e São Francisco do Sul/SC. Por fim, tem-se os municípios de Santa Bárbara/BA, Farias Brito/CE e Porto Vera Cruz/RS como exemplos de centros locais.

[8] Arranjos populacionais são agrupamentos de dois ou mais municípios que apresentam integração populacional entre eles, seja devido a contiguidade entre manchas urbanas ou aos movimentos pendulares.

Neste estudo, seguindo Loureiro *et al.* (2016), é realizada uma simplificação do indicador de hierarquia urbana, tornando-o uma variável binária que assume valor 1 quando o município está na categoria de metrópole (1) ou de capital regional (2), e assume o valor 0 se ele está inserido nas demais categorias. Espera-se que a *dummy* de hierarquia urbana capte a centralidade dos locais, dado que quanto maior o nível de hierarquia urbana, maior é a oferta de serviços de alta complexidade, a rede urbana é mais densa e complexa e o acesso a oportunidades é facilitado, ou seja, o local tende a ser mais compacto (CHRISTALLER, 1966; MOURA *et al.*, 2021).

Ademais, quatro variáveis de densidades são investigadas, sendo elas: a densidade residencial, que mede o número de domicílios particulares permanentes por quilômetros quadrado da área urbana do município; a densidade de estabelecimentos de saúde, que refere-se ao número de estabelecimentos de saúde por quilômetros quadrado da área urbana do município; a densidade de atividade, que evidencia o número de empregos por quilômetros quadrado da área urbana do município; e a densidade de estabelecimentos de educação, que mede o número de estabelecimentos de educação por quilômetros quadrado no município da área urbana do município. As áreas urbanas foram utilizadas para evitar distorções nos indicadores de densidade, pois existem municípios que são extensos e possuem uma área urbana pequena, como é o caso de Altamira-PA.

As variáveis de densidades ponderam as questões associadas ao desigual acesso a oportunidades de trabalho, saúde e educação nos municípios brasileiros. Pereira *et al.* (2020a) utilizaram as bases de dados de cada uma destas densidades para estimar matrizes de tempos de viagem para as 21 maiores cidades brasileiras, como não é possível calcular essas matrizes para os municípios, optou-se por utilizar as densidades de cada uma das oportunidades como uma *proxy* que capta a acessibilidade para estes locais.

A densidade residencial é utilizada nos modelos, pois ela causa impactos na mobilidade urbana, principalmente nos deslocamentos casa-trabalho, na configuração espacial da localidade, visto que uma das principais características de um local compacto é a alta densidade residencial e ainda nas infecções, pois esta variável evidencia, de certa forma, uma aproximação entre os indivíduos (NEUMAN, 2005; RODRIGUES, 2016; LEIVA *et al.*, 2020).

3.2 Metodologia

Esta subseção é fundamentada nos estudos de Bollen (1989), Kline (2011), Macana e Comim (2016) e Hamidi *et al*. (2020), que fazem o uso da modelagem de equações estruturais. Os modelos de equações estruturais (MEE), no inglês, *structural equation modeling* (SEM), consistem em uma técnica estatística multivariada de corte transversal muito utilizada nas mais diversas áreas da pesquisa científica. A visualização de um modelo de equações estruturais se dá através de um diagrama de trajetórias, sendo representado por meio de uma série de equações matriciais (NEVES, 2018). No presente estudo, tal procedimento metodológico é utilizado para analisar os processos que influenciam na disseminação e nas mortes por Covid-19, e como o avanço da doença esteve interligado com a estrutura de organização espacial das cidades no Brasil.

A estimação de modelos de equações estruturais envolve a resolução de um conjunto de equações, em que existe uma equação para cada variável de resultado (endógena) do sistema que afetam e são afetadas por outras variáveis. As variáveis que são apenas preditoras de outras são denominadas influências (ou variáveis exógenas), as quais podem estar correlacionadas entre si, mas são determinadas fora do sistema (EWING; HAMIDI, 2014). Dessa maneira, o MEE pode ser representado da seguinte forma:

$$\boldsymbol{Y} = \boldsymbol{BY} + \boldsymbol{\Gamma X} + \boldsymbol{\alpha} + \zeta \tag{1}$$

Onde $\boldsymbol{X}$ é o vetor de todas variáveis exógenas, $\boldsymbol{Y}$ é o vetor de todas as variáveis endógenas, $\boldsymbol{B} = [\beta_{ij}]$ é a matriz dos coeficientes das variáveis endógenas, $\boldsymbol{\Gamma} = \left[\gamma_{ij}\right]$ é a matriz dos coeficientes das variáveis exógenas, $\boldsymbol{\alpha} = [\alpha_i]$ é o vetor de interceptos e ζ é o termo de erro com média zero e $Cov(\boldsymbol{X}, \zeta) = 0$. Assumindo que,

$$\begin{aligned} \boldsymbol{k} &= \left[k_j\right] = E(\boldsymbol{X}) \\ \Phi &= \left[\phi_{ij}\right] = VAR(\boldsymbol{X}) \\ \boldsymbol{\Psi} &= \left[\psi_{ij}\right] = VAR(\zeta) \end{aligned} \tag{2}$$

Então a esperança da variável endógena é

$$\boldsymbol{\mu_Y} = E(\boldsymbol{Y}) = (\boldsymbol{I} - \boldsymbol{B})^{-1}(\boldsymbol{\Gamma k} + \boldsymbol{\alpha}) \tag{3}$$

Onde o I é a matriz identidade. Como o método de estimação utilizado nesta modelagem faz uso da matriz de variância, é necessário, especificá-la, logo:

A matriz de variância das variáveis endógenas é:

$$\boldsymbol{\Sigma_{YY}} = Var(\boldsymbol{Y}) = (\boldsymbol{I} - \boldsymbol{B})^{-1}(\boldsymbol{\Gamma}\Phi\boldsymbol{\Gamma}' + \boldsymbol{\Psi})\{(\boldsymbol{I} - \boldsymbol{B})^{-1}\}' \quad (4)$$

A matriz de covariância entre as variáveis endógenas e exógenas é expressa por

$$\boldsymbol{\Sigma_{YX}} = Cov(\boldsymbol{Y}, \boldsymbol{X}) = (\boldsymbol{I} - \boldsymbol{B})^{-1}\boldsymbol{\Gamma}\Phi \quad (5)$$

Seja **Z** o vetor de todas as variáveis

$$\boldsymbol{Z} = \begin{pmatrix} \boldsymbol{Y} \\ \boldsymbol{X} \end{pmatrix} \quad (6)$$

Então a esperança de Z é dada por

$$\boldsymbol{\mu} = E(\boldsymbol{Z}) = \begin{pmatrix} \boldsymbol{\mu}_Y \\ \boldsymbol{k} \end{pmatrix} \quad (7)$$

A matriz de variância do modelo é dada por

$$\boldsymbol{\Sigma} = Var(\boldsymbol{Z}) = \begin{pmatrix} \boldsymbol{\Sigma}_{YY} & \boldsymbol{\Sigma}_{YX} \\ \boldsymbol{\Sigma}'_{YX} & \Phi \end{pmatrix} \quad (8)$$

Além da matriz de variância, o método de estimação utiliza a matriz de variância amostral. Logo, seja z_t o vetor de todas as variáveis observadas para a t-ésima observação

$$z_t = \begin{pmatrix} y_t \\ x_t \end{pmatrix} \quad (9)$$

Seja w_t o valor do peso correspondente, onde $t = 1, \ldots, N$ municípios. Se nenhum peso for especificado, então $w_t = 1$. Seja $w_{\cdot}$ a soma dos pesos, então o vetor amostral é

$$\bar{z} = \frac{1}{w_{\cdot}} \sum_{i=1}^{N} w_i z_i \quad (10)$$

Então, a matriz de variância amostral é dada por

$$\boldsymbol{S} = \frac{1}{w_{\cdot} - 1} \sum_{t=1}^{N} w_t (z_t - \bar{z})(z_t - \bar{z})' \quad (11)$$

Segundo Kline (2011), a modelagem de equações estruturais tem por padrão a estimação por máxima verossimilhança (ML), que assume distribuição normal para todas as variáveis endógenas existentes no modelo. Seja $\boldsymbol{\theta}$ o vetor de parâmetros únicos do modelo, tal que

$$\boldsymbol{\theta} = \begin{pmatrix} vec(\boldsymbol{B}) \\ vec(\boldsymbol{\Gamma}) \\ vech(\boldsymbol{\Psi}) \\ vech(\Phi) \\ \boldsymbol{\alpha} \\ \boldsymbol{k} \end{pmatrix} \tag{12}$$

Na Equação (12) acima, $vec(\cdot)$ retorna a variável transformada em um vetor coluna com uma coluna empilhada sobre outra, e o $vech(\cdot)$ retorna a matriz quadrada e tipicamente simétrica da variável transformada em um vetor coluna (apenas a metade inferior da matriz é registrada). Então, sob a suposição da distribuição normal, a função de log-verossimilhança geral para $\boldsymbol{\theta}$ a ser maximizada é

$$logL(\boldsymbol{\theta}) = -\frac{w_.}{2}[k\ log(2\pi) + log\ \{det\ (\boldsymbol{\Sigma}_0)\} + tr(\boldsymbol{D}\boldsymbol{\Sigma}_0^{-1})] \tag{13}$$

onde $\boldsymbol{\Sigma}_0$ é a submatriz de $\boldsymbol{\Sigma}$ correspondente às variáveis observadas, tr é o traço da matriz e

$$\boldsymbol{D} = \int \boldsymbol{S} + (\bar{z} - \boldsymbol{\mu}_0)\ (\bar{z} - \boldsymbol{\mu}_0)' \tag{14}$$

Em que:

$$\int = \begin{cases} 1, se\ a\ variância\ amostral\ \text{é}\ especificada \\ \dfrac{w_. - 1}{w_.}, caso\ contrário. \end{cases} \tag{15}$$

Vale destacar que o termo μ_0 é um subvetor de $\boldsymbol{\mu}$ correspondente às variáveis observadas. Como as variáveis examinadas no presente estudo não passaram no teste de

normalidade de Kolmogorov-Smirnov[9], logo optou-se por utilizar o método de estimação máxima pseudo-verossimilhança, que retira a obrigatoriedade deste pressuposto, tornando o modelo viável (KLINE, 2011; MACANA; COMIM, 2016).

O diagrama 1, apresenta o diagrama do caminho relacional para as variáveis dependentes do MEE, a citar, infecção e mortalidade por Covid-19[10]. Este diagrama apresenta a relação de cada uma das variáveis exógenas com as variáveis endógenas do modelo. O referido modelo é utilizado, pois permite compreender a relação entre variáveis sociais, demográficas, econômicas e espaciais com a taxa de infecção e mortalidade por Covid-19 e observar as relações diretas e indiretas de cada variável no contexto do estudo.

Diagrama 1 - Diagrama de caminho relacional entre as variáveis endógenas e exógenas

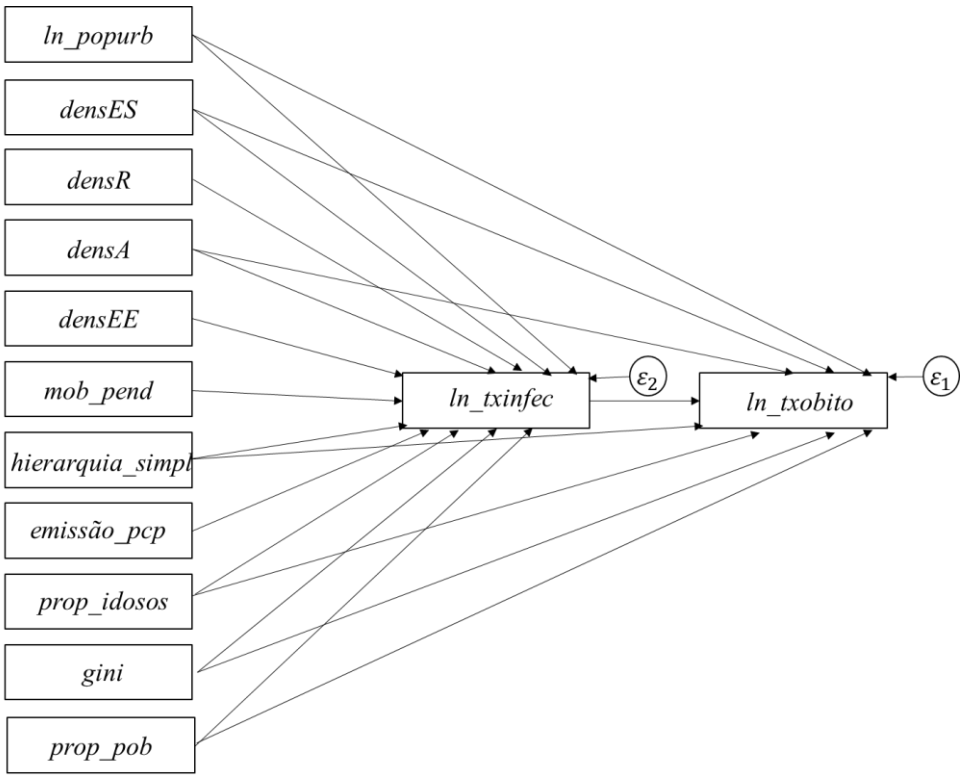

Fonte: Elaboração própria, com base em Hamidi *et al.* (2020).

Uma limitação do modelo proposto, em termos teóricos, é que não há uma construção que consiga relacionar, de forma mais objetiva e precisa, a relação entre a

[9] Neste teste, quando o p-valor é significante rejeita-se o pressuposto de normalidade da variável. Para a variável de infectados o p-valor = 0,004 e para a variável de óbitos o p-valor = 0,000. Dessa forma, entende-se que as variáveis endógenas do modelo não apresentam distribuição normal (CONOVER, 1999).

[10] Para informações mais detalhadas sobre as variáveis de influência ver a Tabela 1.

organização dos municípios, evidenciada pela tipologia de cidades, e as taxas de infecções e mortalidades por Covid-19. Em outras palavras, a despeito da *dummy* de hierarquia urbana tentar captar o nível de compacidade urbana, sabe-se que existem outros aspectos, não ponderados no nível de hierarquia, que são fundamentais para caracterizar as cidades compactas, tais como sustentabilidade, acesso a oportunidades e maior nível de interações econômicas (BREHENY, 1992; *JENKS et al.*, 1996; *NEUMAN*, 2005).

Dessa forma, para avançar na análise, são utilizados os modelos de múltiplos indicadores e múltiplas causas, desenvolvido por Joreskog e Goldberger (1975). O MIMIC pertence a uma espécie de modelo de equações estruturais. Na presente pesquisa, o referido modelo permite captar o nível de compacidade urbana, constituindo uma variável latente, que representa um construto comum de um conjunto de indicadores observáveis.

O modelo MIMIC é composto de duas etapas, com dois tipos de modelos diferentes (JORESKOG; GOLDBERGER, 1975):

(i) um modelo estrutural que mostra a relação entre a variável latente $\boldsymbol{\eta}$ e as variáveis exógenas observáveis $\boldsymbol{\chi}$. No presente estudo, a variável latente $\boldsymbol{\eta}$ refere-se ao nível de compacidade urbana que é determinada pelo conjunto de variáveis exógenas $\boldsymbol{\chi}(j = 1, \ldots, J)$:

$$\boldsymbol{\eta} = \gamma_1\chi_1 + \ldots + \gamma_J\chi_J + \epsilon \text{ (equação estrutural)} \quad (16)$$

(ii) um modelo de mensuração, em que a variável latente é um construto medido por indicadores observáveis e que determina linearmente cada um dos indicadores. Assim, $\boldsymbol{y_i}(i = 1, \ldots, m)$ é o vetor de indicadores observáveis, a citar, nesta análise, infecção e mortalidade da Covid-19 associados com o nível de compacidade urbana $\boldsymbol{\eta}$.

$$\boldsymbol{y_m} = \lambda_m\boldsymbol{\eta} + \mu_m \text{ (modelo de mensuração)} \quad (17)$$

Substituindo $\boldsymbol{\eta}$, de acordo com a equação estrutural, no modelo de mensuração,

$$\boldsymbol{y_m} = \lambda_m(\gamma_1\chi_1 + \ldots + \gamma_J\chi_J + \epsilon) + \mu_m \quad (18)$$

Reescrevendo os vetores referentes às equações (16) e (18), obtém-se:

$$\boldsymbol{\eta} = \gamma'\boldsymbol{\chi} + \epsilon \quad (19)$$

$$\boldsymbol{y} = \lambda'\boldsymbol{\eta} + \mu \tag{20}$$

Tal que,

$$E(\epsilon\mu') = 0, E(\epsilon^2) = \boldsymbol{\sigma}^2, E(\mu\mu') = \boldsymbol{\Theta}^2 \tag{21}$$

Onde **Θ** é a matriz diagonal m x m com $\boldsymbol{\theta}$ sendo o vetor de desvios padrões de μ em sua diagonal (JORESKOG; GOLDBERGER, 1975). Os termos de erro possuem distribuição normal e são mutuamente independentes, o que garante a qualidade dos resultados (BARBOSA, 2012).

Como o modelo de múltiplos indicadores e múltiplas causas está dividido em dois processos, sendo **η** latente, é necessário unir as Equações (19) e (20) para a estimação dos coeficientes do modelo. Os parâmetros devem ser estimados utilizando o elo entre variâncias e covariâncias das variáveis observáveis de causas e indicadores. Os coeficientes de regressão influenciam a variável não observável e, proporcionalmente, todos os indicadores. Essas relações são evidenciadas através de um sistema de três equações:

$$\begin{aligned} \boldsymbol{y_1} &= \lambda_1\boldsymbol{\eta} + \mu_1 \\ \boldsymbol{y_2} &= \lambda_2\boldsymbol{\eta} + \mu_2 \\ \boldsymbol{\eta} &= \gamma_1\chi_1 + \ldots + \gamma_J\chi_J + \epsilon \end{aligned} \tag{22}$$

Na Equação (22), y_1 e o y_2 são as taxas de óbitos e infecções, respectivamente. Os λ's são as cargas fatoriais usadas para estimar a variável latente de nível de compacidade urbana. Na equação estrutural $j = 11$ significa que o modelo estrutural apresenta 11 variáveis exógenas que determinam o nível de compacidade urbana. O diagrama 2 mostra esquematicamente a aplicação do modelo MIMIC no contexto do presente estudo.

Diagrama 2 - Modelo MIMIC para análise da relação entre a compacidade urbana e as taxas de infecção e mortalidade por Covid-19

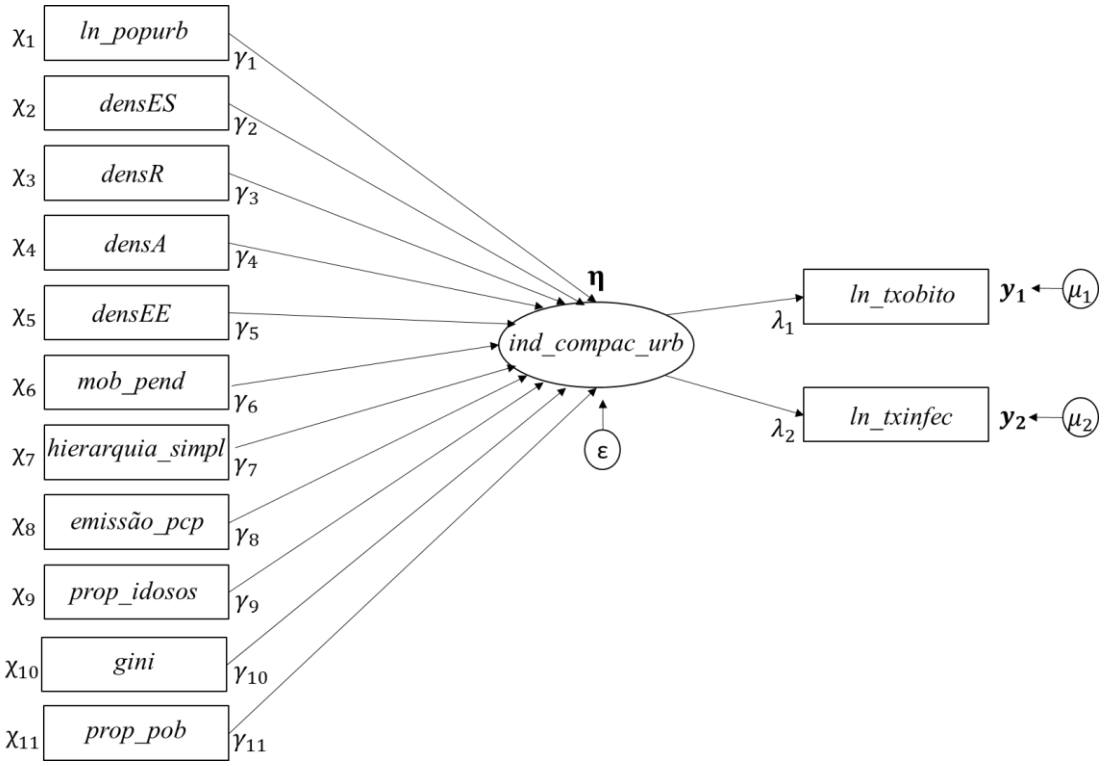

Fonte: Elaboração própria.

Após a especificação do modelo MIMIC é necessário que se avalie a sua propriedade de identificação que, segundo Oliveira (2016), é definida pelo grau de liberdade depois da especificação dos parâmetros a serem estimados. Desta maneira, faz-se necessário que duas condições sejam satisfeitas para garantir identificação dos modelos:

(i) O modelo deve ter no mínimo zero graus de liberdade ($df_M \geq 0$);

(ii) Deve ser atribuída uma escala métrica em toda variável latente (incluindo os resíduos).

Com relação ao item (i), o grau de liberdade é calculado por $df_M = p - q$, em que p evidencia o número de observações e q representa a quantidade de parâmetros estimados no modelo (MACANA, COMIM, 2016). É importante salientar que, nesta modelagem, o número de observações não é equivalente ao tamanho da amostra, visto que este dá a informação acerca do número de variâncias e covariâncias únicas. Assim, o número de observações é dado por $p = \frac{j(j+1)}{2}$, onde o j é o número de variáveis observadas existentes no modelo. Em relação ao número de parâmetros estimados, q,

este inclui os efeitos diretos de todas as variáveis, sejam elas endógenas ou exógenas, sobre as variáveis endógenas e as variâncias e covariâncias (BOLLEN, 1989; KLINE, 2011).

No modelo estimado (Diagrama 2), observa-se um $j = 13$ (11 variáveis exógenas e 2 variáveis endógenas), logo, o número de observações é $p = \frac{13(13+1)}{2} = 91$. Ademais, somando os 13 coeficientes estimados com as variâncias das duas variáveis endógenas e a variável latente, têm-se o número de parâmetros $q = 16$. Logo, o número de graus de liberdade existentes neste modelo é dado por $df_M = 91 - 16 = 75$. Portanto, o modelo é caracterizado como identificado (ou sobreidentificado), dado que possui uma maior quantidade de observações do que de parâmetros, ou seja, $df_M > 0$.

Referente ao item (ii), a escala métrica em toda variável latente se faz importante, pois os construtos latentes não possuem uma forma de medida específica; logo, é necessário estabelecer a escala métrica que pode ser satisfeita através de uma normalização que implica algumas restrições. A primeira restrição exige que todas as variáveis latentes exógenas possuam média zero; a segunda, exige que todas as variáveis latentes endógenas possuem intercepto igual a zero; por fim, a última restrição é a necessidade de fixar o coeficiente do efeito direto da variável latente sobre algum indicador endógeno observável, por padrão, o primeiro indicador especificado no modelo é a referência. Dessa maneira, a variável latente usará uma das variáveis endógenas como restrição, ou referência, e normalizará as outras com base nela. No caso deste estudo é fixada a taxa de infecções por Covid-19 e a taxa de óbitos a tomará como referência. (KLINE, 2011; MACANA; COMIM, 2016).

Após cumprir este processo de identificação, o modelo está pronto para ser estimado. Em termos de pós estimação, é utilizado o resíduo padronizado da raiz quadrada média (em inglês *standardized root mean square residual*, ou apenas SRMR) para medir a qualidade do ajuste dos modelos estimados. Este indicador mostra a diferença entre a covariância observada e a covariância prevista. Desse modo, ele consegue captar o grau de ajuste do modelo. Existem discussões acerca de um valor máximo para que o indicador apresente uma boa qualidade de ajustamento. Brown (2006) afirma que até 0,08 seria um valor aceitável, porém, para Chang *et al.* (2009) um SRMR acima de 0,05 já não é interessante.

O SRMR utiliza como base o primeiro e o segundo momento amostral, ou seja, ele caracteriza a tendência central e a dispersão de uma distribuição de probabilidades,

além de incluir as médias e variâncias de todas as variáveis observadas do modelo. Em outras palavras, ele é um índice da média dos resíduos padronizados entre a matriz de covariância observada e a esperada (HANCOCK; MUELLER, 2006; CANGUR; ERCAN, 2015). Nesse sentido, seja j o número de variáveis observadas no modelo, o SRMR é calculado da seguinte maneira:

$$SRMR = \left\{ \frac{2\sum_{l=1}^{j}(m_l^2 + \sum_{u \leq l} r_{lu}^2)}{j(j+3)G} \right\}^{\frac{1}{2}} \tag{23}$$

Na equação (23) acima, G é o número de grupos de parâmetros do modelo, r_{lu} é o resíduo padronizado da covariância entre a variável l e a u, e m_l é a média residual padronizada. Assim, r_{lu} e m_l são calculados, respectivamente, por:

$$r_{lu} = \frac{s_{lu}}{\sqrt{s_{ll}s_{uu}}} - \frac{\widehat{\sigma_{lu}}}{\sqrt{\widehat{\sigma_{ll}}\widehat{\sigma_{uu}}}} \tag{24}$$

$$m_l = \frac{\overline{z_l}}{\sqrt{s_{ll}}} - \frac{\widehat{\mu_l}}{\sqrt{\sigma_{ll}}}$$

Vale ressaltar, ainda, que os modelos são estimados com erros robustos a heterocedasticidade, e testes de fatores de inflação de variância (ou *Variance Inflation Factors*, isto é, VIF) são empregados para identificar se existe presença de multicolinearidade prejudicial as estimativas. Assim, segundo Gomes e Soares (2021), quando o VIF traz um resultado inferior a 10, é sinal que não existe sobreposição entre as variáveis independentes, em outras palavras, não existe o problema de multicolinearidade.

Devido ao uso de estimações por máxima verossimilhança, os modelos de equações estruturais, incluindo o de múltiplos indicadores e múltiplas causas, não precisam possuir termos de erros independentes, logo a endogenidade não é um problema. Esse tipo de caso, em que o pressuposto da independência dos erros não é uma obrigatoriedade, é o chamado de modelo não recursivo, e o oposto são os modelos recursivos (NEVES, 2018; KLINE, 2011).

4 RESULTADOS

Os resultados são apresentados em duas etapas. Inicialmente, investiga-se o processo de disseminação dos casos acumulados da Covid-19 no território brasileiro e as principais estatísticas descritivas. Na sequência, são apresentados e discutidos os resultados dos modelos empíricos.

4.1 Análise Descritiva

Nesta seção são analisadas a relação entre densidade de demográfica e a distribuição do número acumulado de infectados, as estatísticas descritivas das variáveis utilizadas nos modelos empíricos e a média da taxa de infecções e óbitos por 100 mil habitantes por classe de hierarquia urbana.

Analisando o quantitativo de infectados por Covid-19 no território brasileiro até janeiro de 2021 (Mapa 1), é notável que a região Sudeste apresentou o maior número acumulado de infectados. Tal fato ocorre, certamente, por o maior contingente populacional estar concentrado nessa região, onde existem, de acordo com as estimativas de população, 89.632.912 habitantes, concentrando cerca de 42% da população brasileira (IBGE, 2021). A região Norte, por sua vez, apresentou o menor número absoluto de infecções, certamente por se tratar da região com o menor quantitativo de pessoas, 18.906.962 habitantes, representando uma parcela de aproximadamente 9% da população brasileira.

Em termos relativos, a região Centro-Oeste obteve um maior percentual de infectados pela Covid-19 (5,62% da população). Já a região Sudeste retratou um menor percentual em relação às outras regiões (3,35% da população). Ainda no Mapa 1, é possível identificar a relação entre densidade populacional e número de infecções por Covid-19. Essa variável está presente em diversos estudos sendo apontada como grande determinante das infecções por Covid-19 no mundo (HAMIDI *et al.* 2020; LEIVA *et al.* 2020; BHADRA *et al.*, 2021).

Fica perceptível que o padrão alto-alto é mais encontrado nos municípios metropolitanos brasileiros situados próximos ao litoral. Os municípios na categoria de baixa densidade populacional e baixa disseminação não parecem ter um padrão de distribuição espacial bem definido, porém, no interior do país ele é mais evidente. Um padrão interessante é verificado na região Norte, em que existem locais que mesmo com uma baixa densidade populacional, tem um alto número de infectados, dentre eles,

observa-se em municípios localizados no norte do Pará e do Amapá e no sudeste de Rondônia, por exemplo.

Além disso, é possível observar que, no entorno dos municípios metropolitanos existem locais que possuem média densidade populacional, mas apresentam um baixo nível disseminação do vírus. Como exemplos, é possível citar o entorno da região metropolitana de São Paulo, Florianópolis e João Pessoa.

Mapa 1 - Distribuição espacial do número acumulado de infectados pela Covid-19 e densidade populacional

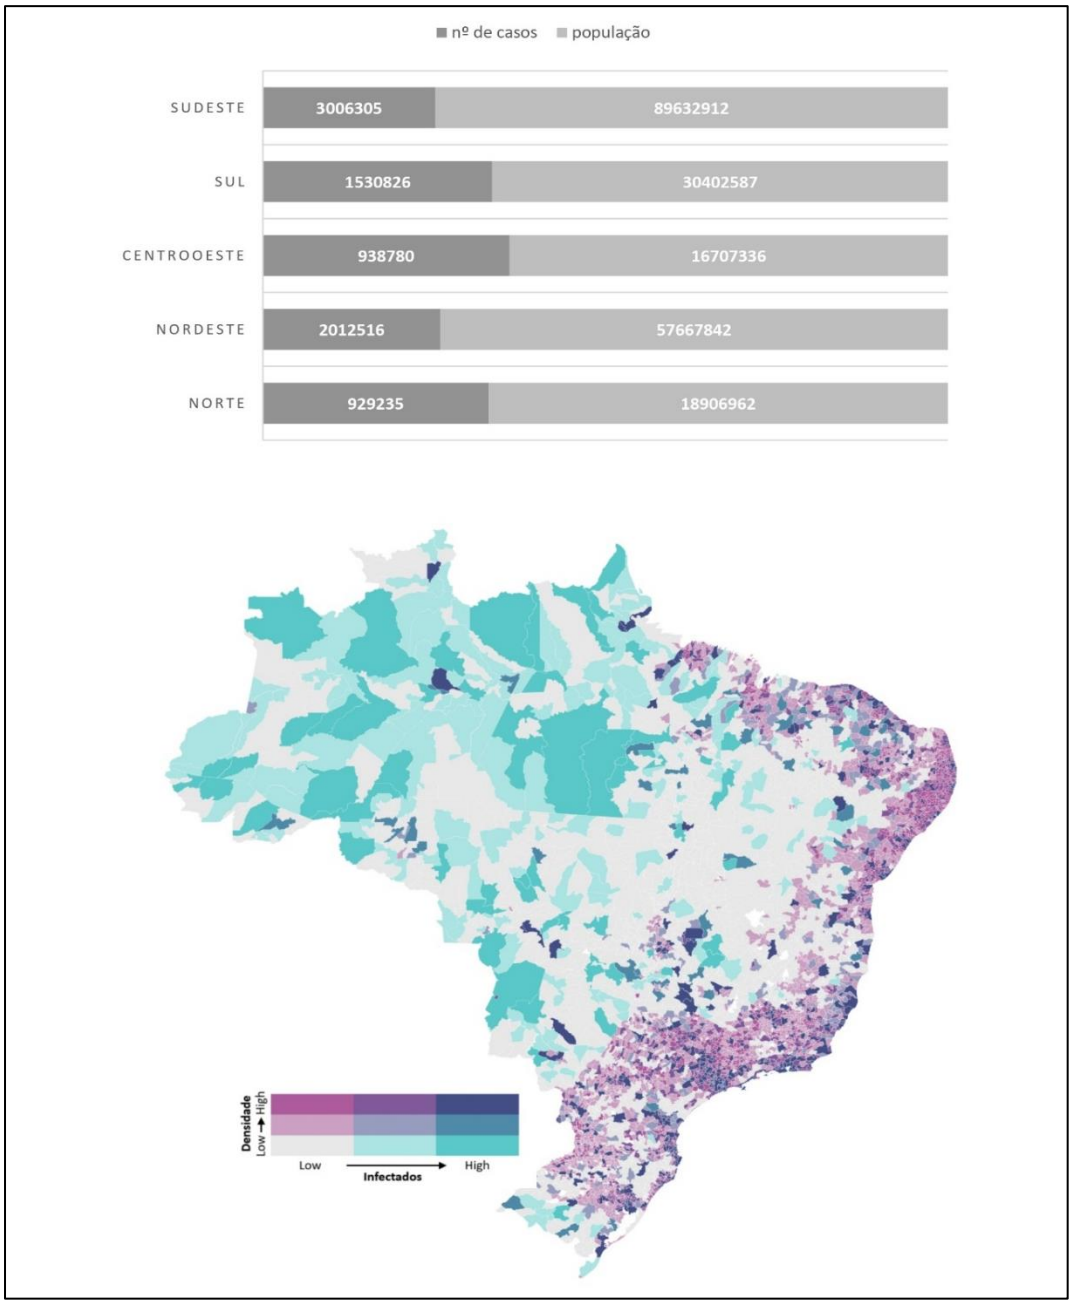

Fonte: Elaboração própria, através dos dados do Ministério da Saúde (dados de 16/01/2021) e do IBGE (2021). *Software* QGIS.

Dessa maneira, constata-se que existem diferenças regionais que podem estar relacionadas ao desigual número de infectados pela Covid-19 no Brasil. Wong e Li (2020) evidenciam que essas desigualdades regionais ditam a velocidade de infecção, pois localidades mais conectadas e compactas possuem números maiores de contaminações inicialmente e as mais afastadas e espraiadas apresentam essas contaminações posteriormente em uma escala menor. Compreender essas diferenças é fundamental no momento de estratégia de contenção de doenças, de maneira geral.

As estatísticas descritivas das variáveis utilizadas nos modelos constam na Tabela 2. Vale ressaltar que a partir desse ponto, as variáveis de disseminação e letalidade da Covid-19 são para data de referência de 16/01/2021, pelos motivos já expostos anteriormente. Na Tabela 2 observa-se que a média da taxa de infecções é mais alta que a da taxa de óbitos, conforme esperado, visto que grande parte dos infectados conseguem se recuperar após a contaminação. Quanto as densidades, observa-se que a densidade média de estabelecimentos de educação é maior que a dos estabelecimentos de saúde, o que evidencia maior presença de instituições educacionais em detrimento às de se saúde nos municípios brasileiros.

Tabela 2 - Estatísticas descritivas das variáveis do modelo

Variável	**Média**	**Desvio Padrão**	**Mínimo**	**Máximo**
ln_txinfec	5,7542	0,6730	2,1913	7,9361
ln_txobito	1,7637	0,7119	-1,1897	3,5395
ln_popurb	9,0743	1,3190	5,3566	16,2272
densES	6,6196	5,0501	0,1868	104,3771
densR	1336,8450	1016,7400	77,3748	27682,6900
densA	546,9462	418,5968	4,7436	6754,5480
densEE	9,1814	12,1461	0,0016	264,4231
mob_pend	0,0112	0,0492	0	1
hierarquia_simpl	0,1022	0,3029	0	1
emissão_pcp	0,0273	0,0411	0	1
prop_idosos	0,1194	0,0320	0,0260	0,2709
gini	0,4966	0,0655	0,2800	0,8000
prop_pob	0,2311	0,1796	0,0000	0,7823

Fonte: Elaboração própria. Nota: O número de observações é de 4.855 municípios. Para mais informações sobre as variáveis, consultar a Tabela 1.

A forma com que as taxas de infecção e óbitos por Covid-19 por 100 mil habitantes se apresentam nas localidades depende da hierarquia urbana (Tabela 3). A taxa média de infecções por 100 mil habitantes é mais elevada nas capitais regionais (531,4174), seguida pelos municípios que se caracterizam como centros sub-regionais

(483,1441) e as metrópoles (453,0339), evidenciando que locais caracterizados como de maior classe de hierarquia urbana possuem uma maior taxa média de infectados por 100 mil habitantes, em detrimento aos menores, nesse caso, os centros de zona (409,5722) e os centros locais (343,0872). Isso ocorre pois lugares com maior hierarquia possuem uma maior região de influência, maior porte populacional e rede urbana mais conectada (IBGE, 2020a).

Tabela 3 - Média de infecções e óbitos por Covid-19 por classes de hierarquia urbana

Hierarquia Urbana	Taxa de Infectados por 100 mil habitantes (16/01/2021)			Taxa de Óbitos por 100 mil habitantes (16/01/2021)		
	Obs.	Média	Desvio-Padrão	Obs.	Média	Desvio-Padrão
Metrópole	203	453,0339	243,8237	203	11,8012	4,3311
Capital Regional	295	531,4174	294,1703	295	10,5343	4,9337
Centro Sub-Regional	481	483,1441	269,2335	481	8,6708	4,7325
Centro de Zona	435	409,5722	265,2186	435	6,8331	4,3833
Centro Local	3859	343,0872	248,6956	3859	5,8989	4,5930

Fonte: Elaboração própria.

As capitais regionais e os centros sub-regionais apresentaram uma taxa média de infecções por 100 mil habitantes maior que as metrópoles, isso pode ter ocorrido, pois no Brasil, especialmente na região Norte, existem locais com baixa densidade, mas com um número alto de infecções. Além disso, existem localidades nas áreas metropolitanas que apresentam baixa infecção pela Covid-19 (Mapa 1).

A taxa média de óbitos por 100 mil habitantes se comportou de maneira similar a taxa de infecção, em que existe uma ordem crescente que evidencia maior taxa de mortes quanto maior é a classe de hierarquia urbana. Nessa perspectiva, as metrópoles apresentaram uma maior taxa média de mortalidade (11,8012), seguido pelas capitais regionais (10,5343), centros sub-regionais (8,6708), centros de zona (6,8331) e, por fim, os centros locais (5,8989). Em suma, em hierarquias urbanas maiores, isto é, em localidades com maior região de influencia, a taxa média de óbitos é mais elevada, o que refuta a hipótese deste estudo fundamentado em Hamidi *et al.* (2020).

Nesse contexto, compreender essas relações entre a forma de organização dos locais e o processo de infeções e mortalidade por Covid-19 é fundamental. Logo, na próxima subseção serão tratados os modelos empíricos que investigam essas associações de forma mais específica.

4.2 Modelos Empíricos

4.2.1 Modelo de Equações Estruturais

Nesta seção são abordadas as questões pertinentes à primeira etapa de modelos empíricos utilizados neste estudo. Aqui, é analisado o modelo de equações estruturais (MEE), relacionando as variáveis descritas anteriormente. Logo, os resultados das estimações deste modelo estão presentes na Tabela 4, trazendo como variáveis dependentes ou endógenas o logaritmo natural da taxa de infectados por Covid-19 e o logaritmo natural da taxa de óbitos por Covid-19, na tentativa de captar disseminação e letalidade do vírus. Na Tabela 4, a coluna 1 apresenta os coeficientes da estimação do modelo para a taxa de infectados e a coluna 2 evidencia esta informação para a taxa de óbitos, já as colunas 3 e 4 apresentam os coeficientes padronizados[11].

Tabela 4 - Resultado do modelo de equações estruturais

	(1)	**(2)**	**(3)**	**(4)**
Variáveis	**ln_txinfec**	**ln_txobito**	**Coeficientes padronizados da coluna 1†**	**Coeficientes padronizados da coluna 2†**
ln_popurb	0,0359***	0,0513***	0,0704***	0,0951***
	(0,0095)	(0,0081)	(0,0186)	(0,0151)
densES	0,0219***	-0,0047**	0,1644***	-0,0333**
	(0,0029)	(0,0021)	(0,0219)	(0,0149)
densR	-0,0002***		-0,3098***	
	(0,0000)		(0,0349)	
densA	0,0002***	0,0001***	0,1140***	0,0389**
	(0,0000)	(0,0000)	(0,0175)	(0,0149)
densEE	0,0038**		0,0686**	
	(0,0018)		(0,0322)	
mob_pend	-1,2360***		-0,0903***	
	(0,1770)		(0,0129)	
hierarquia_simpl	0,1356***	0,2983***		
	(0,0312)	(0,0283)		
emissão_pcp	0,0001		0,0175	
	(0,0001)		(0,0134)	
prop_idosos	-3,9060***	0,9600***	-0,0186***	0,0432**
	(0,3779)	(0,3279)	(0,0176)	(0,0147)
gini	0,5550***	-0,1629	0,0540**	-0,0150
	(0,1875)	(0,1820)	(0,0182)	(0,0167)

[11] O processo de padronização consiste em subtrair de cada valor a média de cada variável, e dividir o resultado dessa diferença pelo respectivo desvio padrão. Assim, os coeficientes padronizados têm o potencial de mostrar o poder explicativo das variáveis comparativamente, uma vez que pondera as diferentes escalas.

prop_pob	-0,7992*** (0,0982)	-0,0797 (0,0754)	-0,2133*** (0,0260)	-0,0201 (0,0190)
ln_txinfec		0,4976*** (0,0145)		0,4704*** (0,0119)
intercepto	5,7936*** (0,1251)	-1,6162*** (0,1358)	8,6094*** (0,2145)	-2,2705*** (0,1854)
Observações	4.855	4.855	4.855	4.855
R^2	0,201	0,201	0,201	0,201
SRMR	0,005	0,005	0,005	0,005

Fonte: Elaboração própria.
Nota: † Coeficientes padronizados de variáveis *dummy* não são apresentados, pois não possuem sentido de interpretação, logo a interpretação da hierarquia urbana será dada através dos coeficientes não padronizados (colunas 1 e 2). Desvios padrão robustos constam entre os parênteses. Níveis de significância: * p<0,10, ** p<0,05, *** p<0,01

Como especificado anteriormente, o grau de ajuste do modelo é dado pelo resíduo padronizado da raiz quadrada média (SRMR), que, seguindo os estudos de Brown (2006) e Chang *et al.* (2009), o ideal é que não passe de 0,05. Neste modelo, o resultado é 0,005, o que evidencia um bom grau de ajuste. O $\boldsymbol{R^2}$, ou coeficiente de determinação, é de 0,201, evidenciando que 20,1% da variação das variáveis endógenas é explicada pelo modelo especificado.

Para os dois modelos, de infecção e letalidade do vírus, as análises são conduzidas para os coeficientes padronizados (colunas 3 e 4). Assim, os resultados são apresentados em unidades de desvio padrão, permitindo que a magnitude do poder de explicação entre as variáveis endógenas e exógenas sejam melhor comparáveis (MACANA; COMIM, 2016; KLINE, 2011).

Com relação ao modelo de infecções, a variável de hierarquia urbana (0,1356), apresenta uma relação positiva a um nível de significância de 1%. Isso mostra que, de fato, os locais mais desenvolvidos e com maior porte populacional estão relacionados com uma maior taxa de infecção pela Covid-19. Batella e Miyazaki (2020) afirmam que a rede urbana está diretamente associada com a difusão do vírus principalmente por questões como nível de centralidade, ligações entre os centros e infraestrutura de circulação. Duarte e Schumann (2022) evidenciam ainda que o processo de disseminação da Covid-19 seguiu uma tendência reticular, mas não uniforme, em que locais com maior proximidade e integração econômica com os municípios polos (mais desenvolvidos) apresentaram o aumento de casos antes que os municípios mais afastados.

A variável de população urbana (0,0704) é estatisticamente significante, e também apresenta uma relação positiva com a disseminação da Covid-19. Esse resultado é

esperado, visto que nos centros urbanos a densidade de pessoas é maior, o que facilita o contato entre os indivíduos, aumentando a chance de transmissão de qualquer doença contagiosa, caso da Covid-19. Esta associação está relacionada, principalmente com o nível de espraiamento urbano, pois locais mais espraiados tendem a possuir esses números mais elevados (HAMIDI *et al.*, 2020; WONG; LI, 2020; BHADRA *et al.*, 2021).

As variáveis de densidade de estabelecimentos de saúde (0,1644), de estabelecimentos de educação (0,0686) e de atividade (0,1140) captam o acesso a oportunidades, visto que quanto mais central, compacto e desenvolvido é o local, maior tende ser a presença dessas oportunidades pro quilômetro quadrado e, consequentemente, melhor o grau de acessibilidade a estas, devido a um sistema mais efetivo de transportes urbanos (SCOTT; HORNER, 2008; PEREIRA *et al.*, 2020a).

Os três indicadores de densidade, acima, foram positivos e significativos corroborando com a ideia de que melhor acesso a oportunidades está relacionado com uma maior taxa de contágio pela Covid-19. Isso ocorre, pois, quanto melhor essa acessibilidade, mais deslocamentos tendem a ocorrer nestas localidades, aumentando, dessa forma, o grau de esposição dos indivíduos (LEIVA *et al*., 2020; PEREIRA *et al.*, 2020b).

A densidade residencial (-0,3098) é significativa a 1% e negativamente relacionada com a taxa de infecções por Covid-19, mostrando que uma menor densidade de domicílios está relacionada com uma maior taxa de infectados por Covid-19. Esse resultado foi persistente, porém não era esperado, visto que em locais com maior densidade residencial tendem a ser mais dificultoso o isolamento, culminando com mais casos (RIBEIRO *et al.*, 2021).

O fluxo de saída de pendulares (-0,0903), apresenta uma relação inversa com a taxa de infectados, denotando que locais com um maior fluxo de saída de pendulares apresentam menores taxas de infecção. Não se esperava esta relação, visto que devido a maior circulação de indivíduos em cidades maiores e mais desenvolvidas, o esperado seria o transporte de casos de Covid-19 destas cidades para as de origem (CIRIACO; LIMA, 2021). Pelo fato de grandes centros possuírem uma maior divulgação de cuidados com o vírus, o resultado negativo dessa variável pode ser dado pelo maior grau de informação dos indivíduos que lá circulam sobre mecanismos de precaução de contaminação pelo novo Coronavírus (MATTA *et al.*, 2021).

A proporção de idosos (-0,1863) apresenta relação inversa com a taxa de

infectados. É esperado que ela tenha esse comportamento, pois municípios que contenham uma maior proporção de indivíduos idosos não são tão propensos a grandes aglomerações quantos os que possuem essa proporção menor, dado que a maior taxa de transmissão da Covid-19 está entre a faixa etária de 20 e 49 anos de idade (MONOD *et al.*, 2021).

Quanto às medidas que captam vulnerabilidade social, denotadas pelo coeficiente de Gini (0,0540) e a proporção de pobres (-0,2133), elas são significativas a 5% e a 1% respectivamente, mas é curioso o resultado inverso das variáveis, onde o coeficiente de Gini se relaciona positivamente com as infecções por Covid-19, mas a proporção de pobres se relaciona inversamente com esta.

Koudjom *et al.* (2022) analisaram indicadores de pobreza juntamente com outras variáveis de controle, entre elas o coeficiente de Gini, para a compreender a disseminação por Covid-19 na África. No estudo eles percebem que as duas variáveis, desigualdade de renda e pobreza, possuem sinal positivo. O sinal oposto das duas variáveis pode está evidente no Brasil, pois nas cidades metropolitanas, existe alto nível de desigualdade de renda, de tal ponto que essa proporção de pobres pode ser uma minoria em meio a um emaranhado de classes sociais existentes (SALATTA; RIBEIRO, 2021).

Em relação ao modelo para óbitos, o principal determinante é a taxa de infeções municipal (0,4707). Essa relação evidencia que maiores taxas de mortalidade estão relacionadas a maiores taxas de infecções, o que é lógico, pois só tem como se falar em mortalidade por um vírus se existirem infectados por ele (HAMIDI *et al.*, 2020).

A hierarquia urbana (0,2983) também é significativamente determinante para a letalidade do vírus, evidenciando que locais com maior hierarquia urbana (metrópoles e capitais regionais) estão associados com uma maior taxa de mortalidade por Covid-19. A despeito do fato de que em locais mais centrais existam melhores mecanismos de funcionamento do sistema de saúde, de forma geral, locais caracterizados como sendo de hierarquias urbanas maiores (metrópoles e capitais regionais) tendem a possuir taxas mais altas de infecções por Covid-19, que, por sua vez, estão relacionados com maiores taxas de mortalidade (LEIVA *et al.*, 2020).

Pereira Júnior *et al.* (2020) evidenciam que três situações podem levar a um aumento de mortalidade em regiões caracterizadas de menor hierarquia urbana (centros sub-regionais e centros de zona), sendo elas: quando a cidade é alvo de passeios turísticos;

quando os nós de tráfego de média e pequena escala[12] apresentam índices mais precisos que os grandes centros; e quando esses núcleos urbanos menores participam de circuitos produtivos, empresariais ou migratórios alternativos. Porém, essas exceções não são capazes mudar o sinal desta relação.

As medidas de acesso a oportunidades apresentaram sentidos diferentes de relação com a taxa de mortalidade com a Covid-19. A relação positiva e estatisticamente significativa da variável de densidade de atividade (0,0389) com a taxa de óbitos evidencia que localidades com maior densidade de empregos, em outras palavras, com melhor acesso a oportunidades a estes, estão relacionadas com uma maior taxa de mortalidade por Covid-19. Isso acontece, pois devido a uma melhor condição de acesso, existe um maior grau de exposição no percurso casa-trabalho (SATHLER; LEIVA, 2022).

Já a densidade de estabelecimentos de saúde (-0,0333) apresenta uma relação inversa com a taxa de óbitos, ou seja, municípios com maiores densidades de estabelecimentos de saúde, em média, apresentam menores taxas de mortalidade. Quanto mais locais estiverem prontos para atender os indivíduos, mais rapidamente são realizados os cuidados emergenciais e maiores as chances de sua recuperação (NORONHA *et al.*, 2020; IBGE, 2020a). Além disso, a maior densidade de estabelecimentos de saúde, facilita o acesso a estes, facilitando o socorro emergencial dos indivíduos no local funcionar de maneira mais rápida (PEREIRA *et al.*, 2020a; LEIVA *et al.*, 2020).

A proporção de idosos (0,0432) evidencia que existe uma relação positiva entre essa variável e a taxa de mortalidade por Covid-19. A população idosa é mais vulnerável ao vírus, devido a um sistema imunológico mais debilitado, o que gera maiores riscos de complicação dos casos, consequentemente, localidades com maior parcela de idosos apresentam, em média, maior letalidade do vírus (KANG; JUNG, 2020; BARBOSA *et al.*, 2020).

Em relação a população urbana (0,0951), nota-se que locais com maior população urbana estão associados com maiores taxas de mortalidade por Covid-19. Isso segue a literatura, pois quanto maior o número de casos notificados, maiores as possibilidades de existirem óbitos pelo vírus (VIEZZER; BIONDI, 2021). A proporção de pobres (-0,0201) e o coeficiente de Gini (-0,0150) não são estatisticamente significativas. Em apêndice

[12] Os nós de tráfego de média e pequena escala se constituem como suportes para a integração rodoviária de meso e microrregiões. Em outras palavras, são pontos de passagem (intermediários) entre regiões (Pereira Júnior *et al.*, 2020).

constam as tabelas de coeficientes dos modelos de equações estruturais para infecções (Tabela 7) e para óbitos (Tabela 8) para as três datas (16/01/2021, 22/12/2020 e 31/12/2020).

Os resultados deste modelo de equações estruturais conseguem evidenciar a relação entre as variáveis econômicas, demográficas e sociais e as taxas de infecção e mortalidade por Covid-19. Porém, tal modelo ainda não consegue apresentar suficientemente a relação entre a estrutura urbana e as referidas taxas, para tanto faz-se necessário avançar no desenho do modelo, por meio da estimação de um modelo de múltiplos indicadores e múltiplas causas.

4.2.2 Modelo de Múltiplos Indicadores e Múltiplas Causas

Nesta seção será analisada a relação entre o nível de espraiamento urbano, através do índice de compacidade urbana, e as taxas de infecções e óbitos por Covid-19, usando o modelo de mútiplos indicadores e múltiplas causas. Os resultados do modelo estrutural MIMIC constam na Tabela 5, nela a variável endógena é o índice de compacidade urbana, influenciado por todas as variáveis já descritas (Tabela 1). A coluna 1 apresenta os coeficientes de cada uma das variáveis preditoras, ou seja, daquelas que estão compondo o índice de compacidade urbana. A coluna 2 evidencia os coeficientes padronizados e, assim como no modelo anterior, as análises são realizadas utilizando os coeficientes padronizados.

O grau de ajuste do modelo, medido pelo SRMR, é de 0,020, o que evidencia que o modelo tem uma boa qualidade de ajustamento. O coeficiente de determinação, de 0,222, mostra que 22,20% da variação da variável endógena é explicada pelo modelo.

Tabela 5 - Resultados do modelo estrutural – modelo de múltiplos indicadores e múltiplas causas (MIMIC)

	(1)	**(2)**
Variáveis	**Índice de compacidade urbana**	**Coeficientes padronizados da coluna 1†**
ln_popurb	0,0448*** (0,0091)	0,1081*** (0,0228)
densES	0,0171*** (0,0031)	0,1578*** (0,0259)
densR	-0,0002*** (0,0000)	-0,3013*** (0,0404)

densA	0,0002*** (0,0000)	0,1283*** (0,0183)
densEE	0,0024 (0,0016)	0,0537 (0,0354)
mob_pend	-0,8523*** (0,1594)	-0,0766*** (0,0134)
hierarquia_simpl	0,2005*** (0,0305)	
emissão_pcp	0,0001 (0,0001)	0,0247 (0,0162)
prop_idosos	-3,2827*** (0,4117)	-0,1921*** (0,0212)
gini	0,4821*** (0,1821)	0,0577** (0,0216)
prop_pob	-0,7754*** (0,0893)	-0,2547*** (0,0290)
Observações	4.855	4.855
R^2	0,222	0,222
SRMR	0,020	0,020

Fonte: Elaboração própria.
Nota: † Coeficientes padronizados de variáveis *dummy* não são apresentados, pois não possuem sentido de interpretação, logo a interpretação da hierarquia urbana será dada através dos coeficientes não padronizados (coluna 1). Desvios padrão robustos constam entre os parênteses. Níveis de significância: * p<0,10, ** p<0,05, *** p<0,01

O Gráfico 1 apresenta o ranking dos impactos dos determinantes significativos do índice de compacidade urbana. A variável que possui maior impacto positivo no indicador de compacidade urbana é a *dummy* de hierarquia urbana (0,2005). Isso evidencia que as cidades com maior nível de centralidade urbana (metrópoles e capitais regionais) apresentam, em média, maior índice de compacidade. Esse resultado é esperado pois as redes urbanas mais estruturadas e interconectadas, característica de cidades compactas, estão presentes em hierarquias urbanas maiores (IBGE, 2020a; LEITE *et al.*, 2015).

Gráfico 1 - Ranking dos impactos dos determinantes significativos do índice de compacidade urbana

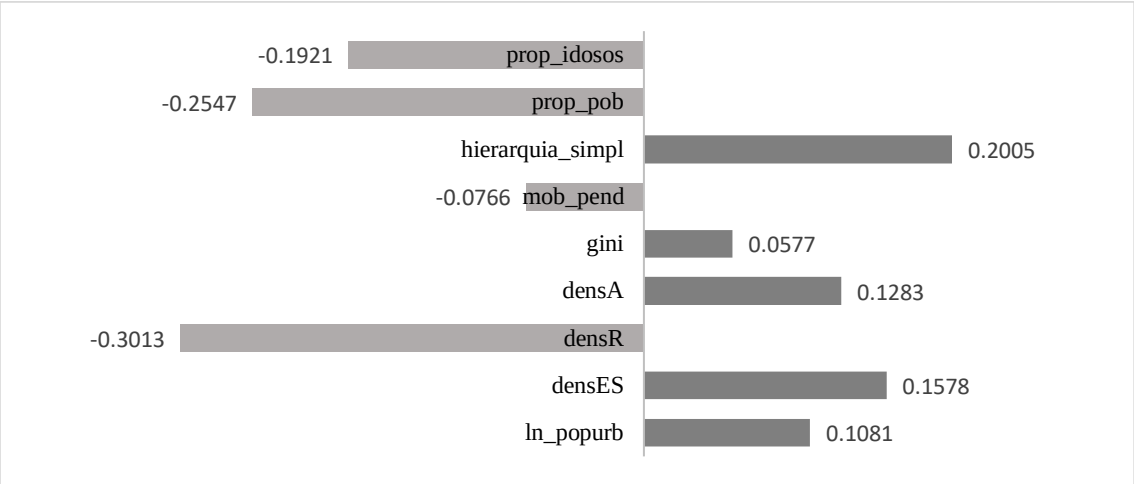

Fonte: Elaboração própria.

A densidade de estabelecimentos de saúde (0,1578) apresenta uma associação positiva, mostrando que quanto mais estabelecimentos de saúde por quilômetro quadrado, maior o indicador de compacidade urbana. Isso é evidente, pois, devido a demanda, locais compactos tendem a possuir uma maior oferta deste tipo de serviço. Além disso, por conta de uma maior oferta de empregos, existe uma retenção de profissionais qualificados nestes lugares, dentre eles, os profissionais de saúde. Ademais, nestas localidades o acesso aos serviços de saúde são facilitados (LEIVA *et al*., 2020; PEREIRA *et al*. 2020a; GARCIA, 2018).

As variáveis de população urbana (0,1081) e de densidade de atividade (0,1283) evidenciam que, em média, quanto maior a população urbana e quanto maior a densidade de empregos, mais compacta será a localidade. Tais evidências para o Brasil corroboram aos achados de Leiva *et al.* (2020), Hamidi *et al*. (2020); Sathler e Leiva (2022); Neuman (2005).

A partir disso, quando se fala de acesso a oportunidades de saúde e de empregos, apreende-se que, de modo geral, locais com melhores níveis de acessibilidade possuem um nível de compacidade urbana maior, consequentemente o espraiamento destes municípios é menor. Isso é evidenciado, pois a rede urbana juntamente com o sistema de transportes públicos coletivos funcionam em sinergia (SCOTT; HORNER, 2008; LEIVA *et al*., 2020).

O fluxo de saída de pendulares (-0,0766) sinaliza que localidades com menores fluxos de saídas de pendulares tendem a ser mais compactas. Locais espraiados, devido a menores oportunidades de empregos, apresentam uma maior taxa de evasão pendular de

indivíduos para centros e subcentros que absorvem essa mão-de-obra (AGUILERA; MIGNOT, 2004).

A proporção de idosos (-0,1921) municipal está negativamente relacionada com o nível de compacidade urbana. Esse resultado pode ser explicado por dois fenômenos: primeiro, a população economicamente ativa geralmente se concentra nos grandes centros, devido ao maior nível de oportunidades de trabalho; segundo, os indivíduos idosos tendem a procurar locais mais dispersos e sossegados, geralmente localizados no interior (MOURA, 1987; CARVALHO, 2011). Portanto, locais que apresentam menor proporção de idosos estão relacionados com maior índice de compacidade urbana.

Sobre as medidas de vulnerabilidade social, percebe-se que a proporção de pobres (-0,2152) indica que localidades com menor proporção indivíduos vivendo abaixo da linha de pobreza, em média, apresentam maiores indicadores de compacidade urbana. Por outro lado, o coeficiente de Gini (0,0577) sinaliza que sociedades mais desiguais em termos de renda estão associadas a localidades mais compactas. Essa questão traz consigo a discussão de suburbanização das cidades, visto que os indivíduos de menor renda tendem a fixar moradia nas periferias devido a um custo de vida mais elevado nas áreas centrais (BATTY *et al*., 1999; MARRA; GONÇALVES, 2012; KOUDJOM *et al.*, 2022).

A densidade residencial (-0,3013) é significativa e apresenta uma relação inversa com a compacidade urbana, tendo um resultado não esperado e persistente. Uma possibilidade é que tal achado esteja relacionado com o fato de cidades compactas captarem mais indivíduos para trabalho e estudo, e, devido a maiores custos de vida nesses locais, esses pendulares podem está residindo mais distante das oportunidades e utilizando os transportes para acessá-las (AGUILERA; MIGNOT, 2004; SATHLER; LEIVA, 2022).

A emissão de CO_2 per capita (0,0334) e a densidade de estabelecimentos de educação (0,0537) não são estatisticamente significantes. Em apêndice constam os resultados dos modelos estruturais de mútiplos indicadores múltiplas causas para infecções (Tabela 9) e para óbitos (Tabela 10), para as três datas de referência (16/01/2021, 22/12/2020 e 31/12/2020). Os resultados são robustos a flexibilização nas datas de referências, tanto em termos de magnitudes, como de sinais.

A Tabela 6 apresenta os resultados do modelo de mensuração da variavel latente (índice de compacidade urbana) e nela, pode-se observar que todos os indicadores são estatisticamente significativos. No referido modelo, a taxa de infecções apresenta um

peso maior dentro do índice de compactação urbana, em comparação com a taxa de óbitos. Esse menor peso da taxa de óbitos pode está relacionado com os efeitos de um sistema de saúde mais eficaz no combate da mortalidade nestes locais, capaz de reduzir o valor desta variável. Logo, espera-se, por exemplo, que o ln da taxa de infecções por 100 mil habitantes aumente aproximadamente 0,8126 desvios padrões dado o aumento de uma unidade de desvio padrão no índice de compacidade urbana.

Tabela 6 - Resultados do modelo de mensuração – modelo de múltiplos indicadores e múltiplas causas (MIMIC)

Variável endógena	**Coeficiente**	**Coeficiente padronizado**	R^2	**Intercepto**	**Intercepto padronizado**
ln_txinfec	1,0000 (Restrição)	0,8126*** (0,0263)	0,6603	5,6492*** (0,1230)	8,3948*** (0,2110)
ln_txobito	0,8229*** (0,0531)	0,6322*** (0,0216)	0,3996	1,6773*** (0,1026)	2,3563*** (0,1465)

Fonte: Elaboração própria.
Nota: Foram observados 4.855 municípios brasileiros. O coeficiente do ln_txinfec é 1pois esse indicador foi a referência para a normalização do construto do índice de compacidade urbana, assegurando a propriedade de identificação do modelo. Desvios padrão robustos constam nos parênteses. Níveis de significância: *p<0.10, ** p<0.05, *** p<0.01.

Ainda na Tabela 6 é possível observar que o construto latente do índice de compacidade urbana explica 66,03% da variação da taxa de infectados por Covid-19 e 39,96% da variação da taxa de óbitos pelo vírus. Portanto, há indicativos claros de que os mecanismos de difusão e óbitos pelo novo coronavírus possuem, de fato, uma relação com o espraiamento urbano, que, por sua vez, é influenciado por uma série de fatores específicos das distintas localidades.

5 CONSIDERAÇÕES FINAIS

Este estudo se propôs a analisar o papel da estrutura urbana no processo de infecções e mortalidade por Covid-19 nos municípios brasileiros. Para isso foi realizada uma análise através de modelos de equações estruturais para captar a relação entre variáveis de densidade, mobilidade, vulnerabilidade social e de estrutura urbana com as taxas de disseminação e mortalidade por Covid-19. Em seguida, utilizando o modelo de múltiplos indicadores e múltiplas causas, é realizada uma investigação sobre a associação dessas taxas com o nível de espraiamento urbano, através do indicador de compacidade urbana.

A literatura utilizada neste estudo evidencia que a geografia de casos e de mortes por Covid-19 não segue um padrão homogêneo, ou seja, cada localidade pode apresentar diferenças no processo de contaminação, prevenção, óbitos e informação sobre o vírus. Estudos como este, se fazem importantes para que planejadores de políticas públicas gerenciem as melhores estratégias de contenção de avanço de doenças altamente contagiosas, como foi o caso da Covid-19.

Os resultados dos modelos econométricos indicam que nas cidades compactas, devido ao fato de possuírem maior hierarquia urbana e melhores condições de acesso a oportunidades, as taxas de mortalidade e óbitos por Covid-19 foram mais altas. Isso evidencia que as cidades mais interligadas e densas são as mais suscetíveis aos riscos dos vírus, mesmo que possuam uma maior infraestrutura e um mais rápido poder de resposta aos mecanismos impostos por estes.

Outro resultado interessante observado é que os indicadores de vulnerabilidade social, índice de Gini e proporção de pobres, apresentaram resultados, com sinais opostos, onde o primeiro afeta positivamente e, o segundo, negativamente a taxa de infecções e o nível de espraiamento urbano. Isso pode ser reflexo de que no Brasil existem locais em que a concentração de renda é elevada, mesmo havendo, por vezes, uma baixa proporção de indivíduos abaixo da linha da pobreza.

O fluxo de saída de pendulares evidencia que a evasão pendular é mais expressiva nas cidades categorizadas com um espraiamento urbano maior. O que converge com a literatura utilizada neste estudo, pois locais menos compactos apresentam, em média, menos oportunidades de trabalho, educação e saúde. Nesse sentido, uma boa parte dos deslocamentos pendulares estão relacionados com a busca pelo acesso à melhores oportunidades.

Os resultados deste estudo contribuem para, de certo modo, preencher uma lacuna existente nas investigações acerca da estrutura urbana das localidades e sua relação com às taxas de disseminação e mortalidade por Covid-19 no Brasil. Espera-se que a presente pesquisa possa ser um ponto de partida para a construção de um guia de direcionamentos para planejadores de políticas públicas lidarem de maneira mais eficiente, não só com a compreensão do processo da Covid-19, mas também de outras infecções virais que possam ocorrer no futuro, no Brasil e no mundo. Os resultados evidenciam relações claras entre a disseminação e letalidade da Covid-19 e aspectos como acesso a oportunidades, mobilidade pendular e centralidade das cidades. Políticas públicas que visem incremento de bem-estar social e econômico, seja através de maior promoção de desenvolvimento sustentável ou de melhoras no sistemas de acesso à oportunidades de saúde, educação e trabalho, precisam ser discutidas, a fim de se ter melhoras na qualidade de vida e redução de letalidade de doenças.

Nessa abordagem, dada a relação espacial observada entre as infecções e mortalidades por Covid-19, um possível desdobramento futuro para este estudo consiste em aprofundar a temática aqui observada, com uma análise através do uso do ferramental de econometria espacial, observando a disseminação e letalidade tanto no período pré vacinação, como no período pós vacinação. Além disso, outro avanço interessante seria se aprofundar na compreensão da relação entre os indicadores de vulnerabilidade social e as taxas de disseminação e mortalidade pelo vírus, visto que o Brasil é um país marcado por fortes desigualdades sociais e de renda.

REFERÊNCIAS

AGUILAR, J.; BASSOLAS, A.; GHOSHAL, G.; HAZARIE, S.; KIRKLEY, A.; MAZZOLI, M.; MELONI, S.; MIMAR, S.; NICOSIA, V.; RAMASCO, J. J.; SADILEK, A. Impact of Urban Structure on Infectious Disease Spreading. **Scientific Reports.** Londres, v. 12, n. 3816, p. 1-13, 2022.

AGUILERA, A.; MIGNOT, D. Urban Sprawl, Polycentrism and Commuting. A Comparison of Seven French Urban Areas. **Urban Public Economics Review**. v. 1, p. 93-111, 2004.

ANAS, A.; ARNOTT, R.; SMALL, K. A. Urban Spatial Structure. **Journal of Economic Literature.** v. 36, p. 1426-1464, 1998.

ANUNCIATO, K. M.; FRANCO, C. Análise dos principais indicadores de pobreza e desigualdade social de Mato Grosso do Sul. **Revista Unemat de Contabilidade**, v. 6, n. 11, 2017.

ARBURY, J. **From Urban Sprawl to Compact City:** An Analysis of Urban Growth Management in Auckland. Dissertação (Mestrado). University of Aukland, 2005.

BARBOSA, E. **A Economia Paralela em Portugal:** Uma Análise com Utilização do Modelo MIMIC. Orientadores: Samuel Cruz Alves Pereira e Elísio Fernando Moreira Brandão. 2010. Dissertação (Mestrado) – Finanças e Fiscalidade, Faculdade de Economia, Universidade do Porto, Porto, 2012.

BARBOSA, I. R.; GALVÃO, M. H. R.; SOUZA, T. A.; GOMES, S. M.; MEDEIROS, A. A.; LIMA, K. S. Incidência e Mortalidade por Covid-19 na população idosa brasileira e sua relação com indicadores contextuais: um estudo ecológico. **Revista Brasileira de Geriatria e Gerontologia**. v. 23, n. 1, p. 1-11, 2020.

BARBOSA, T. P.; COSTA, F. B. P.; RAMOS, A. C. V.; BERRA, T. Z.; ARROYO, L. H; ALVES, Y. M.; SANTOS, F. L.; ARCÊNCIO, R. A. Morbimortalidade por COVID-19 associada a condições crônicas, serviços de saúde e iniquidades: evidências de sindemia. **Pan American journal of public health**, v. *46*, n. 6, 2022.

BATELLA, W.; MIYAZAKI, V. K. Relações entre rede urbana e Covid-19 em Minas Gerais. **Revista Brasileira de Geografia Médica e da Saúde**. p. 102-110, 2020.

BATTY, M.; XIE, Y.; SUN, Z. The Dynamics of Urban Sprawl. **Working paper Series.** Centre for Advanced Spatial Analysis (CASA-UCL). v. 15, p. 1-36, 1999.

BEGA, M. T. S.; SOUZA, M. N. Pandemia e efeito-território: a desigualdade social como catalisadora da Covid-19. **Revista Brasileira de Sociologia.** Curitiba, v. 09, n. 21, p. 25-54, 2021.

BERNAL, J. L.; ANDREWS, N.; GOWER, C.; GALLAGHER, E.; SIMMONS, R.; THELWALL, S.; STOWE, J.; TESSIER, E.; GROVES, N. Effectiveness of Covid-19 Vaccines against the B.1.617.2 (Delta) Variant. **The New England Journal of Medicine**, Massachusetts, v. 385, n. 7, p. 585-594, 2021.

BERTAUD, A. The Spatial Organization of Cities: Deliberate Outcome or Unforeseen Consequence? **UC Berkeley: Institute of Urban and Regional Development.** 2004. Disponível em: https://escholarship.org/uc/item/5vb4w9wb. Acesso em: 16 out. 2022.

BHADRA, A.; MUKHERJEE, A.; SARKAR, K. Impact of population density on Covid-19 infected and mortality rate in India. **Modeling Eart System and Environment**. v. 7, p. 623-629, 2021.

BOLLEN, K. A. Structural Equations with Latent Variables. New York: **Wiley**, 1989.

BREHENY, M. The Compact City: An Introduction. **Built Environment.** v. 18, ed. 4, 1992.

BRITO, S. B. P.; BRAGA, I. O.; CUNHA, C. C.; PALÁCIO, M. A. V.; TAKENAMI, I. Pandemia da COVID-19: o maior desafio do século XXI. **Vigilância Sanitária em Debate**, Rio de Janeiro, v. 8, n. 2, p. 54-63, 2020.

BRITO, F; SOUZA, J. Expansão Urbana nas Grandes Metrópoles: O Significado das migrações Intrametropolitanas e da Mobilidade Pendular na Reprodução da Pobreza. **São Paulo em Perspectiva**, São Paulo, v. 19, n. 4, p. 48-63, 2005.

BROWN, T. A. Confirmatory Factor Analysis for Applied Research. New York: **The Guilford Press**, 2006.

BRUECKNER, J. Lectures on Urban Economics. Cambridge: **MIT Press**, 2011.

BURTON, E.; JENKS, M.; WILLIAMS, K. The compact city. [S.l.]: **Routledge**, 2003.

CANGUR, S.; ERCAN, I. Comparison of Model Fit Indices Used in Structural Equation Modeling Under Multivariate Normality. **Journal of Modern Applied Statistical Methods**. v. 14, n. 1, p.152-167, 2015.

CARVALHO, C. H. R. Desafios da mobilidade urbana no Brasil. **Texto para Discussão Ipea, 2198**. Instituto de Pesquisa Econômica Aplicada (Ipea). 2016. Disponível em http://repositorio.ipea.gov.br/bitstream/11058/6664/1/td_2198.pdf. Acesso em: 10 jul. 2022.

CARVALHO, I. M. M. Mercado de trabalho e vulnerabilidade em regiões metropolitanas brasileiras. **Caderno CRH**. v. 24, n. 62, p. 397-412, 2011.

CAVALCANTE, J. R.; SANTOS, A. C. C.; BREMM, J. M.; LOBO, A. P.; MACÁRIO, E. M.; OLIVEIRA, W. K.; FRANÇA, G. V. A. COVID-19 no Brasil: evolução da epidemia até a semana epidemiológica 20 de 2020. **Epidemiologia e Serviços de Saúde**, Distrito Federal, v. 29, n. 4, p. 1-13, 2020.

CHANG, C.; LEE, A. C.; LEE, C. F. Determinants of capital structure choice: A structural equation modeling approach. **The Quarterly Review of Economics and Finance**, v. 49, n. 02, p. 197-213, 2009

CHAUVIN, J. P. Why Does COVID-19 Affect Some Cities More Than Others? **IDB Working Paper Series**, nº 1251, Interamerican Development Bank, 2021. Disponível

em:https://publications.iadb.org/en/why-does-Covid-19-affect-some-cities-more-others-evidence-first-year-pandemic-brazil. Acesso em: 08 jul. 2022.

CHRISTALLER, W. Central Places in Southern Germany. New Jersey: **Prentice-Hall**, p. 236, 1966.

CONOVER, W. J. Practical Nonparametric Statistics. New York: **Wiley**, 3 ed., 1999.

CNES. Cadastro Nacional de Estabelecimentos de Saúde, 2022. Disponível em: https://cnes.datasus.gov.br/. Acesso em: 12 jun. 2022.

DALBERTO, C. R.; STADUTO, J. A. R. Uma Análise das Economias de Aglomeração e seus Efeitos Sobre os Salários Industriais Brasileiros. **Revista de Economia Contemporânea**. v. 17, n. 13, p. 539-569, 2013.

DIELEMAN, F.; WEGENER, M. Compact City and Urban Sprawl. **Built Environment**. v. 30, n. 4, p. 308-323, 2004.

DUARTE, T.; SCHUMANN, E. As redes urbanas e a difusão do SARS-COV-2: Uma análise da Região de Saúde Sul do Rio Grande do Sul. **Metodologias e Aprendizado**. *[S. l.]*, v. 5, p. 139–150, 2022.

EATON, J.; ECKSTEIN, Z. Cities and Growth: Theory and Evidence from France and Japan, **Regional Science and Urban Economics**. v. 27, p. 443–474, 1997.

ECHENIQUE, M. Cities for the new millennium. Washington: **Routledge**, 2001.

EWING, R.; HAMIDI, S. Measuring urban sprawl and validating sprawl measures. Washington, DC: **National Institutes of Health and Smart Growth America**. 2014.

FUJITA, M.; KRUGMAN, P.; VENABLES, A. J. Economia espacial: urbanização, prosperidade econômica e desenvolvimento humano no mundo. São Paulo: **Futura**, 2002.

GALSTER, G.; HANSON, R.; RATCLIFFE, M. R.; WOLMAN, H.; COLEMAN, S; FREIHAGE,J. Wrestling Sprawl to the Ground: Defining and measuring an elusive concept. **Housing Policy Debate**, v. 12, n. 4, p. 681-717. Londres, 2001.

GARCIA, G. F. **O planejamento da cidade e a mobilidade urbana, uma combinação sustentável**. Orientador: Rômulo José da Costa Ribeiro. 2018. Dissertação (Mestrado) – Arquitetura e Urbanismo, Universidade de Brasília, Brasília, 2018.

GENTIL, C. D. A. **A contribuição dos elementos da forma urbana na construção da mobilidade sustentável.** 2015. Tese (Doutorado) - Curso de Arquitetura e Urbanismo, Universidade de Brasília, Brasília, 2015.

GLAESER, E.; KAHN, M. Sprawl and urban growth. In: Henderson, H.; Thisse, J. Handbook of regional and urban economics. Amsterdam: **North Holland**, vol. 4, cap. 56, 2004.

GOMES, T. C. P.; SOARES, R. A. Avaliação de sustentabilidade do plano financeiro do regime próprio de previdência cearense. **Revista Controle**. v.12, n. 1, p. 275-295, 2021.

GOMIDE, A.A. Mobilidade urbana, iniquidade e políticas sociais. **Políticas Sociais - Acompanhamento e Análise**. v. 12, p. 242-250, 2006.

GROSTEIN, M. D. Metrópole e Expansão Urbana: A persistência de Processos "Insustentáveis". **São Paulo em Perspectiva**. v. 15, n. 1, p. 13-19. São Paulo, 2001.

HANCOCK, G. R.; MUELLER, R. O. Structural Equation Modeling: A Second Course. Charlotte, NC: **Information Age Publishing**. 2006

HAMIDI, S.; SABOURI, S.; EWING, R. Does Density Aggravate the COVID-19 Pandemic? **Journal of the American Planning Association.** v. 86, n. 4, p. 495-509, 2020.

HASSELL, J. M.; BEGON, M.; WARD, M. J.; FÈVRE, E. M. Urbanization and Disease Emergence: Dynamics at the Wildlife–Livestock–Human Interface. **Trends Ecol. Evol.** v. 32, n. 1, p. 55-67, 2017.

IBGE - Instituto Brasileiro de Geografia e Estatística. Censo Brasileiro de 2010. Rio de Janeiro: **IBGE**, 2010.

IBGE - Instituto Brasileiro de Geografia e Estatística. Estimativas de População de 2021. Rio de Janeiro: **IBGE**, 2021.

IBGE – Instituto Brasileiro de Geografia e Estatística. Regiões de Influência das Cidades: 2018. Coordenação de Geografia. Rio de Janeiro: **IBGE**, p. 192, 2020.

INEP - Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira. Censo Escolar, 2021. Brasília: Ministério da Educação - **MEC**, 2022.

JENKS, M.; BURTON, E.; WILLIAMS, K. The Compact City: A Sustainable Urban Form? Reino Unido: **E & FN Spon**, 1996.

JORESKOG, K.; GOLDBERGER, A. Estimation of a Model with Multiple Indicators and Multiple Causes of a Single Latent Variable. **Journal of the American Statistical Association**, v. 70, n. 351, p. 631-639, Sept. 1975.

KANG, S. J.; JUNG, S. I. Age-Related Morbidity and Mortality among Patients with Covid-19. **Infection & Chemotherapy**. v. 52, n. 2, p. 154-164, 2020.

KLINE, R. Principles and Practice of Structural Equation Modeling. New York: **The Guifford Press**, 3 ed., 2011.

KOSFELD, R.; MITZE, T.; RODE, J.; WALDE, K. The Covid-19 containment effects of public health measures: A spatial difference-in-differences approach. **Journal of Regional Science**. v. 61, ed. 4, p. 799– 825, 2021.

KOUDJOM, E.; TAMWO, S.; KPOGNON, K. D. Does poverty increase COVID-19 in Africa? A cross-country analysis**. Health Economics Review**. v.12, n. 51, p. 1-14, 2022.

LEITE, C.; LONGO, M.; GUERRA, M. Redes de Centralidades Multifuncionais e de Compacidade Urbana: na Reestruturação Territorial de São Paulo. **Revista Iberoamericana de Urbanismo**. n. 12, p. 93-119, 2015.

LEIVA, G. C.; REIS, D. S.; FILHO, R. D. O. Estrutura urbana e mobilidade populacional: implicações para o distanciamento social e disseminação da Covid-19. **Revista Brasileira de Estudos de População**, [S. 1.], v. 37, p. 1-22, 2020. Disponível em: https://rebep.org.br/revista/article/view/1635. Acesso em: 10 jan. 2022.

LIMA, G. C. L. S.; SCHECHTMAN, R.; BRIZON, L. C.; FIGUEIREDO, M. Z. Transporte público e COVID-19. O que pode ser feito? **Centro de Estudos em Regulação e Infraestrutura da Fundação Getúlio Vargas (FGV-CERI)**, Rio de Janeiro, p. 01-24, abr. 2020. Disponível em: https://ceri.fgv.br/publicacoes/transporte-publico-e-Covid-19-o-que-pode-ser-feito#:~:text=Em%20vista%20disso%2C%20o%20FGV,a%20crise%20do%20novo%20coronavirus. Acesso em: 07 out. 2021.

LOUREIRO, P. M.; LAS CASAS, D.; MACHADO, A. F.; SIMÕES, R. F. Centralidade Digital e Redes Urbanas: um estudo da hierarquia digital nos municípios brasileiros. *In:* Encontro Nacional de Economia, 44, 2016. **Anais [...].** ANPEC, 2016. p. 1-20. Disponível em: https://www.anpec.org.br/encontro/2016/submissao/files_I/i10-b53f1b47ca7aeae048dcad0109c91b6a.pdf. Acesso em: 03 jan. 2023.

MACANA, E. C.; COMIM, F. Avaliação Do Desenvolvimento Infantil E A Influência Da Família: Uma Análise A Partir Do Modelo De Equações Estruturais Mimic. *In:* Encontro Nacional de Economia, 43, 2016. **Anais [...].** ANPEC, 2016. p. 1-20. Disponível em: https://www.anpec.org.br/encontro/2015/submissao/files_I/i12-80bf795902006d69375b4c2523d6ae98.pdf. Acesso em: 26 ago. 2022.

MACEDO JÚNIOR, A. M. Covid-19: calamidade pública. **Medicus**, Natal, v. 2, n. 1, p. 1-6, 2020.

MARRA, N. C.; GONÇALVES, R. G. O acesso ao direito social à moradia nas metrópoles: a periferização da oferta de habitação da região metropolitana de Belo Horizonte. **Espaço Jurídico Journal of Law [EJJL].** v. 13, n. 1, p. 139–156, 2012.

MARSHALL, A. Princípios de economia: tratado introdutório. São Paulo: **Nova Cultural**, 1985.

MASSUGA, F.; MANGONI, S. S.; DOLIVEIRA, S. L. D. A Influência Dos Setores Econômicos Na Emissão De Co2: Um Estudo Nos Estados Brasileiros. **Revista ADMPG**, *[S. l.]*, v. 12, n. 1, 2022.

MATAMOROS, Z.; CAMPO, N. M. S.; GARCIA, L. E. V.; JIMÉNEZ, I. B. Indicadores demográficos en la incidencia de la Covid-19 en Santiago de Cuba. **Revista Brasileira de Estudos de População**, [S.I.], v. 38, p. 1-17, 2021.

MATTA, G. C.; REGO, S.; SOUTO, E. P.; SEGATA, J. Os impactos sociais da Covid-19 no Brasil: populações vulnerabilizadas e respostas à pandemia [online]. Rio de Janeiro: **Observatório Covid 19**; Editora FIOCRUZ, 2021, 221 p. Informação para ação na

Covid-19 series. ISBN: 978-65-5708-032-0. Disponível em: doi.org/10.7476/9786557080320. Acesso em: 02 nov. 2021

MENDES, D. C.; FILHO, H. N. H.; TELLECHEA, J. A realidade do trabalho home office na atipicidade pandêmica. **Revista Valore**. v. 5, p. 160-191, 2020.

MESQUITA, L. F. R.; PACHECO JÚNIOR, J. M.; FERREIRA, P. M. S.; MELO, J. P. S.; GALVÃO, V. N. S.; CHAVES, A. R. F. Planejamento e Ordenamento Territorial Urbano no cenário Pós-Pandemia da Covid-19: previsões e considerações. In: Congresso Luso-Brasileiro Para O Planejamento Urbano, Regional, Integrado E Sustentável, 9., 2021, Digital. **Anais [...].** Digital: Pluris, 2021. p. 1370-1383. Disponível em: https://pluris2020.faac.unesp.br/Paper1370.pdf. Acesso em: 04 jan. 2022.

MINISTÉRIO DA SAÚDE. Secretaria Extraordinária de Enfrentamento à COVID-19. Nota técnica nº 27/2021-SECOVID/GAB/SECOVID/MS. Administração de dose de reforço de vacinas contra a Covid-19. 2021. Disponível em: https://www.gov.br/saude/pt-br/coronavirus/vacinas/NTDoseReforo.pdf34. Acesso em: 16 jan. 2023

MINISTÉRIO DA SAÚDE. Coronavírus Brasil: Painel COVID-19, 2020. Página Inicial. Disponível em: https://covid.saude.gov.br/. Acesso em 23 mai. 2022

MONOD, M.; BLENKINSOP, A.; XI, X.; HEBERT, D.; BERSHAN, S.; TIETZE, S.; BAGUELIN, M.; BRADLEY, V. C.; CHEN, Y.; COUPLAND, H.; FILIPPI, S.; HOROWICZ, J. I.; MCMANUS, M.; MELLAN, T.; GANDY, A.; HUTCHINSON, M.; UNWIN, H. J. T.; ELSLAND, S. L. V.; VOLLMER, M. A. C.; WEBER, S.; ZHU, H; BEZANCON, A.; FERGUSON, N. M.; MISHRA, S.; FLAXMAN, S.; BHATT, S.; RATMANN, O. Age groups that sustain resurging Covid-19 epidemics in the United States. **Science.** v. 371, n. 6536, p. 1-12, 2021.

MORAES, B. Q. S.; FÉLIX, I. C. G.; QUIRINO, T. R. L.; MACHADO, M. F. Análise dos indicadores da Covid-19 no nordeste brasileiro em quatro meses de pandemia. **Vigilância Sanitária em Debate**, v. 08, n. 3, p. 52-60, jul. 2020.

MORAES, R. F. Prevenindo Conflitos Sociais Violentos em Tempos de Pandemia: garantia da renda, manutenção da saúde mental e comunicação efetiva. **Boletim de Análise Político-Institucional**, n. 22, p. 37-50, abr. 2020.

MOURA, H. A. Impactos das mudanças demográficas sobre as demandas sociais nas metrópoles do Nordeste. **Cadernos de Estudos Sociais**. v. 3, n. 3, p. 241-268, 1987.

MOURA, R; NAGAMINE, L.; FERREIRA, G. Regic: Trajetória, variações e hierarquia urbana em 2018. **Texto para Discussão Ipea, 2666**. Instituto de Pesquisa Econômica Aplicada (Ipea). 2021. Disponível em: https://repositorio.ipea.gov.br/bitstream/11058/10652/1/td_2666.pdf. Acesso em: 02 fev. 2023.

NADALIN, V. **Três ensaios sobre economia urbana e mercado de habitação em São Paulo.** Tese (Doutorado), Instituto de Pesquisas Econômicas (IPE), Universidade de São Paulo (USP), São Paulo, 2010.

NASCIMENTO, E.; MATIAS, L. F. Expansão Urbana e Desigualdade Socioespacial: Uma Análise da Cidade de Ponta Grossa (PR). **Raega - O Espaço Geográfico em Análise**, [S.l.], v. 23, nov. 2011. Disponível em: <https://revistas.ufpr.br/raega/article/view/24833>. Acesso em: 04 mar. 2022.

NASCIMENTO JÚNIOR, L. Urbanização e cidade dispersa: implicações da produção do espaço urbano no brasil, em Moçambique e na Austrália. **Geousp – Espaço e Tempo**, Online, v. 21, n. 2, p. 550-569, ago. 2017.

NASCIMENTO, P. S. Impactos Socioambientais em Áreas de Expansão Urbana de Barreiras (Bahia): Análises Consolidadas. *In:* Simpósio Nacional de Geografia Urbana. n. 16, 2019, Espírito Santo. **Anais** [...], Espírito Santo:UFES, 2019. P. 3978-3993.

NEUMAN, M. The Compact City Fallacy. **Journal of Planning Education and Research**. Tallahassee, v. 25, n. 1, p. 11-26, 2005.

NEVES, J. A. B. Modelo de Equações Estruturais: Uma Introdução Aplicada. Brasília: **Enap**, 2018.

NEWTON, P. Urban form and environmental performance. **Achieving Sustainable Urban Form**. Londres, v. 2, p. 46-53, 2000.

NORONHA, K. V. M. S.; GUEDES, G. R.; TURRA, C. M.; ANDRADE, M. V.; BOTEGA, L.; NOGUEIRA, D.; CALAZANS, J. A.; CARVALHO, L.; SERVO, L.; FERREIRA, M. F. Pandemia por Covid-19 no Brasil: análise da demanda e da oferta de leitos hospitalares e equipamentos de ventilação assistida segundo diferentes cenários. **Cadernos de Saúde Pública**. v. 36, n. 6, p. 1-17, 2020.

NOVA, C. V. **Condicionantes da Área Urbana no Brasil:** uma análise empírica. Orientador: Raul da Mota Silveira Neto. 2014. Dissertação (Mestrado) – Economia, Programa de Pós Graduação em Economia - PIMES, Universidade Federal de Pernambuco, Recife, 2014.

OECD. Compact city policies: a comparative assessment. Paris: **OECD**, 2012. Disponível em: https://www.oecd.org/regional/greening-cities-regions/compact-city.htm. Acesso em: 22 dez. 2021.

OECD. Políticas de reposta das cidades. Paris: **OECD**, 2020. Disponível em: https://www.oecd.org/coronavirus/policy-responses/politicas-de-reposta-das-cidades-4a98f3a8/. Acesso em: 14 jan. 2022.

OLIVEIRA, P. H. G. **Modelagem de Equações Estruturais Aplicada ao Estudo das Relações entre Qualidade e Diversidade da Fauna no Sistema Solo-Serrapilheira**. Orientador: Antonio Carlos Gama-Rodrigues. 2016. Tese (Doutorado) – Produção Vegetal, Centro de Ciências e Tecnologias Agropecuárias, Universidade Estadual do Norte Fluminense, Rio de Janeiro, 2016.

OLIVEIRA, T. M.; ARAJÚJO, A. C. O. Consequências da subnotificação dos casos de COVID-19 para a saúde pública no Brasil. **Interamerican Journal of Medicine and Health**. *[S. L.]*, v. 3, p. 1-4, fev. 2020.

OLIVEIRA, W. K.; DUARTE, E.; FRANÇA, G. V. A.; GARCIA, L. P. Como o Brasil Pode Deter a Covid-19. **Epidemiologia e Serviços de Saúde**, Distrito Federal, v. 29, n. 2, p. 1-8, abr. 2020.

OLIVEIRA, C. A.; MOSSI, M. A.; LEONELLI, G. C. V. O Avanço Legal da Expansão Urbana na Áreal Rural: Contrassenso Democrático e Flexibilização do Perímetro Urbano em Campinas-SP. *In:* ENANPUR, 18., 2019, Natal. **Anais [...].** Natal: Anpur, 2019. p. 1-19. Disponível em: http://anpur.org.br/xviiienanpur/anaisadmin/capapdf.php?reqid=1586. Acesso em: 15 fev. 2022.

PEREIRA, R. H. M.; BRAGA, C. K. V.; SERRA, B.; NADALIN, V. Desigualdades socioespaciais de acesso a oportunidades nas cidades brasileiras - 2019. **Texto para Discussão Ipea, 2535**. Instituto de Pesquisa Econômica Aplicada (Ipea). 2020a. Disponível em http://repositorio.ipea.gov.br/handle/11058/9586. Acesso em: 15 jul. 2022.

PEREIRA, R. H. M.; BRAGA, C. K. V. SERVO, L. M.; SERRA, B.; AMARAL, P.; GOUVEIA, N. Mobilidade Urbana e o Acesso ao Sistema Único de Saúde para Casos Suspeitos e Graves de Covid-19 nas Vinte Maiores Cidades do Brasil. **Nota Técnica nº 14.** Instituto de Pesquisa Econômica Aplicada (Ipea). 2020b. Disponível em: http://repositorio.ipea.gov.br/handle/11058/9840. Acesso em: 10 jul. 2022

PEREIRA, R. H. M.; SCHWANEN, T. Tempo de deslocamento casa-trabalho no Brasil (1992-2009): Diferenças entre regiões metropolitanas, níveis de renda e sexo. **Texto para Discussão Ipea, 1813**. Instituto de Pesquisa Econômica Aplicada (Ipea). 2013. Disponível em: https://www.ipea.gov.br/portal/images/stories/PDFs/TDs/td_1813.pdf. Acesso em: 17 jul. 2022

PEREIRA, R. H. M.; WARWAR, L.; PARGA, J.; BAZZO, J.; BRAGA, C. K.; HERSZENHUT, D.; SARAIVA, M. Tendências e desigualdades da mobilidade urbana no Brasil I: o uso do transporte coletivo e individual. **Texto para Discussão Ipea, 2673**. Instituto de Pesquisa Econômica Aplicada (Ipea). 2021. Disponível em http://repositorio.ipea.gov.br/handle/11058/10713. Acesso em: 13 jul. 2022.

PEREIRA JÚNIOR, E.; SAMPAIO, J. E. H.; GOMES, R. B. A Covid-19 e sua dinâmica de propagação na rede urbana do Ceará, Brasil. **Ateliê Geográfico**. v. 14, n. 3, p. 35-56, 2020.

RIBEIRO, D. A.; BRAGA, A. F. D.; TEIXEIRA, L. Desigualdade socioespacial e o impacto da Covid-19 na população do Rio de Janeiro: análises e reflexões. **Cadernos Metrópole**. v. 23, n. 52, p. 949-969, 2021.

RODRIGUES, J. M. Mobilidade urbana no Brasil: crise e desafios para as políticas públicas. **Revista TCEMG.** v. 34, n. 3, p. 80-93, jul/set. 2016.

RODRÍDEZ-POSE, A.; BURLINA, C. Institutions and the uneven geography of the first wave of the COVID-19 pandemic. **Journal of Regional Science**. v. 61, ed. 4, p. 728–752, 2021.

SALATTA, A. R.; RIBEIRO, M. G. **Boletim Desigualdade nas Metrópoles**. n. 4, 2021. Disponível em: https://www.observatoriodasmetropoles.net.br/wp-content/uploads/2021/07/BOLETIM_DESIGUALDADE-NAS-METROPOLES_04.pdf. Acesso em: 15 jan. 2023.

SALES, L. R. Os Efeitos da Pandemia do Covid-19 nas Desigualdades Sociais e no Planejamento Urbano. **Revista Rural & Urbano**, Recife, v. 5, n. 2, p. 100-121, set. 2020.

SANTOS, L. S.; LIMA, V. M.; COSTA, S. M. F. Ambiente e saúde em tempos de Covid-19: um estudo da pequena cidade de Afuá, Pará. **Revista Geoconexões Online.** v.1, p.245, 2022.

SATHLER, D.; LEIVA, G. A Cidade Importa: urbanização, análise regional e segregação urbana em tempos de pandemia de Covid-19. **Revista Brasileira de Estudos de População.** Rio de Janeiro, v. 39, p. 1-30, 2022.

SCOTT, D. M.; HORNER, M. W. The Role of Urban Form in Shaping Access to Opportunities: An Exploratory Spatial Data Analysis. **Journal of Transport and Land Use**. v. 1, n. 2, p. 89–119, 2008.

SEBBENN, R. A.; RUSCHEL, A. C. Uma análise das vantagens da verticalização urbana. In: ENANPUR, 18., 2019, Natal. **Anais [...].** Natal: Anpur, 2019. p. 1-24. Disponível em: http://anpur.org.br/xviiienanpur/anaisadmin/capapdf.php?reqid=1339#:~:text=O%20ponto%20mais%20relevante%20na,NIJKAMP%20e%20RIENSTRA%2C%201996). Acesso em: 10 dez. 2021.

SILVA, T. C.; KATIKIREDDI, S. V.; OLIVEIRA, V. A.; ORTIZ, R. F.; JÚNIOR, J.B.; PAIXÃO, E. S.; ROBERTSON, C.; PENNA, G. O.; WERNECK, G. L.; BARRETO, M. L.; PEARCE, N.; SHEIKH, A.; NETTO, M. B.; BOAVENTURA, V. S. Vaccine effectiveness of heterologous CoronaVac plus BNT162b2 in Brazil. **Nature Medicine**. v. 28, p. 838-843, 2022.

SIMÕES, R.; AMARAL, P. V. Interiorização e Novas Centralidades Urbanas: Uma Visão Prospectiva para o Brasil. **ANPEC**. v. 12, n. 3, p. 553-579, 2011.

SOARES, J. A S.; ALENCAR, L. D.; CAVALCANTE, L. P S.; ALENCAR, L. D. Impactos da Urbanização Desordenada na Saúde Pública: Leptospirose e Infraestrutura Urbana. **Polêm!ca**. v. 13, n. 1, p. 1006-1020, 2014.

SOUSA, C. R. M. A Pandemia do Covid-19 e a Necropolítica Brasileira. **Revista de Direito**, Viçosa, v. 13, n. 1, p. 1-27, 2021.

SURYA, B; SALIM, A; HERNITA, H; SURIANI, S; MENNE, F; RASYIDI, E. S. Land Use Change, Urban Agglomeration, and Urban Sprawl: A Sustainable Development Perspective of Makassar City, Indonesia. **Land.** v. 10, n. 6, p. 1-31. Basel, 2021.

TAUIL, P. L. Urbanização e Ecologia da Dengue. **Caderno de Saúde Pública**. s. 17, p. 99-102, 2001.

THISSE, J. F. Agglomeration and Regional Imbalance: Why? and is it Bad? **EIB Papers**. v. 5, n. 2, p. 47-67, 2000.

TINOCO, A. Das Economias de Aglomeração às Externalidades Dinâmicas de Conhecimento. **Revista Brasileira de Estudos Urbanos e Regionais**. v. 5, n. 1, p. 47-61, 2003.

VIEZZER, J.; BIONDI, D. The influence of urban, socio-economic, and eco-environmental aspects on COVID-19 cases, deaths and mortality: A multi-city case in the Atlantic Forest, Brazil. **Sustain Cities Soc**. 2021.

WONG, D. W. S.; LI, Y. Spreading of COVID-19: Density matters. **PLoS ONE**. v. 15, n. 12, p. 1-16, 2020.

YÜCEL, S. G.; PEREIRA, R. H. M. PEIXOTO, P. S.; CAMARGO, C. Q. Impact of network centrality and income on slowing infection spread after outbreaks. **Applied Network Science**. v. 8, n. 16, p. 1-22, 2023.

APÊNDICE A – ROBUSTEZ DOS MODELOS ATESTADA PARA OUTRAS DATAS

Tabela 7 - Resultado do modelo de equações estruturais para taxa de infecções

	SEM 16/01/21		SEM 22/12/20		SEM 31/12/20	
	(1)	(2)	(3)	(4)	(5)	(6)
Variáveis	**ln_txinfec**	**Coeficientes Padronizados da Coluna 1 †**	**ln_txinfec**	**Coeficientes Padronizados da Coluna 3 †**	**ln_txinfec**	**Coeficientes Padronizados da Coluna 5 †**
ln_popurb	0,0359*** (0,0095)	0,0704*** (0,0186)	0,0387*** (0,0104)	0,0711*** (0,0191)	0,0385*** (0,0101)	0,0721*** (0,0189)
densES	0,0219*** (0,0029)	0,1644*** (0,0219)	0,0197*** (0,0032)	0,1388*** (0,0226)	0,0219*** (0,0031)	0,1577*** (0,0222)
densR	-0,0002*** (0,0000)	-0,3098*** (0,0349)	-0,0002*** (0,0000)	-0,2945*** (0,0335)	-0,0002*** (0,0000)	-0,3082*** (0,0339)
densA	0,0002*** (0,0000)	0,1140*** (0,0175)	0,0002*** (0,0000)	0,1209*** (0,0174)	0,0002*** (0,0000)	0,1193*** (0,0176)
densEE	0,0038** (0,0018)	0,0686** (0,0322)	0,0041** (0,0019)	0,0701** (0,03216)	0,0039** (0,0018)	0,0676** (0,0320)
mob_pend	-1,2360*** (0,1770)	-0,0903*** (0,0129)	-1,2079*** (0,1828)	-0,0838*** (0,0126)	-1,1932*** (0,1798)	-0,0840*** (0,0126)
hierarquia_simpl	0,1356*** (0,0312)		0,1768*** (0,0331)		0,1647*** (0,0326)	
emissão_pcp	0,0001 (0,0001)	0,0175 (0,0134)	0,0001 (0,0001)	0,0754*** (0,0141)	0,0001 (0,0001)	0,0133 (0,0130)
prop_idosos	-3,9060*** (0,3779)	-0,0186*** (0,0176)	-4,5184*** (0,4086)	0,0146 (0,0130)	-4,2486*** (0,3980)	-0,1924*** (0,0176)
gini	0,5550*** (0,1875)	0,0540** (0,0182)	0,4109** (0,2059)	-0,2004*** (0,0177)	0,4428** (0,2005)	0,0413** (0,0186)
prop_pob	-0,7992*** (0,0982)	-0,2133*** (0,0260)	-0,4797*** (0,1024)	0,0376** (0,0188)	-0,5413*** (0,1011)	-0,1383*** (0,0257)
ln_txinfec				-0,1203*** (0,0256)		
intercepto	5,7936*** (0,1251)	8,6094*** (0,2145)	5,6635*** (0,1355)	7,9021*** (0,2165)	5,6866*** (0,1324)	8,0806*** (0,2158)
Observações	4855	4855	4748	4748	4789	4789
R^2	0,201	0,201	0,356	0,356	0,373	0,373
SRMR	0,005	0,005	0,086	0,086	0,086	0,086

Fonte: Elaboração própria.

Nota: † Coeficientes padronizados de variáveis *dummy* não são apresentados, pois não possuem sentido de interpretação, logo a interpretação da hierarquia urbana será dada através dos coeficientes não padronizados (Coluna 1). Desvios padrão robustos constam entre os parênteses. Níveis de significância: * p<0.10, ** p<0.05, *** p<0.01

Tabela 8 - Resultado do modelo de equações estruturais para taxa de óbitos

	SEM 16/01/21		**SEM 22/12/20**		**SEM 31/12/20**	
	(1)	**(2)**	**(3)**	**(4)**	**(5)**	**(6)**
Variáveis	**ln_txobito**	**Coeficientes Padronizados da Coluna 1†**	**ln_txobito**	**Coeficientes Padronizados da Coluna 3†**	**ln_txobito**	**Coeficientes Padronizados da Coluna 5†**
ln_popurb	0,0513*** (0,0081)	0,0951*** (0,0151)	0,0443*** (0,0087)	0,0796*** (0,0156)	0,0473*** (0,0084)	0,0862*** (0,0154)
densES	-0,0047** (0,0021)	-0,0333** (0,0149)	-0,0071*** (0,0022)	-0,0488** (0,0159)	-0,0061*** (0,0021)	-0,0426** (0,1497
densR						
densA	0,0001*** (0,0000)	0,0389** (0,0149)	0,0001*** (0,0000)	0,0543*** (0,1504)	0,0001*** (0,0000)	0,0488 (0,0121)
densEE						
mob_pend						
hierarquia_simpl	0,2983*** (0,0283)		0,3329*** (0,0298)		0,3177*** (0,0292)	
emissão_pcp						
prop_idosos	0,9600*** (0,3279)	0,0432** (0,0147)	0,6029* (0,3488)	0,0261* (0,0151)	0,8574** (0,3400)	0,1449** (0,0149)
Gini	-0,1629 (0,1820)	-0,0150 (0,0167)	-0,1304 (0,1898)	-0,0117 (0,0169)	-0,1516 (0,1849)	-0,0137 (0,0167)
prop_pob	-0,0797 (0,0754)	-0,0201 (0,0190)	0,0879 (0,0804)	0,0215 (0,0197)	0,0539 (0,0780)	0,0134 (0,0193)
ln_txinfec	0,4976*** (0,0145)	0,4704*** (0,0119)	0,4844*** (0,0152)	0,4426*** (0,0123)	0,4967*** (0,0149)	0,4602*** (0,0121
intercepto	-1,6162*** (0,1358)		-1,6241*** (0,1431)	-2,2155*** (0,1896)	-1,6859*** (0,1402)	0,4602*** (0,0121)
Observações	4855	4855	4748	4748	4789	4789
R^2	0,201	0,201	0,356	0,356	0,373	0,373
SRMR	0,005	0,005	0,086	0,086	0,086	0,086

Fonte: Elaboração própria.

Nota: † Coeficientes padronizados de variáveis *dummy* não são apresentados, pois não possuem sentido de interpretação, logo a interpretação da hierarquia urbana será dada através dos coeficientes não padronizados (Coluna 1). Desvios padrão robustos constam entre os parênteses. Níveis de significância: * p<0.10, ** p<0.05, *** p<0.01

Tabela 9 - Resultados do modelo estrutural para as três datas – modelo de múltiplos indicadores e múltiplas causas (MIMIC)

	MIMIC 16/01/21		**MIMIC 22/12/20**		**MIMIC 31/12/20**	
	(1)	**(2)**	**(3)**	**(4)**	**(5)**	**(6)**
Variáveis	**Índice de Compacidade Urbana**	**Coeficientes Padronizados da Coluna 1†**	**Índice de Compacidade Urbana**	**Coeficientes Padronizados da Coluna 3†**	**Índice de Compacidade Urbana**	**Coeficientes Padronizados da Coluna 5†**
ln_popurb	0,0448*** (0,0091)	0,1081*** (0,0228)	0,0441*** (0,0098)	0,0999*** (0,0230)	0,0454*** (0,0096)	0,1045*** (0,0230)
densES	0,0171*** (0,0031)	0,1578*** (0,0259)	0,0142*** (0,0035)	0,1231*** (0,0276)	0,0165*** (0,0034)	0,1456*** (0,0270)
densR	-0,0002*** (0,0000)	-0,3013*** (0,0404)	-0,0002*** (0,0000)	-0,2776*** (0,0413)	-0,0002*** (0,0000)	-0,2943*** (0,0411)
densA	0,0002*** (0,0000)	0,1283*** (0,0183)	0,0002*** (0,0000)	0,1377*** (0,0182)	0,0002*** (0,0000)	0,1348*** (0,0184)
densEE	0,0024 (0,0016)	0,0537 (0,0354)	0,0026 (0,0017)	0,0543 (0,0358)	0,0024 (0,0017)	0,0522 (0,0355)
mob_pend	-0,8523*** (0,1594)	-0,0766*** (0,0134)	-0,7941*** (0,1765)	-0,0679*** (0,0137)	-0,7957*** (0,1709)	-0,0687*** (0,0135)
hierarquia_simpl	0,2005*** (0,0305)		0,2434*** (0,0327)		0,2295*** (0,0324)	
emissão_pcp	0,0001 (0,0001)	0,0247 (0,0162)	0,2955 (0,2267)	0,0211 (0,0163)	0,3024 (0,2204)	0,0218 (0,0160)
prop_idosos	-3,2827*** (0,4117)	-0,1921*** (0,0212)	-3,8747*** (0,4737)	-0,2117*** (0,0215)	-3,5939*** (0,4590)	-0,1997*** (0,0215)
Gini	0,4821*** (0,1821)	0,0577** (0,0216)	0,3966** (0,1985)	0,0447** (0,0223)	0,4097** (0,1936)	0,0468** (0,0220)
prop_pob	-0,7754*** (0,0893)	-0,2547*** (0,0290)	-0,4985*** (0,0932)	-0,1540*** (0,0292)	-0,5517*** (0,0916)	-0,1730*** (0,0290)
Observações	4.855	4.855	4.748	4.748	4.789	4.789
R^2	0,222	0,222	0,185	0,185	0,190	0,190
SRMR	0,020	0,020	0,019	0,019	0,019	0,019

Fonte: Elaboração própria.

Nota: † Coeficientes padronizados de variáveis *dummy* não são apresentados, pois não possuem sentido de interpretação, logo a interpretação da hierarquia urbana será dada através dos coeficientes não padronizados (Coluna 1). Desvios padrão robustos constam entre os parênteses. Níveis de significância: * p<0.10, ** p<0.05, *** p<0.01

Tabela 10 - Resultados do modelo de mensuração para as três datas – modelo de múltiplos indicadores e múltiplas causas (MIMIC)

MIMIC 16/01/21					
Váriável Endógena	**Coeficiente**	**Coeficiente Padronizado**	R^2	**Intercepto**	**Intercepto Padronizado**
ln_txinfec	1,0000 (Restrição)	0,8126*** (0,0263)	0,6603	5,6492*** (0,1230)	8,3948*** (0,2110)
ln_txobito	0,8229*** (0,0531)	0,6322*** (0,0216)	0,3996	1,6773*** (0,1026)	2,3563*** (-0,1465)
MIMIC 22/12/20					
Váriável Endógena	**Coeficiente**	**Coeficiente Padronizado**	R^2	**Intercepto**	**Intercepto Padronizado**
ln_txinfec	1,0000 (Restrição)	0,8117*** (0,0325)	0,6589	5,5265*** (0,1341)	7,7158*** (0,2125)
ln_txobito	0,7964*** (0,0648)	0,6316*** (0,0264)	0,399	1,5911*** (0,1073)	2,1705*** (0,1480)
MIMIC 31/12/20					
Váriável Endógena	**Coeficiente**	**Coeficiente Padronizado**	R^2	**Intercepto**	**Intercepto Padronizado**
ln_txinfec	1,0000 (Restrição)	0,8150*** (0,0312)	0,6642	5,5430*** (0,1317)	7,8808*** (0,2127)
ln_txobito	0,8025*** (0,0619)	0,6355*** (0,0255)	0,4038	1,6060*** (0,1071)	2,2184*** (0,1497)

Fonte: Elaboração Própria.

Nota: O coeficiente do ln_txinfec é 1pois esse indicador foi a referência para a normalização do construto do índice de compacidade urbana, assegurando a propriedade de identificação do modelo. Desvios padrão robustos constam nos parênteses. Níveis de significância: *p<0.10, ** p<0.05, *** p<0.01.