

---

# DETERMINANTES DA DISSEMINAÇÃO E MORTALIDADE DA COVID-19: UMA ANÁLISE EM CROSS-SECTION DOS BAIRROS DE SALVADOR

*Causes of COVID-19's Dissemination and Death Toll: A Cross-Section Analysis of Salvador's Districts*

## Gisele Ferreira Tiryaki

Economista. Ph.D. em Economia. Professora Associada do Departamento de Economia, Universidade Federal da Bahia (UFBA). Praça da Piedade 6, Salvador (BA). [gtiryaki@ufba.br](mailto:gtiryaki@ufba.br)

## Cláudia Sá Malbouisson Andrade

Economista. Ph.D. em Economia. Professora Associada – UFBA. [cmalbo@ufba.br](mailto:cmalbo@ufba.br)

## Denise Silva Matias

Médica. Ph.D. em Medicina. Professora Adjunta – Centro de Medicina Baseada em Evidências, Escola Bahiana de Medicina e Saúde Pública. Campus Brotas, Salvador (BA). [denisematias@bahiana.edu.br](mailto:denisematias@bahiana.edu.br)

## Maíra Lima Silva

Economista. Doutoranda do Programa de Pós-Graduação em Economia (UFBA). [maaairalima@gmail.com](mailto:maaairalima@gmail.com)

---

**Resumo:** A pandemia da Covid-19 tem provocado perdas significativas em vidas e qualidade da saúde das pessoas, além de impactar negativamente a geração de emprego e renda e a sustentabilidade das contas públicas. Este trabalho busca avaliar se o adensamento populacional, a intensidade das atividades econômicas, os efeitos de vizinhança e características demográficas e socioeconômicas são determinantes do contágio, mortalidade e letalidade da Covid-19. Utilizando dados em *cross-section* dos bairros do município de Salvador no período 2020-2021, foram estimados modelos de regressão quantílica, regressão robusta e análise espacial. Os resultados indicam que bairros com atividades econômicas mais intensas e com população predominantemente de homens negros com baixa escolaridade e renda apresentam maiores níveis de contaminação e gravidade da Covid-19. A predominância de idosos na população foi relevante para as taxas de incidência e mortalidade, enquanto os efeitos de vizinhança revelaram-se importantes apenas para a taxa de letalidade.

**Palavras-chave:** saúde; demografia; renda; vizinhança.

**Abstract:** Besides hurting income and job creation and public budgets' sustainability, the Covid-19 pandemic has caused major losses in human life and health quality. This paper aims at evaluating if population density, economic activity intensity, neighborhood effects, and demographic and economic features influence the degree of infection, mortality, and fatality associated with Covid-19. The paper estimates quantile, robust, and spatial regression models using cross-section data of the neighborhoods comprising Salvador's municipality during the 2020-2021 period. The results show that Covid-19's dissemination and death toll levels are greater in areas with more intense economic activity and whose population is mostly comprised of black men with low education and income levels. The predominance of the elderly in the population increases the incidence and mortality rates, while neighborhood effects were only relevant to the fatality rates.

**Keywords:** health; demographics; income; neighborhood.

JEL: I18; C21

## 1 INTRODUÇÃO

A pandemia do coronavírus SARS-CoV-2 (Covid-19) foi responsável por cerca de 7 milhões de óbitos no mundo entre março de 2020 e março de 2024, sendo mais de 700 mil no Brasil (Worldometer, 2024). As perdas também envolveram maiores taxas de desemprego e redução na renda das famílias, frutos das restrições impostas à atividade econômica por *lockdowns*. Dados do Banco Central do Brasil – BCB (2022) mostram uma contração de 4,6% no produto interno bruto (PIB) *per capita* e um aumento de 12% na taxa de desemprego do Brasil em 2020. Ademais, Levy *et al.* (2021) indicam que quase a totalidade do déficit primário do governo federal em 2020 decorreu da adoção de medidas mitigadoras dos impactos da Covid-19 (e.g. transferências diretas de renda, desonerações fiscais).

Áreas com maior densidade populacional e atividades econômicas intensas estimulam a aglomeração de pessoas, favorecendo o contágio pelo coronavírus. Essa constatação fundamentou a adoção de restrições nas atividades econômicas e na livre movimentação de indivíduos nos primeiros meses da pandemia. Ademais, outras características demográficas e aspectos socioeconômicos também influenciam a incidência e letalidade do vírus.

Indivíduos idosos, do sexo masculino e da raça negra comumente possuem comorbidades que agravam o quadro da doença, como diabetes, hipertensão e doenças cardiovasculares. Pessoas do sexo masculino também tendem a ser menos avessas ao risco e, por isso, adotam condutas que aumentam a probabilidade de contágio e letalidade da Covid-19, como ignorar medidas preventivas e adiar a busca por assistência médica. Por fim, indivíduos com baixa escolaridade e renda têm menor acesso à informação, o que compromete a aderência às práticas de prevenção contra doenças e o acesso a serviços de saúde.

Identificar fatores que tornam determinados grupos de indivíduos mais suscetíveis à contaminação e ao agravamento de infecções é um importante insumo no delineamento de políticas públicas de prevenção, controle e tratamento de doenças infectocontagiosas. A prevalência de determinadas características populacionais em espaços geográficos específicos permite estabelecer áreas de prioridade para intervenção, com estratégias de disseminação de informação e de oferta de serviços de saúde mais bem orientadas.

Este trabalho tem o objetivo de verificar a importância do adensamento populacional, da intensidade das atividades econômicas, dos efeitos de vizinhança e de características demográficas e socioeconômicas para a contaminação e letalidade da Covid-19. O estudo utiliza dados em *cross-section* de bairros do município de Salvador para estimar modelos de regressão quantílica, regressão robusta e análise espacial. Em 2021, Salvador destacava-se como a quarta capital do País em número de óbitos e a sexta em casos confirmados, ocupando posição de liderança em número de óbitos e segunda no ranking de infecções confirmadas na Região Nordeste (FMRP/USP, 2022). A estrutura de bairros de Salvador é particularmente adequada à análise proposta nesse trabalho, em razão da existência de *clusters* espaciais com intensidade nas atividades econômicas e com características demográficas e socioeconômicas específicas.

## 2 REVISÃO DA LITERATURA

Existe uma extensa literatura dedicada a analisar os determinantes da contaminação e gravidade dos casos da Covid-19. Muitos trabalhos têm buscado identificar fatores de risco associados às comorbidades que deixam alguns indivíduos mais predispostos à doença. Já outras pesquisas buscam avaliar como a relação entre esses fatores de risco e aspectos ambientais, comportamentais, demográficos e socioeconômicos levam à proliferação da Covid-19 e ao agravamento do quadro

de saúde dos infectados. Esta seção apresenta uma breve revisão da literatura dessa segunda linha de pesquisa, que é o foco do presente artigo<sup>1</sup>.

Estudos mostram que a densidade populacional e a intensidade das atividades econômicas contribuem para uma maior aglomeração de pessoas, elevando o risco de disseminação do vírus. Wong e Li (2020), por exemplo, estimam que a densidade populacional explica entre 57% e 76% da variância no número de casos de Covid-19 identificados em condados americanos. Sy *et al.* (2021) encontram resultado similar, baseando-se, também, em dados de condados americanos: uma maior densidade demográfica eleva a transmissibilidade da doença, representada pelo número básico de reprodução ( $R_0$ )<sup>2</sup>. Para esses autores, disparidades geográficas no grau de transmissibilidade durante os estágios iniciais de epidemias refletem essencialmente diferenças nas taxas de contato entre indivíduos.

Outras características populacionais que aparentam contribuir para o contágio e letalidade da Covid-19 são a idade, raça e sexo dos indivíduos. Pessoas idosas apresentam um alto risco de contágio e de desenvolvimento de quadros graves de Covid-19. Perrotta *et al.* (2020) e Kang e Jung (2020) afirmam que as funções imunológicas declinam com a idade, elevando a suscetibilidade dos idosos à contaminação pelo vírus. Além disso, comorbidades se intensificam em pacientes idosos, particularmente doenças respiratórias, diabetes e hipertensão, enfermidades que comprometem a recuperação dos pacientes. De acordo com Kang e Jung (2020), alguns estudos mostram que a taxa média de letalidade da Covid é de 2,3%, mas pode atingir de 8% a 10% em indivíduos com idade entre 70 e 79 anos e mais de 25% em idosos com mais de 80 anos<sup>3</sup>.

Indivíduos da raça negra também se mostram particularmente suscetíveis, em razão da prevalência de obesidade e outras comorbidades nesse grupo demográfico e do acesso restrito a serviços de saúde, em razão de restrições econômicas (Kopel *et al.*, 2020; Samuel *et al.*, 2021; Abedi *et al.*, 2021). A obesidade é um dos principais fatores de risco para a Covid-19, pois habitualmente leva a quadros de hipertensão, doenças cardiovasculares e diabetes. Dohet *et al.* (2022) afirmam que pessoas obesas também apresentam reduzido nível de adiponectina, hormônio que possui funções imunológicas anti-inflamatórias.

Utilizando dados de seis grandes cidades americanas, Benitez *et al.* (2020) mostram que bairros com maior representatividade de negros e hispânicos apresentam maiores taxas de incidência da Covid-19<sup>4</sup>. Dados de contaminação entre negros e imigrantes tendem a ser subestimados, já que a realização de testes de detecção é menos frequente, por serem grupos demográficos com renda mais baixa (Borjas, 2020).

Os estudos também apontam fatores biológicos, psicossociais e comportamentais que elevam a probabilidade de infecção e agravamento da doença em indivíduos do sexo masculino. Spagnolo (2020) e Kopel (2020) afirmam que mulheres apresentam respostas imunes e adaptativas mais fortes do que os homens, além de apresentarem menores níveis plasmáticos da enzima ACE2, que é um receptor funcional para o vírus.

Fatores psicossociais e comportamentais também deixam indivíduos do sexo masculino mais expostos à Covid-19, principalmente devido a sua maior propensão ao risco (Lewis; Duch, 2021). Homens preocupam-se menos com o distanciamento social e com outras medidas preventivas de contaminação, como o uso de máscaras e hábitos de higiene, e relutam em buscar ajuda médica

1 Para o leitor interessado, Booth *et al.* (2021) apresentam uma ampla discussão da literatura médica que identifica fatores clínicos de risco da Covid-19.

2 O  $R_0$  é o número de pessoas contaminadas por um único indivíduo em uma população completamente suscetível, sendo função das taxas de contato entre indivíduos, probabilidade de transmissão e duração da infecção. Difere, portanto, do número efetivo de reprodução ( $R_t$ ), definido pelo número de pessoas em uma população com algum grau de imunidade que são infectadas por um indivíduo em um ponto no tempo. De acordo com Sy *et al.* (2021), o  $R_0$  depende do patógeno e de aspectos comportamentais e ambientais, enquanto o  $R_t$  reflete mudanças na imunidade populacional.

3 Taxa de letalidade é o percentual do número de infectados que foram a óbito.

4 A taxa de incidência ou de contaminação refere-se ao número de casos em relação à população da região.

(Baker *et al.*, 2020; Galasso *et al.*, 2020). Ademais, Capuano *et al.* (2020) argumentam que o consumo elevado de bebidas alcoólicas e tabagismo é mais prevalente entre indivíduos do sexo masculino, hábitos que comprometem a imunidade e a saúde.

Por fim, o perfil socioeconômico dos indivíduos influencia seu acesso à informação e aos serviços de saúde, afetando sua suscetibilidade à Covid-19 (Rattay *et al.*, 2020). Indivíduos de baixa renda enfrentam dificuldades em participar do ensino formal, pois precisam se engajar mais jovens em atividades laborais. Possuem, portanto, uma compreensão mais limitada da importância das práticas de prevenção contra a doença. Ademais, a menor renda inviabiliza o acesso aos testes de detecção da doença e restringe o acesso a serviços de saúde de melhor qualidade. Abedi *et al.* (2021) mostram que as taxas de mortalidade por Covid-19 nos Estados Unidos crescem de maneira significativa em condados com maior percentual de pessoas vivendo em situação de pobreza<sup>5</sup>. Já Samuel *et al.* (2021) argumentam que indivíduos com baixo nível educacional normalmente exercem atividades com menor qualificação e que não podem ser exercidas remotamente, o que os expõe a doenças infectocontagiosas.

Estudos sobre os determinantes da incidência e gravidade da Covid-19 no Brasil utilizaram comumente dados agregados nacionais ou em nível dos estados. Demenech *et al.* (2020), por exemplo, estimam um modelo espacial com dados em *cross-section* dos estados brasileiros e mostram que as taxas de contaminação e mortalidade por Covid-19 crescem em estados com maior desigualdade de renda. Já Figueiredo *et al.* (2020) conduzem uma análise de regressão linear, também com dados em *cross-section* dos estados brasileiros, e encontram que a desigualdade de renda e o adensamento domiciliar são importantes preditores das taxas de incidência e óbitos por Covid-19. No entanto, esses artigos não levaram em consideração outras características demográficas relevantes, como idade, raça e sexo dos indivíduos.

Tais elementos estão presentes em França *et al.* (2021), que utilizam dados agregados nacionais para verificar se a Covid-19 afetou de maneira desproporcional a população de renda mais baixa no Brasil. Os autores conduziram uma análise de decomposição para verificar o impacto de diferentes variáveis socioeconômicas e demográficas na determinação de um índice de desigualdade de renda. Posteriormente, analisaram o impacto desse índice sobre o número de casos e gravidade dos sintomas da Covid-19 entre julho e novembro de 2020. Os resultados indicam que a contaminação por Covid-19 é mais significativa entre os indivíduos de maior renda, mas a desigualdade de renda não parece estar associada com a gravidade dos sintomas. A relação positiva entre níveis de contaminação e renda é um fenômeno observado em outros estudos com dados do Brasil, inclusive no presente estudo.

Nicolelis *et al.* (2021) dedicaram-se a mostrar que restrições mais efetivas no tráfego rodoviário nos estágios iniciais da pandemia e uma melhor distribuição de recursos de saúde poderiam ter reduzido a contaminação da Covid-19 no Brasil. Utilizando um modelo multilinear, os autores mostram que um conjunto de 26 rodovias foi responsável por cerca de 30% do transbordamento espacial dos casos de Covid-19. A disseminação teve por origem a cidade de São Paulo e, posteriormente, outras 16 metrópoles foram responsáveis por quase a totalidade da interiorização da doença no País. Como as cidades menores carecem de serviços públicos de qualidade com unidades de terapia intensiva, muitos casos severos da doença foram levados para as capitais e outras cidades de maior porte, amplificando a contaminação.

Vários trabalhos têm avaliado os determinantes do avanço e letalidade da Covid-19 no País utilizando dados estaduais ou municipais. Lourenço e Santos (2022), por exemplo, avaliam a importância da idade, raça, condições de saúde dos pacientes e da infraestrutura do sistema de saúde dos municípios do estado do Rio de Janeiro. Utilizando uma análise linear em *cross-section* dos municípios e um modelo probit com microdados dos infectados, os autores encontram resultados

5 Taxa de mortalidade é o número de óbitos em relação à população.

similares ao presente trabalho: indivíduos idosos, de baixa renda e da raça negra são mais suscetíveis ao agravamento do quadro de saúde em razão da Covid-19.

Destacam-se, ainda, os trabalhos de Cavalcante e Abreu (2020) e Cestari *et al.* (2021), que buscaram avaliar os determinantes da contaminação e gravidade da Covid-19 no Rio de Janeiro e em Fortaleza, respectivamente. Cavalcante e Abreu (2020) utilizam análise espacial para mostrar que as taxas de incidência são maiores em bairros de maior renda, enquanto as taxas de mortalidade e letalidade são mais representativas em bairros de baixa renda, um resultado semelhante ao encontrado no presente trabalho e em França *et al.* (2021). Já Cestari *et al.* (2021), utilizando modelos de regressão linear e espacial, mostram que a incidência de Covid-19 se eleva em bairros com maior percentual de trabalhadores autônomos, já que estes se expõem mais ao risco de contágio por terem menores condições de trabalho remoto.

As estratégias empíricas adotadas nos estudos utilizando dados de Salvador enfatizaram a análise descritiva dos dados, mesmo aqueles que conduziram análise espacial. Natividade *et al.* (2020), por exemplo, mostram que o distanciamento social foi mais eficaz em bairros de maior renda, possivelmente por ser mais difícil para pessoas de baixa renda exercerem trabalho remoto, já que muitas delas estão engajadas na economia informal. Já a pesquisa realizada pela UFBA (2020) utiliza análise espacial para identificar os bairros de Salvador com elevado risco de contaminação, medido pela intensidade do fluxo de transporte público urbano e vulnerabilidade socioeconômica. O trabalho mostra que bairros de baixa renda localizados na região noroeste do município mostraram-se particularmente suscetíveis ao contágio.

Por fim, Pimenta *et al.* (2021) apresentam uma análise econométrica da evolução temporal da contaminação por Covid-19 nos bairros de Salvador ao longo dos primeiros quatro meses de pandemia, levando em consideração o tamanho da população, área, densidade demográfica, indicador de desenvolvimento humano, participação masculina na população do bairro e indicadores de contágio por outras patologias. A análise em painel desses autores evidencia que apenas o tamanho da população apresentou significância estatística, impactando positivamente o contágio pelo coronavírus. Já a análise espacial indica que as taxas de contágio são maiores em bairros de alta renda e as taxas de óbito em bairros de baixa renda, revelando a discrepância entre volume de testagem e acesso a serviços de saúde de qualidade associados a diferentes níveis de renda. Como apontado anteriormente, esse último resultado também ficou evidente em Cavalcanti e Abreu (2020), França *et al.* (2021) e no presente trabalho.

### 3 DETERMINANTES DA COVID-19: DADOS E VARIÁVEIS

Este artigo utiliza dados de contaminação e óbitos associados à Covid-19 nos 170 bairros de Salvador, entre janeiro de 2020 e agosto de 2021 (Secretaria Municipal de Saúde de Salvador – SMS, 2021). Nesse período, foram registrados mais de 200 mil casos de Covid-19, sendo que 7280 indivíduos vieram a óbito. As mulheres representam 54% dos casos identificados, mas apenas 46% dos óbitos registrados no município de Salvador. A infecção por Covid-19 foi mais letal entre pardos e pretos, levando a óbito cerca de 3,6% dos infectados, enquanto a taxa de letalidade entre amarelos e brancos foi de 3,2% e entre indígenas foi de 2,9%. Do total de óbitos, 60,4% ocorreram em adultos com idade superior a 64 anos<sup>6</sup>.

Na Tabela 1, são elencados os dez bairros com maiores taxas de incidência, letalidade e mortalidade associadas à Covid-19, sendo possível notar que as localidades com maior número de casos em relação à sua população não figuram entre os bairros com maior número de óbitos em relação

6 Dados da SEI (2022) indicam que idosos representam cerca de 6% da população de Salvador, mas sua participação chega a exceder 15% em bairros da região centro-atlântica do município.

ao total de casos identificados, embora alguns bairros apresentem altas taxas de incidência e mortalidade (Jardim Armação, Amaralina, Retiro, Jardim das Margaridas e Dois de Julho).

Tabela 1 – Incidência, Letalidade e Mortalidade da Covid-19 em Salvador, 2020-2021

Taxa de Incidência (Número de casos, % da população)		Taxa de Letalidade (Total de óbitos, % total de casos)		Taxa de Mortalidade (Total de óbitos, % da população)	
Jardim Armação	56.4%	Areia Branca	10.8%	Jardim Armação	1.22%
Retiro	53.4%	Periperi	7.6%	Amaralina	0.92%
Patamares	37.2%	Fazenda Grande I	7.5%	Chame-Chame	0.84%
Centro	25.6%	Santo Antônio	7.4%	Retiro	0.76%
J. Margaridas	24.7%	Cajazeiras VI	6.0%	J. Margaridas	0.72%
Amaralina	20.8%	Curuzu	5.9%	Dois de Julho	0.71%
Piatã	19.4%	Santo Agostinho	5.9%	Nazaré	0.66%
Caminho das Árvores	18.7%	Coutos	5.8%	Praia Grande	0.61%
Dois de Julho	17.2%	Mares	5.8%	Barris	0.60%
Baixa de Quintas	17.1%	Nazaré	5.7%	Santo Antônio	0.58%

Fonte: Elaboração própria, dados da SMS (2021) e da SEI (2022).

### 3.1 Indicadores de impacto da Covid-19 e seus determinantes

O presente trabalho tem por objetivo estimar a seguinte equação:

$$Y_i = \beta_0 + \beta_1 dens_i + \beta_2 econ_i + \beta_3 X_i + \varepsilon_i \quad (1)$$

onde  $Y_i$  representa os indicadores de incidência, mortalidade e letalidade associados à Covid-19 para cada bairro  $i$  de Salvador, com  $i = 1, 2, \dots, 163$ <sup>7</sup>.  $dens_i$  é a densidade populacional,  $econ_i$  representa medidas de intensidade da atividade econômica, a matriz  $X_i$  representa um conjunto de características socioeconômicas e demográficas e  $\varepsilon_i$  é o termo de erro.

Cinco indicadores de incidência e mortalidade da Covid-19 foram utilizados alternativamente como variável dependente  $Y_i$ : o logaritmo natural do número total de infecções contabilizadas no bairro ( $\ln total$ ), a razão entre o número total de infecções e a população do bairro ( $casos/hab$ ), o logaritmo natural do número total de óbitos ( $\ln obitos$ ), a razão entre o total de óbitos e o número total de infecções ( $tx/letal$ ) e a razão entre o total de óbitos e a população do bairro ( $obitpop$ ). Os dados de população por bairro foram obtidos em SEI (2022)<sup>8</sup>.

O uso de indicadores alternativos do impacto da Covid-19 permite verificar a robustez dos resultados e analisar aspectos distintos da pandemia. Enquanto  $\ln total$  e  $\ln obitos$  contabilizam a disseminação e mortalidade em termos absolutos, as taxas de incidência, letalidade e mortalidade são indicadores mais precisos do grau de contaminação e gravidade da doença. Em particular, dados de mortalidade estão menos suscetíveis a subnotificações do que dados de contaminação.

Aglomerações ocorrem com maior frequência em bairros com maior densidade populacional e elevam o risco de disseminação da Covid-19. Assim, incluiu-se como variável explicativa o logaritmo natural da quantidade de habitantes por quilômetro quadrado,  $\ln dens$  (SEI, 2022). Ati-

<sup>7</sup> A disponibilidade de dados permitiu que os modelos fossem estimados com dados de, no máximo, 163 bairros.

<sup>8</sup> Duas ressalvas devem ser feitas em relação aos dados. Informações de contaminação por Covid-19 tendem a ser inferiores ao número real, em razão de casos assintomáticos, não-testados ou não-notificados. A segunda ressalva refere-se aos dados obtidos junto à SEI (2022), que são defasados, pois foram obtidos do Censo de 2010. Infelizmente, ainda não estão disponíveis dados demográficos e socioeconômicos mais recentes dos bairros de Salvador.

vidades econômicas mais intensas também estimulam aglomerações e, por isso, dois indicadores alternativos foram utilizados para representar a variável: o logaritmo natural do consumo comercial de energia elétrica (lnenerg) e o logaritmo natural da arrecadação de ISS em 2020 (lniss)<sup>9</sup>.

Dados de COELBA (2021) e PMS (2021) mostram que medidas de *lockdowns* levaram a um declínio acentuado no consumo de energia elétrica e na arrecadação tributária do município (Figura 1). O consumo comercial anual de energia, em particular, reduziu 25,4% entre 2019 e 2020. Já a arrecadação de ISS no município declinou em 19,5% no mesmo período, também evidenciando a contração na atividade econômica.

Figura 1 – Consumo de energia elétrica e arrecadação de ISS no município de Salvador



Fonte: Elaboração própria com dados da COELBA (2021) e PMS (2021). Valores indicam a média móvel nos últimos 12 meses.

Características socioeconômicas e demográficas também podem influenciar o grau de contaminação e mortalidade associadas à Covid-19. Como apontado na seção 2, idade, sexo, raça, escolaridade e nível de renda são aspectos que interferem na conduta do indivíduo, elevam sua probabilidade de contágio e afetam sua capacidade de resistência à doença. As seguintes variáveis socioeconômicas e demográficas dos bairros foram incluídas no estudo (SEI, 2022): percentual da população com 65 anos ou mais (old), percentual da população do gênero feminino (mulher), percentual da população que se declara de raça branca (branco), percentual da população com 15 anos ou mais que são alfabetizadas (alfab), logaritmo natural do rendimento médio dos responsáveis por domicílios particulares permanentes (lnrenda) e percentual da população com rendimento de até um salário-mínimo (rendate1sm)<sup>10</sup>. A elevada correlação entre essas variáveis pode ocasionar multicolinearidade (Tabela A1 do Apêndice). Por essa razão, utilizou-se a análise de componentes principais (PCA) para derivar um indicador de características socioeconômicas e demográficas dos bairros.

Apenas o primeiro componente apresentou autovalor maior do que a unidade e foi retido (Tabela A2 do Apêndice). Esse componente (comp1) é positivamente relacionado com todas as variáveis, exceto com rendate1sm. Ou seja, valores maiores do componente são associados com maiores valores para renda e escolaridade e maior proporção de indivíduos idosos, da raça branca e do gênero feminino na população.

Uma avaliação preliminar da relação entre as variáveis utilizadas na análise empírica revela que a maior parte dos indicadores de contaminação e gravidade da Covid-19 apresenta correlação significativa com os indicadores de atividade econômica e, em menor grau, com o indicador de características demográficas e socioeconômicas (Tabela 2).

<sup>9</sup> A economia informal é representativa no município de Salvador, o que torna o consumo de eletricidade um indicador mais robusto de atividade econômica do que estimativas de produto, ainda indisponíveis para o período de estudo.

<sup>10</sup> Incluir o percentual da população com rendimento até um salário-mínimo permite capturar diferenças na distribuição de renda nos bairros.

Tabela 2 – Correlação em Pares entre as Variáveis

	Intotal	casoshab	Inobitos	obitpop	txletal	lndens	compl	lnenerg	Iniss
Intotal	1,000								
casoshab	0,351	1,000							
Inobitos	0,949	0,234	1,000						
obitpop	0,434	0,770	0,448	1,000					
txletal	0,064	-0,194	0,179	0,289	1,000				
lndens	0,247	-0,239	0,283	-0,114	0,063	1,000			
compl	0,234	0,401	0,165	0,441	-0,055	0,194	1,000		
lnenerg	0,642	0,334	0,631	0,419	0,194	0,053	0,303	1,000	
Iniss	0,486	0,406	0,385	0,204	-0,282	-0,177	0,500	0,723	1,000

Fonte: Elaboração própria.

## 4 ESTRATÉGIA ECONOMETRICA

As estimações econométricas iniciais utilizaram o modelo de mínimos quadrados ordinários (MQO), considerando a presença de heterocedasticidade, que é comum em estimativas com dados em *cross-section*. É possível redefinir a equação (1) da seguinte forma:

$$y_i = \sum_{q=1}^k X_{i,q} \beta_q + e_i \quad (2)$$

onde  $y_i$  representa o indicador de incidência, letalidade ou mortalidade do bairro  $i$ , com  $i = 1, 2, \dots, n$  e  $n = 163$ .  $X_{i,q}$  representa as  $q$  variáveis explicativas e  $e_i$  é o termo de erro.

Os resultados obtidos por MQO podem estar enviesados pela presença de observações extremas ou *outliers*. Estatísticas de influência são utilizadas para verificar a existência de distorções causadas por *outliers*, dentre as quais destacam-se *R-student*, *Cook's Distance*, *Leverage*, *Covratio* e *DFBETA*. O *R-student* é calculado a partir da divisão dos resíduos por seus erros-padrão estimados. Observações que apresentam um valor absoluto do *R-student* maior que dois indicam a possibilidade de viés nas estimativas obtidas pelo MQO.

Já a estatística *Cook's Distance* de uma observação é razão entre (i) a distância do valor predito quando se estima o modelo por MQO e o valor predito quando se exclui essa observação e (ii) o erro médio quadrático da regressão. A presença de *outliers* é identificada quando a *Cook's Distance* excede o valor da expressão (Bollen; Jackman, 1990).

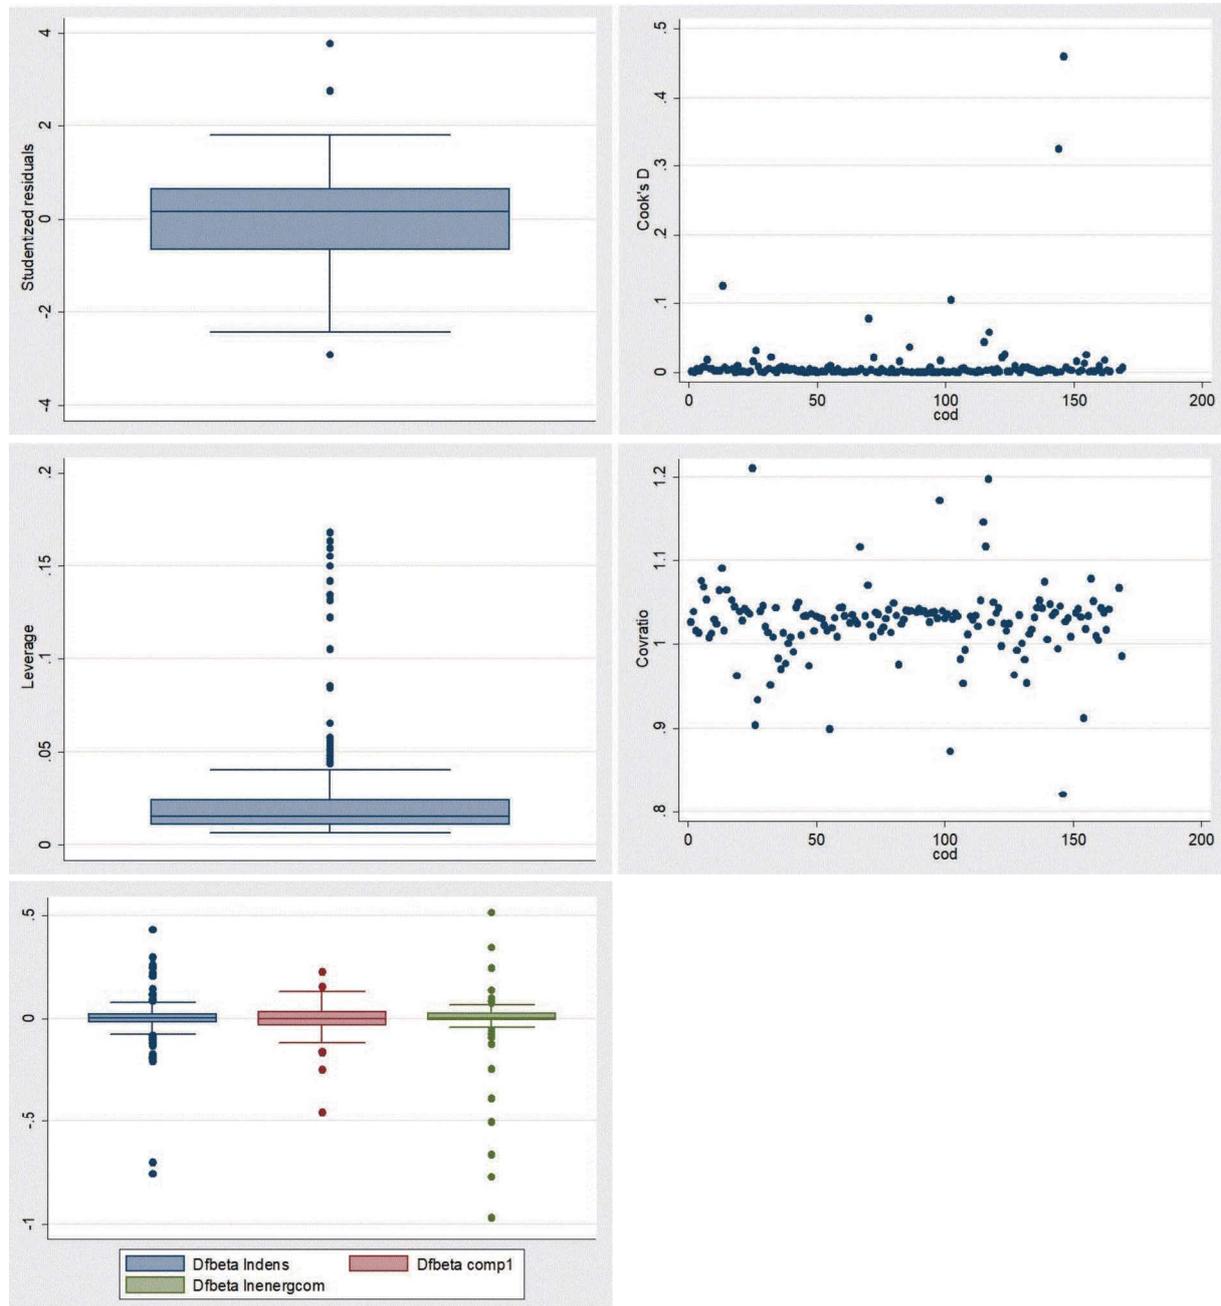
*Leverage* representa os elementos diagonais da matriz de projeção, ou seja, mede a distância no espaço das variáveis explicativas. Os elementos da matriz de projeção (*hat matrix*) representam a contribuição de cada observação das variáveis explicativas para o valor predito. Sempre que um elemento da matriz de projeção excede em mais de duas vezes o valor médio desses elementos diagonais, existe o indicativo da presença de *outliers* (Fox, 2015). Já a *Covratio* mede o efeito de cada observação na matriz de covariância das estimativas. Uma observação é considerada um *outlier* se a *Covratio* é superior ao valor da expressão, onde  $k$  é o número de variáveis independentes, incluindo a constante (Belsley *et al.*, 1980).

Por fim, o *DFBETA* é calculado para cada uma das variáveis explicativas do modelo: estima-se a diferença entre o coeficiente estimado de uma dada variável explicativa quando determinada observação é incluída na estimativa e o valor deste coeficiente quando a observação é omitida, padronizando essa diferença pelo erro-padrão estimado do coeficiente. Se o *DFBETA* de uma

observação excede o valor da expressão  $(2/\sqrt{n})$ , essa observação pode estar enviesando os resultados (Bollen; Jackman, 1990).

Como ilustração, a Figura 2 apresenta os resultados das estatísticas de influência para a estimativa da equação (2) em que  $y_i = \ln total_i$  e  $econ_i = \ln energ_i$ <sup>11</sup>. Observa-se que todas as estatísticas de influência apontam para a presença de *outliers*.

Figura 2 – Estatísticas de influência



Fonte: Elaboração própria. Nota: (1) modelo estimado por MQO em que  $Y_i = \ln total_i$  e  $econ_i = \ln energ_i$ ; (2) valores de referência,  $\eta$ , que indicam ausência de *outliers* para o R-Student,  $-2 < \eta < 2$ ; para o Cooks' D,  $\eta < 0,026$ ; e para o Covratio,  $\eta < 0,078$ .

11 As estimativas das estatísticas de influência para as demais regressões também indicam a presença de *outliers*, mas não foram apresentadas aqui por razão de espaço. Esses resultados estão disponíveis mediante solicitação aos autores.

Duas estratégias econométricas alternativas ao MQO foram utilizadas para lidar com o problema de observações extremas: a regressão mediana e a regressão robusta. A regressão mediana busca minimizar a soma dos valores absolutos dos resíduos, diferente do MQO, que minimiza a soma dos resíduos quadráticos. O estimador da regressão mediana é definido por:

$$\min_b \sum_{i=1}^n |e_i| = \sum_{i=1}^n |y_i - \hat{y}_i| = \sum_{i=1}^n |y_i - x'_i b| \quad (3)$$

onde  $y_i$  é o valor observado da variável dependente,  $X_i$  é a matriz de variáveis explicativas,  $\hat{y}_i$  é o valor predito,  $e_i$  é o termo de erro e  $b$  é o vetor de coeficientes a serem estimados.

A regressão mediana é um caso especial da regressão quantílica, que permite avaliar o impacto de uma variável explicativa em toda a distribuição de  $y_i$ , não somente na sua média condicional, como no MQO (Cameron; Trivedi, 2005). O estimador para um quartil  $q$ ,  $0 < q < 1$ , é definido por:

$$\min_b \sum_{i: q_i \geq x'_i b} q |y_i - x'_i b| + \sum_{i: q_i < x'_i b} (1 - q) |y_i - x'_i b| \quad (4)$$

Os erros-padrão são usualmente estimados por *bootstrap*.

A regressão quantílica é eficiente na presença de *outliers* verticais que distorcem as estimativas do intercepto da regressão, mas não constitui uma solução para observações extremas que influenciam os coeficientes estimados para as variáveis explicativas (*bad leverage points*). Nesses casos, os modelos de regressão robusta têm maior eficiência Gaussiana, tais como o estimador M (Huber, 1964) e o estimador MM (Yohai, 1987). Fox e Weisberg (2019) argumentam que a derivação do estimador M pode ser classificada como uma generalização da estimação por máxima verossimilhança, definida em sua forma linear por:

$$\min_b \sum_{i=1}^n \rho(e_i) = \sum_{i=1}^n \rho(y_i - \hat{y}_i) \quad (5)$$

onde  $\rho$  é a contribuição de cada resíduo para a função objetivo<sup>12</sup>.

De acordo com Fox e Weisberg (2019), ao definir  $\psi = \rho' = \frac{\partial \rho}{\partial b}$ , estimar a equação (5) produz um sistema de  $(k + 1)$  valores para os coeficientes:

$$\sum_{i=1}^n \omega_i (y_i - x'_i b) x'_i = 0 \quad (6)$$

onde  $\omega_i = w(e_i) = \frac{\psi(e)}{e}$ ,  $\psi(e)$  é a função de influência, e  $w(e_i)$  é uma função de ponderação. Se a função de influência é limitada (*bounded-influence*), o estimador é robusto para os valores dos resíduos  $e$ . O estimador M é, portanto, equivalente à estimação de um modelo de mínimos quadrados ponderados. No entanto, como os pesos dependem dos resíduos, que dependem dos coeficientes estimados, e estes, por sua vez, dependem dos pesos, é preciso utilizar uma solução iterativa.

12 Propriedades  $\rho(e): \rho(e) \geq 0; \rho(0) = 0; \rho(e) = \rho(-e); e \rho(e_i) \geq \rho(e_j)$  se  $|e_i| \geq |e_j|$ .

O estimador do MQO, o estimador de Huber e o estimador *Tukey Bisquare* são casos especiais do estimador M, com funções objetivo e de ponderação específicas. Esse estimador, no entanto, não é eficiente na presença de observações com elevada influência (*high leverage*). Sugere-se, então, o uso de estimadores com função de influência limitada (*bounded-influence estimators*). Por exemplo, o estimador *least trimmed squares* (LTS) deriva os coeficientes da regressão,  $\beta$ , de forma a minimizar a soma dos  $m$  menores resíduos quadráticos:

$$LTS(b) = \sum_{i=1}^m |e|_{(i)}^2 \quad (7)$$

onde  $m$  é normalmente definido como  $m = (n/2) + [(k + 2)/2]$ .

Uma aplicação de estimadores com função de influência limitada é obter valores iniciais para a derivação do estimador M. Essa é a estratégia utilizada pelo estimador MM, que também faz uso de estimativas de influência limitada da variância dos erros. Yohai (1987) demonstra que o estimador MM é eficiente em amostras pequenas e apresenta consistência e normalidade assintótica. Veradi e Croux (2009), por sua vez, fazem uso de simulações para mostrar que o estimador MM com uma eficiência de 0,7 apresenta baixo viés em comparação com o MQO, com a regressão quantílica ou com o estimador M. Optou-se, portanto, por adotar o estimador MM com eficiência de 0,7 no presente trabalho, assumindo que os resultados obtidos com esse estimador são mais robustos em relação aos demais.

A última estratégia empírica adotada para garantir a robustez dos resultados foi considerar a possibilidade de dependência espacial. Por exemplo, o acesso a serviços de saúde e a qualidade desses serviços podem ser semelhantes em bairros vizinhos, em razão de decisões de alocação de recursos públicos. Nesse caso, a incidência, mortalidade e letalidade associadas à Covid-19 de uma localidade depende dos valores em áreas vizinhas. O acesso viário e meios de transportes compartilhados por bairros vizinhos também podem fazer com que a incidência de Covid-19 em um bairro influencie o grau de contaminação no vizinho.

A dependência espacial pode ser incorporada através de modelos do tipo *spatial lag dependence* (SLD) ou *spatial error dependence* (SED). Fischer e Wang (2011) afirmam que o modelo SLD pressupõe a existência de correlação espacial na variável dependente em razão de efeitos de vizinhança. Já o modelo SED é utilizado quando se suspeita da existência de uma variável latente não observável e espacialmente correlacionada, ou quando as vizinhanças não são corretamente definidas. Para Anselin (2003), o modelo SLD é mais apropriado para avaliar a presença e relevância da interação espacial e, por essa razão, foi utilizado neste trabalho.

Na estimativa do modelo SLD, a equação (2) precisa ser modificada para:

$$y_i = \tau \sum_{j=1}^n W_{ij} y_j + \sum_{q=1}^k X_{i,q} \beta_q + e_i \quad (8)$$

onde a variável dependente  $y_i$  da área  $i$ , com  $i = 1, 2, \dots, n$ , pode depender das observações da variável dependente de áreas vizinhas,  $y_j$ , com  $i \neq j$ .  $W$  representa a matriz de pesos espaciais (matriz de proximidade espacial), com elementos  $W_{ij} \neq 0$  para cada linha  $i$  em que as colunas  $j$  representem áreas vizinhas de  $i$ , e  $W_{ij} = 0$  para as linhas  $i$  em que as colunas  $j$  não sejam áreas vizinhas de  $i$  (por convenção,  $W_{ii} = 0$ )<sup>13</sup>. Já  $X_{i,q}$  representa as demais variáveis explicativas, enquanto  $e_i$  é o termo de erro (assume-se que  $e_i$  é distribuído independentemente e iden-

13 Neste trabalho, utilizou-se o critério de contiguidade para definir os elementos de  $W$ , ou seja  $W_{ij} \neq 0$  se duas áreas compartilham ao menos um lado comum e  $W_{ij} = 0$  caso contrário (Anselin *et al.*, 2003).

ticamente). A estimativa da equação (8) é realizada por máxima verossimilhança (Anselin, 2003; Fischer; Wang, 2011).

O parâmetro  $\tau$  indica a robustez da relação espacial entre  $y_i$  e  $\sum_{j=1}^n W_{ij}y_j$ , onde  $\sum_{j=1}^n W_{ij}y_j$  é uma combinação linear de observações espacialmente relacionadas e baseadas nos valores de  $W_{ij}$  diferentes de zero. No presente trabalho,  $\sum_{j=1}^n W_{ij}y_j$  representa a média da variável dependente dos bairros vizinhos. A dependência espacial é positiva, se  $\tau > 0$ ; e negativa, se  $\tau < 0$ . Quando  $\tau = 0$ , obtém-se a estimativa da equação (2) por MQO.

Alguns testes de especificação podem ser utilizados para verificar a presença de dependência espacial (Anselin, 2003). A estatística I de Moran permite detectar a presença de autocorrelação espacial global. Valores dessa estatística maiores do que  $[-1/(n-1)]$  revelam a presença de autocorrelação positiva ou a existência de *clusters*. Ou seja, áreas com altas/baixas taxas de incidência, letalidade e mortalidade associadas à Covid-19 são vizinhas de áreas que também possuem altas/baixas taxas de incidência, letalidade e mortalidade<sup>14</sup>.

A estatística I de Moran pressupõe média e variância constantes para a variável de análise e, por isso, não é indicada quando essa variável é expressa sob forma de proporção. Nesse caso, é indicado o uso do I de Moran com taxas Bayesianas empíricas (*EB Rate*), que contabiliza a instabilidade da variância de variáveis calculadas como taxas, levando em consideração as diferentes densidades populacionais das unidades observadas (Anselin, 2019).

Para identificar padrões locais de associação espacial, são comumente utilizados os indicadores I de Moran Local, I de Moran Mediana Local e EB Moran Local. Esses indicadores definem as áreas de associação espacial local por meio de mapas de *clusters*. O I de Moran Local é calculado com base na média dos valores da variável de estudo dos vizinhos de determinada área, sendo sensível à presença de *outliers*. Já o I de Moran Mediana Local utiliza a mediana dos valores da variável de estudo dos vizinhos, minimizando o problema com observações extremas. Para variáveis expressas em percentual, utiliza-se o EB Moran Local como alternativa ao I de Moran Local (Anselin, 2019).

Tanto para os testes de associação espacial global, quanto para os testes de associação local, a significância estatística é auferida por meio de inferência de permutação condicional, com o cálculo de pseudo p-valores (Anselin, 2003)<sup>15</sup>. A Tabela 3 apresenta as estatísticas para os indicadores de associação global, em que se observa a possibilidade de associação espacial para as taxas de incidência, mortalidade e letalidade. Já a evidência de associação global para o número de casos identificados e para o número de óbitos não é robusta.

Tabela 3 – Indicadores de Associação Espacial Global

	$Y_i = \text{Intotal}$	$Y_i = \text{casoshab}$	$Y_i = \text{Inobitos}$	$Y_i = \text{obitpop}$	$Y_i = \text{txletal}$
<b>I-Moran</b>	0.033 (0.226)	0.071 (0.061)	0.016 (0.332)	0.056 (0.103)	0.046 (0.151)
<b>EB Rate</b>		0.074 (0.056)		0.060 (0.092)	0.167 (0.001)

Fonte: Elaboração própria. Nota: Pseudo p-valores são apresentados entre parêntesis.

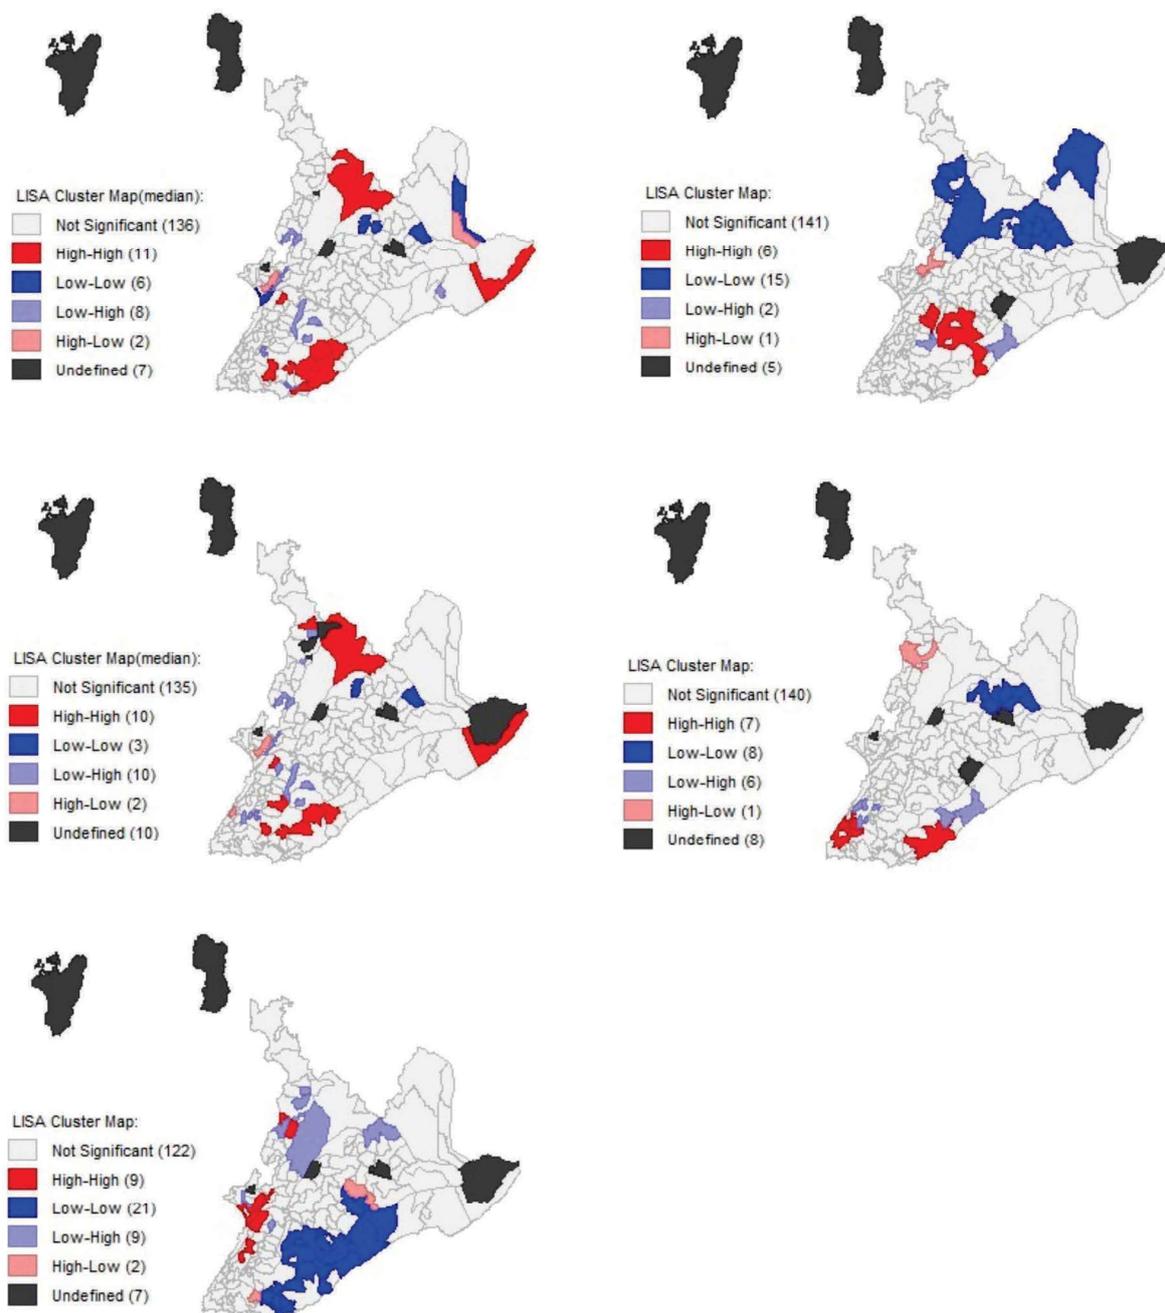
Em relação à associação local, a Figura 3 ilustra o I de Moran Mediana Local e o EB Moran Local para os indicadores de incidência e óbitos por Covid-19, sendo que o EB Moran Local foi utilizado para as variáveis expressas em proporção. A existência de associação local é restrita a pequenos *clusters*, com exceção da taxa de letalidade. A Figura 3(e) mostra um *cluster* de 21 bairros vizinhos com baixas taxas de letalidade na orla atlântica de Salvador.

14 Valores para a estatística inferiores a  $[-1/(n-1)]$  indicam a presença de autocorrelação espacial negativa, revelando dissimilaridade entre as populações de áreas vizinhas (*outliers* espaciais).

15 Foram utilizados filtros de significância com valores de corte de 0,05 (valores inferiores revelam poucos *clusters* significativos). Procedimentos mais conservadores, como Bonferroni e *False Discovery Ratio*, somente são indicados em grandes amostras e, por isso, não foram utilizados aqui.

Uma alternativa ao uso dos indicadores de associação global e local é a condução de testes baseados no multiplicador de Lagrange (LM), cuja hipótese nula é de ausência de interações espaciais. Anselin (2003) e Fischer e Wang (2011) afirmam que esses testes permitem identificar a presença de dependência espacial de maneira mais efetiva do que os indicadores de associação global e local, além de apontarem se é melhor optar pela estimação por SLD ou SED<sup>16</sup>. Os resultados desses testes encontram-se na próxima seção.

Figura 3 – Associação espacial local: Mapas de clusters



Fonte: Elaboração própria. Nota: Áreas identificadas com significância estatística de 0,05.

16 Estimações que apresentam maiores valores dos testes da estatística LM são preferíveis. No presente trabalho, todas as estimações por SED apresentaram estatísticas LM inferiores às encontradas nas estimativas utilizando o modelo SLD (Fischer; Wang, 2011). Esses resultados estão disponíveis mediante solicitação aos autores.

## 5 ANÁLISE EMPÍRICA: DISCUSSÃO DOS RESULTADOS

A Tabela 4 apresenta os resultados obtidos com a estimação dos modelos econométricos que não levam em consideração interações espaciais. Esses resultados são sensíveis à estratégia econométrica adotada. Por isso, a discussão dessa seção enfatiza os resultados obtidos com o estimador MM, considerada a estratégia mais robusta na presença de *outliers*.

Em geral, as variáveis explicativas selecionadas mostram-se determinantes para o total de casos de Covid-19 (colunas 3 e 6, Tabela 4). Assim como salientado por Wong e Li (2020) e Sy *et al.* (2021), quanto maior a densidade populacional e a intensidade das atividades econômicas em um bairro, maior o número total de casos identificados. Esse resultado é estatisticamente significativo e economicamente relevante, indicando a importância do controle de aglomerações.

Tabela 4 – Determinantes da Incidência e Gravidade da Covid-19 no Município de Salvador

	Variável Dependente: Intotal						Variável Dependente: casoshab					
	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)	(11)	(12)
	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG
Indens	0,351**	0,298***	0,243***	0,433***	0,334*	0,150	-0,021**	-0,007**	-0,003	-0,012*	-0,003	0,001
	(0,142)	(0,078)	(0,035)	(0,105)	(0,177)	(0,094)	(0,009)	(0,003)	(0,007)	(0,007)	(0,004)	(0,002)
compl	0,007	-0,010	-0,117***	-0,075**	-0,142***	-0,141***	0,013***	0,010***	0,006***	0,011***	0,008***	0,007***
	(0,037)	(0,025)	(0,014)	(0,031)	(0,044)	(0,029)	(0,003)	(0,002)	(0,001)	(0,002)	(0,002)	(0,002)
lnenerg	0,268***	0,396***	0,833***				0,005***	0,004***	0,014***			
	(0,041)	(0,075)	(0,040)				(0,001)	(0,001)	(0,001)			
lniss				0,219***	0,245***	0,254***				0,002	0,003***	0,003***
				(0,028)	(0,032)	(0,026)				(0,002)	(0,001)	(0,001)
Const.	-0,900	-2,342*	-8,921***	0,746	1,528	3,279***	0,207**	0,085**	-0,120	0,178**	0,077*	0,038
	(1,530)	(1,290)	(0,736)	(1,038)	(1,595)	(0,956)	(0,087)	(0,040)	(0,076)	(0,068)	(0,039)	(0,025)
No. Obs.	163	163	163	128	128	128	163	163	163	128	128	128
R <sup>2</sup>	0,551			0,396			0,319			0,371		
	Variável Dependente: Inobitos						Variável Dependente: obitpop					
	(13)	(14)	(15)	(16)	(17)	(18)	(19)	(20)	(21)	(22)	(23)	(24)
	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG
Indens	0,294***	0,411***	0,324***	0,499***	0,542***	0,329***	-0,0003**	-0,0001	-0,0001	-0,0002	0,00003	0,0001
	(0,091)	(0,100)	(0,032)	(0,100)	(0,164)	(0,108)	(0,0001)	(0,0001)	(0,0002)	(0,0001)	(0,0001)	(0,0001)
compl	-0,026	-0,037	-0,136***	-0,087***	-0,088**	-0,124***	0,0003***	0,0002***	0,0002***	0,0003***	0,0003***	0,0002***
	(0,029)	(0,038)	(0,016)	(0,029)	(0,034)	(0,030)	(0,0001)	(0,00004)	(0,0001)	(0,0001)	(0,0001)	(0,0001)
lnenerg	0,233***	0,337**	0,802***				0,0001***	0,0001***	0,0002***			
	(0,034)	(0,149)	(0,041)				(0,00002)	(0,00002)	(0,00002)			
lniss				0,191***	0,209***	0,217***				-0,00002	-0,00003	0,00002
				(0,029)	(0,033)	(0,028)				(0,0001)	(0,0001)	(0,0001)
Const.	-3,130***	-5,808**	-12,550***	-2,947***	-3,475**	-1,413	0,003**	0,002*	0,001	0,004**	0,003***	0,001
	(1,182)	(2,840)	(0,693)	(1,015)	(1,720)	(1,054)	(0,001)	(0,001)	(0,002)	(0,002)	(0,001)	(0,001)
No. Obs.	160	160	160	128	128	128	160	160	160	128	128	128
R <sup>2</sup>	0,470			0,375			0,322			0,232		

Fonte: Elaboração própria. Nota: \*, \*\* e \*\*\* indicam significância estatística de 10%, 5% e 1%.

Tabela 4 – Determinantes da Incidência e Gravidade da Covid-19 no Município de Salvador (cont.)

	Variável Dependente: txletal					
	(25)	(26)	(27)	(28)	(29)	(30)
	MQO	SQREG	MM-REG	MQO	SQREG	MM-REG
<b>Indens</b>	0.002 (0.001)	0.002* (0.001)	0.003 (0.002)	0.002* (0.001)	0.003** (0.001)	0.003 (0.002)
<b>compl</b>	-0.001* (0.001)	-0.001 (0.001)	-0.001* (0.001)	-0.001 (0.001)	-0.001* (0.001)	-0.001 (0.001)
<b>lnenerg</b>	-0.000 (0.001)	-0.001 (0.001)	-0.001 (0.001)			
<b>lniss</b>				-0.001* (0.001)	-0.001 (0.001)	-0.001** (0.000)
<b>Constante</b>	0.023 (0.022)	0.035 (0.030)	0.027 (0.023)	0.029** (0.011)	0.013 (0.017)	0.019 (0.018)
<b>No. Obs.</b>	160	160	160	128	128	128
<b>R<sup>2</sup></b>	0.049			0.095		

Fonte: Elaboração própria. Nota: \*, \*\* e \*\*\* indicam significância estatística de 10%, 5% e 1%.

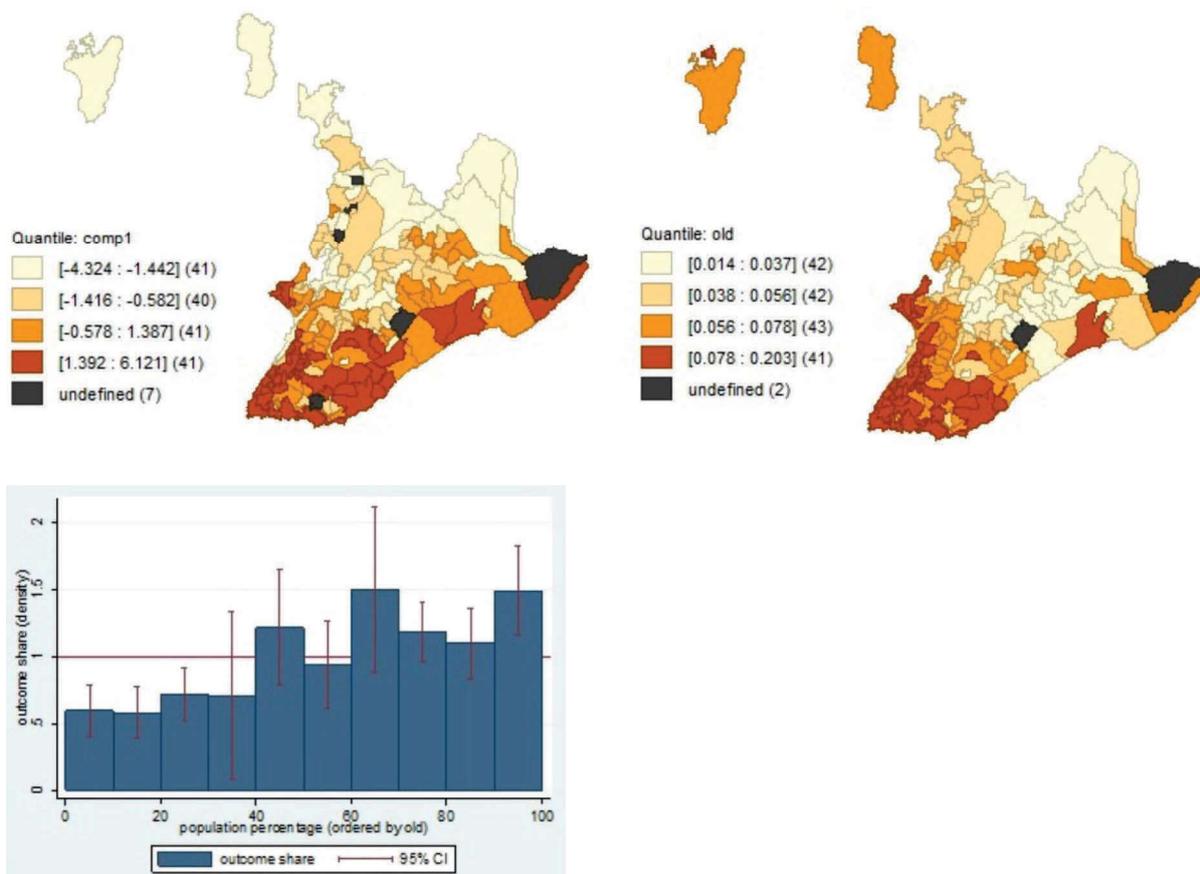
Utilizando os dados da coluna 3, observa-se que um aumento de 10% em *Indens* ou em *lnenerg* eleva o número de infecções em 2,4% e 8,3%, respectivamente. Já quando a atividade econômica é medida pela arrecadação de ISS (coluna 6), um incremento de 10% em *Indens* ou em *lniss* eleva o número de casos identificados em apenas 1,5% e 2,5%, respectivamente, mas o coeficiente de *Indens* deixa de ser estatisticamente significativo.

Outra variável que influencia o total de casos identificados de maneira estatisticamente significativa, embora com menor importância econômica, é o indicador de características demográficas e socioeconômicas. Uma elevação de 10% em *compl* reduz o número de casos identificados em 1,2% ou 1,4% (colunas 3 e 6, respectivamente). Ou seja, o número de casos identificados é menor em bairros com um maior contingente de mulheres e de pessoas que se autodeclaram brancas e com maior escolarização e maior renda. Esse resultado corrobora a literatura que aponta a maior vulnerabilidade de pessoas do sexo masculino, da raça negra e de baixa escolarização e renda ao coronavírus (Kopel, 2020; Rattay *et al.*, 2020; Capuano *et al.*, 2020; Demenech *et al.*, 2020; Figueiredo *et al.*, 2020).

O uso da taxa de incidência como variável dependente gera resultados distintos (colunas 7-12, Tabela 4). Enquanto a densidade populacional perde significância estatística, os indicadores de atividade econômica mantêm-se relevantes, embora apresentem menor representatividade econômica: uma elevação de 10% em *lnenerg* ou em *lniss* aumentaria a taxa de incidência em 1,4% ou 0,3%, respectivamente (colunas 9 e 12, Tabela 4). Já um incremento em *compl* eleva a taxa de incidência, indicando que bairros das áreas nobres de Salvador vêm apresentando maiores taxas de incidência de Covid-19 que bairros com menor renda. Como apontado na seção 2, essa evidência também está presente em Cavalcanti e Abreu (2020), França *et al.* (2021) e Pimenta *et al.* (2021).

Esse resultado contraintuitivo pode estar ocorrendo em razão das regiões mais nobres de Salvador apresentarem maior participação de idosos em sua população. Nas Figuras 4(a) e 4(b), observa-se que a distribuição espacial da variável *old* é muito semelhante a *compl*, e concentra-se na região central e orla atlântica, área nobre de Salvador (Borges; Carvalho, 2017). Já a Figura 4(c) mostra que as taxas de incidência da Covid-19 são mais baixas em bairros com menores frações da população com 65 anos ou mais. Outra explicação seria a possibilidade das áreas nobres de Salvador apresentarem atividade econômica mais intensa e, conseqüentemente, maior aglomeração. Natividade *et al.* (2020) refutam tal conclusão ao apresentarem evidência de que o distanciamento social foi mais efetivo nos bairros mais nobres do município, apesar de o consumo comercial de energia nesses bairros ser superior à média.

Figura 4 – Taxas de incidência de Covid-19 e predominância de idosos na população



Fonte: Elaboração própria.

Dados de contágio são distorcidos, em razão dos indivíduos serem assintomáticos ou não realizarem exames. Subnotificações ocorrem com mais frequência em bairros de renda mais baixa e com menor nível de escolarização. Nesse sentido, indicadores associados ao número de óbitos por Covid-19 tendem a ser mais precisos.

As regressões estimadas com o número total de óbitos por bairro como variável dependente mostram novamente a importância da densidade populacional, da intensidade das atividades econômicas e do perfil demográfico e socioeconômico da população para o número de fatalidades. Utilizando as colunas 13 e 18 da Tabela 4 como referência, observa-se que um aumento de 10% na densidade populacional, no consumo de energia e na arrecadação de ISS elevam o número de óbitos por Covid-19 em 3,2%, 8% e 2,2%, respectivamente. Já comp1 é inversamente relacionado ao número de óbitos: bairros com maior contingente de mulheres e brancos, com maior grau de escolarização e renda apresentam menos óbitos por Covid-19. No caso do total de óbitos, assim como o total de casos, a variável old não enviesou os resultados do indicador socioeconômico e demográfico. Pimenta *et al.* (2021) encontram resultado semelhante em uma análise com dados dos quatro primeiros meses da pandemia por Covid-19 em Salvador, mostrando que a mortalidade do vírus é maior nas regiões de menor renda.

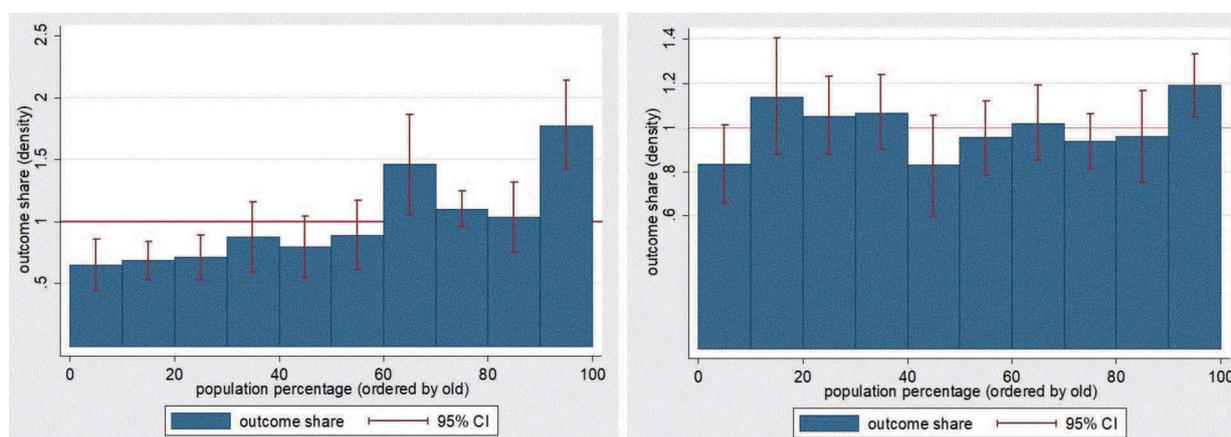
Resultados diversos são obtidos quando se utiliza a taxa de mortalidade por Covid-19 como variável dependente. Mais uma vez, a densidade populacional deixa de ser estatisticamente relevante. Já a atividade econômica mais aquecida aparenta estar associada com maiores taxas de mortalidade, mas somente quando se utiliza o consumo de energia como indicador: com base na coluna 21, um aumento de 10% no consumo de energia elevaria a taxa de mortalidade em apenas 0,16%. Assim como acontece com a taxa de incidência, a taxa de mortalidade apresenta uma relação positiva e estatisticamente significativa com o indicador demográfico e socioeconômico.

Esse resultado aparenta decorrer da relação positiva que existe entre a predominância de idosos na população e a taxa de mortalidade (Figura 5a).

Os últimos resultados apresentados na Tabela 4 utilizam a taxa de letalidade como variável dependente. Nenhuma das variáveis explicativas apresentou desempenho consistente e estatisticamente significativa, exceto *compl* e *lniss*. Bairros de maior renda e de maior arrecadação de ISS de Salvador apresentaram menores taxas de letalidade. Salienta-se, contudo, que esse indicador provavelmente exibe erro de medida, já que o total de casos identificados tende a ser subestimado, particularmente em bairros de baixa renda, o que infla as taxas de letalidade desses bairros. A taxa de letalidade somente é relacionada de maneira estatisticamente significativa com a predominância de idosos na população, *old*, no percentil mais elevado da distribuição dessa variável (Figura 5b).

Na Tabela 5, são apresentados os resultados das estimações de regressões espaciais. Observam-se efeitos de transbordamento espacial de maneira consistente e estatisticamente significativa apenas quando se utiliza taxa de letalidade como variável dependente (colunas 5 e 10)<sup>17</sup>: um aumento na taxa de letalidade de bairros vizinhos eleva a taxa de mortalidade em um bairro. Esse resultado é ratificado pelo teste LM, que rejeita a hipótese de ausência de efeitos espaciais com 99% de confiança. A presença de transbordamentos espaciais pode ser decorrente da qualidade similar da oferta de serviços de saúde em bairros próximos.

Figura 5 – Taxas de mortalidade e letalidade da Covid-19 e predominância de idosos na população



Fonte: Elaboração própria.

## 6 CONCLUSÃO

A pandemia da Covid-19 já foi responsável pela perda de um número significativo de vidas, pela contaminação de um número ainda maior de pessoas e por causar uma severa contração na atividade econômica em 2020. O grau de contaminação e a gravidade das infecções são associadas particularmente às condições de saúde do indivíduo, mas é possível identificar fatores espaciais, demográficos e socioeconômicos que tornam determinadas comunidades mais suscetíveis à doença.

Este trabalho verificou a importância da densidade demográfica, da intensidade das atividades econômicas, dos efeitos de vizinhança e das características demográficas e socioeconômicas para a incidência, mortalidade e letalidade da Covid-19. Bairros mais populosos e com atividades comerciais dinâmicas tendem a gerar aglomerações, facilitando o contágio de doenças infectocontagiosas. A literatura tem apontado que determinados grupos de indivíduos são mais suscetíveis à

<sup>17</sup> A relevância estatística dos efeitos espaciais somente é observada quando *Intotal* é utilizada com variável dependente e a arrecadação de ISS é o indicador de atividade econômica (amostra menor).

contaminação e ao agravamento de infecções por Covid-19, seja por predisposição à presença de comorbidades, por restrições socioeconômicas ou por questões comportamentais.

Tabela 5 – Incidência e Gravidade da Covid-19 no Município de Salvador: Análise Espacial

	(1)	(2)	(3)	(4)	(5)	(6)	(7)	(8)	(9)	(10)
	$Y_i =$ lntotal	$Y_i = ca-$ soshab	$Y_i =$ lnobitos	$Y_i =$ obitpop	$Y_i =$ txletal	$Y_i =$ lntotal	$Y_i = ca-$ soshab	$Y_i =$ lnobitos	$Y_i = obi-$ ttop	$Y_i =$ txletal
$W_i$	0,009 (0,061)	-0,043 (0,108)	0,108 (0,082)	-0,039 (0,108)	0,308*** (0,095)	0,219** (0,096)	0,104 (0,104)	0,156 (0,100)	0,029 (0,115)	0,348*** (0,103)
<b>Lndens</b>	0,476*** (0,063)	-0,020*** (0,004)	0,436*** (0,066)	-0,0002** (0,0001)	0,001 (0,001)	0,415*** (0,077)	-0,012*** (0,004)	0,483*** (0,078)	-0,00003 (0,0001)	0,002 (0,001)
<b>comp1</b>	-0,023 (0,033)	0,012*** (0,003)	-0,121*** (0,033)	0,0003*** (0,0001)	-0,001 (0,001)	-0,078** (0,034)	0,010*** (0,002)	-0,089*** (0,034)	0,0003*** (0,0001)	-0,0002 (0,001)
<b>Lnenerg</b>	0,534*** (0,039)	0,009*** (0,003)	0,505 (0,043)	0,0003*** (0,0001)	-0,001 (0,001)					
<b>Lniss</b>						0,213*** (0,028)	0,002 (0,001)	0,191*** (0,027)	-0,00003 (0,0001)	-0,001 (0,0004)
<b>Constante</b>	-6,450*** (0,863)	0,212*** (0,053)	-4,992 (0,674)	0,003** (0,001)	0,021* (0,011)	-0,604 (0,975)	0,171*** (0,046)	-3,400*** (0,849)	0,003** (0,002)	0,015 (0,012)
<b>No. Obs.</b>	154	152	151	151	151	128	128	128	128	128
<b>R<sup>2</sup></b>	0,635	0,284	0,587	0,271	0,113	0,427	0,376	0,39	0,232	0,188
<b>Teste LR</b>	0,024	0,134	1,821	0,115	9,650	5,261	0,827	2,298	0,056	10,132
<b>p-valor</b>	0,876	0,714	0,177	0,735	0,002	0,022	0,363	0,130	0,812	0,001

Fonte: Elaboração própria. Nota: \*, \*\* e \*\*\* indicam significância estatística de 10%, 5% e 1%.

Os resultados apresentados neste trabalho mostram que a densidade populacional e atividades econômicas intensas contribuem para o aumento do contágio e, conseqüentemente, para a elevação do número de óbitos, em razão da maior aglomeração de pessoas. Os resultados também coadunam com achados da literatura que demonstram que idosos estão mais vulneráveis à Covid-19, assim como indivíduos da raça negra, do sexo masculino e com baixa renda e escolarização. Maior suscetibilidade imunológica e predisposição ao desenvolvimento de diabetes e hipertensão são razões para a vulnerabilidade de pessoas idosas, da raça negra e do sexo masculino. Maior propensão ao risco também faz com que homens adotem condutas que os deixam mais vulneráveis, enquanto a suscetibilidade de pessoas com baixa renda e escolarização deve-se ao seu menor acesso à informação e aos serviços de saúde.

Esses resultados sugerem a necessidade de direcionamento de políticas de saúde pública e de conscientização para esses grupos mais vulneráveis. Tais iniciativas são importantes de serem adotadas tanto para o controle da Covid-19 quanto para outras doenças infectocontagiosas. No caso do município de Salvador, em particular, o estudo permitiu identificar bairros com maior suscetibilidade e que devem receber especial atenção das autoridades governamentais. A importância de transbordamentos espaciais para as taxas de letalidade, por sua vez, revela a necessidade de se monitorar a qualidade na oferta de serviços públicos. Este estudo identificou um *cluster* com 21 bairros com baixas taxas de mortalidade na região central e atlântica do município, revelando a necessidade de se identificar boas práticas nos serviços ofertados nessas localidades para replicação em outros bairros.

A principal limitação do presente trabalho relaciona-se com restrições na base de dados. Informações socioeconômicas dos bairros de Salvador estão defasadas, pois se referem ao Censo de 2010, o que pode ter gerado viés nas estimações. Em trabalhos futuros, será possível utilizar dados atualizados do Censo, permitindo verificar a robustez dos resultados obtidos. A utilização de medidas alternativas de intensidade de aglomerações e de transbordamento espacial também pode trazer maior precisão aos resultados. A literatura tem utilizado medidas de intensidade de tráfego

nas vias (Nicolelis *et al.*, 2020) e de geolocalização de indivíduos via dados de aparelhos celulares (Natividade *et al.*, 2020) como indicadores de respeito ao distanciamento social. Trabalhos futuros podem avançar na estimação desses indicadores para os bairros de Salvador durante o período de maior intensidade da pandemia da Covid-19.

## REFERÊNCIAS

- Abedi, V.; Olulana, O.; Avula, V.; Chaudhary, D.; Khan, A.; Shahjouei, S.; Li, J.; Zand, R. Racial, economic, and health inequality and COVID-19 infection in the United States. **Journal of Racial and Ethnic Health Disparities**, v. 8, n. 3, p. 732-742, 2021.
- ANSELIN, L. Spatial econometrics. In: BALTAGI, B. H. (org.). **A companion to theoretical econometrics**, ed., John Wiley & Sons, 2003, p. 310-330.
- ANSELIN, L. **GeoDa: an introduction to spatial data analysis**. Chicago: University of Chicago, 2019. Disponível em: <https://geodacenter.github.io/documentation.html>. Acesso em: 22 fev. 2022.
- BAKER, P.; WHITE, A.; MORGAN, R. Men's health: COVID-19 pandemic highlights need for overdue policy action. **The Lancet**, v. 395, p. 1886-1888, 2020.
- BANCO CENTRAL DO BRASIL (BCB). **Séries temporais**. Brasília: BCB, 2022. Disponível em: <https://www3.bcb.gov.br/sgspub/>. Acesso em: 27 fev. 2022.
- BELSLEY, D. A.; KUH, E.; WELSCH, R. E. **Regression diagnostics: identifying influential data and sources of collinearity**. New York: Wiley, 1980.
- BENITEZ, J.; COURTEMANCHE, C.; YELLOWITZ, A. Racial and ethnic disparities in COVID-19: evidence from six large cities. **Journal of Economics, Race, and Policy**, v. 3, n. 4, p. 243-261, 2020.
- BOLLEN, K. A.; JACKMAN, R. W. Regression diagnostics: an expository treatment of outliers and influential cases. In: FOX, J.; LONG, J.S. (org.). **Modern Methods of Data Analysis**, p. 257-291, 1990.
- BORGES, Â.; CARVALHO, I. Revisitando os efeitos de lugar: segregação e acesso ao mercado de trabalho em uma metrópole brasileira. **Caderno CRH**, v. 30, p. 121-135, 2017.
- BORJAS, G. J. Demographic determinants of testing incidence and COVID-19 infections in New York City neighborhoods. **NBER Working Paper**, n. 26952, 2020.
- BOOTH, A.; REED, A. B.; PONZO, S.; YASSAEE, A. A.; ARAL, M.; LABRIQUE, A. Population risk factors for severe disease and mortality in COVID-19: A global systematic review and meta-analysis. **PloS One**, v. 16, n. 3, p. 1-30, 2021.
- BUPP, M. R. G. Sex, the aging immune system, and chronic disease. **Cellular Immunology**, v. 294, n. 2, p. 102-110, 2015.
- CAMERON, A. C.; TRIVEDI, P. K. **Microeconometrics: methods and applications**. New York: Cambridge University Press, 2005.
- CAPUANO, A.; ROSSI, F.; PAOLISSO, G. Covid-19 kills more men than women: an overview of possible reasons. **Frontiers in Cardiovascular Medicine**, v. 7, p. 1-7, 2020.

- CAVALCANTE, J. R.; ABREU, A. J. L. COVID-19 no município do Rio de Janeiro: análise espacial da ocorrência dos primeiros casos e óbitos confirmados. **Epidemiologia e Serviços de Saúde**, v. 29, n. 3, p. 1-9, 2020.
- CESTARI, V. R. F.; FLORÊNCIO, R. S.; SOUSA, G. J. B.; GARCES, T. S.; MARANHÃO, T. A.; CASTRO, R. R.; CORDEIRO, L. I.; DAMASCENO, L. L. V.; PESSOA, V. L.; PEREIRA, M. L. D.; MOREIRA, T. M. M. Vulnerabilidade social e incidência de COVID-19 em uma metrópole brasileira. **Ciência & Saúde Coletiva**, v. 26, n. 3, p. 1023-1033, 2021.
- COELBA. **Dados de consumo de energia por bairro de Salvador**. Salvador: COELBA, 2021.
- DEMENECH, L. M.; DUMITH, S. D. C.; VIEIRA, M. E. C. D.; NEIVA-SILVA, L. Desigualdade econômica e risco de infecção e morte por COVID-19 no Brasil. **Revista Brasileira de Epidemiologia**, v. 23, p. 1-12, 2020.
- DOHET, F.; LOAP, S.; MENZEL, A.; IDDIR, M.; DADOUN, F.; BOHN, T.; SAMOUDA, H. Obesity considerations during the COVID-19 outbreak. **International Journal for Vitamin and Nutrition Research**, v. 92, n. 1, p. 67-79, 2022.
- FACULDADE DE MEDICINA DE RIBERÃO PRETO – UNIVERSIDADE DE SÃO PAULO (FMRP/USP). **Covid-19 Brasil**. Ribeirão Preto: FMRP/USP, 2022. Disponível em: <https://ciis.fmrp.usp.br/covid19>. Acesso em: 10 mar. 2022.
- FIGUEIREDO, A. M. D.; FIGUEIREDO, D. C. M. M. D.; GOMES, L. B.; MASSUDA, A.; GIL-GARCIA, E.; VIANNA, R. P. D. T.; DAPONTE, A. Social determinants of health and COVID-19 infection in Brazil: an analysis of the pandemic. **Revista Brasileira de Enfermagem**, v. 73, p. 1-7, 2020.
- FISCHER, M.M.; WANG, J. **Spatial data analysis: models, methods and techniques**. Berlin: Springer Science & Business Media, 2011.
- FOX, J. **Applied regression analysis and generalized linear models**. Londres: Sage Publications, 2015.
- FOX, J.; WEISBERG, S. **An R companion to applied regression**. Londres: Sage publications, 3. ed., 2019.
- FRANÇA, N. C.; CAMPÊLO, G. L.; DE FRANÇA, J. M. S.; VALE, E. G.; BADAGNAN, T. F. A decomposition analysis for socioeconomic inequalities in health status associated with the COVID-19 diagnosis and related symptoms during Brazil's first wave of infections. **Economia**, v. 22, n. 3, p. 251-264, 2021.
- GALASSO, V.; PONS, V.; PROFETA, P.; BECHER, M.; BROUARD, S.; FOUCAULT, M. Gender Differences in COVID-19 Related Attitudes and Behavior: Evidence from a Panel Survey in Eight OECD Countries. **NBER Working Paper**, n. 27359, 2020.
- HUBER, P. Robust estimation of a location parameter. **Annals of Mathematical Statistics**, v. 35, n. 1, p. 73-101, 1964.
- IBGE – INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo demográfico 2022**. Brasília: IBGE, 2024. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico-2022.html?edicao=38166&t=resultados>. Acesso em: 06 mar. 2024.
- 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.

- Kopel, J.; Perisetti, A.; Roghani, A.; Aziz, M.; Gajendran, M.; Goyal, H. Racial and gender-based differences in COVID-19. **Frontiers in Public Health**, v. 8, p. 1-7, 2020.
- LEVY, P. M.; FERREIRA, S. F.; MARTINS, F. S. Política fiscal - Impactos da pandemia sobre os resultados recentes das contas públicas. **IPEA Carta de Conjuntura**, n. 50, 2021.
- LEWIS, A.; DUCH, R. Gender differences in perceived risk of COVID-19. **Social Science Quarterly**, v. 102, n. 5, p. 2124-2133, 2021.
- LOURENÇO, G. F.; DOS SANTOS, P. S. Determinantes da mortalidade por Covid-19 no Rio de Janeiro em 2020. **Cadernos de Ciências Sociais Aplicadas**, v. 19, n. 33, p. 43-56, 2022.
- Natividade, M. D. S.; Bernardes, K.; Pereira, M.; Miranda, S. S.; Bertoldo, J.; Teixeira, M. D. G.; Livramento, H. L.; Aragão, E. Distanciamento social e condições de vida na pandemia COVID-19 em Salvador-Bahia, Brasil. **Ciência & Saúde Coletiva**, v. 25, p. 3385-3392, 2020.
- Nicolelis, M. A.; Raimundo, R. L.; Peixoto, P. S.; Andreazzi, C. S. The impact of super-spreader cities, highways, and intensive care availability in the early stages of the COVID-19 epidemic in Brazil. **Scientific Reports**, v. 11, n. 1, p. 1-12, 2021.
- Perrotta, F.; Corbi, G.; Mazzeo, G.; Boccia, M.; Aronne, L.; D'Agnano, V.; Komici, K.; Mazzarella, G.; Parrella, R.; Bianco, A. COVID-19 and the elderly: insights into pathogenesis and clinical decision-making. **Aging Clinical and Experimental Research**, v. 32, n. 8, p.1599-1608, 2020.
- PIMENTA, R. M. C.; DA SILVA, R. M.; CARDOSO, G. M. P.; NERY, F. S. D.; FARIAS, V. V. L.; FIGUEREDO, W. N.; DE MACEDO, T. T. S. COVID-19 no município de Salvador: estudo ecológico dos primeiros meses da Pandemia. **Research, Society and Development**, v. 10, n. 11, p. 1-13, 2021.
- PREFEITURA MUNICIPAL DE SALVADOR (PMS). **Dados de arrecadação de ISS por bairro de Salvador**. Salvador: PMS, 2021.
- RATTAY, P.; MICHALSKI, N.; DOMANSKA, O. M.; KALTWASSER, A.; DE BOCK, F.; WIELER, L. H.; JORDAN, S. Differences in risk perception, knowledge and protective behaviour regarding COVID-19 by education level among women and men in Germany. Results from the COVID-19 Snapshot Monitoring (COSMO) study. **Plos one**, v. 16, n. 5, 2021.
- SAMUEL, L. J.; GASKIN, D. J.; TRUJILLO, A.; SZANTON, S. L.; SAMUEL, A.; SLADE, E. Race, ethnicity, poverty and the social determinants of the coronavirus divide: US county-level disparities and risk factors. **BMC Public Health**, v. 21, n. 1, p. 1-11, 2021.
- SECRETARIA MUNICIPAL DE SAÚDE (SMS). **Informações sobre contaminação e mortalidade associadas à Covid-19**. Salvador: SMS, 2021.
- Superintendência de Estudos Econômicos e Sociais da Bahia (SEI). **Sistema de informações municipais**. Salvador: SEI, 2022. Disponível em: <http://sim.sei.ba.gov.br/sim/index.wsp>. Acesso em: 27 fev. 2022.
- SPAGNOLO, P. A.; MANSON, J. E.; JOFFE, H. Sex and gender differences in health: what the COVID-19 pandemic can teach us. **Annals of Internal Medicine**, v. 173, n. 5, p. 385-386, 2020.
- SY, K. T. L.; WHITE, L. F.; NICHOLS, B. E. Population density and basic reproductive number of COVID-19 across United States counties. **PloS one**, v. 16, n. 4, 2021.

UNIVERSIDADE FEDERAL DA BAHIA (UFBA). **Risco dos bairros de Salvador ao espalhamento do COVID-19 decorrente da circulação de pessoas e condições socioeconômicas**. Salvador: UFBA, 2020. Disponível em: <http://www.transporteterrestre.eng.ufba.br/wp-content/uploads/2020/04/Nota-T%C3%A9cnica-01-Grupo-GeoCombate-COVID19-BA.pdf>. Acesso em: 21 mar. 2022.

VERADI, V.; CROUX, C. Robust regression in Stata. **The Stata Journal**, v. 9, n. 3, p. 439-453, 2009.

WONG, D. W.; LI, Y. Spreading of COVID-19: Density matters. **Plos one**, v. 15, n. 12, 2020.

WORLDOMETER. COVID-19 Coronavirus Pandemic. Disponível em: <https://www.worldometers.info/coronavirus>. Acesso em: 06 mar. 2024.

YOHAI, V. J. High breakdown-point and high efficiency robust estimates for regression. **The Annals of Statistics**, p. 642-656, 1987.

## APÊNDICE A – ANÁLISE DE COMPONENTES PRINCIPAIS

Tabela A1 – Características Socioeconômicas e Demográficas: Correlação em Pares

	old	mulher	branco	lnrend	Alfab	rendate1sm
old	1,000					
mulher	0,761	1,000				
branco	0,748	0,657	1,000			
lnrend	0,686	0,678	0,951	1,000		
alfab	0,497	0,746	0,602	0,704	1,000	
rendate1sm	-0,666	-0,715	-0,864	-0,938	-0,814	1,000

Fonte: Elaboração própria.

Tabela A2 – Indicador de Características Socioeconômicas e Demográficas: PCA

Componente	Autovalor	Diferença	Proporção	Cumulativo		
Comp1	4,080	3,543	0,816	0,816		
Comp2	0,536	0,249	0,107	0,923		
Comp3	0,287	0,217	0,057	0,981		
Comp4	0,070	0,043	0,014	0,995		
Comp5	0,027	0,003	0,005	1,000		
Comp6	0,024		0,004	1,000		
Associação entre Variáveis e Componentes						
Variável	Comp1	Comp2	Comp3	Comp4	Comp5	Comp6
old	0,378	0,573	0,450	-0,562	0,0002	0,103
mulher	0,394	-0,113	0,629	0,647	-0,131	-0,034
branco	0,423	0,327	-0,364	0,237	0,539	-0,486
lnrend	0,435	0,082	-0,416	0,183	-0,058	0,771
alfab	0,379	-0,720	0,114	-0,379	0,424	0,047
rendate1sm	-0,437	0,167	0,289	0,180	0,713	0,395

Fonte: Elaboração própria.