

# Características multidimensionais e mortalidade por COVID-19 em 2020: uma análise para as regiões metropolitanas brasileiras

Jefferson Douglas da Silva Pereira<sup>1</sup>

Admir Antônio Betarelli Júnior<sup>2</sup>

## RESUMO

A pandemia da COVID-19 trouxe grandes desafios para o Brasil em termos sanitários e socioeconômicos. Muitos estudos têm apontado que o progresso da pandemia pode estar relacionado a características específicas de cada localidade, como o nível de distanciamento social e de estrutura hospitalar. Esses estudos, contudo, não tem considerado como as possíveis configurações entre essas características podem levar a uma alta ou baixa mortalidade por COVID-19 nestas localidades. Neste sentido, o objetivo deste artigo é identificar essas configurações lógicas e analisar como elas se relacionam com a mortalidade por COVID-19 nas regiões metropolitanas brasileiras em cada semestre de 2020. Inicialmente, aplica-se a análise fatorial exploratória para sintetizar as características dessas regiões em dimensões latentes. Em seguida, por meio de uma análise comparativa qualitativa de conjunto difuso (fsQCA), essas dimensões formam as condições que constituem as configurações suficientes para a mortalidade por COVID-19. Um dos principais resultados mostra que as combinações lógicas entre alta estrutura hospitalar básica e alta estrutura hospitalar específica ou alto deslocamento e baixo recursos específicos cobrem 72% das regiões metropolitanas, sendo altamente consistente (92%) com a alta mortalidade por COVID-19.

**Palavras-chave:** COVID-19. Distanciamento social. Análise multivariada.

**JEL:** I10; I18; C38

**Área temática 8:**

## ABSTRACT

The COVID-19 pandemic brought great challenges to Brazil in health and socioeconomic terms. Many studies have shown that the progress of the pandemic may be related to specific characteristics of each location, such as the level of social distance and hospital structure. These studies, however, have not considered how the possible configurations among these characteristics can lead to high or low mortality from COVID-19 in these locations. In this sense, the aim of this article is to identify these logical configurations and analyze how they relate to mortality by COVID-19 in Brazilian metropolitan regions in each semester of 2020. Initially, exploratory factor analysis is applied to synthesize the characteristics of these regions in latent dimensions. Then, through a diffuse-set qualitative comparative analysis (fsQCA), these dimensions form the conditions that constitute sufficient configurations for mortality from COVID-19. One of the main results shows that the logical combinations between high basic hospital structure and high specific hospital structure or high displacement and low specific resources cover 72% of metropolitan regions, being highly consistent (92%) with high mortality by COVID-19.

**Keywords:** COVID-19. Social distancing. Multivariate analysis.

**JEL:** I10; I18; C38

---

<sup>1</sup> Doutorando do Programa de Pós-Graduação em Economia da Universidade Federal de Juiz de Fora (PPGE-UFJF).

<sup>2</sup> Professor Adjunto do Departamento de Economia da UFJF.

## 1 Introdução

O mundo vem enfrentando, desde o início de 2020, um de seus maiores desafios recentes em termos de saúde pública, sociais e econômicos devido à pandemia global da COVID-19, declarada em 11 de março de 2020 (OMS, 2021). Desde o início da pandemia até 31 de dezembro de 2020, o Brasil registrou, aproximadamente, 7,7 milhões de casos de COVID-19, dos quais 194.949 foram mortes (DATASUS, 2021). A COVID-19, como é característico das pandemias, não afetou o país de maneira uniforme (Ahmed et al., 2020). Embora, as regiões metropolitanas (RMs) possuam 58,12% (123.063.272 de 211.755.692) do total da população do Brasil (IBGE, 2020), elas registraram 78,23% do total de óbitos por COVID-19 ocorridos em 2020 no país. Mesmo entre as RMs, a maneira como cada uma foi afetada variou conforme o tempo e a macrorregião em que elas estão localizadas. No primeiro semestre de 2020, das dez RMs com mais mortes por cem mil habitantes, seis se localizavam na região Nordeste, três na região Sudeste e uma na região Norte; no segundo semestre, cinco se localizavam na região Sudeste e outras cinco na região Sul (DATASUS, 2021). Como se vê, a mortalidade por COVID-19 apresenta um caráter dinâmico que pode estar relacionado a fatores intrínsecos de cada região do país, como a qualidade prévia da estrutura de saúde local (Ahmed et al., 2020).

A maneira como a mortalidade por COVID-19 se altera de um período para outro entre as RMs pode se dar em decorrência das ações adotadas para o enfrentamento da pandemia e/ou das diferenças estruturais do sistema de saúde entre cada uma delas. No Brasil, as ações para mitigação dos efeitos da pandemia, como o distanciamento social, foram adotadas de forma descentralizada por governos estaduais e municipais (Moraes et al., 2020). O distanciamento social, inclusive, tem sido apontado por muitos estudos como uma medida importante para reduzir o número de casos e de mortes por COVID-19, no entanto, a magnitude dessa redução varia bastante de uma localidade para outra (Cohen e Kupfershmidt, 2020; Ferguson et al., 2020; Stojkski et al., 2020). Fatores como estrutura hospitalar, nível de financiamento da saúde e recursos específicos para o enfrentamento da doença podem explicar essa variação (Noronha, et al., 2020; Portela, et al., 2020).

A literatura sobre COVID-19 tem focado na identificação das características individuais associadas às mortes pela doença, contudo, alguns estudos têm investigado a importância da estrutura do sistema de saúde (Maciel; et al., 2020; Moreira, 2020; Noronha; et al., 2020; Portela; et al., 2020) e do isolamento social (Aquino; et al., 2020; Cohen; Kupfershmidt, 2020; Ferguson; et al., 2020; Noronha; et al., 2020) para o enfrentamento da

pandemia. Este artigo busca unir essas duas vertentes de pesquisas sobre COVID-19, de modo a analisar como a combinação dos fatores relacionados à estrutura de saúde e ao isolamento social se associam aos níveis de mortalidade por COVID-19 e de que maneira essa combinação pode se modificar entre as localidades e entre períodos, tendo em vista o caráter dinâmico da doença. Dito isto, o objetivo deste artigo é identificar como e quais são os fatores que se relacionam com a mortalidade por COVID-19 nas regiões metropolitanas brasileiras nos dois semestres de 2020.

A análise procede a partir de uma estratégia empírica que combina de maneira sucessiva uma técnica exploratória e outra configuracional. A fim de condensar em poucas variáveis latentes um amplo conjunto de características das RMs do Brasil, que podem influenciar, direta ou indiretamente, na mortalidade por COVID-19, adota-se a técnica de análise fatorial (AF). Em seguida, essas variáveis latentes, agora nomeadas de condições causais, assim como a mortalidade por COVID-19, são transformadas em conjuntos *fuzzy* para aplicação da análise comparativa qualitativa (fsQCA), que revelará como as possíveis configurações lógicas entre essas condições se associam a alta e a baixa mortalidade por COVID-19. A estratégia empírica adotada neste estudo se diferencia das demais análises realizadas até o momento, pois, a partir da fsQCA, ela permite determinar mais de um modelo causal, isto é, mais de uma configuração de condições causais, associado à mortalidade por COVID-19 nas RMs (Ragin, 1987). Espera-se que as configurações lógicas sejam diferentes entre períodos e entre as RMs, e que as RMs com melhores estruturas hospitalares e menores níveis de deslocamento se relacionem com baixa mortalidade por COVID-19 em ambos os semestres.

Os resultados deste estudo podem trazer contribuições importantes no combate à COVID-19. Ao determinar quais combinações de variáveis estão relacionadas à mortalidade por COVID-19 nas RMs, pode-se adotar estratégias descentralizadas considerando as especificidades de cada localidade. Essas especificidades, por sua vez, podem ser conhecidas por meio da caracterização das RMs em relação às suas características próprias. Isto pode tornar as ações de enfrentamento à pandemia mais eficazes e eficientes.

Este artigo conta com esta introdução e outras 5 seções. A seção 2 está dividida em duas subseções: uma detalha a estratégia empírica adotada neste estudo e a outra descreve a base de dados. A seção 3 apresenta os principais resultados. Em seguida, a seção 4 traz as considerações finais deste artigo. E, por fim, apresenta-se as referências utilizadas neste estudo.

## 2 Estratégia empírica

A estratégia empírica adotada neste artigo consiste na aplicação sucessiva de duas técnicas multivariadas, a saber: análise fatorial e análise comparativa qualitativa. A AF, cujos pioneiros são Pearson e Spearman (1904), tem o propósito essencial de descrever, se possível, as relações de covariância entre muitas variáveis em termos de análise de algumas quantidades aleatórias subjacentes, mas não observáveis, chamadas de fatores (Johnson e Wichern, 2007). Neste artigo, a AF é utilizada para sintetizar, em variáveis latentes, as interdependências das características da estrutura hospitalar, do financiamento à saúde e da mobilidade nas regiões metropolitanas brasileiras, no âmbito da pandemia provocada pela COVID-19. Para tanto, é preciso garantir que essas interdependências existam.

O modelo fatorial assume que um vetor  $\mathbf{X}$ , com  $p$  componentes, média  $\boldsymbol{\mu}$  e matriz de covariância  $\boldsymbol{\Sigma}$ , é linearmente dependente de algumas variáveis aleatórias não observáveis  $F_1, F_2, \dots, F_m$ , os fatores comuns, e de  $p$  fontes adicionais de variação,  $\varepsilon_1, \varepsilon_2, \dots, \varepsilon_p$ , os erros ou fatores específicos (Johnson e Wichern, 2007). Em notação matricial, tem-se que:

$$\mathbf{X}_{(px1)} - \boldsymbol{\mu} = \mathbf{L}_{(pxm)}\mathbf{F}_{(mx1)} + \boldsymbol{\varepsilon}_{(px1)} \quad (1)$$

$\mathbf{L}_{(pxm)}$  representa a matriz das cargas fatoriais, formada pelos coeficientes das cargas  $l_{ij}$  da  $i$ -ésima variável sobre o  $j$ -ésimo fator. Estimando os fatores pelo método dos componentes principais<sup>3</sup>, e tomando  $m < p$ , tem-se que a matriz de correlação é dada por:

$$\boldsymbol{\Sigma} = \mathbf{L}\mathbf{L}' + \boldsymbol{\Psi} \quad (2)$$

Em que  $\mathbf{L}\mathbf{L}'$  é a variância comum e  $\boldsymbol{\Psi}$  a variância específica. Segundo Johnson e Wichern (2007), para encontrar a matriz de cargas fatoriais, basta aplicar a decomposição espectral sobre a matriz  $\boldsymbol{\Sigma}$ . Como a estrutura da base de dados deste artigo não apresenta distribuição normal multivariada, o método de estimação dos *scores* fatoriais é o de Mínimos Quadrados Ponderados (MQP) propostos por Bartlett (1937) (Johnson e Wichern, 2007).

Uma vez extraídas, as variáveis latentes são utilizadas na aplicação da QCA, como sendo as condições causais para o resultado nomeado mortalidade por COVID-19. Proposta por Ragin (1987), a QCA introduz a análise das condições necessárias e suficientes para que seja possível determinar mais de um modelo causal que se ajuste aos dados. Uma condição deve estar presente para que determinado caso ocorra (necessidade) ou pode, por si mesma, produzir um certo resultado (suficiência) (Ragin, 1987). Sendo assim, é possível que uma das condições possa, sozinha, estabelecer uma relação causal com a mortalidade por COVID-19

---

<sup>3</sup> Para ver detalhes sobre os outros métodos de estimação de *scores* fatoriais, tais como o método do fator principal e o de máxima verossimilhança, ver Johnson e Wichern (2007).

nas RMs (condição suficiente) ou que ela, ao menos, deva estar presente para que um modelo causal seja encontrado (condição necessária).

Ragin (1987) elaborou a QCA baseando-se no método Booleano dicotômico, que deu origem ao *crisp-set* QCA (csQCA). A fim de permitir a atribuição de valores às condições, que não fossem apenas 0 e 1, como no csQCA, Ragin (2000) propôs o modelo *fuzzy-set* QCA (fsQCA), que admite conjuntos (condições causais) com valores entre 0 e 1. Os conjuntos construídos neste artigo para aplicação da QCA são baseados no método fsQCA.

Ao transformar os fatores latentes obtidos na AF, bem como a mortalidade por COVID-19, em conjuntos *fuzzy*, as informações dos dados são mantidas (Rihoux, 2006). Essa transformação apenas coloca o fator em uma escala de 0 a 1, com os valores representando o nível de pertencimento no conjunto (Longest e Vaisey, 2008). Segundo Ragin (2009), valores iguais a 0 indicam não-pertencimento ao conjunto, enquanto valores iguais a 1 indicam pertencimento total ao conjunto. Entre 0 e 1, pode ser definido um ponto de corte para determinar se esse pertencimento é alto ou baixo, por exemplo, 0,5, o que indicaria que neste ponto não há diferença entre pertencimento ou não-pertencimento no conjunto. Isto torna os conjuntos *fuzzy*, simultaneamente, qualitativos e quantitativos (Ragin, 2009).

Após formados os conjuntos, aplica-se a QCA, que fornecerá as configurações que levam ao resultado (alto ou baixo). A quantidade de configurações possíveis é igual a 2 elevado ao número  $k$  de conjuntos de condições causais (Ganter e Hecker, 2014). Neste estudo, serão 16 configurações possíveis ( $2^4 = 16$ ) que estarão relacionadas à alta ou à baixa mortalidade por COVID-19. Para que essas configurações sejam validadas, são observados os valores de cobertura, que indica a quantidade de casos empiricamente observados para cada configuração, e de consistência que, por sua vez, mostra a proporção de observações consistente com o resultado. Para Ragin (2006) são essas medidas que vão determinar se as configurações geradas foram estabelecidas em termos de necessidade ou suficiência.

Ragin (2008) e Schneider e Wageman (2012) consideram como relações necessárias, aquelas configurações que apresentam medida de consistência iguais ou superiores a 0,90. Essas configurações são chamadas de “expressões primitivas” (Grofman e Schneider, 2009). Dada a possibilidade de um elevado número de configurações, Ragin (1987) propõe a minimização Booleana, que reduz as “expressões primitivas” para configurações o mais curta possível. Isto pode ser feito pelo algoritmo de Quine-McCluskey (1956).

Em resumo, a aplicação da QCA visa explorar as diferentes configurações de condições causais (fatores latentes frutos da sintetização das variáveis via AF) para o resultado pretendido (mortalidade por COVID-19). A partir dessas configurações, será

possível conhecer quais as combinações de fatores que estão relacionadas à mortalidade por COVID-19 e verificar se elas mudam entre o primeiro e o segundo semestre de 2020. Por fim, é preciso ressaltar que as soluções obtidas via QCA não provam estritamente as relações causais (Schneider e Wageman, 2010). Isto implica dizer que, as interpretações dos resultados da QCA devem ser feitas com cautela, para evitar uma conclusão equivocada.

## **2.1 Base de dados**

Os dados utilizados neste estudo referem-se às Regiões Metropolitanas (RMs) brasileiras, que são definidas pela pesquisa semestral de Regiões Metropolitanas, Aglomerações Urbanas e Regiões Integradas de Desenvolvimento, realizada pelo Instituto Brasileiro de Geografia e Estatística (IBGE). Para este estudo considerou-se a pesquisa referente ao primeiro semestre de 2020. De acordo com o IBGE (2020), existem no país 74 regiões metropolitanas, 5 aglomerações urbanas e 3 regiões integradas de desenvolvimento. Neste estudo, estas três denominações serão chamadas de regiões metropolitanas para fins de simplificação. Sendo assim, o estudo refere-se a 82 RMs. Elas são compostas por 1.420 municípios (ou, 25,5% do total de municípios do Brasil) e estão presentes em todas as cinco macrorregiões do país. Em termos de contingente populacional, as RMs possuem 58,12% (123.063.272 de 211.755.692) do total da população brasileira (IBGE, 2020).

A base de dados deste artigo contempla quatro dimensões principais das RMs de modo a associá-las ao padrão de mortalidade por COVID-19. A mortalidade por COVID-19 representa a quantidade de mortos por cem mil habitantes nas 82 RMs brasileiras para os dois semestres de 2020. A propósito, para a extração de todas as variáveis considerou-se o período o semestral, com exceção, da despesa total com saúde por habitante e da população, extraídas com valores anuais. Além disso, para as variáveis referentes à mortalidade por COVID-19, ao percentual da população que recebeu o auxílio emergencial e aos deslocamentos, cujos dados do primeiro semestre não constam informações para os seis meses, considerou-se nos cálculos de acumulado e de média, os valores dos meses disponíveis.

O Quadro 1 fornece as principais informações sobre as variáveis utilizadas neste artigo. Os dados foram extraídos do Departamento de Informática do Sistema Único de Saúde (DATASUS), do Ministério da Saúde; do Ministério da Cidadania; do Instituto Brasileiro de Geografia e Estatística (IBGE); do Tesouro Nacional; e do Relatórios de Mobilidade da Comunidade da Google. As informações sobre mobilidade mostram a variação no deslocamento para alguns municípios conforme algumas atividades em comparação com os dias de referência. Um dia de referência representa um valor normal para esse mesmo dia da

semana e é o valor mediano do período das cinco primeiras semanas de 2020 (3 de janeiro a 6 de fevereiro de 2020), quando não havia sido declarada a pandemia da COVID-19, nem havia restrições de deslocamentos (GOOGLE, 2020).

**Quadro 1 – Descrição das variáveis e fontes dos dados (1º e 2º semestres de 2020)**

Dimensão	Variáveis (Acrônimos)	Descrição das variáveis	Fonte dos dados	Periodicidade
Mortalidade	Mort.COVID-19	Mortalidade por COVID-19 (por 100 mil habitantes)	DATASUS e IBGE	Semestral
Deslocamentos	Mobilidade 1	Mobilidade varejo e lazer (% variação)	Google	Semestral
	Mobilidade 2	Mobilidade mercados e farmácias (% variação)		Semestral
	Mobilidade 3	Mobilidade locais de trabalho (% variação)		Semestral
	Mobilidade 4	Mobilidade transporte público (% variação)		Semestral
Estrutura hospitalar e seu financiamento	Hospitais e ambulatórios	Quantidade hospitais e ambulatórios (por mil habitantes)	DATASUS e IBGE	Semestral
	Profissionais de enfermagem	Quantidade de pessoal da área de enfermagem (por mil habitantes)		Semestral
	Médicos	Quantidade médicos (por mil habitantes)		Semestral
	UTIs	Quantidade UTIs (por mil habitantes)		Semestral
	Leitos	Quantidade leitos de internação (por mil habitantes)		Semestral
	Suporte ventilatório	Quantidade respiradores e ventiladores (por mil habitantes)		Semestral
	Despesa com saúde	Despesas total com saúde (por habitante)	Ministério da Saúde (MS) – SIOPS	Anual
	Repasse obrigatórios	Transferências totais obrigatórias (por habitante)		Semestral
Recursos para enfrentamento à COVID-19	Recursos municipais	Recursos municipais totais para COVID-19 (por habitante)	Tesouro Nacional e IBGE	Semestral
	Recursos estaduais	Recursos estaduais totais para COVID-19 (por habitante)		Semestral
	Recursos federais	Recursos federais totais para COVID-19 (por habitante)		Semestral
	Auxílio emergencial (%)	Percentual da população recebendo auxílio emergencial (percentual da população)	Ministério da Cidadania e IBGE	Semestral

Fonte: Elaborada pelos próprios autores.

A Tabela 1 apresenta as principais estatísticas descritivas das variáveis utilizadas neste estudo, considerando os dois semestres de 2020. A mortalidade por COVID-19 nas RMs é a única variável da Tabela 1 que não foi utilizada na AF, apenas na QCA, como variável resultado, a sua média aumentou em mais 203,2% (de 306,3 para 928,68 mortes/100 mil habitantes) entre o primeiro e o segundo semestre. Em ambos os semestres, o desvio padrão se mostra elevado (323,45 no 1º e 754,26 no 2º), indicando que há grandes diferenças nas taxas de mortalidade entre as RMs.

As variáveis de mobilidade apresentaram variação média negativa em ambos os semestres de 2020 quando comparadas ao período de referência, a única exceção é a mobilidade 2 (mobilidade em áreas de mercados e farmácias) que sofreu variação positiva no segundo semestre. No geral, como disposto na Tabela 1, o deslocamento médio no segundo

semestre foi maior do que no primeiro nas RMs, assim como foi o número de óbitos por COVID-19.

Na Tabela 1 verifica-se que todas as variáveis relacionadas à estrutura hospitalar apresentam médias superiores no segundo semestre quando comparadas ao primeiro, exceto leitos (quantidade de leitos de internação por 1 mil/hab), que apresentou média de 25,08 no primeiro semestre e 25,07 no segundo semestre, e a despesa com saúde (despesa total com saúde por habitante), que manteve a média entre os dois semestres, já que ela tem periodicidade anual. Essa elevação das médias pode estar indicando que as RMs buscaram responder ao aumento da mortalidade por COVID-19 experimentada no segundo semestre, ampliando a estrutura hospitalar.

**Tabela 1: Estatísticas descritivas (1º e 2º semestres de 2020)**

Variáveis	1º semestre		2º semestre	
	Média	Desvio-padrão	Média	Desvio-padrão
Mort.COVID-19	306,3	323,45	928,68	754,26
Mobilidade 1	-38,75	9,9	-16,7	11,44
Mobilidade 2	-8,06	8,47	17,05	13,5
Mobilidade 3	-16,8	6,57	-2,31	5,09
Mobilidade 4	-43,18	11,46	-22,49	19,14
Hospitais e ambulatórios	2033,54	2788,84	2151,57	3020,48
Profissionais de enfermagem	50,22	33,47	53,04	34,83
Médicos	17,92	11,47	19	15,79
UTIs	1,86	1,83	2,09	2,05
Leitos	25,08	22,27	25,07	22,3
Suporte ventilatório	2,18	2,16	2,49	2,45
Despesa com saúde	18165,83	13912,81	18165,83	13911,21
Repasse obrigatórios	16555,09	12786,74	19490,12	15184,97
Recursos municipais	4,42	8,97	21,29	24,03
Recursos estaduais	2,15	5,54	7,41	10,14
Recursos federais	42,65	34,32	363,27	245,29
Auxílio emergencial (%)	34,42	6,99	28,57	6,1

Fonte: Elaborada pelos próprios autores a partir dos dados da pesquisa.

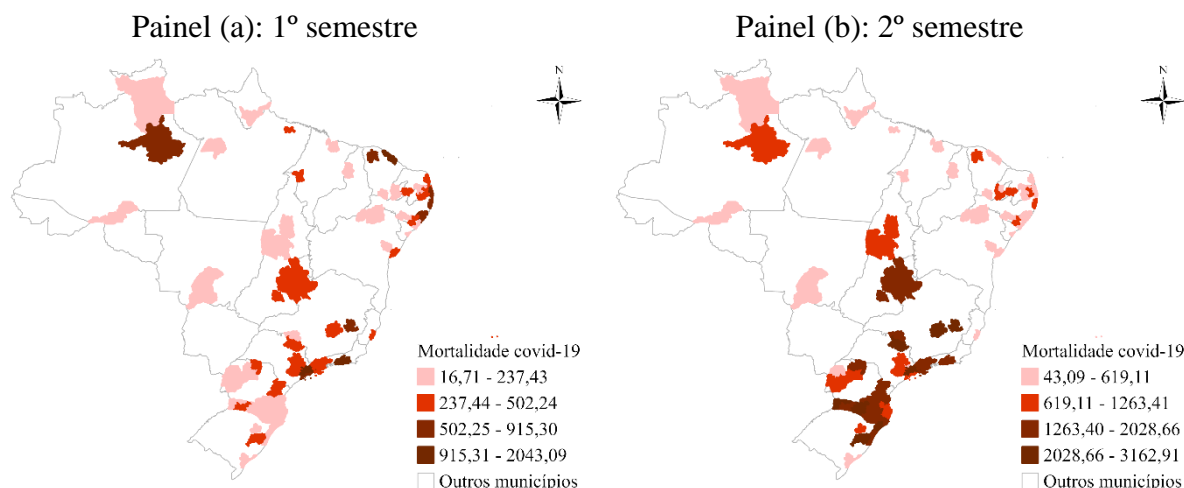
Por fim, a Tabela 1 mostra que os recursos de origem municipal, estadual e federal, destinados exclusivamente para o enfrentamento da COVID-19, foram amplamente elevados no segundo semestre quando se compara com o primeiro, especialmente, os recursos federais, que se elevaram em mais de 8,5 vezes do primeiro para o segundo semestre. Em relação à cobertura do auxílio emergencial, ele atendeu, em média, 34,42% da população das RMs no primeiro semestre e caiu para 28,57% no segundo semestre.

Como foi apresentado na Tabela 1, as estatísticas descritivas (média e desvio-padrão) para variável taxa de mortalidade por COVID-19 apontam para existência de diferenças nas suas taxas entre os períodos e entre as próprias RMs. A Figura 1 ilustra como o número de mortes (por cem mil habitantes) por COVID-19 tem evoluído dentro e entre as RMs em cada período analisado. Quanto mais forte a tonalidade do vermelho maior a mortalidade.



Observa-se na Figura 1 que, no primeiro semestre, as macrorregiões Nordeste, Sudeste e Norte possuíam as RMs com as mais elevadas taxas de mortalidade por COVID-19. No segundo semestre, este cenário muda, e as macrorregiões Sul, Sudeste e Centro-Oeste foram as que apresentaram as RMs com as maiores taxas de mortalidade por COVID-19. Esses resultados corroboram com a hipótese de dinamicidade da doença.

**Figura 1: Óbitos por COVID-19 nas RMs do Brasil**



Fonte: Elaborado pelos próprios autores a partir dos dados da pesquisa.  
Nota: A mortalidade por Covid-19 está em mortes por cem mil habitantes.

De modo geral, verifica-se que, do primeiro semestre para segundo, houve uma mudança na concentração de maiores taxas de mortalidade por COVID-19, com essa taxa sendo maior nas RMs localizadas nas regiões Sul e Sudeste do país. As RMs das regiões Nordeste e Norte foram as que apresentaram as menores taxas de mortalidade por COVID-19 no segundo semestre, contrastando com o fato de no primeiro semestre terem apresentado elevadas taxas de mortalidade. Esses resultados reforçam a necessidade de se compreender como determinados fatores se combinam e afetam a mortalidade por COVID-19 em cada RM.

### 3 Resultados

Esta seção apresenta os principais resultados obtidos neste estudo. Primeiro, discute-se a adequabilidade da aplicação dos métodos multivariados; em seguida, descreve-se e explica-se como as características das RMs estão associadas à mortalidade por COVID-19. Para que se justifique a aplicação da AF, é preciso garantir que a matriz de dados tenha uma quantidade suficiente de altas correlações, coeficientes com magnitudes superiores a 0,30 pode ser um bom ponto de corte (Hair et al., 2009; Afifi et al., 2011). A base de dados deste estudo apresenta 80 coeficientes de correlação superiores a 0,30 (58,82% do total) no primeiro

semestre e 73 (53,68% do total) no segundo semestre de 2020, indicando a adequabilidade da estrutura dos dados para aplicação da AF. Os testes estatísticos apontam para o uso do método dos componentes principais<sup>4</sup> para extração, via AF, das condições causais a serem utilizadas na fsQCA, já que a hipótese de distribuição normal multivariada não é satisfeita (Johnson e Wichern, 2007). A Tabela 2 apresenta os resultados do modelo fatorial, estimado por meio do método dos componentes principais. O teste de esfericidade de Bartlett fornece evidências de que há, para os dois semestres, coeficientes estatisticamente significativos diferentes de zero, a um nível de significância de 1% (Hair et al., 2009). O valor da estatística de Kaiser-Meyer-Olkin (KMO) foi de 0,77 e 0,82 para o primeiro e segundo semestre, respectivamente, indicando adequação do modelo fatorial. Os quatro fatores latentes selecionados atendem aos critérios de Kaiser e Pearson, já que apresentam autovalores superiores a um e, quando juntos, acumulam 78% da variância total dos dados, no primeiro semestre, e 73% no segundo.

Para facilitar a interpretação, as cargas fatoriais foram rotacionadas pelo método ortogonal Varimax de Kaiser (Johnson e Wichern, 2007) e apenas aquelas maiores que 0,60 e com comunalidades iguais ou superiores a 0,50 foram consideradas para nomear os fatores<sup>5</sup>. Por fim, o teste de confiabilidade entre os itens, medido pelo valor do Alfa de Cronbach, aproxima-se de 0,90 nos dois semestres, indicando uma confiabilidade muito boa. Os dois modelos fatoriais dispostos na Tabela 2 revelam que nos dois semestres a composição dos fatores são relativamente estáveis, apenas as composições do segundo e do quarto fatores se modificam de um período para outro. Essa natureza relativamente constante na composição dos fatores permite, ainda que de maneira cautelosa, além da interpretação do modelo de cada semestre, fazer uma análise intertemporal (Ferreira, 2017).

Observa-se na Tabela 2 que o fator 1 é positivamente relacionado às variáveis quantidade do pessoal da enfermagem, quantidade de médicos, quantidade de leitos de internação, despesa total com saúde, e transferências obrigatórias constitucionais para ambos os semestres. O fator 1 representa as estruturas básicas de funcionamento hospitalar e, portanto, será denominado de estrutura hospitalar básica (B). O fator 2, por sua vez, apresenta relação positiva com a quantidade de hospitais e ambulatórios, quantidades de UTIs e quantidade de respiradores e ventiladores nos dois períodos de análise, sendo que no segundo semestre, ele também se relaciona com a variável quantidade de médicos. O fator 2 relaciona-

---

<sup>4</sup> As hipóteses de simetria (teste de Lawley) e homogeneidade (teste de Wald de Jennrich (1970)) das matrizes de correlação, de distribuição normal multivariada (testes estatísticos de Henze-Zirkler e de Doornik-Hansen), de assimetria normal multivariada (Mardia mSkewness) e de curtose (Mardia mKurtosis) foram rejeitadas.

<sup>5</sup> De acordo com Hair et al (2009), para uma base de dados com um número de observações igual a 85, apenas cargas fatoriais acima de 0,60 são significantes a um nível de 5% de significância. A base deste artigo possui 82 observações, então o corte de 0,60 parece ser o mais ideal, já que 0,65 deve ser utilizado para 70 observações.

se diretamente aos mecanismos hospitalares de combate direto à COVID-19, e será chamado de estrutura hospitalar específica (E).

**Tabela 2: Resultados das análises fatoriais (1º e 2º semestres)**

Variáveis	Estrutura hospitalar básica		Estrutura hospitalar específica		Deslocamentos		Recursos específicos		Comunalidades	
	1º	2º	1º	2º	1º	2º	1º	2º	1º	2º
Mobilidade 1					0,73	0,83			0,75	0,70
Mobilidade 2					0,76				0,78	0,60
Mobilidade 3					0,71	0,65			0,78	0,63
Mobilidade 4									0,62	0,53
Hospitais e ambulatórios			0,88	0,93					0,87	0,88
Profissionais de enfermagem	0,83	0,76							0,91	0,89
Médicos	0,91	0,70		0,67					0,94	0,94
UTIs			0,80	0,88					0,87	0,89
Leitos	0,88	0,85							0,83	0,81
Suporte ventilatório			0,73	0,82					0,93	0,94
Despesa com saúde	0,94	0,90							0,95	0,94
Repasses obrigatórios	0,94	0,92							0,89	0,90
Recursos municipais							0,86		0,79	
Recursos estaduais							0,80		0,80	
Recursos federais								0,79		0,70
Auxílio emergencial (%)		-0,66							0,60	0,60
Autovalores	7,01	6,98	2,39	1,95	1,72	1,72	1,38	1,05	-	-
Proporção da variância total (%)	0,34	0,31	0,19	0,25	0,14	0,10	0,12	0,08	-	-

Fonte: Elaborada pelos próprios autores a partir dos dados da pesquisa.

Notas: Testes estatísticos dos modelos fatoriais

1º semestre – Teste de Cronbach: 0,89; Kaiser-Meyer-Olkin (KMO): 0,77; Teste de Bartlett: 1453,81 (valor-p = 0,0000).

2º semestre – Teste de Cronbach: 0,88; Kaiser-Meyer-Olkin (KMO): 0,82; Teste de Bartlett: 1354,23 (valor-p = 0,0000).

Comunalidades inferiores a 0,50 e cargas fatoriais menores que 0,60 foram omitidas da tabela.

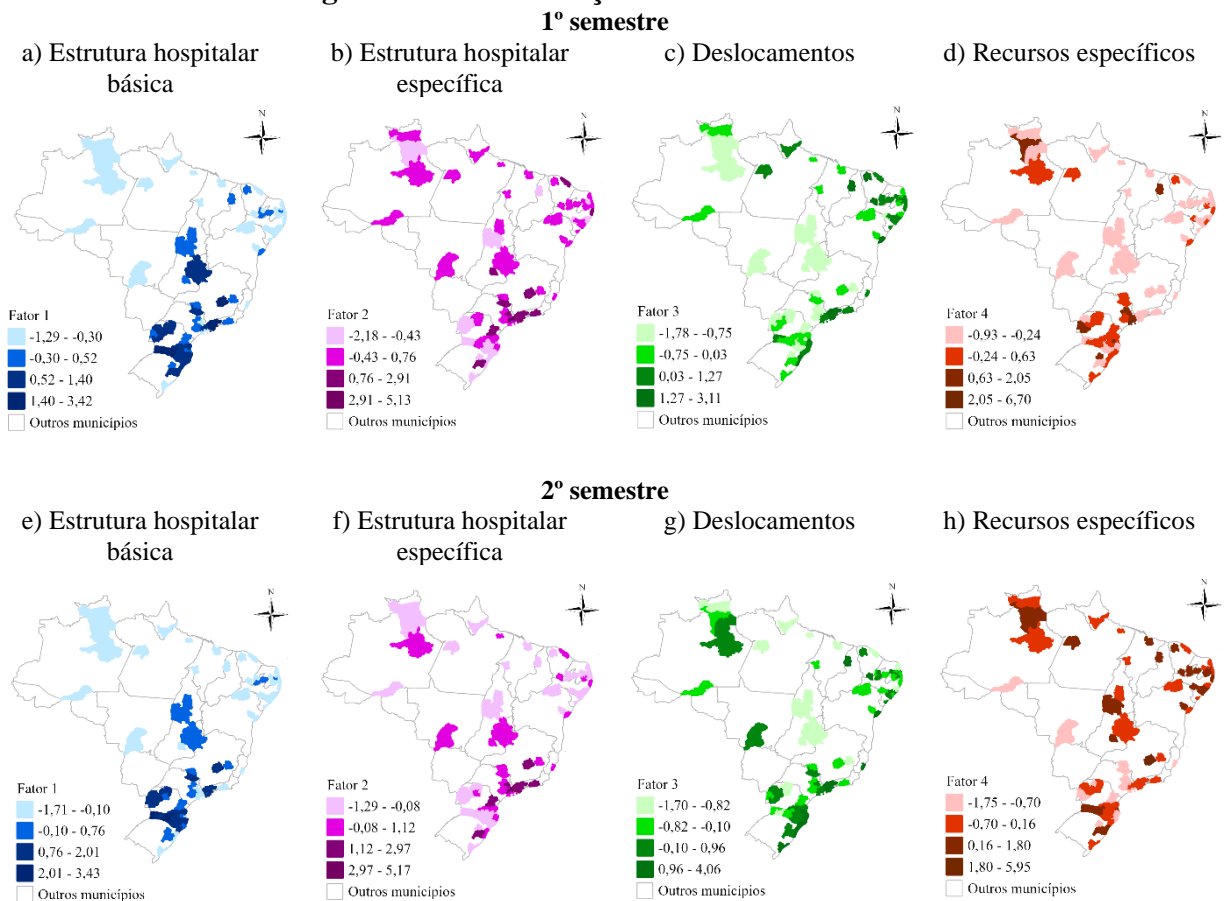
O fator 3 é positivamente relacionado às variáveis de mobilidade varejo e lazer, mercados e farmácias e locais de trabalho no primeiro semestre e mobilidade varejo e lazer e locais de trabalho no segundo, representando os deslocamentos nas RMs. Sendo assim, esse fator será nomeado de deslocamentos (D). Por fim, a Tabela 2 mostra que o fator 4 relaciona-se positivamente com as variáveis recursos municipais e estaduais destinados ao combate à COVID-19 no primeiro semestre e recursos federais destinados ao combate à COVID-19 no segundo semestre. Por representar as diferentes fontes de financiamento para combater a COVID-19, ele será chamado de recursos específicos (R). Esses quatro fatores, como já mencionado na introdução, podem influenciar de maneira direta o progresso da pandemia, portanto, é fundamental conhecer de que forma eles estão dispostos nas RMs.

A Figura 2 ilustra a partir dos fatores B, E, D e R, as RMs em cada um dos semestres de 2020. Quanto mais forte a tonalidade das cores, maiores os valores desses fatores. Em ambos os semestres, as RMs com as maiores estruturas hospitalares básicas estavam

localizadas nas regiões Sudeste e Sul, enquanto as RMs das regiões Norte e Nordeste apresentaram as menores, o que corrobora com a caracterização de estrutura hospitalar feita por Portela et al. (2020). Essa estrutura pouco se modificou de um semestre para outro.

Ao se analisar a estrutura hospitalar específica, verifica-se que as RMs com as melhores estruturas, em ambos os semestres, se localizam principalmente na região Sudeste, enquanto, a grande parte das RMs localizadas nas regiões Nordeste, Norte e Centro-Oeste apresentaram as mais baixas estruturas hospitalares específicas. Esses resultados se aproximam daqueles encontrados por Moreira (2020), em especial, no que diz respeito às regiões Nordeste, o autor destaca que essa região apresenta estrutura hospitalar específica para o combate à COVID-19 aquém do esperado. Por fim, de um semestre para outro o nível dessa estrutura caiu, principalmente, nas RMs das regiões Nordeste e Norte.

**Figura 2: Caracterização das RMs brasileiras**



Fonte: Elaborado pelos próprios autores com base nos dados da pesquisa.

Ainda na Figura 2 é possível verificar que, no que diz respeito aos deslocamentos, as RMs localizadas na região Centro-Oeste foram as que apresentaram os menores níveis de deslocamento em ambos os semestres. De maneira geral, no primeiro semestre de 2020, com

exceção das RMs da região Nordeste, os níveis de deslocamento nas RMs brasileiras como um todo foram menores do que no segundo semestre. Esse aumento nos níveis de deslocamento de um semestre para outro podem ter comprometido o enfrentamento à pandemia, já que para controlá-la é preciso reduzir a transmissão do vírus, e o distanciamento social é efetivo nisto (Aquino; et al.; 2020; Noronha; et al, 2020). Em relação aos recursos específicos para enfrentamento da COVID-19, as RMs do Sul, Sudeste e Norte receberam os maiores aportes no primeiro semestre; no segundo semestre essa distribuição parece ter sido mais equânime entre as RMs de todas as macrorregiões do país, com destaque para as RMs do Nordeste e Norte do país. O fato é que os investimentos em saúde, em especial, no que tange à pandemia precisam serem maiores para que o sistema de saúde possa lidar melhor com a COVID-19 (Aquino; et al., 2020; Maciel; et al., 2020).

As quatro variáveis latentes, encontrados na AF, assim como a mortalidade por COVID-19, são transformados em conjuntos *fuzzy* na fsQCA, o que possibilita averiguar o grau de pertencimento (alto ou baixo) das RMs. De maneira mais precisa, tem-se quatro conjuntos de condições causais - B (estrutura hospitalar básica), E (estrutura hospitalar específica), D (deslocamentos) e R (recursos específicos) - e um conjunto resultado, que é a mortalidade por COVID-19 das RMs, representado pela letra M. Nas análises da fsQCA, as letras maiúsculas e minúsculas devem ser interpretadas como sendo alta e baixa probabilidade condicional das RMs em cada conjunto, respectivamente. Os *scores* da fsQCA são utilizados para verificar se a relação entre as condições causais (B, E, D e R) possuem relação de suficiência com a variável de resultado (M). Os resultados da fsQCA estão na Tabela 3.

**Tabela 3: Matrizes de suficiência e necessidade (1º e 2º semestres)**

	1º semestre					2º semestre					
	M	B	E	D	R	M	B	E	D	R	
M	1,00	0,67	0,76	0,68	0,69	M	1,00	0,85	0,74	0,67	0,62
B	0,67	1,00	0,63	0,62	0,72	B	0,85	1,00	0,67	0,65	0,61
E	0,76	0,63	1,00	0,66	0,64	E	0,74	0,67	1,00	0,63	0,60
D	0,72	0,67	0,70	1,00	0,68	D	0,74	0,73	0,70	1,00	0,71
R	0,69	0,72	0,64	0,63	1,00	R	0,62	0,61	0,60	0,64	1,00

Fonte: Elaborada pelos próprios autores a partir dos dados da pesquisa.

A Tabela 3 mostra as matrizes de suficiência e necessidade para os dois semestres analisados. Elas mostram qual conjunto de condições causais mostra-se mais suscetível a prever o resultado (Longest e Vaisey, 2008). Para o primeiro semestre, alto E é o conjunto isolado mais suficiente para prever M (consistência = 0,76), seguido de D (consistência = 0,72), enquanto, no segundo semestre, é o conjunto alto B (consistência = 0,85), seguido, igualmente, por alto E e alto D (consistência = 0,74). Em ambos os semestres, alto R é o

menos suficiente (consistência = 0,69 e 0,62, respectivamente) para prever M.

As análises da Tabela 3 são preliminares, apenas. Para decidir, probabilisticamente, quais condições causais são suficientes para levar à mortalidade por COVID-19, é preciso estabelecer um método. Para isso, Ragin (2000; 2006) recomenda determinar um ponto de corte, neste caso 0,80, e codificar todas as configurações que forem maiores que 0,80, como suficientes para alto e baixo resultado. A Tabela 4 apresenta essas configurações. Observa-se que no primeiro semestre, há três configurações lógicas que apresentam uma relação de suficiência com alta mortalidade por COVID-19, em 11 RMs (13,4% do total), de acordo com a seguinte expressão primitiva:

$$\text{bEdR} + \text{bEDR} + \text{BEDR} \rightarrow \text{M} \quad (3)$$

Já no segundo semestre, são cinco configurações lógicas que apresentam uma relação de suficiência com alta mortalidade por COVID-19, em 29 RMs (35,4% do total):

$$\text{BeDr} + \text{BEdr} + \text{BEdR} + \text{BEDr} + \text{BEDR} \rightarrow \text{M} \quad (4)$$

Ainda na Tabela 4, observa-se que, no primeiro semestre, apenas uma configuração, em 9 RMs (11% do total), apresenta relação de suficiência com baixa mortalidade por COVID-19, conforme a expressão primitiva a seguir:

$$\text{BedR} \rightarrow \text{m} \quad (5)$$

Enquanto no segundo semestre, quatro configurações, em 21 RMs (25,6% do total), apresentaram relação de suficiência com baixa mortalidade por COVID-19:

$$\text{bedr} + \text{bedR} + \text{beDr} + \text{beDR} \rightarrow \text{m} \quad (6)$$

**Tabela 4: Configurações lógicas e suficientes**

Semestre	Classificação das taxas de mortalidade de COVID-19	Configurações	Consistência		Teste F	Valor-p	Número de RMs
			M	1-M			
1º semestre	Alta	bEdR	0,90	0,75	4,96	0,029	4
		bEDR	0,91	0,73	6,77	0,011	6
		BEDR	0,91	0,75	4,62	0,035	1
	Baixa	BedR	0,77	0,91	4,45	0,038	9
2º semestre	Alta	BeDr	0,92	0,79	4,02	0,048	8
		BEdr	0,93	0,71	13,73	0,000	8
		BEdR	0,93	0,76	6,43	0,013	4
		BEDr	0,95	0,76	10,15	0,002	6
		BEDR	0,93	0,79	4,65	0,034	3
	Baixa	bedr	0,70	0,97	22,06	0,000	6
		bedR	0,64	0,97	31,08	0,000	7
		beDr	0,76	0,97	17,62	0,000	1
		beDR	0,71	0,97	21,55	0,000	7

Fonte: Elaborado pelos próprios autores com base nos dados da pesquisa.

Nota: Todas as configurações são significativamente maiores que 0,80, a um nível de significância de 5%.

A coluna “M” avalia a consistência da configuração com alta M e a coluna “1 – M” avalia os casos sem alta M.

A coluna “Número de RMs” é a quantidade de casos com escores maiores que 0,50.

Como há muitas configurações, Ragin (1987) propõe que elas sejam reduzidas, via

algoritmo de Quine-McCluskey (1956). A Tabela 5 apresenta as configurações lógicas reduzidas, bem como as medidas de ajuste da fsQCA. Como a medida de consistência para baixa mortalidade no segundo semestre é inferior a 0,90 (Ragin, 2008; Schneider e Wageman, 2012), ela não é considerada como uma relação suficiente. Já para alta mortalidade, as medidas de consistência apontam para condições suficientes nos dois semestres de 2020.

No primeiro semestre, RMs com baixa estrutura hospitalar básica (b), alta estrutura hospitalar específica (E) e alto recursos específicos (R), assim como, RMs com alta estrutura hospitalar específica (E), alto deslocamento (D) e alto recursos específicos (R) associam-se à alta mortalidade por COVID-19 (M), conforme a seguinte expressão reduzida:

$$bER + EDR \rightarrow M \quad (7)$$

No segundo semestre, RMs com alta estrutura hospitalar básica (B), alto deslocamento (D) e com baixo recursos específicos (r) estão associadas à alta mortalidade por COVID-19 (M), do mesmo modo que RMs com alta estrutura hospitalar básica (B) e alta estrutura hospitalar específica (E), originando a expressão reduzida seguir:

$$BDr + BE \rightarrow M \quad (8)$$

A tabela 5 mostra que, nos dois semestres, todas as condições causais são necessárias, mas não suficientes, já que, isoladas, não levam à alta mortalidade por COVID-19. As coberturas brutas das soluções indicam que as configurações causais múltiplas se sobrepõem em 49% e 72% no conjunto das altas mortalidade por COVID-19, no primeiro e no segundo semestre, respectivamente. A consistência da solução, por sua vez, revela que 90% e 92% dos casos satisfazem a condição de suficiência no primeiro e no segundo semestre, nesta ordem, em relação à alta mortalidade.

**Tabela 5: Configurações lógicas reduzidas e principais medidas de ajuste**

Semestre	Classificação das taxas de mortalidade de COVID-19	Configurações	Coberturas		Consistência
			Bruta	Única	
1º semestre	Alta	bER	0,43	0,08	0,91
		EDR	0,41	0,06	0,90
		Cobertura total: 0,49		Consistência da solução: 0,90	
2º semestre	Alta	BDr	0,48	0,1	0,93
		BE	0,62	0,24	0,93
		Cobertura total: 0,72		Consistência da solução: 0,92	
	Baixa	bed	0,35	0,35	0,62
		Cobertura total: 0,35		Consistência da solução: 0,62	

Fonte: Elaborado pelos próprios autores com base nos dados da pesquisa.

Por fim, a Tabela 5 mostra que, pelo menos, uma das configurações tanto do primeiro (EDR) quanto do segundo semestre (BDr) que se associa à alta mortalidade por COVID-19 tem a condição causal alto deslocamento (D) como sendo uma condição necessária. Isto indica que o deslocamento é um importante fator que se relaciona com à alta mortalidade por

COVID-19 em ambos os períodos de análise. No primeiro semestre, baixa estrutura hospitalar básica (b) também se mostrou como condição necessária para alta mortalidade por COVID-19 (M) em uma das configurações (bER). É interessante observar que no segundo semestre a combinação alta estrutura hospitalar básica (B) e alta estrutura hospitalar específica (E) se relacionam com alta M. Isto pode ser reflexo de uma maior procura por atendimento hospitalar adequado por infectados pelo novo coronavírus ou ainda de transferência de casos mais graves para RMs com melhor estrutura hospitalar.

#### **4 Considerações finais**

Este estudo buscou identificar como e quais são os fatores que se relacionam com a mortalidade por COVID-19 nas regiões metropolitanas brasileiras nos dois semestres de 2020. As análises até então realizadas buscam identificar os determinantes relacionados à mortalidade por COVID-19 com base no comportamento médio de um conjunto de variáveis. Essas análises, contudo, não são capazes de explicar como essas variáveis se comportam em cada localidade. Isto pode dificultar a eficácia de medidas que visem combater a pandemia. Neste sentido, uma análise mais desagregada pode trazer importantes contribuições para adoção de medidas. Assim sendo, este estudo, primeiro, analisou, por meio da AF, as interdependências entre variáveis-chave no enfrentamento à pandemia, que dizem respeito à estrutura hospitalar, ao financiamento da saúde, aos deslocamentos e aos recursos específicos para o combate da COVID-19 e são referentes às RMs brasileiras. Em seguida, para entender como interações específicas entre estes fatores podem se relacionar com valores altos e baixos de mortalidade por COVID-19, realizou-se a fsQCA.

Os resultados da AF mostraram que o conjunto de variáveis relacionadas à estrutura hospitalar básica (quantidade de pessoal da enfermagem, de médicos, de leitos de internação e despesas com saúde e transferências obrigatórias) representa a principal dimensão das RMs brasileiras em ambos os semestres, seguido da estrutura hospitalar específica, dos deslocamentos e dos recursos para enfrentamento da pandemia. Quando se observa os resultados da fsQCA depois do processo de minimização, verifica-se que, no primeiro semestre, alta mortalidade por COVID-19 nas RMs brasileiras são relacionadas, de maneira simultânea, com altas estruturas hospitalares específicas, altos recursos para enfrentamento da pandemia e baixas estruturas hospitalares básicas ou altos deslocamentos, cobrindo 41% das RMs. No segundo semestre, essa alta mortalidade está associada, ao mesmo tempo, a altas estruturas hospitalares específicas e básicas ou altos deslocamentos e baixos recursos para



enfrentamento da pandemia, cobrindo 72% das RMs. Em ambos os semestres, essas configurações lógicas atingem ou superam 90% de consistência.

Conforme era esperado, as configurações lógicas entre os fatores das RMs e a mortalidade por COVID-19 foram diferentes nos dois semestres. Além disso, observou-se que, em ambos os semestres, o alto deslocamento é uma condição necessária para alta mortalidade por COVID-19 nas RMs, corroborando com o que diz a literatura (Aquino; et al., 2020; Cohen; Kupfershmidt, 2020; Ferguson; et al., 2020; Noronha; et al., 2020). Contudo, a alta estrutura hospitalar específica, em ambos os semestres, e alta estrutura hospitalar básica, no segundo semestre, mostraram-se como sendo condição necessária para alta mortalidade pela doença, o que contraria os resultados de muitos estudos (Maciel; et al., 2020; Moreira, 2020; Noronha; et al., 2020; Portela; et al., 2020).

Esses resultados podem estar revelando duas situações principais. A primeira é que a velocidade de disseminação do novo coronavírus é superior a velocidade de reação do sistema de saúde das RMs em ofertar, a tempo de atender a demanda por atendimento especializado, uma boa estrutura hospitalar para tratamento da COVID-19. A segunda é que RMs com melhor estrutura para atendimento específico da doença podem estar recebendo pacientes, já em estado grave, de RMs com baixa estrutura hospitalar específica. Essas situações podem não estarem sendo captadas nas análises econométricas tradicionais citadas neste estudo, pois elas avaliam o comportamento médio das variáveis.

Em relação aos recursos específicos para enfrentamento da COVID-19, no primeiro semestre alto recursos era uma condição necessária para mortalidade pela doença, enquanto no segundo semestre baixo recursos se associou a essa mortalidade. Isto pode estar indicando que há diferenças entre a velocidade de propagação do novo coronavírus (alta) e a velocidade de destinação dos recursos (baixa) para RMs, especialmente, no primeiro semestre. Já no segundo semestre, o baixo recursos pode estar apontando para a necessidade de mais recursos específicos para enfrentamento da COVID-19 nas RMs.

Ao analisar os resultados dos dois semestres, este estudo sugere que, no início da pandemia, as RMs com melhor estrutura básica de saúde tinham uma maior capacidade de reação à doença. E que no segundo semestre, a velocidade do agravamento da pandemia e o possível atendimento de pacientes, em estado grave, vindo de RMs com baixa estrutura hospitalar sobrecarregaram as RMs com altas estruturas hospitalares básica e específica. Desse modo, RMs devem reforçar sua estrutura específica de atendimento à COVID-19, de modo a suprir sua demanda local, não sobrecarregando outras RMs com melhores estruturas, e, assim, acompanhar, na medida do possível a velocidade de disseminação do vírus. Além

disso, os recursos para enfrentamento da pandemia devem ser direcionados às RMs de maneira mais rápida e mais bem distribuída.

Políticas públicas que visem conter o avanço da pandemia nas RMs devem focar em ações horizontalizadas e combinadas que reduzam a propagação do vírus, melhorem as estruturas hospitalares básicas e específicas e ampliem os recursos específicos para combate da COVID-19. Este artigo ao caracterizar as RMs e estabelecer configurações entre essas características pode fornecer as informações necessárias para que essas políticas sejam mais eficazes e atendam de maneira mais rápida às necessidades específicas de cada RM.

Por fim, cabe ressaltar que uma das limitações deste artigo é que ele não leva em conta as características socioeconômicas e de saneamento básico das RMs que podem impactar no desfecho da COVID-19 ao interagirem com as demais variáveis utilizadas neste estudo. A justificativa para não incluir essas variáveis se dá pelo fato de muitas delas só serem disponibilizadas pelo Censo e, portanto, estarem desatualizadas, datando de 2010, quando ocorreu o último levantamento censitário. De lá para cá, é possível que estas variáveis socioeconômicas e de saneamento tenham assumido outros valores. Portanto, usá-las sem que estejam atualizadas pode, na verdade, comprometer a análise que se fez neste estudo.

## Referências

- AFIFI, A.; MAY, S.; CLARK, V. A. **Practical multivariate analysis**. 5ªEd. CRC Press, 2011.
- AQUINO, E. M. L; et al. Medidas de distanciamento social no controle da pandemia de COVID-19: potenciais impactos e desafios no Brasil. **Ciência & Saúde Coletiva**, v. 25, p. 2423-2446, 2020.
- BARTLETT, M. S. **The statistical conception of mental factors**. **British Journal of Psychology**, v. 28, p. 97-104, 1937.
- COHEN, J; KUPFERSCHMIDT, K. Countries test tactics in ‘war’ against COVID-19. **Science**, 367(6484):1287–8, 2020.
- DATASUS. **CNES – Estabelecimentos por nível de atenção – Brasil**. Disponível em: < <http://tabnet.datasus.gov.br/cgi/tabcgi.exe?cnes/cnv/atencbr.def> > Acesso em: mai.2021.
- DATASUS. **CNES - Recursos físicos - equipamentos - Brasil**. Disponível em: < <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/equipobr.def>>. Acesso em: mai. 2021.
- DATASUS. **CNES - Recursos físicos - hospitalar - leitos complementares - Brasil**. Disponível em: < <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/leiutibr.def> >. Acesso em: mai. 2021.
- DATASUS. **CNES – Recursos Físicos – Hospitalar – Leitos e internação**. Disponível em: < <http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/leiintpi.def>>. Acesso em: mai.2021.

- DATASUS. **CNES - Recursos humanos - profissionais - indivíduos - segundo cbo 2002 - Brasil**. Disponível em: <  
<http://tabnet.datasus.gov.br/cgi/tabcgi.exe?cnes/cnv/prid02br.def>>. Acesso em: mai.2021.
- FERGUSON, N; ET AL. **Report 9: Impact of non-pharmaceutical interventions (NPIs) to reduce COVID19 mortality and healthcare demand**. 2020. Disponível em:  
<<http://spiral.imperial.ac.uk/handle/10044/1/77482>>. Acesso em: mai. 2021.
- FERREIRA, S. F. **Transgressão, norma social e crime: o papel da dissuasão social nas áreas mínimas comparáveis no Brasil (1991–2010)**. Universidade Federal de Juiz de Fora (2017). Disponível em:  
<[http://www.ufjf.br/poseconomia/files/2017/07/TESE\\_Sandro\\_de\\_Freitas\\_Ferreira\\_2017.pdf](http://www.ufjf.br/poseconomia/files/2017/07/TESE_Sandro_de_Freitas_Ferreira_2017.pdf)>. Acesso em: mai. 2021.
- GANTER, A.; HECKER, A. Configurational paths to organizational innovation: qualitative comparative analyses of antecedents and contingencies. **Journal of Business Research**, v. 67, n. 6, p. 1285–1292, 1 jun. 2014.
- GOOGLE. **COVID-19: Relatórios de mobilidade da comunidade**. Disponível em: <  
<https://www.google.com/covid19/mobility/?hl=pt>>. Acesso em: mai.2021.
- GROFMAN, B; SCHNEIDER, C. Q. **An introduction to crisp set QCA, with a comparison to binary logistic regression**. 2009.
- HAIR, J. G.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E. **Multivariate data analysis**. Prentice Hall: New Jersey, 2009.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Estimativas da População**, 2018. Disponível em:  
<<https://www.ibge.gov.br/estatisticas/sociais/populacao/9103-estimativas-de-populacao.html?=&t=o-que-e>>. Acesso em: mai. 2021.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Regiões Metropolitanas, Aglomerações Urbanas e Regiões Integradas de Desenvolvimento**, 2018. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/divisao-regional/18354-regioes-metropolitanas-aglomeracoes-urbanas-e-regioes-integradas-de-desenvolvimento.html?=&t=o-que-e>>. Acesso em: mai. 2021.
- JENNRICH, R. I. An asymptotic chi<sup>2</sup> test for the equality of two correlation matrices. **Journal of the American Statistical Association** v. 65, n. 330, p. 904-912, 1970.
- JOHNSON, R. A., WICHERN, D. W. **Applied Multivariate Statistical Analysis**. New Jersey: Pearson Prentice Hall, 6th edition, 2007.
- LONGEST, K. C.; VAISEY, S. Fuzzy: a program for performing qualitative comparative analysis (QCA) in stata. **The Stata Journal**, v. 8, n. 1, p. 79-104, 2008.
- MACIEL, E. L; et al. Fatores associados ao óbito hospitalar por COVID-19 no Espírito Santo, 2020. **Epidemiologia e Serviços de Saúde**, v. 29, p. e2020413, 2020.
- MCCLUSKEY, Edward J. Minimization of Boolean functions. **The Bell System Technical Journal**, v. 35, n. 6, p. 1417-1444, 1956.
- MINISTÉRIO DA CIDADANIA. **Auxílio emergencial 2020**. Disponível em: <  
<https://aplicacoes.mds.gov.br/sagi/vis/data3/index.php?g=2&ag=m>>. Acesso em: mai.2021.
- MINISTÉRIO DA SAÚDE. **Coronavírus Brasil**. Disponível em: <  
<https://covid.saude.gov.br>>. Acesso em: mai.2021.
- MINISTÉRIO DA SAÚDE. **Recursos e gastos para enfrentamento à COVID (SIOPS)**. Disponível em: <  
[https://qsprod.saude.gov.br/extensions/DEMÁS\\_C19SIOPS/DEMÁS\\_C19SIOPS.html](https://qsprod.saude.gov.br/extensions/DEMÁS_C19SIOPS/DEMÁS_C19SIOPS.html)>. Acesso em: mai.2021.

- MINISTÉRIO DA SAÚDE. **SRAG 2020 - Banco de Dados de Síndrome Respiratória Aguda Grave - incluindo dados da COVID-19**. Disponível em: <<https://opendatasus.saude.gov.br/dataset/bd-srag-2020>>. Acesso em: mai.2021.
- MORAES, R. F; SILVA, L. L. S; TOSCANO, C. M. Covid-19 e medidas de distanciamento social no Brasil: análise comparativa dos planos estaduais de flexibilização. **Nota Técnica n 25 (Dinte): Covid-19 e medidas de distanciamento social no Brasil: análise comparativa dos planos estaduais de flexibilização**. 2020. Disponível em: <<http://repositorio.ipea.gov.br/handle/11058/10165>>. Acesso em: mai. 2021.
- MOREIRA, R. S. COVID-19: unidades de terapia intensiva, ventiladores mecânicos e perfis latentes de mortalidade associados à letalidade no Brasil. **Cadernos de Saúde Pública**, v. 36, p. e00080020, 2020.
- NORONHA, K. V. M. S; et al. 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, p. e00115320, 2020.
- PORTELA, M. C; et al. Limites e possibilidades dos municípios brasileiros para o enfrentamento dos casos graves de COVID-19. **Nota Técnica**, v. 1, 2020.
- RAGIN, C. C. **Fuzzy-Set Social Science**. Chicago: University of Chicago Press. 2000.
- RAGIN, C. C. Set relations in social research: Evaluating their consistency and coverage. **Political Analysis**, SPM-PMSAPSA, v. 14, n. 3, p. 291–310, 2006.
- RAGIN, C. C. **The comparative method: moving beyond qualitative and quantitative strategies**. Berkeley: University of California Press, 1987.
- RAGIN, C. C. **User's guide to fuzzy-set/qualitative comparative analysis**. Tucson: University of Arizona, 2008.
- RAGIN, C. C.; DAVEY, S. **fs/QCA, version 2.5** (computer program). Tucson: Department of Sociology, University of Arizona, 2009.
- RIHOUX, B. Qualitative comparative analysis (QCA) and related systematic comparative methods: Recent advances and remaining challenges for social science research. **International Sociology**, v. 21, n. 5, p. 679-706, 2006.
- SCHNEIDER, C. Q.; WAGEMANN, C. **Set-theoretic methods for the social sciences: A guide to qualitative comparative analysis**. Cambridge: Cambridge University Press, 2012.
- SCHNEIDER, C. Q.; WAGEMANN, C. Standards of good practice in qualitative comparative analysis (QCA) and fuzzy-set. **Comparative Sociology**, v. 9, p. 1-22, 2010.
- SPEARMAN, C. (1961). "General Intelligence" Objectively Determined and Measured. In J. J. Jenkins & D. G. Paterson (Eds.), **Studies in individual differences: The search for intelligence** (pp. 59–73). Appleton-Century-Crofts.
- TESOURO NACIONAL TRANSPARENTE. **Transferências constitucionais para municípios**. Disponível em:<<http://www.tesourotransparente.gov.br/ckan/dataset/transferencias-obrigatorias-da-uniao>>. Acesso em: mai.2021.
- WORLD HEALTH ORGANIZATION. **Coronavirus Disease (COVID-19)-Situation Reports**. Disponível em: <<https://www.who.int/emergencies/diseases/novel-coronavirus-2019/situation-report>>. Acesso em: mai.2021.
- WORLD HEALTH ORGANIZATION. **Timeline: WHO's COVID-19 response**. Disponível em: <<https://www.who.int/emergencies/diseases/novel-coronavirus-2019/interactive-timeline>>. Acesso em: mai.2021.