

Análise espacial das condições de enfrentamento à COVID-19: uma proposta de Índice da Infraestrutura da Saúde do Brasil

Spatial analysis of Brazil's COVID-19 response capacity: a proposal for a Healthcare Infrastructure Index

Évilly Carine Dias Bezerra (<https://orcid.org/0000-0002-9876-6260>)¹
Priscila Soares dos Santos (<https://orcid.org/0000-0002-7313-3651>)¹
Fernanda Cigainski Lisbinski (<https://orcid.org/0000-0001-9131-5996>)¹
Lázaro Cezar Dias (<https://orcid.org/0000-0003-1051-6054>)¹

Abstract *One of the concerns linked to the COVID-19 pandemic is the capacity of health systems to respond to the demand for care for people with the disease. The objective of this study was to create a COVID-19 response Healthcare Infrastructure Index (HII), calculate the index for each state in Brazil, and determine its spatial distribution within and across regions. The HII was constructed using principal component factor analysis. The adequacy of the statistical model was tested using the Kaiser-Meyer-Olkin test and Bartlett's test of sphericity. The spatial distribution of the HII was analyzed using exploratory spatial data analysis. The data were obtained from DATASUS, the Federal Nursing Council, Ministry of Health, Government Procurement Portal, and the Transparency Portal. The nine states in the country's North and Northeast regions showed the lowest indices, while the five states from the Southeast and South regions showed the highest indices. Low-low clusters were observed in Amazonas and Pará and high-high clusters were found in Minas Gerais, Rio de Janeiro, São Paulo, and Paraná.*

Key words *COVID-19, Health system infrastructure, Brazil*

Resumo *Uma das preocupações ligadas à pandemia da COVID-19 se refere à capacidade da estrutura do sistema de saúde suportar a demanda por atendimento e tratamento de pessoas acometidas por esta doença. Diante disso, o objetivo deste estudo consiste em criar e mapear o Índice de Infraestrutura de Saúde (IIS) das Unidades da Federação (UFs) brasileiras, bem como verificar a sua distribuição espacial. Para isso, foi aplicada a metodologia de Análise Fatorial por Componentes Principais. Aplicou-se os testes de Bartlett e Kaiser-Meyer-Olkin para verificação da sua adequabilidade. Em seguida procedeu-se a Análise Exploratória de Dados Espaciais. Os dados foram coletados no DATASUS, COFEN, Ministério da Saúde, Portal de Compras do Governo e Portal da Transparência. Quanto aos resultados, o índice revelou que nove estados do Norte e Nordeste registraram os menores índices e cinco estados do Sudeste e Sul apresentaram os maiores índices. Foi registrado um cluster baixo-baixo nos estados do Amazonas e Pará e um Cluster alto-alto em Minas Gerais, Rio de Janeiro, São Paulo e Paraná.*

Palavras-chave *COVID-19, Infraestrutura do sistema de saúde, Brasil*

¹ Programa de Pós-Graduação em Economia e Desenvolvimento, Universidade Federal de Santa Maria. Av. Roraima 1000, Cidade Universitária. 97105-900 Santa Maria RS Brasil. evillycarine@hotmail.com

Introdução

Os coronavírus são um grupo de vírus de fácil contaminação e comuns aos humanos, outros mamíferos e aves, causando doenças respiratórias, hepáticas, entéricas e neurológicas. Seis espécies de coronavírus são conhecidas por causarem doenças em humanos. Dentre estas, quatro – 229E, OC43, NL63 e HKU1 – são prevalentes e normalmente causam sintomas de resfriado. Os outros dois tipos são de origem zoonótica, associados a doenças muitas vezes fatais. Trata-se do coronavírus da síndrome respiratória aguda grave (SARS-CoV) e o respiratório do Oriente Médio – coronavírus da síndrome (MERS-CoV)¹. A SARS apresenta sintomas de origem infecciosa e de rápida progressão².

Em dezembro de 2019, várias unidades de saúde chinesas relataram a presença de muitos pacientes com pneumonia de causa desconhecida. Este surto, estaria associado a exposições em um mercado de frutos do mar em Wuhan, Província de Hubei, China. Em 31 de dezembro de 2019, o Centro Chinês de Controle e Prevenção de Doenças enviou uma equipe para realizar o acompanhamento e investigar, juntamente com as autoridades de saúde da província de Hubei e da cidade de Wuhan, a origem epidemiológica e etiológica dessa doença. Após este período de análise e investigação, descreveu-se a existência de um novo coronavírus em um estágio inicial de surto, os principais sintomas apresentados pelos enfermos foram febre e tosse com desconforto respiratório^{1,3}.

Em 30 de janeiro de 2020, a OMS decretou Emergência na Saúde Pública de Interesse Internacional, decorrente do rápido aumento do número de casos e óbitos na China, provocados pela doença do novo coronavírus de 2019 (COVID-19). A partir de então, várias medidas sanitárias foram sugeridas pela OMS, tais como o isolamento horizontal das regiões afetadas, controle de temperatura em aeroportos e linhas de metrô, uso de câmeras de vigilância que ajudassem a mapear o caminho da contaminação. Ainda assim, a disseminação do vírus prosseguiu e então no dia 11 de março de 2020 decretou-se a pandemia mundial⁴.

Na data de 03 de julho de 2020, foram confirmados no mundo 10.710.005 casos da COVID-19 e 517.877 mortes. Quarenta dias depois, na data de 12 de agosto de 2020, foram confirmados 20.624.316 casos de COVID-19 e 749.421 mortes, um crescimento de cerca de 48% dos casos

de contaminação e 31% do número de mortes. No Brasil, o primeiro caso registrado foi em 26 de fevereiro de 2020 em São Paulo, e o primeiro óbito foi em 17 de março de 2020, neste mesmo estado⁴. Na data de 03 de julho, o Brasil apresentava 1.539.081 casos e 63.174 mortes acumulados. Até a data de 12 de agosto de 2020, foram confirmados 3.180.758 casos de COVID-19 e 104.528 mortes, um crescimento de cerca de 52% dos casos de contaminação e 40% do número de mortes^{5,6}, tornando o Brasil o segundo país com o maior número de casos e mortes confirmadas por COVID-19.

Diversos países, incluindo o Brasil, têm se mobilizado para melhorar o seu sistema de saúde visando a máxima capacidade de atendimento dos pacientes que apresentarem complicações respiratórias decorrentes da contaminação pela COVID-19. De acordo com dados do DATA-SUS⁷, o Brasil possui 6.237 hospitais, destes 5.298 são hospitais de atendimento geral e 939 são especializados. Com relação aos leitos hospitalares, o Brasil possui 446.503 leitos hospitalares, destes 314.725 são leitos do Sistema Único de Saúde (SUS) (70,49%), enquanto que 131.778, (29,51%) são leitos do sistema privado. A Região Sudeste concentra cerca de 40,57%, seguido da Região Nordeste (27,12%), Região Sul (16,54%), Região Centro-oeste (8,5%) e Região Norte (7,27%). No entanto, Silva⁸ afirma que a situação hospitalar brasileira está muito longe de garantir amplo atendimento de qualidade à população, pois existem várias deficiências em sua estrutura, tais como a quantidade de leitos disponíveis, falta de medicamentos, falta de médicos, estrutura física, boa remuneração, vínculos trabalhistas legais e outros.

Conhecer o contingente de recursos e a capacidade de atendimento à saúde disponível à população de qualquer país ou região é de suma importância para o combate da COVID-19, auxiliando com a manutenção da saúde e da vida da população. Este trabalho pode ser importante ferramenta de decisão aos propositores de políticas públicas (*policymakers*), no que se refere a destinação de recurso público para o controle da disseminação e tratamento de pessoas contaminadas pelo vírus.

Sendo assim, o objetivo deste estudo consiste em criar e mapear o Índice de Infraestrutura de Saúde (IIS) das Unidades da Federação (UFs) brasileiras para enfrentamento da COVID-19, verificando a sua distribuição espacial.

Metodologia

A seção está subdividida em três partes, de modo que na primeira subseção estão apresentados os dados utilizados e suas respectivas fontes. Na segunda, há uma breve apresentação do modelo multivariado, seguida dos tratamentos espaciais dos dados.

Dados utilizados

Com a finalidade de construção de um índice que permita a verificação da estrutura de enfrentamento à COVID-19 nas UFs brasileiras, foram utilizadas variáveis capazes de captar informações de diferentes dimensões em nível estadual, a saber: a estrutura física de saúde em cada UF, bem como o número de trabalhadores deste setor, a existência de dispositivos estratégicos para COVID-19 e, ainda, os recursos financeiros que foram destinados à saúde nas diferentes localidades.

As variáveis utilizadas foram coletadas do DATASUS⁹, do Conselho Federal de Enfermagem (COFEN)¹⁰, da Secretaria de Vigilância à Saúde (SVS), do Portal de Compras do Governo¹¹, Ministério da Saúde¹² e do Portal da transparência^{13,14}. No Quadro 1 estão dispostas as dimensões abordadas no estudo, as variáveis manuseadas na pesquisa e suas respectivas fontes.

Após a seleção dos dados, eles foram padronizados, o que segundo Fávero e Belfiore¹⁵ consiste em subtrair pela média e dividir pelo desvio-padrão da variável em estudo.

Nas subseções a seguir são destacados o método estatístico multivariado de análise fatorial por componentes principais para compor o índice. Em seguida, foram adotadas técnicas espaciais para o estudo da distribuição espacial do IIS. Nas subseções a seguir são destacados os procedimentos econométricos utilizados.

O modelo estatístico multivariado

Conforme mencionado, a construção do IIS se deu através da análise fatorial (AF) por componentes principais. Seguindo Fávero e Belfiore¹⁵, esta técnica permite a geração de fatores não correlacionados através de combinações lineares das variáveis iniciais. Conforme Manly¹⁶, a AF torna possível a redução de muitas variáveis em um menor número de fatores, conforme pode ser observado a seguir:

$$X_p = l_{p1}F_1 + l_{p2}F_2 + \dots + l_{pj}F_j + \varepsilon_p \quad (1)$$

Onde X_p indica a p -ésima variável do modelo; l_p representa o produto da raiz quadrada dos autovalores da matriz de correlações pelos autovetores da raiz de correlações; F_j indica os j -ésimos fatores e ε_p indica a p -ésima combinação linear dos componentes principais Z_{j+1} a Z_p .

Desta forma, as 21 variáveis utilizadas no estudo foram submetidas aos procedimentos generalizados da AF e, a partir da geração dos *scores* fatoriais, foi possível construir o índice de interesse. Formalmente, partindo de Mingoti¹⁷, os procedimentos adotados podem ser representados do seguinte modo:

$$IIS_m = \sum_{j=1}^p \left(\frac{\sigma_j^2}{\sum_{j=1}^p \sigma_j^2} F_{jm} \right) \quad (2)$$

Em que IIS_m é o índice de infraestrutura de saúde da m -ésima Unidade de Federação (UF) brasileira, σ^2 é a variância explicada pelo fator j ; p é o número de fatores selecionados; $\sum_{j=1}^p \sigma_j^2$ representa o somatório das variâncias explicadas pelos p fatores extraídos e F_{jm} é o escore fatorial da UF m , do fator j .

Antes de prosseguir, foi preciso validar a adequabilidade da metodologia de análise fatorial no estudo. Para isso, foram realizados os testes estatísticos de Kaiser-Meyer-Olkin (KMO) e o Teste de Esfericidade de Bartlett. Matematicamente, segundo Fávero e Belfiore¹⁵ os testes são representados conforme as próximas duas equações a seguir:

$$KMO = \frac{\sum_{l=1}^k \sum_{c=1}^k \rho_{lc}^2}{\sum_{l=1}^k \sum_{c=1}^k \rho_{lc}^2 + \sum_{l=1}^k \sum_{c=1}^k \varphi_{lc}^2} \quad (3)$$

Onde l são as linhas e c as colunas da matriz de correlações ρ das variáveis do modelo, já φ denota os coeficientes de correlação de ordem superior das variáveis do modelo. Para a aprovação do método no teste KMO, de acordo com literatura especializada, é recomendado que o valor seja superior a 0,6. No entanto, o KMO pode variar entre 0 e 1, de modo que quanto mais próximo de 1, mais adequado é o modelo.

O teste de Bartlett, por sua vez, é dado, de acordo com Fávero e Belfiore¹⁵, como:

$$X_{Bartlett}^2 = [(n-1) - \left(\frac{2k-5}{6} \right)] \ln |D| \quad (4)$$

Onde n representa o tamanho da amostra, k o número de variáveis, $|D|$ representa o módulo do determinante da matriz de correlações ρ das variáveis que compõem o índice. Para a aprova-

Quadro 1. Informações sobre variáveis e fonte de dados da pesquisa para o ano de 2020.

Dimensão	Variável	Data de acesso (2020)	Descrição dos dados	Fonte
Estruturas físicas	X ₁	11/06	Quantidade de estabelecimentos ambulatoriais de alta complexidade*	DATASUS ⁷
	X ₂	11/06	Quantidade de estabelecimentos ambulatoriais de média complexidade*	
	X ₃	11/06	Quantidade de estabelecimentos ambulatoriais básicos*	
	X ₄	11/06	Quantidade de hospitais de alta complexidade*	
	X ₅	11/06	Quantidade de estabelecimentos hospitalares de média complexidade*	
	X ₆	11/06	Número de postos de saúde*	
Trabalhadores da saúde	X ₇	12/06	Número de auxiliares de enfermagem	COFEN ¹⁰
	X ₈	12/06	Número de enfermeiros	
	X ₉	11/06	Número de médicos*	DATASUS ⁷
	X ₁₀	12/06	Número de técnicos em enfermagem	COFEN ¹⁰
Dispositivos estratégicos para Covid-19	X ₁₁	07/06	Quantidade de testes PCR	Ministério da Saúde ¹²
	X ₁₂	07/06	Quantidade de testes rápidos	
	X ₁₃	11/06	Quantidades de leitos de internação não SUS*	DATASUS ⁷
	X ₁₄	11/06	Quantidades de leitos de internação SUS*	
	X ₁₅	11/06	Quantidade de respiradores e/ou ventiladores*	
	X ₁₆	07/06	Número de UTIs adulto não SUS	Ministério da Saúde ¹²
	X ₁₇	07/06	Número de UTIs adulto SUS	
Recursos financeiros	X ₁₈	11/06	Compras nas modalidades pregão, dispensa e inexigibilidade de licitação para enfrentamento da Covid-19 (R\$)	Portal de Compras ¹¹
	X ₁₉	10/06	Distribuição das despesas com saúde (R\$)	Portal da transparência ¹³
	X ₂₀	10/06	Valor transferido diretamente à UF (R\$)	Portal da transparência ¹⁴
	X ₂₁	10/06	Valor transferido diretamente aos municípios (R\$)	

*Dados obtidos no Cadastro Nacional de Estabelecimentos de Saúde (CNES) foram referentes a abril de 2020, disponíveis no DATASUS.

Fonte: Elaboração própria.

ção da AF segundo esse teste, é preciso rejeitar a hipótese nula de que a matriz de correlação é uma matriz identidade.

Como frequentemente os índices são apresentados com valores dentro de um intervalo que varia de 0 a 1, após a confirmação da adequabilidade do método e da geração dos fatores, os resultados do índice podem ser padronizados, conforme é demonstrado através da seguinte formalização:

$$IIS_m = \frac{IIS_m - IIS_{\min}}{IIS_{\max} - IIS_{\min}} \quad (5)$$

Em que IIS_{\min} e IIS_{\max} são os índices mínimo e máximo calculados, respectivamente. Desta for-

ma, após a padronização, o valor máximo possível do índice passa a ser 1, e o menor, 0. Logo, quanto mais próximo de 1, maior a infraestrutura da saúde para o enfrentamento à COVID-19 da UF em questão. Para a geração dos fatores, foi utilizada a rotação fatorial ortogonal *varimax* que, de acordo com Hair Jr. et al.¹⁸, torna possível uma visualização mais clara de como as variáveis estão associadas e o quanto esta característica reflete de forma positiva ou negativa em cada fator.

Após a rotação ortogonal, aprovação nos testes estatísticos e a construção do índice, é possível observar a distribuição espacial do fenômeno em questão, bem como a verificação da existência de possíveis *clusters*, através da AEDE. Assim, segue para o tratamento espacial dos dados.

Procedimentos de análise espacial

Com a finalidade de verificar como se dá a distribuição no espaço do índice de Infraestrutura de saúde entre as UFs brasileiras, foram utilizadas as estatísticas I de Moran global e local. Consoante Almeida¹⁹, o I de Moran global indica se há ou não similaridade entre as variáveis em análise e o espaço. Caso o resultado dessa estatística seja positivo, então essa similaridade existe de modo que localidades com elevada incidência de uma determinada variável e/ou fenômeno, são também circuncidadas por locais com alta incidência. No caso de um resultado negativo, essa relação se comporta de forma inversamente proporcional. Ou seja, localidades com altos valores são rodeadas por locais com baixos valores. Já o I de Moran Local é utilizado para verificar a existência de clusters espaciais de um dado fenômeno.

O I de Moran Global na sua fórmula matricial, segundo Almeida¹⁹ é dado por:

$$I = \frac{n}{S_o} \frac{z'Wz}{z'z} \quad (6)$$

De modo que n representa o número de regiões que são indexadas por i e j ; z representa as variáveis padronizadas; W representa a matriz de ponderação espacial; S_o é igual a $\sum_i \sum_j w_{ij}$, indicando que as entradas da matriz de pesos espaciais w serão somados; Wz denota a média das variáveis padronizadas nos vizinhos. Para dar prosseguimento à análise espacial, é preciso que o resultado dessa estatística aponte para a rejeição da hipótese nula de aleatoriedade espacial.

A estatística I de Moran Local foi utilizada para verificar a existência de formação de clusters espaciais do IEs_m nas diferentes UFs do Brasil, e é dada por Anselin²⁰ da seguinte forma:

$$I = \sum_i I_i / [S_o (\sum_i z_i^2 / n)] \quad (7)$$

Caso o índice esteja distribuído espacialmente de modo a formar *clusters*, então o resultado dessa estatística aponta para a rejeição da hipótese nula de não existência de *cluster* espacial. Para Almeida¹⁹ o Índice de Moran Local (LISA), tem como condição que a soma dos indicadores locais equivale ao global, com a devida proporção.

Resultados

A adequada aplicabilidade da análise fatorial por componentes principais foi confirmada pelos resultados dos testes KMO (0,7459) e de Bartlett (1.715,09). Desta forma, foi possível prosseguir para a estimativa dos fatores comuns. Através do método de rotação *varimax*, que maximiza a variância do fator, foi possível obter os fatores que compuseram o IIS_m. Ao todo, foram extraídos três fatores e o critério utilizado para essa seleção foi a presença de autovalores maiores do que 1, conforme pode ser observado na Tabela 1.

Os três fatores extraídos, juntos, explicam cerca de 95,42% da variância total dos dados. A rotação ortogonal permitiu que fossem encontrados os coeficientes de correlação entre as 21 variáveis utilizadas e os fatores de cada uma delas. Sendo assim, os resultados das cargas fatoriais e os fatores gerados estão dispostos na Tabela 1. Segundo literatura especializada¹⁷, é recomendada a seleção das cargas fatoriais com valor superior a, no mínimo, 0,5.

O primeiro fator se mostrou relacionado com as variáveis quantidade de estabelecimentos ambulatoriais alta complexidade (x1), estabelecimentos ambulatoriais de média complexidade (x2), estabelecimentos ambulatoriais básicos (x3), hospitais de alta complexidade (x4), hospitais de média complexidade (x5), auxiliares de enfermagem (x7), enfermeiros (x8), médicos (x9), técnicos em enfermagem (x10), quantidade de testes PCR (x11), quantidade de testes rápidos (x12), quantidade de leitos de internação não SUS (x13), leitos de internação SUS (x14), respiradores e/ou ventiladores (x15), UTIs adulto não SUS (x16), UTIs adulto SUS (x17), distribuição das despesas com saúde (x19) e valor transferido aos municípios (x21). Portanto, o Fator 1 representa as estruturas gerais de funcionamento em termos de recursos físicos, humanos e de material.

O segundo fator, por sua vez, se relacionou com as variáveis, hospitais de média complexidade (x5), número de postos de saúde (x6) e valor transferido diretamente à UF (x20). Este fator representa mecanismos iniciais de acesso à atendimento médico e fonte de recursos diretos estaduais. Por fim, o Fator 3 está relacionado com as variáveis quantidades de testes PCR (x11), compras nas modalidades por pregão, dispensa e inexigibilidade de licitação para enfrentamento da COVID-19 (x18) e valor transferido diretamente à UF (x20). Assim, o terceiro fator formou-se no contexto da pandemia da COVID-19, como con-

Tabela 1. Cargas fatoriais, comunalidades, variáveis, autovalores, variâncias por fator.

Variável	Fator 1	Fator 2	Fator 3	Comunalidade
X1	0,9427*	0,2257	0,1700	0,9685
X2	0,9563*	0,2314	0,0045	0,9681
X3	0,9207*	0,3200	-0,0147	0,9503
X4	0,9180*	0,2249	0,2988	0,9826
X5	0,8197*	0,5201*	0,0015	0,9425
X6	0,2070	0,9351*	-0,0741	0,9227
X7	0,9494*	-0,0736	0,1284	0,9232
X8	0,9546*	0,1691	0,2088	0,9835
X9	0,9783*	0,1139	0,1609	0,9960
X10	0,8392*	0,3194	0,4158	0,9791
X11	0,6132*	0,2269	0,6987*	0,9158
X12	0,9501*	0,2676	0,1341	0,9923
X13	0,9831*	0,1139	0,1187	0,9935
X14	0,9113*	0,3798	0,0961	0,9839
X15	0,9583*	0,1125	0,2551	0,9960
X16	0,9085*	0,0341	0,3953	0,9827
X17	0,9713*	0,1875	0,0403	0,9802
X18	0,0280	-0,1663	0,8877*	0,8164
X19	0,8659*	0,2166	0,3522	0,9207
X20	0,1287	0,6369*	0,6591*	0,8567
X21	0,8634*	0,4595	0,1624	0,9829
Autovalores	14,9575	2,5721	2,5081	-
Variância explicada (%)	0,7123	0,1225	0,1194	-
Variância acumulada (%)	0,7123	0,8347	0,9542	-

*Cargas fatoriais maiores que 0,5 foram marcadas por um asterisco.

Fonte: Elaboração própria.

tribuinte para a explicação do funcionamento hospitalar nas UFs brasileiras, diante elevada demanda populacional por atendimento de saúde.

Após a formação dos fatores, seguiu-se para a padronização dos resultados para a formação do índice. Assim, foi construído um índice para cada UF do país. O maior Índice de Infraestrutura de Saúde foi encontrado no estado de São Paulo (0,781795), seguido pelo estado de Minas Gerais (0,352699), ambos na região Sudeste. Os menores índices, por sua vez, foram registrados no Amapá (0,045114) e em Roraima (0,045722), na região Norte do país. Na Tabela 2 é possível observar o IIS_m de cada UF do Brasil.

Os resultados numéricos dos índices sugerem que a distribuição espacial da estrutura do sistema de saúde no Brasil não se dá de forma homogênea. Em exemplo, apenas o estado de São Paulo alcançou um índice superior a 0,5. Ademais, é possível observar disparidades regionais no que tange à essa distribuição. Enquanto os maiores índices concentram-se na região Sudeste, os me-

nores estão presentes na região Norte, onde houve relatos de sobrecarga nos sistemas de saúde e funerário, ocasionados pela COVID-19²¹.

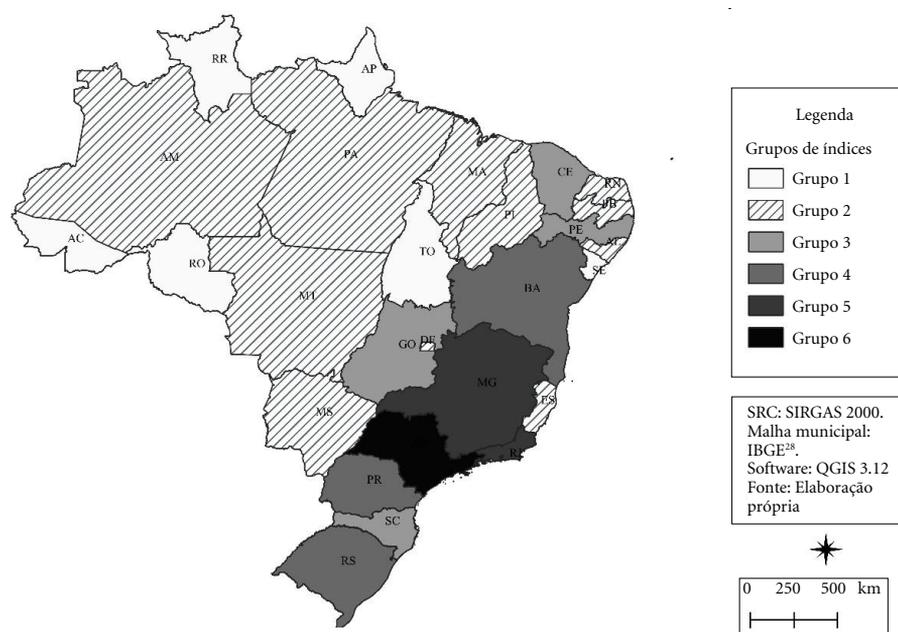
Em prol de uma melhor observação do agrupamento dos IIS_m nas Unidades da Federação, na Figura 1, encontra-se a disposição espacial dos índices nas diferentes localidades do país. Estes resultados foram obtidos através do método *hierarchical clustering*, com indicação de formação de seis agrupamentos. Construídos mediante o método *Ward linkage*, com aplicação de distância euclidiana. Para a obtenção desses grupos, partiu-se dos resultados dos índices, conforme apresentado na Tabela 2.

A Figura 1 organiza os grupos de modo que, quanto maior o índice, mais escura é a tonalidade representada no mapa. Desta forma, é possível observar que os estados do Amapá (0,045114), Roraima (0,045722), Acre (0,045823), Rondônia (0,06500), Sergipe (0,067870) e Tocantins (0,057963) compõem o grupo dos menores índices, ou seja, o Grupo 1.

Tabela 2. Resultados dos Índice de Infraestrutura de Saúde (IIS_m) por UF e região, em 2020.

Região	UF	IIS_m	Região	UF	IIS_m
Norte	Rondônia	0,065007	Nordeste	Sergipe	0,067870
Norte	Acre	0,045823	Nordeste	Bahia	0,218160
Norte	Amazonas	0,080364	Sudeste	Minas Gerais	0,352699
Norte	Roraima	0,045722	Sudeste	Espírito Santo	0,096621
Norte	Pará	0,118611	Sudeste	Rio de Janeiro	0,332393
Norte	Amapá	0,045114	Sudeste	São Paulo	0,781795
Norte	Tocantins	0,057963	Sul	Paraná	0,233039
Nordeste	Maranhão	0,109346	Sul	Santa Catarina	0,156648
Nordeste	Piauí	0,076482	Sul	Rio Grande do Sul	0,229693
Nordeste	Ceará	0,147787	Centro-Oeste	Mato Grosso do Sul	0,082707
Nordeste	Rio Grande do Norte	0,085771	Centro-Oeste	Mato Grosso	0,096832
Nordeste	Paraíba	0,094154	Centro-Oeste	Goiás	0,149312
Nordeste	Pernambuco	0,167269	Centro-Oeste	Distrito Federal	0,110340
Nordeste	Alagoas	0,076142			

Fonte: Elaboração própria, a partir de dados da pesquisa e IBGE²⁷.

**Figura 1.** Disposição espacial dos índices por agrupamento.

O Grupo 2 é formado pelos estados do Amazonas (0,080364), Pará (0,118611), Maranhão (0,109346), Piauí (0,07648), Rio Grande do Norte (0,085771), Paraíba (0,094154), Alagoas (0,076142), Espírito Santo (0,09662), Mato Gros-

so (0,096832), Mato Grosso do Sul (0,082707) e Distrito Federal (0,11034).

No terceiro grupo encontram-se os estados de Pernambuco (0,16726), Ceará (0,147787), Goiás (0,149312) e Santa Catarina (0,156648).

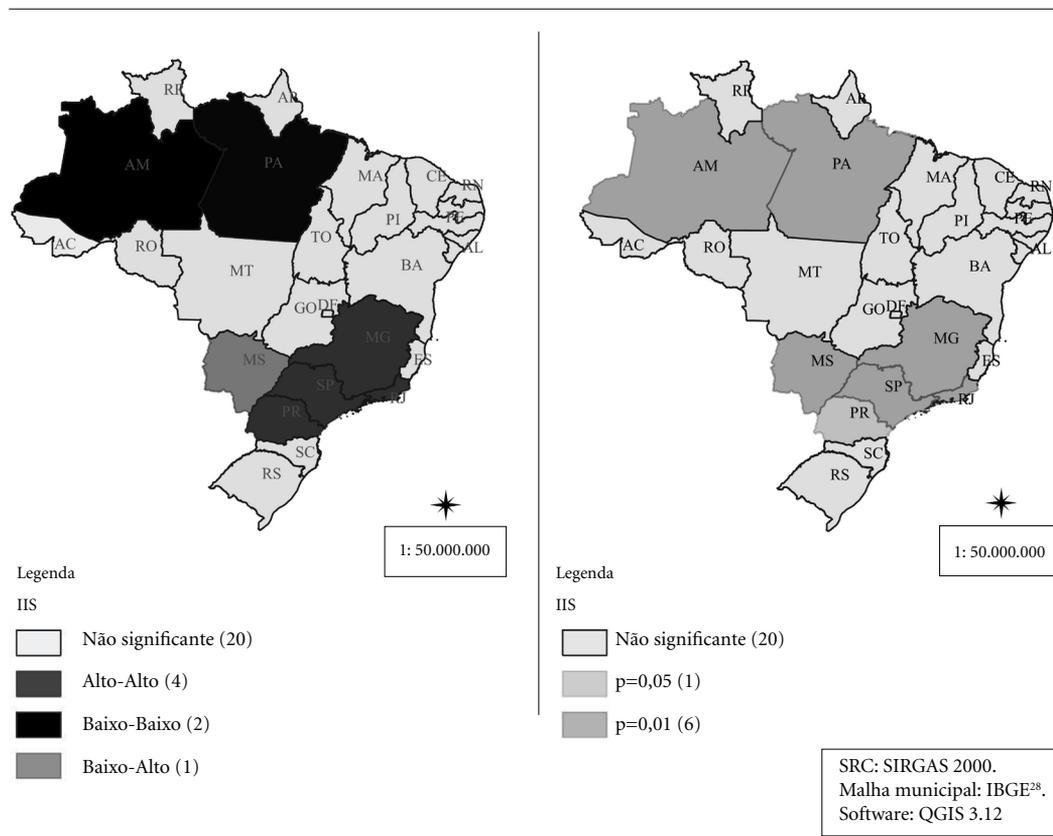


Figura 2. Clusters e nível de significância alcançados através da AEDE.

Fonte: Elaboração própria

Enquanto isso, o Grupo 4 é composto pela Bahia (0,218160), pelo Paraná (0,233039) e pelo Rio Grande do Sul (0,229693).

Os grupos com os maiores valores do IIS_m encontram-se nos grupos 5 e 6. O quinto grupo é formado pelo Rio de Janeiro (0,33239) e por Minas Gerais (0,352699). Destaca-se o fato de que o Grupo 6 abarca somente o estado de São Paulo (0,781795).

Apesar da distribuição espacial do índice nas diferentes UFs se comportar de forma dessemelhante, faz-se necessária a verificação da existência de padrões de dependência espacial. Para tal, utilizam-se os ferramentais estatísticos I de Moran global e I de Moran local.

Com a intenção de obtenção das evidências acerca da correlação espacial, foi calculado o I de Moran global univariado. No cálculo, foram utilizadas as convenções de matriz de contiguidade *queen* (rainha) – os resultados para a matriz *rook* (torre) foram semelhantes. Os resultados foram

capazes de confirmar que o IIS_m é autocorrelacionado espacialmente entre as UFs brasileiras, na medida em que a hipótese nula de aleatoriedade espacial foi rejeitada.

Confirmada a dependência espacial, foi possível analisar os padrões locais de associação espacial da infraestrutura de saúde de enfrentamento à COVID-19 no país. Através do cálculo do I de Moran local, observou-se a formação de *clusters* do tipo baixo-baixo na região Norte do Brasil e do tipo alto-alto na região Sudeste. Ademais, encontrou-se um padrão de aglomeração do tipo baixo-alto no estado do Mato Grosso do Sul. Na Figura 2 é possível observar a formação dos *clusters* no território brasileiro. Considera-se p-valor menor ou igual a 5% como indicador de significância estatística.

A existência de um *cluster* do tipo baixo-baixo significa que UFs com um baixo IIS_m estão também circundados por outros UFs com baixo IIS_m . No caso do *cluster* do tipo alto-alto, o in-

verso ocorre. Ou seja, UFs com elevada infraestrutura de saúde estão rodeados por outras UFs com características semelhantes neste aspecto, isto é, também com alta infraestrutura de saúde. O padrão de *cluster* tipo baixo-alto, por sua vez, indica que UFs com baixo IIS_m estão cercados por outros estados que possuem um IIS_m alto.

O padrão de *clusters* baixo-baixo envolve os estados do Amazonas e do Pará. Já o padrão alto-alto foi observado, sobretudo, nas regiões Sul e Sudeste. Os estados de Minas Gerais, Rio de Janeiro, São Paulo e Paraná compuseram essa aglomeração. O estado do Mato Grosso do Sul, conforme anteriormente mencionado, formou um *cluster* do tipo baixo-alto.

Discussão

A construção do índice buscou evidenciar a distribuição da infraestrutura de saúde no Brasil. Os valores obtidos revelam a heterogeneidade e a desigualdade de acesso da população brasileira ao atendimento no sistema de saúde, evidenciadas pela amplitude da primeira (São Paulo $IIS_m = 0,781795$) e última (Amapá $IIS_m = 0,045114$) unidade de federação em termos de posição no IIS_m . É possível notar que algumas unidades de federação se agruparam com outras de diferentes regiões, mesmo que não sejam estritamente vizinhas. Dentro de uma região há diversas realidades, com escalas diferentes de infraestrutura de saúde.

Ressalta-se que as UFs dos agrupamentos 1 e 2 – região Norte, e parte das regiões Nordeste e Centro-Oeste – possuem baixos níveis de infraestrutura de saúde, em comparação às UFs dos demais agrupamentos. Este padrão também pode ser percebido em termos de *clusters* espaciais estatisticamente significativos. Desta forma é preciso atenção ao Amazonas e ao Pará, por formarem um *cluster* baixo-baixo em termos do IIS_m , o que pode significar maior fragilidade destes locais no que se refere à capacidade de atendimento à população, principalmente em situações críticas, de choque elevado de demanda.

A situação das localidades com baixa infraestrutura de saúde pode ser agravada pela distância entre essas UFs e aquelas com maior IIS_m , para uma possível tentativa de transferência de pacientes graves para outras unidades de saúde, por exemplo. Smolski et al.²², em uma análise do Rio Grande do Sul, suas Regiões de Saúde e seus respectivos municípios, com relação à disponibilidade de leitos hospitalares no enfrentamento da

COVID-19, concluíram que a maior parte da população é dependente de deslocamentos para ter acesso a este tipo de serviço de saúde, o qual está concentrado em centros de referência regional; além disso, foi observado que há desigualdades na distribuição e oferta de leitos hospitalares e respiradores/ventiladores; e, em algumas Regiões de Saúde nem sequer foram encontrados registros de leitos de UTI do tipo Adulto. Pedrosa e Albuquerque²³ também buscaram analisar a distribuição dos casos da COVID-19 e dos leitos de unidade de terapia intensiva (UTI), destinados exclusivamente à doença, porém no estado brasileiro do Ceará.

Uma boa infraestrutura para o enfrentamento de episódios de alta demanda pelos serviços de saúde, como é o caso da pandemia da COVID-19, pode ser fundamental no combate à mortalidade pela doença. Uma evidência disso é o estudo de Moreira²⁴, que buscou identificar regiões com maiores taxas de mortalidade específica decorrentes da COVID-19, e locais de maior escassez de leitos de UTI e ventiladores pulmonares. Os principais resultados apontaram para quatro perfis em potencial de mortalidade, formado pelo conjunto de Regiões de Saúde com coeficientes baixos; valores médios; coeficientes altos; e coeficientes muito altos. As regiões de saúde que apresentaram as maiores médias na mortalidade, localizam-se em locais cuja escassez de leitos de UTI e de ventiladores foi observada, principalmente, em partes das regiões Nordeste, Sudeste e Sul.

Para Noronha et al.²⁵ diante da pandemia da COVID-19 no Brasil, a pressão por atendimentos, evidencia mais a desigualdade de oferta de serviços de saúde, insuficientes, mesmo com a presença do setor privado. O reforço da estrutura deve ser feito, por exemplo, com hospitais de campanha, combinados a estratégias da redução da velocidade de contaminação.

Os maiores valores do índice de infraestrutura de saúde construído foram localizados, sobretudo, na região Sudeste e, mais especificamente, em São Paulo. Sublinha-se aqui as informações da Agência Nacional de Saúde Suplementar (ANS)²⁶ para março de 2020, onde foi verificado que a região Sudeste é a região que conta com o maior número de beneficiários de planos de saúde, medidos por número de vínculos firmados com instituições de saúde suplementar. Em seguida, encontram-se as regiões Sul, Nordeste, Centro-Oeste e por fim, a região Norte. Ademais, segundo a Pesquisa de Orçamentos Familiares (POF) de 2008, as famílias da região Sudeste são

as com maiores despesas médias com assistência à saúde e planos de saúde, seguidas pelas regiões Sul, Centro-Oeste, Nordeste e Norte²⁷.

Importante destacar que o nível de infraestrutura de saúde não reflete isoladamente o nível de vulnerabilidade da UF em relação a pandemias, como a de COVID-19, uma vez que fatores como velocidade de propagação do vírus, índice de isolamento, uso de máscaras, outras medidas que reduzam o contágio, quantidade de habitantes, distância de moradias e a quantidade de pessoas por domicílio, possivelmente poderiam interferir. Estes elementos podem ser avaliados em trabalhos posteriores.

Espera-se que este estudo contribua com as políticas públicas voltadas à ampliação da infraestrutura de saúde no Brasil, em especial com a finalidade de atenuar as existentes disparidades regionais. Dentre as limitações deste estudo, des-

tacam-se as poucas produções científicas acerca da pandemia da COVID-19 e de seu comportamento em nível nacional, visto que é um fenômeno recente e ainda de difícil mensuração de seus efeitos, o que limita a discussão acerca do assunto. Outras limitações associam-se a estruturas de saúde recém-criadas no período da pandemia, o que dificulta a contemplação de todas as informações no estudo. Além disso, é preciso ponderar que a infraestrutura da saúde é destinada à prevenção, diagnóstico e tratamento de diversas doenças, não apenas à COVID-19, então os resultados obtidos devem ser analisados com parcimônia, uma vez que o sistema de saúde deve ser preparado para o enfrentamento de diversos tipos de enfermidades. Recomenda-se que futuros trabalhos ampliem o estudo através de informações municipais e ao longo do tempo, com índices dinâmicos.

Colaboradores

Todos os autores participaram igualmente de todas as etapas de execução do trabalho, desde a ideia inicial, até a escrita e revisão do artigo.

Referências

- Zhu N, Zhang D, Wang W, Li X, Yang B, Song J, Zhao X, Huang B, Shi W, Lu R, Niu P, Zhan F, Ma X, Wang D, Xu W, Wu G, Gao GF, Tan W, China Novel Coronavirus Investigating and Research Team. A novel coronavirus from patients with pneumonia in China, 2019. *N Engl J Med* 2020; 382(8):727-733.
- Tsang KW, Ho PL, Ooi GC, Yee WK, Wang T, Chan -Yeung M, Lam WK, Seto WH, Yam LY, Cheung TM, Wong PC, Lam B, Ip MS, Chan J, Yuen KY, Lai KN. A cluster of cases of severe acute respiratory syndrome in Hong Kong. *N Engl J Med* 2003; 348(20):1975-1983.
- World Health Organization (WHO). *Novel coronavirus: China, 2020* [Internet]. [acessado 2020 Jun 26]. Disponível em: <http://www.who.int/csr/don/12-january-2020-novel-coronavirus-china/en/>
- Organização Pan-Americana da Saúde (OPAS). *Folha informativa - COVID-19: doença causada pelo novo coronavírus, 2020* [Internet]. [acessado 2020 Jul 04]. Disponível em: https://www.paho.org/bra/index.php?option=com_content&view=article&id=6101:-covid19&Itemid=875
- Brasil. Ministério da Saúde (MS). *Coronavírus - COVID 19: O que você precisa saber* [Internet]. 2020 [acessado 2020 Jun 26]. Disponível em: <https://coronavirus.saude.gov.br/>
- Brasil. Ministério da Saúde (MS). *COVID-19 no Brasil* [Internet]. 2020 [acessado 2020 Jul 4]. Disponível em: <http://susanalitico.saude.gov.br/#/dashboard/>
- Brasil. Ministério da Saúde (MS). DATASUS. *Tabnet* [Internet]. [acessado 2020 Jun 11]. Disponível em: <https://datasus.saude.gov.br/informacoes-de-saude-tabnet/>
- Silva HB. *Mais Médicos e o Médicos pelo Brasil, 2019* [Internet]. [acessado 2020 Jun 26]. Disponível em: http://www.portal.cfm.org.br/index.php?option=com_content&view=article&id=28381:2019-08-09-19-00-50&catid=46:artigos&Itemid=18
- Brasil. Ministério da Saúde (MS). DATASUS. *Leitos de internação* [Internet]. [acessado 2020 Jun 26]. Disponível em: <http://tabnet.datasus.gov.br/cgi/defthtm.exe?cnes/cnv/leintbr.def>
- Conselho Federal de Enfermagem (COFEN). *Enfermagem em números* [Internet]. [acessado 2020 Jun 12]. Disponível em: <http://www.cofen.gov.br/enfermagem-em-numeros>
- Portal de Compras. *Painel de compras COVID-19* [Internet]. 2020 [acessado 2020 Jun 11]. Disponível em: <https://www.comprasgovernamentais.gov.br/index.php/transparencia/60-transparencia/1313-transparencia-dos-dados-de-compras-para-o-covid-19>
- Brasil. Ministério da Saúde (MS). *Painel de leitos e insumos* [Internet]. 2020 [acessado 2020 Jun 7]. Disponível em: <https://covidinsumos.saude.gov.br/paineis/insumos/painel.php>
- Portal da Transparência. *Saúde: Distribuição das despesas com saúde por localidade* [Internet]. 2020 [acessado 2020 Jun 10]. Disponível em: <http://www.portal-transparencia.gov.br/funcoes/10-saude?ano=2020>
- Portal da Transparência. *Recursos transferidos* [Internet]. 2020 [acessado 2020 Jun 10]. Disponível em: <http://www.portaldatransparencia.gov.br/transferencias>
- Fávero LP, Belfiore P. *Manual de análise de dados*. Rio de Janeiro: Elsevier; 2017.
- Manly BFJ. *Métodos estatísticos multivariados: uma introdução*. 3ª ed. Porto Alegre: Bookman; 2008.
- Mingoti SA. *Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada*. Belo Horizonte: Editora UFMG; 2005.
- Hair Jr JF, Black WC, Babin BJ, Anderson RE, Tatham RL. *Análise multivariada de dados*. Porto Alegre: Bookman Editora; 2009.
- Almeida E. *Econometria espacial*. Campinas: Alínea; 2012.
- Anselin L. Local Indicators of Spatial Association – LISA. *Geographical Analysis* 1995; 27(2):93-115.
- Silva SG. Pandemia e afetações das emoções: reflexões sobre a realidade da Covid-19 no estado do Amapá. *Rev Bras Sociol Emoção* 2020; 19(55):113-124.
- Smolski FMS, Battisti IDE, Soder RM, Rotta E, Kucharski KW. *Disponibilidade de leitos hospitalares e ventilação mecânica no Rio Grande do Sul: desafios no enfrentamento da COVID-19* [Internet]. 2020 [acessado 2020 Jun 25]. Disponível em: https://www.researchgate.net/publication/341651488_Disponibilidade_de_leitos_hospitalares_e_ventilacao_mecanica_no_Rio_Grande_do_Sul_desafios_no_enfrentamento_da_COVID-19
- Pedrosa NL, Albuquerque NLS. Análise Espacial dos Casos de COVID-19 e leitos de terapia intensiva no estado do Ceará, Brasil. *Cien Saude Colet* 2020; 25(Supl. 1):2461-2468.
- Moreira RS. COVID-19: unidades de terapia intensiva, ventiladores mecânicos e perfis latentes de mortalidade associados à letalidade no Brasil. *Cad Saude Publica* 2020; 36(5):e00080020.
- Noronha KVMS, Guedes GR, Turra CM, Andrade MV, Botega L, Nogueira D, Calazans JÁ, Carvalho L, Servo L, Ferreira ME. Pandemia por COVID-19 no Brasil: análise da demanda e da oferta de leitos hospitalares e equipamentos de ventilação assistida segundo diferentes cenários. *Cad Saude Publica* 2020; 36(6):e00115320.
- Agência Nacional de Saúde Suplementar (ANS). *Beneficiários* [Internet]. [acessado 2020 Jun 29]. Disponível em: http://www.ans.gov.br/anstabnet/cgi-bin/dh?dados/tabnet_br.def
- Instituto Brasileiro de Geografia e Estatística (IBGE). *Sistema IBGE de Recuperação Automática* [Internet]. [acessado 2020 Jun 28]. Disponível em: <https://sidra.ibge.gov.br>
- Instituto Brasileiro de Geografia e Estatística (IBGE). *Malhas municipais 2019* [Internet]. [acessado 2020 Jun 6]. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/15774-malhas.html?=&t=downloads>

Artigo apresentado em 16/07/2020

Aprovado em 13/09/2020

Versão final apresentada em 15/09/2020

