

UMA ANÁLISE ESPACIAL DAS CONDIÇÕES DE ENFRENTAMENTO À COVID-19: UMA PROPOSTA DE ÍNDICE DA ESTRUTURA HOSPITALAR DO BRASIL¹

Évilly Carine Dias Bezerra²
Priscila Soares dos Santos³
Fernanda Cigainki Lisbinski⁴
Lázaro Cezar Dias⁵

RESUMO

O comportamento exponencial da pandemia do COVID-19 gera preocupações nos organismos nacionais e internacionais. Uma delas se refere à capacidade da estrutura hospitalar 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 Estruturação Hospitalar (IEH) dos estados brasileiros, 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 IEH 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. Estrutura hospitalar. Brasil

Classificação JEL: I10, I14, I18

Área Temática: 16. Descentralização, planejamento regional e desenvolvimento

ABSTRACT

The exponential behavior of COVID-19 pandemic curve raises concerns in national and international institutions. An inquietation is related to the capacity of the hospital structure to support the demand for care and treatment of patients affected by this disease. The objective of this paper is to create and map a Index of the Brazilians states Hospital Structure (IHS), as well as to verify its spatial distribution. For this purpose, the Principal Component Factor Analysis was used e, Bartlett and also Kaiser – Meyer – Olkin tests are applied to check their suitability. Then, the Exploratory Analysis of Spatial Data was carried out. Data were collected at DATASUS, COFEN, Ministry of Health, Government Procurement Portal and Transparency Portal. The IHS reveals that nine states in the North and Northeast recorded the lowest indexes, and five states in the Southeast and South have the highest indexes. A low-low cluster was

¹ O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES).

² Mestranda em Economia e Desenvolvimento (PPGE&D) pela Universidade Federal de Santa Maria (UFSM).
E-mail: evillycarine@hotmail.com.

³ Mestranda em Economia e Desenvolvimento (PPGE&D) pela Universidade Federal de Santa Maria (UFSM).
E-mail: pri.soaares@gmail.com.

⁴ Mestranda em Economia e Desenvolvimento (PPGE&D) pela Universidade Federal de Santa Maria (UFSM).
E-mail: lisbinskif@gmail.com.

⁵ Mestrando em Economia e Desenvolvimento (PPGE&D) pela Universidade Federal de Santa Maria (UFSM).
E-mail: lzar.cezar@gmail.com.

registered in the states of Amazonas and Pará and a high-high cluster in Minas Gerais, Rio de Janeiro, São Paulo and Paraná.

Keywords: COVID-19. Hospital structure. Brazil

JEL Classification: I10, I14, I18

1 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 estes, 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) – (ZHU et al, 2020). A SARS apresenta sintomas de origem infecciosa, tais como febre seguida de complicações respiratórias, rapidamente progressivo, estes são os principais sinais e sintomas do qual a síndrome deriva seu nome (TSANG et. al, 2003).

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 (ORGANIZAÇÃO MUNDIAL DA SAÚDE (OMS), 2020a; ZHU et. al., 2020).

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 mundial (OMS, 2020).

Até a data de 03 de julho de 2020, foram confirmados no mundo 10.710.005 casos da COVID-19 e 517.877 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 estado (OMS, 2020). Até a data de 03 de julho, o Brasil apresentou 1.539.081 casos e 63.174 mortes acumulados. Tendo em vista a limitação de testes disponíveis, pressupõe-se subnotificação. O Ministério da Saúde afirma que a progressão desta epidemia é de crescimento exponencial. As medidas adotadas e recomendadas para conter o avanço do vírus consistem em cuidados com higiene, testagem do maior número de casos e o isolamento/distanciamento social, tendo em vista que os sintomas desta doença podem ser silenciosos (assintomático) (MINISTÉRIO DA SAÚDE, 2020, 2020b).

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 DATASUS (2020), 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, Silva (2019), 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.

Destarte, conhecer o tamanho da estrutura hospitalar, o contingente de recursos e a capacidade de atendimento à saúde (alta e média complexidade) disponível à população de qualquer país ou região é de suma importância para o combate da COVID-19 e corrobora a manutenção da saúde e da vida da população. Assim, este trabalho torna-se importante ferramenta de decisão aos propositores de políticas públicas (*policymakers*) principalmente, na destinação de recurso público para o controle da disseminação e tratamento das pessoas contaminadas pelo vírus.

Sendo assim, essa pesquisa busca responder a seguinte pergunta norteadora: como se encontra a estrutura hospitalar dos estados brasileiros para o enfrentamento da COVID-19? O objetivo deste estudo consiste em criar e mapear um índice de estruturação hospitalar dos estados brasileiros, bem como verificar a sua distribuição espacial. Para isso, busca-se apresentar uma revisão de literatura com alguns estudos que abordam o tema e a metodologia proposta; analisar os fatores que determinam a estrutura hospitalar dos estados brasileiros, e; criar um índice para verificação e comparação da estrutura hospitalar dos estados, por meio de sua distribuição espacial.

Este trabalho se diferencia dos demais em sua proposta de compreender a estrutura hospitalar, ao estudar por meio da construção do índice a estrutura hospitalar dos estados e Distrito Federal no enfrentamento da COVID-19. Diante disso, a metodologia adotada se utiliza da técnica da estatística multivariada, análise fatorial para a elaboração de um indicador sintético, o IEH. Posteriormente, faz-se uso da análise exploratória de dados espaciais (AEDE) para verificar a distribuição desse índice no território analisado, identificando a existência ou não de autocorrelação espacial (dependência espacial) e heterogeneidade espacial (diferenças estruturais) entre os 26 estados brasileiros mais o Distrito Federal, bem como se as relações de vizinhança e proximidade entre estes influenciam sua estrutura hospitalar.

O trabalho encontra-se distribuído em cinco seções. Essa introdução busca contextualizar o leitor sobre o assunto tratado. Seguido de uma revisão da literatura apresentando as principais contribuições na área de estudo. Adiante, apresenta-se de forma detalhada a metodologia utilizada no desenvolvimento da pesquisa. Posteriormente, faz-se a análise e discussão dos resultados encontrados. E, por fim, apresenta-se as conclusões.

2 ESTUDOS EMPÍRICOS SOBRE COVID-19 E ABORDAGEM ESPACIAL

Estudos sobre a COVID-19 pela literatura econômica são exercícios teórico-exploratórios contemporâneos, visto que, sua manifestação epidemiológica inicia-se no final de 2019 e atinge os países mais gravemente em 2020; portanto, os trabalhos apresentados nesta seção são recentes. Destacam-se neste estudo, os trabalhos desenvolvidos por Pedrosa e Albuquerque (2020), Moreira (2020), Smolski et al (2020) e Rolim (2020), que se utilizaram metodologia próxima a abordada nesta pesquisa para explicar diferentes problemas de pesquisa atrelados à COVID-19, tomando como base diferentes localidades e regiões brasileiras.

Pedrosa e Albuquerque (2020) buscaram analisar a distribuição dos casos da COVID-19 e dos leitos de unidade de terapia intensiva (UTI), destinados exclusivamente à doença, no

estado brasileiro do Ceará. Os autores distribuíram geograficamente o número de casos da doença para 184 municípios, utilizando como base os casos registrados no período de 15 de março de 2020 (primeiro registro no estado) a 18 de abril de 2020 (último dado disponível até o momento da pesquisa). Foram construídos mapas dos valores brutos e estimados, a partir do cálculo do índice de Moran e uso do *BoxMap* e *MoranMap*. Os autores estudaram 3.000 casos e 459 leitos. Com relação aos leitos de UTI, estes foram distribuídos por meio de referências geolocalizadas. Os principais resultados demonstraram que as maiores taxas se concentraram na capital do estado, Fortaleza, sobretudo nas regiões metropolitana (RM) e sul. Verificou-se a presença de autocorrelação espacial positiva no índice bayesiano local ($I = 0,66$). A distribuição dos leitos de UTI, sobreposta ao *BoxMap*, demonstrou *clusters* (agrupamentos) com padrão Alto-Alto de número de leitos na RM de Fortaleza, sobretudo, de municípios localizados ao sul dessa mesma região, e ainda, nos municípios de Sobral e seus vizinhos (oeste) e Aracati e seu entorno. Com relação ao padrão de transição do tipo Alto-Baixo ou Baixo-Alto, observou-se presença nos municípios de Quixadá, Quixeramobim e Canindé. O Padrão Baixo-Baixo, encontra-se no extremo sul, extremo oeste e em uma determinada faixa da porção central. Por fim, o *MoranMap* mostrou a formação de *clusters* estatisticamente significativos neste estado.

Em seu estudo, Moreira (2020) buscou identificar tanto as regiões que apresentavam as maiores taxas de mortalidade específica decorrentes da COVID-19, quanto as que apresentam maior escassez de leitos de UTI e ventiladores pulmonares. Para isso, o autor realizou um estudo ecológico transversal, utilizando na análise as Regiões de Saúde no Brasil. Os dados utilizados no desenvolvimento desta pesquisa foram coletados no Departamento de Informática do Sistema Único de Saúde (DATASUS) (sendo, do Cadastro Nacional de Estabelecimentos de Saúde - 2019, Sistemas de Informação de Mortalidade - 2017 e Projeções Populacionais - 2017). As taxas de mortalidade específica foram calculadas por 100 mil habitantes, decorrentes de hipertensão, neoplasias, diabetes, doenças cardíacas e respiratórias, leitos de unidades de terapia intensiva (UTI) total, leitos de UTI privados, leitos de UTI do Sistema Único de Saúde (SUS) e ventiladores do SUS. O perfil de mortalidade foi determinado pela análise de perfis em potencial, e a análise de agrupamentos dos leitos e ventiladores foi realizada por meio do método de análise espacial. Foram construídos mapas de Kernel para a visualização dos dados, com nível de significância de 5%. Os principais resultados apontaram para quatro perfis em potencial de mortalidade, sendo eles: perfil 1, formado pelo conjunto de Regiões de Saúde com coeficientes baixos; perfil 2, valores médios; perfil 3, coeficientes altos; e, perfil 4, 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.

Smolski et al (2020) visaram descrever em seu estudo, a situação em que se encontrava o Estado do Rio Grande do Sul, suas Regiões de Saúde e seus respectivos municípios, com relação à disponibilidade de leitos hospitalares no enfrentamento à COVID-19. Para isto, utilizaram dados disponibilizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), para a população estimada, e DATASUS, referentes à número de leitos hospitalares e leitos UTI para cada município do estado, número de leitos hospitalares e leitos UTI para cada Região de Saúde, número de habitantes para cada município e Região de Saúde, estrutura etária dos municípios (proporção de crianças, adultos e idosos) e Regiões de Saúde. Os dados coletados são apresentados por meio de tabelas e mapas, verificando a distribuição espacial destes no território gaúcho. Além disso, os autores calcularam o Coeficiente de Disponibilidade de Leitos (CDL); Coeficiente de Disponibilidade Leitos de UTI (CDLU); e, os Coeficientes locais das localidades, com relação ao número de leitos totais, leitos SUS e Não-SUS, verificando a sua distribuição espacial. Os principais resultados apontaram 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; o número de pessoas idosas tende a ser maior

em municípios com menor população absoluta; há desigualdades na distribuição e oferta de leitos hospitalares e respiradores/ventiladores; e, em algumas Regiões de Saúde não foram encontrados registros de leitos de UTI do tipo Adulto.

Rolim (2020) verificou a correlação espacial da COVID-19 em municípios do estado do Paraná. Para verificar se os fenômenos ocorrem aleatoriamente no espaço ou se há correlação espacial na sua ocorrência, o autor se utilizou da estatística I de Moran e da heterogeneidade espacial, por meio do uso da LISA (*Local indicators of spatial association*), que trata-se de uma decomposição local do I de Moran. Os resultados, ao utilizar matrizes com 3, 5 e 10 vizinhos, apontaram para a existência de correlação espacial entre municípios com maior coeficiente de incidência da COVID-19, sendo este detectado, principalmente, no noroeste e no oeste do estado.

Diante disso, são incipientes os estudos da temática abordada que utilizam como método a análise fatorial na construção de um índice e, analisando a sua distribuição espacial. Sendo assim, verifica-se a necessidade e a importância de avançar nessa pesquisa, servindo como uma diretriz para formulação e adoção de políticas públicas voltadas ao enfrentamento da pandemia global causada pela COVID-19.

3 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.

3.1 DADOS UTILIZADOS

Com a finalidade de construção de um índice que permita a verificação da estrutura de enfrentamento à COVID-19 nos estados brasileiros, foram utilizadas variáveis capazes de captar informações de diferentes dimensões em nível estadual, a saber: a estrutura física de saúde em cada estado, 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 DATASUS, do Conselho Federal de Enfermagem (COFEN), da Secretaria de Vigilância à Saúde (SVS), do Portal de Compras do Governo, Ministério da Saúde e do Portal da transparência. Há quatro dimensões de destaque: estruturas físicas, trabalhadores da saúde, dispositivos estratégicos para Covid-19 e recursos financeiros. No Quadro 1 estão dispostas as dimensões abordadas no estudo, as variáveis manuseadas na pesquisa e suas respectivas fontes.

Quadro 1 – Informações sobre variáveis e fonte de dados da pesquisa

Dimensão	Dados	Descrição dos dados	Fonte
Estruturas físicas	X_1	Quantidade de estabelecimentos ambulatoriais de alta complexidade	DATASUS (2020a)
	X_2	Quantidade de estabelecimentos ambulatoriais de média complexidade	DATASUS (2020a)
	X_3	Quantidade de estabelecimentos ambulatoriais básicos	DATASUS (2020a)
	X_4	Quantidade de hospitais de alta complexidade	DATASUS (2020a)
	X_5	Quantidade de estabelecimentos hospitalares de média complexidade	DATASUS (2020a)
	X_6	Número de postos de saúde	DATASUS (2020a)

Dimensão	Dados	Descrição dos dados	Fonte
Trabalhadores da saúde	X_7	Número de auxiliares de enfermagem	COFEN (2020)
	X_8	Número de enfermeiros	COFEN (2020)
	X_9	Número de médicos	DATASUS (2020a)
	X_{10}	Número de técnicos em enfermagem	COFEN (2020)
Dispositivos estratégicos para Covid-19	X_{11}	Quantidade de testes PCR	Ministério da Saúde (2020)
	X_{12}	Quantidade de testes rápidos	Ministério da Saúde (2020)
	X_{13}	Quantidades de leitos de internação não SUS	DATASUS (2020a)
	X_{14}	Quantidades de leitos de internação SUS	DATASUS (2020a)
	X_{15}	Quantidade de respiradores e/ou ventiladores	DATASUS (2020a)
	X_{16}	Número de UTIs adulto não SUS	Ministério da Saúde (2020)
	X_{17}	Número de UTIs adulto SUS	Ministério da Saúde (2020)
Recursos financeiros	X_{18}	Compras nas modalidades pregão, dispensa e inexigibilidade de licitação para enfrentamento da covid-19 (R\$)	Portal de Compras (2020)
	X_{19}	Distribuição das despesas com saúde (R\$)	Portal da transparência (2020a)
	X_{20}	Valor transferido diretamente ao estado (R\$)	Portal da transparência (2020)
	X_{21}	Valor transferido diretamente aos municípios (R\$)	Portal da transparência (2020)

Nota: Dados obtidos no CNES foram referentes a abril de 2020.

Fonte: Elaboração própria.

Após a seleção dos dados, eles foram padronizados, o que segundo Fávero e Belfiore (2017) consiste em subtrair pela média e dividir pelo desvio-padrão da variável em estudo. Posteriormente foi aplicado 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 IEH. Nas subseções a seguir são destacados os procedimentos econométricos utilizados.

3.2 O MODELO ESTATÍSTICO MULTIVARIADO

Conforme mencionado, a construção do IEH se deu através da análise fatorial (AF) por componentes principais. Seguindo Fávero e Belfiore (2017), esta técnica permite a geração de fatores não correlacionados através de combinações lineares das variáveis iniciais. Conforme Mingoti (2005), a AF torna possível a redução de muitas variáveis em um menor número de fatores, conforme pode ser observado a seguir:

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

onde Z_p representa as variáveis observadas, l_p as cargas fatoriais, F_j os fatores comuns não correlacionados e ε_p o termo de erro. Este último corresponde aos erros de medição e não pode ser explicado pelos fatores comuns.

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 Mingoti (2005), os procedimentos adotados podem ser representados do seguinte modo:

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

em que IEH_m é o índice de estrutura hospitalar do m -ésimo estado brasileiro, 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 do estado 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 Belfiore (2017) os testes são representados conforme as próximas duas equações a seguir.

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

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 Belfiore (2017), como:

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

onde n representa o tamanho da amostra, k o número de variáveis, D o determinante da matriz de correlações ρ . Para a aprovação 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:

$$IEH_m = \frac{IEH_m - IEH_{min}}{IEH_{m\acute{a}x} - IEH_{min}} \quad (5)$$

Em que IEH_{min} e $IEH_{m\acute{a}x}$ são os índices mínimo e máximo calculados, respectivamente. Desta forma, 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 estrutura hospitalar de enfrentamento à COVID-19 do estado em questão. Cabe salientar que, para a geração dos fatores, foi utilizada a rotação fatorial ortogonal *varimax* que, de acordo com Hair Jr. et al. (2009), 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 Análise Exploratória de Dados Espaciais (AEDE). Assim, segue-se para o tratamento espacial dos dados.

3.3 PROCEDIMENTOS DE ANÁLISE ESPACIAL

Nesta etapa do estudo foram calculadas duas diferentes estatísticas: a estatística I de Moran global e a I de Moran local. Consoante Almeida (2012), 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 rodeados por locais com baixos valores.

O I de Moran Global, segundo Almeida (2012) é dado por:

$$I = \frac{n \sum_i \sum_j w_{ij} z_i z_j}{S_0 \sum_{i=1}^n z_i^2} \quad (6)$$

de modo que n representa o número de regiões; z representa as variáveis padronizadas; S_0 é igual a $\sum_i \sum_j w_{ij}$, indicando que as entradas da matriz de pesos espaciais w serão somados; w_z denota a média das variáveis padronizadas nos vizinhos, através de uma matriz de ponderação espacial w . Para dar prosseguimento à análise espacial, é preciso que o resultado dessa estatística aponte para a rejeição da hipótese nula de aleatoriedade espacial.

Para verificar a existência de formação de clusters espaciais do IEH_m nos diferentes estados do Brasil, é preciso calcular a estatística I de Moran Local, que é dada por Anselin (1995) da seguinte forma:

$$I = \frac{\sum_i I_i}{S_0 (\sum_i z_i^2 / n)} \quad (7)$$

Caso o índice esteja distribuído espacialmente de modo a formar *clusters*, então o resultado dessa estatística apontará para a rejeição da hipótese nula de não existência de *cluster* espacial. Os resultados dos procedimentos adotados estão dispostos na próxima seção.

4 ANÁLISE ESPACIAL DO ÍNDICE DE ESTRUTURA HOSPITALAR

A adequada aplicabilidade da análise fatorial por componentes principais foi confirmada pelos resultados dos testes KMO e de Bartlett. 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 IEH. Ao todo, foram extraídos três fatores e o critério utilizado para essa seleção foi a presença de raízes características maiores do que 1, conforme pode ser observado na Tabela 1.

Tabela 1 - Raiz característica, variâncias e resultados dos testes

Fator	<i>Eigenvalue</i>	Variância explicada (%)	Variância acumulada (%)
F1	14,9575	0,7123	0,7123
F2	2,5721	0,1225	0,8347
F3	2,5081	0,1194	0,9542
KMO	0,7459	Teste Bartlett	1715,09

Fonte: Elaboração própria.

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 2. Segundo literatura especializada (Mingoti, 2005), é recomendada a seleção das cargas fatoriais com valor a partir de 0,5.

Tabela 2 - Cargas fatoriais e comunalidades por variáveis

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

Fonte: Elaboração própria.

O primeiro fator se mostrou relacionado com as variáveis quantidade de estabelecimentos ambulatoriais de alta complexidade (x1), quantidade de estabelecimentos ambulatoriais de média complexidade (x2), quantidade de estabelecimentos ambulatoriais básicos (x3), quantidade de hospitais de alta complexidade (x4), quantidade de estabelecimentos de hospitais de média complexidade (x5), número de auxiliares de enfermagem (x7), número de enfermeiros (x8), número de médicos (x9), número de técnicos em enfermagem (x10), quantidade de testes PCR (x11), quantidade de testes rápidos (x12), quantidade de leitos de internação não SUS (x13), quantidade de leitos de internação SUS (x14), quantidade de respiradores e/ou ventiladores (x15), número de UTIs adulto não SUS (x16), número de UTIs adulto SUS (x17), distribuição das despesas com saúde (x19) e valor transferido diretamente 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 quantidade de hospitais de média complexidade (x5), número de postos de saúde (x6) e valor transferido diretamente ao estado (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 ao estado (x20). Assim, o terceiro fator formou-se no contexto da pandemia da COVID-19, como contribuinte para a explicação do funcionamento hospitalar nos estados brasileiros, 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 estado do país. O maior índice de estrutura hospitalar 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 3 é possível observar o IEH de cada estado do Brasil.

Tabela 3 - Resultados dos IEH para 2020, PIB de 2017 (R\$1.000,00) e Índice de GINI por Estado e Distrito Federal

Região	Estado	IEH	PIB	GINI
Norte	Rondônia	0,065007	43.506.499	0,685438
Norte	Acre	0,045823	14.271.063	0,683552
Norte	Amazonas	0,080364	93.204.175	0,864348
Norte	Roraima	0,045722	12.103.236	0,732573
Norte	Pará	0,118611	155.195.371	0,713909
Norte	Amapá	0,045114	15.479.885	0,760111
Norte	Tocantins	0,057963	34.101.687	0,718403
Nordeste	Maranhão	0,109346	89.524.184	0,718413
Nordeste	Piauí	0,076482	45.358.616	0,762321
Nordeste	Ceará	0,147787	147.890.392	0,776868
Nordeste	Rio Grande do Norte	0,085771	64.294.547	0,792442
Nordeste	Paraíba	0,094154	62.386.787	0,780075
Nordeste	Pernambuco	0,167269	181.550.642	0,790753
Nordeste	Alagoas	0,076142	52.843.468	0,717189
Nordeste	Sergipe	0,067870	40.703.766	0,730294
Nordeste	Bahia	0,218160	268.660.841	0,782179
Sudeste	Minas Gerais	0,352699	576.199.051	0,814669
Sudeste	Espírito Santo	0,096621	113.351.863	0,744212
Sudeste	Rio de Janeiro	0,332393	671.362.364	0,830275
Sudeste	São Paulo	0,781795	2.119.854.035	0,868631
Sul	Paraná	0,233039	421.374.933	0,773287
Sul	Santa Catarina	0,156648	277.191.961	0,760057
Sul	Rio Grande do Sul	0,229693	423.150.937	0,781079
Centro-Oeste	Mato Grosso do Sul	0,082707	96.372.195	0,679388
Centro-Oeste	Mato Grosso	0,096832	126.805.058	0,703132
Centro-Oeste	Goiás	0,149312	191.898.690	0,784650
Centro-Oeste	Distrito Federal	0,110340	244.682.756	-

Fonte: Elaboração própria, a partir de dados da pesquisa e IBGE (2020).

Os resultados numéricos dos índices sugerem que a distribuição espacial da estrutura hospitalar 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 menores estão presentes na região Norte, onde houve relatos de sobrecarga nos sistemas de saúde e funerário, ocasionados pela COVID-19 (SILVA, 2020).

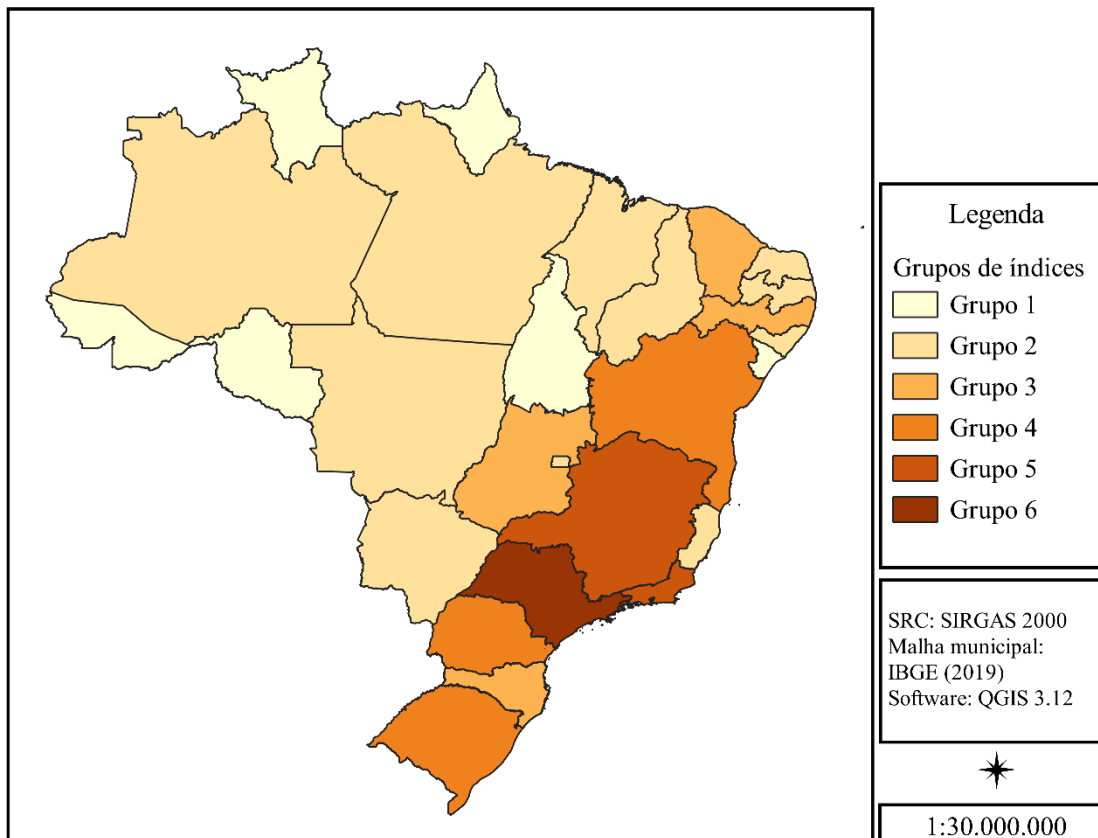
Nota-se que há predominância de elevados valores de IEH em estados de maior Produto Interno Bruto (PIB), ao passo que os estados com menores PIBs do Brasil apresentam menores valores do IEH. Esse grau de associações entre essas variáveis é notado pelo coeficiente de correlação entre esses valores ser da ordem de 0,98, um grau que Callegari-Jacques (2003) considera muito alto de associação entre as variáveis.

Em termos de desigualdade, medido pelo Índice de GINI, é possível notar que em alguns casos, locais de maiores níveis de desigualdade apresentaram maior IEH, como no caso de São Paulo que apresenta o maior IEH e o maior índice de GINI. Mas numa correlação de 0,64. Considerada por Callegari-Jacques (2003) como forte.

Em prol de uma melhor observação do agrupamento dos IEH nos estados brasileiros. Na Figura 1 é possível visualizar a disposição espacial dos índices nos diferentes estados 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 já apresentado na Tabela 3.

Figura 1 – Disposição espacial dos índices por agrupamento



Fonte: Elaboração própria

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.

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 Grosso (0,096832) e Mato Grosso do Sul (0,082707).

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

Observadas as prováveis disparidades regionais, sublinha-se ainda as informações da Agência Nacional de Saúde Suplementar (ANS, 2020) 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 Norte (IBGE, 2020).

Os dados acumulados de casos e óbitos da COVID-19 do dia 13 de junho de 2020 para o Brasil indicavam que a Região Norte possuía a maior incidência de casos de contaminação 954,14 casos por 100.000 habitantes (hab./100.000) e maior taxa de mortalidade 42,61 (hab./100.000) mortes. Seguida da região Nordeste com incidência de 526,65 (hab./100.000) e mortalidade de 23,91 (hab./100.000). Região Sudeste com incidência de 337,50 (hab./100.000) e mortalidade de 22,23 (hab./100.000). Centro-Oeste com incidência de 237,21 (hab./100.000), mortalidade de 4,42 (hab./100.000). E, por fim, região Sul com menor incidência de casos (123,95 hab./100.000) e menor mortalidade (2,83 hab./100.000). Já a taxa de letalidade é maior na Região Sudeste (6,59%), seguida por Nordeste (4,54%), Norte (4,47%), Sul (2,28%) e Centro-oeste (1,87%) (MINISTÉRIO DA SAÚDE, 2020).

Esses dados revelam que regiões com maior número de casos tendem a apresentar maior número de mortes, indicando que o número elevado de casos pressiona o sistema de saúde. Quanto menor a capacidade de atendimento, possivelmente, maior a probabilidade de elevação das mortes evitáveis. Uma evidência para este acontecimento é notada quando, por exemplo, os estados do Norte e Nordeste ocupam as nove menores posições do IEH (Amapá, Roraima, Acre, Tocantins, Roraima, Sergipe, Alagoas, Piauí, Amazonas)⁶, vindo das duas regiões com maiores taxas de incidência e mortalidade de COVID-19 por 100.000 habitantes, possivelmente, a estrutura da saúde ofertada pelo estado pode afetar o limite de atendimento disponível. É possível construir perfis de mortalidade medidos pelo acesso de equipamentos de tratamento de saúde, ver trabalho de Moreira (2020).

Entretanto, os estados presentes nas regiões apresentam níveis diferentes de enfrentamento à pandemia, com níveis diferentes de estratégias de isolamento e outras medidas de prevenção à proliferação e contágio do vírus. Assim (ver Figura 1), tanto o nível de estrutura hospitalar do estado pode variar dentro de sua própria região, como se aproximar de outra região. Essa desigualdade de estrutura pode ser vista mesmo entre os municípios do estado com elevado IEH (SMOLSKI et al, 2020).

Para Noronha et al (2020) 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.

Apesar da distribuição espacial do índice nos diferentes estados e comportar de forma dessemelhante, faz-se necessária a confirmação 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)⁷. Destarte, os resultados foram capazes de confirmar que o IEH é autocorrelacionado espacialmente entre os estados brasileiros, na medida em que a hipótese nula de aleatoriedade espacial foi rejeitada.

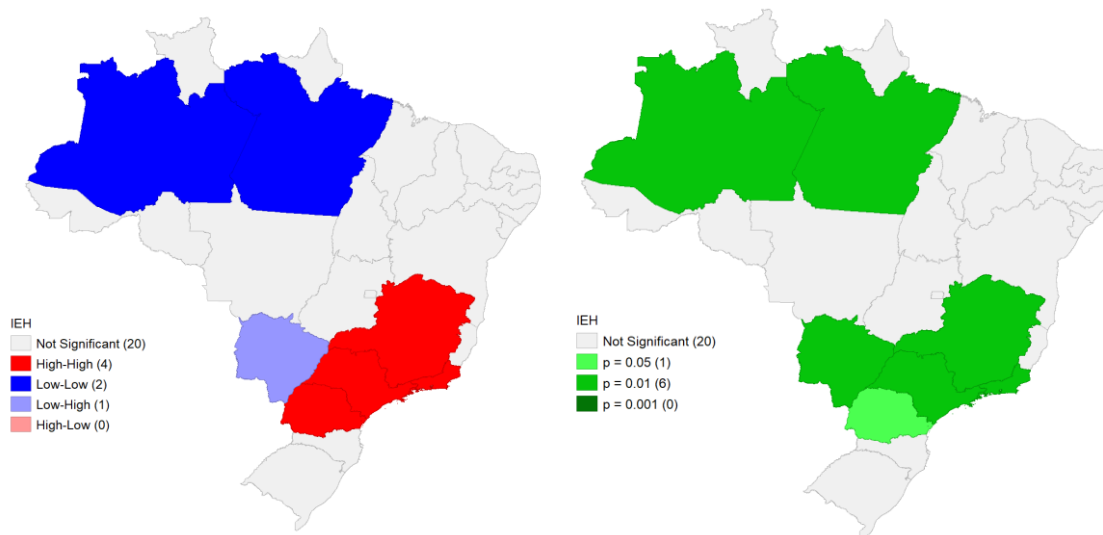
Confirmada a dependência espacial, foi possível analisar os padrões locais de associação espacial da estrutura hospitalar de enfrentamento à COVID-19 no país. Através do cálculo do I de Moran local, observou-se a formação de *clusters* do tipo baixo-baixo na região Norte do Brasil e do tipo alto-alto na região Sudeste. Ademais, encontrou-se um padrão de aglomeração do tipo baixo-alto no estado do Mato Grosso do Sul. Resultados de dependência

⁶ Destes nove estados, apenas Tocantins, Sergipe e Piauí, apresentam incidência de casos e mortes (por 100.000 habitantes) menores que a média nacional (MINISTÉRIO DA SAÚDE, 2020).

⁷ Os resultados para a matriz Torre foram semelhantes.

espacial significativa para estudos sobre COVID-19 também foram encontrados nos trabalhos de Pedrosa e Albuquerque (2020), e Rolim (2020). Na Figura 2 é possível observar a formação dos *clusters* no território brasileiro.

Figura 2 - *Clusters* e nível de significância alcançado através da AEDE



Fonte: Elaboração própria.

A existência de um *cluster* do tipo baixo-baixo significa que, estados com um baixo IEH estão também circundados por outros estados com baixo IEH. No caso do *cluster* do tipo alto-alto, o inverso ocorre. Ou seja, estados com elevada estrutura hospitalar estão rodeados por outros estados com características semelhantes neste aspecto, isto é, com alta estrutura hospitalar. O padrão de *cluster* tipo baixo-alto, por sua vez, indica que estados com baixo IEH estão cercados por outros estados que possuem um IEH 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.

5 CONCLUSÃO

Os valores obtidos no IEH, revelam a heterogeneidade e desigualdade de acesso da população brasileira ao atendimento hospitalar, evidenciadas pela amplitude do primeiro e último estado em termos de posição no IEH. Estes valores guardam correlação forte com o PIB e Índice de GINI. Inicialmente não foi tratada a causalidade entre esses valores, o que é sugerido para trabalhos futuros que ampliem o debate entre saúde, riqueza e desigualdade na realidade brasileira.

É possível notar que alguns estados se agruparam com outros de diferentes regiões, mesmo que não sejam estritamente vizinhos, o que ilustra como a questão espacial no estudo da saúde pode ser incluída, e faz-se relevante para o debate da infraestrutura hospitalar. Dentro de uma região há diferentes realidades, com escalas diferentes de estrutura hospitalar estadual.

Ressalta-se que estados dos agrupamentos 1 e 2 – Região Norte, e parte das Regiões Nordeste e Centro-Oeste - possuem baixos níveis de estrutura hospitalar, de forma que podem entrar rapidamente em colapso, diante de níveis próximos e elevados de velocidade de contágio, em comparação aos demais estados dos demais agrupamentos.

Este padrão também pode ser percebido em termos de *clusters* espaciais estatisticamente significativos. Desta forma é preciso atenção aos estados do Amazonas e Pará, por formarem um *cluster* baixo-baixo em termos do IEH, o que pode significar maior fragilidade destes estados no que se refere à capacidade de atendimento à população, principalmente em situações críticas, de choque elevado de demanda. Isto pode ser agravado pela distância entre esses estados e aqueles com maior IEH, para uma possível tentativa de transferência de pacientes graves para outros hospitais.

Espera-se que este estudo contribua com as políticas públicas voltadas à ampliação da estrutura hospitalar nos estados brasileiros. Recomenda-se que futuros trabalhos ampliem o estudo através de informações municipais, com índices dinâmicos.

REFERÊNCIAS

ALMEIDA, E. **Econometria espacial**. Campinas: Alínea, 2012.

ANSELIN, L. Local Indicators of Spatial Association – LISA. **Geographical Analysis**, v. 27, n. 2, p. 93-115, 1995.

ANS. **Beneficiários**. Disponível em: <http://www.ans.gov.br/anstabnet/cgi-bin/dh?dados/tabnet_br.def>. Acesso em: 29 jun. 2020.

CALLEGARI-JACQUES, Sidia M. **Bioestatística: princípios e aplicações**. Porto Alegre: Artmed, 2003.

COFEN. **Enfermagem em números**. Disponível em: <<http://www.cofen.gov.br/enfermagem-em-numeros>>. Acesso em: 12 jun. 2020.

DATASUS. **Leitos de internação**. Disponível em: <<http://tabnet.datasus.gov.br/cgi/deftohtm.exe?cnes/cnv/leiintbr.def>>. Acesso em: 26 jun. 2020.

_____. **Tabnet**. Disponível em: <<https://datasus.saude.gov.br/informacoes-de-saude-tabnet/>>. Acesso em: 11 jun. 2020a.

FÁVERO, L. P.; BELFIORE, P. **Manual de análise de dados**. Rio de Janeiro: Elsevier, 2017.

HAIR Jr., J. F. et al. **Análise multivariada de dados**. Bookman Editora, 2009.

IBGE. **Sistema IBGE de Recuperação Automática**. Disponível em: <<https://sidra.ibge.gov.br>>. Acesso em: 28 jun. 2020.

MINGOTI, S. A. **Análise de dados através de métodos de estatística multivariada: uma abordagem aplicada**. Editora UFMG, 2005.

MINISTÉRIO DA SAÚDE. **Coronavirus – COVID 19: O que você precisa saber**. Disponível em: <<https://coronavirus.saude.gov.br/>>. Acesso em: 26 jun. 2020.

_____. **COVID-19 no Brasil**. Disponível em: <<http://susanalitico.saude.gov.br/#/dashboard/>>. Acesso em: 4 de jul. 2020b.

_____. **Painel de leitos e insumos.** Disponível em: <<https://covid-insumos.saude.gov.br/paineis/insumos/painel.php>>. Acesso em: 7 jun. 2020a.

MOREIRA, R. da 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, n. 5, 2020.

NORONHA, Kenya Valeria Micaela de Souza 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, n. 6, 2020.

OMS. **Folha informativa – COVID-19: doença causada pelo novo coronavírus**, 2020.

Disponível em:

<https://www.paho.org/bra/index.php?option=com_content&view=article&id=6101:covid19&Itemid=875>. Acesso em: 04 jul. 2020.

OMS. **Novel coronavirus: China, 2020.** Disponível em: <<http://www.who.int/csr/don/12-january-2020-novel-coronavirus-china/en/>>. Acesso em: 26 jun. 2020a.

PEDROSA, N. L.; ALBUQUERQUE, N. L. S. de. Análise Espacial dos Casos de COVID-19 e leitos de terapia intensiva no estado do Ceará, Brasil. **Ciência e Saúde Coletiva**, v. 25, s. 1. Rio de Janeiro, junho, 2020.

PORTAL DA TRANSPARÊNCIA. **Recursos transferidos.** Disponível em:

<<http://www.portaldatransparencia.gov.br/transferencias>>. Acesso em: 10 jun. 2020.

_____. **Saúde: Distribuição das despesas com saúde por localidade.** Disponível em:

<<http://www.portaltransparencia.gov.br/funcoes/10-saude?ano=2020>>. Acesso em: 10 jun. 2020a.

PORTAL DE COMPRAS. **Painel de compras COVID-19.** Disponível em:

<<https://www.comprasgovernamentais.gov.br/index.php/transparencia/60-transparencia/1313-transparencia-dos-dados-de-compras-para-o-covid-19>>. Acesso em: 11 jun. 2020.

ROLIM, C. Correlação espacial da covid-19 em municípios do estado do Paraná. **Nota Técnica Nesde/UFPR 01/2020.** Curitiba: UFPR e SESA, 2020.

SILVA, H. B. **Mais Médicos e o Médicos pelo Brasil**, 2019. 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>. Acesso em: 26 jun. 2020.

SILVA, Selma Gomes da. Pandemia e afetações das emoções: reflexões sobre a realidade da Covid-19 no estado do Amapá. **Revista Brasileira de Sociologia da Emoção**, v. 19, n. 55, abril de 2020. Suplemento Especial – Pensando a Pandemia à luz da Antropologia e da Sociologia das Emoções, p. 113-124, maio de 2020.

SMOLSKI, F. M. da S. et al. **Disponibilidade de leitos hospitalares e ventilação mecânica no Rio Grande do Sul: desafios no enfrentamento da COVID-19.** Nota Técnica 1, 2020.

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>. Acesso em: 25 jun. 2020.

TSANG, K. W. et al. A cluster of cases of severe acute respiratory syndrome in Hong Kong. **The New England Journal of Medicine**, v. 348, n. 20, p. 1975-1983, 2003.

ZHU, N. et al. A novel coronavirus from patients with pneumonia in China, 2019. **The New England Journal of Medicine**, v. 382, n. 8, p. 727-733, 2020.