

Análise da relação entre o índice IDHM e a densidade demográfica com a incidência de Covid-19 no município de São Paulo - SP

RESUMO

A velocidade da disseminação da Covid-19 levou à adoção de uma série de medidas pelos governos do mundo todo visando a proteção social. Há um esforço coletivo para identificar quais fatores influenciam na transmissão. Portanto, este estudo tem o objetivo de analisar o quanto os índices de desenvolvimento de São Paulo (IDHM) e a densidade demográfica podem contribuir na identificação de distritos que necessitem de gerenciamento prioritário. O estudo se caracteriza sendo ecológico, exploratório e analítico e para a realização do teste de hipóteses, aplicou-se um modelo de regressão linear múltipla (RLM). O município de São Paulo é dividido em 96 distritos. Foram observados dados sobre os casos da doença, sobre densidade demográfica e sobre o IDHM nestes distritos por meio da RLM. Os resultados apontam que o IDHM se relaciona inversamente ao número de óbitos, contudo, a densidade demográfica não se mostrou como indicativo de vulnerabilidade local de maneira isolada. Estas variáveis analisadas conjuntamente apontam os distritos em que ações de combate e prevenção deverão ser urgentes, assim como, a elaboração de planos que conduzam à um planejamento urbano que favoreça a qualidade de vida e adote medidas compatíveis com os princípios da cidade resiliente.

PALAVRAS-CHAVE: Covid-19, planejamento urbano, pandemia, indicadores de desenvolvimento, cidades inteligentes.

Daniela Belchior Brito

daniela.belchior@gmail.com

Universidade Nove de Julho, São Paulo, São Paulo, Brasil.

José Eduardo Storopoli

josees@uni9.pro.br

Universidade Nove de Julho, São Paulo, São Paulo, Brasil.

João Alexandre Paschoalin Filho

jalexandre@uni9.pro.br

Universidade Nove de Julho, São Paulo, São Paulo, Brasil.

Rafael Urnhani Batista da Silva

rafael.urnhani@gmail.com

Universidade Nove de Julho, São Paulo, São Paulo, Brasil.

Osmar da Silva Júnior

osmarirlog@gmail.com

Universidade Nove de Julho, São Paulo, São Paulo, Brasil.

1 INTRODUÇÃO

O estado de pandemia pela contaminação da COVID-19 foi declarado pela OMS em 11 de março de 2020. A pandemia COVID-19 resultou em 295.577.202 casos confirmados e 5.460.818 mortes em todo o mundo até o dia 05/01/2021, de acordo com o portal online do Centro de Pesquisas do Coronavírus Johns Hopkins (2021). A doença é altamente infecciosa e seus principais sintomas incluem tosse seca, fadiga, mialgia, febre e dispneia (ZHONG et al., 2020). Dada a alta concentração da população e das atividades econômicas nas cidades, elas tendem a apresentar focos de infecções por COVID-19. Segundo Guimarães et. al. (2020) a difusão espacial da contaminação pelo novo coronavírus deve ser enfrentada de uma forma diferenciada em relação aos problemas usuais de saúde pública devido à dificuldade do combate à doença em um mundo globalizado, o que altera as escalas da vida e da economia, expandindo as conexões causadas por um mundo mais complexo, e desta forma, exigindo um direcionamento sobre a problemática. Consequentemente, muitos pesquisadores estão se esforçando para explorar a dinâmica da pandemia em áreas urbanas a fim de compreender os impactos do COVID-19 nas cidades (HOLANDA, 2020).

Tais evidências indicam que os impactos e os mecanismos de resposta diferem de um contexto para outro, e nem sempre é possível apresentar recomendações idênticas que se aplicam a diferentes cidades e países (STIER, BERMAN & BETTENCOURT, 2020). Além disso, altas densidades populacionais significam uma maior vulnerabilidade das cidades durante uma pandemia (DESAI, 2020). Contudo, o adensamento demográfico e a distribuição espacial dos elementos urbanos, tratados por Velavan e Meyer (2020), demonstram um grau de suscetibilidade, interferindo na velocidade de contágio da doença. Desta forma, também é observada uma distribuição heterogênea nos territórios municipais em relação à qualidade da oferta dos serviços de saúde e educação, assim como, disponibilidade de acesso aos meios de transporte.

Nesse contexto, a densidade demográfica, que também pode ser chamada de densidade populacional ou população relativa, é a medida expressa pela relação entre a população e a superfície do território, onde nas regiões superpovoadas o número de indivíduos por unidade de área é grande, ao passo que numa região fracamente povoada esse número é pequeno (FUNBEC, 1983). Quando muito alta, aliada à baixos níveis de renda e educação, interfere nas condições gerais de vida, como por exemplo: na perda de imunidade devido nutrição inadequada, na capacidade de manter a higiene e na configuração de moradias com habitações lotadas e inseguras, aumentando o risco de contaminação destas pessoas (ALVES E LIMA, 2020). Portanto, os determinantes sociais da saúde, incluindo a pobreza, o ambiente físico da habitação e questões étnicas, também estão associados ao grau de suscetibilidade, morbidade e incidência de casos da doença do vírus da COVID-19 (ABRAMS & SZEFLER, 2020).

No Brasil, o primeiro caso registrado da doença foi em 25 de fevereiro de 2020 na cidade de São Paulo (ITO & PONGELUPPE, 2020), sendo a cidade responsável pela disseminação de mais de 80% dos casos durante as primeiras semanas do mês de março para outros municípios brasileiros, o que pôde rotular a cidade como uma superdisseminadora da COVID-19 (NICOLELIS et. al, 2021). Apesar de ser o município mais rico do Brasil, São Paulo apresenta grandes desigualdades sociais e econômicas entre seus 96 distritos, o que dificulta muito o acesso da população de

baixa renda à moradia, obrigando as famílias desse estrato a viver em moradias improvisadas e favelas (FERREIRA, 2020). No município, o agravamento das doenças respiratórias no Sistema Único de Saúde (SUS) durante a pandemia da COVID-19 tornou o sistema frágil quanto à assistência em saúde (DOS SANTOS et al., 2021).

Sendo assim, as configurações urbanas que possuem a capacidade de impulsionar a disseminação da contaminação podem ser mensuradas e analisadas por meio do Índice de Desenvolvimento Humano Municipal (IDHM) estabelecido para cada localidade. Os índices IDHM são usados como medidas comparativas para classificar regiões com base em seu grau de desenvolvimento humano (BARBOSA et al., 2017). Neste cenário, o desenvolvimento é compreendido como um processo de expansão das liberdades reais que os cidadãos usufruem (SEN, 2000). Os economistas Mahbub Haq e Amartya Sen, desenvolveram o Índice de Desenvolvimento Humano (IDH) em 1990. Este índice é mundialmente adotado e calculado a partir das dimensões de longevidade, educação e renda (OLIVEIRA et al., 2020), assim como o IDHM e varia de 0 a 1 e é resultante de dados do Censo Demográfico Brasileiro com o objetivo de medir o nível de desenvolvimento dos municípios brasileiros.

Diante do exposto, este estudo justifica a importância da análise atualizada da distribuição epidemiológica da COVID-19 em todos os distritos do município de São Paulo, assim como, relacionar com o desenvolvimento socioeconômico, utilizando como indicador o IDHM, de forma a considerar que as pandemias expõem a vulnerabilidade e a resiliência do sistema urbano de forma expansiva e também servem como agentes de mudança para o planejamento de cidades e regiões resilientes globalmente (BANAI, 2020). O resultado desta análise pode indicar direções para ações futuras que conduzam à proteção social em eventos semelhantes à pandemia.

Portanto, este estudo tem como objetivo analisar o quanto os índices de desenvolvimento de São Paulo e a densidade demográfica, utilizados no planejamento urbano, podem contribuir na identificação de distritos que necessitem de gerenciamento prioritário no enfrentamento da contaminação pelo novo coronavírus. Esta reflexão se torna urgente e justifica este estudo como medida para maximizar o poder de resiliência das cidades, visto que, as comunidades sustentáveis serão aquelas que viabilizem uma arquitetura adequada de proximidade e distanciamento alinhadas à critérios de adaptação que permitam responder de acordo com os vários requisitos de vida (SAKELLARIDES, 2020).

Para este estudo, foi desenvolvido um modelo de regressão linear múltipla (RLM) para prever o quanto a densidade demográfica local, aliada ao valor de IDHM, indicam uma relação com as taxas de contaminação observadas. Diante desta análise, percebe-se que a configuração atual desigual das comunidades faz com que cada localidade tenha um impacto diferente decorrente da pandemia pelo novo coronavírus. Desta forma, faz-se necessária a adoção de estratégias urbanas que proporcionem proteção à saúde e forneçam oportunidades de isolamento social adequado aos cidadãos. Para isso, a análise socioespacial se mostra como um componente primário na composição de embasamentos para um novo direcionamento do planejamento urbano.

2 REFERENCIAL TEÓRICO

A rápida contaminação a disseminação da doença foi sendo responsável pela sobrecarga do sistema de saúde pública em diversos países do mundo, tanto desenvolvidos, quanto em desenvolvimento (MACIEL, SILVA & FARIAS, 2020). O maior problema da doença foi a inexistência de medicamentos ou vacina que pudessem conter de imediato a disseminação no mundo, portanto a tendência apresentada era de que a mesma se espalhasse em uma velocidade maior em locais de maior aglomeração, sendo que as cidades se apresentam como um espaço propício à veiculação do vírus (JARDIM & BUCKERIDGE, 2020). Este fato, demonstra que a adoção de medidas que pudessem minimizar a taxa de contaminação fosse urgente. Neste sentido, The Lancet (2020) destacou que as principais estratégias de controle da Covid-19 foram: o distanciamento social e a lavagem frequente das mãos. Contudo, estas ações foram difíceis de praticar por milhões de cidadãos que moram em comunidades muito adensadas ou em moradias precárias, sofrendo com as consequências da falta de saneamento e de acesso à água potável (FERREIRA, 2020).

Este cenário de discrepâncias sociais foi alcançado devido ao aumento contínuo da população humana, à aglomeração, ao movimento humano, à alteração ambiental e complexidade ecossistêmica relacionada a atividades e criações humanas (MORENS, 2020). Já no estudo de Leiva et al. (2020), os autores relatam que foi observada uma forte disseminação da doença nas periferias, demonstrando assim a vulnerabilidade dos cidadãos à doença em vista das aglomerações, moradias com muitos habitantes, saneamento deficiente, precariedade nos transportes e falhas no sistema de saúde para o tratamento da população. Importante apontar que cidadãos, inclusive nas faixas etárias mais baixas, com status socioeconômico desfavorecido apresentaram maior letalidade em decorrência da contaminação pela COVID-19.

Para analisar possíveis soluções sociais para a crise atual, é necessário entender que historicamente, as pandemias atingiram minorias e populações de menor poder econômico de maneira desigual (SHARIFI & GARMSIR, 2020). Os indivíduos com maior risco costumam ser aqueles já marginalizados - os pobres e as minorias que enfrentaram discriminação sendo prejudicados em relação à saúde ou limitados no acesso à cuidados médicos, mesmo em tempos pré-pandêmicos, conforme Wade (2020). Assim, pandemias ainda afetaram a desigualdade social existente, minando ou reforçando as estruturas de poder anteriores.

Estes fatores dificultam a adesão de ações de combate à transmissão da COVID-19 através do distanciamento social e às determinações de quarentena, o que foi observado por Wasdani e Prasad (2020) por meio de moradores de favela urbana, evidenciando que o distanciamento social é mais uma aspiração do que uma realidade alcançável sem o apoio econômico direcionado aos mais socialmente vulneráveis da sociedade.

No Brasil, Oliveira e Arantes (2020) mostram que a população que vive nas regiões de “Miolo” e “Subúrbio Ferroviário” seria exposta a um perigo maior devido às taxas de pobreza e habitação precária. Estes bairros periféricos possuem alta densidade demográfica, deficiências nos serviços de saúde e falta de saneamento básico, o que contraria as recomendações de higiene e isolamento social.

Assim, a densidade por si só não pode ser um preditor da propagação de doenças infecciosas, outros fatores, como o estado de desenvolvimento, a disponibilidade de medidas de prevenção e resposta, a extensão da adesão às medidas de saneamento e distanciamento social, e a extensão do acesso a amenidades e a infraestrutura de saúde pública também são importantes. Embora o aumento da densidade possa ser um fator que permite a transmissão de doenças infecciosas, as cidades de alta densidade costumam estar mais bem preparadas e têm mais acesso aos recursos necessários para uma resposta oportuna necessária para prevenir a propagação de vírus (CONNOLLY et al., 2020). Desta forma, os impactos da pandemia no aspecto social no geral, expôs as desigualdades sociais, dificultando a recuperação das comunidades (SHARIFI & GARMSIR, 2020).

No Brasil, o governo federal publicou a Portaria n. 188 (2020) do Ministério da Saúde (MS), em 3 de fevereiro de 2020 declarando emergência em Saúde Pública de Importância Nacional, e a Lei n. 13.979 (2020), de 6 de fevereiro de 2020 que segue as orientações da OMS para o enfrentamento da emergência, ressaltando ações de isolamento social, de quarentena e de restrições em rodovias, portos e aeroportos (PEREIRA, OLIVEIRA & SAMPAIO, 2020). Estas determinações afetaram a todos os Estados e municípios.

A cidade de São Paulo, já apresentava uma série de vulnerabilidades, sendo uma delas a desigualdade socioeconômica advinda de deficiências na elaboração e aplicação de políticas públicas no passado, conforme Buckeridge e Phillipi Junior (2020). Através deste histórico, São Paulo se tornou uma das cidades mais populosas do mundo, com 12 milhões de habitantes (SLOVIC et al., 2019). Neste contexto, no boletim do Centro de Vigilância Epidemiológica - CVE - "Prof. Alexandre Vranjac" disponibilizado pelo portal online do Governo de São Paulo, foram divulgados até 25/09/2020 os resultados da disseminação da contaminação no município pelo novo coronavírus, sendo 288.081 casos registrados e 12.547 óbitos. O contágio no município ocorreu de maneira desigual, portanto, afetando mais gravemente algumas localidades do que outras, esse fato fica evidente quando se analisa distribuição dos registros da doença por distrito municipal.

A Prefeitura Municipal de São Paulo apresenta o município dividido em 96 distritos e cada distrito possui um valor para o (IDHM) revisto periodicamente. A separação do município por distritos permite uma análise espacial diferenciada, MacEachren (2004) aponta que, a análise espacial com base em ferramentas quantitativas contribui para evidenciar a importância do arranjo espacial na distribuição do fenômeno mapeado, no caso, o impacto da contaminação pelo Covid-19.

Este arranjo urbano pode ser observado pelos tomadores de decisão, políticos, planejadores e pesquisadores no sentido de priorizar ações de proteção social e de estratégias para o combate à pandemia pela Covid-19. Neste contexto, abrem-se oportunidades e apresentam-se desafios na gestão urbana.

Ultramari, Saldiva e Levy (2020) apontam que o enfrentamento às pandemias requer o suporte da ciência, o que considera as evidências como base para a elaboração de políticas públicas e uma gestão urbana direcionadas a cidades inteligentes e resilientes. Este conceito está ligado à inovação, à junção de competências e ao embasamento científico que, juntos, conduzem à uma melhoria da vida urbana. Neste sentido, Sakellarides e Kickbush (2020) indicam que os preparativos para esta melhoria da qualidade de vida urbana sejam previstos pela

cidade inteligente através do entendimento do planejamento e como este é realizado, construindo valores importantes para a comunidade, contribuindo para a melhoria da competência dos cidadãos, assim como a participação e o envolvimento. Por meio desse envolvimento, um sentimento de domínio pode começar a substituir o sentimento de medo e incerteza da sociedade. Uma comunidade de aprendizagem com alta coesão social e baixa desigualdade social será mais bem preparada para responder à fenômenos como a pandemia pelo Covid-19. Esta crise humanitária, portanto, oferece uma oportunidade de compreender e aplicar a tecnologia da cidade inteligente no bem-estar social e gestão de crises (JAMES, JALINSINSKA & SMITH, 2020).

Portanto, a crise humanitária enfrentada atualmente oferece uma oportunidade de compreender e aplicar a tecnologia da cidade inteligente no bem-estar social e gestão de crises, conforme descrito por James, Jalisinska e Smith (2020). Já Kunzman (2020) complementa que, a crise da COVID-19 também pode impulsionar o desenvolvimento da cidade inteligente, pois, conforme evidenciado, o cotidiano das pessoas vem sendo alterado pela crescente preferência pelo teletrabalho, telemedicina, sistemas de vigilância e comércio e educação online.

Neste sentido, para a preparação à uma grande epidemia é preciso entender não apenas o vírus e como ele se espalha, mas também o funcionamento da cidade, suas organizações e como operam, as comunidades e suas relações, assim como o entendimento sobre os indivíduos e como eles fazem escolhas (SAKELLARIDES, 2020).

3 METODOLOGIA

Trata-se de um estudo ecológico, exploratório e analítico (LIMA-COSTA; BARRETO, 2003; MACIEL *et al.*, 2020), cujas unidades de análise foram os 96 distritos do município de São Paulo. O objetivo deste estudo é analisar o quanto os índices de desenvolvimento de São Paulo, utilizados no planejamento urbano, podem contribuir na identificação de distritos que necessitem de gerenciamento prioritário no enfrentamento da contaminação pelo novo coronavírus, portanto aplicou-se uma regressão linear múltipla (RLM). A análise de regressão é uma técnica estatística indicada para estudar o relacionamento entre as variáveis (dependentes e independentes), além de predizer o valor de uma variável específica com base em uma coleção de variáveis, assim é preciso analisar pressupostos estatísticos como normalidade dos resíduos e homocedasticidade. (JOHNSON & WICHERN, 2002). Para a realização do teste de hipóteses, utilizou-se a análise de RLM que permite extrair o efeito simultâneo dos constructos latentes e das variáveis de controle sobre a variável de resultado (HAIR *et al.*, 2014).

A abordagem desta pesquisa é de natureza quantitativa. De acordo com Malhotra (2001), a abordagem quantitativa procura mensurar os dados e utilizar alguma forma da análise estatística. A pesquisa também foi realizada com abordagem descritiva, que é um tipo de pesquisa conclusiva que tem como finalidade central a definição de algo, através de formulações prévias de hipóteses específicas (MALHOTRA, 2001). As pesquisas descritivas são identificadas por serem bem estruturadas e apresentarem objetivos bem definidos e métodos formais (MATTAR *et al.*, 1999). Para testar as hipóteses, utilizou-se a análise de RLM com o software JASP, onde é possível analisar o efeito de variáveis de

predição (independentes) em uma variável de resultado (dependente) (MALHOTRA, 2001).

O uso da técnica de RLM busca analisar a relação de óbitos relacionados à COVID-19, a partir dos dados divulgados pela Secretaria de Estado da Saúde (SES) de São Paulo em 10 de julho de 2020. Para a densidade demográfica e o IDHM, que considera indicadores de longevidade, educação e renda da população brasileira, utilizou-se o Atlas do Desenvolvimento Humano no Brasil, de 2013, elaborado pelo Programa das Nações Unidas para o Desenvolvimento (PNUD). Por se tratar de dados não coletados pelo pesquisador, e sim obtidos a partir de pesquisa documental e sem tratamento científico, esses são considerados dados secundários (MATTAR *et al.*, 1999).

Na análise do município de São Paulo, foram considerados os dados dos 96 distritos paulistanos com suas respectivas densidades demográficas medidas em habitante por quilômetro quadrado, obtidos na página da Secretaria de Desenvolvimento Urbano da Prefeitura Municipal de São Paulo. O IDHM pôde ser encontrado no Atlas do Trabalho e Desenvolvimento da Cidade de São Paulo, publicado pela Secretaria de Desenvolvimento Econômico e Trabalho em 2007. O IDHM foi construído pelo Programa das Nações Unidas para o Desenvolvimento (PNUD), juntamente ao Instituto de Pesquisa Econômica Aplicada (IPEA) e a Fundação João Pinheiro, representando assim o desenvolvimento humano local através da análise dos eixos: longevidade, educação e renda. Este índice é classificado em: muito baixo (de 0 a 0,499), baixo (de 0,500 a 0,599), médio (de 0,600 a 0,699), alto (de 0,700 a 0,799) e muito alto (de 0,800 a 1). Desta forma, o IDHM permite comparar o atendimento às necessidades básicas e demonstrar caminhos para o desenvolvimento das capacidades locais, visto que, regiões com maior IDHM tendem a apresentar melhor desempenho na alocação de recursos, segundo Bohn, Ervilha e Dalberto (2016).

Na cidade de São Paulo há atualização diária do número total de casos divulgados pela Secretaria Municipal da Saúde (SMS), no entanto, a pesquisa valeu-se do Relatório Situacional publicado em 29 de maio de 2020¹, que apresenta dados separados por distrito. O período selecionado para esta análise se justifica pela intenção de analisar como a primeira onda da contaminação pela COVID-19 se comportou nos diferentes distritos, momento em que não havia informações científicas sobre quais medidas de proteção à saúde adotar mediante o evento inédito.

Desta forma, a partir do estudo destes dados através da RLM verificou-se a relação entre a quantidade de óbitos de acordo com o IDHM e a densidade demográfica local de forma a analisar as maneiras nas quais as variáveis independentes estão relacionadas as outras (DANCEY e REIDY, p. 384, 2013). Este modelo fornece uma medida do efeito que a densidade demográfica e o IDHM de cada localidade têm sobre a quantidade de óbitos, objetivando prever esta quantidade de acordo com as variáveis adotadas. A medida deste efeito é dada pelos valores de R, R² e R² ajustado, indicando que, nos resultados obtidos, quanto mais próximo de 1 estes valores, melhor o modelo prediz de acordo com os valores observados (FIELD, p. 170, 2009).

¹ Disponível em:

https://www.prefeitura.sp.gov.br/cidade/secretarias/upload/saude/COVID19_Relatorio_Situacional_SMS_20200529.pdf.

Acesso em 13/01/2022.

Diante disso, torna-se importante avaliar o poder de explicação do modelo que verifica se o ajuste do modelo é adequado e se está intimamente ligado à estatística F que é simplesmente uma razão de duas variâncias. As variâncias são medidas de dispersão, ou até que ponto os dados estão dispersos em relação à sua média, assim, valores maiores representam maior dispersão (HAIR *et al.*, 2014; FIELD, 2009). O coeficiente de determinação múltipla que informa o poder de explicação do modelo em função das p variáveis independentes consideradas, dado por R^2 . Quando o ajuste é bom, o modelo explica boa parte da variação total e, conseqüentemente, o valor de R^2 é próximo de 1, ou seja, o coeficiente de determinação é uma medida da qualidade do ajuste (HAIR *et al.*, 2014; FIELD, 2009).

A quantidade de óbitos se apresenta como a variável dependente e o IDHM e a densidade demográfica são as variáveis independentes. Para esta análise utilizou-se o software JASP (JASP Team, 2020) versão 0.12.2, um programa de estatísticas de código aberto e gratuito, apoiado financeiramente por várias universidades e fundos de pesquisa.

4 RESULTADOS E DISCUSSÃO

Utilizou-se a técnica de RLM, a qual refere-se a uma equação que busca explicar a influência de variáveis independentes em uma variável dependente (MELLO & PETERNELLI, 2013). Para o teste de RLM as variáveis foram selecionadas de acordo com a representatividade do R de Pearson e com o valor de significância p inferior a 0,001, indicando um nível de confiança rigoroso e menor probabilidade de ocorrência de um erro alfa (LEVIN, 1978). Sendo assim, verificou-se que as variáveis IDHM e densidade demográfica medida em habitantes por quilômetro quadrado em cada um dos 96 distritos do município de São Paulo apresentaram relacionamentos mais relevantes entre si e também em relação ao número de óbitos registrados pelo COVID-19. A seguir, os distritos da capital de São Paulo com os respectivos valores relacionados às variáveis selecionadas:

Tabela 1 - Dados relacionados aos distritos do município de São Paulo

Distrito	Óbitos	E-Sus	Idhm	Hab./km ²	Distrito	Óbitos	E-Sus	Idhm	Hab./km ²
Vila Sônia	46	1172	0,895	10954	Lapa	46	570	0,941	6574
Vila Prudente	88	913	0,867	10529	Lajeado	102	2494	0,748	12093
Vila Medeiros	106	1142	0,836	16873	José Bonifácio	80	1857	0,804	8803
Vila Matilde	83	1219	0,864	11792	Jardim São Luís	157	4141	0,796	10845
Vila Mariana	79	1265	0,95	15173	Jardim Paulista	45	968	0,957	14540
Vila Maria	76	2092	0,824	9616	Jardim Helena	103	1452	0,751	14840
Vila Leopoldina	20	318	0,907	5484	Jardim Ângela	156	4835	0,75	7899
Vila Jacuí	94	1601	0,779	18490	Jaraguá	101	2445	0,791	6696
Vila Guilherme	38	350	0,868	7874	Jaguaré	36	553	0,849	7555
Vila Formosa	73	894	0,884	12811	Jaguara	14	301	0,863	5412
Vila Curuçá	92	1944	0,765	15366	Jaçanã	53	622	0,816	12129
Vila Andrade	63	3024	0,853	12332	Jabaquara	123	1880	0,892	15871
Tucuruvi	64	572	0,858	10938	Itaquera	139	3307	0,795	14032
Tremembé	149	1405	0,826	3504	Itaim Paulista	122	2686	0,762	18673
Tatuapé	77	982	0,936	11180	Itaim Bibi	60	1037	0,953	9351
Socorro	21	194	0,841	2929	Ipiranga	78	1132	0,906	10178
Sé	22	248	0,858	11262	Iguatemi	99	2498	0,751	6513
Saúde	83	1052	0,942	14694	Guaianases	80	1281	0,768	17882
Sapopemba	205	3896	0,786	21076	Grajaú	183	6726	0,754	3922
São Rafael	61	2512	0,767	11934	Freguesia do Ó	124	1483	0,85	13555
São Miguel	78	1099	0,808	12277	E. Matarazzo	77	1410	0,801	13059
São Mateus	121	2181	0,804	10908	Cursino	82	1082	0,885	8523
São Lucas	93	1177	0,864	14378	Consolação	40	446	0,95	15504
São Domingos	49	1034	0,854	8484	Cidade Tiradentes	131	3027	0,766	14100
Santo Amaro	44	648	0,943	4587	Cidade Líder	79	2227	0,817	12411
Santana	92	707	0,925	9428	Cidade Dutra	110	2039	0,815	6702
Santa Cecília	71	544	0,93	21466	Cidade Ademar	151	2462	0,825	22223
Sacomã	144	3027	0,839	17454	Casa Verde	75	603	0,874	12060
Rio Pequeno	67	1178	0,855	12212	Carrão	76	641	0,886	11104
República	49	377	0,901	24774	Capão Redondo	163	4301	0,782	19759
Raposo Tavares	58	1187	0,819	7950	Cangaíba	106	2381	0,801	8539
Ponte Rasa	71	1119	0,834	14671	Campo Limpo	86	4117	0,806	16513
Pirituba	105	1611	0,841	9821	Campo Grande	58	716	0,921	7688
Pinheiros	39	577	0,96	8171	Campo Belo	63	483	0,935	7472
Perus	53	2229	0,772	3355	Cambuci	29	298	0,903	9474
Perdizes	56	694	0,957	18223	Cachoeirinha	140	3653	0,802	10791
Penha	92	1468	0,865	11312	Butantã	28	325	0,928	4336
Pedreira	59	1358	0,777	7717	Brasilândia	209	4943	0,769	12615
Pq. do Carmo	47	1309	0,799	4432	Brás	31	292	0,868	8361
Pari	22	344	0,863	5965	Bom Retiro	27	269	0,847	8473
Parelheiros	77	2883	0,747	855	Belém	44	544	0,897	7510
Morumbi	26	1245	0,938	4119	Bela Vista	28	749	0,94	26715
Mooca	69	668	0,909	9834	Barra Funda	15	232	0,917	2568
Moema	42	781	0,961	9263	Artur Alvim	97	1874	0,833	15950
Marsilac	7	136	0,701	41	Aricanduva	61	1427	0,83	13579
Mandaqui	85	912	0,885	8212	Anhanguera	30	1308	0,774	1978
Limão	79	1086	0,847	12735	Alto de Pinheiros	33	273	0,955	5600
Liberdade	52	596	0,936	18674	Água Rasa	74	897	0,886	12313

Fonte – Dados da pesquisa.

Desta forma, é possível observar a quantidade de óbitos e casos confirmados da COVID-19 (E-SUS) divulgados no relatório situacional durante o mês de maio de 2020 relacionados ao IDHM de cada distrito e a densidade demográfica. Com estes dados, foi possível apresentar na tabela 2 a descrição estatística, onde são apontados a média, o desvio padrão e os valores mínimo e máximo de cada variável da amostra:

Tabela 2 - Descrições estatísticas das variáveis relacionadas aos distritos municipais, tais como: média, desvio padrão, valores mínimos e máximos

Descrição Estatística				
	ÓBITOS	E-SUS	IDHM	HAB/KM²
Válidos	96	96	96	96
Omissos	0	0	0	0
Média	77,406	1.502,677	0.852	11.035,542
Desvio Padrão	42,364	1.232,776	0.065	5.221,350
Mínimo	7,000	136,000	0.701	41,000
Máximo	209,000	6.726,000	0.961	26.715,000


Fonte – Dados da pesquisa.

A descrição estatística apresenta que a média de óbitos nos distritos do município de São Paulo no período selecionado foi de 77 mortes, sendo que o distrito que teve menos óbitos foi o Marsilac que contabilizou 7 mortes e o distrito mais afetado pela contaminação foi Brasilândia que levou à óbito 209 mortes até o período considerado para este estudo.

A média de casos confirmados da doença nos distritos foi de 1.500 casos, sendo que o distrito menos afetado registrou 136 casos (Marsilac) e o distrito mais afetado (Grajaú) 6.726 casos dentro do mesmo período. O distrito de Bela Vista apresentou a maior densidade demográfica, com 26.715 habitantes por quilômetro quadrado e o distrito com menor densidade demográfica é o Marsilac, que registra 41 habitantes por quilômetro quadrado.

De acordo com os valores de máximo e mínimo apontados na tabela 2, o IDHM considerado nestes distritos vai de 0,7 (alto) à 0,96 (muito alto). Na escala com as faixas de desenvolvimento humano apresentada na figura 1 abaixo é possível observar como ocorrem as classificações em relação às grandezas do IDHM:

Figura 1 - Faixas de Desenvolvimento Humano



Fonte: Programa das Nações Unidas para o Desenvolvimento. Disponível em: <https://www.br.undp.org/content/brazil/pt/home/idh0/conceitos/o-que-e-o-idhm.html>. Acesso em 12/01/2022.

Esta escala é aplicada a todos os municípios do Brasil e, no caso de São Paulo, o IDHM foi calculado considerando a divisão entre os distritos, o que demonstra a variação das condicionantes dentro do próprio município. Sendo assim, alguns distritos puderam ser selecionados de acordo com as maiores variações de dados, ou seja, os distritos com as maiores e menores densidades demográficas e com os maiores e menores números de pessoas contaminadas. Nesta análise, os grupos de distritos que apresentam comportamento semelhante entre si na variação do número de casos, óbitos e densidade demográfica foram apontados na Tabela 3 e numerados de acordo com a característica de comportamento dos dados.

Tabela 3 - Distritos que apresentaram variações significativas entre óbitos, casos de COVID-19 e densidade demográfica.

	Distrito	Óbitos	E-SUS	IDHM	Hab./km²	hab/ha
1	Santa Cecília	71	544	0,93	21466	214,66
	República	49	377	0,901	24774	247,74
	Bela Vista	28	749	0,94	26715	267,15
2	Sapopemba	205	3896	0,786	21076	210,76
	Cidade Ademar	151	2462	0,825	22223	222,23
3	Tremembé	149	1405	0,826	3504	35,04
	Grajaú	183	6726	0,754	3922	39,22
4	Marsilac	7	136	0,701	41	0,41

Fonte: Dados da Pesquisa.

Na análise dos dados selecionados na Tabela 3 foi possível destacar que os distritos agrupados de Bela Vista, Santa Cecília e República (1) apresentam números baixos de óbitos e casos registrados pela COVID-19, estão em uma localidade classificada como IDHM muito alto (e acima de 0,9) e caracterizam-se pela densidade demográfica elevada. Estes distritos se assemelham entre si pelos comportamentos dos dados apresentados e também pelas características físicas por serem distritos centrais no município de São Paulo. O IDHM destes distritos indica que se trata de uma região que favorece o acesso à serviços públicos, em especial aos serviços de saúde relacionados à longevidade e à um local em que a população possui maior renda e escolaridade.

Em contrapartida, embora com densidades também relativamente altas, os distritos de Sapopemba e Cidade Ademar (2) apresentaram elevados números de óbitos e casos da COVID-19. Estes distritos se caracterizam por apresentarem IDHM mais baixos entre os destacados e estão localizados em regiões mais periféricas do município. Nestas duas situações, a densidade demográfica permanece alta, contudo, há alterações drásticas na quantidade de pessoas atingidas pela contaminação. A localização destes distritos, assim como a caracterização física dos mesmos, ou seja, as características das moradias e acesso aos serviços de saúde são diferenciadas e podem ser observadas pela diferença do IDHM, o que pode indicar condições mais deficientes de acesso à serviços de saúde, menor renda e escolaridade dos cidadãos residentes nestes distritos.

Nos distritos de Tremembé e Grajaú (3), opostamente, as densidades demográficas apresentadas se caracterizam por serem baixas, contudo, os números dos cidadãos impactados pela COVID-19 foram altos e nestas localidades o IDHM é intermediário dentre os destacados. Estes distritos, possuem

localizações periféricas, próximas aos extremos da cidade. Esta característica se relaciona à maiores distâncias ao centro da cidade, o que contribui para a necessidade maior do uso de transportes públicos para deslocamento para as regiões centrais.

Já no distrito de Marsilac (4) todos os dados apresentaram-se como baixos dentre os selecionados. Este distrito se caracteriza pela extensa área, o que confere uma densidade demográfica menor e está localizado no limite da região sul do município, o que dificulta o acesso às regiões centrais da cidade por meio de transporte público. O IDHM neste distrito, é o mais baixo dentre os selecionados, característico dos distritos de regiões periféricas. A distribuição geográfica destes distritos pode ser observada na Figura 4. Assim, observou-se que os números de casos variaram nos distritos e estas variações puderam apresentar relações com o IDHM e a densidade demográfica de cada localidade, desta forma, as correlações entre as variáveis, calculadas por meio do JASP foram apresentadas em uma matriz de correlação conforme tabela 4 abaixo:

Tabela 4 - Análise das correlações entre as variáveis selecionadas referentes aos dados por distrito do município de São Paulo com R de Pearson, p-valor e intervalo de confiança (IC).

Correlação de Pearson					
Variável	ÓBITOS	HAB./KM²	IDHM	E-SUS	
1. ÓBITOS	R de Pearson	—			
	p-valor	—			
	Máximo 95% IC	—			
	Mínimo 95% IC	—			
2. HAB./KM ²	R de Pearson	0.342	—		
	p-valor	< .001	—		
	Máximo 95% IC	0.508	—		
	Mínimo 95% IC	0.152	—		
3. IDHM	R de Pearson	-0.471	0.065	—	
	p-valor	< .001	0.529	—	
	Máximo 95% IC	-0.299	0.262	—	
	Mínimo 95% IC	-0.614	-0.137	—	
4. E-SUS	R de Pearson	0.814	0.143	-0.608	—
	p-valor	< .001	0.165	< .001	—
	Máximo 95% IC	0.872	0.334	-0.464	—
	Mínimo 95% IC	0.734	-0.059	-0.721	—

* p < .05, ** p < .01, *** p < .001

Fonte: Fonte – Dados da pesquisa.

Nesta primeira análise verifica-se que a correlação entre as variáveis independentes apresentou significância entre as combinações: densidade e óbitos, óbitos e IDHM, óbitos e casos menos graves da doença, e por fim, IDHM e casos. Esta análise considerou a escala de intensidade no relacionamento de coeficientes de correlação positivos e negativos apresentada por Dancey e Reidy (2013). Desta forma, conforme observado na figura 2, as forças das correlações podem ir de -1 à 1, onde se localizam a perfeição dos relacionamentos e forças próximas à zero

apresentam relacionamentos fracos. Relações positivas são aquelas que ocorrem no mesmo sentido e as negativas apresentam as relações contrárias.

Figura 2 - Intensidade no relacionamento de coeficientes de correlação positivos e negativos (DANCEY & REIDY, p. 197, 2013).

Perfeito	+1	-1
Forte	+0,9	-0,9
	+0,8	-0,8
	+0,7	-0,7
Moderado	+0,6	-0,6
	+0,5	-0,5
	+0,4	-0,4
Fraco	+0,3	-0,3
	+0,2	-0,2
	+0,1	-0,1
Zero	0	

Fonte: DANCEY & REIDY, p. 197, 2013.

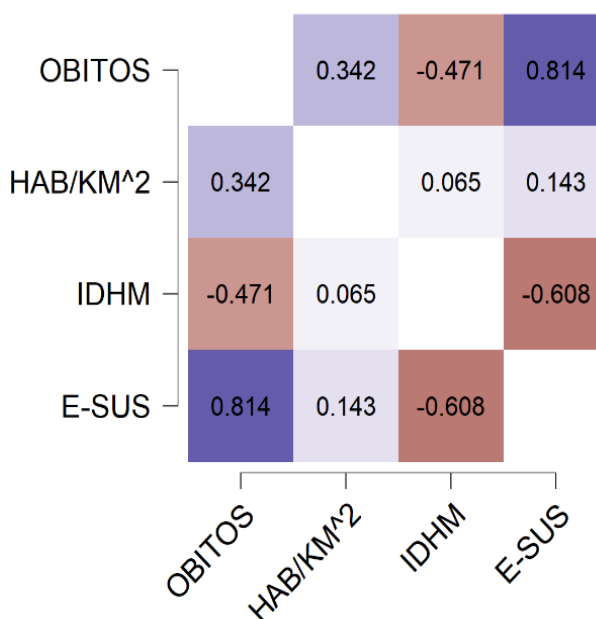
A maior representatividade válida para o estudo nesta verificação foi de 60% na relação entre o IDHM e o número de casos confirmados da doença. Esta relação aparece como negativa indicando que em localidades com o IDHM mais baixo apresenta uma quantidade maior de casos confirmados de COVID-19. Esta relação é denominada moderada.

Em segundo lugar, a análise demonstra que o IDHM também se relaciona com uma força moderada negativa com o número de óbitos. Assim, as localidades com menor IDHM se relacionaram à maiores quantidades de casos e óbitos decorrentes do coronavírus. Esta correlação entre as variáveis é de 47,1%.

Na sequência, constatou-se 34,2% de correlação entre as variáveis densidade demográfica e quantidade de óbitos. Esta relação aparece como positiva, indicando que onde maiores densidades demográficas indicam maior número de óbitos pela contaminação da Covid-19, o que Velavan e Meyer (2020) ressaltam como meios propícios de propagação das contaminações.

Estas correlações podem ser melhor visualizadas por meio do mapa de calor apresentado na figura 3 abaixo:

Figura 3 - Mapa de calor



Fonte: Fonte – Dados da pesquisa.

A relação demonstrada entre densidade demográfica e número de casos de COVID-19 menos graves é considerada fraca (coeficiente de correlação de 0,143) e positiva. Isto significa que estas variáveis se comportam na mesma direção. Quanto maior a densidade demográfica, maior o número de casos de COVID-19, e, quanto menor a densidade demográfica, menor o número de casos. Embora esta relação tenha sido apontada, pela baixa correlação, não se considerou como significativa neste estudo, visto que o valor-p calculado pelo JASP foi maior que 0,001.

A partir do comportamento das variáveis demonstrado acima para uma análise de regressão, optou-se por se excluir a variável “Número de Casos (E-Sus)” e analisar apenas os casos mais graves da doença que levaram à óbitos. Desta forma, a análise de regressão apontou os seguintes dados:

Tabela 5 - R de Pearson entre todas as variáveis do teste de regressão linear múltipla e análise de significância através do valor-p

Resumo do Modelo - ÓBITOS

Modelo	R	R ²	R ² ajustado	RMSE	Teste de Hipóteses
H ₀	0.000	0.000	0.000	42.364	Rejeitada
H ₁	0.602	0.362	0.348	34.205	Não rejeitada

Fonte: Fonte – Dados da pesquisa.

De posse dos resultados da RLM da Tabela 4, a análise de variância mostrou que a hipótese (H₀) de não haver regressão é rejeitada, isto é, o modelo é significativo a um nível de significância de 0,05. (HAIR et al., 2014; FIELD, 2009). Diante desses fatores, confirma-se a hipótese (H₁) de que há regressão e com isso, obteve-se os coeficientes R=0.6, R²= 0,36 e R² ajustado = 0,34. De acordo com Field (p. 170, 2009) um R (coeficiente de correlação múltiplo) no valor de 1 indica a perfeição do modelo preditivo através dos dados apresentados, portando o R

demonstra o quanto o modelo é capaz de prever e desta forma, o R^2 (coeficiente de determinação) indica a qualidade de variação na variável resultante que pode ser decorrente da aplicação do modelo e assim, o R^2 é a melhor adequação do modelo.

Para análise dos coeficientes, a tabela 5 abaixo demonstra o comportamento das hipóteses:

Tabela 6 - Coeficientes da regressão linear múltipla não padronizados, valores de t, valor-p, intervalo de confiança em 95% das variáveis IDHM e densidade demográfica

Coeficientes						95% IC		Estatísticas de colinearidade	
Modelo	Não padronizado	Erro Padrão	Padronizado	t	p	Mínimo	Máximo	Tolerância	VIF
Ho (Intercepto)	319.486	46.414		6.883	< .001	227.316	411.655		
Idhm	-323.674	54.216	-0.496	-5.970	< .001	-431.336	-216.012	0.996	1.004
Hab./km ²	0.003	6,74E-01	0.375	4.514	< .001	0.002	0.004	0.996	1.004

Fonte: Fonte – Dados da pesquisa.

Em todas as variáveis se verifica significância através o p-valor, desta forma é possível observar os valores máximos e mínimos com um intervalo de confiança (IC) de 95%. O valor VIF demonstrado na tabela se relaciona à identificação de multicolinearidade, visto que valores baixos de VIF apontam maior colinearidade. Foi possível verificar se as variáveis utilizadas apresentam alto índice de correlação através do teste de colinearidade. Neste teste as variáveis apresentaram baixas proporções de variância e, de acordo com a tabela 5, valor de VIF abaixo de 10, não demonstra problemas no ajuste do modelo (FIELD, 2009).

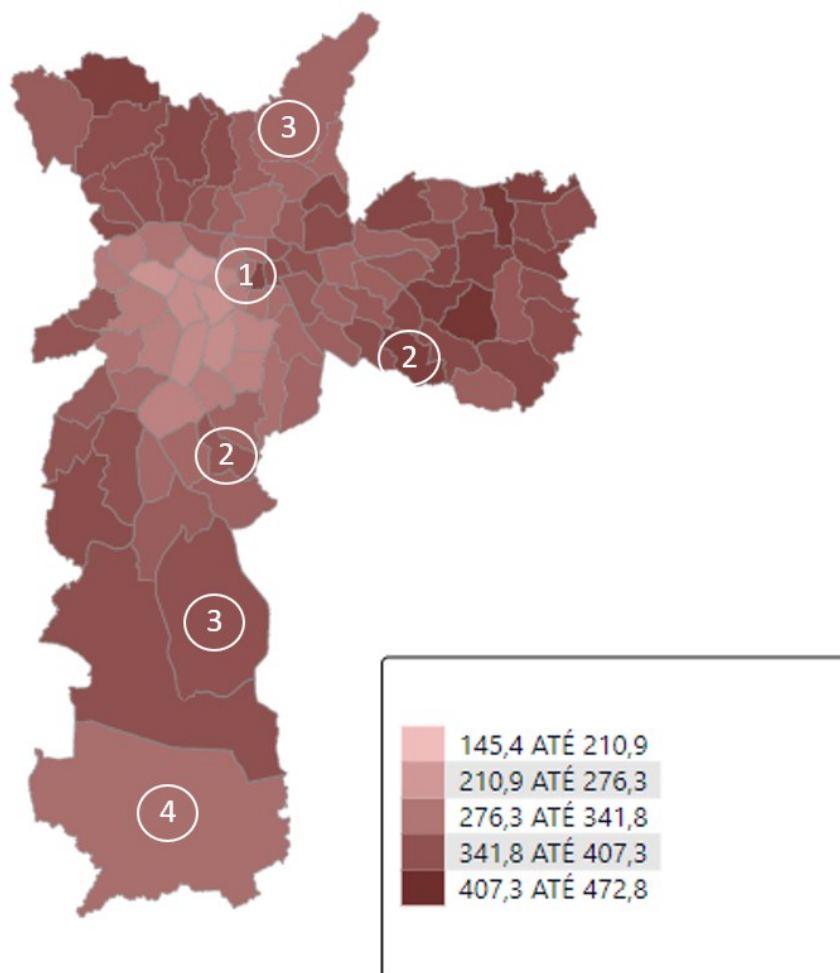
O coeficiente de determinação múltipla (R^2), que representa a proporção da variação em Y e é explicada através do conjunto de variáveis explanatórias selecionadas revelou que, a associação entre a variável critério e explicativas é moderadamente forte (R Múltiplo= 0,60), conforme demonstrado na Figura 2. Juntos, IDHM e Densidade demográfica foram responsáveis por 34,8% da variância do sucesso em testes (R^2 ajustado). O IDHM está relacionado negativamente aos óbitos, enquanto a Densidade demográfica está relacionada positivamente. O coeficiente de regressão para o IDHM foi de -323,67 (Intervalo de Confiança de 95% variando de -431,66 a -216,01) e para densidade demográfica foi de 0,003 (Intervalo de Confiança de 95% variando de 0,002 a 0,004). Os intervalos de confiança incluíram um valor negativo, relacionado ao IDHM, portanto, pode-se concluir que os coeficientes de regressão populacionais para IDHM é negativo. Já o intervalo de confiança relacionado à densidade demográfica é positivo, sendo assim, o coeficiente desta variável é positivo. (IDHM- t= -5,97; valor-p < 0,001/ densidade demográfica - t= 4,514; valor-p < 0,001).

Os coeficientes de regressão padronizados mostram que o IDHM é um preditor mais forte que a densidade demográfica, representando uma relação moderada com o número de óbitos, enquanto o coeficiente sobre a densidade demográfica aponta para um relacionamento positivo fraco com os óbitos registrados. A equação da regressão para uma previsão de óbitos é $y = a + (bx)$, substituindo para esse modelo tem-se: $y = 319,486 + (0,003 \text{ Densidade Demográfica}) - (323,674 \text{ IDHM})$.

Desta forma, é possível verificar a relação destas variáveis, assim como prever de acordo com a equação de RLM, a quantidade de óbitos em decorrência do valor do IDHM e a densidade de um distrito específico no município de São Paulo. Para

ilustração do impacto da contaminação de acordo com a localidade, tem-se a Figura 4, que considera a distribuição dos distritos conforme indicações da tabela 3:

Figura 4 – Distribuição geográfica por taxa padronizada de mortalidade até 18/01/2022 de acordo as indicações da Tabela 3.



Fonte: Painel Covid-19 – Município de São Paulo. Disponível em: https://www.prefeitura.sp.gov.br/cidade/secretarias/saude/vigilancia_em_saude/doencas_e_agravos/coronavirus/index.php?p=310771. Acesso em 26/01/2022.

Assim, as taxas de mortalidade aparecem distribuídas espacialmente no município por meio da localidade das subprefeituras. A análise realizada teve o propósito de demonstrar o quanto os óbitos podem ser explicados através do IDHM local e/ou sobre a densidade demográfica de cada distrito. A taxa padronizada é calculada com projeção da população residente em 2020 e padronizada por idade, que é uma técnica para anular a influência da estrutura etária, o que permitiu a comparação entre diferentes territórios.

Neste sentido, foi possível observar que o IDHM do município de São Paulo está relacionado inversamente à quantidade de óbitos registrados, ou seja, nas localidades com o IDHM denominado “muito alto” e relaciona a quantidades menores de registros de óbitos e, quanto menor o IDHM, neste estudo, caracterizados por “alto”, maiores as taxas de mortalidade. Portanto, os baixos

níveis de IDHM revelam não apenas vulnerabilidade da população, mas também dificuldades nos serviços de saúde quanto ao diagnóstico e tratamento de enfermidades, o que foi constatado também nos municípios cearenses, de forma similar ao panorama de fragilidade esperada dos serviços de saúde do Brasil e nos países da América (MACIEL, SILVA & FARIAS, 2020). Embora as doenças respiratórias sejam causas de incapacidade e óbitos, fatores como: a pobreza, aglomeração, exposição ambiental e condições de vida geralmente precárias, também deixam os indivíduos mais vulneráveis a esse tipo de doença em todas as regiões e classes sociais do mundo (MENDONÇA *et al.*, 2020).

Estas relações também foram observadas no estudo de Dos Santos *et al.* (2021) em que os resultados obtidos para a taxa de letalidade por COVID-19 relacionada com o IDHM do Estado do Pará forneceram fortes evidências que populações mais pobres, tomando como referência os IDHM's, podem estar em maior risco de mortalidade associada à COVID-19. Igualmente, no estudo Banhos *et al.* (2021), a urbanização e o IDHM foram indicadores sociais associados à ocorrência de casos de COVID-19 em municípios paranaenses. Neste contexto, a pandemia da COVID-19 tem afetado desproporcionalmente as populações em situação de vulnerabilidade socioeconômica (OLIVEIRA *et al.*, 2020).

Esses indicadores sociais já foram apontados no estudo de Mann *et al.* (1992) que defendia que, fatores de ordem social e econômica influenciam na disseminação das epidemias. Igualmente, os estudos de Junior e Castilho (2003) e Lesser e Kitro (2016) apontam claramente fatores associados às condições de vida como: saneamento básico, acesso à água, educação e renda, são determinantes para a taxa de contaminação e velocidade de propagação, observadas as diferenças entre os diferentes patógenos. Complementam Costa *et al.* (2020) que, essas evidências são reforçadas pelo fato de que muitas das recomendações feitas pela Organização Mundial da Saúde OMS (2020) são difíceis de serem cumpridas por grande parte da população brasileira. Ora por motivos socioeconômicos, que dificultam o distanciamento social, ou porque muitas pessoas e famílias compartilham os mesmos cômodos de moradias precárias, até mesmo porque tais domicílios não dispõem de acesso adequado às redes de água e/ou de esgotamento sanitário.

Associa-se, ainda, outros tipos de estudos sobre infecções que trazem resultados semelhantes, como o estudo de Johansen, Carmo e Alves (2014), que investigaram a distribuição espacial dos casos de infecção por dengue no município de Campinas/SP. Esses autores também apontaram que os segmentos populacionais residentes em territórios com menor Índice de Desenvolvimento Humano Municipal (IDHM), dois quais concentravam-se as piores condições socioeconômicas e de acesso a recursos e serviços urbanos, apresentaram maiores taxas de incidência de dengue. Da mesma forma, no estudo de Lesser e Kitron (2016) apontaram que as condições socioeconômicas, a disponibilidade de infraestrutura precária e a densidade demográfica são fatores importantes quando se observa a questão da epidemia do vírus zika. A partir disso, podemos inferir que há uma relação inversa entre o IDHM e as taxas de contaminação.

Sendo assim, a associação entre COVID-19 e o IDHM, revela a importância do rastreamento geográfico em espaços de potencial transmissão infecciosa local como aspecto fundamental para coordenar melhor as ações de enfrentamento à pandemia (MACIEL, SILVA & FARIAS, 2020), visto que o IDHM pode representar um

indicador indireto para a saúde, pois seus componentes avaliam a expectativa de vida, a renda e a escolaridade (BANHOS *et al.*, 2021).

Esta análise indica que a alta densidade demográfica apresentada nos distritos com IDHM denominado “muito alto” pode estar relacionada à preferência de moradia nas localidades centrais da cidade devido à melhores condições de infraestrutura como acesso ao metrô, serviços de educação e saúde. Consequentemente, Banhos *et al.* (2021) sugerem que o IDHM maior facilita as condições de circulação viral intensa, transmissibilidade e recrudescimento do quadro clínico da Covid-19 (MACIEL; CASTRO-SILVA; FARIAS, 2020). Contudo, não foi o observado pelos distritos centrais associados na Tabela 3, que, embora apresentem altas densidades e IDHM, demonstram menores casos de contaminados e óbitos decorrentes da COVID-19.

Neste sentido, a densidade demográfica alta pode estar associada à melhores condições de infraestrutura, diminuindo a possibilidade de óbitos, maior acesso à serviços de saúde, como por exemplo, no distrito de Bela Vista. Assim, torna-se importante observar o IDHM das localidades analisadas, pois, à exemplo do distrito de Sapopemba, também com uma alta densidade demográfica, porém, foi altamente impactado com a COVID-19. A diferença entre estes dois distritos está no IDHM, Bela Vista com 0,94 (muito alto) e Sapopemba com 0,78 (alto), o que indica diferenças na infraestrutura e em suas localizações que privilegiam ou dificultam as condições de transporte para regiões diferentes da cidade que forneçam os serviços essenciais à sociedade.

Ainda nesse contexto, nota-se que as desigualdades socioespaciais identificadas por meio dos índices e indicadores apresentados na Tabela 3 chamam a atenção para a necessidade de se observar o território, ao que diz respeito ao desempenho de propagação da pandemia quanto às estratégias de seu enfrentamento. Como exemplo, no estudo de Basso (2020) é citado que a maior favela com maior densidade demográfica do país que se chama Paraisópolis e que esta ignora a pandemia, mesmo com maior densidade populacional do país, considerando os serviços públicos deficientes e a aglomeração, as iniciativas são improvisadas pelas associações de moradores, enquanto comunidade ignora alertas e isolamento. Assim, a realidade de Paraisópolis é considerada como um território paulistano de alta vulnerabilidade socioespacial à contaminação da Covid-19. Consequentemente, a densidade demográfica de Paraisópolis contribuiu para que a população estivesse mais exposta à contaminação pela COVID-19 e, associada ao baixo IDHM, devido à falta de uma estrutura de acesso aos serviços essenciais, caracteriza-se por demonstrar uma região de alta vulnerabilidade social. Assim, na análise de suscetibilidade à contaminação pela COVID-19, deve considerar o IDHM local, pois a densidade demográfica de forma isolada não demonstra relação com as quantidades de casos e óbitos coletados neste estudo. Ao relacionar o IDHM diferem-se os distritos com altas densidades que demonstraram maior resiliência durante a pandemia daqueles que foram fortemente impactados.

Desse contexto, para Guimarães *et al.* (2020) a difusão espacial da contaminação pelo novo coronavírus deve considerar a dificuldade no enfrentamento da doença em um mundo globalizado, o que altera as escalas da vida e da economia, expandindo as conexões causadas por um mundo mais complexo. Nesse sentido, o Brasil, assim como outros países menos

desenvolvidos, é extremamente afetado por doenças como a COVID-19, e ainda é agravado devido a extrema pobreza (DOS SANTOS *et al.*, 2021).

5 CONSIDERAÇÕES FINAIS

O objetivo deste estudo foi analisar o quanto os índices de desenvolvimento de São Paulo (IDHM) e a densidade demográfica, utilizados no planejamento urbano, podem contribuir na identificação de distritos que necessitem de gerenciamento prioritário no enfrentamento da contaminação pelo novo coronavírus, portanto aplicou-se um modelo de regressão linear múltipla (RLM). Os dados coletados para esta análise são da primeira onda de COVID-19 no município de São Paulo com a intenção de se analisar como a contaminação se comportou nos diferentes distritos, em um momento em que não havia informações científicas sobre quais medidas de proteção à saúde adotar mediante o evento inédito.

Este estudo apresentou boa validade interna, pois os dados são representativos dos estratos geográficos analisados, assim, o coeficiente de determinação R^2 de 0.362 indica que os preditores são capazes de explicar que 36,2% dos óbitos por COVID-19 estão relacionados às variáveis de densidade demográfica e IDHM de cada distrito da capital paulistana. Pode-se inferir que os residentes em territórios com menor IDHM, e, portanto, onde se concentram as piores condições socioeconômicas e de acesso a serviços urbanos, apresentaram maiores taxas de incidência de COVID-19. Portanto, há uma relação inversa entre o IDHM e a probabilidade de contaminação.

Na análise da relação entre as variáveis de densidade demográfica e o IDHM, o valor resultante pode ser considerado relevante, embora mais próximo à zero do que à 1, onde 1 significa a perfeição do modelo para previsão de óbitos pela Covid-19, porém, se tratando de ciências sociais, há influência direta pelo comportamento humano. Neste estudo, como não houve a pretensão de prever com exatidão a quantidade de óbitos por distrito, mas sim uma previsão aproximada, pode-se considerar o modelo proposto e analisar como as variáveis independentes envolvidas podem contribuir para um melhor planejamento urbano do município de São Paulo.

A partir destas análises e por meio de argumentação do estado da arte, apresentou-se diversos estudos em que o IDHM pode se comportar como um indicador como métrica de avaliação da vulnerabilidade social e, nestes casos, locais com populações mais suscetíveis à contaminação como, à COVID-19. Esses fatores corroboram juntamente com os dados apresentados de densidade demográfica e da indicação de áreas que demandam maior atenção, pois podem apresentar graves consequências sociais, ambientais e econômicas. Contudo, a densidade demográfica de maneira isolada não se demonstrou como indicativa da vulnerabilidade, mas quando associada ao IDHM conduz a conclusões que convergem para o constatado por autores que também investigaram o comportamento destas variáveis diante da pandemia.

Conforme Alves e Lima (2020), a renda per capita interfere também no aumento das taxas de contaminação e, o IDHM por possuir este indicador em seu cálculo, acaba por ser impactado igualmente, demonstrando assim, compatibilidade com os resultados deste estudo. No aspecto relacionado à

longevidade também atrelado ao IDHM reforça a ideia de que onde a população é mais saudável, com uma expectativa maior de vida, há menos mortes pela Covid-19, onde os autores identificam que a idade do cidadão contribui menos do que a renda per capita ao risco de contaminação ao vírus. Por fim, o indicador de escolaridade do IDHM também teria relação com a taxa de contaminação, indicando distritos com maior acesso à educação, menores índices de confirmação da doença.

Estes três indicadores do IDHM, juntamente com a análise local de densidade demográfica podem constituir um plano com diretrizes municipal ou distritais de forma a minimizar os efeitos da contaminação pelo coronavírus e maximizar a qualidade de vida nestes locais. Como sugestão, incluir neste estudo o deslocamento de massas entre os distritos implicaria em uma melhoria do direcionamento das ações que, embora possam ser específicas em cada localidade, sejam interligadas e integradas.

Neste sentido, estratégias de soluções integradas podem se utilizar de tecnologias centradas no cidadão, constituindo um modelo de cidade inteligente interessante e eficaz aos próximos eventos. Assim, é importante visualizar as particularidades do município de São Paulo e seus distritos para as soluções sejam baseadas na realidade, facilitando a ação de gestores locais. E, diante da complexidade da dinâmica urbana do município de São Paulo, a investigação das variáveis IDHM e densidade demográfica não são suficientes para demonstrar soluções claras em planejamento urbano que contribuam para a proteção da saúde pública, sendo necessário considerar outras variáveis de comportamento individual e coletivo diante da pandemia e demais variáveis políticas.

Recomenda-se mais estudos que considerem outras características socioambientais, além do IDHM, pois, conforme demonstrado, a pandemia da COVID-19 afeta os distritos do estado de São Paulo de uma forma não uniforme e desproporcional, além de análises dos comportamentos das variáveis durante outros períodos da pandemia, inclusive após o início das vacinações.

Ademais, a contribuição deste estudo é a de que a pandemia da COVID-19 impactou o município de São Paulo de forma desigual e principalmente nas regiões com baixo IDHM. O estudo denota também regiões com maiores fragilidades sociais e econômicas, estão mais sujeitas às complicações geradas pela doença. Nesse contexto, os pressupostos deste estudo podem colaborar com as tomadas de decisões e ações de políticas públicas e governamentais no enfrentamento da pandemia da Covid-19.

Sugere-se adotar medidas emergenciais que estejam alinhadas às estruturas de vigilância nas áreas mais vulneráveis das áreas metropolitanas brasileiras, a fim de monitorar, isolar os suspeitos e tratar os casos de COVID-19. Embora as medidas de segurança recomendadas pela Organização Mundial da Saúde (OMS) sejam insuficientes, e até mesmo impraticáveis na maioria das áreas mais vulneráveis, torna-se urgente preparar uma resposta rápida e compatível com as características desses locais, evitando assim, a contaminação de COVID-19 entre as classes mais pobres. Além de estratégias importantes como o pagamento de auxílio emergencial possam incluir ações do Estado, da iniciativa privada e das organizações sociais.

Este estudo expõe algumas limitações que são próprias da metodologia empregada, pois em estudos ecológicos, quando observa-se a existência de uma

relação entre duas variáveis no nível agregado resulta, necessariamente, o fato de que essa relação permanecer no nível individual. Outras limitações da pesquisa se devem ao período analisado, tendo um recorte isolado durante a primeira onda da doença no município.

Conclui-se que a ocorrência do coeficiente de incidência de COVID-19 foi desigualmente distribuída nos distritos de São Paulo e isso possivelmente tenha relação com a grandeza do índice IDHM. O mapeamento desigual de COVID-19 e sua relação com o IDHM em São Paulo podem contribuir com ações de enfrentamento regional à pandemia, bem como, abrir caminho para análises que permitam compreender melhor o comportamento da doença. O conhecimento geográfico da incidência de COVID-19 atrelado à mortalidade devido ao menor índice de IDHM, pode ser utilizado para evidenciar locais onde intervenções são necessárias. Assim, consegue-se investigar quais são as regiões com maior demanda de investimento governamental, para assim diminuir a letalidade causada pelo vírus e contribuir para aumentar a resiliência municipal diante de eventos futuros.

Analysis of the relation between the IDHM index and demographic density with the incidence of Covid-19 in the municipality of São Paulo - SP

ABSTRACT

The speed of the spread of Covid-19 has led to the adoption of a series of measures by governments around the world aimed at social protection. There is a collective effort to identify which factors influence transmission. Therefore, this study aims to analyze how much São Paulo's development indices (MHDI) and population density can contribute to the identification of districts that need priority management. The study is characterized by being ecological, exploratory and analytical and for carrying out the hypothesis test a multiple linear regression model (MLR) was applied. The municipality of São Paulo is divided into 96 districts. Data on cases of the disease, on population density and on the MHDI in these districts were observed through the RLM. The results show that the IDHM is inversely related to the number of deaths, however, the population density did not prove to be an indication of local vulnerability in isolation. These variables analyzed together point out the districts in which combat and prevention actions should be urgent, as well as the elaboration of plans that lead to urban planning that favors the quality of life and adopts measures compatible with the principles of the resilient city.

KEYWORDS: Covid-19, urban planning, pandemic, development indicators, smart cities.

REFERÊNCIAS

ABRAMS, Elissa M.; SZEFLER, Stanley J. COVID-19 and the impact of social determinants of health. *The Lancet Respiratory Medicine*, v. 8, n. 7, p. 659-661, 2020.

ALVES, Joao Guilherme; LIMA, Tiago Pessoa. COVID-19 lethality in non-elderly individuals in cities with different Human Development Index. *Tropical Doctor*, v. 51, n. 1, p. 124-125, 2021.

BANAI, Reza. Pandemic and the planning of resilient cities and regions. *Cities*, v. 106, p. 102929, 2020.

BANHOS, Nathália Garcia et al. Análise temporo-espacial da evolução da Covid-19 no Estado do Paraná no período de março a setembro de 2020. *Brazilian Journal of Development*, v. 7, n. 4, p. 40520-40539, 2021.

BARBOSA, Francis Régis Gonçalves Mendes. Índice de Desenvolvimento Relativo, IDH-M e IFDM: em busca da operacionalização das liberdades instrumentais de Amartya Sen. *Ensaio FEE*, v. 38, n. 2, p. 295-328, 2017.

BOHN, Liana et al. Idhm E Eficiência: O Desenvolvimento Municipal Sob Um Novo Prisma. *Anais do XLIII Encontro Nacional de Economia*, 2016.

BRASIL. Ministério da Saúde. Definição de Caso e Notificação: Casos suspeitos de doença pelo Coronavírus (COVID-2019). 2020. Disponível em: <https://rb.gy/crqqqa>. Acesso em: 12 jul. 2020.

BUCKERIDGE, Marcos Silveira; PHILIPPI JUNIOR, ARLINDO. Ciência e políticas públicas nas cidades: revelações da pandemia da Covid-19. *Estudos Avançados*, v. 34, n. 99, p. 141-156, 2020.

CONNOLLY, Creighton; KEIL, Roger; ALI, S. Harris. Extended urbanisation and the spatialities of infectious disease: Demographic change, infrastructure and governance. *Urban studies*, v. 58, n. 2, p. 245-263, 2021.

DANCEY, C. P.; REIDY, J. Estatística sem matemática para psicologia: usando o SPSS. Porto Alegre: Penso Editora, 2013.

DESAI, D. Urban Densities and the Covid-19 Pandemic: Upending the Sustainability Myth of Global Megacities, ORF Occasional Paper, No. 244, Observer Research Foundation, 2020.

DOS SANTOS, Sirlei Borges et al. A epidemiologia da Covid-19 e sua relação com o Índice de Desenvolvimento Humano Municipal do Estado do Pará. *Research, Society and Development*, v. 10, n. 14, p. e27101421578-e27101421578, 2021.

FERREIRA, Marcos César. Spatial association between the incidence rate of Covid-19 and poverty in the São Paulo municipality, Brazil. *Geospatial health*, v. 15, n. 2, 2020.

FIELD, Andy. *Descobrimo a Estatística Usando o SPSS-5*. Penso Editora, 2009.

FUNBEC. Fundação Brasileira para o Desenvolvimento do Ensino de Ciências. Laboratório básico polivalente de ciências para o 1º grau: manual do professor. 2. ed. Rio de Janeiro: MEC/FENAME, 1983.

GOVERNO DO ESTADO DE SÃO PAULO. Fundação Sistema Estadual de Análise de Dados (Seade). São Paulo: população dos municípios paulistas: População dos 645 municípios de São Paulo. 2018. Disponível em: <https://rb.gy/k5qguk>. Acesso em: 12 jul. 2020.

GOVERNO DO ESTADO DE SÃO PAULO. Fundação Sistema Estadual de Análise de Dados (Seade). SP contra o novo Coronavírus: Boletim Completo. 2020. Disponível em: <https://rb.gy/vdkrsq>. Acesso em: 12 jul. 2020.

GUIMARÃES, Raul Borges et al. O raciocínio geográfico e as chaves de leitura da Covid-19 no território brasileiro. *Estudos avançados*, v. 34, p. 119-140, 2020.

HOLANDA, Vanderlan Nogueira. Pandemia de COVID-19 e os esforços da ciência para combater o novo coronavírus. *Revista Interfaces: Saúde, Humanas e Tecnologia*, v. 8, n. 1, p. 360-361, 2020.

IPEA. Instituto De Pesquisa Econômica Aplicada – Ipea; Pnud. Programa Das Nações Unidas Para O Desenvolvimento – Pnud; FJP. Fundação João Pinheiro – FJP. Atlas do desenvolvimento humano no Brasil, 2013.

ITO, Nobuiki Costa; PONGELUPPE, Leandro Simões. O surto da COVID-19 e as respostas da administração municipal: munificência de recursos, vulnerabilidade social e eficácia de ações públicas. *Revista de Administração Pública*, v. 54, p. 782-838, 2020.

JAMES, Philip et al. Smart cities and a data-driven response to COVID-19. *Dialogues in Human Geography*, p. 2043820620934211, 2020.

JASP Team (2020). JASP (Version 0.12.2) [Computer software]. Disponível em: <https://jasp-stats.org>

JARDIM, Vinícius Carvalho; BUCKERIDGE, Marcos Silveira. Análise sistêmica do município de São Paulo e suas implicações para o avanço dos casos de Covid-19. *Estudos avançados*, v. 34, p. 157-174, 2020.

JOHNS HOPKINS UNIVERSITY. Coronavirus COVID-19 Global Cases by Johns Hopkins CSSE [Internet]. Johns Hopkins University; 2020 [acessado em 19 nov. 2020]. Disponível em: <https://coronavirus.jhu.edu/map.html>

JOHANSEN, Igor Cavallini; CARMO, Roberto Luiz do; ALVES, Luciana Correia. Desigualdade social intraurbana: implicações sobre a epidemia de dengue em Campinas, SP, em 2014. *Cadernos Metrópole*, v. 18, p. 421-440, 2016.

JOHNSON, Richard Arnold; WICHERN, Dean. *Applied Multivariate Statistical Analysis*, 767 Prentice Hall. Upper Saddle River, New Jersey, 2002.

KUNZMANN, Klaus. R. Smart Cities after Covid-19: Ten Narratives. *disP-The Planning Review*, v. 56, n. 2, p. 20-31, 2020.

LANCET. Redefining vulnerability in the era of COVID-19. 395: 1089, abr. 2020.

LEIVA, Guilherme de Castro; SATHLER, Douglas; ORRICO, Romulo Dante. Estrutura urbana e mobilidade populacional: implicações para o distanciamento social e disseminação da Covid-19. *Revista Brasileira de Estudos de População*, v. 37, 2020.

LESSER, Jeffrey; KITRON, Uriel. A geografia social do Zika no Brasil. *Estudos avançados*, v. 30, p. 167-175, 2016.

LEVIN, Jack. *Estatística aplicada a Ciências Humanas*. Edit. 1978.

LIMA-COSTA, Maria Fernanda; BARRETO, Sandhi Maria. Tipos de estudos epidemiológicos: conceitos básicos e aplicações na área do envelhecimento. *Epidemiologia e serviços de saúde*, v. 12, n. 4, p. 189-201, 2003.

MACIEL, Jacques Antonio Cavalcante; CASTRO-SILVA, Igor Iuço; FARIAS, Mariana Ramalho de. Análise inicial da correlação espacial entre a incidência de COVID-19 e o desenvolvimento humano nos municípios do estado do Ceará no Brasil. *Revista Brasileira de Epidemiologia*. 2020; 23: E200057.

MALHOTRA, Naresh K. Pesquisa de Marketing-: uma orientação aplicada. Bookman Editora, 2001.

MANN, Jonathan M. et al. AIDS in the World. Harvard University Press, 1992.

MATTAR, Fauze Najib et. al. Pesquisa de marketing: metodologia, Planejamento. 5. ed. São Paulo: Atlas, 1999.

MELLO, Márcio Pupin de; PETERNELLI, Luiz Alexandre. Conhecendo o R: uma visão mais que estatística. Viçosa, Ed. UFV, 2013.

MENDONÇA, Flávia Daspett et al. Região Norte do Brasil e a pandemia de COVID-19: análise socioeconômica e epidemiológica/North region of Brazil and the COVID-19 pandemic: socioeconomic and epidemiologic analysis/Región Norte de Brasil y la pandemia de COVID-19: análisis. Journal Health NPEPS, v. 5, n. 1, p. 20-37, 2020.

MORENS, David M.; DASZAK, Peter; TAUBENBERGER, Jeffery K. Escaping Pandora's box — another novel coronavirus. N Engl J Med. 2020; 382:1293-5

NICOLELIS, Miguel A. et al. The impact of super-spreader cities, highways, and intensive care availability in the early stages of the COVID-19 epidemic in Brazil. Scientific reports, v. 11, n. 1, p. 1-12, 2021.

OLIVEIRA, Lucas Amaral, ARANTES, Rafael Aguiar. Neighborhood effects and urban inequalities: the impact of covid-19 on the periphery of Salvador, Brazil. City & Society (Washington, DC), v. 32, n. 1, 2020.

OLIVEIRA, Roberta Gondim de. et al. Desigualdades raciais e a morte como horizonte: considerações sobre a COVID-19 e o racismo estrutural. Cadernos de Saúde Pública, v. 36, 2020.

PEREIRA, Ana Karine; OLIVEIRA, Marília Silva; SAMPAIO, Thiago da Silva. Heterogeneidades das políticas estaduais de distanciamento social diante da COVID-19: aspectos políticos e técnico-administrativos. Revista de Administração Pública. Rio de Janeiro, 54 (4). P. 678 - 696. 2020.

PNUD. Programa das Nações Unidas para o Desenvolvimento. Atlas do Desenvolvimento Urbano no Brasil. 2013. Disponível em: <https://rb.gy/0qc6a8>. Acesso em: 12 jul. 2020.

PREFEITURA DA CIDADE DE SÃO PAULO. Secretaria de Desenvolvimento Econômico e Trabalho. Atlas do Trabalho e Desenvolvimento da Cidade de São Paulo. 2007.

PREFEITURA DA CIDADE DE SÃO PAULO. Secretaria Municipal da Saúde. Boletim Diário Covid-19 no Município de São Paulo. 2020a. Disponível em: <https://rb.gy/aoaohy>. Acesso em: 12 jul. 2020.

PREFEITURA DA CIDADE DE SÃO PAULO. Secretaria Municipal de Desenvolvimento Urbano. População Recenseada e Taxas de Crescimento: Município de São Paulo, Regiões e Distritos Municipais. 2018. Disponível em: <https://rb.gy/0snqbw>. Acesso em: 12 jul. 2020.

PREFEITURA DA CIDADE DE SÃO PAULO. Secretaria Municipal de Desenvolvimento Urbano. COVID-19: Relatório Situacional de 30 de abril de 2020. 2020b. Disponível em: <https://rb.gy/xbkfly>. Acesso em: 12 jul. 2020.

PREFEITURA DA CIDADE DE SÃO PAULO. Secretaria Municipal de Desenvolvimento Urbano. COVID-19: Relatório Situacional de 29 de maio de 2020. 2020c. Disponível em: <https://rb.gy/xbkfly>. Acesso em: 12 jul. 2020.

RODRIGUES-JÚNIOR, Antonio Luiz; CASTILHO, Euclides Ayres de. A epidemia de Aids no Brasil, 1991-2000: descrição espaço-temporal. Revista da Sociedade Brasileira de Medicina Tropical, v. 37, n. 4, p. 312-317, 2004

SAKELLARIDES, Constantino. From Viral City to Smart City: Learning from Pandemic Experiences. Revista Científica da Ordem dos Médicos. Acta Med Port 2020 Jun;33(6):359-361.

SAKELLARIDES, Constantino. KICKBUSCH, Ilona. Flu City - Smart City: applying health promotion principles to a pandemic threat. Health Promotion International. Vol. 21 No. 2. 2020.

SEN, Amartya. Desenvolvimento como liberdade, Companhia das Letras. 2000.

SHARIFI, Ayyoob; KHAVARIAN-GARMSIR, Amir Reza. The COVID-19 pandemic: Impacts on cities and major lessons for urban planning, design, and management. Science of the Total Environment, p. 142391, 2020.

SLOVIC, Anne Dorothee et al. O longo caminho para a equidade: restrições de acesso ao emprego e desigualdades sobrepostas na cidade de São Paulo. Journal of Transport Geography, v. 78, p. 181-193, 2019.

STIER, Andrew J.; BERMAN, Marc G.; BETTENCOURT, Luis. COVID-19 attack rate increases with city size. arXiv preprint arXiv:2003.10376, 2020.

ULTRAMARI, Clovis. SALDIVA, Paulo. LEVY, Wilson. A Covid-19 e as cidades inteligentes. Folha de São Paulo. 17/06/2020. Disponível em: <https://www1.folha.uol.com.br/opiniao/2020/06/a-covid-19-e-as-cidadesinteligentes.shtml>

VELAVAN, Thirumalaisamy P.; MEYER, Christian G The COVID-19 epidemic. Tropical Medicine and International Health. Vol. 25. N. 3. P. 278-280. 2020.

WADE, Lizzie, 2020. An unequal blow. Science 368 (6492), 700–703.

WASDANI, Kishinchand Poornima; PRASAD, Ajnesh. The impossibility of social distancing among the urban poor: the case of an Indian slum in the times of COVID-19. Local environment, v. 25, n. 5, p. 414-418, 2020.

ZHONG, Bao-Liang et al. Knowledge, attitudes, and practices towards COVID-19 among Chinese residents during the rapid rise period of the COVID-19 outbreak: a quick online cross-sectional survey. International journal of biological sciences, v. 16, n. 10, p. 1745, 2020.

Recebido: 18 mai. 2022.

Aprovado: 20 jun. 2022.

DOI: 10.3895/rbpd.v11n3 esp.13627

Como citar: BRITO, D. B.; STOROPOLI, J. E.; FILHO, J. A. P.; SILVA, R. U. B.; OSMAR, S. J. Análise da relação entre o índice IDHM e a densidade demográfica com a incidência de Covid-19 no município de São Paulo – SP. **R. bras. Planej. Desenv.** Curitiba, v. 11, n. 03, p. 767-794, set./dez. 2022. Disponível em: <<https://periodicos.utfpr.edu.br/rbpd>>. Acesso em: XXX.

Correspondência:

Daniela Belchior Brito

Av. Professor Luiz Ignácio Anhaia Mello, 1363 - Vila Prudente, São Paulo - SP

Direito autoral: Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

