

**UNIVERSIDADE NOVE DE JULHO
PROGRAMA DE MESTRADO EM CIDADES INTELIGENTES E
SUSTENTÁVEIS**

LORENZO GOTTARDI

**A POBREZA MULTIDIMENSIONAL NOS MUNICÍPIOS DO ESTADO DE SÃO
PAULO: DISTRIBUIÇÃO ESPACIAL E RELAÇÃO COM A PANDEMIA DE
COVID-19**

SÃO PAULO

2023

LORENZO GOTTARDI

A POBREZA MULTIDIMENSIONAL NOS MUNICÍPIOS DO ESTADO DE SÃO PAULO: DISTRIBUIÇÃO ESPACIAL E RELAÇÃO COM A PANDEMIA DE COVID-

19

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Cidades Inteligentes e Sustentáveis da Universidade Nove de Julho - UNINOVE, como requisito para obtenção do título de Mestre.

Aluno: Lorenzo Gottardi

Orientadora: Prof.^a Dr.^a Alessandra Cristina Guedes Pellini

SÃO PAULO

2023

FICHA CATALOGRÁFICA

Gottardi, Lorenzo.

A pobreza multidimensional nos municípios do estado de São Paulo: distribuição espacial e relação com a pandemia de covid-19. / Lorenzo Gottardi. 2023.

136 f.

Dissertação (Mestrado) - Universidade Nove de Julho - UNINOVE, São Paulo, 2023.

Orientador (a): Prof^a. Dr^a. Alessandra Cristina Guedes Pelini.

1. Análise espacial. 2. Cidades inteligentes. 3. COVID-19. 4. Objetivos de desenvolvimento sustentável. 5. Pobreza multidimensional.

I. Pelini, Alessandra Cristina Guedes. II. Título.

CDU 711.4

“A POBREZA MULTIDIMENSIONAL NOS MUNICÍPIOS DO ESTADO DE SÃO PAULO: DISTRIBUIÇÃO ESPACIAL E RELAÇÃO COM A PANDEMIA DE COVID-19”

Por

Lorenzo Gottardi

Dissertação apresentada ao Programa de Pós-Graduação em Cidades Inteligentes e Sustentáveis da Universidade Nove de Julho – UNINOVE, como requisito parcial para obtenção do título de Mestre em Cidades Inteligentes e Sustentáveis, sendo a banca examinadora formada por:

Prof. Dr. Francisco Chiaravalloti Neto – Universidade de São Paulo – USP

Profa. Dra. Alessandra Cristina Guedes Pellini – Universidade Nove de Julho – UNINOVE

Prof. Dr. Jose Eduardo Storopoli – Universidade Nove de Julho – UNINOVE

Prof. Dr. Cristiano Capellani Quaresma – Universidade Nove de Julho – UNINOVE

São Paulo, 22 de março de 2023.

Dedicatória

A todos aqueles que vivem
diariamente situações de
privação e pobreza..

Agradecimentos

Agradeço:

À minha mãe, que além de me dar a minha própria vida, me encaminhou o processo seletivo para este programa de Mestrado e me apoiou ao longo de todo este caminho.

Ao meu pai, que com todo o seu jeito acolhedor e protetor se dispôs em todos os momentos a estar ao meu lado.

À Di, minha companheira, que tanto soube entender minhas ausências ao longo deste processo e sobretudo por me preencher com amor e carinho, me recarregando as energias para chegar ao final desta jornada.

À Amora e Guaíra, ainda que não falem, me dão amor a cada nova chegada em casa.

Aos meus tão amados irmãos, Raquel e Vitor, por sempre estarem dispostos a brincar comigo.

Aos meus amigos, de escola, da Ordem DeMolay, do trabalho, e dos encontros que a vida nos proporciona, pelos momentos de lealdade e amizade.

À UNINOVE pela oportunidade de viver um dos maiores desafios da minha carreira, em especial à coordenação do curso e à Suely lafrate por todo apoio

Aos meus Professores do programa de Mestrado em Cidades Inteligentes e Sustentáveis, em especial, aos professores Doutor Cristiano Capellani Quaresma e Doutor José Eduardo Storopoli por colaborarem na construção deste trabalho e aceitarem compor minhas bancas de qualificação e de defesa.

Aos Professores Doutor Francisco Chiaravalotti Neto e Doutora Ligia Vizeu Barrozo por aceitarem o convite de me avaliarem ao longo da elaboração deste trabalho, a professora Ligia com grandes contribuições na banca de qualificação e o professor Francisco na banca de defesa.

À minha querida orientadora, professora doutora Alessandra Cristina Guedes Pellini, que com maestria e uma grande dose de paciência me conduziu com segurança por um caminho até então desconhecido para mim.

Por fim, agradeço ao Pai Celestial, que me apresentou mais este desafio, e eu, com fé, pude conquistar mais esta etapa.

RESUMO

Introdução: O primeiro dos Objetivos de Desenvolvimento Sustentável da Organização das Nações Unidas é a erradicação da pobreza em todas as suas formas, em todos os lugares. A concepção da pobreza como fenômeno multidimensional é central para a compreensão das privações que os indivíduos sofrem e como estas limitam o desenvolvimento de suas capacidades. Em janeiro de 2020, a Organização Mundial da Saúde declarou a COVID-19 como uma pandemia, que, ao longo dos anos de 2020 e 2021, atingiu todos os municípios do estado de São Paulo, sendo que, de acordo com o Banco Mundial, a pandemia pode ter ampliado a pobreza no mundo em cerca de 15%. **Objetivo:** Construir um indicador de pobreza multidimensional para os municípios do estado de São Paulo, e identificar a relação entre a pobreza multidimensional e indicadores de internação e óbito por COVID-19. **Método:** Trata-se de um estudo descritivo e ecológico, com componente analítico, que se propôs a construir um índice de pobreza multidimensional (IPM) conforme o método de Alkire-Foster (2009). Também foram levantados dados sobre internações e óbitos por COVID-19 nos municípios do estado de São Paulo nos anos de 2020 e 2021. Por fim, foram utilizadas técnicas de análise espacial, como os índices de Moran global e local, para a verificação da associação entre os indicadores de COVID-19 e o índice de pobreza multidimensional. **Resultados:** O IPM foi composto de 5 (cinco) dimensões e 14 indicadores, e 356 (55,19%) municípios foram considerados multidimensionalmente pobres por apresentarem um total privações acima da linha da pobreza, definida em 0,2. Foi observada uma associação negativa e fraca entre o IPM e as taxas de internação e mortalidade por COVID-19 nos anos de 2020 e 2021. A análise de correlação espacial bivariada apresentou uma mudança de padrão entre os anos de 2020 e 2021, evidenciando um deslocamento da concentração das taxas de internação e mortalidade em direção aos municípios do interior do estado de São Paulo, com destaque para a formação de aglomerados de municípios com alta pobreza multidimensional e altas taxas de mortalidade em 2021, em especial os DRS de Registro e Sorocaba. **Conclusão:** A caracterização espacial do IPM e dos indicadores de COVID-19, bem como o estudo da relação entre estes fenômenos, pode orientar ações preventivas e curativas, bem como instigar novos estudos na área.

Palavras-chave: Análise Espacial, Cidades Inteligentes, COVID-19, Objetivos de Desenvolvimento Sustentável, Pobreza Multidimensional.

ABSTRACT

Introduction: The first of the United Nations' Sustainable Development Goals is the eradication of poverty in all its forms, everywhere. The conception of poverty as a multidimensional phenomenon is central to understanding the deprivations that individuals suffer and how they limit the development of their capabilities. In January 2020, the World Health Organization declared COVID-19 a pandemic, which, throughout 2020 and 2021, affected all municipalities in the state of São Paulo. According to the World Bank, the pandemic may have increased poverty worldwide by around 15%. **Objective:** To construct a multidimensional poverty indicator for municipalities in the state of São Paulo and to identify the relationship between multidimensional poverty and COVID-19 hospitalization and mortality indicators. **Method:** This is a descriptive and ecological study with an analytical component that aimed to construct a multidimensional poverty index (MPI) according to the Alkire-Foster method (2009). Data on COVID-19 hospitalizations and deaths in municipalities in the state of São Paulo in 2020 and 2021 were also collected. Finally, spatial analysis techniques, such as global and local Moran's indexes, were used to verify the association between COVID-19 indicators and the multidimensional poverty index. **Results:** The MPI was composed of 5 dimensions and 14 indicators, and 356 (55.19%) municipalities were considered multidimensionally poor for presenting a total of deprivations above the poverty line, defined at 0.2. A weak negative association was observed between the MPI and COVID-19 hospitalization and mortality rates in 2020 and 2021. Bivariate spatial correlation analysis showed a change in pattern between 2020 and 2021, highlighting a shift in the concentration of hospitalization and mortality rates towards municipalities in the interior of the state of São Paulo, particularly the formation of clusters of municipalities with high multidimensional poverty and high mortality rates in 2021, especially in the DRS of Registro and Sorocaba. **Conclusion:** The spatial characterization of the MPI and COVID-19 indicators, as well as the study of the relationship between these phenomena, can guide preventive and curative actions, as well as stimulate new studies in the area.

Keywords: Spatial Analysis, Smart Cities, COVID-19, Sustainable Development Goals, Multidimensional Poverty.

SUMÁRIO

1. INTRODUÇÃO	17
1.1. OBJETIVOS	20
1.1.1. Objetivo Geral	20
1.1.2. Objetivos Específicos	20
1.2. JUSTIFICATIVA	20
2. REFERENCIAL TEÓRICO	23
2.1. CONCEITOS DE POBREZA	23
2.1.1. Medidas para a pobreza multidimensional	26
2.1.2. A pobreza no contexto das Cidades Inteligentes	28
2.2. CIDADES INTELIGENTES	30
2.3. RELAÇÃO ENTRE POBREZA E SAÚDE	31
2.4. EPIDEMIAS, DETERMINANTES SOCIAIS DE SAÚDE E A PANDEMIA DE COVID-19	34
3. MÉTODOS	42
3.1. TIPO DE ESTUDO	42
3.2. ÁREA DE ESTUDO	42
3.3. POPULAÇÃO E PERÍODO DE ESTUDO	45
3.4. FONTES DE DADOS	46
3.5. CONSTRUÇÃO DO ÍNDICE DE POBREZA MULTIDIMENSIONAL	47
3.5.1. Unidades de medida e de análise	51
3.5.2. Dimensões e Indicadores	52
3.5.3. Cortes de privação e cortes de pobreza	58
3.6. TRATAMENTO DOS DADOS DE COVID-19 NO ESTADO DE SÃO PAULO	60
3.6.1. Descrição da base de dados de SRAG	61
3.7. RELAÇÃO DOS INDICADORES DE COVID-19 COM A POBREZA MULTIDIMENSIONAL	61
3.8. APRESENTAÇÃO DOS RESULTADOS	63
3.9. ASPECTOS ÉTICOS	64
4. RESULTADOS	65
4.1. EPIDEMIOLOGIA DESCRITIVA E DISTRIBUIÇÃO ESPACIAL DAS INTERNAÇÕES E DOS ÓBITOS CONFIRMADOS PARA COVID-19 NO ESTADO DE SÃO PAULO	65
4.2. O ÍNDICE DE POBREZA MULTIDIMENSIONAL NOS MUNICÍPIOS PAULISTAS	77
4.3. RELAÇÃO ENTRE POBREZA MULTIDIMENSIONAL E COVID-19	85
5. DISCUSSÃO	99

6. CONCLUSÃO E CONSIDERAÇÕES FINAIS	107
7. REFERÊNCIAS	109
Apêndice A - Intensidade da pobreza (A), Incidência da pobreza (H) e resultado do índice de pobreza multidimensional (M0) por Município do Estado de São Paulo.	117

LISTA DE SIGLAS

ACP	ANÁLISE DE COMPONENTES PRINCIPAIS
AF	ALKIRE-FOSTER
AIDS	SÍNDROME DA IMUNODEFICIÊNCIA ADQUIRIDA
ANS	AGÊNCIA NACIONAL DE SAÚDE SUPLEMENTAR
BA	BAHIA
CADUNICO	CADASTRO ÚNICO
CD	CENSO DEMOGRÁFICO
CE	CEARÁ
CF/88	CONSTITUIÇÃO FEDERAL BRASILEIRA DE 1988
CI	CIDADES INTELIGENTES
CIS	CIDADES INTELIGENTES E SUSTENTÁVEIS
CNS	CONSELHO NACIONAL DE SAÚDE
CP	COMPONENTE PRINCIPAL
CRAS	CENTRO DE REFERÊNCIA DE ASSISTÊNCIA SOCIAL
DA	DISTRITO ADMINISTRATIVO
DRS	DEPARTAMENTO REGIONAL DE SAÚDE
DSS	DETERMINANTES SOCIAIS DE SAÚDE
ESP	ESTADO DE SÃO PAULO
ESPII	EMERGÊNCIA DE SAÚDE PÚBLICA DE IMPORTÂNCIA INTERNACIONAL

ESPIN	EMERGÊNCIA EM SAÚDE PÚBLICA DE IMPORTÂNCIA NACIONAL
EUA	ESTADOS UNIDOS DA AMÉRICA
FDR	FALSE DISCOVERY RATE
GeoSES	ÍNDICE SOCIOECONÔMICO DO CONTEXTO GEOGRÁFICO PARA ESTUDOS EM SAÚDE
HIV	VÍRUS DA IMUNODEFICIÊNCIA HUMANA
IBGE	INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA
ICV	ÍNDICE DE CONDIÇÕES DE VIDA
IDEB	ÍNDICE DE DESENVOLVIMENTO DA EDUCAÇÃO BÁSICA
IDH	ÍNDICE DE DESENVOLVIMENTO HUMANO
IPM	ÍNDICE DE POBREZA MULTIDIMENSIONAL
HSH	HOMENS QUE TIVERAM RELAÇÕES SEXUAIS COM OUTROS HOMENS
JHU	JOHN HOPKINS UNIVERSITY
LGPD	LEI GERAL DE PROTEÇÃO DE DADOS PESSOAIS
LOAS	LEI ORGÂNICA DA ASSISTÊNCIA SOCIAL
MA	MARANHÃO
MEC	MINISTÉRIO DA EDUCAÇÃO
MS	MINISTÉRIO DA SAÚDE
MSP	MUNICÍPIO DE SÃO PAULO
ODS	OBJETIVOS DE DESENVOLVIMENTO SUSTENTÁVEL
OMS	ORGANIZAÇÃO MUNDIAL DA SAÚDE
ONU	ORGANIZAÇÃO DAS NAÇÕES UNIDAS

OPAS	ORGANIZAÇÃO PAN-AMERICANA DE SAÚDE
OPHI	INICIATIVA DE ESTUDOS DE POBREZA E DESENVOLVIMENTO HUMANO DA UNIVERSIDADE DE OXFORD
PIB	PRODUTO INTERNO BRUTO
PNAD	PESQUISA NACIONAL POR AMOSTRA DE DOMICÍLIOS
PNS	PESQUISA NACIONAL DE SAÚDE
POF	PESQUISA DE ORÇAMENTOS FAMILIARES
RSI	REGULAMENTO SANITÁRIO INTERNACIONAL
SE	SEMANA EPIDEMIOLÓGICA
SEADE	SISTEMA ESTADUAL DE ANÁLISE DE DADOS
SEDS	SECRETARIA DESENVOLVIMENTO SOCIAL DO ESTADO DE SÃO PAULO
SG	SÍNDROME GRIPAL
SISVAN	SISTEMA DE VIGILÂNCIA ALIMENTAR E NUTRICIONAL
SRAG	SÍNDROME RESPIRATÓRIA AGUDA GRAVE
TIC	TECNOLOGIAS DE INFORMAÇÃO E COMUNICAÇÃO
UDH	UNIDADE DE DESENVOLVIMENTO HUMANO
UF	UNIDADE FEDERADA
UNDP	UNITED NATIONS DEVELOPMENT PROGRAMME
UTI	UNIDADE DE TERAPIA INTENSIVA

LISTA DE QUADROS

Quadro 1 - Corte de pobreza oficial dos Estados Unidos da América, 2022.....	48
Quadro 2 - Medida de pobreza multidimensional do Banco Mundial, 2018.....	49
Quadro 3 - Dimensões, indicadores e respectivas fontes, selecionados para a construção do Índice de Pobreza Multidimensional no estado de São Paulo	54
Quadro 4 - Composição final dos indicadores do Índice de Pobreza Multidimensional: dimensão, indicadores e respectivos pesos	80

LISTA DE FIGURAS

Figura 1 - Modelo de Determinantes Sociais de Saúde de Dahlgren e Whitehead .	33
Figura 2 - Mapas do estado de São Paulo e do Brasil, 2022	43
Figura 3 - Mapa dos Departamentos Regionais de Saúde (DRS) do estado de São Paulo, 2022	45
Figura 4 - Internações por SRAG confirmadas para COVID-19, segundo faixa etária e ano. Estado de São Paulo, 2020 e 2021	68
Figura 5 - Óbitos confirmados para COVID-19, segundo faixa etária e ano. Estado de São Paulo, 2020 e 2021	68
Figura 6 - Taxas de internações brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2020	70
Figura 7 - Taxas de internações brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2021	71
Figura 8 - Taxas de internações padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS) e ano. Estado de São Paulo, 2020 e 2021	72

- Figura 9** - Mapas das taxas de internações por COVID-19, por 100 mil habitantes, segundo município e ano. (A) Taxas brutas em 2020. (B) Taxas padronizadas em 2020. (C) Taxas brutas em 2021. (D) Taxas padronizadas em 2021. Estado de São Paulo, 2020 e 2021 73
- Figura 10** - Taxas de mortalidade brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2020 74
- Figura 11** - Taxas de mortalidade brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2021 75
- Figura 12** - Taxas de mortalidade padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS) e ano. Estado de São Paulo, 2020 e 2021 76
- Figura 13** - Mapas das taxas de mortalidade por COVID-19, por 100 mil habitantes, segundo município e ano. (A) Taxas brutas em 2020. (B) Taxas padronizadas em 2020. (C) Taxas brutas em 2021. (D) Taxas padronizadas em 2021. Estado de São Paulo, 2020 e 2021 77
- Figura 14** - Mapa dos Índices de Pobreza Multidimensional segundo município do estado de São Paulo, com destaque para os limites dos Departamentos Regionais de Saúde, 2022 82
- Figura 15** - Mapa dos Índices de Pobreza Multidimensional segundo Departamento Regional de Saúde (DRS) do estado de São Paulo, 2022 83
- Figura 16** - Mapa da autocorrelação espacial das taxas de internação padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2020 90
- Figura 17** - Mapa da autocorrelação espacial das taxas de internação padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2021 91

Figura 18 - Mapa da autocorrelação espacial das taxas de mortalidade padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2020	92
Figura 19 - Mapa da autocorrelação espacial das taxas de mortalidade padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2021	93
Figura 20 - Mapa da autocorrelação espacial do Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2022	94
Figura 21 - Mapa da correlação espacial entre a taxa de internação padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2020	95
Figura 22 - Mapa da correlação espacial entre a taxa de internação padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2021	96
Figura 23 - Mapa da correlação espacial entre a taxa de mortalidade padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2020	97
Figura 24 - Mapa da correlação espacial entre a taxa de mortalidade padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2021	98

LISTA DE TABELAS

Tabela 1 - Análise dos cortes de pobreza de acordo com o teste de correlação de Tau de Kendall	59
Tabela 2 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo sexo e ano. Estado de São Paulo, 2020 e 2021	66
Tabela 3 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo raça/cor e ano. Estado de São Paulo, 2020 e 2021.....	66

Tabela 4 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo escolaridade e ano. Estado de São Paulo, 2020 e 2021	67
Tabela 5 - Distribuição dos sinais e sintomas apresentados pelos casos internados de SRAG, confirmados para COVID-19, segundo ano. Estado de São Paulo, 2020 e 2021.....	69
Tabela 6 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Educação”	78
Tabela 7 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Condições Habitacionais”	78
Tabela 8 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Saúde e Assistência Social”	79
Tabela 9 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Trabalho e Renda”	79
Tabela 10 - Índices de Pobreza Multidimensional calculados para os Departamentos Regionais de Saúde (DRS) do estado de São Paulo, 2022	84
Tabela 11 - Resultados do teste de normalidade de <i>Shapiro-Wilk</i> para os indicadores de COVID-19 e o Índice de Pobreza Multidimensional nos municípios do estado de São Paulo, em 2020 e 2021	85
Tabela 12 - Resultados dos coeficientes de correlação de <i>Spearman</i> entre o Índice de Pobreza Multidimensional (IPM) e os indicadores padronizados de COVID-19 nos municípios do estado de São Paulo, em 2020 e 2021	86
Tabela 13 - Resultados dos coeficientes de correlação de <i>Spearman</i> entre o Índice de Pobreza Multidimensional (IPM) e os indicadores padronizados de COVID-19, segundo os Departamentos Regionais de Saúde do estado de São Paulo, em 2020 e 2021	87
Tabela 14 - Índices de Moran Global univariados do Índice de Pobreza Multidimensional e dos indicadores padronizados de internação e de óbito por COVID-19 nos municípios do estado de São Paulo, em 2020 e 2021.	89

1. INTRODUÇÃO

O debate sobre a pobreza é central para o Brasil, para o mundo e para as políticas públicas. De acordo com o inciso III do artigo 3º da Constituição Federal Brasileira de 1988 (CF/88), a erradicação da pobreza é um objetivo fundamental da nação (Constituição da República Federativa do Brasil, 1988). A Agenda 2030 da Organização das Nações Unidas (ONU), da qual o Brasil é signatário, também elenca como o primeiro, entre os 17 Objetivos de Desenvolvimento Sustentável (ODS), a erradicação da pobreza em todas as suas formas (ONU, 2016).

Por outro lado, as inovações tecnológicas e as transformações políticas e sociais fazem com que as cidades se deparem, a todo momento, com soluções inovadoras para problemas cada vez mais complexos, e, nesse sentido, as cidades têm se reorganizado dinamicamente. Por isso, o conceito de “Cidades Inteligentes” (CI) tem sido amplamente debatido na academia, sofrendo transformações ao longo do tempo (Dallabrida, 2020, pp. 50-51). Inicialmente atrelado à ideia de cidade conectada, com grande infraestrutura de serviços de Tecnologia de Informação e Comunicação (TIC), na qual governantes e sociedade poderiam ter acesso a dados e informações para a tomada de decisão, o conceito rompeu as fronteiras da área da tecnologia, alcançando outras áreas do conhecimento que contribuíram para a sua construção. Assim, a visão de Cidades Inteligentes a partir das TIC’s foi combinada com uma abordagem que considera a gestão territorial, a participação social, a inovação e a integração de políticas públicas, sendo as TIC’s ferramentas utilizadas em favor da cidade e da sociedade. Alinhada a esta perspectiva, a Câmara dos Deputados, em um estudo publicado em 2021, conceitua Cidades Inteligentes a partir de uma abordagem humana e sustentável, em que a tecnologia e a infraestrutura da cidade propiciam maior inclusão, participação e bem-estar na vida das pessoas (Câmara dos Deputados, 2021).

Por outro lado, ainda que as TICs tenham o potencial de contribuir para construção de cidades e territórios inteligentes, o acesso a estas tecnologias ainda é bastante desigual no mundo e no Brasil. De acordo com a Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD) que analisou o acesso à televisão e à internet no quarto semestre de 2021, cerca de 15,33% da população brasileira não tem acesso à internet. Considerando ainda que no período pandêmico o distanciamento social tornou-se determinação legal, a falta de acesso pode ter sido fator determinante para

uma exclusão social ainda mais grave para estas pessoas. Mozorov (2019) descreve como a ideia de cidades inteligentes e a implementação de soluções tecnológicas, ao mesmo tempo que promovem a eficiência e o bem-estar, podem aumentar as desigualdades e a concentração de poder político.

Ao pensarmos na ideia de Cidades Inteligentes e Sustentáveis (CIS), a pobreza certamente não poderá estar presente nesse contexto; talvez por isso a sua erradicação seja o primeiro dos 17 ODS definidos pela ONU. Destaca-se que o conceito de pobreza extrapola a ideia de pobreza meramente atrelada à renda, sendo considerado aqui o conceito de pobreza multidimensional, conforme defendido por Sen (2010), para quem, “a pobreza deve ser vista como privação de capacidades básicas em vez de meramente como baixo nível de renda” (Sen, 2010, p.120), ainda que o baixo nível de renda seja uma privação relevante.

Soma-se a isto o fato de, em 2019, o mundo ter registrado o primeiro caso de Síndrome Respiratória Aguda Grave (SRAG), causada pelo vírus SARS-CoV-2, responsável pela doença COVID-19, que, em 11 de janeiro de 2020, foi declarada como uma pandemia pela Organização Mundial da Saúde (OMS), organização vinculada à ONU (Organização Pan-Americana da Saúde [OPAS], 2020a).

No Brasil, o primeiro caso de COVID-19 foi confirmado pelo Ministério da Saúde (MS) em 26 de fevereiro de 2020, na cidade de São Paulo (Ferreira, 2020). No estado de São Paulo (ESP), o Governo determinou medidas de combate à pandemia, destacando-se a criação do Centro de Contingência do Coronavírus e a instituição do Plano São Paulo, que impôs medidas de circulação e distanciamento social mais ou menos rígidas, conforme a evolução dos indicadores relacionados à COVID-19 (São Paulo, 2020).

Nesse contexto, o impacto econômico da pandemia passou a ser objeto de discussão política e acadêmica. Em relatório do Banco Mundial, a previsão era a de que a pandemia de COVID-19 não só interromperia o histórico de queda de pobreza no mundo, mas também aumentaria o número de pessoas abaixo da linha da pobreza, que, em 2019, era de 648 milhões de pessoas, podendo chegar a 685 milhões em 2022, sendo que a previsão pré-pandemia considerava uma redução da pobreza no mundo, que em 2022 atingiria 596 milhões de pessoas (Banco Mundial, 2022, p.7). Ou seja, a pandemia deveria aumentar o número de pessoas em condição de pobreza no mundo em 15%.

Assim, tendo o Brasil se comprometido com os ODS, a atuação dos entes subnacionais é mister para alcançar as metas estabelecidas na Agenda 2030 da ONU. Sendo São Paulo um estado pujante, econômica e populacionalmente, a pergunta de pesquisa que se coloca é: como os indicadores de óbitos e internações por COVID-19 se relacionam com a pobreza multidimensional nos municípios do ESP?

Para responder a esta pergunta, este trabalho se debruçou sobre como a academia tem estudado a pobreza no bojo dos determinantes sociais de saúde (DSS), buscando entender e explicar a relação entre a saúde e fatores socioeconômicos. Dessa forma, esta dissertação se estrutura da seguinte forma: no primeiro capítulo apresentamos a introdução, os objetivos e a justificativa do estudo. No segundo capítulo, trazemos os principais conceitos teóricos abordados, de modo que o leitor possa compreender o que é pobreza, o que é saúde, o que são os determinantes sociais de saúde e como isto é percebido em um contexto de cidades inteligentes.

No terceiro capítulo está descrita a metodologia empregada para a construção do índice de pobreza multidimensional (IPM) e para compreender a relação entre a pobreza multidimensional e os indicadores referentes às internações e aos óbitos por COVID-19 nos municípios paulistas. Neste capítulo estão descritos: o tipo de estudo, a área do estudo, sua população e período considerado, as fontes de dados e os procedimentos para a construção do IPM, como foram tratados os indicadores de COVID-19 e como foi analisada a relação entre a pobreza e a COVID-19. Os capítulos quatro e cinco - Resultados e Discussão, respectivamente - apresentam e discutem os principais achados da pesquisa, espacializando os dados de COVID-19 e de pobreza multidimensional nos municípios do ESP, e, por fim, os achados referentes à correlação espacial entre pobreza e COVID-19. O sexto e último capítulo dedica-se à finalização da dissertação, trazendo as conclusões e considerações finais.

1.1. OBJETIVOS

1.1.1. Objetivo Geral

Construir um indicador de pobreza multidimensional para os municípios do estado de São Paulo, e identificar a relação entre a pobreza multidimensional e indicadores de internação e óbito por COVID-19.

1.1.2. Objetivos Específicos

- ✓ Descrever os casos internados por SRAG e óbitos, confirmados para COVID-19 no estado de São Paulo, nos anos pandêmicos de 2020 e 2021, segundo pessoa, tempo e lugar;
- ✓ Caracterizar a distribuição espacial dos indicadores de internação e de óbito por COVID-19 nos municípios do estado de São Paulo, nos anos pandêmicos de 2020 e 2021;
- ✓ Construir um Índice de Pobreza Multidimensional para os municípios do estado de São Paulo;
- ✓ Descrever a distribuição espacial do Índice de Pobreza Multidimensional nos municípios do estado de São Paulo;
- ✓ Verificar a relação entre os indicadores de internação e de óbito por COVID-19 e o Índice de Pobreza Multidimensional nos municípios do estado de São Paulo.

1.2. JUSTIFICATIVA

A erradicação da pobreza em todas as suas formas e lugares é o primeiro dos Objetivos de Desenvolvimento Sustentável definidos na Agenda 2030 da ONU, sendo necessário compreender a pobreza para além da renda, como uma situação de privação vivida por um indivíduo. Assim, construir um índice de pobreza multidimensional que permita a espacialização da pobreza entre os municípios do

ESP, considerando as especificidades deste estado, permite oferecer um produto que pode subsidiar políticas públicas, planos estaduais e locais, e até mesmo outros estudos que contribuam para que o alcance do primeiro dos ODS se torne cada dia mais próximo.

Cumprе ressaltar que a Secretaria de Desenvolvimento Social do Estado de São Paulo (SEDS) desenvolveu, em 2015, um índice de pobreza multidimensional para monitorar e acompanhar a pobreza no ESP. Todavia, o cálculo deste indicador é realizado a partir das informações apenas dos cidadãos cadastrados no Cadastro Único (CADUNICO), que é uma ferramenta do Ministério da Cidadania para a identificação e caracterização da população de baixa renda no Brasil. Assim, o IPM mantido pela SEDS mede a pobreza multidimensional em um grupo bastante específico da população, diferentemente da proposta deste estudo, que utiliza dados do Censo Demográfico (CD). Dessa forma, o uso dos dados do Censo mostra-se mais adequado, ao passo que engloba toda a população, e não somente aquela inscrita no Cadastro Único.

Nesse aspecto, o presente trabalho busca colaborar para a construção e a sistematização do conhecimento sobre a pobreza no ESP. Considerando, ainda, o contexto pandêmico em 2020 e 2021, período abrangido neste estudo, é igualmente relevante entender como a pandemia se associa à pobreza multidimensional no ESP. Adicionalmente, este trabalho propõe uma reflexão em um nível de escala para além da cidade, buscando entender dinâmicas regionais que ultrapassam os limites municipais.

Estudos buscando compreender a relação entre a COVID-19 e indicadores socioeconômicos já foram desenvolvidos, indicando a importância deste tipo de análise para a construção do conhecimento (Ferreira, 2020; Oliveira et al., 2021). Entretanto, a relação entre a pobreza multidimensional e a COVID-19 tem sido pouco explorada nos trabalhos acadêmicos (Tavares & Betti, 2021; Polo et al. 2022; Henao-Cespedes et al., 2022). A compreensão da pobreza como um fenômeno para além da variável renda é um fator chave para a superação das mais variadas privações vividas pelas camadas mais necessitadas da sociedade, sobretudo em um contexto pandêmico. Ademais, considerar a pobreza de forma mais ampla do que apenas baseada em questões econômicas e financeiras é estar alinhado com o preconizado no ODS 1 da ONU, de erradicação da pobreza em todas as suas formas.

Outrossim, entender as diferenças socioespaciais dos municípios do ESP e sua relação com indicadores de saúde é fundamental para o planejamento das ações governamentais a nível municipal, regional e estadual. Destaca-se que, tanto o Sistema Único de Saúde (SUS), principal política pública de combate à pandemia, e o Sistema Único da Assistência Social, principal política pública de combate à pobreza, se organizam a partir da cooperação e integração dos entes federados, os municípios, estados e a união. Assim, os serviços são concebidos considerando as realidades locais, regionais e nacionais, pois apenas as ações isoladas de um município não são capazes de solucionar questões de âmbito regional. Dessa forma, é fundamental o fomento e a ampliação do debate e construção de soluções regionais. Assim, a compreensão da relação entre saúde e condições socioeconômicas, no caso deste trabalho entre a COVID-19 e a pobreza multidimensional, colabora para o planejamento e o desenvolvimento regional.

Logo, a contribuição deste trabalho consiste em ampliar o debate acadêmico a nível de planejamento urbano e desenvolvimento regional, e compreender a dispersão espacial dos indicadores de COVID-19 no ESP, bem como, por meio da construção de um IPM adequado à realidade desta Unidade Federada (UF), verificar a relação entre a pobreza multidimensional e a COVID-19 em seus municípios. Portanto, este estudo ecológico tem o potencial de fornecer algumas informações necessárias para o entendimento da relação entre o IPM e a COVID-19 e indicar caminhos para a prevenção em cenários futuros.

2. REFERENCIAL TEÓRICO

Para o desenvolvimento desta pesquisa, os conceitos centrais trabalhados foram os de “Pobreza”, “Cidades Inteligentes” e “Determinantes Sociais de Saúde” (DSS), além da “Relação entre a COVID-19 e indicadores sociais”. Assim, este capítulo dedica-se a esses temas, formando o arcabouço teórico para o entendimento sobre “qual pobreza”, em “qual localidade”, “como a pobreza se conecta com a saúde e como se relaciona com a pandemia de COVID-19”.

2.1. CONCEITOS DE POBREZA

Ao longo da segunda metade do século XX, em especial a partir dos anos 1980, o debate em torno do conceito de pobreza e de como medir a pobreza em uma determinada sociedade se intensificou e se aprofundou (Hagenaars & Vos, 1988). Até então, considerava-se “pobre” todo indivíduo que não possuía renda suficiente para adquirir uma cesta básica de bens que suprisse suas necessidades alimentares, multiplicada por três para contemplar outras despesas da família¹ (Kageyama & Hoffmann, 2006).

Assim, acendeu-se um debate sobre a definição do conceito de pobreza. De acordo com Hagenaars e Vos (1988):

Basicamente, todas as definições podem ser classificadas em uma das categorias abaixo:

- A. Pobreza é ter menos do que um mínimo absoluto objetivamente definido.
- B. Pobreza é ter menos do que outros naquela sociedade.
- C. Pobreza é o sentimento de que você não tem o suficiente para sobreviver.

A pobreza, de acordo com a primeira categoria de definição, é absoluta; para a segunda categoria é relativa, e conforme a terceira categoria pode ser absoluta, relativa, ou estar entre ambas. Outra diferença entre as categorias é que a terceira define pobreza subjetivamente, enquanto a primeira e a segunda definem pobreza em uma situação objetiva (p. 212, tradução do autor).

¹ *United States Census Bureau. The History of the Official Poverty Measure.* Disponível em: <https://www.census.gov/topics/income-poverty/poverty/about/history-of-the-poverty-measure.html#:~:text=The%20current%20official%20poverty%20measure,account%20for%20other%20family%20expenses>

Nota-se, aqui, que o conceito de pobreza é separado em três categorias: 1) pobreza absoluta; 2) pobreza relativa; e 3) sensação subjetiva de pobreza. Ainda nesse mesmo estudo, os autores destacam quatro subcategorias de pobreza absoluta, uma para a pobreza relativa e três para a definição subjetiva de pobreza (Hagenaars & Vos, 1988).

A pobreza absoluta pode, ainda, ser classificada como: 1) um mínimo absoluto de renda para a aquisição de bens de necessidades básicas (vestimenta, habitação e alimentação, por exemplo); 2) a relação entre o total gasto com alimentação e o total da renda, sendo que, se esta relação for superior a um terço, está configurada a situação de pobreza; 3) a relação entre o total de gastos fixos (aluguel, energia, transporte) e a renda; e 4) a relação entre o gasto corrente e a renda, de modo a identificar famílias que rotineiramente recorrem a linhas de crédito para o pagamento de suas despesas, e se o resultado desta relação for maior do que 1, aquele indivíduo ou família é considerado(a) pobre.

Quanto à subcategoria de pobreza relativa, ela pode ser observada quando um indivíduo ou uma família tem uma defasagem de bens que são de consumo comum em uma determinada sociedade.

Por fim, as três subdivisões da definição subjetiva de pobreza são: 1) a definição de um mínimo de renda subjetivo a partir do quanto aquele indivíduo ou família entende como suficiente, comparado ao quanto aquele indivíduo ou família efetivamente recebe; 2) a definição que busca conciliar o conceito de pobreza subjetiva com a abordagem de necessidades básicas, perguntando às pessoas o que elas consideram como uma cesta mínima de bens para a superação da pobreza, e verifica-se, então, se aquele indivíduo ou família possui renda para a aquisição de tal cesta de bens; e 3) a definição de um mínimo oficial de renda, como o valor que uma pessoa ou família recebe estando em um programa de proteção ou assistência social (Hagenaars & Vos, 1988).

Crespo e Gurovitz (2002), em uma revisão bibliográfica, apresentam como a academia tem pensado e discutido o conceito de pobreza. Assim, os autores identificam três eixos de estudo sobre a pobreza: 1) sobrevivência; 2) necessidades básicas; e 3) privação relativa.

O conceito de “pobreza-sobrevivência” está atrelado à ideia de nutrição e manutenção da saúde física. Este conceito embasou muitas políticas públicas de bem-estar social na segunda metade do século XX; entretanto, o ponto de crítica a este

modelo é a ideia de atender o mínimo para a sobrevivência. O conceito de pobreza baseado em necessidades básicas está vinculado aos serviços e bens essenciais para a vida, tais como água potável, saneamento básico, saúde e educação. Ampliou-se, então, a percepção anterior de pobreza, superando a ideia de sobrevivência. Em mais um passo dado nessa discussão, o conceito de pobreza como privação relativa leva em consideração critérios mais rigorosos e uma sistematização científica que possibilita a comparação entre estudos e análises, incorporando também os aspectos observados de níveis de conforto e papéis sociais desempenhados, trazendo, inclusive, um olhar social para a pobreza, e não apenas individual (Crespo & Gurovitz, 2002).

Nessa perspectiva de pobreza como “privação relativa”, Anand e Sen (1997) afirmam que “Pobreza é, em diversas maneiras, a pior forma de privação humana. Isto pode englobar não apenas as necessidades de bem-estar material, mas também a negação de oportunidades de viver uma vida tolerável.” (p. 4). Logo, a pobreza passa a ser entendida como a privação de capacidades.

De acordo com Sen (2010), “[...] a pobreza deve ser vista como privação de capacidades básicas em vez de meramente como baixo nível de renda [...]” (p. 120), ou seja, a conceituação de pobreza por meio unicamente da variável renda despreza diversos outros aspectos fundamentais para se compreender a pobreza real de um indivíduo em seu contexto socioeconômico. O mesmo autor afirma que três argumentos sustentam o conceito de pobreza como a privação de capacidades: 1) a pobreza analisada sob a perspectiva de renda é instrumental, enquanto a ideia de privação de capacidades considera fatores intrinsecamente relevantes, como acesso a serviços de educação e saúde, por exemplo; 2) embora a renda seja uma importante ferramenta de geração de capacidades, outras variáveis também são relevantes para a análise da pobreza real; e 3) a relação entre baixa renda e privação de capacidades não é linear, pois existem outros fatores a se considerar, tais como idade, papéis sexuais e sociais, localização, condições epidemiológicas, além da possível concorrência de diversos destes fatores para um mesmo indivíduo.

Outro ponto destacado por Sen (2010) é a distribuição desigual da renda dentro da própria família, e, por fim, o autor aponta que, em países ricos, pessoas podem ser consideradas pobres, ainda que sua renda seja maior quando comparada à de outros países e sociedades; contudo, esta pobreza é relativa àquele contexto social, por

trazer dificuldades para participar da vida de uma comunidade, em decorrência de não conseguir atingir um determinado patamar de consumo, por exemplo.

Neste trabalho, o conceito de pobreza abordado é justamente aquele apresentado por Sen (2010), isto é, compreendendo a pobreza a partir de privações que os municípios paulistas apresentam, impossibilitando o desenvolvimento das capacidades dos cidadãos, que, em decorrência dessas privações, experimentam uma situação de pobreza. Ou seja, a pobreza que considera não apenas a renda, mas também outros aspectos que podem privar um indivíduo de desenvolver suas capacidades.

2.1.1. Medidas para a pobreza multidimensional

Tendo Sen (2010) apresentado seu conceito de pobreza, um novo desafio se apresentava - como medir a pobreza de maneira multidimensional? Inicialmente, duas abordagens foram consideradas: a abordagem de “união”, e a abordagem de “intersecção”. Quando se considera a pobreza multidimensional a partir da “união”, buscam-se as pessoas que têm baixa renda, ou condições de moradia ruins, ou baixo nível de escolaridade; enquanto a “intersecção” procura aqueles que têm baixa renda, condições de moradia ruins e baixo nível de escolaridade, ou seja, as três condições ao mesmo tempo (Atkinson, 2003).

Alkire e Foster (2011) propuseram, então, uma metodologia de mensuração da pobreza multidimensional, o método Alkire-Foster (AF), que consiste em identificar as privações que um determinado indivíduo sofre em um dado número de indicadores que estão em n dimensões. Assim, temos, para cada dimensão, um conjunto de indicadores que a compõem, e, para cada um desses indicadores, é definido um corte de pobreza, possibilitando a identificação de uma privação, ou não, e, combinado com os demais indicadores das outras dimensões, conta-se a quantidade de privações para que seja aplicado um segundo corte de pobreza, determinando, assim, a sua multidimensionalidade (Alkire & Foster, 2011).

Nessa metodologia, cabe destacar dois pontos: mensura-se a incidência da pobreza, isto é, quantos indivíduos são multidimensionalmente pobres; e também a amplitude desta pobreza, ou seja, o quanto esses indivíduos são multidimensionalmente pobres, haja vista que é isso o que a soma das privações indica (Alkire & Foster, 2011). No Capítulo 3, de Métodos, serão detalhadamente

descritos os passos e os procedimentos realizados neste trabalho para a elaboração do IPM pelo método Alkire-Foster.

Atualmente, diversos países têm adotado medidas de pobreza multidimensional como índices oficiais para a elaboração de políticas públicas e o subsídio de processos de planejamento. O método Alkire-Foster (AF) tornou-se, então, uma das principais maneiras de medir a pobreza multidimensional. Considerando apenas os países da América Latina, ao menos nove países já utilizam algum índice de pobreza multidimensional, a saber: México, 2009; Chile, 2015; Costa Rica, 2015; Equador, 2015; Honduras, 2016; República Dominicana, 2017; Panamá, 2018; Colômbia, 2020 e Paraguai, 2021.

Alkire e Santos (2014) apresentam uma proposta de IPM global, de modo a possibilitar a comparação da pobreza multidimensional entre diferentes países. As autoras propõem três dimensões: 1) saúde; 2) educação e 3) padrão de vida. A dimensão “saúde” contempla dois indicadores - desnutrição e mortalidade infantil. No que tange ao tema “educação”, os indicadores utilizados são anos de escolaridade e frequência das crianças na escola; e, por fim, na dimensão “padrão de vida”, é observado se há acesso à energia elétrica e água potável, condições de saneamento e habitação, combustível para cozinhar, e se há bens como rádio, televisão, telefone, bicicleta, motocicleta, geladeira, carro ou caminhão (Alkire & Santos, 2014).

As autoras justificam a opção pelo método AF para a mensuração da pobreza multidimensional sob os argumentos de que este método possibilita: 1) o uso de variáveis cardinais e ordinais; 2) atende ao princípio da monotonicidade, ou seja, caso um indivíduo multidimensionalmente pobre altere as suas condições de privação, o IPM medirá esta alteração, pois o cálculo do hiato de pobreza indicará o quanto aquele indivíduo tem de privações; 3) a possibilidade de decompor o IPM por subgrupos, identificando diferenças nas privações destes estratos; e 4) permite dividir o IPM em indicadores e perceber a influência de cada variável nas privações da população (Alkire & Santos, 2014, p. 253).

Já em 2021, Alkire e Kanagaratnam discutiram as possibilidades de avanços e a incorporação de novas variáveis ao IPM Global criado por Alkire e Santos (2014), de modo a alinhar o IPM global aos ODS da ONU. As autoras apontaram 33 (trinta e três) indicadores que poderiam fortalecer a medida de pobreza multidimensional, tendo se debruçado sobre pesquisas nacionais de 105 países, buscando analisar, dentre os 33 indicadores listados, quais possibilitariam que o IPM Global fosse

calculado para ao menos 75 países e 3,5 bilhões de pessoas. Com base nesses critérios, identificaram os indicadores “possuir computador ou *notebook*”, “carroça de tração animal”, “terreno e tamanho de terreno”, “propriedade de gado/rebanhos/aves”, “conta bancária” e “quantidade de quartos usados como dormitório”. Por fim, analisando esses seis indicadores, as autoras justificam que apenas “possuir computador ou *notebook*” e “carroça de tração animal” deveriam ser incluídos como medidas de privação ao indicador de posse de bens da dimensão de padrão de vida do IPM Global original criado por Alkire e Santos (2014). Quanto aos outros indicadores do IPM Global original, Alkire e Kanagaratnam (2021) propuseram alterações nos cortes de privação nos indicadores de nutrição, mortalidade infantil, moradia e posse de bens, tornando-os mais exigentes, ou contemplando mais fatores para a determinação da privação.

Por fim, é importante destacar que a ONU, em parceria com a Iniciativa de Estudos de Pobreza e Desenvolvimento Humano da Universidade de Oxford, publicou um livro para orientar sobre como elaborar um IPM para monitorar os ODS, propondo a construção de IPM a partir do método AF (*United Nations Development Programme & Oxford Poverty and Human Development Initiative*, 2019, p. 47).

2.1.2. A pobreza no contexto das Cidades Inteligentes

Em 2000, os chefes de diversas nações, reunidos em Assembleia Geral da Organização das Nações Unidas (ONU), elaboraram um documento chamado de “Declaração do Milênio”, no qual se estabeleceram diversos objetivos para o desenvolvimento, dentre os quais, o primeiro tratava de “reduzir para a metade, até o ano de 2015, a porcentagem de habitantes do planeta com rendimentos inferiores a um dólar por dia, e a das pessoas que passam fome; de igual modo, reduzir para a metade a porcentagem de pessoas que não têm acesso a água potável ou carecem de meios para obtê-la” (ONU, 2001, p. 9).

Em 2016, ou seja, após o prazo estabelecido pela Declaração do Milênio, a ONU criou a Agenda 2030, elencando 17 Objetivos de Desenvolvimento Sustentável, sendo o primeiro desta lista o seguinte: “Objetivo 1. Acabar com a pobreza em todas as suas formas, em todos os lugares” (ONU, 2016, p. 15).

Cumpra ressaltar que o texto do Objetivo 1 considera a pobreza “em todas as suas formas”; ademais, este objetivo geral se desdobra em sete objetivos específicos, abaixo transcritos:

- 1.1. Até 2030, erradicar a pobreza extrema para todas as pessoas em todos os lugares, atualmente medida como pessoas vivendo com menos de US\$ 1,90 por dia;
- 1.2. Até 2030, reduzir pelo menos à metade a proporção de homens, mulheres e crianças, de todas as idades, que vivem na pobreza, em todas as suas dimensões, de acordo com as definições nacionais;
- 1.3. Implementar, em nível nacional, medidas e sistemas de proteção social adequados, para todos, incluindo pisos, e até 2030 atingir a cobertura substancial dos pobres e vulneráveis;
- 1.4. Até 2030, garantir que todos os homens e mulheres, particularmente os pobres e vulneráveis, tenham direitos iguais aos recursos econômicos, bem como o acesso a serviços básicos, propriedade e controle sobre a terra e outras formas de propriedade, herança, recursos naturais, novas tecnologias apropriadas e serviços financeiros, incluindo microfinanças;
- 1.5. Até 2030, construir a resiliência dos pobres e daqueles em situação de vulnerabilidade, e reduzir a exposição e vulnerabilidade destes a eventos extremos relacionados com o clima e outros choques e desastres econômicos, sociais e ambientais;
- 1.6. Garantir uma mobilização significativa de recursos a partir de uma variedade de fontes, inclusive por meio do reforço da cooperação para o desenvolvimento, para proporcionar meios adequados e previsíveis para que os países em desenvolvimento, em particular os países menos desenvolvidos, implementem programas e políticas para acabar com a pobreza em todas as suas dimensões;
- 1.7. Criar marcos políticos sólidos em níveis nacional, regional e internacional, com base em estratégias de desenvolvimento a favor dos pobres e sensíveis ao gênero, para apoiar investimentos acelerados nas ações de erradicação da pobreza (ONU, 2016, p.17).

Nota-se que o conceito de pobreza apresentado, ainda que não explicitamente, no relatório da ONU, transcende a ideia de pobreza medida apenas pela renda, mas considera questões como gênero, vulnerabilidade, acesso a serviços básicos, além de citar o termo “pobreza em todas as suas dimensões”, aproximando-se, assim, do conceito de pobreza como privação de capacidades descrito por Sen (2010).

2.2. CIDADES INTELIGENTES

O surgimento de novas tecnologias é diário. A todo momento, inovações apresentam novas e mais modernas soluções, mais rápidas e mais eficientes para as demandas do cotidiano. Inicialmente atrelado à ideia de cidade conectada, com grande infraestrutura de serviços de Tecnologias de Informação e Comunicação (TICs), o conceito de Cidades Inteligentes (CI) rompeu as fronteiras da área da tecnologia, alcançando outras áreas do conhecimento que contribuíram para a sua construção. Assim, a visão de cidades inteligentes a partir das TIC foi superada com uma proposta mais abrangente, considerando a gestão territorial, a participação social, a inovação, a integração de políticas públicas e o capital humano. Nas palavras de Dallabrida (2020), “Cidades Inteligentes são consideradas aquelas que desenvolvem iniciativas de excelência para dar resposta às necessidades da pessoa humana, inspiradas numa concepção inovadora mediante a utilização de TIC.” (Dallabrida, 2020, p. 52).

Em relatório recente, o Centro de Estudos e Debates Estratégicos da Câmara dos Deputados conceituou “Cidades Inteligentes” da seguinte forma:

“Cidade inteligente é o espaço urbano orientado para o investimento em capital humano e social, o desenvolvimento econômico sustentável e o uso de tecnologias disponíveis para aprimorar e interconectar os serviços e a infraestrutura das cidades, de modo inclusivo, participativo, transparente e inovador, com foco na elevação da qualidade de vida e do bem-estar dos cidadãos.” (Câmara dos Deputados, 2021, p. 21).

Logo, percebe-se que o conceito de CI abarca, atualmente, questões muito além da inovação e da tecnologia. Isso é fundamental para a compreensão do conceito de pobreza multidimensional no contexto das Cidades Inteligentes e Sustentáveis (CIS).

Todavia, o levantamento realizado pela Pesquisa Nacional por Amostra de Domicílios Contínua (PNAD), referente ao quarto trimestre de 2021, revelou que aproximadamente 15,33% da população brasileira não possui acesso à internet. Tal situação pode ter contribuído para uma exclusão social dessas pessoas de forma ainda mais severa durante o período pandêmico, em que o distanciamento social se tornou obrigatório.

Outrossim, ainda que as tecnologias da informação gerem soluções mais eficientes, automatize processos e gere ganhos para a sociedade, é importante refletir

também sobre como estes benefícios são distribuídos na sociedade. Para Morozov (2019) a discussão sobre as cidades inteligentes apresentou grandes dificuldades em colocar o cidadão no centro do processo de desenvolvimento, sendo que, segundo o autor, o debate deu-se muito mais em torno do termo “*inteligente*”, e que o debate sobre as cidades se relegou ao segundo plano. Neste aspecto, o autor relaciona como o processo implementação de soluções inteligentes para as cidades desloca para a governança de poucos agentes privados boa parte da competência estatal, sobretudo nos projetos de infraestrutura. Assim, organizações que concentram grande poder econômico apresentam projetos inovadores que trazem eficiência, mas que desumanizam a cidade e concentram poder econômico e poder político na mão de algumas empresas (Morozov, 2019).

“Ainda que a tecnologia esteja fornecendo processos e produtos mais rápidos, melhores e mais baratos, avanços nas ciências da vida, em inteligência artificial, em Big Data etc., também é possível observar um aumento nas desigualdades em distribuição de renda, riqueza e poder político.” (Morozov, 2019, p.160)

Assim, o aspecto multidimensional da pobreza, como explicado anteriormente, conjugado com uma ideia de Cidades Inteligentes em que o cidadão seja verdadeiramente o protagonista do processo de desenvolvimento, indica o motivo de o primeiro Objetivo de Desenvolvimento Sustentável ser a erradicação da pobreza em todas as suas formas e lugares, sendo, então, central que os países e seus entes subnacionais se organizem institucionalmente, e, conjuntamente com a sociedade, pensem, discutam e apresentem soluções para o alcance deste objetivo.

2.3. RELAÇÃO ENTRE POBREZA E SAÚDE

A saúde de um indivíduo, ou de uma população, varia não somente de acordo com os aspectos biológicos, visto que existem outros fatores que influenciam a disseminação de uma doença em uma determinada população. Assim, a multidimensionalidade do processo saúde-doença deve ser compreendida levando-se em conta questões sociais, econômicas, culturais, raciais, psicológicas e ambientais, em que o indivíduo ou uma população está inserido. Logo, para uma compreensão mais abrangente do processo saúde-doença, no final da década de 1970, começou a ganhar força sua concepção como um processo sistêmico (Cruz, 2011).

A OMS conceitua saúde como “(...) um estado de completo bem-estar físico, mental e social, e não apenas a ausência de doença ou de enfermidade” (OMS, 1946). É possível perceber, então, que a ideia de saúde engloba não somente aspectos individuais, mas também as relações e as circunstâncias sociais de cada indivíduo ou grupo.

Nesse contexto, diversos estudos buscam conceituar o que seriam os Determinantes Sociais de Saúde (DSS), e, em um trabalho de revisão bibliográfica sobre este conceito, Buss e Filho (2007) afirmam que:

As diversas definições de determinantes sociais de saúde (DSS) expressam, com maior ou menor nível de detalhe, o conceito atualmente bastante generalizado de que as condições de vida e trabalho dos indivíduos e de grupos da população estão relacionadas com sua situação de saúde (p. 78).

O modelo de DSS de Dahlgren e Whitehead organiza como os diversos fatores se relacionam com o processo saúde-doença (Figura 1). Este modelo descreve diversas camadas de determinantes, incluindo desde fatores individuais até outras macroquestões vividas pelo indivíduo (Buss & Filho, 2007, p. 83-84).

Figura 1 - Modelo de Determinantes Sociais de Saúde de Dahlgren e Whitehead.



Fonte: Buss e Filho, 2007.

Conforme pode ser observado na Figura 1, fatores individuais e estilo de vida compõem os determinantes mais próximos ao indivíduo, sendo estes considerados como determinantes sociais, pois as opções pessoais estão diretamente relacionadas a contextos e influências sociais e do meio, não sendo somente de responsabilidade individual. Na camada seguinte, temos as redes sociais e comunitárias, relacionadas ao nível de coesão social existente, que exerce um papel central na promoção e proteção da saúde de uma comunidade. Um nível acima, encontram-se os determinantes relacionados a condições de trabalho, acesso a serviços como educação e saúde, além de questões habitacionais e acesso a água tratada e a serviços de saneamento básico, e, ainda, questões envolvendo a segurança alimentar. Por fim, na camada mais externa, de condições socioeconômicas, culturais e ambientais gerais, contemplam-se os macrodeterminantes que impactam nas camadas inferiores (Buss & Filho, 2007, p. 84).

É possível identificar uma aproximação do modelo de Dahlgren e Whitehead aos índices de pobreza multidimensional, pois, tal como a saúde, a situação de pobreza de um indivíduo deve considerar diversos fatores para a sua interpretação.

A relação entre variáveis socioeconômicas e a saúde já foi objeto de estudo de inúmeras pesquisas. Como exemplo, Santos-Neto et al. (2016) analisaram a relação entre desigualdades sociais e mortes em decorrência de tuberculose na cidade de São Luís (MA). Para isso, os autores realizaram um estudo ecológico com o objetivo

de entender a relação espacial entre o fator determinante (desigualdades sociais) e a ocorrência de mortes por tuberculose, e puderam concluir que há associação significativa nesta relação, bem como indicaram que o desenvolvimento social contribui para a redução das mortes causadas pela doença.

Trevilato et al. (2022), por sua vez, verificaram que raça/cor, escolaridade, idade, histórico de aborto ou perda fetal, e a quantidade de consultas de pré-natal são variáveis que estão associadas ao nascimento de crianças com anomalias congênitas. Nesse estudo, os autores usaram o modelo de Dahlgren e Whitehead para classificar as variáveis nas diferentes camadas dos determinantes sociais de saúde. Como conclusão, os autores identificaram que mulheres pretas, comparadas às brancas, têm 20% mais chance de terem filhos com anomalias congênitas. No que tange à idade, ter mais de 40 anos aumentou em 97% esta chance. Verificando se a mulher já possui filhos e gestações anteriores, ambos os fatores foram associados à ocorrência de anomalias congênitas; todavia, estas variáveis não são consenso como determinantes sociais para este fenômeno, pois a literatura dispõe de outros estudos com conclusões diferentes, ainda que no trabalho de Trevilato et al. (2022) tenha sido encontrada esta associação. Por fim, ao analisarem fatores socioeconômicos, como a escolaridade, foi identificado que o fato de a mulher ter menos de quatro anos de estudo aumentou em 50% a chance de ocorrência de anomalia congênita.

Conforme apresentado, fatores do indivíduo, do microambiente e do macroambiente têm impacto direto e grande influência na saúde de indivíduos ou grupos. Neste trabalho, buscamos analisar e compreender a relação da pobreza multidimensional com eventos de importância epidemiológica, usando como estudo de caso a pandemia de COVID-19 nos anos de 2020 e 2021.

2.4. EPIDEMIAS, DETERMINANTES SOCIAIS DE SAÚDE E A PANDEMIA DE COVID-19

A literatura é vasta em apresentar estudos epidemiológicos de determinantes sociais de saúde em epidemias, tal como em Beyrer et al. (2013), Seabra et al. (2022), Lonroth et al. (2009), Lima et al. (2023) e Souza et al. (2022).

Beyrer et al. (2013), em um estudo sobre o aumento da epidemia de Síndrome da Imunodeficiência Adquirida (AIDS) entre homens que tiveram relações sexuais com

outros homens (HSH) no ano de 2013, concluiu que os HSH negros, com menor renda, que estão encarcerados e têm menor escolaridade, são aqueles com maior risco de contágio do HIV.

Seabra et al. (2022) analisaram a distribuição espacial e a tendência da epidemia de AIDS entre HSH jovens no estado do Pará. O estudo concluiu que os meses de janeiro, maio, junho, agosto e outubro são aqueles com maior variação dos diagnósticos da doença no estado. Isto decorre do fato de janeiro e agosto serem subsequentes aos meses de férias; por outro lado, maio, junho e outubro são meses de festividades tradicionais, ocorrendo as festas de São João em maio e junho e o Círio de Nazaré em outubro, quando o estado recebe turistas que acompanham estes eventos. Ademais, as características socioeconômicas analisadas pelos autores indicam que houve maior chance de infecção em HSH jovens nas cidades com maior número de homens com empregos formais, média salarial alta e elevado percentual de homens com ensino fundamental completo.

Lonroth et al. (2009), ao discutirem o controle da epidemia de tuberculose, reiteram a importância de garantir esforços na mitigação dos fatores de risco e determinantes sociais (p. 2244), destacando, em seu estudo, o uso de cigarro e álcool, a desnutrição e insegurança alimentar, ambientes de moradia e trabalho com pouca ventilação, a falta de acesso a métodos de cocção seguros, a falta de conhecimento sobre hábitos preventivos e a inacessibilidade a tratamento de saúde adequado. Todavia, os autores concluem que é preciso entender mais a fundo como outros aspectos de pobreza podem se relacionar aos casos de tuberculose, de modo a subsidiar ações que possibilitem a contenção da epidemia da doença.

Em um estudo realizado no estado do Pará, com a população indígena, Lima et al. (2023) verificaram a taxa de autocorrelação entre casos de tuberculose e dados de transferência de renda usando o índice de Moran Global, sendo os beneficiários de programas governamentais de transferência de renda a população de baixa renda e em situação de vulnerabilidade. Na análise bivariada do índice de Moran, foi possível localizar onde havia altas taxas de incidência de tuberculose e alto número de pessoas recebendo auxílios de renda, e locais com altas taxas de incidência de tuberculose, mas com baixo número de beneficiários de programas de transferência de renda. Esses resultados são importantes para a orientação da formulação de políticas públicas de saúde.

Em um estudo realizado na cidade de Salvador (BA), Souza et al. (2022) verificaram a relação entre o índice de condições de vida (ICV) e casos de síndrome congênita associada ao Zika vírus. O ICV é composto por cinco indicadores obtidos pelo Censo Demográfico: proporção de responsáveis pelo domicílio com renda mensal maior do que dois salários mínimos (renda), proporção de pessoas alfabetizadas entre 10 e 14 anos (educação), percentual de domicílios com abastecimento de água (saneamento), percentual de domicílios em aglomerados subnormais (favela) e moradores por cômodo, este último aferido a partir da divisão da média de moradores por domicílios pela média de cômodos usados como dormitórios. Nessa análise, os autores identificaram uma associação espacial positiva entre locais com piores condições de vida e nascidos vivos com síndrome congênita associada ao Zika vírus. Ou seja, os fenômenos sociais captados pelo ICV influenciam a possibilidade de uma criança nascer com síndrome congênita associada ao Zika vírus.

Nota-se que o estudo da relação de determinantes sociais de saúde e diferentes doenças é importante para entender de que maneiras é possível agir preventivamente, quais populações deve-se priorizar e em quais locais as políticas públicas e orientações de ações de combate devem atuar. Para este estudo, a COVID-19 é a doença sob análise, no sentido de compreender como a pobreza multidimensional se associa a esta doença.

O SARS-CoV-2, agente etiológico da COVID-19, causou, no final de 2019, um surto de pneumonia, identificado inicialmente na cidade de Wuhan, China, e posteriormente deflagrou uma pandemia que ainda hoje atinge milhões de pessoas em todo o mundo. Em 30 de janeiro de 2020, a OMS considerou a COVID-19 como uma Emergência de Saúde Pública de Importância Internacional (ESPII) (OPAS, 2020b), o mais alto nível de alerta segundo o Regulamento Sanitário Internacional (RSI) (OMS, 2009). Em 11 de março de 2020, a COVID-19 foi caracterizada como uma pandemia pela OMS (OPAS, 2020a). De acordo com dados do Boletim Epidemiológico Especial n.º 146 do Ministério da Saúde, até 31 de dezembro de 2022 foram registrados 660.300.641 casos em todo o mundo, dos quais 6.689.977 (1,01%) evoluíram para óbito.

No Brasil, em 3 de fevereiro de 2020, o Ministério da Saúde publicou a Portaria n.º 188, que declarou Emergência em Saúde Pública de Importância Nacional (ESPIN) em decorrência da Infecção Humana pelo novo Coronavírus (2019-nCoV),

considerando o grau de disseminação do SARS-CoV-2 no continente americano (BRASIL, 2020).

Em 26 de fevereiro de 2020, ocorreu o primeiro caso com diagnóstico confirmado de COVID-19 em território nacional (Ferreira, 2020). O Boletim Epidemiológico do Ministério da Saúde, referente à última Semana Epidemiológica (SE) de 2020 (SE 53, de 27 de dezembro de 2020 a 2 de janeiro de 2021), indicava que 2021 iniciou com um total de 84.586.904 casos confirmados de COVID-19 no mundo, sendo 7.716.405 deles no Brasil (cerca de 9% do total de casos). Quanto ao número de óbitos no mundo, no mesmo período, foram 1.835.788, e no Brasil 195.725 (cerca de 11% dos óbitos de todo o mundo) (Ministério da Saúde, 2021).

Conforme o Boletim Epidemiológico n.º 146 do Ministério da Saúde, o último a ser editado referente ao ano de 2022 (SE 52 de 2022, de 25 a 31 de dezembro de 2022), na ocasião contabilizavam-se 36.331.281 casos confirmados e 693.853 óbitos no Brasil, o que representava, respectivamente, 5,5% e 10,3% dos totais mundiais desses indicadores (Ministério da Saúde, 2022a).

A pandemia de COVID-19 sobrecarrega os sistemas de saúde, levando a um enorme impacto econômico em todo o mundo, sendo um desafio para todos os governos e sociedades. Em resposta, inúmeros pesquisadores direcionaram esforços no sentido de entender e propor soluções para a pandemia e suas consequências econômicas e sociais.

No que se refere aos indicadores socioeconômicos, este trabalho optou pela utilização de um índice de pobreza multidimensional. A construção deste indicador se mostra como alternativa à compreensão da pobreza unidimensional, mensurada apenas pela renda. Nove países da América Latina já utilizam IPMs para o diagnóstico, o planejamento e a determinação de políticas públicas que abordam fatores não monetários, visto que este índice apresenta um grande potencial de medida para o alcance da erradicação da pobreza em todas as suas formas e lugares (*United Nations Development Programme & Oxford Poverty and Human Development Initiative*, 2019).

No ano de 2020, mais de 60 mil artigos foram publicados sobre a COVID-19, ou seja, a centralidade deste tema, naquele momento, demandou à academia a construção de amplo conhecimento sobre esta matéria (Oliveira et al., 2021). Destacam-se, ainda, alguns autores que se debruçaram sobre a compreensão da relação entre indicadores de COVID-19 e indicadores socioeconômicos, como

Bermudi et al. (2021), Barrozo et al. (2020), Ferreira (2020); Maciel, Castro-Silva e Farias (2020), Lorenz et al. (2021), Figueiredo et al. (2020), Sanhueza-Sanzana et al. (2021), Polo et al. (2022), Henao-Cespedes et al. (2022) e Tavares e Betti (2021).

A relação entre indicadores socioeconômicos e COVID-19 foi também objeto de um estudo realizado por Bermudi et al. (2021) sobre as mortes ocorridas entre 15 de março e 13 de junho de 2020 por COVID-19 no município de São Paulo (MSP), que concluiu que o nível socioeconômico exerce um efeito protetor ao risco de morte por COVID-19. A análise temporal realizada pelos autores indica que houve uma mudança no risco de morte por COVID-19 ao longo do tempo. Inicialmente, contextos de melhores indicadores socioeconômicos apresentavam maior risco de mortalidade, haja vista que esses indivíduos estiveram no exterior, onde tiveram contato com o vírus, e, em seu retorno ao município de São Paulo, transmitiram o vírus para pessoas de seu convívio. Todavia, a partir da décima sexta semana epidemiológica de 2020, piores condições socioeconômicas tornaram-se um fator de risco para o óbito por COVID-19.

Destaca-se que a variável para identificar o contexto socioeconômico utilizada por Bermudi et al. (2021) foi o GeoSES (Índice Socioeconômico do Contexto Geográfico para Estudos em Saúde), um índice construído por Barrozo et al. (2020) que abrange sete dimensões socioeconômicas: educação, mobilidade, pobreza, riqueza, renda, segregação e privação de recursos e serviços. O GeoSES varia entre -1 e +1, sendo que, quanto mais próximo de +1, melhor a condição socioeconômica, e quanto mais próximo de -1, piores as condições socioeconômicas. Para a construção do indicador, os autores usaram a técnica de Análise de Componente Principal (ACP) para, em um primeiro momento, selecionar as principais variáveis de cada uma das dimensões, e, dentre estas, aplicar novamente a ACP e selecionar as variáveis que mais contribuem para o componente principal geral, e que, por fim, foram incluídas em uma última ACP, que resultou nos scores que permitiram o cálculo do GeoSES (Barrozo et al., 2020).

Ferreira (2020) analisou, no âmbito do município de São Paulo, a relação entre a COVID-19 e as variáveis: 1) salário médio, 2) percentual de domicílios em favelas e 3) população acima de 60 anos; classificadas pelo autor como determinantes sociais de pobreza. O estudo identificou que distritos administrativos (DAs) com menor média salarial, maior percentual de domicílios em favelas e menor população acima de 60 anos são mais vulneráveis à COVID-19 (Ferreira, 2020). Em outro trabalho, Maciel,

Castro-Silva e Farias (2020) analisaram se a incidência de casos de COVID-19 teria relação com o Índice de Desenvolvimento Humano (IDH) nos municípios do Ceará. Os autores identificaram que a distribuição de casos da doença variou entre os municípios, mas com associação ao IDH Municipal (IDH-M), haja vista que a análise espacial bivariada pelo índice de Moran aplicada pelos autores, apontou uma correlação positiva entre municípios que apresentaram alto coeficiente de incidência de COVID-19 e alto IDH (Maciel, Castro-Silva & Farias, 2020).

Lorenz et al. (2021) buscaram entender a distribuição espacial da taxa de mortalidade dos casos de COVID-19 hospitalizados na cidade de São Paulo entre 27 de fevereiro e 19 de novembro de 2020. Os autores trabalharam com uma base de dados que associava os óbitos a uma Unidade de Desenvolvimento Humano (UDH), conforme definido no Atlas do Desenvolvimento Humano, que são áreas territoriais cujos indicadores socioeconômicos são homogêneos. Os autores identificaram que uma melhora nas condições socioeconômicas diminuiu o risco de morte dos casos hospitalizados por COVID-19 no município de São Paulo. Para a compreensão do contexto socioeconômico de cada UDH, os autores utilizaram as variáveis de renda *per capita*, percentual de pessoas empregadas com mais de 18 anos com empregos formais, percentual de crianças de 0 a 5 anos que não frequentam escola, percentual de pessoas morando em domicílios com renda *per capita* menor do que meio salário mínimo cujo trajeto para o trabalho leva mais de uma hora e percentual de pessoas hospitalizadas por COVID-19 em hospitais privados. Os autores identificaram associação espacial entre o risco de morte para pessoas hospitalizadas e as condições socioeconômicas do UDH, sobretudo para a variável “renda *per capita*”.

Figueiredo et al. (2020), por sua vez, analisaram a influência de fatores socioeconômicos na evolução da pandemia de COVID-19 nas UF brasileiras. Os autores concluíram que estados com maior desigualdade de renda tiveram maior transmissão do SARS-CoV-2. Os autores elaboraram um modelo de regressão múltipla que apontou uma associação entre o índice de Gini, que mede a desigualdade social, e a incidência da COVID-19 nas UF. Esta incidência esteve associada, ainda, a domicílios com alto grau de adensamento. Para explicar a taxa de mortalidade por COVID-19, o modelo identificou que piores índices de Gini, maior percentual de domicílios superlotados e maiores taxas de desocupação laboral são variáveis que determinam, em certa medida, a evolução para óbito dos casos de COVID-19. Tais variáveis foram consideradas pelos autores como determinantes sociais da doença.

Um estudo sobre a letalidade da COVID-19, realizado na cidade de Fortaleza (CE), também concluiu que a alta desigualdade social esteve associada a maiores taxas de letalidade. No artigo, Sanhueza-Sanzana et al. (2021) demonstraram que bairros de Fortaleza com alto percentual de domicílios em condições de pobreza, rendimento mensal mediano baixo de mulheres, maior proporção de domicílios chefiados por mulheres, menor proporção de pessoas com mais de 65 anos e maior proporção de analfabetismo apresentaram maiores taxas de letalidade. Evidenciou-se, assim, que a pandemia de COVID-19 impactou de forma mais grave as populações mais pobres da cidade de Fortaleza, corroborando a afirmação de que a pobreza é um determinante social da COVID-19.

Quanto à relação entre pobreza multidimensional e COVID-19, Polo et al. (2022) analisaram a associação entre os óbitos por COVID-19 e o IPM na Colômbia no ano de 2020. Os autores buscaram compreender a relação de cada uma das dimensões do IPM colombiano com os dados de óbitos por COVID-19, e puderam concluir que as pessoas com privações nas dimensões de habitação, educação, infância e juventude e saúde tiveram maior risco de morte por COVID-19 do que as pessoas sem essas privações. A dimensão “trabalho” não apresentou associação estatisticamente significativa com os óbitos por COVID-19. Entretanto, os resultados observados nas demais dimensões indicam que houve associação entre vulnerabilidade social e óbitos por COVID-19 naquele país em 2020.

Outro estudo, que analisou a relação entre IPM e COVID-19 na cidade de Manizales, na Colômbia, foi conduzido por Henao-Cespedes et al. (2022). Considerando o conceito dos DSS, os autores afirmam que o IPM pode ser interpretado como um indicador de risco para a COVID-19, justamente por sua característica multidimensional. Analisando a densidade de casos de COVID-19 por comuna (região administrativa da cidade de Manizales), observou-se uma associação entre esses fatores, sendo que nas comunas com maior pobreza multidimensional a densidade de casos de COVID-19 também foi maior.

Por fim, o estudo efetuado por Tavares e Betti (2021) buscou compreender a associação entre IPM e COVID-19, tendo como área de estudo as unidades federativas do Brasil. Os autores usaram dados da Pesquisa de Orçamentos Familiares (POF) para propor dois IPMs, um composto de indicadores relacionados à prevenção do contágio da COVID-19 e outro com indicadores relacionados à superação daquelas pessoas diagnosticadas com a doença. Os autores usaram,

dentre outras técnicas, o método AF para a construção dos IPMs. Como resultados, Tavares e Betti (2021) verificaram que, para os dois IPMs, no decorrer do tempo, o vírus passou a atingir de forma mais intensa os mais vulneráveis, sendo as regiões Norte e Nordeste aquelas com maiores riscos de infecção e morte por COVID-19. Quanto à mudança da relação entre COVID-19 e IPM, os autores destacam que a partir da décima quarta SE de 2020 houve um aumento da correlação entre estas variáveis, indicando que as regiões mais vulneráveis passam a ser mais acometidas pela COVID-19.

Além de permitir a análise da relação entre a pobreza multidimensional e os indicadores de COVID-19, a espacialização desses indicadores nos municípios do estado de São Paulo pode fornecer informações valiosas para uma melhor compreensão da pandemia considerando o contexto social, contribuindo para que os gestores públicos municipais e estaduais adotem medidas preventivas mais eficazes.

3. MÉTODOS

3.1. TIPO DE ESTUDO

Este estudo é um estudo quantitativo, exploratório e descritivo, que utiliza de técnicas estatísticas e de sistemas de informação geográficas para entender a relação entre a pobreza multidimensional e epidemias, analisando o caso da pandemia de COVID-19 nos municípios do Estado de São Paulo nos anos de 2020 e 2021.

Por buscar construir um indicador de pobreza multidimensional para os municípios do estado de São Paulo, e identificar a relação entre a pobreza multidimensional e indicadores de internação e óbito por COVID-19 nos municípios paulistas, este trabalho se conforma, assim, em um estudo descritivo ecológico com componente analítico.

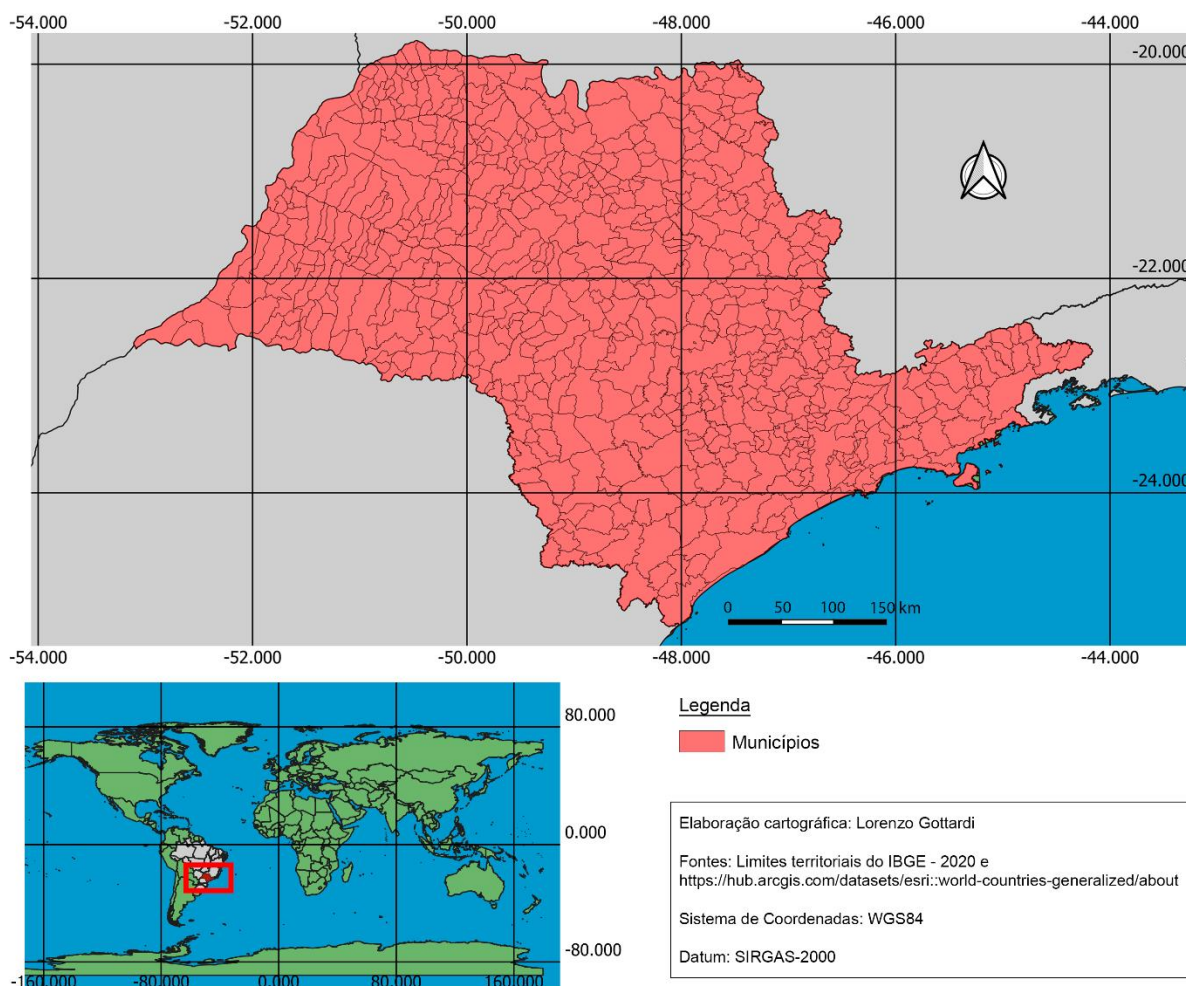
Conforme definido por Lima-Costa e Barreto (2003) e Rouquayrol e Gurgel (2018), um estudo ecológico se caracteriza por comparar a ocorrência de uma determinada doença em um dado grupo de indivíduos e um outro fator de análise; em nosso caso, a COVID-19 (doença) e a pobreza multidimensional (fator).

Assim, neste trabalho, a análise consiste na caracterização da distribuição espacial da pobreza multidimensional, das internações e dos óbitos por COVID-19, bem como na relação entre estes indicadores nos municípios do estado de São Paulo.

3.2. ÁREA DE ESTUDO

A área de abrangência desta pesquisa engloba os 645 municípios do estado de São Paulo (Figura 2). Cabe ressaltar a diversidade que estes municípios apresentam no que tange às suas características populacionais, territoriais, demográficas e socioeconômicas.

Figura 2 - Mapas do estado de São Paulo e do Brasil, 2022.



Fonte: Elaborado pelo autor.

As estimativas da Fundação Sistema Estadual de Análise de Dados (SEADE) calculam que o ESP tinha população estimada de 44.892.912 habitantes no ano de 2021, sendo o município mais populoso a própria capital, com 11.914.851 habitantes, e o município menos populoso Borá, cuja população era de apenas 811 pessoas. O Produto Interno Bruto (PIB) do estado é de mais de R\$ 2,3 trilhões. Dentre os municípios do estado, São Paulo tem o PIB mais alto, com mais de R\$ 763 bilhões, e o menor é o do município de Torre de Pedra, com pouco mais de R\$ 31 milhões (IBGE, 2022).

Quanto aos indicadores de educação, o estado de São Paulo contou, em 2019, com os maiores Índices de Desenvolvimento da Educação Básica (IDEB) do país, tanto para os anos iniciais quanto para os anos finais do ensino fundamental. A taxa

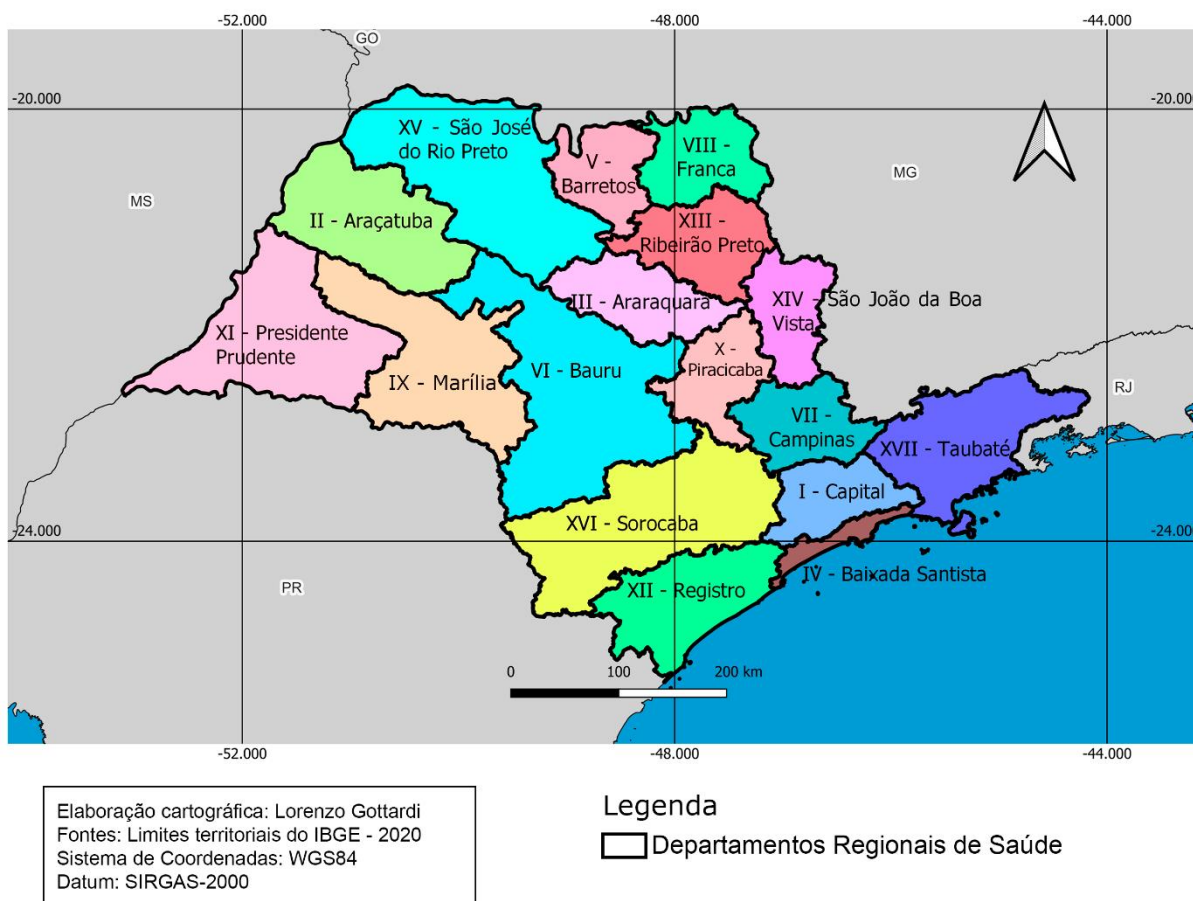
de analfabetismo (pessoas de 15 anos ou mais que não sabem ler ou escrever) do estado, em 2010, era de 4,3%, sendo Barra do Turvo o município com a maior taxa de analfabetismo (17,1%), e a menor (1,5%) em Águas de São Pedro. Cabe, ainda, citar o IDH calculado para o ano de 2010, que, para todo o estado é de 0,783, sendo São Caetano do Sul o município com o maior IDH (0,862) e Ribeirão Branco aquele de menor IDH (0,639) (IBGE, 2022)².

Considerando a extensão, o tamanho da população e toda a heterogeneidade do território paulista, é comum que regiões supramunicipais e infraestadual sejam formatadas para a organização e o acompanhamento das ações do Poder Público. Podemos citar como exemplo as regiões administrativas, os Departamentos Regionais de Saúde, as Diretorias Regionais de Assistência e Desenvolvimento Social, as regiões administrativas judiciárias, e diversas outras formas de regionalização elaboradas conforme lógica própria.

Assim, no presente trabalho, de modo a aprimorar a capacidade de representação e interpretação dos resultados gerados a partir das análises dos dados, optou-se também por agrupar os municípios segundo os 17 (dezesete) Departamentos Regionais de Saúde do ESP, exibidos na Figura 3, a seguir.

² Dados disponíveis em: <https://cidades.ibge.gov.br/brasil/sp/panorama>

Figura 3 - Mapa dos Departamentos Regionais de Saúde (DRS) do estado de São Paulo, 2022.



Fonte: Elaborado pelo autor.

3.3. POPULAÇÃO E PERÍODO DE ESTUDO

Para este estudo, as unidades de análise definidas são os municípios do ESP, e agregaremos os indicadores municipais por DRS para realização da descrição e análise da pobreza multidimensional e da COVID-19. Dessa forma, os dados levantados para a construção do IPM referem-se a toda a população residente nesse estado. Para os indicadores de COVID-19, consideramos a população residente de cada município do ESP que foi internada ou que faleceu por COVID-19, sendo estes indicadores de internação e óbitos relativizados pela população municipal de modo a permitir a comparação entre os municípios.

Já o período de estudo abrange os anos de 2020 e 2021, para os quais foram coletados os dados necessários à construção dos indicadores de COVID-19 de interesse do trabalho.

Cabe ressaltar que todos os dados manipulados - tanto aqueles referentes à pobreza multidimensional, quanto os relativos à COVID-19 - foram consolidados em indicadores ou índices para cada unidade de análise, isto é, os municípios paulistas.

3.4. FONTES DE DADOS

Para a construção do Índice de Pobreza Multidimensional (IPM), os dados utilizados foram todos secundários, obtidos nas bases de dados governamentais do Instituto Brasileiro de Geografia e Estatística (IBGE), da Fundação SEADE, do TabNet - DATASUS/MS (Departamento de Informática do Sistema Único de Saúde do Ministério da Saúde), do Sistema de Vigilância Alimentar e Nutricional (SISVAN) e do Ministério da Educação (MEC). Destaca-se aqui que, a princípio, pretendia-se utilizar os dados das variáveis obtidas do Censo Demográfico (CD) 2022; contudo, estes ainda não estavam disponíveis até o final desta pesquisa, sendo então usados aqueles do Censo Demográfico 2010. O processo de construção do IPM será descrito em tópico a seguir.

Os dados sobre as internações e os óbitos por COVID-19 foram consultados nas bases de dados de Síndrome Respiratória Aguda Grave (SRAG) mantidas pelo Ministério da Saúde, registrados no sistema SIVEP-Gripe, que inclui os casos de SRAG e os óbitos confirmados para COVID-19³. De acordo com o Guia de Vigilância Epidemiológica da COVID-19 elaborado pelo MS (2022), é considerado caso de SRAG:

“Indivíduo com SG [síndrome gripal] que apresente: dispneia/desconforto respiratório ou pressão ou dor persistente no tórax ou saturação de O₂ menor do que 95% em ar ambiente ou coloração azulada (cianose) dos lábios ou rosto.” (Ministério da Saúde, 2022, p. 22).

Já os casos confirmados de COVID-19 decorrem de: 1) critério laboratorial, com teste de biologia molecular, imunológico ou pesquisa de antígeno, sendo o teste imunológico não indicado para indivíduos vacinados; 2) critério clínico, nos casos de

³ BRASIL. Ministério da Saúde. *OpenDataSUS*. Disponível em: <https://opendatasus.saude.gov.br/dataset/srag-2021-e-2022>

Síndrome Gripal (SG) ou SRAG com disfunção olfativa ou gustatória sem causa anterior; 3) critério clínico-epidemiológico para caso de SG ou SRAG que teve contato com caso confirmado para COVID-19 nos últimos 14 dias; e 4) critério clínico-imagem, nos casos de SG ou SRAG sem confirmação laboratorial que apresente determinadas alterações na tomografia de tórax (Ministério da Saúde, 2022, pp. 23-25).

As populações utilizadas para a elaboração dos indicadores de COVID-19 (brutos e padronizados) foram obtidas nos endereços eletrônicos da Fundação SEADE. Os mapas cartográficos digitais do Brasil, do estado de São Paulo e dos municípios paulistas foram adquiridos no endereço eletrônico do IBGE (IBGE, 2021).

3.5. CONSTRUÇÃO DO ÍNDICE DE POBREZA MULTIDIMENSIONAL

Na aplicação do conceito de pobreza, os governos utilizam metodologias para a mensuração e valores de referência para classificar quem é, ou não, considerado pobre. Esses valores de referência são chamados de “cortes de pobreza”, e são utilizados para focalizar as políticas públicas em populações em situação de vulnerabilidade social.

Nos Estados Unidos da América (EUA), por exemplo, o corte de pobreza é dado pelo valor da renda familiar, sendo considerado o número de pessoas da família e em qual estado a família habita (com análise diferenciada para o Alaska e o Hawaii), conforme o Quadro 1, abaixo:

Quadro 1 - Corte de pobreza oficial dos Estados Unidos da América, 2022⁴.

Membros na família	Renda Mensal <i>per capita</i> em dólares		
	EUA (exceto Alaska e Hawaii)	Alaska	Hawaii
1	US\$ 1.132,50	US\$ 1.699,00	US\$ 1.563,00
2	US\$ 762,92	US\$ 1.144,50	US\$ 1.053,00
3	US\$ 639,72	US\$ 959,67	US\$ 883,00
4	US\$ 578,13	US\$ 867,25	US\$ 798,00
5	US\$ 541,17	US\$ 811,80	US\$ 747,00
6	US\$ 516,53	US\$ 774,83	US\$ 713,00
7	US\$ 498,93	US\$ 748,43	US\$ 688,71
8	US\$ 485,73	US\$ 728,63	US\$ 670,50

Fonte: Adaptado de: Departamento de Saúde e Serviços Humanos do Governo dos Estados Unidos da América, 2022.

No Brasil, o Decreto n.º 10.852, de 8 de novembro de 2021, definiu, em seu artigo 20, que a linha de extrema pobreza é caracterizada pela renda familiar *per capita* de até R\$ 100,00; e a linha de pobreza em R\$ 200,00, ou seja, as famílias com renda familiar *per capita* entre R\$ 100,01 e R\$ 200,00 encontram-se em situação de pobreza (Decreto n.º 10.852, 2021). Esses valores foram atualizados pelo Decreto n.º 11.013, de 29 de março de 2022, que define a linha de extrema pobreza em R\$ 105,00 e a linha de pobreza entre R\$ 105,01 e R\$ 210,00 (Decreto n.º 11.013, 2022).

O Banco Mundial, por sua vez, adota como linha internacional de extrema pobreza o valor de US\$ 1,90 (um dólar e noventa centavos) de renda *per capita* diária. Contudo, considerando as diferenças demográficas entre os países no mundo, foram instituídas linhas de pobreza para os países de renda média-baixa como US\$ 3,20 (três dólares e vinte centavos) *per capita* diária, e para os países de renda média-alta a renda *per capita* diária de US\$ 5,50 (cinco dólares e cinquenta centavos) (Banco Mundial, 2020, p. 29).

⁴ *United States of America. National Archives. Department of Health and Human Services. Annual Update of the HHS Poverty Guidelines.* Disponível em: <https://www.federalregister.gov/documents/2022/01/21/2022-01166/annual-update-of-the-hhs-poverty-guidelines>

Em 2017, o Banco Mundial recebeu a recomendação da “Comissão *Atkinson* sobre Pobreza Global” para a criação de uma medida de pobreza multidimensional, que foi instituída em 2018, usando o método AF, considerando três (03) dimensões e seis (06) indicadores. Neste índice, cada dimensão tem o mesmo peso no cálculo, e os indicadores têm o mesmo peso dentro de cada dimensão, como descrito abaixo, no Quadro 2:

Quadro 2 - Medida de pobreza multidimensional do Banco Mundial, 2018.

Indicador	Dimensão	Peso
Renda <i>per capita</i>	Pobreza monetária	1/3
Grau de escolaridade	Educação	1/6
Matrícula escolar de crianças	Educação	1/6
Acesso a água potável	Infraestrutura básica	1/9
Acesso a saneamento	Infraestrutura básica	1/9
Acesso a eletricidade	Infraestrutura básica	1/9

Fonte: Adaptado de: Banco Mundial, 2018.

Nessa medida, considera-se pobre todo indivíduo que é privado em uma dimensão, ou que, na soma dos pesos dos indicadores, seja privado no equivalente a uma dimensão, ou seja, um terço (Banco Mundial, 2018; Banco Mundial, 2020, p. 29).

Neste trabalho, a mensuração da pobreza não apenas a partir da ótica unidimensional da renda, mas por um conjunto de indicadores de diferentes dimensões, visa caracterizar a pobreza conforme o conceito apresentado por Sen (2010); pois, ainda que a renda seja determinante no desenvolvimento de capacidades, ela não deve ser a única variável considerada. Nesse aspecto, a concepção de pobreza a partir das capacidades vai ao encontro do disposto no Artigo 1º da Lei n.º 8.742, de 7 de dezembro de 1993 - a Lei Orgânica da Assistência Social (LOAS):

Art. 1º - A assistência social, direito do cidadão e dever do Estado, é Política de Seguridade Social não contributiva, que provê os mínimos sociais, realizada através de um conjunto integrado de ações de iniciativa pública e

da sociedade, para garantir o atendimento às necessidades básicas (Lei n.º 8.742, de 7 de dezembro de 1993).

Esta Lei preconiza que o Estado deve prover os mínimos sociais para garantir as necessidades básicas do cidadão que estão além da renda. Nesse sentido, a utilização de um índice de pobreza multidimensional se justifica não apenas teórica, mas também legalmente.

Neste trabalho, o Índice de Pobreza Multidimensional foi elaborado utilizando o método proposto por Alkire-Foster (2009). Assim, a construção do índice seguiu as seguintes etapas:

1. Escolha da unidade de medida e da unidade de análise de pobreza;
2. Escolha e definição das dimensões que compõem o IPM;
3. Definição dos indicadores que compõem cada uma das dimensões do IPM;
4. Definição dos pesos de cada indicador e dimensões;
5. Definição dos cortes de privação de cada indicador para considerar um município privado, ou não, naquele indicador;
6. Definição do corte de pobreza, isto é, estabelecer quem é, ou não, multidimensionalmente pobre a partir da soma das privações de todos os indicadores.

Tendo sido aplicados estes cortes, torna-se possível verificar a incidência da pobreza (H), e o hiato de pobreza (A), ou seja, o quanto cada município é multidimensionalmente pobre. Assim, o IPM é a multiplicação destes resultados:

$$\text{IPM} = H * A$$

Como no caso deste trabalho a unidade de medida é a mesma que a unidade de análise - o município -, a incidência da pobreza (H) será igual a 1 (um) quando o município for considerado multidimensionalmente pobre, e será igual a 0 (zero) caso o município não seja considerado multidimensionalmente pobre. Já o hiato da pobreza (A) será a proporção de privações que cada município sofre. Assim, o IPM de cada município será igual ao seu hiato de pobreza (A) multiplicado pela incidência da pobreza (Alkire & Foster, 2009). O processo metodológico de cada um desses passos será descrito com maior detalhamento a seguir.

3.5.1. Unidades de medida e de análise

Os IPMs dos países latino-americanos são calculados com base em pesquisas cujas unidades de medida são domicílios ou famílias, e a unidade de análise é o próprio país. Todavia, tais pesquisas podem ser agregadas em nível municipal, estadual ou nacional, haja vista que dispõem de todos os dados para tais agregações. Da mesma forma, o IPM Global, elaborado por Alkire e Santos (2014) e revisado por Alkire e Kanagaratnam (2021), tem o país como unidade de análise e os domicílios como unidades de medida (Alkire & Santos, 2014, p. 253). No presente trabalho, o objetivo é debruçar-se sobre a pobreza multidimensional no nível municipal no ESP. Assim, nossa unidade de análise e de medida é o próprio município.

A escolha da análise e mensuração a partir dos municípios justifica-se pela enorme relevância para a geração de conhecimento sobre as condições destes territórios, contudo, limita a possibilidade do uso de diversas pesquisas amostrais que têm como unidade de medida o domicílio, tais como a Pesquisa Nacional de Saúde (PNS) e a Pesquisa Nacional por Amostra de Domicílios (PNAD), visto que, por serem amostrais, não oferecem dados para todos os municípios do ESP.

No caso deste trabalho, a variação de H não foi entre 0 e 1, mas sim de 0 ou 1, pois, sendo o município a unidade de medida, a proporção de indivíduos abaixo da linha da pobreza só pode ser ou 1 ou 0. Ou seja, ou o município é multidimensionalmente pobre ($H = 1$), ou ele não é multidimensionalmente pobre ($H = 0$). Isto se dá em decorrência da escolha do município como unidade de medida, que limita a apenas um indivíduo a análise, o próprio município. Ou seja, a identificação da pobreza multidimensional não foi a nível de domicílio, ou família, e, em seguida, somando o número de pessoas abaixo da linha da pobreza, mas sim, considerando se aquele determinado município como multidimensionalmente pobre ou não.

Dessa forma, sendo o IPM a multiplicação entre H e A , e H podendo assumir apenas o valor de 0 ou 1, o IPM será A se o município for classificado como multidimensionalmente pobre ($H = 1$), ou o IPM será 0, independentemente do valor de A , se o município não for considerado multidimensionalmente pobre ($H = 0$).

3.5.2. Dimensões e Indicadores

Para a definição das dimensões que compõem o IPM calculado neste trabalho, foram usados como referência os IPMs existentes nos países da América Latina (México, 2009; Chile, 2015; Costa Rica, 2015; Equador, 2015; Honduras, 2016; República Dominicana, 2017; Panamá, 2018; Colômbia, 2020 e Paraguai, 2021). Assim, levantamos 36 dimensões, sendo 21 dimensões diferentes, que, todavia, se confundiam entre si, como, por exemplo, a dimensão “Saúde, Água e Alimentação” do IPM do Equador, que apresenta indicadores referentes a fenômenos que eram classificados na dimensão “Saúde” do IPM da Costa Rica, ou ainda, na dimensão “Condições de moradia e acesso a serviços públicos domiciliares” do IPM da Colômbia (Costa Rica, 2015; Equador, 2015; Colômbia, 2020).

Assim, o processo de escolha das dimensões caminhou conjuntamente com a determinação de quais indicadores comporiam o IPM deste trabalho. Desse modo, listou-se, assim como feito para as dimensões, os 133 indicadores incluídos nestas últimas, sendo 119 diferentes daqueles abordados nos IPMs latino-americanos. Tal como no caso das dimensões, alguns países usam indicadores que são também empregados em outros países, mas há, ainda, casos de indicadores que se sobrepõem em partes, ou mesmo que englobam mais de um indicador quando comparados a outros países. Esse é, por exemplo, o caso do indicador “Indisponibilidade de algum serviço básico no domicílio”, do IPM do México, que avalia a forma de abastecimento de água, coleta de esgoto, abastecimento de energia elétrica e combustível para a cocção do domicílio, quando, em geral, estes fenômenos são medidos separadamente nos demais IPMs, como o indicador “Água potável” do IPM da República Dominicana, ou mesmo o indicador “Tipo de combustível para cozinhar” do IPM de Honduras (México, 2009; Honduras, 2016; República Dominicana, 2017).

Outro fator relevante para a definição e a escolha dos indicadores é a própria disponibilidade de dados. Um exemplo desta situação é o indicador “Controle de gravidez” do IPM do Panamá, que mede se há alguma mulher entre 15 e 49 anos de idade que esteve grávida nos últimos cinco anos e não teve acompanhamento médico pré-natal. Esse tipo de indicador não pôde ser incluído neste trabalho, justamente pela indisponibilidade de dados sobre o fenômeno que representa.

Assim, após a análise individual de cada indicador, foram considerados, *a priori*, 85 indicadores dos IPMs latino-americanos, compatíveis com 24 indicadores brasileiros. Desta forma, com um universo já reduzido de indicadores selecionados, os 24 indicadores correspondentes no Brasil foram classificados em cinco dimensões, que representam as dimensões dos indicadores oriundos dos IPMs de referência, chegando-se na conformação exibida detalhadamente no Quadro 3.

Quadro 3 - Dimensões, indicadores e respectivas fontes, selecionados para a construção do Índice de Pobreza Multidimensional no estado de São Paulo.

Dimensão	Indicador	Fonte
Condições Habitacionais	ch_bens_domesticos	Foram utilizadas as informações referentes à “posse de bens duráveis” do arquivo “Tabela 2.20.8.6” dos “resultados_gerais_da_amostra” do Censo Demográfico 2010.
Condições Habitacionais	ch_cond_rua_aceeso	Foram utilizadas as variáveis de “existência de pavimentação/calçada/meio-fio” do arquivo “Tabela 4.20.1” das informações do pacote de tabelas referentes ao “Entorno_dos_Domicílios” do estado de São Paulo do Censo Demográfico 2010.
Condições Habitacionais	ch_densidade_domicilio	Foram utilizadas as variáveis de “densidade de moradores por dormitório” do arquivo “Tabela 4.20.2.3” das informações do pacote de tabelas referentes a “Famílias_e_Domicílios” do estado de São Paulo do Censo Demográfico 2010.
Condições Habitacionais	ch_destino_lixo	Foram utilizadas as variáveis de “destino do lixo” do arquivo “Tabela 4.20.4” das informações do pacote de tabelas referentes ao “Entorno_dos_Domicílios” do estado de São Paulo do Censo Demográfico 2010.
Condições Habitacionais	ch_sem_aceeso_internet	Foi utilizada a variável que indica o “número de domicílios particulares permanentes com Microcomputador com acesso a <i>internet</i> ” do arquivo “Tabela 2.20.8.6” dos “resultados_gerais_da_amostra” do Censo Demográfico 2010.
Condições Habitacionais	ch_sem_agua	Foram utilizadas as variáveis de “forma de abastecimento de água” do arquivo “Tabela 4.20.2” das informações do pacote de tabelas referentes ao “Entorno_dos_Domicílios” do estado de São Paulo do Censo Demográfico 2010.
Condições Habitacionais	ch_sem_banheiro_saneamento	Foram utilizadas as variáveis de “existência de banheiro ou sanitário” e “tipo de esgotamento” do arquivo “Tabela 4.20.3” das informações do pacote de tabelas referentes ao “Entorno_dos_Domicílios” do estado de São Paulo do Censo Demográfico 2010.
Condições Habitacionais	ch_sem_energia_eletrica	Foram utilizadas as variáveis “V045” e “V046” do arquivo “Domicilio01_SP” dos “Resultados_do_Universo” e “Agregados_por_setores_Censitários” do Censo Demográfico 2010, que medem “Domicílios particulares permanentes com energia elétrica de outras fontes [que não companhia distribuidora]” e “Domicílios particulares permanentes sem energia elétrica”, respectivamente.

Condições Habitacionais	ch_tipo_paredes	Foram utilizadas as variáveis de “tipo de material das paredes externas” do arquivo “Tabela 2.20.8.1” dos “resultados_gerais_da_amostra” do estado de São Paulo do Censo Demográfico 2010.
Educação	ed_alfabetizacao_15	Foram utilizadas as informações das variáveis “V012 a V077” do arquivo “Pessoa01_SP” dos “Resultados_do_Universo” e “Agregados_por_setores_Censitários” do Censo Demográfico 2010, que medem “Pessoas alfabetizadas com 15 anos de idade” a “Pessoas alfabetizadas com 80 anos ou mais de idade”.
Educação	ed_nivel_instrucao	Foram utilizadas as variáveis de “nível de instrução” do arquivo “Tabela 3.20.1.15” das informações do pacote de tabelas referentes à “Educacao_e_Deslocamento” do estado de São Paulo do Censo Demográfico 2010.
Educação	ed_tdi	Foi utilizada a “Taxa de Distorção Idade-série” do INEP (Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira) para o ano de 2021.
Saúde e Assistência Social	sas_benef_plano_saude	Foram utilizados os dados de “quantidade de beneficiários de Planos de Saúde particulares” da Agência Nacional de Saúde Suplementar (ANS) para o mês de setembro/2022.
Saúde e Assistência Social	sas_cobertura_ab_esf	Foram utilizados os dados de “Cobertura da Atenção Básica” e da “Estratégia Saúde da Família” por município do estado de São Paulo para o mês de dezembro de 2020.
Saúde e Assistência Social	sas_mort_infantil	Foram utilizados os dados de “óbito infantil” por município do estado de São Paulo, extraídos do TabNet do DATASUS para o ano de 2020.
Saúde e Assistência Social	sas_peso_idade	Foram utilizados os dados de “relação peso-idade” do Sistema de Vigilância Alimentar e Nutricional (SISVAN) para o mês de dezembro de 2021.
Trabalho e Renda	ter_desemprego_10anos	Foi utilizada a variável que indica o “número de pessoas de 10 anos ou mais desocupadas” do arquivo “Tabela 2.20.6.1” dos “resultados_gerais_da_amostra” do Censo Demográfico 2010.
Trabalho e Renda	ter_desemprego_14anos	Foi utilizada a variável que indica o “número de pessoas de 14 anos ou mais desocupadas” do arquivo “Tabela 2.20.6.1” dos “resultados_gerais_da_amostra” do Censo 2010.
Trabalho e Renda	ter_sem_contrib_previdencia	Foram utilizadas as variáveis que indicam o “número de pessoas ocupadas não contribuintes com a previdência social” do arquivo “Tabela 4.20.1.5” das informações do pacote de tabelas referentes a “Trabalho_e_Rendimento” do estado de São Paulo do Censo Demográfico 2010.

Trabalho e Renda	ter_taxa_dependencia	Foi calculada a “Soma da população de 0 a 14 anos e maiores de 59 anos, dividido pela população de 15 a 59 anos, vezes 100”.
Trabalho e Renda	ter_trab_infantil	Foi utilizada a “taxa de trabalho infantil” do Censo Demográfico de 2010, extraída do TabNet do DATASUS.
Trabalho e Renda	ter_trab_infantojuvenil	Foi utilizada a variável que indica o “número de pessoas de 10 a 13 anos ocupadas” do arquivo “Tabela 2.20.6.1” dos “resultados_gerais_da_amostra” do Censo Demográfico 2010.
Trabalho e Renda	ter_trab_informal	Foram utilizadas as variáveis que indicam o “número de pessoas de 10 anos ou mais que estejam trabalhando sem carteira de trabalho assinada, ou que trabalhem por conta própria, ou seja, não remuneradas, ou trabalhadores na produção para o próprio consumo”, do arquivo “Tabela 2.20.6.4” dos “resultados_gerais_da_amostra” do Censo Demográfico 2010.
Vida Comunitária	vc_cert_nascimento	Foi utilizada a variável “V002” da planilha “Pessoa10_SP” dos “Resultados_do_Universo” e “Agregados_por_setores_Censitários” do Censo Demográfico 2010, que identifica o “total de pessoas até 10 anos de idade que não tinha registro de nascimento”.

Fonte: Elaborado pelo autor.

Logo, nessa primeira etapa de levantamento de indicadores que poderiam compor o IPM do presente trabalho, obtivemos 24 possíveis indicadores classificados em cinco dimensões, da seguinte forma: nove indicadores na dimensão “Condições Habitacionais”, três na dimensão “Educação”, quatro na dimensão “Saúde e Assistência Social”, sete na dimensão “Trabalho e Renda” e apenas um na dimensão “Vida Comunitária” (Quadro 3).

Após o levantamento desses dados, aplicamos a técnica de Análise de Componentes Principais (ACP) em cada uma das dimensões, de modo a realizar uma segunda seleção de indicadores dentre os 24. Como a dimensão “Vida Comunitária” continha apenas um indicador, não foi necessário aplicar a ACP nesta dimensão, e o único indicador foi mantido para o IPM.

A técnica de ACP, como ferramenta de análise de dados, é indicada para a redução de um conjunto de dados, de modo a construir uma forma de interpretação preservando a maior parte da informação inicial (Varella, 2008; Cadima & Jolliffe, 2021). A ACP é uma técnica bastante utilizada para a análise da relação entre indicadores socioeconômicos e de saúde, como nos trabalhos de Santos-Neto et al. (2016), Barrozo et al. (2020), Bermudi et al. (2021) e Lorenz et al. (2021).

A ACP busca, a partir das variáveis originais, construir um novo conjunto de variáveis denominadas Componentes Principais (CP). Cada CP resultante captura o máximo possível da variação total dos dados iniciais, e, para cada variável original do conjunto de dados tem-se o seu peso (*loading*) na construção do CP. Como as variáveis são distintas entre si, para a geração do CP deve ser realizada a padronização das variáveis, de modo que a média seja igual a zero e a variância igual a um. Assim, está dada a matriz de correlação, a partir da qual serão obtidos os autovalores, os autovetores e o CP. Para a operacionalização deste procedimento, foi utilizada a função “*principal*” do pacote de funções “*psych*” nos *softwares R* (versão 4.2.0, 2022) e *RStudio IDE* (2022.12.0, *build* 353).

A opção de aplicar a ACP em cada uma das dimensões deu-se em razão de que a análise previamente realizada, considerando todos os 24 indicadores conjuntamente, resultou em um componente principal que capturava apenas 21,9% da variância de todas as variáveis, ou seja, aplicar o ACP para todas as variáveis acarretaria na perda de quase 80% das informações presentes na base de dados. Após essa etapa, foram selecionadas as variáveis com autovalores acima de 0,6, ou

seja, considerando apenas as variáveis com grandes autovalores de correlação com o componente principal.

Os pesos atribuídos aos indicadores e às dimensões seguiu o observado na maior parte dos IPMs consultados na literatura (Alkire & Kanagaratnam, 2021; Paraguai, 2021; Colômbia, 2020; Panamá, 2018; República Dominicana, 2017; Honduras, 2016; Chile, 2015; Costa Rica, 2015; Equador, 2015; Alkire & Santos, 2014; México, 2009).

3.5.3. Cortes de privação e cortes de pobreza

As linhas de corte dos indicadores determinam quais indivíduos são, ou não, privados em cada um dos indicadores. Já a linha de corte para a definição de pobreza multidimensional é a medida de privação a partir da qual os municípios serão considerados pobres multidimensionalmente.

Para os indicadores, foi adotado como linha de corte de privação o percentil 75, ou seja, 25% dos municípios com os piores resultados em cada um dos indicadores foram classificados como privados naquele indicador. Isto significa que, para cada indicador, 162 municípios foram considerados privados, enquanto que 483 foram considerados não privados. Esta opção foi adotada por duas razões: em primeiro lugar, porque esse critério permite identificar desigualdades em cada um dos indicadores, ou seja, essa estratégia permite identificar aqueles que apresentam maiores deficiências; a segunda razão para a sua adoção, é que o corte a partir do percentil permite a agregação do IPM por quaisquer outras divisões territoriais maiores, haja vista que todos os indicadores são calculados a partir da população municipal. Assim, o IPM agregado para os Departamentos Regionais de Saúde (DRS) pode ser obtido pela média dos IPMs municipais que compõem cada uma dessas regiões, ou seja, o IPM de cada DRS é calculado da seguinte forma:

$$IPM_{DRS} = \mu IPM_{MUN}$$

Logo, a opção pelo corte de privação de cada indicador com base no percentil 75 simplifica o cálculo do IPM regional. Assim, o cálculo do IPM por DRS nos permite observar a pobreza também regionalmente.

Outrossim, para a definição do corte de pobreza, calculamos inicialmente o IPM por município, a partir de quatro diferentes critérios: 1) considerando multidimensionalmente pobres os municípios que tiverem um hiato de pobreza igual ou maior que 0,2 - valor máximo de cada dimensão; ou 2) um hiato de pobreza referente a um quarto do valor máximo de privação (0,25); ou 3) um hiato de pobreza igual ou maior do que 0,33, isto é, um terço do máximo de privação; ou 4) um hiato de pobreza maior ou igual a 0,4, ou seja, o valor de duas dimensões somadas.

Uma vez aplicados esses cortes de pobreza, o IPM foi calculado para cada município e, conseqüentemente, a partir do cálculo da média dos IPM municipais, para cada DRS. Esse procedimento nos permitiu aplicar o teste de correlação de *Tau de Kendall*, um teste de sensibilidade indicado pelo *United Nations Development Programme & Oxford Poverty and Human Development Initiative* (2019) para ser utilizado na definição do corte de pobreza, de modo a verificar se a mudança no corte de pobreza altera significativamente o quanto cada DRS é pobre em comparação às demais. Optamos, por fim, pelo uso do corte de pobreza de 0,2, ou seja, o valor de uma dimensão, haja vista que o teste *Tau de Kendall* gerou os seguintes resultados (Tabela 1):

Tabela 1 - Análise dos cortes de pobreza de acordo com o teste de correlação de *Tau de Kendall*.

Cortes de pobreza (pares para a comparação)	Correlação de <i>Tau de Kendall</i>
0,2 e 0,25	0,8823529
0,2 e 0,33	0,8529412
0,2 e 0,4	0,8088235
0,25 e 0,33	0,9411765
0,25 e 0,4	0,8970588
0,33 e 0,4	0,8970588

Fonte: Elaborado pelo autor.

Tais resultados apontam que a menor correlação foi encontrada ao compararmos os cortes de 0,2 e 0,4; todavia, ainda assim, há uma grande correlação

entre estes dois pontos de corte, evidenciando que qualquer corte de pobreza adotado, dentre os listados, altera muito pouco a mensuração do grau de pobreza entre os municípios.

3.6. TRATAMENTO DOS DADOS DE COVID-19 NO ESTADO DE SÃO PAULO

As informações referentes à pandemia de COVID-19 foram obtidas na base de dados de SRAG (SIVEP-Gripe), mantida pelo Ministério da Saúde. Desta base, extraíram-se os registros referentes às internações e aos óbitos por SARS-CoV-2. Tais dados foram tabulados segundo o município de residência de cada caso, sendo, então, calculadas as taxas de mortalidade e de internação por 100 mil habitantes, conforme as fórmulas descritas abaixo (Laprega & Fabbro, 2022):

Taxa de mortalidade específica por COVID-19 = número de óbitos por COVID-19 em determinado município e ano / população municipal no mesmo ano * 100.000.

Taxa de internação por SRAG por COVID-19 = número de internações por SRAG por COVID-19 em determinado município e ano / população municipal no mesmo ano * 100.000.

As taxas de mortalidade e de internação foram relativizadas por 100 mil habitantes, de modo que fosse possível a comparação entre os municípios, haja vista a disparidade populacional encontrada entre os municípios paulistas. As taxas foram também padronizadas segundo idade e sexo, de modo a se controlar o efeito dessas variáveis nos desfechos observados, tendo em vista as diferenças das estruturas populacionais no tocante à distribuição etária e segundo o sexo (Queiroz et al., 2020; Silva, Jardim & Lotufo, 2021).

Ademais, cabe ressaltar que optamos por não usar dados referentes a casos leves de COVID-19 (registrados na base de dados e-SUS Notifica), por haver a possibilidade de casos assintomáticos, ou até mesmo sintomáticos que não foram identificados e notificados, por não terem realizado testes laboratoriais comprobatórios (BRASIL, 2022).

3.6.1. Descrição da base de dados de SRAG

A base de dados de SRAG oferece uma ampla gama de variáveis a serem trabalhadas. Para esta pesquisa, realizamos filtros e seleções de modo a reduzir a base apenas às observações e variáveis de interesse. Com relação aos filtros aplicados, foram selecionados apenas os registros referentes aos residentes no estado de São Paulo, hospitalizados e cujo campo de classificação final do caso identificou SRAG por COVID-19.

Já quanto à seleção das variáveis, foram escolhidas as seguintes: data do preenchimento da ficha de notificação, semana epidemiológica do preenchimento da ficha de notificação, data dos primeiros sintomas, semana epidemiológica dos primeiros sintomas, sexo, idade, data de nascimento, tipo idade, raça, escolaridade, unidade federativa de residência do paciente, regional de saúde de residência, município de residência, zona geográfica, sintomas de febre, tosse, dor de garganta, dispneia, desconforto respiratório, saturação, diarreia, vômito, dor abdominal, fadiga, perda de olfato, perda de paladar, outros sintomas, outros desconfortos, se puérpera ou parturiente, fator de risco como cardiopatia, doença hematológica, Síndrome de Down, doença hepática, asma, diabetes, doença neurológica, pneumopatia, imunodepressão, doença renal, obesidade, valor do índice de massa corpórea, outros fatores de risco, lista de outros fatores de risco, data da internação, regional de saúde da internação, município de internação, internação em Unidade de Terapia Intensiva (UTI), se houve coleta de amostra para teste diagnóstico, resultado do teste antigênico, resultado do teste antigênico para SARS-CoV-2, resultado do teste de RT-PCR, resultado do teste RT_PCR para SARS-CoV-2, diagnóstico final do caso, evolução do caso e se houve internação.

3.7. RELAÇÃO DOS INDICADORES DE COVID-19 COM A POBREZA MULTIDIMENSIONAL

Para verificar a relação entre os indicadores de internação e óbito por COVID-19 e o Índice de Pobreza Multidimensional, foram aplicadas técnicas estatísticas de análise de associação espacial entre as variáveis. O emprego dos Índices de Moran

Global e Local possibilitou verificar a existência de agrupamentos com padrões diferenciados (Luzardo, Filho & Rubim, 2017).

O Índice de Moran Global verifica a interdependência entre todos os polígonos em análise - no caso deste trabalho, todos os municípios do ESP. Este índice varia de -1 a +1, sendo +1 uma perfeita correlação espacial, e, caso o valor seja 0, indica que não há correlação espacial, e -1, que há grande dispersão dos dados (Ribeiro et al. 2018).

Já para o Índice de Moran Local, elabora-se uma matriz de vizinhança, na qual, quando um município é vizinho do outro atribui-se valor 1 (um), e quando não é vizinho atribui-se valor zero, medindo, então, a dependência apenas entre os municípios vizinhos. Assim, a partir da matriz de vizinhança, é possível identificar o comportamento de autocorrelação para cada uma das variáveis de interesse (análise univariada), e a correlação entre duas variáveis entre um município e seus vizinhos (análise bivariada), que podem apresentar comportamento de associação espacial positiva ou negativa (Santos & Souza, 2007).

Na análise bivariada do Índice de Moran Local, faz-se uma comparação do valor de uma variável de um determinado município com o valor de uma segunda variável dos municípios vizinhos, conforme estabelecido na matriz de vizinhança. Neste trabalho, optou-se pela construção de uma matriz de vizinhança considerando a existência de divisa entre os municípios, ou seja, uma matriz de vizinhança do tipo “*queen*” (que compartilham uma fronteira ou um vértice em comum), considerando os vizinhos de primeira ordem (Almeida, 2012).

É possível projetar os resultados da análise do Índice de Moran Local em mapas - conhecidos como Local Indicators of Spatial Association (LISA MAPS) - que apresentam os municípios em aglomerados classificados em quatro categorias: “Alto-Alto”, quando um município possui um valor alto da variável “A” e seus vizinhos apresentam valores altos da variável “B”; “Alto-Baixo”, quando um município revela um valor alto da variável “A” e seus vizinhos têm valores baixos da variável “B”; “Baixo-Alto”, quando um município possui um valor baixo da variável “A” e seus vizinhos exibem valores altos da variável “B”; e “Baixo-Baixo”, quando um município apresenta um valor baixo da variável “A” e seus vizinhos denotam valores baixos da variável “B”. Também é possível identificar situações em que não há associação estatisticamente significativa entre o município e seus vizinhos (Almeida, 2012; Ribeiro et al. 2018).

Para essa técnica de análise espacial, indica-se, ainda, o emprego de um segundo procedimento para identificar os erros do tipo 1, ou seja, os falsos positivos. Assim, optamos por aplicar a técnica do False Discovery Rate (FDR) em cada uma das análises de Moran Local Bivariado. O procedimento consiste em ordenar o p-valor encontrado para os municípios na análise bivariada, obtendo assim a classificação ordenada de todos os municípios pelo p-valor, de 1 a 644, e multiplicar esta classificação pelo nível de significância desejado, no caso deste trabalho, 0,05, e dividir pelo total de observações, que, para este trabalho, é de 644, haja vista que, pela matriz de vizinhança construída, o município de Ilha Bela não possui vizinhos, não sendo então considerado na análise bivariada. Se o resultado desta conta for maior ou igual ao p-valor inicialmente encontrado, é considerado significativo (Castro & Singer, 2006).

Nesta pesquisa, a análise univariada do Índice de Moran foi aplicada para as taxas padronizadas de internações e de óbitos por COVID-19 nos anos de 2020 e 2021, e também para o IPM. Já a análise bivariada do Índice de Moran Local foi empregada para verificar a correlação espacial entre cada um dos indicadores de COVID-19 - internação e óbito - e o IPM. Os dados foram carregados no *software GeoDa subversion (1.20.0.22)*, a partir do qual pôde ser criada a matriz de vizinhança do tipo “queen” e extraídos os resultados para as estatísticas de autocorrelação e correlação espacial.

3.8. APRESENTAÇÃO DOS RESULTADOS

Após as informações serem tabuladas e organizadas, foram elaborados gráficos, tabelas e mapas temáticos, estes últimos para caracterizar a distribuição espacial dos indicadores de interesse e suas relações espaciais (taxa de internação de SRAG por COVID-19, taxa de mortalidade por COVID-19 e IPM), segundo os municípios do ESP.

De modo a facilitar a análise, os gráficos foram ordenados a partir dos valores da taxa padronizada, para que a visualização se tornasse fluida e coerente. As legendas dos mapas foram elaboradas por quantis, exceto no mapa da distribuição espacial do IPM, pois, neste caso, os municípios considerados não pobres foram

agrupados em uma única classe separada, e as demais classes foram definidas com igual intervalo de separação.

Ademais, de modo a otimizar e facilitar a compreensão sobre os fenômenos da pobreza multidimensional e da COVID-19, bem como a relação entre eles, a análise dos resultados será realizada pelos DRS. Assim, os indicadores municipais serão agregados ao nível regional, de modo que esta regionalização permita a realização de uma análise mais coesa e inteligível.

Para o desenvolvimento desta pesquisa, os seguintes *softwares* e aplicativos foram utilizados: 1) QGIS, versão 3.22.12, ano 2022; 2) R, versão 4.2.0, 2022; 3) *RStudio* IDE, 2022.12.0, *build* 353; 4) Microsoft Excel, 2013; e 5) *GeoDa subversion* 1.20.0.22, 2022.

3.9. ASPECTOS ÉTICOS

Para este trabalho, foram observadas, em quaisquer circunstâncias, as normas e diretrizes que regulamentam as pesquisas envolvendo seres humanos, previstas na Resolução n.º 466, de 12 de dezembro de 2012, do Conselho Nacional de Saúde (CNS), para a Pesquisa Científica em Seres Humanos (CNS, 2012). Foram respeitados o sigilo e a confidencialidade dos sujeitos da pesquisa (casos e óbitos por COVID-19 residentes no estado de São Paulo), e também consideradas as disposições legais previstas na Lei n.º 13.709, de 14 de agosto de 2018 – Lei Geral de Proteção de Dados Pessoais (LGPD, 2018) e da Lei n.º 13.853, de 8 de julho de 2019 (LGPD, 2019), que trouxe alterações à Lei de 2018.

4. RESULTADOS

4.1. EPIDEMIOLOGIA DESCRITIVA E DISTRIBUIÇÃO ESPACIAL DAS INTERNAÇÕES E DOS ÓBITOS CONFIRMADOS PARA COVID-19 NO ESTADO DE SÃO PAULO

A base de dados de Síndrome Respiratória Aguda Grave (SRAG) contempla todos os casos de SRAG, inclusive aqueles casos confirmados para COVID-19, em território nacional. Também são disponibilizadas algumas informações do perfil dessa população, tais como raça, sexo, idade e escolaridade, sintomas identificados, data dos primeiros sintomas, se houve internação e óbito e diversas outras informações referentes aos casos de SRAG.

Para o ano de 2020, a base de SRAG contém 1.200.887 registros, sendo 716.621 (59,67%) confirmados para a COVID-19 em todo o Brasil. Já no ESP, foram notificados 356.884 casos de SRAG, dos quais 202.234 (56,67%) confirmados para a COVID-19, ou seja, o ESP registrou 29,72% dos casos totais de SRAG e 28,22% dos casos de SRAG confirmados para COVID-19 no Brasil, considerando o local de registro e o local de residência dos casos. Com relação às internações e aos óbitos por COVID-19 - as duas variáveis dependentes de interesse deste trabalho - o país registrou 674.228 internações e 229.392 óbitos, sendo que, destes, 196.810 internações (29,19%) e 55.523 óbitos (24,20%) ocorreram no estado de São Paulo.

No ano de 2021, foram registrados 1.733.262 casos de SRAG no Brasil, sendo a COVID-19 a causa de 1.206.434 (69,60%). Do total de casos de SRAG no Brasil, 490.363 (28,29%) foram registrados no ESP, sendo 345.453 confirmados para COVID-19 (28,63% dos casos do Brasil). Desse total, 1.166.188 precisaram de internação hospitalar e 377.718 casos evoluíram para óbito no Brasil. Já no ESP, houve 335.237 internações (28,75% das internações do Brasil) e 103.979 óbitos (27,53% dos óbitos do Brasil).

Com relação às informações do perfil das pessoas internadas por SRAG ou que foram a óbito, confirmadas para COVID-19 no ESP, pode-se verificar, na Tabela 2, sua distribuição segundo o sexo, percebendo-se que, tanto em 2020 quanto em 2021, os homens foram mais afetados do que as mulheres.

Tabela 2 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo sexo e ano. Estado de São Paulo, 2020 e 2021.

	Internações				Óbitos			
	2020		2021		2020		2021	
Sexo	N	%	N	%	N	%	N	%
Masculino	109.972	55,42%	189.223	56,44%	31.771	57,22%	58.442	56,21%
Feminino	86.833	43,76%	146.009	43,55%	23.752	42,78%	45.536	43,79%
Ignorado	5	0,002%	5	0,001%	0	0,000%	1	0,001%
Total	196.810	100,00%	335.237	100,00%	55.523	100,00%	103.979	100,00%

Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Já a Tabela 3 apresenta a distribuição dos casos internados e óbitos por COVID-19 segundo raça/cor, cuja predominância é observada entre brancos e pardos. Em 2021, por exemplo, a soma dos óbitos de pessoas brancas e pardas representou 80,2% de todos os óbitos por COVID-19 registrados na base. É importante destacar que entre 12,1% e 20,6% dos dados não continham informações sobre raça/cor registrados, assim, não é possível identificar seguramente a distribuição das internações e óbitos neste quesito.

Tabela 3 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo raça/cor e ano. Estado de São Paulo, 2020 e 2021.

	Internações				Óbitos			
	2020		2021		2020		2021	
Raça/Cor	N	%	N	%	N	%	N	%
Branca	105.120	52,97%	202.462	60,39%	31.457	56,66%	64.936	62,45%
Parda	38.529	19,42%	62.267	18,57%	11.263	20,29%	20.304	19,53%
Preta	9.860	4,97%	14.410	4,30%	3.209	5,78%	5.085	4,89%
Amarela	2.547	1,28%	3.316	0,99%	806	1,45%	1.036	1,00%
Indígena	147	0,07%	162	0,05%	35	0,06%	40	0,04%
Sem informação	40.607	20,63%	52.620	15,70%	8.753	15,76%	12.578	12,10%
Total	196.810	100,00%	335.237	100,00%	55.523	100,00%	103.979	100,00%

Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Outro fator sociodemográfico disponível na base de SRAG é a escolaridade. A Tabela 4 apresenta a frequência, segundo a escolaridade, dos casos internados e óbitos por COVID-19 no ESP. Destaca-se o grande número de casos sem informação sobre a escolaridade - em torno de 60% dos casos. Todavia, destaca-se o fato de que as pessoas com nível superior corresponderam a apenas 3,80% dos óbitos em 2020 e 4,58% em 2021.


Tabela 4 - Internações por SRAG e óbitos, confirmados para COVID-19, segundo escolaridade e ano. Estado de São Paulo, 2020 e 2021.

Escolaridade	Internações				Óbitos			
	2020		2021		2020		2021	
	N	%	N	%	N	%	N	%
Sem escolaridade / Analfabeto	3.501	1,76%	4.969	1,48%	1.599	2,88%	2.302	2,21%
Fundamental I	19.969	10,06%	31.231	9,32%	7.856	14,15%	13.644	13,12%
Fundamental II	13.585	6,85%	23.706	7,07%	4.307	7,76%	8.630	8,30%
Médio	25.723	12,96%	48.638	14,51%	5.327	9,59%	12.824	12,33%
Superior	13.631	6,87%	21.465	6,40%	2.109	3,80%	4.766	4,58%
Não se aplica	885	0,45%	943	0,28%	38	0,07%	53	0,05%
Sem informação	119.516	60,72%	204.285	60,93%	34287	61,75%	61760	59,39%
Total	196.810	100%	335.237	100%	55.523	100%	103.979	100%

Fonte: Elaborado pelo autor. Dados de Internações e Óbitos por SRAG disponíveis em: Datasus (2022).

A idade é também um fator importante a ser considerado para as internações e os óbitos por COVID-19, haja vista que se trata de um conhecido fator de risco. A Figura 4, abaixo, apresenta a quantidade de internações por faixa etária identificadas na base de SRAG, confirmadas para COVID-19.


Figura 4 - Internações por SRAG confirmadas para COVID-19, segundo faixa etária e ano. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Evidencia-se que a população de maior idade sofreu mais com a pandemia de COVID-19, pois, ainda que não seja a faixa etária de maior proporção na população paulista, as pessoas com 75 anos de idade ou mais representam o grupo com a maior participação, tanto nas internações (Figura 4) como nos óbitos por COVID-19 (Figura 5), em ambos os anos estudados.

Figura 5 - Óbitos confirmados para COVID-19, segundo faixa etária e ano. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Há ainda, na base de SRAG, informações referentes aos sinais e sintomas apresentados pelos casos internados. A Tabela 5 resume a frequência de cada um dos sinais/sintomas relatados, com destaque para tosse, dispneia e saturação de O₂ menor do que 95%. Chama a atenção o sintoma de fadiga, que, de um ano para outro, passou de 13,40% para 30,60%.

Tabela 5 - Distribuição dos sinais e sintomas apresentados pelos casos internados de SRAG, confirmados para COVID-19, segundo ano. Estado de São Paulo, 2020 e 2021.

Sinais/Sintomas	2020		2021	
	N	%	N	%
Tosse	145.535	71,37%	241.540	69,26%
Dispneia	139.773	68,54%	250.501	71,83%
Saturação O ₂ < 95,0%	122.868	60,25%	244.327	70,06%
Febre	121.983	59,82%	185.025	53,05%
Desconforto respiratório	116.722	57,24%	201.584	57,80%
Dor de garganta	35.336	17,32%	63.053	18,08%
Diarreia	28.033	13,74%	45.425	13,02%
Fadiga	27.337	13,40%	106.709	30,60%
Vômito	15.372	7,53%	26.272	7,53%
Perda de paladar	13.521	6,63%	39.903	11,44%
Perda de olfato	12.913	6,33%	38.086	10,92%
Dor abdominal	6.273	3,07%	21.123	6,05%
Outros sinais/sintomas	68.495	33,59%	101.752	29,17%

Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

A fim de se comparar a distribuição das taxas de internações e óbitos por COVID-19, por 100 mil habitantes, entre os municípios do território paulista nos anos de 2020 e 2021, foi realizada uma padronização das taxas por sexo e faixa etária.

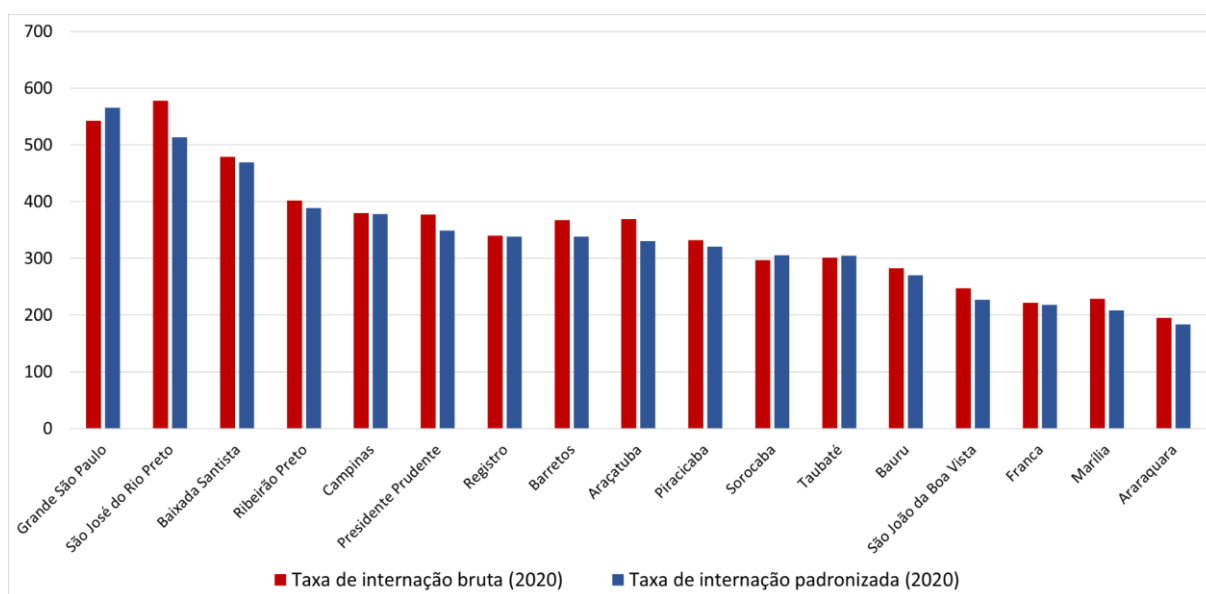
As distribuições das taxas brutas e padronizadas das internações de casos de SRAG confirmados para COVID-19, segundo Departamento Regional de Saúde

(DRS), para os anos de 2020 e 2021, são exibidas, respectivamente, nas Figuras 6 e 7. Na Figura 8 é feita uma comparação das taxas padronizadas entre os dois anos estudados.

A padronização fez com que as taxas de internação por COVID-19 em 2020 diminuíssem nos DRS de Araçatuba, Araraquara, Baixada Santista, Barretos, Bauru, Campinas, Franca, Marília, Piracicaba, Presidente Prudente, Registro, Ribeirão Preto, São João da Boa Vista e São José do Rio Preto. Já nos DRS da Grande São Paulo, Sorocaba e Taubaté, o ajuste realizado teve efeito inverso, resultando em aumento das taxas de internação por 100 mil habitantes (Figura 6). Verifica-se, assim, que, ao padronizarmos os dados, a comparação dos indicadores de COVID-19 entre os municípios e DRS torna-se mais precisa.

Como também pode ser percebido na Figura 6, o Departamento Regional de Saúde de São José do Rio Preto teve a maior taxa bruta de internação por COVID-19; todavia, ao se aplicar a padronização, nota-se uma importante redução em seu valor, enquanto que no DRS da Grande São Paulo, a taxa de internação bruta é menor que a padronizada, sendo esta a maior taxa padronizada entre os DRS do ESP.


Figura 6 - Taxas de internações brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2020.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Se no ano de 2020 apenas os DRS da Grande São Paulo, Baixada Santista, e São José do Rio Preto superaram 400 internações por 100 mil habitantes (taxa padronizada), no ano de 2021, todos os DRS ultrapassaram este patamar, sendo que apenas as taxas de internação do DRS da Baixada Santista foram menores do que 500 por 100 mil habitantes. Ademais, nota-se que as taxas de internação padronizadas foram maiores do que as brutas apenas nos DRS da Grande São Paulo, Registro, Sorocaba e Taubaté. Destaca-se que o DRS de São José do Rio Preto foi o que apresentou, em 2021, as maiores taxas bruta e padronizada, acima de 1.000 por 100.000 habitantes (Figura 7).

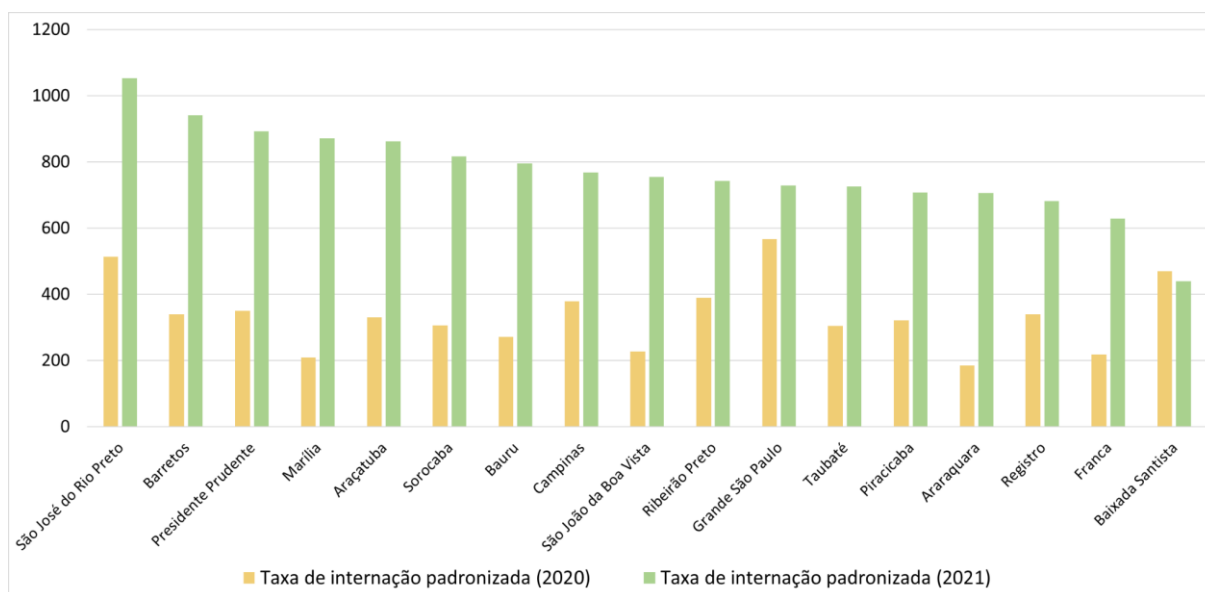
Figura 7 - Taxas de internações brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Ao compararmos as taxas de internação padronizadas de 2020 e 2021, verificamos um grande crescimento em todas as Regionais de Saúde, com exceção do DRS da Baixada Santista, que apresentou redução na taxa padronizada de internação por COVID-19 por 100 mil habitantes entre os dois anos.

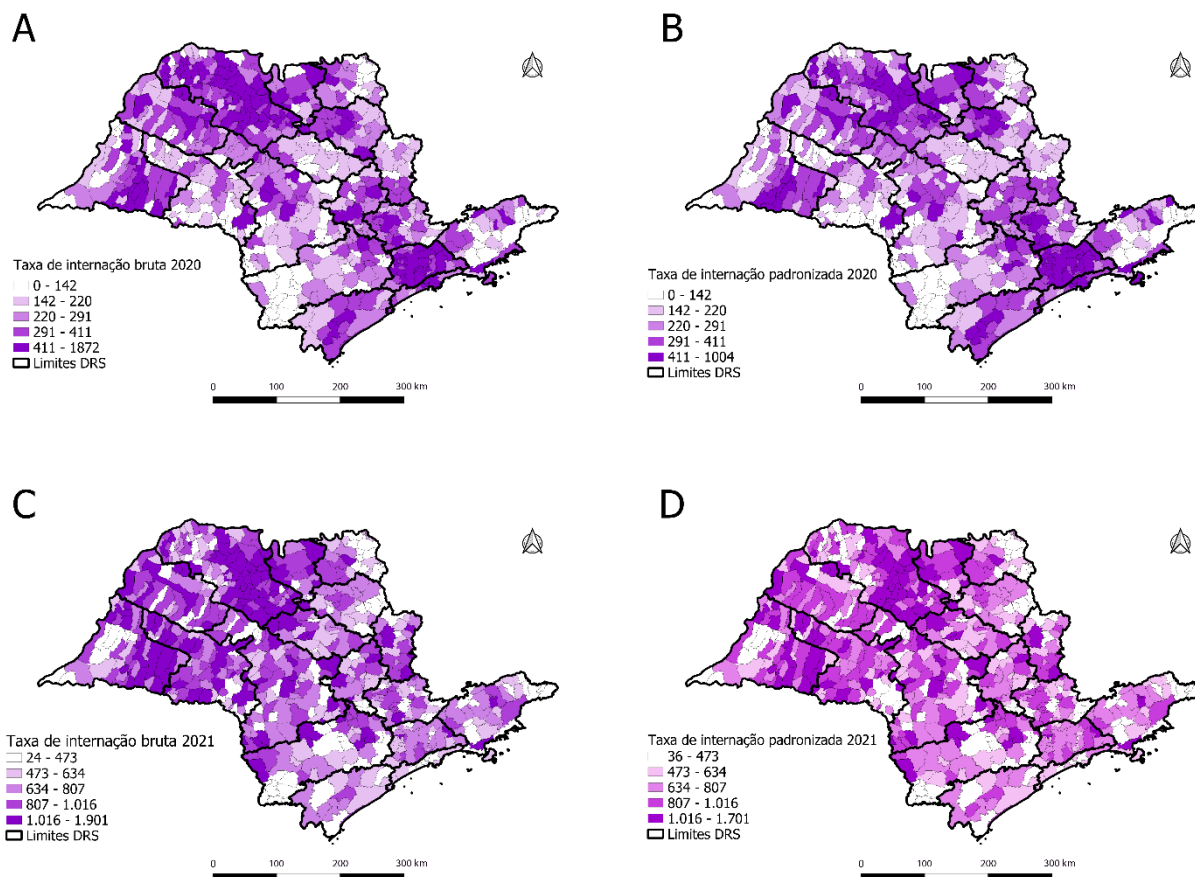
Figura 8 - Taxas de internações padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS) e ano. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

As taxas de internação por COVID-19, brutas e padronizadas por 100.000 habitantes, podem ser também observadas nos mapas da Figura 9, abaixo, que caracterizam a distribuição espacial dessas taxas nos municípios do ESP nos anos de 2020 e 2021. Foi possível notar que a aplicação da técnica de padronização por idade e sexo altera consideravelmente a taxa de internação de municípios com população pequena. Entre as cidades cuja padronização diminuiu a taxa bruta em 20% ou mais no ano de 2020, de um total de 69 municípios, encontramos apenas três com mais de 20 mil habitantes (Santos, São Caetano e Serra Negra). Nota-se, ainda, que a variação entre a taxa bruta e a taxa padronizada foi mais homogênea no ano de 2021, comparado ao ano de 2020.

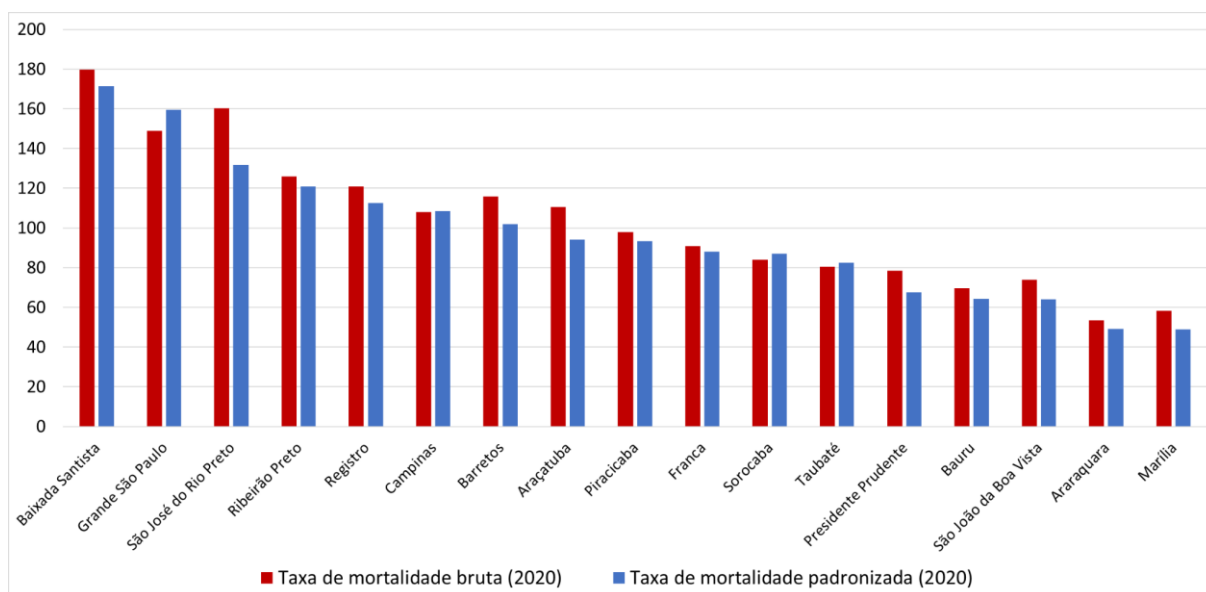
Figura 9 - Mapas das taxas de internações por COVID-19, por 100 mil habitantes, segundo município e ano. (A) Taxas brutas em 2020. (B) Taxas padronizadas em 2020. (C) Taxas brutas em 2021. (D) Taxas padronizadas em 2021. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Na sequência, apresentamos as análises referentes às taxas brutas e padronizadas de mortalidade por COVID-19, por 100 mil habitantes. Nota-se que o DRS da Baixada Santista apresentou as maiores taxas de mortalidade, tanto bruta quanto padronizada, no ano de 2020. Ainda que tenha apresentado taxas menores de internação, comparado aos DRS de São José do Rio Preto e Grande São Paulo, a Baixada Santista foi o DRS com as maiores taxas de mortalidade por COVID-19 por 100 mil habitantes no ESP, com a taxa bruta chegando a 179,71, e a padronizada a 171,43, em 2020 (Figura 10).

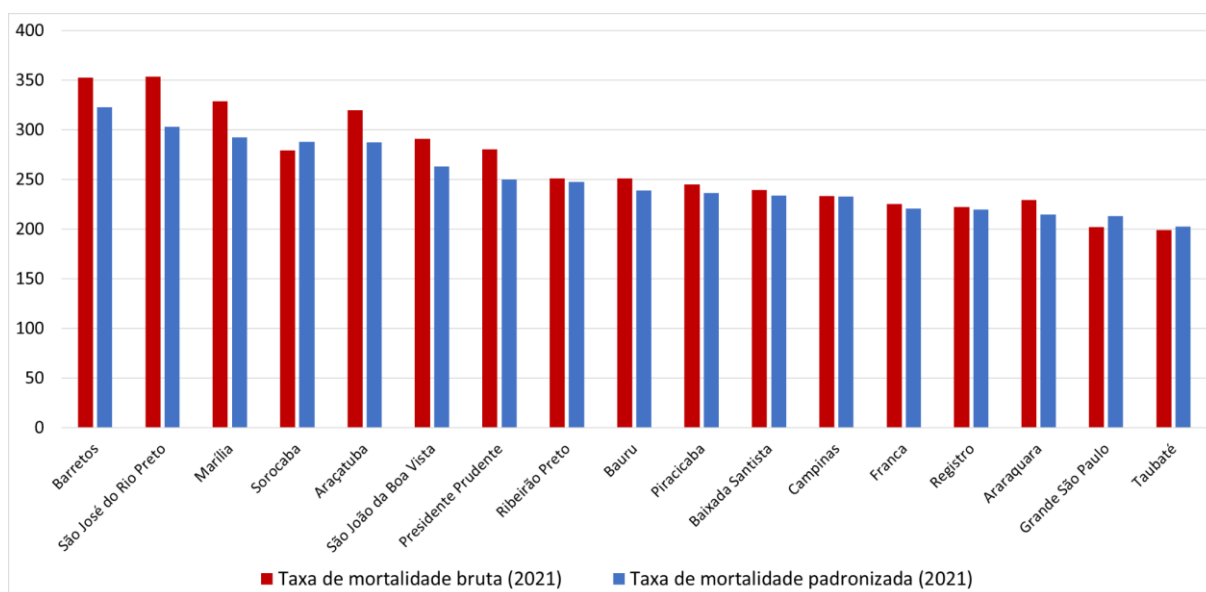
Figura 10 - Taxas de mortalidade brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2020.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Já no ano de 2021, todos os DRS apresentaram taxas brutas e padronizadas de mortalidade por COVID-19 acima de 200 por 100 mil habitantes, sendo a Regional de Taubaté aquela com as menores taxas (bruta e padronizada em torno de 200) e a de Barretos com as maiores taxas de mortalidade (bruta de 352,18 e padronizada de 322,50) (Figura 11).

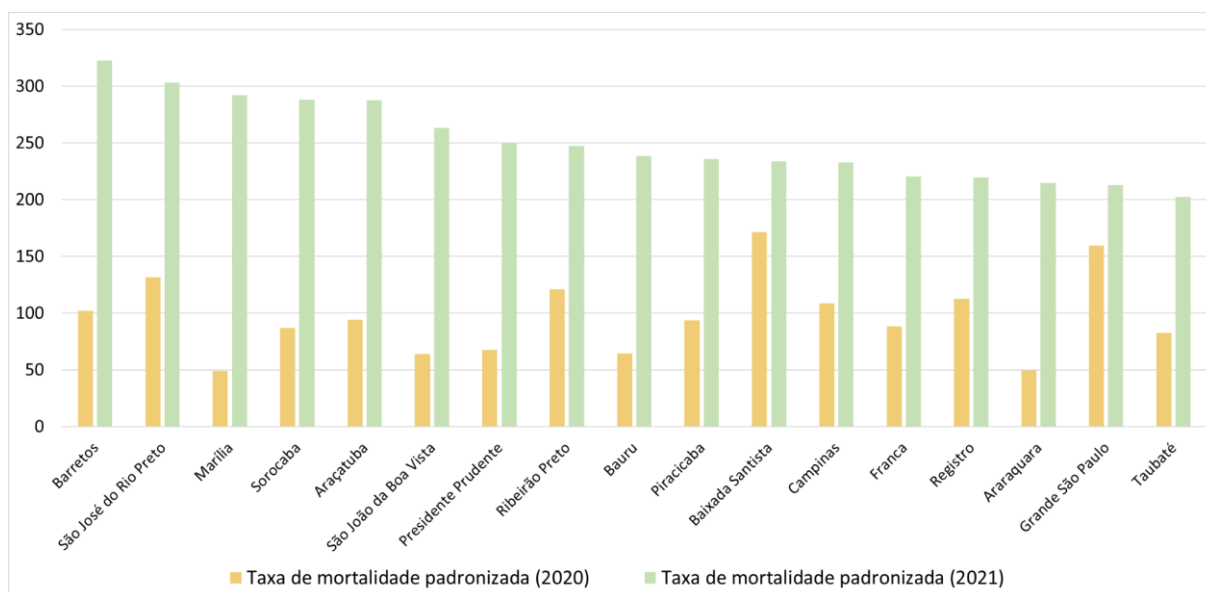
Figura 11 - Taxas de mortalidade brutas e padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS). Estado de São Paulo, 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

Ressalta-se que a taxa de mortalidade padronizada do DRS da Grande São Paulo, que em 2020 foi a segunda maior (ficando atrás apenas da Baixada Santista), em 2021 foi a segunda menor taxa, denotando que neste segundo ano houve uma interiorização dos óbitos decorrentes da pandemia de COVID-19 no ESP, com destaque para a Regional de Marília, onde a taxa de mortalidade aumentou em 498%, passando de 48,83 em 2020, para 292,14 por 100.000 habitantes em 2021, como pode ser observado na Figura 12.

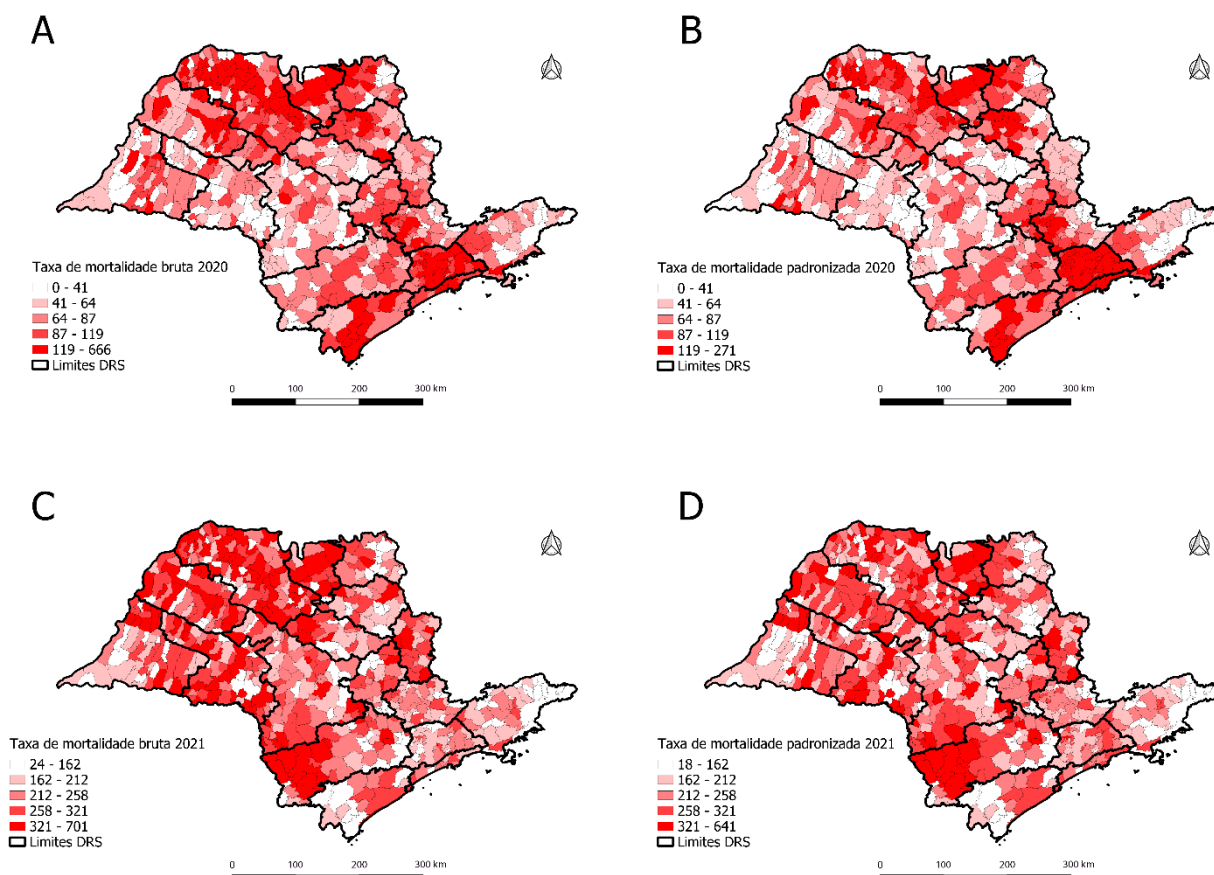
Figura 12 - Taxas de mortalidade padronizadas por COVID-19, por 100 mil habitantes, segundo Departamento Regional de Saúde (DRS) e ano. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

De modo a caracterizar a distribuição espacial dos óbitos por COVID-19 no ESP, a Figura 13 apresenta as taxas brutas e padronizadas de mortalidade por 100 mil habitantes segundo município e ano. A padronização da taxa de mortalidade no ano de 2020 identificou 148 municípios com variação negativa igual ou superior a 20%, sendo que, dentre esses, apenas 21 apresentam população acima de 20 mil habitantes, com destaque para os municípios de Santos, São Caetano do Sul e Catanduva, que possuem populações acima de 100 mil habitantes. Em contrapartida, 76 municípios apresentaram variação positiva superior a 20%, sendo que 48 destes tem população com mais de 20 mil habitantes, e destes 48, há ainda 24 com mais de 100 mil habitantes, destacando-se os municípios do DRS da Grande São Paulo. E, tal como observado na padronização das taxas de internação, nas taxas de mortalidade o ano de 2021 também apresentou resultados mais homogêneos com as taxas padronizadas.

Figura 13 - Mapas das taxas de mortalidade por COVID-19, por 100 mil habitantes, segundo município e ano. (A) Taxas brutas em 2020. (B) Taxas padronizadas em 2020. (C) Taxas brutas em 2021. (D) Taxas padronizadas em 2021. Estado de São Paulo, 2020 e 2021.



Fonte: Elaborado pelo autor. Dados de Internações por SRAG e Óbitos disponíveis em: Datasus (2022).

5.2. O ÍNDICE DE POBREZA MULTIDIMENSIONAL NOS MUNICÍPIOS PAULISTAS

A construção do IPM a partir das 24 variáveis listadas a partir dos IPMs dos países latino americanos deu-se, como descrito no capítulo de métodos, a partir da realização de ACP em cada uma das dimensões, buscando considerar as principais variáveis. Os resultados das ACP estão dispostos nas Tabelas 1 a 4, a seguir:

Tabela 6 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Educação”.

Variável	Peso no CP
% de pessoas sem alfabetização com mais de 15 anos	0,945442
% de pessoas sem instrução e ensino fundamental incompleto	0,944895
Taxa de distorção idade-série do ensino fundamental	-0,00868
Proporção da Variância do CP	0,59

Fonte: Elaborado pelo autor.

Tabela 7 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Condições Habitacionais”.

Variável	Peso no CP
% de domicílios particulares permanentes sem pavimentação	0,79006
% de domicílios particulares permanentes que não possuem geladeira	0,73155
% de domicílios particulares permanentes que tinham banheiro não conectado à rede geral de esgoto ou fossa séptica ou não tinham banheiro	0,71407
% de domicílios particulares permanentes sem serviço de coleta do lixo	0,65761
% de domicílios particulares permanentes cuja forma de abastecimento de água não era através da rede geral de distribuição	0,61051
% de domicílios particulares permanentes cuja forma de abastecimento de energia elétrica não era através da rede geral de distribuição	0,58637
% de domicílios particulares permanentes com mais de três moradores por dormitório	0,58375
% de domicílios particulares permanentes com paredes cujo material não é alvenaria nem madeira aparelhada	0,57579
% de domicílios particulares permanentes com computador sem acesso à <i>internet</i>	0,00846
Proporção da Variância do CP	0,388

Fonte: Elaborado pelo autor.

Tabela 8 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Saúde e Assistência Social”.

Variável	Peso no CP
% de pessoas beneficiárias de Plano de Saúde particular	0,767153
% de crianças com a relação peso-idade baixa ou muito baixa	0,625053
Taxa de mortalidade infantil	0,125562
Taxa de cobertura da Atenção Básica e Estratégia Saúde da Família do SUS	-0,714457
Proporção da Variância do CP	0,376

Fonte: Elaborado pelo autor.

Tabela 9 - Resultado dos autovalores e da proporção da variação do Componente Principal da dimensão “Trabalho e Renda”.

Variável	Peso no CP
% de pessoas com 10 anos ou mais ocupadas que não sejam empregadores, ou não tenham carteira assinada ou não sejam militares e funcionários públicos estatutários	0,838729
% de pessoas que no trabalho principal não contribuem para instituto de previdência social	0,793076
% de pessoas ocupadas com idade entre 10 e 13 anos	0,649837
Taxa de trabalho infantil	0,639521
Taxa de dependência econômica	0,550236
% de pessoas da população economicamente ativa sem ocupação com 10 anos ou mais	-0,612632
% de pessoas da população economicamente ativa sem ocupação com 14 anos ou mais	-0,614217
Proporção da Variância do CP	0,46

Fonte: Elaborado pelo autor.

Tendo em vista que foram consideradas, para cada dimensão, as variáveis com autovalores acima de 0,6. Não foi aplicada a ACP para a dimensão de vida comunitária pelo fato de ser composta por apenas um indicador.

Tendo sido selecionados os indicadores de cada dimensão, determinamos os seus pesos, de forma que todas as dimensões possuem o mesmo peso no IPM, e os indicadores dentro de cada dimensão têm pesos iguais. Assim, os indicadores e as dimensões escolhidos para a composição do IPM foram (Quadro 4):

Quadro 4 - Composição final dos indicadores do Índice de Pobreza Multidimensional: dimensão, indicadores e respectivos pesos.

Dimensão	Indicador	Peso da dimensão	Peso dos indicadores
Condições Habitacionais	ch_cond_ rua_ acesso	0,2	0,04
	ch_bens_domesticos		0,04
	ch_sem_banheiro_saneamento		0,04
	ch_sem_agua		0,04
	ch_destino_lixo		0,04
Educação	ed_alfabetizacao_15	0,2	0,1
	ed_nivel_instrucao		0,1
Saúde e Assistência Social	sas_benef_plano_saude	0,2	0,1
	sas_peso_idade		0,1
Trabalho e Renda	ter_trab_informal	0,2	0,05
	ter_trab_infantil		0,05
	ter_sem_contrib_previdencia		0,05
	ter_trab_infantojuvenil		0,05
Vida Comunitária	vc_cert_nascimento	0,2	0,2

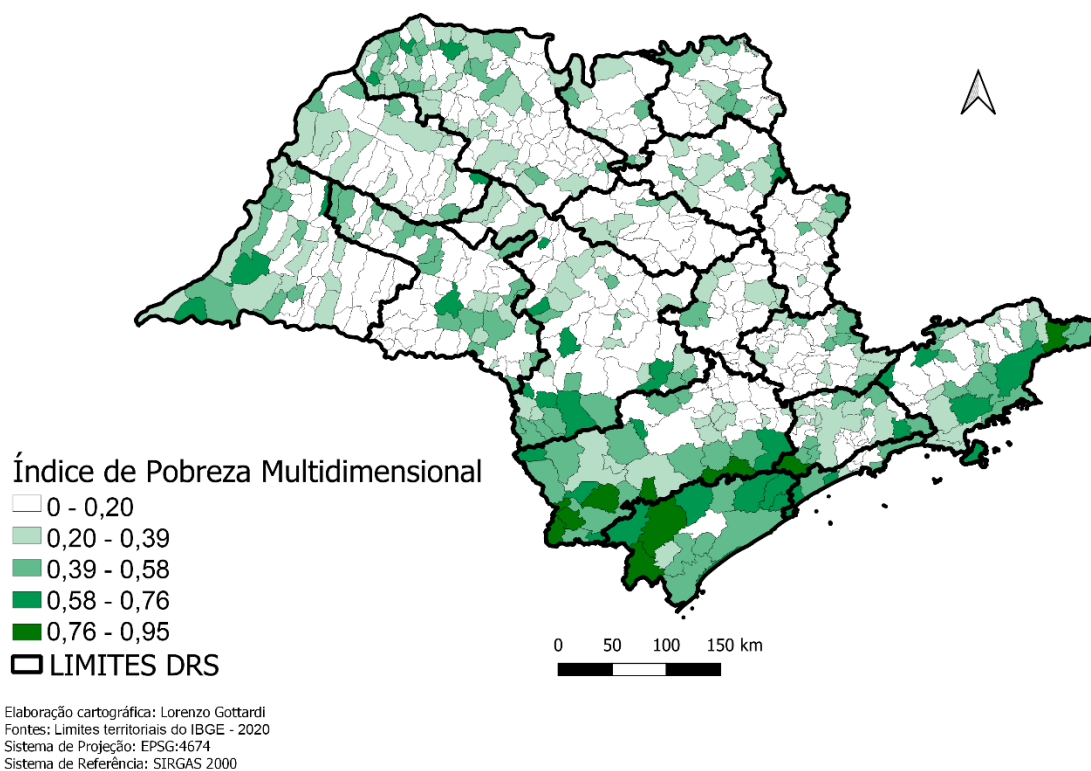
Fonte: Elaborado pelo autor.

Dessa forma, foi possível calcular o hiato (A) e a incidência (H) da pobreza de cada município. Dos 645 municípios do ESP, 82 (12,71%) não foram considerados privados em nenhum dos 24 indicadores selecionados. Além disso, 207 municípios (32,09%) apresentaram IPM igual a zero, pois os valores auferidos do hiato de pobreza variaram entre 0,04 e 0,19, sendo, assim, inferiores ao corte de pobreza estabelecido, de 0,2. Dessa forma, no total, 289 (82 + 207) municípios (44,81%) apresentaram IPM igual a zero, ou seja, não foram considerados multidimensionalmente pobres. Três municípios do ESP (Bom Sucesso de Itararé, Barra do Chapéu e Itapirapuã Paulista) foram os que apresentaram o maior número de indicadores com privação - um total de 13 (treze) indicadores cada. Entretanto, face aos pesos de cada indicador, o município de Bom Sucesso de Itararé foi o que apresentou o maior hiato de pobreza, e, conseqüentemente, o maior IPM (0,95).

Destaca-se que os três municípios supramencionados fazem parte do XVI Departamento Regional de Saúde - Sorocaba. Há, ainda, o município de Eldorado, do DRS de Registro, que registrou 12 (doze) indicadores em situação de privação, contudo, devido ao peso dos indicadores, apresentou o segundo maior IPM (0,92). Ressalta-se, ainda, que, dentre os dez municípios com os maiores IPM, seis deles encontram-se no DRS XVI - Sorocaba: Bom Sucesso de Itararé, Barra do Chapéu, Itapirapuã Paulista, Ribeirão Branco, Tapiraí e Ribeirão Grande.

A Figura 14, a seguir, denota a distribuição espacial dos IPM nos municípios do ESP, e a Figura 15, a distribuição dos IPM segundo os DRS, calculados a partir da média dos IPM de seus municípios componentes. Ao observar a Figura 14, identificamos que o DRS de Registro se destaca dos demais pela concentração de municípios em situação de pobreza multidimensional, enquanto que os DRS de Piracicaba, Araraquara e São João da Boa Vista evidenciam poucos municípios em estado de pobreza. A distribuição espacial do IPM evidenciou o fato de que o ESP possui municípios mais ricos ao centro, e municípios em condição de pobreza em áreas mais periféricas.

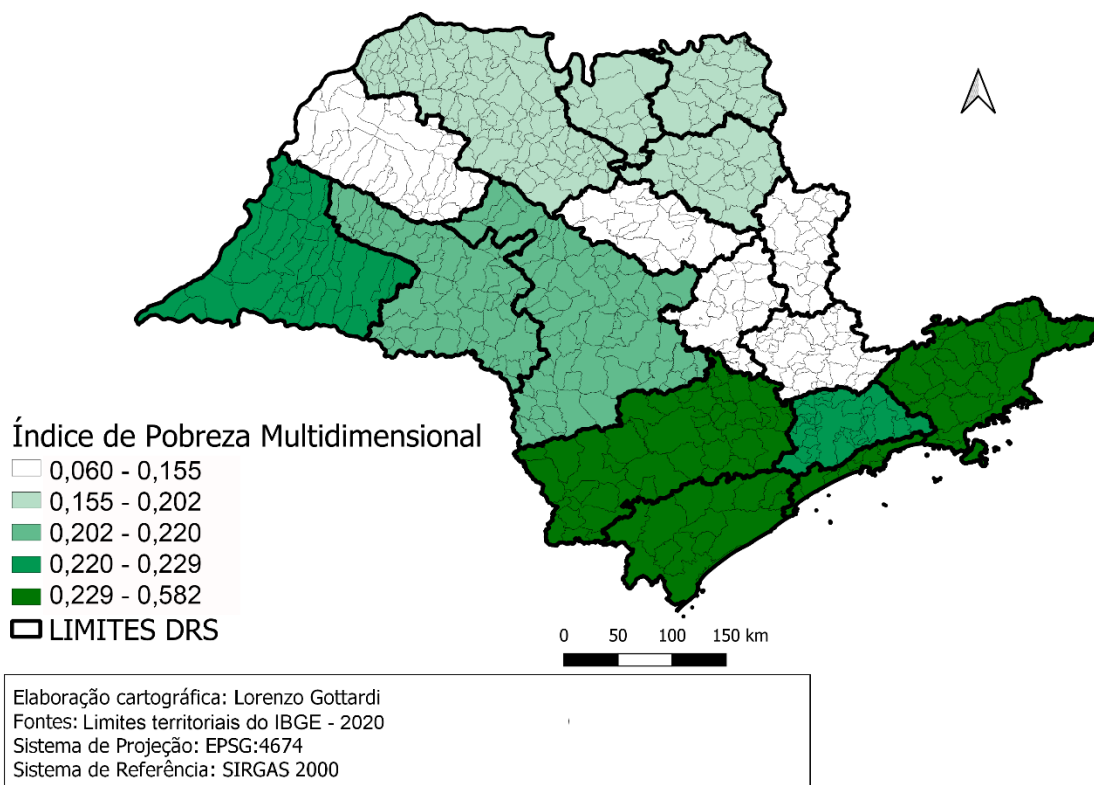
Figura 14 - Mapa dos Índices de Pobreza Multidimensional segundo município do estado de São Paulo, com destaque para os limites dos Departamentos Regionais de Saúde, 2022.



Fonte: Elaborado pelo autor.

Já quanto ao mapa da pobreza segundo os DRS (média dos IPMs dos municípios de cada DRS), representado na Figura 15, identificamos que Registro, Sorocaba, Baixada Santista e Taubaté apresentam os maiores IPMs Regionais. Contudo, cumpre ressaltar que entre os municípios desses DRS, a pobreza não se distribui de maneira equânime, isto é, existem desigualdades internas, como, por exemplo, o DRS de Sorocaba, que apresenta municípios ao sul com alto IPM e municípios ao norte com IPM baixo (Figura 14).

Figura 15 - Mapa dos Índices de Pobreza Multidimensional segundo Departamento Regional de Saúde (DRS) do estado de São Paulo, 2022.



Fonte: Elaborado pelo autor.

No Apêndice A são apresentados detalhadamente os valores de A (hiato de pobreza), H (incidência da pobreza) e M0 (o IPM em si) para cada um dos municípios do estado de São Paulo. Já a Tabela 10, abaixo, apresenta o valor dos IPMs obtidos para cada DRS do ESP. Destaca-se ainda que oito DRS apresentaram valor de IPM menor do que o corte de pobreza multidimensional. Isto está relacionado ao fato de nestes DRS muitos municípios apresentam baixos níveis de privação. Nota-se ainda que estes DRS se localizam na parte centro-norte do Estado, evidenciando a concentração da pobreza e da riqueza no território.

Tabela 10 - Índices de Pobreza Multidimensional calculados para os Departamentos Regionais de Saúde (DRS) do estado de São Paulo, 2022.

DRS	IPM
XII - Registro	0,582
XVI - Sorocaba	0,356
IV - Baixada Santista	0,352
XVII - Taubaté	0,341
XI - Presidente Prudente	0,229
I - Grande São Paulo	0,223
VI - Bauru	0,220
IX - Marília	0,218
XV - São José do Rio Preto	0,202
XIII - Ribeirão Preto	0,172
V - Barretos	0,169
VIII - Franca	0,164
II - Araçatuba	0,155
VII - Campinas	0,151
XIV - São João da Boa Vista	0,131
X - Piracicaba	0,072
III - Araraquara	0,060

Fonte: Elaborado pelo autor.

5.3. RELAÇÃO ENTRE POBREZA MULTIDIMENSIONAL E COVID-19

Após analisarmos os dados de internações e óbitos por COVID-19, e elaborarmos o Índice de Pobreza Multidimensional para os municípios e DRS do ESP, a próxima etapa consistiu em investigar as associações existentes entre esses dois fenômenos. Nesta fase, a primeira análise executada foi um teste de normalidade dos indicadores. O teste de *Shapiro-Wilk* apresentou os seguintes resultados para cada variável (Tabela 11):

Tabela 11 - Resultados do teste de normalidade de *Shapiro-Wilk* para os indicadores de COVID-19 e o Índice de Pobreza Multidimensional nos municípios do estado de São Paulo, em 2020 e 2021.

Indicador	Resultado do <i>p</i> -valor do Teste de <i>Shapiro-Wilk</i>
Índice de Pobreza Multidimensional	< 0,001
Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2020)	< 0,001
Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2020)	< 0,001
Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2021)	< 0,001
Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2021)	< 0,001

Fonte: Elaborado pelo autor.

Assim, para todas as variáveis testadas, os *p*-valores resultantes foram infinitamente menores do que 0,05, o que nos levou a rejeitar a hipótese de que os dados possuem uma distribuição gaussiana, ou seja, os indicadores trabalhados não apresentam distribuição normal. Dessa forma, optou-se pela aplicação do teste de correlação de *Spearman* entre os indicadores de COVID-19 e o IPM, de modo a compreender o quanto, e em que sentido, a pobreza multidimensional se relaciona com a COVID-19 no ESP. O resultado desta etapa é apresentado na Tabela 12, a seguir.

Tabela 12 - Resultados dos coeficientes de correlação de *Spearman* entre o Índice de Pobreza Multidimensional (IPM) e os indicadores padronizados de COVID-19 nos municípios do estado de São Paulo, em 2020 e 2021.

Variáveis correlacionadas	Coeficiente de correlação de Spearman	p-valor
IPM e Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2020)	-0,2319307	< 0,001
IPM e Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2020)	-0,1283018	0,001
IPM e Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2021)	-0,2238019	< 0,001
IPM e Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2021)	-0,1253385	0,001

Fonte: Elaborado pelo autor.

Os resultados obtidos indicam que há uma relação negativa significativa entre o IPM e os indicadores de COVID-19, ou seja, quanto maior o valor do IPM (mais pobreza), menores as taxas de internação e de mortalidade por COVID-19. Observam-se correlações de fraca magnitude entre o IPM e as taxas padronizadas de internações e óbitos por COVID-19 nos municípios do ESP, em ambos os anos estudados (Tabela 12). Assim, podemos afirmar que o IPM explica em torno de 1,6% da variância total dos indicadores de mortalidade, e em torno de 5% da variância total dos indicadores de internação por COVID-19 nos municípios do ESP.

De modo a aprofundar o entendimento acerca desta relação, optamos também por realizar testes de correlação com os dados agrupados pelos Departamentos Regionais de Saúde, cujos resultados encontram-se resumidos na Tabela 13:

Tabela 13 - Resultados dos coeficientes de correlação de *Spearman* entre o Índice de Pobreza Multidimensional (IPM) e os indicadores padronizados de COVID-19, segundo os Departamentos Regionais de Saúde do estado de São Paulo, em 2020 e 2021.

Departamento Regional de Saúde	IPM e Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2020)		IPM e Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2020)		IPM e Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2021)		IPM e Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2021)		N (quantidade de municípios no território do DRS)	Ranking por IPM
	Coeficiente	p-valor	Coeficiente	p-valor	Coeficiente	p-valor	Coeficiente	p-valor		
Registro	-0,75	0,00138*	-0,74	0,00177*	-0,36	0,189	-0,35	0,199	15	1
Sorocaba	-0,59	0,0000115*	-0,27	0,0594	-0,50	0,000273*	-0,04	0,777	48	2
Baixada Santista	-0,82	0,0636	-0,76	0,0184*	0,30	0,429	0,36	0,339	9	3
Taubaté	-0,42	0,00828*	-0,45	0,00442*	-0,34	0,0347*	-0,43	0,00586*	39	4
Presidente Prudente	-0,48	0,000931*	-0,29	0,0528	-0,15	0,337	-0,08	0,6	45	5
Grande São Paulo	-0,23	0,165	-0,26	0,111	-0,11	0,448	-0,21	0,192	39	6
Bauru	-0,24	0,0496*	-0,23	0,06	-0,03	0,809	0,16	0,2	68	7
Marília	-0,29	0,0235*	-0,20	0,115	-0,14	0,28	-0,23	0,695	62	8
São José do Rio Preto	-0,24	0,0141*	-0,01	0,913	-0,32	0,00116*	-0,06	0,536	102	9
Ribeirão Preto	-0,05	0,798	0,01	0,971	-0,31	0,12	-0,14	0,489	26	10
Barretos	-0,32	0,195	-0,32	0,345	-0,24	0,19	-0,59	0,01*	18	11
Franca	-0,18	0,424	-0,02	0,935	-0,19	0,403	-0,10	0,664	22	12
Araçatuba	-0,14	0,38	-0,05	0,749	-0,13	0,42	0,12	0,452	40	13
Campinas	-0,50	0,00069*	-0,50	0,000674*	-0,31	0,0439*	-0,52	0,000386*	42	14
São João da Boa Vista	-0,09	0,719	-0,28	0,24	-0,18	0,438	-0,19	0,431	20	15
Piracicaba	0,13	0,519	0,12	0,55	0,09	0,646	-0,20	0,336	26	16
Araraquara	0,15	0,489	0,25	0,23	-0,43	0,034*	-0,19	0,36	24	17
Estado de São Paulo	-0,23	0,00000000252*	-0,13	0,00109*	-0,22	0,00000000915*	-0,13	0,00142*	645	-

Fonte: Elaborado pelo autor. *p-valor menor do que 0,05.

Os resultados obtidos a partir da análise de correlação de *Spearman*, considerando-se cada DRS separadamente, corroboram os achados iniciais para o ESP como um todo. Entre os DRS, alguns apresentaram coeficientes de correlação bastante altos, tal como Registro, que teve valores de correlação negativos de alta magnitude (maior do que 0,70) entre o IPM e suas taxas padronizadas de internação e de óbito em 2020. Por outro lado, os DRS de São José do Rio Preto e Franca, por exemplo, apresentaram coeficientes de correlação entre o IPM e as taxas de mortalidade padronizadas em ambos os anos próximos de zero, não indicando associação entre essas variáveis.

Destacam-se, ainda, alguns DRS com correlações positivas entre o IPM e a mortalidade padronizada (ou seja, quanto maior o IPM, maior a mortalidade por COVID-19), contudo, muito fracas e sem significância, a saber: Ribeirão Preto, Piracicaba e Araraquara, em 2020; e Baixada Santista, Bauru e Araçatuba, em 2021. Algumas correlações positivas fracas e não significativas também foram encontradas entre o IPM e as taxas de internação padronizadas, destacando-se os DRS de Piracicaba e Araraquara em 2020, e Baixada Santista e Piracicaba em 2021.

Uma segunda etapa da análise de correlação refere-se à autocorrelação espacial da pobreza multidimensional e dos indicadores de internação e de óbito por COVID-19, e a correlação espacial entre esses indicadores. Dessa forma, optamos por usar os Índices de Moran Global e Local univariados e o Índice de Moran Local bivariado. Assim, além de identificar a existência e a magnitude da dependência espacial dos indicadores, foi possível também detectar aglomerados onde constatamos alta pobreza multidimensional e altas taxas de COVID-19, ou alta pobreza multidimensional e baixas taxas de COVID-19, ou baixa pobreza multidimensional e altas taxas de COVID-19, ou baixa pobreza multidimensional e baixas taxas de COVID-19.

A Tabela 14, a seguir, exhibe os valores dos Índices de Moran Global do Índice de Pobreza Multidimensional e dos indicadores de internação e de óbito por COVID-19 nos anos de 2020 e 2021.

Tabela 14 - Índices de Moran Global univariados do Índice de Pobreza Multidimensional e dos indicadores padronizados de internação e de óbito por COVID-19 nos municípios do estado de São Paulo, em 2020 e 2021.

Variáveis autocorrelacionadas	Índice de Moran Global univariado	p-valor
Índice de Pobreza Multidimensional	0,335	0,001
Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2020)	0,447	0,001
Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2020)	0,419	0,001
Taxa de internação padronizada por COVID-19 por 100 mil habitantes (2021)	0,279	0,001
Taxa de mortalidade padronizada por COVID-19 por 100 mil habitantes (2021)	0,205	0,001

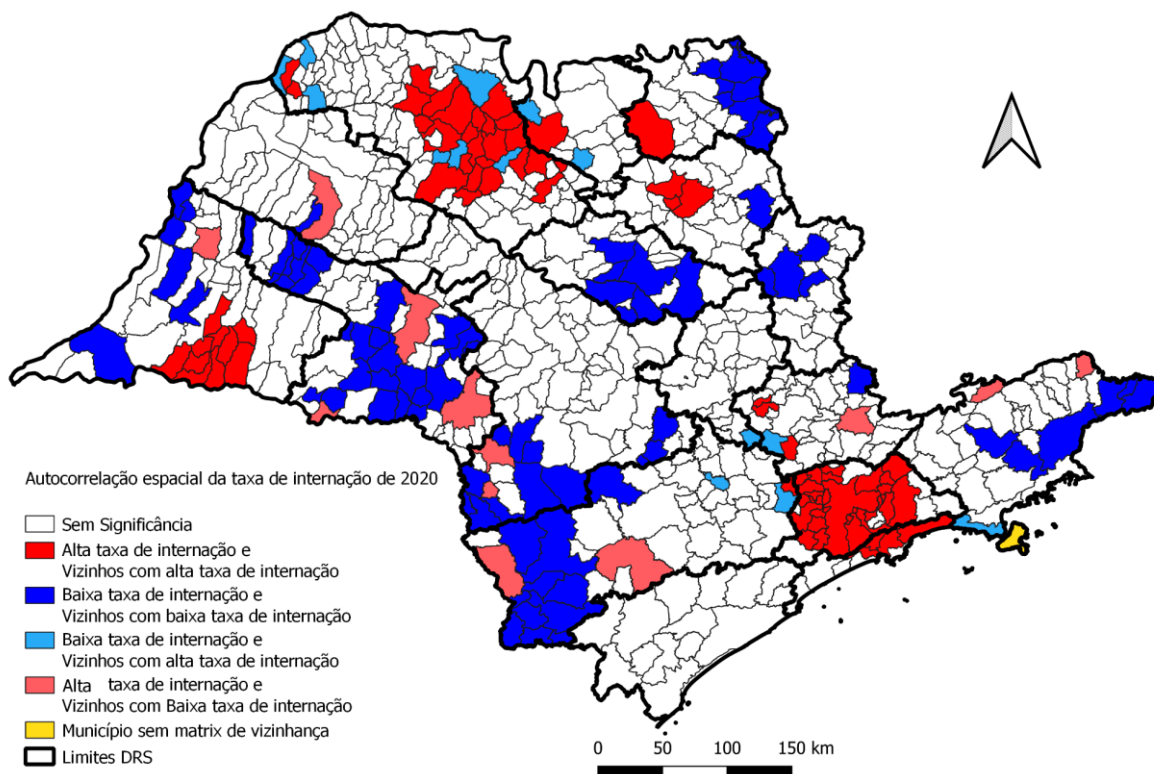
Fonte: Elaborado pelo autor.

Os resultados dos Índices de Moran Global univariados indicam que há autocorrelação espacial nos indicadores-alvo deste trabalho. Assim, para uma melhor caracterização dessas dependências espaciais, foram elaborados mapas de aglomerados para cada um dos indicadores (LISA MAP). Esses mapas permitem verificar como os resultados de cada indicador, de cada município, se relacionam espacialmente com os resultados do mesmo indicador nos municípios vizinhos.

A Figura 16 denota claramente os agrupamentos de municípios e respectivos vizinhos com altas taxas de internação por COVID-19 no ano de 2020, em três regiões do ESP. Um aglomerado reúne alguns municípios do DRS de Presidente Prudente; outro está localizado na Grande São Paulo, e um terceiro aglomerado é verificado entre São José do Rio Preto e Votuporanga, no oeste do ESP.

Alguns aglomerados de baixas taxas entre os municípios e seus vizinhos são observados no Vale da Paraíba, em direção à divisa com o estado do Rio de Janeiro; no centro-sul do estado de São Paulo, no entorno das cidades de Itapeva e Marília; além da região de Franca e aquela próxima a Araraquara e São Carlos (Figura 16).

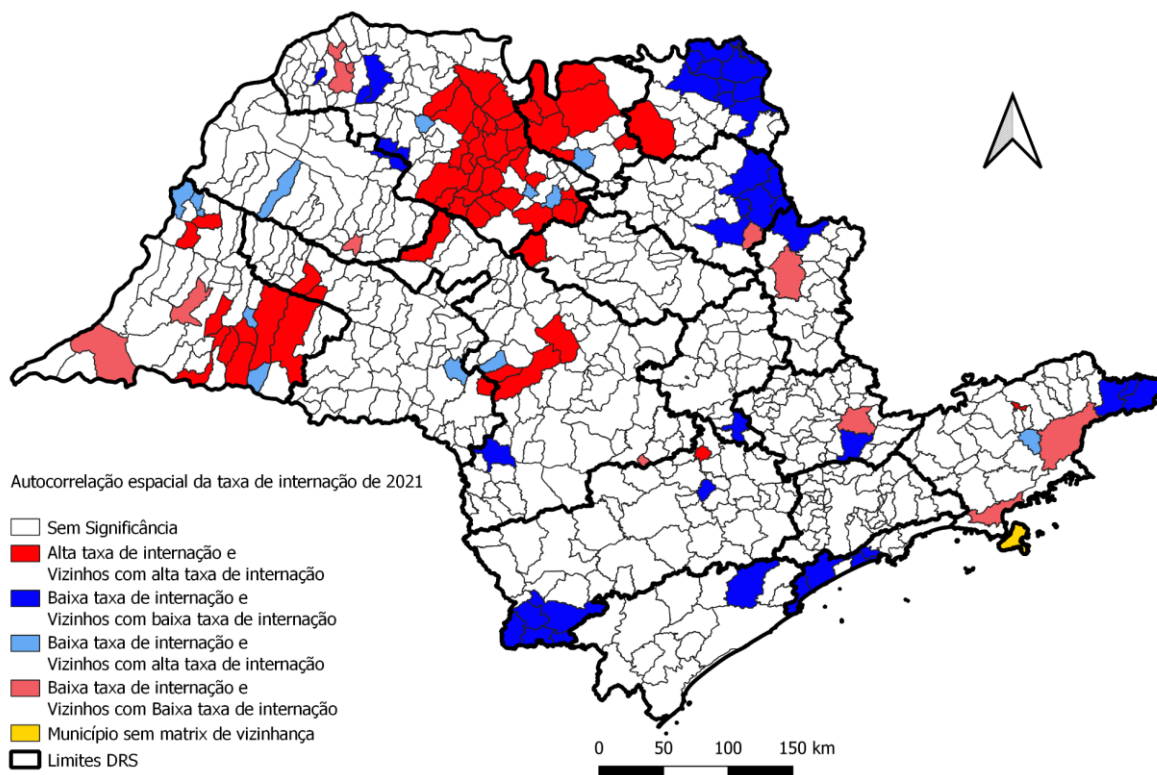
Figura 16 - Mapa da autocorrelação espacial das taxas de internação padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2020.



Fonte: Elaborado pelo autor.

Todavia, ao observarmos a Figura 17, notamos que há uma mudança dos padrões de aglomerados de internações por COVID-19 no ano de 2021, em comparação a 2020. A análise de autocorrelação espacial da taxa de internação padronizada de COVID-19 por 100 mil habitantes, no ano de 2021, apresenta dois grandes aglomerados de municípios com altas taxas. O primeiro se assemelha ao aglomerado encontrado em 2020, na região próxima de Presidente Prudente, porém, com um aumento do número de municípios incluídos neste aglomerado em 2021. O segundo também pôde ser verificado em 2020, na região de São José do Rio Preto e Votuporanga, no oeste do estado. Não se observa, no entanto, o aglomerado alto-alto na região da Grande São Paulo, verificado em 2020. Já os aglomerados de baixas taxas de internação em 2021 se encontram principalmente na região de Franca, tal qual pôde ser observado em 2020, mas com mais municípios classificados no aglomerado de 2021 (Figura 17).

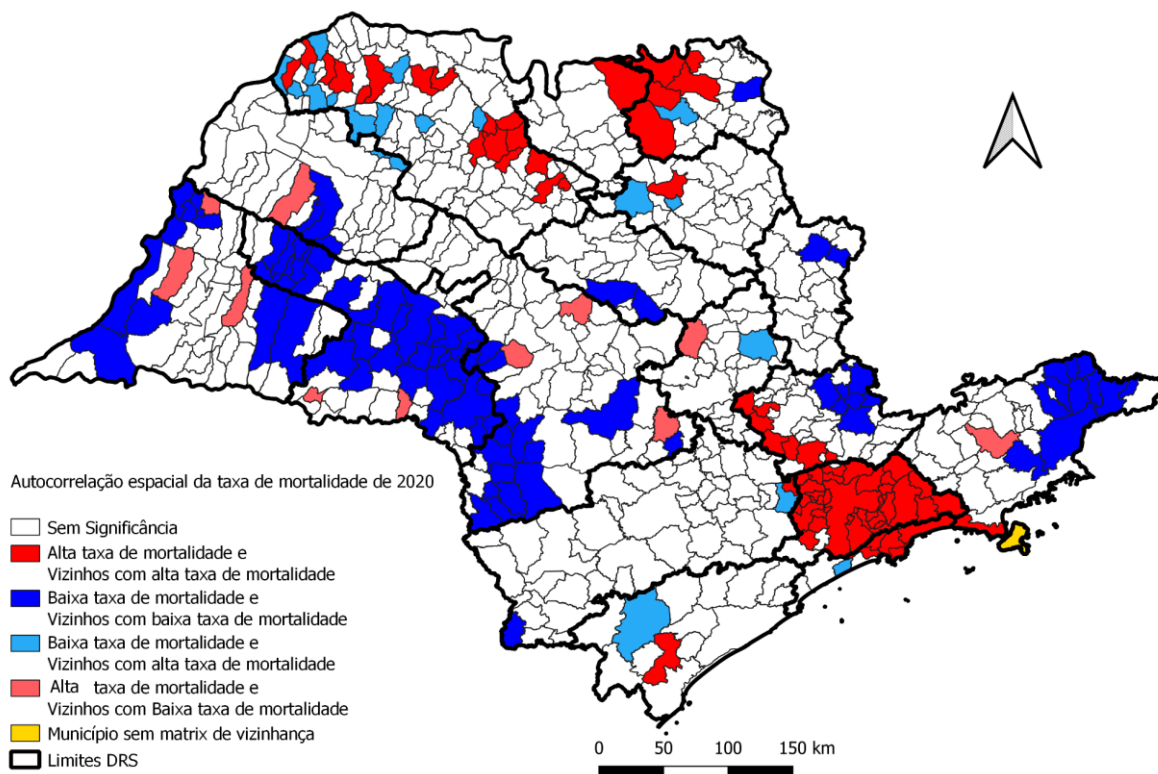
Figura 17 - Mapa da autocorrelação espacial das taxas de internação padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2021.



Fonte: Elaborado pelo autor.

Na análise da autocorrelação espacial da mortalidade padronizada no ano de 2020 (Figura 18), destacam-se três grandes aglomerados de municípios com baixas taxas de óbitos - um na região nordeste do estado, na divisa com o Rio de Janeiro; outro na região sudoeste, já na divisa com o Mato Grosso do Sul; e um terceiro aglomerado bastante extenso, que perpassa quatro DRS (Bauru, Marília, Presidente Prudente e Araçatuba), formado por municípios que vão do centro-sul do estado, na divisa com o Paraná, até próximo a Presidente Prudente, no sudoeste do estado. Por outro lado, na região da Grande São Paulo, abrangendo, ainda, municípios do DRS da Baixada Santista e alguns da Regional de Campinas, observamos um aglomerado de municípios com autocorrelação espacial de altas taxas de óbitos por COVID-19 no ano de 2020 (Figura 18).

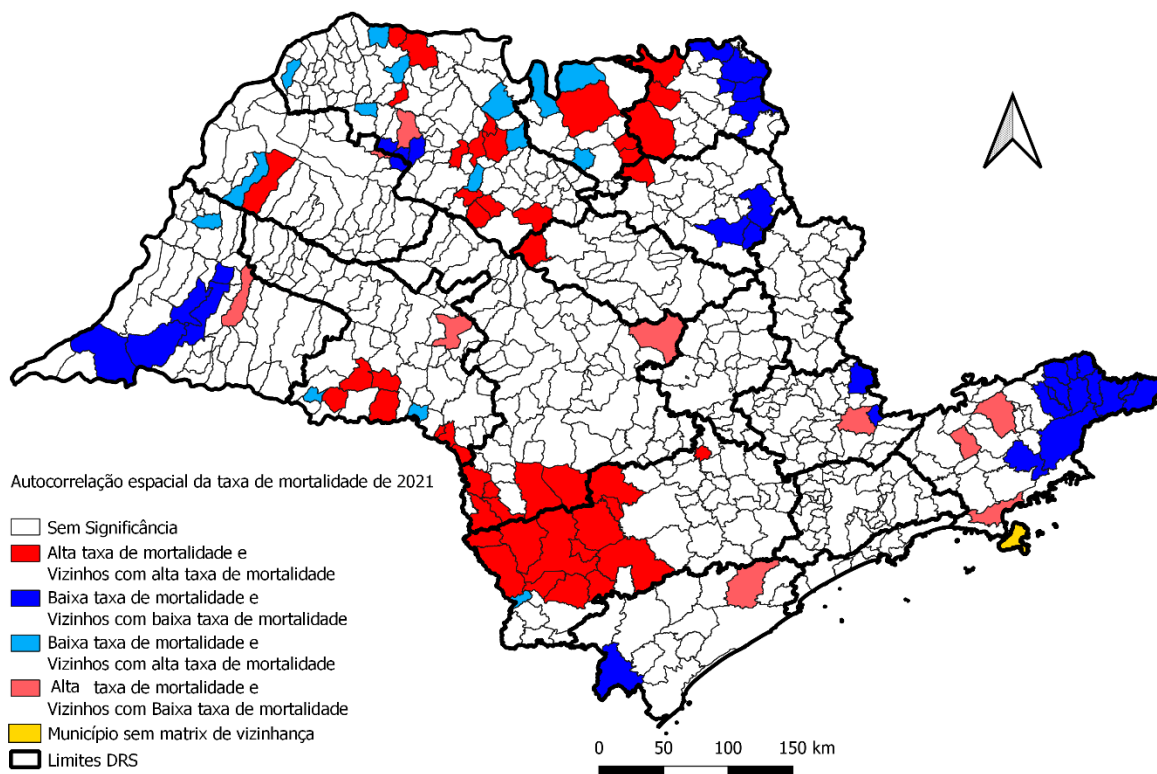
Figura 18 - Mapa da autocorrelação espacial das taxas de mortalidade padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2020.



Fonte: Elaborado pelo autor.

Por fim, a autocorrelação espacial das taxas de óbitos no ano de 2021 apresentou menos aglomerados de municípios, como pode ser observado na Figura 19, a seguir. Destacam-se os aglomerados de municípios com baixas taxas de óbito a nordeste (região próxima ao estado do Rio de Janeiro), a sudoeste (próximo à divisa de Mato Grosso do Sul e Paraná) e ao norte do estado, na região de Franca. Há ainda um grande aglomerado de municípios com altas taxas de óbitos no centro-sul do ESP, englobando a região do entorno da cidade de Itapeva, em 2021 (Figura 19).

Figura 19 - Mapa da autocorrelação espacial das taxas de mortalidade padronizadas de COVID-19, por 100 mil habitantes, nos municípios do estado de São Paulo, em 2021.



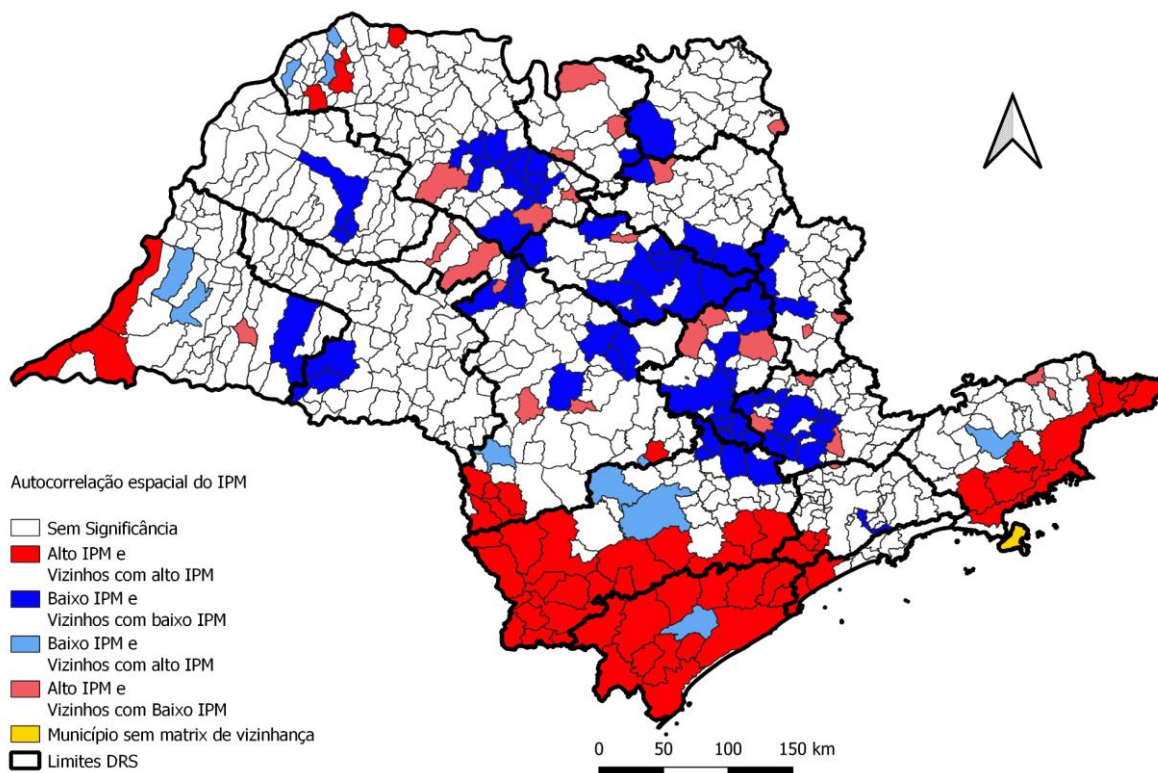
Fonte: Elaborado pelo autor.

Já na análise da autocorrelação espacial do Índice de Pobreza Multidimensional (Figura 20), evidencia-se a concentração de municípios pobres na região do Vale do Ribeira, no DRS de Registro, alcançando, ainda, municípios do DRS de Sorocaba vizinhos ao DRS de Registro e próximos do Paraná. A região do litoral norte, no DRS de Taubaté, também apresentou um aglomerado de alta pobreza multidimensional. No sudoeste do estado, os municípios de Rosana, Teodoro Sampaio e Presidente Epitácio configuram um aglomerado de alta pobreza na região.

Um fator importante a ser destacado na Figura 20 é a centralidade socioeconômica do município de Registro. No aglomerado presente na região, com predominância de municípios classificados com alto índice de pobreza e vizinhos também com alta pobreza, o município de Registro é classificado como de baixa pobreza, com vizinhos com alta pobreza. Isso evidencia a cidade como polo socioeconômico da região. Cumpre observar, ainda, os aglomerados de baixa

pobreza no centro do estado, sobretudo nos DRS de Campinas, Piracicaba e Araraquara, e alguns outros municípios nos DRS de Ribeirão Preto, São João da Boa Vista, Franca, Bauru e São José do Rio Preto.

Figura 20 - Mapa da autocorrelação espacial do Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2022.



Fonte: Elaborado pelo autor.

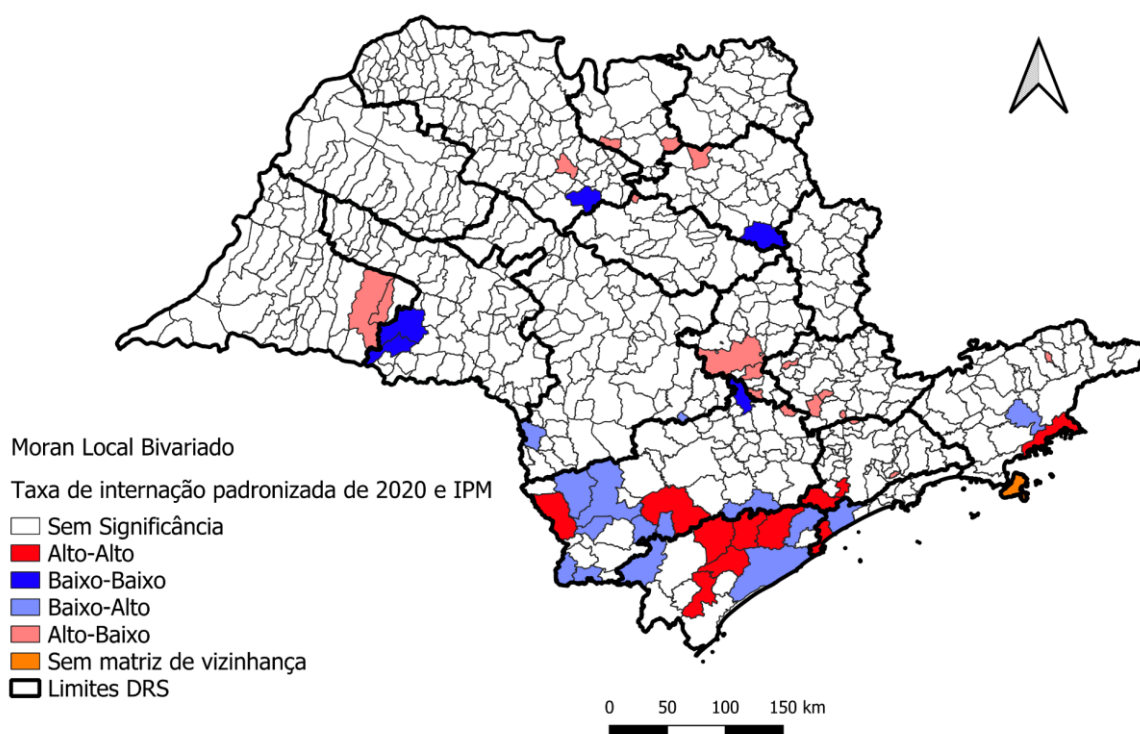
Tal qual na análise de autocorrelação descrita acima, o Índice de Moran Local bivariado foi usado para verificar a dependência espacial entre as taxas de internação e de mortalidade padronizadas por COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos anos de 2020 e 2021. Assim, os mapas a seguir (LISA MAPS - Figuras 21 a 24) denotam os resultados dessas análises nos municípios do ESP.

Destacados na cor azul-escuro, os aglomerados de municípios com padrão espacial baixo-baixo, ou seja, localidades com baixas taxas de internação padronizada por COVID-19 em 2020 e vizinhos com baixa pobreza multidimensional, foram identificados em alguns poucos municípios do estado, a saber, Itajobi no DRS

de São José do Rio Preto; Maracá e Paraguaçu Paulista no DRS de Marília; Santa Rita do Passa Quatro no DRS de Ribeirão Preto e Tietê no DRS de Sorocaba (Figura 21).

Ainda na Figura 21, é possível observar, nos DRS de Sorocaba, Registro Baixada Santista, Grande São Paulo e Taubaté, aglomerados do tipo alto-alto, ou seja, municípios com altas taxas de internação e vizinhos com alta pobreza multidimensional (na cor vermelho-escuro); e baixo-alto nos mesmos DRS (exceto na Grande São Paulo), representados por municípios com baixas taxas de internação e vizinhos com alta pobreza multidimensional (na cor azul-claro), em 2020 (Figura 21).

Figura 21 - Mapa da correlação espacial entre a taxa de internação padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2020.

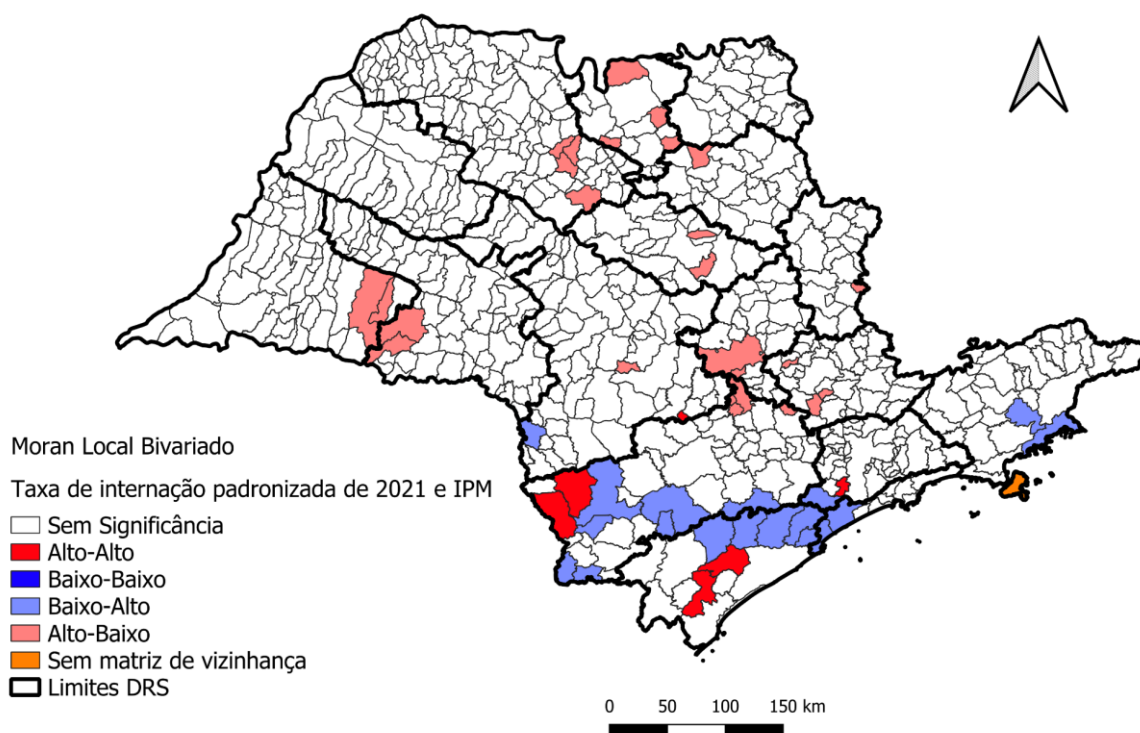


Fonte: Elaborado pelo autor.

Quanto à correlação espacial entre as taxas de internação padronizadas por COVID-19 no ano de 2021 e o Índice de Pobreza Multidimensional (Figura 22), podemos perceber que, ao longo de uma faixa que liga municípios ao sul do DRS da

Baixada Santista, passando por municípios limítrofes entre os DRS da Grande São Paulo, Registro e Sorocaba (incluindo dois municípios ao sul deste DRS), foram identificados alguns aglomerados de municípios com baixas taxas de internação e vizinhos com alta pobreza multidimensional (padrão baixo-alto, na cor azul-claro). Destacam-se, ainda, os municípios de Embu-Guaçu (no DRS da Grande São Paulo), Registro e Jacupiranga (DRS de Registro) e Itararé e Itaberá (DRS de Sorocaba), que apresentaram padrão de alta taxa de internação por COVID-19 em 2021 e vizinhos com alta pobreza multidimensional. No interior do estado, foram identificados, ainda, 26 municípios com padrão do tipo alto-baixo (na cor vermelho-claro), distribuídos em 11 DRS (Figura 22).

Figura 22 - Mapa da correlação espacial entre a taxa de internação padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2021.

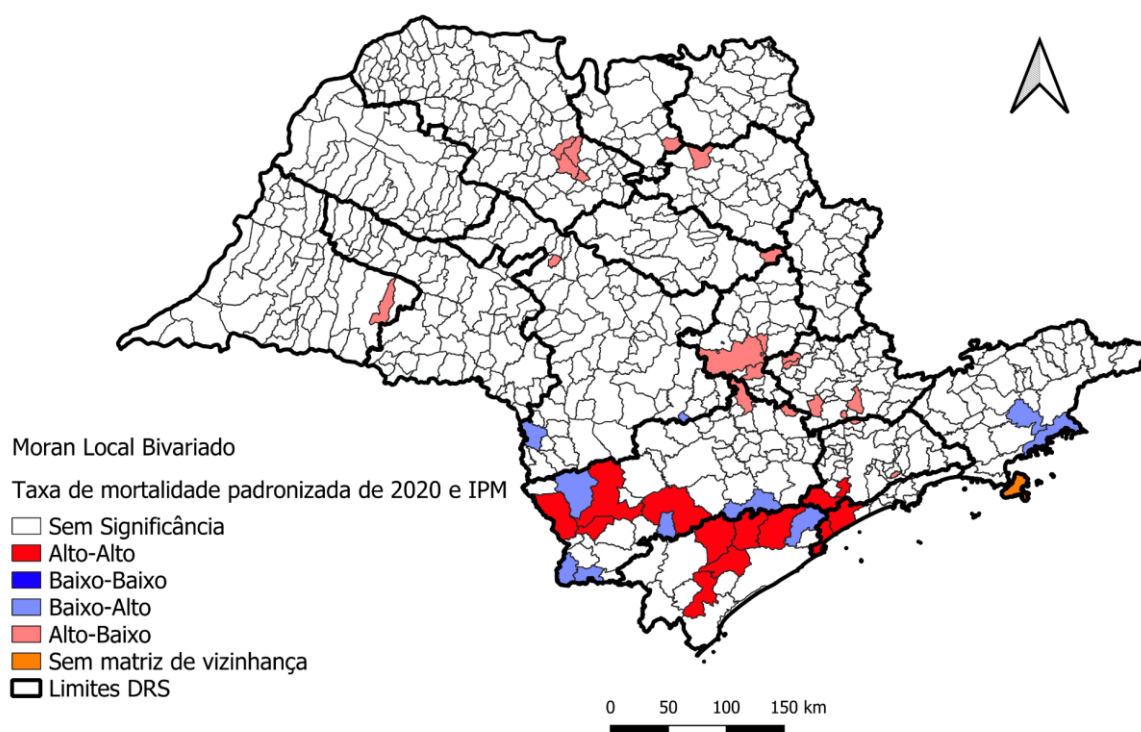


Fonte: Elaborado pelo autor.

Ao analisarmos a correlação espacial entre a mortalidade por COVID-19 em 2020 e o Índice de Pobreza Multidimensional (Figura 23), notamos um padrão

bastante semelhante àquele da correlação espacial entre a taxa de internação e o IPM no mesmo ano, ou seja, aglomerados de municípios com padrão alto-alto (vermelho-escuro) misturados a outros com padrão baixo-alto (em azul-claro) nos DRS da Baixada Santista, Grande São Paulo, Registro e Sorocaba (os dois primeiros apenas com aglomerados de padrão alto-alto). Todavia, há uma predominância maior de municípios classificados como alto-alto em comparação ao ilustrado na Figura 21 (Figura 23).

Figura 23 - Mapa da correlação espacial entre a taxa de mortalidade padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2020.

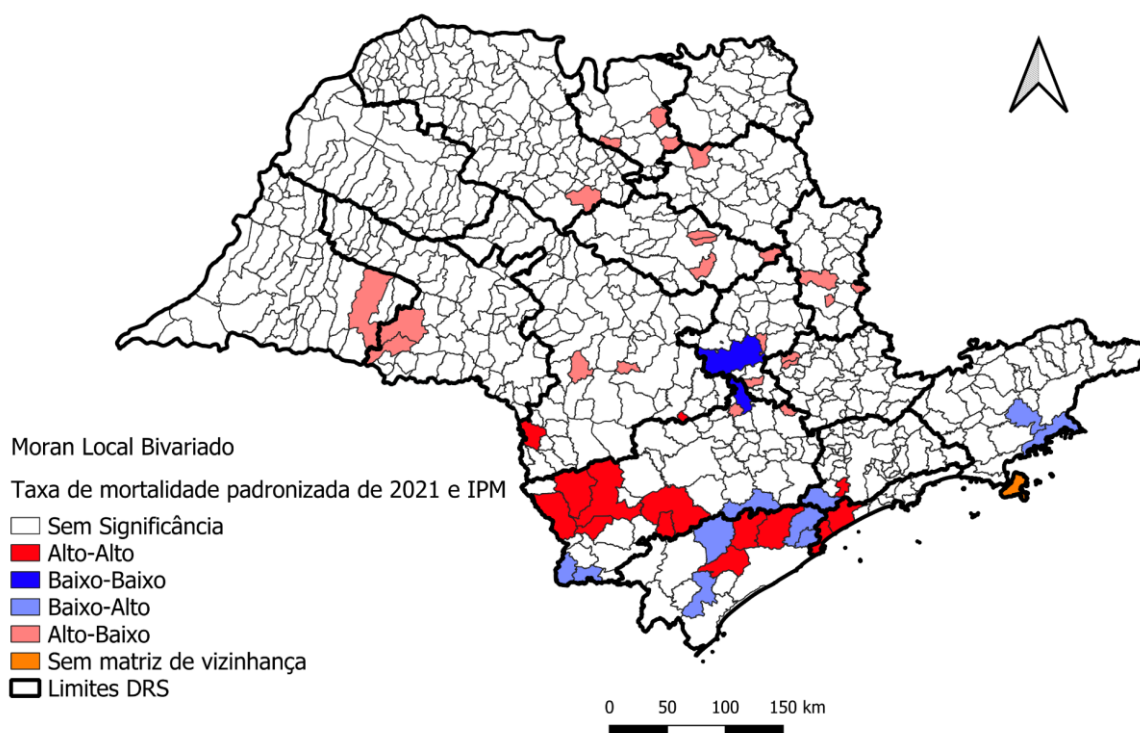


Fonte: Elaborado pelo autor.

Por fim, ao analisarmos a correlação espacial entre a taxa de mortalidade no ano de 2021 e o IPM (Figura 24), mais uma vez identificamos um grande aglomerado de municípios com padrão similar ao descrito anteriormente (Figura 23), nos DRS da Baixada Santista, Grande São Paulo, Registro e Sorocaba. Destacam-se, ainda, os municípios de Piracicaba e Tietê, com padrão de correlação baixo-baixo, localizados

no centro do estado; e 23 municípios espalhados em 11 diferentes DRS do interior do estado com padrão do tipo alto-baixo (Figura 24).

Figura 24 - Mapa da correlação espacial entre a taxa de mortalidade padronizada de COVID-19, por 100 mil habitantes, e o Índice de Pobreza Multidimensional, nos municípios do estado de São Paulo, em 2021.



Fonte: Elaborado pelo autor.

Em síntese, a análise de correlação espacial local bivariada entre as taxas padronizadas de internação e de mortalidade por COVID-19 e o Índice de Pobreza Multidimensional, nos anos de 2020 e 2021, revelou padrões regionalmente diferenciados de associação entre essas variáveis no ESP. Destacam-se os aglomerados identificados nos DRS da Baixada Santista, Grande São Paulo, Registro e Sorocaba, que mesclaram padrões do tipo alto-alto e baixo-alto.

5. DISCUSSÃO

Dentre os resultados encontrados neste trabalho, o perfil sociodemográfico da base de SRAG indica que a proporção de casos de internação e óbitos por COVID-19 foi maior em homens e pessoas idosas, sobretudo aquelas com 75 anos ou mais de idade. Quanto aos dados de escolaridade e raça/cor, a base de dados apresentou muitos registros sem informação a respeito desses quesitos, não sendo possível caracterizar, de maneira sólida, o impacto da pandemia a partir dessas características. Para Maciel, Castro-Silva e Farias (2020), e Bermudi et al. (2021), a idade e o sexo também foram classificados como fatores de risco para a COVID-19; de acordo com esses autores, homens com mais de 70 anos foram mais suscetíveis ao óbito pela doença. Lorenz et al. (2021) também identificam o sexo e a idade como fatores de risco para o óbito por COVID-19. Bermudi et al. (2021) destaca que existem diferenças de comportamento entre homens e mulheres, como a maior propensão a adotar medidas de higienização das mãos e busca por cuidados preventivos, que protegem as mulheres da contaminação. Cabe salientar que a padronização dos indicadores de COVID-19 por sexo e idade aprimorou a capacidade de análise dos dados, sendo que cidades com população mais velha do que a média do estado, como Santos, São Caetano, Serra Negra e Catanduva, por exemplo, apresentaram variações positivas entre os valores das taxas padronizadas e brutas de internação e óbito.

Lima-Costa e Barreto (2003) já chamavam a atenção para a necessidade de estudos epidemiológicos sobre a saúde do idoso, haja vista que esta parcela da população tem crescido cada vez mais e demandado políticas públicas de saúde específicas, o que ficou ainda mais evidente durante a pandemia de COVID-19. Os autores destacam a importância do rigor metodológico para a elaboração de estudos epidemiológicos com enfoque nessa camada da população. Os resultados encontrados neste trabalho corroboram as proposições desses autores, buscando avançar na organização do conhecimento sobre os grupos mais expostos à COVID-19, possibilitando, assim, que os agentes formuladores de políticas de saúde, tanto na esfera pública como na privada, possam compreender melhor esse fenômeno e atuar de maneira mais efetiva nas estratégias de prevenção, em seus vários níveis.

Outro ponto a ser destacado dentre os achados deste estudo é a construção do Índice de Pobreza Multidimensional, que identificou que 44,81% dos municípios do ESP não foram classificados como multidimensionalmente pobres. Observa-se maior

concentração de pobreza em municípios periféricos do ESP, em especial no DRS de Registro e parte dos DRS de Sorocaba e Taubaté. Ao observarmos a autocorrelação espacial do IPM, o centro do estado apresenta agrupamentos de municípios com baixo IPM e com vizinhos também com baixo nível deste indicador, em especial nos DRS de Campinas, Piracicaba, Araraquara, São João da Boa Vista, Ribeirão Preto, Bauru (na parte norte) e São José do Rio Preto, enquanto nos DRS de Taubaté, Registro, Sorocaba, Bauru (na parte sul) e Presidente Prudente encontramos aglomerados de municípios do tipo alto-alto, ou seja, municípios com IPM alto e com vizinhos que também têm IPM alto.

Cabe aqui refletir sobre a situação paulista sob a ótica dos conceitos de cidades inteligentes e da pobreza multidimensional. De acordo com o grupo de trabalho deste tema na Câmara dos Deputados, a melhora na qualidade de vida das pessoas é central para o debate sobre as cidades inteligentes, dessa forma, o padrão de distribuição espacial da pobreza multidimensional requer da sociedade e do poder público a capacidade de discutir sobre as desigualdades regionais paulistas (Câmara dos Deputados, 2021). Nesse aspecto, ainda que em todos os DRS tenham sido identificados municípios em situação de pobreza multidimensional, podemos identificar que em alguns DRS a concentração da pobreza é nitidamente maior.

Diversas publicações (Narayan, 2000; PNUD & OPHI, 2019; Dallabrida, 2020; Câmara dos Deputados, 2021) ressaltam a importância da participação social no processo de solução das questões sociais. Nesse ponto, há grande confluência entre o conceito de cidades inteligentes, pobreza multidimensional e a construção de um IPM, pois a resolução dos problemas sociais perpassa pela escuta e o protagonismo da própria população envolvida naquele determinado contexto.

Assim, a construção de um IPM para a orientação das ações públicas deve considerar, ao longo de seu processo, a participação social. Isso amplia o potencial deste indicador, de modo a contribuir para que as cidades se tornem “mais inteligentes”, pois, na medida em que a população é envolvida na construção do IPM, os fenômenos são mensurados, propostas e soluções são elaboradas, e a reavaliação contínua de todo o processo permite identificar novos desafios, tendo como elemento central deste ciclo a participação social (PNUD & OPHI, 2019; Narayan, 2000).

Ocorre que não dispomos de um IPM formulado a partir da participação popular, e, em decorrência disso, a construção deste índice baseia-se em indicadores de bases oficiais, em maior parte provenientes do Censo Demográfico, identificando-se, aqui,

uma limitação deste processo, ao passo que o Censo é realizado a cada 10 (dez) anos.

Ademais, a Câmara dos Deputados (2021) alia a ideia de uma cidade inteligente à proposta de sustentabilidade integral, isto é, sustentabilidade não apenas ambiental, mas também econômica e política, com inclusão, acessibilidade e mobilidade (p. 88). Os autores afirmam que as cidades devem oferecer aos seus munícipes bem-estar, segurança, mobilidade, urbanidade, sustentabilidade e prosperidade, ou seja, uma cidade inteligente deve considerar a multidimensionalidade dos fenômenos sociais. Nesse aspecto, o IPM se apresenta como uma ferramenta de grande utilidade para que as cidades possam ser compreendidas e avaliadas como “inteligentes”.

Não há aqui a intenção de determinar “o quanto inteligentes” são os municípios paulistas, mas sim, propor a reflexão e pautar a necessidade da inclusão da sociedade no centro do debate de seus problemas. Tendo em vista que o IPM é uma ferramenta de identificação, mensuração e monitoramento dos problemas, a escolha de seus indicadores deve refletir os fenômenos sociais que caracterizam a pobreza em suas múltiplas dimensões, o que pode ser um desafio quando os dados disponíveis para a construção do indicador não refletem, necessariamente, tais fenômenos.

Quanto aos indicadores de COVID-19 tratados neste trabalho, pudemos identificar que as taxas de internação por COVID-19 no ano de 2020 foram maiores nos municípios dos DRS da Grande São Paulo, São José do Rio Preto e Baixada Santista, enquanto que as menores taxas ocorreram nos DRS de Araraquara, Marília e Franca. Já no ano de 2021, as maiores taxas foram observadas nos DRS de São José do Rio Preto, Barretos, Presidente Prudente, Marília e Araçatuba, indicando que, neste ano, a pandemia atingiu de modo mais intenso o interior do estado.

Ao analisarmos as taxas de mortalidade por COVID-19 no ano de 2020, percebemos as maiores taxas nos DRS da Baixada Santista, Grande São Paulo e São José do Rio Preto (os mesmos DRS que tiveram as maiores taxas de internação neste ano), e as mais baixas nos DRS de Marília e Araraquara (de modo similar às taxas de internação). Já no ano de 2021, a mortalidade foi maior nos DRS de Barretos e São José do Rio Preto (assim como as internações neste ano), e menor nos DRS de Taubaté e da Grande São Paulo.

Nesse aspecto, o avanço da pandemia para o interior do estado era esperado. A pandemia chegou ao ESP pela capital paulista, trazida por pessoas que viajaram ao

exterior e tiveram contato com o vírus (Bermudi et al., 2021). A partir dos grandes centros, a doença se disseminou para o restante do estado, em especial facilitada por rodovias principais e pela rede aeroportuária, conforme descrito por Rex, Borges e Kafer (2020) e Palasio et al. (2023).

No que tange à correlação entre os indicadores da pandemia de COVID-19 e o Índice de Pobreza Multidimensional, obtida por meio do coeficiente de correlação de *Spearman*, tivemos como resultado uma associação negativa fraca e significativa entre o IPM e as taxas de internação e de mortalidade em ambos os anos analisados.

Na correlação verificada para cada DRS, considerando apenas os municípios de cada departamento, os resultados estatisticamente significativos apresentaram associação negativa, que variou entre fraca (-0,24 para a taxa de internação no DRS de São José do Rio Preto no ano de 2020) e forte (-0,75 para a taxa de internação no DRS de Registro em 2020), ou seja, quanto maior a pobreza multidimensional, menores as taxas de internação por COVID-19.

Neste aspecto, deve-se observar que a análise a nível estadual, considerando os indicadores municipais, não captura as desigualdades e dinâmicas socioeconômicas intramunicipais. A título de exemplo, o caso da cidade de São Paulo, cujo IPM calculado foi de 0,223, relativamente baixo na comparação com os demais municípios paulistas. Todavia, isso não significa que o distrito Pinheiros ou Moema são multidimensionalmente pobres. Tão pouco isso quer dizer a pobreza multidimensional no distrito de São Miguel Paulista é da ordem de 0,223, pois as enormes desigualdades notoriamente conhecidas da cidade de São Paulo não são percebidas na escala de análise deste trabalho. Assim, os resultados obtidos pela correlação de *spearman*, devem ser lidos com esta ressalva, pois como observado na literatura em análise intramunicipal é possível identificar uma relação positiva entre piores condições socioeconômicas e indicadores de COVID-19, não identificados neste trabalho, podendo a escala de análise ser uma de suas explicações.

Por outro lado, os estudos de Polo et al. (2022) e Henao-Cespedes (2022) encontraram uma associação positiva entre a COVID-19 e o IPM em regiões da Colômbia. Henao-Cespedes (2022) identificou que as regiões mais pobres apresentavam maior densidade de casos confirmados por COVID-19 na cidade de Manizales, enquanto Polo et al. (2022) buscaram compreender a associação entre a COVID-19 e cada uma das dimensões do IPM da Colômbia, identificando que as dimensões de condições habitacionais e de acesso a serviços públicos, infância e

juventude, educação e saúde apresentam associação positiva com os indicadores de COVID-19, enquanto que a dimensão de trabalho não esteve associada à pandemia. Cabe ressaltar que a Colômbia dispõe de um IPM oficial (Colômbia, 2020), assim, ambos os autores usaram o índice oficial, que estava atualizado para o ano de 2019.

Esse padrão de associação também foi observado nos resultados da análise de correlação espacial bivariada entre os indicadores de COVID-19 e o IPM do presente estudo em algumas regiões do ESP. Pudemos perceber aglomerados do tipo alto-alto e baixo-alto, isto é, municípios com altas taxas de internação e mortalidade e municípios vizinhos com IPM alto, e municípios com baixas taxas de internação e mortalidade e vizinhos com alta pobreza multidimensional em uma faixa que abrange municípios dos DRS da Baixada Santista, Grande São Paulo, Registro e Sorocaba. Ao analisarmos este aglomerado específico, observamos que as taxas de mortalidade apresentaram predominância do padrão alto-alto, enquanto as taxas de internação apresentaram mais municípios com padrão baixo-alto.

Nesse sentido, cabe destacar que a análise espacial contribui para este diagnóstico justamente por considerar a dependência espacial dos fenômenos, o que não é levado em conta na análise de correlação simples, realizada neste trabalho por meio do coeficiente correlação de Spearman. Assim, identificar esta dependência espacial é mais um passo no sentido de compreender a relação entre a pobreza multidimensional e a pandemia de COVID-19, considerando a diversidade territorial do estado de São Paulo.

Ferreira (2020), Bermudi et al. (2021), Lorenz et al. (2021), e Sanhueza-Sanzana et al. (2021) realizaram estudos em nível municipal, buscando identificar e compreender a relação entre indicadores socioeconômicos e a pandemia de COVID-19. Ferreira (2020), Bermudi et al. (2021) e Lorenz et al. (2021) tiveram como área de estudo o município de São Paulo. Ferreira (2020) identificou uma correlação espacial entre a incidência de COVID-19 e alto percentual de domicílios em favelas e salários baixos, tendo como unidades de análise os distritos da cidade. Bermudi et al. (2021), por sua vez, tendo trabalhado com óbitos suspeitos e confirmados de COVID-19, usaram o GeoSES como indicador socioeconômico, e observaram que quanto melhor o indicador socioeconômico, menor o risco de óbito por COVID-19. Já Lorenz et al. (2021) verificaram uma associação negativa entre a renda *per capita* e a taxa de mortalidade de casos hospitalizados.

Em nosso estudo, diferentemente dos autores supracitados, encontramos uma correlação negativa fraca entre o IPM e os indicadores de internação e óbito por COVID-19. Cabe destacar que nosso estudo definiu os municípios do estado de São Paulo como unidades de análise, sem considerar, portanto, a heterogeneidade presente internamente nestes municípios. Outra possível explicação para este achado é o fato de que regiões mais pobres tendem a ter uma política de testagem menos efetiva, registrando um maior número de casos de SRAG por agente etiológico não especificado, de modo que a notificação de casos de internação e morte por COVID-19 acaba por não refletir bem a realidade, devido à subnotificação. Já as áreas mais ricas tendem a ter mais testes para a identificação da causa de SRAG, com menos casos de SRAG sem agente etiológico especificado, como descrito por Souza et al. (2020).

Ademais, existe a possibilidade de que uma parcela dos casos tenha sido atraída para os grandes polos para realizar o seu tratamento, nem sempre declarando seus endereços de residência corretamente. O estudo de Palasio et al. (2023), que versa sobre o fluxo de origem e destino de pacientes internados com SRAG por COVID-19 no estado de São Paulo, identificou que 24% dos casos residentes no estado foram internados em municípios diferentes daqueles em que residiam.

Figueiredo et al. (2020) e Tavares e Betti (2021) tiveram como área de estudo as unidades federativas brasileiras. Figueiredo et al. (2020) notaram que estados com maior desigualdade na distribuição de renda, maior proporção de pessoas morando em domicílios adensados e maior taxa de desocupação também apresentavam maiores índices de transmissão do vírus da COVID-19. Já Tavares e Betti (2021) construíram dois IPMs - um para observar a prevenção à COVID-19, e outro para observar a recuperação da COVID-19 - nos estados brasileiros. Os autores puderam concluir que inicialmente havia uma associação negativa entre indicadores de vulnerabilidade e mortes por COVID-19, entretanto, o autor percebeu que, após a décima quarta semana epidemiológica de 2020, estados com maior vulnerabilidade apresentavam maiores taxas de mortalidade por COVID-19, com uma associação mais forte para o IPM de recuperação do que o de prevenção.

Assim, percebemos que, nos trabalhos cuja área de estudo foi definida no nível municipal, foi possível capturar de modo mais preciso a relação entre os indicadores socioeconômicos e a pandemia de COVID-19, considerando que, em nosso trabalho, a associação evidenciada na literatura não pôde ser identificada do ponto de vista

estatístico. Contudo, na análise de correlação espacial bivariada entre a taxa de mortalidade por COVID-19 no anos de 2020 e 2021 e o IPM, demonstrou-se a formação de aglomerados de municípios com altas taxas de mortalidade e vizinhos com alta pobreza multidimensional em uma parte considerável dos DRS de Registro e Sorocaba, corroborando o descrito na literatura sobre o deslocamento dos casos a partir dos grandes centros urbanos ricos para as áreas mais periféricas (Ferreira, 2020; Bermudi et al., 2021; Tavares e Betti, 2021).

Cabe ressaltar, ainda, que, conforme observado no presente estudo, as internações e os óbitos por COVID-19 atingiram de maneira mais intensa os municípios do interior do estado no ano de 2021, em comparação ao ano de 2020.

Essa mudança de padrão de aglomerados entre os anos de 2020 e 2021 também é descrita por Bermudi et al. (2021) no município de São Paulo, e por Tavares e Betti (2021) nos estados brasileiros, que, ao analisarem a relação entre os dados de COVID-19 e indicadores socioeconômicos ao longo das semanas epidemiológicas, identificaram que a doença atingiu inicialmente a camada menos vulnerável socioeconomicamente, mas, no decorrer do tempo, passou a ter maior impacto na camada mais pobre da população.

Algumas hipóteses podem ser levantadas a partir dessa discussão. Este trabalho buscou tratar os dados de COVID-19 de maneira anualizada, o que pode, em certa medida, não ter permitido identificar variações mais precisas dos indicadores ao longo do período de estudo, de modo que não foi possível analisar como se deu a relação entre os indicadores de COVID-19 e o IPM em momentos de pico da pandemia. Soma-se a isso o fato de que grandes centros urbanos tendem a ter taxas de transmissão mais altas, em decorrência da aglomeração de pessoas e da maior dificuldade de se observarem as medidas preventivas, como o distanciamento social, enquanto que os municípios do interior, menos adensados e com maior área rural, podem ter sido menos impactados. Ou seja, a dinâmica social do território em grandes centros urbanos adensados e das cidades com grandes áreas rurais e baixa densidade populacional pode ter determinado, em parte, os resultados ora encontrados.

Ademais, tal como observado por Rex, Borges e Kafer (2020), a dispersão da pandemia se deu a partir da Região Metropolitana de São Paulo, classificada como um “*hotspot*” pelos autores, que destacaram, ainda, as rodovias e os aeroportos como fatores chaves para a disseminação da COVID-19 no estado de São Paulo. Esta

análise corrobora o identificado neste trabalho, pois os autores apontam que o centro do ESP, por dispor de maior número de rodovias e aeroportos, foram locais relevantes para a propagação da pandemia.

Nota-se que este trabalho conseguiu trazer à luz análises exploratórias relevantes para a sistematização do conhecimento sobre a relação entre indicadores socioeconômicos e a pandemia de COVID-19, encontrando pontos de convergência e debate na literatura da área.

No entanto, é importante destacar algumas limitações do presente estudo, como o uso de dados do Censo Demográfico de 2010 do IBGE para a construção do IPM. Devido ao tempo transcorrido, esses dados podem estar defasados e não refletir as condições socioeconômicas atuais dos municípios paulistas. Ademais, algumas variáveis consideradas para construção do IPM referem-se a levantamentos mais recentes do que o Censo de 2010; dessa forma, a construção do índice se deu a partir de variáveis com anos de referência diferentes.

Além disso, é necessário enfatizar as limitações inerentes a um estudo de delineamento ecológico, uma vez que as associações identificadas no nível agregado de análise deste trabalho não necessariamente se reproduzem em outras escalas de análise. Em outras palavras, os achados deste estudo para um determinado município podem não ser encontrados, na mesma medida, em toda a sua extensão, dado que o fenômeno identificado no nível municipal pode apresentar padrões heterogêneos em níveis intramunicipais, conforme observado por vários autores.

6. CONCLUSÃO E CONSIDERAÇÕES FINAIS

A realização deste trabalho pôde contribuir para a sistematização do conhecimento sobre a relação entre indicadores sociais e a pandemia de COVID-19. A espacialização de um Índice de Pobreza Multidimensional construído para os municípios do estado de São Paulo permitiu identificar os municípios mais vulneráveis, especialmente em regiões periféricas do estado. Além disso, a caracterização espacial das taxas de internação e de mortalidade por COVID-19, nos anos de 2020 e 2021, possibilitou a compreensão das dinâmicas específicas desses fenômenos.

As associações espaciais identificadas também ajudam a compreender o impacto da pobreza na pandemia em nível regional, o que, embora já tenha sido parcialmente explicado pela literatura precedente, suscitou novas discussões e hipóteses. Nesse aspecto, o estudo lançou luz sobre a dependência espacial da pandemia, sobretudo por ter sido o primeiro a apresentar esta análise no âmbito do estado de São Paulo. Além disso, tais achados convidam novos estudos a explorar as dinâmicas regionais do planejamento urbano, pensando o território para além dos limites administrativos dos municípios.

A pobreza, um fenômeno multidimensional que é o foco do primeiro dos ODS da ONU, é central na discussão sobre como construir “cidades inteligentes”. Nesse sentido, o uso do IPM para a análise socioeconômica dos municípios contribui para a construção e consolidação dessa área do conhecimento. Outrossim, considerar o IPM como um Determinante Social de Saúde para epidemias - neste caso, a COVID-19 - é um avanço que auxilia na compreensão do processo saúde-doença, bem como de suas implicações decorrentes. Da mesma forma, a representação espacial dos indicadores de COVID-19 nos municípios do ESP é um avanço para compreendermos a extensão do impacto e dos efeitos da pandemia, que ainda hoje nos assola.

Outrossim, a elaboração de um IPM que possa fornecer informações sobre a pobreza no ESP, bem como a caracterização espacial desta pobreza, permite que a sociedade e o governo desenvolvam soluções para mitigar as diversas privações enfrentadas pela população. Nesse sentido, a compreensão da autocorrelação espacial dos indicadores de COVID-19, juntamente com a associação espacial desses indicadores com o IPM, também permite verificar o comportamento dessa epidemia nas diferentes regiões do território paulista. Esses novos conhecimentos podem servir como base para a elaboração de estratégias que propiciem uma resposta mais rápida

diante de novas ocorrências dessa natureza, além de orientar a formulação de planos e políticas públicas voltados para a prevenção e mitigação de seus impactos e efeitos.

Como sugestões para estudos futuros, ressaltamos que o Índice de Pobreza Multidimensional pode ser empregado na análise de sua relação com outros agravos que envolvam doenças com potencial pandêmico, bem como pode ser aplicado em outras escalas de análise. Ademais, em estudos posteriores poderá ser explorada a ponderação dos indicadores e dimensões que compõem o IPM a partir de métricas estatísticas como a própria ACP, ou uma análise de sensibilidade. Outrossim, é oportuno considerar a desigualdade e não a pobreza multidimensional, ou seja, não aplicar uma linha de corte que separe os municípios pobres dos não pobres, mas sim, considerar na plenitude suas privações e identificar o quanto estes indicadores afetam todos os municípios do Estado.

Quanto à possibilidade de novos estudos destes dois fenômenos, realizar uma análise espacial que considere os fluxos de materiais e pessoas pelo estado, sobretudo através da malha rodoviária e aeroportuária estadual, pode identificar diferentes relações das percebidas neste estudo, que optou por realizar a análise a partir da matriz de vizinhança.

7. REFERÊNCIAS

Alkire, S., & Foster, J. (2009). Counting and multidimensional poverty measurement. Oxford Poverty & Human Development Initiative, University of Oxford, Working Paper, n. 32. Recuperado de: <https://www.ophi.org.uk/wp-content/uploads/OPHI-wp32.pdf>

Alkire, S., & Foster, J. (2011). Counting and multidimensional poverty measurement. *Journal of Public Economics*, 95, 476-487.

Alkire, S., & Kanagaratnam, U. (2021). Revisions of the global multidimensional poverty index: indicator options and their empirical assessment. *Oxford Development Studies*, <https://doi.org/10.1080/13600818.2020.1854209>

Alkire, S., & Santos, E. M. (2013). Measuring Acute Poverty in the Developing World: Robustness and Scope of the Multidimensional Poverty Index. Oxford Poverty & Human Development Initiative, University of Oxford, Working Paper, n. 59. Recuperado de: <https://www.ophi.org.uk/wp-content/uploads/ophi-wp-591.pdf>

Alkire, S., & Santos, E. M. (2014). Measuring Acute Poverty in the Developing World: Robustness and Scope of the Multidimensional Poverty Index. *World Development*, Volume 59, 251-274.

Almeida, Eduardo. (2012). *Econometria espacial aplicada*. Campinas: Editora Alínea.

Anand, S., Sen, A. (1997). *Concepts of human Development and poverty: a multidimensional perspective*. New York: United Nations Development Programme.

Atkinson, A. B. (2003). Multidimensional deprivation: contrasting social welfare and counting approaches. *Journal of Economic Inequality*, 1, 51-65.

Banco Mundial (2018). *Poverty and shared prosperity. Piecing together the poverty puzzle*. Washington: The World Bank

Banco Mundial (2020). *Poverty and shared prosperity. Reversals of fortune*. Washington: The World Bank

Banco Mundial (2022). *Poverty and shared prosperity. Correcting course*. Washington: The World Bank

Barrozo, L. V., Fornaciali, M., de André, C. D. S., Morais, G. A. Z., Mansur, G., Cabral-Miranda, W., ... & Amaro Júnior, E. (2020). GeoSES: A socioeconomic index for health and social research in Brazil. *PloS one*, 15(4), e0232074. <https://doi.org/10.1371/journal.pone.0232074>

Bermudi, P. M. M., Lorenzo, C., de Aguiar, B. S., Faila, M. A., Barrozo, L. V., Chiavaralotti-Neto, F. (2021). Spatiotemporal ecological study of COVID-19 mortality in the city of Sao Paulo, Brazil: Shifting of the high mortality risk from areas with the best to those with the worst socio-economic conditions. *Travel Medicine and Infectious Disease*, 39, 101945. <https://doi.org/10.1016/j.tmaid.2020.101945>

Beyrer, C., Sullivan, P., Sanchez, J., Baral, S. D., Collins, C., Wirtz, A. L., Altman, D., Trapence, G., & Mayer, K. (2013). The increase in global HIV epidemics in MSM. *AIDS*, 27, p. 2665-2678. DOI:10.1097/01.aids.0000432449.30239.fe

Buss, P. M., & Filho, A. P. (2007). A saúde e seus determinantes sociais. *Physis: Revista de Saúde Coletiva*. Rio de Janeiro, v. 17, n. 1. p 77-93. <https://doi.org/10.1590/S0103-73312007000100006>

Cadima, J., & Jolliffe, I. T. (2021). Principal component analysis: a review and recent developments. *Phil. Trans. R. Soc. A* 374: 20150202. <http://dx.doi.org/10.1098/rsta.2015.0202>

Câmara dos Deputados (2021). Cidades Inteligentes. Uma abordagem humana e sustentável. 1 ed. Brasília-DF: Câmara dos deputados. Recuperado a partir de https://www2.camara.leg.br/a-camara/estruturaadm/altosestudios/pdf/cidades_inteligentes.pdf

Castro, M. C. de, & Singer, B. H. (2006). Controlling the False Discovery Rate: A New Application to Account for Multiple and Dependent Tests in Local Statistics of Spatial Association. *Geographical Analysis*, 38, pp. 180-208.

Chile (2015). Informe de desarrollo social. Recuperado em http://www.desarrollosocialyfamilia.gob.cl/pdf/upload/IDS_INAL_FCM_3.pdf

Colômbia (2020). Boletín Técnico. Medida de pobreza multidimensional municipal. Recuperado em https://img.lalr.co/cms/2021/09/03041930/boletin_tec_pobreza_multidimensional_20.pdf

Conselho Nacional de Saúde. Resolução nº 466, de 12 de dezembro de 2012. Recuperado de <https://conselho.saude.gov.br/resolucoes/2012/Reso466.pdf>

Constituição da República Federativa do Brasil de 1988 (1988, 5 de outubro). Brasília. Recuperado a partir de http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm

Costa Rica (2015). Índice de pobreza multidimensional (IPM). Resultados generales. Recuperado em https://www.inec.cr/sites/default/files/documentos/pobreza_y_presupuesto_de_hogares/pobreza/publicaciones/copublicipm-29102015.pdf

Crespo, A. P. A., & Gurovitz, E. (jul./dez. 2002). A pobreza como um fenômeno multidimensional. *Revista de Administração de Empresas*, v. 01, n. 2, p.1-12.

Cruz, M.M. (2011). Concepção de saúde-doença e o cuidado em saúde. In Oliveira, R. G., & Júnior, W. V. M. (Orgs.), *Qualificação dos gestores SUS* (pp. 404). Rio de Janeiro, RJ: EAD/Ensp.

Dallabrida, V. R. (out/dez 2020). Da cidade inteligente, ao território inovador, rumo à inteligência territorial. *Desenvolvimento em questão*. Ano 18. n. 53. p 46-71. doi: <http://dx.doi.org/10.21527/2237-6453.2020.53.46-71>

Datasus (2022). SRAG 2021 a 2023 - Banco de Dados de Síndrome Respiratória Aguda Grave - incluindo dados da COVID-19. Recuperado em: <https://opendatasus.saude.gov.br/dataset/srag-2021-a-2023>

Davies, S. E., & Bennet, B. (2016). A gendered human rights analysis of Ebola and Zika: locating gender in global health emergencies. *International affairs*, 92, 5, 1041-1060.

Decreto n.º 10.852 de 8 de novembro de 2021. Regulamenta o Programa Auxílio Brasil, instituído pela Medida Provisória nº 1.061, de 9 de agosto de 2021. *Diário Oficial da União*. Brasília-DF.

Decreto n.º 11.013 de 29 de março de 2022. Altera o Decreto nº 10.852, de 8 de novembro de 2021, que regulamenta o Programa Auxílio Brasil.. *Diário Oficial da União*. Brasília-DF.

Equador (2015). Índice de pobreza multidimensional. Recuperado em https://www.ecuadorencifras.gob.ec/documentos/web-inec/Sitios/Pobreza_Multidimensional/assets/infografia.pdf

Ferreira, M.C., (2020). Spatial Association Between the Incidence Rate of COVID-19 and Poverty in the São Paulo Municipality, Brazil. *Geospatial Health* 15 (2). <https://doi.org/10.4081/gh.2020.921>.

Figueiredo, A. M., Figueiredo, D. C. M. M., Gomes, L. B., Massuda, A., Gil-Garcia, E., Viana, R. P. de T., & Daponte, A. (2020). Determinantes sociais da saúde e infecção por COVID-19 no Brasil: uma análise da epidemia. *Revista Brasileira de Enfermagem*, 73 (Suppl 2), e20200673, 1-7.

Hagenaars, A., & Vos, K. (1988). The definition and measurement of poverty. *Journal of Human Resources* .Vol. 23, n. 2, p211-221

Henao-Céspedes, V., Garcés-Gómez, A., Ruggeri, S., & Henao-Céspedes, T. M. (2022). The Egyptian Journal of Remote Sensing and Space Sciences, 25. <https://doi.org/10.1016/j.ejrs.2021.04.002>

Honduras (2016). Evolución. Índice de pobreza multidimensional - Honduras 2012-2016. Recuperado em <http://ipm.scgg.gob.hn/index.php/2019/07/31/evolucion-ipm-honduras-2012-2016/>

IBGE - Instituto Brasileiro de Geografia e Estatística (2021). Geociências: Malhas Municipais. Recuperado de http://downloads.ibge.gov.br/downloads_geociencias.htm

IBGE - Instituto Brasileiro de Geografia e Estatística (2022). IBGE Cidades. Brasília-DF. Recuperado em: <https://cidades.ibge.gov.br/>

Kageyama, A., & Hoffmann, R. (2016). Pobreza no Brasil: uma perspectiva multidimensional. *Economia E Sociedade*, 15(1), 79–112. Recuperado de <https://periodicos.sbu.unicamp.br/ojs/index.php/ecos/article/view/8642922>

Laprega & Fabbro, (2022). Coeficientes e índices mais usados em Epidemiologia. In Franco, L. J., Passos, A. D. C. (Orgs). *Fundamentos de epidemiologia*. 3a ed. Santana do Parnaíba - SP: Manole

Lei n.º 8.742 de 7 de dezembro de 1993 (1993, 8 de dezembro). Lei Orgânica da Assistência Social. Recuperado a partir de http://www.planalto.gov.br/ccivil_03/leis/18742.htm

Lei n.º 13.709 de 14 de agosto de 2018 (2018, 15 de agosto). Lei Geral de Proteção de Dados. Recuperado a partir de http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/l13709.htm

Lei n.º 13.853 de 8 de julho de 2019 (2019, 9 de julho). Altera a Lei nº 13.709, de 14 de agosto de 2018, para dispor sobre a proteção de dados pessoais e para criar a Autoridade Nacional de Proteção de Dados; e dá outras providências. Recuperado a partir de http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2019/lei/l13853.htm

Lima, I. B., Nogueira, L. M. V., Trindade, L. de N. M., Rodrigues, I. L. A., Andre, S. R., & Souza, A. I. (2023). Geoespacialização da tuberculose e os programas de transferência de renda entre indígenas em território endêmico. *Revista brasileira de Enfermagem*, 76 (Supl 2), e20220216, 1-7. <https://doi.org/10.1590/0034-7167-2022-0216pt>

Lima-Costa, M. F., & Barreto, S. M. (2003). Tipos de estudos epidemiológicos: conceitos básicos e aplicações na área do envelhecimento. *Epidemiologia e Serviços de Saúde*, 12(4), 189-201. <https://dx.doi.org/10.5123/S1679-49742003000400003>

Lonnoroth, K, Jaramillo, E., Willians, B. G., Dye, C., & Raviglione, M. (2009). Drivers of tuberculosis epidemics: The role of risk factors and social determinants. *Social Science & Medicine*, 668, 2240-2246. doi:10.1016/j.socscimed.2009.03.041

Lorenz, C., Bermudi, P. M. M., faila, M. A., de Aguiar, B. S., Torpocov, T. N., Chiavaraloti-Neto, F., & Barrozo, L. V. (2021). Examining socioeconomic factors to understand the hospital case-fatality rates of COVID-19 in the city of São Paulo, Brazil. *Transactions of the Royal Society Tropical Medicine and Hygiene*; 115(11): 1282-1287. DOI: 10.1093/trstmh/trab144

Luzardo, J. A. R., Castañeda Filho, R. M., Rubim, I. B. (2017) Análise exploratória com o emprego do Índice de Moran. *GEOgraphia*; 19(40): 161-79. <https://doi.org/10.22409/GEOgraphia2017.v19i40.a13807>

Maciel, J. A. C., Castro-Silva, I. I., & Farias, M. R. (2020). 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* [online], v. 23 doi: <https://doi.org/10.1590/1980-549720200057>

México (2009). Metodología para la medición multidimensional de la pobreza en México. Recuperado em <https://www.coneval.org.mx/Medicion/MP/Paginas/Metodologia.aspx>

Ministério da Saúde (2021). 44 Boletim epidemiológico especial. Doença pelo coronavírus COVID-19. Recuperado a partir de <https://www.gov.br/saude/pt-br/coronavirus/boletins-epidemiologicos/boletim-epidemiologico-covid-19-no-44.pdf/view>

Ministério da Saúde (2022). Guia de Vigilância Epidemiológica. Emergência de saúde pública de importância nacional pela doença pelo coronavírus 2019. Versão 4. Brasília-DF. Recuperado a partir de <https://www.gov.br/saude/pt-br/coronavirus/publicacoes-tecnicas/guias-e-planos/guia-de-vigilancia-epidemiologica-covid-19/view>

Ministério da Saúde (2023). 146 Boletim epidemiológico especial. Doença pelo coronavírus COVID-19. Recuperado a partir de <https://www.gov.br/saude/pt-br/centrais-de-conteudo/publicacoes/boletins/epidemiologicos/covid-19/2022/boletim-epidemiologico-no-146-boletim-coe-coronavirus/view>

Morozov, E. & Bria, F. (2019). A cidade inteligente – Tecnologias urbanas e democracia. São Paulo: Ubu Editora.

Narayan, D; Patel, R; Schafft, K; Rademacher, A.; Koch-Schulte, S. (2000). Voices of the poor : can anyone hear us? (English). Washington, D.C. : World Bank Group. <http://documents.worldbank.org/curated/en/131441468779067441/Voices-of-the-poor-can-anyone-hear-us>

Oliveira, E. A, Oliveira M. C. L., Martelli, D. B., Colosimo, E. A., Silva, L. R., Lanza, K., ... Silva, A.C.S. (2021). COVID-19 pandemic and the answer of science: a year in review. An Acad Bras Cienc 93: e20210543. DOI 10.1590/0001-3765202120210543.

OMS, Organização Mundial da Saúde (1946). Constituição da Organização Mundial da Saúde (OMS/WHO). Recuperado a partir de <http://www.nepp-dh.ufrj.br/oms2.html>

OMS, Organização Mundial da Saúde (2009). Regulamento Sanitário Internacional. RSI-2005. ANVISA (trad). Brasília-DF. Recuperado a partir de <https://www.gov.br/anvisa/pt-br/assuntos/paf/regulamento-sanitario-internacional/arquivos/7181json-file-1>

ONU, Organização das Nações Unidas (2001). Nações Unidas declaração do milênio. Recuperado em: <https://www.oas.org/dil/port/2000%20Declara%C3%A7%C3%A3o%20do%20Milenio.pdf>

ONU, Organização das Nações Unidas (2016). Transformando nosso mundo: a agenda 2030 para desenvolvimento sustentável. Recuperado em: https://www.mds.gov.br/webarquivos/publicacao/Brasil_Amigo_Pesso_Idosa/Agenda2030.pdf

OPAS, Organização Pan-Americana da Saúde (2020a). OMS afirma que COVID-19 é agora caracterizada como pandemia. Recuperado de <https://www.paho.org/pt/news/11-3-2020-who-characterizes-covid-19-pandemic>

OPAS, Organização Pan-Americana da Saúde (2020b). OMS declara emergência de saúde pública de importância internacional por surto de novo coronavírus. Recuperado de <https://www.paho.org/pt/news/30-1-2020-who-declares-public-health-emergency-novel-coronavirus>

Palasio, R. G. S., Lorenz, C., Lucas, P. C. de C., Nielsen, L., Massuda, E. T., Trevisan, C. M., Cortez, A. L., Monteiro, P. de C. M., Simões, C. S., Ferreira, P. M., Pellini, A. C. G., Yu, A. L. F., & Carvalhanas, T. R. M. (2023). Spatial, spatio-temporal, and origin-destination flow analyses of patients with severe acute respiratory syndrome hospitalized for COVID-19 in Southeastern Brazil, 2020-2021. *Revista do Instituto de Medicina Tropical de São Paulo*. 65, e6, p. 1-14. <http://doi.org/10.1590/S1678-9946202365006>

Panamá (2018). Índice de pobreza multidimensional de Panamá. Año 2018. Recuperado em <https://www.gabinetesocial.gob.pa/wp-content/uploads/2019/12/MED-DAES-Informe-del-%C3%8Dndice-de-Pobreza-Multidimensional-de-Panam%C3%A1-2018.pdf>

Paraguai (2021). Boletín Técnico. Índice de pobreza multidimensional (IPM) Paraguay. Recuperado em https://www.ine.gov.py/Publicaciones/Biblioteca/documento/8e39_BOLETIN_TECNICO_IPM_2020.pdf

Polo, G.; Soler-Tovar, D.; Jimenez, L. C. V.; Benavides-Ortiz, E.; & Acosta, C. M. (2022). Bayesian spatial modeling of COVID-19 case-fatality rate inequalities. *Spatial and Spatio-temporal Epidemiology*, 41. <https://doi.org/10.1016/j.sste.2022.100494>

Portaria n.º 188/2020 de 3 de fevereiro de 2020. Diário Oficial da União, Edição 24-A, Seção I, p. 1. Declara Emergência em Saúde Pública de importância Nacional (ESPIN) em decorrência da Infecção Humana pelo novo Coronavírus (2019-nCoV). Brasília-DF.

Queiroz, B.L, Freire, F. H. M. A., Lima, E.E.C., & Gonzaga, M. R. (junho 2020). O papel da estrutura etária na análise da mortalidade por Covid-19. *Cien Saude Colet*. V. 25, n. 9. doi: <https://doi.org/10.1590/1413-81232020259.19682020>

República Dominicana (2017). IPM-RD. Índice de pobreza multidimensional de la República Dominicana. Recuperado em https://www.mppn.org/wp-content/uploads/2016/11/10.-DOMINICAN_REPUBLIC.pdf

Rex, F. E., Borges, C. A. S., & Kafer, P. S. (September 2020). Spatial analysis of the COVID-19 distribution pattern in São Paulo State, Brazil. *Ciência & Saúde Coletiva*. V. 25, n. 9, pp 3377-3384. doi: 10.1590/1413-81232020259.17082020.

Ribeiro, J. M. L., Gonçalves, M. E., Rodrigues, L., Santos, M. I. P. (2018). Gastos per capita com educação e desenvolvimento humano: uma análise espacial do estado de

minas gerais. VI Congresso em Desenvolvimento Social. Recuperado em: https://congressods.com.br/sexto/anais_sexto/ARTIGOS_GT07/GASTOS%20PER%20CAPITA%20COM%20EDUCACAO%20E%20DESENVOLVIMENTO%20HUMAN%20UMA%20ANALISE%20ESPACIAL%20DO%20ESTADO%20DE%20MINAS%20GERAIS.pdf

Rouquayrol, M. Z. (2018). *Epidemiologia e Saúde*. 8 ed. Rio de Janeiro: Medbook.

Sanhueza-Sanzana, C. Aguiar, I. W. O., Almeida, R. L. F., Kendal, C., Mendes, A. & Kerr, L. R. F. S. (2021). Desigualdades sociais associadas com a letalidade por COVID-19 na cidade de Fortaleza, Ceará, 2020. *Epidemiol. Serv. Saude, Brasília*, 30(3):e2020743, 1-12. doi: 10.1590/S1679-49742021000300022

Santos, S. M., & Souza, W. V. (Orgs) (2007). *Introdução à Estatística Espacial para a Saúde Pública*. Brasília : Ministério da Saúde. pp.120.

Santos-Neto, M., Yamamura, M., Popolin, M. P., Queiroz, A. A. R. de, Arroyo, L. H., Crispim, J. de A., ... Arcencio, R. A. (2016). The impact of social inequities on mortality due to pulmonary Tuberculosis in São Luis, Maranhão, Brazil. *International Archives of Medicine*. Vol. 9 No. 219. doi: 10.3823/2090

São Paulo (Estado). Plano São Paulo. 2020. Recuperado em: <https://www.saopaulo.sp.gov.br/planosp/>.

Seabra, I. L., Pedroso, A. O., Rodrigues, T. B., Ferreira, G. R. O. N., Ferreira, A. L. da S., Arcêncio, R. A., ... & Botelho, E. P. (2022) Temporal trend and spatial analysis of the HIV epidemic in young men who have sex with men in the second largest Brazilian Amazonian province. *BMC Infectious Diseases*, 22:190, 1-12. <https://doi.org/10.1186/s12879-022-07177-w>

Sen, A. (2010). *Desenvolvimento como liberdade*. 8ª reimpressão. São Paulo: Companhia das letras.

Silva, G. A., Jardim, B. C., & Lotufo, P. A. (2021) Mortalidade por COVID-19 padronizada por idade nas capitais das diferentes regiões do Brasil. *Cad. Saúde Pública* 2021; 37(6):e00039221. doi: 10.1590/0102-311X00039221

Souza, M. P. A., da natividade, M. S., Werneck, G. L., & dos Santos, D. N. (2022). Congenital Zika syndrome and living conditions in the largest city of northeastern Brazil. *BMC Public Health*, 22:1231, 1-12. <https://doi.org/10.1186/s12889-022-13614-x>

Tavares, F. F.; Betti, G. (2021). The pandemic of poverty, vulnerability, and COVID-19: Evidence from a fuzzy multidimensional analysis of deprivations in Brazil. *World Development*, v.1139. <https://doi.org/10.1016/j.worlddev.2020.105307>

Trevilato, G. C., Riquinho, D. L., Mesquita, M. O., Rosset, I., Augusto, L. G. da S., & Nunes, L. N. (2022). Anomalias congênitas na perspectiva dos determinantes sociais da saúde. *Cadernos de Saúde Pública*, 38(1), e00037021. 1-13. doi: 10.1590/0102-311X00037021

United Nations Development Programme, & Oxford Poverty and Human Development Initiative (2019). How to build a national multidimensional poverty index. using the MPI to inform the SDGs. New York-USA. Recuperado em [https://ophi.org.uk/wp-content/uploads/How to Build Handbook 2019 PDF.pdf](https://ophi.org.uk/wp-content/uploads/How_to_Build_Handbook_2019_PDF.pdf)

Varella, C. A. A. (2008). Análise Multivariada Aplicada às Ciências Agrárias. Análise de componentes principais. Rio de Janeiro: Universidade Federal Rural do Rio de Janeiro. Recuperado em <http://www.ufrj.br/institutos/it/deng/varella/Downloads/multivariada%20aplicada%20as%20ciencias%20agrarias/Aulas/analise%20de%20componentes%20principais.pdf>

Apêndice A - Intensidade da pobreza (A), Incidência da pobreza (H) e resultado do Índice de Pobreza Multidimensional (M0) segundo município do estado de São Paulo.

Município	DRS	A	H	M0
ADAMANTINA	IX - Marília	0,10	0	0,000
ADOLFO	XV - São José do Rio Preto	0,14	0	0,000
AGUAI	XIV - São João da Boa Vista	0,20	1	0,200
AGUAS DA PRATA	XIV - São João da Boa Vista	0,16	0	0,000
AGUAS DE LINDOIA	VII - Campinas	0,25	1	0,250
AGUAS DE SANTA BARBARA	VI - Bauru	0,12	0	0,000
AGUAS DE SAO PEDRO	X - Piracicaba	0,10	0	0,000
AGUDOS	VI - Bauru	0,00	1	0,000
ALAMBARI	XVI - Sorocaba	0,26	1	0,260
ALFREDO MARCONDES	XI - Presidente Prudente	0,20	1	0,200
ALTAIR	V - Barretos	0,44	1	0,440
ALTINOPOLIS	XIII - Ribeirão Preto	0,20	1	0,200
ALTO ALEGRE	II - Araçatuba	0,40	1	0,400
ALUMINIO	XVI - Sorocaba	0,28	1	0,280
ALVARES FLORENCE	XV - São José do Rio Preto	0,40	1	0,400
ALVARES MACHADO	XI - Presidente Prudente	0,18	0	0,000
ALVARO DE CARVALHO	IX - Marília	0,20	1	0,200
ALVINLANDIA	IX - Marília	0,20	1	0,200
AMERICANA	VII - Campinas	0,10	0	0,000
AMERICO BRASILIENSE	III - Araraquara	0,00	1	0,000
AMERICO DE CAMPOS	XV - São José do Rio Preto	0,05	0	0,000
AMPARO	VII - Campinas	0,12	0	0,000
ANALANDIA	X - Piracicaba	0,24	1	0,240
ANDRADINA	II - Araçatuba	0,24	1	0,240
ANGATUBA	XVI - Sorocaba	0,13	0	0,000
ANHEMBI	VI - Bauru	0,15	0	0,000
ANHUMAS	XI - Presidente Prudente	0,10	0	0,000
APARECIDA	XVII - Taubaté	0,38	1	0,380

APARECIDA D'OESTE	XV - São José do Rio Preto	0,35	1	0,350
APIAI	XVI - Sorocaba	0,40	1	0,400
ARACARIGUAMA	XVI - Sorocaba	0,26	1	0,260
ARACATUBA	II - Araçatuba	0,04	0	0,000
ARACOIABA DA SERRA	XVI - Sorocaba	0,22	1	0,220
ARAMINA	VIII - Franca	0,24	1	0,240
ARANDU	VI - Bauru	0,48	1	0,480
ARAPEI	XVII - Taubaté	0,40	1	0,400
ARARAQUARA	III - Araraquara	0,00	1	0,000
ARARAS	X - Piracicaba	0,30	1	0,300
ARCO-IRIS	IX - Marília	0,45	1	0,450
AREALVA	VI - Bauru	0,29	1	0,290
AREIAS	XVII - Taubaté	0,33	1	0,330
AREIOPOLIS	VI - Bauru	0,44	1	0,440
ARIRANHA	XV - São José do Rio Preto	0,49	1	0,490
ARTUR NOGUEIRA	VII - Campinas	0,38	1	0,380
ARUJA	I - Grande São Paulo	0,08	0	0,000
ASPASIA	XV - São José do Rio Preto	0,50	1	0,500
ASSIS	IX - Marília	0,00	1	0,000
ATIBAIA	VII - Campinas	0,12	0	0,000
AURIFLAMA	II - Araçatuba	0,09	0	0,000
AVAI	VI - Bauru	0,19	0	0,000
AVANHANDAVA	II - Araçatuba	0,10	0	0,000
AVARE	VI - Bauru	0,10	0	0,000
BADY BASSITT	XV - São José do Rio Preto	0,00	1	0,000
BALBINOS	VI - Bauru	0,60	1	0,600
BALSAMO	XV - São José do Rio Preto	0,19	0	0,000
BANANAL	XVII - Taubaté	0,41	1	0,410
BARAO DE ANTONINA	VI - Bauru	0,52	1	0,520
BARBOSA	II - Araçatuba	0,60	1	0,600
BARIRI	VI - Bauru	0,10	0	0,000
BARRA BONITA	VI - Bauru	0,00	1	0,000
BARRA DO CHAPEU	XVI - Sorocaba	0,90	1	0,900
BARRA DO TURVO	XII - Registro	0,86	1	0,860

BARRETOS	V - Barretos	0,00	1	0,000
BARRINHA	XIII - Ribeirão Preto	0,39	1	0,390
BARUERI	I - Grande São Paulo	0,10	0	0,000
BASTOS	IX - Marília	0,10	0	0,000
BATATAIS	XIII - Ribeirão Preto	0,00	1	0,000
BAURU	VI - Bauru	0,34	1	0,340
BEBEDOURO	V - Barretos	0,00	1	0,000
BENTO DE ABREU	II - Araçatuba	0,10	0	0,000
BERNARDINO DE CAMPOS	IX - Marília	0,30	1	0,300
BERTIOGA	IV - Baixada Santista	0,51	1	0,510
BILAC	II - Araçatuba	0,14	0	0,000
BIRIGUI	II - Araçatuba	0,00	1	0,000
BIRITIBA-MIRIM	I - Grande São Paulo	0,60	1	0,600
BOA ESPERANCA DO SUL	III - Araraquara	0,20	1	0,200
BOCAINA	VI - Bauru	0,13	0	0,000
BOFETE	VI - Bauru	0,71	1	0,710
BOITUVA	XVI - Sorocaba	0,12	0	0,000
BOM JESUS DOS PERDOES	VII - Campinas	0,18	0	0,000
BOM SUCESSO DE ITARARE	XVI - Sorocaba	0,95	1	0,950
BORA	IX - Marília	0,10	0	0,000
BORACEIA	VI - Bauru	0,34	1	0,340
BORBOREMA	III - Araraquara	0,15	0	0,000
BOREBI	VI - Bauru	0,18	0	0,000
BOTUCATU	VI - Bauru	0,00	1	0,000
BRAGANCA PAULISTA	VII - Campinas	0,10	0	0,000
BRAUNA	II - Araçatuba	0,10	0	0,000
BREJO ALEGRE	II - Araçatuba	0,24	1	0,240
BRODOWSKI	XIII - Ribeirão Preto	0,39	1	0,390
BROTAS	VI - Bauru	0,05	0	0,000
BURI	XVI - Sorocaba	0,46	1	0,460
BURITAMA	II - Araçatuba	0,20	1	0,200
BURITIZAL	VIII - Franca	0,05	0	0,000
CABRALIA PAULISTA	VI - Bauru	0,58	1	0,580
CABREUVA	VII - Campinas	0,12	0	0,000

CACAPAVA	XVII - Taubaté	0,12	0	0,000
CACHOEIRA PAULISTA	XVII - Taubaté	0,08	0	0,000
CACONDE	XIV - São João da Boa Vista	0,42	1	0,420
CAFELANDIA	VI - Bauru	0,24	1	0,240
CAIABU	XI - Presidente Prudente	0,32	1	0,320
CAIEIRAS	I - Grande São Paulo	0,08	0	0,000
CAIUA	XI - Presidente Prudente	0,39	1	0,390
CAJAMAR	I - Grande São Paulo	0,16	0	0,000
CAJATI	XII - Registro	0,32	1	0,320
CAJOBI	V - Barretos	0,30	1	0,300
CAJURU	XIII - Ribeirão Preto	0,29	1	0,290
CAMPINA DO MONTE ALEGRE	XVI - Sorocaba	0,66	1	0,660
CAMPINAS	VII - Campinas	0,18	0	0,000
CAMPO LIMPO PAULISTA	VII - Campinas	0,12	0	0,000
CAMPOS DO JORDAO	XVII - Taubaté	0,31	1	0,310
CAMPOS NOVOS PAULISTA	IX - Marília	0,44	1	0,440
CANANEIA	XII - Registro	0,40	1	0,400
CANAS	XVII - Taubaté	0,51	1	0,510
CANDIDO MOTA	IX - Marília	0,20	1	0,200
CANDIDO RODRIGUES	III - Araraquara	0,00	1	0,000
CANITAR	IX - Marília	0,33	1	0,330
CAPAO BONITO	XVI - Sorocaba	0,37	1	0,370
CAPELA DO ALTO	XVI - Sorocaba	0,26	1	0,260
CAPIVARI	X - Piracicaba	0,17	0	0,000
CARAGUATATUBA	XVII - Taubaté	0,32	1	0,320
CARAPICUIBA	I - Grande São Paulo	0,34	1	0,340
CARDOSO	XV - São José do Rio Preto	0,37	1	0,370
CASA BRANCA	XIV - São João da Boa Vista	0,12	0	0,000
CASSIA DOS COQUEIROS	XIII - Ribeirão Preto	0,60	1	0,600
CASTILHO	II - Araçatuba	0,21	1	0,210
CATANDUVA	XV - São José do Rio Preto	0,00	1	0,000
CATIGUA	XV - São José do Rio Preto	0,00	1	0,000
CEDRAL	XV - São José do Rio Preto	0,00	1	0,000
CERQUEIRA CESAR	VI - Bauru	0,14	0	0,000

CERQUILHO	XVI - Sorocaba	0,00	1	0,000
CESARIO LANGE	XVI - Sorocaba	0,18	0	0,000
CHARQUEADA	X - Piracicaba	0,04	0	0,000
CHAVANTES	IX - Marília	0,00	1	0,000
CLEMENTINA	II - Araçatuba	0,10	0	0,000
COLINA	V - Barretos	0,00	1	0,000
COLOMBIA	V - Barretos	0,34	1	0,340
CONCHAL	X - Piracicaba	0,29	1	0,290
CONCHAS	VI - Bauru	0,28	1	0,280
CORDEIROPOLIS	X - Piracicaba	0,00	1	0,000
COROADOS	II - Araçatuba	0,05	0	0,000
CORONEL MACEDO	VI - Bauru	0,44	1	0,440
CORUMBATAI	X - Piracicaba	0,00	1	0,000
COSMOPOLIS	VII - Campinas	0,00	1	0,000
COSMORAMA	XV - São José do Rio Preto	0,50	1	0,500
COTIA	I - Grande São Paulo	0,12	0	0,000
CRAVINHOS	XIII - Ribeirão Preto	0,20	1	0,200
CRISTAIS PAULISTA	VIII - Franca	0,04	0	0,000
CRUZALIA	IX - Marília	0,10	0	0,000
CRUZEIRO	XVII - Taubaté	0,08	0	0,000
CUBATAO	IV - Baixada Santista	0,14	0	0,000
CUNHA	XVII - Taubaté	0,62	1	0,620
DESCALVADO	III - Araraquara	0,00	1	0,000
DIADEMA	I - Grande São Paulo	0,10	0	0,000
DIRCE REIS	XV - São José do Rio Preto	0,50	1	0,500
DIVINOLANDIA	XIV - São João da Boa Vista	0,34	1	0,340
DOBRADA	III - Araraquara	0,40	1	0,400
DOIS CORREGOS	VI - Bauru	0,10	0	0,000
DOLCINOPOLIS	XV - São José do Rio Preto	0,50	1	0,500
DOURADO	III - Araraquara	0,10	0	0,000
DRACENA	XI - Presidente Prudente	0,00	1	0,000
DUARTINA	VI - Bauru	0,10	0	0,000
DUMONT	XIII - Ribeirão Preto	0,20	1	0,200
ECHAPORA	IX - Marília	0,65	1	0,650

ELDORADO	XII - Registro	0,92	1	0,920
ELIAS FAUSTO	X - Piracicaba	0,14	0	0,000
ELISIARIO	XV - São José do Rio Preto	0,10	0	0,000
EMBAUBA	XV - São José do Rio Preto	0,19	0	0,000
EMBU DAS ARTES	I - Grande São Paulo	0,18	0	0,000
EMBU-GUACU	I - Grande São Paulo	0,46	1	0,460
EMILIANOPOLIS	XI - Presidente Prudente	0,19	0	0,000
ENGENHEIRO COELHO	X - Piracicaba	0,29	1	0,290
ESPIRITO SANTO DO PINHAL	XIV - São João da Boa Vista	0,10	0	0,000
ESPIRITO SANTO DO TURVO	IX - Marília	0,40	1	0,400
ESTIVA GERBI	XIV - São João da Boa Vista	0,24	1	0,240
ESTRELA D'OESTE	XV - São José do Rio Preto	0,00	1	0,000
ESTRELA DO NORTE	XI - Presidente Prudente	0,14	0	0,000
EUCLIDES DA CUNHA PAULISTA	XI - Presidente Prudente	0,72	1	0,720
FARTURA	VI - Bauru	0,34	1	0,340
FERNANDO PRESTES	XV - São José do Rio Preto	0,05	0	0,000
FERNANDOPOLIS	XV - São José do Rio Preto	0,00	1	0,000
FERNAO	IX - Marília	0,45	1	0,450
FERRAZ DE VASCONCELOS	I - Grande São Paulo	0,28	1	0,280
FLORA RICA	XI - Presidente Prudente	0,20	1	0,200
FLOREAL	XV - São José do Rio Preto	0,10	0	0,000
FLORIDA PAULISTA	IX - Marília	0,40	1	0,400
FLORINIA	IX - Marília	0,20	1	0,200
FRANCA	VIII - Franca	0,10	0	0,000
FRANCISCO MORATO	I - Grande São Paulo	0,50	1	0,500
FRANCO DA ROCHA	I - Grande São Paulo	0,12	0	0,000
GABRIEL MONTEIRO	II - Araçatuba	0,20	1	0,200
GALIA	IX - Marília	0,40	1	0,400
GARCA	IX - Marília	0,00	1	0,000
GASTAO VIDIGAL	XV - São José do Rio Preto	0,34	1	0,340
GAVIAO PEIXOTO	III - Araraquara	0,10	0	0,000
GENERAL SALGADO	XV - São José do Rio Preto	0,30	1	0,300
GETULINA	VI - Bauru	0,17	0	0,000
GLICERIO	II - Araçatuba	0,30	1	0,300

GUAICARA	VI - Bauru	0,34	1	0,340
GUAIMBE	IX - Marília	0,18	0	0,000
GUAIRA	V - Barretos	0,05	0	0,000
GUAPIACU	XV - São José do Rio Preto	0,14	0	0,000
GUAPIARA	XVI - Sorocaba	0,57	1	0,570
GUARA	VIII - Franca	0,34	1	0,340
GUARACAI	II - Araçatuba	0,10	0	0,000
GUARACI	V - Barretos	0,29	1	0,290
GUARANI D'OESTE	XV - São José do Rio Preto	0,40	1	0,400
GUARANTA	IX - Marília	0,40	1	0,400
GUARARAPES	II - Araçatuba	0,05	0	0,000
GUARAREMA	I - Grande São Paulo	0,20	1	0,200
GUARATINGUETA	XVII - Taubaté	0,08	0	0,000
GUAREI	XVI - Sorocaba	0,50	1	0,500
GUARIBA	XIII - Ribeirão Preto	0,19	0	0,000
GUARUJA	IV - Baixada Santista	0,46	1	0,460
GUARULHOS	I - Grande São Paulo	0,30	1	0,300
GUATAPARA	XIII - Ribeirão Preto	0,28	1	0,280
GUZOLANDIA	II - Araçatuba	0,40	1	0,400
HERCULANDIA	IX - Marília	0,44	1	0,440
HOLAMBRA	VII - Campinas	0,24	1	0,240
HORTOLANDIA	VII - Campinas	0,23	1	0,230
IACANGA	VI - Bauru	0,10	0	0,000
IACRI	IX - Marília	0,45	1	0,450
IARAS	VI - Bauru	0,65	1	0,650
IBATE	III - Araraquara	0,04	0	0,000
IBIRA	XV - São José do Rio Preto	0,19	0	0,000
IBIRAREMA	IX - Marília	0,14	0	0,000
IBITINGA	III - Araraquara	0,30	1	0,300
IBIUNA	XVI - Sorocaba	0,70	1	0,700
ICEM	XV - São José do Rio Preto	0,34	1	0,340
IEPE	XI - Presidente Prudente	0,08	0	0,000
IGARACU DO TIETE	VI - Bauru	0,30	1	0,300
IGARAPAVA	VIII - Franca	0,39	1	0,390

IGARATA	XVII - Taubaté	0,62	1	0,620
IGUAPE	XII - Registro	0,56	1	0,560
ILHA COMPRIDA	XII - Registro	0,70	1	0,700
ILHA SOLTEIRA	II - Araçatuba	0,09	0	0,000
ILHABELA	XVII - Taubaté	0,61	1	0,610
INDAIATUBA	VII - Campinas	0,04	0	0,000
INDIANA	XI - Presidente Prudente	0,09	0	0,000
INDIAPORA	XV - São José do Rio Preto	0,38	1	0,380
INUBIA PAULISTA	IX - Marília	0,30	1	0,300
IPAUSSU	IX - Marília	0,00	1	0,000
IPERO	XVI - Sorocaba	0,32	1	0,320
IPEUNA	X - Piracicaba	0,00	1	0,000
IPIGUA	XV - São José do Rio Preto	0,20	1	0,200
IPORANGA	XII - Registro	0,76	1	0,760
IPIUA	VIII - Franca	0,05	0	0,000
IRACEMAPOLIS	X - Piracicaba	0,00	1	0,000
IRAPUA	XV - São José do Rio Preto	0,45	1	0,450
IRAPURU	XI - Presidente Prudente	0,62	1	0,620
ITABERA	XVI - Sorocaba	0,52	1	0,520
ITAI	VI - Bauru	0,63	1	0,630
ITAJOBI	XV - São José do Rio Preto	0,24	1	0,240
ITAJU	VI - Bauru	0,25	1	0,250
ITANHAEM	IV - Baixada Santista	0,50	1	0,500
ITAOCA	XVI - Sorocaba	0,70	1	0,700
ITAPECERICA DA SERRA	I - Grande São Paulo	0,41	1	0,410
ITAPETININGA	XVI - Sorocaba	0,14	0	0,000
ITAPEVA	XVI - Sorocaba	0,32	1	0,320
ITAPEVI	I - Grande São Paulo	0,30	1	0,300
ITAPIRA	XIV - São João da Boa Vista	0,10	0	0,000
ITAPIRAPUA PAULISTA	XVI - Sorocaba	0,90	1	0,900
ITAPOLIS	III - Araraquara	0,05	0	0,000
ITAPORANGA	VI - Bauru	0,52	1	0,520
ITAPUI	VI - Bauru	0,49	1	0,490
ITAPURA	II - Araçatuba	0,46	1	0,460

ITAQUAQUECETUBA	I - Grande São Paulo	0,50	1	0,500
ITARARE	XVI - Sorocaba	0,51	1	0,510
ITARIRI	XII - Registro	0,70	1	0,700
ITATIBA	VII - Campinas	0,04	0	0,000
ITATINGA	VI - Bauru	0,09	0	0,000
ITIRAPINA	X - Piracicaba	0,37	1	0,370
ITIRAPUA	VIII - Franca	0,25	1	0,250
ITOBI	XIV - São João da Boa Vista	0,42	1	0,420
ITU	XVI - Sorocaba	0,10	0	0,000
ITUPEVA	VII - Campinas	0,08	0	0,000
ITUVERAVA	VIII - Franca	0,05	0	0,000
JABORANDI	V - Barretos	0,44	1	0,440
JABOTICABAL	XIII - Ribeirão Preto	0,00	1	0,000
JACAREI	XVII - Taubaté	0,04	0	0,000
JACI	XV - São José do Rio Preto	0,00	1	0,000
JACUPIRANGA	XII - Registro	0,48	1	0,480
JAGUARIUNA	VII - Campinas	0,00	1	0,000
JALES	XV - São José do Rio Preto	0,25	1	0,250
JAMBEIRO	XVII - Taubaté	0,34	1	0,340
JANDIRA	I - Grande São Paulo	0,14	0	0,000
JARDINOPOLIS	XIII - Ribeirão Preto	0,00	1	0,000
JARINU	VII - Campinas	0,26	1	0,260
JAU	VI - Bauru	0,05	0	0,000
JERQUARA	VIII - Franca	0,14	0	0,000
JOANOPOLIS	VII - Campinas	0,29	1	0,290
JOAO RAMALHO	XI - Presidente Prudente	0,15	0	0,000
JOSE BONIFACIO	XV - São José do Rio Preto	0,25	1	0,250
JULIO MESQUITA	IX - Marília	0,24	1	0,240
JUMIRIM	XVI - Sorocaba	0,04	0	0,000
JUNDIAI	VII - Campinas	0,00	1	0,000
JUNQUEIROPOLIS	XI - Presidente Prudente	0,05	0	0,000
JUQUIA	XII - Registro	0,42	1	0,420
JUQUITIBA	I - Grande São Paulo	0,85	1	0,850
LAGOINHA	XVII - Taubaté	0,57	1	0,570

LARANJAL PAULISTA	VI - Bauru	0,05	0	0,000
LAVINIA	II - Araçatuba	0,15	0	0,000
LAVRINHAS	XVII - Taubaté	0,16	0	0,000
LEME	X - Piracicaba	0,10	0	0,000
LENCOIS PAULISTA	VI - Bauru	0,00	1	0,000
LIMEIRA	X - Piracicaba	0,10	0	0,000
LINDOIA	VII - Campinas	0,28	1	0,280
LINS	VI - Bauru	0,00	1	0,000
LORENA	XVII - Taubaté	0,04	0	0,000
LOURDES	II - Araçatuba	0,29	1	0,290
LOUVEIRA	VII - Campinas	0,04	0	0,000
LUCELIA	IX - Marília	0,20	1	0,200
LUCIANOPOLIS	VI - Bauru	0,24	1	0,240
LUIS ANTONIO	XIII - Ribeirão Preto	0,05	0	0,000
LUIZIANIA	II - Araçatuba	0,30	1	0,300
LUPERCIO	IX - Marília	0,25	1	0,250
LUTECIA	IX - Marília	0,18	0	0,000
MACATUBA	VI - Bauru	0,00	1	0,000
MACAUBAL	XV - São José do Rio Preto	0,30	1	0,300
MACEDONIA	XV - São José do Rio Preto	0,74	1	0,740
MAGDA	XV - São José do Rio Preto	0,20	1	0,200
MAIRINQUE	XVI - Sorocaba	0,12	0	0,000
MAIRIPORA	I - Grande São Paulo	0,40	1	0,400
MANDURI	VI - Bauru	0,24	1	0,240
MARABA PAULISTA	XI - Presidente Prudente	0,62	1	0,620
MARACAI	IX - Marília	0,13	0	0,000
MARAPOAMA	XV - São José do Rio Preto	0,10	0	0,000
MARIAPOLIS	IX - Marília	0,30	1	0,300
MARILIA	IX - Marília	0,10	0	0,000
MARINOPOLIS	XV - São José do Rio Preto	0,30	1	0,300
MARTINOPOLIS	XI - Presidente Prudente	0,09	0	0,000
MATAO	III - Araraquara	0,00	1	0,000
MAUA	I - Grande São Paulo	0,14	0	0,000
MENDONCA	XV - São José do Rio Preto	0,25	1	0,250

MERIDIANO	XV - São José do Rio Preto	0,34	1	0,340
MESOPOLIS	XV - São José do Rio Preto	0,19	0	0,000
MIGUELOPOLIS	VIII - Franca	0,43	1	0,430
MINEIROS DO TIETE	VI - Bauru	0,15	0	0,000
MIRA ESTRELA	XV - São José do Rio Preto	0,28	1	0,280
MIRACATU	XII - Registro	0,70	1	0,700
MIRANDOPOLIS	II - Araçatuba	0,26	1	0,260
MIRANTE DO PARANAPANEMA	XI - Presidente Prudente	0,38	1	0,380
MIRASSOL	XV - São José do Rio Preto	0,19	0	0,000
MIRASSOLANDIA	XV - São José do Rio Preto	0,40	1	0,400
MOCOCA	XIV - São João da Boa Vista	0,00	1	0,000
MOGI DAS CRUZES	I - Grande São Paulo	0,26	1	0,260
MOGI GUACU	XIV - São João da Boa Vista	0,00	1	0,000
MOGI MIRIM	XIV - São João da Boa Vista	0,00	1	0,000
MOMBUCA	X - Piracicaba	0,10	0	0,000
MONCOES	XV - São José do Rio Preto	0,30	1	0,300
MONGAGUA	IV - Baixada Santista	0,60	1	0,600
MONTE ALEGRE DO SUL	VII - Campinas	0,22	1	0,220
MONTE ALTO	XIII - Ribeirão Preto	0,00	1	0,000
MONTE APRAZIVEL	XV - São José do Rio Preto	0,05	0	0,000
MONTE AZUL PAULISTA	V - Barretos	0,09	0	0,000
MONTE CASTELO	XI - Presidente Prudente	0,48	1	0,480
MONTE MOR	VII - Campinas	0,32	1	0,320
MONTEIRO LOBATO	XVII - Taubaté	0,66	1	0,660
MORRO AGUDO	VIII - Franca	0,10	0	0,000
MORUNGABA	VII - Campinas	0,14	0	0,000
MOTUCA	III - Araraquara	0,25	1	0,250
MURUTINGA DO SUL	II - Araçatuba	0,30	1	0,300
NANTES	XI - Presidente Prudente	0,20	1	0,200
NARANDIBA	XI - Presidente Prudente	0,10	0	0,000
NATIVIDADE DA SERRA	XVII - Taubaté	0,68	1	0,680
NAZARE PAULISTA	VII - Campinas	0,46	1	0,460
NEVES PAULISTA	XV - São José do Rio Preto	0,10	0	0,000
NHANDEARA	XV - São José do Rio Preto	0,10	0	0,000

NIPOA	XV - São José do Rio Preto	0,15	0	0,000
NOVA ALIANCA	XV - São José do Rio Preto	0,00	1	0,000
NOVA CAMPINA	XVI - Sorocaba	0,75	1	0,750
NOVA CANAA PAULISTA	XV - São José do Rio Preto	0,64	1	0,640
NOVA CASTILHO	II - Araçatuba	0,14	0	0,000
NOVA EUROPA	III - Araraquara	0,10	0	0,000
NOVA GRANADA	XV - São José do Rio Preto	0,04	0	0,000
NOVA GUATAPORANGA	XI - Presidente Prudente	0,25	1	0,250
NOVA INDEPENDENCIA	II - Araçatuba	0,14	0	0,000
NOVA LUZITANIA	II - Araçatuba	0,30	1	0,300
NOVA ODESSA	VII - Campinas	0,10	0	0,000
NOVAIS	XV - São José do Rio Preto	0,20	1	0,200
NOVO HORIZONTE	XV - São José do Rio Preto	0,05	0	0,000
NUPORANGA	VIII - Franca	0,25	1	0,250
OCAUCU	IX - Marília	0,34	1	0,340
OLEO	IX - Marília	0,54	1	0,540
OLIMPIA	V - Barretos	0,14	0	0,000
ONDA VERDE	XV - São José do Rio Preto	0,10	0	0,000
ORIENTE	IX - Marília	0,00	1	0,000
ORINDIUIVA	XV - São José do Rio Preto	0,10	0	0,000
ORLANDIA	VIII - Franca	0,00	1	0,000
OSASCO	I - Grande São Paulo	0,24	1	0,240
OSCAR BRESSANE	IX - Marília	0,20	1	0,200
OSVALDO CRUZ	IX - Marília	0,05	0	0,000
OURINHOS	IX - Marília	0,00	1	0,000
OURO VERDE	XI - Presidente Prudente	0,48	1	0,480
OUROESTE	XV - São José do Rio Preto	0,20	1	0,200
PACAEMBU	IX - Marília	0,48	1	0,480
PALESTINA	XV - São José do Rio Preto	0,19	0	0,000
PALMARES PAULISTA	XV - São José do Rio Preto	0,15	0	0,000
PALMEIRA D'OESTE	XV - São José do Rio Preto	0,30	1	0,300
PALMITAL	IX - Marília	0,05	0	0,000
PANORAMA	XI - Presidente Prudente	0,48	1	0,480
PARAGUACU PAULISTA	IX - Marília	0,04	0	0,000

PARAIBUNA	XVII - Taubaté	0,31	1	0,310
PARAISO	XV - São José do Rio Preto	0,05	0	0,000
PARANAPANEMA	VI - Bauru	0,50	1	0,500
PARANAPUA	XV - São José do Rio Preto	0,64	1	0,640
PARAPUA	IX - Marília	0,20	1	0,200
PARDINHO	VI - Bauru	0,33	1	0,330
PARIQUERA-ACU	XII - Registro	0,40	1	0,400
PARISI	XV - São José do Rio Preto	0,40	1	0,400
PATROCINIO PAULISTA	VIII - Franca	0,10	0	0,000
PAULICEIA	XI - Presidente Prudente	0,29	1	0,290
PAULINIA	VII - Campinas	0,00	1	0,000
PAULISTANIA	VI - Bauru	0,47	1	0,470
PAULO DE FARIA	XV - São José do Rio Preto	0,20	1	0,200
PEDERNEIRAS	VI - Bauru	0,00	1	0,000
PEDRA BELA	VII - Campinas	0,57	1	0,570
PEDRANOPOLIS	XV - São José do Rio Preto	0,30	1	0,300
PEDREGULHO	VIII - Franca	0,05	0	0,000
PEDREIRA	VII - Campinas	0,00	1	0,000
PEDRINHAS PAULISTA	IX - Marília	0,08	0	0,000
PEDRO DE TOLEDO	XII - Registro	0,70	1	0,700
PENAPOLIS	II - Araçatuba	0,10	0	0,000
PEREIRA BARRETO	II - Araçatuba	0,10	0	0,000
PEREIRAS	VI - Bauru	0,48	1	0,480
PERUIBE	IV - Baixada Santista	0,60	1	0,600
PIACATU	II - Araçatuba	0,25	1	0,250
PIEDADE	XVI - Sorocaba	0,50	1	0,500
PILAR DO SUL	XVI - Sorocaba	0,52	1	0,520
PINDAMONHANGABA	XVII - Taubaté	0,14	0	0,000
PINDORAMA	XV - São José do Rio Preto	0,00	1	0,000
PINHALZINHO	VII - Campinas	0,56	1	0,560
PIQUEROBI	XI - Presidente Prudente	0,24	1	0,240
PIQUETE	XVII - Taubaté	0,37	1	0,370
PIRACAIA	VII - Campinas	0,36	1	0,360
PIRACICABA	X - Piracicaba	0,10	0	0,000

PIRAJU	VI - Bauru	0,10	0	0,000
PIRAJUI	VI - Bauru	0,12	0	0,000
PIRANGI	XV - São José do Rio Preto	0,20	1	0,200
PIRAPORA DO BOM JESUS	I - Grande São Paulo	0,28	1	0,280
PIRAPOZINHO	XI - Presidente Prudente	0,14	0	0,000
PIRASSUNUNGA	X - Piracicaba	0,10	0	0,000
PIRATININGA	VI - Bauru	0,38	1	0,380
PITANGUEIRAS	XIII - Ribeirão Preto	0,05	0	0,000
PLANALTO	XV - São José do Rio Preto	0,05	0	0,000
PLATINA	IX - Marília	0,45	1	0,450
POA	I - Grande São Paulo	0,00	1	0,000
POLONI	XV - São José do Rio Preto	0,28	1	0,280
POMPEIA	IX - Marília	0,00	1	0,000
PONGAI	VI - Bauru	0,00	1	0,000
PONTAL	XIII - Ribeirão Preto	0,24	1	0,240
PONTALINDA	XV - São José do Rio Preto	0,40	1	0,400
PONTES GESTAL	XV - São José do Rio Preto	0,20	1	0,200
POPULINA	XV - São José do Rio Preto	0,30	1	0,300
PORANGABA	VI - Bauru	0,56	1	0,560
PORTO FELIZ	XVI - Sorocaba	0,04	0	0,000
PORTO FERREIRA	III - Araraquara	0,04	0	0,000
POTIM	XVII - Taubaté	0,48	1	0,480
POTIRENDABA	XV - São José do Rio Preto	0,15	0	0,000
PRACINHA	IX - Marília	0,44	1	0,440
PRADOPOLIS	XIII - Ribeirão Preto	0,20	1	0,200
PRAIA GRANDE	IV - Baixada Santista	0,30	1	0,300
PRATANIA	VI - Bauru	0,24	1	0,240
PRESIDENTE ALVES	VI - Bauru	0,19	0	0,000
PRESIDENTE BERNARDES	XI - Presidente Prudente	0,28	1	0,280
PRESIDENTE EPITACIO	XI - Presidente Prudente	0,22	1	0,220
PRESIDENTE PRUDENTE	XI - Presidente Prudente	0,00	1	0,000
PRESIDENTE VENCESLAU	XI - Presidente Prudente	0,18	0	0,000
PROMISSAO	VI - Bauru	0,25	1	0,250
QUADRA	XVI - Sorocaba	0,53	1	0,530

QUATA	XI - Presidente Prudente	0,04	0	0,000
QUEIROZ	IX - Marília	0,10	0	0,000
QUELUZ	XVII - Taubaté	0,36	1	0,360
QUINTANA	IX - Marília	0,44	1	0,440
RAFARD	X - Piracicaba	0,00	1	0,000
RANCHARIA	XI - Presidente Prudente	0,05	0	0,000
REDENCAO DA SERRA	XVII - Taubaté	0,52	1	0,520
REGENTE FEIJO	XI - Presidente Prudente	0,35	1	0,350
REGINOPOLIS	VI - Bauru	0,00	1	0,000
REGISTRO	XII - Registro	0,20	1	0,200
RESTINGA	VIII - Franca	0,39	1	0,390
RIBEIRA	XVI - Sorocaba	0,56	1	0,560
RIBEIRAO BONITO	III - Araraquara	0,14	0	0,000
RIBEIRAO BRANCO	XVI - Sorocaba	0,81	1	0,810
RIBEIRAO CORRENTE	VIII - Franca	0,50	1	0,500
RIBEIRAO DO SUL	IX - Marília	0,32	1	0,320
RIBEIRAO DOS INDIOS	XI - Presidente Prudente	0,54	1	0,540
RIBEIRAO GRANDE	XVI - Sorocaba	0,78	1	0,780
RIBEIRAO PIRES	I - Grande São Paulo	0,08	0	0,000
RIBEIRAO PRETO	XIII - Ribeirão Preto	0,35	1	0,350
RIFAINA	VIII - Franca	0,28	1	0,280
RINCAO	III - Araraquara	0,00	1	0,000
RINOPOLIS	IX - Marília	0,35	1	0,350
RIO CLARO	X - Piracicaba	0,00	1	0,000
RIO DAS PEDRAS	X - Piracicaba	0,00	1	0,000
RIO GRANDE DA SERRA	I - Grande São Paulo	0,20	1	0,200
RIOLANDIA	XV - São José do Rio Preto	0,48	1	0,480
RIVERSUL	XVI - Sorocaba	0,67	1	0,670
ROSANA	XI - Presidente Prudente	0,29	1	0,290
ROSEIRA	XVII - Taubaté	0,32	1	0,320
RUBIACEA	II - Araçatuba	0,24	1	0,240
RUBINEIA	XV - São José do Rio Preto	0,32	1	0,320
SABINO	VI - Bauru	0,10	0	0,000
SAGRES	IX - Marília	0,20	1	0,200

SALES	XV - São José do Rio Preto	0,33	1	0,330
SALES OLIVEIRA	VIII - Franca	0,10	0	0,000
SALESOPOLIS	I - Grande São Paulo	0,46	1	0,460
SALMOURAO	IX - Marília	0,50	1	0,500
SALTINHO	X - Piracicaba	0,00	1	0,000
SALTO	XVI - Sorocaba	0,00	1	0,000
SALTO DE PIRAPORA	XVI - Sorocaba	0,10	0	0,000
SALTO GRANDE	IX - Marília	0,45	1	0,450
SANDOVALINA	XI - Presidente Prudente	0,44	1	0,440
SANTA ADELIA	XV - São José do Rio Preto	0,14	0	0,000
SANTA ALBERTINA	XV - São José do Rio Preto	0,40	1	0,400
SANTA BARBARA D'OESTE	VII - Campinas	0,00	1	0,000
SANTA BRANCA	XVII - Taubaté	0,04	0	0,000
SANTA CLARA D'OESTE	XV - São José do Rio Preto	0,30	1	0,300
SANTA CRUZ DA CONCEICAO	X - Piracicaba	0,19	0	0,000
SANTA CRUZ DA ESPERANCA	XIII - Ribeirão Preto	0,20	1	0,200
SANTA CRUZ DAS PALMEIRAS	XIV - São João da Boa Vista	0,00	1	0,000
SANTA CRUZ DO RIO PARDO	IX - Marília	0,20	1	0,200
SANTA ERNESTINA	III - Araraquara	0,00	1	0,000
SANTA FE DO SUL	XV - São José do Rio Preto	0,20	1	0,200
SANTA GERTRUDES	X - Piracicaba	0,04	0	0,000
SANTA ISABEL	I - Grande São Paulo	0,45	1	0,450
SANTA LUCIA	III - Araraquara	0,00	1	0,000
SANTA MARIA DA SERRA	X - Piracicaba	0,10	0	0,000
SANTA MERCEDES	XI - Presidente Prudente	0,32	1	0,320
SANTA RITA D'OESTE	XV - São José do Rio Preto	0,49	1	0,490
SANTA RITA DO PASSA QUATRO	XIII - Ribeirão Preto	0,00	1	0,000
SANTA ROSA DE VITERBO	XIII - Ribeirão Preto	0,00	1	0,000
SANTA SALETE	XV - São José do Rio Preto	0,20	1	0,200
SANTANA DA PONTE PENSA	XV - São José do Rio Preto	0,30	1	0,300
SANTANA DE PARNAIBA	I - Grande São Paulo	0,28	1	0,280
SANTO ANASTACIO	XI - Presidente Prudente	0,04	0	0,000
SANTO ANDRE	I - Grande São Paulo	0,00	1	0,000
SANTO ANTONIO DA ALEGRIA	XIII - Ribeirão Preto	0,44	1	0,440

SANTO ANTONIO DE POSSE	VII - Campinas	0,48	1	0,480
SANTO ANTONIO DO ARACANGUA	II - Araçatuba	0,28	1	0,280
SANTO ANTONIO DO JARDIM	XIV - São João da Boa Vista	0,29	1	0,290
SANTO ANTONIO DO PINHAL	XVII - Taubaté	0,51	1	0,510
SANTO EXPEDITO	XI - Presidente Prudente	0,38	1	0,380
SANTOPOLIS DO AGUAPEI	II - Araçatuba	0,20	1	0,200
SANTOS	IV - Baixada Santista	0,00	1	0,000
SAO BENTO DO SAPUCAI	XVII - Taubaté	0,46	1	0,460
SAO BERNARDO DO CAMPO	I - Grande São Paulo	0,10	0	0,000
SAO CAETANO DO SUL	I - Grande São Paulo	0,00	1	0,000
SAO CARLOS	III - Araraquara	0,10	0	0,000
SAO FRANCISCO	XV - São José do Rio Preto	0,50	1	0,500
SAO JOAO DA BOA VISTA	XIV - São João da Boa Vista	0,00	1	0,000
SAO JOAO DAS DUAS PONTES	XV - São José do Rio Preto	0,30	1	0,300
SAO JOAO DE IRACEMA	XV - São José do Rio Preto	0,30	1	0,300
SAO JOAO DO PAU D'ALHO	XI - Presidente Prudente	0,24	1	0,240
SAO JOAQUIM DA BARRA	VIII - Franca	0,00	1	0,000
SAO JOSE DA BELA VISTA	VIII - Franca	0,53	1	0,530
SAO JOSE DO BARREIRO	XVII - Taubaté	0,78	1	0,780
SAO JOSE DO RIO PARDO	XIV - São João da Boa Vista	0,00	1	0,000
SAO JOSE DO RIO PRETO	XV - São José do Rio Preto	0,14	0	0,000
SAO JOSE DOS CAMPOS	XVII - Taubaté	0,10	0	0,000
SAO LOURENCO DA SERRA	I - Grande São Paulo	0,55	1	0,550
SAO LUIS DO PARAITINGA	XVII - Taubaté	0,56	1	0,560
SAO MANUEL	VI - Bauru	0,14	0	0,000
SAO MIGUEL ARCANJO	XVI - Sorocaba	0,50	1	0,500
SAO PAULO	I - Grande São Paulo	0,30	1	0,300
SAO PEDRO	X - Piracicaba	0,39	1	0,390
SAO PEDRO DO TURVO	IX - Marília	0,40	1	0,400
SAO ROQUE	XVI - Sorocaba	0,16	0	0,000
SAO SEBASTIAO	XVII - Taubaté	0,37	1	0,370
SAO SEBASTIAO DA GRAMA	XIV - São João da Boa Vista	0,30	1	0,300
SAO SIMAO	XIII - Ribeirão Preto	0,08	0	0,000
SAO VICENTE	IV - Baixada Santista	0,20	1	0,200

SARAPUI	XVI - Sorocaba	0,37	1	0,370
SARUTAIA	VI - Bauru	0,73	1	0,730
SEBASTIANOPOLIS DO SUL	XV - São José do Rio Preto	0,05	0	0,000
SERRA AZUL	XIII - Ribeirão Preto	0,49	1	0,490
SERRA NEGRA	VII - Campinas	0,18	0	0,000
SERRANA	XIII - Ribeirão Preto	0,00	1	0,000
SERTAOZINHO	XIII - Ribeirão Preto	0,00	1	0,000
SETE BARRAS	XII - Registro	0,61	1	0,610
SEVERINIA	V - Barretos	0,14	0	0,000
SILVEIRAS	XVII - Taubaté	0,53	1	0,530
SOCORRO	VII - Campinas	0,49	1	0,490
SOROCABA	XVI - Sorocaba	0,10	0	0,000
SUD MENNUCCI	II - Araçatuba	0,05	0	0,000
SUMARE	VII - Campinas	0,10	0	0,000
SUZANAPOLIS	II - Araçatuba	0,54	1	0,540
SUZANO	I - Grande São Paulo	0,16	0	0,000
TABAPUA	XV - São José do Rio Preto	0,20	1	0,200
TABATINGA	III - Araraquara	0,30	1	0,300
TABOAO DA SERRA	I - Grande São Paulo	0,34	1	0,340
TACIBA	XI - Presidente Prudente	0,30	1	0,300
TAGUAI	VI - Bauru	0,34	1	0,340
TAIACU	V - Barretos	0,45	1	0,450
TAIUVA	V - Barretos	0,34	1	0,340
TAMBAU	XIV - São João da Boa Vista	0,08	0	0,000
TANABI	XV - São José do Rio Preto	0,27	1	0,270
TAPIRAI	XVI - Sorocaba	0,80	1	0,800
TAPIRATIBA	XIV - São João da Boa Vista	0,20	1	0,200
TAQUARAL	V - Barretos	0,20	1	0,200
TAQUARITINGA	III - Araraquara	0,10	0	0,000
TAQUARITUBA	VI - Bauru	0,44	1	0,440
TAQUARIVAI	XVI - Sorocaba	0,26	1	0,260
TARABAI	XI - Presidente Prudente	0,40	1	0,400
TARUMA	IX - Marília	0,00	1	0,000
TATUI	XVI - Sorocaba	0,00	1	0,000

TAUBATE	XVII - Taubaté	0,00	1	0,000
TEJUPA	VI - Bauru	0,62	1	0,620
TEODORO SAMPAIO	XI - Presidente Prudente	0,48	1	0,480
TERRA ROXA	V - Barretos	0,04	0	0,000
TIETE	XVI - Sorocaba	0,00	1	0,000
TIMBURI	IX - Marília	0,54	1	0,540
TORRE DE PEDRA	VI - Bauru	0,14	0	0,000
TORRINHA	VI - Bauru	0,38	1	0,380
TRABIJU	III - Araraquara	0,14	0	0,000
TREMEMBE	XVII - Taubaté	0,46	1	0,460
TRES FRONTEIRAS	XV - São José do Rio Preto	0,45	1	0,450
TUIUTI	VII - Campinas	0,41	1	0,410
TUPA	IX - Marília	0,00	1	0,000
TUPI PAULISTA	XI - Presidente Prudente	0,20	1	0,200
TURIUBA	II - Araçatuba	0,10	0	0,000
TURMALINA	XV - São José do Rio Preto	0,50	1	0,500
UBARANA	XV - São José do Rio Preto	0,20	1	0,200
UBATUBA	XVII - Taubaté	0,51	1	0,510
UBIRAJARA	IX - Marília	0,29	1	0,290
UCHOA	XV - São José do Rio Preto	0,10	0	0,000
UNIAO PAULISTA	XV - São José do Rio Preto	0,30	1	0,300
URANIA	XV - São José do Rio Preto	0,10	0	0,000
URU	VI - Bauru	0,10	0	0,000
URUPES	XV - São José do Rio Preto	0,15	0	0,000
VALENTIM GENTIL	XV - São José do Rio Preto	0,10	0	0,000
VALINHOS	VII - Campinas	0,04	0	0,000
VALPARAISO	II - Araçatuba	0,00	1	0,000
VARGEM	VII - Campinas	0,36	1	0,360
VARGEM GRANDE DO SUL	XIV - São João da Boa Vista	0,20	1	0,200
VARGEM GRANDE PAULISTA	I - Grande São Paulo	0,20	1	0,200
VARZEA PAULISTA	VII - Campinas	0,12	0	0,000
VERA CRUZ	IX - Marília	0,08	0	0,000
VINHEDO	VII - Campinas	0,20	1	0,200
VIRADOURO	V - Barretos	0,05	0	0,000

VISTA ALEGRE DO ALTO	V - Barretos	0,25	1	0,250
VITORIA BRASIL	XV - São José do Rio Preto	0,48	1	0,480
VOTORANTIM	XVI - Sorocaba	0,00	1	0,000
VOTUPORANGA	XV - São José do Rio Preto	0,05	0	0,000
ZACARIAS	XV - São José do Rio Preto	0,10	0	0,000