



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CARTOGRÁFICA E DE AGRIMENSURA
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS GEODÉSICAS E
TECNOLOGIAS DA GEOINFORMAÇÃO

ANA CLÁUDIA BEZERRA DE ALBUQUERQUE BORBOREMA DE ANDRADE

**UMA ABORDAGEM CARTOGRÁFICA DO RISCO DE ESPALHAMENTO DA
COVID-19 EM RECIFE-PE**

Recife
2021

ANA CLÁUDIA BEZERRA DE ALBUQUERQUE BORBOREMA DE ANDRADE

**UMA ABORDAGEM CARTOGRÁFICA DO RISCO DE ESPALHAMENTO DA
COVID-19 EM RECIFE-PE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Mestra em Ciências Geodésicas e Tecnologias da Geoinformação. Área de concentração: Ciências Geodésicas e Tecnologias da Geoinformação

Orientadora: Profa. Dra. Andrea Flávia Tenório Carneiro

Coorientador: Prof. Dr. Daniel Carneiro da Silva

Recife

2021

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

A553a Andrade, Ana Cláudia Bezerra de Albuquerque Borborema de.
 Uma abordagem cartográfica do risco de espalhamento da COVID-19 em
 Recife-PE / Ana Cláudia Bezerra de Albuquerque Borborema de Andrade. –
 2021.
 115 f.: il., figs., tabs.

 Orientadora: Profa. Dra. Andrea Flávia Tenório Carneiro.
 Coorientador: Prof. Dr. Daniel Carneiro da Silva.
 Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG.
 Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da
 Geoinformação, Recife, 2021.
 Inclui referências, apêndices.

 1. Engenharia cartográfica. 2. Mobilidade urbana. 3. Disseminação da
 COVID-19. 4. Risco associado à COVID-19. 5. Mapas de duas variáveis.
 I. Carneiro, Andrea Flávia Tenório (Orientadora). II. Silva, Daniel Carneiro
 da (Coorientador). III. Título.

UFPE

526.1 CDD (22. ed.)

BCTG/2021-244

ANA CLÁUDIA BEZERRA DE ALBUQUERQUE BORBOREMA DE ANDRADE

**UMA ABORDAGEM CARTOGRÁFICA DO RISCO DE ESPALHAMENTO DA
COVID-19 EM RECIFE-PE**

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do título de Mestra em Ciências Geodésicas e Tecnologias da Geoinformação. Área de concentração: Ciências Geodésicas e Tecnologias da Geoinformação

Aprovada em: 27/05/2021.

BANCA EXAMINADORA

Profa. Dra. Andrea Flávia Tenório Carneiro (Orientadora)
Universidade Federal de Pernambuco

Prof. Dr. Neison Cabral Ferreira Freire (Examinador Externo)
Fundação Joaquim Nabuco, Instituto de Pesquisas Sociais, Centro Integrado de
Estudos Georreferenciados para a Pesquisa Social

Dra. Márcia Cristina de Souza Matos Carneiro (Examinadora Externa)
Instituto Brasileiro de Geografia e Estatística, Unidade Estadual de Pernambuco

Dedico este trabalho ao meu marido, parceiro e amigo, Henrique, que sempre me apoiou. E também ao meu filho, Heitor, que suportou minha ausência em muitos momentos.

AGRADECIMENTOS

Primeiramente gostaria de agradecer a Deus, pela saúde e oportunidade.

Ao meu esposo Henrique, pela dedicação, confiança e estímulo permanente. À minha irmã Duda, pelo exemplo. E aos meus pais, pelo apoio fornecido em mais esta jornada.

Ao 3º Centro de Geoinformação, Organização Militar subordinada à Diretoria de Serviço Geográfico, que compreendeu os horários de estudo e possibilitou o cumprimento dos créditos.

Agradeço também à minha orientadora a Profa. Dra. Andrea Flávia Tenório Carneiro, por aceitar conduzir o meu trabalho de pesquisa. À Profa. Dra. Lucilene Antunes Correia Marques de Sá, pela amizade e apoio no decorrer de minha formação acadêmica. E ao Prof. Jorge Ubirajara Pedreira Júnior da Escola Politécnica da Universidade Federal da Bahia (EPUFBA), pelas orientações e esclarecimentos prestados.

Aos amigos e colegas do mestrado, desejo-lhes sorte e espero que tenham sucesso em suas vidas.

Por último, quero agradecer também ao Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação (PPGCGTG), da Universidade Federal de Pernambuco (UFPE) e todo o seu corpo docente.

RESUMO

Entender os relacionamentos existentes entre os serviços disponíveis e acessíveis em uma sociedade sob a ótica da mobilidade e controle urbano, vem por fornecer aos governantes meios para uma adequada gestão da saúde pública. Embora a pandemia da COVID-19 seja global, no nível local, a COVID-19 afetou desproporcionalmente a população recifense. Para compreender o padrão das desigualdades nos efeitos da doença, o presente estudo examina o perigo potencial dos bairros do Recife em função dos fluxos de indivíduos do transporte público coletivo (motivo trabalho), do acumulado de casos no contexto epidemiológico inicial e dos índices de vulnerabilidade social e envelhecimento populacional municipal. Identificou-se agrupamentos espaciais significativos de bairros mais propensos ao espalhamento da COVID-19 em bairros com altos índices de envelhecimento e de vulnerabilidade social, ambos significativamente associados ao tráfego oriundo da Pesquisa Origem-Destino. Os resultados possibilitaram relacionar o fenômeno com essas características sociais, apontando que o tráfego de pessoas que utilizam transporte público é um importante indicador para identificar as áreas com maior risco à disseminação da COVID-19, e que requerem maiores atenções no combate à pandemia.

Palavras-chave: mobilidade urbana; disseminação da COVID-19; risco associado à COVID-19; mapas de duas variáveis.

ABSTRACT

Understanding the existing relationships between available and accessible services in a society from the perspective of mobility and urban control, comes from providing governments with the means for proper public health management. Although the COVID-19 pandemic is global, at the local level, COVID-19 has disproportionately affected the recifense population. To understand the pattern of inequalities in the effects of the disease, the present study examines the potential danger of Recife neighborhoods due to the flows of individuals from public transportation (work motive), the accumulated cases in the initial epidemiological context and the indexes of social vulnerability and municipal population aging. Significant spatial clusters of neighborhoods more prone to the spread of COVID-19 were identified in neighborhoods with high rates of aging and social vulnerability, both significantly associated with traffic from the Origin-Destination Survey. The results made it possible to relate the phenomenon with these social characteristics, pointing out that the traffic of people who use public transport is an important indicator to identify the area's most at risk for the spread of COVID-19, and that require greater attention in the fight against the pandemic.

Keywords: urban mobility; dissemination of COVID-19; risk associated with COVID-19; two variable maps.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Recorte de tela do painel da Universidade Johns Hopkins em 24/07/2020	21
Figura 2 –	Rotas de viagens aéreas e de trem de saída originário de Wuhan (China)	22
Figura 3 –	Recorte do portal GEOCOVID-19 Brasil em 24/07/2020	24
Figura 4 –	Recorte de tela do site da inloco em 24/07/2020	24
Figura 5 –	Mapa dos casos de COVID-19 com eixos de dispersão e análise do envelhecimento populacional no estado de São Paulo em 15/04/2020	25
Figura 6 –	Recorte do mapa dinâmico do acumulado de casos em Pernambuco até 22/05/2020	26
Figura 7 –	Mapa dos fluxos de internação hospitalar no NRS Sul da Bahia	27
Figura 8 –	Recorte de tela. (a) painel colaborativo em 24/07/2020; (b) mapa colaborativo Juntos Contra o Covid em 24/07/2020	28
Figura 9 –	Recorte de tela do painel Covid São Paulo em 29/07/2020	29
Figura 10 –	Recorte de tela do painel Covid Rio de Janeiro em 29/07/2020	29
Figura 11 –	Recorte de tela do painel Covid Distrito Federal em 29/07/2020	30
Figura 12 –	Recorte de tela do painel Covid Rio Grande do Sul em 29/07/2020	30
Figura 13 –	Recorte de tela. (a) Dashboard COVID 19 Maceió - Eng. de Agrimensura - CECA em 29/07/2020; (b) Painel da Unicamp em 29/07/2020	31
Figura 14 –	Recorte de tela. (a) Painel ES COVID-19 em 29/07/2020; (b) Painel COVID-19 Teresina em 29/07/2020	32
Figura 15 –	Recorte de tela do Painel Covid-19 Recife em 29/07/2020	33
Figura 16 –	Padrão espacial da rede de transporte aéreo entre os países do mundo	34
Figura 17 –	Rotas iniciais (origem nacional) de disseminação da COVID	35

Figura 18 –	Migração líquida de país para país entre 2010 e 2015	36
Figura 19 –	Infográfico da disseminação da COVID-19 no município de São Paulo em 27/05/2020	37
Figura 20 –	Dispersão da COVID-19 no estado do Paraná entre 12/03 e 12/04/2020	37
Figura 21 –	Classificação e região de influência das cidades no Paraná em 2007	38
Figura 22 –	Gráfico dos diferentes tipos de Modo de Transporte Principal, em Recife	40
Figura 23 –	Modelo conceitual de determinação do risco associado a uma vulnerabilidade	43
Figura 24 –	Mapas dos relacionamentos por condado. (a) taxa de mortalidade da doença cardiovascular entre homens; (b) densidade habitacional; (c) mapa bivariado	46
Figura 25 –	Legenda bivariada do mapa de relacionamento por condado da taxa de mortalidade da doença cardiovascular entre homens x densidade habitacional	47
Figura 26 –	Processo construtivo da legenda bivariada	48
Figura 27 –	Legenda bivariada representando um exemplo de grupo de observações em que existe uma forte relação entre as variáveis e classes	49
Figura 28 –	Representação cartográfica coroplética bivariada dos casos confirmados e do envelhecimento populacional no estado de São Paulo até 04/07/2020	49
Figura 29 –	Fluxograma geral da pesquisa	52
Figura 30 –	Mapa da área de estudo	53
Figura 31 –	Recorte da planilha dos fluxos (quantidade de viagens) da Matriz OD motivo Trabalho utilizando Transporte Público no município do Recife/PE	54
Figura 32 –	Representação cartográfica do número de passageiros que utilizam o sistema de transporte público, motivo trabalho	56
Figura 33 –	Recorte de tela do resultado da pesquisa no <i>overpass</i> turbo	57
Figura 34 –	Recorte de tela do <i>site</i> do IPEA	61

Figura 35 –	Recorte de tela do notebook no ArcGIS Pro	62
Figura 36 –	Representação das zonas de tráfego contidas no Recife	64
Figura 37 –	Recorte de tela de parte do código em python	64
Figura 38 –	Representação das UDH contidas no Recife	65
Figura 39 –	Recorte de tela de parte do código em python	65
Figura 40 –	Recorte de tela de parte do código em python	67
Figura 41 –	Recorte de tela de parte do código em python	67
Figura 42 –	Recorte de tela de parte do código em python	68
Figura 43 –	Recorte de tela de parte do código em python	68
Figura 44 –	Escolha do tipo de distribuição das variáveis, representação do processo construtivo e leitura da legenda bivariada	70
Figura 45 –	Mapa do número de casos em 23/03/2020	71
Figura 46 –	Mapa do Perigo Potencial dos bairros ao espalhamento da COVID-19	72
Figura 47 –	Ilustração do fluxo total de viagens para a zona 59	74
Figura 48 –	Ilustração do fluxo total de viagens para a zona 124	74
Figura 49 –	Mapa dos itinerários do transporte público geridos pelo Grande Recife CTM	75
Figura 50 –	Histogramas das variáveis Perigo Potencial e o índice de envelhecimento	76
Figura 51 –	Modos de transporte principal por faixa etária	78
Figura 52 –	Mapa de variáveis. (a) PP_b ; (b) Índice de Envelhecimento populacional	79
Figura 53 –	Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19 ($PP_b \times \% \text{ Idosos}$)	80
Figura 54 –	Mapa do número de casos de COVID-19 nos bairros do Recife em 23/03/2020	81
Figura 55 –	Mapa do acumulado de casos da COVID-19 nos bairros do Recife entre 23/03/20 e 31/12/20	82
Figura 56 –	Histograma do IVS	83
Figura 57 –	Modos de transporte principal por faixa de renda	84
Figura 58 –	Mapa de variáveis. (a) IVS; (b) PP_b dos bairros ao espalhamento da COVID-19	85

Figura 59 –	Rampa de estratificação da camada IVS	86
Figura 60 –	Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19 ($PP_b \times IVS$) – 5x5	87
Figura 61 –	Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19 ($PP_b \times IVS$) – 3x3	89
Figura 62 –	Mapa da variação dos casos confirmados por bairros do Recife entre os dias 10 e 25 de maio de 2020	91

LISTA DE TABELAS

Tabela 1 – <i>Ranking</i> dos bairros com maior Perigo Potencial e do número total de casos ao término da pesquisa	73
Tabela 2 – Resultados dos coeficientes de correlação	77
Tabela 3 – Percentuais de usuários por modo de transporte principal para o trabalho (> 60 anos)	78
Tabela 4 – Percentuais de usuários por modo de transporte principal para o trabalho (faixa de renda)	84
Tabela 5 – <i>Ranking</i> dos bairros com maior Risco e dos bairros com maior IVS	90

LISTA DE ABREVIATURAS E SIGLAS

AL	Alagoas
BA	Bahia
BDE	Base de Dados do Estado
CAISM	Hospital da Mulher Prof. Dr. José Aristodemo Pinotti
CECA	Campus de Engenharias e Ciências Agrárias
CECOM	Centro de Saúde da Comunidade
CIEVS	Centro de Informações Estratégicas de Vigilância em Saúde
CNM	Confederação Nacional de Municípios
CSV	<i>Comma Separated Values</i>
CTM	Consórcio de Transporte Metropolitano
CTTU	Companhia de Trânsito e Transporte Urbano
D.A.D.O	Dados e Análises para Decisões Operacionais
EPUFBA	Escola Politécnica da Universidade Federal da Bahia
Fiocruz	Fundação Oswaldo Cruz
GDF	Governo do Distrito Federal
GeoJSON	<i>JavaScript Object Notation</i>
Gepag	Grupo de Estudos e Pesquisa Ambiente, Sociedade e Geotecnologias
HC	Hospital das Clínicas
HES	Hospital Estadual Sumaré
HIV	Vírus da Imunodeficiência Humana
HRP	Hospital Regional Piracicaba
IBGE	Instituto Brasileiro de Geografia e Estatística
ICPS	Instituto da Cidade Pelópidas Silveira
IDE	Infraestrutura de Dados Espaciais
IDH	Índice de Desenvolvimento Humano
IE	Instituições de Ensino
IG	Informação Geográfica
IPEA	Instituto de Pesquisa Econômica Aplicada
IVS	Índice de Vulnerabilidade Social
MS	Ministério da Saúde
NRS	Núcleo Regional de Saúde
OD	Origem-Destino

ODS	Objetivo de Desenvolvimento Sustentável
OMS	Organização Mundial de Saúde
ONU	Organização das Nações Unidas
OSM	<i>OpenStreetMap</i>
PCR	Prefeitura da Cidade do Recife
PDF	<i>Portable Document Format</i>
PE	Pernambuco
PI	Piauí
RJ	Rio de Janeiro
RMR	Região Metropolitana do Recife
RPA	Região Político Administrativa
RS	Rio Grande do Sul
SARG	Síndrome Respiratória Aguda Grave
SARS	Síndrome Respiratória Aguda
SARS-CoV-2	<i>Severe Acute Respiratory Syndrome Coronavirus</i>
SES	Secretaria Estadual de Saúde
SIG	Sistemas de Informações Geográficas
UDH	Unidade de Desenvolvimento Humano
UEM	Universidade Estadual de Maringá
UFBA	Universidade Federal da Bahia
UFPR	Universidade Federal do Paraná
Unesp	Universidade Estadual Paulista
UTI	Unidade de Tratamento Intensivo
XML	<i>eXtensible Markup Language</i>
ZIKV	Zika vírus

SUMÁRIO

1	INTRODUÇÃO	17
1.1	OBJETIVOS	18
1.1.1	Objetivo Geral	19
1.1.2	Objetivos Específicos	19
2	FUNDAMENTAÇÃO TEÓRICA	20
2.1	A ESPACIALIZAÇÃO DA PANDEMIA	20
2.2	TIPOS DE MOBILIDADE E FATORES QUE FAVORECEM A PROPAGAÇÃO	33
2.3	O RISCO DE DISSEMINAÇÃO DE DOENÇAS	41
2.4	REPRESENTANDO O RISCO	44
3	MATERIAIS E MÉTODOS	51
3.1	MATERIAIS UTILIZADOS DURANTE A PESQUISA	51
3.2	PROCEDIMENTOS METODOLÓGICOS	51
3.2.1	Definição da área de estudo	52
3.2.2	Coleta dos Dados	53
3.2.2.1	Aquisição dos bairros	53
3.2.2.2	Aquisição dos fluxos e zonas de tráfego	54
3.2.2.3	Aquisição do sistema viário	56
3.2.2.4	Aquisição do número de casos da doença	58
3.2.2.5	Aquisição dos indicadores socioeconômicos	59
3.2.3	Processamento dos dados	62
3.2.3.1	Preparação do Ambiente	62
3.2.3.2	Transformação dos Dados	63
3.2.3.3	Determinação do Risco (Rv)	68
3.2.4	Método de estratificação das variáveis e representação do Risco (Rv)	69
4	RESULTADOS E DISCUSSÕES	71
4.1	ANÁLISE DOS BAIRROS MAIS SUSCETÍVEIS AO RISCO DE DISSEMINAÇÃO DA COVID-19 EM FUNÇÃO DO ÍNDICE DE ENVELHECIMENTO ($PP_b \times \% \text{ Idosos}$)	76
4.1.1	Análise estatística	76

4.1.2	Análise gráfica	79
4.2	ANÁLISE DOS BAIRROS MAIS SUSCETÍVEIS AO RISCO DE DISSEMINAÇÃO DA COVID-19 EM FUNÇÃO DO ÍNDICE DE VULNERABILIDADE SOCIAL (PP_b x IVS)	82
4.2.1	Análise estatística	83
4.2.2	Análise gráfica	85
5	CONCLUSÕES E RECOMENDAÇÕES	92
	REFERÊNCIAS	95
	APÊNCICE A – CÓDIGO <i>PYTHON</i> DA METODOLOGIA	106
	APÊNDICE B – DADOS DAS DISTRIBUIÇÕES	113

1 INTRODUÇÃO

A pandemia da COVID-19, causada pelo novo coronavírus, *Severe Acute Respiratory Syndrome Coronavirus – 2* (SARS-CoV-2), requereu da comunidade Geo o rápido desenvolvimento de novas ferramentas para análise e visualização de dados geoespaciais e tabulares que auxiliassem no acompanhamento da evolução no número de casos. E, por meio da compreensão de que a disseminação da COVID-19 é provocada pela interação humana, ou seja, transmissível de pessoa a pessoa, denota-se esta transmissibilidade como sendo um processo dinâmico e complexo, orientado por redes, onde a complexidade da mobilidade urbana dificulta o desenvolvimento de estratégias eficazes para contenção e mitigação no curso do tempo que é imposto pela velocidade em que o vírus se espalha.

Neste ponto, reconhece-se o impacto que os sistemas de transportes e a gestão da mobilidade têm sobre a disseminação da doença, e a importância que deve ser dada ao estudo desse processo de transmissão, dentre outros fatores como por exemplo, o acesso da comunidade aos serviços essenciais, e enfatiza-se sua significativa contribuição ao que tange a elaboração de políticas públicas. Sendo assim, a presente pesquisa tem por objetivo determinar o risco de disseminação da COVID-19, utilizando o transporte público coletivo como veículo de espalhamento desta.

Sendo assim, em função de como a doença se espalha, inicialmente, a acessibilidade decorrente da abundância de voos propiciou sua rápida disseminação da China para todo o globo. Semelhantemente ao que ocorreu em 2002, em dezembro de 2019, iniciou-se na China um surto da Síndrome Respiratória Aguda Grave (SARS) (ZHANG et al., 2021). Enquanto que no Brasil, em 25 de fevereiro de 2020 na capital Paulista foi identificado o primeiro caso da doença (BRASIL, 2020a).

Já a capital Pernambucana, área de estudo do presente trabalho, se deu inserida neste cenário de surto em 12 de março de 2020, quando surgiram os dois primeiros casos. Diante desta conjuntura epidemiológica inicial, a Secretaria de Saúde da Prefeitura do Recife passou a disponibilizar relatórios diários com o número total de casos da doença por bairro. Assim, a partir do acumulado de casos até 23/03/2020, buscou-se identificar e compreender a propensão dos bairros recifenses aos casos da doença.

Contudo, a fim de identificar o relacionamento existente entre a propagação do número de casos e o tráfego oriundo do transporte público coletivo, o presente estudo científico estimou o potencial de absorção do número de casos da doença, e identificou quais os bairros do Recife que seriam mais afetados. Para tanto, a partir da análise dos dados de tráfego diário fornecidos pelo Instituto das Cidades Pelópidas Silveira (ICPS), verificou-se o padrão de viagens do grupo de indivíduos que utilizam o transporte público coletivo para se locomoverem para o trabalho.

Nesse contexto, o presente trabalho explana a metodologia utilizada para a identificação dos bairros recifenses mais vulneráveis e do processo de construção dos mapas coropléticos bivariados.

Segundo a Confederação Nacional de Municípios (CNM), a mobilidade urbana é apresentada como tema transversal em todos os Objetivo de Desenvolvimento Sustentável (ODS) da Agenda 2030 da Organização das Nações Unidas (ONU) no Brasil, com o intuito que ampliar a visualização dos impactos e qualificar os debates e integração dos objetivos e metas (CNM, 2021). E, nesse âmbito, o presente estudo científico está alinhado com o ODS 3 (boa saúde e bem-estar), Meta 3.d (reforçar as capacidades locais para o alerta precoce, redução e gerenciamento de emergências e riscos nacionais e globais de saúde).

A dissertação está estruturada em cinco partes: Na primeira seção tem-se a **Introdução**, na qual se faz uma breve contextualização do tema estudado, como também apresenta a hipótese aqui elencada e os objetivos propostos. Na segunda seção, tem-se o **Embasamento Teórico** que apresenta uma revisão de literatura e engloba os principais conceitos abordados neste estudo. Em seguida expõe-se a terceira seção, **Materiais e Métodos**, na qual explana-se os materiais e métodos empregados neste estudo. A quarta seção exhibe os **Resultados e Discussões**, na qual aborda-se o método escolhido e discorre-se sobre sua congruência. Finalmente, na última seção, estão as **Conclusões e Recomendações** para quaisquer pesquisas futuras.

1.1 OBJETIVOS

Para atingir os objetivos propostos neste estudo científico, é apresentado o estado da arte das tendências em tecnologias da Geoinformação no tocante a espacialização da pandemia, e é realizada uma investigação sobre a correlação

existente entre o potencial de disseminação da doença e indicadores sociais por meio do reconhecimento de dois padrões em um único mapa.

1.1.1 Objetivo Geral

Investigar o risco da disseminação da COVID-19 nos bairros do município do Recife – PE, Brasil, em função da mobilidade urbana e dos Índice de Vulnerabilidade Social e de Envelhecimento populacional, como um subsídio ao desenvolvimento de planos de gestão sustentável para a redução do risco da disseminação de pandemias.

1.1.2 Objetivos Específicos

- Analisar o impacto da mobilidade urbana na disseminação da COVID-19.
- Analisar o Perigo Potencial de disseminação da COVID-19 em função dos bairros onde ocorreram os primeiros casos e do fluxo de pessoas que utilizam o transporte público coletivo para trabalhar.
- Determinar e representar cartograficamente o risco de disseminação da COVID-19 em função da mobilidade por transporte público coletivo em Recife-PE.
- Determinar e representar cartograficamente o risco de disseminação da COVID-19 em função dos índices de envelhecimento e de vulnerabilidade dos bairros de Recife-PE.
- Fornecer dados científicos para subsídio à gestão sustentável na redução do risco da disseminação de pandemias do município do Recife.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentado o referencial teórico do estudo realizado. São expostos trabalhos técnicos e científicos pertinentes à pesquisa.

2.1 A ESPACIALIZAÇÃO DA PANDEMIA

A partir dos primeiros casos confirmados do novo coronavírus, diversas instituições de pesquisa e ensino, iniciaram, intensivamente, a espacialização da pandemia, por meio de mapas estáticos e dinâmicos, *dashboards* (aplicativos de painel) e *SIG Web* (JOHNS HOPKINS UNIVERSITY AND MEDICINE, 2021; MAPBIOMAS, 2021). Com a difusão das geotecnologias, bem como, com a popularização de Sistemas de Informações Geográficas (SIG) livres, a exemplo o software QGIS, ocorreu o favorecimento da produção de mapas em larga escala, devido a visibilidade dada ao tema.


Esses mapas, diariamente, tentam acompanhar a evolução da pandemia no Brasil e no mundo (CASTRO et al., 2021), de forma a monitorar os números de confirmados, recuperados e óbitos, e a velocidade com que o vírus se espalha territorialmente. E, a partir da publicidade diária de dados oficiais, atribui-se aos mapas um caráter volátil, traço da constante necessidade do Poder Público e da sociedade que requer a atualização desses mapas.

Essa volatilidade modificou a forma de publicação de produtos cartográficos. Os desenvolvedores de SIG passaram a disponibilizar seus mapas por intermédio de aplicativos online, e projetar aplicativos de software que operam com *big data* de maneira amigável ao usuário (FRANCH-PARDO et al., 2020). Na busca por integrar estes dados, o rastreamento histórico e o mapeamento dinâmico das variáveis espaço-temporais em várias escalas passaram a ser inestimáveis (ZHOU et al., 2020). Segundo Lee e Kang (2015), o futuro ainda trará um volume muito maior de informações, onde a produção de dados geoespaciais aumentaria em pelo menos 20% a cada ano. Fato que ficou expresso nos últimos anos com a evolução das técnicas de aquisição, processamento e representação de dados.

Foi o painel da Universidade *Johns Hopkins* que atraiu a atenção generalizada do público e profissionais para essa temática. O painel apresenta, em tempo real, o número de infecções, fatalidades e recuperações por região, o que veio por auxiliar

as autoridades de saúde pública e emergência na tomada de decisões, em como, por exemplo, encerrar eventos ou atrações populares e pedir às pessoas que praticassem o distanciamento social, de forma a restringir o surto (Figura 1).

Figura 1 - Recorte de tela do painel da Universidade Johns Hopkins em 24/07/2020



Fonte: JOHNS HOPKINS UNIVERSITY AND MEDICINE (2021).


Destarte, as necessidades de pesquisa passaram a incluir a capacidade de cruzar variáveis de diferentes tipos para interpretar a doença, sua análise espacial e dimensões espaço-temporais; seu impacto geográfico na tomada de decisão e na vida cotidiana; e na modelagem preditiva da evolução do número de casos (FRANCH-PARDO et al., 2020). Consequentemente, o uso de ferramentas geoespaciais e estatísticas tornou-se particularmente relevante no combate da pandemia.

Seja através do mapeamento de casos, da expansão da pandemia, do mapeamento das populações mais vulneráveis ou dos equipamentos e serviços, para o entendimento dos impactos atuais e potenciais do novo coronavírus, a comunidade cartográfica deparou-se com a urgência da situação. Mapas estáticos e com dados antigos passaram a ser insuficientes. Para tanto, a Informação Geográfica (IG) passou a ser comunicada por meio de mapas da web interativos e dashboards para ajudar rapidamente na comunicação do cenário atual para que todos tenham conhecimento. Mapeamento epidemiológico, desenvolvimento de plataformas de *big data* para a operação de vários centros de prevenção e controle do surto, e painéis para exibir visualmente esses dados, tornaram-se as principais ferramentas nos processos de tomada de decisão.

Desjardins, Hohl e Delmelle (2020), fornecem um grande número de métodos sobre a dinâmica da transmissão espacial que possibilitem o feedback efetivo ao Poder Público e à sociedade. Coccia (2020), por sua vez, propõe melhorar as estimativas do número de infecções, detectar possíveis novos surtos e, assim, facilitar intervenções mais bem-sucedidas em saúde pública; Kuupiel et al. (2020), buscam melhorar a localização dos serviços e controles de saúde, pontos de atendimento e facilitar o acesso, o que se traduz em uma melhoria nos resultados dos pacientes, tempo e recursos materiais; já Chan, Skali e Torgler (2020) e Mollalo, Vahedi e Rivera (2020), empenharam-se em entender e mapear o movimento humano e formular medidas científicas, políticas e sociais apropriadas; por fim, Giuliani et al. (2020) tentaram prever a disseminação espacial e as tendências temporais do surto, essenciais para os serviços de saúde. Todos estudos voltados a compreender como as mais variadas variáveis geográficas poderiam vir a auxiliar no enfrentamento da COVID-19.

A epidemia causada pelo SARS-CoV-2, teve origem na cidade de Wuhan – China, em dezembro de 2019, e se disseminou rapidamente nacional e globalmente. Wu, Leung e Leung (2020) apresentam um estudo que prevê a potencial expansão nacional e internacional do vírus. No mapa (Figura 2), as linhas mais escuras e grossas representam maior número de passageiros e consequentemente as possibilidades para disseminação da COVID-19.

Figura 2 - Rotas de viagens aéreas e de trem de saída originário de Wuhan (China)



Fonte: Wu, Leung e Leung (2020).

Musselwhite, Avineri e Susilo (2020) afirmam que devido à hipermobilidade de nosso estilo de vida atual, à globalização e à conectividade e acessibilidade de Wuhan, o primeiro epicentro, ocorreu a rápida disseminação da doença, tornando-a numa pandemia mundial em questão de semanas.

Desde então, a IG vem sendo explorada e utilizada como ferramenta para o entendimento do surto no Brasil e no mundo, quer seja no monitoramento de casos, óbitos ou recuperados; na análise de áreas de contaminação; no mapeamento de vulnerabilidade ao vírus; no gerenciamento da capacidade de atendimento; na identificação de áreas que precisam de atenção por parte da gestão pública; ou no mapeamento do espalhamento dos casos, tal qual este estudo.


No entanto, a pandemia evidenciou as deficiências na forma como a IG é utilizada na saúde pública. Essa crise revelou o desequilíbrio existente entre o potencial de espalhamento do vírus e a disponibilidade dos serviços de saúde (ANDERSON et al., 2020; BUCKEE et al., 2020; FORTALEZA et al., 2020; FORTALEZA et al., 2020; JELOKHANI-NIARAKI, 2021; KRAEMER et al., 2020; MARTÍN-CALVO et al., 2020; PEPE et al., 2020; WANG, F., 2020; WU, LEUNG e LEUNG, 2020).

Desde o início do surto, a pandemia está sendo espacializada pelos mais variados profissionais independentes, empresas privadas, órgãos públicos e instituições de pesquisa e ensino. Estudiosos e especialistas das mais diversas áreas concentraram esforços para o desenvolvimento de pesquisas que favorecessem a análise das características do vírus e de sua transmissão.

Quer seja no monitoramento do progresso de casos ou na predição e análise de tendência da propagação da pandemia, os mapas elaborados neste hiato convergiram para espacialização de tópicos específicos:

- **Estimativa de novos casos.** As estimativas representam a propagação da doença com e sem supressão de fluxo de pessoas (Figura 3 – portal com as estatísticas da pandemia, apresenta projeções de casos ativos e acumulados, e demanda do número de leitos para todo o país, com e sem suspensão de fluxo; elaborado por uma rede interinstitucional que reúne instituições acadêmicas e empresas).


Figura 3 - Recorte do portal GEOCOVID-19 Brasil em 24/07/2020



Fonte: UEFS (2020).

- **Análise do índice de isolamento social.** A Figura 4 apresenta um recorte de tela onde o percentual populacional ilustrado, indica os indivíduos que estão respeitando as recomendações de isolamento social. A partir deste indicador, as autoridades podem direcionar recursos de saúde, segurança e comunicação inloco (2020).


Figura 4 - Recorte de tela do site da inloco em 24/07/2020



Fonte: inloco (2020).

- **Mapas estáticos.** Esses abordam a pandemia com métodos clássicos da cartografia temática. Como exemplo, os elaborados pelos Departamentos de Engenharia Cartográfica e de Agrimensura e de Geografia da Universidade Estadual Paulista – Unesp (e. g. Figura 5 - mapa dos casos de COVID-19).


Figura 5 - Mapa dos casos de COVID-19 com eixos de dispersão e análise do envelhecimento populacional no estado de São Paulo em 15/04/2020



Fonte: Guimarães e Pugliesi (2021).

- **Acumulados de novos casos.** A Figura 6 apresenta um mapa coroplético do acumulado de casos confirmados da COVID-19 por município do estado de Pernambuco até 22/05/2020, criado pelo projeto de pesquisa COVIDecart do Departamento de Engenharia Cartográfica e de Agrimensura e pelo Programa de Pós-Graduação em Ciências Geodésicas e Tecnologias da Geoinformação – Universidade Federal de Pernambuco).


Figura 6 - Recorte do mapa dinâmico do acumulado de casos em Pernambuco até 22/05/2020



Fonte: DECART (2020).

- **Impacto na mobilidade e análise da demanda por serviços de saúde.** A Figura 7 ilustra um mapa dinâmico, o qual representa os fluxos das internações x vulnerabilidade social *versus* respiradores do Núcleo Regional de Saúde – NRS, Sul do estado da Bahia até 24/04/2020; GeoCombate COVID-19 BA – Universidade Federal da Bahia.


Figura 7 - Mapa dos fluxos de internação hospitalar no NRS Sul da Bahia



Fonte: GEOCOMBATE COVID-19 BA (2020).

- Mapeamento colaborativo.** Mapas colaborativos também contribuíram para a espacialização da pandemia, a exemplo da iniciativa cita-se: o painel da COVID-19, Figura 8a, desenvolvido por uma equipe multidisciplinar, cuja iniciativa é ajudar os governos e a população, na escala intramunicipal, a ter informações e possibilita a contribuição de qualquer pessoa desde que seja preenchido um formulário; e o mapa do projeto Juntos Contra o Covid, Figura 8b, criado por um estudante de medicina da Universidade Federal do Paraná – UFPR, com o intuito de possibilitar ao cidadão o acesso à informação de número de casos em uma determinada rua. O mesmo é alimentado por formulários respondidos anonimamente pela internet.

Figura 8 - Recorte de tela. (a) painel colaborativo em 24/07/2020; (b) mapa colaborativo Juntos Contra o Covid em 24/07/2020



Fonte: (a) PIRES et al. (2020); (b) HAJAR (2020).

Segundo a Fundação Oswaldo Cruz – Fiocruz, os dados coletados pelo projeto Juntos Contra o Covid, apesar de não serem baseados em dados de órgãos públicos, apresentam tendências parecidas com as apontadas em informações oficiais. Os dados disponibilizados no portal foram validados pelo MS e pela Fiocruz.

- **Dashboards.** A fim de acompanhar essa dinâmica na visualização de dados e agrupá-los em um portal, alguns Estados criaram *dashboards* contendo os números de novos casos, óbitos e recuperados por meio de mapas dinâmicos, gráficos e relatórios. As figuras 9, 10, 11 e 12 ilustram alguns exemplos. Os painéis espacializam dados de casos confirmados, óbitos, recuperados (por etnia, faixa etária e sexo), hospitalizações, taxa de ocupação de leitos de UTI, número de municípios infectados,


bem como mapas com indicação de risco associado ao distanciamento social, entre outros dados.

Figura 9 - Recorte de tela do painel Covid São Paulo em 29/07/2020




Fonte: ALVES et al. (2020).

Figura 10 - Recorte de tela do painel Covid Rio de Janeiro em 29/07/2020




Fonte: SES-RJ (2020).

Figura 11 - Recorte de tela do painel Covid Distrito Federal em 29/07/2020



Fonte: GDF (2020).


Figura 12 - Recorte de tela do painel Covid Rio Grande do Sul em 29/07/2020



Fonte: SES/RS (2020).

A Figura 13a apresenta um mapa interativo que monitora o avanço da pandemia na cidade de Maceió/AL em tempo real, por meio de um *dashboard*; já a figura 13b apresenta o mesmo tipo de mapa que acompanha também os casos de COVID-19 nos hospitais de Campinas (HC-CAISM-CECOM), Sumaré (HES) e Piracicaba (HRP).


Figura 13 - Recorte de tela. (a) Dashboard COVID 19 Maceió - Eng. de Agrimensura - CECA em 29/07/2020; (b) Painei da Unicamp em 29/07/2020



Fonte: (a) CECA/UFAL (2020); (b) UNICAMP (2020).

A Figura 14a apresenta o Painel Covid do Espírito Santo e Figura 14b o Painel Covid Teresina/PI. Em ambos os casos, o painel centraliza a coleta dos dados em tempo real sobre casos, locais de teste, instalações médicas e estoque, e capacidade dos principais recursos, e espacializar essas informações em mapas interativos, o que possibilita realizar a análise desses dados de maneira a identificar onde os recursos são necessários e priorizar intervenções, e responder à sociedade, comunicando suas ações.

Figura 14 - Recorte de tela. (a) Painel ES COVID-19 em 29/07/2020; (b) Painel COVID-19 Teresina em 29/07/2020




Fonte: (a) SES/ES (2020); (b) FMS (2020).

Com a finalidade de apoiar o desenvolvimento de pesquisas de mapeamento da pandemia, a ESRI disponibilizou licença gratuita do ArcGIS Pro para organizações dos setores público e privado que lutam contra a pandemia da doença até o final do ano de 2020. Durante este período, o estudante que fizesse seu cadastro teria acesso ao ArcGIS Hub, a tutoriais, recursos e vídeos, sem qualquer custo, e fazer uso do aplicativo para desenvolver produtos relacionados à temática.

O D.A.D.O – Dados e Análises para Decisões Operacionais (Figura 15), é mais um exemplo de plataforma concebida com o auxílio das ferramentas da ESRI. Criada pelo Porto Digital, para facilitar e instrumentar a tomada de decisão sobre qualquer operação de interesse da cidade, o painel possibilita identificar o Risco da Cidade – calculado a partir da análise de índices do sistema de saúde, como a ocupação de

UTI e progressão de casos e óbitos por COVID-19, índice de isolamento social e outros (Prefeitura da Cidade do Recife - PCR, 2020).

Figura 15 - Recorte de tela do Painel Covid-19 Recife em 29/07/2020




Fonte: PCR (2020).

Contudo, a pandemia do COVID-19 é repleta de incógnitas, e muitas delas possuem uma dimensão espacial, o que leva a compreender o fenômeno como geográfico e potencialmente mapeável (FRANCH-PARDO et al., 2020).

2.2 TIPOS DE MOBILIDADE E FATORES QUE FAVORECEM A PROPAGAÇÃO

Segundo Nitahara (2020), pesquisadores da Fundação Oswaldo Cruz (Fiocruz) que trabalham no sequenciamento do genoma do novo coronavírus descobriram que as cepas que circulam no Brasil se assemelham às encontradas na Europa, na América do Norte e na Oceania. Logo, a descoberta indica que o patógeno que causa a doença chegou ao país por avião. A Figura 16 ilustra esse comportamento, Coelho et al. (2020), mapearam o padrão espacial da rede de transporte aéreo entre os 44 países que tiveram mais de 100 casos e para os quais os dados de séries temporais tiveram pelo menos dez dias após o 100º caso, e a escala de cores representa as diferentes taxas de crescimento do COVID-19 em cada país.

Figura 16 - Padrão espacial da rede de transporte aéreo entre os países do mundo




Fonte: Coelho et al. (2020).

Candido et al. (2020), realizaram estudo similar e identificaram o percentual de tráfego de passageiros nas vinte principais rotas de voos internacionais para aeroportos brasileiros.

No estudo, Candido et al. (2020), evidenciam que a proporção de casos importados estimados por aeroporto de destino está altamente correlacionada com a proporção de casos importados detectados. Já Pereira et al. (2020), identificaram as rotas iniciais de importação e disseminação do vírus no Brasil (Figura 17) com base nos primeiros registros oficiais da doença e do quantitativo de passageiros nos vinte aeroportos com maior número de embarques no ano de 2019. No estudo, discute-se a hipótese de que os fluxos de pessoas e mercadorias direcionados pela centralidade exercida, principalmente por São Paulo e Rio de Janeiro, podem ter contribuído com a disseminação da doença para parte dos estados da região Norte e Nordeste, que registraram casos da doença apenas mais tardiamente, como foi o caso dos estados de Rondônia, Roraima, Amapá e Maranhão. A pesquisa ainda destaca que o processo é semelhante ao que ocorreu em escala internacional a partir do Reino Unido, de onde o vírus foi disseminado para vários países da Europa e Américas.

Figura 17 - Rotas iniciais (origem nacional) de disseminação da COVID




Fonte: Pereira et al. (2020).

A compreensão da disseminação da doença, deve-se ainda acrescentar a dinâmica advinda do sistema de transporte hidroviário, colocando este meio de mobilidade também como um meio propagador para a disseminação da COVID-19.

Essa variedade de modais vem por tornar ainda mais complexo o estudo dos fluxos de viagens, possibilitando que a análise do impacto destes sobre a dinâmica da sociedade, ainda sob a ótica espacial, figure-se como uma importante ferramenta no auxílio da gestão de crises. Dados de migração, por exemplo, possibilitam compreender quão ativa e heterogênea essa análise. A Figura 18 ilustra um exemplo de mapeamento da migração líquida estimada por país de origem e destino entre os anos de 2010 e 2015, com base nos dados da Divisão de População da Organização das Nações Unidas – ONU. Na figura, os círculos azuis indicam que há migração líquida positiva (mais entradas), já os círculos vermelhos apontam que há migração líquida negativa (mais fluxos de saída). Cada ponto amarelo representa 1.000 pessoas.

Figura 18 - Migração líquida de país para país entre 2010 e 2015




Fonte: Galka (2020).

No Brasil, as rotas iniciais de disseminação desse vírus estiveram relacionadas, predominantemente, aos fluxos aéreos uma vez que 66,7% dos estados brasileiros tiveram primeiros casos relacionados a pessoas com o histórico de viagem internacional (PEREIRA et al., 2020). Sendo estas posteriormente substituídas pelas rodovias, logo após a redução de voos no país em função do Decreto nº 10.282, de 20 de março de 2020 (BRASIL, 2020b) que define os serviços públicos e as atividades essenciais.

Um estudo realizado pela Universidade Estadual Paulista por intermédio do mapeamento das rotas de dispersão da doença no estado de São Paulo (Figura 19), possibilita a análise de que o direcionamento da disseminação do vírus, em que posteriormente à concentração na região metropolitana, segue em direção ao interior do estado seguindo a rede de transportes.


Figura 19 - Infográfico da disseminação da COVID-19 no município de São Paulo em 27/05/2020



Fonte: Guimarães e Pugliesi (2021).

Parizotto (2020) apresenta um estudo realizado pelo Grupo de Estudos e Pesquisa Ambiente, Sociedade e Geotecnologias – Gepag, da Universidade Estadual de Maringá – UEM, no qual aponta essa mesma tendência no estado do Paraná. A pesquisa revelou que o direcionamento da dispersão da doença está vinculado à organização das principais rotas paranaenses (Figura 20).

Figura 20 - Dispersão da COVID-19 no estado do Paraná entre 12/03 e 12/04/2020




Fonte: Parizotto (2020).

Analisando o avanço territorial do número de casos do COVID-19, estima-se que a interrupção do transporte público, seria uma forma de bloquear o espalhamento do vírus, uma vez que, conforme o Ministério da Saúde – MS (2020), a transmissão ocorre de pessoa para pessoa.

Anteriormente à pandemia, Ferreira (2011) desenvolveu um estudo com o objetivo de classificar e identificar as regiões de influência das cidades paranaenses em 2007, evidenciando a dinamicidade a que a região metropolitana está sujeita, considerando as informações de fluxos materiais e imateriais, e esclarecendo a articulação das redes no território (Figura 21).

Figura 21 - Classificação e região de influência das cidades no Paraná em 2007



Fonte: Ferreira (2011).

O estudo de modelos para determinar a disseminação de epidemias permite descrever a propagação de uma doença em larga escala, e possibilita afirmar a influência dos fluxos de viagens de indivíduos sob essa propagação. Gautreau, Barrat e Barthélemy (2008), utilizando argumentos analíticos e numéricos, demonstraram que a partir da análise de dados da rede aeroportuária, podia-se prever o espalhamento global de doenças com estimativa dos horários de chegada destas às mais variadas localidades. Estudos semelhantes foram desenvolvidos por Brockmann e Helbing (2013) e Iannelli et al. (2017).

Diversas são as abordagens nessa temática, Rvachev e Longini (1985) apontaram uma abordagem de modelagem da difusão epidêmica global. Enquanto

que Longini (1988), Grais, Ellis e Glass (2003) e Brownstein, Wolfe e Mandl (2006), discutem sobre o comportamento de surtos específicos, como influenza pandêmica, HIV ou SARS, sob essa ótica do estudo de tráfego.

Segundo Iannelli et al., (2017), no contexto da disseminação de epidemias, a previsão de surtos tornou-se particularmente importante para questões de Saúde Pública. Com o aumento dos meios de transporte e da dinâmica dos tráfegos, aumentou o risco de disseminação de doenças emergentes globais como a Influenza A – H1N1 – gripe suína, Síndrome Respiratória Aguda – SARS ou Ebola vírus – EBOV e, mais recentemente, o Zika vírus – ZIKV (COLIZZA et al., 2007; YANG et al., 2009; POLETTTO et al., 2014).

Todas essas doenças, oriundas da transmissão do coronavírus possuem a mesma particularidade, são transmissíveis. E, sua transmissão acontece de uma pessoa doente para outra ou por contato próximo. López-Olmedo et al., (2020), por meio de uma revisão da literatura, concluíram que existe um aumento na probabilidade de infecções respiratórias associadas ao uso do transporte público. Silva et al. (2020) apontaram em estudo de caso realizado sobre a correlação existente entre os casos de COVID-19 e a utilização do sistema de transporte público, que a incidência de contágio viral da influenza A ou B foi 54% maior em pessoas que utilizam frequentemente o transporte público em comparação com pessoas que não utilizam frequentemente o serviço. E, no que diz respeito à disseminação da COVID-19, o fluxo seja em largas escalas (nível global), nível regional ou local, deve ser estudado sob a dinâmica dos sistemas de transportes e da gestão da mobilidade, atribuindo assim demasiada importância à pesquisa.


O desenvolvimento de um plano de mobilidade urbana requer uma série de pesquisas. Dentre estas, destaca-se a Pesquisa de Origem-Destino de Pessoas, também conhecida como Pesquisa OD.

Segundo a PCR (2015), a Pesquisa OD é realizada com o interstício de dois anos e é considerada a base para o planejamento do sistema de transporte público, tais quais: definição de linhas de ônibus, expansão do sistema de metrô, definição da operação do sistema de navegabilidade dos rios Capibaribe e Beberibe, funcionamento do sistema complementar, a localização das estações de bicicletas compartilhadas e a identificação dos principais corredores caminháveis da cidade, dentre outras. E tem por objetivo, identificar os hábitos de deslocamento da população, que incluem as origens e destinos e principais características das viagens

realizadas na área observada. Onde entende-se por deslocamento como sendo os segmentos componentes de uma mesma viagem realizada por um indivíduo, por modos sucessivos distintos, em um único sentido. E viagem, como sendo o movimento em um único sentido de uma pessoa entre dois pontos, com um ou mais deslocamentos e com um propósito definido Instituto da Cidade Pelópidas Silveira – ICPS (2016).

Segundo o ICPS (2018), a pesquisa é uma importante ferramenta de coleta de informações a respeito das necessidades de mobilidade da população e é a diretriz fundamental para a reorganização de linhas de ônibus, implantação de faixas exclusivas de ônibus, estudos de expansão do metrô, implantação de ciclovias e ciclofaixas, recuperação de calçadas e mudanças na circulação do tráfego urbano, uma vez que a mesma é resultado da análise dos diferentes tipos de modo de transporte principal (Figura 22). Entende-se meio de transporte principal como sendo o deslocamento com maior duração temporal dentre os diversos deslocamentos que compõem uma viagem (ICPS, 2016).

Figura 22 - Gráfico dos diferentes tipos de Modo de Transporte Principal, em Recife



Fonte: ICPS (2018).

Portanto, entender a disseminação da doença por intermédio do uso dos sistemas de transportes públicos torna-se essencial a fim de traçar estratégias

eficazes para que haja o funcionamento adequado dos serviços essenciais (TIRACHINI e CATS, 2020). Apesar das recomendações de evitar contato a menos de dois metros com outras pessoas (OMS, 2020), Chen (2020) divulgou em estudo que pessoas viajando de ônibus podem ser infectadas por outros passageiros sentados a mais de 4,5 metros de distância, além de que o vírus permaneceu dentro do veículo por mais de 30 minutos. Segundo o MS (2020), o tempo de incubação do vírus varia de 2 a 14 dias. Sendo assim, a possibilidade de pessoas contaminadas estarem assintomáticas passa a existir, implicando no risco de que outros indivíduos venham a ser contaminados.

Dentre as medidas para reduzir a transmissão de doenças infecciosas, destacam-se o fechamento de repartições públicas, comércio, e grandes polos geradores de viagens, aumento do trabalho remoto, a suspensão total ou parcial de serviços não essenciais (HENSON, TIMMONS e MCDANIEL, 2017) e a suspensão da operação do transporte público (MO et al., 2021). Nesse sentido, Silva et al. (2020), afirmam que como consequência do distanciamento social, tem-se o atraso na disseminação de doenças contagiosas, como a COVID-19, tornando a taxa de transmissão mais lenta, dando oportunidade ao sistema de saúde de absorver a demanda de pessoas infectadas por COVID-19 e acometidas por outras comorbidades.

Logo, a compreensão e quantificação da disseminação do vírus nos sistemas de transporte público torna-se essencial para avaliar as consequências para a saúde pública, analisando-se cenários e estratégias alternativas (TIRACHINI e CATS, 2020).

2.3 O RISCO DE DISSEMINAÇÃO DE DOENÇAS

A pandemia trouxe incertezas aos mais diversos campos profissionais, cenário em que houve uma maior aceitação por parte da sociedade e mercado, de trabalhos e pesquisas que envolvam a atuação de cientistas de dados, desenvolvedores, analistas e engenheiros de dados. A análise espacial do padrão de disseminação da doença tornou-se um grande desafio para a saúde pública em todos os países, onde seu comportamento e impactos ainda são desconhecidos. Portanto, investigar seu padrão de propagação é fundamental para nortear os próximos passos para a superação desta crise (BUCKEE et al., 2020; REX, BORGES e KÄFER, 2020).

Estudar o risco relacionado à disseminação da doença, por sua vez, nos possibilita compreender a complexidade sistêmica do próprio risco. Sendo assim, torna-se necessária a reflexão sobre como essa dinâmica da sociedade contemporânea influi sob a área sanitária. Segundo Schwartz (2001), a saúde é um processo sistêmico que se relaciona com todos os demais sistemas sociais, gerando uma indeterminação latente. Logo, estudos relacionados à dinâmica espacial da doença, ou seja, como a mesma se relaciona com as características sociais, tornam-se importantes instrumentos para a Administração Pública e para a sociedade.

Em 31 de dezembro de 2020, o município do Recife, capital pernambucana, apresentava um total cumulativo de 50.997 casos e destes, 9.711 casos de Síndrome Respiratória Aguda Grave (SRAG) para COVID-19, segundo dados publicados pelo Centro de Informações Estratégicas de Vigilância em Saúde (CIEVS, 2020). Dos quais apenas 4.888 casos possuem a informação de raça ou cor, onde cerca de 70,4% do total de indivíduos com COVID-19 são negros, embora os negros representem apenas 8,16% da população recifense (BDE, 2021a). Para os demais casos (4.823) a etnia foi ignorada (CIEVS, 2020). Disparidades raciais como esta foram encontradas por Zakeri et al. (2020) e Pareek et al. (2020).

Relacionando o número de casos da doença com o sexo, destes 9.711, 51,8% são mulheres, e comparando este grupo com a população de residentes adultos com dados de etnia disponíveis, verifica-se que mulheres negras representam apenas 4,15% da população recifense (BDE, 2021a; CIEVS, 2020). Fatores de nível de vizinhança, como vulnerabilidade social, podem explicar porque os negros e outras minorias podem ser mais afetadas pela pandemia da COVID-19 do que outras raças (BIGGS et al., 2021). Além disso, 41,1% dos casos relatados de COVID-19 até 31/12/2020 ocorreram entre os indivíduos com 60 anos ou mais (CIEVS, 2020).

Pareek et al. (2020) sugerem que uma maior prevalência de privação socioeconômica (por exemplo, com moradias precárias), fatores culturais, como viver em famílias multigeracionais e trabalhar em ocupações de alto risco podem aumentar a suscetibilidade em grupos étnicos minoritários. Sendo assim, o impacto desigual da pandemia na população mais vulnerável não é surpreendente. Além das raciais, verificam-se ainda desigualdades como rendimento, acesso à saneamento, escolaridade, ocupação e meio de transporte.

Passageiros de transporte público são desproporcionalmente compostos por minorias raciais, o que pode aumentar seu risco de exposição à COVID-19

(ROLLSTON e GALEA, 2020), uma vez que existe um aumento na probabilidade de infecções respiratórias associadas ao uso do transporte público (LÓPEZ-OLMEDO et al., 2020).

Freire e Natenzon (2020) apresentam a seguinte equação para determinação do risco: $\text{Risco} = \text{Perigo} \times \text{Vulnerabilidade}$, originalmente proposta por Aragón (2011, p. 89). Os autores definem que o risco estaria diretamente envolvido com a simultaneidade dos processos naturais e das estruturas sociais.

Contudo, segundo Ayres et al. (1999), o conceito de risco na epidemiologia diz respeito às chances probabilísticas de susceptibilidade, atribuíveis a um indivíduo qualquer de grupos populacionais particularizados, delimitados em função da exposição aos agentes de interesse técnico ou científico. Ou seja, à medida que neste estudo se analisa os fluxos de indivíduos usuários do transporte público coletivo, e particulariza-se uma comunidade com vulnerabilidades, permite-se então a identificação de um determinado grupo com maiores probabilidades de exposição à COVID-19.

Portanto, torna-se necessária a compreensão do risco de espalhamento da doença relacionando-a às características sociais. A Figura 23 ilustra o diagrama conceitual da premissa adotada na determinação desse risco.

Figura 23 - Modelo conceitual de determinação do risco associado a uma vulnerabilidade



Fonte: Pereira Júnior et al. (2020).

Natenzon (2021) esquematiza a construção social do risco, considerando que o Perigo (ciências naturais), a Exposição (uso do solo e planejamento) e a Vulnerabilidade (ciências sociais) constituem o risco avaliado, e que as Incertezas (ações políticas e culturais) complementam este tornando-o gerenciável. Câmara e Davis (2004) afirmam que os mapas temáticos são instrumentos poderosos na análise espacial do risco que uma determinada doença possui. Estes possibilitam a visualização da distribuição espacial do evento, sugerindo os determinantes locais deste, e fatores etiológicos desconhecidos que possam ser formulados em termos de hipóteses, de forma a apontar associações entre um evento e seus determinantes.

Portanto, a fim de compreender como os dados sobre os determinantes sociais podem ajudar a concentrar os esforços para melhorar a saúde da comunidade, e depreender o impacto da pandemia sobre a rotina dessa comunidade, estimando o risco, expõe-se ainda a necessidade de compreender como o tráfego de seus residentes poderá afetar o espalhamento da doença.

2.4 REPRESENTANDO O RISCO

Mapas coropléticos de uma variável permitem que variáveis únicas sejam representadas em mapas separados e por meio de diferentes tonalidades ou cores, avultando sua interpretação quantitativa. A maioria desses mapas se concentra numa variável específica, com renda familiar, por exemplo, ou quaisquer índices sociais ou econômicos. Segundo Leonowicz (2006), a visualização coroplética de uma variável não é suficiente em estudos mais complexos, quando diferentes fenômenos e suas inter-relações devem ser considerados.

Compreendido como sendo um mapa estatístico, um mapa coroplético é originalmente elaborado a partir da intensidade e matiz das cores, de maneira a exprimir a progressão da variável analisada, respondendo quantitativamente: o que, quanto, onde e em que ordem. Para tanto, o uso de proporções ou taxas torna-se essencial para que haja a correta representação da variável analisada, ou seja, para uma adequada representação da variável estudada, o conjunto de dados deve ser normalizado.

Conforme Bertin (1968), toda informação a ser traduzida para a forma gráfica é composta por quatro componentes principais, sendo elas: comprimento, forma espacial, continuidade temporal e tipologia, e que, somente pela análise detalhada

destas e, pelo conhecimento das propriedades do plano, é que se é possível traduzir corretamente os dados para forma gráfica, transformando-os em IG.

A tarefa essencial da representação gráfica é transcrever as três relações fundamentais – de diversidade ($\neq$), de ordem (O) e de proporcionalidade (Q) – que se podem estabelecer entre objetos, fatos e fenômenos da realidade posta à frente do cartógrafo para sua representação em mapa, por relações visuais de mesma natureza. Assim, a diversidade será transcrita por uma diversidade visual; a ordem por uma ordem visual; a proporcionalidade por uma proporcionalidade visual (BERTIN, 1978; BORBOREMA e MARTINELLI, 2012). Uma vez que estas sejam consideradas, define-se o método de representação adequado observando o tipo da primitiva gráfica (ponto, linha ou polígono) e a percepção a ser obtida do fenômeno analisado.


O método coroplético de duas variáveis (também chamado de método coroplético bivariado), abordado neste estudo, pode ser definido como sendo uma variação de um mapa coroplético simples, que permite retratar dois fenômenos separados simultaneamente. Compreende-se que a forma da legenda do mapa é baseada em um diagrama de dispersão estatístico, em que cada eixo representa os valores de uma variável (EYTON, 1984). E o método de seleção de classe para cada variável divide a legenda retangular em caixas menores, cada uma delas representando uma relação única das variáveis (ROBINSON et al., 1995).

Fienberg (1979, p; 176), caracteriza que o método se destina a transmitir a distribuição espacial de duas variáveis e a concentração geográfica de sua relação. Entretanto, deve-se entender que os mapas mostram apenas a coincidência existente entre as distribuições, além de compreender que para criar o mapa, as duas variáveis estão relacionadas, uma vez que esse mapeamento possibilitará mostrar onde essas duas variáveis tendem a concordar ou discordar.

Segundo Meyer, Broome e Schweitzer (1975, p. 102), a ideia original para elaboração de mapas de cores de duas variáveis é atribuída ao Diretor do *U.S. Bureau of the Census*, *Vicent P. Barabba*, que, em 1974, sugeriu que dois mapas coropléticos diferentes fossem “cruzados”. A Figura 24 ilustra essa ideia, em 24a tem-se um mapa coroplético da taxa de mortalidade de doença cardiovascular entre homens de 35 a 74 anos (entre 1968 e 1971), onde o azul escuro indica altas taxas, enquanto que o amarelo baixas. A Figura 24b apresenta outro mapa que representa a proporção da população vivendo em domicílios com mais de um indivíduo por cômodo em 1970),

onde o vermelho escuro indica altas taxas, ao passo que o amarelo as baixas. A Figura 24c, apresenta o mapa bivariado criado pela sobreposição dos dois anteriores (24a e 24b). Onde percebe-se que, de fato, existe uma variação geográfica entre a distribuição da mortalidade cardiovascular masculina e densidade habitacional representada por grupos de condados contíguos.

Figura 24 - Mapas dos relacionamentos por condado. (a) taxa de mortalidade da doença cardiovascular entre homens; (b) densidade habitacional; (c) mapa bivariado




Fonte: adaptado de U.S. Bureau of the Census (1976).

O objetivo desse método é representar, monossemicamente, diferentes tipos de conjuntos de dados utilizando apenas cores. Leonowicz (2006), aborda que devido ao fato de ser difícil produzir mapas coropléticos de uma variável facilmente comparáveis, mapas de duas variáveis parecem ser uma solução razoável por intermédio da visualização coroplética bivariada, de forma a encontrar maneiras mais eficientes de visualizar as relações geográficas existentes.

Wainer (1978) sugere que para a elaboração de mapas estatísticos bivariados, inicialmente se faça mapas uni variados e que na criação dos mesmos, se utilize apenas uma cor, usando branco em vez de amarelo como a extremidade inferior em ambos. Fienberg (1979, p; 175), enfatiza que o esquema de cores da grade bivariada atribuída ao mapa do *U.S. Bureau of the Census* (Figura 24c), localizado no canto inferior direito concentra-se em atenção nos quatro cantos, enquanto que num esquema de cores projetado para medir a relação entre duas variáveis focalizariam a atenção na ou perto da diagonal, correndo da direita inferior para a esquerda superior. Dunn (1989) destaca que as cores escolhidas para o mapa da Figura 24c, foram particularmente inadequadas devido ao fato de que o esquema apresentado requer de uma lógica visual devido ao domínio dos dois subconjuntos distintos, violetas e não violetas, e a dificuldade de discriminar entre os nove tons violetas. Leonowicz (2006) por sua vez, afirma que o esquema de cores escolhido de fato carece de uma lógica visual, visto que as classes mais baixas, marcados em amarelo, destacam-se dos outros; que os tons violetas usados para classes mais altas são difíceis de discriminar; que a tonalidade verde é intuitivamente percebida como uma cor individual; e que não há uma combinação entre as cores azul e amarelo (Figura 25).

Figura 25 - Legenda bivariada do mapa de relacionamento por condado da taxa de mortalidade da doença cardiovascular entre homens x densidade habitacional




Fonte: adaptado de U.S. Bureau of the Census (1976).

A técnica pode ser compreendida como sendo a combinação da representação de duas variáveis. Onde, inicialmente, é atribuído um esquema de cores para cada uma delas.

Dunn (1989) explica que o princípio básico do mapeamento de duas variáveis é particionar a distribuição bivariada dos dados em um pequeno número de classes, atribuir a cada classe uma cor e, em seguida, sombrear o mapa básico de acordo. A Figura 26 ilustra esse processo onde cada variável possui três classes, ou seja, o mapa bivariado é criado por um processo de sobreposição, e são nove cores resultantes que representam as combinações das variáveis.

Figura 26 - Processo construtivo da legenda bivariada




Fonte: A autora (2021).

Leonowicz (2006), explica que os mapas coropléticos de duas variáveis são destinados para mostrar uma relação entre as variáveis, e que uma distinção entre dois tipos de observações deve ser feita durante a seleção da quantidade de classes.

Ainda segundo o autor, o primeiro grupo de observações consiste nessas unidades cujos valores confirmam uma forte relação entre as variáveis (no caso de uma relação positiva: se os valores da primeira variável são baixos, os valores da segunda variável são também baixos; e se os valores da primeira variável forem altos, os valores da segunda variável também serão altos), o outro grupo é composto de unidades em que os valores possuem uma associação espacial negativa (valores de positivo e desvios negativos de uma relação linear), a Figura 27 ilustra esse relacionamento.


Figura 27 - Legenda bivariada representando um exemplo de grupo de observações em que existe uma forte relação entre as variáveis e classes



Fonte: adaptado de Leonowicz (2006).

Esse método de divisão de classes possibilita a visualização das regiões em que há concordância ou não entre as variáveis analisadas. A Figura 28 apresenta um exemplo recente da utilização deste método, o mapa ilustra a relação existente entre os casos confirmados da COVID-19 e o envelhecimento por município do Estado de São Paulo.

Figura 28 - Representação cartográfica coroplética bivariada dos casos confirmados e do envelhecimento populacional no estado de São Paulo até 04/07/2020



Fonte: Guimarães e Pugliesi (2021).

A representação cartográfica coroplética bivariada, neste produto cartográfico além de possibilitar a identificação dos municípios que possuem maior risco quanto ao espalhamento do vírus, promove o reconhecimento de dois padrões em um único mapa, uma vez que o mesmo é composto por duas rampas de cores que se combinam em uma legenda em forma de grade, a qual ilustra todas as combinações de padrões possíveis.

Se as relações geográficas fossem aleatórias, o mapa resultante não mostraria nenhuma tendência particular para uma concentração de área de cores semelhantes. Ao analisar-se o mapa, compreende-se que existe, de fato, uma variação geográfica na distribuição dos casos confirmados da doença e do índice de envelhecimento populacional, uma vez que se torna fácil identificar a presença de *clusters* de municípios na região Noroeste e centro Oeste em que altas taxas de casos confirmados acontecem em locais com maiores índices de envelhecimento, bem como percebe-se que em torno da capital, prevalece a taxa da COVID-19 alta e o baixo índice de envelhecimento.

Fienberg (1979, p; 176), aponta em estudo sobre mapas estatísticos que existem algumas questões a serem respondidas ao se optar por utilizar este método de representação:

- i. escolha dos intervalos de classes (método de estratificação em função da distribuição);
- ii. escolha das cores (uma vez que as rampas de cores devem ser combinadas);
- iii. o número de classes a serem usadas (quanto mais classes, maior será a dificuldade em interpretar as combinações das variáveis – três classes: nove cores individuais, quatro classes: 16 cores individuais, e assim sucessivamente);
- iv. o sistema bivariado é superior a um sistema de uma única cor e padrões geométricos?
- v. o usuário consegue extrair informações adicionais do mapa bivariado, além daquelas que podem ser extraídas dos dois mapas uni variados colocados lado a lado?

3 MATERIAIS E MÉTODOS

O presente estudo baseou-se em artigos de jornais e revistas relacionados à pandemia da COVID-19 e trabalhos que envolvessem revisões bibliográfica ou metodologias específicas para a disseminação da doença, além dos boletins epidemiológicos, ou de análise do risco de espalhamento desta em função da mobilidade urbana.

3.1 MATERIAIS UTILIZADOS DURANTE A PESQUISA


Para aquisição e processamento dos dados utilizados na pesquisa, foram utilizados os seguintes materiais:

- Anaconda IDE, edição individual (Anaconda Distribution);
- Jupyter Notebook;
- ArcGIS Pro 2.5.0, 01 licença Learn ArcGIS válida até 31/12/20;
- Microsoft Windows 10, versão de 64 bits;
- Microsoft Office, 01 licença do Office Home and Student 2016;
- IBM SPSS Statistics Subscription, versão trial para estudantes;
- Internet.

3.2 PROCEDIMENTOS METODOLÓGICOS

Os procedimentos metodológicos executados nesta pesquisa estão ilustrados no fluxograma da Figura 29, e os detalhamentos da metodologia proposta estão descritos nas seções a seguir.

Figura 29 - Fluxograma geral da pesquisa




Fonte: A autora (2020).

3.2.1 Definição da área de estudo

A área de estudo definida é compreendida pela cidade do Recife, situada no estado de Pernambuco, Figura 30. O município possui 1.537.704 habitantes e uma população estimada de 1.653.461 habitantes para o ano de 2020, distribuídos em 218,498 km² (BDE, 2021b; IBGE, 2021). Limita-se ao Norte com as cidades de Paulista e Olinda, à Leste com o Oceano Atlântico, ao Sul com Jaboatão dos Guararapes, e à Oeste com os municípios de Camaragibe e São Lourenço da Mata. A faixa litorânea em que está compreendida a cidade apresenta baixa altitude, com altitude média de 4 m acima do nível do mar, chegando a possuir, em alguns pontos, cotas inferiores a este.

Numa região metropolitana, a conurbação e a mobilidade intensa entre os municípios certamente tem influência na disseminação de doenças, porém o estudo de caso considerou apenas o município de Recife devido à disponibilização dos casos e óbitos por bairro, o que não ocorre com outros municípios da Região Metropolitana de Recife (RMR).

Figura 30 - Mapa da área de estudo



Fonte: A autora (2020).

3.2.2 Coleta dos Dados

Abaixo seguem descritas as ações desenvolvidas na Etapa 2 da presente metodologia.

3.2.2.1 Aquisição dos bairros

A área de estudo subdivide-se em 94 bairros. Os limites espaciais foram obtidos no portal E-SIG Recife da Prefeitura da Cidade do Recife (<https://esigportal.recife.pe.gov.br/arcgis/apps/webappviewer/index.html?id=679e74b46c7b44caaad64abd5f751b4b>), no formato *shapefile*.

Considerando os elementos de qualidade de dados espaciais, o dado de entrada utilizado não apresentou restrições.

3.2.2.2 Aquisição dos fluxos e zonas de tráfego

A Pesquisa OD utilizada neste estudo foi a Pesquisa Origem-Destino Metropolitana 2018, organizada pelo Instituto da Cidade Pelópidas Silveira – ICPS, e o Grande Recife Consórcio de Transporte Metropolitano – CTM. A Pesquisa contemplou a população que reside, trabalha, estuda ou busca serviços nos municípios da RMR.

Os dados de fluxo – Matriz OD (<http://icps.recife.pe.gov.br/node/61317>) e o limite espacial (<https://docs.google.com/uc?export=download&id=1uyKCRqyN-QU1FwQ4HJNl4Tjd14cVtMvb>) das zonas de tráfego foram obtidos em links para download disponíveis na página de internet do ICPS. Contudo os limites espaciais das zonas de tráfego não coincidem exatamente com os limites de bairros recifenses, questão a ser tratada na seção 3.2.3.2.

As análises e resultados da Pesquisa OD foram extraídas de uma base de dados constituída por 115.160 respostas. Cada resposta desta pesquisa, refere-se a um viajante. A Figura 31, apresenta um extrato da Matriz OD motivo Trabalho utilizando Transporte Público. Por exemplo, a posição 10x13 indica que ocorreram 895 viagens da zona 10 para a zona 13 pelo motivo Trabalho utilizando Transporte Público.

Figura 31 - Recorte da planilha dos fluxos (quantidade de viagens) da Matriz OD motivo Trabalho utilizando Transporte Público no município do Recife/PE

ZONAS	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20
1	223		29			21			7	29								7		
2	72																			
3	31		145			31		31		50	10		126			10				
4																				
5					2													3		
6			5							30										
7										509			111							
8			10					19		7										
9										1003										
10										1124										
11		10	152							309	268		895			322		29	19	
12		5	5							104	45	26	2029	120			15	5		
13										134		187	372							
14			16							455	51	577		42	51		187	195		16
15										10										
16										71	25		88			124	10	25	24	64
17										7	7		151			42	50		9	
18										25			177			122		220	71	
19										120	10	48	110			125	127	187		
20	8															38		3		31
21																14			5	
22											12		21	12						
23	15									115			57					11		
24										50			16				6	44	41	
25										102			173		15	24		7	9	
26										58			35	8					70	
27	12												14							
28													60							
29			37							152			4					37		
30										52			148			10				
31						8				35			15							
32										17						17				
33																				
34													8							
35													13	8	13				13	
36	24								24											
37	17		17			54						17								
38												12						24		
39																				
40																				

Fonte: adaptado de ICPS (2020).

A pesquisa é resultado da lei municipal do Recife nº 18.205/2015, que notificou e obrigou empresas e Instituições de Ensino – IE, a concederem as informações necessárias ao planejamento da mobilidade urbana do Recife. Todos os colaboradores das empresas e componentes das IE (professores, funcionários administrativos, corpo discente) foram obrigados a responder, individualmente, um questionário com perguntas sobre sua rotina de deslocamento.

A Matriz OD utilizada como base para esse estudo, consiste em uma matriz quadrada com 253 elementos nas linhas e colunas, onde cada campo deste corresponde ao número de viagens entre as zonas. No total, a Pesquisa OD 2018 compreende 253 zonas distribuídas ao longo de todo território da RMR, das quais 106 estão inseridas na área de trabalho.

As zonas de tráfego foram baseadas nos setores censitários definidos pelo Instituto Brasileiro de Geografia e Estatística – IBGE. Cada zona consistiu no agrupamento de oito a dez setores censitários formando uma área contínua, sem ser cortada por barreiras naturais do tráfego, com população em torno de 10.000 habitantes (5.000 na área central do Recife), uso do solo homogêneo e considerando estratos de faixa etária da população de cada zona e a faixa de renda em que ela se insere.

Segundo os dados da pesquisa OD ICPS (2018), cerca de 43% da população do Recife utiliza os sistemas de transportes públicos para deslocamentos por motivo de trabalho. Cada planilha da Pesquisa contém as informações gerais sobre a mesma, tais quais: total de viagens de cada par OD em relação à origem, e o percentual de cada par OD em relação ao destino; e um arquivo shapefile – delimitações espaciais das zonas de tráfego.

Considerando os elementos de qualidade de dados espaciais, o dado de entrada utilizado apresentou algumas restrições:


- **Consistência lógica – Conceitual:** Em decorrência da diferença entre as unidades espaciais do dado de entrada. Cada Zona de Tráfego tem seu limite espacial definido por meio dos setores censitários formulados pelo IBGE, considerando os estratos de faixa etária da população de cada zona e a faixa de renda em que ela se insere;
- **Consistência topológica:** *Em decorrência da existência de inconsistências na geometria dos dados de entrada na mesma classe:* Existência de geometrias

inválidas, multiparte e lacunas. A validação topológica foi realizada manualmente e automaticamente no ArcGIS Pro; e

- **Acurácia temporal** – *Em decorrência do tempo em que é realizada a carga das mudanças no banco de dados:* Dados fornecidos pelo ICPS com publicação em 2018.

A Figura 32 ilustra o padrão de viagens, média por dia, dos usuários do Transporte Público que se deslocam para o Trabalho. Para espacialização dos fluxos, utilizou-se como elementos espaciais a malha viária do município.

Figura 32 - Representação cartográfica do número de passageiros que utilizam o sistema de transporte público, motivo trabalho




Fonte: A autora (2020).

3.2.2.3 Aquisição do sistema viário

As vias foram adquiridas por intermédio do *overpass turbo* (<https://overpass-turbo.eu/>), Figura 33. Neste é possível realizar consultas espaciais sobre a base de

dados do *OpenStreetMap* – OSM, a qual é uma base vetorial constituída por elementos geométricos (nós – *nodes*; linhas – *ways*; e relações – *relations*: entre nós, linhas ou ambos), onde o nó é a entidade básica, e todos os elementos possuem um nó com coordenadas, os quais são compostos por um código XML OSM, cada um deles contém: nó; o tipo da entidade geométrica; e *Tags* (etiquetas).

Figura 33 - Recorte de tela do resultado da pesquisa no *overpass turbo*



Fonte: A autora (2020).

Essa base segue uma classificação específica, e fazendo-se a consulta pela *tag* “*highway*”, tipifica-se o nível hierárquico das vias (*primary* – rodovias estaduais e federais, em vermelho; *secondary* – avenidas principais de grande tráfego, em azul; e *tertiary* – vias coletoras de tráfego, em cinza). Ainda de forma a adquirir apenas o sistema viário contido no polígono do município, fez-se a consulta pela *tag* “*geocodeArea*” com o atributo “Recife”. Posteriormente, exportou-se o dado filtrado no formato GeoJSON (*.geojson) – *JavaScript Object Notation*. Este por sua vez, é um formato aberto usado para transferência de dados estruturados entre um servidor *Web* e uma aplicação *Web*.

A limpeza topológica e validação da camada vetorial foi realizada no *software* ArcGIS Pro 2.5.0, etapa em que se removeu as feições com extensão inferior a 500 m. Para a absorção dos dados de fluxo, fez-se uma união espacial entre as feições das zonas de tráfego e da malha viária, através da ferramenta *Spatial Join* do aplicativo.

A fim de atestar a conectividade entre os bairros recifenses, buscou-se sobrepor a esta base: as faixas azuis e rotas exclusivas para transportes públicos, camada disponibilizada pela Companhia de Trânsito e Transporte Urbano – CTTU, para *download* no formato GeoJSON (<http://dados.recife.pe.gov.br/dataset/faixas-e-corredores-de-onibus>); e os itinerários do transporte público geridos pelo Grande Recife Consórcio de Transporte Metropolitano – CTM, camada disponibilizada pelo CTM, para *download* no formato *shapefile* (<http://icps.recife.pe.gov.br/node/61205>).

3.2.2.4 Aquisição do número de casos da doença

Até a fase de transmissão local, 17/03/2020, todos os casos suspeitos, de acordo com as definições de caso do MS, eram notificados através da Plataforma do Centro de Informações Estratégicas de Vigilância em Saúde de Pernambuco (CIEVS PE) e monitorados pelo município (PERNAMBUCO, 2020). Após, o estabelecimento da transmissão comunitária no Recife, quando não foi possível identificar a origem da contaminação, o monitoramento de casos da COVID-19 passou a ser incorporado à vigilância sentinela da síndrome gripal e à vigilância universal da SRAG, conforme orientação do MS. No entanto, a partir de 18/03/2020, foram notificados apenas os casos que atendiam à definição de caso de SRAG.

Para a classificação dos bairros recifenses mais propensos à epidemia grave da COVID-19, assim como Ramos Jr et al. (2020), o presente estudo utilizou o contexto epidemiológico inicial. Este constituído pelo acumulado de casos da doença até 23/03/2020, onde foram confirmados 30 casos da COVID-19, sendo 66,7% do sexo feminino e 33,3% do masculino. Segundo Pernambuco (2020), os casos da doença são associados ao bairro que reside o indivíduo infectado.

Sendo assim, os dados do número de infectados foram obtidos através dos boletins disponibilizados pelo CIEVS, realizados pela Diretoria Executiva de Vigilância à Saúde da Secretaria de Saúde do Recife. O CIEVS disponibiliza diariamente os relatórios para *download* no formato PDF (*Portable Document Format*). Para manipular essas informações foi necessária a conversão desses dados para o formato CSV (*Comma Separated Values*), para tanto utilizou-se a ferramenta Tabula especificando as coordenadas e página em que se encontram os quantitativos de casos por bairro. Os arquivos CSV foram obtidos fazendo o *upload* dos relatórios na página da *web* do Tabula (<http://127.0.0.1:8080>) e posterior *download*.

Considerando os elementos de qualidade de dados espaciais, o dado de entrada utilizado apresentou algumas restrições:

- **Consistência lógica** – *Formato*: O número de casos é fornecido em Boletim Epidemiológico diário, disponibilizado pela Secretaria de Saúde do Recife no formato PDF; e
- **Acurácia temporal** – *Em decorrência da observação da evidência*: Dados fornecidos no Boletim Epidemiológico diário, geralmente disponibilizado no período vespertino do dia posterior ao da amostra.

3.2.2.5 Aquisição dos indicadores socioeconômicos

Segundo o IBGE (2021), o Recife detém apenas 69,2% de seu saneamento básico adequado, enquanto que apenas 49,6% das vias possuem adequada urbanização, ou seja, quando o crescimento urbano é superior ao crescimento rural.

A fim de entender a influência dessa desigualdade no tocante à pandemia, o presente estudo procurou entender o relacionamento de alguns indicadores socioeconômicos com a disseminação da doença. Para tanto, fez-se a análise exploratória dos dados buscando entender o relacionamento desses fenômenos com a dinâmica da mobilidade urbana.

Primeiramente buscou-se em função do índice de envelhecimento populacional, determinar quais bairros do Recife seriam potencialmente atingidos pela doença, visto que os mais idosos fazem prioritariamente parte do grupo de maior risco à COVID-19. Dados de órgãos de saúde oficiais, como Organização Mundial de Saúde – OMS e do MS, ressaltam que os idosos estão entre os mais suscetíveis e entre aqueles afetados pelos maiores índices de letalidade quando atingidos pela doença (Fiocruz, 2020).

- Índice de Envelhecimento Municipal: valores obtidos, por bairro, no *site* da PCR (<http://www2.recife.pe.gov.br/pagina/informacoes-socioeconomicas>).


Considerando os elementos de qualidade de dados espaciais, o dado de entrada utilizado apresentou algumas restrições:

- **Consistência topológica:** *Em decorrência da existência de inconsistências na geometria dos dados de entrada na mesma classe:* Existência de geometrias inválidas, multiparte e lacunas. A validação topológica foi realizada manualmente e automaticamente no ArcGIS Pro; e
- **Acurácia temporal** – *Em decorrência do tempo em que é realizada a carga das mudanças no banco de dados:* Dados fornecidos pela PCR com publicação em 2010.

Sob uma análise social, deve-se ainda ressaltar que, segundo Ramos Jr et al. (2020), a estratificação por motivo “trabalho” e modo coletivo representa parcela mais vulnerável da população, que não só realizam viagens mais longas e duradouras, mas também apresentam classe de renda média ou baixa, localizadas em áreas de menor Índice de Desenvolvimento Humano – IDH. Sendo assim, o presente estudo buscou determinar quais bairros do Recife seriam potencialmente atingidos pela doença em função dessa vulnerabilidade.

- Índice de Vulnerabilidade Social – IVS: valores obtidos, por Unidades de Desenvolvimento Humano – UDH, no Atlas da Vulnerabilidade Social, disponíveis no *site* do Instituto de Pesquisa Econômica Aplicada – IPEA, no formato x/s (Figura 34).

Figura 34 - Recorte de tela do site do IPEA



Fonte: IPEA (2020).

Considerando os elementos de qualidade de dados espaciais, o dado de entrada utilizado na análise apresentou algumas restrições:

- **Consistência lógica – Conceitual:** Em decorrência da diferença entre as unidades espaciais do dado de entrada. Cada UDH tem seu limite espacial definido por meio de recortes espaciais de forma a que cada uma delas possua maior homogeneidade socioeconômica. É formada com base nos setores censitários do IBGE, e possui o objetivo de retratar as desigualdades intrametropolitanas de forma mais contundente (IPEA, 2020);
- **Consistência topológica:** Em decorrência da existência de inconsistências na geometria dos dados de entrada na mesma classe: Existência de geometrias inválidas, multiparte e lacunas. A validação topológica foi realizada manualmente e automaticamente no ArcGIS Pro; e
- **Acurácia temporal – Em decorrência do tempo em que é realizada a carga das mudanças no banco de dados:** Dados fornecidos pelo IPEA com publicação em 2017.


3.2.3 Processamento dos dados

3.2.3.1 Preparação do Ambiente

O Jupyter Notebook é um ambiente de código aberto baseado na *web* que auxilia a análise de grandes conjuntos de dados, e suporta mais de 40 linguagens das quais, a linguagem *Python* foi a adotada neste estudo. Para instalação do Jupyter foi utilizado o gerenciador de pacotes conda. Este possibilita a pesquisa de mais de 7.500 pacotes de ciência de dados e aprendizado de máquina.

Inicialmente, fez-se a instalação do Anaconda que é uma plataforma de distribuição *Python*, de código aberto, que possibilita a criação, instalação, atualização e gerenciamento de variados ambientes de dados. Quando instalasse o ArcGIS Pro, automaticamente o Miniconda é instalado, o que possibilita o usuário alternar entre o notebook e o Map (Figura 35). No presente estudo, a escrita do *script* para cálculo e processamento dos dados apresentados, foi feita no Jupyter (Apêndice A).

Figura 35 - Recorte de tela do notebook no ArcGIS Pro



Fonte: A autora (2020).

Para leitura, espacialização e análise da gama de dados de fluxo, fez-se uso das bibliotecas Pandas e Numpy, que possibilitam o manuseio de *datasets*, e facilitam a análise, filtragem, indexação e classificação destes.

O código original da metodologia (disponível em https://github.com/pedreirajr/GeoCombatCOVID19/blob/master/NT01-COVID-19_X_Transp.ipynb) foi escrito pelo Prof, Dr. Jorge Ubirajara Pedreira Junior da Escola Politécnica da Universidade Federal da Bahia – EPUFBA, membro do Grupo GeoCombate COVID-19 BA do Departamento de Engenharia de Transportes e Geodésia da EPUFBA. Código este que posteriormente foi adequado aos dados utilizados neste estudo.

3.2.3.2 Transformação dos Dados


Para agregação das unidades espaciais e posterior cálculo do potencial de absorção das zonas e determinação do Perigo Potencial, foi usado o formulário desenvolvido por Pereira Júnior et al. (2020), metodologia esta posteriormente adaptada por Ramos Jr et al. (2020).

i. Compatibilização das bases de dados utilizadas

Comumente, ao utilizarmos dados de diferentes fontes, dispomos de camadas vetoriais que são referidas às unidades espaciais não coincidentes, a exemplo cita-se: setores censitários, bairro, distrito sanitário, dentre outros.

De forma a realizar as análises sob uma única unidade espacial, no presente estudo definiu-se que o bairro deveria delimitar o território, visto que este continha os dados de interesse (unidade usada pela Secretaria de Saúde do Recife para os dados de casos da doença). Inicialmente foi necessário uniformizar as áreas de trabalho, visto que os limites das zonas de tráfego da Pesquisa OD são diferentes dos limites de bairros do Recife (Figura 36).

Figura 36 - Representação das zonas de tráfego contidas no Recife



Fonte: A autora (2020).

Para tanto, fez-se a agregação espacial entre as duas camadas de forma a determinar quanto existia de área de interseção entre uma determinada zona i e um determinado bairro b . A Figura 37 ilustra esse processo, onde: zt – camada vetorial das zonas de tráfego e nb – camada vetorial dos bairros.

Figura 37 - Recorte de tela de parte do código em *python*


```
I = np.zeros((len(zt),len(nb)))

for i in np.arange(len(zt)):
    for j in np.arange(len(nb)):
        I[i,j] = zt.loc[i,'geometry'].intersection(nb.loc[j,'geometry']).area
```

Fonte: A autora (2020).

Nesse processo calcula-se as proporções das feições de área (zona de tráfego) que estão dentro do limite de entrada (bairros). O mesmo foi aplicado à camada vetorial das UDH (Figura 38), disponibilizadas pelo IPEA, de forma a identificar as interseções entre os bairros recifenses e as UDH.

Figura 38 - Representação das UDH contidas no Recife



Fonte: A autora (2020).

A Figura 39 ilustra o processo de ponderação pelas áreas das interseções, onde: *udh* – camada vetorial das UDH e *nb* – camada vetorial dos bairros.

Figura 39 - Recorte de tela de parte do código em *python*

```
I_ub = np.zeros((len(udh),len(nb)))

for i in np.arange(len(udh)):
    for j in np.arange(len(nb)):
        I_ub[i,j] = udh.loc[i,'geometry'].intersection(nb.loc[j,'geometry']).area
```

Fonte: A autora (2020).

ii. Cálculo do potencial de espalhamento da COVID-19 (P_i)

Determinação de P_i para uma determinada zona i , por meio da equação 1.

$$P_i = \sum_b p_b \times \frac{S_{inb}}{SZ_i}, \forall i \in Z \quad (1)$$

Onde,

Z – Conjunto de dados das zonas de tráfego;

B – Conjunto de dados dos bairros;

p_b – Prevalência de casos no bairro $b \in B$;

SZ_i – Área de uma determinada zona de tráfego $i \in Z$;

$S_{i \cap b}$ – Área de interseção entre uma zona i e um bairro b .

Entende-se o potencial de espalhamento como sendo a carga de infecção, valor este medido a partir da combinação da carga de infectividade e da mobilidade populacional entre os bairros do Recife. E os dados de prevalência de casos são dados pelo acumulativo do número absoluto de casos em cada bairro da área estudada.

iii. Cálculo do potencial de absorção da COVID-19 (A_j)

Determinação do potencial que uma zona de tráfego possui de absorver a doença, por meio da equação 2.

$$A_j = \sum_i P_i (f_{ij} + f_{ji}), \forall j \in Z \quad (2)$$

Onde,

P_i – Potencial de espalhamento;

f_{ij} – Fluxo diário de indivíduos saindo da zona i para a zona j , em que $i, j \in Z$.

O fluxo diário de indivíduos (número total de viagens entre cada Origem-Destino) é dado pelo total de resultados da pesquisa que saem de uma zona i para a zona j , em que i, j estão contidos nas zonas de tráfego. A Figura 40 ilustra esse processo, onde: zt – camada vetorial das zonas de tráfego, P – camada vetorial com os valores obtidos para o potencial de espalhamento por bairro, e ft – padrões de viagem por zona de tráfego.

Figura 40 - Recorte de tela de parte do código em *python*

```
A = [None] * len(zt)

for j in np.arange(len(zt)):
    A[j] = sum([x * y for x, y in zip(ft[:,j],P)]) + sum([x * y for x, y in zip(ft[j,:],P)])
```

Fonte: A autora (2020).

Para a indexação dos padrões de viagem por zona de tráfego utilizou-se o módulo *pickle* que permite serializar e desserializar uma estrutura de objeto *python*. Ou seja, uma determinada hierarquia de objetos (lista com a quantidade de viagens entre as possíveis zonas, como o exemplo da Figura 30) é convertida em um fluxo de *bytes*, o que posteriormente possibilitou o cálculo do potencial de absorção da COVID-19 nas zonas.

A Figura 41 ilustra esse processo de indexação, onde: *zt* – camada vetorial das zonas de tráfego, *ORIG* – zona de origem da viagem, *DEST* – zona de destino da viagem, *ZONA* – geometria de uma determinada zona da camada *zt*, e *VIAG* – quantidade de viagens de uma determinada origem para um determinado destino.

Figura 41 - Recorte de tela de parte do código em *python*

```
ft_OD = np.zeros((len(zt),len(zt)))
for i in np.arange(len(zt)):
    for j in np.arange(len(zt)):
        try:
            ft_OD[i,j] = float(fOD[(fOD['ORIG'] == zt.loc[i,'ZONA']) & (fOD['DEST'] == zt.loc[j,'ZONA'])].VIAG)
        except:
            ft_OD[i,j] = 0
pickle.dump(ft_OD, open('ft_OD', 'wb'))
```

Fonte: A autora (2020).

iv. Cálculo do perigo potencial (PP_b)

Determinação do potencial de espalhamento da doença por zona de tráfego, calculado por meio da equação 3.

$$PP_b = \sum_j A_j \times \frac{I_{j \cap b}}{SB_b}, \forall b \in B \quad (3)$$

Onde,

A_j – Potencial de absorção;

$I_{j \cap b}$ – Área de interseção entre uma zona j e um bairro b ;

SB_b – Área de um determinado bairro $b \in B$.

Sendo assim, o PP_b de um determinado bairro absorver a doença é dado pelo somatório do potencial de absorção da COVID-19 das zonas que interceptam este bairro multiplicada pela proporção de área que estas zonas têm com o bairro. A Figura 42 ilustra esse processo, onde: nb – camada vetorial dos bairros, SB – lista com os valores de bairro, A – camada vetorial com os valores obtidos para o potencial de absorção por bairro, e I – áreas das interseções entre bairros e zonas de tráfego.

Figura 42 - Recorte de tela de parte do código em *python*

```
PP = [None] * len(nb)

for b in np.arange(len(nb)):
    PP[b] = sum([x * y / SB[b] for x, y in zip(A, I[:, b])])
```

Fonte: A autora (2020).

Ao final o PP_b é normalizado entre 0 e 1, conforme a equação 4.

$$PP_b^{norm} = \frac{PP_b - \min(PP_b)}{\max(PP_b) - \min(PP_b)} \quad (4)$$

Onde,

PP_b – Perigo Potencial.

A Figura 43 ilustra esse processo, onde: PP – valores do perigo potencial por bairro e nb – camada vetorial de bairros.

Figura 43 - Recorte de tela de parte do código em *python*

```
PP = (PP - min(PP)) / (max(PP) - min(PP))

nb['PP'] = PP
```

Fonte: A autora (2020).

3.2.3.3 Determinação do Risco (R_v)

As condições socioeconômicas dos bairros recifenses são heterogêneas, e, diante dessa disparidade para determinados estratos da população, a fim de compreender a influência dessa desigualdade no tocante à pandemia sob a ótica da mobilidade. Para tanto faz-se uso do método coroplético bivariado, calculando-se o

Risco por meio do cruzamento espacial entre os resultados obtidos. Para a elaboração dos mapas foi utilizado o aplicativo ArcGIS Pro 2.5.0.

O método possibilita realizar investigações sobre as informações verificadas, a fim de descobrir padrões, testar hipóteses, verificar suposições ou detectar anomalias. Ao realizar a espacialização desses produtos bivariados, será possível identificar a ocorrência ou não de aglomerados de bairros do Recife em que ocorrem altas taxas de casos associadas aos maiores índices de envelhecimento, ou maiores taxas de vulnerabilidade social. Possibilitando assim realizar a análise espacial do relacionamento entre o PP_b e um índice socioeconômico qualquer.


3.2.4 Método de estratificação das variáveis e representação do Risco (R_v)

Inicialmente fez-se necessário verificar se a distribuição das variáveis era normal, de forma a utilizar o método estatístico adequado tanto na escolha do método de classificação, bem como na avaliação da correlação existente entre o PP_b e o índice de envelhecimento, bem como entre o PP_b e o IVS. Para análise estatística dos dados utilizou-se o *software* SPSS.

Após realização da análise exploratória dos dados, optou por estratificar as variáveis com o método de intervalo geométrico, o qual cria intervalos geométricos minimizando a soma dos quadrados do número de elementos em cada classe. O método cria um equilíbrio entre o destaque de mudanças nos valores médios e os valores extremos, produzindo assim um resultado que é visualmente atraente e cartograficamente abrangente (ESRI, 2020).

Para classificação dos mapas de uma variável, os índices foram divididos em cinco classes. Já nos mapas bivariados, os mesmos índices foram divididos em três classes, conforme apresentado no item 2.5 deste trabalho. A Figura 44 ilustra essa escolha e reapresenta o processo de construção da legenda bivariada, elencando a sobreposição criada após a divisão das distribuições em três classes, ilustrando como deve ser realizada a leitura da mesma.

Figura 44 - Escolha do tipo de distribuição das variáveis, representação do processo construtivo e leitura da legenda bivariada




Fonte: A autora (2020).

4 RESULTADOS E DISCUSSÕES

Nesta pesquisa, foi abordado o risco da disseminação da COVID-19 em uma escala local. Partindo do pressuposto que os bairros do Recife são ligados por fluxos de passageiros. A análise feita possibilitou afirmar que a metodologia apresentada pode ser empregada para analisar o impacto da mobilidade urbana na disseminação da pandemia. Conclui-se ainda que o presente estudo poderia auxiliar a modelagem da disseminação de outras doenças transmissíveis tal qual a da COVID-19. Para determinar quais bairros seriam mais vulneráveis, tal qual apresentado na seção 3.2.2.4, utilizou-se o número absoluto de casos no cenário epidemiológico inicial (23/03/2020). A Figura 45 ilustra a amostra utilizada.

Figura 45 - Mapa do número de casos em 23/03/2020




Fonte: A autora (2021).

A questão principal abordada no estudo foi o PP_b de disseminação da COVID-19 em função do fluxo proveniente de cada Origem e das características da rede de tráfego. Onde, para a determinação dos bairros recifenses com maior PP_b , buscou-se quantificar a suscetibilidade destes em decorrência da mobilidade.

Para tanto, em função dos fluxos, inicialmente fez-se o cálculo de quais zonas de tráfego possuíam maior Potencial de Espalhamento. E, em função do número de casos com base no contexto epidemiológico inicial (23/03/2020), determinou-se quais destas zonas possuíam maior Potencial de Absorção.

Posteriormente, calculou-se que o PP_b de um determinado bairro absorver a doença era dado pelo somatório do Potencial de Absorção das zonas que interceptavam este bairro multiplicado pela proporção de área que estas zonas tinham com o referido bairro. A Figura 46 apresenta quais bairros, segundo a metodologia utilizada, possuem maior Perigo Potencial de disseminação da doença. Para representação do Perigo, optou-se figurar a propensão dos bairros por meio de uma rampa de cor proporcional, onde o mais claro retrata os bairros do Recife com menor perigo, enquanto que o mais escuro estampa aqueles com maior perigo.

Figura 46 - Mapa do Perigo Potencial dos bairros ao espalhamento da COVID-19



Fonte: A autora (2021).

Ressalta-se ainda o fato de que a presente análise não levou em consideração um cenário em que se assumiu a presença do distanciamento social, com restrições

de viagens e suspensões de atividades econômicas e sociais não essenciais, uma vez que os dados de fluxo são oriundos da Pesquisa OD do biênio 2017/2018.

O cenário de imposição de medidas restritivas foi instaurado na área de estudo em 16/05/2020, quando o estado de Pernambuco atingiu a marca de 1.000 mortos pela COVID-19. Com a medida de restringir a circulação de veículos e pessoas, o governo do Estado publicou o Decreto nº 49.017, de 11 de maio de 2020 (Pernambuco, 2020). Supõe-se neste estudo que essa medida tenha contribuído para a redução do número de casos naqueles bairros como maiores valores calculados para PP_b , visto que os bairros recifenses com alto PP_b não foram tão impactados, como ilustrado na figura 46 e descrito na Tabela 1.

Tabela 1 - *Ranking* dos bairros com maior Perigo Potencial e do número total de casos ao término da pesquisa


Perigo Potencial (PP_b)		Total de casos em 31/12/20	
Posição	Bairro	Posição	Bairro
1º	Paissandu	1º	Boa Viagem
2º	Ilha do Leite	2º	Várzea
3º	Pina	3º	Ibura
4º	Derby	4º	Cohab
5º	Graças	5º	Iputinga
6º	Boa Viagem	6º	Imbiribeira
7º	Santana	7º	Casa Amarela
8º	Boa Vista	8º	Água Fria
9º	Casa Amarela	9º	Cordeiro
10º	Espinheiro	10º	Madalena

Fonte: A autora (2021).

A metodologia utilizada, ao apontar os bairros do Recife que seriam mais atingidos pela doença, destacou a importância da medida de restrições instaurada, uma vez que os bairros de Paissandu, Ilha do Leite, Pina, Derby e Graças, seriam àqueles com maior potencial de importação de novos casos em função dos fluxos de tráfego. Onde, os dois primeiros, bairros confrontantes e localizados na região central da capital (Região Político Administrativa I – RPA 1), concentram 0,11% do total de residências recifenses (IBGE, 2010), confrontando o ponto de vista que estes bairros por não possuírem o caráter predominantemente residencial, de fato, não foram os mais impactados pela doença. Visto que a notificação do número de casos é associada ao bairro que reside o indivíduo com a doença. Enquanto que os dois primeiros bairros mais impactados, ainda segundo o apresentado na tabela 1, concentram 13,58% do total de residências (IBGE, 2010).


A Figura 47 ilustra o fluxo de viagens em que o Destino era a zona 59, zona a qual o bairro de Paissandu está inserido. Destaca-se que, segundo os dados de tráfego do sistema de transporte público utilizados neste estudo, o total de 153.157 viagens compreende o triplo do número de viagens com Destino para a zona 124, na qual está inserido o bairro do Derby (Figura 48). Fato que explica os valores obtidos para o PP_b .

Figura 47 - Ilustração do fluxo total de viagens para a zona 59



Fonte: A autora (2021).

Figura 48 - Ilustração do fluxo total de viagens para a zona 124




Fonte: A autora (2021).

Contudo, o Recife é um município extremamente denso quando nos referimos ao sistema viário, onde as conexões existentes entre os bairros recifenses não se limitam às vias principais. Sua malha de logradouros, em que há tráfego de transporte público, é densa, o que promove ao tráfego o caráter de potencial catalisador para

disseminação da COVID-19. Tirachini e Cats (2020) afirmam que a conectividade oferecida pelos sistemas de transporte não é apenas um ativo e um catalisador para a troca de ideias e bens, mas também um potencial catalisador para adversidades, como um vírus. O que não determina que haverá uma maior infectividade, mas suporta a ideia de que essa conectividade amplifica a dispersão da doença, uma vez que dificulta a fiscalização dos usuários dos sistemas de transporte público. A Figura 49 apresenta essa conectividade indicada na presença da malha do transporte público geridos pelo Grande Recife CTM, em todos os bairros do Recife.

Figura 49 - Mapa dos itinerários do transporte público geridos pelo Grande Recife CTM



Fonte: A autora (2021).

Quanto ao potencial de dispersão do número de casos, este deve ser proporcional ao número de passageiros de um determinado bairro que possui casos da COVID-19 para outro, e suas interrelações. Consequentemente ocasionando um maior risco de novas importações neste. Para tanto buscou-se analisar o risco desses bairros, relacionando o PP_b a dois diferentes indicadores socioeconômicos: o índice de envelhecimento municipal e o IVS.


4.1 ANÁLISE DOS BAIRROS MAIS SUSCETÍVEIS AO RISCO DE DISSEMINAÇÃO DA COVID-19 EM FUNÇÃO DO ÍNDICE DE ENVELHECIMENTO ($PP_b \times \% \text{ Idosos}$)

Abaixo seguem apresentados em duas partes os resultados obtidos: análise estatística (análise exploratória dos dados) e gráfica (análise da variabilidade espacial dos dados) para o Perigo Potencial e o Índice de Envelhecimento Populacional.

4.1.1 Análise estatística

Inicialmente verificou-se se as variáveis seguiam uma distribuição normal (Figura 50), obtendo-se que o PP_b apresenta uma distribuição assimétrica positiva, onde a tendência é que haja desvios positivos maiores do que os negativos, a qual torna o modelo normal inadequado. Sendo assim, optou-se por calcular a correlação entre as variáveis com o coeficiente de correlação de Pearson, uma vez que, dependendo do tamanho da amostra, não se baseia em uma suposição de normalidade.

Figura 50 - Histogramas das variáveis Perigo Potencial e índice de envelhecimento



Fonte: A autora (2021).

A fim de verificar a correlação existente entre as variáveis: PP_b e o índice de envelhecimento, inicialmente calculou-se o coeficiente de correlação de Pearson (+0,405 com um sigma menor que 0,01 para as duas extremidades), onde verificou-se que existe uma relação linear moderada entre as duas variáveis. Indicando que são proporcionais, pois à medida que o índice de envelhecimento aumenta, aumenta também o PP_b .

Posteriormente aplicou-se também às variáveis testes de correlação não-paramétrica, a fim de atestar esse relacionamento e verificar se as distribuições não assumiam nenhuma distribuição teórica para os dados. Estima-se que essa violação da distribuição é devida à assimetria identificada na distribuição de PP_b . Supõe-se isto pois os valores do Perigo Potencial possuem uma grande concentração nos valores menores, valores estes determinados em função dos hábitos de mobilidade da população recifense. Sendo assim, optou-se por representar os dados em escala logarítmica.

Além deste, aplicou-se ainda às duas distribuições variáveis dois testes de correlação não-paramétricas determinando os coeficientes de correlação de Kendall e Spearman, ambos com um sigma menor que 0,01 para as duas extremidades. Comprovando que as variáveis não possuem alta correlação. A Tabela 2 consolida os valores encontrados.


Tabela 2 - Resultados dos coeficientes de correlação

Coeficiente de correlação	Valor
Pearson	0,405
Tau de Kendall	0,243
Rô de Spearman	0,361
N	94

Fonte: A autora (2021).

Assume-se então que talvez o sistema de transporte público não seja o principal modal utilizado pelos idosos. E, a fim de verificar essa prerrogativa, buscou-se junto ao Instituto das Cidades Pelópidas Silveira – ICPS, identificar qual o tipo de modal principal utilizado para deslocamento até o trabalho dos residentes no Recife por faixa etária. A Figura 51 apresenta o resultado dessa consulta.

Figura 51 - Modos de transporte principal por faixa etária



Fonte: ICPS (2018).

A Tabela 3 destaca os valores apresentados na Figura 51 para aqueles que possuem acima de 60 anos.

Tabela 3 - Percentuais de usuários por modo de transporte principal para o trabalho (> 60 anos)

Modo de Transporte Principal	Valor
A pé	51,94 %
Bicicleta	1,54 %
Carro	20,10 %
Motocicleta	1,08 %
Ônibus	20,55 %
Metrô	3,01 %
Outro	1,78 %


Fonte: adaptado de ICPS (2018).

Segundo os dados fornecidos pelo ICPS (2018), afirma-se que apenas 23,56% do grupo de indivíduos faz uso do sistema de transporte público coletivo, justificando a correlação moderada encontrada. Embora o transporte público coletivo não seja o principal modal utilizado pelos idosos, vale ressaltar que o risco permanece. Mesmo que não o utilizem, outras pessoas próximas pertencentes às demais faixas etárias podem atuar como vetores de transmissão da COVID-19 para estes idosos.

4.1.2 Análise gráfica

Segue apresentada a sequência de mapas elaborados com a finalidade de ilustrar o relacionamento espacial entre o PP_b e o índice de envelhecimento populacional.

Figura 52 - Mapa de variáveis. (a) PP_b ; (b) Índice de Envelhecimento populacional




Fonte: A autora (2021).

A partir do cruzamento das representações ilustradas na Figura 52, no intuito de identificar espacialmente a relação existente entre elas, a Figura 53 apresenta o relacionamento do PP_b e do índice de envelhecimento da população por bairro, por meio do mapeamento coroplético bivariado.

Conforme ilustrado na Figura 53, percebe-se que se as relações geográficas fossem aleatórias, o mapa resultante não mostraria nenhuma tendência particular para uma concentração de área de cores semelhantes (*cluster* de valores alto/alto formado pelos bairros recifenses na região central do mapa – Paissandu, Ilha do Leite, Derby e Boa Vista; *cluster* de valores baixo/baixo formado a Noroeste do mapa – Dois Irmãos, Caxangá e Sítio dos Pintos).


Figura 53 - Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19 ($PP_b \times \% \text{ Idosos}$)



Fonte: A autora (2021).

Ainda analisando-se o mapa, compreende-se que existe, de fato, uma variação geográfica na distribuição dos casos confirmados da COVID-19 e do índice de envelhecimento populacional, uma vez que se torna fácil identificar a presença de um *cluster* de bairros na região central do município. É possível verificar a coincidência desses *clusters* com a representação de onde surgiram os primeiros casos confirmados (Figura 54), e com a representação do acumulado de casos no fim do período observado (Figura 55).


Figura 54 - Mapa do número de casos de COVID-19 nos bairros do Recife em 23/03/2020



Fonte: A autora (2021).

A Figura 55 espacializa o acumulado de casos da COVID-19 ao término do período desta pesquisa (31/12/20), um total de 9.515 casos de SRAG para COVID-19). Onde, segundo a faixa etária, em 31/12/20, o CIEVS (2020) divulgou que cerca de 41% do número total de casos disponibilizados no período referiam-se aos indivíduos com mais de 60 anos.

Figura 55 - Mapa do acumulado de casos da COVID-19 nos bairros do Recife entre 23/03/20 e 31/12/20



Fonte: A autora (2021).

Todavia, segundo os percentuais dos usuários por modal fornecidos pelo ICPS (2018) – Tabela 3, e os resultados obtidos com a aplicação dos testes estatísticos, observou-se a existência de uma tendência particular para a concentrações de áreas de cores semelhantes no mapa ilustrado pela Figura 53, caracterizando a existência de uma relação linear moderada entre o PP_b e o índice de envelhecimento populacional.


4.2 ANÁLISE DOS BAIRROS MAIS SUSCETÍVEIS AO RISCO DE DISSEMINAÇÃO DA COVID-19 EM FUNÇÃO DO ÍNDICE DE VULNERABILIDADE SOCIAL (PP_b x IVS)

Seguem apresentados em duas partes os resultados obtidos: análise estatística (análise exploratória dos dados) e gráfica (análise da variabilidade espacial dos dados) para o Perigo Potencial e o Índice de Vulnerabilidade Social.

4.2.1 Análise estatística

Diferentemente da análise anterior, após a determinação do coeficiente de correlação de Pearson, verificou-se que o valor calculado (-0,427 com um sigma menor que 0,01), aponta que as variáveis aqui espacializadas possuem correlação negativa. Ou seja, conforme aumenta a desigualdade, o Perigo Potencial diminui.

Inicialmente buscou-se analisar a distribuição do IVS. Embora esta siga uma distribuição normal (Figura 56), como analisado anteriormente, o método mais indicado para a classificação dos intervalos do PP_b é o de intervalos geométricos.




Fonte: A autora (2021).

Contudo, se conforme aumenta a desigualdade, diminui o Perigo Potencial, como explicar essa afirmação?

O IVS é calculado por setor censitário urbano com base na proporção de domicílios com renda até $\frac{1}{2}$ salário mínimo per capita, na proporção de domicílios sem abastecimento de água e coleta de lixo, bem como na inadequação de esgotamento sanitário dos domicílios (FREIRE, CAMPOS e FUSCO, 2020). Fato este que corrobora para que os bairros do Recife com maior vulnerabilidade social também sejam aqueles que apresentam classe de renda média ou baixa, localizadas em áreas de menor IDH.

Segundo o ICPS (2018), os maiores usuários do transporte público são aqueles com renda entre um e três salários mínimos (Figura 57).

Figura 57 - Modos de transporte principal por faixa de renda



Fonte: ICPS (2018).

A Tabela 4 destaca os valores apresentados na Figura 57 para aqueles com faixa de renda até cinco salários mínimos.

Tabela 4 - Percentuais de usuários por modo de transporte principal para o trabalho (faixa de renda)

Faixa de Renda	Modo de Transporte Principal	Valor
De 3 a 5 salários mínimos	A pé	5,30 %
	Bicicleta	2,23 %
	Carro	43,67 %
	Motocicleta	5,16 %
	Ônibus	33,36 %
	Metrô	6,92 %
	Outro	3,36 %
De 2 a 3 salários mínimos	A pé	7,42 %
	Bicicleta	4,25 %
	Carro	18,13 %
	Motocicleta	9,60 %
	Ônibus	50,89 %
	Metrô	6,70 %
De 1 a 2 salários mínimos	Outro	3,00 %
	A pé	7,46 %
	Bicicleta	4,42 %
	Carro	7,61 %
	Motocicleta	8,68 %
	Ônibus	61,29 %
	Metrô	8,30 %
	Outro	2,24 %

Até 1 salário mínimo	A pé	52,53 %
	Bicicleta	2,29 %
	Carro	4,44 %
	Motocicleta	3,78 %
	Ônibus	31,72 %
	Metrô	4,23 %


Fonte: adaptado de ICPS (2018).

Segundo os percentuais fornecidos pelo ICPS (2018), aqueles com menor renda residem próximo ao trabalho, visto que para esta finalidade, o principal modal utilizado por eles é a pé (Tabela 4). Validando assim que as condições socioeconômicas dos bairros recifenses são heterogêneas, o que reforça a necessidade de compreender a influência dessa desigualdade no tocante à pandemia sob a ótica da mobilidade.

4.2.1 Análise gráfica

Segue apresentada a sequência de mapas elaborados com a finalidade de ilustrar o relacionamento espacial entre o PP_b e o IVS.


Figura 58 - Mapa de variáveis. (a) IVS; (b) PP_b dos bairros ao espalhamento da COVID-19



Fonte: A autora (2021).

Segundo o IPEA (2020), o índice é o resultado da média aritmética dos subíndices: IVS Infraestrutura Urbana, IVS Capital Humano e IVS Renda e Trabalho, e cada um deles entra no cálculo do IVS final com o mesmo peso. Quando representado, o índice deve ser lido conforme o apresentado na Figura 59.


Figura 59 - Rampa de estratificação da camada IVS



Fonte: IPEA (2020).

Para visualizar o relacionamento espacial entre as duas variáveis fez-se então o emprego do método coroplético bivariado (Figura 60). Sendo assim, ao criar o mapa de relacionamento entre o PP_b e o IVS, as variáveis foram divididas em cinco classes, manualmente, com os valores de intervalo da figura 59.


Figura 60 - Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19 (PP_b x IVS) – 5x5



Como apontado por Fienberg (1979, p. 176), quanto mais classes, maior é a dificuldade em interpretar as combinações das variáveis. Mas, embora a leitura do mapa seja confusa em função das cinco classes selecionadas, resultando numa variação de 25 cores diferentes, destaca-se no mapa as regiões em que há coincidência entre as duas variáveis.

Entretanto, não se consegue diferenciar os diferentes tons de verde ou de vermelho, ocasionando uma confusão ao tentar compreender em que classe está contido cada bairro. Como o resultado obtido não possui fácil entendimento, o presente estudo, assim como Freire, Campos e Fusco (2020), classificou o IVS em três classes utilizando o método de intervalo geométrico. A Figura 61 ilustra o mesmo relacionamento em três classes.

Figura 61 - Mapa dos bairros do Recife mais propensos ao Risco de disseminação da COVID-19
 $(PP_b \times IVS) - 3 \times 3$



Fonte: A autora (2021).

O mapa ilustra a relação existente entre o PP_b e o IVS por bairro do Recife. Percebe-se que as relações geográficas não são aleatórias, compreendendo-se que existe, uma variação geográfica na distribuição do PP_b e do IVS, uma vez que se torna fácil identificar a presença de um *cluster* de bairros na região Nordeste do município, onde se concentram os bairros com maiores valores do índice (Morro da Conceição, Brejo de Beberibe, Bomba do Hemetério, Água Fria, Dois Unidos e Peixinhos).

Ao analisarmos o mapa, percebe-se que os bairros recifenses que apresentam valores maiores para o IVS estão dentre os que possuem maior propensão à disseminação da COVID-19, conforme *ranking* apresentado no Tabela 5.

Tabela 5 - *Ranking* dos bairros com maior Risco e dos bairros com maior IVS


Bairros mais propensos ao Risco de disseminação da COVID-19			Bairros com maior IVS		
Posição	Bairro	R_v	Posição	Bairro	R_v
1º	Pina	0,444	1º	Passarinho	1,00
2º	Passarinho	0,366	2º	Bairro da Guabiraba	0,999
3º	Morro da Conceição	0,308	3º	Brejo de Beberibe	0,996
4º	Mangueira	0,303	4º	Dois Unidos	0,993
5º	Dois Unidos	0,293	5º	Peixinhos	0,921
6º	Brejo de Beberibe	0,291	6º	Nova Descoberta	0,886
7º	Peixinhos	0,275	7º	Córrego do Jenipapo	0,885
8º	Bomba do Hemetério	0,271	8º	Guabiraba	0,876
9º	Brejo da Guabiraba	0,243	9º	Vasco da Gama	0,838
10º	Campina do Barreto	0,237	10º	Barro	0,825

Fonte: A autora (2021).

Como afirmado anteriormente, o Recife é uma das capitais brasileiras com maior desigualdade social (IBGE, 2021). Ao realizar a análise das distribuições separadamente, verifica-se que nem todos os bairros com maior vulnerabilidade social (maiores valores para o IVS) são, necessariamente, aqueles em que possuem os maiores valores para o R_v , identificando-se visualmente a existência de relação inversa entre as variáveis.

Freire, Campos e Fusco (2020) desenvolveram uma análise do relacionamento entre o número de casos da COVID-19 e o IVS na capital pernambucana. No estudo, os autores utilizaram o método coroplético bivariado para representar as duas variáveis. A Figura 62 ilustra o produto apresentado no estudo.

Figura 62 - Mapa da variação dos casos confirmados por bairros do Recife entre os dias 10 e 25 de maio de 2020



Fonte: Freire, Campos e Fusco (2020).

No estudo, Freire, Campos e Fusco (2020) afirmam que apesar de Boa Viagem apresentar a maior variação no número de casos no período observado, o bairro possui baixo IVS (0,03) e, se comparado ao bairro vizinho, o Ibura, a situação é bastante diferente, mesmo o bairro possuindo um valor de 0,33 para o IVS. Sendo assim, bem como analisado neste estudo, entende-se que nem sempre o bairro com maior risco será aquele com maior valor para o IVS, enfatizando assim duas situações distintas que expõem as desigualdades sociais.

Logo, pode-se deduzir que a relação inversa identificada entre as variáveis (PP_b e o IVS) é resultante dessas desigualdades.

5 CONCLUSÕES E RECOMENDAÇÕES

Este estudo analisou a influência da mobilidade urbana sob a disseminação de casos da COVID-19. Após as análises realizadas foi possível identificar padrões entre a dinâmica da doença e o perfil etário da população, bem como desse espalhamento com a vulnerabilidade social dos bairros recifenses. Para atingir os objetivos propostos neste estudo científico, foi apresentado o estado da arte das tendências em tecnologias da Geoinformação no tocante a espacialização da pandemia, como também foi realizada uma investigação sobre a correlação existente entre o potencial de disseminação da doença e indicadores sociais por meio do reconhecimento de dois padrões em um único mapa.

O fato de analisar a pandemia da COVID-19 sob o impacto que o sistema de transporte público coletivo tem sobre a disseminação da doença, possibilitou identificar a importância que deve ser dada ao estudo do potencial de transmissão oriundo do uso deste modal.

Para o desenvolvimento da metodologia utilizada e identificação dos bairros do Recife mais propensos à doença, fez-se necessária a compatibilização das bases de dados empregadas. Usualmente são utilizadas bases de dados de diferentes fontes, os quais dispõem de dados relacionais e não-relacionais, uma vez que não há, nacionalmente, uma exigência por padronização na publicação de todos os diferentes tipos de dados e metadados oriundos das secretarias de saúde ou de mobilidade e controle urbano.

Considerando os elementos de qualidade de dados espaciais, os dados de entrada utilizados nas análises apresentaram algumas restrições, tais quais: consistência lógica (conceitual e formato), consistência topológica, acurácia temática e temporal, e usabilidade. Este último devido ao fato de o código utilizado estar escrito em *python*, este com o objetivo de manipular com variabilidade, velocidade, volume, valor e veracidade das bases de dados, e calcular os índices por bairro, o que requer conhecimento prévio por parte do operador.

Posteriormente, para a determinação do PP_b , investigou-se o relacionamento existente entre o tráfego oriundo do transporte público coletivo daqueles que o utilizam com o interesse “residência > trabalho”, e o acumulado de casos no contexto epidemiológico inicial. Estimando assim o potencial de absorção do número de casos

da doença, o que possibilitou identificar quais os bairros mais predispostos à disseminação da COVID-19.

Verificou-se então que os bairros de Paissandu, Ilha do Leite, Pina, Derby e Graças seriam àqueles com maior potencial de importação de novos casos em função dos fluxos de tráfego oriundos do transporte público coletivo, motivo trabalho.

Entretanto, de maneira geral, em toda análise, os resultados convergiram ao entendimento de que, provavelmente, a determinação das medidas restritivas, em 16/05/2020, com a publicação do Decreto nº 49.017, de 11 de maio de 2020 (PERNAMBUCO, 2020), não catalisou o espalhamento da doença para aqueles bairros que seriam mais suscetíveis, seja pela presença daqueles mais idosos ou da parcela de indivíduos com maior vulnerabilidade social. Uma vez que, ao término do período de observação do acumulado de casos (31/12/20), os bairros recifenses mais atingidos foram Boa Viagem, Várzea, Ibura, Cohab e Iputinga, supõe-se então que a determinação de medidas restritivas no que tange a interrupção do transporte público coletivo nessas localidades, poderiam mitigar o aumento do número de casos da COVID-19.

Quanto à representação do risco, o método coroplético bivariado veio por facilitar a publicação da iminente atenção que deve ser dada ao estudo. Método que potencializa em um único mapa a compreensão do fenômeno analisado, ou seja, para o caso em questão, os mapas bivariados apontam de forma clara quais os bairros que estão mais vulneráveis à doença segundo uma escala de risco (baixo > alto) e um indicador socioeconômico.

Em síntese, segundo os resultados obtidos com a aplicação dos testes estatísticos e as análises gráficas realizadas, observou-se nos mapas bivariados a existência de *clusters* de cores, estes caracterizados por uma relação linear moderada entre o PP_b e os índices considerados.

Ao realizar a análise da evolução do risco de disseminação aos índices utilizados nesta pesquisa, pode-se concluir que o estudo do fluxo contribui para a identificação dos bairros mais propensos. E que, embora não seja um modelo preditivo, atesta-se que a mobilidade urbana é uma das variáveis a serem inseridas em modelos matemáticos e epidemiológicos que buscam prever a propagação de doenças similares à COVID-19. Enfatiza-se também a necessidade de incluir a análise da dinâmica urbana nos estudos de enfrentamento à pandemia.

Para futuros trabalhos, sugere-se incorporar à análise outras variáveis no intuito de compreender como as relações socioeconômicas podem ter influenciado na disseminação da COVID-19 em Recife. Recomenda-se também que o cálculo do PP_b seja ampliado para os demais modais (transporte público individual, carro, motocicleta, a pé, bicicleta) e para os diferentes tipos de viagens interesse (residência > trabalho; residência > educação; residência > trabalho > educação; residência > educação > trabalho).

Sugere-se ainda que, devido às restrições temporais e espaciais, sejam realizados estudos voltados à política de dados abertos e Infraestrutura de Dados Espaciais – IDE, de forma a auxiliar os gestores no processo de padronização da publicação de dados geoespaciais por parte das Secretarias de Saúde e de Mobilidade e Controle Urbano.

Em suma, estima-se que a integração desses fluxos de dados deve auxiliar na tomada de decisão com o intuito de mitigar a disseminação da COVID-19, visto que a metodologia aqui testada, mesmo com a escassez de dados de fluxo durante a pandemia, representa os hábitos de viagem dos usuários do sistema de transporte público do Recife.

Por fim, embora as pessoas reconheçam a gravidade da pandemia da COVID-19 e a necessidade de seguir com as medidas preventivas, à medida que a pandemia se torna prolongada, essas mesmas pessoas estão diminuindo as percepções de risco. Contudo, como uma visão de futuro, deseja-se que a gestão da pandemia promova a confiança nas respostas do governo, e que estas soluções não afetem a qualidade de vida das próximas gerações.

REFERÊNCIAS

- ALVES, D.; BERNARDI, F.A.; CARVALHO, I.; NEIVA, M.B.; CREPALDI, N.Y.; LIMA, V.C. **Painel Covid São Paulo**. 2020. Disponível em: <<https://ciis.fmrp.usp.br/covid19/sp-br>>. Acesso em: 29 jul. 2020.
- ANDERSON, R.M.; HEESTERBEEK, H.; KLINKENBERG, D.; HOLLINGSWORTH, T.D. **How will country-based mitigation measures influence the course of the COVID-19 epidemic?** The Lancet, 2020. v. 395, n. 10228, p. 931–934. Acessado em: 30 nov. 2020.
- ARAGÓN, G.C. **Construcción y reconstrucción del desastre**. Cidade do México: [s.n.], 2011. ed. Plaza y Valdés. Disponível em: <<http://observatoriogeograficoamericalatina.org.mx/egal6/Geografiasocioeconomica/Geografiaespacial/620.pdf>>. Acesso em: 12 jan. 2021.
- AYRES, J.R.C.M.; FRANÇA JUNIOR, I.; CALAZANS, G.J.; SALETTI FILHO, H.C. **Vulnerabilidade e prevenção em tempos de AIDS. Sexualidade pelo avesso: direitos, identidades e poder**, 1999. Disponível em: <<https://repositorio.usp.br/item/001047427>>. Acesso em: 3 jun. 2021.
- BDE. **População residente por cor ou raça, segundo o sexo**. Base de Dados do Estado. Governo do Estado de Pernambuco., 2021a. Disponível em: <http://www.bde.pe.gov.br/visualizacao/Visualizacao_formato2.aspx?codFormatacao=1245&CodInformacao=1127&Cod=3>. Acesso em: 3 jun. 2021.
- _____. **População residente por grupos de idade, segundo o sexo. Governo do Estado de Pernambuco**. Base de Dados do Estado (BDE). Governo do Estado de Pernambuco. Instituto Brasileiro de Geografia e Estatística, Censos Demográficos - Resultados do Universo. Período de referência 2010., 2021b. Disponível em: <http://www.bde.pe.gov.br/visualizacao/Visualizacao_formato2.aspx?codFormatacao=1465&CodInformacao=1207&Cod=3>. Acesso em: 23 jun. 2021.
- BERTIN, J. **Sémiologie graphique**. Les diagrammes. Les réseaux. Les cartes. 1968. Disponível em: <https://www.persee.fr/doc/assr_0003-9659_1968_num_26_1_1815_t1_0176_0000_3>. Acesso em: 12 ago. 2020.
- _____. **Theory of communication and theory of the graphic**. International Yearbook of Cartography. n. 18, p.118-126, 1978. Acessado em: 30 nov. 2020.
- BIGGS, E.N.; MALONEY, P.M.; RUNG, A.L.; PETERS, E.S.; ROBINSON, W.T. **The Relationship Between Social Vulnerability and COVID-19 Incidence Among Louisiana Census Tracts**. Frontiers in Public Health, 20 jan. 2021. v. 8. Disponível em: <<https://www.frontiersin.org/articles/10.3389/fpubh.2020.617976/full>>. Acesso em: 30 maio. 2021.
- BORBOREMA, A.C.B.A.; MARTINELLI, M. **Generalização Cartográfica Aplicada a Mapas Temáticos Turísticos**. IV Simpósio Brasileiro de Ciências Geodésicas e Tecnologias da Geoinformação, Recife - PE, maio. 2012. p. 1–10. Disponível em:

<https://www3.ufpe.br/cgtg/SIMGEOIV/CD/artigos/Todos_Artigos/088_5.pdf>. Acesso em: 26 ago. 2020.

BRASIL. **Lei Federal nº 13.979, de 6 de fevereiro de 2020.** Dispõe sobre as medidas para enfrentamento da emergência de saúde pública de importância internacional decorrente do coronavírus responsável pelo surto de 2019. Presidência da República Secretaria-Geral. Subchefia para Assuntos Jurídicos., 2020a. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/Lei/L13979.htm>. Acesso em: 26 ago. 2020.

_____. **Decreto nº 10.282, de 20 de março de 2020.** Regulamenta a Lei nº 13.979, de 6 de fevereiro de 2020, para definir os serviços públicos e as atividades essenciais. 2020b. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2019-2022/2020/decreto/D10282.htm>. Acesso em: 26 ago. 2020.

BROCKMANN, D.; HELBING, D. **The hidden geometry of complex, network-driven contagion phenomena.** Science, 2013. v. 342, n. 6164, p. 1337–1342. Acesso em: 30 nov. 2020.

BROWNSTEIN, J.S.; WOLFE, C.J.; MANDL, K.D. **Empirical evidence for the effect of airline travel on inter-regional influenza spread in the United States.** PLoS Medicine, 2006. v. 3, n. 10, p. 1826–1835. Acesso em: 30 nov. 2020.

BUCKEE, C.O.; BALSARI, S.; CHAN, J.; CROSAS, M.; DOMINICI, F.; GASSER, U.; GRAD, Y.H.; GRENFELL, B.; HALLORAN, M.E.; KRAEMER, M.U.G.; LIPSITCH, M.; METCALF, C.J.E.; MEYERS, L.A.; PERKINS, T.A.; SANTILLANA, M.; SCARPINO, S.V.; VIBOUD, C.; WESOLOWSKI, A.; SCHROEDER, A. **Aggregated mobility data could help fight COVID-19.** Science, 10 abr. 2020. v. 368, n. 6487, p. 145.2-146. Disponível em: <<https://www.sciencemag.org/lookup/doi/10.1126/science.abb8021>>. Acesso em: 17 dez. 2020.

CÂMARA, G.; DAVIS, C. **Análise Espacial e Geoprocessamento.** In: CÂMARA, Gilberto; DAVIS, Clodoveu; MONTEIRO, A. M. V. (Org.). Introdução à Ciência da Geoinformação. [S.l.]: [s.n.], 2004. Acesso em: 17 jul. 2020.

CANDIDO, D.S.; WATTS, A.; ABADE, L.; KRAEMER, M.U.G.; PYBUS, O.G.; CRODA, J.; OLIVEIRA, W.; KHAN, K.; SABINO, E.C.; FARIA, N.R. **Routes for COVID-19 importation in Brazil.** Journal of Travel Medicine, 1 abr. 2020. v. 27, n. 3. Acesso em: 29 jul. 2020.

CASTRO, R.R.; SANTOS, R.S.C.; SOUSA, G.J.B.; PINHEIRO, Y.T.; MARTINS, R.R.I.M.; PEREIRA, M.L.D.; SILVA, R.A.R. **Epidemiology and Infection Spatial dynamics of the COVID-19 pandemic in Brazil.** Epidemiology and Infection, 2021. Disponível em: <<https://doi.org/10.1017/S0950268821000479>>. Acesso em: 29 jul. 2020.

CECA/UFAL. **Dashboard COVID 19 Maceió.** Curso de Engenharia de Agrimensura do Campus de Engenharia e Ciências Agrárias da Universidade Federal de Alagoas, 2020. Disponível em: <<https://agrimensuraufal.maps.arcgis.com/apps/opsdashboard/index.html#/7ef6d01e>>

09254a25b9681be549bbe2ee?utm=apoioacrise-coronavirus>. Acesso em: 29 jul. 2020.

CHAN, F.H.; SKALI, A.; TORGLER, B. **A Global Dataset of Human Mobility**. 2020. n. 2012, p. 1–5. Acesso em: 11 fev. 2021.

CHEN, S. **Coronavirus can travel twice as far as official ‘safe distance’ and stay in air for 30 minutes, Chinese study finds**. South China Morning Post, 2020.

Disponível em:

<<https://www.scmp.com/news/china/science/article/3074351/coronavirus-can-travel-twice-far-official-safe-distance-and-stay>>. Acesso em: 11 fev. 2021.

CIEVS - Centro de Informações Estratégicas de Vigilância em Saúde. **Boletim Epidemiológico N. 291. Data de emissão 31/12/2020**. Secretaria de Saúde do Recife., 2020. Disponível em:

<https://cievsrecife.files.wordpress.com/2021/01/boletim-recife_coronavirus-31-12-20.pdf>. Acesso em: 1º jan. 2021.

CNM - Confederação Nacional de Municípios. **Mobilidade Urbana e os Objetivos de Desenvolvimento Sustentável**. 2021. Disponível em:

<<https://observatoriodabicicleta.org.br/uploads/2021/02/MobilidurbanaODSCNM.pdf>>. Acesso em: 3 jun. 2021.

COCCIA, M. **Factors determining the diffusion of COVID-19 and suggested strategy to prevent future accelerated viral infectivity similar to COVID**. Science of the Total Environment, 2020. v. 729, p. 138474. Disponível em:

<<https://doi.org/10.1016/j.scitotenv.2020.138474>>. Acesso em: 30 nov. 2020.

COELHO, M.T.P.; RODRIGUES, J.F.M.; MEDINA, A.M.; SCALCO, P.; TERRIBILE, L.C.; VILELA, B.; DINIZ-FILHO, J.A.F.; DOBROVOLSKI, R. **Global expansion of COVID-19 pandemic is driven by population size and airport connections**.

PeerJ, 2020. v. 8, n. August. Acesso em: 30 nov. 2020.

COLIZZA, V.; BARRAT, A.; BARTHELEMY, M.; VALLERON, A.J.; VESPIGNANI, A. **Modeling the worldwide spread of pandemic influenza: Baseline case and containment interventions**. PLoS Medicine, 2007. v. 4, n. 1, p. 0095–0110. Acesso em: 30 nov. 2020.

DECART. **Evolução dos Casos Confirmados**. UFPE, 2020. Disponível em: <<https://sites.google.com/view/covidecart>>. Acesso em: 22 maio 2020.

DESJARDINS, M.R.; HOHL, A.; DELMELLE, E.M. **Rapid surveillance of COVID-19 in the United States using a prospective space-time scan statistic: Detecting and evaluating emerging clusters**. Applied Geography, 2020. v. 118, n. March, p. 102202. Disponível em: <<https://doi.org/10.1016/j.apgeog.2020.102202>>. Acesso em: 30 nov. 2020.

DUNN, R. **A Dynamic Approach to Two-Variable Color Mapping**. The American Statistician, 1 nov. 1989. v. 43, n. 4, p. 245–252. Disponível em:

<<https://www.tandfonline.com/doi/abs/10.1080/00031305.1989.10475669>>. Acesso

em: 26 abr. 2020.

ESRI. Disponível em: <<https://www.esri.com/en-us/home>>. Acesso em: 16 jul. 2020.

_____. **Ajuda do ArcGIS Pro**. Disponível em: <<https://pro.arcgis.com/en/pro-app/latest/help/mapping/layer-properties/data-classification-methods.htm#:~:text=Geometrical%20interval,-The%20geometrical%20interval&text=The%20algorithm%20creates%20geometric%20intervals,between%20intervals%20is%20fairly%20consistent>>. Acesso em: 03 jan. 2021.

EYTON, J.R. **Map Supplement: Complementary-Color, Two-Variable Maps**. *Annals of the Association of American Geographers*, 3 jul. 1984. v. 74, n. 3, p. 477–490. Disponível em: <http://www.jstor.org/stable/2563009>>. Acesso em: 26 abr. 2020.

FERREIRA, S.C. **A Centralidade de Londrina, Maringá, Cascavel, Ponta Grossa e Guarapuava na Rede Urbana do Paraná**. *Raega, Paraná* 23, p. 06-31. Disponível em: <<https://revistas.ufpr.br/raega/article/view/24696>>. Acesso em: 09 set. 2020.

FIENBERG, S.E. **Graphical Methods in Statistics**. *The American Statistician*, 1 nov. 1979. v. 33, n. 4, p. 165–178. Disponível em: <<https://www.tandfonline.com/doi/abs/10.1080/00031305.1979.10482688>>. Acesso em: 26 abr. 2020.

Fiocruz - Fundação Osvaldo Cruz. **Mapa: pesquise sua rua e veja o risco de contaminação por coronavírus**. Estado de Minas. Notícia. Disponível em: <https://www.em.com.br/app/noticia/nacional/2020/05/25/interna_nacional,1150461/mapa-pesquise-sua-rua-e-veja-o-risco-de-contaminacao-por-coronavirus.shtml>. Acesso em: 29 maio. 2020.

_____. **Covid-19: indicadores oferecem dados sobre grupos de risco**. Notícia. Disponível em: <<https://agencia.fiocruz.br/covid-19-indicadores-oferecem-dados-sobre-grupos-de-risco>>. Acesso em: 30 abr. 2020.

FMS - Fundação Municipal de Saúde. **Painel Covid-19 Teresina**. Fundação Municipal de Saúde de Teresina - Estado do Piauí, 2020. Disponível em: <<http://www.painelcovid19teresina.pmt.pi.gov.br/>>. Acesso em: 29 jul. 2020.

FORTALEZA, C.M.C.B.; GUIMARÃES, R.B.; DE ALMEIDA, G.B.; PRONUNCIATE, M.; FERREIRA, C.P. **Taking the inner route: spatial and demographic factors affecting vulnerability to COVID-19 among 604 cities from inner São Paulo State, Brazil**. *Epidemiology and Infection*, 2020. Disponível em: <<https://www.seade.gov.br/>>. Acessado em: 30 nov. 2020.

FORTALEZA, C.M.C.B.; GUIMARÃES, R.B.; CATÃO, R.C.; FERREIRA, C.P.; DE ALMEIDA, G.B.; PUGLIESI, E. **Elementary spatial structures and dispersion of COVID-19: health geography directing responses to public health emergency in São Paulo State, Brazil**. 2020. p. 1–10. Acesso em: 30 nov. 2020.

FRANCH-PARDO, I.; NAPOLETANO, B.M.; ROSETE-VERGES, F.; BILLA, L.

Spatial analysis and GIS in the study of COVID-19. A review. Science of the Total Environment, 2020. v. 739, p. 140033. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2020.140033>>. Acesso em: 10 fev. 2021.

FREIRE, N.C.F.; CAMPOS, L.R.; FUSCO, W. **Pandemia avança nos bairros mais pobres na Região Metropolitana do Recife.** Recife: [s.n.], 2020. Disponível em: <https://www.fundaj.gov.br/images/stories/cieg/covid/notas/10-NOTA_CIEG_COVID_01JUNHO2020_BAIRROS_RMR.pdf>. Acesso em: 11 fev. 2021.

FREIRE, N.C.F.; NATENZON, C.E. **Vulnerabilidade Social como uma dimensão do Risco aos Desastres Naturais por Inundações Catastróficas na Zona da Mata Norte do Estado de Alagoas, Brasil.** Projeto e Tecnologia. Revista Ímpeto N. 10., 2020. p. 14. Disponível em: <<https://www.seer.ufal.br/index.php/revistaimpeto/article/view/11477/7838>>. Acesso em: 11 fev. 2021.

GALKA, M. **World Migration Map.** 2020. Disponível em: <http://metrocosm.com/global-migration-map.html?utm_medium=website&utm_source=archdaily.com.br&fbclid=IwAR3dY4agjqoiSF6NM0HIsTbhOxcQ5CLZPI8uIS3pwqPHhIP1hNFuan6amtA>. Acesso em: 21 out. 2020.

GAUTREAU, A.; BARRAT, A.; BARTHÉLEMY, M. **Global disease spread: Statistics and estimation of arrival times.** Journal of Theoretical Biology, 2008. v. 251, n. 3, p. 509–522. Acesso em: 26 abr. 2020.

GDF - Governo do Distrito Federal. **Painel COVID-19 no Distrito Federal.** 2020. Disponível em: <[>https://covid19.ssp.df.gov.br/extensions/covid19/covid19.html#/](https://covid19.ssp.df.gov.br/extensions/covid19/covid19.html#/)>. Acesso em: 29 jul. 2020.

GEOCOMBATE COVID-19 BA. **Risco dos bairros de Salvador ao espalhamento do COVID-19 decorrente da circulação de pessoas e condições socioeconômicas.** UFBA, 2020. Disponível em: <<https://drive.google.com/open?id=13w8Je9wLmMT3LMuLNV8oyLrRMpHjcbtF>>. Acesso em: 30 ago. 2020.

GIULIANI, D.; DICKSON, M.M.; ESPA, G.; SANTI, F. **Modelling and predicting the spatio-temporal spread of cOVID-19 in Italy.** BMC Infectious Diseases, 2020. v. 20, n. 1, p. 1–10. Acesso em: 11 fev. 2021.

GRAIS, R.F.; ELLIS, J.H.; GLASS, G.E. **Assessing the impact of airline travel on the geographic spread of pandemic influenza.** European Journal of Epidemiology, 2003. v. 18, n. 11, p. 1065–1072. Acesso em: 11 fev. 2021.

GUIMARÃES, R.B.; PUGLIESI, E. A. **Radar COVID-19.** 2021. Disponível em: <<http://covid19.fct.unesp.br/mapeamento-cartografico/>>. Acesso em: 9 jan. 2021.

HAJAR, F.N. **Juntos Contra o COVID.** 2020. Disponível em: <<https://juntoscontraocovid.org/map.html>>. Acesso em: 20 jul. 2020.

HENSON, T.C. TIMMONS, M.; MCDANIEL, J. **Public Transit Emergency Preparedness Against Ebola and Other Infectious Diseases: Legal Issues**. The National Academies Press: Washington, 2017. Disponível em: <<https://repository.netecweb.org/items/show/323>>. Acesso em: 09 set. 2020.

IANNELLI, F.; KOHER, A.; BROCKMANN, D.; HÖVEL, P.; SOKOLOV, I.M. **Effective distances for epidemics spreading on complex networks**. Physical Review E, 2017. v. 95, n. 1, p. 1–7.
IBGE. IBGE Cidades. **Instituto Brasileiro de Geografia e Estatística**, 2021. Disponível em: <<https://cidades.ibge.gov.br>>. Acesso em: 21 jun. 2021.

ICPS - Instituto da Cidade Pelópidas Silveira. **Relatório Executivo da Pesquisa Origem-Destino do Recife 2016**. Instituto da Cidade Pelópidas Silveira, 2016. Disponível em: <https://docs.google.com/uc?export=download&id=1PFHBXaU8Pido7_JICvCbJSeg16JUIERe>. Acesso em: 26 abr. 2020.

_____. **Pesquisa Origem-Destino (OD) 2018**. Instituto da Cidade Pelópidas Silveira, 2018. Disponível em: <<http://planodemobilidade.recife.pe.gov.br/node/61265>>. Acesso em: 26 abr. 2020.

_____. **Matrizes Origem-Destino da Pesquisa OD 2018**. Instituto da Cidade Pelópidas Silveira, 2020. Disponível em: <<http://icps.recife.pe.gov.br/node/61317>>. Acesso em: 8 jun. 2021.

inloco. **Índice de isolamento social**. 2020. Disponível em: <<https://mapabrasileirodacovid.inloco.com.br/pt/>>. Acesso em: 24 jul. 2020.

IPEA - Instituto de Pesquisa Econômica Aplicada. **Índice de Vulnerabilidade Social**. Atlas de Vulnerabilidade Social, 2020. Disponível em: <<http://ivs.ipea.gov.br/index.php/pt/>>. Acesso em: 5 jul. 2021.

JELOKHANI-NIARAKI, M. **Collaborative spatial multicriteria evaluation: a review and directions for future research**. International Journal of Geographical Information Science, 2021. v. 35, n. 1, p. 9–42. Disponível em: <<https://doi.org/10.1080/13658816.2020.1776870>>. Acesso em: 9 jun. 2021.

JOHNS HOPKINS UNIVERSITY AND MEDICINE. **Coronavirus Resource Center. COVID-19 Dashboard**. 2021. Disponível em: <<https://coronavirus.jhu.edu/map.html>>. Acesso em: 3 jun. 2021.

KRAEMER, M.U.G.; YANG, C.; GUTIERREZ, B.; WU, C.; KLEIN, B.; LI, R.; HANAGE, W.P.; BROWNSTEIN, J.S.; LAYAN, M.; VESPIGNANI, A.; TIAN, H.; DYE, C.; PYBUS, O.G.; SCARPINO, S.V. **Supplementary Materials for The effect of human mobility and control measures on the COVID-19 epidemic in China**. Science, 2020. v. 368(6490), p. 493–497. Acesso em: 19 dez. 2020.

KUUPIEL, D.; ADU, K.M.; BAWONTUO, V.; ADOGBOBA, D.A.; DRAIN, P.K.; MOSHABELA, M.; MASHAMBA-THOMPSON, T.P. **Geographical accessibility to glucose-6-phosphate dioxxygenase deficiency point-of-care testing for antenatal**

care in Ghana. *Diagnostics*, 2020. v. 10, n. 4. Acesso em: 19 dez. 2020.

LEE, J.G.; KANG, M. **Geospatial Big Data: Challenges and Opportunities.** *Big Data Research*, 2015. v. 2, n. 2, p. 74–81. Disponível em: <<http://dx.doi.org/10.1016/j.bdr.2015.01.003>>. Acesso em: 20 jul. 2020.

LEONOWICZ, A. **Two-variable choropleth maps as a useful tool for visualization of geographical relationship.** *Geografija*, 2006. v. 42, n. 1, p. 33–37. Disponível em: <<https://publications.lsmuni.lt/object/elaba:6210410/index.html>>. Acesso em: 19 dez. 2020.

LONGINI, I. M. **A mathematical model for predicting the geographic spread of new infectious agents.** *Mathematical Biosciences* 90, 367–383, 1988. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0025556488900752>>. Acesso em: 18 ago. 2020. Acesso em: 11 fev. 2021.

LÓPEZ-OLMEDO, N.; STERN, D.; PÉREZ-FERRER, C.; GONZÁLEZ-MORALES, R.; CANTO-OSORIO, F.; BARRIENTOS-GUTIÉRREZ, T. **Revisión rápida: probabilidad de contagio por infecciones respiratorias agudas en el transporte público y medidas para mitigarlo.** *Salud Pública de México*, 19 maio. 2020. p. 1. Disponível em: <<http://www.saludpublica.mx/index.php/spm/article/view/11601>>. Acesso em: 29 jul. 2020.

MAPBIOMAS. **Geocovid. 2021.** Disponível em: <<https://covid.mapbiomas.org/cases>>. Acesso em: 3 jun. 2021.

MARTÍN-CALVO, D.; ALETA, A.; PENTLAND, A.; MORENO, Y.; MORO, E. **Effectiveness of social distancing strategies for protecting a community from a pandemic with a data-driven contact network based on census and real-world mobility data.** *MT Connection Sciences*, 2020. p. 1–9. Disponível em: <https://covid-19-sds.github.io/assets/pdfs/Preliminary_Report_Effectiveness_of_social_distance_strategies_COVID-19.pdf>. Acesso em: 19 dez. 2020.

MEYER, M.A.; BROOME, F.R.; SCHWEITZER, R.H. **Color Statistical Mapping by the U.S. Bureau of the Census.** *The American Cartographer*, 14 jan. 1975. v. 2, n. 2, p. 101–117. Disponível em: <<https://www.tandfonline.com/doi/full/10.1559/152304075784313250>>. Acesso em: 29 jul. 2020.

MO, B.; FENG, K.; SHEN, Y.; TAM, C.; LI, D.; YIN, Y.; ZHAO, J. **Modeling epidemic spreading through public transit using time-varying encounter network.** *Transportation Research Part C: Emerging Technologies*, 2021. v. 122, n. October 2020, p. 102893. Disponível em: <<https://doi.org/10.1016/j.trc.2020.102893>>. Acesso em: 2 jun. 2021.

MOLLALO, A.; VAHEDI, B.; RIVERA, K.M. **GIS-based spatial modeling of COVID-19 incidence rate in the continental United States.** *Science of the Total Environment*, 2020. v. 728, p. 138884. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2020.138884>>. Acesso em: 19 dez. 2020.

MS - Ministério da Saúde. **Painel Coronavírus**. 2020. Disponível em: <<https://covid.saude.gov.br/>>. Acesso em: 27 jul. 2020.

MUSSELWHITE, C.; AVINERI, E.; SUSILO, Y. Editorial JTH 16 – **The Coronavirus Disease COVID-19 and implications for transport and health**. Journal of Transport & Health, mar. 2020. v. 16, p. 100853. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S2214140520300578>>. Acesso em: 26 ago. 2020.

NATENZON, C. E. **La pandemia Covid-19 em una perspectiva de gestión de riesgo de desastres**. I Webinar da atividade de Seminários de Integração do PPGAU-UFAL. Disponível em: <<https://www.youtube.com/watch?v=dVDqdGfeLLw&list=LL&index=2>>. Acesso em: 11 fev. 2021.

NITAHARA, A. **Coronavírus chegou ao Brasil pela Europa, América do Norte e Oceania**. Agência Brasil, 2020. Disponível em: <<https://agenciabrasil.ebc.com.br/saude/noticia/2020-06/coronavirus-chegou-ao-brasil-pela-europa-america-do-norte-e-oceania#:~:text=Pesquisadores da Fundação Oswaldo Cruz,do Norte e na Oceania>>. Acesso em: 24 jul. 2020.

OMS – Organização Mundial da Saúde. **Ações críticas de preparação, prontidão e resposta para COVID-19**. Orientação Técnica 2020. Disponível em: <<https://www.who.int/emergencies/diseases/novel-coronavirus-2019/technical-guidance/critical-preparedness-readiness-and-response-actions-for-covid-19>>. Acesso em: 30 maio. 2020.

PAREEK, M.; BANGASH, M.N.; PAREEK, N.; PAN, D.; SZE, S.; MINHAS, J.S.; HANIF, W.; KHUNTI, K. **Ethnicity and COVID-19: an urgent public health research priority**. The Lancet, maio. 2020. v. 395, n. 10234, p. 1421–1422. Disponível em: <<https://linkinghub.elsevier.com/retrieve/pii/S0140673620309223>>. Acesso em: 05 maio. 2021.

PARIZOTTO, T. C. **Pesquisadores trabalham no mapeamento sobre a covid-19**. Assessoria de Comunicação Social da Universidade Estadual de Maringá, 2020. Disponível em: <http://www.noticias.uem.br/index.php?option=com_content&view=article&id=24484:pesquisadores-trabalham-no-mapeamento-sobre-a-covid-19&catid=986:pgina-central&Itemid=210>. Acesso em: 26 abr. 2020.

PCR - Prefeitura da Cidade do Recife. **A nova pesquisa Origem-Destino do Recife**. Prefeitura da Cidade do Recife, 2015. Disponível em: <<http://icps.recife.pe.gov.br/node/568>>. Acesso em: 30 jun. 2020.

_____. **Painel COVID-19 Recife**. Prefeitura da Cidade do Recife, 2020. Disponível em: <<https://experience.arcgis.com/experience/305086baffdf4225aae1339fb9df7ba2/?utm=apoioacrise-coronavirus>>. Acesso em: 29 jul. 2020.

PEPE, E.; BAJARDI, P.; GAUVIN, L.; PRIVITERA, F.; LAKE, B.; CATTUTO, C.;

TIZZONI, M. **COVID-19 outbreak response, a dataset to assess mobility changes in Italy following national lockdown**. Scientific Data, 2020. v. 7, n. 1, p. 1–16. Acesso em: 11 fev. 2021.

PEREIRA JÚNIOR, J.U.; DELEGADO, J.P.M.; PEDRASSOLI, J.C.; SOUZA, F.A.; BRITO, P.L.; VIANA, M.S.; GALINDO, E.; BARATA, A.; CASSIANO, A.; JÚNIOR, C.; SANTOS, G. **Risco dos bairros de Salvador ao espalhamento do COVID-19 decorrente da circulação de pessoas e condições socioeconômicas**. Nota Técnica de pesquisadores do grupo GeoCombate COVID-19 BA - 29/03/2020. NT01. [S.l.]: [s.n.], 2020. Disponível em: <<http://www.transporteterrestre.eng.ufba.br/wp-content/uploads/2020/04/Nota-Técnica-01-Grupo-GeoCombate-COVID19-BA.pdf>>. Acesso em: 26 abr. 2020.

PEREIRA, V.H.C.; DINIZ, M.T.M.; ROCHA, G.C.; OLIVEIRA JÚNIOR, M.A.C. **Identificação das Rotas Iniciais de Importação e Disseminação da COVID-19 no Brasil**. Geosaberes, 2 jul. 2020. v. 11, p. 423. Acesso em: 11 fev. 2021.

PERNAMBUCO. **Decreto nº 48.809, de 14 de março de 2020**. Governo do Estado de Pernambuco, 2020. Disponível em: <<https://www.pecontracoronavirus.pe.gov.br/wp-content/uploads/2020/04/de488092020.pdf>>. Acesso em: 26 ago. 2020.

PIRES, D.; FRANCISCO, E.R.; GRANEMANN, E.; RIBEIRO, J.; PROCÓPIO, P.; ALMEIDA, R. **Monitoramento colaborativo COVID-19**. 2020. Disponível em: <<https://hubsetecnologia.maps.arcgis.com/apps/opstdashboard/index.html#/37b0654e558240198ffaf9074dc448ba>>. Acesso em: 27 jul. 2020.

POLETTI, G.M.F.; PASTORE Y PIONTTI, A.; ROSSI, L.; BIOGLIO, L.; CHAO, D.L.; LONGINI, I.M.; HALLORAN, M.E.; COLIZZA, V.; VESPIGNANI, A. **Assessing the impact of travel restrictions on international spread of the 2014 west African Ebola epidemic**. Eurosurveillance, 2014. v. 19, n. 42, p. 1–6. Acesso em: 11 fev. 2021.

RAMOS JR, A.N.; BARREIRA FILHO, E.B.; OLIVEIRA NETO, F. M.; SANTOS, J.O. **Propensão à epidemia grave de COVID-19 da população residente em bairros do Município de Fortaleza**. 2020. Disponível em: <https://www.academia.edu/43339342/Relatório_Técnico_Propensão_à_epidemia_grave_de_COVID_19_da_população_residente_em_bairros_do_Município_de_Fortaleza?email_work_card=view-paper>. Acesso em: 21 nov. 2020.

REX, F.E.; BORGES, C.A.S.; KÄFER, P.S. **Spatial analysis of the COVID-19 distribution pattern in São Paulo State, Brazil**. Ciência & Saúde Coletiva, set. 2020. v. 25, n. 9, p. 3377–3384. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1413-81232020000903377&tlng=en>. Acesso em: 08 jan. 2021.

ROBINSON, A.H.; MORRISON, J.L.; MUEHRCKE, P.C.; KIMERLING, A.J.; GUPTILL, S.C. **Elements of Cartography**. 6th ed ed. New York: [s.n.], 1995. Acesso em: 29 jul. 2020.

ROLLSTON, R.; GALEA, S. **COVID-19 and the Social Determinants of Health**. American Journal of Health Promotion, 19 jul. 2020. v. 34, n. 6, p. 687–689. Disponível em: <<http://journals.sagepub.com/doi/10.1177/0890117120930536b>>. Acesso em: 11 fev. 2021.

RVACHEV, L.A.; LONGINI, I.M. **A mathematical model for the global spread of influenza**. Mathematical Biosciences, 1985. v. 75, n. 1, p. 3–22.

SCHWARTZ, G.A.D. **Direito à saúde: abordagem sistêmica, risco e democracia**. Revista de Direito Sanitário, 1 mar. 2001. v. 2, n. 1, p. 27. Disponível em: <<http://www.revistas.usp.br/rdisan/article/view/13085>>. Acesso em: 29 jul. 2020.

SES/ES. **Painel ES COVID-19**. Secretaria de Saúde do Estado do Espírito Santo, 2020. Disponível em: <<https://experience.arcgis.com/experience/ca28c1669d1e42d4a7e709b9201dc55b/>>. Acesso em: 29 jul. 2020.

SES/RJ. **Painel Covid Rio de Janeiro**. Secretaria de Saúde do Estado do Rio de Janeiro, 2020. Disponível em: <<http://painel.saude.rj.gov.br/monitoramento/covid19.html>>. Acesso em: 29 jul. 2020.

SES/RS. **Painel Coronavírus RS**. Secretaria de Saúde do Rio Grande do Sul, 2020. Disponível em: <<https://ti.saude.rs.gov.br/covid19/>>. Acesso em: 29 jul. 2020.

SILVA, C.F.A.; MEIRA, L.H.; DE OLIVEIRA, L.K.; DOS SANTOS, P.R.G.; DE OLIVEIRA, I.K. **Analysis of spatial correlation between public transportation system users and covid-19 cases: A case study in Recife (PE) | Análise da correlação espacial entre os usuários de sistemas de transporte público e os casos de covid-19**. Revista Brasileira de Gestao e Desenvolvimento Regional, 2020. v. 16, n. 4, p. 346–359. Disponível em: <<https://www.scopus.com/inward/record.url?eid=2-s2.0-85100206381&partnerID=40&md5=2509e150399582f0a58036234dcdee9d>>. Acesso em: 11 fev. 2021.

Tabula. Disponível em: <<https://tabula.technology/>>. Acesso em: 02 jan. 2021.

TIRACHINI, A.; CATS, O. **The Journal of Public Transportation is published by the Center for Urban Transportation Research at the University of South Florida Journal of Public Transportation**. scholarcommons. Journal of Public Transportation, 2020. v. 22, n. 1, p. 1–21. Acesso em: 07 out. 2021.

UEFS. **Portal GEOCOVID-19 Brasil**. 2020. Disponível em: <<http://portalcovid19.uefs.br/>>. Acesso em: 24 jul. 2020.

UNICAMP. **Casos positivos Covid-19 - Hospitais da Unicamp**. 2020. Disponível em: <<https://unicamp-arcgis.maps.arcgis.com/apps/opsdashboard/index.html#/3f735ecea81b419196870772a74da4a6/?utm=apoioacrise-coronavirus>>. Acesso em: 29 jul. 2020.

WANG, F. **Why public health needs GIS: a methodological overview**. Annals of

GIS, 2020. v. 26, n. 1, p. 1–12. Disponível em:
<<https://doi.org/10.1080/19475683.2019.1702099>>. Acesso em: 29 jul. 2020.

WAINER, H.; FRANCOLINI, C.M. **An Empirical Inquiry concerning Human Understanding of Two-Variable Color Maps**, 1980. *The American Statistician*, 34(2), 81–93. doi:10.1080/00031305.1980.10483006. Acesso em: 28 out. 2020.

WU, J.T.; LEUNG, K.; LEUNG, G.M. **Nowcasting and forecasting the potential domestic and international spread of the 2019-nCoV outbreak originating in Wuhan, China: a modelling study**. *The Lancet*, 2020. v. 395, n. 10225, p. 689–697. Disponível em: <[http://dx.doi.org/10.1016/S0140-6736\(20\)30260-9](http://dx.doi.org/10.1016/S0140-6736(20)30260-9)>. Acesso em: 29 jul. 2020.

YANG, Z.; YUAN, Z.; JIA, Z. **Estimating the Number of People Infected with COVID-19 in Wuhan Based on Migration Data**. *Jornal da Universidade de Ciência e Tecnologia Eletrônica da China*, 2020, 49 (3): 330-338.doi: 10.12178 / 1001-0548.2020030. Acesso em 17 dez. 2020.

ZAKERI, R.; BENDAYAN, R.; ASHWORTH, M.; BEAN, D. M.; DODHIA, H.; DURBABA, S.; O'GALLAGHER, K.; PALMER, C.; CURCIN, V.; AITKEN, E.; BERNAL, W.; BARKER, R.D.; NORTON, S.; GULLIFORD, M.; TEO, J.T.H.; GALLOWAY, J.; DOBSON, R.J.B.; SHAH, A.M. **A case-control and cohort study to determine the relationship between ethnic background and severe COVID-19**. *EClinicalMedicine*, nov. 2020. v. 28, p. 100574. Disponível em:
<<https://linkinghub.elsevier.com/retrieve/pii/S2589537020303187>>. Acesso em: 28 out. 2020

ZHANG, J.; FENG, B.; WU, Y.; XU, P.; KE, R.; DONG, N. **The effect of human mobility and control measures on traffic safety during COVID-19 pandemic**. *PLoS ONE*, 2021. v. 16, n. 3 March 2021, p. 493–497. Acesso em: 29 jul. 2020.

ZHOU, C.; SU, F.; PEI, T.; ZHANG, A.; DU, Y.; LUO, B.; CAO, Z.; WANG, J.; YUAN, W.; ZHU, Y.; SONG, C.; CHEN, J.; XU, J.; LI, F.; MA, T.; JIANG, L.; YAN, F.; YI, J.; HU, Y.; LIAO, Y.; XIAO, H. **COVID-19: Challenges to GIS with Big Data**. *Geography and Sustainability*, 2020. v. 1, n. 1, p. 77–87. Acesso em: 29 jul. 2020.

APÊNDICE A – CÓDIGO PYTHON DA METODOLOGIA

```

import os
import pandas as pd
import numpy as np
import geopandas as gpd
import pysal
import descartes
from shapely.geometry import Point, MultiPoint, Polygon, mapping
import matplotlib.pyplot as plt
import six
import matplotlib as mpl
import matplotlib.colors as mcolors
import folium
from folium.plugins import MarkerCluster
import pickle
from openpyxl import Workbook
from openpyxl import load_workbook
%matplotlib inline

# Leitura dos arquivos de entrada
# Zonas de tráfego (espacial)
fp = "dados/zonas-transp.shp"
zt = gpd.read_file(fp)
# Bairros (espacial)
fp2 = "dados/bairros.shp"
nb = gpd.read_file(fp2)
# UDH (espacial)
fp3 = "dados/RM_Recife_UDH.shp"
udh = gpd.read_file(fp3)
# Fluxos entre as zonas de tráfego (tabelar)
fOD = pd.read_excel("dados/zonas-trafego-trabalho-transp-pub.xlsx", decimal = ",")
fOD['ORIG'] = fOD['ORIG'].astype(str)
fOD['DEST'] = fOD['DEST'].astype(str)

```

```

# Casos de COVID-19 por bairro e SE (tabelar)
casos = pd.read_excel('dados/casos-SE.xlsx')
# Dados de população - Censo 2010 e PCR (tabelar)
pop_rec = pd.read_excel("dados/pop_recife.xlsx", decimal = ",")
# Indicadores IPEA (tabelar)
ivs_rmr = pd.read_excel('dados/ivs_rmr.xlsx', decimal = ",")
ivs_rmr['UDH_ATLAS'] = ivs_rmr['UDH_ATLAS'].astype(str)
udh = pd.merge(udh,
ivs_rmr[['UDH_ATLAS','idhm','ivs','ivs_infraestrutura_urbana','ivs_capital_humano',
        'ivs_renda_e_trabalho','t_sem_agua_esgoto','t_densidadem2']],
on='UDH_ATLAS', how='outer')

#Computando os parâmetros
# área dos bairros
SB = list(nb.area)
# área das zonas de tráfego
SZ = list(zt.area)
# Determinação das interseções entre bairros e zonas de tráfego
l = np.zeros((len(zt),len(nb)))
for i in np.arange(len(zt)):
    for j in np.arange(len(nb)):
        l[i,j] = zt.loc[i,'geometry'].intersection(nb.loc[j,'geometry']).area

# Indexação dos padrões de viagem por zona de tráfego
#ft_OD = np.zeros((len(zt),len(zt)))
#for i in np.arange(len(zt)):
#    for j in np.arange(len(zt)):
#        try:
#            ft_OD[i,j] = float(fOD[(fOD['ORIG'] == zt.loc[i,'ZONA']) & (fOD['DEST'] ==
zt.loc[j,'ZONA'])].VIAG)
#        except:
#            ft_OD[i,j] = 0
#pickle.dump(ft_OD, open('ft_OD', 'wb'))
# Fluxos

```

```

ft = pickle.load(open('ft_OD','rb'))
# Determinando a prevalência do COVID-19 nas zonas de tráfego
pop_rec = pd.read_excel("dados/pop_recife.xlsx", decimal = ",")
nb['pop'] = 0
for index, row in pop_rec.iterrows():
    try:
        nb.loc[nb['EBAIRRNOME']==row['Bairro'],'pop'] = row['Pop_Total']
    except:
        "{} not in neighborhood list".format(row['Bairro'])
nb['c'] = 0
for index, row in casos.iterrows():
    try:
        nb.loc[nb['EBAIRRNOME']==row['Bairro'],'c'] = row['S1']
    except:
        "{} not in neighborhood list".format(row['Bairro'])
for i in np.arange(len(nb)):
    if nb.loc[i,'pop'] > 0:
        nb.loc[i,'prev'] = nb.loc[i,'c']/nb.loc[i,'pop']
    else:
        nb.loc[i,'prev'] = 0

#Cálculo da Suscetibilidade dos Bairros em decorrência da mobilidade
# Determinação do Potencial de Espalhamento
P = [None] * len(zt)
for i in np.arange(len(zt)):
    P[i] = sum([x * y / SZ[i] for x, y in zip(nb['prev'],l[i,])])
zt['P'] = P
# Determinação do Potencial de Absorção
A = [None] * len(zt)
for j in np.arange(len(zt)):
    A[j] = sum([x * y for x, y in zip(ft[:,j],P)]) + sum([x * y for x, y in zip(ft[j,:],P)])
zt['A'] = A
# Determinação do Perigo Potencial dos bairros
PP = [None] * len(nb)

```

```

for b in np.arange(len(nb)):
    PP[b] = sum([x * y / SB[b] for x, y in zip(A, I[:, b])])
PP = (PP - min(PP)) / (max(PP) - min(PP))
nb['PP'] = PP
# Densidade demográfica
nb['dd'] = 0
for index, row in pop_rec.iterrows():
    nb.loc[nb['EBAIRRNOME'] == row['Bairro'], 'dd'] = row['Dens_Dmgf']
# Percentual de envelhecimento
nb['id'] = 0
for index, row in idosos.iterrows():
    nb.loc[nb['EBAIRRNOME'] == row['Bairro'], 'id'] = row['Pop>60%']
# Determinando a interseção entre as zonas de tráfego e bairros
I_ub = np.zeros((len(udh), len(nb)))
for i in np.arange(len(udh)):
    for j in np.arange(len(nb)):
        I_ub[i, j] = udh.loc[i, 'geometry'].intersection(nb.loc[j, 'geometry']).area
# Indicadores por bairro
idhm_b = [None] * len(nb)
ivs_b = [None] * len(nb)
ivs_iu_b = [None] * len(nb)
ivs_ch_b = [None] * len(nb)
ivs_rt_b = [None] * len(nb)
sae_b = [None] * len(nb)
pm2_b = [None] * len(nb)
for i in np.arange(len(nb)):
    area = I_ub[I_ub[:, i] > 0, i]
    if len(area) == 1:
        idhm_b[i] = udh.loc[np.squeeze(np.argwhere(I_ub[:, i] > 0)), 'idhm']
        ivs_b[i] = udh.loc[np.squeeze(np.argwhere(I_ub[:, i] > 0)), 'ivs']
        ivs_iu_b[i] =
udh.loc[np.squeeze(np.argwhere(I_ub[:, i] > 0)), 'ivs_infraestrutura_urbana']
        ivs_ch_b[i] =
udh.loc[np.squeeze(np.argwhere(I_ub[:, i] > 0)), 'ivs_capital_humano']

```

```

    ivs_rt_b[i] =
udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'ivs_renda_e_trabalho']
    sae_b[i] = udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 't_sem_agua_esgoto']
    pm2_b[i] = udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 't_densidadem2']
else:
    idhm = udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'idhm'].values
    ivs = udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'ivs'].values
    ivs_iu =
udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'ivs_infraestrutura_urbana'].values
    ivs_ch =
udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'ivs_capital_humano'].values
    ivs_rt =
udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 'ivs_renda_e_trabalho'].values
    sae =
udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 't_sem_agua_esgoto'].values
    pm2 = udh.loc[np.squeeze(np.argwhere(l_ub[:,i]>0)), 't_densidadem2']
    idhm_b[i] = sum([x * y for x, y in zip(list(idhm), list(area))]) / sum(list(area))
    ivs_b[i] = sum([x * y for x, y in zip(list(ivs), list(area))]) / sum(list(area))
    ivs_iu_b[i] = sum([x * y for x, y in zip(list(ivs_iu), list(area))]) / sum(list(area))
    ivs_ch_b[i] = sum([x * y for x, y in zip(list(ivs_ch), list(area))]) / sum(list(area))
    ivs_rt_b[i] = sum([x * y for x, y in zip(list(ivs_rt), list(area))]) / sum(list(area))
    sae_b[i] = sum([x * y for x, y in zip(list(sae), list(area))]) / sum(list(area))
    pm2_b[i] = sum([x * y for x, y in zip(list(pm2), list(area))]) / sum(list(area))
nb['idhm'] = idhm_b
nb['ivs'] = ivs_b
nb['ivs_iu'] = ivs_iu_b
nb['ivs_ch'] = ivs_ch_b
nb['ivs_rt'] = ivs_rt_b
nb['sae'] = sae_b
nb['pm2'] = pm2_b
# Normalização dos Indicadores Socioeconômicos
nb['dd'] = (nb['dd'] - min(nb['dd'])) / ((max(nb['dd']) - min(nb['dd'])))
nb['id'] = (nb['id'] - min(nb['id'])) / ((max(nb['id']) - min(nb['id'])))
nb['inv_idhm'] = 1 - nb['idhm']

```

```

nb['idhm'] = (nb['idhm']-min(nb['idhm']))/((max(nb['idhm'])-min(nb['idhm'])))
nb['inv_idhm'] = (nb['inv_idhm']-min(nb['inv_idhm']))/((max(nb['inv_idhm'])-
min(nb['inv_idhm'])))
nb['ivs'] = (nb['ivs']-min(nb['ivs']))/((max(nb['ivs'])-min(nb['ivs'])))
nb['ivs_iu'] = (nb['ivs_iu']-min(nb['ivs_iu']))/((max(nb['ivs_iu'])-min(nb['ivs_iu'])))
nb['ivs_ch'] = (nb['ivs_ch']-min(nb['ivs_ch']))/((max(nb['ivs_ch'])-min(nb['ivs_ch'])))
nb['ivs_rt'] = (nb['ivs_rt']-min(nb['ivs_rt']))/((max(nb['ivs_rt'])-min(nb['ivs_rt'])))
nb['sae'] = (nb['sae']-min(nb['sae']))/((max(nb['sae'])-min(nb['sae'])))
nb['pm2'] = (nb['pm2']-min(nb['pm2']))/((max(nb['pm2'])-min(nb['pm2'])))

```

#Determinação dos Indicadores de Risco

```

R_dd = nb['PP']*nb['dd']
R_idosos = nb['PP']*nb['id']
R_idhm = nb['PP']*nb['inv_idhm']
R_ivs = nb['PP']*nb['ivs']
R_ivs_iu = nb['PP']*nb['ivs_iu']
R_ivs_ch = nb['PP']*nb['ivs_ch']
R_ivs_rt = nb['PP']*nb['ivs_rt']
R_sae = nb['PP']*nb['sae']
R_pm2 = nb['PP']*nb['pm2']
nb['R_dd'] = R_dd; nb['R_idosos'] = R_idosos; nb['R_ivs'] = R_ivs; nb['R_idhm'] =
R_idhm
nb['R_ivs_iu'] = R_ivs_iu; nb['R_ivs_ch'] = R_ivs_ch; nb['R_ivs_rt'] = R_ivs_rt;
nb['R_sae'] = R_sae; nb['R_pm2'] = R_pm2;

```

#Salvando os arquivos

Potencial de Espalhamento e Absorção das Zonas de Tráfego

```
zt.to_file('abs_zonas_S1.shp')
```

Perigo Potencial e Riscos por bairro

```
nb.to_file('covid_bairros_S1.shp')
```

Rankings e Histograma

```
b = list(nb.loc[nb['PP'].sort_values(ascending=False)[:10].index,'EBAIRRNome'])
```

```
valores_PP = list(nb.loc[nb['PP'].sort_values(ascending=False)[:10].index,'PP'])
```



```

pop_rec['Bairro_ord'] = pd.Categorical(pop_rec['Bairro'],categories=list(b),
ordered=True)
ordinal = lambda n: "%d%s" % (n,"tsnrhtdd"[(n/10%10!=1)*(n%10<4)*n%10::4])
index = [ordinal(i) for i in range(1,11)]
b1 = pd.DataFrame(list(zip(b, pop_rec.sort_values('Bairro_ord')[:10].Pop_Total,
valores_PP)), columns = ['Bairro','População','Perigo Potencial'], index = index)
b1.to_excel (r'Ranking_S1.xlsx', header = True, sheet_name = 'PP')
nb.PP.plot(kind='hist')
plt.savefig('histograma_PP_S1.png', format='png')
b = list(nb.loc[nb['R_ivs'].sort_values(ascending=False)[:10].index,'EBAIRRNOME'])
valores_IVS = list(nb.loc[nb['R_ivs'].sort_values(ascending=False)[:10].index,'R_ivs'])
pop_rec['Bairro_ord'] = pd.Categorical(pop_rec['Bairro'],categories=list(b),
ordered=True)
ordinal = lambda n: "%d%s" % (n,"tsnrhtdd"[(n/10%10!=1)*(n%10<4)*n%10::4])
index = [ordinal(i) for i in range(1,11)]
b2 = pd.DataFrame(list(zip(b, pop_rec.sort_values('Bairro_ord')[:10].Pop_Total,
valores_IVS)), columns = ['Bairro','População'], index = index)
arquivo_excel = load_workbook('Ranking_S1.xlsx')
planilha2 = arquivo_excel.create_sheet("IVS")
arquivo_excel.save('Ranking_S1.xlsx')
pd.read_excel('Ranking_S1.xlsx')
with pd.ExcelWriter('Ranking_S1.xlsx') as writer:
    b1.to_excel(writer, sheet_name='PP')
    b2.to_excel(writer, sheet_name='IVS')
nb.R_ivs.plot(kind='hist')
plt.savefig('histograma_IVS_S1.png', format='png')

```

APÊNDICE B – DADOS DAS DISTRIBUIÇÕES

Bairro	Índices				
	PP_b	Idosos	R_{vId}	IVS	R_{vIVS}
Recife	0,435	0,236	0,103	0,512	0,223
Santo Antônio	0,189	1,000	0,189	0,252	0,048
São Jose	0,105	0,458	0,048	0,619	0,065
Ilha Joana Bezerra	0,190	0,311	0,059	0,818	0,156
Cabanga	0,062	0,833	0,052	0,580	0,036
Coelhos	0,284	0,393	0,112	0,708	0,201
Ilha Do Leite	0,996	0,712	0,709	0,231	0,230
Boa Vista	0,522	0,918	0,479	0,224	0,117
Paissandu	1,000	0,805	0,805	0,233	0,233
Santo Amaro	0,239	0,611	0,146	0,523	0,125
Soledade	0,520	0,914	0,475	0,217	0,113
Espinheiro	0,471	0,933	0,439	0,109	0,051
Aflitos	0,301	0,853	0,257	0,000	0,000
Derby	0,816	0,963	0,786	0,187	0,152
Jaqueira	0,491	0,979	0,480	0,268	0,131
Graças	0,651	0,866	0,563	0,003	0,002
Encruzilhada	0,198	0,847	0,168	0,308	0,061
Rosarinho	0,362	0,619	0,224	0,371	0,134
Tamarineira	0,366	0,801	0,293	0,139	0,051
Boa Viagem	0,622	0,783	0,487	0,164	0,102
Ipsep	0,324	0,859	0,278	0,491	0,159
Jordao	0,165	0,468	0,077	0,755	0,124
Ibura	0,189	0,413	0,078	0,809	0,153
Pina	0,831	0,572	0,475	0,535	0,445
Brasília Teimosa	0,307	0,783	0,241	0,464	0,143
Imbiribeira	0,256	0,501	0,128	0,581	0,148
Torreão	0,170	0,916	0,155	0,335	0,057
Campo Grande	0,150	0,600	0,090	0,628	0,094
Peixinhos	0,298	0,318	0,095	0,922	0,275
Hipódromo	0,160	0,925	0,148	0,331	0,053
Campina Do Barreto	0,295	0,484	0,143	0,806	0,238
Arruda	0,257	0,573	0,148	0,457	0,118
Água Fria	0,334	0,525	0,175	0,685	0,229
Fundão	0,230	0,538	0,124	0,558	0,128
Cajueiro	0,203	0,736	0,149	0,411	0,083
Porto Da Madeira	0,186	0,549	0,102	0,460	0,085
Beberibe	0,267	0,481	0,129	0,800	0,214
Linha Do Tiro	0,156	0,407	0,064	0,800	0,125
Dois Unidos	0,295	0,404	0,119	0,993	0,293
Passarinho	0,367	0,305	0,112	1,000	0,367
Guabiraba	0,123	0,350	0,043	0,876	0,108
Bomba Do Hemetério	0,374	0,579	0,216	0,727	0,272
Casa Amarela	0,496	0,760	0,376	0,278	0,138
Casa Forte	0,405	0,878	0,355	0,326	0,132

Santana	0,558	0,816	0,455	0,328	0,183
Parnamirim	0,511	0,775	0,396	0,332	0,170
Poco	0,263	0,740	0,195	0,331	0,087
Monteiro	0,239	0,565	0,135	0,399	0,096
Alto Do Mandu	0,206	0,732	0,151	0,482	0,099
Apipucos	0,202	0,527	0,106	0,418	0,084
Mangabeira	0,271	0,557	0,151	0,636	0,172
Alto Jose Do Pinho	0,270	0,520	0,141	0,735	0,199
Morro Da Conceição	0,406	0,532	0,216	0,760	0,308
Alto Jose Bonifácio	0,187	0,453	0,085	0,765	0,143
Vasco Da Gama	0,238	0,509	0,121	0,838	0,199
Nova Descoberta	0,191	0,430	0,082	0,887	0,169
Brejo De Beberibe	0,293	0,344	0,101	0,996	0,292
Macaxeira	0,219	0,372	0,081	0,657	0,143
Dois Irmãos	0,167	0,367	0,061	0,402	0,067
Sítio Dos Pintos	0,136	0,385	0,052	0,530	0,072
Brejo Da Guabiraba	0,244	0,372	0,091	0,999	0,244
Córrego Do Jenipapo	0,153	0,467	0,071	0,885	0,136
Pau Ferro	0,123	0,594	0,073	0,487	0,060
Madalena	0,242	0,657	0,159	0,175	0,042
Torre	0,358	0,592	0,212	0,223	0,080
Prado	0,185	0,571	0,106	0,434	0,080
Zumbi	0,237	0,633	0,150	0,381	0,090
Cordeiro	0,306	0,621	0,190	0,377	0,115
Ipatinga	0,355	0,467	0,166	0,561	0,199
Torrões	0,222	0,397	0,088	0,597	0,132
Engenho Do Meio	0,079	0,765	0,061	0,487	0,039
Cidade Universitária	0,023	0,389	0,009	0,473	0,011
Várzea	0,105	0,461	0,048	0,546	0,057
Caxangá	0,079	0,360	0,028	0,467	0,037
Curado	0,048	0,384	0,018	0,812	0,039
Ilha Do Retiro	0,271	0,486	0,132	0,257	0,070
Afogados	0,258	0,589	0,152	0,631	0,163
Mustardinha	0,351	0,552	0,193	0,588	0,206
Mangueira	0,370	0,534	0,198	0,822	0,304
Bongi	0,211	0,546	0,115	0,616	0,130
San Martin	0,211	0,593	0,125	0,595	0,125
Jiquiá	0,113	0,476	0,054	0,696	0,079
Estancia	0,104	0,550	0,057	0,640	0,066
Caçote	0,232	0,384	0,089	0,697	0,161
Areias	0,197	0,641	0,126	0,517	0,102
Jardim São Paulo	0,107	0,602	0,064	0,550	0,059
Barro	0,257	0,445	0,114	0,826	0,212
Cohab	0,170	0,474	0,081	0,716	0,122
Tejipió	0,205	0,669	0,137	0,495	0,101
Sancho	0,144	0,395	0,057	0,624	0,090
Totó	0,126	0,553	0,069	0,777	0,098
Coqueiral	0,110	0,521	0,057	0,777	0,085

Ponto De Parada	0,238	0,685	0,163	0,378	0,090
Alto Sta. Terezinha	0,196	0,000	0,000	0,798	0,156