UNIVERSIDADE FEDERAL DA PARAÍBA
CENTRO DE CIÊNCIAS EXATAS E DA NATUREZA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELOS DE DECISÃO E SAÚDE

UM SISTEMA DE SUPORTE À DECISÃO ESPACIAL PARA DETERMINAR O NÍVEL DE PRIORIDADE MUNICIPAL PARA O COMBATE À COVID-19 NO ESTADO DA PARAÍBA

Catarina Ferreira Pontes

João Pessoa/PB
2022

CATARINA FERREIRA PONTES

UM SISTEMA DE SUPORTE À DECISÃO ESPACIAL PARA DETERMINAR O NÍVEL DE PRIORIDADE MUNICIPAL PARA O COMBATE À COVID-19 NO ESTADO DA PARAÍBA

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Modelos de Decisão e Saúde do Centro de Ciências Exatas e da Natureza da Universidade Federal da Paraíba, como requisito à obtenção do título de mestre.

Linha de Pesquisa: Modelos de Decisão.

Orientadores:
Prof. Dr. Ronei Marcos de Moraes
Prof. Dr. Rodrigo Pinheiro de Toledo Vianna

João Pessoa/PB
2022

Catalogação na publicação
Seção de Catalogação e Classificação

P814s Pontes, Catarina Ferreira.
Um sistema de suporte à decisão espacial para determinar o nível de prioridade municipal para o combate à Covid-19 no estado da Paraíba / Catarina Ferreira Pontes. - João Pessoa, 2022.
84 f. : il.

Orientação: Ronei Marcos de Moraes, Rodrigo Pinheiro de Toledo Vianna.
Dissertação (Mestrado) - UFPB/CCEN.

1. Saúde - modelos de decisão. 2. Infecções por coronavírus. 3. Análise espacial. 4. Análise espaço-temporal. 5. Decisão multicritério. I. Moraes, Ronei Marcos de. II. Vianna, Rodrigo Pinheiro de Toledo. III. Título.

UFPB/BC CDU 614:578.834(043)

Elaborado por Gracilene Barbosa Figueiredo - CRB-15/794

CATARINA FERREIRA PONTES

UM SISTEMA DE SUPORTE À DECISÃO ESPACIAL PARA DETERMINAR O NÍVEL DE PRIORIDADE MUNICIPAL PARA O COMBATE À COVID-19 NO ESTADO DA PARAÍBA

Aprovada em: 21 de fevereiro de 2022.

BANCA EXAMINADORA

Prof. Dr. Ronei Marcos de Moraes
Orientador (UFPB)

Prof. Dr. Rodrigo Pinheiro de Toledo Vianna
Orientador (UFPB)

Profa. Dra. Liliane dos Santos Machado
Membro interno (UFPB)

Profa. Dra. Caliandra Maria Bezerra Luna Lira
Membro interno (UFPB)

Profa. Dra. Luciana Moura Mendes de Lima
Membro externo (ESP)

Profa. Dra. Rafaella Queiroga Souto
Membro externo (UFPB)

Prof. Dr. Regivan Hugo Nunes Santiago
Membro externo (UFRN)

AGRADECIMENTOS

À Deus, por sempre me fortalecer nos piores momentos, por me guiar e iluminar meus passos e por me proporcionar coragem para nunca desistir dos meus sonhos e objetivos.

À minha família, que esteve a meu lado, me incentivando e me tranquilizando, durante esse processo, principalmente à minha mãe Andréa, que a todo o momento acreditou na minha capacidade e ao meu pai Gildemar que foi minha maior inspiração. Às minhas irmãs Bárbara e Lays por tornarem os dias mais leves. Aos meus tios Socorro e Ribamar por todo o amor e motivação. Aos meus avós Joana e Antônio pelo carinho e preocupação.

Aos meus orientadores Ronei e Rodrigo por toda a atenção, paciência e dedicação, por sempre acreditarem no meu potencial e por todo apoio nos momentos mais difíceis.

Aos meus amigos Matheus, Rômulo, Gabriel, Louise, Lainy, Isa Bruna, Luiz Henrique, Gerlane, Weriklys, Karlenne, Flávia, Jodavid e Josemary por toda ajuda, seja direta ou indireta, que foram fundamentais.

Aos colegas do Laboratório de Estatística Aplicada ao Processamento de Imagens e Geoprocessamento (LEAPIG), que sempre forneceram suporte durante a trajetória pelo programa, em especial a Claryce.

Aos professores do programa, por todo profissionalismo e conhecimento compartilhado.

E à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), pelo apoio financeiro essencial para o andamento da pesquisa.

RESUMO

A pandemia da COVID-19 foi considerada uma das mais graves crises de saúde pública da história recente, interferindo na homeostasia das organizações de saúde do mundo e provocando um colapso econômico e social. Desse modo, este trabalho, objetivou caracterizar a conexão entre os aspectos geográficos e o acometimento por COVID-19 no estado da Paraíba, bem como construir um sistema de suporte à decisão espacial para determinar os níveis de prioridade municipais para combate à COVID-19 municipal, assim descritos: "não prioritário", "tendência a não prioritário", "tendência a prioritário" e "prioritário". Trata-se, pois de um estudo do tipo quantitativo, exploratório e ecológico, a partir de dados secundários dos casos de COVID-19 do estado da Paraíba por município, disponibilizados pelo Sistema de Notificações de Síndrome Gripal do Ministério da Saúde. A população do estudo foi composta por todos os casos confirmados para COVID-19 da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021. As análises dos dados seguiram as etapas presentes na arquitetura do *Multiple Criteria Decision Making*: Análise Estatística, Teste de Normalidade, Razão de Incidências Espacial, Análise Espacial, Análise Espaço-temporal, Tempo do Aglomerado Espaço-Temporal, Persistência do Aglomerado Espaço-Temporal, Coeficiente de Correlação de Spearman e Sistema Baseado em Regras *Fuzzy*. Ao longo da pesquisa, foram registrados 373.789 casos de COVID-19, desses, foram mais acometidos: indivíduos de 20 a 60 anos (75,23%), sexo biológico feminino (55,99%) e, comorbidades do tipo doença cardíaca (4,46%). Logo, com a aplicação do *Spatial Decision Support System* baseado em *Weighted Linear Combination*, obteve-se como produto um mapa de decisão final que permitiu a detecção e visualização espacial de municípios segundo o nível de prioridade. Foi evidenciado que 153 municípios foram classificados como "não prioritário", 51 como "tendência a não prioritário" e 19 como "tendência a prioritário". A partir desse resultado, os gestores podem intervir de maneira mais assertiva, direcionando a tomada de decisão de acordo com múltiplos fatores de risco para COVID-19 no estado da Paraíba.

Palavras-chave: Infecções por coronavírus; Análise espacial; Análise espaço-temporal; Sistemas de Apoio à Decisão Espacial Multicritério.

ABSTRACT

The COVID-19 pandemic has been considered one of the most serious public health crises in recent history, interfering with the homeostasis of the world's health organizations and causing economic and social collapse. Thus, this work aimed to characterize the connection between geographic aspects and the involvement by COVID-19 in the state of Paraíba, as well as to build a spatial decision support system to determine the level of priority by county to combat COVID-19, described as follows: “non-priority”, “trend to non-priority”, “trend to priority” and “priority”. It is, therefore, a quantitative, exploratory and ecological study, based on secondary data of COVID-19 cases in the state of Paraíba by county, made available by the Influenza Syndrome Notification System of the Ministry of Health. The study population consisted of all confirmed COVID-19 cases from the 12th epidemiological week of 2020 to the 32nd epidemiological week of 2021. Data analysis followed the steps present in the Multiple Criteria Decision Making architecture: Statistical Analysis, Normality Test, Spatial Incidence Ratio, Spatial Analysis, Spatio-Temporal Analysis, Time of the Spatio-Temporal Cluster, Persistence of the Spatio-Temporal Cluster, Spearman Correlation Coefficient and Fuzzy Rule-Based System. During the research, 373,789 cases of COVID-19 were collected, of which the most affected were: individuals aged 20 to 60 years (75.23%), female biological sex (55.99%) and comorbidities such as heart disease (4.46%). Therefore, with the application of the Spatial Decision Support System based on Weighted Linear Combination, a final decision map was obtained as a product that allowed the detection and spatial visualization by counties according to priority level. It was evidenced that 153 counties were classified as “non-priority”, 51 as “non-priority trend” and 19 as “priority trend”. Based on this result, managers can provide assertive interventions, making decision based on multiple risk factors for COVID-19 in the state of Paraíba.

Keywords: Coronavirus infections, Spatial analysis, Spatio-temporal analysis, Multicriteria Spatial Decision Support Systems.

LISTA DE FIGURAS

Figura 1 - Arquitetura adaptada do SDSS de Moraes, Nogueira e Sousa (2014)..... 22
Figura 2 - Sistema de Apoio à Decisão Espacial baseado em WLC 35
Figura 3 - Mapa político-administrativo do estado da Paraíba 36
Figura 4 - Número de registro de casos novos (a) e casos acumulados (b) de COVID-19 da 12ª semana epidemiológica 2020 (15/03/2020 a 21/03/2020) a 32ª semana epidemiológica de 2021 (25/07/2021 a 01/08/2021) no estado da Paraíba 40
Figura 5 - Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 12ª semana epidemiológica de 2020, no estado da Paraíba 42
Figura 6 - Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 28ª semana epidemiológica de 2020, no estado da Paraíba 42
Figura 7 - Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 35ª semana epidemiológica de 2020, no estado da Paraíba 43
Figura 8 - Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 22ª semana epidemiológica de 2021, no estado da Paraíba 44
Figura 9 - Mapa *Scan* espaço-temporal dos casos novos da COVID-19 no estado da Paraíba, da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021 45
Figura 10 – Mapa de decisão provido pelo SDSS para os casos novos de COVID-19 no estado da Paraíba..... 47
Figura 11 – Mapa de decisão provido pelo SDSS para os casos femininos de COVID-19 no estado da Paraíba 49
Figura 12 - Mapa de decisão provido pelo SDSS para os casos masculinos de COVID-19 no estado da Paraíba 49
Figura 13 - Mapa de decisão provido pelo SDSS para os casos menores de 20 anos com COVID-19 no estado da Paraíba 50

Figura 14 - Mapa de decisão provido pelo SDSS para os casos de 20 a 60 anos com COVID-19 no estado da Paraíba 50
Figura 15 - Mapa de decisão provido pelo SDSS para os casos maiores de 60 anos com COVID-19 no estado da Paraíba 51
Figura 16 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com doenças cardíacas no estado da Paraíba 52
Figura 17 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com doenças respiratórias no estado da Paraíba 52
Figura 18 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com diabetes no estado da Paraíba 53
Figura 19 - Sistema de Apoio à Decisão Espacial baseado em WLC 54
Figura 20 - Mapa de decisão final do SDSS baseado em WLC 55

LISTA DE QUADROS

Quadro 1 - Principais t-normas e t-conormas 30

LISTA DE TABELAS

Tabela 1- Valores assumidos pela correlação de Spearman 29
Tabela 2 - Distribuição dos casos de COVID-19 de acordo com a faixa etária, sexo e comorbidades da 12ª semana epidemiológica de 2020(15/03/2020 a 21/03/2020) a 32ª semana epidemiológica de 2021 (25/07/2021 a 01/08/2021) no estado da Paraíba 38
Tabela 3 - Variáveis linguísticas, termos linguísticos e domínio utilizado no SDSS referente ao subcritério casos novos da COVID-19 46

LISTA DE ABREVIATURAS E SIGLAS

CEP	Comitê de Ética em Pesquisa
COVID-19	*Coronavirus Disease 2019*
EUA	Estado Unidos da América
IBGE	Instituto Brasileiro de Geografia e Estatística
OMS	Organização Mundial da Saúde
RIE	Razão de Incidências Espacial
RT-PCR	Transcriptase Reversa seguida pela Reação em Cadeia da Polimerase
SARS-CoV-2	Síndrome Respiratória Aguda pelo coronavírus 2
SRAG	Síndrome Respiratória Aguda Grave
MERS	Síndrome Respiratória do Oriente Médio
SNSG	Sistema de Notificações de Síndrome Gripais
SDSS	*Spatial Decision Support System*
SDSS-MC	*Spatial Decision Support System- Multiple Criteria*
SIG	Sistema de Informação Geográfica
MCDM	*Multiple Criteria Decision Making*
UTI	Unidade de Terapia Intensiva
WLC	*Weighted Linear Combination*
SUS	Sistema Único de Saúde
HAS	Hipertensão Arterial Sistêmica

LISTA DE NOTAÇÕES

C	Total de geo-objetos na região geográfica
Z	Número total de casos
F	Função de distribuição acumulada assumida para os dados
Fx	Função de distribuição acumulada empírica dos dados
G	Região geográfica
gi	Geo-objeto
M	Total de indivíduos na população sob risco
$L1$	Conjunto de todas as zonas circulares
C	Total de geo-objetos
r_s	Coeficiente de correlação de Spearman
N	Número de pares de observações
λ	Razão de verossimilhança
J_i	Número máximo de áreas mais próximas do geo-objeto
p_1	Probabilidade do acontecimento dos casos dentro da zona
m_l	Número de indivíduos sob risco da zona
q_l	Probabilidade de casos fora da zona
z_l	Casos registrados na zona
$E(l_2)$	Número esperado de casos em dentro da zona
z_{l2}	Número total de casos na zona cilíndrica l_2
N_t	Intervalos de pontos discretos no tempo
PT	Período de Tempo
d_i	Diferença de classificação para as duas variáveis.
U	Universo
A	Conjunto

SUMÁRIO

1 INTRODUÇÃO 14
2 OBJETIVOS 17
2.1 OBJETIVO GERAL 17
2.2 OBJETIVOS ESPECÍFICOS 17
3 REFERENCIAL TEÓRICO 18
3.1 ASPECTOS GERAIS DA COVID-19 18
3.2 EPIDEMIOLOGIA ESPACIAL E SISTEMA DE APOIO À DECISÃO ESPACIAL 21
3.2.1 Análise Estatística 24
3.2.2 Teste de Normalidade 24
3.2.3 Razão de Incidências Espacial (RIE) 25
3.2.4 Métodos de Detecção de Aglomerados Espaciais 26
3.2.5 Estatística Scan Espacial 27
3.2.6 Estatística Scan Espaço-Temporal 29
3.2.7 Análise de Correlação 30
3.2.8 Sistema Baseado em Regras Fuzzy 31
3.3 TOMADA DE DECISÃO MULTICRITÉRIO 34
4 METODOLOGIA 38
4.1 CARACTERIZAÇÃO DA ÁREA DO ESTUDO 38
4.2 CARACTERIZAÇÃO DO ESTUDO 38
4.3 ASPECTOS ÉTICOS 40
5 RESULTADOS 40
5.1 ANÁLISE DESCRITIVA DOS CASOS DE COVID-19 NO ESTADO DA PARAÍBA 40
5.2 ANÁLISE ESPACIAL 43
5.3 ANÁLISE ESPAÇO-TEMPORAL 47
5.4 SISTEMA BASEADO EM REGRAS *FUZZY* 48
5.5 SISTEMA DE SUPORTE À DECISÃO ESPACIAL BASEADO EM WLC 57
6. DISCUSSÃO 59
7 CONSIDERAÇÕES FINAIS 64
8 REFERÊNCIAS 67

1 INTRODUÇÃO

A COVID-19 (*Coronavirus Disease 2019*) é uma infecção causada pelo SARS-CoV-2 (Síndrome Respiratória Aguda pelo Coronavírus 2), um vírus pertencente à família dos *Coronaviridae*, de RNA com sentido positivo, que é um potente causador de doenças respiratórias agudas graves. No final de dezembro de 2019, em Wuhan, China, foi identificada pela primeira vez a sua transmissão em humanos. Em março de 2020, a COVID-19 foi rotulada como uma pandemia pela Organização Mundial da Saúde (OMS), devido ao crescimento dos números de casos e a sua velocidade de contaminação no mundo (ZHAO *et al*., 2020; LI *et al*., 2020).

Em 03 de novembro de 2021, foram registrados 247.472.724 casos confirmados de COVID-19 no mundo, sendo 93.867.665 (37,93%) casos nas Américas, 77.527.689 (31,32%) na Europa, 44.030.064 (17,79%) no Sudeste da Ásia, 16.399.307 (6,62%) no Mediterrâneo Oriental, 9.488.950 (3,83%) no Pacífico Ocidental e 6.158.285 (2,48%) na África. Os Estados Unidos e o Brasil contribuíram com 72,04% dos casos registrados nas Américas. Juntos representaram 27,32% dos casos em nível mundial (OMS, 2021).

No Brasil, em 03 de novembro de 2021, foram registrados 21.835.785 casos e 608.235 mortes por COVID-19. Na região Nordeste, foram registrados 4.857.516 casos acumulados e 118.131 óbitos, apresentando uma taxa de incidência de novos casos de 8.511,3 para cada 100 mil habitantes e mortalidade de 207,0 na mesma proporção. Dessa forma, o Nordeste é a segunda região mais acometida por casos e óbitos por coronavírus em todo país. Acompanhar a evolução dessa afecção se torna um desafio para os diversos sistemas de vigilância epidemiológica (BRASIL, 2021).

No estado da Paraíba foram implantadas medidas sanitárias antes mesmo do primeiro caso confirmado em 19 de março de 2020. Contudo, o estado, até o mês de novembro de 2021, já notificou mais de 454.529 casos e cerca de 9.430 óbitos (2,10% de letalidade), sendo a capital João Pessoa, com 108.835 casos (23,94%), município com a maior quantidade de casos. No entanto, existe também a confirmação do vírus em pequenos municípios do estado, representando o processo de interiorização do vírus (PEDROSA; ALBUQUERQUE, 2020).

Diante disso, é importante que se tenha um conhecimento sobre a distribuição geográfica dos casos através dos Sistemas de Informação Geográfica (SIG) que são instrumentos indispensáveis para criar mapas e análises espaciais epidemiológicas. Dessa forma, os gestores podem aperfeiçoar e desenvolver estratégias, por meio de análise da

distribuição espacial de enfermidades e suas ligações com aspectos da população, da mobilidade e do ambiente (SOUZA *et al.*, 2020).

Nessa perspectiva, com o aumento do número de casos de SARS-CoV-2 na Paraíba e compreendendo que a pandemia se comporta de diferentes formas a depender de aspectos territoriais, do perfil demográfico e da economia, deve-se analisar a sua distribuição espacial, espaço-temporal e suas características demográficas (TRAN *et al.*, 2020). Sendo assim, identificar o padrão da distribuição espacial da COVID-19 é importante para que exista um maior controle da doença, reduzindo assim a propagação e, consequentemente, sua morbimortalidade, além de ser um importante instrumento para auxiliar no direcionamento dos recursos voltados para saúde pública (SÁ; NOGUEIRA; MORAES, 2015).

Em razão dos diversos fatores relacionados à ocorrência da COVID-19 possuírem certo nível de incerteza, necessita-se de alternativas para obtenção de um modelo de suporte de decisão que proporcione a classificação das áreas em diferentes graus de prioridade para cada variável e que enseje a implementação do conhecimento da realidade e auxilie aos gestores públicos a tomada de decisão direcionada ao agravo. Desse modo, analisar as características do território, bem como seu perfil histórico, demográfico, epidemiológico, administrativo, político e social e cultural, é indispensável para o monitoramento e resposta de uma tomada de decisão voltada aos reais problemas de saúde pública de uma determinada população. Essa análise possibilita a avaliação e o planejamento de intervenções para as problemáticas, além de proporcionar aos gestores um olhar ampliado para medidas de promoção e de atenção integral à saúde (SANTOS; RIGOTTO, 2010).

Portanto, o presente estudo fundamentou-se no Sistema de Suporte à Decisão Espacial (SDSS – *Spatial Decision Support Systems*), que é organizado considerando aspectos epidemiológicos para tomada de decisão na gestão da saúde pública, sendo possível tratar informações representadas por componentes de área. O resultado final provido deste sistema é um mapa de decisão que mostra subáreas de acordo com os níveis de prioridade (MORAES; NOGUEIRA; SOUSA, 2014). Neste trabalho, é possível detectar e determinar os níveis de prioridade de combate a COVID-19 por município no estado da Paraíba.

Tendo em vista os fatos analisados e apresentados, este estudo visa caracterizar a conexão entre os aspectos geográficos e o acometimento por COVID-19 no estado da

Paraíba, bem como construir um sistema de suporte à decisão espacial para determinar o nível de prioridade municipal para o combate a COVID-19 na Paraíba.

Nesta perspectiva, como contribuições do presente estudo, ressalta-se a inclusão de várias análises simultâneas no sistema de apoio à decisão multicritério para suporte à tomada de decisão segundo os níveis de prioridade. Como vantagem, ela é flexível e pode ser adotada para diferentes agravos, territórios e períodos de tempo. Sua relevância na saúde é o subsídio para os gestores públicos e profissionais de saúde que, através do acesso a esse modelo, podem utilizá-los para intervir em problemas de saúde pública, desenvolver ações de promoção e prevenção em saúde, além de fornecer um suporte para que o processo de tomada de decisão, seja eficiente. Ademais, através desse estudo pode-se conhecer as características epidemiológicas dos casos da COVID-19 no estado da Paraíba.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Elaborar um sistema de suporte à decisão espacial para determinar o nível de prioridade municipal para o combate à COVID-19 no estado da Paraíba.

2.2 OBJETIVOS ESPECÍFICOS

- Identificar os municípios da Paraíba com maior Razão de Incidências Espacial para as variáveis: casos novos, sexo, faixa etária e comorbidades para a COVID-19;
- Descrever a evolução da distribuição espacial dos casos da COVID-19 no estado da Paraíba;
- Analisar a distribuição espacial e espaço-temporal dos casos da COVID-19 no estado da Paraíba, por meio de aglomerados significativos no espaço e no tempo;
- Modelar a tomada de decisão multicritério a partir de um SDSS baseado em *Weighted Linear Combination* (WLC).

3 REFERENCIAL TEÓRICO

3.1 ASPECTOS GERAIS DA COVID-19

A pandemia COVID-19 foi considerada uma das mais graves crises de saúde pública da história recente, atingindo de forma devastadora todos os aspectos da humanidade, interferindo na homeostasia das organizações de saúde do mundo, provocando um colapso econômico e social (VASCONCELOS *et al.,* 2021). No caso da COVID-19 e de outras pandemias consideradas recentes, como a Síndrome Respiratória do Oriente Médio (MERS), gripe aviária (H5N1), gripe suína (H1N1) e SARS, estão relacionadas a um crescimento caótico da área urbana e consequentemente um avanço sobre áreas silvestres, agropecuárias e pecuárias (DOS SANTOS JÚNIOR *et al.,* 2020).

Os coronavírus são vírus envelopados, com RNA de fita simples, esféricos e envoltos por uma camada proteica. São pertencentes à ordem *Nidovirales*, família *Coronoviridae* e subfamília *Orthocoronaviridae* e podem ser classificados nos seguintes gêneros: *Alphacoronavírus* (α-COV), *Betacoronavírus* (β-COV), *Deltacoronavírus* (δ-COV) e *Gammacoronavírus* (γ-COV). O SARS-CoV-2 se diferencia dos outros vírus do trato respiratório por possuir uma sazonalidade bienal característica e causar manifestações respiratórias, intestinais, hepáticas e neuronais, podendo ocasionar complicações irreversíveis no ser humano (ALBUQUERQUE; SILVA; ARAÚJO, 2020; SOUZA *et al.*, 2021).

Em dezembro de 2019, em Wuhan, província de Hubei, China, foi observada pela primeira vez sua transmissão em humanos. Em janeiro de 2020, a OMS rotulou o vírus como emergência de saúde pública internacional, devido ao crescimento dos números de casos e a sua velocidade de contaminação. Em 30 de março de 2020, a OMS declarou estado de pandemia da COVID-19 (SHELEME; BEKELE; AYELA, 2020).

Portanto, com os números alarmantes de mortes e infectados, o epicentro do Coronavírus foi se alterando da China para Europa, na Itália, Espanha e Reino Unido de forma sequencial. Seguindo para os Estados Unidos da América (EUA), onde a quantidade de infectados foi maior do que todos os outros países. No Brasil, em 17 de abril de 2021, foram registrados 13.746.681 casos acumulados e 365.444 mortes, ficando atrás dos EUA e da Índia em relação ao total de casos (OMS, 2021).

Experiências anteriores com epidemias, como a Síndrome Respiratória Aguda Grave (SRAG) em 2003 e a MERS, em 2015, no leste e sudeste da Ásia, possibilitaram que seus governantes implementassem medidas rápidas e eficientes na saúde, para

controlar a contaminação do SARS-CoV-2. Na Coreia do Sul foi programada uma eficaz estratégia de testes em massa na população, para identificar precocemente e isolar os casos confirmados. Já em Cingapura, houve uma rápida contenção através de ações de saúde pública e econômicas voltadas para os grupos sociais mais vulneráveis (ZHANG *et al.*, 2020).

O diagnóstico precoce do COVID-19, desenvolvimento e fornecimento de testes diagnósticos, a detecção precoce de casos sintomáticos e as medidas de isolamento social são considerados prioridades para a prevenção e controle da infecção no mundo. Essa detecção do vírus está relacionada à presença do SARS-CoV-2 de ácido nucléico e de anticorpos de imunoglobulina (IgM e IgG) (YEGOROV *et al.*, 2021).

A sensibilidade do teste mede a capacidade de identificação correta da doença no paciente com o resultado positivo. De acordo com o estudo de Tsang *et al* (2021), utilizar esfregaços nasofaríngeos como referência, esfregaços nasais e da garganta agrupados fornecem uma sensibilidade de 97%, enquanto somente o teste de saliva, oferece sensibilidade de 85%, esfregaços nasais 86% e esfregaços de garganta 68%. Já a especificidade do teste mensura a capacidade de identificar corretamente as pessoas negativas para a COVID-19. No caso de sensibilidade muito baixa, inferior a 68% para esfregaços de garganta sugere que eles podem perder quase um terço (32%) dos casos infectados, dando um resultado falso negativo, interferindo diretamente no diagnóstico.

Na clínica, a Transcrição Reversa de Reação em Cadeia da Polimerase (RT-PCR), realizado por meio do *swab* nasofaríngeo, que amplifica sequências de RNA do vírus, é considerado o teste padrão-ouro para a identificação do coronavírus. Porém, esse método apresenta dificuldades, tais como: ambiente específico, treinamento adequado dos profissionais de saúde, equipamentos de proteção e insumos básicos, além de ser um teste que gera desconforto ao usuário (JAHRSDÖRFER *et al*., 2021; TSANG *et al*., 2021).

No entanto, como a COVID-19 continua a pressionar os sistemas de saúde, principalmente nos países subdesenvolvidos e o alcance da vacinação ainda é muito restrito, além do surgimento de novas variantes mais transmissíveis, há necessidade do reconhecimento da contaminação precocemente. Sendo assim, a realização de testes, em conjunto com o rastreio de contatos sintomáticos e assintomáticos, campanhas de prevenção e ações de educação em saúde, são uma das alternativas mais eficientes para o controle da contaminação (WYLLIE *et al.*, 2021).

A propagação do SARS-CoV-2 acontece através de uma complexa rede de interação humana, onde é afetada por ações de contenção ou liberação. Dessa forma, as

ondas da COVID-19 representam um fenômeno de ascendência expressiva dos números de casos e um declínio no decorrer do tempo, onde o pico da onda pode reduzir consideravelmente ou permanecer constante a depender das intervenções de cada país. Observa-se que o relaxamento das ações sanitárias, nos países que tiveram o achatamento da curva da mortalidade, resultou em uma segunda onda mais impactante e fatal (VASCONCELOS *et al*., 2021a).

É evidente, contudo, que após o início da vacinação a letalidade da COVID-19 reduziu significativamente, impactando positivamente na redução de óbitos. O estudo de Rosenberg (2022) traz que a eficácia contra a hospitalização permaneceu alta, com declínios modestos limitados a pessoas com 65 anos de idade ou mais, esses resultados apoiam a eficácia contínua das vacinas, em conjunto com estratégias de prevenção comportamental, para reduzir a morbimortalidade da COVID-19.

A resposta da pandemia no mundo se comporta de diferentes maneiras a depender das características do território, do perfil demográfico, da cultura, da economia e dos tipos de governos. Na Europa Ocidental observa-se que a população é mais velha do que a das Américas, sofrendo assim alterações consideráveis no comportamento do vírus. Países como a França, Itália, Espanha e Reino Unido registram altos números de casos e mortes, porém rapidamente com a expansão dos sistemas de saúde, ampliação da capacidade hospitalar, em destaque nos leitos de Unidades de Terapia Intensiva (UTI), aumento das testagens para o SARS-CoV-2, intervenções econômicas para fornecer suporte tanto às empresas quanto aos cidadãos desempregados têm ajudado a reduzir as consequências da COVID-19 (TRAN *et al.*,2020).

A conjuntura política no Brasil durante a pandemia do novo coronavírus se encontra fragilizada devido a um cenário de incertezas e agravamento de crises econômica, política, sanitária, sociais e ausência de coordenação geral do governo federal que minimize o risco da COVID-19. Essa instabilidade teve início com as recorrentes alterações de liderança do cargo de ministro da saúde, resultando em consequências imensuráveis nas decisões de saúde. Entretanto, como o sistema de saúde do Brasil segue o princípio da descentralização, os estados e municípios têm autonomia para determinar estratégias de saúde pública e medidas no combate da transmissão do vírus, a exemplo de decretos que permitem implantar medidas que reforçam o isolamento social (BARBERIA *et al*., 2021).

De acordo com Rocha *et al*., (2021), no Brasil as desigualdades socioeconômicas tiveram maior impacto no curso da pandemia do que fatores como idade e condições de

saúde, alterando a gravidade de forma desproporcional nos estados e municípios com maior vulnerabilidade social e de recursos. Dessa maneira, é importante ressaltar que a região Nordeste juntamente com a região Norte são as duas regiões mais pobres do Brasil, considerando o enfoque econômico e de desigualdade social. Apesar da COVID-19 ter tido seu primeiro surgimento em São Paulo e Rio de Janeiro, na região Sudeste, os índices de mortalidade se elevaram rapidamente nas regiões Norte e Nordeste, que possuem maior vulnerabilidade. Devido a isto, políticas públicas e ações estratégicas focadas no problema, são fundamentais para proteger os locais com maior fragilidade socioeconômica.

No estado da Paraíba o primeiro registro de caso da COVID-19 foi no dia 19 de março de 2020 através de um viajante vindo da Europa, que desembarcou no aeroporto de João Pessoa. Após trinta dias do seu primeiro registro, a Paraíba já contabilizou 245 casos e até o dia 06 de novembro de 2021, registrou 455.577 casos acumulados com o quantitativo de 9.443 óbitos e taxa de letalidade de 2,1% (PARAÍBA, 2021). Segundo o estudo de Rocha *et al.* (2021), a maior ocorrência de óbitos no estado da Paraíba foi registrada em hospitais públicos vinculados ao Sistema Único de Saúde – SUS, o que demonstra que esses hospitais e o SUS foram os pilares na assistência dos casos de COVID-19 no estado.

Dentre os municípios do estado, o mais atingido pela pandemia até o dia 06 de novembro de 2021 foi a capital João Pessoa, com 109.065 casos, seguido por Campina Grande com 47.183 casos e Patos com 14.217 casos. De acordo com Silva (2021), a faixa etária mais acometida pela COVID-19 é entre 30 a 49 anos, contudo, a letalidade da doença é mais evidente na população idosa. Ressalta-se ainda que o estado alcançou o índice de isolamento social que foi preconizado apenas no início da pandemia, com 58,5% na semana epidemiológica 13, período de 22 a 28 de março de 2020.

3.2 EPIDEMIOLOGIA ESPACIAL E SISTEMA DE APOIO À DECISÃO ESPACIAL

É possível definir a epidemiologia espacial como o estudo da distribuição geográfica e espacial do acontecimento de uma doença em seu território, que é capaz de relacionar condições de risco ambientais, demográficos, comportamentais, sociais e econômicos, além de poder solucionar problemas em que o espaço geográfico participa da análise (CARVALHO; SOUZA, 2005). O trabalho precursor de John Snow,

envolvendo a epidemia de cólera que ocorreu em Londres em 1854, originou mapas que retrataram a existência da relação entre mortes por cólera e o suprimento público de água (SNOW, 2008).

No cenário da epidemiologia espacial, é válido ressaltar a análise espacial, a qual tem a função de reconhecer variáveis explicativas e entender os fenômenos associados à dinâmica da distribuição espacial das doenças e formas de prevenção e monitoramento das enfermidades (MAGALHÃES, 2012). Para entender o perfil epidemiológico de agravos que refletem riscos à saúde pública, é primordial utilizar a análise espacial. Esta tem sido aplicada na área da saúde em doenças como: tuberculose (SÁ, 2015), dengue (MELO; MORAES, 2018), hanseníase (FREITAS; DUARTE; GARCIA, 2017), anomalias congênitas do sistema nervoso (LIMA *et al*., 2019; LIMA, VIANNA, MORAES, 2019) e na condição crônica em crianças e adolescentes (PINTO; SILVA; MORAES, 2018).

A análise espacial na saúde se aplica a uma linha da vigilância da saúde que depende da forma de reconhecimento do território conforme as relações entre circunstâncias de vida e saúde, se destacando por ser uma área de investigação inter e transdisciplinar de grande importância para o reconhecimento de problemas. Os acontecimentos associados à saúde, como o nascimento, enfermidades e óbitos podem ser distribuídos geograficamente. Essa distribuição geográfica e a relação espacial desses acontecimentos em saúde são foco da epidemiologia espacial, que no ramo da saúde, contribui para ampliar a percepção e entendimento dos processos saúde/doença, visualizando a ocorrência dos casos, bem como o risco potencial das áreas (CARVALHO; SOUZA-SANTOS, 2005).

Dessa forma, a respeito da necessidade de obter medidas de controle de agravos e de auxílio à tomada de decisão em saúde, e suporte na caracterização geográfica e epidemiológica, utiliza-se o SDSS, que possibilita utilizar distintos componentes de forma integrada ou isolada, que são capazes de tratar a informação, bem como modelar e gerenciar dados espaciais e não-espaciais, possibilitando aos gestores de saúde apoio na solução de problemas espaciais, viabilizando a elaboração e análise de perspectivas alternativas (MORAES; MELO, 2018).

É fundamental o emprego de técnicas que realce os processos ambientais e sociais que interferem no perfil de transmissão de doenças, para que estratégias eficientes de prevenção e controle sejam adotadas. Portanto, a segmentação do espaço, de acordo com indicadores sociais e ambientais, somado aos conhecimentos relacionados ao grau de

endemicidade da área, estabelece uma ferramenta de suporte ao planejamento das medidas de controle (RESENDES, 2010).

O SDSS agrupa características espaciais e não espaciais que apoiam o método de tomada de decisão. As informações espaciais podem ser correspondidas por coordenadas geográficas de uma localização e suas interações espaciais, sendo fundamentais no processo final de decisão (KEENAN; JANKOWSKI, 2019). O sistema pode ser adaptado para problemas espaciais semiestruturados ou não estruturados, de maneira participativa e reiterada, com a aplicabilidade para tratar com bancos de dados (espaciais e não espaciais), competência de modelagem analítica, de apoio à decisão e da exibição da informação (SUGUMARAN; DEGROOTE, 2011).

A arquitetura SDSS desenvolvida por Moraes, Nogueira e Sousa (2014) é constituída por etapas que envolvem análise estatística, análise espacial e análise espaço-temporal e um sistema fundamentado em regras difusas. O produto dessa arquitetura (Figura 1) é um mapa de decisão que pode ser utilizado como um instrumento para auxiliar o gestor na tomada de decisão em saúde.

Nas etapas de análise estatística, existe a possibilidade de fazer análises descritivas, tabelas e gráficos para compreender a distribuição e aspectos estatísticos da afecção em estudo. Adiante, os dados espaciais são analisados de acordo com a Razão de Incidências Espacial (RIE), estatística *Scan* espacial, *Scan* espaço-temporal, Correlação de Spearman, método de classificação, servindo de entrada para um sistema baseado em regras *Fuzzy*. Vale salientar que essa arquitetura é composta por módulos, assim, suas etapas podem ser utilizadas de acordo com o foco da pesquisa. Os resultados obtidos por essa arquitetura SDSS são mapas de decisão em que são visualizadas subáreas prioritárias, para o combate de doenças, conforme distintos níveis de prioridade, sendo uma ferramenta importante para fornecer apoio ao gestor na tomada de decisão (MORAES; NOGUEIRA; SOUSA, 2014).

Figura 1 - Arquitetura adaptada do SDSS de Moraes, Nogueira e Sousa (2014).

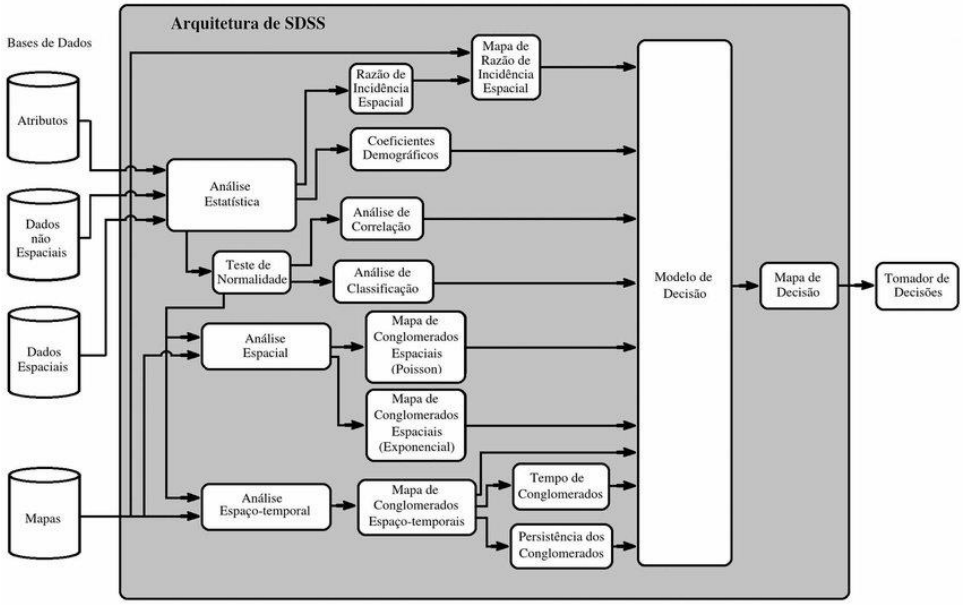

Fonte: Adaptado Moraes, Nogueira e Sousa (2014).

3.2.1 Análise Estatística

Nesta etapa, as análises descritivas, tabelas e gráficos podem ser elaboradas de forma a conhecer a distribuição e aspectos estatísticos da doença em estudo.

3.2.2 Teste de Normalidade

Esse teste de hipóteses tem a finalidade de averiguar se a distribuição das variáveis pode ser aproximada pela distribuição Normal (SIEGEL, 2006). O teste considera o nível de concertação entre a distribuição de uma coleção de valores amostrais e a estatística de teste apoiado no grau de significância estabelecido. Pode-se aplicar o teste de *Lilliefors*, uma derivação do teste de Kolmogorov-Smirnov, que mede a diferença absoluta entre a atribuição da distribuição acumulada reconhecida para os dados e a atribuição de distribuição acumulada empírica, segundo a equação (1).

$$B = max \vee F - F_x \vee \qquad (1)$$

onde: F é uma função de distribuição acumulada conhecida e suposta para os dados e F_x confere a função de distribuição acumulada empírica dos dados. No caso do *p-valor* ser

maior que 0,05, conhecido como nível de significância, os dados dispõem de uma distribuição Normal (SIEGEL, 2006).

3.2.3 Razão de Incidências Espacial (RIE)

É uma medida espacial que tem a finalidade de conhecer a relação de duas incidências no acontecimento de um fenômeno, isto é, mostra a incidência de casos de uma determinada área em relação à população sob risco desse local (LIMA *et al*., 2019a). Para compreender a RIE, é indispensável definir dois conceitos importantes na análise espacial: a região geográfica e o geo-objeto.

A região geográfica é uma área geográfica demarcada do estudo onde os fenômenos epidemiológicos vão ocorrer e sobre a qual os eventos de interesse ocorrem. Pode ser demonstrada por um conjunto de objetos distintos e localizáveis geograficamente dentro dela; estes, por sua vez, podem ser chamados geo-objetos (GOODCHILD, 1992). Por exemplo, para um estudo epidemiológico focado nas condições crônicas entre crianças e adolescentes no território paraibano, a Paraíba é a região geográfica. Este estudo pode ser desenvolvido a partir das totalizações das notificações de casos de doenças crônicas em cada município paraibano. Assim, a Paraíba é a região geográfica, e cada município é um geo-objeto.

Nesta perspectiva, é importante compreender o conceito de região geográfica, que é uma área geográfica onde os fenômenos epidemiológicos ocorrem. Portanto, os geo-objetos são decorrentes desses eventos localizados na região geográfica. Desse modo, a RIE apresenta as duas incidências na ocorrência de um fenômeno, ou seja, a incidência em um geo-objeto g_i com relação à incidência de todos da região *G*. A primeira apresenta a razão entre o número de casos avaliados em uma subárea em relação à população em risco na mesma sub-área. O segundo apresenta a razão entre o número total de casos computados em toda região geográfica, com relação à população total em risco.

Seja uma região geográfica *G* formada por um conjunto de *C* geo-objetos, isto é $g_i \in G$, i=1, ... , *C*. Seja *Z*, uma variável aleatória que equivale ao número total de casos registrados de um dado período de tempo dentro de cada geo-objeto em g_i na região geográfica *G* e *M*, denominado como a população sob risco na região geográfica *G*. Desse modo, a RIE para cada geo-objeto g_i é dada pela seguinte equação (LIMA *et al.*, 2019).

$$RIE(g_i) = \frac{\frac{Z_{g_i}}{M_{g_i}}}{\frac{\sum_{j=1}^{C} Z_{g_j}}{\sum_{j=1}^{C} M_{g_j}}} = \frac{\frac{Z_{g_i}}{M_{g_i}}}{\frac{Z}{M}} \quad (2)$$

ou seja, a RIE é fornecida pela incidência de um evento epidemiológico no geo-objeto g_i dividido pela incidência em toda a região geográfica.

Para análise da RIE(g_i) foram aplicadas as seguintes categorias: RIE nula, quando não existe incidência do evento epidemiológico no geo-objeto g_i; maior que 0 e menor que 0,5 indica que a RIE é inferior à metade da incidência global na região geográfica no geo-objeto g_i; maior ou igual a 0,5 e menor do que 1,0, a RIE naquela subárea é maior ou igual à metade e inferior à incidência em toda a região geográfica; maior ou igual a 1,0 e menor do que 1,5, a RIE naquela sub-área é maior ou igual à incidência em toda a região geográfica, mas não a excede em mais do que 50%; maior ou igual a 1,5 e menor do que 2,0, a RIE naquela sub-área é maior ou igual à 1,5 vezes a incidência em toda a região geográfica, mas não a excede em mais do que 2 vezes; e quando maior ou igual a 2,0 a RIE naquela sub-área é maior ou igual à 2,0 vezes a incidência em toda a região geográfica (LIMA *et al.*, 2019b).

Os mapas da RIE são utilizados como modelo para análise dos mapas da estatística Scan espacial e espaço-temporal. A RIE propicia a padronização das informações consoante a população sob risco dos geo-objetos, associando a incidência de cada geo-objeto à incidência da região geográfica em um dado período de tempo (LIMA et al., 2019a). Destarte, ela oportuniza a comparação direta entre os geo-objetos de um mesmo mapa.

3.2.4 Métodos de Detecção de Aglomerados Espaciais

Foram utilizados métodos de aglomerados espaciais, conceituados pela literatura como um conjunto de regiões que representam risco considerável de ocorrer determinado evento. Sua finalidade é identificar áreas significativas e não significativas de um evento em estudo, a partir de uma região geográfica, através de informações geo-referenciadas (HOLMES; MORAES; VIANNA, 2015). O foco está em visualizar se o evento possui uma distribuição espacial aleatória ou se apresenta aglomerados espaciais.

Na literatura nacional e internacional são fornecidas opções de métodos considerando a natureza dos dados utilizados, possíveis indicações e limitações, como

possibilidade de uso, foram pré-selecionadas: a estatística *Scan* espacial (KULLDORFF; NAGARWALLA, 1995), *Besag* e *Newell* (BESAG; NEWELL, 1991) e *Getis-Ord* (GETIS; ORD, 1992). O método selecionado para a análise espacial dos dados da pesquisa adequou à estatística *Scan* espacial. A preferência desse método foi devido a sua possibilidade de apresentar melhores resultados no que corresponde a identificação de aglomerados espaciais quando aplicado a regiões com baixa população, tal como em situações em que o interesse do estudo se baseia em analisar áreas de incidência elevada, todavia com limitado conhecimento anterior da área (THOMAS; CARLIN, 2003).

3.2.5 Estatística Scan Espacial

O método de varredura *Scan* foi aplicado com a finalidade de identificar áreas com conglomerados, em que seu acontecimento implica diretamente em uma maior chance de ocorrência dentro do próprio conglomerado do que fora, ou seja, um conglomerado pode ser um município ou um grupo de municípios dos quais o risco de ocorrência de casos de COVID-19 é mais elevado do que fora dele. Ressalta-se que a definição de risco utilizado no *Scan* não equivale ao risco definido na epidemiologia. Esse método faz uma relação da informação da área com um círculo único dentro do geo-objeto, podendo atribuir variadas formas geométricas, como uma elipse (NEIL; MOORE; SABHNANI, 2005), um retângulo (DUCZMAL; ASSUNÇÃO, 2004) e um círculo (KULLDORFF *et al.*, 2006).

A forma geométrica circular favorece a observação da aplicabilidade do método, contudo, conforme Kulldorff *et al*. (2006) determinar a forma geométrica apropriada não é de importância fundamental, pois seja qual for a opção, exerce o objetivo básico de identificar aglomerado geográfico. Porém, garante que determinadas formas podem apresentar uma execução melhor que outras. Diante disso, para que a inferência estatística seja fundamentada, é essencial que inicialmente a seleção seja apoiada no real formato do aglomerado, antes da análise dos dados, com o propósito de evitar tendências na pré-seleção.

A varredura *Scan* atribui uma janela circular para cada centroide, onde o círculo é disposto em um dos geo-objetos do estudo e seu raio é incrementado até o tamanho máximo determinado (MELO; MELO; MORAES, 2016). Para cada centroide, o raio possibilita que varie do zero ao máximo valor recomendado, que é 50% da população em

risco. O mapa da RIE pode ser usado como referência para se determinar o melhor mapa resultante do *Scan*.

Seja M o total de indivíduos na população sob risco em determinada região geográfica G e seja Z o número total de casos registrados em G. Para cada centroide, círculos posicionados tiveram o raio aumentado envolvendo centroides vizinhos até um percentual da população pré-determinado, paralelamente para cada área contida pelo raio do círculo se realiza um teste de significância com o objetivo de saber se a sub-área (geo-objeto) é um candidato a aglomerados. Considerando, dessa forma, L_1 um conjunto de todas as zonas circulares, sabendo que $L_1 \subseteq G$, e onde C é o número total de geo-objetos em G e J_i é o número máximo de áreas mais próximas do geo-objeto g_i (SÁ, *et al.*, 2020).

$$L_1 = \{l_{ij} \in G \vee 1 \leq i \leq C, 1 \leq j \leq J_i\} \tag{3}$$

A razão de verossimilhança pode ser definida como a razão de verossimilhança das informações sob uma hipótese alternativa seguido pela verossimilhança de uma hipótese nula (NEIL; MOORE; SABHNANI, 2005; KULLDORFF; NAGARWALLA, 2006).

Assim, seja $p_l = z_l/m_l$ a probabilidade do acontecimento dos casos dentro da zona l, que possui z_l casos registrados e m_l indivíduos sob risco e $q_l = (Z - z_l)/(M - m_l)$ a probabilidade de casos fora da zona. Se a zona l for candidata a um aglomerado, tem-se a seguinte razão de verossimilhança (SÁ *et al*., 2020):

$$\lambda = \begin{cases} sup_1 \in L_1 \left(\frac{z_l}{E_{(l)}}\right)^{z_l} \left(\frac{Z - z_l}{Z - E_{(l)}}\right)^{Z - z_l}, se \\ \frac{z_l}{E_{(l)}} > \frac{Z - z_l}{Z - E_{(l)}} \\ 1, casocontrário \end{cases} \tag{4}$$

onde: $E(l) = \frac{z_l}{M}$ é o valor esperado de casos dentro da zona l.

Desse modo a significância estatística do conglomerado mais plausível dos casos considerados é obtida mediante as simulações de Monte Carlo com α = 0,05 (LUCENA; MORAES, 2009; MOURA, 2006). Nesse método *Scan* a delimitação é obtida em relação ao percentual da população perante o risco. Desta forma, o raio de busca é estabelecido aumentando até que abranja no máximo β% da população, não havendo uma

normatização sobre este percentual da população, buscando o percentual que se adeque em cada cenário analisado (MELO; MELO; MORAES, 2016).

3.2.6 Estatística Scan Espaço-Temporal

Tem o objetivo de visualizar aglomerados que sucedem no espaço e no tempo simultaneamente. Esse método é similar ao espacial, porém distingue-se por considerar o tempo. Desse modo, utiliza a forma geométrica do cilindro, cuja base compreende o espaço geográfico e a altura do cilindro, o tempo, possibilitando que a base e altura modifiquem constantemente conforme a varredura. É recomendado que a medida da base geográfica e o período de tempo sejam restritos à metade da quantidade de casos estabelecidos e a metade do período total. Logo, a janela do cilindro desloca-se no espaço e no tempo de forma que, a determinada área geográfica, também encontre cada período de tempo provável, transpondo em cilindros justapostos de variados tamanhos, onde são experimentados quanto à probabilidade de fazer parte de um aglomerado espaço-temporal. A significância desses aglomerados é obtida usando a simulação de Monte Carlo, da qual a hipótese nula confirma que não existe aglomerados espaço-temporal na área geográfica e a hipótese alternativa que há pelo ao menos um aglomerado (KULLDORFF *et al.*, 1998).

Partindo dessa definição, é possível realizar a análise espaço-temporal de duas maneiras: a análise retrospectiva, utilizada pela análise de dados coletados em um período de tempo definido, e a análise prospectiva, que é utilizada em dados que são mantidos em contínua atualização. Então, pode-se afirmar que a análise do tipo retrospectiva destaca o padrão de acontecimentos, ao passo que a análise do tipo prospectiva tem a finalidade de examinar a atividade do fenômeno, sobretudo sobre as novas informações obtidas. Da mesma maneira que a estatística *Scan*, na estatística *Scan* espaço-temporal dois modelos frequentemente são utilizados, o Poisson e Bernoulli. Como na área da epidemiologia trabalha-se, usualmente, com dados de contagem, o Modelo de Poisson é mais utilizado (YAMADA; ROGERSON; LEE, 2009; LUCENA; MORAES, 2012).

No *Scan* espacial são observadas zonas circulares em L_1 e o período de tempo é observado como N_t intervalos de pontos discretos no tempo, do tempo inicial t_1 até o tempo final t_{Nt} (TANGO, 2010), ou seja:

$$PT = \{t_1, \dots, t_{Nt}\}$$

(5)

Na análise espaço-temporal pode-se obter duas informações adicionais que são o tempo dos aglomerados, ou seja, o momento em que determinado período de tempo do aglomerado é detectado e a persistência dos aglomerados, o que consiste em quanto tempo cada aglomerado detectado existe (MORAES; NOGUEIRA; SOUSA, 2014).

Então, atendendo um período de tempo em L_1 em um estudo do tipo retrospectivo, como é o caso da presente pesquisa, a base do cilindro reflete o espaço (L_1) e sua altura reflete o período de tempo (PT), definindo assim um domínio cilíndrico dado por $L_2 = L_1 \; X \; PT$. Se a zona cilíndrica l_2 for uma candidata a um aglomerado, a seguinte razão de verossimilhança é fornecida (LIMA, 2019):

$$\lambda = \begin{cases} sup_{l2} \in L_2 \left(\frac{z_{l_2}}{E(l_2)}\right)^{Z_{l_2}} \left(\frac{Z - z_{l_2}}{Z - E(l_2)}\right)^{z_{l_2}}, se \\ \frac{z_{l_2}}{E(l_2)} > \frac{Z - z_{l_2}}{Z - E(l_2)} \\ 1, casocontrário \end{cases}$$

(6)

onde: $\mathcal{Z}$ é o número total de casos registrados em G X PT, Z_{l_2} significa o número total de casos na zona cilíndrica l_2 e $E(l_2)$ retrata o número esperado de casos esperados na mesma zona cilíndrica, que são dados por:

$$z_{l_2} = \sum (i,t) \in l_2 z_{it} e E(l_2) = \sum (i,t) \in l_2 e_{it}$$

(7)

onde: z_{it} e e_{it} são o valor total de casos e o valor esperado de casos, na devida ordem, e ambos definidos para o geo-objeto i em um tempo específico t. Sendo assim, o número esperado de casos e_{it} é apresentado por:

$$e_{it} = \frac{\sum_{i=1}^{c} z_{it} \sum_{t=1}^{N_t} z_{it}}{M}$$

(8)

3.2.7 Análise de Correlação

É uma medida que tem a finalidade de investigar e avaliar o grau de correlação entre as variáveis. Essa análise é realizada pela estatística intitulada coeficiente de

correlação, sendo capaz de assumir valores no intervalo de -1 correlação perfeita negativa a +1 correlação perfeita positiva, podendo ser atribuído o valor zero, que aponta ausência se correlação (SIEGEL, 1956).

Os dados da pesquisa podem apresentar dois tipos de testes estatísticos, os testes paramétricos ou não-paramétricos. No tipo de análise de correlação paramétrica dispomos do método de Pearson e para correlação não paramétrica utilizamos um método similar, a correlação de Spearman (r_s), que mede o grau de associação entre duas variáveis e requer que ambas sejam medidas pelo menos em uma escala ordinal. (SIEGEL, 1956). Pode ser calculada pela equação:

$$r_s = 1 - \frac{6 \sum_{i=1}^{N} d_i^2}{N^3 - N} \tag{9}$$

onde d_i^2 é a diferença de classificação para as duas observações e N o número de pares de observações.

Os valores considerados pela correlação de Spearman estão demonstrados na Tabela 1.

Tabela 1- Valores assumidos pela correlação de Spearman.

ρ_s	**Interpretação**
0,9 a 1 (-0,9 a -1)	Correlação muito alta positiva (negativa)
0,7 a 0,9 (-0,7 a -0,9)	Correlação alta positiva (negativa)
0,5 a 0,7 (-0,5 a -0,7)	Correlação moderada positiva (negativa)
0,3 a 0,5 (-0,3 a -0,5)	Correlação baixa positiva (negativa)
0 a 0,3 (0 a -0,3)	Correlação sem significância

Fonte: Mukaka (2012).

Assim, a correlação de Spearman foi utilizada com a finalidade de mapear as tendências dos resultados, de acordo com as variáveis em cada município do estado da Paraíba.

3.2.8 Sistema Baseado em Regras Fuzzy

Os achados oriundos dos módulos anteriores auxiliam uma entrada para um sistema baseado em regras *fuzzy*, e a saída é um mapa que recomenda as regiões de acordo

com os variados níveis de prioridades. Diante disso, é importante compreender alguns conceitos relacionados à lógica *fuzzy*.

A lógica *fuzzy* tem sido empregada com frequência em distintos problemas devido a possibilidade de compreender determinados fenômenos que não podem ser explicados pela lógica clássica (SOARES *et al.*, 2018). É um método que possibilita lidar com dados imprecisos e incertos e tem como base a teoria dos conjuntos *fuzzy* (ZADEH, 1965).

Então, conceitua-se um conjunto *fuzzy* como uma categoria de objetos com regulares graus de agregação. Esse conjunto é definido por funções de pertinência, concedidas a todo objeto do conjunto, que variam entre zero e um. Por conseguinte, sendo A um conjunto no universo U e x um elemento pertencente a U, a função de pertinência de um conjunto *fuzzy*, relaciona a cada ponto em U, um número real presente no intervalo de 0 a 1, ou seja, $A{:}U \rightarrow [0,1]$ (ZADEH, 1965). Nesses conjuntos, podem-se obter operações de intersecção e união, utilizando respectivamente os operadores t-norma e t-conorma (MORAES; BANON; SANDRI, 2002). Podem ser visualizadas no Quadro 1 as principais t-normas e t-conormas.

Quadro 1 – Principais t-normas e t-conormas

T-norma	**T-conorma**
min (*a*,*b*)	max (*a*,*b*)
$a \; x \; b$	$a + b - ab$
max (a+b-1)	min (a + b, 1)
$\begin{cases} a \; se \; b = 1 \\ b \; se \; a = 1 \\ 0 \; se \; não \end{cases}$	$\begin{cases} a \; se \; b = 0 \\ b \; se \; a = 0 \\ 1 \; se \; não \end{cases}$

Fonte: Moraes (1998).

Geralmente o modo de expressar o fundamento dessa lógica é através de regras do tipo condição-ação. Logo, a regra *fuzzy* é um elemento que pode capturar um conhecimento específico, onde as circunstâncias são dadas por um conjunto de termos linguísticos, que estão relacionados às variáveis de entrada e saída (PASSINO, 1998; MASSAD *et al*., 2004).

Esse sistema possui duas partes, a parte antecedente (SE), formada pelas variáveis de entrada que representam uma condição, e a parte consequente (ENTÃO), formada pelas variáveis de saída, apontando uma conclusão. Ortega (2001) ressalta que no

antecedente é permitido o uso de mais de um conectivo, como o “E” e “OU” e que no consequente há a possibilidade de mais de uma conclusão. Assim sendo, uma regra *fuzzy* possui o seguinte aspecto:

$$SE\ (x\ \text{é}\ a_i)\ E\ (y\ \text{é}\ b_i)\ ENTÃO\ (w\ \text{é}\ c_i)$$

onde x e y representam as variáveis linguísticas de entrada, w a de saída, e a_i, b_i e c_i são realizações dessas variáveis, medidas com a interação do usuário com o sistema (GOMIDE; GUDWIN, 1994). Ressalta-se que a variável linguística demonstra um valor qualitativo apresentado por um termo linguístico que pode ser palavras ou frases e quantitativamente por sua função de pertinência (MASSAD *et al.*, 2004).

No presente estudo, foi utilizado o sistema baseado em regras *fuzzy* fundamentado por Mamdani e Assilian (1975). De acordo com a proposta por Mandami em 1974, para construção de um sistema *fuzzy*, é necessário seguir quatro passos:

- Fuzzificação: Nesta etapa mensura-se o grau de pertinência da entrada pertencente a cada conjunto *fuzzy*, por meio de uma ligação entre os componentes de entrada e a base de conhecimento. Esses componentes passam por um processo denominado de fuzzificação, que traduz os valores das informações em variáveis linguísticas, de acordo com a aplicação de regras de formação (PASSINO; YURKOVICH, 1997; SANTOS *et al*., 2011).

- Regras *fuzzy*: As regras são elaboradas com variáveis linguísticas que são determinadas por uma variável cujos valores são palavras ou frases em uma linguagem natural ou artificial. (ZADEH, 1973; KING, MAMDANI, 1977). Essa fase obtém o grau de pertinência com que cada entrada pertence a cada conjunto *fuzzy*.

- Motor de inferência: Esta etapa é definida por processar os dados de entrada com as regras, de maneira a inferir os conjuntos de saída. Além disso, são definidas as t-normas, t-conormas e as regras de inferência (SANTOS *et al.*, 2011).

- Defuzzificação: corresponde a etapa final, na qual os dados *fuzzy* são transformados em valores numéricos precisos, através de métodos para obter a saída do sistema. Como exemplo desse método, se tem como principais o método do centro de área (centroide), método do máximo e o método da média dos máximos (ORTEGA, 2001; MASSAD *et al*., 2004).

3.3 TOMADA DE DECISÃO MULTICRITÉRIO

Com o rápido crescimento e evolução dos processos no mundo, a tomada de decisão se torna um grande desafio, isso pelas várias causas que podem levar a uma decisão final, como o problema e conflitos de interesse, a relevância da decisão, distintos fatores relacionados ao problema, dentre outros. Na condição espacial, o método de tomada de decisão também é complexo e demanda de informações espaciais desenvolvidas com base em muitas fontes e compreendidas por uma diversidade de tomadores de decisão em relação a diversos critérios, metas e ou alternativas. Dessa forma, pode ser utilizado a Tomada de Decisão Multicritério (*Multiple Criteria Decision Making* - MCDM) que determina um agrupamento de procedimentos que fornecem esse suporte e produzem uma ordem de prioridade para a alternativa (LIMA *et al*., 2019).

É possível definir a MCDM como uma pesquisa que utiliza técnicas e procedimentos nos quais podem ser agregados critérios diferentes ao processo de tomada de decisão em consonância com a Sociedade Internacional de MCDM (INTERNATIONAL SOCIETY ON MULTIPLE CRITERIA DECISION MAKING, 2019). Segundo Guarnieri (2015), a MCDM possibilita resolver ou atenuar problemas de decisão que englobam distintas concepções, acontecimentos incertos e objetivos divergentes. Destarte, a sua aplicação viabiliza estruturar o processo decisório em fases bem estabelecidas, colaborando na tomada de decisão.

A MCDM tem sido utilizada em diferentes áreas do conhecimento, tais como: energia, ambiente, materiais, gestão em saúde, nos sistemas de informação geográficas, na segurança e controle de riscos, gestão da informação, dentre outros (SEN; YANG, 1998; YU *et al*., 2018). No âmbito da saúde, a MCDM vem sendo usada para determinar níveis de prioridades para o combate de doenças, auxiliando o gestor nas estratégias de prevenção, diagnóstico e tratamento, análise e avaliação das tecnologias em saúde, dentre outros (ADUNLIN; DIABY; XIAO, 2014).

É possível identificar na literatura, que alguns estudos (MARCZEWSKI; RINNER, 2015; FERRETTI; MONTIBELLER, 2016) abordam o SDSS-MC associado ao SIG, que utiliza dados espaciais e as preferências do tomador de decisão para obter a decisão final. Segundo Malczewski e Rinner (2015), o SDSS-MC pode ser abordado de três maneiras diferentes: MCDM convencional para problemas espaciais, MCDM espacialmente explícito e otimização multiobjetivo espacial.

A abordagem tradicional de MCDM para problemas espaciais é comumente determinada por não atender as propriedades fundamentais das informações espaciais, como a heterogeneidade e dependência espacial (MARCZEWSKI; RINNER, 2015). Dessa forma, concede-se uma homogeneidade espacial à escolha do tomador de decisão e funções de valor. Esse método vem sendo utilizado para lidar com problemas espaciais, através de técnicas como: combinação linear ponderada, métodos de referência, hierarquia analítica e o processo de rede (MALCZEWSKI, 2000; DROBNE; LISEC, 2009).

Os componentes fundamentais para a MCDM são: os critérios nas quais as alternativas são analisadas, as alternativas a serem analisadas, os pesos dos critérios que medem a relevância relativa de cada um, concedidos por especialistas, e pontuações que representam a ordem de preferência das possibilidades (THOKALA; DUENAS, 2012).

O sistema proposto foi validado no estudo de Lima *et al*. (2019) com base nos casos de tuberculose no município de João Pessoa, ano de 2013, e empregou dois critérios e quatro subcritérios, a partir da arquitetura de SDSS de Moraes, Nogueira e Sousa (2014) e a WLC. Cada subcritério é processado e produz como resultado um mapa de decisão georreferenciado. Ou seja, cada geo-objeto da região geográfica relativo a um subcritério específico é verificado, segundo as informações dos SDSS, utilizando: informações espaciais, não espaciais, análise estatística, análise espacial, análise espaço-temporal e análise de correlação, que são unidas por um sistema *fuzzy* fundamentado em regras e que conceberam o mapa. Adiante, esses resultados são avaliados e combinados por um MCDM, resultando em um mapa de decisão final que direciona alternativas em quatro níveis de prioridade: “não prioritário”, “tendência a não prioritário”, “tendência a prioritário” e “prioritário”, empregados ao problema em questão (LIMA, 2019).

Dessa forma, constata-se que arquitetura apresentada no estudo de Lima *et al*. (2019) exibe uma abordagem genérica que pode ser empregada em contextos e situações distintas e proporciona ajustes segundo temática em foco (Figura 2). Além disso, pode ser caracterizada como uma arquitetura que permite como saída um mapa de decisão final, baseado em níveis de prioridade, que proporciona ao gestor público fácil interpretação para uma tomada de decisão mais precisa.

A WLC para tomada de decisão espacial é um método simples, de fácil compreensão e tem sido utilizado de maneira consistente no método MCDM (MALCZEWSKI, 2000). Pode ser conceituado como uma técnica que usa informações espaciais e as preferências do tomador de decisão para conceder o mapa de decisão

(MARCZEWSKI; RINNER, 2015). O WLC considera os seguintes elementos: o peso para cada critério e o valor da função, para gerar o mapa de decisão final (Figura 2). O peso retrata a relevância de cada critério no entendimento do tomador de decisão. A função de valor transforma os diferentes níveis de um critério em uma escala comparável (LEE, 2010; MALCZEWSKI, 2011). Assim, para escolher a alternativa mais adequada para cada geo-objeto, utiliza-se o método WLC expresso a seguir:

$$P^*(g_i) = max_i \left\{ \sum_{j=1}^{K} z_{ij}(g_i) w_j \right\}, \forall i = 1,2,\dots,m;$$
$$j = 1,2,\dots,K \; e \; g_i = 1,2,\dots,n \qquad (10)$$

onde $P^*(g_i)$ é a pontuação mais adequada entre as *m* opções para cada geo-objeto g_i; z_{ij} é a função de valor da i-ésima opção em termos do j-ésimo critério para cada região geográfica e w_j é o peso conferido a cada um dos *K* critérios.

No presente estudo, os pesos da WLC foram calculados através de uma proporção com informações obtidas diretamente dos dados da pesquisa, na qual foram calculadas cada proporção discriminada pelas categorias: casos novos; sexo feminino; sexo masculino; faixa etária menor de 20 anos, de 20 a 60 anos e maior de 60 anos; e as comorbidades, doenças cardíacas, doenças respiratórias e diabetes. Em seguida o valor obtido foi multiplicado e somado pelo valor de saída do SDSS baseado em regras *fuzzy*, onde se obteve um resultado final para cada categoria.

Figura 2 – Sistema de Apoio à Decisão Espacial baseado em WLC.

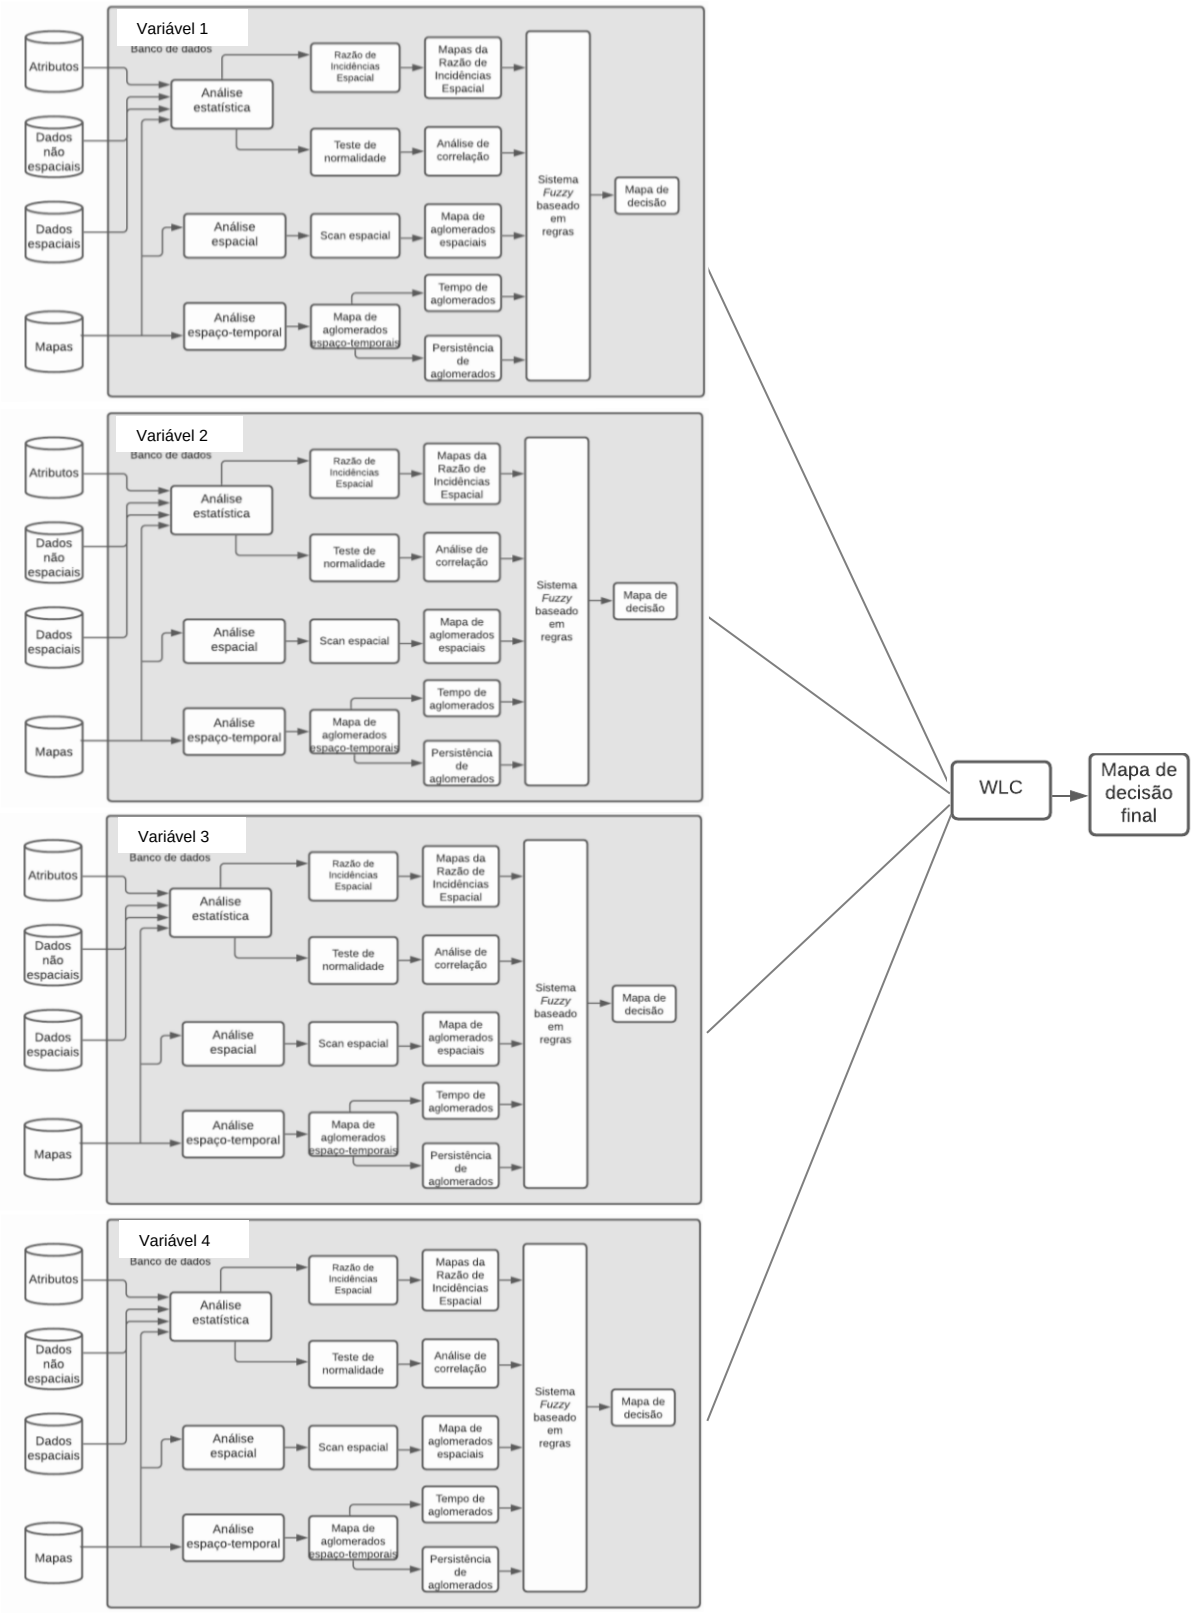

Fonte: Elaboração pela própria autora (2022).

4 METODOLOGIA

4.1 CARACTERIZAÇÃO DA ÁREA DO ESTUDO

O estudo foi desenvolvido no estado da Paraíba, que ocupa uma extensão territorial de 56.469,778 km², com uma população em torno de 4.059.905 habitantes, totalizando uma densidade demográfica de 66,70 habitantes/km² em 2020, constituindo-se por 223 municípios, que são divididos em quatro mesorregiões, sendo a Mata Paraibana, Agreste Paraibano, Borborema e Sertão Paraibano. O estado é localizado na região Nordeste do Brasil e faz limites com os estados do Rio Grande do Norte ao norte, Ceará a oeste, Pernambuco ao sul e o Oceano Atlântico a leste, conforme pode ser observado na Figura 3 (IBGE, 2020).

Figura 3 – Mapa político-administrativo do estado da Paraíba.

Fonte: Paraíba (2020).

4.2 CARACTERIZAÇÃO DO ESTUDO

Estudo do tipo quantitativo, exploratório e ecológico. Utilizou-se dados do tipo secundários dos casos de COVID-19 do estado da Paraíba, disponibilizados pelo Sistema de Notificações de Síndrome Gripais (SNSG) do Ministério da Saúde (MS), no período da 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020) a 32ª semana

epidemiológica de 2021 (25/07/2021 a 01/08/2021). Em relação aos dados da população residente no estado foram obtidos a partir do Instituto Brasileiro de Geografia e Estatística (IBGE).

A população do estudo foi estabelecida por todos os casos novos confirmados de COVID-19 no estado da Paraíba durante o período determinado para o estudo. Os critérios de inclusão estabelecidos foram todos os casos confirmados pelo SNSG que pudessem responder aos objetivos propostos da pesquisa. Os critérios de exclusão foram os casos presentes no SNSG que estavam confirmados para outras Síndromes Gripais.

A *priori,* realizou-se uma seleção das variáveis de interesse (critérios) no banco de dados do SNSG: data de notificação, comorbidades, sexo, município de residência e idade. A coleta de dados foi registrada em uma planilha eletrônica e, em seguida, foram realizadas as análises de acordo com as etapas presentes na arquitetura do MCDM que foi descrita no capítulo 3: análise estatística com o, teste de normalidade e a RIE, análise espacial, análise espaço-temporal com o tempo do aglomerado espaço-temporal e a persistência do aglomerado espaço-temporal, coeficiente de correlação de Spearman e sistema baseado em regras *fuzzy*. Dessarte foram elaboradas tabelas, mapas, gráficos e um mapa de decisão final, fornecendo uma melhor visualização dos resultados.

A RIE foi verificada para cada município do estado da Paraíba entre a 12ª semana epidemiológica de 2020 e a 32ª semana epidemiológica de 2021. Foi escolhido o coeficiente de correlação de Spearman, pois os dados da pesquisa não seguem uma distribuição normal. Assim, a correlação teve o objetivo de analisar o grau de correlação da RIE no período de estudo para cada um dos municípios. Em relação à análise espacial e espaço-temporal, foram utilizados os métodos *Scan* espacial e *Scan* espaço-temporal retrospectivo, respectivamente. Em ambas as análises se avaliou os valores de 0,1% a 20% da população sob risco de acordo com os métodos *Scan* (KULLDORFF, 2015). Vale ressaltar que o risco utilizado pelo método *Scan* não corresponde ao risco definido na Epidemiologia. Os valores citados de 0,1%, 0,3%, 0,4%, 0,6% da população sob risco, foram os que apresentaram os melhores resultados. Os mapas da estatística *Scan* espacial foram analisados para cada semana e do *Scan* espaço-temporal, conforme a semana e a persistência do aglomerado, usando como referência os mapas da RIE. Esses resultados foram reunidos por um sistema baseado em regras *fuzzy*. Todas essas informações foram verificadas para cada critério do problema em questão. Logo após, esses achados foram combinados utilizando o WLC.

Para as análises foram utilizados *software* livres e gratuitos, a análise espacial foi realizada como auxílio do R versão 3.6.3 e a análise espaço-temporal foi obtida através do *SaTScan* versão 9.7.

4.3 ASPECTOS ÉTICOS

O estudo foi realizado por meio de dados secundários de domínio público, respeitando todos os aspectos éticos em pesquisa, seguindo a Resolução 510 de 2016 do Conselho Nacional de Saúde (CNS), logo, não houve a necessidade da submissão e avaliação do Comitê de Ética em Pesquisa (CEP) (CNS, 2016).

5 RESULTADOS

5.1 ANÁLISE DESCRITIVA DOS CASOS DE COVID-19 NO ESTADO DA PARAÍBA

Foram registrados 373.789 casos confirmados para COVID-19 da 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020) a 32ª semana epidemiológica de 2021 (25/07/2021 a 01/08/2021) no estado da Paraíba. Desses, 281.216 (75,23%) casos, média de 3.388, eram de indivíduos na faixa etária entre 20 e 60 anos, 209.286 (55,99%) e média de 2.521 casos eram do sexo biológico feminino e 16.697 (4,46%) em média de 201 casos por semana tinham presença de comorbidades do tipo doença cardíaca, como pode ser visualizado na Tabela 2.

Tabela 2 – Distribuição dos casos confirmados para COVID-19 de acordo com a faixa etária, sexo e comorbidades da 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020) a 32ª semana epidemiológica de 2021 (25/07/2021 a 01/08/2021) no estado da Paraíba

Variáveis	n	%	Média semanal
Faixa etária			
Menor que 20 anos	42.315	11,33	509
20 a 60 anos	281.216	75,23	3.388
Maior que 60 anos	50.202	13,44	604
Sexo			
Feminino	209.286	55,99	2.521
Masculino	164.453	43,99	1.981
Comorbidades			
Doenças Cardíacas	16.697	4,46	201
Diabetes	9.805	2,62	118
Doenças Respiratórias	4.357	1,16	52
Sem Informação	342.930	91,74	4.132

Legenda: n: número de casos

Fonte: Elaboração pela própria autora (2022).

Acerca dos casos novos, foi observado, durante o período de estudo, que houve quatro picos; o primeiro ocorreu na 28ª semana epidemiológica de 2020 (05/07/20 a 11/07/2020), com 7.713 casos; o segundo pico aconteceu na 49ª semana epidemiológica de 2020 (29/11/2020 a 05/12/2020), com 5.115 casos; o terceiro pico decorreu na 11ª semana epidemiológica de 2021 (14/03/2021 a 20/03/2021), com 8.127 casos e o quarto pico ocorreu na 22ª semana epidemiológica de 2021 (06/06/2021 a 12/06/2021), com 10.281 casos, conforme pode ser observado na Figura 4a. Deve-se salientar que esses momentos não se referem às ondas de COVID-19 no estado.

Na Figura 4b verifica-se a distribuição dos casos acumulados da COVID-19 no estado da Paraíba, onde é observado uma variação de 12 a 374.789 casos registrados, correspondentes da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de

2021. A Figura 4b mostrou uma característica crescente em todas as semanas com casos acumulados registrados, apresentando um menor registro nas semanas iniciais e um aumento considerável nas semanas subsequentes.

Figura 4 – Número de registro de casos novos (a) e casos acumulados (b) de COVID-19 da 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020) a 32ª semana epidemiológica de 2021 (25/07/2021 a 01/08/2021) no estado da Paraíba.

a)

b)

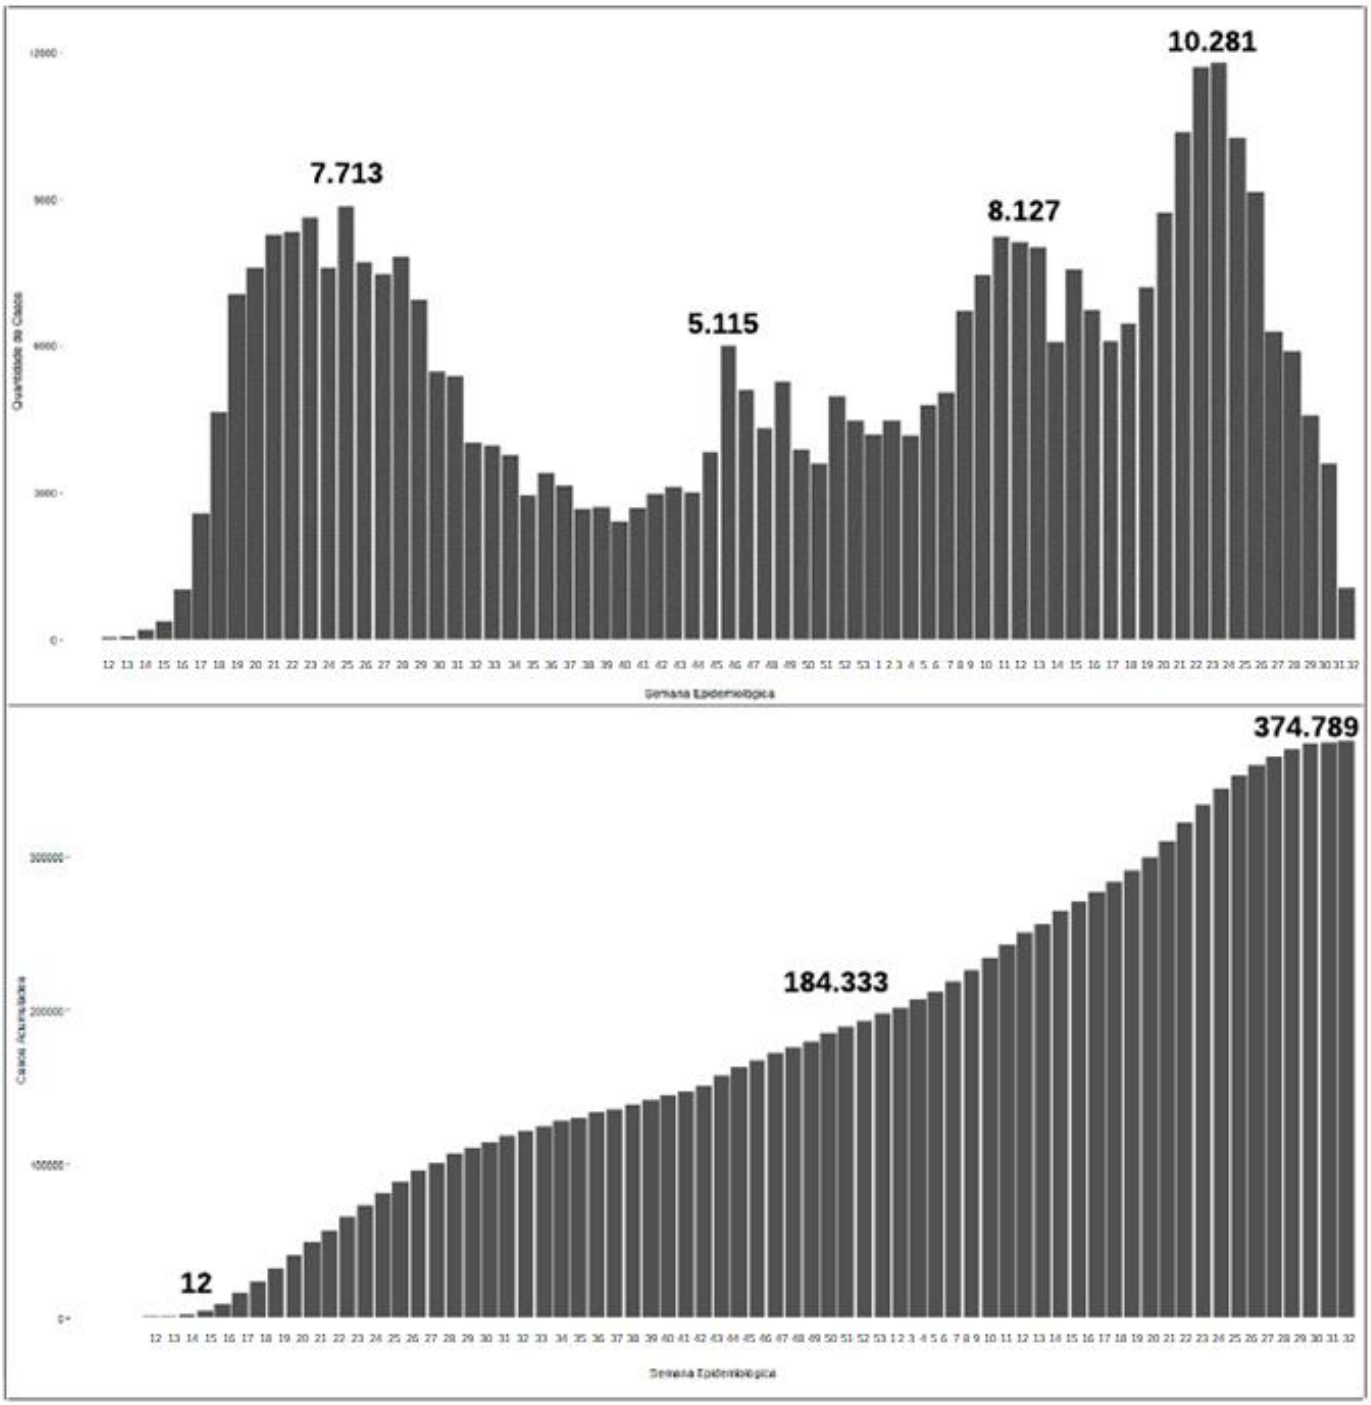

Fonte: Elaboração pela própria autora (2022).

5.2 ANÁLISE ESPACIAL

Em relação à análise espacial foram elaborados os mapas da RIE e da estatística *Scan* circular para as variáveis: casos novos, sexo feminino, sexo masculino, faixa etária menor de 20 anos, de 20 a 60 anos, maior de 60 anos, comorbidades do tipo diabetes, doenças cardíacas e doenças respiratórias da COVID-19 no período da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021.

A seguir serão apresentados os mapas resultantes dessa análise referente à variável casos novos os mapas relativos às demais variáveis estarão no APÊNDICE A. Para uma melhor compreensão espacial da doença no estado, a análise foi dividida em quatro momentos diferentes. O primeiro momento foi referente ao início da pandemia no estado da Paraíba, representado pelos mapas da RIE e *Scan* da 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020), onde foi registrada a presença de aglomerados em João Pessoa, Pitimbu na região leste do estado e Sousa e Igaracy na região oeste do estado (Figura 5).

O segundo momento compreendeu o primeiro pico da pandemia, registrado na 28ª semana epidemiológica de 2020 (05/07/20 a 11/07/2020), onde foi evidenciada a disseminação da doença para municípios da região metropolitana e para os municípios localizados ao Sudoeste do estado, como Conceição (Figura 6).

O terceiro momento demonstrou a interiorização dos casos da COVID-19 no estado para municípios de pequeno e médio porte, como Belém do Brejo do Cruz e São José do Brejo do Cruz ao Norte, Lastro e Sousa ao Oeste e Monteiro e Coxixola ao Sul, representado pela 35ª semana epidemiológica de 2020 (23/08/2020 a 29/08/2020) (Figura 7). O quarto momento foi evidenciado pela 22ª semana epidemiológica de 2021 (06/06/2021 a 12/06/2021), representando o pico máximo de casos novos durante toda a pandemia e disseminação da doença por todo o estado (Figura 8).

No primeiro momento, evidenciado pela 12ª semana epidemiológica de 2020 (15/03/2020 a 21/03/2020), a COVID-19 esteve presente em quatro municípios: João Pessoa, Pitimbu, Igaracy e Sousa, todos com RIE de 2,0 ou mais vezes o valor desta medida no estado. A RIE variou entre 0 e 54,73, sendo Igaracy, localizado ao oeste do estado, o município com maior valor registrado (Figura 5). A estatística *Scan* foi utilizada com 0,1% do percentual da população sob risco, identificando os 4 municípios destacados na Figura 5.

Figura 5 – Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 12ª semana epidemiológica de 2020, no estado da Paraíba.

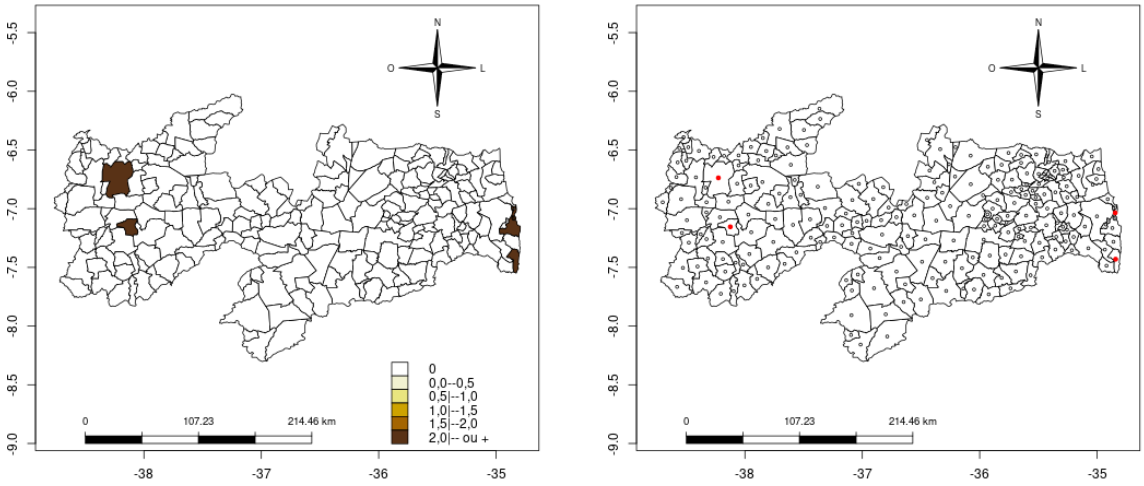

Fonte: Elaboração pela própria autora (2022).

O segundo momento foi compreendido pelo primeiro pico da pandemia da COVID-19, na 25ª semana epidemiológica de 2020 (05/07/20 a 11/07/2020), marcado pela presença de aglomerado espacial em todas as regiões do estado, com destaque na região Nordeste. Dessa forma, 22 municípios apresentaram uma RIE maior ou igual a 2,0 vezes a incidência do estado da Paraíba, variando de 0 a 4,86, onde o município de Baía da Traição obteve o maior registro. A estatística *Scan* foi utilizada com 0,1% do percentual da população sob risco (Figura 6).

Figura 6 – Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 25ª semana epidemiológica de 2020, no estado da Paraíba.

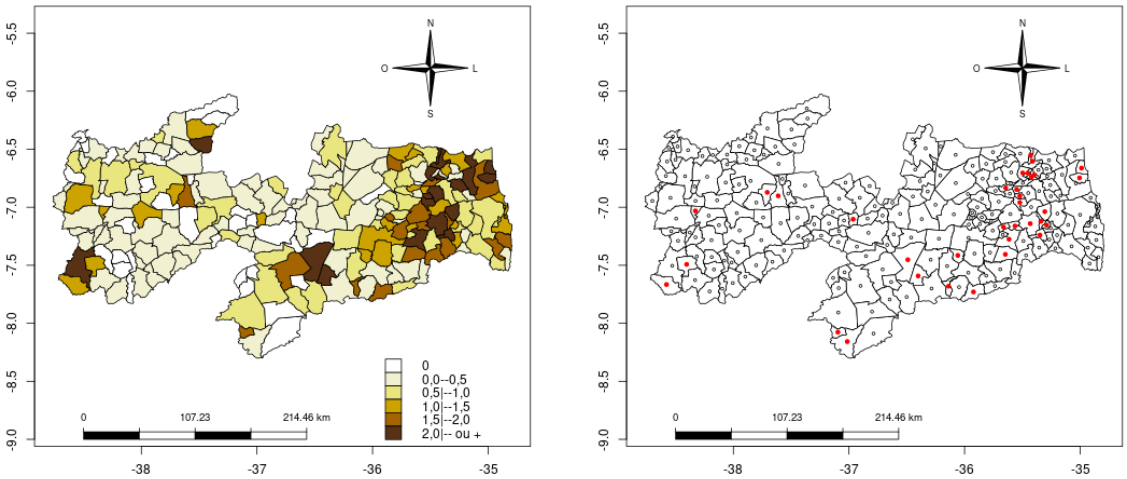

Fonte: Elaboração pela própria autora (2022).

O terceiro momento foi determinado pela 35ª semana epidemiológica de 2020 (23/08/2020 a 29/08/2020), apresentando uma disseminação dos casos para o interior do estado da Paraíba. Nessa semana, 44 municípios apresentaram RIE maior ou igual a 2 vezes o valor da incidência do estado da Paraíba, variando de 0 a 11,82, sendo Junco do Seridó, município localizado ao Norte do estado com o maior registro. Na estatística *Scan* foi utilizado o percentual de 0,4% da população sob o risco, encontrando aglomerados principalmente na região Norte e Oeste do estado e registro de aglomerados isolados na região Sul (Figura 7).

Figura 7 – Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 35ª semana epidemiológica de 2020, no estado da Paraíba.

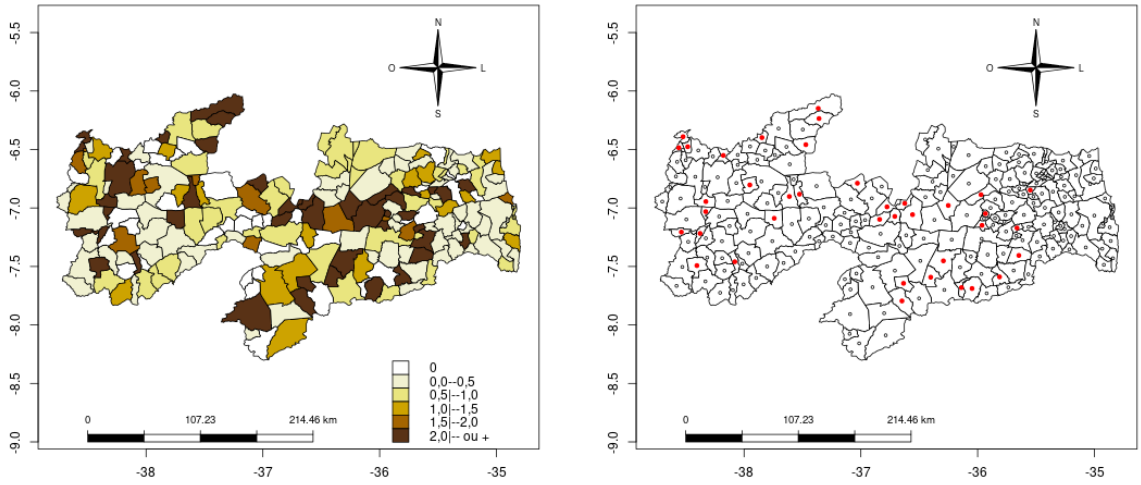

Fonte: Elaboração pela própria autora (2022).

O quarto momento foi caracterizado pela 22ª semana epidemiológica de 2021 (06/06/2021 a 12/06/2021), com 40 municípios apresentando a RIE maior ou igual a 2 vezes o valor do estado. Foi obtido a variação de 0 a 8,63, sendo o município de Prata, localizado na região Sul com maior registro. Na estatística *Scan* foi utilizado o percentual de 0,1% da população sob o risco, identificando aglomerados em todas as regiões do estado da Paraíba (Figura 8).

Figura 8 – Mapas da RIE e *Scan* espacial dos casos de COVID-19 na 22ª semana epidemiológica de 2021, no estado da Paraíba.

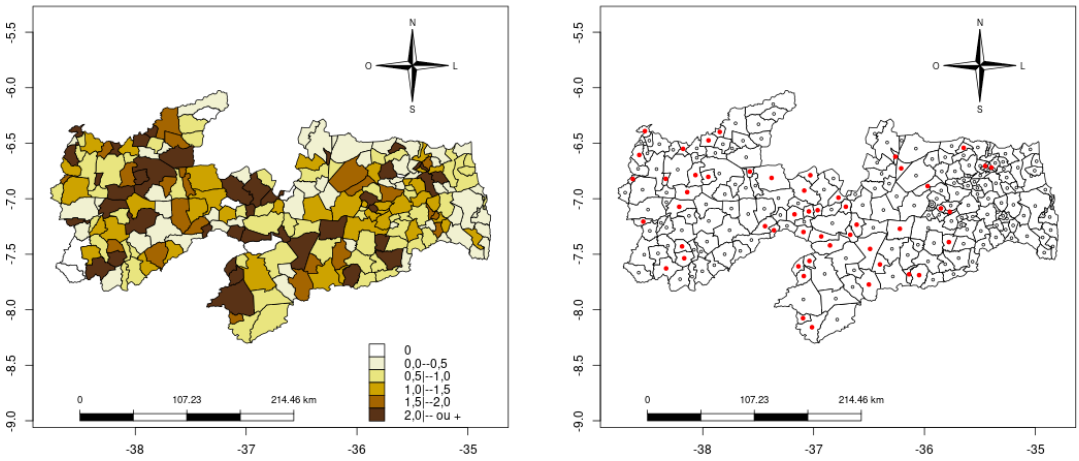

Fonte: Elaboração pela própria autora (2022).

5.3 ANÁLISE ESPAÇO-TEMPORAL

A análise espaço-temporal dos casos da COVID-19 da 12ª semana epidemiológica de 2020 até a 32ª semana epidemiológica de 2021 possibilitou visualizar a difusão espacial pelos municípios no período determinado, facilitando a compreensão dos fatores influenciadores na expansão do vírus e na necessidade de contenção da doença, a partir de medidas protocolares de saúde no estado da Paraíba. Feita uma análise retrospectiva, usando o modelo de Poisson, foi possível identificar aglomerados que aconteceram anteriormente no espaço e no tempo, fornecendo um mapa como resultado para cada variável estudada (casos novos, feminino, masculino, faixa etária menor que 20 anos, faixa etária de 20 a 60 anos, faixa etária maior que 60 anos, doenças cardíacas, doenças respiratórias e diabetes). Serão apresentados os mapas resultantes dessa análise referente à variável casos novos, os mapas relativos às demais variáveis estão no APÊNDICE A.

Foram aplicados os percentuais sob risco da população com o objetivo de encontrar o resultado mais adequado. Os percentuais encontrados mais pertinentes ao estudo foram 0,1%, 0,3%, 0,4% e 0,6% da população, em seguida os resultados do *Scan* espaço-temporal foram avaliados com base nos mapas da RIE e da *Scan* espacial. É importante destacar que, *a priori*, é feita uma procura dentro dos resultados com os percentuais aplicados e, após isso, é realizada uma procura mais aprofundada para o resultado final.

Na Figura 9, é possível visualizar o mapa gerado pela estatística *Scan* espaço-temporal para os casos novos de COVID-19 no estado da Paraíba. Observa-se através da análise do mapa que foram identificados cinco aglomerados, os quais estão localizados na região Norte do estado, constituído por São José do Brejo do Cruz, na região Central do estado, constituído por Quixabá e Areia de Baraúnas e na região na região Sul do estado, constituído por Riacho de Santo Antônio e Zebelê. A persistência máxima dos aglomerados significativos do início ao final do período de estudo foi de 29 semanas e o mínimo foi de 9 semanas (Figura 9).

Figura 9 – Mapa *Scan* espaço-temporal dos casos novos da COVID-19 no estado da Paraíba, da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021.

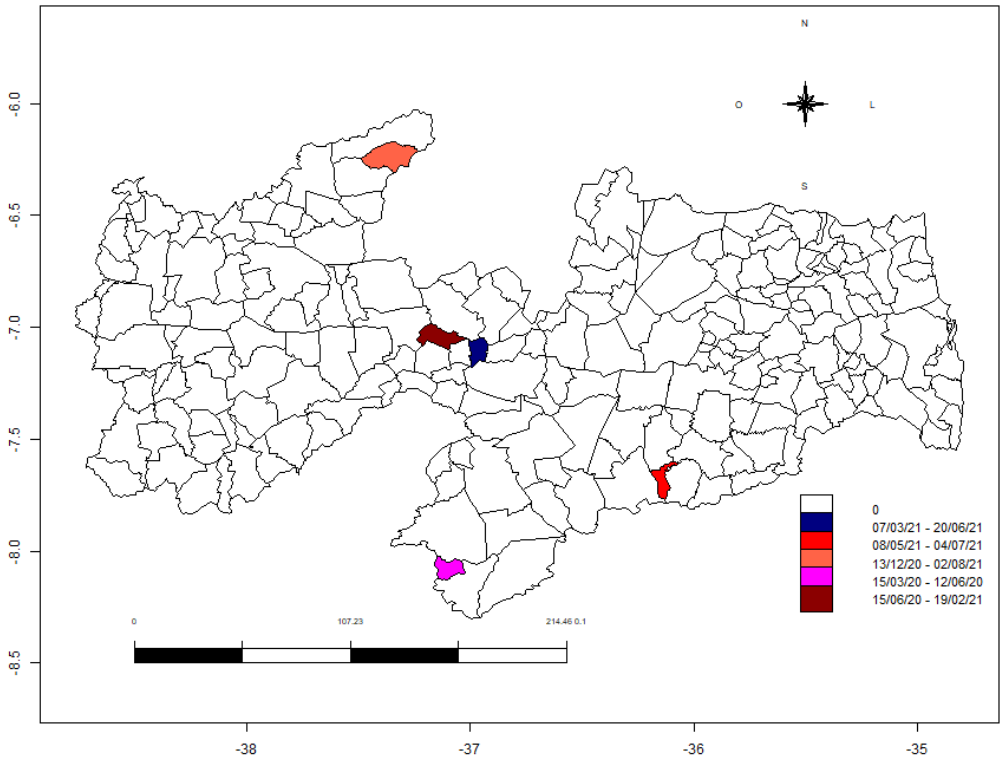

Fonte: Elaboração pela própria autora (2022).

5.4 SISTEMA BASEADO EM REGRAS *FUZZY*

As análises anteriormente citadas dos casos novos de COVID-19 no estado da Paraíba foram elementos de entrada para o sistema baseado em regras *fuzzy*. Foram utilizadas as variáveis de entrada: RIE, *Scan* espacial, *Scan* espaço-temporal, tempo de aglomerado, persistência do aglomerado e correlação de Spearman. Como saída, foram obtidos os graus de prioridades dos municípios, sendo estes: “prioritário”, “endência à

prioritário", "tendência a não prioritário" e "não prioritário". Para demonstrar o SDSS, foi utilizado o subcritério casos novos, de acordo com a Tabela 3.

À vista disso, as variáveis linguísticas, os termos linguísticos, e as funções de pertinência foram iguais para todos os subcritérios, sendo modificado apenas o domínio retirado dos dados analisados. As funções de pertinência usadas para as variáveis de entrada e saída do SDSS foram do tipo trapezoidal e triangular, as regras foram determinadas através da arquitetura de Moraes, Nogueira e Sousa (2014), porém, foi preciso realizar adaptações que se encaixassem às características da doença e seus critérios, totalizando 204 regras.

Tabela 3 - Variáveis linguísticas, termos linguísticos e domínio utilizado no SDSS referente ao subcritério casos novos da COVID-19 (Continua)

Variável linguística de Entrada	Explanação da variável linguística	Termos linguísticos	Domínio
Razão de Incidências Espacial	Município segundo a RIE	Muito alta	[1.99, 328]
		Alta	[1.49, 2.08]
		Média	[0.99, 1.58]
		Baixa	[0.49, 1.08]
		Muito baixa	[-1,0, 0.58]
Scan espacial	Município com detecção ou ausência de aglomerado espacial	Com Scan	[0.95, 1.05]
		Sem Scan	[-0.05, 0.05]
Scan espaço-temporal temporal	Município com detecção ou ausência de aglomerado	Com Scan	[0.95, 1.05]
		Sem Scan	[-0.05, 0.05]
Tempo do aglomerado espaço-temporal	Período (semana) em que o município apresentou aglomerado espaço-temporal	Muito recente	[64.5, 77]
		Recente	[28, 64]
		Não Recente	[2, 28]
Persistência do aglomerado espaço-temporal	Tempo de persistência em que o município foi um aglomerado espaço-temporal significativo	Sem persistência	[-0.9965, 0.8896]
		2 semanas	[0.106, 1.892]
		4 semanas	[1.115, 2.91]
		8 semanas	[2.11, 3.85]
Coeficiente de correlação de Spearman	Grau de correlação da RIE durante o período de estudo para cada município	Alta positiva	[0.658, 1.5]
		Moderada positiva	[0.185, 0.812]
		Fraca	[-0.331, 0.35]
		Moderada negativa	[-0.803, -0.183]

Tabela 3 - Variáveis linguísticas, termos linguísticos e domínio utilizado no SDSS referente ao subcritério casos novos da COVID-19 (Continuação)

Variável linguística de Entrada	Explanação da variável linguística	Termos linguísticos	Domínio
Variável linguística de saída	Identificação dos níveis de prioridade para intervenção dos municípios	Prioritário	[0.721, 1.3]
Níveis de prioridade dos municípios		Tendência à Prioritário	[0.397, 0.9233]
		Tendência a não prioritário	[0.07855, 0.602]
		Não prioritário	[-0.3, 0.2855]

Fonte: Elaboração pela própria autora (2022).

O mapa de decisão provido pelo SDSS apresentou os níveis de prioridades dos municípios da Paraíba de acordo com os casos novos, sexo, faixa etária e comorbidades da COVID-19. Na Figura 10 é possível visualizar que dos 223 municípios para o subcritério casos novos, 183 foram considerados "não prioritários" e estavam dispersos por todo o estado. Cinco com "tendência a não prioritário" com maior concentração a Oeste do estado, 26 com "tendência a prioritário" e nove municípios estavam como "prioritário", mais localizados na região sudoeste do estado. Os mapas referentes aos outros subcritérios estão presentes no Apêndice.

Figura 10 – Mapa de decisão provido pelo SDSS para os casos novos de COVID-19 no estado da Paraíba, 2020-2021.

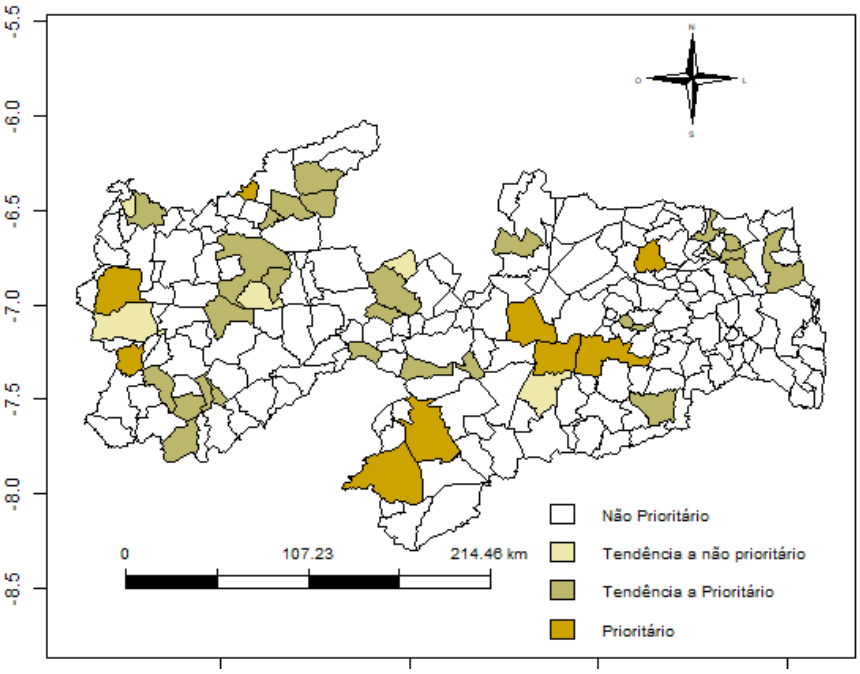

Fonte: Elaboração pela própria autora (2022).

Na figura 11, o mapa de decisão georreferenciado provido pelo SDSS mostrou os níveis de prioridade dos municípios referente aos casos femininos de COVID-19. Dos 223 municípios, 185 foram considerados como “não prioritários” e estavam dispersos por todo estado. Seis com “tendência a não prioritário” mais concentrado a leste do estado, 26 com “tendência a prioritário” com maior concentração a sudoeste, e seis considerados como “prioritários”, com maior concentração na região central e norte do estado.

Figura 11 – Mapa de decisão provido pelo SDSS para os casos femininos de COVID-19 no estado da Paraíba, 2020-2021.

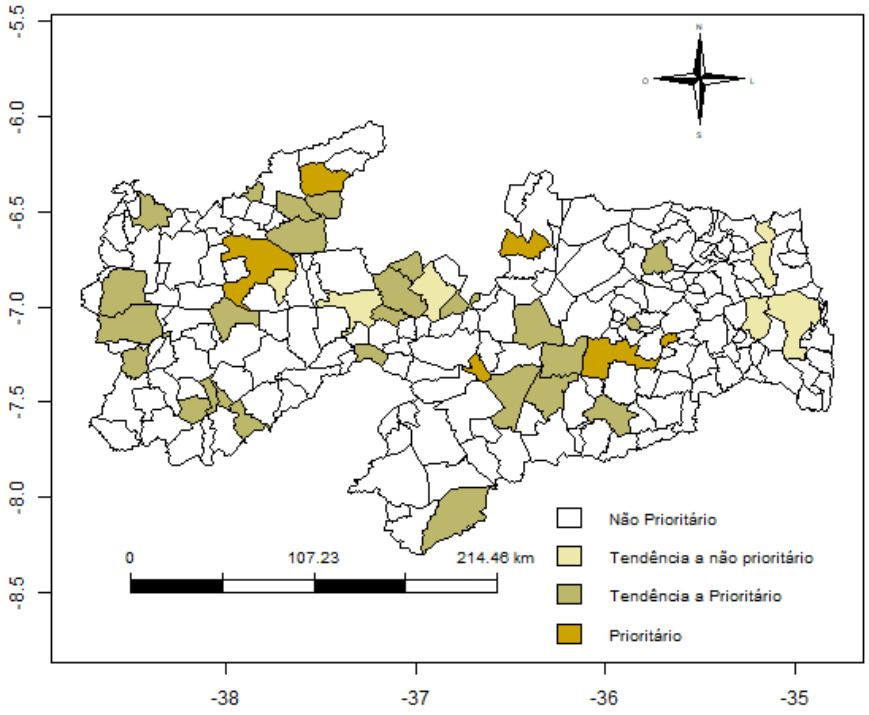

Fonte: Elaboração pela própria autora (2022).

O mapa de decisão provido pelo SDSS determinou os níveis de prioridades dos municípios referentes aos casos masculinos de COVID-19. Foram considerados como “não prioritários” 178 municípios, que estavam dispersos por todo estado. Seis com “tendência a não prioritário” mais concentrado a norte do estado, 34 com “tendência a prioritário” com maior concentração a sudoeste, e cinco considerados como “prioritários’’, como pode ser visualizado na Figura 12.

Figura 12 - Mapa de decisão provido pelo SDSS para os casos masculinos de COVID-19 no estado da Paraíba, 2020-2021.

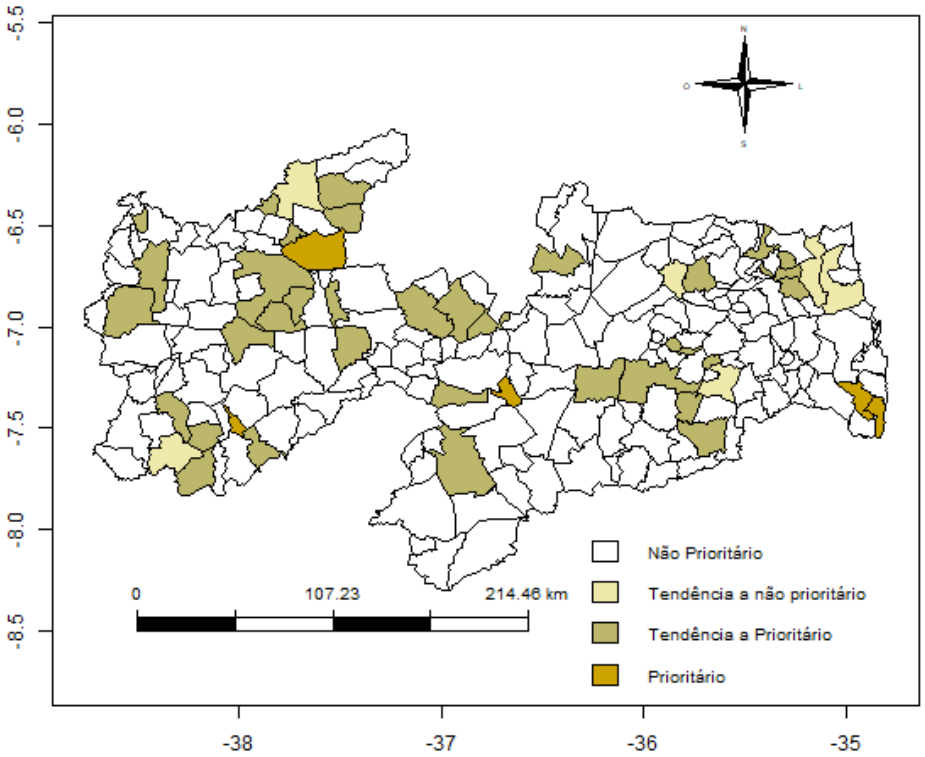

Fonte: Elaboração pela própria autora (2022).

De acordo com a idade, foram elaborados mapas de decisão providos do SDSS para os níveis de prioridade segundo as faixas etárias: menor de 20 anos, de 20 a 60 anos e maior que 60 anos. O mapa para a variável menor de 20 anos (Figura 13) identificou 192 municípios como “não prioritários”, que estavam dispersos por todo estado. Cinco com “tendência a não prioritário”, 24 com “tendência a prioritário”, e dois considerados como “prioritários’’. O mapa para a variável de 20 a 60 anos (Figura 14) mostrou 192 municípios como “não prioritários”, que estavam dispersos por todo estado. Cinco com “tendência a não prioritário”, 24 com “tendência a prioritário”, e dois considerados como “prioritários’’. Para a variável maior de 60 anos (Figura 15), foi possível visualizar no mapa de decisão SDSS 192 municípios como “não prioritários”, que estavam dispersos por todo estado. Três com “tendência a não prioritário”, 22 com “tendência a prioritário”, e seis considerados como “prioritários’’.

Figura 13 - Mapa de decisão provido pelo SDSS para os casos confirmados para a COVID-19 em menores de 20 anos de idade no estado da Paraíba, 2020-2021.

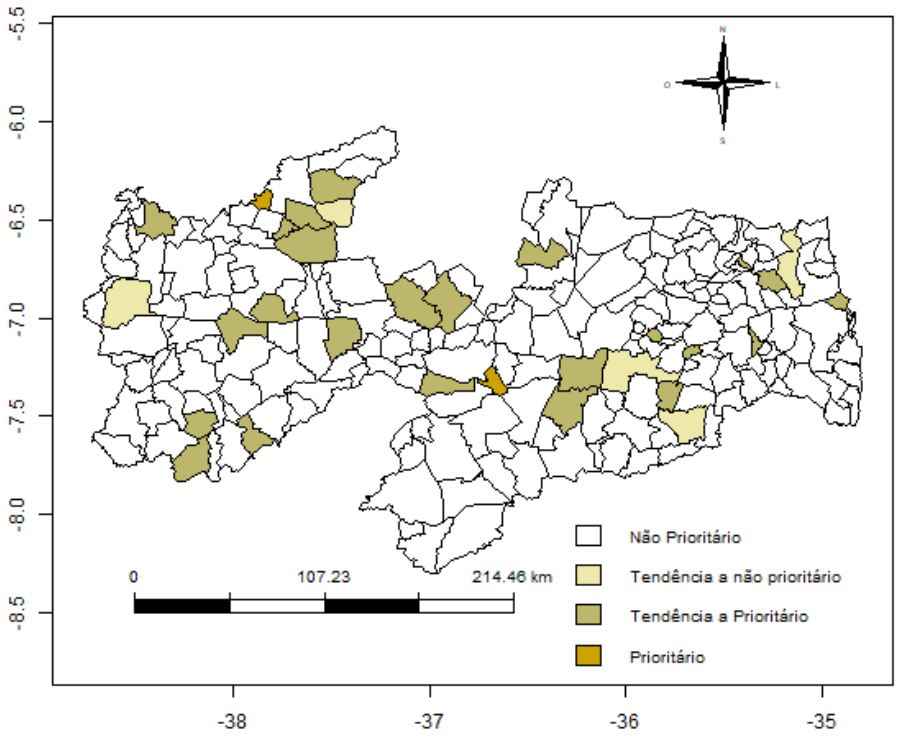

Fonte: Elaboração pela própria autora (2022).

Figura 14 - Mapa de decisão provido pelo SDSS para os casos confirmados para COVID-19 na faixa etária de 20 a 60 anos no estado da Paraíba, 2020-2021.

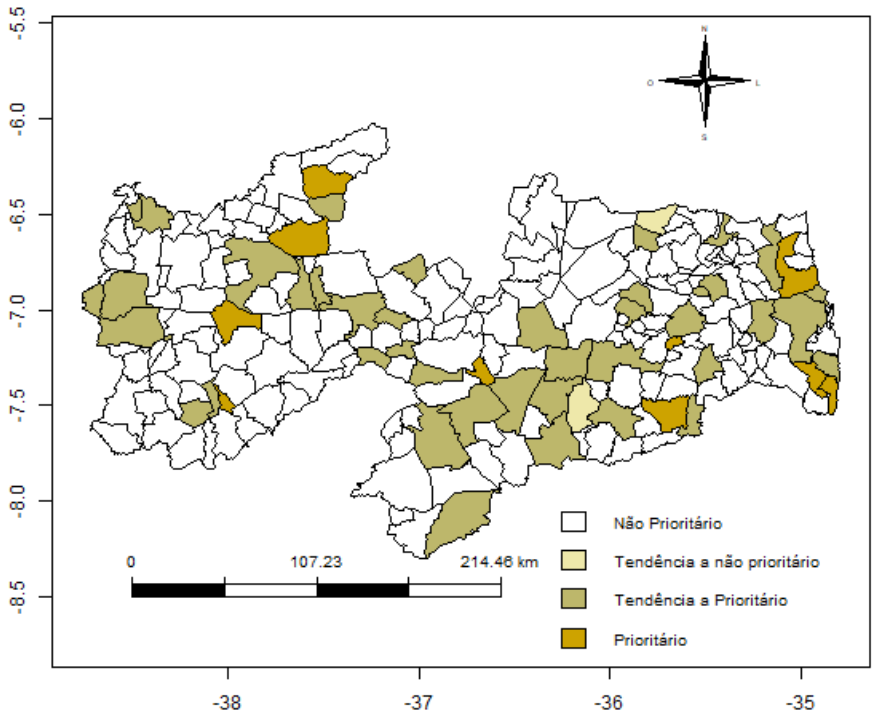

Fonte: Elaboração pela própria autora (2022).

Figura 15 - Mapa de decisão provido pelo SDSS para os casos confirmados da COVID-19 em maiores de 60 anos de idade no estado da Paraíba, 2020-2021.

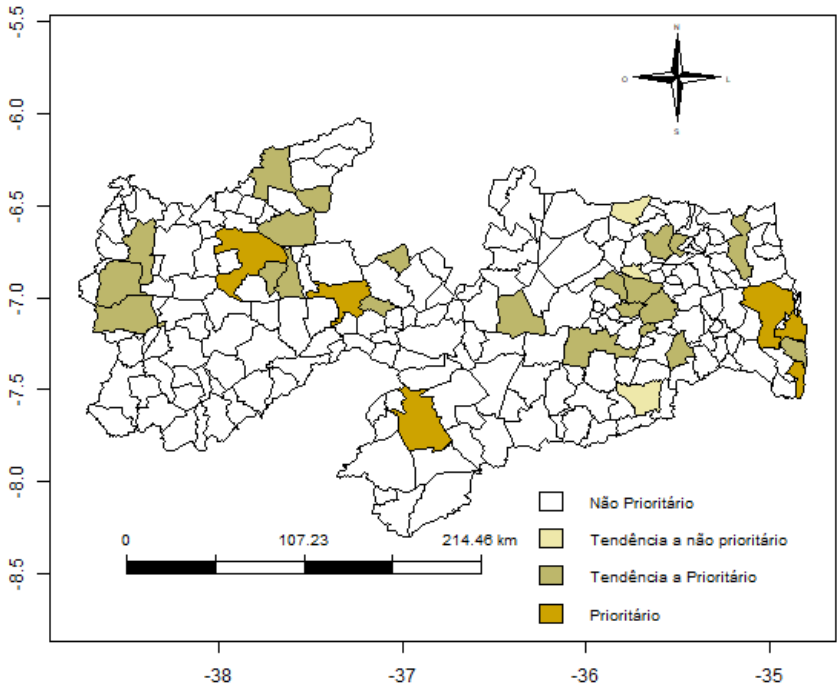

Fonte: Elaboração pela própria autora (2022).

A confecção de mapas de decisão providos do SDSS, segundo as comorbidades, foram observados para os níveis de prioridade conforme as doenças cardíacas, as doenças respiratórias e a diabetes. O mapa para o critério doenças cardíacas apontou 212 municípios como “não prioritários”, que estavam dispersos por todo estado. Dez com “tendência a prioritário”, e um município considerado como “prioritários’’ localizado na região leste do estado (Figura 16). Para o critério doenças respiratórias (Figura 17), o mapa demonstrou 210 municípios como “não prioritários”, que estavam dispersos por todo estado. Dois com “tendência a não prioritário”, oito com “tendência a prioritário”, e três municípios considerados como “prioritários’’. O mapa referente a variável diabetes (Figura 18), identificou 211 municípios como “não prioritários”, que estavam presentes na maior parte do estado. Oito com “tendência a prioritário”, e quatro municípios considerados como “prioritários’’ localizados nas regiões leste e oeste do estado.

Figura 16 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com doenças cardíacas no estado da Paraíba, 2020-2021.

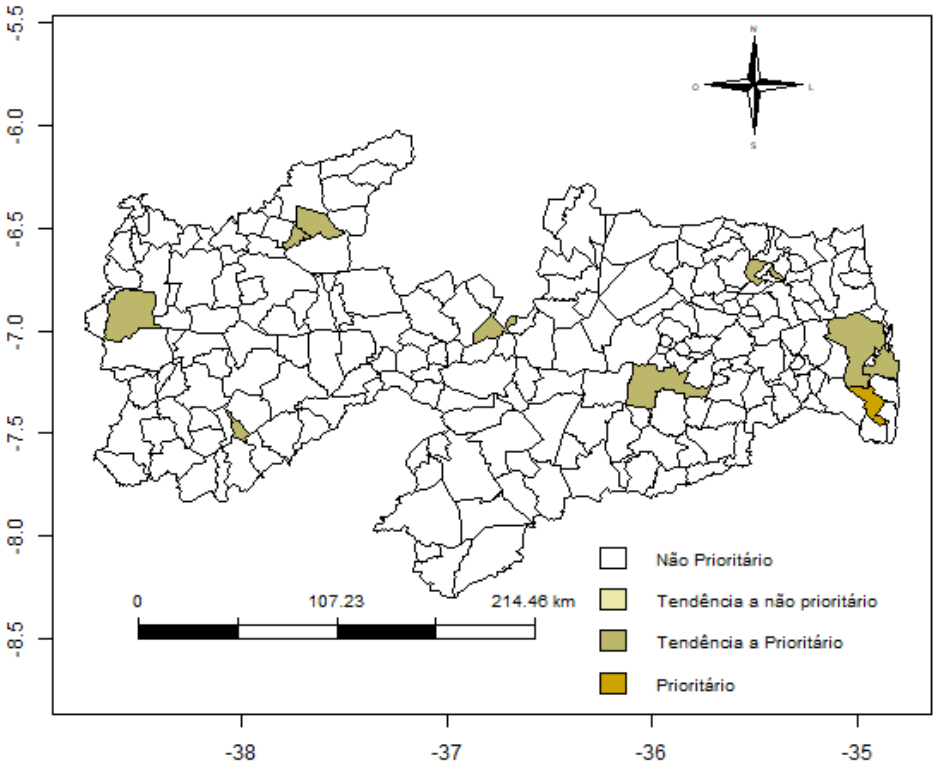

Fonte: Elaboração pela própria autora (2022).

Figura 17 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com doenças respiratórias no estado da Paraíba, 2020-2021.

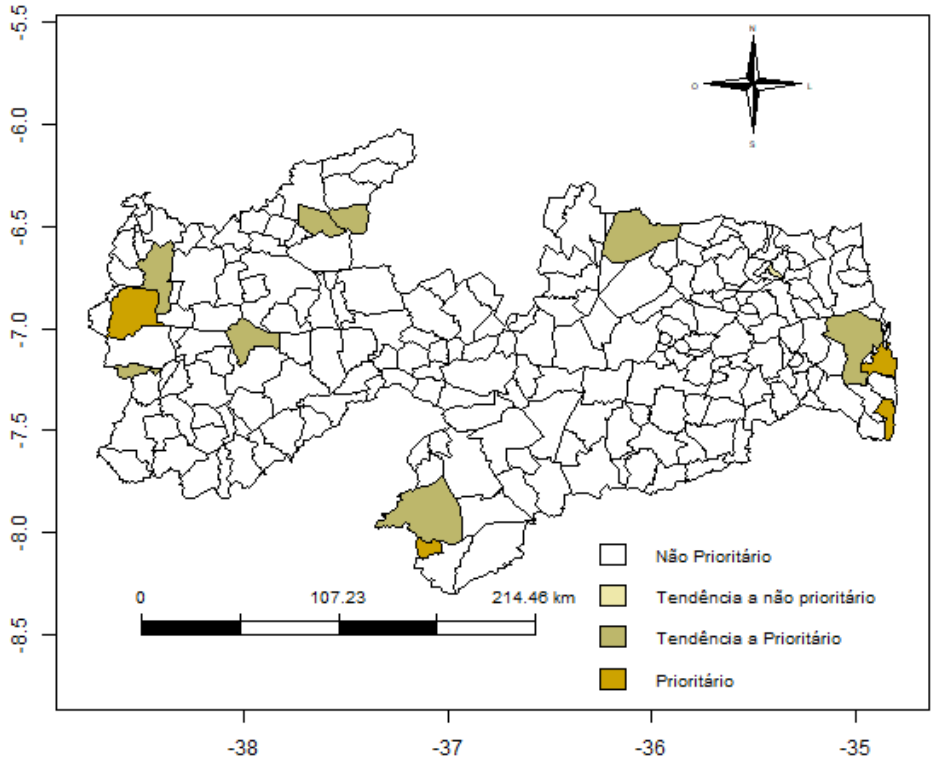

Fonte: Elaboração pela própria autora (2022).

Figura 18 - Mapa de decisão provido pelo SDSS para os casos de COVID-19 com diabetes no estado da Paraíba, 2020-2021.

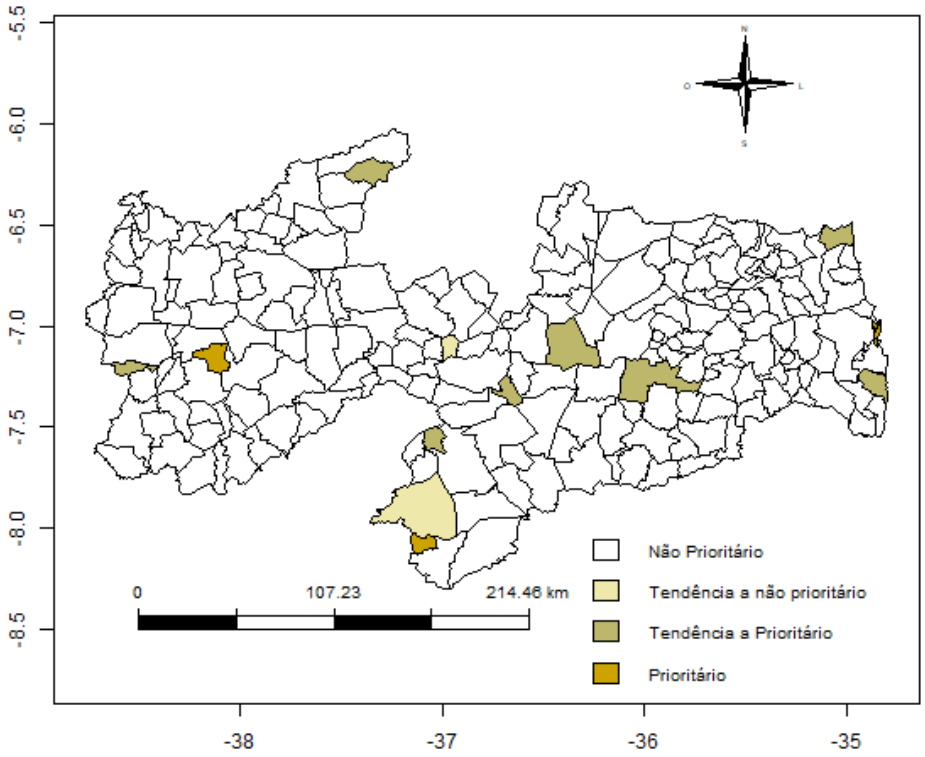

Fonte: Elaboração pela própria autora (2022).

5.5 SISTEMA DE SUPORTE À DECISÃO ESPACIAL BASEADO EM WLC

No SDSS baseado em WLC proposto nesse estudo (Figura 2), é uma adaptação da arquitetura de Lima *et al.* (2019), onde foram utilizados os critérios casos novos, sexo feminino e masculino, faixa etária menor de 20 anos, de 20 a 60 anos e maior de 60 anos e as comorbidades doenças cardíacas, doenças respiratórias e diabetes, para originar os mapas de decisão, em seguida, foi aplicado a WLC a cada saída do sistema baseado em regras *fuzzy* para obtenção do mapa de decisão final.

Figura 19 - Sistema de Apoio à Decisão Espacial baseado em WLC.

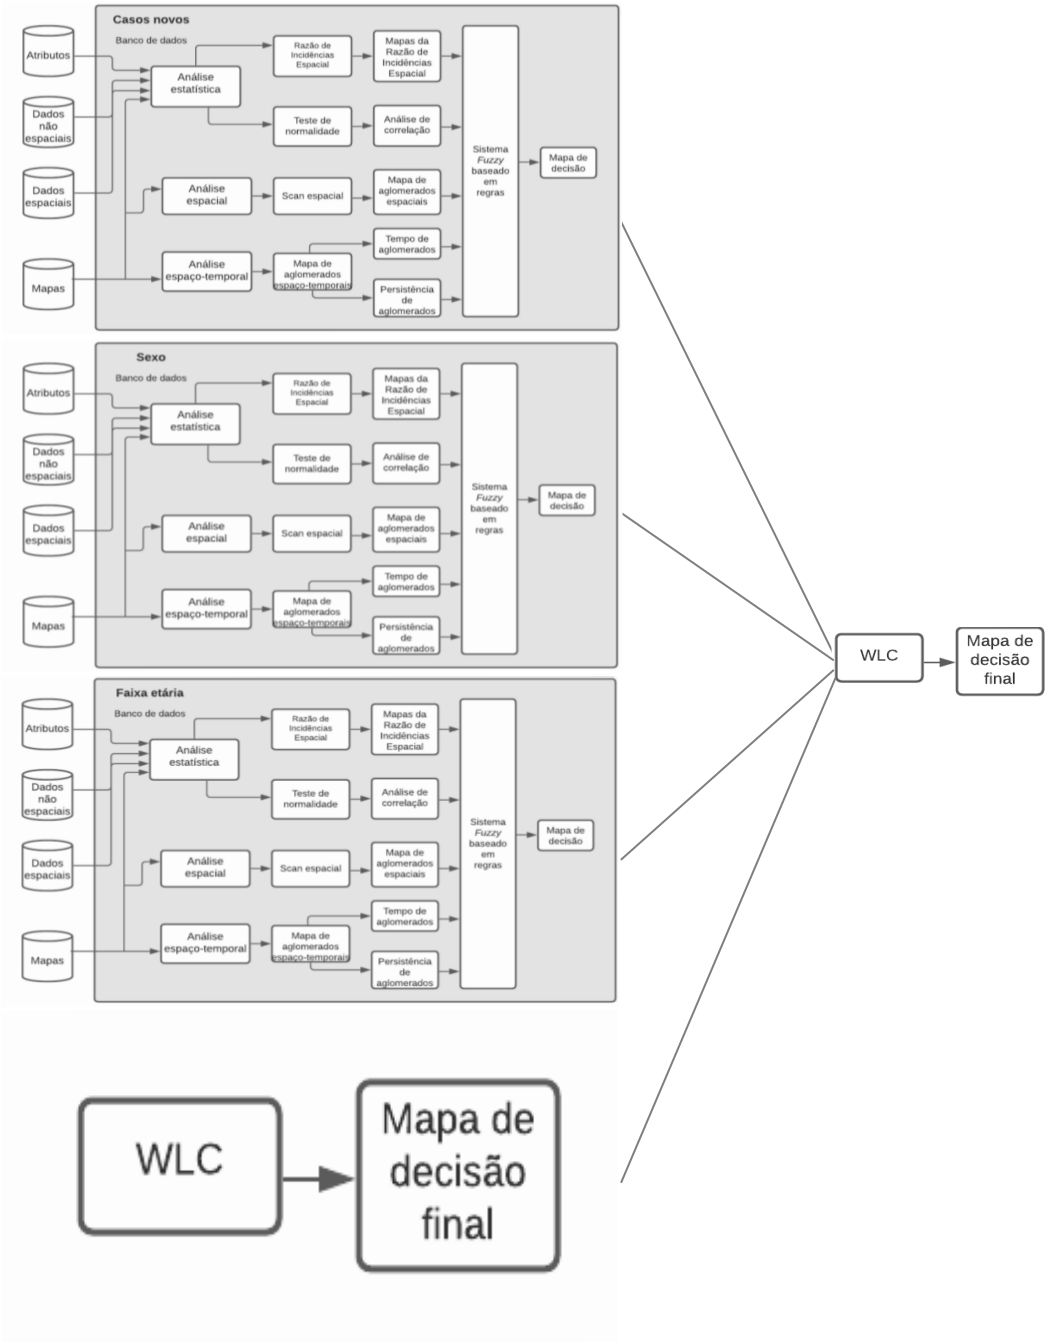

Fonte: Elaboração pela própria autora (2022).

Conforme a Figura 19, o mapa de decisão final produzido pelo SDSS baseado em WLC mostra os níveis de prioridades para intervenção dos municípios da Paraíba aplicada aos casos de COVID-19. Os resultados de cada variável foram combinados pelo WLC como um critério em um problema MCDM. Esses pesos da WLC foram determinados através de uma proporção com informações obtidas diretamente dos dados da pesquisa, na qual foram calculadas cada proporção discriminada pelas categorias: casos novos; sexo feminino; sexo masculino; faixa etária menor de 20 anos, de 20 a 60 anos e maior de 60 anos; e as comorbidades, doenças cardíacas, doenças respiratórias e diabetes. Em seguida o valor obtido foi multiplicado e somado pelo valor de saída do SDSS baseado em regras *fuzzy*, onde se obteve um resultado final para cada categoria. Os maiores pesos foram atribuídos para casos novos e indivíduos do sexo feminino.

WLC = [0,2461 0,0002 0,0025 0,0052 0,1471 0,0962 0,0411 0,1731 0,0272]

onde: 0,2461: peso atribuído aos casos novos; 0,0002: peso atribuído as doenças respiratórias; 0,0025: peso atribuído a diabetes; 0,0052: peso atribuído as doenças cardíacas; 0,1471: peso atribuído ao sexo feminino; 0,0962: peso atribuído ao sexo masculino; 0,0411: peso atribuído a faixa etária menor de 20 anos; 0,1731: peso atribuído a faixa etária de 20 a 60 anos; e 0,0272: peso atribuído a faixa etária maior de 60 anos.

Como resultado final, um novo mapa foi obtido mostrando quatro alternativas de combate à doença: “não prioridade”, “tendência não prioritária”, “tendência prioritária” e "prioritário", ou seja, níveis de prioridade para combate à doença para cada geo-objeto presente na região geográfica em estudo. Foi evidenciado que 153 municípios foram classificados como “não prioritário”, 51 como “tendência a não prioritário” e 19 como “tendência a prioritário”.

Figura 20 – Mapa de decisão final do SDSS baseado em WLC.

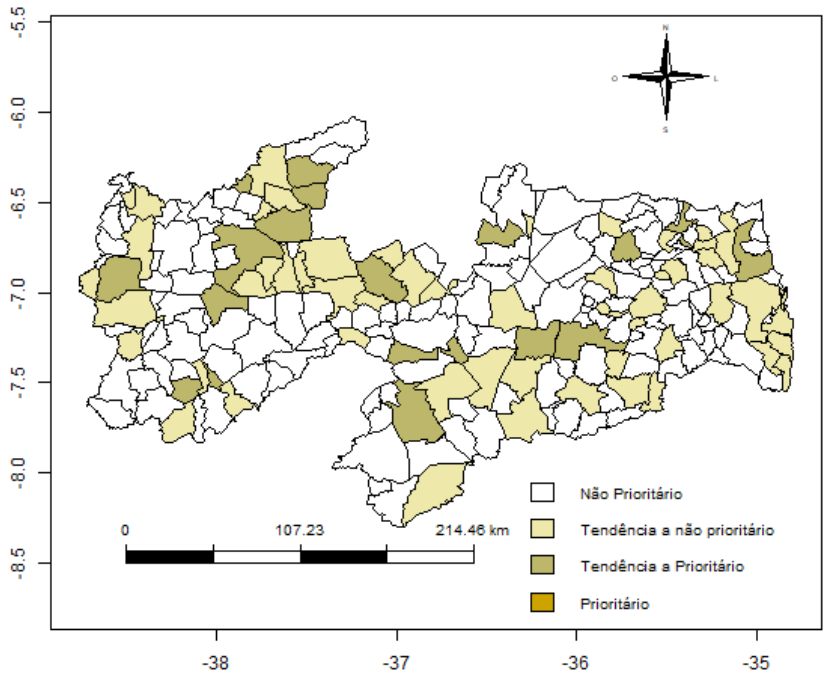

Fonte: Elaboração pela própria autora (2022).

6. DISCUSSÃO

O vírus da COVID-19 é disseminado de forma fácil e rápida por secreções contaminadas, manifestando-se como uma síndrome respiratória aguda, que na maioria dos casos é leve ou assintomática, contudo, pode ocorrer em sua forma mais grave, provocando insuficiência respiratória e complicações associadas, que podem ser letais (BRASIL, 2020). A letalidade dessa doença está associada a vários fatores determinantes de saúde, evidenciando a presença de comorbidades pré-estabelecidas, a exemplo das doenças crônicas; idade avançada superior a 60 anos e populações em situação de vulnerabilidade social que não possuem fácil acesso aos serviços de saúde (OUSLANDER, 2020).

De acordo com o presente estudo, a faixa etária de 20 a 60 anos foi a mais acometida pela COVID-19 no estado da Paraíba, com 281.216 (75,23%) dos registros dos casos totais. Tais achados, evidenciados através da pesquisa de Silva (2021) realizada na Paraíba, onde a faixa etária de 30 a 39 anos foi a mais acometida pela afecção, corroborando com a pesquisa de Cavalcante; Abreu (2020) traz que a faixa etária menor que 50 anos foi a que mais teve casos da doença no estado do Rio de Janeiro. Os prováveis

fatores que influenciam a ocorrência desses achados estão relacionados à fase ativa do trabalhador nessa faixa etária, aumentando a necessidade de se deslocar para outros ambientes e o contato interpessoal, o que permite uma maior exposição ao vírus. O maior nível de isolamento na Paraíba foi no início da pandemia, em volta da 13º semana epidemiológica de 2020 (22/03/2020 a 28/03/2020) com 62,2%, vale salientar que inicialmente, a recomendação da OMS era de um isolamento superior a 70%.

Em relação a população com idade maior que 60 anos, foram registrados 50.202 (13,43%) dos casos no estado da Paraíba. Apesar de não ser a faixa etária de maior registro, é necessário que exista uma atenção elevada para essa população devido aos riscos de evoluírem a óbito. O estudo de Paiva (2021) verifica que os indivíduos da referida faixa de idade apresentaram risco de quatro vezes maior de ir a óbito no que se refere aos mais jovens. A população idosa engloba características singulares devido ao próprio processo de envelhecimento, onde o organismo e o sistema de defesa são mais frágeis e vulneráveis, tornando-a mais suscetível ao acometimento e complicações de patologias (ROCHA *et al*., 2021).

A respeito da variável sexo, os registros do sexo feminino foram maiores, com 209.286 (55,99%) casos da COVID-19, cerca de 12% a mais que os casos do sexo masculino. Evidencia-se que a população no estado da Paraíba entre 30 e 39 anos, é formada na maior parte, por pessoas do sexo feminino (IBGE, 2012). Tal achado foi concordante com os dados do estudo de Silva (2021), que traz a população feminina como a mais acometida em relação aos casos e óbitos por COVID-19 na Paraíba. Na literatura, foram encontrados poucos estudos que correlacionaram a saúde da mulher com o aumento da ocorrência dessa patologia, destacando uma necessidade cada vez maior de uma atenção especializada voltada a esse público (CHEN *et al*., 2020).

Na atualidade, as mulheres estão cada vez mais adentrando no mercado de trabalho e estabelecendo um papel social de extrema importância (BONIOL *et al*., 2019). Os dados do Gabinete de Informação do Conselho de Estado na China informam que mais de 90% dos profissionais de saúde na província de Hubei são mulheres, ressaltando a natureza de gênero da força de trabalho de saúde e o risco que os profissionais de saúde predominantemente femininos incorrem (FENG *et al*., 2020). Segundo Wenham *et al.* (2020), reconhecer até que ponto os surtos de doenças afetam mulheres e homens de maneira diferente é um passo fundamental para compreender os efeitos primários e secundários de uma emergência de saúde em diferentes indivíduos e comunidades e para criar políticas e intervenções eficientes e equitativas.

Das comorbidades apontadas neste estudo, a mais acometida por COVID-19 foi a doença cardíaca, com 4,46% dos casos registrados, seguido por diabetes com 2,62% e doença respiratória com 1,16%. Pesquisas realizadas pelo mundo (AZIZ, FATIMA, ASSALY, 2020; CHEN T. *et al*., 2020; LIU Y. *et al*., 2020) trazem que portadores de comorbidades como Hipertensão Arterial Sistêmica (HAS), diabetes, cardiopatia e pneumopatias estão associadas ao aumento do risco da morbimortalidade em pessoas com COVID-19, apresentando um prognóstico desfavorável em comparação com aqueles que não apresentam comorbidades. A pesquisa de Paiva (2021) aponta que as comorbidades doença cardiovascular e diabetes estão relacionadas aos desfechos mais fatais em pacientes com COVID-19, aumentando aproximadamente 4 vezes mais o risco de morte.

Sobre os casos novos de COVID-19 no estado da Paraíba observa-se que o máximo de casos novos registrados aconteceu na 22ª semana epidemiológica de 2021 (06/06/2021 a 12/06/2021), com 10.281 casos (Figura 4a). Vale salientar que as notificações de casos de COVID-19 caem consideravelmente em fins de semana e feriados, o que resulta em um aumento da concentração de notificações durante a semana. Segundo os dados do Ministério da Saúde (2020), os domingos e as segundas-feiras são os dias que possuem o menor registro de notificação, isso devido ao regime de plantão nos centros de saúde e em laboratórios, o que retarda o envio das informações.

Na figura 4b observamos os registros dos casos acumulados da COVID-19 no estado da Paraíba, onde é percebido uma variação de 12 a 374.789 casos registrados, correspondentes da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021. Percebe-se que os casos foram aumentando substancialmente e progressivamente nas semanas epidemiológicas posteriores aos feriados, período de eleições e festas de fim de ano, isso porque há um maior número de pessoas reunidas, apesar das recomendações de distanciamento social, aumentando a disseminação do vírus. Esse aumento na notificação ocorre de 5 a 15 dias após essas datas, visto o período de incubação do vírus.

No estado da Paraíba foram realizados 274.985 testes do tipo RT-PCR para COVID-19 até a 32ª semana epidemiológica de 2021, desses testes 100.544 (36,26%) foram na capital João Pessoa, seguido por Campina Grande com 25.920 (9,42%) testes, Monteiro 8.058 (2,95%), Santa Rita com 7.017 (2,56%) e Cabedelo com 7.017 (2,54%) testes realizados, e no total, foram positivados 93.097 (33,85%) dos casos (PARAÍBA, 2021).

A vacinação contra COVID-19 na Paraíba teve início no dia 18 de janeiro de 2021 e após um ano, temos o estado como o segundo ente federativo que mais vacinou, com

uma cobertura da população com idade de 18 anos ou mais, acima de 82%, ficando atrás apenas do Rio Grande do Sul (FILHO *et al.*, 2021). Podemos observar que é notável uma estabilização no número de óbitos por semana, apesar de simultaneamente existir um aumento do número de casos de COVID-19, essas vacinas possuem uma ação benéfica sobre a alta taxa de casos graves e mortalidade causada pelo SARS-CoV-2, um objetivo fundamental da vacinação (BERNAL *et al.*, 2021).

Contudo, é importante destacar que o isolamento social e o fortalecimento da vacinação de toda a população, são os únicos instrumentos existentes atualmente para o controle da pandemia, bem como para reduzir os já altos custos humanitário e econômico (PRIESEMANN *et al.*, 2021). De acordo com o estudo de Guimarães (2021), o Brasil tem experiência acumulada ao longo de 40 anos na construção de confiabilidade do Programa Nacional de Imunização, o que causa uma boa adesão à vacinação e coloca o país em vantagem com relação a outros países, como os EUA. Porém, é perceptível que nas áreas mais carentes, entre os grupos vulneráveis, a cobertura vacinal é menor, fazendo essencial o fortalecimento de ações comprometidas com a diminuição das iniquidades de vacinação antes de novos picos de contaminação, além de reforçar o uso de máscara e álcool 70% (PERRY *et al.*, 2021).

Sob a perspectiva da análise espacial dos casos de COVID-19 no estado da Paraíba da 12ª semana epidemiológica de 2020 a 32ª semana epidemiológica de 2021 foi evidenciado uma propagação espacial por municípios, que inicialmente atingiu a região metropolitana de João Pessoa, ao leste do estado, e difundiu-se para os municípios localizados ao Norte do estado nos municípios de Sousa e Igaracy (Figura 5) e em seguida houve uma disseminação para todo o estado (Figuras 7 e 8).

O presente estudo identificou que nas primeiras semanas epidemiológicas, a COVID-19 estava mais concentrada na região metropolitana de João Pessoa, onde retêm os serviços de saúde mais especializados, uma melhor infraestrutura, maiores propostas de emprego e uma maior concentração populacional, o que propicia um maior alastramento do vírus. Porém, com o passar das semanas epidemiológicas, a doença começou a se disseminar para o interior e em áreas mais remotas do estado, áreas essas, vistas por possuírem baixa densidade demográfica e prejudicado acesso aos serviços mais especializados (FLOSS *et al*., 2020). Dessarte, estes aspectos podem estar associados com a redução da velocidade de contágio da doença, contudo, estes locais possuem uma maior situação de vulnerabilidade e pobreza, além de uma dificuldade na implantação e

implementação de políticas públicas, atenuando o problema nessas áreas (KARIM; CHEN, 2021).

A velocidade e o potencial de disseminação da COVID-19 estabelecem uma sequência de desafios semanais, ou até mesmo diários, à saúde pública, obstando a tomada de decisão por parte dos gestores em seus distintos âmbitos de governo (QUININO *et al*., 2021). Devido a isso, é imprescindível conhecer como funciona a distribuição da doença em uma região, bem como compreender a sua difusão e de como está acontecendo o processo de interiorização da região metropolitana para áreas com menor desenvolvimento (PEDROSA; ALBUQUERQUE, 2020). Neste aspecto, Huchler, Russel e Stroebel (2020) ressaltam que entender as conexões sociais, econômicas, comerciais e o deslocamento de viagens é primordial para entender a expansão territorial da COVID-19.

O SSDS baseado em WLC proposto neste estudo possibilitou a agregação de vários critérios, envolvendo características como sexo, idade e comorbidades, além da combinação de aspectos espaciais e não-espaciais, resultando em um mapa de decisão final com os níveis de prioridades para intervenção dos municípios do estado da Paraíba aplicada à COVID-19. Na literatura, foi encontrado o estudo de Lima *et al* (2019), que utiliza múltiplos critérios para determinar os níveis de prioridades das anomalias congênitas do sistema nervoso no estado da Paraíba, porém, não foram encontrados estudos com MCDM para a COVID-19.

O estudo constatou que no mapa de decisão final três níveis de prioridades foram identificados “não prioritário”, “tendência a não prioritário e “tendência a prioritário”, a maioria dos municípios considerados “tendência a prioritário” apresentam uma maior densidade populacional, e/ou fazem fronteiras com outros estados, e/ou possuem vulnerabilidade socioeconômica mais acentuada, fatores estes, que favorecem o aumento da disseminação da COVID-19. Do enfoque epidemiológico, as alternativas "prioridade" e "tendência de prioridade" requerem futuras intervenções do gestor público, respectivamente. Essas possibilidades auxiliam ao gestor a investigar possibilidades de escolha múltipla com base em múltiplos critérios, para assim, obter uma preferência na alternativa e uma tomada de decisão coerente e assertiva, voltada para a necessidade do município (LIMA *et al*., 2019).

Nessa perspectiva, o SDSS baseado em WLC pode ser aplicado em diversas situações no âmbito da saúde pública, visto que vem sendo uma ferramenta que contribui para a gestão da vigilância epidemiológica, considerando o conhecimento administrativo

e epidemiológico, particularmente no que concerne áreas prioritárias para o combate de doenças. Desse modo, há como ter uma compreensão mais confiável da real conjuntura da pandemia da COVID-19 no estado da Paraíba, além de favorecer um melhor planejamento para designar recursos, selecionar o tipo de intervenção nos serviços públicos e privados, em ações de intervenções na prevenção, diagnóstico e tratamento, no desenvolvimento e elaboração de políticas públicas, conforme as necessidades de cada região. Vale acentuar que essa abordagem é geral e pode ser estendida a outros problemas das ciências da saúde, bem como em outras áreas além desta, levando em consideração informações georreferenciadas.

7 CONSIDERAÇÕES FINAIS

O presente estudo apresentou um SDSS multicritério, adaptado do trabalho de Lima *et al*. (2019), denominado SDSS baseado em WLC. Ele permitiu subsidiar a tomada de decisão através de diversos métodos que resultaram em um mapa de decisão final. Este instrumento contempla níveis de prioridade para intervenção nos municípios aplicada a COVID-19. Esses níveis podem auxiliar os gestores de saúde a tomarem decisões mais fundamentadas ao cenário real da pandemia, bem como, auxiliar na adoção de estratégias de intervenção ao combate da doença e no desenvolvimento de políticas públicas.

Esse SDSS baseado em WLC apresentou uma abordagem inovadora, com um olhar interdisciplinar, relacionando estatísticas e análise espacial, tomada de decisão em múltiplos critérios e epidemiologia. Esse método pode ser adotado para outras doenças, empregando módulos específicos segundo a problemática em foco, possibilitando um suporte adaptativo ao processo de decisão. Ressalta-se que foi utilizado em seu desenvolvimento *software* gratuitos, o que oferece baixo custo, facilitando sua implementação em diversas áreas. Além disso, os seus resultados possuem fácil compreensão, em particular para os gestores que não possuem contato com esse método no dia a dia.

Nesse sentido, ao utilizarmos esse cabedal de conhecimentos para o estudo e análise da COVID-19, compreendendo a velocidade e potencial de sua disseminação e os vários desafios semanais e até mesmo diários à saúde pública, é possível observar tanto o aumento da incidência dos casos em determinadas áreas, como a possibilidade concreta de uma intervenção baseada nos recursos disponíveis e divulgados pelas secretarias municipais e estadual de saúde. Assim, devemos ressaltar a importância da tomada de

decisão baseada em evidências científicas, o que implica diretamente na melhoria e otimização dos serviços, evitando sobrecargas e aumento das demandas da atenção secundária e terciária de saúde.

Diante disso, abre-se espaço para possíveis trabalhos futuros, sugerindo: a aplicação desse modelo para a tomada de decisão para a variável óbitos de COVID-19, bem como, a sua utilização e adequação para outros tipos de agravos, como doenças sazonais, transmissíveis e não transmissíveis.

PRODUÇÃO ACADÊMICA

PONTES, C.F, FREIRE J.F.R. C, NASCIMENTO, K.R.B, VIANNA, R.P.T, MORAES, R.M. ASPECTOS CLÍNICOS E EPIDEMIOLÓGICOS DA COVID19: UMA REVISÃO DE LITERATURA. **II Congresso Brasileiro Interdisciplinar de Ciência e Tecnologia**, 2021.

PONTES, C.F *et al.* Análise Espaço e Espaço-Temporal da Covid-19 no Estado da Paraíba. **Espaço e Geografia**. Artigo submetido em: 07 de fevereiro de 2022.

ROCHA, J. M. F. R. C.; PONTES, C. F.; FEITOSA, C. R. S.; MORAES, R. M. (2021) Perfil dos óbitos pela COVID-19 no Estado da Paraíba**.** ***Principia***. ISSN: 1414-462X.

8 REFERÊNCIAS

ADUNLIN, G.; DIABY, V; XIAO, H. Application of multicriteria decision analysis in health care: a systematic review and bibliometric analysis. **Health Expectations**, v. 18, n. 6, p. 1894-1905, 2015.

ALBUQUERQUE, LP; SILVA, RB; ARAÚJO, RMS. COVID-19: origin, pathogenesis, transmission, clinical aspects and current therapeutic strategies. **Rev Pre Infec e Saúde**, v. 6, 2020. Disponível em: http://www.ojs.ufpi.br/index.php/nupcis/article/view/10432. DOI: https://doi.org/10.26694/repis.v6i0.10432

AZIZ, M.; FATIMA, R.; ASSALY, R. Elevated Interleukin-6 and Severe COVID-19: A Meta-Analysis. **Journal of Medical Virology John Wiley and Sons Inc**., , 2020. Disponível em: <https://pubmed.ncbi.nlm.nih.gov/32343429/>.

BARBERIA, G. *et al* . The effect of state-level social distancing policy stringency on mobility in the states of Brazil. **Rev. Adm. Pública**, Rio de Janeiro , v. 55, n. 1, p. 27-49, Feb. 2021 . Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0034-76122021000100027&lng=en&nrm=iso>. Acesso em 20 de abril de 2021. http://dx.doi.org/10.1590/0034-761220200549.

BERNAL, JL. *et al.* Early effectiveness of COVID-19 vaccination with BNT162b2mRNA vaccine and ChAdOx1 adenovirus vector vaccine onsymptomatic disease, hospitalisations and mortality in olderadults in England. **MedRxiv**, 2021. Acesso em 03 de abril de 2021.

BESAG, J.; NEWELL, J. The detection of clusters in rare diseases. **Journal of the Royal Statistical Society**, v. 154, p. 143-55, 1991.

BONIOL M *et al*. **Gender equity in the health workforce: analysis of 104 countries: Working Paper 1.** World Health Organization, Geneva 2019.

BRASIL. Ministério da Saúde. Secretaria de Vigilância em Saúde. **Guia de vigilância epidemiológica Emergência de saúde pública de Importância nacional pela Doença**

pelo coronavírus 2019 – covid-19. Ministério da Saúde, Secretaria de Vigilância em Saúde. – Brasília: Ministério da Saúde, 2021. Disponível em: https://www.conasems.org.br/wp-content/uploads/2021/03/Guia-de-vigila%CC%82ncia-epidemiolo%CC%81gica-da-covid_19_15.03_2021.pdf. Acesso em 10 maio 2021.

_____. Ministério da Saúde**. Diretrizes para diagnóstico e tratamento da COVID-19.** Brasília, DF, 2020. Disponível em: https://portalarquivos.saude.gov.br/images/pdf/2020/May/08/Diretriz-Covid19-v4-07-05.20h05m.pdf. Acesso em: 20 jul. 2021.

CARVALHO, M. S.; SOUZA, S. R. Análise de dados espaciais em saúde pública: métodos, problemas, perspectivas. **Cad. saúde pública**, Rio de Janeiro, v. 21, n. 2, p. 361–378, 2005. https://doi.org/10.1590/S0102-311X2005000200003.

CHEN, N et al. Epidemiological and clinical characteristics of 99 cases of 2019 novel coronavirus pneumonia in Wuhan, China: a descriptive study. **Lancet**, v. 395, p. 507–13, Feb. 2020. https://doi.org/10.1016/S0140-6736(20)30211-7.

CHEN, T. et al. Clinical characteristics of 113 deceased patients with coronavirus disease coronavirus pneumonia in Wuhan, China: a descriptive study. **The Lancet**, v. 395, n. Disponível em: **https://doi.org/10.1111/jgs.16464**

CONSELHO NACIONAL DE SAÚDE. **Resolução nº 510/2016 – Dispõe sobre a pesquisa em Ciências Humanas e Sociais**. Brasil: Ministério da Saúde, Brasília, DF, 2016. Disponível em: http://conselho.saude.gov.br/resolucoes/2016/Reso510.pdf. Acesso em: 12 jun. 2021.

DOS SANTOS JÚNIOR, P. J *et al*. ANÁLISE SÓCIO-HISTÓRICA DA PANDEMIA DA COVID-19. **Revista Transformar**, v. 14, n. 2, p. 30-39, 2020.

DROBNE S, LISEC A. Multi-attribute decision analysis in GIS: weighted linear combination and ordered weighted averaging. **Informatica,** v.33, p. 74-459, 2009.

DUCZMAL, L.; ASSUNÇÃO, R. A simulated annealing strategy for the detection of arbitrarily shaped spatial clusters. **Computational Statistics & Data Analysis**, v. 45, n. 2, p. 269-286, 2004.

FENG *et al*. The epidemiological characteristics of an outbreak of 2019 novel coronavirus disease (COVD-19). The Novel Coronavirus Pneumonia Emergency Response Epidemiology Team, ***China CDC Weekly,*** v.2, p. 113-122, 2020. https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8392929/

LUCENA, S. E. DE F.; MORAES, R. M. Detection of space-time cluster of homicides by stabbing in the João Pessoa city, Paraíba state, Brazil**. Boletim de Ciências Geodésicas,** v. 18, n. 4, p. 605–623, 2012.

FILHO *et al*. COVID-19 – IMPACTO EPIDEMIOLÓGICO DA VACINAÇÃO. Subsecretaria de Saúde Gerência de Informações Estratégicas em Saúde **CONECTA-SUS**, 2021. Disponível em: https://www.saude.go.gov.br/files//conecta-sus/produtos-tecnicos/I%20-%202021/COVID-19%20-%20Impacto%20Epidemiol%C3%B3gico%20da%20Vacina%C3%A7%C3%A3o.pdf

FLOSS, M *et al*. A pandemia de COVID-19 em territórios rurais e remotos: perspectiva de médicas e médicos de família e comunidade sobre a atenção primária à saúde. **Cadernos de Saúde Pública** [online]. 2020, v. 36, n. 7 [Acessado 20 Janeiro 2022], e00108920. Disponível em: <https://doi.org/10.1590/0102-311X00108920>. Epub 24 Jul 2020. ISSN 1678-4464.

FREITAS, L.R.S.; DUARTE, E.C.; GARCIA, L.P. Análise da situação epidemiológica da hanseníase em uma área endêmica no Brasil: distribuição espacial dos períodos 2001-2003 e 2010-2012. **Revista Brasileira de Epidemiologia,** v. 20, p. 702-713, 2017.

GETIS, A.; ORD, J. K. (1992) The Analysis of Spatial Association by Use of Distance Statistics. **Geographical Analysis**, v.v24, p. 189-206.

GOMIDE, F.A.C.; GUDWIN, R.R. Modelagem, Controle, Sistemas e Lógica Fuzzy. **SBA Controle & Automação**, v. 4, n. 3, p. 97-115, 1994.

GOODCHILD, M. Geographical Data Modeling. **Computers & Geosciences**, v.8, n. 4, p. 401-408, 1992. https://doi.org/10.1016/0098-3004(92)90069-4.

GUARNIERI, P. Decision Models in Engineering and Management. **Springer**, 2015.

GUIMARÃES, RM *et al*. Como superar a estagnação da curva de cobertura vacinal da primeira dose contra a covid-19 no Brasil?. **SciELO**, [*s. l.*], 20 dez. 2021. DOI https://doi.org/10.1590/SciELOPreprints.3380. Disponível em: https://preprints.scielo.org/index.php/scielo/preprint/view/3380. Acesso em: 19 jan. 2022.

HOLMES, D. C. S. C.; MORAES, R. M.; VIANNA, R. P. T. A Rule for Combination of Spatial Clustering Methods. In: The Seventh International Conferences on Pervasive Patterns and Applications, 2015, Nice, França. Anais. **Proceedings of the Seventh International Conferences on Pervasive Patterns and Applications**, p. 55-59, 2015.

INTERNATIONAL SOCIETY ON MULTIPLE CRITERIA DECISION MAKING. **Mission of the Society**. Disponível em: <https://www.mcdmsociety.org/content/mission-society>. Acesso em: 8 set 2021.

JAHRSDÖRFER, B *et al*. Independent Side-by-Side Validation and Comparison of 4 Serological Platforms for SARS-CoV-2 Antibody Testing. **The Journal of Infectious Diseases**, Oxford, p. 796-801, 15 jul. 2021. DOI https://doi.org/10.1093/infdis/jiaa656. Disponível em: https://academic.oup.com/jid/article/223/5/796/5926414. Acesso em: 13 maio 2021.

KARIM SA, CHEN HF. Deaths From COVID-19 in Rural, Micropolitan, and Metropolitan Areas: A County-Level Comparison. **J Rural Health,** v. 37, p.124-132, 2021. doi: 10.1111/jrh.12533.

KEENAN, P.B.; JANKOWSKI, P. Spatial decision support systems: three decades on. **Decision Support Systems**, v. 116, p. 64-76, 2019.

KULLDORFF, M.; HUANG, L.; PICKLE, L.; DUCZMAL, L. An elliptic spatial scan statistic. **Statistics in Medicine**, v. 25, n. 22, p. 3929-3943, 2006.

KULLDORFF, M.; NAGARWALLA, N. Spatial disease clusters: detection and inference. **Statistics in Medicine**, v.14, p. 799-810, 1995.

LEE M-C. The analytic hierarchy and the network process in multicriteria decision making: performance evaluation and selecting key performance indicators based on ANP model. In: Convergence and hybrid information technologies. **IntechOpen**; 2010.

LI, R *et al*. Substantial undocumented infection facilitates the rapid dissemination of novel coronavirus (SARS-CoV-2), 2020. ***Science,*** *368*(6490), 489-493.

LIMA, LMM, *et al*. Análise espacial das anomalias congênitas do sistema nervoso. **Cad saúde colet**.2019;27(3):257-63.http://dx.doi.org/10.1590/1414462x201900030313

LIMA, LMM, *et al*. A new combination rule for Spatial Decision Support Systems for epidemiology. **Int J Health Geogr** [Internet]. 2019 [citado 2021 mai 8]; 18:25. Disponível em: https://ijhealthgeographics.biomedcentral.com/articles/10.1186/s12

LIU, R *et al*. Positive rate of RT-PCR detection of SARS-CoV-2 infection in 4880 cases from one hospital in Wuhan, China, from Jan to Feb 2020. **Clin Chim Acta**, China, v. 505, p. 172-5, 2020. https://doi.org/10.1016/j.cca.2020.03.009.

LUCENA, S. E. DE F.; MORAES, R. M. Detection of space-time cluster of homicides by stabbing in the João Pessoa city, Paraíba state, Brazil. **Boletim de Ciências Geodésicas**, v. 18, n. 4, p. 605–623, 2012.

MAGALHÃES, G.B. O uso do geoprocessamento e da estatística nos estudos ecológicos em epidemiologia: o caso da dengue em 2008 na região metropolitana de fortaleza. **Hygeia**, v. 8, n. 15, p. 63-77, 2012.

MALCZEWSKI, J; RINNER, C. Análise de decisão multicritério em ciência da informação geográfica. Avanços na ciência da informação geográfica. **Nova York: Springer**; 2015.

MALCZEWSKI J. Local weighted linear combination. **Trans GIS**, v. 15, n. 4, p. 55-439, 2011. https://doi.org/10.1111/j.1467-9671.2011.01275.x

MAMDANI, E.H.; ASSILIAN, S. An experiment in linguistic synthesis with a fuzzy logic controller. **International Journal of Man-Machine Studies**, v. 7, n. 1, p. 1-3, 1975.

MARRO, A. A; MATHEUS, A.; SOUZA, C. Lógica fuzzy: conceitos e aplicações. Natal: **Universidade Federal do Rio Grande do Norte** (UFRN), 2010.

MASSAD, E. et al. Métodos quantitativos em medicina. **Editora Manole Ltda**, 2004.

MELO, J. C. S.; MELO, A. C. O.; MORAES, R. M. Comparação dos Métodos Scan Circular e Flexível na Detecção de Aglomerados Espaciais de Dengue. In: **Escola de Informática Teórica e Métodos Formais** (ETMF 2016); 22-23 Nov; Natal, Brasil. Anais. Natal, Brasil. 2016. p. 11-19.

MORAES, R. M.; NOGUEIRA, J. A.; SOUSA.A.C. A new architecture for a spatio-temporal decision support system for epidemiological purposes. **Anais do Flins**. João Pessoa, 2014.

MORAES, R.M.; MELO, A.C.O. Sistemas de Suporte à Decisão Espacial e Aplicações. **Comunicações em Informática**, v. 1, n. 1, p. 2-5, 2017. DOI: 10.22478/ufpb.2595-0622.2017v1n1.36862

MORAES, R.M.; BANON, G.J.F.; SANDRI, S.A. Fuzzy expert systems architecture for image classification using mathematical morphology operators. **Information Sciences**, v. 142, n.1, p. 7-21, 2002.

NEIL, D. B.; MOORE, A. W.; SABHNANI, M. Morbidity and mortality weekly report. **Detecting Elongated Disease Clusters**, v. 545, 197 p., 2005

ORTEGA, N.R.S. **Aplicação da teoria de conjuntos fuzzy a problemas da biomedicina.** 2001.152 f. Tese (Doutorado em Ciências) – Instituto de Física. Universidade de São Paulo, São Paulo, 2001.

OUSLANDER, JG. Coronavirus Disease19 in Geriatrics and Long-Term Care: An Update. **J Am Geriatr Soc**, v. 5, p. 918-921, 2020. doi: 10.1111/jgs.16464. Epub 2020 Apr 16. PMID: 32243567.

PARAÍBA (Estado). **Secretaria de Saúde do Estado da Paraíba**. Paraíba, PB, 2020c. Disponível em: https://paraiba.pb.gov.br/diretas/saude. Acesso em: 25 dez 2021.

PASSINO, K. M. Fuzzy control. Menlo Park, Calif: **Addison-Wesley**, 1998.

PASSINO, K. M.; YURKOVICH, S. Fuzzy Control. Boston: Addison-Wesley **Longman Publishing Co**., 1997.

PEDROSA, N. L.; ALBUQUERQUE, N. L. S. Análise Espacial dos Casos de COVID-19 e leitos de terapia intensiva no estado do Ceará, Brasil. **Ciênc. saúde coletiva**, Rio de Janeiro, v. 25, p. 2461-8, 2020. Suppl. 1. https://doi.org/10.1590/1413-81232020256.1.10952020.

PERRY M, *et al.* Inequalities in coverage of COVID-19 vaccination: A population register based cross-sectional study in Wales, UK. **Vaccine**, v39, n.42, p. 6256-6261.

PINTO, M.M.P.S.; SILVA, A.T.M.C.; MORAES, R.M. Detecção de aglomerados espaciais dos casos de crianças/adolescentes em condição crônica em hospitais de referência na Paraíba, Brasil. In**: III Congresso Brasileiro de Ciências da Saúde (CONBRACIS),** 13 a 15 de Junho, Campina Grande: Realize, 2018.

PRIESEMANN, *et al*. Calling for Pan-European Commitment for Rapid and Sustained Reduction in SARS - CoV -2 Infections, **The Lancet,** 397 (2021) 91. https://doi: 10.1016/S0140-6736(20)32625-8

VASCONCELLOS, F. H. M., *et al*. Aspectos Espacial E Temporal E Fatores Associados À Interiorização Da Covid-19 Em Pernambuco Interiorizaçao Da Covid Em Pernambuco. **Cien Saude Colet** (2021/Mar). [Citado em 20/01/2022]. Disponível em: http://www.cienciaesaudecoletiva.com.br/artigos/aspectos-espacial-e-temporal-e-fatores-associados-a-interiorizacao-da-covid19-em-pernambuco-interiorizacao-da-covid-em-pernambuco/17997?id=17997

VASCONCELOS, G. L *et al*. Standard and anomalous waves of COVID-19: A multiple-wave growth model for epidemics. **MedRxiv**, [*s. l.*], 2021. DOI 10.1101/2021.01.31.21250867. Disponível em: https://www.medrxiv.org/content/10.1101/2021.01.31.21250867v4. Acesso em: 16 nov. 2021.

RICH, E.; KNIGHT, K. Inteligência Artificial. Rio de Janeiro: **McGraw Hill**, 1993.

ROCHA, R *et al*. Effect of socioeconomic inequalities and vulnerabilities on health-system preparedness and response to COVID-19 in Brazil: a comprehensive analysis. **Lancet Glob Health**, Boston, v. 1, p. 20-36, 12 abr. 2021. DOI doi.org/10.1016/S2214-109X(21)00081-4. Disponível em: www.thelancet.com/lancetgh. Acesso em: 16 jun. 2021.

ROCHA, J. M. F. R. C.; PONTES, C. F.; FEITOSA, C. R. S.; MORAES, R. M. (2021) Perfil dos óbitos pela COVID-19 no Estado da Paraíba**.** ***Principia***. ISSN: 1414-462X.

ROSENBERG, E. S *et al*. Covid-19 Vaccine Effectiveness in New York State. **The new england journal of medicine**, [*s. l.*], ed. 386, p.116-127, 2022. DOI DOI: 10.1056/NEJMoa2116063. Disponível em: https://www.nejm.org/doi/full/10.1056/NEJMoa2116063#author_affiliations. Acesso em: 6 fev. 2022.

SÁ, L.R. **Um sistema de suporte a tomada de decisão espacial: usando o perfil demográfico para o controle da tuberculose no município de João Pessoa-PB.** 2015.

Dissertação (Mestrado)-Pós-graduação em Modelos de Decisão e Saúde, Departamento de Estatística, Universidade Federal da Paraíba, João Pessoa.

SÁ, L. R.; NOGUEIRA, J. A.; MORAES, RONEI M. (2015) Modelo de decisão sobre o perfil demográfico para o controle da tuberculose usando lógica fuzzy. **Revista Eletrônica de Enfermagem**, v. 17, n. 2, p. 223-237. ISSN: 1518-1944. Disponível/Available Online in English. Disponível/Available Online em Português. DOI: 10.5216/ree.v17i2.27643.

SANTOS A., VIEIRA ILS, MACANEIRO AP, SOUZA SS. Perfil demográfico-epidemiológico da tuberculose pulmonar bacilífera no município de São José, Santa Catarina, Brasil. **Rev APS,** v.15, n.1, p. 49-54, 2012.

SANTOS, A.L.; RIGOTTO, R.M. Território e territorialização: incorporando as relações produção, trabalho, ambiente e saúde na atenção básica à saúde. **Trabalho, educação e saúde**, v. 8, n. 3, p. 387-406, 2011. http://dx.doi.org/10.1590/S1981-77462010000300003.

SANTOS, A. D. *et al*. Avaliação baseada em Lógica Fuzzy para um Framework voltado a construção de simuladores baseados em RV. In: XII **Symposium on Virtual and Augmented Reality**, 2011.

SEN P, YANG J-B. Multiple criteria decision support in engineering design. London: **Springer Science & Business Media**; 1998.

SIEGEL, S; Estatística não-Paramétrica para as ciências do comportamento. 2 ed. **São Paulo: Bookman**, 2006. 448 p.

SILVA, L. H. **SISTEMA DE SUPORTE À DECISÃO ESPACIAL FUZZY PARA O COMBATE À COVID-19 NO ESTADO DA PARAÍBA, BRASIL**. 2021. Dissertação (Mestrado) - UFPB, João Pessoa, 2021.

SOUZA ALP. Geoprocessamento e Vigilância Epidemiológica no enfrentamento da Covid-19 na Macrorregião Triangulo Sul, MG. **Ra. e Rum.** V. 8, n. 1, p.4º de dezembro

de 2020 [acesso 13º de maio de 2021];8(1):189-201. Disponível em: http://www.seer.unirio.br/raizeserumos/article/view/10389

SOUZA, ASR *et al* . Aspectos gerais da pandemia de COVID-19. **Rev. Bras. Saude Mater. Infant.**, Recife , v. 21, supl. 1, p. 29-45, fev. 2021 . Disponível em <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1519-38292021000100029&lng=pt&nrm=iso>. acessos em 17 abr. 2021. Epub 24-Fev-2021. https://doi.org/10.1590/1806-9304202100s100003.

SNOW, J. On the mode of communication of cólera (revisited classics). **Hygeia: Revista Brasileira de Geografia Médica e da Saúde**, v. 4, n. 6, p. 1-11, 2008.

SHELEME T; BEKELE F; AYELA T. Clinical Presentation of Patients Infected with Coronavirus Disease 19: A Systematic Review. *Infectious Diseases: **Research and Treatment*.** January 2020. doi:10.1177/1178633720952076

SUGUMARAN, R.; DEGROOTE, J. Spatial Decision Support Systems: Principles and practices. **CRC Press**, 2011.

TANGO, T. Statistical Methods for Disease Clustering. **Springer**, 2010.

TRAN, B. X *et al*. Impact of COVID-19 on Economic Well-Being and Quality of Life of the Vietnamese During the National Social Distancing. **Frontiers in Psychology** , [*s. l.*], v. 11, 2020. DOI 10.3389/fpsyg.2020.565153. Disponível em: https://www.frontiersin.org/article/10.3389/fpsyg.2020.565153. Acesso em: 18 mar. 2021.

TSANG, H. F, *et al*. An update on COVID-19 pandemic: the epidemiology, pathogenesis, prevention and treatment strategies. **Expert Review of Anti-infective Therapy**, v. 19, n. 7, p. 877-888, 2021.

THOKALA, P.; DEVLIN, N.; MARSH, K.; BALTUSSEN, R.; BOYSEN, M.; KALO, Z. Multiple criteria decision analysis for health care decision making—an introduction:

report 1 of the ISPOR MCDA Emerging Good Practices Task Force. **Value in health**, v. 19, n. 1, p. 1- 13, 2016.

THOMAS, A.; CARLIN, B. Late detection of breast and colorectal cancer in Minnesota conties: an application of spatial smoothing and clustering. **Statistics in Medicine**, v. 22, p. 113–127, 2003

World Health Organization (WHO). **WHO Coronavirus Disease (COVID-19) Dashboard.Published 2020**. Acesso em 17 abril 2021. https://covid19.who.int/

WYLLIE A. L *et al.* Saliva or nasopharyngeal swab specimens for detection of SARS-CoV-2. **The New England journal of medicine**, *383*(13), 1283–1286. https://doi.org/10.1056/NEJMc2016359

YEGOROV, S *et al*. Epidemiology, clinical characteristics, and virologic features of COVID-19 patients in Kazakhstan: A nation-wide retrospective cohort study. **The Lancet Regional Health** , [*S. l.*], p. 30-47, 22 mar. 2021. DOI https://doi.org/10.1016/j.lanepe.2021.100096. Disponível em: https://www.sciencedirect.com/science/article/pii/S2666776221000739?via%3Dihub. Acesso em: 17 jun. 2021.

YU, SU-MIN.; WANG J.; WANG, JIAN-QIANG.; LI, L. A multi-criteria decision-making model for hotel selection with linguistic distribution assessments. **Applied Soft Computing**, v. 67, p. 741-755, 2018.

ZADEH, L.A. Fuzzy sets. **Information and Control**, v. 8, n. 3, p. 338-353, 1965.

ZHAO, WYU, *et al.* Clinical characteristics and durations of hospitalized patients with COVID-19 in Beijing: a retrospective cohort study. **MedRxiv**. 2020.

APÊNDICE A – Resultado dos mapas da RIE, do *Scan* espacial, do *Scan* espaço-temporal e da decisão do SDSS referente a cada critério.

Figura 1 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério sexo feminino: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

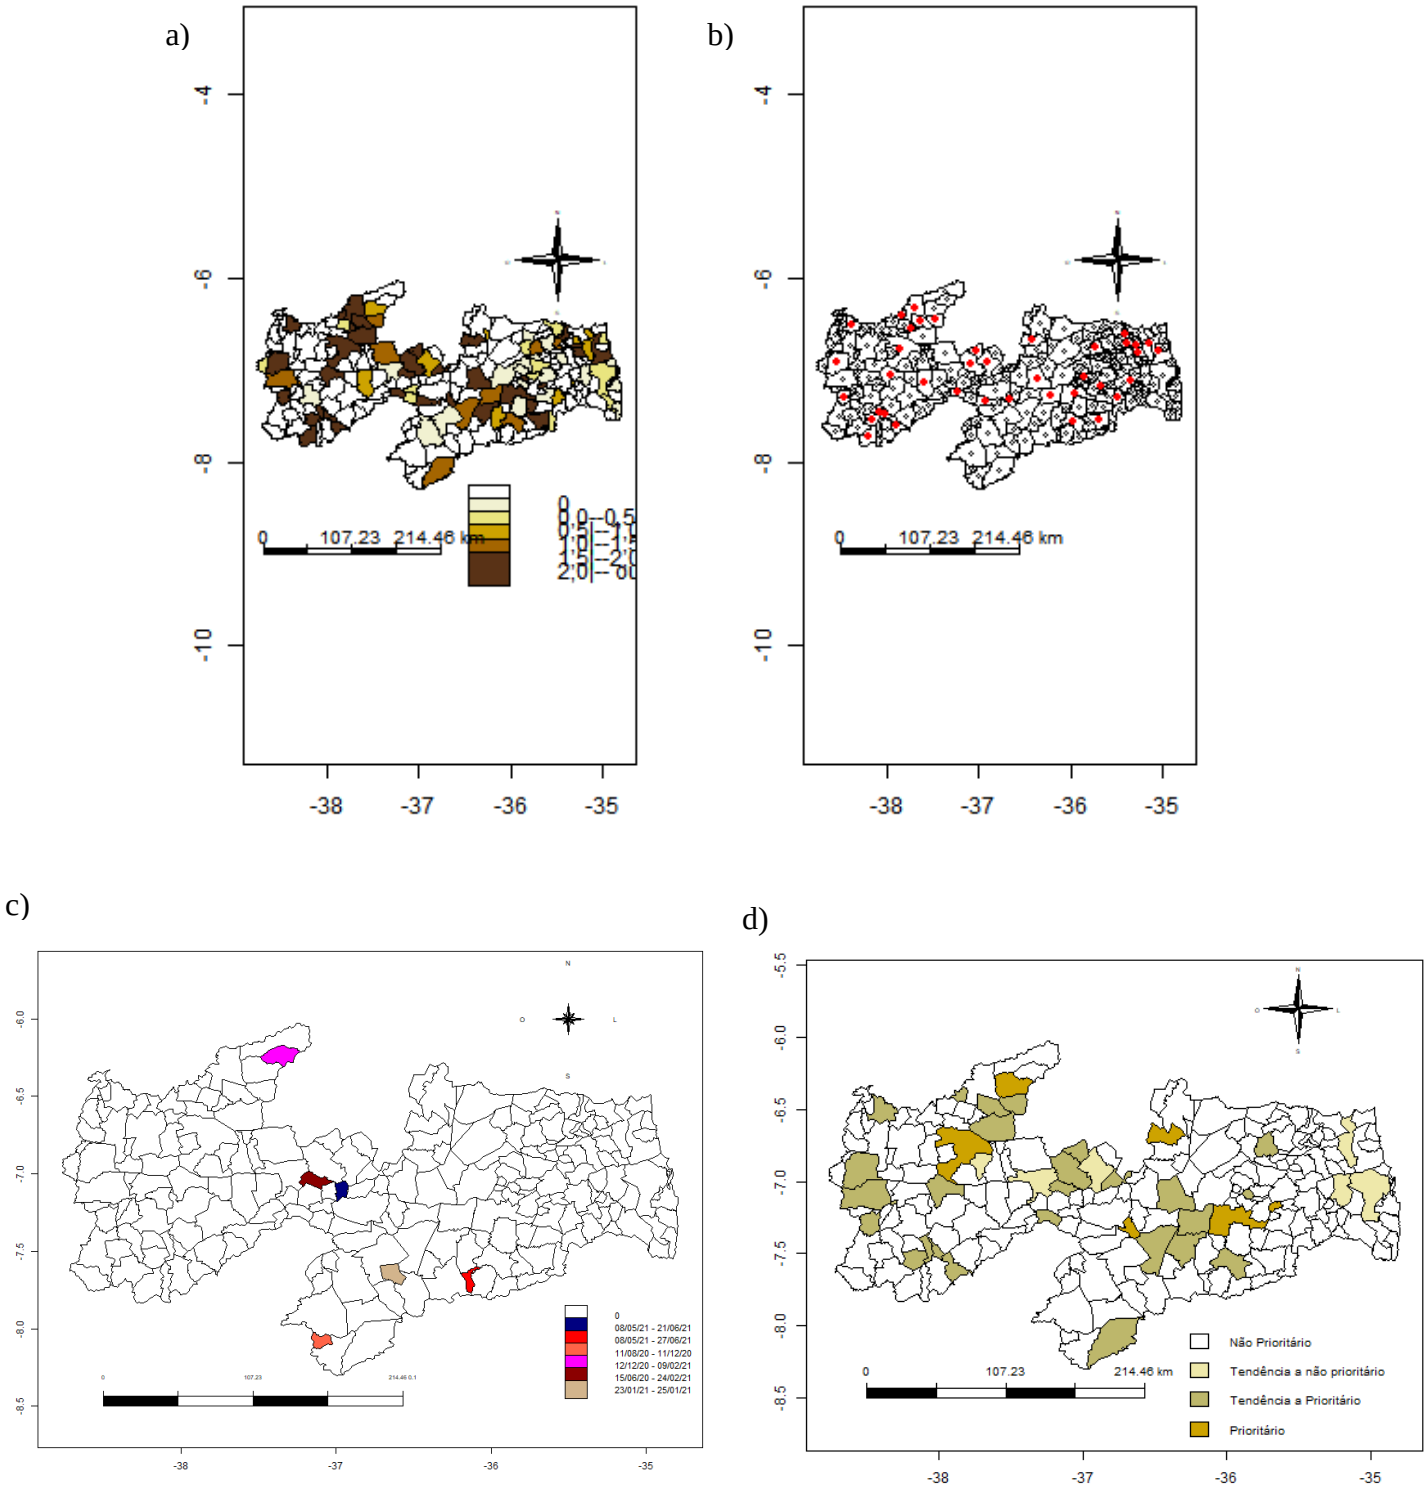

Fonte: Elaboração pela própria autora (2022).

Figura 2 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério sexo masculino: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

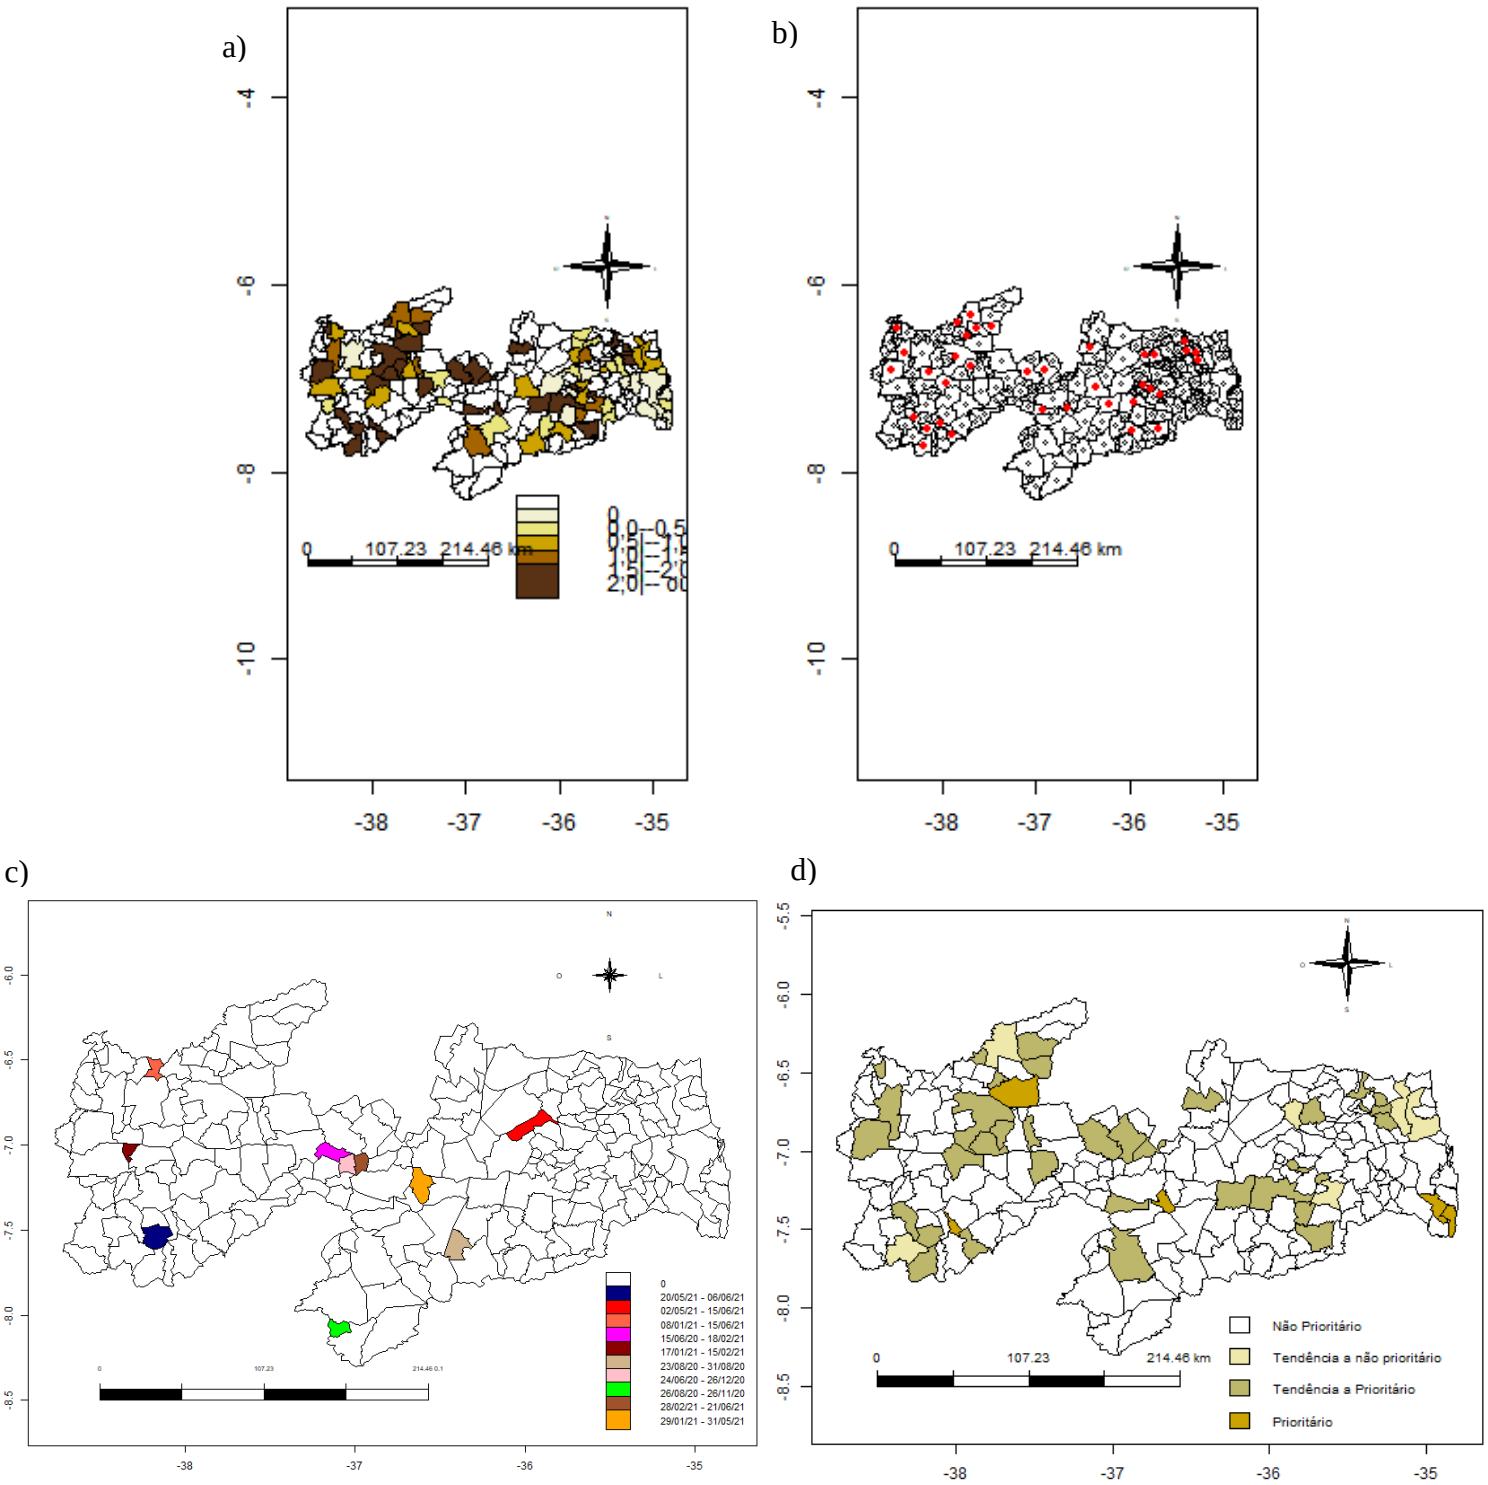

Fonte: Elaboração pela própria autora (2022).

Figura 3 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério faixa etária menor de 20 anos: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

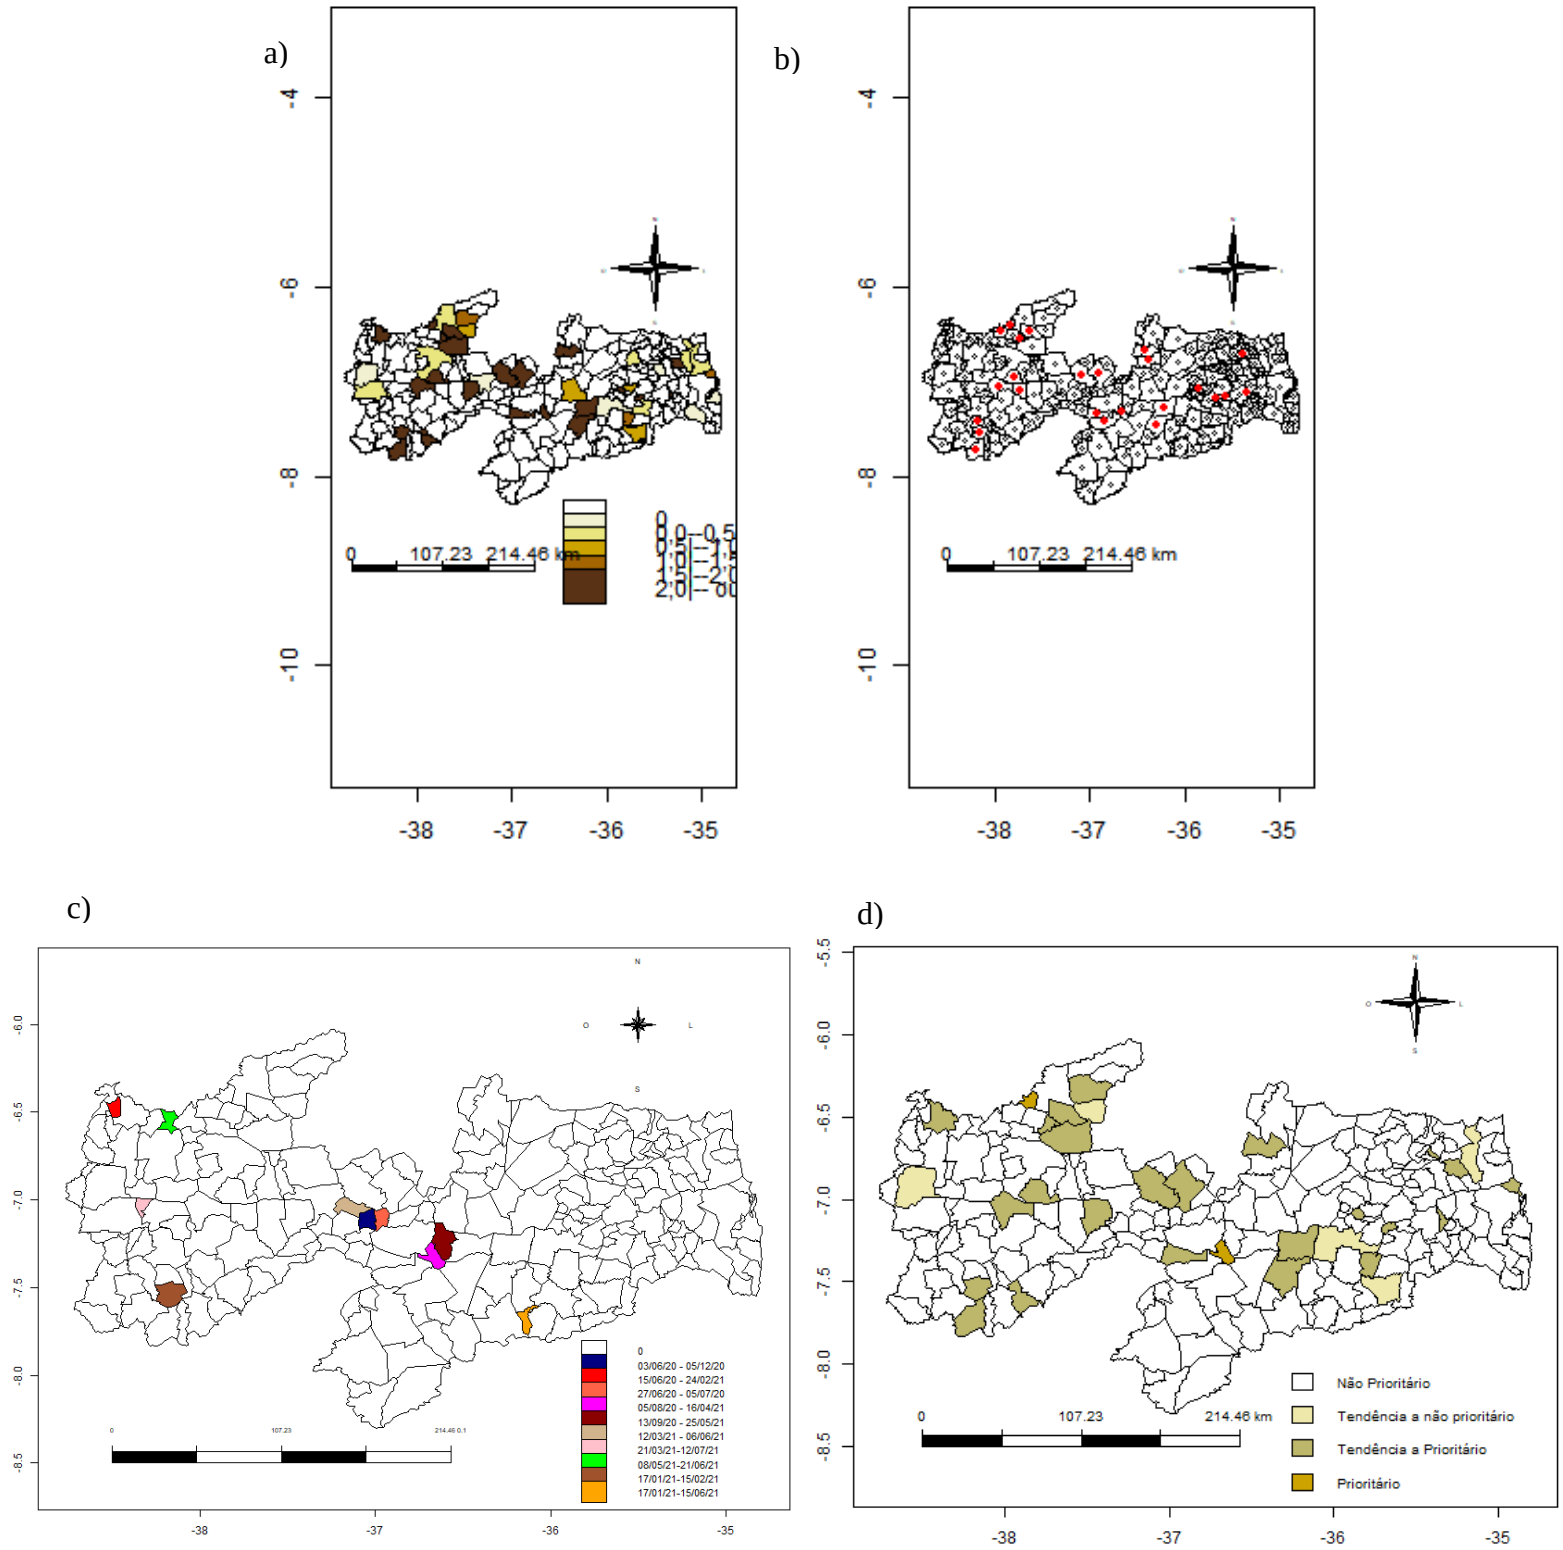

Fonte: Elaboração pela própria autora (2022).

Figura 4 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério faixa etária de 20 a 60 anos: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

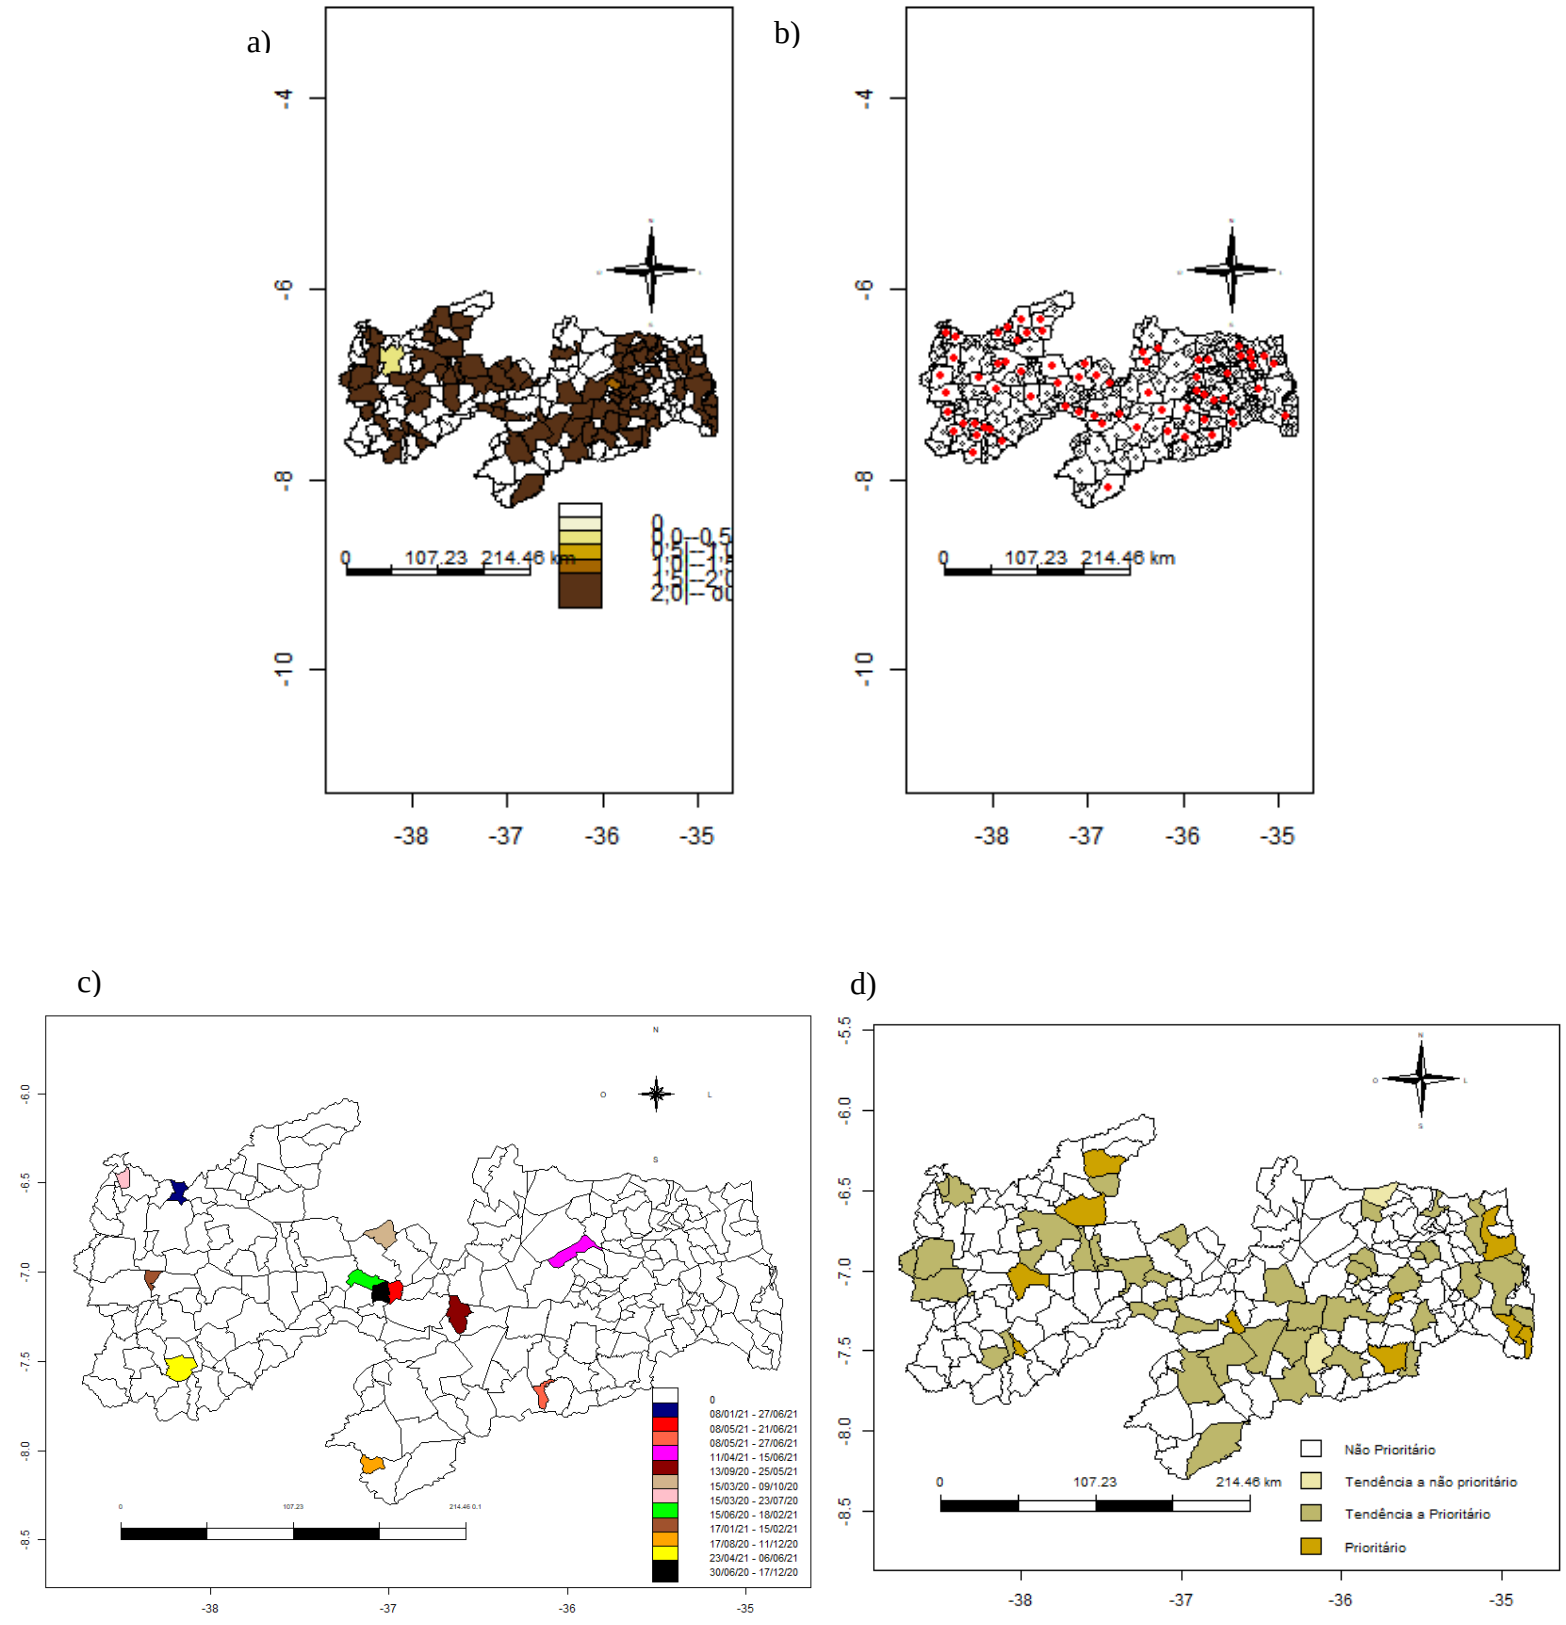

Fonte: Elaboração pela própria autora (2022).

Figura 5 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério faixa etária maior de 60 anos: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

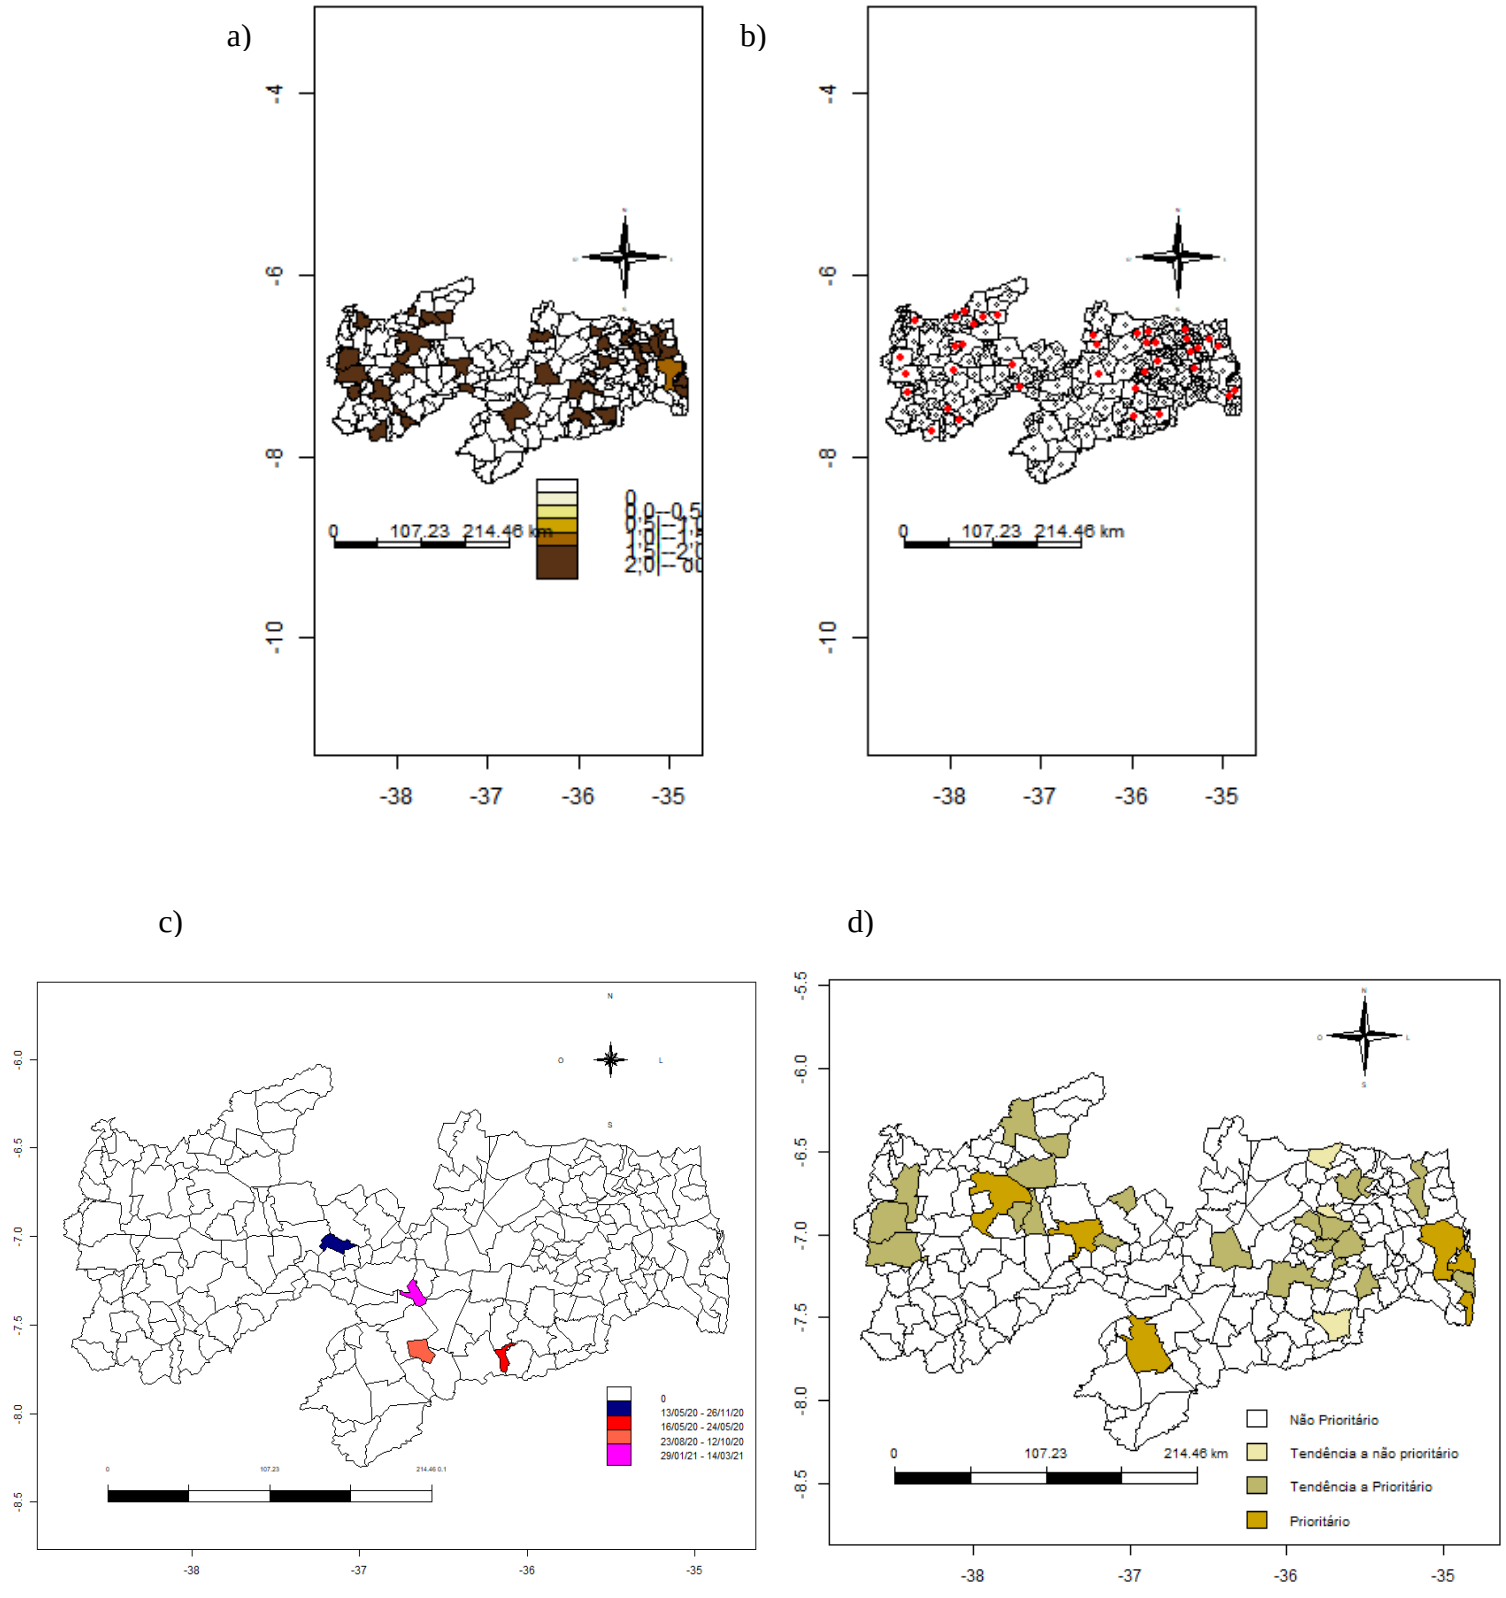

Fonte: Elaboração pela própria autora (2022).

Figura 6 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério doença cardíaca: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

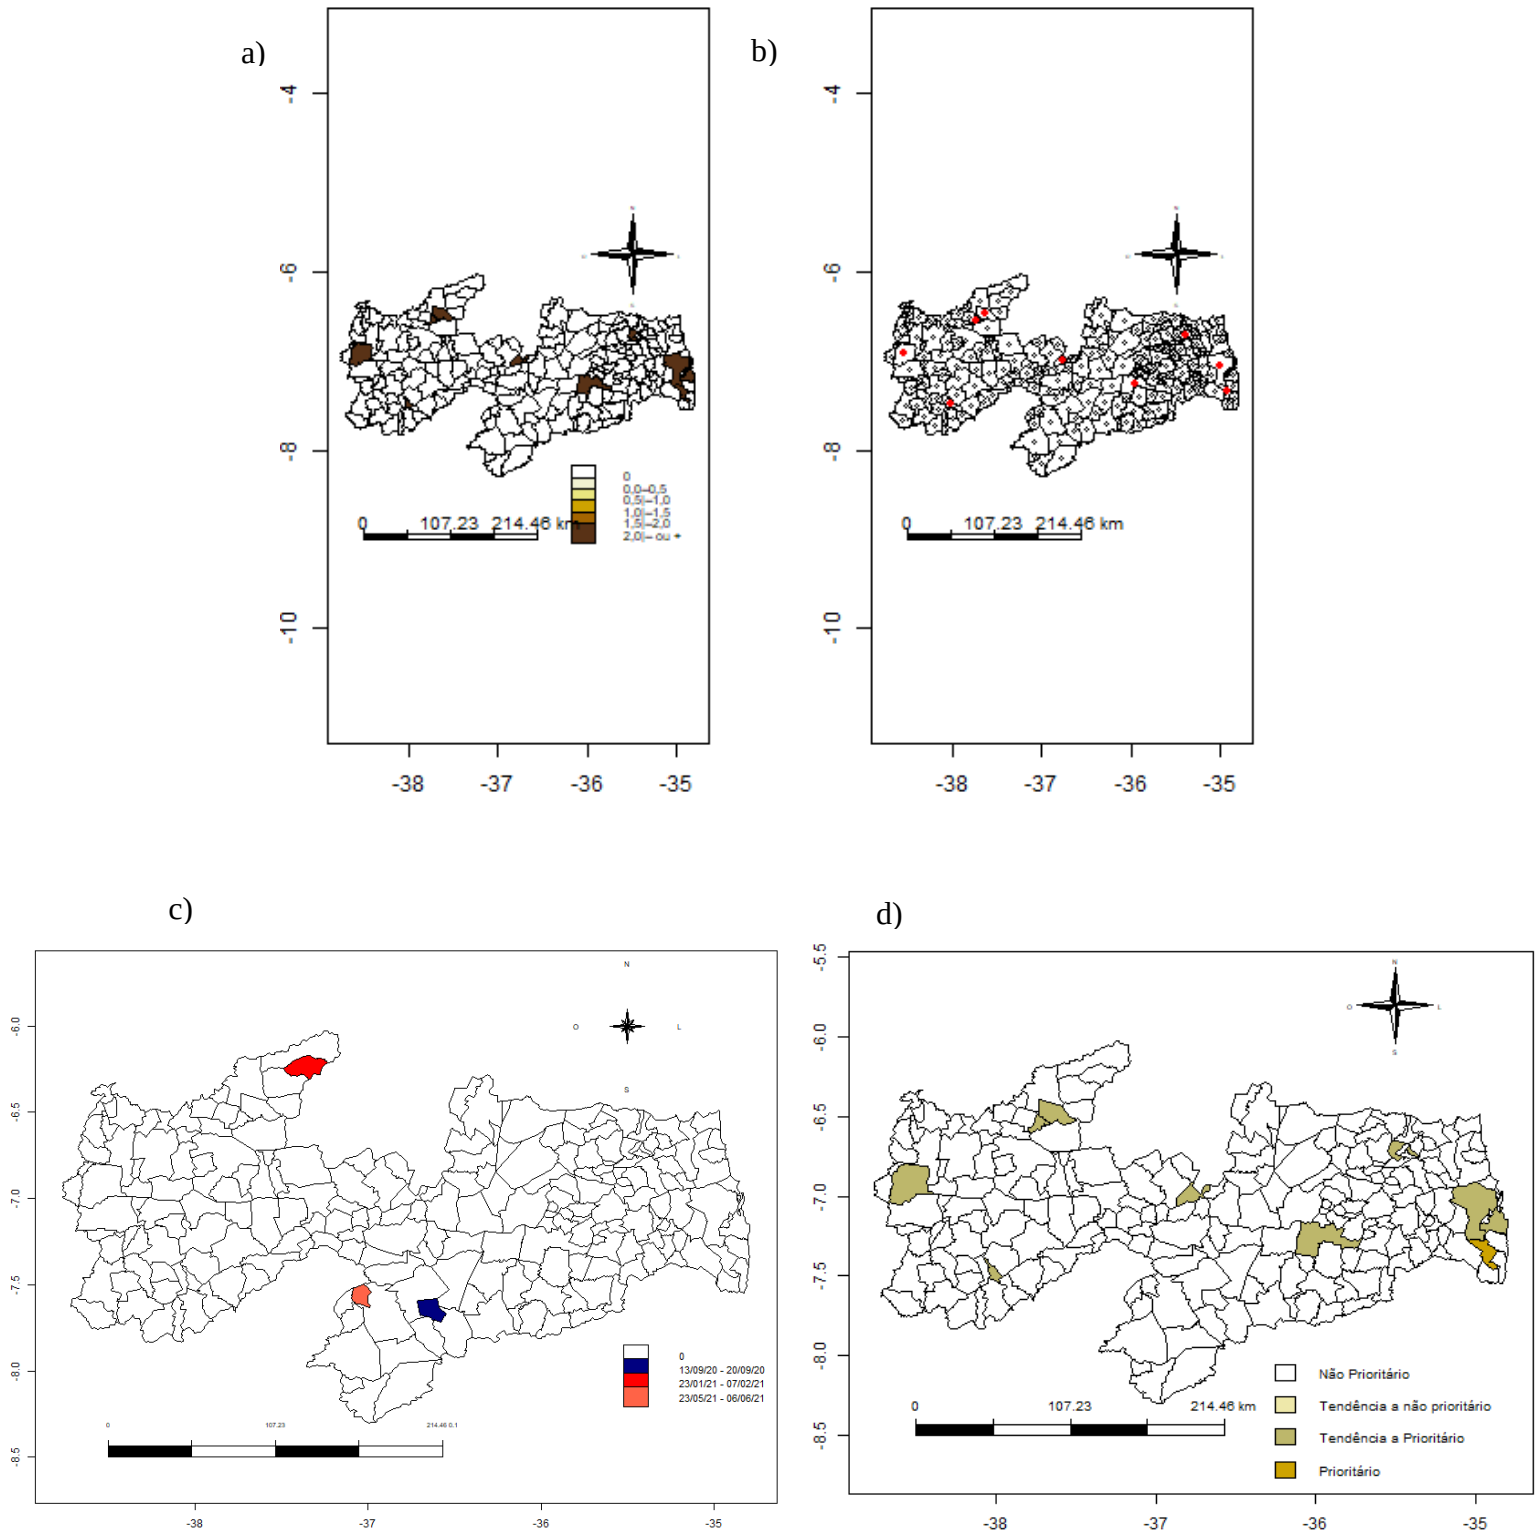

Fonte: Elaboração pela própria autora (2022).

Figura 7 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério doença respiratória: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

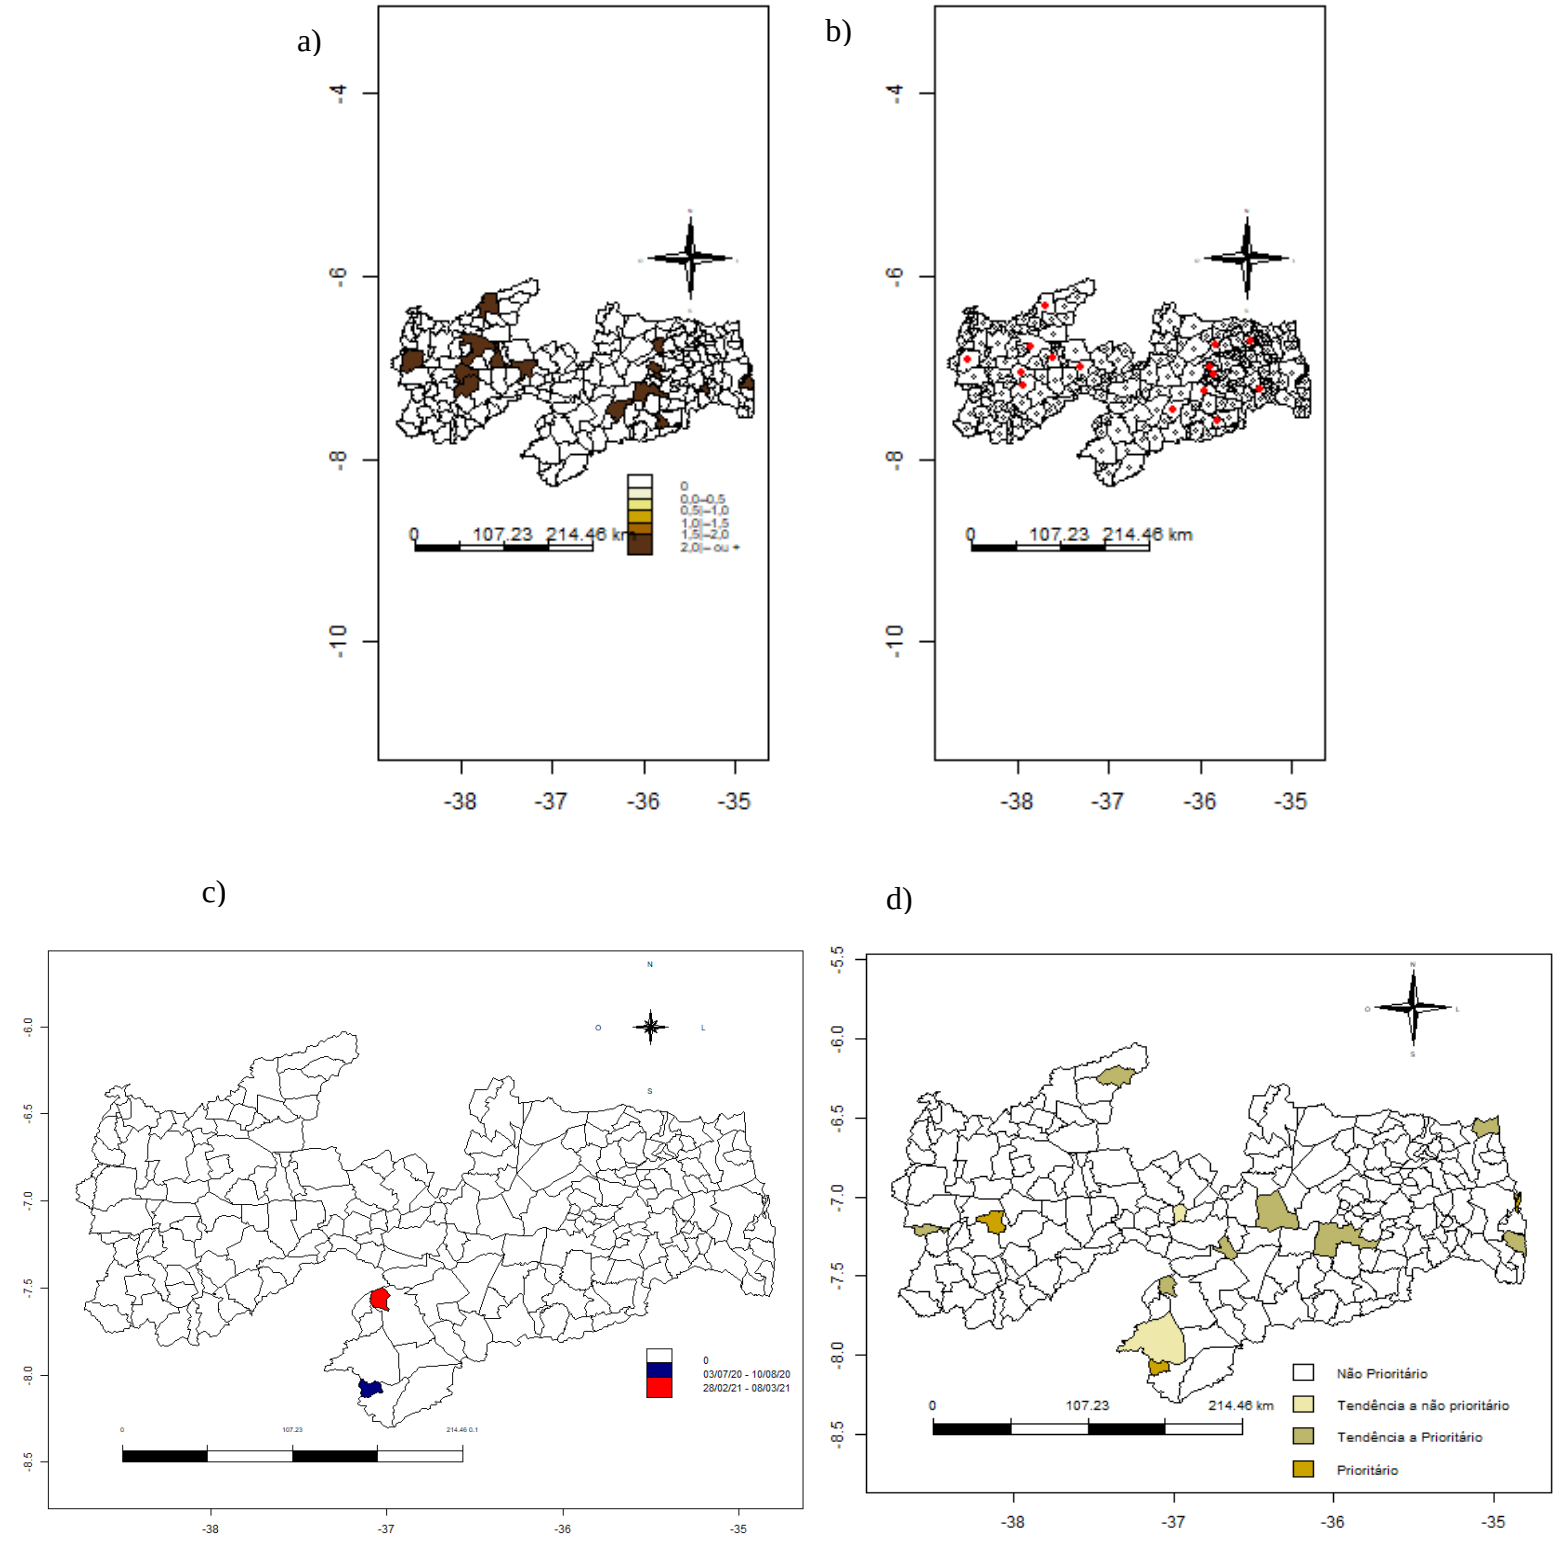

Fonte: Elaboração pela própria autora (2022).

Figura 8 - Mapas da COVID-19, semana epidemiológica 32°, Paraíba referente ao Critério diabetes: (a) RIE, (b) *Scan* espacial, (c) *Scan* espaço-temporal e (d) Decisão do SDSS referente a esse critério.

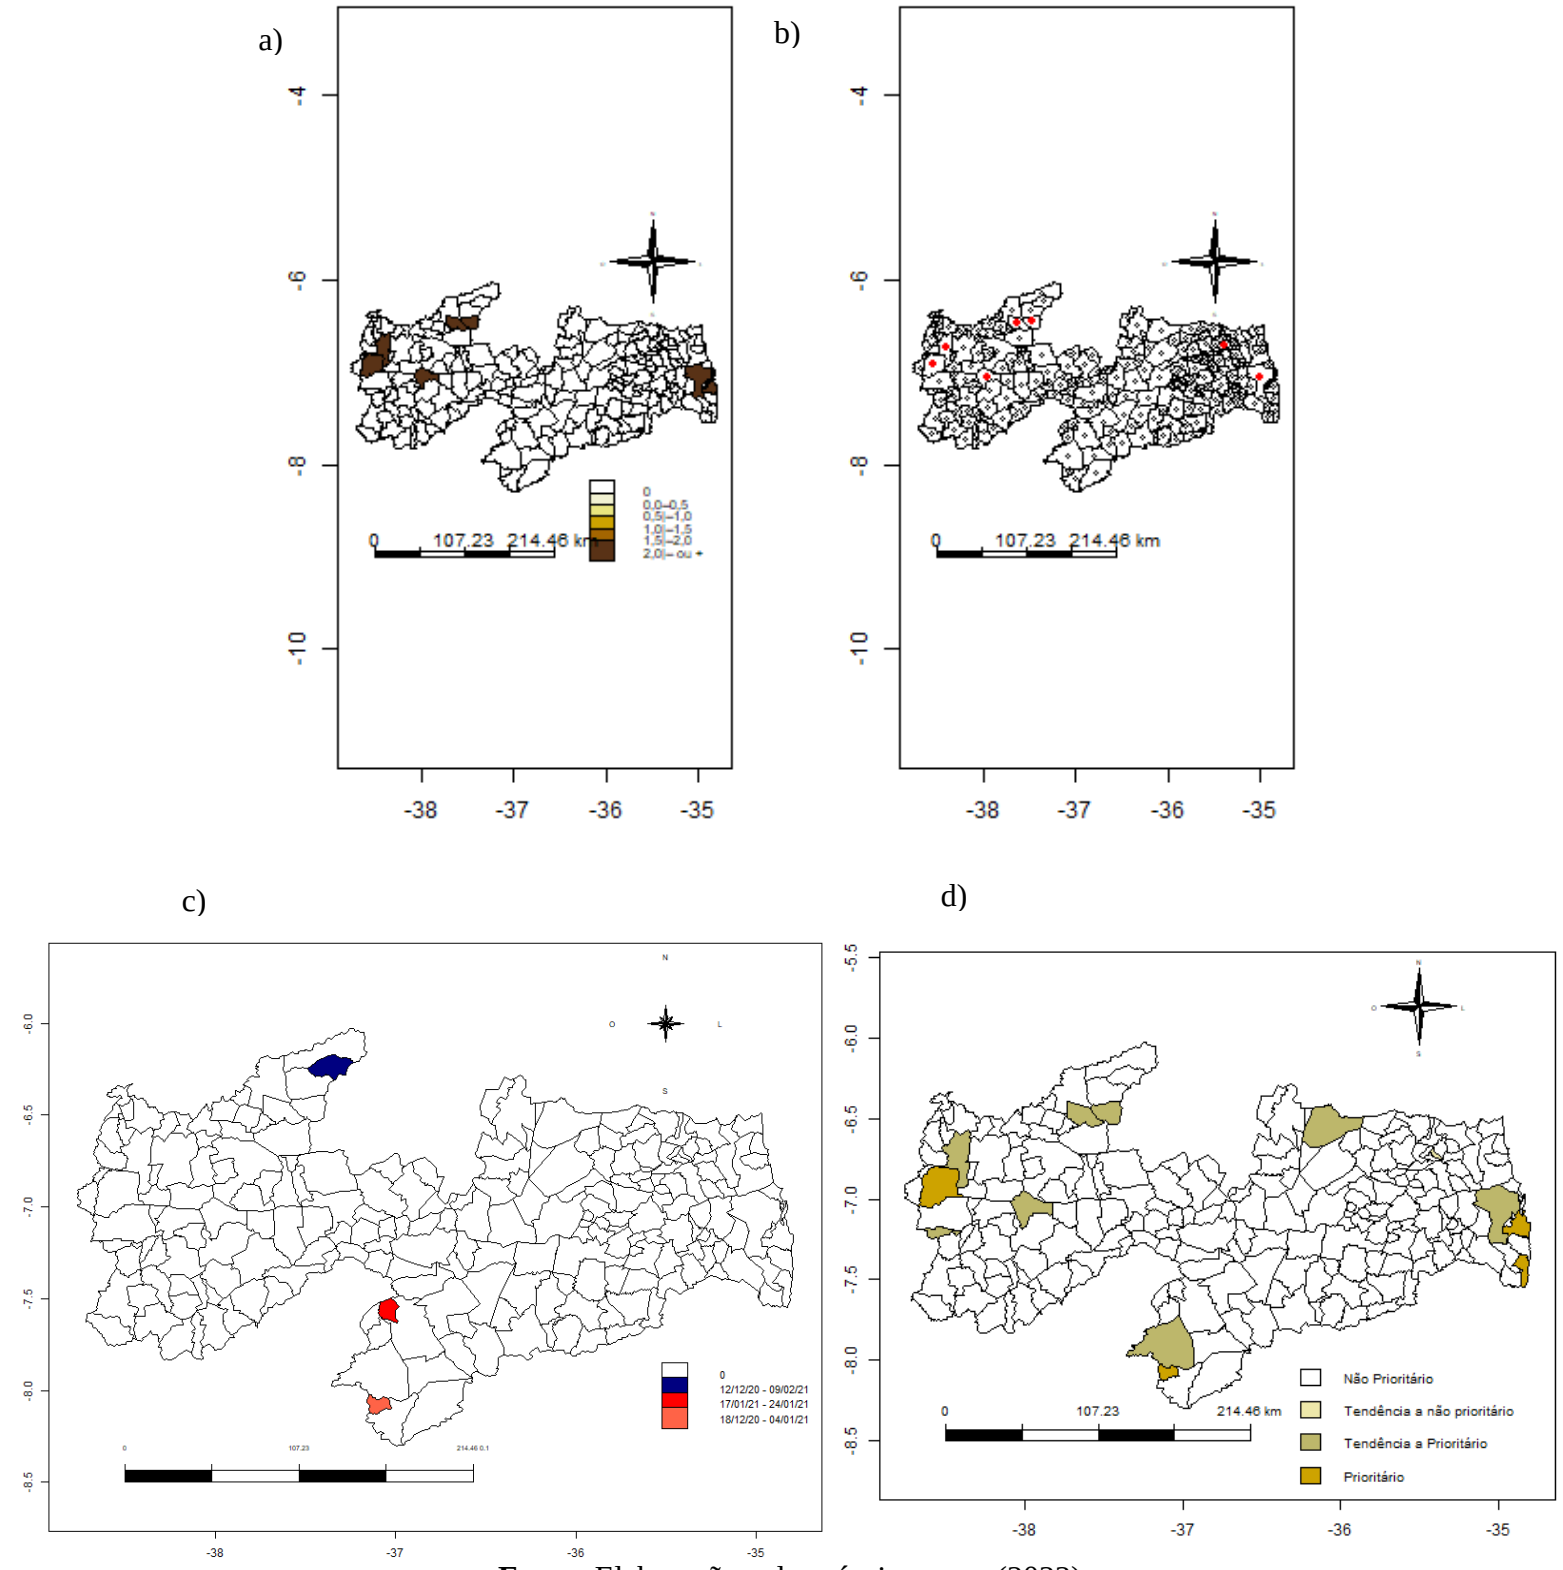

Fonte: Elaboração pela própria autora (2022).