

**UNIVERSIDADE DE SÃO PAULO**  
**FACULDADE DE FILOSOFIA LETRAS E CIÊNCIAS HUMANAS**  
**DEPARTAMENTO DE GEOGRAFIA**

**ARIELLY TOMAZIA COSTA**

**Análise do padrão de distribuição espacial das Pessoas com Deficiência (PCDs) no  
município de São Paulo/SP em 2010**

**Analysis of the spatial distribution pattern of People with Disabilities  
in São Paulo/SP in 2010**

São Paulo  
2024

ARIELLY TOMAZIA COSTA

**Análise do padrão de distribuição espacial das Pessoas com Deficiência (PCDs) no  
município de São Paulo/SP em 2010**

Trabalho de Graduação Individual II (TGI) apresentado  
ao Departamento de Geografia da Faculdade de  
Filosofia, Letras e Ciências Humanas, da Universidade  
de São Paulo, como parte dos requisitos para obtenção  
do título de Bacharel em Geografia.

Área de Concentração: Cartografia e Geografia da  
Saúde

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Ligia Vizeu Barrozo

São Paulo

2024

COSTA, Arielly Tomazia. **Análise do padrão de distribuição espacial das Pessoas com Deficiência (PCDs) no município de São Paulo/SP em 2010.** Trabalho de Graduação Individual II (TGI) apresentado à Faculdade de Filosofia, Letras e Ciências Humanas da Universidade de São Paulo para obtenção do título de Bacharel em Geografia.

Aprovado em:

Banca Examinadora

Prof<sup>a</sup>. Dr<sup>a</sup>. Ligia Vizeu Barrozo \_\_\_\_\_ Instituição Universidade de São Paulo (USP)  
Julgamento \_\_\_\_\_ Assinatura \_\_\_\_\_

Dr<sup>a</sup>. Waldirene Ribeiro do Carmo \_\_\_\_\_ Instituição Universidade de São Paulo (USP)  
Julgamento \_\_\_\_\_ Assinatura \_\_\_\_\_

Dr<sup>a</sup>. Sara Lopes de Moraes \_\_\_\_\_ Instituição Universidade de São Paulo (USP)  
Julgamento \_\_\_\_\_ Assinatura \_\_\_\_\_

## **AGRADECIMENTOS**

Aos bons amigos que fiz durante a faculdade, com quem compartilhei lutas, choros, lágrimas e risadas. Vocês sempre estiveram ao meu lado, oferecendo suporte e encorajamento incondicional.

À minha família, que me possibilitou suportar todas as adversidades, acreditando sempre no poder transformador da educação. Em especial, ao meu querido pai, cuja fé em mim nunca vacilou desde o momento em que entrei na faculdade até sua partida.

Aos professores, que ao longo dos anos demonstraram seus espíritos de luta e encorajamento em prol da disseminação do pensamento geográfico.

E, por fim, à minha orientadora, por acreditar no tema e me orientar com seus conhecimentos.

## RESUMO

COSTA, Arielly Tomazia. **Análise do padrão de distribuição espacial das Pessoas com Deficiência (PCDs) no município de São Paulo/SP em 2010.** 2024. 59 f. Trabalho de Graduação Individual (TGI) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2024.

Este estudo realizou uma análise do padrão de distribuição espacial e racial dos indicadores referentes aos tipos de deficiências – física, mental, visual e auditiva – entre brancos e não brancos nas áreas de ponderação do município de São Paulo em 2010. Após o mapeamento do perfil racial e econômico das pessoas com deficiência, utilizando os dados do Censo 2010 do IBGE com os pacotes do software R, foi aplicado o método estatístico de Moran Local. Pautado na hipótese de que exista um padrão marcado de distribuição, foi avaliado e identificado quais são os padrões de distribuição, concentração ou dispersão espacial que muitas vezes não são percebidos nas análises estatísticas convencionais. A relevância deste estudo reside em sua capacidade de oferecer uma base quantitativa sólida, fundamentada em dados, estatística descritiva e mapeamento espacial. Foi identificado que os padrões de desigualdade racial entre as regiões de São Paulo persistem mesmo entre pessoas com a mesma deficiência. A análise revelou que a distribuição está mais relacionada à renda do que à deficiência, com a variável cor sendo distribuída de forma que os considerados brancos tendem a se concentrar em áreas de maior renda e não-brancos em áreas de menor renda. Diante disso, este estudo contribui para uma visão detalhada que possa auxiliar a formulação de políticas públicas municipais e promover o direito a todos os espaços da cidade para as pessoas com deficiência.

Palavras-chave: Distribuição espacial. Deficiência. Mapeamento Espacial. Concentração espacial.

## ABSTRACT

COSTA, Arielly Tomazia. **Analysis of the spatial distribution pattern of People with Disabilities in São Paulo/SP in 2010.** 2024. 59 f. Trabalho de Graduação Individual (TGI) – Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2024.

This study conducted an analysis of the spatial and racial distribution patterns of indicators related to types of disabilities – physical, mental, visual, and auditory – among whites and non-whites in the weighting areas of the municipality of São Paulo in 2010. After mapping the racial and economic profile of people with disabilities using data from the 2010 Census of IBGE with R software packages, the Local Moran statistical method was applied. Based on the hypothesis that there is a marked distribution pattern, the study evaluated and identified the patterns of distribution, concentration, or spatial dispersion that are often not perceived in conventional statistical analyses. The relevance of this study lies in its ability to provide a solid quantitative basis, grounded in data, descriptive statistics, and spatial mapping. It was identified that the patterns of racial inequality among the regions of São Paulo persist even among people with the same disability. The analysis revealed that the distribution is more related to income than to disability, with the variable of color being distributed in such a way that whites tend to concentrate in higher-income areas and non-whites in lower-income areas. Therefore, this study contributes to a detailed perspective that can aid in the formulation of municipal public policies and promote the right to all city spaces for people with disabilities.

Keywords: Spatial distribution. Disability. Spatial mapping. Spatial concentration

## **LISTA DE ILUSTRAÇÕES**

Figura 1	Gráfico de deficiências no Brasil até 2010	1
Figura 2	Esquema evolutivo dos conceitos da CIF	7
Figura 3	Mapa das regiões, subprefeituras e distritos municipais	13

de São Paulo em 2024

Figura 4	Teste de acurácia do intervalo de dados para a variável deficiência auditiva	17
Figura 5	Mapa dos respondentes com deficiência visual em SP	19
Figura 6	Percentual de PCDs visual que se consideram brancos em SP	20
Figura 7	Percentual de PCDs visual que se autodeclaram não brancas em SP	21
Figura 8	Mapa dos respondentes com deficiência auditiva em SP	22
Figura 9	Percentual de PCDs auditiva que se consideram brancos em SP	23
Figura 10	Percentual de PCDs auditiva que se autodeclaram não brancas em SP	24
Figura 11	Mapa dos respondentes com deficiência física em SP	25
Figura 12	Percentual de PCDs física que se consideram brancos em SP	26
Figura 13	Percentual de PCDs física que se autodeclaram não brancas em SP	27
Figura 14	Mapa dos respondentes com deficiência mental em SP	28
Figura 15	Percentual de PCDs mental que se consideram brancos em SP	29
Figura 16	Percentual de PCDs mental que se autodeclaram não brancas em SP	30
Figura 17	Índice de Moran Local para pessoas brancas em SP	31
Figura 18	Índice de Moran Local para pessoas não brancas em SP	32
Figura 19	Índice de Moran Local de PCDs visual em SP	33
Figura 20	Índice de Moran Local de PCDs auditiva em SP	34
Figura 21	Índice de Moran Local de pessoas brancas com deficiência auditiva em SP	35
Figura 22	Índice de Moran Local de pessoas não brancas com deficiência auditiva em SP	35
Figura 23	Índice de Moran Local de PCDs física em SP	36
Figura 24	Índice de Moran Local de pessoas brancas com deficiência física em SP	37
Figura 25	Índice de Moran Local de pessoas não brancas com deficiência física em SP	38
Figura 26	Índice de Moran Local de PCDs mental em SP	39
Figura 27	Índice de Moran Local de pessoas brancas com deficiência mental em SP	40

Figura 28	Índice de Moran Local de pessoas não brancas com deficiência mental em SP	40
Figura 29	Índice de Moran Local da renda de pessoas não brancas em SP	41

## **LISTA DE TABELAS**

Tabela 1	Descrição das variáveis utilizadas	15
----------	------------------------------------	----

## **LISTA DE ABREVIATURAS E SIGLAS**

AP Área de Ponderação

CID Classificação Internacional de Doenças

CIF	Classificação Internacional de Funcionalidade, Incapacidade e Saúde
IBGE	Instituto Brasileiro de Geografia e Estatística
ICIDH	<i>International Classification of Impairment, Disabilities and Handicaps</i>
IDHM	Índice de Desenvolvimento Humano Municipal
INPE	Instituto Nacional de Pesquisas Espaciais
LISA	<i>Local Indicator of Spatial Association</i>
OMS	Organização Mundial da Saúde
PCD	Pessoa com Deficiência
PNUD	Programa das Nações Unidas para o Desenvolvimento
SPSS	<i>Statistical Package for the Social Science</i>

## SUMÁRIO

<b>1. INTRODUÇÃO</b>	<b>1</b>
<b>1.1. Hipótese</b>	<b>3</b>

<b>1.2. Objetivo Geral</b>	<b>4</b>
<b>1.3. Objetivos Específicos</b>	<b>4</b>
<b>2. FUNDAMENTAÇÃO TEÓRICA</b>	<b>4</b>
<b>2.1. Histórico e Conceitos de Deficiência</b>	<b>4</b>
<b>2.2. Conceitos de Espaço</b>	<b>9</b>
<b>2.3. Conceitos de Análise Espacial</b>	<b>10</b>
<b>2.3.1. <i>Mapas Coropléticos</i></b>	<b>10</b>
<b>2.3.2. <i>Definição de Classes</i></b>	<b>11</b>
<b>2.3.3. <i>Índice de Moran Local</i></b>	<b>12</b>
<b>3. METODOLOGIA</b>	<b>12</b>
<b>3.1. Área de Estudo</b>	<b>12</b>
<b>3.2. Coleta de Dados</b>	<b>14</b>
<b>3.2.1. <i>Manipulação e Tratamento das Variáveis</i></b>	<b>15</b>
<b>3.3. Técnicas de Visualização e Análise Espacial</b>	<b>16</b>
<b>4. INTERPRETAÇÃO E ANÁLISE DOS RESULTADOS</b>	<b>18</b>
<b>4.1. Mapeamento Geral dos Dados</b>	<b>18</b>
<b>4.1.1. <i>PCDs Visual</i></b>	<b>18</b>
<b>4.1.2. <i>PCDs Auditiva</i></b>	<b>21</b>
<b>4.1.3. <i>PCDs Física</i></b>	<b>24</b>
<b>4.1.4. <i>PCDs Mental</i></b>	<b>27</b>
<b>4.2. Análise de Distribuição Espacial</b>	<b>30</b>
<b>4.2.1. <i>Testando a Hipótese de Dependência Espacial: Local</i></b>	<b>30</b>
<b>4.2.1.1. Pessoas Brancas e Não Brancas</b>	<b>31</b>
<b>4.2.1.2. PCDs Visual</b>	
<b>32</b>	
<b>4.2.1.3. PCDs Auditiva</b>	<b>33</b>
<b>4.2.1.4. PCDs Física</b>	
<b>36</b>	
<b>4.2.1.5. PCDs Mental</b>	
<b>38</b>	
<b>4.2.1.6. Renda de Pessoas Não Brancas</b>	<b>40</b>

<b>5. DISCUSSÃO E SÍNTESE DOS RESULTADOS</b>	<b>41</b>
<b>6. CONSIDERAÇÕES FINAIS</b>	<b>42</b>
<b>REFERÊNCIAS</b>	<b>43</b>
<b>ANEXO A – Scripts utilizados</b>	<b>47</b>

## 1. INTRODUÇÃO

A condição de pessoa com deficiência (PCD) traz consigo uma série de aspectos que impactam o dia a dia do cidadão, incluindo atividades diárias, moradia e sensação de pertencimento urbano. De acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), com base nos dados do último Censo Demográfico de 2010, o Brasil contava com mais de 45 milhões de pessoas com alguma forma de deficiência. Isso é ilustrado pela representação da Comissão Nacional de Classificação do IBGE, que contrasta as classificações das deficiências com a população total do Brasil até o momento da pesquisa.

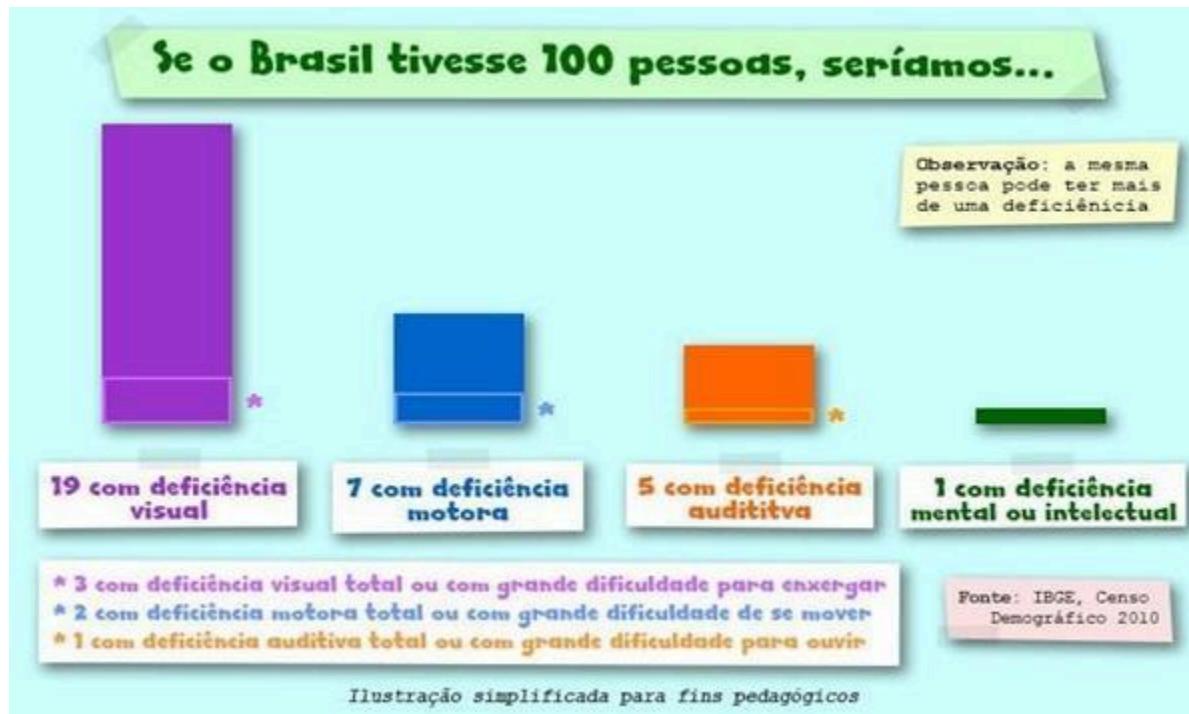


Figura 1: Gráfico de deficiências no Brasil até 2010. Fonte: Comissão Nacional de Classificação, adaptado do Censo Demográfico IBGE (2010).

Por outro lado, é importante destacar que até o ano de 2010, a cidade de São Paulo contava com pouco mais de 11 milhões de habitantes, de acordo com o mesmo Censo. Deste modo, nota-se que é significativo a quantidade de indivíduos que estão morando permanentemente na cidade de São Paulo. Tais pessoas usufruem das habitações, dos serviços de saúde, de educação, segurança, entretenimento e até mesmo movimentando o turismo. É

indiscutível que São Paulo apresenta-se como uma cidade cosmopolita, dentro de um espaço em que habitam indivíduos heterogêneos que experienciam o espaço de formas distintas.

Concomitantemente a isto, deve-se compreender que para fins de análise espacial, é intrínseco que haja uma contextualização do grupo investigado e suas relações com os espaços regionais de moradia da cidade. Assim como explicita em seus escritos, para Hall (1966), parte ou quase tudo que o homem é, pressupõe de sua experiência no espaço, o sentimento do espaço resulta da síntese de numerosos dados sensoriais, de ordem visual, auditiva, cinestésica, olfativa e térmica. Desta forma, pode-se afirmar que as pessoas com deficiência, como todos os grupos sociais, possuem uma estrutura corporal própria situada em um tempo e em um espaço. Como também, tais indivíduos poderão vir a organizar seus espaços de moradia de acordo com suas maneiras de habitar. Segundo Norberg-Schulz (1981), o lugar revela-se como a manifestação completa do ato de habitar do homem, neste local, o indivíduo é capaz de criar sua identidade a partir do sentido de pertencimento que este local atribui. Todavia, o modo como interagem com o plano espacial reflete sua psico-sociabilidade em distintos graus e seus acessos são configurados por um corpo em movimento dentro de um contexto socioeconômico e histórico demarcado que propicia o desenvolvimento de suas identidades dentro da cidade.

Vale considerar que a comunidade de pessoas com deficiência, considerados população residente permanente na cidade de São Paulo, até o presente momento desta pesquisa, não possui uma demarcação bem estruturada do seu padrão de distribuição socioespacial, que podem se obter informações claras, no que diz respeito à cor/raça e rendimento mensal.

Além disto, como caracteriza Lindo (2011), uma cartográfica adequada, pode ser capaz de fornecer ricas informações que auxiliam no enfrentamento às dificuldades, na diminuição dos conflitos políticos/culturais, na promoção da aproximação de pessoas, observabilidade de problemas ambientais, como também promover soluções ao prever um planejamento urbano bem estruturado para as regiões. Partindo deste ponto, tais dados, representações e cartograficamente se desenvolvidos adequadamente, pode proporcionar a esta população a garantia de dimensão quantitativa propiciando visibilidade para atuação de ações em políticas públicas que colaborem na busca por direitos e melhorias assertivas que auxiliem no cotidiano da pessoa com deficiência. Através dos dados do IBGE, é possível extrair informações que trazem consigo uma realidade mapeável, que busca proporcionar insumos que sugiram melhorias e aperfeiçoamento em políticas públicas de habitação que promovam qualidade de vida a estes indivíduos.

Este estudo é motivado pela necessidade premente de compreender a situação atual da população com deficiência em São Paulo, utilizando os dados do Censo 2010 do IBGE. A análise espacial desses dados é essencial para revelar as complexas dinâmicas sociais, econômicas, geográficas e étnicas que impactam diretamente esse grupo. Ao mapear o perfil racial e econômico dos indivíduos com deficiência, busca-se identificar padrões de distribuição e exclusão que muitas vezes passam despercebidos nas análises estatísticas convencionais. A relevância deste estudo reside em sua capacidade de oferecer uma base quantitativa sólida, fundamentada em dados, estatística descritiva e mapeamento espacial. Justifica-se a partir do objetivo de proporcionar uma visão detalhada que possa orientar a formulação de políticas públicas regionais e promover a acessibilidade para as pessoas com deficiência. Esta abordagem não apenas evidencia as barreiras de pertencimento aos espaços físicos enfrentados por esse grupo, mas também reconhece as desigualdades sócio-políticas que causam agravamento de suas dificuldades.

Além disso, a integração dos dados raciais e econômicos no estudo proporciona uma visão mais abrangente e interseccional do perfil de distribuição das pessoas com deficiência a fim de compreender os desafios enfrentados pela população com deficiência que são acometidas por outras desigualdades como a racial. A importância de compreender como fatores como raça e renda interagem com acesso ao espaço e os locais de moradia é fundamental para a criação de políticas públicas que realmente atendam às necessidades de todos os cidadãos. Portanto, este trabalho não apenas contribui para o conhecimento acadêmico, mas também tem um impacto direto e prático na vida das pessoas com deficiência, no qual pode-se servir de insumo para futuros planos diretores.

### **1.1. Hipótese**

Sob a mesma linha de raciocínio, no tocante aos PCDs, leva-se em consideração a heterogeneidade do espaço da cidade de São Paulo, pode-se hipotetizar que haja um padrão entre os percentuais de pessoas com deficiência distribuídos espacialmente, suas regiões e áreas de ponderação, seja em termos de maior concentração, menor ou dispersão, que dialogue diretamente ou inversamente com os percentuais de corpos deficientes brancos ou não brancos que se identificam como semelhantes na cidade de São Paulo.

### **1.2. Objetivo Geral**

Mapear, analisar e discutir o padrão de distribuição espacial, na medida que comprehende em quais níveis percentuais estão alocadas as PCDs dentro do município de São Paulo até o ano 2010.

### **1.3. Objetivos Específicos**

- Analisar, a partir de dados do Censo, o perfil espacial da população com deficiência auditiva, visual, mental e física permanente de São Paulo;
- Mapear a distribuição das pessoas com deficiência, estabelecendo um comparativo com os seus percentuais separados por raça;
- Estabelecer relações quantitativas entre as variáveis geográficas;
- Averiguar através de estatística descritiva a existência de relações de dependência espacial nos percentuais de deficiência;
- Dissertar de que forma o espaço interfere no ordenamento e nas configurações dos indivíduos com deficiência distribuídos em São Paulo;
- Identificar aspectos convergentes e divergentes entre as pessoas com deficiência e o pertencimento na cidade;
- Discutir como a distribuição espacial das pessoas com deficiência se relaciona com as disparidades econômicas, identificando padrões e diferenças significativas entre essas áreas;
- Analisar os padrões espaciais para discutir as relações étnico econômicas na cidade com base nessa população.

## **2. FUNDAMENTAÇÃO TEÓRICA**

### **2.1. Histórico e Conceitos de Deficiência**

Na obra “Educação Especial em tempos de Inclusão: fundamentos”, Corrêa (2011) descreve um breve histórico da educação especial, pontuando os conceitos de deficiência datados de antes da idade média até o século XX. A obra descreve que no mundo pré modernidade, no qual as conceitualizações acerca da origem da deficiência estava sob domínio da igreja católica, as pessoas das quais nasciam com o corpo atípico e apresentavam algum tipo de dificuldade para

exercer trabalhos, eram consideradas inúteis e fadadas à morte, o período de inquisição sacrificou muitas pessoas que eram entendidas como loucas, deficientes mentais ou considerados endemoniados, justamente por possuírem algum tipo de anormalidade funcional. A autora pontua que aquelas as quais nasciam com algum tipo de anormalidade, eram consideradas como sendo indivíduos que dotaram de um certo castigo de Deus e necessitavam serem excluídas do convívio social a fim de punição. Assim como descreve Corrêa (2011), no início da Era Moderna os médicos Paracenso e Cardano tornaram-se pioneiros a defender a ideia de que a deficiência mental era fruto de um problema médico, congênito e hereditário em contrapartida ao teor teológico e moral, como afirmava o clero. Sendo assim, observa-se luz às primeiras impressões do que futuramente tornaram-se as formulações do Modelo Médico das deficiências.

Ainda sob a historicidade proposta por Corrêa (2011) em 1650, Thomas Willis foi o primeiro a descrever a anatomia do cérebro humano, sugerindo que a deficiência mental era resultado de alterações estruturais no cérebro. Entre os séculos XVII e XVIII, estudiosos como John Locke (1690), Jean-Marc Gaspard Itard (1800), Charles M. Eppe (1770), Valentin Hauy (1784), Esquirol (1818), Belhomme (1824), Edouard Séguin (1846) e Maria Montessori fizeram avanços significativos na compreensão e formulação dos deficientes sob a perspectiva médica e comportamental. Conforme aborda Foresti (2022), até o século XVIII, as noções sobre deficiência estavam fortemente associadas ao misticismo e ocultismo. Durante esse período, a maioria da população ainda não tinha acesso às novas concepções sobre deficiência, suas causas e formas de integração social. Predominava o consenso de que pessoas com deficiência eram "incapacitadas", "inválidas" ou "deficientes", sem entendimento sobre diferenças individuais. Deste modo, o ideal de imutabilidade defendido pela igreja foi substituído pelo pensamento de cura e reabilitação das pessoas com deficiência.

Concomitantemente a isto, o autor pontua que até a primeira metade do século XX, o modelo médico de deficiência predominou, enfocando a deficiência como um problema individual que requer intervenção médica para corrigir ou mitigar limitações físicas ou mentais. Este modelo trata-se da expressão da máxima de uma limitação corporal do indivíduo para interagir socialmente. Tratava a deficiência como uma tragédia pessoal, sendo esta um problema a ser resolvido, este pensamento impulsionou inúmeros ideias voltados no intuito de promover a cura. De acordo com Foresti (2022), este modelo, o ponto focal estava nas condições médicas e fisiológicas do próprio indivíduo que apresentava a deficiência. Tal modelo defendia que as

desvantagens são naturais inerentes aos contornos do corpo, sendo assim, os impedimentos na realização de qualquer interação ou atividade eram conhecidos como indivíduos sem apreço.

Em contrapartida, na segunda metade do século xx, o modelo social começou a ganhar força quando o sociólogo Paul Hunt e demais estudiosos com deficiência desenvolveram este modelo a fim de discutir as limitações sociais, para além da abordagem médica (GAUDENZI; ORTEGA, 2016). Além disso, nomes como Michael Oliver, Paul Abberley e Vic Finkelstein foram pioneiros na idealização do modelo. De acordo com os autores, esses estudiosos buscavam compreender a deficiência a partir de uma perspectiva sociológica, utilizando o conceito de estigma proposto por Erving Goffman. Goffman criticava a abordagem individualista, que focava apenas na anatomia do corpo e rotulava indivíduos como inaptos, ignorando as estruturas sociais que impedem a participação social das pessoas com deficiência.

Ademais, os pensadores que defendiam o modelo social tornaram suas teorias como um instrumento político para interpretar a realidade e promover a transformação social, com premissas de que o processo da deficiência inicia-se na interação social e os PCDs devem possuir autonomia sobre suas próprias vidas e ações. Partindo do mesmo ponto de vista, a discussão acerca das conceitualizações de deficiência partem de ambos os modelos, embora o modelo médico predominou no pensamento cotidiano, no qual indica-se os sentidos de lesões e deficiência como sendo sinônimos e desconsidera qualquer relação com os pontos de interações sociais.

Todavia, conforme afirma Bampi (2008), foram nas primeiras formulações de deficiência com enfoque nas condições médicas, que a Organização Mundial da Saúde (OMS) desenvolveu a Classificação Internacional de Doenças (CID), no qual codifica as doenças com base nas condições físicas e anatômicas dos indivíduos. O autor também pontua que foi somente em 1976, que a OMS publicou a International Classification of Impairment, Disabilities and Handicaps (ICIDH). Para o autor, este documento se diferenciava da CID ao buscar incorporar as classificações contidas na CID com foco no tipo de lesão e suas consequências, visando incluir as consequências de doenças crônicas e debilitantes e sistematizar a linguagem biomédica relativa às lesões e à deficiência. No ICIDH, conforme pontua Bampi (2008, p. X):

De acordo com esse marco conceitual, impairment (deficiência) foi descrita como a perda ou a anormalidade em órgãos e sistemas e nas estruturas do corpo, disability (incapacidade) foi caracterizada como a consequência da deficiência do ponto de vista de rendimento funcional, ou seja, no desempenho das

atividades essenciais à vida diária, e handicap (desvantagem) refletia a adaptação do indivíduo ao meio ambiente, resultante da deficiência e da incapacidade.

No entanto, essa formulação apresentava algumas falhas, pois não considerava os aspectos sociais e ambientais relacionados à deficiência. Em resposta, a OMS criou a Classificação Internacional de Funcionalidade, Incapacidade e Saúde (CIF) em 2001, incorporando e expandindo a ICIDH. A CIF aborda as múltiplas causas das condições de saúde, incluindo fatores ambientais, restrições nas atividades e a participação social dos indivíduos. Esta modificação, idealizada por Battistella (2011) em conjunto com a Secretaria do Estado dos Direitos da Pessoa com Deficiência, exemplifica a evolução da CIF em 2001.



Figura 2: Esquema evolutivo dos conceitos da CIF. Fonte: BATTISTELLA (2011). Secretaria do Estado de São Paulo, 2009.

Além disso, essa classificação adota uma abordagem biopsicossocial, levando em conta as condições sociais e ambientais nas quais a pessoa com deficiência está inserida. Conforme a teoria do modelo social proposta pela CIF, lesão e deficiência são conceitos distintos: uma pessoa

pode ter lesões sem ser considerada deficiente. Nesse modelo, são feitas distinções claras entre saúde e doença.

Em 2006, a Assembleia Geral das Nações Unidas firmou um tratado internacional na Convenção sobre os Direitos das Pessoas com Deficiência, que entrou em vigor como lei brasileira em 2008, com o objetivo de proteger e promover os direitos e a dignidade das pessoas com deficiência. Sob essa perspectiva, e considerando o modelo social e os preceitos discutidos na CIF, de acordo com a convenção, o conceito de deficiência é definido como:

Pessoas com deficiência são aquelas que têm impedimentos de longo prazo de natureza física, mental, intelectual ou sensorial, os quais, em interação com diversas barreiras, podem obstruir sua participação plena e efetiva na sociedade em igualdade de condições com as demais pessoas (BRASIL, 2009, p. 1).

A definição presente no Decreto nº 6.949, de 25 de agosto de 2009, serviu como precursora para inúmeras discussões entre o poder executivo, o legislativo e órgãos competentes, com o objetivo de estabelecer uma conceitualização alinhada aos preceitos definidos pela ONU. Como resultado dessas discussões, foi sancionada, em 2015, a Lei nº 13.146, conhecida como a Lei Brasileira de Inclusão da Pessoa com Deficiência (Estatuto da Pessoa com Deficiência). Desde a promulgação deste Estatuto até a elaboração desta pesquisa, diversos decretos foram inseridos para aprimorar suas definições.

De acordo com o Decreto nº 11.066, de 2022, a avaliação da pessoa com deficiência adota uma perspectiva biopsicossocial e, quando necessária, deve ser realizada por uma equipe multiprofissional, considerando os impedimentos nas funções e estruturas do corpo, os fatores socioambientais e pessoais, as limitações no desempenho das atividades e a restrição da participação. Para a definição de deficiência auditiva, considera-se o disposto no decreto de 2023:

Considera-se deficiência auditiva a limitação de longo prazo da audição, unilateral total ou bilateral parcial ou total, a qual, em interação com uma ou mais barreiras, obstrui a participação plena e efetiva da pessoa na sociedade, em igualdade de condições com as demais pessoas (Constituição da República Federativa do Brasil, Art. 1º).

Ademais, desde então algumas limitações de interações ambientais e sociais dos indivíduos também ganharam descrições como deficiência a partir de leis incluídas no Estatuto

da Pessoa com Deficiência, como a Lei 14.126, de 22 de março de 2021, que classifica a visão monocular como deficiência sensorial, do tipo visual.

Embora muitas conceitualizações tenham sido atualizadas desde 2010, para a aplicação do Censo 2010, o IBGE categorizou as deficiências com base nos preceitos da CIF. Os respondentes foram solicitados a assinalar o grau de dificuldade que enfrentavam em interações envolvendo diferentes sentidos e habilidades, classificando-as como "alguma dificuldade", "grande dificuldade" ou "não consegue de modo algum". Essas categorias incluíam visão, audição, controle motor e físico, e habilidades cognitivas.

## **2.2. Conceitos de Espaço**

Para análise da distribuição espacial em uma cidade cosmopolita como São Paulo, que abriga um contingente significativo de indivíduos experienciando o espaço de maneiras distintas, deve-se conceitualizar a noção de espaço sob a perspectiva geográfica. Existem três dimensões do que se pode chamar de espaço, sendo elas: o espaço absoluto, o espaço relacional e o espaço relativo. O espaço absoluto carece da noção unidimensional, este existe independente da matéria, é fixo no qual os objetos apenas existem, com latitudes, coordenadas, com uma estrutura geométrica estática. Em contrapartida, o espaço relativo diz respeito aos processos dinâmicos entre os objetos que existem, este espaço depende da matéria e mais que isto, das relações entre elas, por último, o espaço relacional, que é uma afeição mais complexa, no que diz respeito às relações entre os objetos mas a percepção interna sob essas relações (SILVA, 1978). Segundo Harvey, o espaço é definido pelas circunstâncias em que é utilizado e é um produto das práticas humanas que podem transformar um espaço absoluto em relativo ou relacional, por meio das relações econômicas, sociais e ambientais envolvidas. Desta forma, o espaço é uma unidade tridimensional que engloba e toma caráter a partir dos cisalhamentos que nele são aferidos (SILVA, 1978).

Partindo deste ponto de vista, de acordo com Lefebvre (2008, p. 61-62), em sua obra "Espaço e Política", ele salienta:

O espaço não é um objeto científico descartado pela ideologia ou pela política; ele sempre foi político e estratégico. Se esse espaço tem um aspecto neutro, indiferente em relação ao conteúdo, portanto 'puramente' formal, abstrato de uma abstração racional, é precisamente porque ele já está ocupado, ordenado, já objeto de estratégias antigas, das quais nem sempre se encontram vestígios. O

espaço foi formado, modelado a partir de elementos históricos ou naturais, mas politicamente. O espaço é político e ideológico. É uma representação literalmente povoada de ideologia. Existe uma ideologia do espaço. Por quê? Porque esse espaço, que parece homogêneo, que parece dado de uma vez na sua objetividade, na sua forma pura, tal como o constatamos, é um produto social.

Tal afirmação reflete a pluralidade dos espaços e como seus ordenamentos carregam uma lógica ideológica e política. Tanto Harvey quanto Lefebvre (2008) argumentam que o espaço não é fixo, imutável ou neutro; ele se organiza e adquire caráter de forma ordenada, sob a perspectiva dos agentes que atuam e produzem nesse espaço. Esses ordenamentos possuem um caráter político, com o objetivo de reproduzir as lógicas da produção capitalista do espaço. Outrossim, o ato de habitar e apropriar-se do espaço é ordenado e pode ser articulado por fatores comuns a um grupo de pessoas que se denominam semelhantes tanto pela ausência quanto pela presença de alguns elementos convergentes. A distribuição dentro de um determinado espaço tem forte relação com as condições de habitação e existência proporcionadas para que possam apropriar-se desse espaço. Conforme pontua o geógrafo humanista Tuan (1983) em sua obra "Espaço e Lugar", o indivíduo, através da experiência com seu próprio corpo, organiza o espaço para atender às suas necessidades biológicas. Tuan salienta que essa organização ocorre sob uma perspectiva sensorial, funcionando como uma via de mão dupla: de dentro para fora, considerando a percepção sensorial do próprio corpo, e de fora para dentro, levando em conta os elementos políticos, estratégicos e partidários que já estruturaram aquele espaço. Assim, há uma constante troca entre o meio externo e o interno.

### **2.3. Conceitos de Análise Espacial**

#### **2.3.1. *Mapas Coropléticos***

Dentro do universo da cartografia temática, existem inúmeras possibilidades na estruturação de uma representação geográfica. O critério de escolha de qual mapeamento é o mais adequado a ser executado deve considerar o tipo de dado, a área do estudo e o tipo e classe das variáveis quantitativas e qualitativas. Na literatura, conforme aponta Barrozo (2023) existem dois tipos de dados: quantitativos e qualitativos, no caso dos dados quantitativos estes podem ser representados por dados absolutos ou relativos, o princípio dos dados absolutos é pautado na proporcionalidade, ou seja, na expressiva quantidade exata, exigindo assim os usos de pontos ou figuras geométricas para expressar a grandeza, por exemplo nos mapas de localização. Em

contrapartida, ao tratar-se de dados relativos, que denominam-se dados advindos de um cálculo, o princípio passa a ser a ordem e utiliza-se variáveis como cores ou valor para expressar a ordem. sendo assim, utiliza-se cores em uma escala gradativa para explicar a amostra do fenômeno como nos mapas coropléticos.

De acordo com Sluter (2015), as primeiras menções ao termo "mapas coropléticos" surgiram em 1938, quando o geógrafo americano John Kirtland Wright escreveu "Os Problemas em Mapeamentos Populacionais". Esse termo ganhou popularidade, possibilitando o reconhecimento do primeiro mapa considerado coroplético que havia sido feito em 1826 por Pierre Dupin, no qual representou o mapa dos índices de analfabetismo nas províncias francesas. Os mapas coropléticos utilizam dados relativos, como taxas, densidades, índices e percentuais, para representar valores numéricos de fenômenos, quando estes valores são conhecidos em área geográficas definidas por limites políticos, administrativos ou estatísticos, tais como municípios ou setores censitários.

A respeito dos mapas coropléticos:

Os mapas coropléticos são elaborados com dados quantitativos e apresentam sua legenda ordenada em classes conforme as regras próprias de utilização da variável visual valor por meio de tonalidades de cores, ou ainda, por uma sequência ordenada de cores que aumentam de intensidade conforme a sequência de valores apresentados nas classes estabelecidas... são indicados para representar distribuições espaciais de dados que se refere às áreas (ARCHELA; THERY, 2008, p. 9).

### **2.3.2. *Definição de Classes***

Nos mapas coropléticos considera-se que o valor da variável representativa do fenômeno está uniformemente distribuído dentro dos limites de cada área. Neste caso, quando trata-se de organizar as classes de dados espaciais em mapas coropléticos, assume-se que a variação espacial ocorre como um histograma estatístico tridimensional, por esta razão, busca-se realizar testes como a *discretização* dos dados para compreensão da distribuição espacial dos valores entre as classes. Isso permite avaliar simetrias, valores discrepantes e analisar a amplitude relativa de variação dos dados. A escolha do número de classes é crucial para o desempenho do mapa:

O limite superior do número de classes é determinado, não apenas pela natureza dos dados, mas pelo fato de que o olho humano não pode distinguir entre

pequenas diferenças nos valores de tonalidade. O limiar de diferenciação para a tonalidade não é conhecido, tanto para cores como para tons de cinza, mas acredita-se que sete ou oito tonalidades em uma sequência espectral se aproximam do limite para um leitor de mapas habitual (JENKS apud COULSON, 1987, p. 17).

Sob essa mesma perspectiva, é fundamental que o número de classes não seja inferior à amplitude dos dados apresentados, pois isso poderia resultar na perda de detalhes para o leitor. Da mesma forma, o número de classes não deve ser superior à variação dos dados, a fim de evitar distorções interpretativas do objeto mapeado. Isso é sugerido pela fórmula de Sturges (1926; SILVA, 1980; FONTÃO; ZAVATTINI, 2019):

$$K = 1 + 3,3 \log(n)$$

Nesta fórmula, (n) se apresenta o número de unidades geográficas. Os conceitos de definições de classes bem como dos mapas devem seguir a lógica alinhada à finalidade da elaboração dos mapas e da análise, a escolha do melhor método está intrinsecamente ligada à distribuição dos dados e de quais aspectos o idealizador busca demonstrar no mapa. Por consequência, no desenvolvimento dos mapas, utilizou-se os testes em que é possível observar qual variação é mais aconselhada para cada conjunto de dados.

### **2.3.3. *Índice de Moran Local***

O Índice de Moran Local, também conhecido como *Local Indicator of Spatial Association* (LISA), é uma medida estatística utilizada para identificar padrões espaciais locais e quantificar a autocorrelação espacial. Esse índice permite a análise da dependência espacial ao nível das unidades individuais, em contraste com o Índice de Moran Global, que avalia a autocorrelação em toda a área de estudo. O Índice de Moran Local é essencial para detectar *clusters* (agrupamentos) de valores altos ou baixos e pontos de anomalia (*outliers*) na distribuição espacial dos dados. Através dessa medida, é possível identificar áreas específicas onde a correlação espacial é mais forte ou mais fraca do que o esperado sob uma hipótese de aleatoriedade.

## **3. METODOLOGIA**

### **3.1. Área de estudo**

São Paulo está localizada no sudeste do Brasil, com coordenadas geográficas aproximadas de 23°33'S de latitude e 46°38'W de longitude. A cidade é parte da Região Metropolitana de São Paulo, também conhecida como Grande São Paulo, que é a maior região metropolitana do país. Obtendo uma área territorial de São Paulo é de aproximadamente 1.521 km<sup>2</sup>. A cidade é caracterizada por um relevo variado, que inclui planícies, colinas e algumas elevações montanhosas nas regiões periféricas. Este relevo diversificado contribui para a heterogeneidade do uso do solo e das condições de urbanização. Não obstante, de acordo com os dados do Censo de 2010 do IBGE, data em que esta referente pesquisa se passa, São Paulo possuía uma população de aproximadamente 11,25 milhões de habitantes, consolidando sua posição como a cidade mais populosa do Brasil, apresenta-se uma densidade demográfica registrada de cerca de 7.400 habitantes por km<sup>2</sup>. A respeito dos aspectos morfoclimáticos, segundo Aziz Ab'Saber (1973), a cidade de São Paulo está inserida no domínio morfoclimático de Mares de Morros, no bioma Mata Atlântica, apresenta predominantemente clima subtropical, com verões quentes e úmidos e invernos relativamente secos e amenos. Em 2010, o Índice de Desenvolvimento Humano Municipal (IDHM) de São Paulo foi registrado em 0,805, classificado como "muito alto" pelo Programa das Nações Unidas para o Desenvolvimento (PNUD).



Figura 3: Mapa das regiões, subprefeituras e distritos municipais de São Paulo em 2024.

### 3.2. Coleta de dados

Os microdados foram extraídos do Censo 2010, demarcados por setor censitário agregados por área de ponderação. Vale considerar que as Áreas de Ponderação (AP) são unidades geográficas, definidas apenas para os Censos de 2000 e 2010, constituídas do agrupamento mutuamente exclusivo de setores censitários contíguos. Desta forma, são construídas pelo IBGE para que seja possível aplicar os procedimentos de calibração dos pesos amostrais. Segundo o IBGE “as áreas de ponderação são a menor unidade geográfica com possibilidade de obter representatividade estatística a partir das amostras dos Censos Demográficos.”

Para o Censo de 2010, o IBGE estabeleceu que uma AP deveria ter, no mínimo, 400 domicílios ocupados na amostra. Em geral, APs são regiões dentro de municípios e, por esta razão, permitem fazer análises intramunicipais. No entanto, quando os próprios municípios não possuem aquele mínimo de domicílios estabelecido, o próprio município é considerado, por inteiro, como uma única área de ponderação. No caso dessa pesquisa, há 310 APs distribuídas

entre as 32 subprefeituras e seus setores censitários entre as regiões sul, norte, leste e oeste. O Censo Demográfico trabalha com análise probabilística, neste censo, devido ao fato da cidade de São Paulo apresentar uma população superior a 500 mil habitantes, a amostragem é fracional de 5%. A pesquisa deu ênfase ao método quantitativo, na análise da distribuição espacial da população com de algum tipo de deficiência no município de São Paulo.

Devido ao baixo número na amostra dos fenômenos a serem estudados, deu-se por método preferível, agrupá-los e utilizar-se dos dados que correspondem às questões das seguintes variáveis sobre deficiência: dificuldade de enxergar, de ouvir, de andar e/ou caminhar e dificuldade intelectual mental da população residente permanente dentro da amostragem. Neste sentido, tais variáveis apresentaram-se como resoluções em subcategorias que denotavam uma escala que se apresentava entre alguma dificuldade, grande dificuldade e dificuldade permanente nas qualificações de deficiências apresentadas no questionário dentro desta área de ponderação. Além destas variáveis, se extraiu variáveis do tipo de deficiência a partir da cor ou raça, sendo elas: brancos e não brancos, estes últimos sendo considerados todos de cor preta, parda, amarela e indígena, bem como dados de renda mensal, de brancos e não brancos.

### ***3.2.1. Manipulação e Tratamento das Variáveis***

Por tratar-se de um método de pesquisa quantitativo, para fins de pesquisa, buscou-se articular os microdados do Censo de 2010 no software estatístico *Statistical Package for the Social Science* (SPSS), no qual os cálculos referentes aos percentuais de deficiência visual, para caminhar, auditiva e mental fossem realizados a partir do número de respondentes gerais da pesquisa dentro destas áreas de ponderação. Conforme mencionado anteriormente, os dados foram agrupados entre os que tinham dificuldade para enxergar, para ouvir, cognitiva e para caminhar, dentro do espectro; alguma dificuldade, grande dificuldade e dificuldade permanente. No caso do último, o termo “dificuldade para caminhar”, fora substituído por deficiência física e no quesito dificuldade cognitiva, retratado aqui como deficiência mental.

É essencial destacar que as formulações conceituais sobre os termos de deficiência estão baseadas nos dados do IBGE até 2010. Reconhece-se que, no momento da leitura desta pesquisa, essas conceitualizações podem ter sido atualizadas. Para fins metodológicos na construção dos

mapas, os termos foram substituídos, mas na introdução desta pesquisa, as conceitualizações originais que fundamentaram o estudo, assim como suas fontes, estão mantidas.

Sob o mesmo ponto de vista, em termos de métodos, no que diz respeito às variáveis como cor, foram agrupados os valores médios de respondentes brancos e de não brancos, este último incluindo pardos, pretos e indígenas, para se obter o peso em porcentagem deste perfil. Do mesmo modo, foram cruzados os valores de renda mensal dos correspondentes de população permanente juntamente com o peso médio em percentual separados entre brancos e não brancos, para melhor compreensão do perfil socioeconômico da população da renda dentro desta amostragem e área de ponderação. Os cálculos e o descritivo das variáveis utilizadas na construção dos mapas podem ser exemplificados na Tabela 1.

Tabela 1: Descrição das variáveis utilizadas. Fonte: Adaptado do Censo 2010.

Variável	Descrição
P_Branco	quantidade de respondentes brancos dividida pelo total de respondentes e multiplicado por 100
P_NAOBRANCOS	quantidade de respondentes não brancos dividido pelo total de respondentes e multiplicado por 100
P_DEFVIS	quantidade de respondentes com deficiência visual dividido pelo total de respondentes e multiplicado por 100
P_DEFVISBR	quantidade de respondentes com deficiência visual que são brancos dividido pela quantidade de respondentes com deficiência visual e multiplicado por 100
P_DEFVIS_NBR	quantidade de respondentes não brancos com deficiência auditiva dividido pela quantidade total de respondentes com deficiência auditiva e multiplicado por 100
P_DEFAUD	quantidade de respondentes com deficiência auditiva dividido pelo total de respondentes e multiplicado por 100
P_DEFAUDBR	quantidade de respondentes brancos com deficiência auditiva dividido pela quantidade total de respondentes com deficiência auditiva e multiplicado por 100
P_DEFAUDNBR	quantidade de respondentes não brancos com deficiência auditiva dividido pela quantidade total de respondentes com deficiência auditiva e multiplicado por 100
P_DEFCAFMIN	quantidade de respondentes com deficiência física dividido pelo total de respondentes e multiplicado por 100
P_DEFCAFMINBR	quantidade de respondentes com deficiência física brancos dividido pela quantidade de respondentes com deficiência física e multiplicado por 100
P_DEFCAFMINnbr	quantidade de respondentes não brancos com deficiência física dividido pela quantidade de respondentes com deficiência física e multiplicado por 100

P_DEFMENTAL	quantidade de respondentes com deficiência mental <sup>1</sup> dividido pelo total de respondentes e multiplicado por 100
P_DEFMENTALBR	quantidade de respondentes com deficiência mental brancos dividido pela quantidade de respondentes com deficiência mental e ultipliado por 100
P_DEFMENTALNBR	quantidade de respondentes não brancos com deficiência mental dividido pela quantidade total de respondentes com deficiência mental e multiplicado por 100
RENDAMENSAL_V6529_mean	renda mensal dos respondentes
RENDANOBR_mean	renda mensal de pessoas não brancas respondentes
RENDABR_mean	renda mensal de pessoas não brancas respondentes

### 3.3. Técnicas de Visualização e Análise Espacial

Os resultados foram apresentados cartograficamente através do programa RStudio, utilizando-se da base cartográfica extraída do SSPPS, com os arquivos shapefile extraídos do Geosampa e o arquivo contendo os cálculos das variáveis conforme mencionado anteriormente. Além disto seguiu-se a metodologia descrita por Barrozo (2023) para a elaboração dos mapas coropléticos no R. Desta forma, tornou-se possível traçar os dados georreferenciados unidos às variáveis calculadas em um só arquivo compatível com os pacotes de análise espacial do R. Conforme orientado por Barrozo (2023), após o processo de união dos dados em uma só *data frame* e a remoção dos valores nulos, iniciou-se o processo de análise exploratória dos dados. Nesta fase, o objetivo metodológico concentrou-se na identificação de quais eram a quantidade de classes e seus intervalos entre os valores das variáveis, neste ponto, constatou-se que seria necessário a realização de um processo de discretização dos dados para compreensão tanto do padrão de distribuição dos valores de cada variável quanto para a compreensão de quantas classes e de que forma elas poderiam ser representadas visualmente no mapa e na legenda. Segundo Cauvin (2008), é aconselhável que os mapas coropléticos devem manter-se entre 4 a 7 classes. Neste sentido, o processo de discretização trata-se de uma técnica que refere-se à transformação de variáveis contínuas em variáveis discretas, neste processo pode-se realizar teste referente a melhor maneira de se visualizar as classes do mapa.

Pautado na metodologia descrita por Barrozo (2023), a posterior, através da construção de um histograma de distribuição dos valores de cada uma das variáveis percentuais de deficiência encontradas, observou-se a distribuição e aplicou-se o *teste de jenks* para os seguintes métodos de divisão das variáveis em intervalos de classes: *quantile*, *equal*, *Sd*, *Jenks* e *k means*. Após este

<sup>1</sup> Não se considerou como deficiência mental as perturbações ou doenças mentais como autismo, neurose, esquizofrenia e psicose.

processo realizado em todas as variáveis percentuais, realizou-se um teste em que buscava apurar a acurácia de cada uma das divisões para fins de análise dos maiores valores, esta etapa foi realizada com o pacote *ClassInt* (BIVAND, 2023) do R.

```

> # Teste do intervalo dos dados para p DEFAULT
> print(jenks.tests(def_fixed))
  # classes Goodness of fit Tabular accuracy
  8           0           0
> print(jenks.tests(def_sd))
  # classes Goodness of fit Tabular accuracy
  7.0000000  0.9220800  0.7013126
> print(jenks.tests(def_equal))
  # classes Goodness of fit Tabular accuracy
  7.0000000  0.9393097  0.7309009
> print(jenks.tests(def_quant))
  # classes Goodness of fit Tabular accuracy
  7.0000000  0.9320702  0.7851699
> print(jenks.tests(def_jenks))
  # classes Goodness of fit Tabular accuracy
  7.0000000  0.9578275  0.7999818
> print(jenks.tests(def_kmeans))
  # classes Goodness of fit Tabular accuracy
  7.0000000  0.9576445  0.7991231
> tm_fill(col = "p_BRANCOS", title = "'p_BRANCOS'"
```

Figura 4: Teste de acurácia do intervalo de dados para a variável deficiência auditiva. Fonte:  
Elaboração própria.

Durante o processo de comparação dos índices dos diferentes estilos de discretizações e adotando, conforme a literatura, quanto mais próximos de 1 para *Goodness of Fit* e para *Tabular Accuracy*, maior a acurácia do estilo, ao final deste método, os dados estavam prontos para a construção dos mapas coropleticos, conforme cada resultado do teste de discretização e de acurácia constatou. Na fase final, utilizou-se dos pacotes de construção de mapas *Tmap* e buscou-se manter uma escala de cores compatíveis com dados populacionais. Contudo, parte dos *scripts* com os passos realizados no processo de tratamento, discretização e construção dos mapas podem ser encontrados em anexo deste trabalho.

Para a elaboração dos mapas do Índice de Moran Local, pautou-se na metodologia descrita por Barrozo (2023), utilizando-se do pacote para análise de agrupamentos locais *rgeoda* do R, no qual buscou-se inicialmente calcular o coeficiente de Moran para cada uma das variáveis. De acordo com a literatura, este coeficiente permite identificar o grau de autocorrelação entre a variável e o local. Segundo Anselin (1995), esse valor pode ir de +1 a -1, sendo que, quanto mais próximo de 1, mais forte a autocorrelação. Após essa etapa, cada uma das variáveis foi manipulada com comandos que possibilitam a criação de uma matriz de vizinhança com a definição de rótulos, cores e clusters de associação espacial, como *low-low*, *high-high*, *low-high* e *high-low*, para plotar a visualização dos mapas de Moran Local.

## 4. INTERPRETAÇÃO E ANÁLISE DOS RESULTADOS

### 4.1. Mapeamento Geral dos Dados

Foram analisadas e mapeadas as variáveis de deficiência visual, auditiva, mental e física dos respondentes que assinaram para alguma dificuldade, grande dificuldade ou não conseguiram de jeito nenhum, em cada uma das deficiências, segundo a classificação do Censo 2010 do IBGE. Os mapas que demonstram a variável deficiência sob a divisão de brancos e não brancos consideram o universo amostral abordado em cada área de ponderação no mapa em que a variável deficiência é analisada em sua totalidade. Em outras palavras, esses mapas com quebra (brancos e não brancos) são desdobramentos das amostras do mapa geral, refletindo a distribuição racial dentro do conjunto total de pessoas com deficiência. A amostra total de respondentes foi um pouco superior a 11 milhões e 253 mil, distribuídos em 310 áreas de ponderação. A amostra para deficientes visuais foi de aproximadamente 3.421 mil; para deficiência auditiva, 856 mil; para deficientes físicos, 1.164 mil; e para deficientes mentais, 235 mil.

#### 4.1.1. *PCDs Visual*

No mapa exemplificado na figura 5, observa-se uma homogeneidade dos percentuais da população com deficiência visual residente no extremo sul do município, com percentuais que vão de 16,4 a 19,6% de pessoas. Nas demais áreas de ponderação, observa-se heterogeneidade dos índices de deficientes visuais. Há uma faixa vertical na zona oeste com índices de 11,7 a 16,4% de pessoas com deficiência visual nesta região. Em suma, nas demais regiões, o padrão de distribuição é heterogêneo entre os índices; em outros termos, altos percentuais coexistem baixos percentuais nas mesmas regiões e áreas de ponderação.

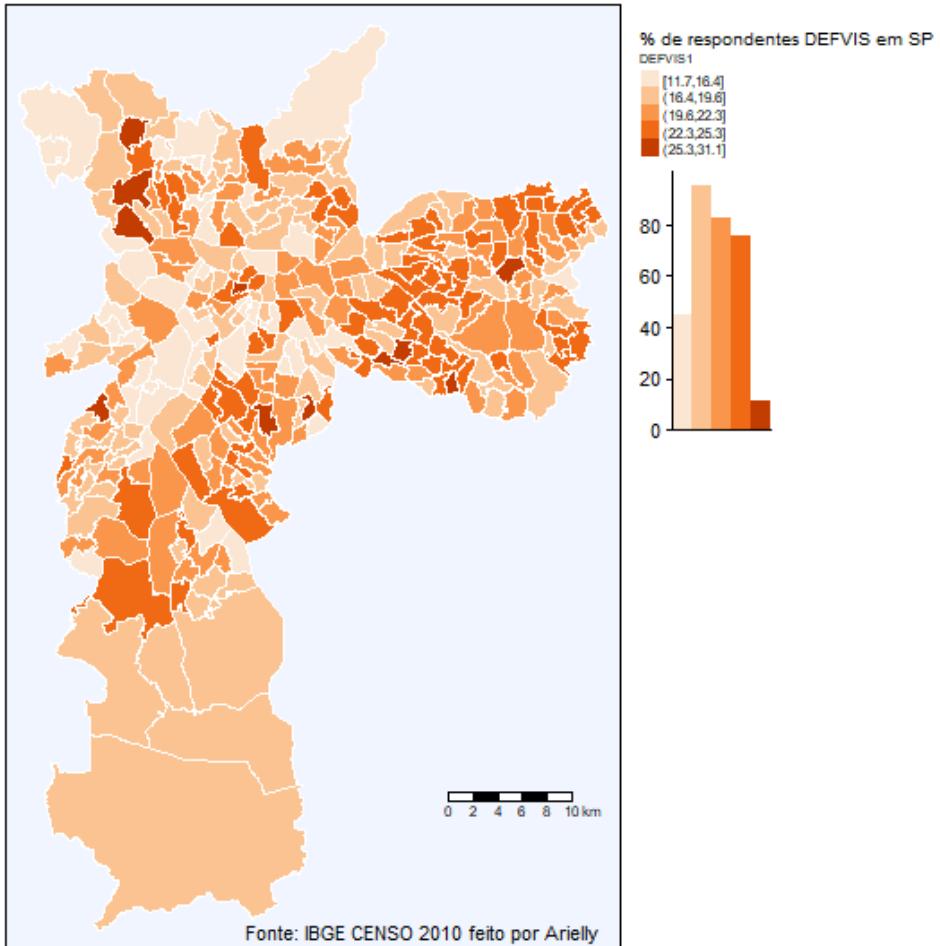


Figura 5: Mapa dos respondentes com deficiência visual em SP.

A figura 6 demonstra o mapa em que revela que um grande percentual de PCDs visuais que se identificam como brancas está concentrado nas regiões sul, sudoeste e central de São Paulo. Em contraste, os extremos da cidade, incluindo o extremo sul, norte e leste, apresentam percentuais mais baixos, variando de 31% a 47% de PCDs visual que se consideram brancos.

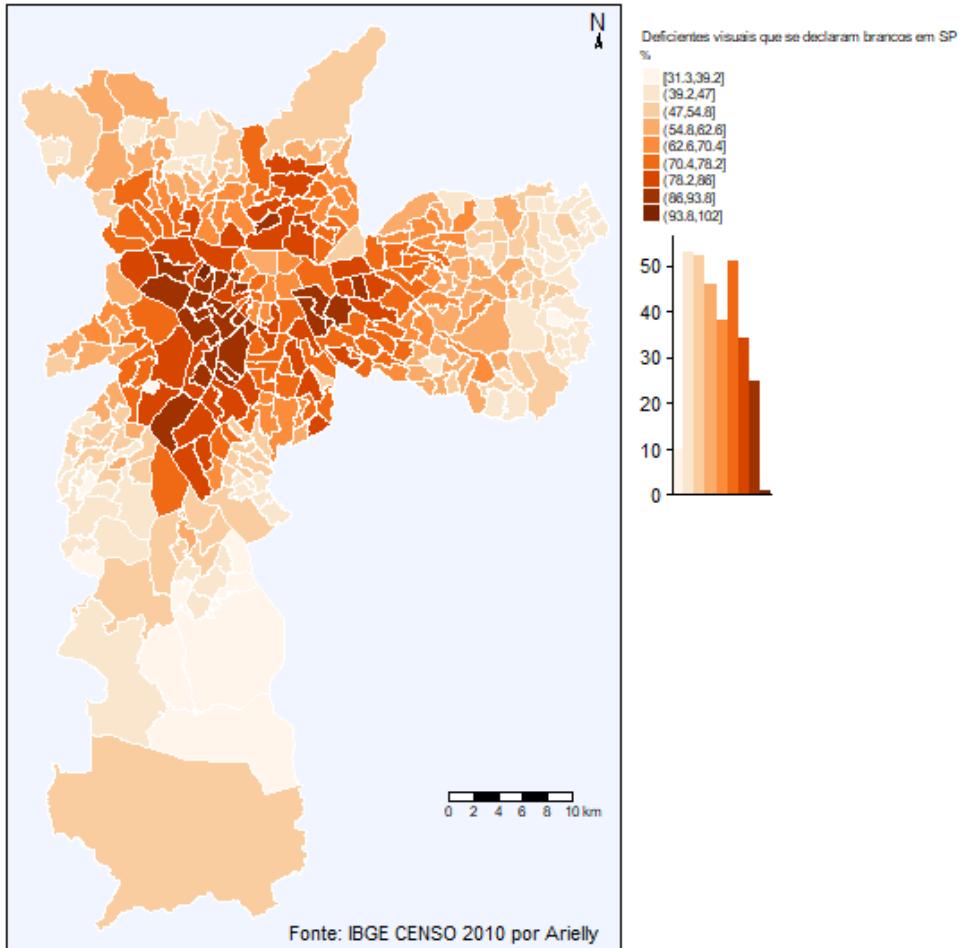


Figura 6: Percentual de PCDs visual que se consideram brancos em SP.

No mapa da Figura 7, é possível observar o percentual de pessoas que se identificam como PCDs visual e se declaram não brancas. Há um contraste marcante entre as áreas periféricas e as porções centrais da cidade. Os índices de pessoas não brancas com deficiência visual são claramente expressivos no extremo sul, enquanto são significativamente menores na zona oeste e nas regiões leste e sul centrais.

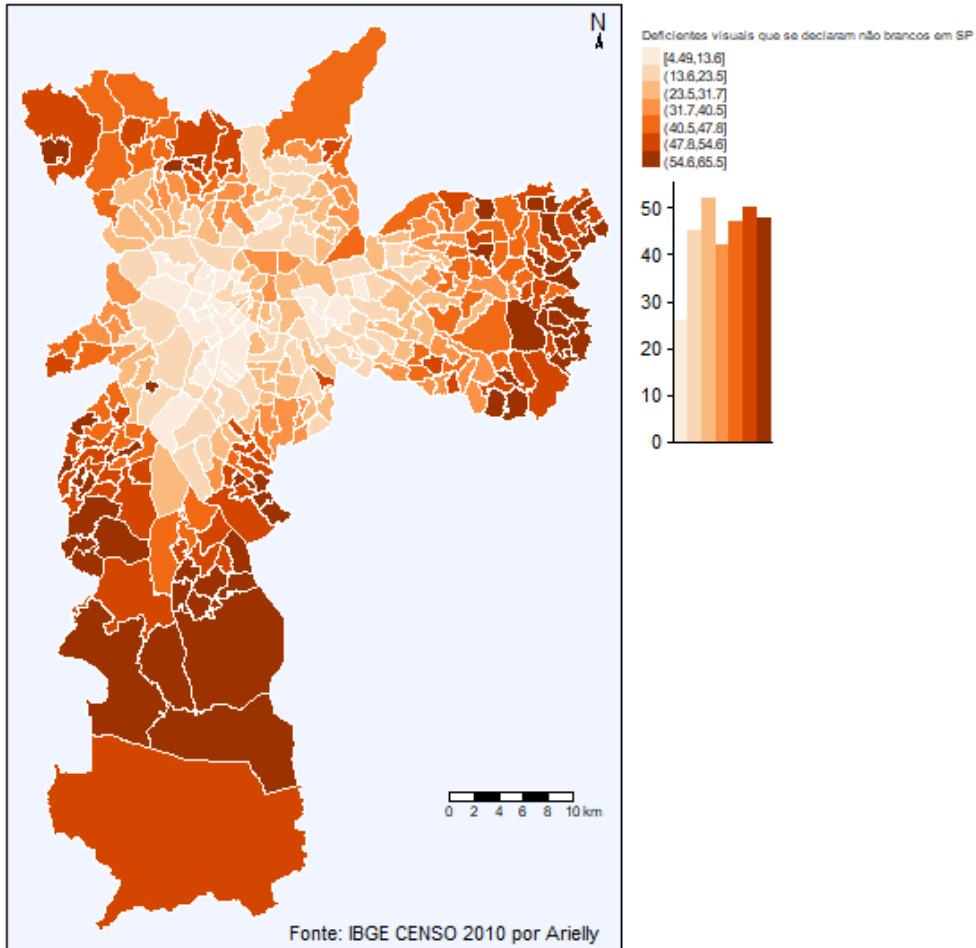


Figura 7: Percentual de PCDs visual que se autodeclaram não brancas em SP.

#### 4.1.2. *PCDs Auditiva*

O mapa da figura 8 demonstra a porcentagem de deficientes auditivos entre os respondentes na cidade de São Paulo, variando de 2% a 7,6% de pessoas que assinalaram para algum grau de deficiência auditiva. No extremo sul, os percentuais estão na faixa dos 4%. Observa-se uma distribuição heterogênea nas demais regiões, com percentuais altos e baixos coexistindo nas diferentes áreas de ponderação.

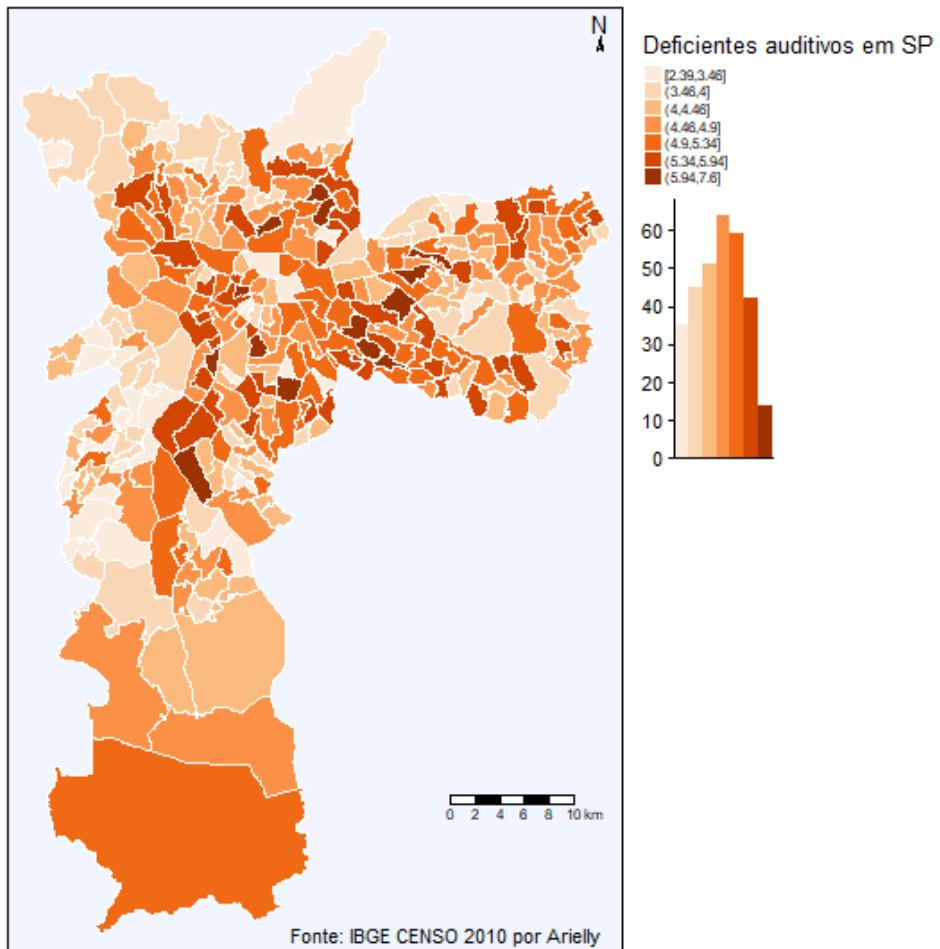


Figura 8: Mapa dos respondentes com deficiência auditiva em SP.

Na figura 9, o mapa denuncia que dentro do universo das pessoas com deficiência auditivas apresentadas na figura 8, tem-se os percentuais das pessoas que se denominam brancas; pode-se observar que os altos índices de brancos estão localizados na região centro oeste em direção ao sul, com percentuais na faixa dos 80% a 100% de pessoas com deficiência auditiva que se denominam brancos em determinadas áreas de ponderação, enquanto que nas regiões periféricas apresenta-se valores baixos e médios que variam de 25 a 50%.

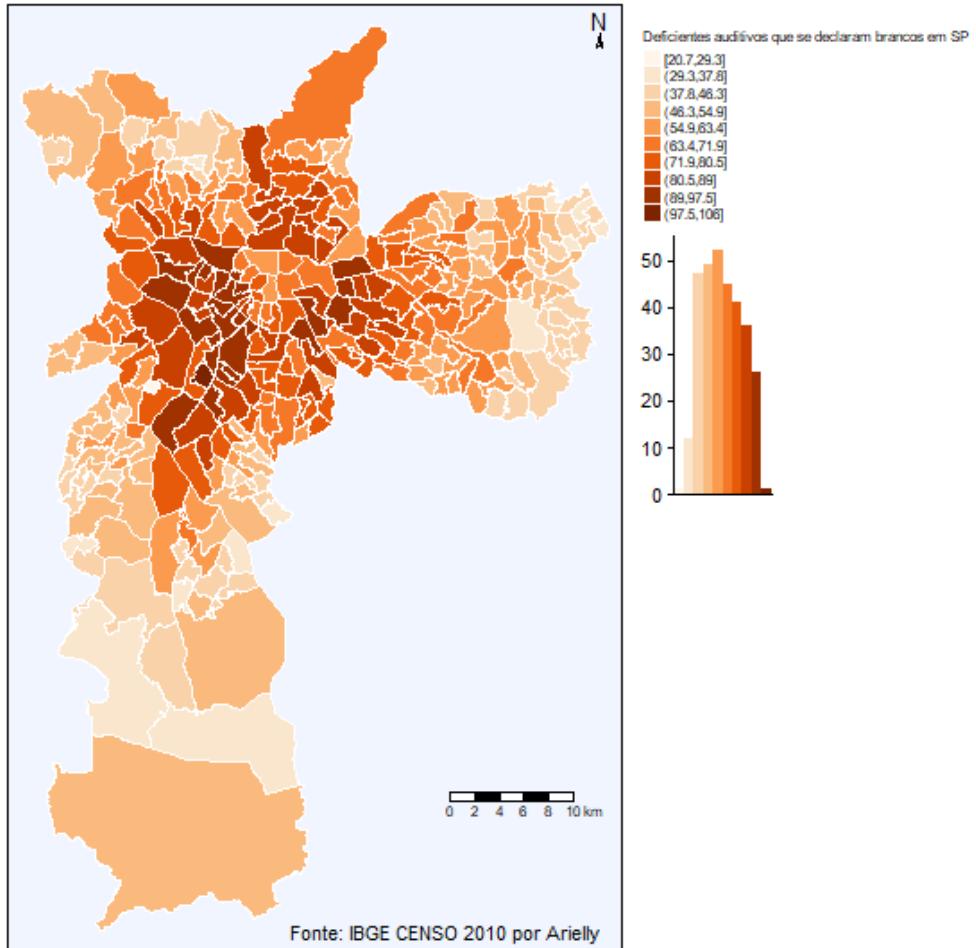


Figura 9: Percentual de PCDs auditiva que se consideram brancos em SP.

Em paralelo ao anterior, a figura 10 apresenta percentuais de respondentes que possuem deficiência auditiva mas que se consideram não brancos. Este mapa contrasta com o anterior, na medida que demonstra os percentuais mais altos de pessoas não brancas nas extremidades sul e leste, enquanto as regiões centro-oeste, centro-leste e centro-sul têm valores mais baixos, assumindo que nestas áreas de ponderação há maior concentração de brancos e menos de não brancos. É importante destacar que, em algumas áreas ponderadas do sul, os índices de deficientes auditivos que se consideram não brancos variam de 2% a 11%.

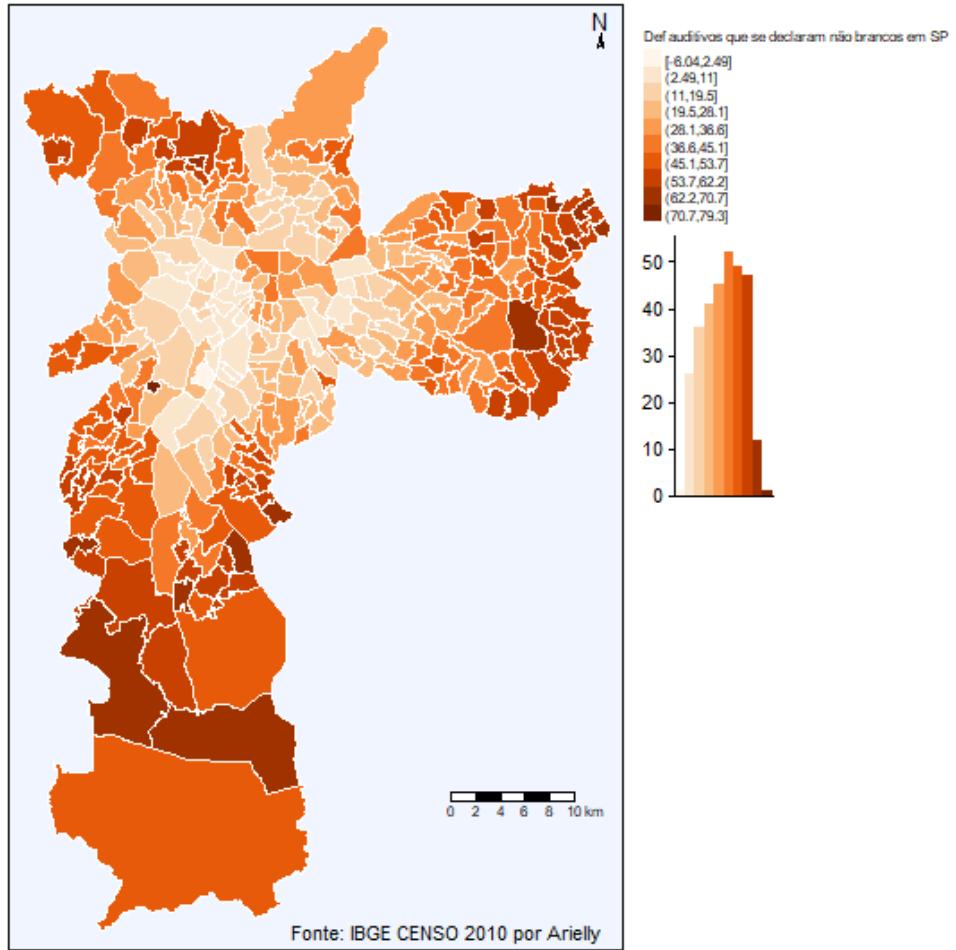


Figura 10: Percentual de PCDs auditiva que se autodeclaram não brancos em SP.

#### 4.1.3. *PCDs Física*

A figura 11 identifica os percentuais de pessoas que assinaram possuir qualquer dificuldade permanente de locomoção em SP, denominadas no mapa como deficiência física. Constatata-se que o extremo sul se destaca, com percentuais variando entre 8,2% a 10,4% de pessoas com deficiência física nestas áreas de ponderação. Em contraste, às demais regiões apresentam uma distribuição heterogênea dos percentuais, sem agrupamentos específicos.

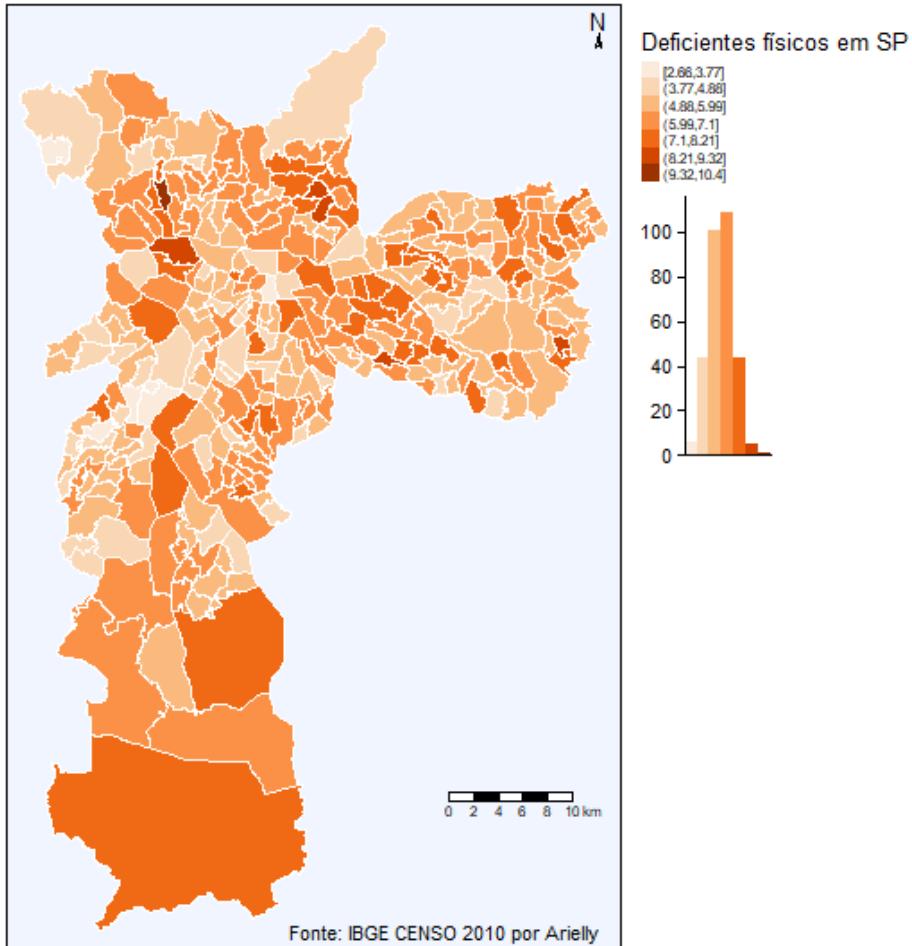


Figura 11: Mapa dos respondentes com deficiência física em SP.

A partir dos percentuais dos deficientes físicos nas áreas de ponderação, demonstrados na figura anterior, pode-se observar que dentro do universo de deficientes físicos há uma quebra entre os que se consideram brancos exemplificados na figura 12. Nota-se que, no extremo sul, as áreas de ponderação apresentam percentuais mais altos de deficientes físicos que se identificam como brancos, variando de 38% a 56%. Em contrapartida, as regiões centro-sul, centro-oeste e centro-leste exibem percentuais mais baixos de deficientes físicos brancos. Além disso, as extremidades ao leste e norte também revelam altos índices de percentuais de pessoas que têm deficiência física e que se identificam como brancos.

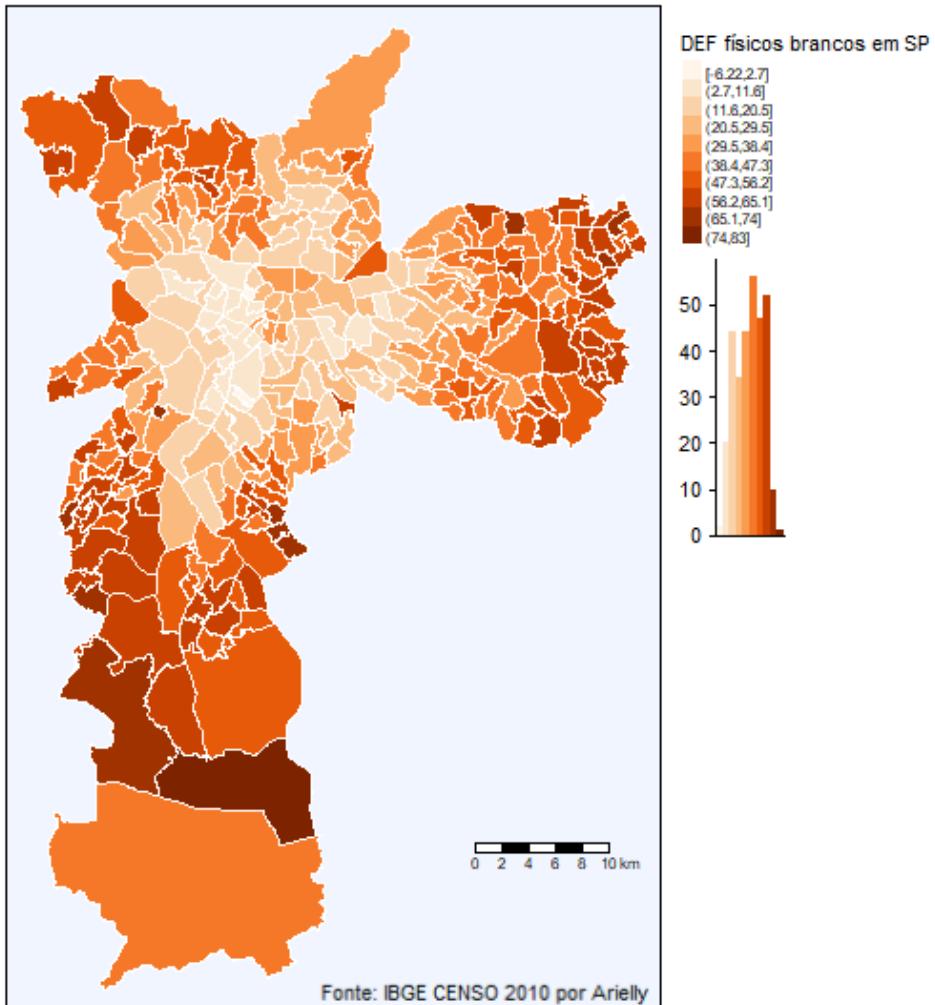


Figura 12: Percentual de PCDs física que se consideram brancos em SP.

Em contrapartida, a figura 13 apresenta-se os percentuais de pessoas que dentro do universo de deficientes físicos apresentados na figura 12 se consideram não brancas. Ao comparar a figura anterior (10), nota-se que os índices mais altos de deficientes que não se consideram brancos estão nas áreas de ponderação das regiões centro-sul, centro-oeste e norte, enquanto as áreas de ponderação do extremo leste mostram valores mais baixos, ou seja, nestas regiões há uma concentração de PCDs auditiva que se consideram brancos, esta relação inversamente proporcional pode ser exemplificada comparando a figura 12 e 13. Vale destacar que ambos os mapas revelam percentuais elevados nas áreas de ponderação das regiões do extremo sul, com valores variando entre 52,7% a 61,6%.

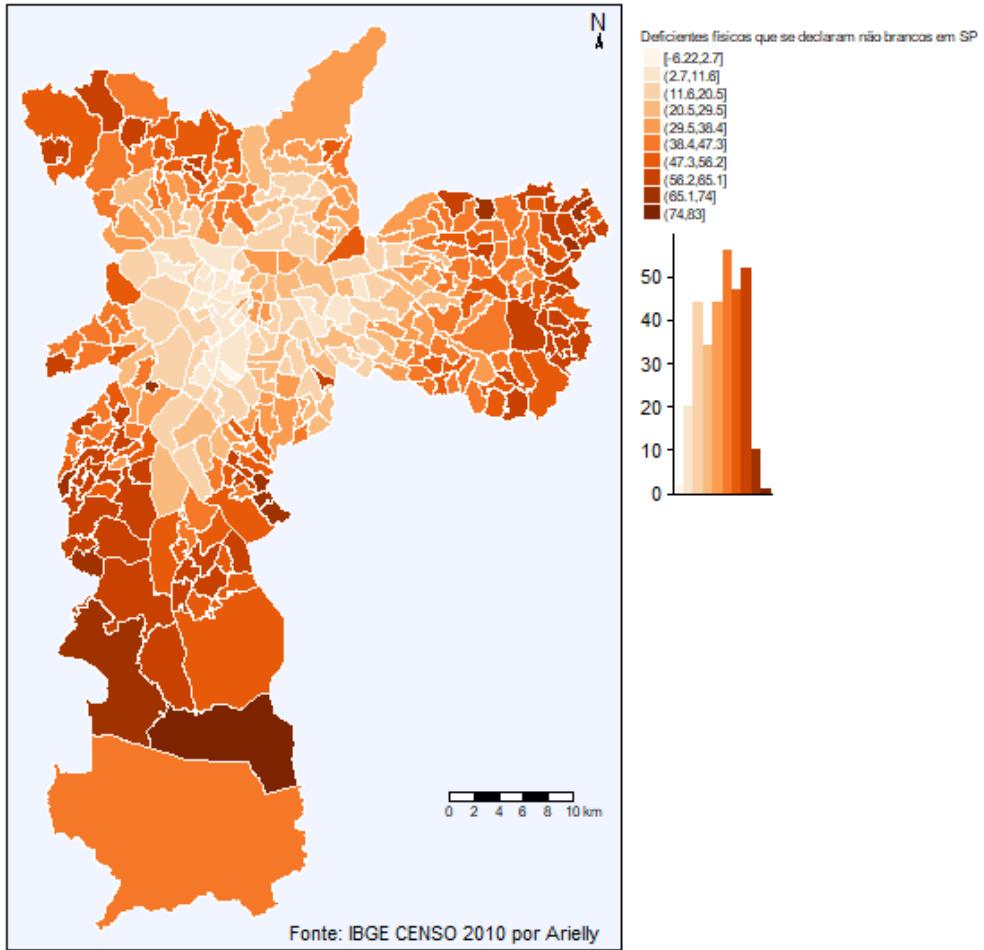


Figura 13: Percentual de PCDs física que se autodeclararam não brancos em SP

#### 4.1.4. *PCDs Mental*

O mapa acima (figura 14), traz a representação do percentual de respondentes de população permanente que possuem deficiências mentais segundo os critérios do IBGE. Observa-se que esses percentuais são baixos, variando entre 0 e 2,7% das pessoas possuem algum tipo de deficiência mental. Os maiores valores estão concentrados no extremo sul com 1,6% dos respondentes possuindo algum grau de deficiência mental, enquanto nas outras regiões, a distribuição das PCDs mental não segue um padrão homogêneo e na mesma região, diferentes percentuais estão dispersos pelas áreas de ponderação.

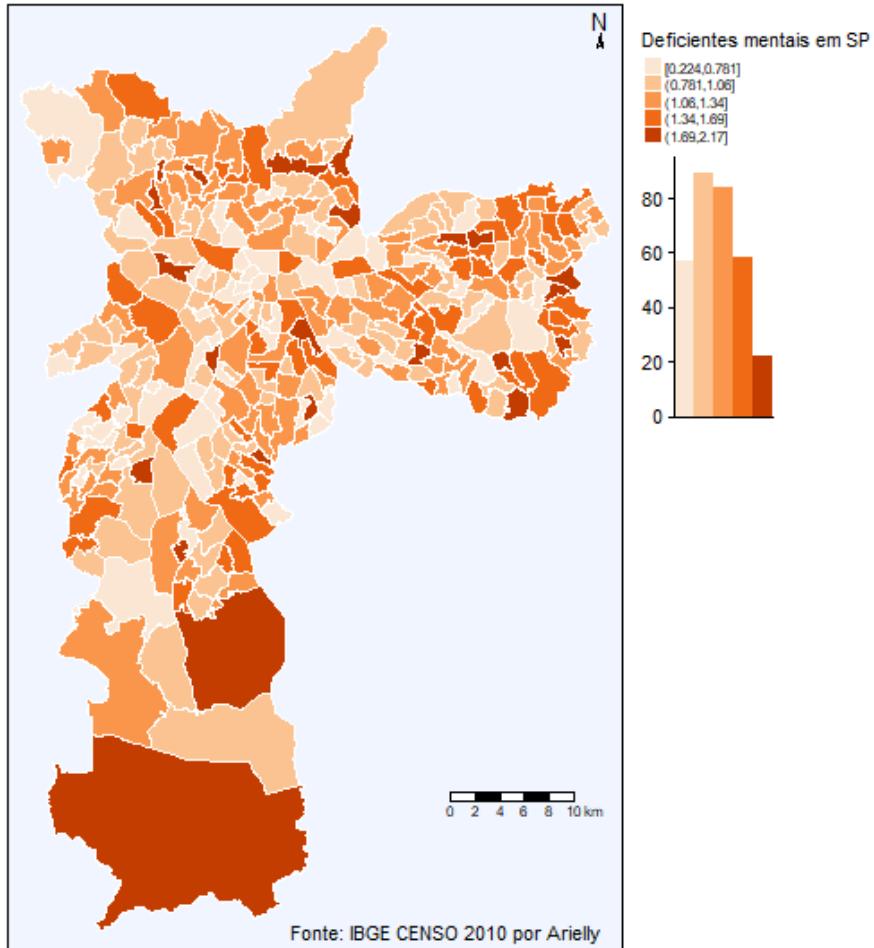


Figura 14: Mapa dos respondentes com deficiência mental em SP.

Considerando o universo de respondentes com deficiências mentais exemplificadas na figura 13, o mapa 15 oferece um panorama dos percentuais nas regiões onde estão concentradas as PCDs mental que se identificam como brancas. Observa-se uma concentração dos maiores percentuais, acima de 70%, nas áreas de ponderação das regiões centrais, espalhando-se em direção ao sul, oeste, norte e leste. Em contraste, as áreas do extremo sul exibem valores médios de pessoas com deficiências mentais brancos, o que sugere que nestes locais há maior concentração de não brancos como no extremo leste que apresenta os menores percentuais de indivíduos com deficiências mentais que se consideram brancos.

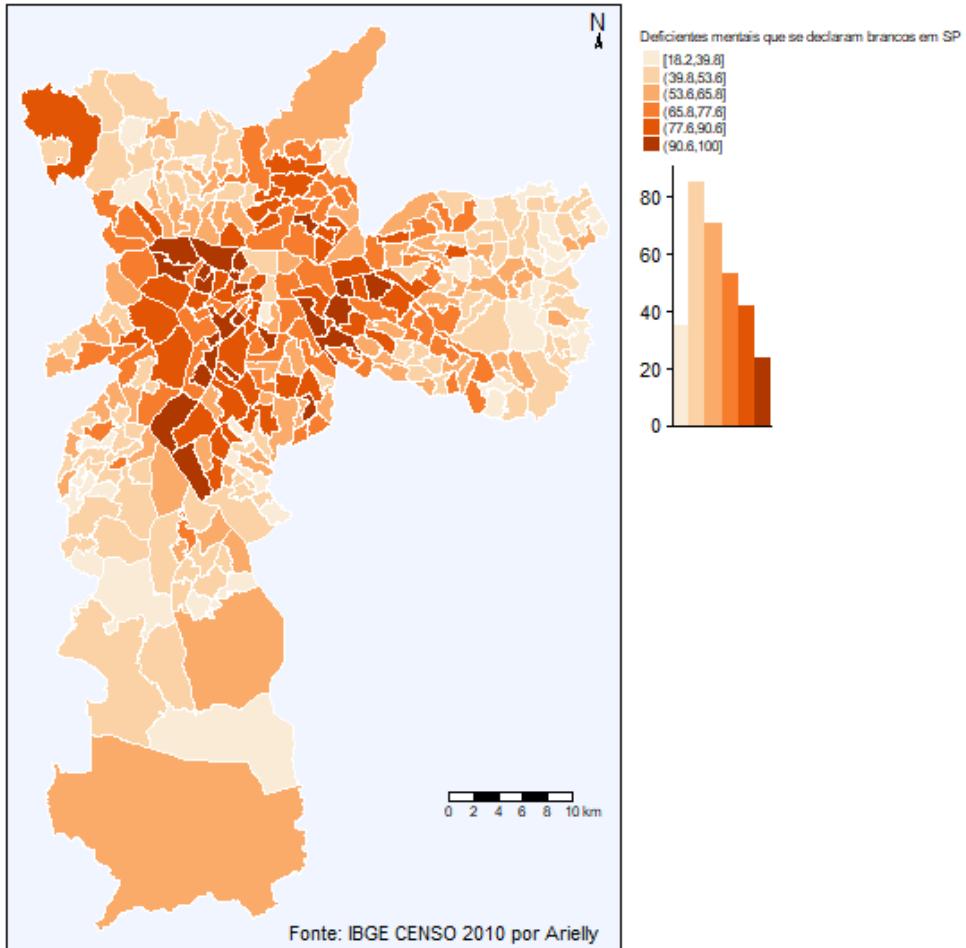


Figura 15: Percentual de PCDs mental que se consideram brancos em SP.

Em um comparativo entre a figura 15 e 16, observa-se uma relação antagônica nas distribuições espaciais das pessoas com deficiência mental que se denominam brancos e não brancos dentro do universo das PCDs mental nas áreas de ponderação. Nota-se que os menores percentuais de indivíduos considerados não brancos estão localizados nas porções centro-sul, espalhando-se em direção ao oeste, leste e norte com índices que vão de 0 a 21%. Em contraste, as áreas nos extremos norte, leste e sul apresentam os maiores contingentes de deficientes mentais identificados como não brancos. Destacam-se algumas áreas de ponderação no extremo leste com índices acima de 60% e na porção sul com valores que não ultrapassam 8% de indivíduos considerados não brancos.

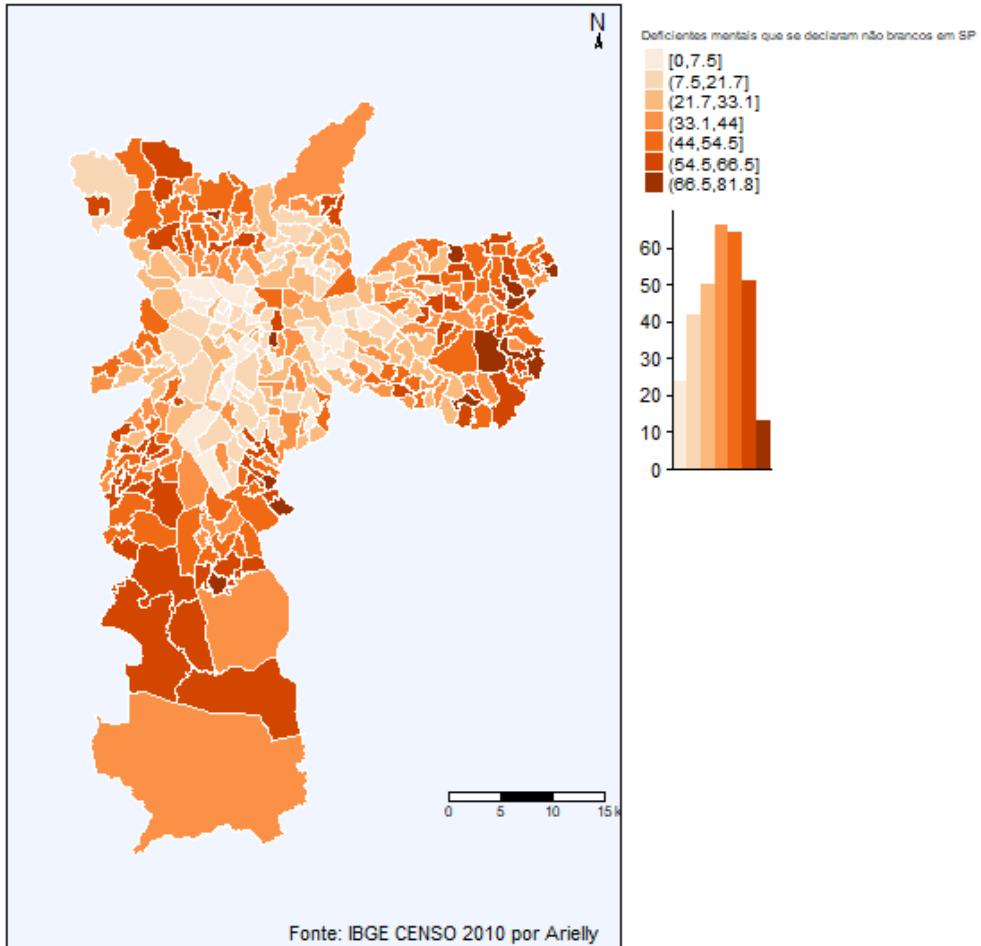


Figura 16: Percentual de PCDs mental que se autodeclararam não brancos em SP.

#### 4.2. Análise de Distribuição Espacial

Neste capítulo, foram utilizadas todas as variáveis do mapeamento acima, além das variáveis que trazem um panorama dos respondentes brancos e não brancos na cidade de SP.

##### 4.2.1. *Testando a Hipótese de Dependência Espacial: Local*

De acordo com o Instituto Nacional de Pesquisas Espaciais (INPE), o Índice de Moran Local, desenvolvido por Luc Anselin em 1994, é uma ferramenta estatística fundamental para analisar a autocorrelação espacial local. O Índice de Moran Local investiga a covariância entre um polígono específico e seus vizinhos, definidos por uma determinada distância. Esse conjunto de métodos estatísticos permite identificar áreas de alta concentração, onde regiões com índices elevados estão próximas umas das outras, assim como outliers, que são áreas com índices

discrepantes em relação aos seus vizinhos, sugerindo a presença de padrões não uniformes ou desigualdades significativas em relação à variável de interesse.

#### 4.2.1.1. Pessoas Brancas e Não Brancas

Na observação do índice de Moran Local para as figuras 17 e 18, percebe-se uma relação lógica complementar indiretamente proporcional. Na figura 17, observa-se a formação de clusters de alta concentração de pessoas brancas entre os polígonos das áreas de vizinhança da zona oeste e sul (High-High). Enquanto isso, na figura 18, essa mesma relação alta apresenta-se nas áreas de vizinhança do extremo sul e leste de pessoas não brancas. Além disso, nas regiões centro oeste da figura 19, constata-se dependência do tipo (Low-Low) entre os polígonos das áreas de vizinhança dessa região. Em ambos os mapas, há uma baixa presença de outliers entre os polígonos de vizinhança das chamadas áreas de transição, denominadas (High-Low) e (Low-High). Esses padrões podem revelar desigualdade racial entre as áreas de vizinhança.

**Moran Local do percentual de pessoas brancas em SP**

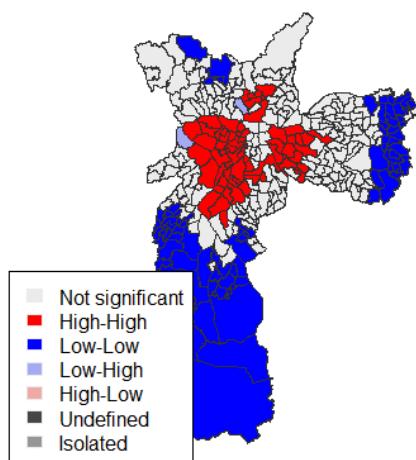


Figura 17: Índice de Moran Local para pessoas brancas em SP. Fonte: Elaboração própria.

**Moran Local do percentual de pessoas não brancas em SP**

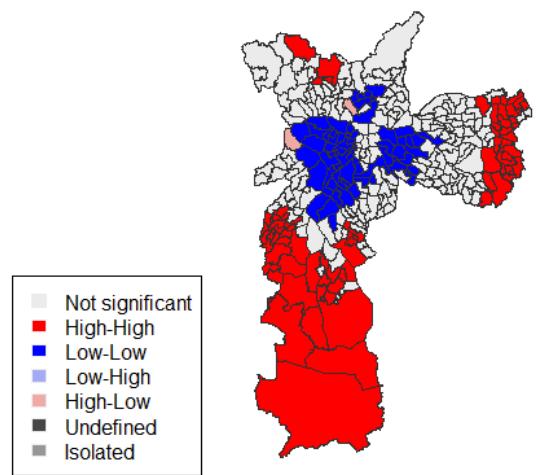


Figura 18: Índice de Moran Local para pessoas não brancas em SP. Fonte: Elaboração própria.

#### 4.2.1.2. PCDs Visual

Observa-se na figura 19, a análise sobre a variável deficiência física. Constatou-se que há áreas com alta concentração de deficientes visuais, onde os percentuais são altos e estão cercados por áreas com percentuais igualmente altos, principalmente no leste de São Paulo (*High-High*). Essas áreas indicam *clusters* de alta concentração de pessoas com deficiência visual, sugerindo uma possível segregação ou uma área de alta densidade de deficientes visuais. Na relação (*Low-Low*), as áreas com baixa concentração de deficientes visuais, onde os percentuais são baixos e estão cercados por áreas com percentuais igualmente baixos, estão principalmente na zona oeste e na parte central. Essas regiões indicam clusters de baixa concentração de pessoas com deficiência visual, possivelmente áreas com menor presença dessa população. No que se refere às relações (*Low-High*) e (*High-Low*), não há uma presença significativa dessas áreas no mapa apresentado. Áreas em branco no mapa indicam dependência e autocorrelação isoladas em termos de concentração de deficientes visuais. Essas áreas não se enquadram em nenhuma das categorias de alta ou baixa autocorrelação significativa, indicando uma distribuição mais isolada ou dispersa.

### Moran Local do percentual de deficientes visuais em SP

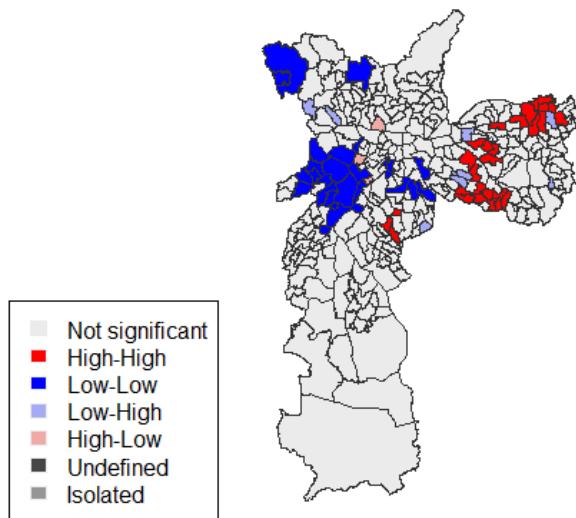


Figura 19: Índice de Moran Local de PCDs visual em SP. Fonte: Elaboração própria.

#### 4.2.1.3. PCDs Auditiva

A análise do índice de Moran Local no mapa revela que São Paulo apresenta regiões com diferentes padrões de concentração de pessoas com deficiência auditiva, sob o aspecto da variável deficiência física, na autocorrelação (*Low-Low*), estão predominantemente as porções sudoeste e noroeste do mapa. Denunciando que nestas regiões uma área de baixa concentração de deficientes auditivos é vizinha de outra com índices de concentração igualmente baixos. No quesito (*High-High*), os polígonos com alta concentração de altos percentuais estão espalhadas nas zonas leste e central. É notável que predominam áreas com valores isolados, indicando a ausência de um padrão de interdependência espacial entre os percentuais e seus polígonos vizinhos para a variável em questão, que é a deficiência auditiva. Em outras palavras, não há uma concentração nem baixa nem alta, mas sim um padrão único e isolado da variável.

#### Moran Local do percentual de deficientes auditivos em SP

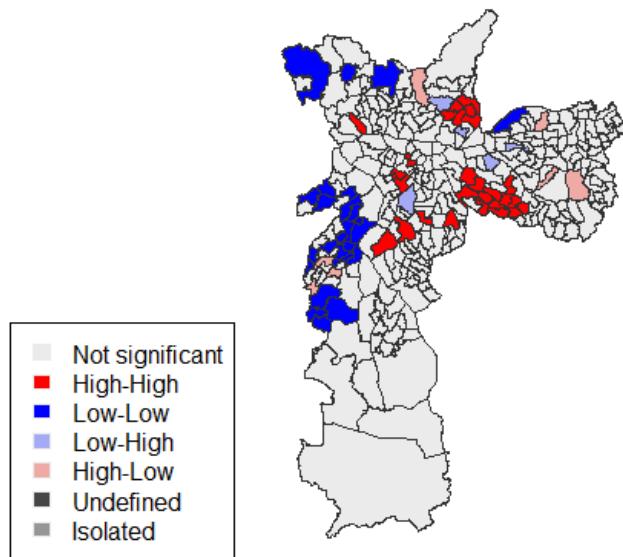


Figura 20: Índice de Moran Local de PCDs auditiva em SP. Fonte: Elaboração própria.

Quando ocorre a autocorrelação granulométrica dos percentuais a partir da variável raça entre as áreas de ponderação e a vizinhança, constata-se que o Moran Local no mapa da figura 21 demonstra que as regiões com um alto percentual de indivíduos no universo das pessoas com deficiência auditiva que se denominam brancos estão cercadas por regiões vizinhas com percentuais igualmente altos, especialmente nos polígonos das áreas oeste e central. Na figura 22, as regiões vermelhas, indicando autocorrelação de altos níveis (*High-High*), estão concentradas principalmente na parte sul do mapa, sugerindo um agrupamento significativo de PCDs auditiva que não se consideram brancos entre as áreas de vizinhança dessa região.

**Moran Local do percentual de deficientes auditivos que são brancos em SP**

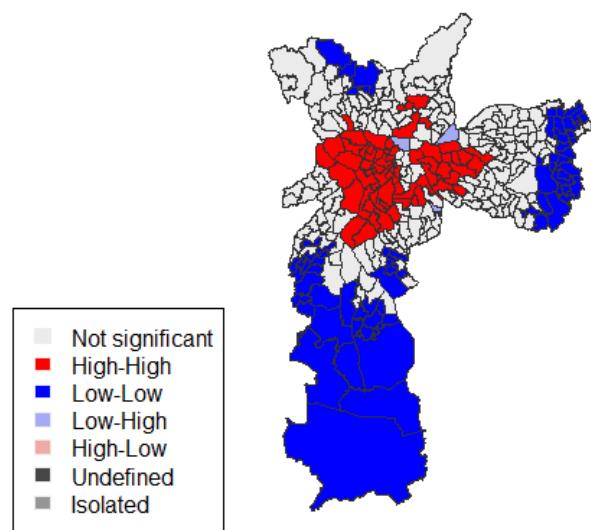


Figura 21: Índice de Moran Local de pessoas brancas com deficiência auditiva em SP. Fonte: Elaboração própria.

**Moran Local do percentual de deficientes auditivos que não são brancos em SP**

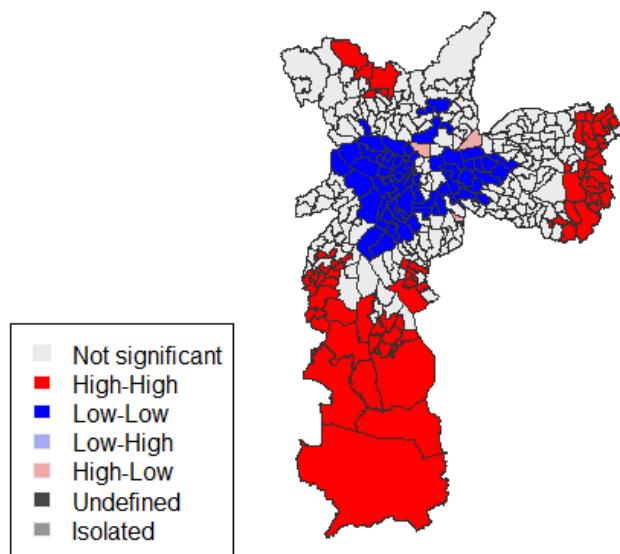


Figura 22: Índice de Moran Local de pessoas não brancas com deficiência auditiva em SP. Fonte: Elaboração própria.

Por outro lado, na figura 22, as regiões centrais apresentam um baixo percentual de indivíduos com deficiência auditiva que não são brancos cercados por regiões vizinhas com

percentuais igualmente baixos. As regiões azuis (*Low-Low*) estão localizadas principalmente na parte central do mapa, indicando um agrupamento significativo de valores baixos nessas áreas. No caso dos outliers (*Low-High*) e (*High-Low*), não há *clusters* visivelmente significativos nessa categoria em ambos os mapas.

#### 4.2.1.4. PCDs Física

A figura 23 exemplifica a autocorrelação entre os índices das áreas de vizinhança dos respondentes que se denominam deficientes físicos em SP. Observa-se concentrações de altos níveis de deficientes físicos em áreas isoladas no mapa, como na zona leste, central e norte (*High-High*). Enquanto que em algumas áreas de ponderação como no extremo norte e alguns polígonos no sul, revelam uma concentração de baixos índices de deficientes físicos entre as áreas vizinhas. Uma grande parte da extensão da cidade apresenta relação isolada, isto explica-se que nessas áreas, na análise de Moran Local, a classificação de "isolados" geralmente refere-se a áreas que não têm valores similares aos seus polígonos vizinhos em termos da variável de interesse. Isso significa que os valores observados nessas áreas são estatisticamente independentes dos valores observados nos polígonos ao redor. Esses isolados podem indicar áreas com características únicas e distintas que não seguem o padrão espacial das regiões circundantes, como também não há *anti-clusters outliers* (*High-Low*) e (*Low-High*) significativos no mapa.

**Moran Local do percentual de deficientes físicos em SP**

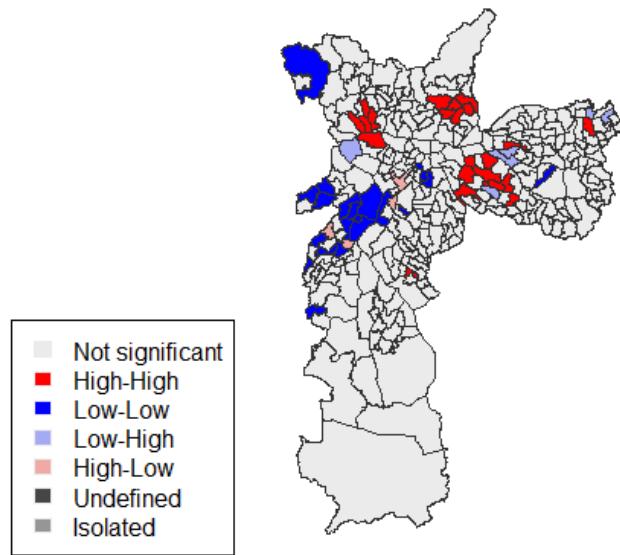
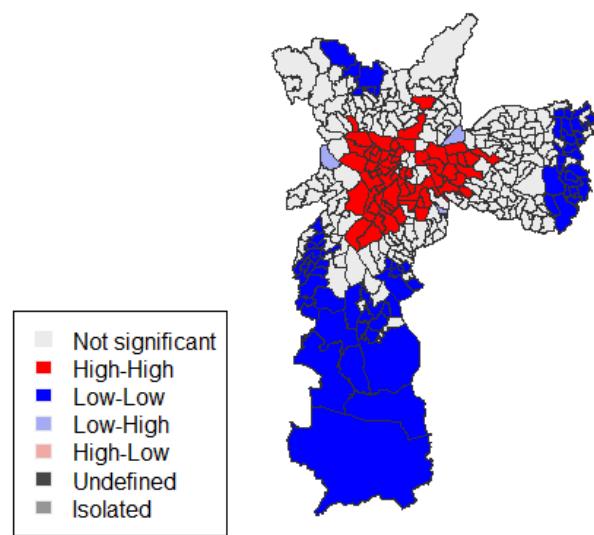


Figura 23: Índice de Moran Local de PCDs física em SP Fonte: Elaboração própria.

Os mapas se complementam na medida em que ao analisá-los há uma concentração de altos índices do percentual de pessoas com deficiência física que se denominam brancos entre os polígonos das áreas vizinhas da zona central da cidade (Figura 24) e por esta razão, esta mesma região na figura 25 em que é possível identificar os clusters dos deficientes físicos que não se consideram brancos, uma concentração de baixos índices. Todavia, na figura 25 ocorre predominância de clusters de autocorrelação do tipo (*High-High*) entre os porcentuais de deficientes físicos que não se consideram brancos nas áreas periféricas do sul, norte e leste. Não há predominância de outliers do tipo (*High-Low*) e (*Low-High*) espalhados pelas zonas da cidade.

**Moran Local do percentual de deficientes físicos que são brancos em SP**



Figuras 24: Índice de Moran Local de pessoas brancas com deficiência física em SP. Fonte:  
Elaboração própria.

**Moran Local do percentual de deficientes físicos que não são brancos em SP**

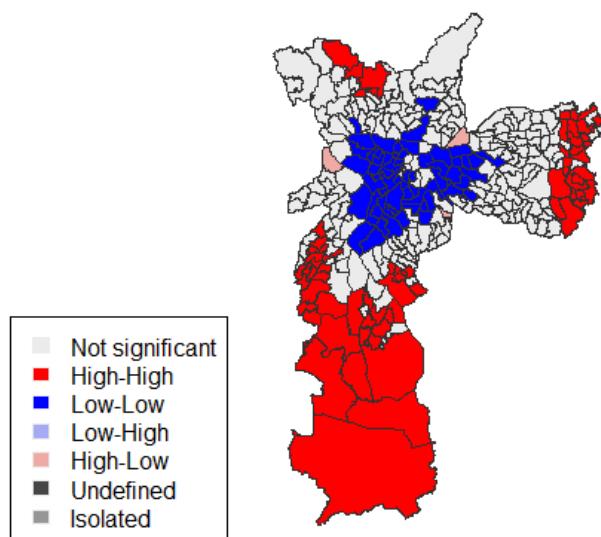


Figura 25: Índice de Moran Local de pessoas não brancas com deficiência física em SP. Fonte:  
Elaboração própria.

#### 4.2.1.5. PCDs Mental

Sob o ponto de vista da variável deficientes mentais, a figura 26 demonstra a autocorrelação entre os índices das áreas de vizinhança dos respondentes que se denominam deficientes mentais em SP. Observa-se clusters concentrados de altos níveis de deficientes físicos em áreas distribuídas no mapa, como em polígonos da zona leste e sul (*High-High*). Enquanto que em algumas áreas de ponderação centrais, revelam um nível de dependência do tipo (*low-low*) de baixos índices de deficientes físicos entre as áreas vizinhas. Vale pontuar que uma vasta extensão da cidade apresenta relação isolada, isto explica-se que nessas áreas, na análise de Moran Local, a classificação de "isolados" geralmente refere-se a áreas que não têm valores similares aos seus polígonos vizinhos em termos da variável de interesse. Isso significa que os valores observados nessas áreas são estatisticamente independentes dos valores observados nos polígonos ao redor. Esses isolados podem indicar áreas com características únicas e distintas que não seguem o padrão espacial das regiões circundantes. É interessante observar que ocorre uma relação (*Low-High*) no extremo norte e extremo sul, esses pontos de anti-clusters indicam áreas onde estão há concentração de percentuais baixos vizinhas a uma concentração de níveis altos.

**Moran Local do percentual de deficientes mentais em SP**

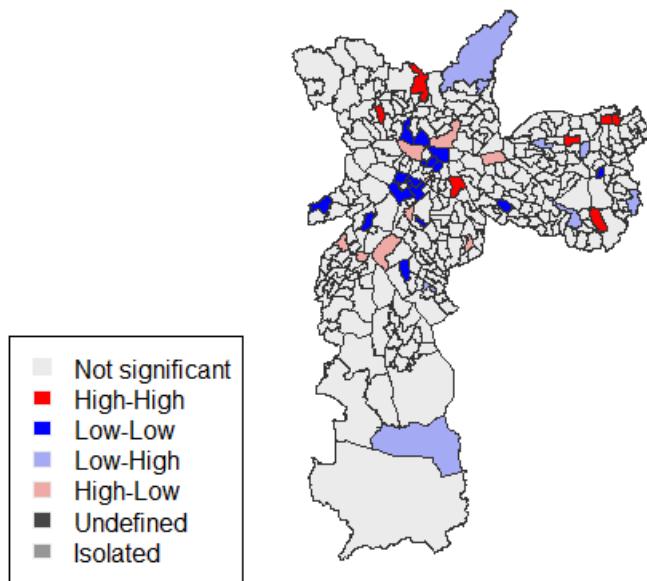


Figura 26: Índice de Moran Local de PCDs mental em SP. Fonte: Elaboração própria.

Na análise da autocorrelação espacial dos polígonos entre as áreas de ponderação apresentadas nas figuras 27 e 28, a respeito do percentual de deficientes mentais que se identificam como brancos e não brancos, observa-se que na figura 27, as áreas com alta concentração de dependência espacial (*High-High*) entre os polígonos vizinhos estão localizadas na zona central, sul e sentido leste, isto significa que em uma mesma região têm-se áreas vizinhas com altos índices de concentração de PCDs mental que se denominam brancos. Por uma relação causal, na figura 28, no que se refere aos deficientes mentais que se denominam não brancos, essas áreas são exemplificadas por uma concentração (*Low-Low*), em outros termos, concentração de baixos índices de deficientes mentais que se denominam não brancos. Existem poucas áreas que se apresentam como áreas que possuem vizinhança com padrão distinto entre os clusters de relação (*High-Low*) e (*Low-High*) entre os polígonos de vizinhança.

**Moran Local do percentual de deficientes mentais que são brancos em SP**

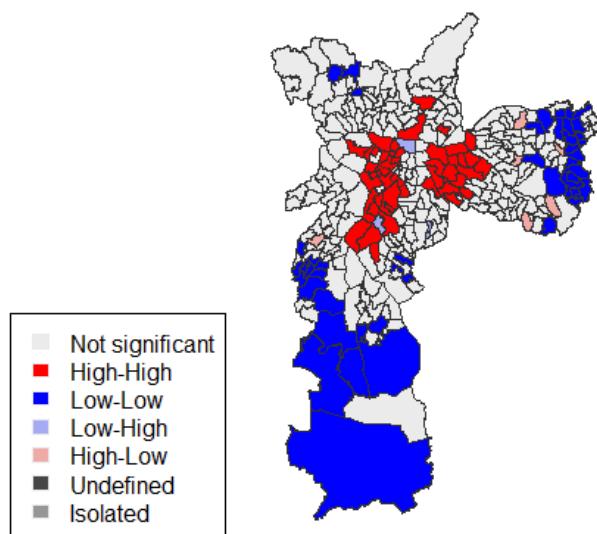


Figura 27: Índice de Moran Local de pessoas brancas com deficiência mental em SP. Fonte: Elaboração própria.

**Moran Local do percentual de deficientes mentais que não são brancos em SP**

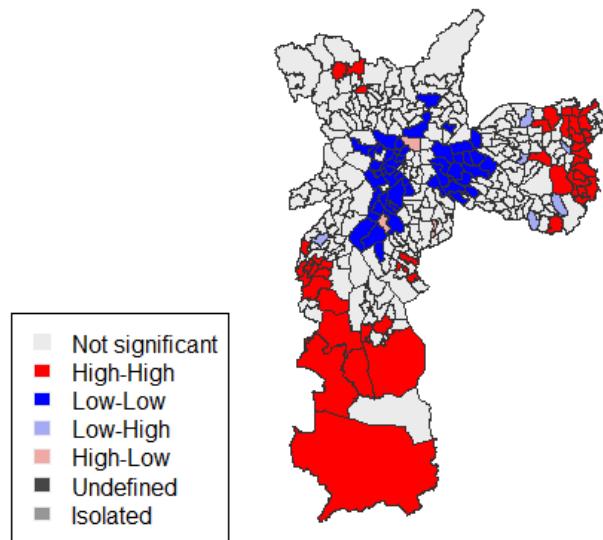


Figura 28: Índice de Moran Local de pessoas não brancas com deficiência mental em SP. Fonte: Elaboração própria.

#### 4.2.1.6. Renda de Pessoas Não Brancas

A interpretação do mapa da figura 29 do índice de moran local revela-se que os clusters das regiões vermelhas (*High-High*), estão principalmente concentrados no extremo sul e em alguns pontos da parte central e extremo leste do mapa, indicando um agrupamento significativo de altos valores de renda das pessoas não brancas nessas áreas. Todavia, os *clusters* de caráter (*Low-Low*) estão localizados principalmente na parte central da cidade de São Paulo, indicando um agrupamento significativo de baixos valores de renda nessas áreas. No caso dos outliers contidos nos clusters de categoria (*Low-High*) ou (*High-Low*) é possível observar regiões isoladas com esse padrão, mas não são predominantes no mapa.

Figura 29: Índice de Moran Local da renda de pessoas não brancas em SP. Fonte: Elaboração própria.

## 5. DISCUSSÃO E SÍNTESE DOS RESULTADOS

Após a apresentação dos resultados, obtém-se um panorama mais detalhado acerca da população que se denomina deficientes na cidade de São Paulo. A princípio deve-se considerar que a amostragem é significativa em todas as deficiências, com destaque da deficiência visual, que em algumas áreas de ponderação apresentaram quase 30% dos respondentes assinalando possuir algum tipo de dificuldade em enxergar. A explicação destes altos percentuais parte do ideal de que no momento de aplicação do Censo, conforme rege a literatura, não é categorizado a partir de uma doença congênita ou adquirida, mas sim pautada na dificuldade em enxergar de algum grau no meio social.

No caso da deficiência mental, os percentuais no mapeamento são os mais baixos mas quando recortado estes valores entre os brancos e não brancos, observa-se uma predominância de respondentes que assinalaram possuir algum nível de deficiência mental que se denominam não brancos nas áreas de ponderação das regiões periféricas da cidade, como extremo norte, leste e sul, em distritos como Perus, Tremembé, Marsillac e Guaianases. Este fato pode ser constatado ao analisar a dependência local desta mesma variável, observa-se uma concentração de altos níveis percentuais entre as áreas vizinhas destas regiões.

É interessante expandir as análises comparando os resultados da teoria da dependência local e o mapeamento dos percentuais das variáveis, nota-se que em todos os mapas ocorre predominância observável de pessoas não brancas nas áreas periféricas, a variável raça dentro do universo dos que se denominam pessoas com deficiência é muito determinada para os locais em que os indivíduos estão distribuídos. Neste ponto, pode-se observar uma desigualdade racial espacial entre as PCDs, em que mesmo com concentrações altas em algumas áreas de ponderação, ainda reproduzem uma lógica espacial que em bairros das regiões sul, oeste e central como Vila Mariana, Pinheiros, Morumbi, Vila Olímpia, Itaim Bibi, Consolação há maior predominância de pessoas com deficiência que se denominam brancas.

Ao identificar os padrões encontrados a partir da correlação entre os polígonos de vizinhança do índice de Moran Local para a variável renda das pessoas brancas, este denuncia a concentração de altas rendas nas regiões oeste, central e sul, em detrimento das rendas mais baixas que se concentram nas áreas de ponderação das porções periféricas da cidade. Logo, ao traçar as variáveis raça, renda e deficiência, comprehende-se que as variáveis raça e renda são preponderantes para que os indivíduos com deficiências se organizem no espaço. A variável da deficiência, por si só, não serve como indicador de concentração entre as PCDs. No entanto, a

raça gera agrupamentos em regiões onde os indivíduos se identificam racialmente. Em outras palavras, em algumas áreas pode-se observar uma concentração de pessoas com deficiência, mas elas estão segregadas pela raça e pela renda. Os considerados brancos tendem a se agrupar nas zonas oeste, sul e norte, enquanto os considerados não brancos estão distribuídos nas áreas periféricas da cidade.

## 6. CONSIDERAÇÕES FINAIS

Os dados apresentados demonstram a complexidade das discussões acerca dos padrões de distribuição de PCDs na cidade de São Paulo. A construção de pertencimento do espaço, bem como suas dinâmicas e as noções do espaço absoluto, relativo e relacional abordados na literatura não se materializam igualmente para nenhuma das deficiências, bem como os aspectos que sustentam tais organizações no espaço partem de indicadores econômicos e raciais. Outrossim, as conceitualizações a respeito dos diferentes tipo de deficiência sob o modelo social juntamente com os resultados desta pesquisa podem servir de insumo para entender as localidades das pessoas que enfrentam algum tipo de dificuldade em relação às ações no cotidiano e proporcionar políticas públicas centralizadas nessas populações propondo a implementação de soluções que garantam a acessibilidade universal em todas as regiões da cidade, especialmente nas áreas periféricas onde a presença de pessoas com deficiência e de não brancos é mais significativa. Se determinadas regiões recebem mais políticas públicas de infraestrutura, como ruas asfaltadas, iluminação, sinalização; de saúde, como UBS com bons profissionais e centros de reabilitação terapêutica; de segurança, como policiamento nas ruas e câmeras de segurança; ou de entretenimento, como centros urbanos de convivência, praças, lazer ao ar livre e esportes, esses ambientes terão uma maior possibilidade de oferecer uma experiência mais abrangente do espaço para seus habitantes. Em contraste, as regiões que não possuem essas melhorias terão apenas duas opções: não ter acesso a esses serviços ou precisar se deslocar para locais onde esses serviços estão disponíveis. Esse deslocamento, no entanto, nem sempre é garantido pelo estado, criando uma barreira adicional para os moradores dessas áreas menos favorecidas.

Por tais razões, esses dados, se corretamente disponibilizados, podem diagnosticar os locais onde ocorrem as distribuições e os perfis de indivíduos que se concentram, possibilitando a elaboração de um plano de soluções que promovam o bem-estar das pessoas. Além disso,

propõe-se incentivar as pessoas com deficiência a se organizarem em comunidades locais para lutar pelo direito de pertencimento aos espaços, como forma de melhorar a qualidade de vida em seus distritos. É intrínseco ressaltar a importância deste trabalho na desmistificação de senso comuns e preconceitos a respeito dos conceitos de deficiência. Deficiência não é sinônimo de doença, nem é necessariamente acarretada por uma doença, pois doença implica cura e deficiência não implica cura. Há casos em que as dificuldades encontradas são de caráter reversível ou de caráter permanente. Em ambos os casos, é necessário considerar as dificuldades impostas pelo meio para que esses indivíduos possam exercer sua cidadania. No caso de dificuldades reversíveis, é possível adaptar o ambiente para que o indivíduo consiga reverter o grau de dificuldade. Em ambos os casos, a deficiência não deve ser focada apenas na avaliação médica, mas sim abordada de forma multifocal.

## REFERÊNCIAS

AB'SÁBER, A. N. **Está nascendo o novo mapa do Brasil.** Caderno de Ciências da Terra, São Paulo, 1973.

AMIRILAN, M. L. T.; PINTO, E. B.; GHIRARDI, M. I. G.; LICHTIG, I.; MASINI, E. F. S.; PASQUALIN, L. **Conceituando deficiência.** Revista de Saúde Pública, v. 34, n. 1, p. 97-103, 2000. Disponível em: <<https://www.scielo.br/j/rsp/a/HTPVXH94hXtm9twDKdywBgy/>>. Acesso em: 20 mai. 2024.

ANJOS JÚNIOR, O. R. dos; CIRÍACO, J. da S.; SILVA, M. V. B. da. **Testando a hipótese de dependência espacial na taxa de crime dos municípios da região sul do Brasil.** In: ENCONTRO DE ECONOMIA DA REGIÃO SUL, 2016, ANPEC-SUL. Disponível em: <[https://www.anpec.org.br/sul/2016/submissao/files\\_I/i3-a129429fa7b1731dd449475ddeb27626.pdf](https://www.anpec.org.br/sul/2016/submissao/files_I/i3-a129429fa7b1731dd449475ddeb27626.pdf)>. Acesso em: 14 jun. 2024.

ANSELIN, L. **Local Indicators of Spatial Association – LISA.** In: *Geographical Analysis*, v. 27, n. 2, April 1995.

ARCHELA, R. S; THÉRY, H. **Orientação metodológica para construção e leitura de mapas temáticos.** Confins, n. 3, 2008. DOI: <https://doi.org/10.4000/confins.3483>.

BAMPI, L. N. DA S.; GUILHEM, D.; ALVES, E. D. **Social Model**: A New Approach of the Disability Theme. *Revista Latino-americana De Enfermagem*, 18 (4), p. 816–823. DOI: <https://doi.org/10.1590/S0104-11692010000400022>.

BARROZO, L. V. **Dados quantitativos relativos: mapa coroplético**. In: BARROZO, L. V., *Cartografia Temática em R para estudantes de Geografia*, 2023. Disponível em: <<https://ligaviz.github.io/RCartoTematica/>>. Acesso em: 14 jun. 2024.

BARROZO, L. V. **Padrões espaciais**: testes e visualização. *Princípios de Cartografia Temática e Análise Espacial Aplicados à Geografia da Saúde*, 07 agosto 2023. Programa de Pós-graduação em Geografia Física, FFLCH, Universidade de São Paulo.

BATTISTELLA, L. R. **Conceito de deficiência segundo a convenção da ONU e os critérios da CIF**. São Paulo: Secretaria de Estado dos Direitos da Pessoa com Deficiência, 2011. Disponível em: <<https://www.desenvolvimentosocial.sp.gov.br/a2sitebox/arquivos/documentos/274.pdf>>. Acesso em: 13 jul. 2024.

BIVAND, R. **classInt**: Choose Univariate Class Intervals. R package version 0.4-10, 2023. Disponível em: <<https://CRAN.R-project.org/package=classInt>> Acesso em: 14 jul. 2024.

BRASIL. **Decreto nº 6.949, de 25 de agosto de 2009**. Promulga a convenção internacional sobre os direitos das pessoas com deficiência e seu protocolo facultativo, assinados em Nova York, em 30 de março de 2007. Brasília, 2009. Disponível em: <[http://www.planalto.gov.br/ccivil\\_03/\\_Ato2007-2010/2009/Decreto/D6949.htm](http://www.planalto.gov.br/ccivil_03/_Ato2007-2010/2009/Decreto/D6949.htm)>. Acesso em: 15 mai. 2024.

BRASIL. **Lei nº 14.126, de 22 de março de 2021**. Classifica a visão monocular como deficiência sensorial, do tipo visual. Disponível em: <[https://www.planalto.gov.br/ccivil\\_03/\\_ato2019-2022/2021/lei/L14126.htm](https://www.planalto.gov.br/ccivil_03/_ato2019-2022/2021/lei/L14126.htm)> Acesso em: 14 jun. 2024.

CORRÊA, M. A. M. **Educação especial em tempos de inclusão**: fundamentos. 1. ed. Rio de Janeiro: Fundação CECIERJ, 2011. v. 1. Disponível em:

<<https://canalcederj.cecierj.edu.br/012016/a1af164aed3aff470abbd469102d4a12.pdf>>. Acesso em: 5 jul. 2024.

COULSON, M. R. C. **In the matter of class intervals for choropleth maps:** with particular reference to the work of George F Jenks. *Cartographica: The International Journal for Geographic Information and Geovisualization*, v. 24, n. 2, p. 16-39, 1987.

DINIZ, D. **Social model:** a new approach of the disability theme. *Revista Latino-Americana de Enfermagem*, Ribeirão Preto, v. 14, n. 4, p. 644-645, jul./ago. 2006. Disponível em: <<https://www.scielo.br/j/rlae/a/yBG83q48WG6KDHamFXXsgVkr/?format=pdf>> Acesso em: 15 jun. 2024.

FONTÃO, P. A. B.; ZAVATTINI, J. A. **Variabilidade das chuvas anuais na Região Metropolitana de São Paulo (RMSP) e no Sistema Cantareira:** classificação e frequência dos anos-padrão. *Revista Brasileira de Geografia Física*, v. 12, n. 02, p. 457-469, 2019.

FORESTI, T.; BOUSFIELD, A. B. da S. **A compreensão da deficiência a partir das teorias dos modelos médico e social.** *Revista Psicologia Política*, São Paulo, v. 22, n. 55, p. 654-667, 2022. Disponível em: <[http://pepsic.bvsalud.org/scielo.php?script=sci\\_arttext&pid=S1519-549X2022000300010&l](http://pepsic.bvsalud.org/scielo.php?script=sci_arttext&pid=S1519-549X2022000300010&l)>. Acesso em: 15 jun. 2024.

GAUDENZI, P.; ORTEGA, F. **Problematizando o conceito de deficiência a partir das noções de autonomia e normalidade.** *Ciência & Saúde Coletiva*, v. 21, n. 10, p. 3061-3070, 2016. DOI: <https://doi.org/10.1590/1413-812320152110.16642016>.

HALL, E. T. **A Dimensão Oculta.** Rio de Janeiro: Francisco Alves, 1966.

IBGE. **Resultados Gerais da Amostra - Características gerais da população, religião e pessoas com deficiência.** 2012. Disponível em: <<https://censo2010.ibge.gov.br/apps/areaponderacao/>>. Acesso em: 24 mai. 2024.

IBGE. **Panorama.** 2022. Disponível em: <<https://cidades.ibge.gov.br/brasil/sp/sao-paulo/panorama>>. Acesso em: 26 mai. 2024.

LEFEBVRE, H. **Espaço e Política**. Belo Horizonte: Editora UFMG, 2008.

LINDO, P. V. de F.. **Geografia e política de assistência social**: territórios, escalas e representações cartográficas para políticas públicas. São Paulo: Cultura Acadêmica, 2011. ISBN 9788579831966. Disponível em: <<http://hdl.handle.net/11449/109176>> Acesso em: 10 jun. 2024.

NORBERG-SCHULZ, C. **Genius Loci**: Paysage, Ambiance, Architecture. Bruxelles: Pierre Mardaga, 1981.

R Core Team. **R: A Language and Environment for Statistical Computing**. R Foundation for Statistical Computing, Vienna, Austria, 2024. Disponível em: <https://www.R-project.org/>. Acesso em: 16 jul. 2024.

SASSAKI, R. K. **Conceituando deficiência**. Revista de Saúde Pública, São Paulo, v. 34, n. 1, p. 12-17, fev. 2000. DOI: <https://doi.org/10.1590/S0034-8910200000100017>.

SILVA, A. C. **O conceito de espaço de David Harvey**: implicações ontometodológicas. De quem é o pedaço, p. 91-97, 1978.

SILVA, B. C. N. **A propósito de uma técnica de seleção de intervalos de classe para fins de mapeamento**. Geografia, 5, p. 85-96, 1980.

SLUTER, C. R.; CRUZ, C. B. M. (Org.); MENEZES, P. M. L. (Org.). **Cartography – Maps Connecting the World**. 1. ed. Suíça: Springer International Publishing AG, 2015. 386p.

STURGES, H. A. **The choice of a class interval**. Journal of the American Statistical Association, 21, p. 65-66, 1926.

TUAN, Y. **Espaço e Lugar**: a perspectiva da experiência. São Paulo: DIFFEL, 1983. Disponível em:  
<<https://fundacc.sp.gov.br/uploads/2021/04/Espaco-e-lugar-a-perspectiva-da-experiencia-YI-FU-TUAN.pdf>>. Acesso em: 22 mai. 2024.

## **ANEXO A – Scripts utilizados**

```

#para limpar a memória e construir do zero
rm(list=ls(all=TRUE))
options(scipen = 999)
#instalando os pacotes
install.packages(c("R.utils", "tidyverse", "sf", "ggplot2", "ggspatial", "archive", "readxl",
"gridExtra", "classInt", "tmap", "RColorBrewer"))
library(R.utils)
library(tidyverse)
library(sf)
library(ggplot2, warn.conflicts=FALSE)
library(ggspatial)
library(archive)
library(readxl)
library(gridExtra)
library(classInt)
library(tmap)
library(RColorBrewer)
#identificar o arquivo no computador
> caminho_arquivo <- "C:/Users/Martin/Downloads/DEFICIENCIAS_MSP/deficiencias.xlsx"
# Instale o pacote se ainda não o tiver feito
install.packages("readxl")
# Carregue o pacote
library(readxl)
#lendo o arquivo
dadosDef<- read_excel(caminho_arquivo)
head (dadosDef)
#O conjunto de dados tem 33 varaveis
#Carregando o shapefile
install.packages("sf")
library(sf)
DEF <- st_read("C:/Users/Martin/Downloads/DEFICIENCIAS_MSP/MSP_AreaPond.shp")

```

```

#Identificando o tipo do objeto
class(dadosDef)
head(dadosDef)
#Construindo geometria para o arquivo
install.packages("ggplot2")
library("ggplot2")
ggplot()+
  geom_sf(data = DEF, colour = "black", fill = "orange") #para plotar Def
dados_sf<- st_as_sf(DEF)
#Identificando quais os titulos dos nomes das variaveis
names(dadosDef)
#Atribuindo os dados a um novo objeto
dadosDef<- dadosDef %>%
  #Instalar pacote que permite rodar o select
  install.packages("dplyr")
library("dplyr")
  #Selecionando apenas as colunas das varáveis que contem medidas
dadosDef<- dadosDef %>%
  select(COD_AREAPOND,                                     p_BRANCOS,
         p_NAOBRANCOS,p_DEFVIS,p_DEFVIS_BR,p_DEFVIS_NBR,p_DEF_AUD,p_DEFAUD_B
         R,p_DEFAUD_NBR,p_DEFCAMIN,p_DEFCAMIN_BR,p_DEFCAMIN_NBR,
         p_DEFMENTAL,
         p_DEFMENTAL_BR,p_DEFMENTAL_NBR,RENTA_MENSAL_V6529_mean,RENTA_NA
         OBR_mean,RENTA_BR_mean,)

#Transformando cod_area_pond em character
dadosDef$COD_AREAPOND <- as.character(dadosDef$COD_AREAPOND)
dadosDef$COD_AREAPOND <- as.character(dadosDef$COD_AREAPOND)
#Tabela criada com somente os dados de percentual conforme o select
head(dadosDef)
#Resumir quais dados nao temos
summary(dadosDef)

```

```

#Testando intervalo de classes (histograma das variaveis)

# Carregar o pacote 'devtools' pra trazer o histograma dos dados

library(devtools)

install.packages("devtools")

hist(novo_dados_oficial$p_BRANCOS, main=NULL)
hist(novo_dados_oficial$p_NAOBRANCOS, main=NULL)
hist(novo_dados_oficial$p_DEFVIS, main=NULL)
hist(novo_dados_oficial$p_DEFVIS_BR, main=NULL)
hist(novo_dados_oficial$p_DEFVIS_NBR, main=NULL)
hist(novo_dados_oficial$p_DEFAUD_BR, main=NULL)
hist(novo_dados_oficial$p_DEF_AUD, main=NULL)
hist(novo_dados_oficial$p_DEFAUD_NBR, main=NULL)
hist(novo_dados_oficial$p_DEFCAMIN, main=NULL)
hist(novo_dados_oficial$p_DEFCAMIN_BR, main=NULL)
hist(novo_dados_oficial$p_DEFCAMIN_NBR, main=NULL)
hist(novo_dados_oficial$p_DEFMENTAL, main=NULL)
hist(novo_dados_oficial$p_DEFMENTAL_BR, main=NULL)
hist(novo_dados_oficial$p_DEFMENTAL_NBR, main=NULL)
hist(novo_dados_oficial$RENTA_MENSAL_V6529_mean, main=NULL)
hist(novo_dados_oficial$RENTA_NAOBR_mean, main=NULL)
hist(novo_dados_oficial$RENTA_BR_mean, main=NULL)
hist(novo_dados_oficial$Defmentalbr, main=NULL)

#Inserindo uma a uma das variaveis

#Unir o arquivo shapefile ao arquivo sf mais completo pra obtermos um arquivo sf contendo as
variaveis de ambos mas antes, é necessário manter a mesma grafia da variavel em comum

#para alterar o nome da coluna cod_areapond

colnames(DEF)[colnames(DEF) == "CD_APONDE"] <- "COD_AREAPOND"

#Carregar pacote sf

library(sf)

class(dadosDef)

class (dados_sf)

```

```

class (DEF)

#Renomear a coluna no arquivo dados_sf
colnames(dados_sf)[colnames(dados_sf) == "CD_APONDE"] <- "COD_AREAPOND"
novo_dados_gerais <- left_join(dados_sf, dadosDef, by = "COD_AREAPOND")
head (novo_dados_gerais)

#para resumir os dados quantitativos
summary(novo_dados_gerais)

#Instalando tmap
install.packages("tmap")

#Carregando tmap
library(tmap)

#para definir o modo estático
tmap_mode(mode = "plot")

#Pulando a parte do histograma

#Realizando o teste com quantile,jeanks,equal e sd nas variaveis
#SELECCIONANDO CADA UMA DAS VARIAVEIS NO TESTE

#P_branco
map_cont <- tm_shape(novo_dados_gerais) + #indica o nome do arquivo shapefile que será
mapeado

  tm_fill(col = "p_BRANCOS",title = "p_BRANCOS",style = "cont") + #indica a variável e
escala contínua

  tm_layout(title = "Cont", title.size = 1.0, legend.title.size = 0.6, legend.text.size = 0.6,
legend.outside = TRUE)+ #define o layout

  tm_scale_bar()

map_eq <- tm_shape(novo_dados_gerais) + #indica o nome do arquivo shapefile que será
mapeado

  tm_fill(col = "p_BRANCOS",title = "p_BRANCOS",n = 7, style = "equal", legend.hist =
TRUE) +
  tm_layout(title = "Equal", title.size = 1.0, legend.title.size = 0.6, legend.text.size = 0.6,
legend.outside = TRUE)+

  tm_scale_bar()

```

```

map_qt <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_BRANCOS", title = "p_BRANCOS", n = 7, style = "quantile", legend.hist = TRUE) +
  tm_layout(title = "Quantile", title.size = 1.0, legend.title.size = 0.6, legend.text.size = 0.6, legend.outside = TRUE) +
  tm_scale_bar()
map_jk <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_BRANCOS", title = "p_BRANCOS", n = 7, style = "jenks", legend.hist = TRUE) +
  tm_layout(title = "Jenks", title.size = 1.0, legend.title.size = 0.6, legend.text.size = 0.6, legend.outside = TRUE) +
  tm_scale_bar()
map_sd <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_BRANCOS", title = "p_BRANCOS", n = 7, style = "sd", palette = "RdYlGn", legend.hist = TRUE) +
  tm_layout(title = "Standard \nde\aviation", title.size = 1.0, legend.title.size = 0.6, legend.text.size = 0.6, legend.outside = TRUE) +
  tm_scale_bar()
#organiza a apresentação dos mapas
tmap_arrange(map_cont, map_eq, map_qt, map_jk, map_sd, nrow = 3, ncol = 6, heights = unit(c(5, 5), c('cm', 'cm')))

#Tentando criar um mapa sem classes pra entender a distribuicao
#P_NAOBRANCOS
map_cont <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", style = "cont") +
  tm_layout(title = "Cont", title.size = 0.6, legend.title.size = 0.5, legend.text.size = 0.5, legend.outside = TRUE) +
  tm_scale_bar()

map_eq <- tm_shape(novo_dados_gerais) +

```

```

tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", n = 7, style = "equal",
legend.hist = TRUE) +
  tm_layout(title = "Equal", title.size = 0.6, legend.title.size = 0.5, legend.text.size = 0.5,
legend.outside = TRUE) +
  tm_scale_bar()

map_qt <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", n = 7, style = "quantile",
legend.hist = TRUE) +
  tm_layout(title = "Quantile", title.size = 0.6, legend.title.size = 0.5, legend.text.size = 0.5,
legend.outside = TRUE) +
  tm_scale_bar()

map_jk <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", n = 7, style = "jenks",
legend.hist = TRUE) +
  tm_layout(title = "Jenks", title.size = 0.6, legend.title.size = 0.5, legend.text.size = 0.5,
legend.outside = TRUE) +
  tm_scale_bar()

map_sd <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", n = 7, style = "sd", palette =
"RdYlGn", legend.hist = TRUE) +
  tm_layout(title = "Standard \n deviation", title.size = 0.6, legend.title.size = 0.5, legend.text.size
= 0.5, legend.outside = TRUE) +
  tm_scale_bar()

install.packages("tmap")
library(tmap)
tmap_arrange(map_cont, map_eq, map_qt, map_jk, map_sd, nrow = 3, ncol = 6, heights = unit(c(5,
5), c('cm', 'cm'))))
install.packages("grid")

```

```

library(grid)
map_def_branco <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_BRANCOS", title = "p_BRANCOS", style = "cont") + #indica a variável e
escala contínua
tm_scale_bar()
map_def_Nbrancos <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_NAOBRANCOS", title = "p_NAOBRANCOS", style = "cont") + #indica a
variável e escala contínua
tm_scale_bar()
map_def <- tm_shape(novo_dados_gerais) +
  tm_fill(col = "p_DEVIS", title = "p_DEVIS", style = "cont") + #indica a variável e escala
contínua
tm_scale_bar()
#para organizar os 3 mapas em uma linha
tmap_arrange(map_def_branco, map_def_Nbrancos, map_def, nrow = 3, heights = unit(c(8, 1),
c('cm', 'null')))
install.packages("dplyr")
library(dplyr)
head(novo_dados_gerais)
names(novo_dados_gerais)
#para selecionar apenas dados que não são NAs
novo_dados_oficial <- novo_dados_gerais %>% filter(!is.na(COD_AREAPOND)))
install.packages("dplyr")
library(dplyr)
#pra ver a dimensao do objeto criado
dim(novo_dados_oficial)
str(novo_dados_oficial)
# INICIANDO TESTE DE DISCRETIZACAO
library(classInt)
# Calculando objetos pelo classINT para P BRANCOS
pall <- c("wheat1", "red3")

```

```

opar <- par(mfrow=c(2,3))

brancos_fixed <- classIntervals(novo_dados_oficial$p_BRANCOS, n=8, style="fixed",
fixedBreaks=c(20, 30, 40, 50, 60, 70, 80, 90))
brancos_sd <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="sd")
brancos_equal <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="equal")
brancos_quant <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="quantile")
brancos_fisher <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="fisher")
brancos_jenks <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="jenks")
brancos_dpih <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="dpih")
brancos_headtails <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="headtails")
brancos_maximum <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="maximum")
brancos_kmeans <- classIntervals(novo_dados_oficial$p_BRANCOS, n=7, style="kmeans")

# Teste do intervalo dos dados para p BRANCOS
print(jenks.tests(brancos_fixed))
print(jenks.tests(brancos_sd))
print(jenks.tests(brancos_equal))
print(jenks.tests(brancos_quant))
print(jenks.tests(brancos_jenks))
print(jenks.tests(brancos_kmeans))

# Calculando objetos pelo classINT para P NBRANCOS
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

nbrancos1_fixed <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="fixed",
fixedBreaks=c(0, 10, 20, 30, 40, 50, 70))
nbrancos1_sd <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="sd")

```

```

nbrancos1_equal <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="equal")
nbrancos1_quant      <-      classIntervals(novo_dados_oficial$p_NAOBRANCOS,      n=7,
style="quantile")
nbrancos1_fisher <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="fisher")
nbrancos1_jenks <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="jenks")
nbrancos1_dpih <- classIntervals(novo_dados_oficial$p_NAOBRANCOS, n=7, style="dpih")
nbrancos1_headtails      <-      classIntervals(novo_dados_oficial$p_NAOBRANCOS,      n=7,
style="headtails")
nbrancos1_maximum      <-      classIntervals(novo_dados_oficial$p_NAOBRANCOS,      n=7,
style="maximum")
nbrancos1_kmeans      <-      classIntervals(novo_dados_oficial$p_NAOBRANCOS,      n=7,
style="kmeans")

```

```

# Teste do intervalo dos dados para p NBRANCOS
print(jenks.tests(nbrancos1_fixed))
print(jenks.tests(nbrancos1_sd))
print(jenks.tests(nbrancos1_equal))
print(jenks.tests(nbrancos1_quant))
print(jenks.tests(nbrancos1_jenks))
print(jenks.tests(nbrancos1_kmeans))

```

```

# Calculando objetos pelo classINT para P DEFVIS
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defvis1_fixed      <-      classIntervals(novo_dados_oficial$p_DEFVIS,      n=5,      style="fixed",
fixedBreaks=c(0.0, 10.0, 20.0, 30.0, 40.0))
defvis1_sd <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="sd")
defvis1_equal <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="equal")

```

```

defvis1_quant <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="quantile")
defvis1_fisher <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="fisher")
defvis1_jenks <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="jenks")
defvis1_dpih <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="dpih")
defvis1_headtails <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="headtails")
defvis1_maximum <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="maximum")
defvis1_kmeans <- classIntervals(novo_dados_oficial$p_DEFVIS, n=5, style="kmeans")

# Teste do intervalo dos dados para p DEFVIS
print(jenks.tests(defvis1_fixed))
print(jenks.tests(defvis1_sd))
print(jenks.tests(defvis1_equal))
print(jenks.tests(defvis1_quant))
print(jenks.tests(defvis1_jenks))
print(jenks.tests(defvis1_kmeans))

library(classIntervals)
install.packages("classIntervals")
# Calculando objetos pelo classINT para P DEFVIS_BR
pall <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

# Carregar o pacote classInt
library(classInt)

# Calculando objetos pelo classINT para P DEFVIS_BR
pall <- c("wheat1", "red3")
opar <- par(mfrow = c(2, 3))

```

```

defvisbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 9, style = "fixed",
fixedBreaks = c(30, 40, 50, 60, 70, 80, 90, 100))
defvisbr1_sd <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "sd")
defvisbr1_equal <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "equal")
defvisbr1_quant <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "quantile")
defvisbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "fisher")
defvisbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "jenks")
defvisbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "dpih")
defvisbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "headtails")
defvisbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "maximum")
defvisbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFVIS_BR, n = 7, style = "kmeans")

```

```

# Teste do intervalo dos dados para p DEFVIS_BR
print(jenks.tests(defvisbr1_fixed))
print(jenks.tests(defvisbr1_sd))
print(jenks.tests(defvisbr1_equal))
print(jenks.tests(defvisbr1_quant))
print(jenks.tests(defvisbr1_jenks))
print(jenks.tests(defvisbr1_kmeans))

```

```

# Calculando objetos pelo classINT para P DEFVIS_NBR
pal1 <- c("wheat1", "red3")
opar <- par(mfrow = c(2, 3))

```

```

defvisnbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 9, style = "fixed",
fixedBreaks = c(30, 40, 50, 60, 70, 80, 90, 100))
defvisnbr1_sd <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "sd")

```

```

defvisnbr1_equal <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "equal")
defvisnbr1_quant <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "quantile")
defvisnbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "fisher")
defvisnbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "jenks")
defvisnbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "dpih")
defvisnbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "headtails")
defvisnbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "maximum")
defvisnbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFVIS_NBR, n = 7, style = "kmeans")

# Teste do intervalo dos dados para p DEFVIS_BR
print(jenks.tests(defvisnbr1_fixed))
print(jenks.tests(defvisnbr1_sd))
print(jenks.tests(defvisnbr1_equal))
print(jenks.tests(defvisnbr1_quant))
print(jenks.tests(defvisnbr1_jenks))
print(jenks.tests(defvisnbr1_kmeans))

# Carregar o pacote classInt
library(classInt)

# Calculando objetos pelo classINT para P DEFAUD
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defaud1_fixed <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="fixed",
fixedBreaks=c(2, 3, 4, 5, 6, 7, 8))

defaud1_sd <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="sd")
defaud1_equal <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="equal")
defaud1_quant <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="quantile")
defaud1_fisher <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="fisher")
defaud1_jenks <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="jenks")
defaud1_dpih <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="dpih")
defaud1_headtails <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="headtails")
defaud1_maximum <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7,
style="maximum")
defaud1_kmeans <- classIntervals(novo_dados_oficial$p_DEF_AUD, n=7, style="kmeans")

```

# Teste do intervalo dos dados para p DEFAUD

```

print(jenks.tests(defaud1_fixed))
print(jenks.tests(defaud1_sd))
print(jenks.tests(defaud1_equal))
print(jenks.tests(defaud1_quant))
print(jenks.tests(defaud1_jenks))
print(jenks.tests(defaud1_kmeans))

```

# Carregar o pacote classInt

```
library(classInt)
```

# Calculando objetos pelo classINT para P DEFAUD\_nBR

```

pall <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defNbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="fixed",
fixedBreaks=c(20, 35, 50, 65, 80, 95, 100))

```

```

defNbr1_sd <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="sd")
defNbr1_equal <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="equal")
defNbr1_quant <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="quantile")
defNbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="fisher")
defNbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="jenks")
defNbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="dpih")
defNbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="headtails")
defNbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="maximum")
defNbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFAUD_NBR, n=7, style="kmeans")

# Teste do intervalo dos dados para p DEFAUD_NBR
print(jenks.tests(defNbr1_fixed))
print(jenks.tests(defNbr1_sd))
print(jenks.tests(defNbr1_equal))
print(jenks.tests(defNbr1_quant))
print(jenks.tests(defNbr1_jenks))
print(jenks.tests(defNbr1_kmeans))

# Carregar o pacote classInt
library(classInt)

# Calculando objetos pelo classINT para P DEFAUD_BR
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defaudbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="fixed",
fixedBreaks=c(20, 35, 50, 65, 80, 95, 100))

defaudbr1_sd <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="sd")
defaudbr1_equal <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="equal")
defaudbr1_quant <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="quantile")
defaudbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="fisher")
defaudbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="jenks")
defaudbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7, style="dpih")
defaudbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7,
style="headtails")
defaudbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7,
style="maximum")
defaudbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFAUD_BR, n=7,
style="kmeans")

# Teste do intervalo dos dados para p DEFAUD_BR
print(jenks.tests(defaudbr1_fixed))
print(jenks.tests(defaudbr1_sd))
print(jenks.tests(defaudbr1_equal))
print(jenks.tests(defaudbr1_quant))
print(jenks.tests(defaudbr1_jenks))
print(jenks.tests(defaudbr1_kmeans))

# Carregar o pacote classInt
library(classInt)

# Calculando objetos pelo classINT para P DEFCAMIN
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defcam1_fixed <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="fixed",
fixedBreaks=c(1, 3, 5, 7, 9))

defcam1_sd <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="sd")
defcam1_equal <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="equal")
defcam1_quant <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="quantile")
defcam1_fisher <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="fisher")
defcam1_jenks <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="jenks")
defcam1_dpih <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="dpih")
defcam1_headtails <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="headtails")
defcam1_maximum <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5,
style="maximum")
defcam1_kmeans <- classIntervals(novo_dados_oficial$p_DEFCAVIN, n=5, style="kmeans")

```

```
# Teste do intervalo dos dados para p DEFCAVIN
```

```

print(jenks.tests(defcam1_fixed))
print(jenks.tests(defcam1_sd))
print(jenks.tests(defcam1_equal))
print(jenks.tests(defcam1_quant))
print(jenks.tests(defcam1_jenks))
print(jenks.tests(defcam1_kmeans))

```

```
# Carregar o pacote classInt
```

```
library(classInt)
```

```
# Calculando objetos pelo classINT para P DEFCAVIN_NBR
```

```

pa11 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defcnbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=8, style="fixed",
fixedBreaks=c(0, 10, 20, 30, 40, 50, 60, 70, 80))

```

```

defcnbr1_sd <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="sd")
defcnbr1_equal <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="equal")
defcnbr1_quant <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="quantile")
defcnbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="fisher")
defcnbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="jenks")
defcnbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="dpih")
defcnbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="headtails")
defcnbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="maximum")
defcnbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFCAVIN_NBR, n=7, style="kmeans")

# Teste do intervalo dos dados para p DEFCAVIN_NBR
print(jenks.tests(defcnbr1_fixed))
print(jenks.tests(defcnbr1_sd))
print(jenks.tests(defcnbr1_equal))
print(jenks.tests(defcnbr1_quant))
print(jenks.tests(defcnbr1_jenks))
print(jenks.tests(defcnbr1_kmeans))

# Carregar o pacote classInt
library(classInt)

# Calculando objetos pelo classINT para P DEFCAVIN_BR
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defcbr1_fixed <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="fixed",
fixedBreaks=c(20, 40, 60, 80, 100))

defcbr1_sd <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="sd")

defcbr1_equal <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="equal")

defcbr1_quant <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="quantile")

defcbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="fisher")

defcbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="jenks")

defcbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5, style="dpih")

defcbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5,
style="headtails")

defcbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5,
style="maximum")

defcbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFCAVIN_BR, n=5,
style="kmeans")

```

# Teste do intervalo dos dados para p DEFCAVIN\_BR

```

print(jenks.tests(defcbr1_fixed))
print(jenks.tests(defcbr1_sd))
print(jenks.tests(defcbr1_equal))
print(jenks.tests(defcbr1_quant))
print(jenks.tests(defcbr1_jenks))
print(jenks.tests(defcbr1_kmeans))

```

# Calculando objetos pelo classINT para P DEFMENTAL

```

pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

```

```

defmental1_fixed <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="fixed",
fixedBreaks=c(0, 0.5, 1.0, 1.5, 2))

defmental1_sd <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="sd")

```

```

defmental1_equal <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="equal")
defmental1_quant      <-      classIntervals(novo_dados_oficial$p_DEFMENTAL,      n=5,
style="quantile")
defmental1_fisher <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="fisher")
defmental1_jenks <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="jenks")
defmental1_dpih <- classIntervals(novo_dados_oficial$p_DEFMENTAL, n=5, style="dpih")
defmental1_headtails      <-      classIntervals(novo_dados_oficial$p_DEFMENTAL,      n=5,
style="headtails")
defmental1_maximum      <-      classIntervals(novo_dados_oficial$p_DEFMENTAL,      n=5,
style="maximum")
defmental1_kmeans      <-      classIntervals(novo_dados_oficial$p_DEFMENTAL,      n=5,
style="kmeans")

# Teste do intervalo dos dados para p DEFMENTAL
print(jenks.tests(defmental1_fixed))
print(jenks.tests(defmental1_sd))
print(jenks.tests(defmental1_equal))
print(jenks.tests(defmental1_quant))
print(jenks.tests(defmental1_jenks))
print(jenks.tests(defmental1_kmeans))

# Calculando objetos pelo classINT para P DEFMENTAL_BR
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

defmebr1_fixed <- classIntervals(novo_dados_oficial$p_DEFMENTAL_BR, n=6, style="fixed",
fixedBreaks=c(0, 20, 40, 60, 80, 100))
defmebr1_sd <- classIntervals(novo_dados_oficial$p_DEFMENTAL_BR, n=6, style="sd")
defmebr1_equal      <-      classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="equal")

```

```

defmebr1_quant      <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="quantile")
defmebr1_fisher     <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="fisher")
defmebr1_jenks      <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="jenks")
defmebr1_dpih <- classIntervals(novo_dados_oficial$p_DEFMENTAL_BR, n=6, style="dphi")
defmebr1_headtails  <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="headtails")
defmebr1_maximum    <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="maximum")
defmebr1_kmeans     <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_BR,      n=6,
style="kmeans")

# Teste do intervalo dos dados para p DEFMENTAL_BR
print(jenks.tests(defmebr1_fixed))
print(jenks.tests(defmebr1_sd))
print(jenks.tests(defmebr1_equal))
print(jenks.tests(defmebr1_quant))
print(jenks.tests(defmebr1_jenks))
print(jenks.tests(defmebr1_kmeans))

# Calculando objetos pelo classINT para P DEFMENTAL_NBR
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3))

defmeNbr1_fixed    <-  classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR,      n=7,
style="fixed", fixedBreaks=c(0, 20, 40, 50, 60, 80, 90))
defmeNbr1_sd <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7, style="sd")

```

```

defmeNbr1_equal <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="equal")
defmeNbr1_quant <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="quantile")
defmeNbr1_fisher <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="fisher")
defmeNbr1_jenks <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="jenks")
defmeNbr1_dpih <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="dpih")
defmeNbr1_headtails <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="headtails")
defmeNbr1_maximum <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="maximum")
defmeNbr1_kmeans <- classIntervals(novo_dados_oficial$p_DEFMENTAL_NBR, n=7,
style="kmeans")

# Teste do intervalo dos dados para p DEFMENTAL_NBR
print(jenks.tests(defmeNbr1_fixed))
print(jenks.tests(defmeNbr1_sd))
print(jenks.tests(defmeNbr1_equal))
print(jenks.tests(defmeNbr1_quant))
print(jenks.tests(defmeNbr1_jenks))
print(jenks.tests(defmeNbr1_kmeans))
library (classInt)

# Calculando objetos pelo classINT para RENDA_MENSAL_V6529_MEAN
pal1 <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3)) # Adicionando o parêntese de fechamento aqui

renda1_fixed <- classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean, n=6,
style="fixed", fixedBreaks=c(0, 1000, 5000, 10000, 15000, 20000))

```

```

renda1_sd    <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="sd")
renda1_equal  <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="equal")
renda1_quant   <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="quantile")
renda1_fisher  <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="fisher")
renda1_jenks   <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="jenks")
renda1_dpih    <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,  n=6,
style="dpih")
renda1_headtails <- classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean, n=6,
style="headtails")
renda1_maximum  <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean,
n=6, style="maximum")
renda1_kmeans   <-  classIntervals(novo_dados_oficial$RENDAMENSAL_V6529_mean, n=6,
style="kmeans")

```

```

# Teste do intervalo dos dados para RENDAMENSAL_V6529_MEAN
print(jenks.tests(renda1_fixed))
print(jenks.tests(renda1_sd))
print(jenks.tests(renda1_equal))
print(jenks.tests(renda1_quant))
print(jenks.tests(renda1_jenks))
print(jenks.tests(renda1_kmeans))

```

```

# Calculando objetos pelo classINT para RENDAMENSAL_NBR_mean
pall <- c("wheat1", "red3")
opar <- par(mfrow=c(2,3)) # Adicionei o parêntese de fechamento aqui

```

```

rendanbr1_fixed <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="fixed", fixedBreaks=c(0, 1000, 5000, 10000, 15000, 20000))
rendanbr1_sd <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6, style="sd")
rendanbr1_equal <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="equal")
rendanbr1_quant <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="quantile")
rendanbr1_fisher <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="fisher")
rendanbr1_jenks <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="jenks")
rendanbr1_dpih <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="dpih")
rendanbr1_headtails <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="headtails")
rendanbr1_maximum <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="maximum")
rendanbr1_kmeans <- classIntervals(novo_dados_oficial$RENDAMENSAL_NBR_mean, n=6,
style="kmeans")

# Teste do intervalo dos dados para RENDAMENSAL_NBR_mean
print(jenks.tests(rendanbr1_fixed))
print(jenks.tests(rendanbr1_sd))
print(jenks.tests(rendanbr1_equal))
print(jenks.tests(rendanbr1_quant))
print(jenks.tests(rendanbr1_jenks))
print(jenks.tests(rendanbr1_kmeans))

# Adicionar a coluna de teste de Jenks pra cada variavel ao dataframe

```

```

library(dplyr)
#P_branco
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(BRANCOS = cut(p_BRANCOS, brancos_jenks$brks, include.lowest = TRUE))
names (novo_dados_oficial)
#p_Nbrancos
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(NBRANCOS1 = cut(p_NAOBRANCOS, nbrancos1_sd$brks, include.lowest = TRUE))
names (novo_dados_oficial)
#Defvis
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DEFVIS1 = cut(p_DEFVIS, defvis1_jenks$brks, include.lowest = TRUE))
names (novo_dados_oficial)
#DefVis_Br
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DEFVISBR1 = cut(p_DEFVIS_BR, defvisbr1_sd$brks, include.lowest = TRUE))
names (novo_dados_oficial)
#Def_vis_Nbr
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DEFVISnBR1 = cut(p_DEFVIS_NBR, defvisnbr1_jenks$brks, include.lowest = TRUE))
names (novo_dados_oficial)
#Defaud
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DEFaud1 = cut(p_DEF_AUD, defaud1_jenks$brks, include.lowest = TRUE))
names (novo_dados_oficial)
# Defaud_br
novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DEFaudbr1 = cut(p_DEFAUD_BR, defaudbr1_sd$brks, include.lowest = TRUE))
names (novo_dados_oficial)
# Defaud_nbr
novo_dados_oficial <- novo_dados_oficial %>%

```

```

  mutate(DEFaudnbr1 = cut(p_DEFAUD_NBR, defNbr1_sd$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # Defcamin
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(Defcamin1 = cut(p_DEFCAVIN, defcam1_sd$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # Defcaminbr
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(Defcbr1= cut(p_DEFCAVIN_BR, defcbr1_sd$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # DefcamNbr
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(Defcnbr= cut(p_DEFCAVIN_NBR, defcnbr1_sd$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # defmental
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(Defme1= cut(p_DEFMENTAL, defmental1_jenks$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # Defmentalbr
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(Defmebr1= cut(p_DEFMENTAL_BR, defmebr1_jenks$brks, include.lowest = TRUE))
  names (novo_dados_oficial)
  # DefmentalNBR
  novo_dados_oficial <- novo_dados_oficial %>%
  mutate(DefmeNbr1= cut(p_DEFMENTAL_NBR, defmeNbr1_jenks$brks, include.lowest =
TRUE))
  names (novo_dados_oficial)
  library (dplyr)
  # rendamensal
  novo_dados_oficial <- novo_dados_oficial %>%

```

```

mutate(renda1= cut(RENDA_MENSAL_V6529_mean, renda1_jenks$brks, include.lowest =
TRUE))

names (novo_dados_oficial)

# rendabr

novo_dados_oficial <- novo_dados_oficial %>%
  mutate(rendabr1= cut(RENDA_BR_mean, rendabr1_jenks$brks, include.lowest = TRUE))

names (novo_dados_oficial)

# rendaNbr

novo_dados_oficial <- novo_dados_oficial %>%
  mutate(rendaNbr1= cut(RENDA_NAOBR_mean, rendaNbr1_jenks$brks, include.lowest =
TRUE))

names (novo_dados_oficial)

#Exportar essa coluna como dataflame pro qgis

library(sf)

st_write(novo_dados_oficial, "dadosdis.shp")

print(novo_dados_oficial)

library(tmap)

# Criando os gráficos tmap

brancos_sd <- tm_shape(novo_dados_oficial, bbox = novo_dados_oficial)+

tm_fill()+
  tm_shape(novo_dados_oficial) + #indica o nome do arquivo shapefile que será mapeado
  tm_fill(col = "brancos_sd",title = "", style = "sd", palette = "Oranges", legend.hist = TRUE) +
  tm_layout(title = "Renda de n-brancos em SP", title.size = 0.6, legend.title.size = 0.7,
legend.text.size = 0.6, legend.outside = TRUE, bg.color = "aliceblue")+
  tm_shape(novo_dados_oficial)+

  tm_borders(col = "white", lwd = 1)+

  tm_credits("Fonte: IBGE SENSO 2010 - Arielly", position = c("RIGHT", "BOTTOM"))+
  tm_scale_bar(width = 0.2, position = c("0.71", "0.13"))

#para visualizar o mapa

brancos_sd

```

```

# Carregar o pacote 'tmap'
library(tmap)

# Exibir o mapa com as seguintes variáveis
tm_shape(novo_dados_oficial) + # Especifica o objeto sf a ser mapeado
  tm_fill(col = "DEFVIS1", # Especifica a coluna do shapefile a ser usada para preenchimento
          title = "% de deficientes visuais em São Paulo",
          style = "sd") # Define o estilo de preenchimento

# Criando os gráficos usando viridis para uma escala contínua com ggplot
# Carregar os pacotes necessários
library(ggplot2)
library(sf)
library(viridis)
library(ggspatial)

# Criando os gráficos tmap
defvis.sd <- tm_shape(novo_dados_oficial, bbox = novo_dados_oficial) +
  tm_fill() +
  tm_shape(novo_dados_oficial) + #indica o nome do arquivo shapefile que será mapeado
  tm_fill(col = "DEFVIS1", title = "DEFVIS1", style = "sd", palette = "Oranges", legend.hist =
TRUE) +
  tm_layout(title = "% de DEFVIS em São Paulo", title.size = 0.8, legend.title.size = 0.5,
legend.text.size = 0.5, legend.outside = TRUE, bg.color = "aliceblue") +
  tm_shape(novo_dados_oficial) +
  tm_borders(col = "white", lwd = 1) +
  tm_credits("Fonte: IBGE CENSO 2010 feito por Arielly", position = c("RIGHT",
"BOTTOM")) +
  tm_scale_bar(width = 0.2, position = c("0.71", "0.13"))

#para visualizar o mapa
defvis.sd

```

```

library(tmap)

# Criando o mapa básico
defvisbr.sd <- tm_shape(novo_dados_oficial) +
  tm_fill(col = "DEFVISBR1", title = "%", style = "sd", palette = "Oranges", legend.hist =
TRUE) +
  tm_borders(col = "white", lwd = 1) +
  tm_layout(title = "Deficientes visuais que se declaram brancos em SP",
  title.size = 0.8,
  legend.title.size = 0.5,
  legend.text.size = 0.5,
  legend.outside = TRUE,
  bg.color = "aliceblue") +
  tm_credits("Fonte: IBGE CENSO 2010 por Arielly", position = c("RIGHT", "BOTTOM")) +
  tm_scale_bar(width = 0.2, position = c("0.71", "0.13"))

# Adicionando a rosa dos ventos
defvisbr.sd <- defvisbr.sd +
  tm_compass(position = c("RIGHT", "TOP"), type = "arrow", size = 0.5)

# Exibindo o mapa
defvisbr.sd

```

```

library(tmap)

# Criando o mapa básico
DEFaud1.jenks <- tm_shape(novo_dados_oficial) +
  tm_fill(col = "DEFaud1", title = "", style = "jenks", palette = "Oranges", legend.hist = TRUE) +
  tm_borders(col = "white", lwd = 1) +
  tm_layout(title = "Deficientes auditivos em SP",

```

```

title.size = 0.8,
legend.title.size = 0.5,
legend.text.size = 0.5,
legend.outside = TRUE,
bg.color = "aliceblue") +
tm_credits("Fonte: IBGE CENSO 2010 por Arielly", position = c("RIGHT", "BOTTOM")) +
tm_scale_bar(width = 0.2, position = c("0.71", "0.13"))

# Adicionando a rosa dos ventos
DEFaud1.jenks <- DEFaud1.jenks +
tm_compass(position = c("RIGHT", "TOP"), type = "arrow", size = 0.5)

# Exibindo o mapa
DEFaud1.jenks

# Criando os gráficos tmap
renda1.jenks <- tm_shape(novo_dados_oficial, bbox = novo_dados_oficial) +
tm_fill() +
tm_shape(novo_dados_oficial) + #indica o nome do arquivo shapefile que será mapeado
tm_fill(col = "renda1", title = "", style = "jenks", palette = "Oranges", legend.hist = TRUE) +
tm_layout(title = "Renda geral em SP", title.size = 0.6, legend.title.size = 0.7, legend.text.size =
0.6, legend.outside = TRUE, bg.color = "aliceblue") +
tm_shape(novo_dados_oficial) +
tm_borders(col = "white", lwd = 1) +
tm_credits("Fonte: IBGE CENSO 2010 - Arielly", position = c("RIGHT", "BOTTOM")) +
tm_scale_bar(width = 0.2, position = c("0.71", "0.13"))

#para visualizar o mapa
renda1.jenks

```

```

# Criando o mapa
renda1.jenks <- tm_shape(novo_dados_oficial, bbox = novo_dados_oficial) +
  tm_fill(col = "renda1",
  title = "",
  style = "jenks",
  palette = "Oranges",
  legend.hist = TRUE) +
  tm_layout(title = "Renda geral em SP",
  title.size = 0.6,
  legend.title.size = 0.7,
  legend.text.size = 0.6,
  legend.outside = TRUE,
  bg.color = "aliceblue") +
  tm_shape(novo_dados_oficial) +
  tm_borders(col = "white", lwd = 1) +
  tm_credits("Fonte: IBGE CENSO 2010 por Arielly", position = c("RIGHT", "BOTTOM")) +
  tm_scale_bar(width = 0.2, position = c("0.71", "0.13")) +
  tm_compass(position = c("RIGHT", "TOP"), type = "arrow", size = 0.5)

# Visualizando o mapa
renda1.jenks
library(ggspatial)
#Para usar p_defvis (sem a variavel de jenks)
library(ggplot2)
library(ggspatial)
library(sf)

# Definindo uma paleta de cores em tons de laranja
orange_palette <- colorRampPalette(c("yellow", "orange", "red"))(256)

ggplot(data = novo_dados_oficial) +
  geom_sf(aes(fill = p_DEFVIS_BR)) +

```

```

scale_fill_gradientn(colors = orange_palette) + # Usar a paleta de cores laranja personalizada
labs(
  title = "Pessoas brancas com deficiência visual em São Paulo-SP",
  fill = "% defvis brancos",
  caption = "Fonte: IBGE 2010 feito por ARIELLY"
) +
  theme_minimal() +
  annotation_scale(location = "bl", width_hint = 0.5) + # Adicionar escala no canto inferior
  esquerdo
  annotation_north_arrow(location = "br", which_north = "true",
    style = north_arrow_fancy_orienteering) # Adicionar rosa dos ventos no canto
  inferior direito

```

```

install.packages("viridis")
library(viridis)

# Definindo uma paleta de cores em tons de laranja
orange_palette <- colorRampPalette(c("yellow", "orange", "red"))(256)

ggplot(data = novo_dados_oficial) +
  geom_sf(aes(fill = p_DEFVIS_NBR)) +
  scale_fill_gradientn(colors = orange_palette) + # Usar a paleta de cores laranja personalizada
  labs(
    title = "Pessoas não brancas com deficiência visual em SP",
    fill = "% defvis n-brancos",
    caption = "Fonte: IBGE 2010 feito por ARIELLY"
) +

```

```

theme_minimal() +
  annotation_scale(location = "bl", width_hint = 0.5) + # Adicionar escala no canto inferior
  esquerdo
  annotation_north_arrow(location = "br", which_north = "true",
    style = north_arrow_fancy_orienteering) # Adicionar rosa dos ventos no canto
  inferior direito

ggplot(data = novo_dados_oficial) +
  geom_sf(aes(fill = cut(DEFVIS,
    breaks = c(20.0, 30.0, 40.0, 50.0, 60.0, 70.0, 80.0, 90.0, 100.0)),
    labels = c("10.0-30.0%", "30.1-50.0%", "50.1-70.0%", "70.1-90.0%",
    "90.1%+")))) +
  scale_fill_manual(values = viridis_pal()(6)) +
  labs(title = "Porcentual de deficientes visuais em São Paulo - SP", fill = "p_DEFVIS") +
  theme_minimal() +
  annotation_scale(location = "bl", width_hint = 0.5) +
  annotation_north_arrow(location = "br", which_north = "true",
    style = north_arrow_fancy_orienteering)

```

```

#CONSTRUINDO COEFICIENTES DE MORAN^S
install.packages("spdep")
library(spdep)
# Criacao do boxsplot
# Carregando os pacotes
install.packages("spdep")
library(spdep)
# Criar vizinhança
nb <- poly2nb(novo_dados_oficial)
# Converter vizinhança em lista de pesos

```

```

lw <- nb2listw(nb, style = "W", zero.policy = TRUE)

install.packages("RColorBrewer")
library(RColorBrewer)

# Calcular o coeficiente de Moran para BRANCOS:
I <- moran(novo_dados_oficial$p_BRANCOS, lw, length(nb), Szero(lw))[1]
I

moran.test(novo_dados_oficial$p_BRANCOS, lw, alternative="greater")
library(rgeoda)

#para calcular uma matriz de pesos do tipo 'queen'
queen_w <- queen_weights(novo_dados_oficial)

#para visualizar
summary(queen_w)

#para selecionar a coluna 'tmi' de 'coorte2'
percentualbr = novo_dados_oficial["p_BRANCOS"]

#para calcular o moran local da tmi
lisa_percentualbr <- local_moran(queen_w, percentualbr)

#para definir as cores
lisa_colors <- lisa_colors(lisa_percentualbr)

#para definir os rótulos
lisa_labels <- lisa_labels(lisa_percentualbr)
#para definir os clusters
lisa_clusters <- lisa_clusters(lisa_percentualbr)
#para plotar o mapa do Moran local para brancos

```

```
plot(st_geometry(percentualbr),
  col=sapply(lisa_clusters, function(x){return(lisa_colors[[x+1]])}),
  border = "#333333", lwd=0.2)
title(main = "Moran Local do percentual de pessoas brancas em SP")
legend('bottomleft', legend = lisa_labels, fill = lisa_colors, border = "#eeeeee")
```