



Pós-Graduação em Ciência da Computação

EDCLEY JOSÉ DA SILVA - UFPE

**UM ESTUDO COMPARATIVO DE TÉCNICAS DE VISUALIZAÇÃO DE
DISTRIBUIÇÕES PARA DADOS GEOGRÁFICOS**



Universidade Federal de Pernambuco
posgraduacao@cin.ufpe.br
<http://cin.ufpe.br/~posgraduacao>

Recife
2020

EDCLEY JOSÉ DA SILVA - UFPE

**UM ESTUDO COMPARATIVO DE TÉCNICAS DE VISUALIZAÇÃO DE
DISTRIBUIÇÕES PARA DADOS GEOGRÁFICOS**

Dissertação apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciências da Computação.

Área de Concentração: Mídia e Interação.

Orientador: Prof. Dr. Nivan Roberto Ferreira Júnior

Coorientador: Dr. Fábio Markus Nunes Miranda

Recife

2020

Catálogo na fonte
Bibliotecária Arabelly Ascoli CRB4-2068

S586e Silva, Edcley José da
Um estudo comparativo de técnicas de visualização de distribuições para dados geográficos / Edcley José da Silva – 2020.
85 f.: il. fig., tab.

Orientador: Nivan Roberto Ferreira Júnior
Dissertação (Mestrado) – Universidade Federal de Pernambuco. Cln. Ciência da Computação. Recife, 2020.
Inclui referências.

1. Visualização. 2. Dados geográficos. 3. Distribuição de dados. 4. Incerteza I. Ferreira Júnior, Nivan Roberto (orientador). II. Título.

006.7 CDD (22. ed.) UFPE-CCEN 2020-92

Edcley José da Silva

**“UM ESTUDO COMPARATIVO DE TÉCNICAS DE VISUALIZAÇÃO
DE DISTRIBUIÇÕES PARA DADOS GEOGRÁFICOS”**

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Ciência da Computação da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Mestre em Ciência da Computação

Aprovado em: 20/04/2020.

BANCA EXAMINADORA

Profa.Dra. Renata Maria Cardoso Rodrigues de Souza
Centro de Informática / UFPE

Prof. Dr. Jorge Luis Poco Medina
Escola de Matemática Aplicada / FGV

Prof. Dr. Nivan Roberto Ferreira Júnior
Centro de Informática / UFPE
(Orientador)

Dedico este trabalho ao meu avô materno Pedro Gonçalo da Silva (*in memoriam*) que me deixou no início do curso em 22/04/2018 e não pode ver seu primeiro neto Mestre. Onde quer que esteja este trabalho é para você, como na canção que gostava: - "Que as custas de uma enxada conseguiram ser doutor".

AGRADECIMENTOS

A Deus primeiramente e a nossa senhora de Fátima, a quem sou devoto. Agradeço imensamente ao meu orientador Prof. Nivan que desde o primeiro momento foi super atencioso comigo, desde nossa primeira reunião, jamais esquecerei todo cuidado, atenção, flexibilidade e controle para jamais deixar nosso objetivo escapar. Agradeço também por toda paciência ao longo dessa incrível jornada onde adquiri novos e imensos conhecimentos na área da visualização de dados. Sua humanidade também em situações difíceis como quando perdi meu avô no início do curso me mostraram mais que um orientador, um mestre. Sei que foi difícil esse processo de aprendizado de muitas e imensas novidades para um recém formado oriundo da engenharia de software, mas o apoio de Nivan entendendo e me ajudando dia-a-dia durante o curso seja presencial ou on-line me ajudaram a pouco a pouco ir me tornando o especialista que no final do curso esperava ser. Ao entrar imaginava que visualização era algo bem limitado e hoje agradeço a Nivan todo aprendizado que expandiu minha mente para compreender o leque de oportunidades que existem e a multidisciplinaridade que trazem novos e divertidos desafios para a visualização de dados. Não poderia deixar de agradecer também a Fábio que somou bastante nesse trabalho compartilhou muito conhecimento e sem ele o resultado não seria o mesmo. Agradeço ainda a Dona Fabrícia recepcionista do bloco E do CIn e Dona Kátia do Bloco D que sempre tornavam mais leves os dias, mais caloroso o clima e mais humano o nosso centro quando era exaustivo chegar às 06:00hs da manhã na universidade e voltar às 22:00hs. Também a toda equipe da sec-pós que com todo cuidado e zelo removiam todos impedimentos burocráticos. Aos amigos de Vitória do ônibus no período em que frequentei que também alegravam os dias e dividiam os pesos diários: Lizandra, Giva, Iury, Júnior, Aline, Leandro, Tayslane, Andreza, Dayvison, Amanda, Eduarda e David. Aos amigos da PG: Carlos, Moniky, Sara e as estatísticas M^a Beatriz e Adyla. A Iunaly e Iloane grandes amigas que tive o prazer de me reaproximar em nome da ciência. Gratidão imensa a Suzana minha amiga e orientadora da graduação que sempre me estimulou a me lançar em busca de novos desafios, conhecimentos e experiência que pudessem agregar a minha vida profissional. Também gostaria de agradecer a toda equipe do estágio onde através da engenharia e da governança da TI pude trabalhar diretamente com a visualização de dados e o impacto das tomadas de decisões que foram o estímulo para o projeto. Por fim, mas não menos importante (talvez mais) gostaria de agradecer aos que sempre estiveram comigo desde o princípio: minha família sal e luz, meus afilhados, meus pais que durante todo o curso fizeram tudo que estava ao alcance e foram sempre compreensivos com as abdições que era preciso fazer, e todos meus familiares de Pernambuco, Piauí e São Paulo.

RESUMO

Atualmente o avanço tecnológico revolucionou a maneira como são estudados os fenômenos naturais. Os fenômenos naturais podem ser representados através de distribuições de dados geográficos que são uma fonte rica em informações e podem ser explorados de diferentes maneiras uma delas é a representação de incerteza por meio da distribuição de probabilidade. Modelar a incerteza desse tipo de distribuição e representar em visualização geográfica é complicado porque os mapas, que são os tipos comuns de visualização geográfica, precisam do ambiente visual para representar o espaço geográfico não sobrando muitas formas de representar quaisquer outras informações. Uma das maneiras frequentemente utilizadas como solução é a sumarização estatística como a média e a variância, mas só sumarizar os dados pode não ser suficiente porque esconde comportamentos dos dados e gera ambiguidade. A ocultação da incerteza dos dados em visualização é justificada pela forma como a incerteza é representada que pode não ser compreendida pelo usuário. Foram propostas técnicas para representar distribuições, mas geralmente elas só representam a presença e a disseminação de incerteza. Estudos mostraram que é importante quantificar a incerteza porque melhora a tomada de decisão, algumas abordagens mais recentes baseadas em probabilidade de proporção dos dados, animação e interação se propuseram a fazer essa quantificação de probabilidade de modo mais preciso, mas não foram usadas, nem comparadas formalmente para dados geográficos. Assim o objetivo desse trabalho inclui: comparar qualitativamente as principais abordagens para visualizar distribuições de probabilidade no cenário geográfico, adaptar as abordagens recentemente propostas no contexto dos dados abstratos, para apoiar a quantificação da incerteza de tarefas analíticas e realizar um estudo de usuário que possa comparar técnicas quanto ao desempenho de cada uma. Os resultados indicam que quantificar incerteza com interação geralmente registra melhor desempenho do que outras técnicas e fatores como distância, tamanho e variação influenciam o desempenho das tarefas.

Palavras-chaves: Visualização. Dados Geográficos. Distribuição de dados. Incerteza.

ABSTRACT

Currently, technological advances have revolutionized the way natural phenomena are studied. Natural phenomena can be represented through distributions of geographic data that are a rich source of information and can be explored in different ways. One of them is the representation of uncertainty through the distribution of probability. Modeling the uncertainty of this type of distribution and representing it in geographic visualization is complicated because maps, which are the common types of geographic visualization, need the visual environment to represent geographic space and there are not many ways to represent any other information. One of the ways often used as a solution is statistical summarization such as mean and variance, but summarizing the data alone may not be enough because it hides the data's behavior and generates ambiguity. The concealment of the uncertainty of the data in visualization is justified by the way the uncertainty is represented that may not be understood by the user. Technical proposals have been proposed to represent distributions, but generally they only represent the presence and spread of uncertainty. Studies have shown that it is important to quantify uncertainty because it improves decision making, some more recent approaches based on probability of proportion of data, animation and interaction have proposed to make this quantification of probability more precisely, but have not been used or compared formally for geographic data. Thus the objective of this work includes: to qualitatively compare the main approaches to visualize probability distributions in the geographical scenario, to adapt the recently proposed approaches in the context of abstract data, to support the quantification of the uncertainty of analytical tasks and to carry out a user study that can compare techniques regarding the performance of each one. The results indicate that quantifying uncertainty with interaction generally records better performance than other techniques and factors such as distance, size and variation influence the performance of tasks.

Keywords: Visualization. Geographic data. Distribution of data. Uncertainty.

LISTA DE FIGURAS

Figura 1 – Representações comum de dados quantitativos ou categóricos em visualizações.	16
Figura 2 – Estudos de visualização de distribuição.	18
Figura 3 – Interface da <i>Pangloss</i> com uso de amostragem para distribuição de (MORITZ; FISHER, 2017)	19
Figura 4 – Formas usuais de visualização de distribuição de probabilidade.	20
Figura 5 – Propostas frequentistas para estimar em contagens.	21
Figura 6 – Classificação dos métodos de visualização de distribuição de dados geográficos por (ŚLUSARSKI; JURKIEWICZ, 2019) traduzida pelo autor.	22
Figura 7 – Abordagens clássicas de <i>choropleth</i>	22
Figura 8 – Diferentes técnicas de <i>choropleth</i> para distribuições de dados com incerteza retratada.	23
Figura 9 – Múltipla visualização por (MACEACHREN et al., 2005).	23
Figura 10 – Diferentes propostas de <i>glyph</i> para distribuições de dados geográficos com incerteza.	24
Figura 11 – Visualização utilizando mapa de pontos por (KIMERLING, 2009).	25
Figura 12 – Incerteza para dados geográficos com interação por (PAHINS; FERREIRA; COMBA, 2019).	25
Figura 13 – Solução utilizando <i>choropleth</i> apresentada distribuição de dados geográficos por (HUANG et al., 2019).	26
Figura 14 – Matriz de correlação por (HUANG et al., 2019)	27
Figura 15 – Plataforma proposta para representar incerteza com interação e mapa de calor por (CHEN et al., 2018).	28
Figura 16 – Estudo de dados hipotéticos em mapa por (KESSLER; LOTSTEIN, 2018).	29
Figura 17 – Regiões pulsantes de (KARDOS; MOORE; BENWELL, 2006) em três momentos diferentes.	30
Figura 18 – Tabela de classificação de tarefas de (NUSRAT; KOBOUROV, 2015) traduzida pelo autor.	33
Figura 19 – Visualização utilizando a técnica de densidade representada por pontos. fonte: o Autor.	34
Figura 20 – Visualização utilizando a técnica de mapas hipotéticos. fonte: o Autor.	35
Figura 21 – Visualização utilizando a técnica de interação. fonte: o Autor.	36
Figura 22 – Diagrama sequencial das etapas do estudo. Fonte: O autor (2020)	38
Figura 23 – Modelo de interface das perguntas para todas as visualizações. fonte: o Autor	39

Figura 24 – Erro relativo por técnica para tarefa de extrair valor <i>dataset</i> chuvas. Fonte: O autor (2020).	49
Figura 25 – Distribuição do tempo por técnica para tarefa de extrair valor <i>dataset</i> chuvas (com zoom na imagem mais a direita). Fonte: O autor (2020).	50
Figura 26 – Distribuição da medida de confiança por técnica para tarefa de extrair valor <i>dataset</i> chuvas. Fonte: O autor (2020).	51
Figura 27 – Erro relativo por técnica para tarefa de extrair valor <i>dataset</i> táxis. Fonte: O autor (2020).	51
Figura 28 – Distribuição do tempo por técnica para tarefa de extrair valor <i>dataset</i> táxis com zoom na imagem mais a direita. Fonte: O autor (2020).	53
Figura 29 – Distribuição da medida de confiança por técnica para tarefa de extrair valor <i>dataset</i> táxis. Fonte: O autor (2020).	53
Figura 30 – Erro relativo por técnica para tarefa de comparar distribuições <i>dataset</i> Chuvas. Fonte: O autor (2020).	54
Figura 31 – Distribuição do tempo por técnica para tarefa de comparar distribui- ções <i>dataset</i> chuvas (com zoom na imagem mais a direita). Fonte: O autor (2020).	55
Figura 32 – Distribuição da medida de confiança por técnica para tarefa de com- parar distribuições <i>dataset</i> chuvas. Fonte: O autor (2020).	56
Figura 33 – Erro relativo por técnica para tarefa de comparar distribuições <i>dataset</i> táxis. Fonte: O autor (2020).	56
Figura 34 – Distribuição do tempo por técnica para tarefa de comparar distribui- ções <i>dataset</i> táxis com zoom na imagem mais a direita. Fonte: O autor (2020).	58
Figura 35 – Distribuição da medida de confiança por técnica para tarefa de com- parar distribuições <i>dataset</i> táxis. Fonte: O autor (2020).	58
Figura 36 – Erro relativo por técnica para tarefa de encontrar extremos <i>dataset</i> chuvas. Fonte: O autor (2020).	59
Figura 37 – Distribuição do tempo por técnica para tarefa de encontrar extremos <i>dataset</i> chuvas com zoom na imagem mais a direita. Fonte: O autor (2020).	60
Figura 38 – Distribuição da medida de confiança por técnica para tarefa de encon- trar extremos <i>dataset</i> chuvas. Fonte: O autor (2020).	60
Figura 39 – Erro relativo por técnica para tarefa de encontrar extremos <i>dataset</i> táxis. Fonte: O autor (2020).	61
Figura 40 – Distribuição do tempo por técnica para tarefa de encontrar extremos <i>dataset</i> táxis com zoom na imagem mais a direita. Fonte: O autor (2020).	62
Figura 41 – Distribuição da medida de confiança por técnica para tarefa de encon- trar extremos <i>dataset</i> táxis. Fonte: O autor (2020).	63

Figura 42 – Distribuição do erro por técnica para tarefa de Estimar a Média <i>dataset</i> chuvas. Fonte: O autor (2020).	63
Figura 43 – Distribuição do tempo por técnica para tarefa de estimar a média <i>dataset</i> chuvas. Fonte: O autor (2020).	65
Figura 44 – Distribuição da medida de confiança por técnica para tarefa de estimar a média <i>dataset</i> chuvas. Fonte: O autor (2020).	65
Figura 45 – Erro relativo por técnica para tarefa de estimar a média <i>dataset</i> táxis. Fonte: O autor (2020).	66
Figura 46 – Distribuição do tempo por técnica para tarefa de estimar a média <i>dataset</i> táxis. Fonte: O autor (2020).	67
Figura 47 – Distribuição da medida de confiança por técnica para tarefa de estimar a média <i>dataset</i> táxis. Fonte: O autor (2020).	68
Figura 48 – Uso do fator de distâncias no estudo na técnica de mapa de pontos. Fonte: O Autor (2020).	69
Figura 49 – Fator de variação dos dados das regiões no estudo na técnica de mapa de pontos. Fonte: O Autor (2020).	69
Figura 50 – Representação do tamanho das regiões como fator na técnica de mapa de pontos. Fonte: O Autor (2020).	70
Figura 51 – Erro relativo por fatores para a técnica de mapa de pontos <i>dataset</i> chuvas. Fonte: O autor (2020).	70
Figura 52 – Distribuição do tempo por fatores para a técnica de mapas de pontos <i>dataset</i> chuvas. Fonte: O autor (2020).	71
Figura 53 – Erro relativo por fatores para a técnica de mapa de pontos <i>dataset</i> táxis. Fonte: O autor (2020).	72
Figura 54 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos <i>dataset</i> táxis. Fonte: O autor (2020).	73
Figura 55 – Erro relativo por fatores para a técnica de mapas hipotéticos <i>dataset</i> chuvas. Fonte: O autor (2020).	73
Figura 56 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos <i>dataset</i> chuvas. Fonte: O autor (2020).	74
Figura 57 – Erro relativo por fatores para a técnica de mapas hipotéticos <i>dataset</i> táxis. Fonte: O autor (2020).	75
Figura 58 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos <i>dataset</i> táxis. Fonte: O autor (2020).	76

LISTA DE TABELAS

Tabela 1 – Tarefas de usuário	31
Tabela 2 – Primeira parte - perguntas pessoais	39
Tabela 3 – Segunda parte - perguntas do estudo do usuário.	40
Tabela 4 – Sexo dos participantes - Quantidade x Técnicas	43
Tabela 5 – Experiência com estatística - Quantidade x Técnicas	44
Tabela 6 – Experiência com visualização - Quantidade x Técnicas	44
Tabela 7 – Nível de Escolaridade - Quantidade x Técnicas	44
Tabela 8 – Normalidade das distribuições da acurácia.	46
Tabela 9 – Normalidade das distribuições de tempo.	47
Tabela 10 – Normalidade das distribuições de medida de confiança.	47
Tabela 11 – Tarefa x Erro Médio por Técnicas organizado por <i>datasets</i>	48
Tabela 12 – Tarefa x Tempo Médio por Técnicas organizado por <i>datasets</i>	48
Tabela 13 – Tarefa x Medida de Confiança média por Técnicas organizado por <i>datasets</i>	49
Tabela 14 – Resultados dos Testes para Tarefa de extrair valor <i>dataset</i> chuvas.	50
Tabela 15 – Resultados dos testes para tarefa de extrair valor <i>dataset</i> táxis.	52
Tabela 16 – Resultados dos Testes para Tarefa de Comparar Distribuições <i>dataset</i> chuvas.	54
Tabela 17 – Resultados dos Testes para Tarefa de Comparar Distribuições <i>dataset</i> táxis.	57
Tabela 18 – Resultados dos Testes para Tarefa de encontrar extremos <i>dataset</i> chuvas.	59
Tabela 19 – Resultados dos Testes para Tarefa de encontrar extremos <i>dataset</i> táxis.	61
Tabela 20 – Resultados dos Testes para Tarefa de Estimar a Média <i>dataset</i> chuvas.	64
Tabela 21 – Resultados dos Testes para Tarefa de estimar a média <i>dataset</i> táxis.	66
Tabela 22 – Resultados dos testes entre os fatores estudados para a técnica de mapa de pontos no <i>dataset</i> chuvas	71
Tabela 23 – Resultados dos testes entre os fatores estudados para a técnica de mapa de pontos no <i>dataset</i> táxis.	72
Tabela 24 – Resultados dos testes entre os fatores estudados para a técnica de mapas hipotéticos <i>dataset</i> chuvas	74
Tabela 25 – Resultados dos testes entre os fatores estudados para a técnica de mapas hipotéticos <i>dataset</i> táxis.	75

LISTA DE ABREVIATURAS E SIGLAS

APAC	<i>Agência Pernambucana de Águas e Clima</i>
BR	<i>Brasil</i>
CDF	<i>Cummulative Density Function)</i>
EUA	<i>Estados Unidos da América</i>
HOPS	<i>Hypothetical Outcome Plots</i>
KS	<i>Kolmogorov–Smirnov</i>
KW	Kruskal-Wallis
MB	<i>Megabyte</i>
NYC	<i>Nova York</i>
W	Wilcoxon

SUMÁRIO

1	INTRODUÇÃO	15
1.1	OBJETIVOS	16
2	REFERENCIAL TEÓRICO	18
2.1	VISUALIZAÇÃO DE DISTRIBUIÇÕES DE DADOS	18
2.2	TÉCNICAS DE VISUALIZAÇÃO DE DISTRIBUIÇÕES PARA DADOS GE- OGRÁFICOS	21
2.2.1	Técnicas Estáticas	22
2.2.2	Técnicas Interativas	25
2.2.3	Técnicas Dinâmicas	28
3	DESIGN DO EXPERIMENTO	31
3.1	TAREFAS ANALÍTICAS	31
3.2	METÁFORAS VISUAIS APLICADAS	33
3.3	HIPÓTESES	37
3.4	DADOS	37
3.5	QUESTIONÁRIO QUALI-QUANTITATIVO	38
3.6	CONSIDERAÇÕES FINAIS	42
4	RESULTADOS E DISCUSSÕES	43
4.1	UNIVERSO DA PESQUISA E USUÁRIOS	43
4.2	ANÁLISE QUALITATIVA	44
4.2.1	Técnica de Interação	44
4.2.2	Percepções Técnica de Mapa de Pontos	45
4.2.3	Percepções Técnica de Mapas Hipotéticos	45
4.3	ANÁLISE QUANTITATIVA	46
4.3.1	Procedimento de Análise	46
4.4	ANÁLISE QUANTITATIVA	48
4.4.1	Tarefa de Extrair Valor - <i>dataset</i> Chuvas	49
4.4.2	Tarefa de Extrair Valor - <i>dataset</i> Táxis	51
4.4.3	Tarefa Comparar Distribuições - <i>dataset</i> Chuvas	54
4.4.4	Tarefa Comparar Distribuições - <i>dataset</i> Táxis	56
4.4.5	Tarefa Encontrar Extremos - <i>dataset</i> Chuvas	59
4.4.6	Tarefa Encontrar Extremos - <i>dataset</i> Táxis	61
4.4.7	Tarefa de Estimar a Média - <i>dataset</i> chuvas	63
4.4.8	Tarefa Estimar a Média - <i>dataset</i> Táxis	66

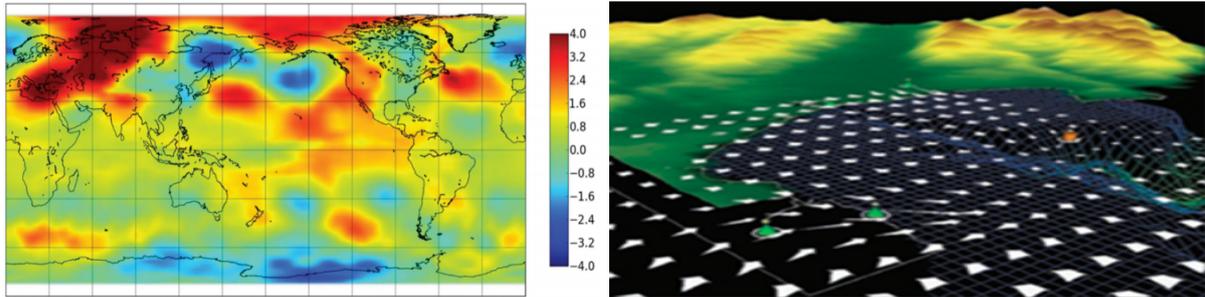
4.5	ANÁLISE QUANTITATIVA - FATORES DA TAREFA DE COMPARAR DIS- TRIBUIÇÕES	68
4.5.1	Resultados Técnica de mapa de pontos	70
4.5.2	Resultados Técnica de Mapas Hipotéticos	73
4.6	DISCUSSÕES	77
5	CONCLUSÃO	78
	REFERÊNCIAS	81

1 INTRODUÇÃO

Novas tecnologias de coletas de dados, poder computacional e análise visual revolucionaram o estudo dos fenômenos geográficos com novas técnicas e sistemas para a visualização de dados espaciais que permitem a análise de dados em um vasto conjunto de áreas, como saúde (FREIFELD et al., 2008), climatologia (MAYHUA et al., 2018), ecologia (FERREIRA et al., 2011), mobilidade urbana (FERREIRA et al., 2013), entre tantos outros.

Um aspecto onipresente na análise de dados (em particular em geográficos), que é comumente ignorado (HULLMAN, 2019), é a presença de aleatoriedade ou incerteza. Esta incerteza vem da aleatoriedade intrínseca presente nos fenômenos naturais e na variabilidade presente nos dados devido a completude, consistência, erros, modelagens, amostragem e etc. (MACEACHREN et al., 2005). Nesta dissertação, a concentração maior é em situações onde é possível modelar essa incerteza por meio de distribuições de probabilidade. Este também é um problema importante para o uso das estratégias recentes para dar suporte à visualização interativa de grandes volumes de dados baseadas em amostragem (MORITZ et al., 2017; FISHER et al., 2012) e agregações (WANG et al., 2016; PAHINS; FERREIRA; COMBA, 2019). Desta forma, um problema central na visualização de dados geográficos é como suportar a exploração visual de distribuições de probabilidade em mapas visto que os canais visuais dos mapas que geralmente são utilizados para representar dados geográficos frequentemente estão ocupados. Este problema não é de fácil resolução. De fato, mapas geográficos utilizam dos canais visuais posicionais da visualização para representar o contexto geográfico, o que restringe as possibilidades de representação.

As soluções mais comuns para representar distribuições de probabilidade em dados geográficos fazem uso de medidas de síntese, ou aqui chamadas de sumários estatísticos, como a média e a variância (KINKELDEY; MACEACHREN; SCHIEWE, 2014) (veja Fig. 1) Estes sumários são eficientes em reduzir a quantidade de dados a ser analisada, entretanto, é possível ter coleções de dados completamente diferentes com mesmas estatísticas como média e variância (MATEJKA; FITZMAURICE, 2017). Isto não só torna a representação ambígua, mas também pode esconder padrões importantes presentes nos dados (PAHINS; FERREIRA; COMBA, 2019). Além disso, e mais importante, estas representações não conseguem ser bem interpretadas, mesmo por indivíduos com treinamento estatístico (BELIA et al., 2005; CUMMING; FINCH, 2005; CORRELL; GLEICHER, 2014). Esta dificuldade se encontra no fato de que os usuários de tais visualizações devem realizar inferências mentais, a fim de realizar tarefas analíticas (comparação, ordenação, etc.), o que é uma tarefa não trivial e, em muitos casos, impossível. Por este motivo, tem sido defendido por muitos pesquisadores uma representação mais fidedigna da distribuição dos dados representados e, não somente, sumários estatísticos (ROUSSELET; FOXE; BOLAM, 2016; WEISSGERBER et al., 2015). Alguns trabalhos recentes propuseram soluções para este problema da quan-



(a) Visualização usando cores para representar inferências estatísticas por (POCO; MAYHUA; HEER, 2018). (b) Visualização usando *glyph* para representar a disseminação de incerteza por (ZHENG et al., 2016).

Figura 1 – Representações comum de dados quantitativos ou categóricos em visualizações.

tificação, no contexto de dados abstratos (não geográficos). Estas se baseiam no uso de ferramentas de amostragem e interatividade (FERREIRA; FISHER; KONIG, 2014) ou no uso da visão frequentista de probabilidade para construir visualizações (HULLMAN; RESNICK; ADAR, 2015; FERNANDES et al., 2018). A grande inovação das propostas feitas foi conseguir comunicar a incerteza e quantificá-la, tornando as visualizações dinâmicas ou mais intuitivas. Entretanto, até onde se sabe, elas não foram aplicadas para dados geográficos e, também, não foram formalmente comparadas.

1.1 OBJETIVOS

O objetivo geral deste trabalho é adaptar as principais soluções propostas para dados abstratos (não geográficos) para visualizar distribuições de probabilidade no contexto geográfico e, assim, resolver os problemas discutidos anteriormente e avaliar essas técnicas em termos de precisão, tempo e confiança por meio de uma comparação experimental (estudo de usuário).

Como objetivos específicos este trabalho tem por finalidade:

- Utilizar dados gerados por organizações simulando um ambiente real para dar suporte a tomada de decisões de tarefas analíticas que necessitam quantificar incertezas por meio de visualização espacial;
- Apresentar alternativas de distribuição de probabilidades para visualização de dados geográficos com base na literatura recente sobre visualização de dados abstratos.
- Levantar qualitativamente as impressões dos usuários para adaptações de visualizações realizadas;

O presente trabalho foi executado sob a supervisão do comitê de ética da UFPE tendo sido aprovado com o Certificado de Apresentação de Apreciação Ética (CAAE) Nº 23754819.5.0000.5208. Os capítulos restantes desta dissertação encontram-se estruturados da seguinte forma:

2 Referencial Teórico: apresenta os trabalhos realizados pela comunidade científica no desenvolvimento de métodos de otimizar a representação de incerteza para distribuição de dados geográficos.

3 Design do Experimento: explana sobre as metodologias e os métodos para realizar os objetivos, responder o problema de pesquisa, e confirmar as hipóteses deste trabalho.

4 Resultados e discussões: descreve e discute os resultados dos experimentos efetuados para análise e avaliação da comparação entre as técnicas aqui desenvolvidas.

5 Conclusão: apresenta as considerações finais sobre os principais tópicos abordados nesta dissertação, incluindo as contribuições alcançadas e as indicações de trabalhos futuros a serem executados.

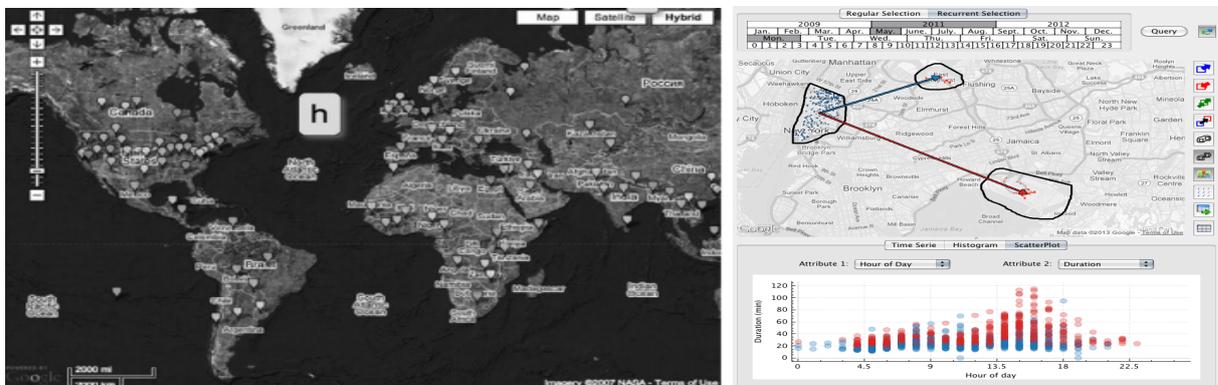
2 REFERENCIAL TEÓRICO

Projetar técnicas para visualizar distribuições de dados é um problema de pesquisa importante para dados em geral, sejam geográficos ou não. Esse capítulo descreve a literatura sobre estas técnicas, focando nas principais inovações, nas limitações e nas oportunidades de melhorias encontradas.

2.1 VISUALIZAÇÃO DE DISTRIBUIÇÕES DE DADOS

Distribuições de dados são objetos essenciais na análise de dados. Estes objetos matemáticos são comumente utilizados para além de representar conjuntos de dados modelar a variabilidade do conjunto e também para modelar a aleatoriedade/incerteza de fenômenos naturais em tarefas de quantificação.

Sistemas de visualização interativa de dados em geral fazem grande uso de agregações para sumarizar distribuições dos dados e, assim, construir representações visuais. Por exemplo, no estudo de (FREIFELD et al., 2008) um mapeamento de doenças infecciosas de escala global feita por mídias de internet é realizado para apoiar ações de saúde de acordo com os locais de registro de doenças Fig. 2a. Na ecologia, (FERREIRA et al., 2011) explora dados obtidos de modelos populacionais de pássaros do ponto de vista espacial e temporal. Finalmente, na mobilidade urbana (FERREIRA et al., 2013) a incerteza pode ser identificada através da exploração da concentração de viagens de táxis realizadas na cidade de Nova Iorque, que nos permite fazer questionamentos sobre aspectos humanos como fatores econômicos que levam a um determinado padrão nos movimentos temporais Fig. 2b. (POCO et al., 2014) e (WILLIAMS et al., 2013) buscam possibilitar a exploração de resultados de modelagens e previsões climáticas, além de possibilitar o estudo da variabilidade de previsões de modelos para diferentes abordagens e configurações paramétricas.



(a) Distribuição de doenças mapeadas em ferramenta de (b) Exploração de distribuição de dados de (FERREIRA et al., 2013)

Figura 2 – Estudos de visualização de distribuição.

Além dessa aplicação, existem também as estratégias para suportar visualização interativa de grandes quantidades de dados, seja por amostragem ou pela construção de estruturas de dados. Em seu trabalho, (WANG et al., 2016) cria uma estrutura baseada em cubos de dados chamada de Cubos Gaussianos. Esta estrutura consiste no uso de implementações eficientes de cubos de dados para armazenar estatísticas que possuem definição para a modelagem da distribuição dos dados através da abordagem paramétrica usando Gaussianas. Já (PAHINS; FERREIRA; COMBA, 2019) apresenta uma estratégia que estende a anterior, chamada de *Quantile Datacube Structure*, que codifica distribuições de forma não paramétrica (e aproximada), usando como base em estatísticas robustas como função de densidade acumulada e quartis. Uma outra estratégia para esse problema é a proposta por (MORITZ; FISHER, 2017), que usam amostragem progressiva, que é uma técnica de aproximar o valor da consulta por de agregações e pré cálculos de um conjunto de dados, para que em grandes volumes de dados o usuário não tenha que esperar até o final do processamento de toda a base para ter uma resposta. Assim o usuário recebe um valor prévio e ao final do processamento o resultado final é exibido e o usuário pode comparar o resultado prévio com o final. Os autores criam uma ferramenta de visualização chamada *Pangloss* (Fig. 3), que reúne visualizações com incerteza, filtros e outros recursos.

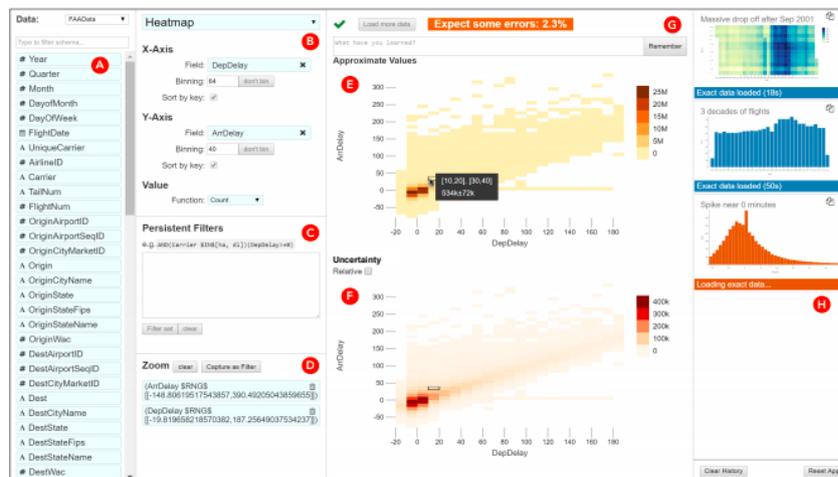


Figura 3 – Interface da *Pangloss* com uso de amostragem para distribuição de (MORITZ; FISHER, 2017)

A dificuldade apontada nesse cenário é uma aproximação precisa que consiga representar de modo mais fiel possível os resultados reais para dar suporte a uma tomada de decisão efetiva.

Entretanto, o uso de sumários estatísticos para representar distribuições, principalmente estatísticas de momento pode ser problemático porque os sumários escondem a variabilidade (a incerteza) e se você apresentar apenas estatísticas pontuais pode dar às pessoas uma falsa sensação de precisão sobre os dados (KAY et al., 2016). O uso de sumários estatísticos só consegue representar poucas características de uma distribuição, por exemplo, a média, a variância ((CORRELL; GLEICHER, 2014)), quartis ((WICKHAM;

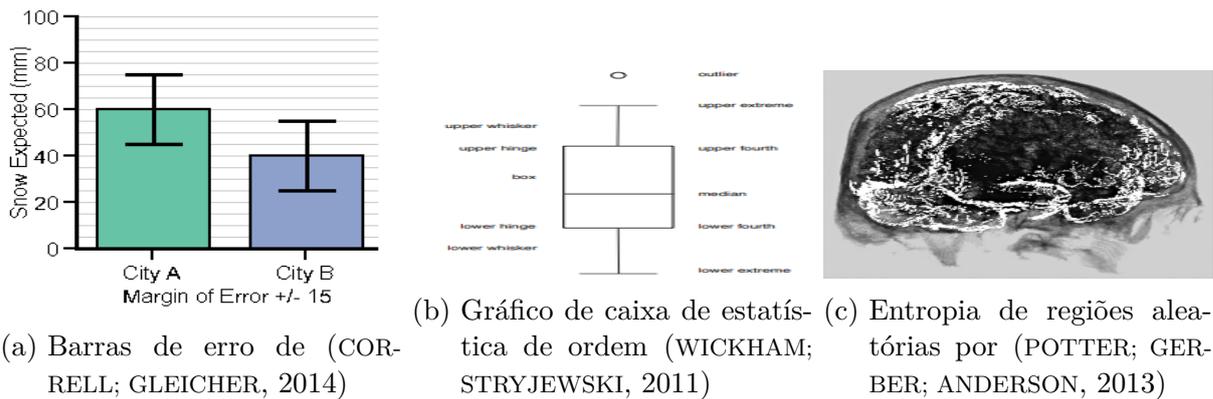


Figura 4 – Formas usuais de visualização de distribuição de probabilidade.

STRYJEWSKI, 2011)) e entropia ((POTTER; GERBER; ANDERSON, 2013)) Fig. 4. Isto torna essas visualizações dúbias (pois mais de uma distribuição tem os mesmos sumários estatísticos). (KALE; KAY; HULLMAN, 2019) mostram que diferentes e importantes organizações que precisam tomar decisões importantes fazem uso de sumários. Essas organizações ao compilarem e comunicarem esses sumários, acabam tomando uma série de decisões analíticas (tarefas), através da combinação de informações de estudos conduzidos com diferentes medidas ou em diferentes contextos. E o problema está nesta flexibilização que é possível na sumarização estatística, mas isso tem um preço, causa o que os autores chamam de “crise de replicação”, demonstrando como a flexibilidade na tomada de decisões produz vários e diferentes caminhos possíveis de decisões para as tarefas analíticas, que o tomador de decisão vai escolher a seu critério. Além disso, a abordagem de uso de sumários estatísticos em visualizações é difícil de ser interpretada (CUMMING; FINCH, 2005), mesmo para indivíduos com treinamento estatístico (BELIA et al., 2005). De fato, tarefas analíticas centrais na leitura de visualizações como estimar média, correlação e a comparação entre distribuições, são difíceis de serem realizadas. Para pensar adequadamente nas tarefas, os usuários precisam interpretar todas as perguntas e conclusões sobre os dados de maneira probabilística, mesmo com o auxílio de visualizações para auxiliar a quantificação de tarefas, ainda pode ser muito difícil porque pensar dessa forma adiciona uma grande complexidade ao processo de análise. Por este motivo, (FERREIRA; FISHER; KONIG, 2014) apresentam uma ferramenta, baseada em anotações interativas, para representar a incerteza. Esta ferramenta é baseada na ideia de quantificação automática da probabilidade de algumas tarefas analíticas através das interações.

Outras abordagens recentemente propostas para resolver esse problema usam a visão frequentista (discretizam a visualização para transformar o problema de estimar em contagem) são: o *quantile dot plot* Fig. 5a e o *Hypothetical Outcome Plots* Fig. 5b.

O *quantile dot plot* ((FERNANDES et al., 2018)) tenta melhorar a estimativa de probabilidade acumulada, usando uma adaptação dos *dot plots* (gráfico de pontos). Através de um estudo empírico, os autores mostraram que através dessa abordagem a precisão

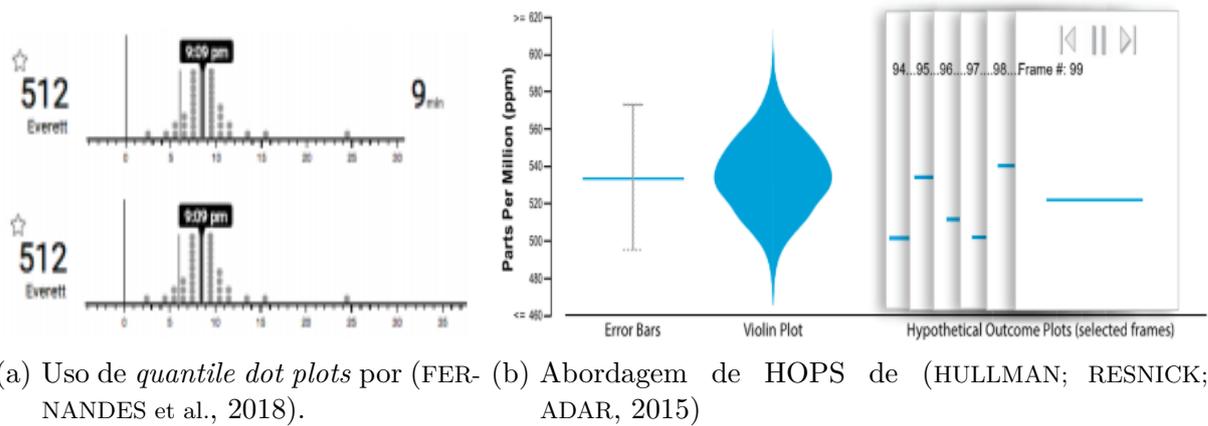


Figura 5 – Propostas frequentistas para estimar em contagens.

melhora e a incerteza é melhor comunicada aos usuários.

Já a técnica de HOPS (gráficos de cenários hipotéticos) faz uso de animação para retratar possíveis amostras da distribuição. Essa abordagem consegue ser mais intuitiva para usuários não treinados em estatística, porque permite uma maior percepção de comportamento da distribuição dos dados, uma boa percepção quanto aos limites dos dados além de permitir julgar correlação entre as distribuições, o que não é possível em outras abordagens. A contrapartida é que o uso dessa técnica está limitado a uma certa quantidade de dados e requer muita atenção para acompanhar as animações. Para avaliar o desempenho dessa abordagem os autores realizam uma comparação com gráficos de barra e gráficos de violinos em tarefas de comparações para testar com qual delas o usuário consegue representar melhor a distribuição de probabilidades. O cenário de teste usou análises simples contendo apenas duas e três distribuições. Os resultados mostram que das 3 técnicas os usuários conseguem tem melhores resultados com a animação hipotética dos dados. A taxa de erros registrada pelos dados hipotéticos foi a menor das três, porém demorou mais tempo para que os usuários testados finalizassem o experimento.

2.2 TÉCNICAS DE VISUALIZAÇÃO DE DISTRIBUIÇÕES PARA DADOS GEOGRÁFICOS

Considerando o contexto geográfico, (ŚLUSARSKI; JURKIEWICZ, 2019) classificam os vários métodos para visualização de distribuições/incerteza entre estáticos, dinâmicos e interativos, cada qual de acordo com sua natureza. A classificação feita pelos autores também classifica os métodos de visualização quanto ao tipo de incerteza que representam e outras características Fig. 6. Para o contexto geográficos os tipos de incerteza são categorizados em três: posicional, de valor de atributo e temporal. A incerteza posicional diz respeito principalmente à precisão das coordenadas representadas. A incerteza de valor de atributo é a propriedade dos dados espaciais que reflete a correteza/variabilidade dos atributos associados às posições espaciais. A incerteza temporal está relacionada à alteração dos dados ao longo do tempo e expressa a ocorrência dos dados em comparação com a frequência

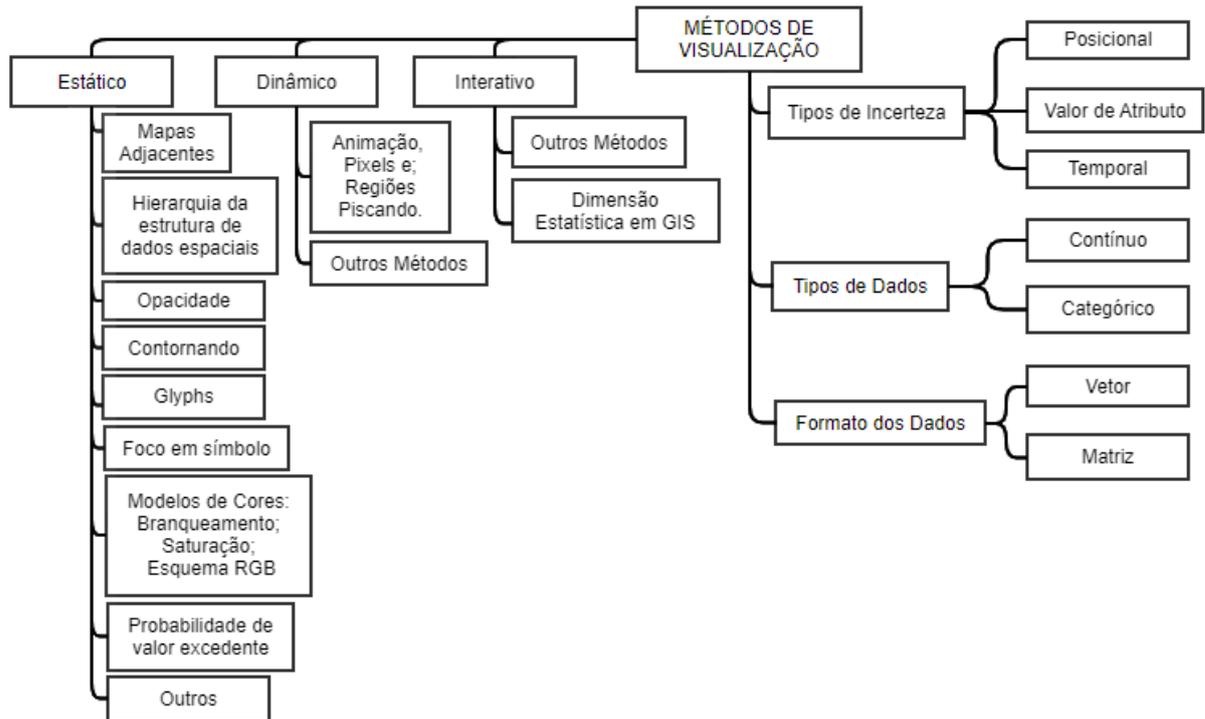
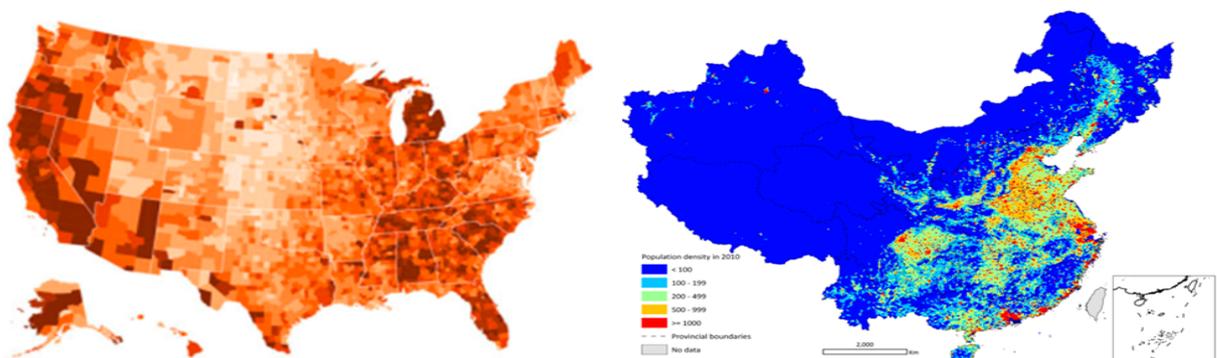


Figura 6 – Classificação dos métodos de visualização de distribuição de dados geográficos por (ŚLUSARSKI; JURKIEWICZ, 2019) traduzida pelo autor.

necessária de atualizações. Neste trabalho, o foco será a incerteza de valor de atributo, pois esse é o cenário mais comum em análise de dados. A seguir são apresentadas algumas técnicas utilizadas para visualizar incerteza de atributo de dados geográficos de acordo com a classificação de (ŚLUSARSKI; JURKIEWICZ, 2019): estáticas, interativas e dinâmicas.

2.2.1 Técnicas Estáticas

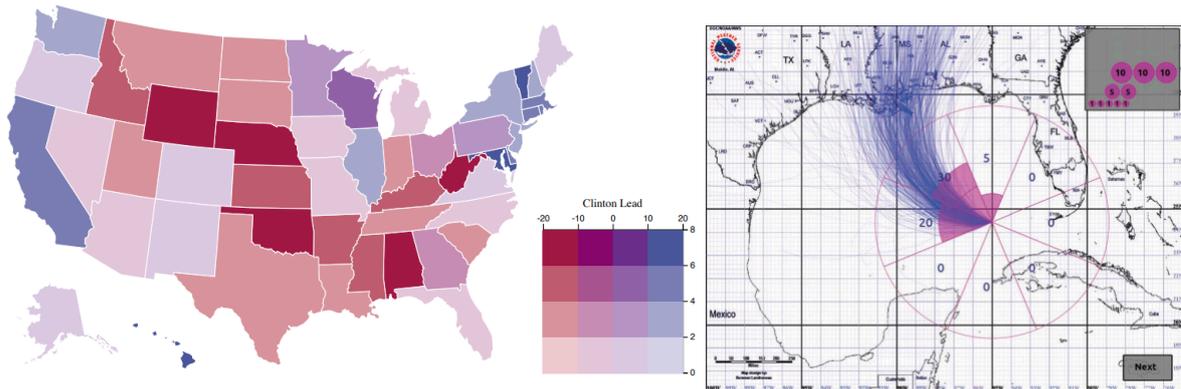


(a) Visualização de distribuição geográfica por (ZHENG et al., 2016). (b) Mapa de calor (HeatMap) por (CHEN et al., 2018)

Figura 7 – Abordagens clássicas de *choropleth*.

Um exemplo clássico de abordagem estática é a técnica de mapa coroplético ou *choropleth*, que é basicamente uma representação visual de um sumário estatístico de uma distribuição (correspondendo a uma região do mapa) com cores. Muitas variações desta técnica

foram propostas para representar mais informações das distribuições (KINKELDEY et al., 2015). Na Fig. 7a, (ZHENG et al., 2016) consideram o *choropleth* estático como mais dependente da intuição do usuário. Nessa proposta, a média da distribuição de cada região é mapeada para uma cor que é usada para preencher os *pixels* que compõem o polígono correspondente. Na Fig. 7b os mesmos autores utilizam mapa de calor para mostrar a mudança social de densidade populacional. Nesse tipo de mapa os limites de polígonos dão lugar a concentração de ocorrência de um evento.



(a) Uso de escala multidimensional (x e y) para representar incerteza por (CORRELL; MORITZ; HEER, 2018) (b) Incerteza em previsão de furacão através de possíveis rotas em linhas por (COX; HOUSE; LINDELL, 2013).

Figura 8 – Diferentes técnicas de choropleth para distribuições de dados com incerteza retratada.

Uma terceira opção é o uso de uma paleta de cores bi-dimensional para representar não só a média, mas também alguma medida de espalhamento ao mesmo tempo (Fig. 8a).

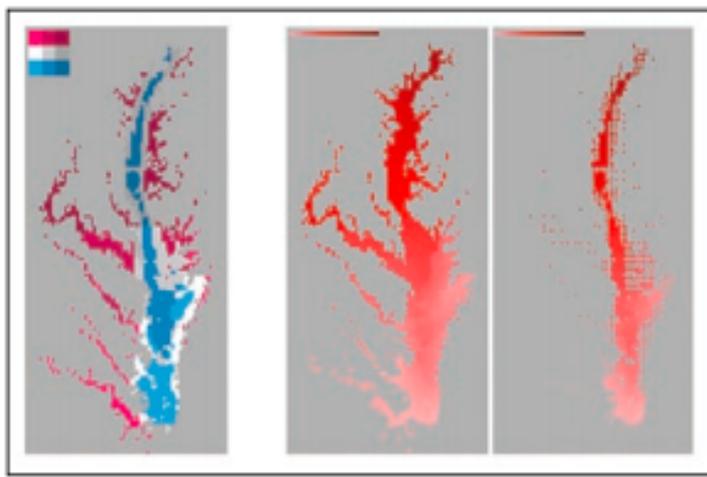


Figura 9 – Múltipla visualização por (MACEACHREN et al., 2005).

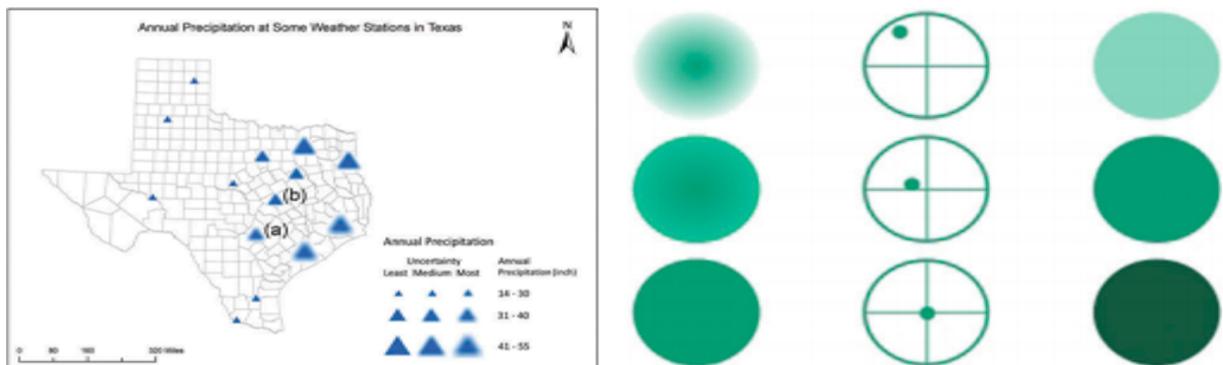
Foi encontrada ainda uma proposta de (COX; HOUSE; LINDELL, 2013) de fazer previsões com base em conhecimento sobre os dados em tempo real para exibir opções de comportamento que uma região pode assumir (Fig. 8b), uma proposta interessante, porém nosso foco não está em trajetórias de dados numéricos.

A múltipla visualização é outra variação de *choropleth* que se utiliza de mais de um quadro ao mesmo tempo, para representar as distribuições de dados com variáveis distintas, ou seja, mais de uma visualização posicionadas lado-a-lado que exibe in-

diversas visualizações de dados com variáveis distintas, ou seja, mais de uma visualização posicionadas lado-a-lado que exibe in-

formações diferentes sobre a mesma distribuição. Cada visualização exibe informações diferentes para que uma visualização possa ser complementada pela outra na comunicação da incerteza. Assim o usuário é capaz de tomar sua decisão comparando ao mesmo tempo a informação sobre mais de um ângulo, se o usuário tem dúvida sobre o que é mostrado em uma visualização pode conferir em outra e ter ou não uma certeza, como é mostrado pela Fig. 9 que representa a concentração de nitrogênio inorgânico na baía de Chesapeake-EUA e as incertezas relacionadas. Em (MACEACHREN et al., 2005) a múltipla visualização é apresentada como fator para melhoria da percepção do usuário quanto a risco e a incerteza. Entretanto, manter a consistência das visualizações de modo que usuários consigam compreender e se concentrar pode ser complexo.

Outro método de visualização estática é a técnica de *glyph* que utiliza de objetos ou símbolos que representem uma informação no contexto em que estão inseridos. Essa técnica, assim como *choropleth*, possui adaptações para representar incerteza: técnica de borrão (*Blur*), desfoque de símbolo, delimitação do símbolo, a junção de mais de uma delas e etc. Essas adaptações permitem que os símbolos representem mais de uma variável sobre a distribuição. A Fig. 10b mostra essa técnica e suas adaptações.



(a) Aplicação de *glyph* em mapa por (SCHOLZ; LU, 2014). (b) Tipos de *glyph* de incertezas de (KINKELDEY; MACEACHREN; SCHIEWE, 2014).

Figura 10 – Diferentes propostas de *glyph* para distribuições de dados geográficos com incerteza.

Entretanto, um problema comum em glyphs é o *overplotting*, que é a inserção de um objeto sobre o outro gerando inibição de elementos, devido a necessidade de representar muita informação e dispor de pouco espaço. Além disso, pela escala do mapa e falta de alinhamento entre os glyphs, comumente é difícil fazer comparações entre estes elementos gráficos e, portanto, de estimar a probabilidade em tarefas do usuário com precisão. Finalmente, o *glyph* pode ser muito simples e abstrato levando a problemas na comunicação da informação.

Outra técnica estática é a de dispersão de pontos (aqui chamada de mapa de pontos) (Fig. 11). Ela se baseia na técnica de *scatterplot* que é um gráfico de dispersão tradicional que representa cada objeto em um conjunto de dados com um ponto, posicionado

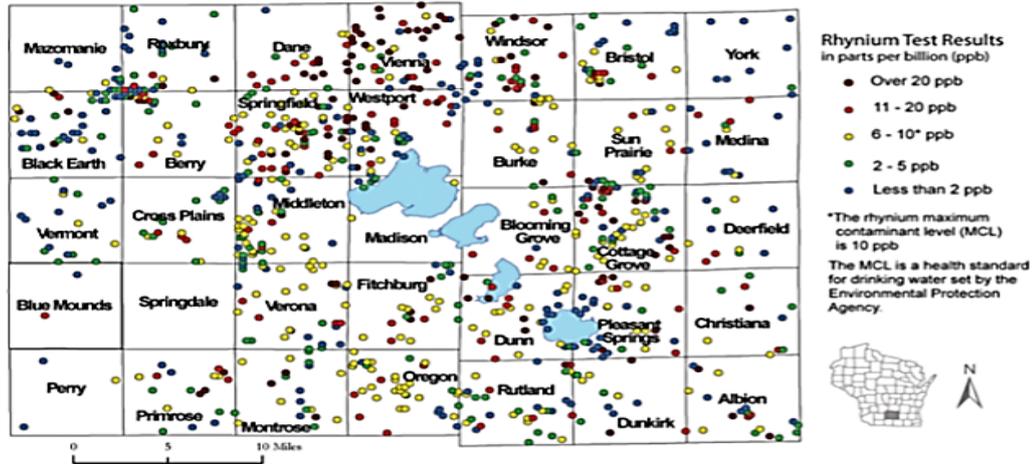


Figura 11 – Visualização utilizando mapa de pontos por (KIMERLING, 2009).

em duas dimensões ortogonais contínuas x e y (SARIKAYA; GLEICHER, 2018). No caso dos mapas de pontos, cada ponto é espalhado no mapa para representar atributos que ocorrem em localizações específicas. Os valores da distribuição são representados através da cor e quantidade de pontos em um determinado local isso ajuda a mostrar o comportamento da distribuição e assim comunicar incertezas ao usuário. As etapas fundamentais do mapeamento de pontos são selecionar o tamanho do ponto, determinar o valor da unidade de pontos (a quantidade de fenômeno representado por um ponto) e colocar o número correto de pontos de maneira a refletir com precisão as diferenças de densidade na distribuição geográfica (SEVERTSON; VATOVEC, 2012). (KIMERLING, 2009) afirma que nessa técnica a unidade de percepção, cor, proximidade, distribuição geográfica e relevância visual têm influências substanciais no que os participantes vêem e em suas crenças de risco resultantes.

2.2.2 Técnicas Interativas

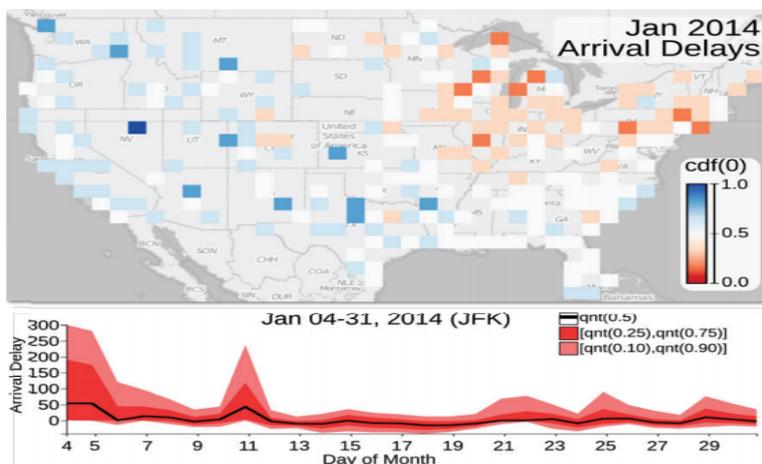


Figura 12 – Incerteza para dados geográficos com interação por (PAHINS; FERREIRA; COMBA, 2019).

(PAHINS; FERREIRA; COMBA, 2019) apresentam um tipo de variação de *choropleth* para distribuição de dados geográficos onde existe interação (Fig. 12). A visualização apresentada faz uso de um cursor que o usuário pode movimentar para ajustar o parâmetro de consulta (ou valor ou quantil desejado) e visualizar no mapa ou os quantis da distribuição ou a CDF de cada distribuição. É

uma aplicação prática do uso interativo da visualização para modelar a distribuição dos dados em qualquer cenário. Entretanto, os autores não fazem uma avaliação de quanto efetiva é esta avaliação.

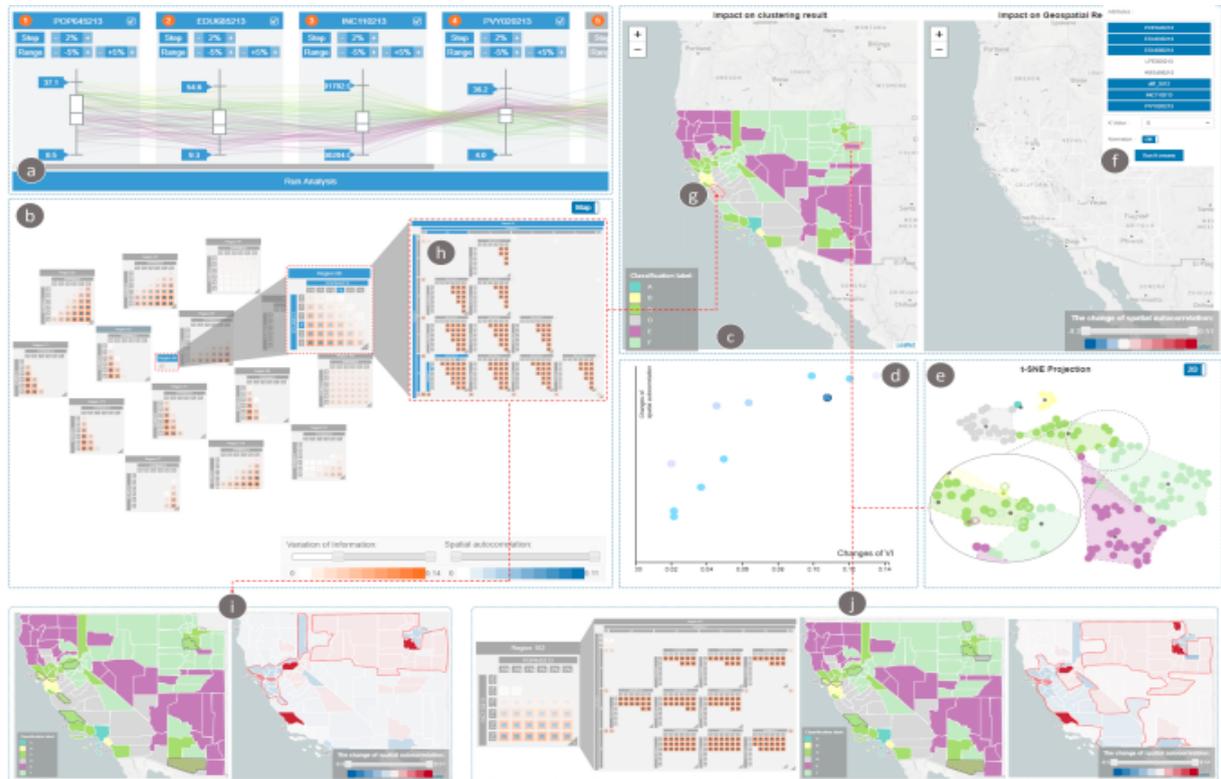


Figura 13 – Solução utilizando *choropleth* apresentada distribuição de dados geográficos por (HUANG et al., 2019).

Uma outra variação de *choropleth*, proposta por (HUANG et al., 2019), utiliza interação para comunicar o tipo de incerteza de atributos e como eles impactam nas regiões, a representação da distribuição de uma dada região de acordo com um tipo de estimativa ou classificação de quanto grande é o impacto da incerteza em uma região. O estudo aborda distribuições de dados do censo populacional dos Estados Unidos para tentar prever mudanças, encontrar padrões e perfis no grupo populacional de um conjunto de regiões dos Estados Unidos. Através de cálculo estatístico, como por exemplo a variância da distribuição, o impacto da incerteza é calculado, esses cálculos de impacto fazem uso de seleção de amostras aleatórias do conjunto de dados para fazer uma aproximação já que a base de dados é muito extensa. Mas não somente o impacto geográfico por meio de cores é mostrado nas regiões, também há um agrupamento das regiões correlacionadas sobre a incerteza por meio de um tipo de visualização que consegue mostrar as regiões que são mais prováveis de mudar dado o impacto da calculado da incerteza Fig. 13. O usuário é capaz de ver os impactos da incerteza nas regiões ao utilizar filtros por meio de coordenadas paralelas, que são um tipo de visualização onde dados são apresentados no mesmo eixo por meios de linhas de correlação. Esses filtros permitem mostrar o ta-

manho do impacto da incerteza dos atributos com base no histórico dos dados, isso pode ser feito inclusive para mais de uma variável e ter ainda correlação entre elas. A medida que o usuário utiliza a ferramenta as cores dos polígonos vão representando através da cor o impacto calculado pelo algoritmo com base na seleção que o usuário deseja saber.

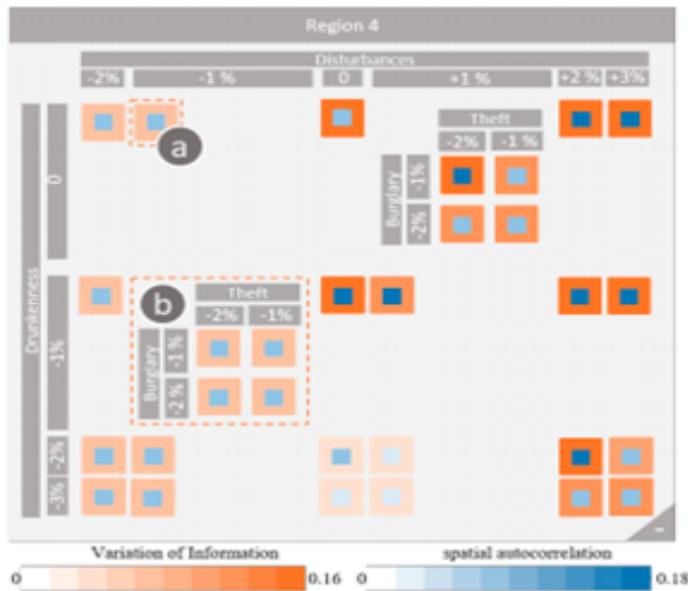


Figura 14 – Matriz de correlação por (HUANG et al., 2019)

Nesse caso as informações da distribuição geradas são exibidas em mais detalhes ao selecionar uma região, sob a forma de matriz (matriz de impacto da incerteza) que ajudam a representar os cálculos estatísticos que são feitos para tentar prever as chances de mudança de uma região sobre um determinado atributo. Dentre os atributos analisados podemos citar a escolaridade, preferência política e a porcentagem de pessoas nascidas no exterior que vivem em uma determinada região. As matrizes que são geradas mostram o impacto quantificado da autocorrelação espacial da distribuição e o impacto na variação das informações após aplicação de algum filtro. Todo esse processo envolve interatividade, uma vez que o uso da ferramenta do estudo requer interação por parte do usuário conforme mostra a Fig. 14. Utilizar de matrizes de correlação de impacto, agrupamentos de regiões e cálculo de impactos pode ser difícil de executar quando a dimensão dos dados aumenta, por ser tratar de distribuições de dados geográficos essa é uma tendência quase certa. Outro ponto que dificulta é o número de execuções para medir o impacto da incerteza e as chances de uma região mudar o comportamento de seus atributos, que pode ser longa demais. Também quando o número de atributos e o intervalo de incerteza aumentam não é mais interessante mostrar a matriz inteira devido a sobrecarga no número de matizes que dificulta o entendimento. Além disso, as visualizações projetadas podem não ser ótimas para representar e identificar as chances de mudanças, por que em alguns casos as cores podem ser indiferentes.

Em outro trabalho, levando em consideração o descolamento dos usuários através do uso de táxis (Origem/Destino) (CHEN et al., 2018) criam uma plataforma de visualização com interação para distribuição dos veículos e seus deslocamentos registrados. Para maior precisão de probabilidades das distribuições, o trabalho faz uso da técnica de mapa de calor que utiliza da concentração de pontos para aumentar localmente a intensidade das cores representadas e assim mostrar a incerteza.

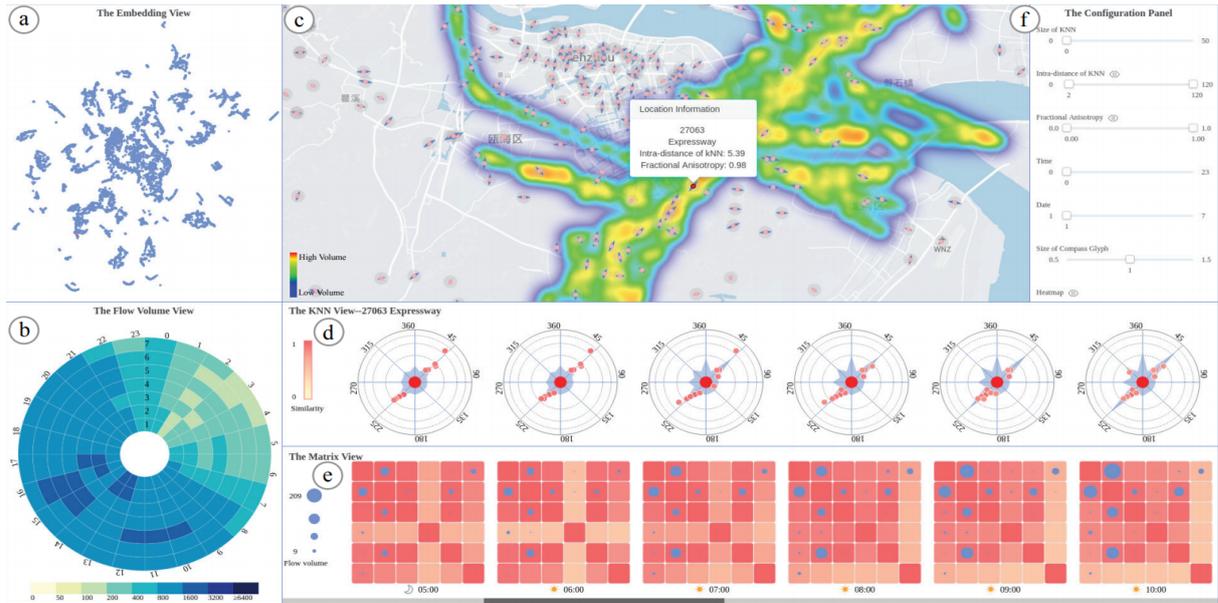


Figura 15 – Plataforma proposta para representar incerteza com interação e mapa de calor por (CHEN et al., 2018).

Nesse caso a ferramenta criada utiliza recursos de apoio como matrizes e algoritmos não automáticos para fazer predileções e ajudar a representar incertezas. Por ser parecida com a técnica de dispersão de pontos o uso da técnica de mapa de calor implica nos mesmos problemas dos mapas de pontos como o *overplotting* e principalmente requer a ajuda de gráficos externos para conseguir visualizar outros atributos da distribuição uma vez que, o espaço geográfico nessa abordagem só permite representar um atributo. A plataforma implementada permite através de interação análises: geoespaciais, de padrões (de população), temporais, estatísticas, estruturadas e não estruturadas, fornecendo uma experiência analítica rica em contexto para os usuários. Nesse caso os autores fizeram adaptações das abordagens convencionais de análise visual para dados geográficos com foco em permitir consultas para tomar decisões mais assertivas e interativas sem quantificação de incerteza. A Fig. 15 extraída de (CHEN et al., 2018) mostra a ferramenta destacando o ponto 'c' como a representação da densidade, o ponto 'b' com o volume de fluxo das regiões, os pontos 'd' e 'e' classificando a tendência de correlação de incerteza e a matriz de impacto respectivamente e por fim o ponto 'f' com *sliders* que funcionam como filtros.

2.2.3 Técnicas Dinâmicas

Um exemplo das técnicas dinâmicas é apresentado no estudo de (KESSLER; LOTSTEIN, 2018) onde um grupo de pessoas é submetida a tomar decisões sobre a distribuição de probabilidades de rotas de táxis utilizando as coordenadas geradas via GPS em uma plataforma de geo-visualização. São testadas fluxos de animações que mudam frequentemente para mostrar o deslocamento real dos táxis e tentar fazer predileções, o estudo faz uma

breve comparação para medir a eficiência de comunicar incerteza partindo de um cenário completamente estático até atingir um cenário hipotético com animação Fig. 16. Os usuários deveriam prever a rota (os pontos) com maiores chances no mapa observando as mudanças dinâmicas. Em contrapartida, o estudo fez uso do mesmo cenário de modo estático e semi-dinâmico. Esse terceiro tipo combinava duas adaptações: o tamanho do símbolo fixado e a transparência mudando (uma espécie de *glyph*) para gerar a animação. Os resultados apontaram para a preferência dos usuários para a visualização estática por que os usuários consideraram mais confusa as visualizações com animações, porém relataram que para visualizar mudanças e correlações a animação é melhor. O foco da pesquisa era avaliar apenas a animação visual de pontos no mapa comparando visualizações de distribuição de probabilidade com e sem animação na tentativa de identificar qual a melhor e a pior para a percepção da incerteza. Os autores não abordam elementos diferentes de símbolos ou *glyphs* para comunicar incerteza. E nenhuma tarefa é atribuída para avaliação, os usuários precisam apenas responder perguntas relacionadas aspectos gerais das visualizações.



Figura 16 – Estudo de dados hipotéticos em mapa por (KESSLER; LOTSTEIN, 2018).

Outro estudo que utiliza abordagens dinâmicas é o de (KARDOS; MOORE; BENWELL, 2006). Usando distribuições do censo populacional da Nova Zelândia em 2001, os autores reúnem um grupo de participantes para avaliar visualizações de incertezas de uma região específica da Nova Zelândia e opinar se as visualizações eram úteis ou não para representar a incerteza, no caso de ser útil dar uma nota para a visualização. Para cada usuário nove visualizações das técnicas de incerteza de atributos foram avaliadas mapas adjacentes, sobreposição de textura, nitidez de imagem, sobreposição de neblina, mistura de *pixels*, saturação de cores, som, regiões piscando e animação (em ordem de aparência). O objetivo do experimento era avaliar se a técnica de regiões piscando (com 1.5 segundos de transição entre os quadros) era considerada a técnica mais útil para visualizar distribuições. Os resultados mostraram que a técnica de regiões pulsantes (Fig. 17) foi a única dos nove métodos de visualização de dados geográficos testados que tiveram uma pontuação de "útil" maior do que "não útil", superando ainda as outras técnicas de visualização

de incerteza de atributos em termos de velocidade de compreensão e eficácia geral. Uma limitação apontada é que a exibição de distribuições nessa técnica acaba sendo trêmula o que pode ser irritante para alguns usuários.

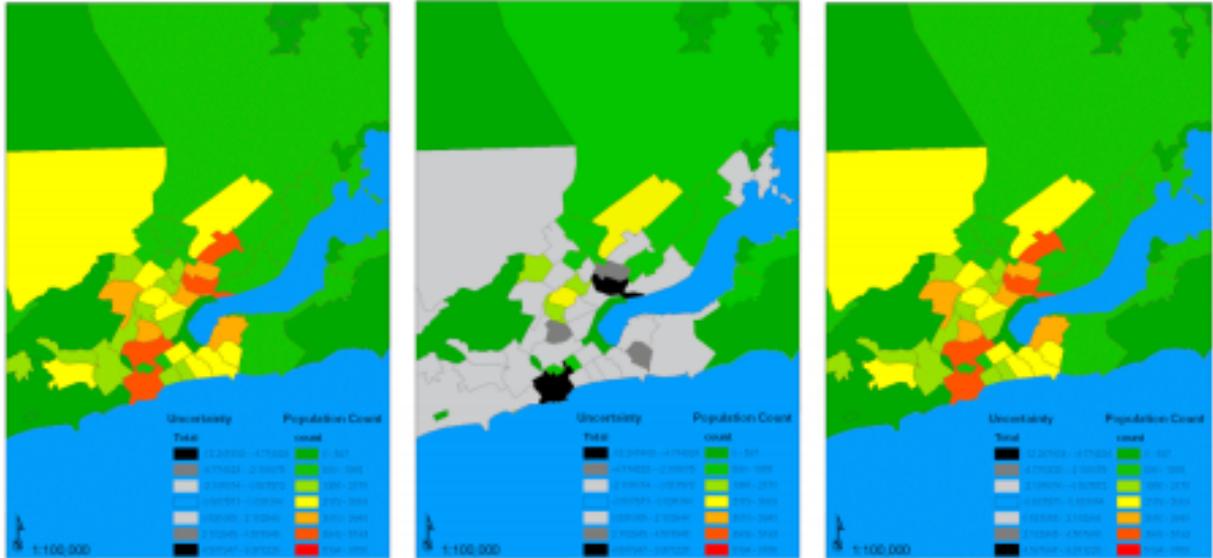


Figura 17 – Regiões pulsantes de (KARDOS; MOORE; BENWELL, 2006) em três momentos diferentes.

Assim como os métodos comuns de dados abstratos, os métodos propostos para visualizar distribuições de probabilidade para dados geográficos não dão suporte a quantificação de tarefas analíticas desse modo o objetivo deste trabalho é adaptar os métodos para dados abstratos que resolveram esse problema, para o cenário geográfico e realizar uma comparação entre eles.

3 DESIGN DO EXPERIMENTO

Neste trabalho, é utilizada uma metodologia de pesquisa para *design* de experimento semelhante à empregada nos trabalhos de (FERREIRA; FISHER; KONIG, 2014) e (HULLMAN; RESNICK; ADAR, 2015). Assim, são apresentadas no presente capítulo as tarefas analíticas através das quais será possível testar a eficácia das visualizações, a seleção e adaptação de metáforas visuais, as hipóteses formuladas e, finalmente, o design do experimento realizado para comparar as técnicas selecionadas.

3.1 TAREFAS ANALÍTICAS

As tarefas que seriam utilizadas no estudo foram definidas com base no estudo feito por (AMAR; EAGAN; STASKO, 2005), dos tipos de tarefas de maior interesse pelo usuário. Este trabalho trata de um catálogo de tarefas analíticas de baixo nível que fazem parte do processo de análise de dados em geral. As tarefas identificadas são listadas na Tab. 1.

Tabela 1 – Tarefas de usuário

TAREFA	DESCRIÇÃO
Recuperar valor	Dado um conjunto de casos, encontrar atributos desses casos.
Filtrar	Dadas algumas condições nos valores dos atributos, encontrar casos de dados que satisfaçam essas condições.
Calcular Valor Derivado	Dado um conjunto de casos de dados, calcule uma representação numérica agregada daqueles casos de dados. (Por exemplo, média).
Encontrar Extremos	Encontrar casos de dados que possuam um valor extremo (seja ele máximo ou mínimo) de um atributo em seu intervalo dentro dos dados conjunto.
Ordenar	Dado um conjunto de casos de dados, classificar de acordo com alguma métrica.
Determinar intervalo de alcance	Dado um conjunto de casos de dados e um atributo de interesse, encontrar o intervalo de valores dentro do conjunto.
Caracterizar Distribuição	Dado um conjunto de casos de dados e um atributo de interesse, caracterizar a distribuição dos valores do atributo ao longo do conjunto.

Localizar Anomalias	Identificar qualquer anomalia dentro de um determinado conjunto de casos de dados em relação a um determinado relacionamento ou expectativa, por exemplo número de <i>outliers</i> .
Agrupamento	Dado um conjunto de casos de dados, encontre agrupamentos de valores de atributo semelhantes.
Correlacionar	Dado um conjunto de casos de dados e dois atributos, determinar relações úteis entre os valores desses atributos.

Em seu trabalho, (FERREIRA; FISHER; KONIG, 2014) discutem a necessidade de traduzir estas tarefas para versões probabilísticas quando se lida com distribuições de probabilidade. Desta forma, a meta é dar suporte à quantificar a probabilidade de algum fato (objeto da tarefa analítica) acontecer. Por exemplo, a tarefa de "extrair valor" (listada na Tab.1) foi transformada para a de julgar a probabilidade de uma amostra de uma distribuição dada A ser menor que um valor fixo c , ou seja, avaliar a distribuição cumulativa da distribuição ($Pr(A \leq c)$). (FERREIRA; FISHER; KONIG, 2014) também discutem uma versão desta tarefa que envolve estimar a probabilidade da amostra estar em um intervalo dado, ou seja, $Pr(c_1 \leq A \leq c_2)$ De maneira semelhante, a tarefa de comparação, que em um contexto determinístico significa comparar dois valores, foi traduzida para julgar a probabilidade de que uma amostra de uma distribuição A seja menor do que uma amostra de uma outra distribuição B (i.e., $Pr(A < B)$). Outras tarefas traduzidas para o contexto probabilístico foram: identificar extremos e ordenação (ranqueamento).

No contexto de dados geográficos, (ANDRIENKO; ANDRIENKO, 2006) em seu trabalho classificam estas tarefas executando um refinamento, destacando as tarefas de comparação como sendo fatores-chave para identificar padrões e comportamentos a respeito de técnicas e dos próprios dados. É através da tarefa de comparação que é possível ver ainda segundo (ANDRIENKO; ANDRIENKO, 2006) possíveis associações e outros fatores. (NUSRAT; KOBOUROV, 2015) fazem uma classificação entre as possíveis tarefas de interpretação de informações em dados geográficos. As tarefas são organizadas pelos autores por cores de acordo com a similaridade das tarefas e por dimensões de acordo com a forma como as tarefas se relacionam com as dimensões, que são quatro: objetivos, significado, características e cardinalidade dos dados. A Fig. 18 mostra a classificação de tarefas discutida onde é possível ver a relação entre a tarefa seu objetivo (quanto a exploração), significado (quanto a análise dos dados), características (quanto ao nível de entendimento para o usuário) e cardinalidade (quanto ao número de variáveis) cada X mostra quando esses relacionamentos acontecem.

	Objetivos			Significado				Características		Cardinalidade		
	Explorar	Buscar	Extrair	Relação de Mapa	Relação de Dados	Navegação	Derivar	Baixo Nível	Alto Nível	Única	Múltipla	Todas
Reconhecimento	X	-	-	X	-	-	-	X	-	X	-	-
Detectar Mudanças	X	-	-	X	-	-	-	X	-	X	-	-
Comparar	X	-	-	-	X	-	-	X	-	-	X	-
Encontrar top-x	-	X	-	-	X	-	-	-	X	-	-	X
Filtrar	-	X	-	-	X	-	-	-	X	-	-	X
Agrupar	-	X	-	-	X	-	-	-	X	-	-	X
Localizar	-	X	-	-	-	X	-	X	-	-	-	X
Encontrar Adjacentes	-	X	-	-	-	X	-	-	X	-	X	-
Sumarizar	-	-	X	-	-	-	X	-	X	-	-	X
Identificar	-	-	X	-	-	-	X	X	-	X	-	-

Figura 18 – Tabela de classificação de tarefas de (NUSRAT; KOBOUROV, 2015) traduzida pelo autor.

Para o presente estudo, é seguida a abordagem de (FERREIRA; FISHER; KONIG, 2014) que também faz uso de algumas das tarefas de (ANDRIENKO; ANDRIENKO, 2006) e (NUSRAT; KOBOUROV, 2015), traduzindo as tarefas para versões probabilísticas. Desta forma, foram selecionadas as seguintes tarefas para avaliação das visualizações no contexto geográfico:

- Extrair Valor: $Pr(A \leq c)$, $Pr(A \geq c)$ e $Pr(c_1 < A < c_2)$;
- Comparar Distribuições: $Pr(A \leq B)$;
- Encontrar extremos (máximo e mínimo): Dentre uma coleção de distribuições $\{A_1, A_2, \dots, A_n\}$, qual maximiza $Pr(A_i \leq c)$;
- Estimar a média aritmética de uma distribuição dada (calcular valor derivado);

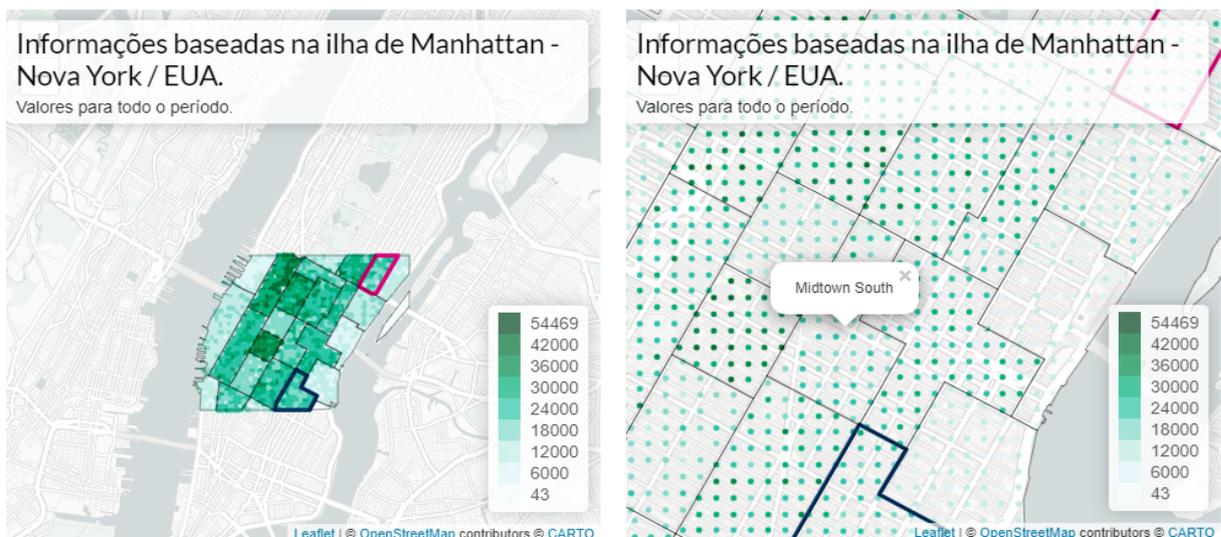
Estas tarefas foram selecionadas por serem comuns no contexto geográfico e terem sido utilizadas em estudos anteriores sobre visualizações de dados com incerteza (ŚLUSARSKI; JURKIEWICZ, 2019). É preciso reiterar, todavia, que nos estudos anteriores não foi dado o foco da estimativa/quantificação das probabilidades, mas sim a incerteza era interpretada de forma qualitativa.

3.2 METÁFORAS VISUAIS APLICADAS

Existe um grande número de técnicas de visualização de distribuições de probabilidade (veja discussão no Cap. 2.1). Estas variam não só pelos métodos, mas também para os

dados utilizados. Neste trabalho, é fixado o caso comum de análise visual de dados geográficos, onde se tem regiões geográficas limitadas (e.g., bairros, cidades, estados, etc.) e uma distribuição de probabilidade associada a cada uma dessas regiões. A metáfora visual mais comumente utilizada neste caso são os mapas coropléticos e suas variantes (*choropleth maps*). Neste cenário, os métodos mais comuns para representação de incerteza são o uso de transparências (para representar medidas de dispersão como a variância), paletas de cores bi-dimensionais (para representar tanto o valor esperado da distribuição quanto uma medida de dispersão), ou uso e múltiplos mapas (que mostram o valor esperado e a dispersão separadamente). Estas estratégias são análogas ao uso de visualizações baseadas em sumários estatísticos para dados uni-dimensionais como intervalos de confiança e box plots. Enquanto, eles mostram detalhes de uma distribuição, que são necessariamente ambíguos, e não dão suporte às tarefas analíticas discutidas anteriormente. Por este motivo, será tentando adaptar os desenvolvimentos de técnicas frequentistas e interativas que possam auxiliar na realização de tais tarefas.

A primeira técnica que é generalizada adapta a ideia de *dot plots* (KAY et al., 2016) para o contexto espacial, chamada de mapas de pontos (*dot maps*). Para representar visualmente a distribuição correspondente a uma região em particular, esta técnica desenha pontos posicionados aleatoriamente dentro da região. Cada ponto corresponde a uma amostra da distribuição. Os pontos são coloridos de acordo com o valor da amostra associada a ele. Quanto maior a incidência de um valor na distribuição daquela região mais pontos receberam uma determinada cor. A quantidade de pontos é proporcional a área em m² do polígono. A Fig. 19 mostra um exemplo de tal mapa.



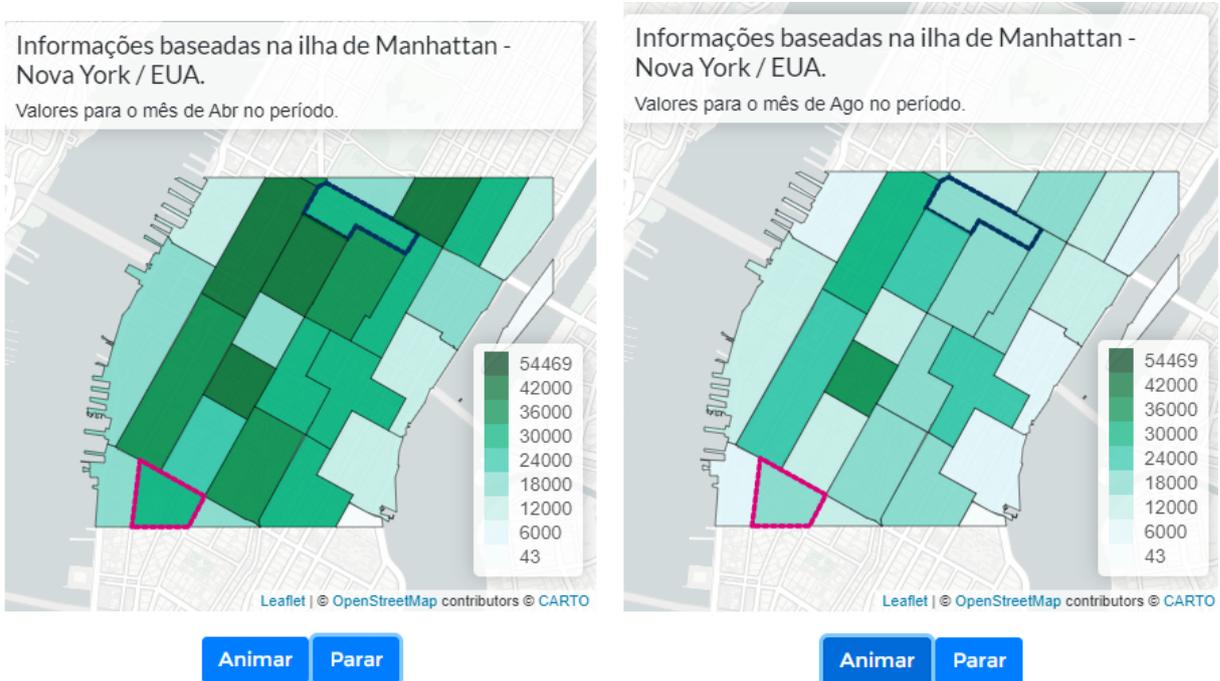
(a) Mapa de pontos usando pouco zoom para intensificar os pontos predominantes. (b) Mapa de pontos usando mais zoom para aumentar a precisão.

Figura 19 – Visualização utilizando a técnica de densidade representada por pontos. fonte: o Autor.

Note que essa visualização torna a execução das tarefas analíticas descritas anterior-

mente intuitivas, pois elas consistem basicamente em contar pontos dentro de uma região com uma certa coleção de cores.

A segunda técnica que será adaptada para o contexto geográfico é a técnica de gráficos hipotéticos (*hypothetical outcome plots*). Essa adaptação será chamada de mapas hipotéticos. Similarmente aos mapas de pontos, esta técnica também segue a abordagem frequentista. Entretanto, isto é feito tomando amostras das diferentes distribuições, usá-las como entrada para uma técnica visualização comum (no nosso caso, um mapa coroplético) como um possível *cenário hipotético*. A abordagem, então, usa animações para exibir diversos mapas hipotéticos. Existem várias maneiras de fazer a amostragem. Quando não existe correlação a priori, pode ser feita amostragem independente das diversas distribuições. Por outro lado, quando existe correlações a priori, é possível mostrar os cenários hipotéticos que correspondem às amostragens de todas as distribuições conjuntamente. Neste trabalho, é usada essa segunda opção. Como exemplo disso o estudo do número de corridas de táxi nos diferentes bairros da cidade de Nova Iorque para os diferentes meses do ano. Note que, existe uma clara correlação entre as distribuições correspondentes a cada mês. Desta forma, neste exemplo, a animação resultante apresenta 12 quadros que são apresentados de forma aleatória (ao final, a animação recomeça). O tempo de exposição para cada quadro foi definido como 660ms. Este tempo foi estabelecido através de um teste piloto com usuários.



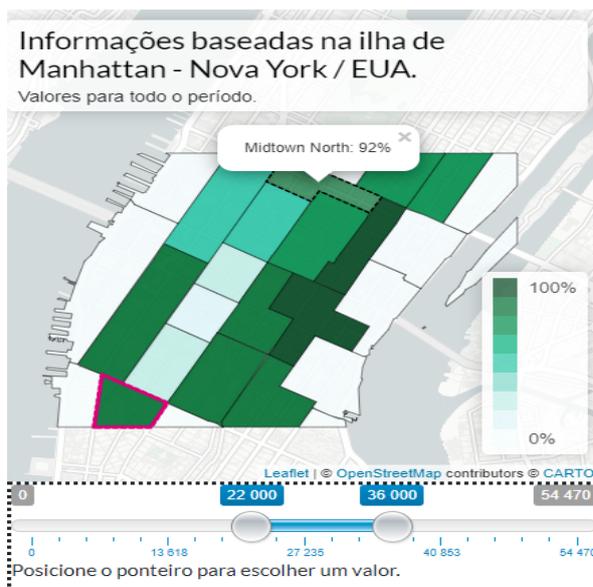
- (a) Mapas hipotéticos mostrando um quadro (*frame*) dos dados com a opção de parar selecionada. (b) Mapas hipotéticos com quadro capturado de outro mês, opção de animar é a selecionada.

Figura 20 – Visualização utilizando a técnica de mapas hipotéticos. fonte: o Autor.

Na implementação (Fig. 20) proposta por este trabalho, o usuário conta com a opção de parar em um determinado quadro para tirar dúvidas sobre um fato específico, em seguida pode retomar a animação quando quiser.

Além da atualização dos quadros a visualização exibe, ao passar o *mouse* por cima de uma determinada região, o valor corrente da distribuição e assim ter outra informação sobre a distribuição.

Por fim, a última técnica utilizada neste trabalho é baseada em interação proposta por (FERREIRA; FISHER; KONIG, 2014). Uma abordagem similar também foi usada no trabalho recente de (PAHINS; FERREIRA; COMBA, 2019). Esta técnica consiste em fixar o conjunto de tarefas a serem suportadas e, para cada uma delas, criar ferramenta na interativa para quantificar a probabilidade de que o fato descrito pela tarefa acontecer. O resultado desta ferramenta é usado para criar mapeamentos visuais usando técnicas usuais ou anotações sobre elas. No presente caso, são fixadas as tarefas extrair valor e de comparação. Para dar suporte à primeira tarefa, a interface apresenta um *slider*, no qual o usuário pode definir um intervalo $[c_1, c_2]$ de valores. O sistema usa então esse intervalo para quantificar implicitamente o valor de $Pr(c_1 \leq A \leq c_2)$ para cada região. O usuário pode mudar o valor do intervalo e interativamente o mapa coroplético associado é atualizado. Para suportar a tarefa de comparação, similar a proposta de (FERREIRA; FISHER; KONIG, 2014), o usuário pode efetuar um duplo clique em uma região A e todas as outras regiões do mapa são comparadas com A em termos de distribuição, o resultado de processo é $Pr(A \leq B)$, onde B representa cada uma das regiões e seus respectivos conjuntos de dados.



(a) Técnica de interação usando a barra horizontal para escolher um intervalo de valores.



(b) Técnica de interação comparando a probabilidade da distribuição de uma região ser menor.

Figura 21 – Visualização utilizando a técnica de interação. fonte: o Autor.

O resultado é representado por meio das cores das regiões. A Fig. 21 demonstra o uso desta técnica.

As três técnicas foram implementadas na plataforma *web*, na linguagem *JavaScript*, usando as bibliotecas *D3.js*, *Leaflet.js* e *Turf.js*.

3.3 HIPÓTESES

Para o estudo comparativo entre as técnicas, existem algumas hipóteses sobre a performance delas a ser validadas a partir da coleta de dados no estudo com o usuário. São elas:

- H1 - Dentre as 3 técnicas a visualização com interação é a de maior acurácia para as tarefas de extrair valor, comparação e encontrar extremos.
- H2 – As técnicas de mapa de pontos e mapas hipotéticos devem ter medidas de confianças mais baixos que a técnica de interação com exceção para a tarefa de estimar média.
- H3 – O tempo de resposta do usuário na técnica de interação tende a ser menor ou igual ao tempo registrado nas outras técnicas com exceção para a tarefa de estimar média.
- H4 - O tempo de resposta do usuário tende a aumentar quanto maior a distância geográfica entre as regiões a serem comparadas.
- H5 - Fatores como distância entre polígonos, tamanho das regiões e a magnitude da variância da distribuição de cada região impactam negativamente a acurácia do usuário para as respostas das tarefas nas técnicas de mapa de pontos e mapas hipotéticos para a tarefa de comparação.

3.4 DADOS

Para realizar os testes com usuários são usados dois conjuntos de dados (ou *datasets*) para gerar distribuições de dados geográficas. Estes foram selecionados para simular cenários reais de análise de dados que envolvem distribuições geográficas.

O primeiro contendo dados de distribuições de índice pluviométrico observado nas cidades do estado de Pernambuco - BR, composto por 184 regiões, com dados de chuvas referentes a todos os meses do período dos anos de 2016 a 2018. Totalizando um conjunto de 36 valores para cada região. Os dados são coletados através de postos meteorológicos e disponibilizados de forma aberta pelo órgão regulador - *Agência Pernambucana de Águas e Clima* através de seu *site*¹. O segundo conjunto de dados é o de corridas de táxi na

¹ <http://www.apac.pe.gov.br/meteorologia/monitoramento-pluvio.php>

cidade de NYC (EUA) Para este estudo, são usadas somente as corridas que começam em algumas vizinhanças da ilha de Manhattan (*Central Park, Clinton East, Clinton West, East Chelsea, East Village, Garment District, Gramercy, Greenwich Village North, Kips Bay, Lenox Hill East, Lenox Hill West, Lincoln Square East, Meatpacking-West Village West, Midtown Center, Midtown East, Midtown North, Midtown South, Murray Hill, Penn Station-Madison Sq West, Roosevelt Island, Stuy Town-Peter Cooper Village, Sutton Place-Turtle Bay North, Times Sq-Theatre District, UN-Turtle Bay South, Union Sq, Upper East Side South, West Chelsea-Hudson Yards e West Village*). O conjunto das 29 vizinhanças é composto de dados referentes a um ano (2018). Os dados foram agregados mensalmente para cada vizinhança, totalizando 12 valores para a distribuição de cada vizinhança. Os dados têm tamanho de 0,1 MB, são coletados através do monitoramento dos táxis com auxílio da localização geográfica dos veículos e disponibilizados de forma aberta pela prefeitura de NYC através Comissão de táxi e limusine da cidade de Nova York².

3.5 QUESTIONÁRIO QUALI-QUANTITATIVO

Para a coleta de dados deste trabalho foi utilizado um questionário inserido nas visualizações dividido em três partes. A Fig. 22 mostra as etapas para a realização do estudo em especial as 3 etapas do questionário: informações de perfil, execução de tarefas e comentário final.

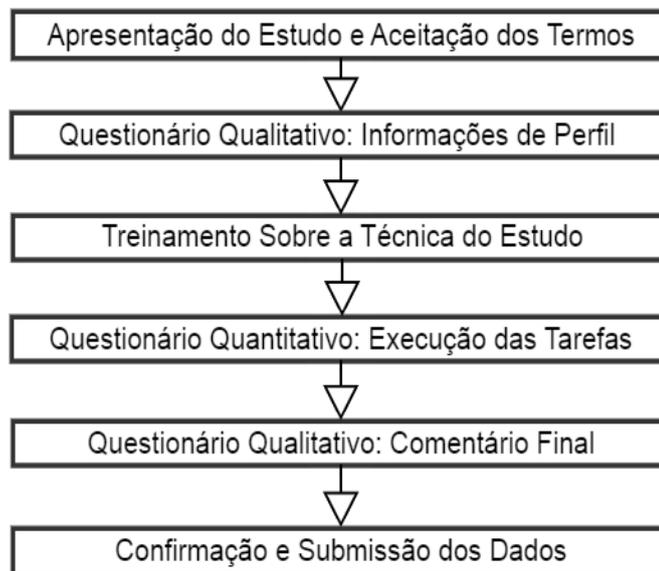


Figura 22 – Diagrama sequencial das etapas do estudo. Fonte: O autor (2020)

A primeira parte do questionário é qualitativa e trata de questões pessoais que tem por objetivo mapear o perfil do participante. A segunda parte do questionário é quantitativa

² <https://www1.nyc.gov/site/tlc/about/tlc-trip-record-data.page>

e diz respeito a perguntas que envolvem a parte de estudo de usuário propriamente dita, as tarefas, e tem o objetivo de medir a eficiência da técnica sob estudo para representar risco, incerteza e fazer comparações conforme visto em estudos da literatura e citados neste trabalho. A terceira parte do questionário é qualitativa e faz uso de um campo textual para o participante escrever e dar sua opinião sob a visualização, a forma como ela representa os dados e demais aspectos do teste que considerar pertinente. Entre a parte de informações pessoais e a de tarefas foi alocada uma etapa de treinamento a respeito de aspectos da visualização, ou seja, como a técnica funcionaria e poderia auxiliar as respostas necessárias para as perguntas da parte do comentário do questionário.

A primeira parte do questionário possui 6 (seis) questões sobre o perfil dos participantes (Tab. 2), e alternavam entre estrutura de questão aberta e fechada, a segunda parte referente possui mais 26 (vinte e seis) questões de modo aberto que testam as tarefas analíticas, as respostas a essas 26 questões são de caráter numérico, era ainda coletado o tempo e acurácia para medir a precisão das respostas (veja Fig. 23).

Tabela 2 – Primeira parte - perguntas pessoais

NÚMERO	TEXTO
1	Por favor entre com seu e-mail.
2	Qual sua idade?
3	Informe seu gênero.
4	Qual seu grau de escolaridade?
5	Você é daltônico?
6	Você tem experiência com estatística?

Perguntas

Figura 23 – Modelo de interface das perguntas para todas as visualizações. fonte: o Autor

É válido destacar que todas aplicações do estudo foram feitas individualmente (aplicando a vários participantes, um a um) e sendo a metade *in loco*, ou seja, no próprio local de trabalho do participante. Apesar de não interferir no preenchimento do questionário, no caso *in loco* o pesquisador ficou no mesmo ambiente do respondente, com exceção de algumas aplicações acompanhadas a distância, para esclarecer quaisquer dúvidas de

preenchimento e também para, durante o uso do sistema, fazer observações e anotações, caso necessário, usando a técnica de observação direta. Nenhuma execução do estudo se deu por *e-mail*, telefone ou sem treinamento, todas execuções aconteceram em plataforma *on-line* hospedada em servidor e autoguiadas pelo sistema. A oportunidade de acompanhar a aplicação dos testes por meio dos questionários junto aos participantes foi algo positivo, pois acabou por permitir um melhor entendimento do uso de cada visualização, assim como permitiu ainda que fossem tomadas notas de pequenas frases, palavras soltas e características dos participantes, verbalização de medos, dúvidas e raciocínios pensados e observações apontadas pelos participantes. Esta etapa pode ser entendida como protocolo *Think Aloud*, que é um método onde o participante é convidado a falar em voz alta durante a solução de um problema ou execução de uma tarefa. Como se fosse "um relatório oral do conteúdo da memória de curto prazo e representa um traçado dos processos cognitivos que as pessoas apresentam ao realizarem uma tarefa" (LEHNHART; LÖBLER; TAGLIAPIETRA, 2019). Assim, o participante pode verbalizar seus pensamentos sem necessariamente descrever ou explicitar o que ele está fazendo - ocorre apenas a verbalização das informações.

Na Tab.3 são apresentadas as perguntas feitas ao usuário durante o estudo. Para as perguntas de comparação entre regiões foram incluídas implicitamente através da escolha das regiões tipos de variações: de tamanho da região grande ou pequeno (T+,T-), distância entre as regiões: grande ou pequena (D+,D-) e variação dos dados da região, grande ou pequena (V+,V-). Sendo do N^o 1 ao 13 perguntas referentes ao conjunto de dados de chuva e de 14 a 26 perguntas referentes ao conjunto de dados de corrida de táxis.

Tabela 3 – Segunda parte - perguntas do estudo do usuário.

N ^o	TEXTO	TIPO
1	Qual a probabilidade de chover em A abaixo de 100mm?.	
2	Qual a probabilidade de chover em A acima de 100mm?	
3	Qual a probabilidade de chover em A entre 50 e 150mm?	
4	Entre A e B, qual das duas é mais provável de chover abaixo de 100mm?	
5	Qual é a probabilidade de chover menos em A do que no B?	D-
6	Qual é a probabilidade de chover menos em A do que em B?	D+
7	Qual é a probabilidade de chover menos em A do que em B?	V-
8	Qual é a probabilidade de chover menos em A do que em B?	V+
9	Qual é a probabilidade de chover menos em A do que em B?	T-
10	Qual é a probabilidade de chover menos em A do que em B?	T+

11	Selecione na lista o nome da região que tem a maior probabilidade de chover abaixo de 100mm?	
12	Selecione na lista o nome da região que tem a menor probabilidade de chover abaixo de 100mm?	
13	Estime qual a média de chuvas em A.	
14	Qual a probabilidade de o número de corridas de táxis em A está abaixo de 18000?	
15	Qual a probabilidade de o número de corridas de táxis em A está acima de 20000?	
16	Qual a probabilidade de o número de corridas de táxis em A está entre 18000 e 35000?	
17	Entre A e B, qual das duas regiões é mais provável que o número de corridas de táxi esteja abaixo de 27000?	
18	Qual é a probabilidade do número de corridas de táxi em A ser menor que Times B?	D-
19	Qual é a probabilidade do número de corridas de táxi em A ser menor que B?	D+
20	Qual é a probabilidade do número de corridas de táxi em A ser menor que B?	V-
21	Qual é a probabilidade do número de corridas de táxi em A ser menor que B?	V+
22	Qual é a probabilidade do número de corridas de táxi em A ser menor que em B?	T-
23	Qual é a probabilidade do número de corridas de táxi em A ser menor que em B?	T+
24	Selecione na lista o nome da região com maior probabilidade de ter o número de corridas de táxis acima de 34000?	
25	Selecione na lista o nome da região com menor probabilidade de ter um número de corridas de táxis acima de 3500?	
26	Estime qual é o número médio de corridas de táxi em A.	

Para finalizar a terceira etapa pediu para o participante comentar livremente sobre o todo: visualização/estudo.

3.6 CONSIDERAÇÕES FINAIS

Neste experimento, cada participante é exposto a um único estímulo (técnica de visualização). Como será descrito no próximo capítulo, a decisão de qual estímulo cada participante irá receber é sistemática e feita de tal maneira que nem os participantes e nem o pesquisador tem controle desta decisão. Esta decisão foi tomada para reduzir possíveis vieses e efeitos de aprendizagem durante a realização do experimento. Pelo mesmo motivo, a ordem em que as questões são apresentadas é aleatória e diferente para cada usuário.

4 RESULTADOS E DISCUSSÕES

Neste capítulo, são apresentados os resultados das análises sobre dados coletados seguindo o procedimento descrito no capítulo anterior. Além de discussões referentes à validade das hipóteses apresentadas na seção 3.3. Para começar a discussão é necessário descrever a população de estudo e a amostra de usuários que participaram do experimento.

4.1 UNIVERSO DA PESQUISA E USUÁRIOS

A população alvo consiste são pessoas que satisfazem os seguintes critérios:

1. Não ter contato prévio com a solução;
2. Ter idade mínima de 18 (dezoito) anos.
3. Ter nível de escolaridade mínimo de graduação.
4. Não ter deficiência motora que impossibilite o uso de qualquer uma das visualizações.
5. Não ter problema visual com exceção de Daltonismo (que é um problema hereditário caracterizado por uma anomalia na visão das cores, especialmente uma confusão entre o vermelho e o verde) uma vez que as visualizações trabalham com escala de cores seguras para pessoas daltônicas.

Para o experimento, foram recrutados 66 (sessenta e seis) participantes. Estes foram divididos em 3 grupos (22 pessoas cada) onde cada grupo é exposto a uma das técnicas de visualização presente estudadas. Os participantes foram distribuídos alternadamente para os grupos seguindo uma ordem das técnicas pré-estabelecidas pelo pesquisador sempre na sequência interação, mapa de pontos e mapas hipotéticos (informação não conhecida por parte dos participantes).

O perfil dos participantes é apresentado nas tabelas 4, 5, 6 e 7 de acordo com as características pesquisadas: sexo, experiência com estatística, experiência com visualização de dados e nível de escolaridade.

Tabela 4 – Sexo dos participantes - Quantidade x Técnicas

Sexo	Geral	Interação	Mapa de Pontos	Mapas Hipotéticos
Masculino	41	12	17	12
Feminino	25	10	5	10

Tabela 5 – Experiência com estatística - Quantidade x Técnicas

Exp. Estatística	Geral	Interação	Mapa de Pontos	Mapas Hipotéticos
Possui	39	14	9	16
Não Possui	26	8	13	6

Tabela 6 – Experiência com visualização - Quantidade x Técnicas

Exp. Visualização	Geral	Interação	Mapa de Pontos	Mapas Hipotéticos
Possui	43	17	13	13
Não Possui	23	5	9	9

Tabela 7 – Nível de Escolaridade - Quantidade x Técnicas

Nível de Escolaridade	Geral	Interação	Mapa de Pontos	Mapas Hipotéticos
Graduação	36	13	12	11
Pós Graduação	30	9	10	11

4.2 ANÁLISE QUALITATIVA

Nesta seção são discutidos os comentários e as transcrições do *think aloud* dos usuários transcritos durante a realização do experimento, bem como os comentários facultativos que foram deixados ao final do processo (como descrito no capítulo anterior). Durante a realização do estudo, os usuários foram convidados de modo facultativo, a deixar sua opinião sobre a experiência deles com uso das ferramentas construídas e do processo de análise em si. Esses comentários obtidos serão discutidos para nos ajudar a entender em mais detalhes impressões subjetivas de usabilidade, bem como, nos dar uma ideia preliminar sobre a validade das hipóteses do estudo.

4.2.1 Técnica de Interação

Em geral, os usuários tiveram reações positivas quanto a técnica de interação. Por se tratar de uma técnica que exige muita atenção quanto ao uso correto poderia haver muitas reações negativas. Um determinado usuário por exemplo reportou: - *"Achei legal e fácil, mas tive medo de errar as respostas, o raciocínio mesmo se tinha entendido corretamente porque segui uma lógica de uso da ferramenta então ou eu acertei todas ou errei todas, A ferramenta ajuda bastante é só pegar a lógica e usar, muito rápido e tranquilo"*. Alguns participantes, no entanto, reportaram insegurança ao usar a ferramenta. De fato, a percepção foi que a ferramenta tornava algumas tarefas bastante simples ao ponto de gerar dúvidas se haveria no estudo perguntas "armadilhas" feitas propositalmente com intuito

de gerar repostas incorretas. Este fato pode ser observado no seguinte comentário: - *"eu fiquei com um pouco de medo de confiar na ferramenta, mas quando você aprende e entende o uso aí é bem mais fácil, mesmo assim eu tentava conferir tirar uma prova para ter certeza e aumentar minha confiança"*. A única tarefa em que foi observada comentários específicos foi a tarefa de estimar a média. Esta foi vista como a tarefa mais desafiadora e de fato exige um conhecimento mais avançado de estatística para estimar a média a partir da função de probabilidade acumulada. Um usuário reportou- *"Gostei, achei bem iterativo, só fiquei em dúvida com a média"*.

4.2.2 Percepções Técnica de Mapa de Pontos

Os participantes do estudo relataram certa dificuldade em fazer inferências na técnica de densidade de pontos. Para responder de modo mais preciso possível os usuários tentaram usar todos os recursos possíveis é o que nos diz o seguinte comentário: - *"No começo eu achei um pouco mais complicado os pontos, achei difícil estimar, então eu contava as cores das bolinhas, olhava mais de cima, quando eu dava mais zoom dava para ver melhor, com o passar do tempo tive mais confiança, algumas perguntas podem confundir se não prestar atenção, acho que seria interessante ver os valores de cada bolinha"*. Também a hipótese H5 que trata do impacto de fatores como variação nos dados e distância entre as regiões nas respostas pode ser visto nos seguintes comentários: - *"Senti dificuldades para comparar regiões com valores próximos no gráfico, talvez a quantidade de faixas devesse ser menor, ou até combinar esse tipo de visualização com algum dado de média da região inteira no passar do mouse"*; - *"Você tem que analisar bem porque tem umas regiões que estão mais próximas e outras mais distantes, em alguns casos é preciso dar zoom, colocando mais zoom você tem uma noção melhor"*. Esses comentários revelam a dificuldade para chegar a um resultado preciso indo de encontro a hipótese H5. Além disso, é necessário observar uma grande necessidade de uso de instrumentos de interação como zoom (navegação no mapa) para poder comparar essas regiões muito distantes. Por fim, foi possível observar uma insegurança conforme esperado pela hipótese H2. É o que nos mostra o seguinte comentário: - *"Tive dificuldade em como analisar os dados devido ao processo de contar, as distâncias dificultam um pouco, é um processo incerto e a ferramenta não dá nenhum feedback para a gente ter mais certeza sobre as distribuições de dados"*.

4.2.3 Percepções Técnica de Mapas Hipotéticos

Os comentários para a técnica de mapas hipotéticos ajudaram a mostrar uma ideia considerada pelos autores, mas não presente em nas hipóteses: que o uso de animações pode tornar o processo de estimativa difícil. Além disso, a variação visual de muitas regiões ao mesmo tempo pode incomodar e causar confusão. É o que se observa no seguinte comentário: - *"É muita coisa para analisar e observar, assim muitas variáveis passando ao mesmo tempo, senti falta de usar papel ou calculadora, de certa forma é cansativa e a questão de*

responder o mais rápido possível também gera insegurança". É interessante também frisar que os usuários se sentiram pouco confiantes, conforme a hipótese H2, por não poderem utilizar materiais externos para auxiliar nas repostas, para isso basta observar comentários como por exemplo: - "Eu achei legal, mas você fica insegura especialmente quem é acostumada a calcular que é o meu caso, as cores e os números da legenda ajudam, as perguntas são parecidas então precisa prestar bastante atenção". Também para esta técnica a hipótese H5 pode ser observada, os usuários sentiram dificuldades para comparar regiões distantes ou com distribuições semelhantes: - "Foi muito difícil comparar cidades que estão muito longe uma da outra, as cores são semelhantes para alguns ranges de cores embora se tenha a ajuda visual com o valor de interesse (pop up), A ordem aleatória dos meses faz com que seja muito difícil fazer a estimação de interesse".

4.3 ANÁLISE QUANTITATIVA

Esta seção apresenta a análise quantitativa, em termos de acurácia, tempo de resposta e medida de confiança reportada dos participantes, realizada para validar as hipóteses com os dados obtidos por meio do estudo com usuário.

4.3.1 Procedimento de Análise

Para decidir quais testes devem ser aplicados foram analisados, primeiramente, a distribuição dos dados obtidos quanto à normalidade. Para cada distribuição de dados das repostas obtidas das perguntas que compõe cada tarefa foi aplicado o teste de Kolmogorov-Smirnov (KS) para testar a normalidade dos dados para a acurácia (erro relativo), tempo (que é medido em minutos) e medida de confiança (medida em escala de 1-5 sendo 1 pouco e 5 muito confiante), os resultados dos testes de normalidades são apresentados respectivamente nas tabelas Tab.8, Tab.9, Tab.10.

Tabela 8 – Normalidade das distribuições da acurácia.

Testes de Normalidade - Acurácia				
	dataset	Kolmogorov-Smirnov		
		Est. teste	df	Sig.
Extrair Valor	Chuvas	0,209	198	0,000
	Táxis	0,236	198	0,000
Comparar Distribuições	Chuvas	0,274	396	0,000
	Táxis	0,256	396	0,000
Encontrar Extremos	Chuvas	0,247	132	0,000
	Táxis	0,220	132	0,000
Estimar a Média	Chuvas	0,256	66	0,000
	Táxis	0,261	66	0,000

Tabela 9 – Normalidade das distribuições de tempo.

Testes de Normalidade - Tempo				
	<i>dataset</i>	Kolmogorov-Smirnov		
		Est. teste	df	Sig.
Extrair Valor	Chuvas	0,298	198	0,000
	Táxis	0,371	198	0,000
Comparar Distribuições	Chuvas	0,328	396	0,000
	Táxis	0,369	396	0,000
Encontrar Extremos	Chuvas	0,321	132	0,000
	Táxis	0,278	132	0,000
Estimar a Média	Chuvas	0,240	66	0,000
	Táxis	0,211	66	0,000

Tabela 10 – Normalidade das distribuições de medida de confiança.

Testes de Normalidade - Medida de Confiança				
	<i>dataset</i>	Kolmogorov-Smirnov		
		Est. teste	df	Sig.
Extrair Valor	Chuvas	0,207	198	0,000
	Táxis	0,249	198	0,000
Comparar Distribuições	Chuvas	0,211	396	0,000
	Táxis	0,183	396	0,000
Encontrar Extremos	Chuvas	0,35	132	0,000
	Táxis	0,263	132	0,000
Estimar a Média	Chuvas	0,236	66	0,000
	Táxis	0,208	66	0,000

Observando os resultados dos testes é possível ver que não há diferença significativa que indique que os dados sigam uma distribuição normal, desta forma, há a necessidade do uso de testes não paramétricos. O processo de análise faz uso do teste de Kruskal-Wallis para amostras independentes(KW), para as técnicas que forem agrupadas em mais de dois grupos e do teste de Wilcoxon (W) para distribuições que forem agrupadas em dois grupos (como o teste entre os pares), caso o KW apresente diferença significativa entre as técnicas será executado o W para identificar possíveis diferenças significativas. Em todos os testes adotamos o nível de significância de 5% ou 0,050.

4.4 ANÁLISE QUANTITATIVA

A acurácia de cada técnica foi medida de acordo com o erro relativo¹ para eliminar a influência da escala dos dois conjuntos de dados. Os resultados descritivos estão sumarizados na Tab.11, que mostra o erro relativo médio (com o desvio entre parêntesis em baixo de cada elemento) para cada combinação de técnica e tarefa analítica. Pode-se observar que a técnica de interação registra os menores erros relativos médios para as tarefas de extrair valor, comparar distribuições e encontrar extremos. Isto dá uma primeira indicação que a hipótese H1 será comprovada ao menos nessas tarefas. Em seguida apresentamos mais duas tabelas descritivas sobre os resultados do tempo (Tab.12) e da medida de confiança (Tab.13).

Tabela 11 – Tarefa x Erro Médio por Técnicas organizado por *datasets*

ID	Tarefa	Interação		Mapa de Pontos		Mapas Hipotéticos	
		Chuvas	Táxis	Chuvas	Táxis	Chuvas	Táxis
1	Extrair Valor	0,03 (0,02)	0,03 (0,17)	0,54 (0,4)	1,45 (2,34)	0,40 (0,39)	0,70 (2,33)
2	Comparar Distribuições	0,03 (0,19)	0,05 (0,26)	0,53 (0,47)	0,59 (0,42)	0,59 (0,89)	0,53 (0,45)
3	Encontrar Extremos	0,05 (0,03)	0,21 (0,36)	0,25 (0,43)	0,47 (0,45)	0,26 (0,45)	0,35 (0,43)
4	Estimar a Média	1,17 (1,55)	0,16 (0,24)	0,97 (0,84)	0,21 (0,15)	0,34 (0,44)	0,07 (0,01)

Tabela 12 – Tarefa x Tempo Médio por Técnicas organizado por *datasets*

ID	Tarefa	Interação		Mapa de Pontos		Mapas Hipotéticos	
		Chuvas	Táxis	Chuvas	Táxis	Chuvas	Táxis
1	Extrair Valor	0,89 (2,57)	1,74 (6,05)	0,36 (2,03)	1,65 (1,61)	0,22 (1,60)	2,08 (3,70)
2	Comparar Distribuições	1,80 (6,30)	1,43 (4,02)	1,24 (2,36)	1,01 (3,70)	1,09 (1,46)	1,73 (3,49)
3	Encontrar Extremos	2,43 (4,44)	2,15 (5,40)	1,43 (1,03)	2,04 (0,80)	1,90 (7,95)	1,30 (1,97)
4	Estimar a Média	2,00 (1,58)	2,58 (1,24)	1,05 (0,76)	2,28 (1,61)	1,36 (1,85)	0,94 (0,73)

¹ Erro relativo = (valor real - valor obtido)/valor real.

Tabela 13 – Tarefa x Medida de Confiança média por Técnicas organizado por *datasets*

ID	Tarefa	Interação		Mapa de Pontos		Mapas Hipotéticos	
		Chuvas	Táxis	Chuvas	Táxis	Chuvas	Táxis
1	Extrair Valor	4,41 (0,01)	4,50 (0,99)	3,68 (0,1)	3,71 (1,09)	3,51 (0,01)	3,63 (1,23)
2	Comparar Distribuições	4,25 (0,01)	4,33 (1,06)	3,47 (0,00)	3,46 (1,02)	3,11 (0,01)	2,92 (1,10)
3	Encontrar Extremos	4,29 (0,02)	4,43 (0,99)	3,70 (0,02)	4,18 (0,78)	3,47 (0,02)	4,06 (1,02)
4	Estimar a Média	2,5 (1,43)	2,45 (1,29)	3,40 (0,90)	3,36 (0,95)	3 (1,02)	3,36 (1,29)

A seguir, foram analisadas cada uma das tarefas analíticas individualmente.

4.4.1 Tarefa de Extrair Valor - *dataset* Chuvas

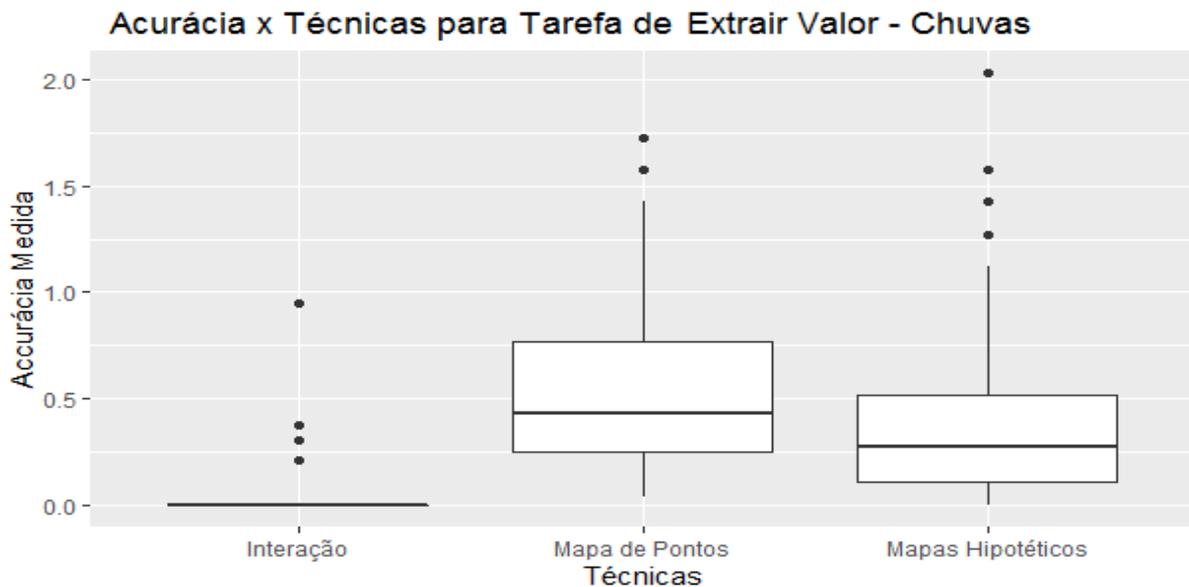


Figura 24 – Erro relativo por técnica para tarefa de extrair valor *dataset* chuvas. Fonte: O autor (2020).

A Fig. 24 nos mostra que para a tarefa de extrair valor com o *dataset* de chuvas a técnica de interação registra os menores erros relativos, com apenas alguns *outliers* confirmando H1. Ao observar o tamanho do erro é possível ver que o tamanho do erro da técnica de mapa de pontos e mapas hipotéticos é considerável com relação a técnica de interação que beira 0. Para verificar se o comportamento das técnicas é o mesmo ou se há uma diferença e quão grande é essa diferença foram aplicados os testes estatísticos.

Tabela 14 – Resultados dos Testes para Tarefa de extrair valor *dataset* chuvas.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de extrair valor é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativa o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	2333,000	2407,000	3787,000
<i>p-value</i>	0,000	0,000	0,006

A Tab.14 mostra os resultados dos testes aplicados. Confirmando que há uma diferença significativa entre todas as técnicas. Além disso, foi verificado que a técnica de mapa de pontos tem os maiores erros relativos registrados enquanto que a técnica de interação a maior precisão.

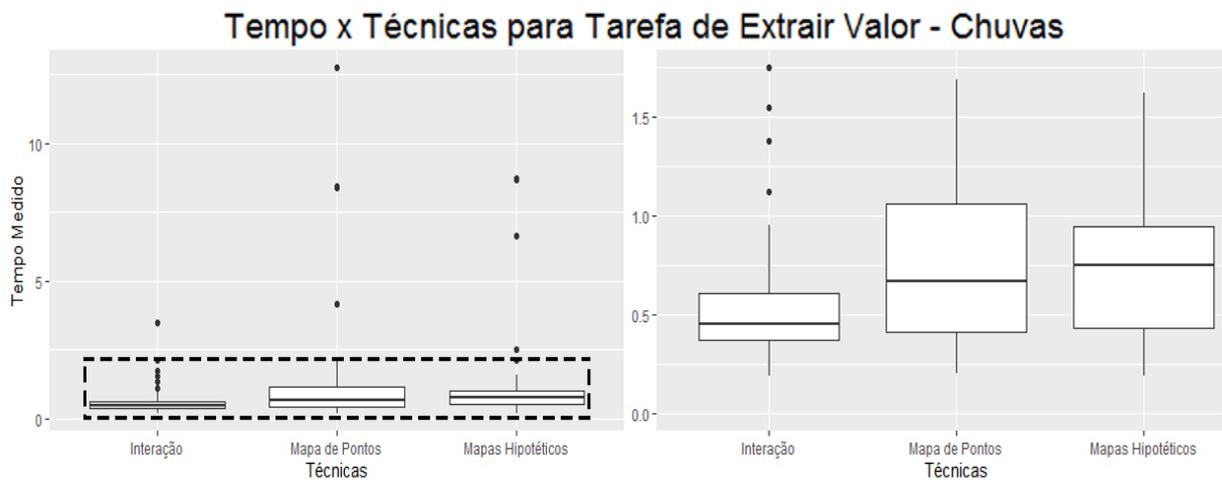


Figura 25 – Distribuição do tempo por técnica para tarefa de extrair valor *dataset* chuvas (com zoom na imagem mais a direita). Fonte: O autor (2020).

A Fig. 25 mostra que a técnica de interação registrou menor tempo de execução por parte dos usuários para responderem as tarefas analíticas foram aplicados os testes, onde foi possível constatar uma diferença significativa de KW entre as técnicas (com diferença significativa de teste 0,000), analisando os pares o único par que não houve divergência foi o das técnicas de mapa de pontos e mapas hipotéticos (com *p-value* de teste 0,868 bem acima de 0,05) isso reforça H3.

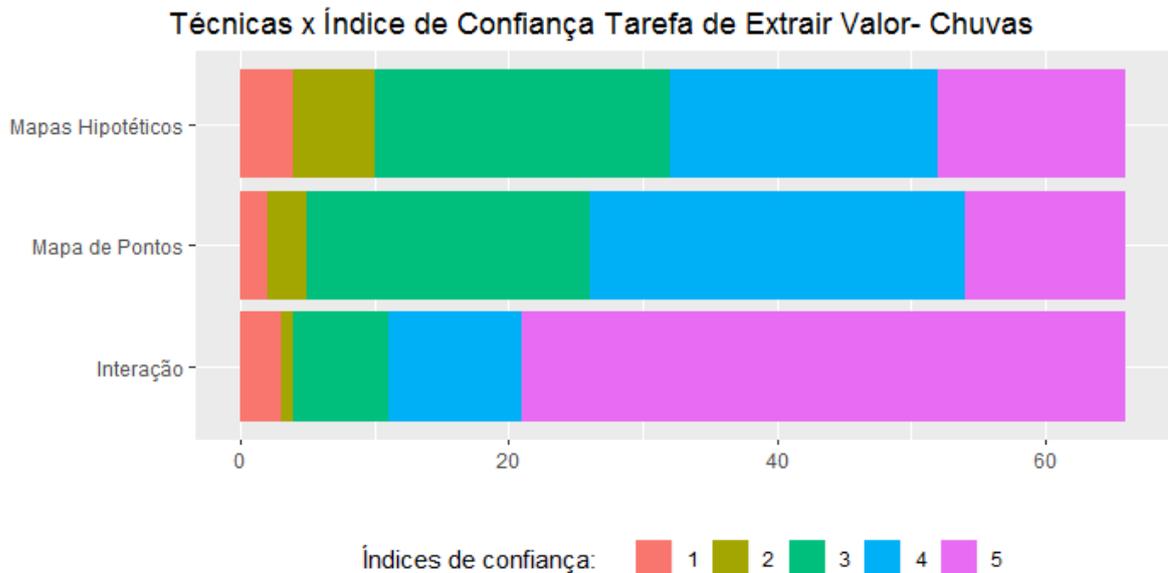


Figura 26 – Distribuição da medida de confiança por técnica para tarefa de extrair valor *dataset* chuvas. Fonte: O autor (2020).

A Fig. 26 mostra que a técnica de interação registrou maior medida de confiança por parte dos usuários enquanto as técnicas de mapas de pontos e mapas hipotéticos visualmente tiveram desempenho semelhante. Quando a medida confiança foi testada estatisticamente o teste de KW alertou sobre uma forte divergência (com *p-value* de teste 0,000) entre as técnicas ficou claro que a diferença (pares) entre a técnica de interação e as demais é muito significativa (com *p-value* de teste 0,000) enquanto que entre as técnicas de mapa de pontos e mapas hipotéticos o comportamento é semelhante (com *p-value* de teste 0,412). Esses resultados já eram esperados por H2.

4.4.2 Tarefa de Extrair Valor - *dataset* Táxis

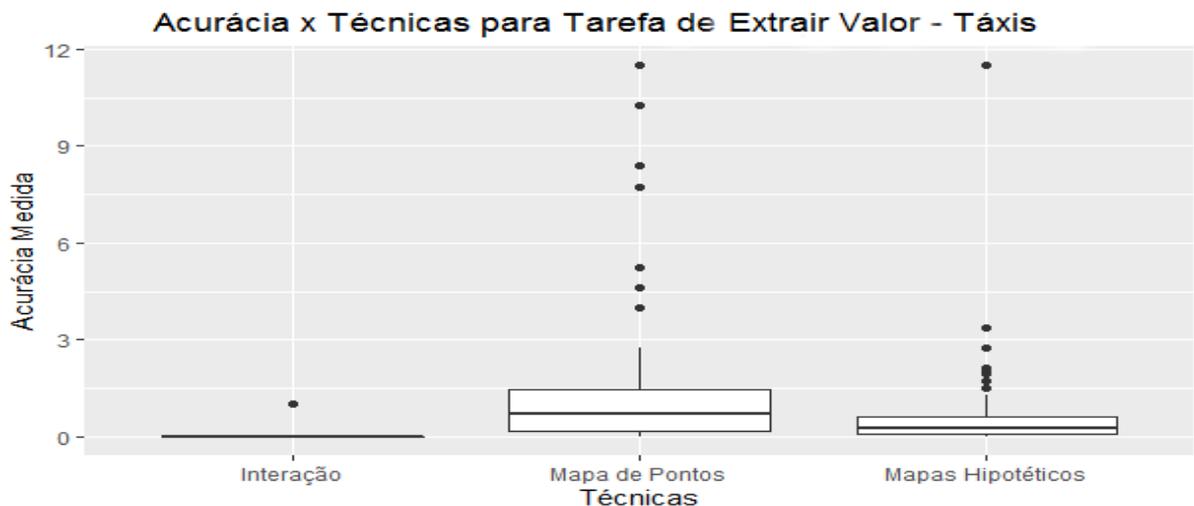


Figura 27 – Erro relativo por técnica para tarefa de extrair valor *dataset* táxis. Fonte: O autor (2020).

A Fig. 27 exhibe o resultado do erro relativo, no caso do *dataset* de táxis, para a tarefa de extrair valor com detalhe da presença de alguns *outliers*. A técnica de interação é visivelmente a que tem os menores erros relativos (com mediana de 0,00), como aconteceu no caso das chuvas. O tamanho do erro nessa tarefa para a técnica de mapa de pontos foi um tamanho considerado com alcance visual de 1,5. A técnica de mapa de pontos (com mediana de 0,69) chama atenção por ser a que visivelmente a técnica que tem os maiores erros relativos e uma quantidade maior de *outliers*. A técnica de mapas hipotéticos se aproxima mais da técnica de interação (com mediana de 0,25) mais também registra alguns *outliers* porém numa ocorrência menor em amplitude e quantidade do que a técnica de mapa de pontos. Para verificar como o comportamento das técnicas é em termos de proximidade novamente foi feito uso dos testes estatísticos.

Tabela 15 – Resultados dos testes para tarefa de extrair valor *dataset* táxis.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de extrair valor é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativo o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	2322,000	2641,000	3794,500
<i>p-value</i>	0,000	0,000	0,007

A Tab.15 confirma que há diferença significativa entre todas as técnicas, com essa informação e o desempenho da técnica de interação que teve a maior precisão o que confirma H1. Os testes e a distribuição dos resultados das técnicas também revelam que a técnica de mapa de pontos tem os maiores erros relativos registrados, o que indica bastante dificuldade por parte de alguns usuários e uma eficiência não tão boa para essa tarefa com esse conjunto de dados. Já a técnica de mapas hipotéticos tem um desempenho próximo da interação com um erro relativo tão baixo que chega a ser irrelevante.

A Fig. 28 nos ajuda a perceber que a técnica de mapa de pontos tem o menor tempo entre as três técnicas, mas a técnica de interação registrou um desempenho semelhante à de mapa de pontos. Chama atenção como na técnica de mapa de pontos os *outliers* se fazem muito presentes mostrando uma possível dificuldade que pode ser até mesmo a observação dos elementos e a velocidade da transição dos quadros.

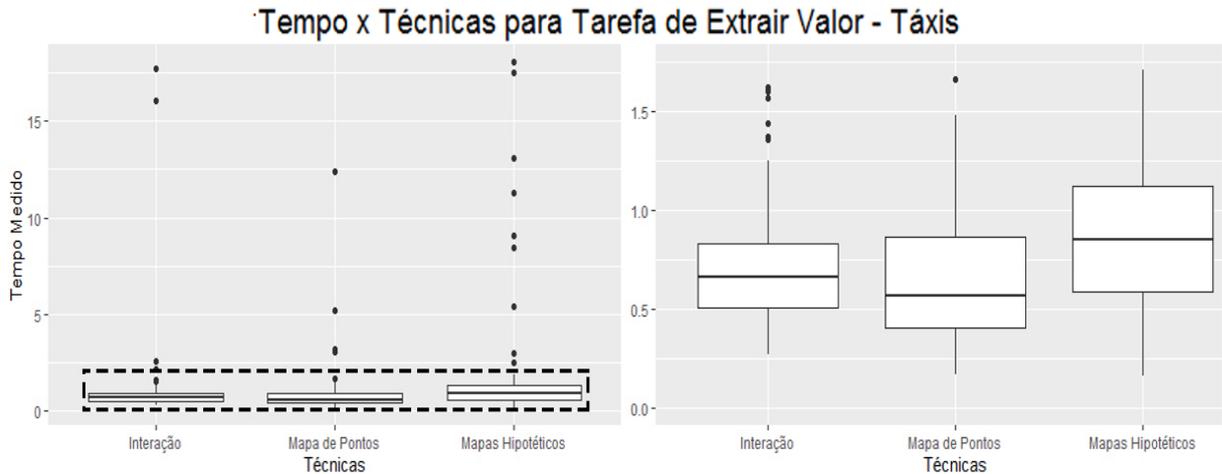


Figura 28 – Distribuição do tempo por técnica para tarefa de extrair valor *dataset* táxis com zoom na imagem mais a direita. Fonte: O autor (2020).

A estatística de KW revelou que as técnicas não seguem o mesmo comportamento (com *p-value* de teste de 0,004), observando a relação dos pares de técnicas se confirmou o esperado de que entre a técnica de interação e a técnica de mapa de pontos há o mesmo comportamento (com *p-value* de teste de 0,157), o que não existe para as demais relações entre as técnicas. Assim H3 também pode ser aplicada a essa tarefa.

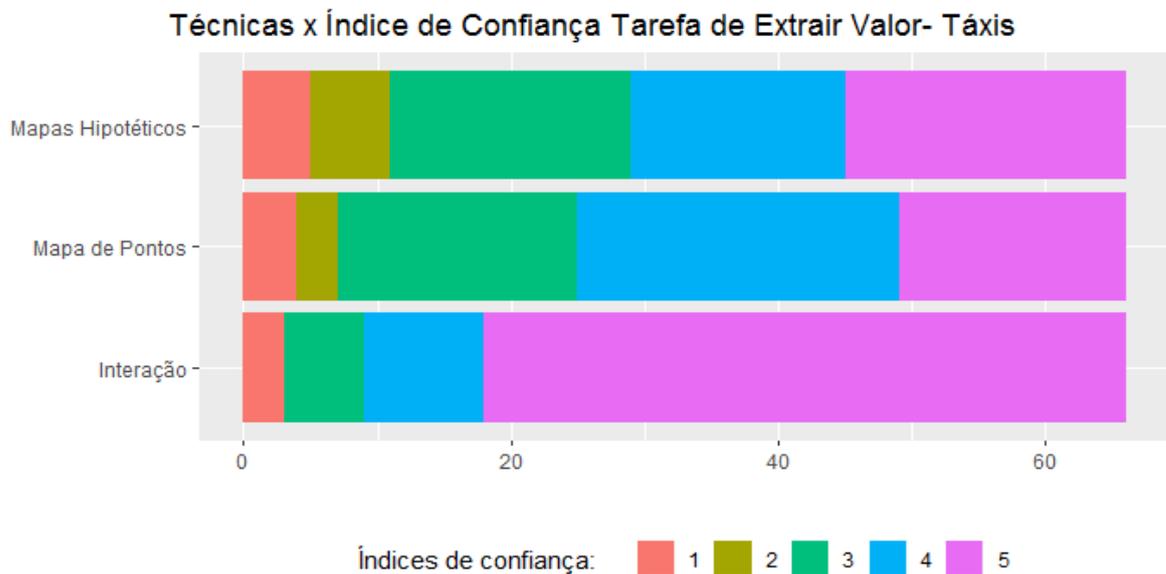


Figura 29 – Distribuição da medida de confiança por técnica para tarefa de extrair valor *dataset* táxis. Fonte: O autor (2020).

Na Fig. 29 a técnica de interação aparece com o índice mais alto de medida de confiança em predominância por parte dos usuários, as outras técnicas tiveram desempenho mais distribuído os usuários se dividiram quanto a medida de confiança o que acabou por gerar um comportamento próximo. Recorrendo aos testes o KW aponta uma alta diferença entre as técnicas (*p-value* de teste de 0,000), quando examinado os pares as técnicas de

mapas de pontos e mapa hipotéticos são as únicas semelhantes (p -value de teste de 0,822), já a técnica de interação diverge das demais (p -value de teste de 0,000) isso confirma H2.

4.4.3 Tarefa Comparar Distribuições - *dataset* Chuvas

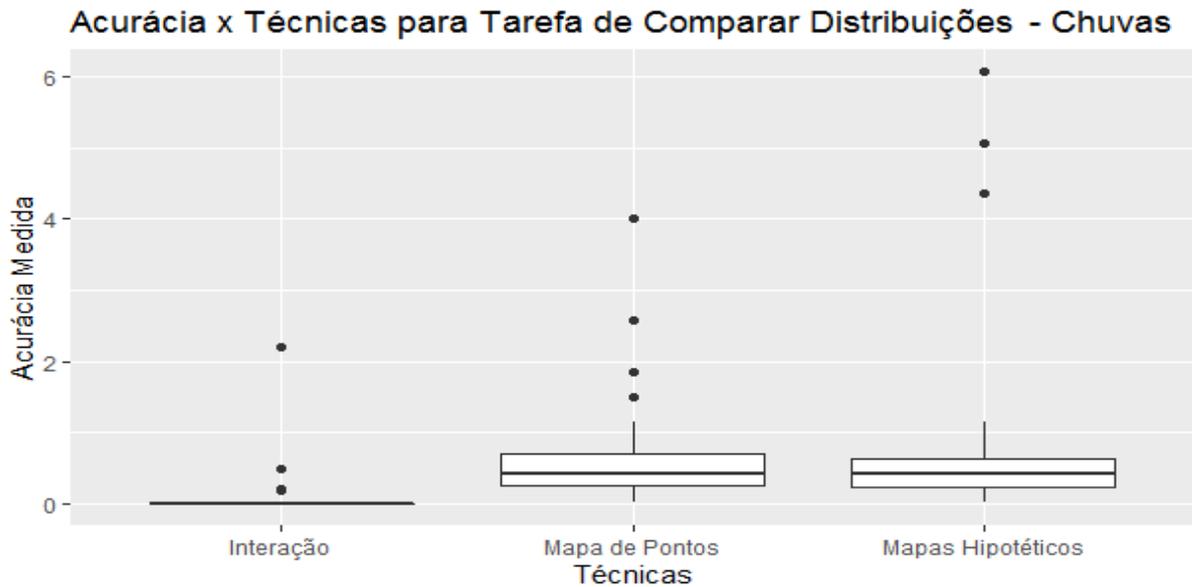


Figura 30 – Erro relativo por técnica para tarefa de comparar distribuições *dataset* Chuvas. Fonte: O autor (2020).

A Fig. 30 mostra a distribuição do erro do *dataset* das chuvas para a tarefa de comparar distribuições. A técnica de interação aqui registra os menores erros relativos com apenas alguns *outliers*, mas esse erro relativo tem magnitude próxima das outras técnicas enquanto a mediana da interação é de 0,00 a mediana do mapa de pontos é de 0,43, o que mostra que o mapa de pontos e os mapas hipotéticos se por um lado não são as melhores técnicas por outro não tem erro relativo de grande magnitude soma-se a isso o tamanho dos erros é pequeno visualmente falando. Este resultado era esperado, pois a técnica de interação proporciona as respostas diretamente e funciona como uma linha base de avaliação para essa tarefa. Então os testes estatísticos foram executados.

Tabela 16 – Resultados dos Testes para Tarefa de Comparar Distribuições *dataset* chuvas.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de comparar distribuições é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativa o p -value deve ser menor ou igual a 0,050.			

Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	9048,500	9061,500	17005,500
<i>p-value</i>	0,000	0,000	0,435

A Tab.16 resume os resultados obtidos pelos testes confirmando, que há sim uma diferença e ela é significativa entre todas as técnicas. Por outro lado, o teste por pares mostra que a técnica de mapa de pontos e a de mapas hipotéticos não possuem diferença significativa, seguindo o mesmo comportamento. Com base nos testes e na distribuição dos resultados das técnicas, a técnica de interação possui a maior precisão enquanto as demais não apresentam diferença significativa para nos permitir classificar qual é a melhor ou pior das duas. Essas informações confirmam H1 para essa tarefa.

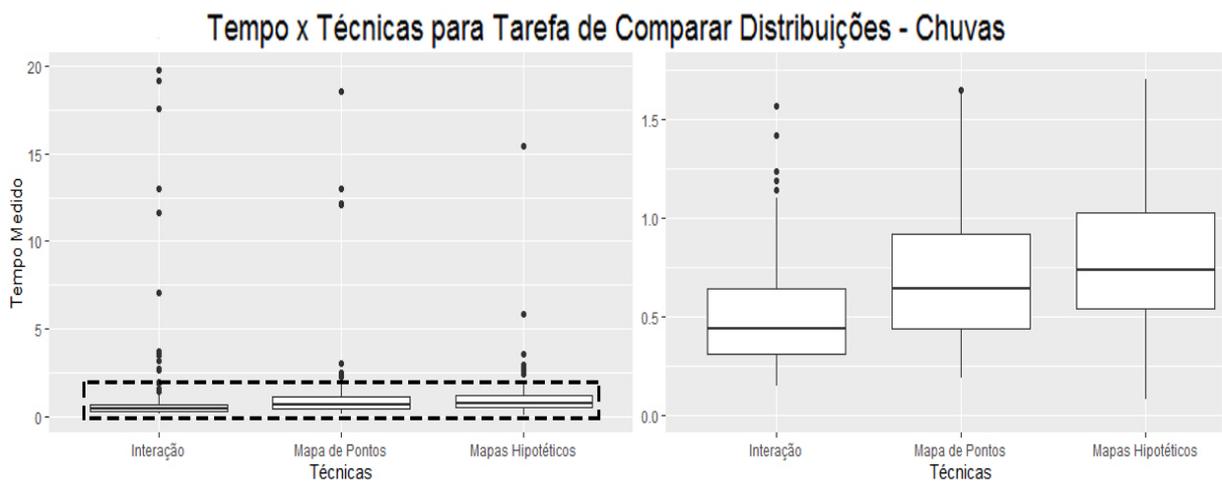


Figura 31 – Distribuição do tempo por técnica para tarefa de comparar distribuições *dataset* chuvas (com zoom na imagem mais a direita). Fonte: O autor (2020).

A Fig. 31 indica que a técnica de interação registrou menor tempo (conforme previsto em H3) por parte dos usuários para responderem, quando olhadas as três técnicas é possível ver certa diferença entre elas. Porém a interação registrou mais *outliers* fato que pode ser explicado pela insegurança relatada de alguns usuários que achavam a técnica "fácil demais" e acreditavam estar fazendo algo errado como mostrado nos comentários. Ao procurar diferenças entre as técnicas o teste de KW apontou a divergência (com *p-value* de 0,000) e o teste por pares mostrou o que já se pensava que ambos os pares tinham diferenças significantes (inferiores a 0,05 nos testes), o que confirma a interação como mais rápida, o mapa de pontos como intermediário e os mapas hipotéticos mais lento nessa tarefa confirmando H3.

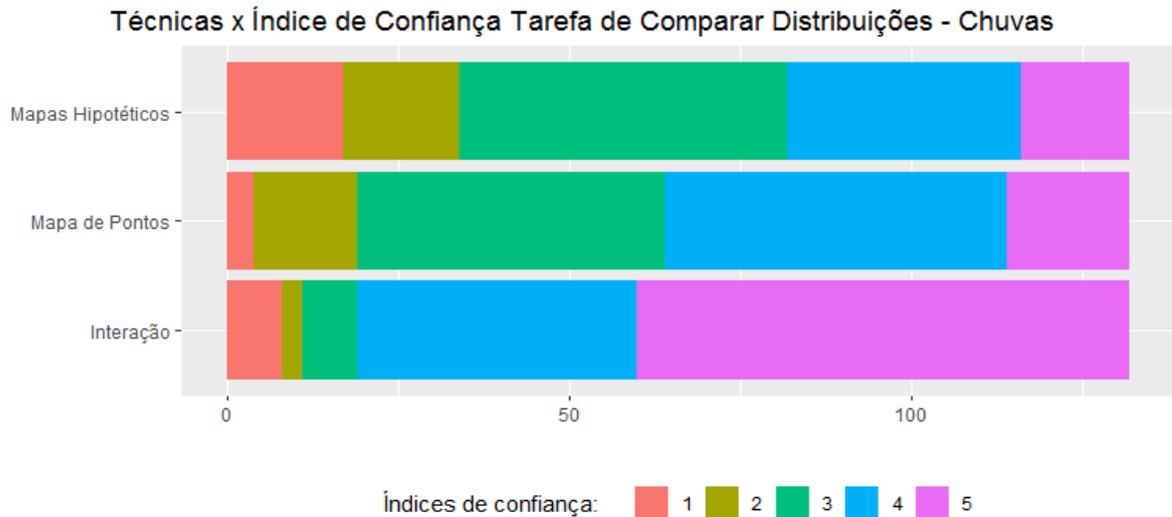


Figura 32 – Distribuição da medida de confiança por técnica para tarefa de comparar distribuições *dataset* chuvas. Fonte: O autor (2020).

A Fig. 32 revela que a técnica de interação tem seus índices de medida de confiança na escala de 4 e 5 o que é uma medida de confiança muito alta, já as técnicas de mapas hipotéticos e mapa de pontos tem desempenho parecido porém os mapas hipotéticos tem certa concentração de índice baixo de medida de confiança(1). A estatística de KW mostra ampla divergência entre as técnicas das técnicas (com *p-value* de teste de 0,000). Quando olhadas por emparelhamento todos os pares registram divergência, assim a interação é a que detém maior medida de confiança seguida pela técnica de mapa de pontos e mapas hipotéticos, embasando, portanto H2 para essa tarefa.

4.4.4 Tarefa Comparar Distribuições - *dataset* Táxis

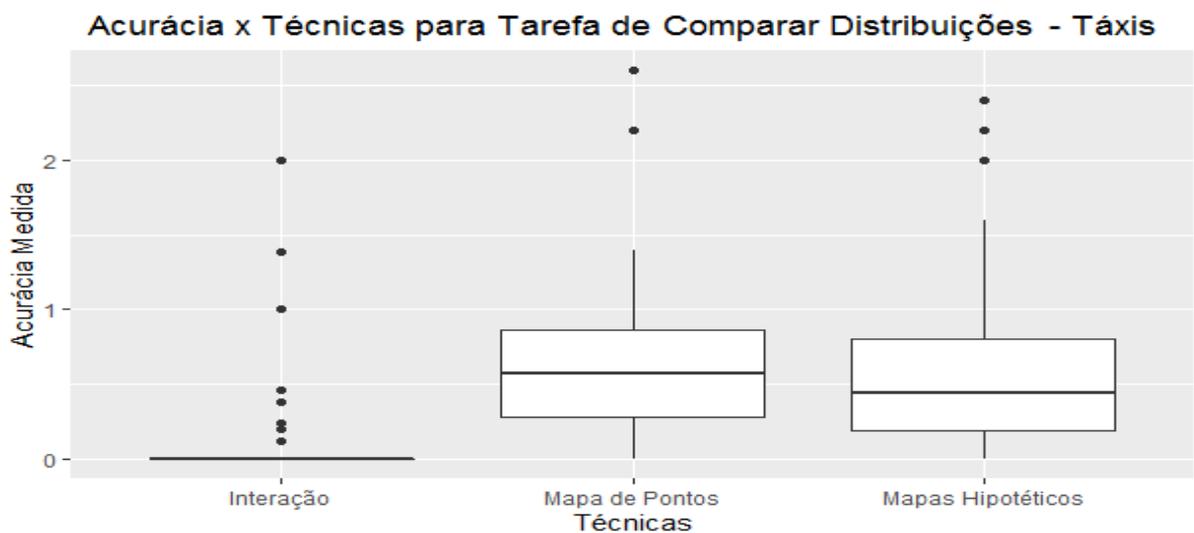


Figura 33 – Erro relativo por técnica para tarefa de comparar distribuições *dataset* táxis. Fonte: O autor (2020).

A Fig. 33 apresenta o erro relativo, mas agora para o *dataset* de táxis na tarefa de comparar distribuições. A técnica de interação assim como ocorreu nos dados das chuvas também registra os menores erros relativos, porém aqui com mais *outliers* (8), mas o resultado muito próximo de zero também. O mapa de pontos e os mapas hipotéticos tiveram um erro mais distante da técnica de interação com tamanhos bem consistentes, com erros concentrados na mesma faixa de 0,5 para as duas o que já apresenta uma diferença mais considerável. Os *outliers* deixam em dúvida se H1 se aplica totalmente a essa tarefa. Para verificar esta dúvida faz-se necessário o uso dos testes.

Tabela 17 – Resultados dos Testes para Tarefa de Comparar Distribuições *dataset* táxis.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de comparar distribuições é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativa o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	9621,500	9806,500	16447,500
<i>p-value</i>	0,000	0,000	0,093

Na Tab.17 os resultados provam que existe diferença significativa entre todas as técnicas, mas o teste por pares mostra que entre as técnicas de mapa de pontos e de mapas hipotéticos não existe diferença significativa. Com base nos testes e na distribuição dos resultados coletados é possível afirmar que a técnica de interação possui a maior precisão enquanto as demais não. Mas o mapa de pontos e os mapas hipotéticos não apresentam diferença significativa para nos permitir classificar qual é a melhor ou pior das duas. Ainda assim H1 pode ser aceita.

A Fig. 34 mostra um comportamento igual para o tempo como aconteceu nos dados das chuvas a técnica de interação registrou menor tempo enquanto as outras técnicas tiveram tempo maior com certa diferença visual. Olhando as estatísticas houve diferença entre as técnicas (KW com *p-value* de 0,000), entre os pares de técnicas também se constatou diferença em todos os casos (com *p-value* menor que 0,05). Chama atenção que ambas as técnicas registraram muitos *outliers* destacando maior dúvida, raciocínio para responder. Por fim H3 também pode ser aceita para essa tarefa.

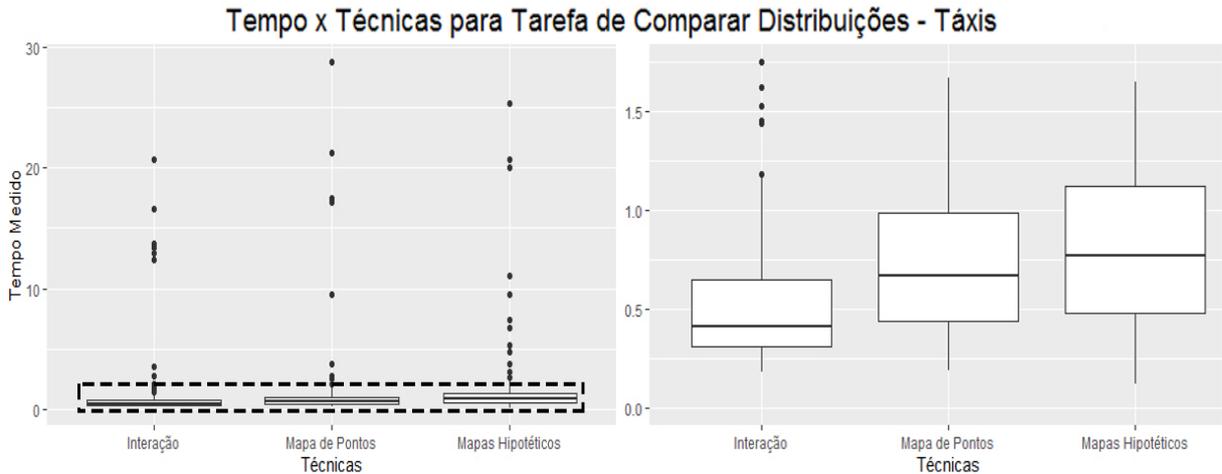


Figura 34 – Distribuição do tempo por técnica para tarefa de comparar distribuições *dataset* táxis com zoom na imagem mais a direita. Fonte: O autor (2020).

A Fig. 35 nos permite concluir que a técnica de interação registrou os maiores índices de medida de confiança, enquanto as demais registraram um espalhamento dos resultados com detalhe para os mapas hipotéticos que teve a maior concentração de índice 1. Os testes afirmaram por KW diferença significativa (de 0,000) e por todos os testes de pares também houve diferença (*p-value* de 0,000). Essas informações só confirmam H2.

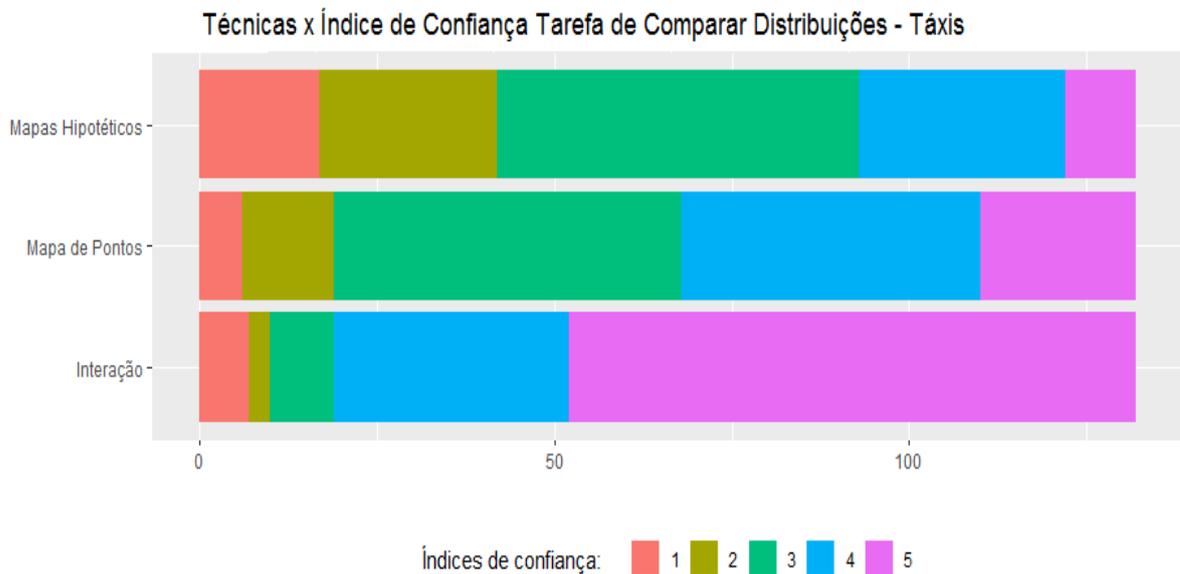


Figura 35 – Distribuição da medida de confiança por técnica para tarefa de comparar distribuições *dataset* táxis. Fonte: O autor (2020).

4.4.5 Tarefa Encontrar Extremos - *dataset* Chuvas

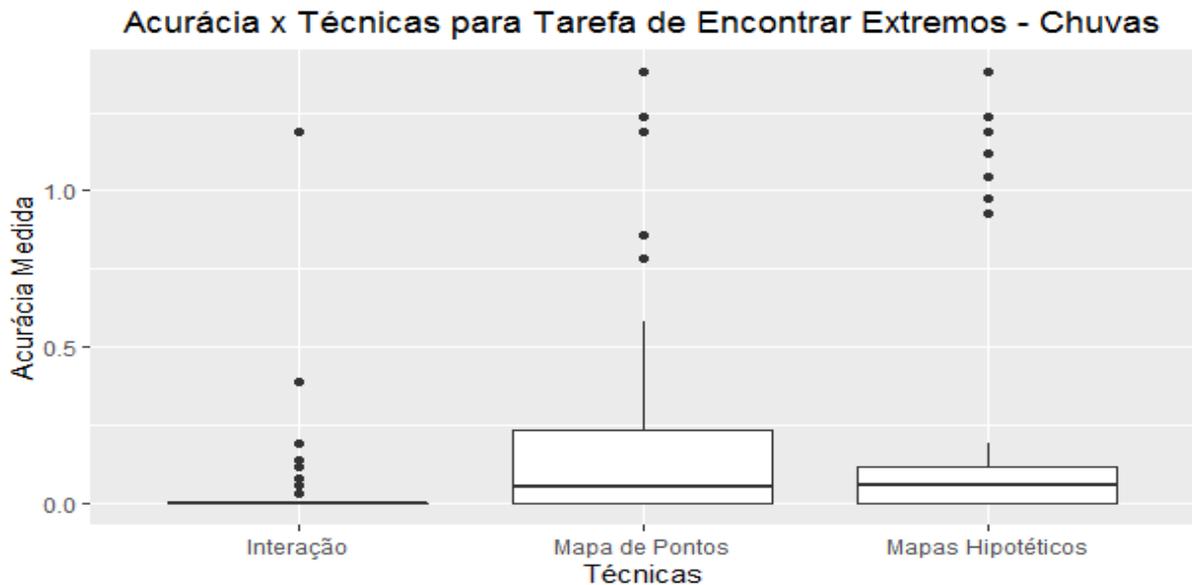


Figura 36 – Erro relativo por técnica para tarefa de encontrar extremos *dataset* chuvas. Fonte: O autor (2020).

A Fig. 36 mostra como existe uma diferença visual de erro muito apertada entre as técnicas, a única técnica que teve o tamanho do erro um pouco maior foi a de mapa de pontos, a mediana foi relativamente próxima entre as técnicas (interação - 0,00, mapa de pontos - 0,05, mapas hipotéticos - 0,06) para esta tarefa de encontrar os extremos (máximo e mínimo). Das três a técnica de interação é a que registra os menores erros relativos, conforme previsto em H1, mas como os resultados de erros foram muito pequenos as técnicas não apresentam indícios de desempenho insatisfatório. Para comparar estatisticamente as técnicas os testes são aplicados.

Tabela 18 – Resultados dos Testes para Tarefa de encontrar extremos *dataset* chuvas.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de encontrar extremos é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,001	Rejeitar a hipótese nula.
Para ser significativa o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	1627,500	1587,000	16447,500
<i>p-value</i>	0,001	0,000	0,632

A Tab.18 mostrou uma diferença significativa entre todas as técnicas, mas o teste por pares mostrou que a técnica de mapa de pontos e a de mapas hipotéticos não possuem entre si diferença significativa. Com isso a técnica de interação pode ser classificada como mais precisa enquanto que as demais não apresentaram diferença significativa para nos permitir classificar qual é a mais e a menos precisa das duas.

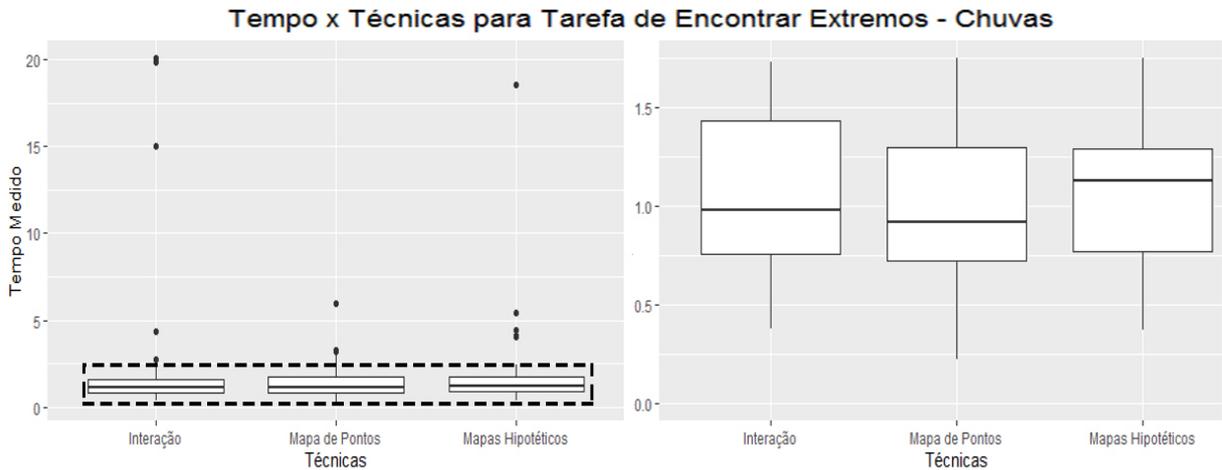


Figura 37 – Distribuição do tempo por técnica para tarefa de encontrar extremos *dataset* chuvas com zoom na imagem mais a direita. Fonte: O autor (2020).

A Fig. 37 mostra um empate visual de tempo entre as técnicas e pela primeira o teste de KW mostrou que não há diferença entre nenhuma das técnicas (p -value de 0,867), mas esse resultado ainda é suficiente para embasar H3. O único detalhe foi a presença de alguns *outliers* em todas as técnicas.

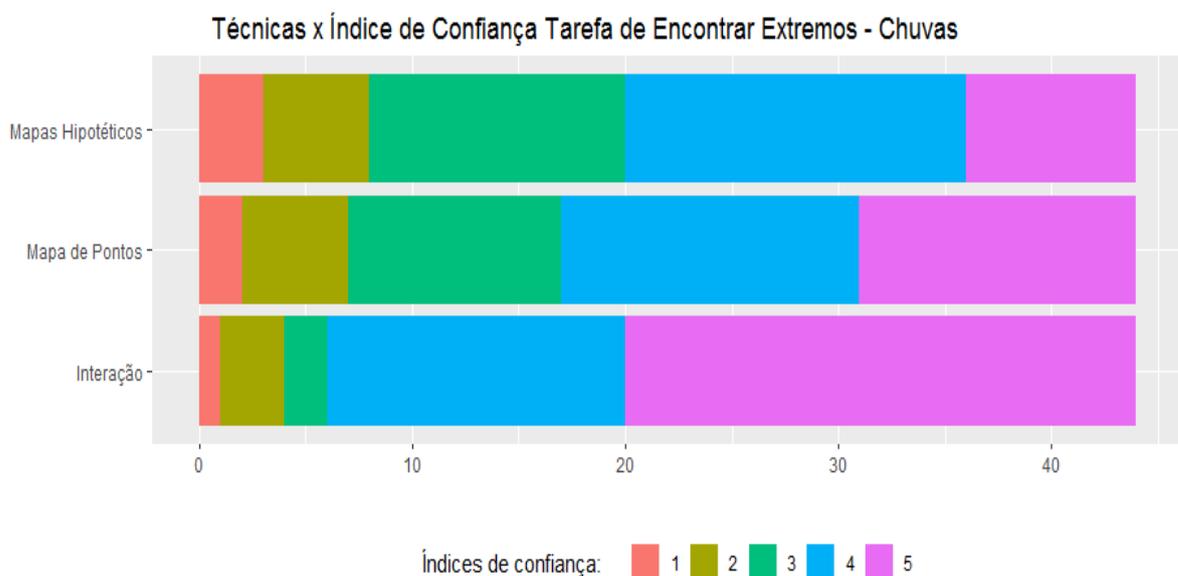


Figura 38 – Distribuição da medida de confiança por técnica para tarefa de encontrar extremos *dataset* chuvas. Fonte: O autor (2020).

A Fig. 38 traz pela primeira vez um espalhamento da medida de confiança mais próximo entre as três técnicas para uma mesma tarefa analítica. A técnica de interação ainda permanece registrando os maiores índices de medida de confiança, o mapa de pontos e os mapas hipotéticos agora passam a ter índices mais altos do que os observados frequentemente. Apesar do espalhamento mais parecido permanece uma diferença entre as técnicas (KW com p -value de 0,001), entre os pares a interação ainda se destacou das demais (p -value de 0,000 em ambas), enquanto que entre mapa de pontos e mapas hipotéticos não houve diferença (p -value de 0,322). Nesse cenário H2 é verdade.

4.4.6 Tarefa Encontrar Extremos - *dataset* Táxis

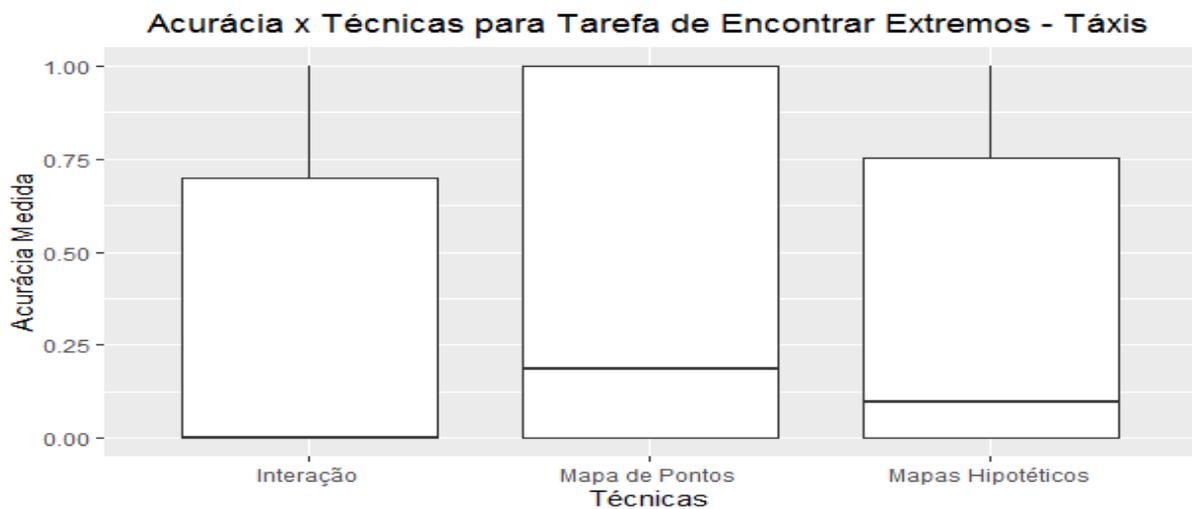


Figura 39 – Erro relativo por técnica para tarefa de encontrar extremos *dataset* táxis. Fonte: O autor (2020).

A Fig. 39 mostra a distribuição do erro relativo do *dataset* de táxis para a tarefa de encontrar os extremos (máximo e mínimo) com um grande espalhamento dos resultados das técnicas e por isso não é possível visualmente apontar uma técnica melhor do que a outra. Chama atenção o tamanho do erro que é visivelmente grande o que mostra que nesse contexto de tarefa e conjunto de dados a uma implicação de erro muito grande. A única informação diferente é a mediana, a da técnica de interação é menor comparada as demais. Então são executados os testes para verificar se há diferença no comportamento estatístico das técnicas.

Tabela 19 – Resultados dos Testes para Tarefa de encontrar extremos *dataset* táxis.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão

A distribuição da tarefa de encontrar extremos é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativa o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	1627,500	1587,000	16447,500
<i>p-value</i>	0,000	0,026	0,064

A Tab.19 mostra os resultados dos testes. Os resultados confirmam que existe uma diferença significativa entre todas as técnicas. O teste por pares mostra que a técnica de mapa de pontos e a de mapas hipotéticos não possui diferença significativa entre si o que não nos permitir classificar qual é a mais e a menos adequada das duas. Quando comparadas com a técnica de interação as demais técnicas tem diferenças. Com isso a técnica de interação com um erro relativo um pouco menor que as demais e comprovado no teste a sua diferença significativa para com as demais valida H1. O desempenho da técnica de interação aqui diverge um pouco com o que aconteceu nos dados das chuvas, com relação ao espalhamento dos dados, o que pode ser justificado pela presença de regiões próximas com mesmo padrão de dados. Isso dificulta mais encontrar os extremos por ter mais opções classificadas com as mesmas cores enquanto que no mapa de pontos a precisão da distribuição é maior e nos mapas hipotéticos é possível ver as cores mudando sendo complementadas pelos valores da distribuição.

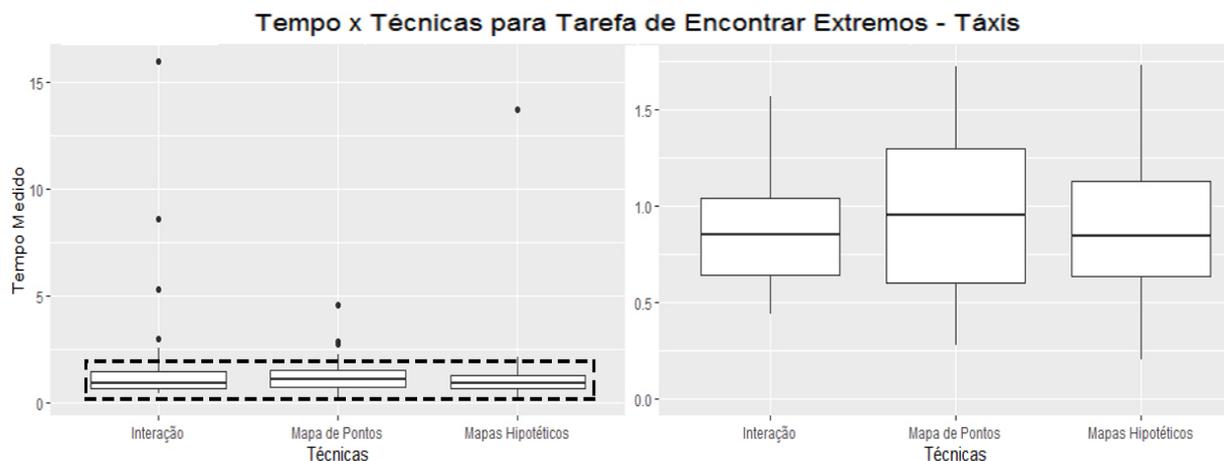


Figura 40 – Distribuição do tempo por técnica para tarefa de encontrar extremos *dataset* táxis com zoom na imagem mais a direita. Fonte: O autor (2020).

A Fig. 40 apresenta um cenário de tempo muito parecido entre os usuários. As medianas da técnica de interação e mapas hipotéticos parecem iguais, enquanto a de mapas

hipotéticos maior. Ao aplicar o teste de KW as técnicas não apresentaram diferença entre si (p -value de 0,641) o que nos permite aceitar H3. Detalhe apenas para a técnica de interação que registrou um pouco mais de *outliers*.

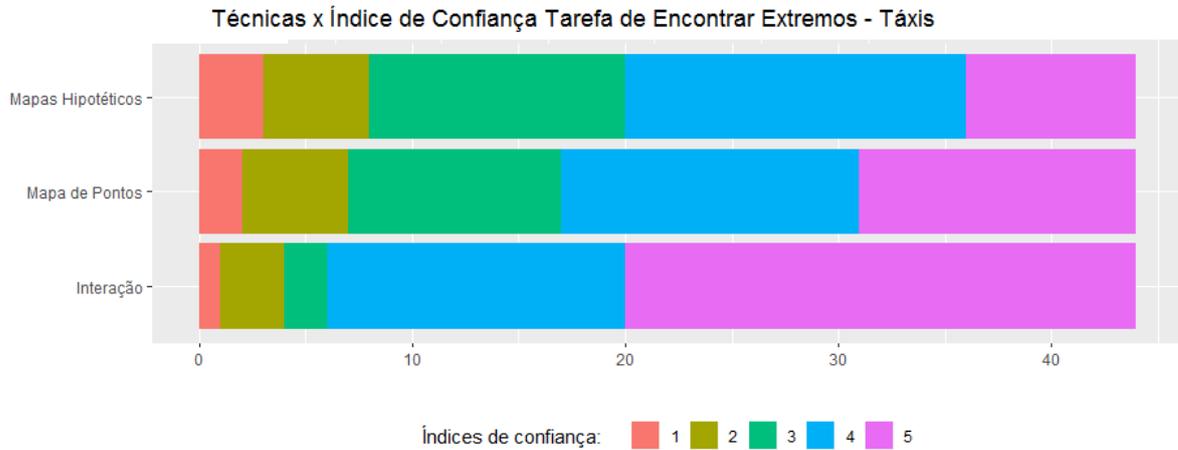


Figura 41 – Distribuição da medida de confiança por técnica para tarefa de encontrar extremos *dataset* táxis. Fonte: O autor (2020).

A Fig. 41 mostra que apesar da distribuição próxima do erro entre a técnica de interação e as demais a medida de confiança não muda e a interação ainda é a técnica com maiores índices. O teste de KW mostra diferença entre as técnicas (p -value de 0,032) e o teste de pares confirma que a interação se diferencia das demais (interação-mapa de pontos p -value de 0,035 e interação-mapas hipotéticos p -value de 0,014) enquanto entre o mapa de pontos e os mapas hipotéticos não há diferença (p -value de 0,900). Tanto visual quanto estatisticamente é possível aceitar H2.

4.4.7 Tarefa de Estimar a Média - *dataset* chuvas

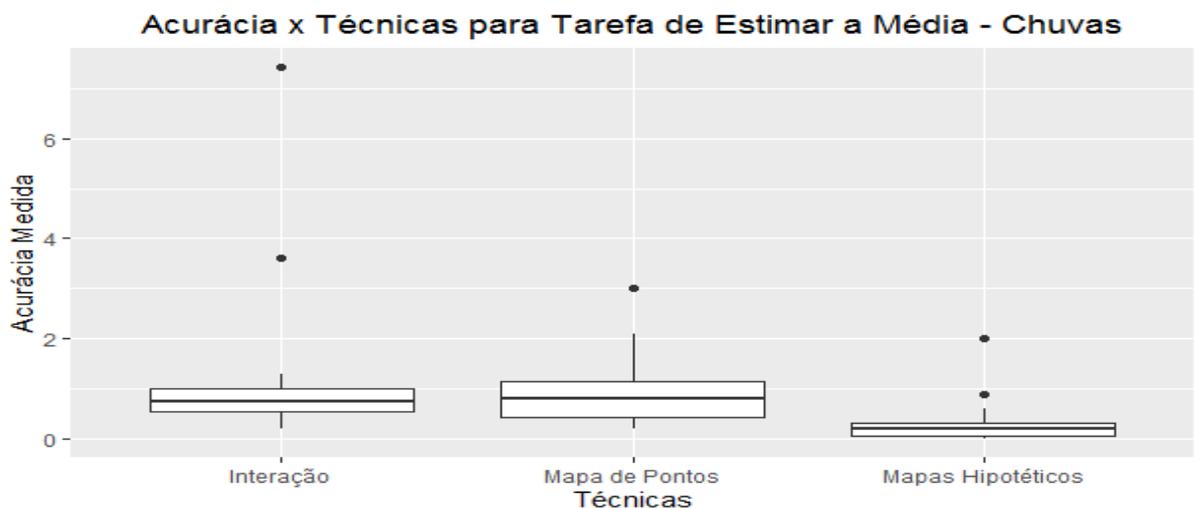


Figura 42 – Distribuição do erro por técnica para tarefa de Estimar a Média *dataset* chuvas. Fonte: O autor (2020).

A Fig. 42 mostra a distribuição do erro relativo do *dataset* de chuvas para a tarefa de estimar a média de uma região. Aqui a técnica de mapas hipotéticos registrou visualmente a menor distribuição com valores mais próximos a zero. O tamanho dos erros foi muito pequeno e bem concentrado mostrando comportamentos padronizados nas técnicas. Poucos *outliers* apareceram nos resultados das técnicas. As técnicas de interação e mapa de pontos registraram distribuições mais altas indicando que H1 não seria para esta tarefa com se esperava. Para a estatística também refutaria H1 devem ser feitos os testes.

Tabela 20 – Resultados dos Testes para Tarefa de Estimar a Média *dataset* chuvas.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de estimar a média é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,000	Rejeitar a hipótese nula.
Para ser significativo o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	483,000	317,000	350,500
<i>p-value</i>	0,777	0,000	0,001

A Tab.20 mostra os resultados dos testes. O teste de KW revela que existe uma diferença significativa entre todas as técnicas, mas o teste por pares de W mostra que entre a técnica de interação e a de mapa de pontos não existe diferença significativa enquanto que entre a técnica de mapas hipotéticos e as demais existe diferença significativa. Com isso a melhor técnica pode ser considerada a de mapas hipotéticos, como esperado a interação não possui bons resultados para esta tarefa comprovando H1.

A Fig. 43 mostra um tempo maior para a técnica de interação e um menor entre as outras técnicas com alguns *outliers*.

O teste de KW mostrou diferença (*p-value* de 0,017 entre as técnicas), os testes por pares mostraram que a técnica de interação se distanciou muito no tempo das demais (interação - mapa de pontos *p-value* de 0,007, interação - mapas hipotéticos *p-value* de 0,027), mas entre o par mapa de pontos mapas hipotéticos não (*p-value* 1,000) o que nos permite também refutar H3 para essa tarefa.

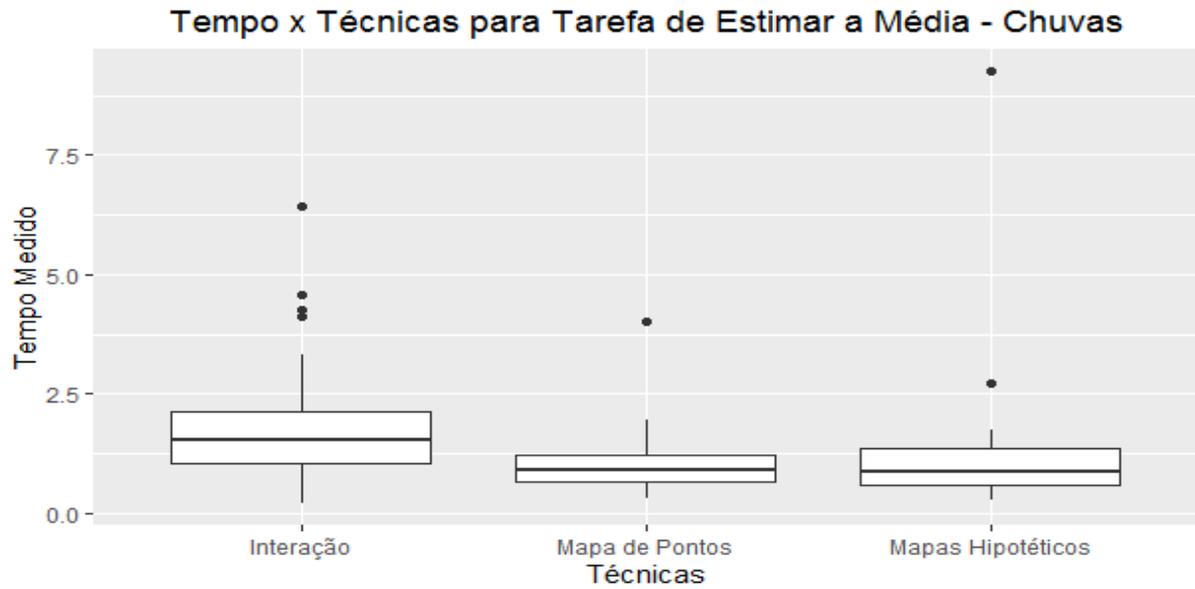


Figura 43 – Distribuição do tempo por técnica para tarefa de estimar a média *dataset* chuvas. Fonte: O autor (2020).

A Fig. 44 mostra uma inversão do que foi observado até agora, a técnica de interação não tem mais os maiores índices de medida de confiança refutando também a H2 para essa tarefa. Já as demais técnicas que obtiveram melhor acurácia tiveram maior medida de confiança. O teste de KW mostrou que a mudança na medida de confiança da interação fez com que não houve diferença entre as técnicas (p -value de 0,056).

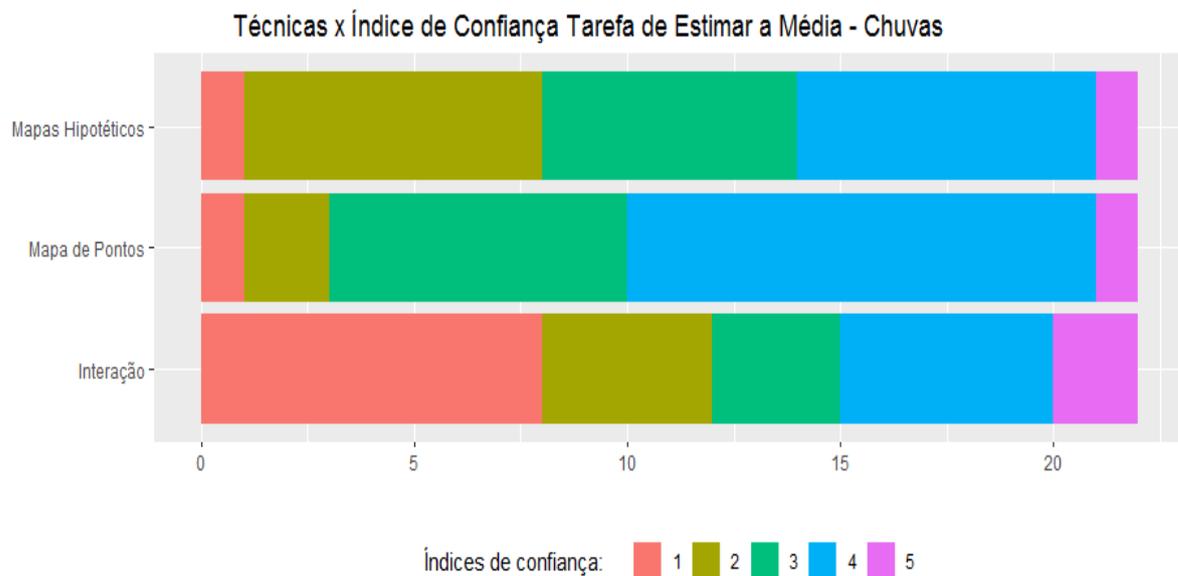


Figura 44 – Distribuição da medida de confiança por técnica para tarefa de estimar a média *dataset* chuvas. Fonte: O autor (2020).

4.4.8 Tarefa Estimar a Média - *dataset* Táxis

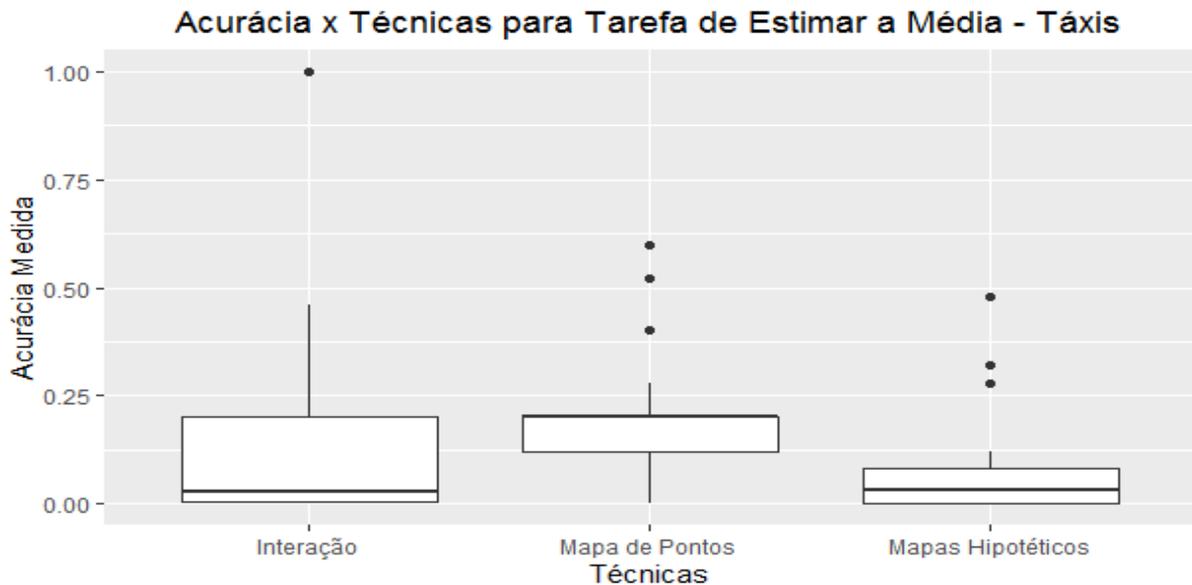


Figura 45 – Erro relativo por técnica para tarefa de estimar a média *dataset* táxis. Fonte: O autor (2020).

Na Fig. 45 a distribuição do erro relativo do *dataset* de táxis para a tarefa de estimar a média apresenta um comportamento diferente para a técnica de interação. Aqui a técnica de mapas hipotéticos registrou visualmente a menor distribuição com valores mais próximos a zero e apenas alguns *outliers*, enquanto a de interação teve erros relativos mais espalhados com maior tamanho a de mapa de pontos se comportou igual aos dados das chuvas. Apesar dos tamanhos de erros observados eles atingem índices muito baixos. Para verificar se o comportamento estatístico das técnicas é o mesmo observado nos dados das chuvas são executados os testes.

Tabela 21 – Resultados dos Testes para Tarefa de estimar a média *dataset* táxis.

Teste de Hipótese			
Hipótese nula	Teste	Sig.	Decisão
A distribuição da tarefa de estimar a média é igual nas categorias de técnicas.	Amostras Independentes de Teste de KW	0,003	Rejeitar a hipótese nula.
Para ser significativo o <i>p-value</i> deve ser menor ou igual a 0,05.			
Estatísticas de teste por pares			
	F1-F2	F1-F3	F2-F3
Wilcoxon W	1627,500	1587,000	16447,500
<i>p-value</i>	0,051	0,202	0,000

Na Tab.21 o resultado do teste de KW revela que existe uma diferença entre todas as técnicas, mas o teste por pares de W mostra que entre a técnica de mapa de pontos-interação e entre interação-mapas hipotéticos não existe comportamento significativo. Já entre o mapa de pontos e os mapas hipotéticos a diferença é significativa. É possível ver uma melhora no desempenho da técnica de interação as medianas confirmam isso (interação - 0,027; mapa de pontos - 0,2; mapas hipotéticos - 0,029), essa melhora pode ser explicada pela variância da distribuição dos dados de táxis onde a variação é alta o que permite mais facilmente identificar resultados enquanto que nos dados das chuvas a variação é alta o que dificulta e gera um erro relativo maior. E com um erro tão próximo de zero de ambas as ferramentas podem ser consideradas com bons resultados.

Assim a interação teve um melhor resultado para a tarefa de estimar a média quando as regiões eram formadas por distribuições de dados com pouca variação, isso aconteceu é preciso rejeitar a hipótese H1.

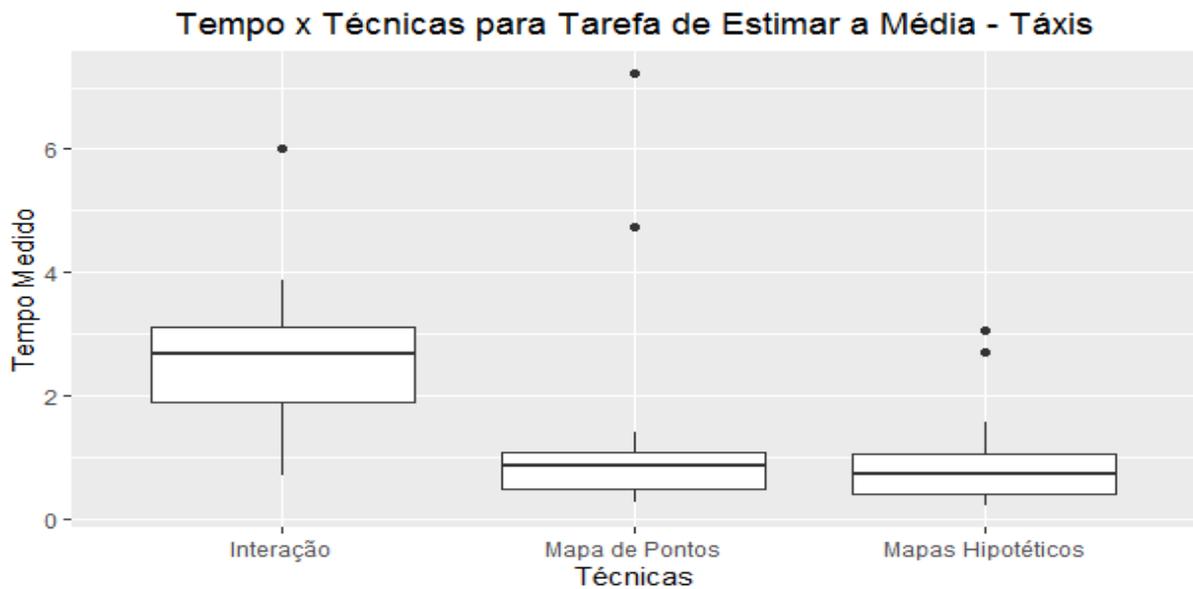


Figura 46 – Distribuição do tempo por técnica para tarefa de estimar a média *dataset* táxis. Fonte: O autor (2020).

Na Fig. 46 esta representado o resultado do tempo dos usuários onde o tempo maior foi registrado pela técnica de interação e o menor visualmente igual entre as outras com os mapas hipotéticos um pouco mais precisos que o mapa de pontos. Testando as técnicas por KW existe diferença entre elas (p -value de 0,000). O desempenho do tempo da interação é totalmente diferente das demais nos pares (p -value de 0,000 para todos os casos), enquanto que o par mapa de pontos - mapas hipotéticos não (p -value de 0,769). Assim como esperado H3 é rejeitada para essa tarefa.

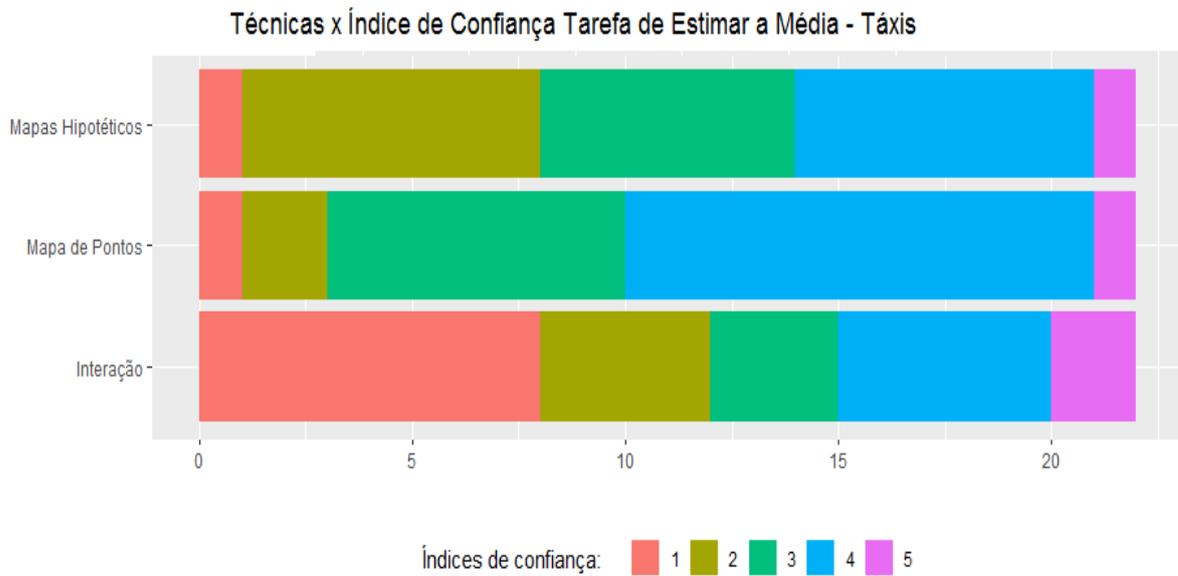
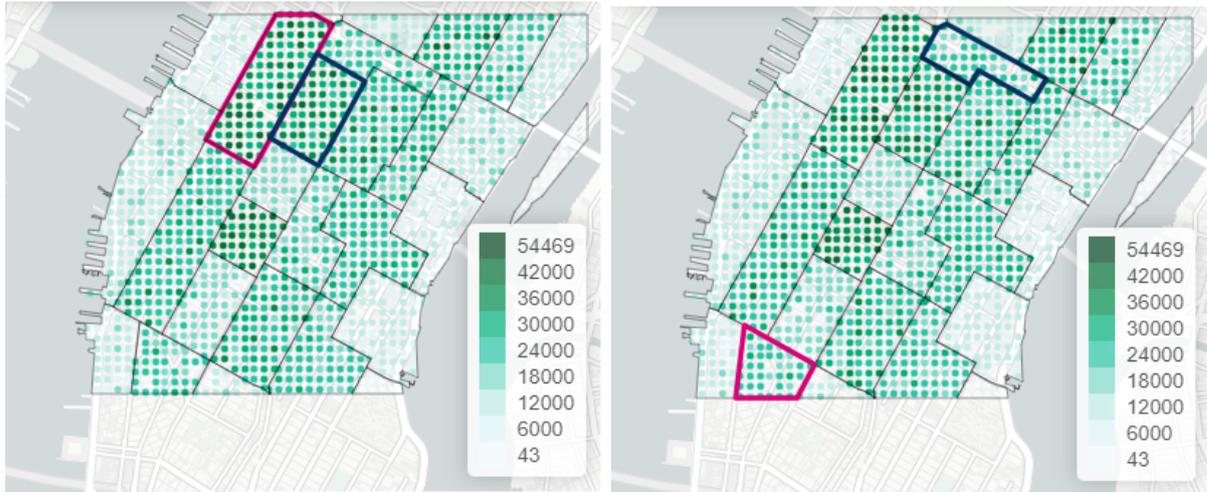


Figura 47 – Distribuição da medida de confiança por técnica para tarefa de estimar a média *dataset* táxis. Fonte: O autor (2020).

A Fig. 47 não traz nenhuma novidade comparado aos dados das chuvas, a medida de confiança da interação registra os menores índices. Como esperado H2 não se aplica a esta tarefa. As técnicas de mapa de pontos e mapas hipotéticos tem, portanto, os melhores índices de medida de confiança. Até estatisticamente não há nenhuma diferença entre as técnicas (KW com *p-value* de 0,149).

4.5 ANÁLISE QUANTITATIVA - FATORES DA TAREFA DE COMPARAR DISTRIBUIÇÕES

Nesta seção, é discutido o impacto de fatores como distância entre as regiões comparadas, variação nos dados das regiões comparadas e tamanho dos polígonos comparados sobre a acurácia na tarefa de comparar distribuições. Para analisar as variáveis de fatores foi escolhida a tarefa de comparar distribuições por envolver duas regiões simultaneamente. Para escolha das regiões a serem testadas foi necessário uma análise e seleção manual dos dois conjuntos de dados para isolar as variáveis e selecionar casos de regiões que ao serem comparadas pelo usuário satisfazem a análise dos fatores. Ao final para os 3 fatores e suas variações (totalizando 6 cenários diferentes) existe um conjunto de 12 regiões selecionadas (2 para ser testada em cada cenário), para cada conjunto de dados. As figuras Fig. 48, Fig. 49 e Fig. 50 retratam como esses fatores foram retratados para o usuário, em especial aqui utilizamos a técnica de mapa de pontos para demonstração.



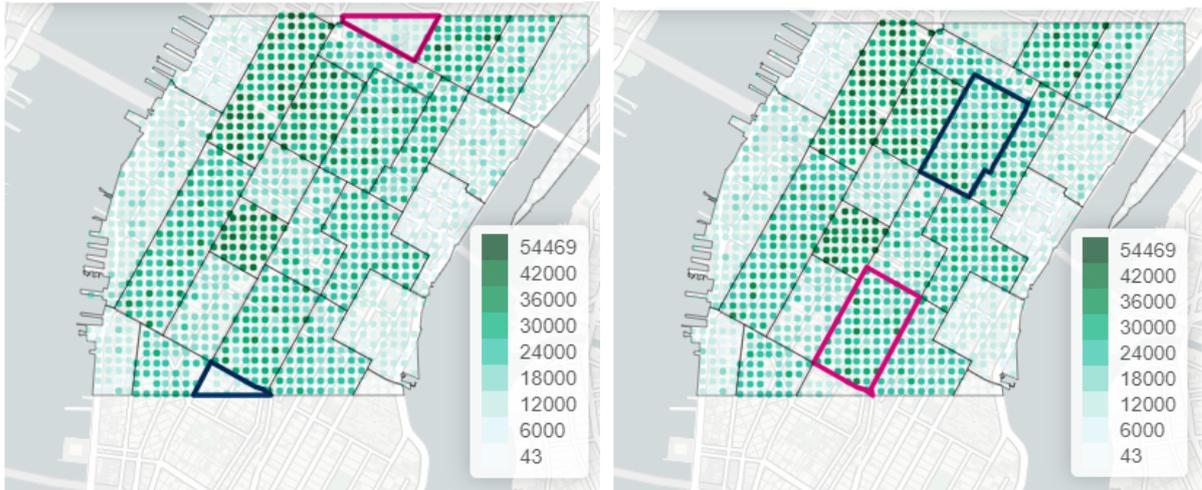
(a) Fator de curta distância entre as regiões (b) Fator de longa distância entre as regiões.

Figura 48 – Uso do fator de distâncias no estudo na técnica de mapa de pontos. Fonte: O Autor (2020).



(a) Fator de baixa variação entre as regiões (b) Fator de alta variação entre as regiões.

Figura 49 – Fator de variação dos dados das regiões no estudo na técnica de mapa de pontos. Fonte: O Autor (2020).



(a) Fator de tamanho pequeno entre as regiões (b) Fator de tamanho grande entre as regiões.

Figura 50 – Representação do tamanho das regiões como fator na técnica de mapa de pontos. Fonte: O Autor (2020).

4.5.1 Resultados Técnica de mapa de pontos

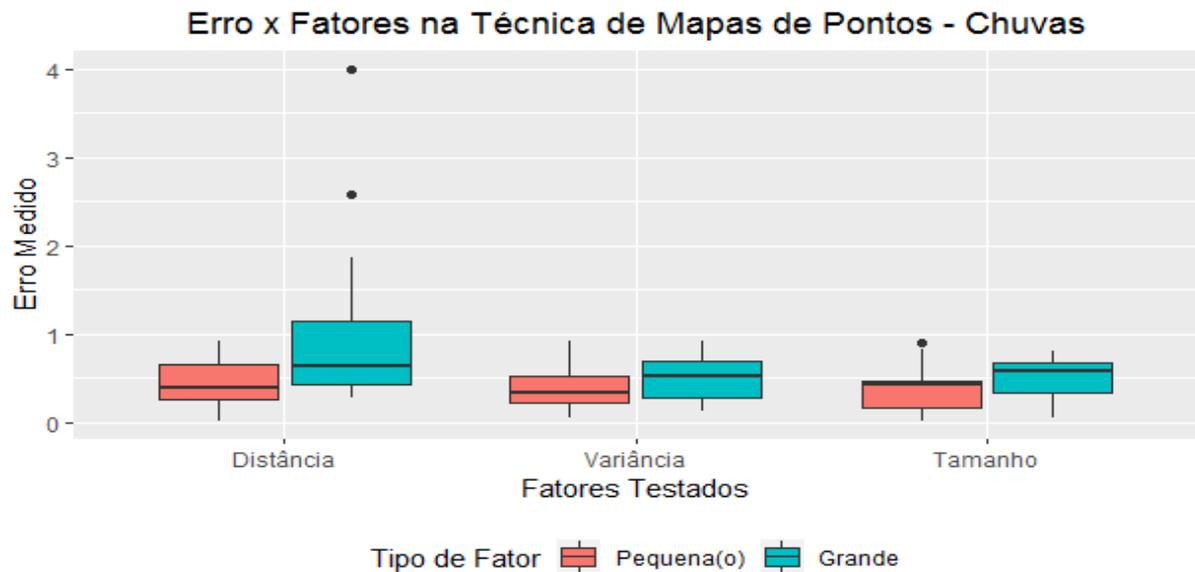


Figura 51 – Erro relativo por fatores para a técnica de mapa de pontos *dataset* chuvas. Fonte: O autor (2020).

Para a técnica de mapa de pontos os resultados mostram que nos dados de chuvas todos os tipos de fatores grandes registraram maior erro relativo do que os tipos de fatores pequenos. Assim H5 parece ser válida para esse contexto. Para avaliar o comportamento estatístico dos dados é realizado testes para responder qual ou quais fatores divergem mais.

Tabela 22 – Resultados dos testes entre os fatores estudados para a técnica de mapa de pontos no *dataset* chuvas

Estatísticas de teste por pares			
	D - D +	V - V +	T - T +
Wilcoxon W	380,000	427,000	433,000
<i>p-value</i>	0,007	0,110	0,145

Testamos os pares dos fatores: distância longa e curta, variância alta e baixa e tamanho grande e pequeno. Os resultados de W mostram que apenas o fator distância (par longa e curta distâncias), no mapa de pontos possui uma diferença significativa, confirmando então H5 apenas para distância.

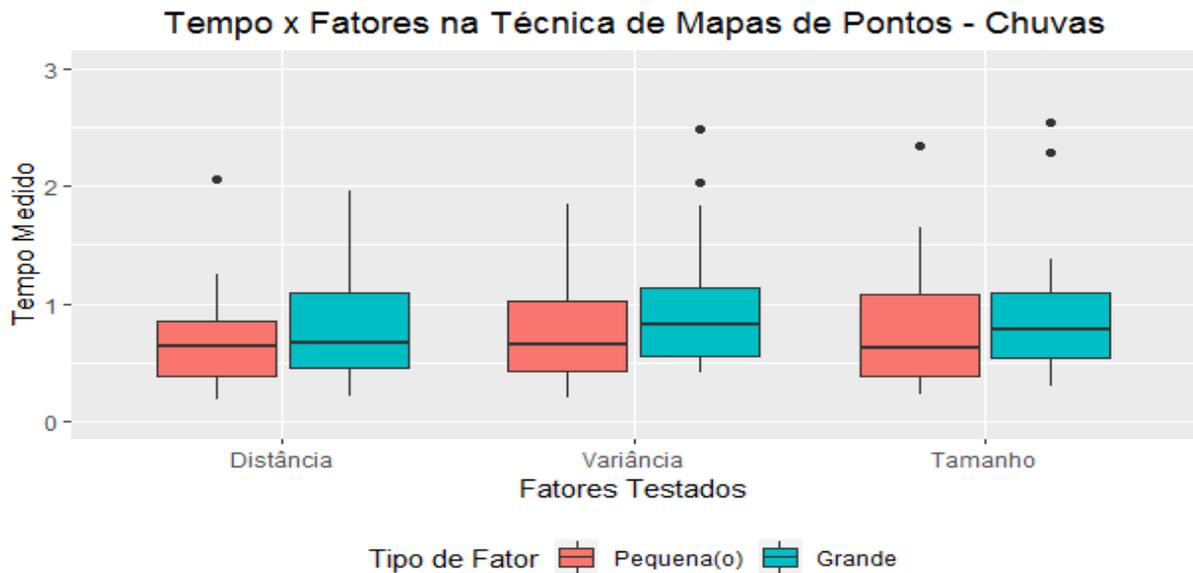


Figura 52 – Distribuição do tempo por fatores para a técnica de mapas de pontos *dataset* chuvas. Fonte: O autor (2020).

A Fig. 52 apresenta o tempo de resposta de cada fator, em todos os casos o tempo foi maior ou superior nos tipos de fatores grandes do que nos tipos de fatores pequenos. A análise estatística, no entanto, não apresentou diferenças entre os pares de fatores (*p-value* de distâncias 0,664, *p-value* de variância 0,218, *p-value* de tamanhos 0,324), mostrando que apesar do tempo maior nos tipos de fatores grande H4 não tem diferença significativa suficiente para provar que é verdadeira.

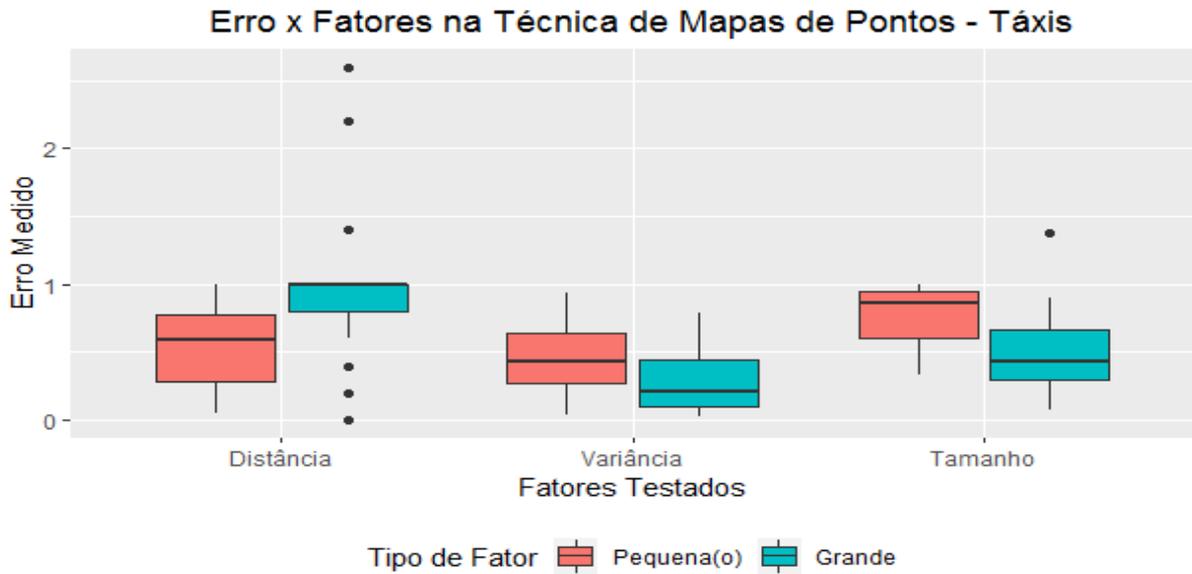


Figura 53 – Erro relativo por fatores para a técnica de mapa de pontos *dataset* táxis. Fonte: O autor (2020).

Para a técnica de mapa de pontos nos dados de táxis o comportamento da distância foi o mesmo observado nos dados das chuvas, com alguns *outliers*. Já os outros fatores de variação e tamanho ocorreu o inverso: os tipos de fatores pequenos registraram maior erro relativo do que os tipos de fatores grandes.

Tabela 23 – Resultados dos testes entre os fatores estudados para a técnica de mapa de pontos no *dataset* táxis.

Estatísticas de teste por pares			
	D - D +	V - V +	T - T +
Wilcoxon W	380,000	399,000	433,000
<i>p-value</i>	0,007	0,024	0,002

Os testes por pares de W mostram que todos os fatores registraram diferença significativa, isso pode ser explicado devido a algumas pequenas particularidades observadas nos dados dos táxis. Nesse conjunto de dados a variação no geral é pequena, assim os polígonos têm variação extremamente próxima ou muito diferente e os tamanhos dos polígonos apesar de serem diferentes são mais proporcionais com formato regulares do que os polígonos dos dados das chuvas. Como no geral dentre os fatores só a distância teve diferença significativa H_5 só é verdadeira para a distância, logo consideramos que usar o mapa de pontos seja mais difícil em regiões distantes ou muito próximas.

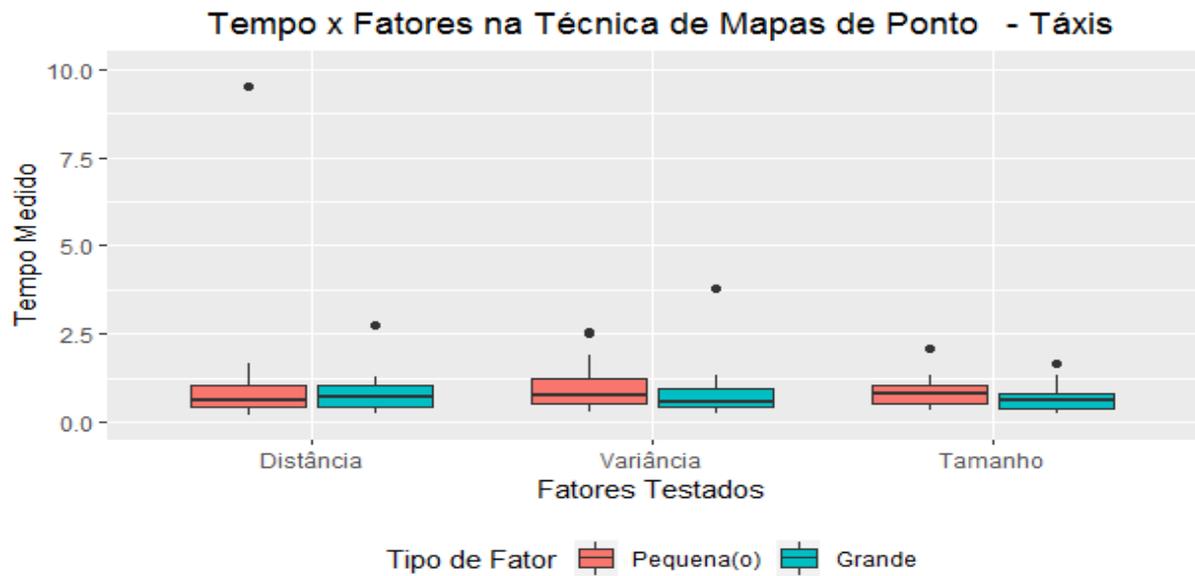


Figura 54 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos *dataset* táxis. Fonte: O autor (2020).

A Fig. 54 apresenta o comportamento do tempo de resposta em relação a cada fator, não foi registrado visualmente diferenças apenas alguns *outliers*, os testes por pares também não identificaram diferença (p -value de distâncias 0,972, p -value de variância 0,162, p -value de tamanhos 0,133) por isso H4 não se confirma para a técnica de mapa de pontos.

4.5.2 Resultados Técnica de Mapas Hipotéticos

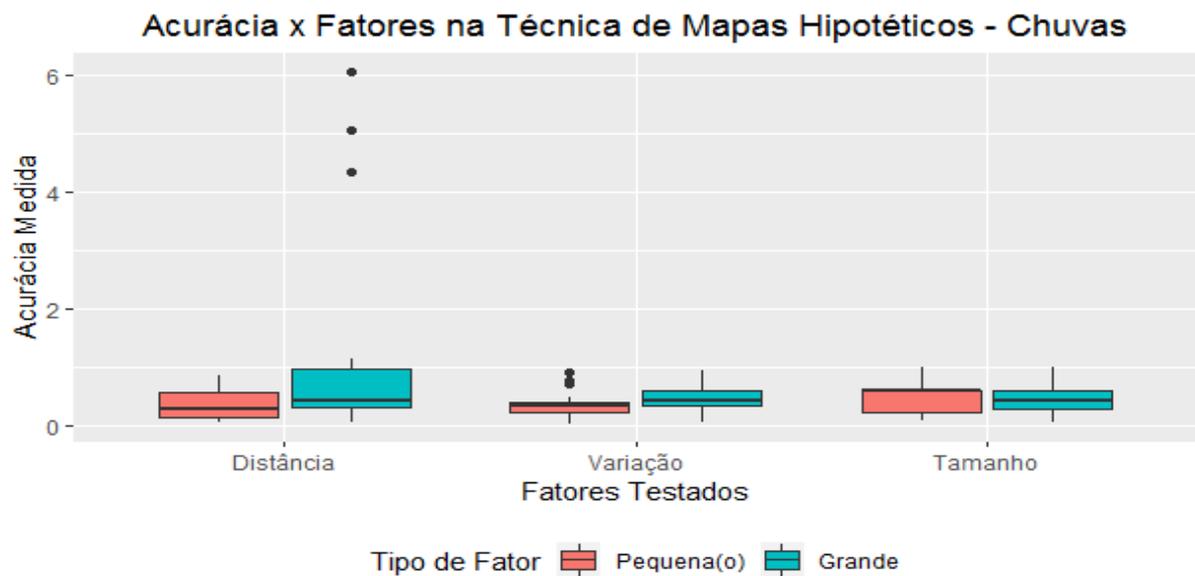


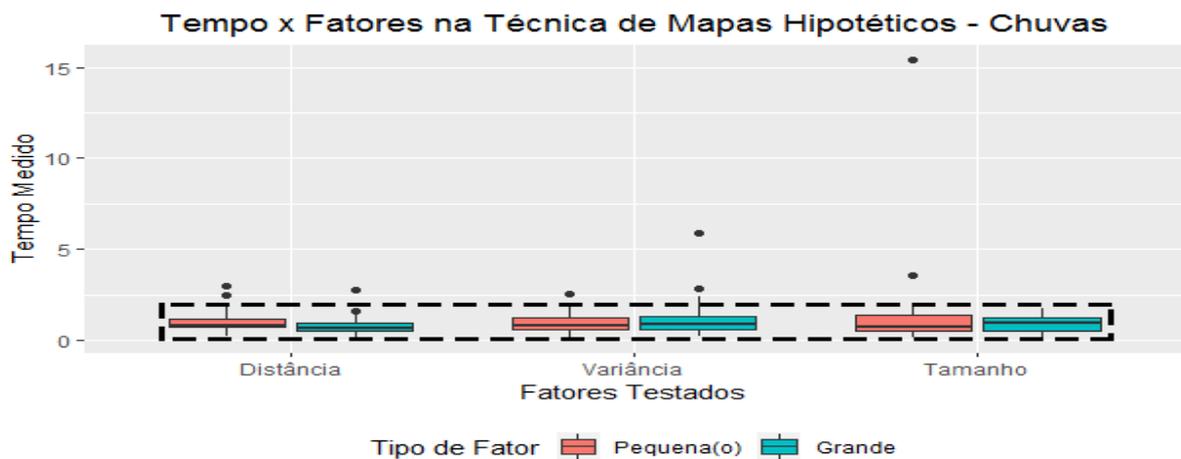
Figura 55 – Erro relativo por fatores para a técnica de mapas hipotéticos *dataset* chuvas. Fonte: O autor (2020).

Para a técnica de mapas hipotéticos nos dados das chuvas todos os tipos de fatores grandes registraram maior erro relativo do que os tipos de fatores pequenos, assim H5 é validada já visualmente. Para confirma H5 é aplicado os testes para responder se há diferenças.

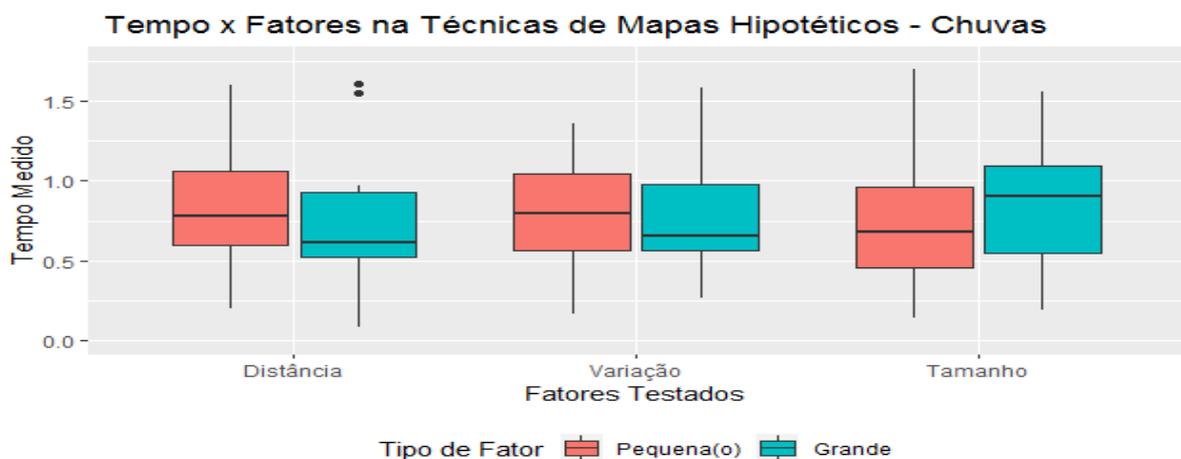
Tabela 24 – Resultados dos testes entre os fatores estudados para a técnica de mapas hipotéticos *dataset* chuvas

Estatísticas de teste por pares			
	D - D +	V - V +	T - T +
Wilcoxon W	395,000	426,000	477,000
<i>p-value</i>	0,019	0,105	0,672

Os testes por pares de W mostram que apenas o fator distância entre as regiões possui uma diferença significativa confirmando que H5 só é válida para a distância.



(a) Comportamento observado



(b) Zoom aplicado sobre a visualização

Figura 56 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos *dataset* chuvas. Fonte: O autor (2020).

A Fig. 56 apresenta o tempo de resposta dos fatores medido para o conjunto de dados das chuvas nos mapas hipotéticos. Nenhum fator registrou distribuições muito diferentes nos testes por pares (p -value de distâncias 0,173, p -value de variância 0,805, p -value de tamanhos 0,707), não sendo possível aceitar H4.

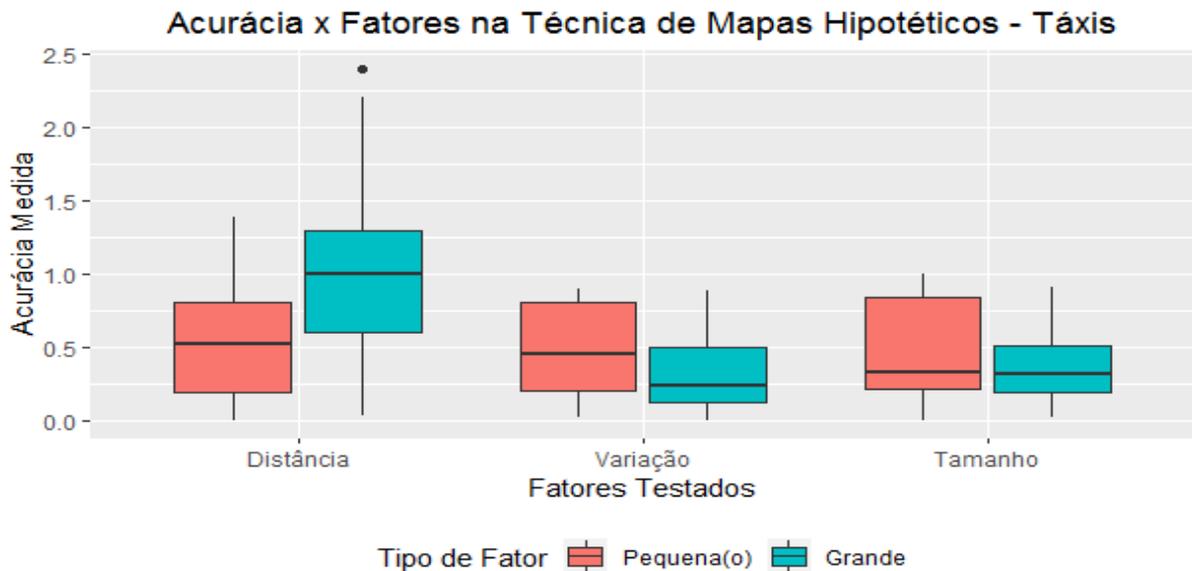


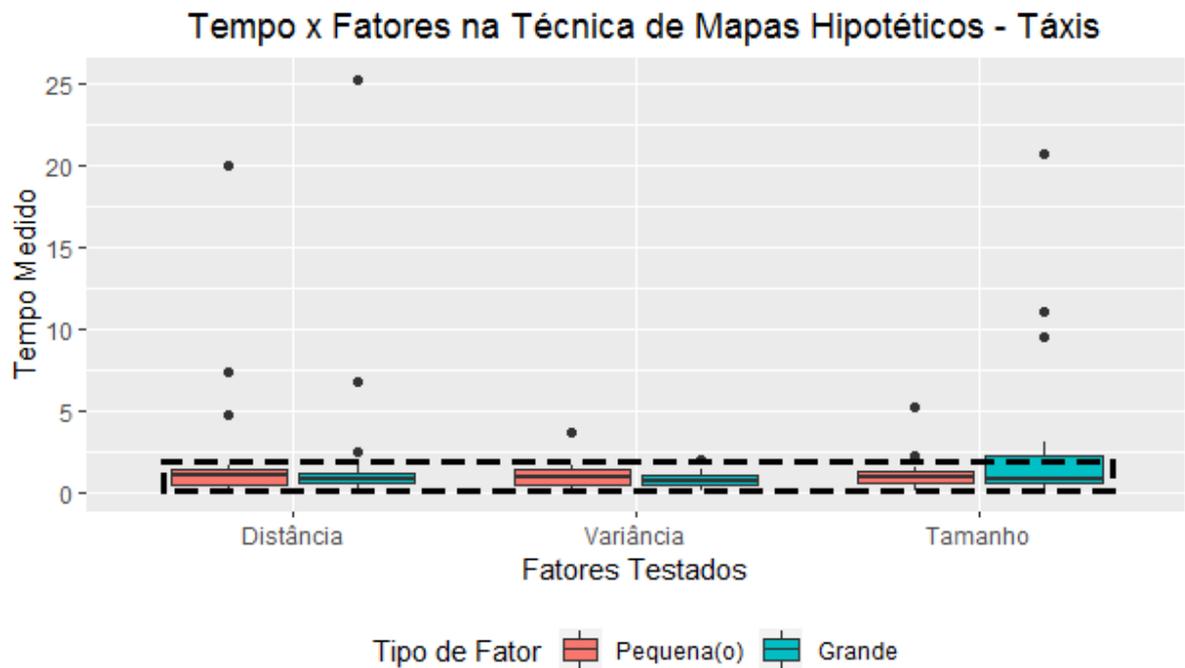
Figura 57 – Erro relativo por fatores para a técnica de mapas hipotéticos *dataset* táxis. Fonte: O autor (2020).

Para a técnica de mapas hipotéticos os resultados se comportaram de forma semelhante aos resultados da técnica de mapa de pontos nos dados dos táxis. Apenas a distância confirmou H5. Analisando os dados estatisticamente é possível ver qual ou quais fatores se diferenciam mais.

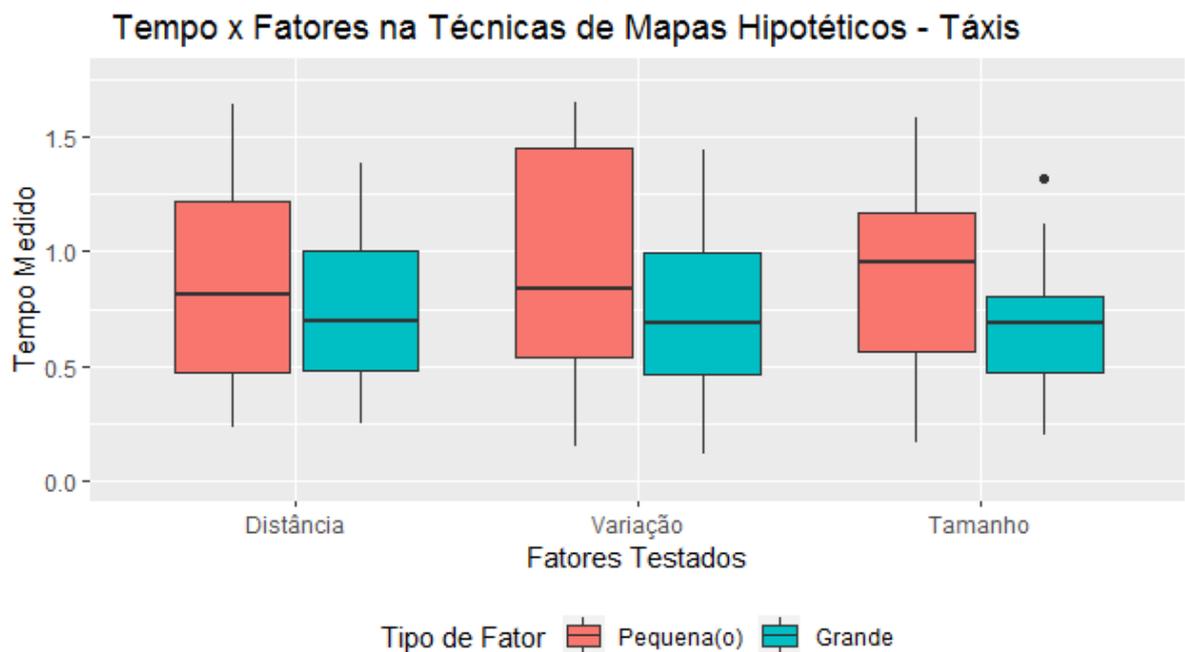
Tabela 25 – Resultados dos testes entre os fatores estudados para a técnica de mapas hipotéticos *dataset* táxis.

Estatísticas de teste por pares			
	D - D +	V - V +	T - T +
Wilcoxon W	377,000	416,000	448,000
p -value	0,005	0,063	0,269

Os resultados dos testes mostram que o comportamento da distância entre as regiões possui uma diferença significativa. O que nos permite concluir que a distância realmente importa e confirma H5.



(a) Comportamento observado.



(b) Zoom aplicado sobre a visualização.

Figura 58 – Distribuição do tempo por fatores para a técnica de mapas hipotéticos *dataset* táxis. Fonte: O autor (2020).

A Fig. 58 apresenta o tempo de resposta medido onde contrariando o esperado por H4 nenhum tipo de fator grande registrou maior tempo pelo contrário a diferença entre os tipos de fatores grande e pequeno chega a ser um pouco maior visualmente falando. Olhando para os testes de pares não é possível identificar divergências no comportamento dos fatores (p -value de distâncias 0,699, p -value de variância 0,324, p -value de tamanhos

0,944), terminando por concordar que H4 não se aplica.

4.6 DISCUSSÕES

Os resultados confirmam que das três técnicas a visualização com interação foi a que gerou maior acurácia nas respostas do usuário para as tarefas, com exceção de estimar a média confirmando a hipótese $H1$ que dizia que a interação seria a mais precisa para 3 das 4 tarefas. Os *plots* de média de confiança nos permitem afirmar que o mapa de pontos e os mapas hipotéticos tiveram índices de medida de confiança mais baixo que a técnica de interação conforme previsto em $H2$. Com exceção da tarefa de estimar a média a $H3$ é comprovada pois o tempo de resposta do usuário na técnica de interação foi menor ou igual ao tempo registrado pelas outras técnicas. A $H4$ dizia que com o fature de distância o tempo de resposta apresentaria diferenças significativas, mas isso não foi comprovado, o tempo de resposta do usuário não aumentou apesar da distância geográfica entre as regiões nas técnicas. Quanto aos fatores de distância, tamanho e variação da distribuição de cada polígono apenas a distância se provou como fator que impacta negativamente a acurácia do usuário para as respostas das tarefas nas técnicas de mapa de pontos e mapas hipotéticos. Confirmando parcialmente a $H5$, já que essa hipótese previa que todos os fatores teriam diferença significativa entre si em termos de erro.

5 CONCLUSÃO

Este estudo teve como finalidade comparar três técnicas de representação de distribuição de probabilidade em dados geográficos. Para tanto, primeiramente, buscou-se fazer um levantamento bibliográfico a respeito das técnicas envolvidas. Esse levantamento nos permitiu selecionar três técnicas que foram adaptadas para visualizações de dados geográficos. Para comparar estas adaptações foi aplicado um questionário com perguntas sobre tarefas analíticas descritas na literatura e foram medidas a acurácia, o tempo e a medida de confiança para cada uma das técnicas. O estudo se deu utilizando dados reais através de uma plataforma criada unicamente para realização desse trabalho, essa plataforma permitiu ainda coletar alguns comentários sobre a percepção dos usuários para visualizações. A coleta e análise dos dados indicaram que a técnica de interação possui melhor desempenho em acurácia (erro relativo), tempo e medida de confiança para as tarefas de extrair valor, comparar distribuições, e encontrar extremos. Estatisticamente, os resultados da técnica de interação apresentaram diferenças significativas com relação as demais técnicas para acurácia, tempo e medida de confiança. A única tarefa que a técnica de interação não obteve bons resultados foi a tarefa de estimar a média, para esse caso a técnica de mapas hipotéticos tem os melhores resultados. Observou-se também que um comportamento comum das técnicas de mapa de pontos e mapas hipotéticos, mesmo na tarefa de estimar a média em que seus resultados podem ser considerados satisfatórios foram as medidas de confiança que permaneciam baixos, o que pode ser explicado em comentários sobre a ausência de precisão que as técnicas de pontos e de mapas hipotéticos não conseguem fornecer para o usuário. Outro fato também destacado é o fato da técnica de interação automatizar o processo de cálculo e disponibilização da resposta de modo simples, o que gera certa desconfiança nos usuários sobre a facilidade para obter respostas. Assim estimam-se alcançados os objetivos propostos desta pesquisa.

Algumas limitações aconteceram neste estudo, que apontam também para futuras direções de pesquisa. Por se tratar de um estudo voluntário que precisa de algum tipo de acompanhamento e que leva uma média de 30 minutos para ser respondido o número de voluntários limitou-se a 66. Também por se tratar de um recrutamento voluntário não foi possível balancear a quantidade de participantes entre os perfis: sexo, experiência com estatística, experiência com visualização e nível de escolaridade. Sem esse balanceamento e com amostra não tão grande não foi possível realizar testes estatísticos para verificar se esses perfis influenciam ou não na precisão das respostas dos usuários. A base de dados utilizada também precisa ser mais estudada para entender com mais detalhes o papel da base de dados nas tarefas. Por exemplo os dados das regiões quando bem definidos, isto é, possuem pouca variação podem aumentar a precisão bem como o caso contrário pode dificultar a precisão das respostas. Além disso, há a necessidade de se investigar a influência

da quantidade de regiões nas respostas. Neste estudo, usamos dois *datasets* que possuem quantidades diferentes de regiões (chuvas - 178 regiões, táxis - 29 regiões) porque mais de um conjunto de dados com características diferentes podem revelar comportamentos diferentes para uma mesma tarefa dada a particularidade de cada conjunto de dados. Isto permitirá ter uma recomendação mais direta sobre que técnica usar em cada situação. Bem como o formato dos polígonos, formatos regulares ou irregulares podem também impactar no modo como as técnicas são representadas especialmente o caso dos pontos. O mesmo raciocínio vale para o tamanho dos polígonos por exemplo o *dataset* de táxis possui mais uniformidade no tamanho dos seus polígonos, mas possui algumas regiões extremamente pequenas em área geométrica o que reflete na visualização o polígono fica quase invisível. Assim é importante avaliar posteriormente esses detalhes. Outra limitação apontada é testar se a capacidade de quantificar incerteza realmente leva a melhores decisões na prática.

Fatores pessoais dos usuários podem representar limitações, usuários com personalidades naturais de insegurança ainda que se sintam seguros de suas respostas refutaram responder confiança máxima na técnica de interação e se sentem desconfiados que alcançar suas respostas seja algo considerado "trivial", a ausência desse fenômeno poderia ter aumentado a medida de confiança na técnica de interação. Assim é interessante investigar o papel de fatores externos difíceis de serem medidos como a autoconfiança e nervosismo pessoal do participante como fatores que pode influenciar na eficiência de uma técnica.

Uma outra direção de investigação é analisar se tipos de perfis influenciam na eficiência de cada técnica através de mais coletas de dados de modo segmentado para comparar perfis. Por exemplo, pessoas com maior grau de formação podem ter mais facilidade de entender e até quantificar mentalmente a incerteza enquanto que pessoas com menor grau de formação não. Pessoas com mais experiência em estatística podem demorar mais tempo, ter menos confiança e uma acurácia incerta por quererem responder as perguntas com máximo de embasamento matemático possível. Pessoas com mais experiência em visualização podem compreender melhor os elementos utilizados no contexto espacial para representar a presença da incerteza, o que pode facilitar o entendimento das distribuições das regiões e assim aumentar a precisão. Entender se esses perfis impactam os resultados pode ajudar a modelar soluções de quantificação de incerteza em dados geográficos tanto para leigos quando para especialistas nos perfis.

Além disso, pretende-se estudar variações adicionais das técnicas propostas e, até mesmo, abordagens híbridas. Em particular avaliar se a técnica de mapa de pontos com a organização da distribuição dos pontos dentro de polígonos, seguindo um padrão (por exemplo, de alta densidade no centro e de pequena densidade nas extremidades), influência positivamente no desempenho das tarefas.

Por fim, também devem ser conduzidos novos testes comparando as técnicas com dados sintéticos que permitam ter um melhor controle sobre elementos como o tamanho

de polígonos e etc. Testando conjuntos de polígonos e dados padronizados sinteticamente podemos descobrir qual o perfil de base de dados com que as técnicas de mapa de pontos e mapas hipotéticos tem melhor e pior desempenho.

REFERÊNCIAS

- AMAR, R.; EAGAN, J.; STASKO, J. Low-level components of analytic activity in information visualization. In: *IEEE Symposium on Information Visualization, 2005. INFOVIS 2005*. IEEE, 2005. Disponível em: <[https://doi.org/10.1109%2Finfvis.2005.1532136](https://doi.org/10.1109/2Finfvis.2005.1532136)>.
- ANDRIENKO, N.; ANDRIENKO, G. *Exploratory Analysis of Spatial and Temporal Data: A Systematic Approach*. Springer-Verlag, 2006. ISBN 978-3-540-25994-7. Disponível em: <<https://doi.org/10.1007/3-540-31190-4>>.
- BELIA, S.; FIDLER, F.; WILLIAMS, J.; CUMMING, G. Researchers misunderstand confidence intervals and standard error bars. *Psychological methods*, American Psychological Association, v. 10, n. 4, p. 389, 2005. Disponível em: <<https://doi.org/10.1037/1082-989X.10.4.389>>.
- CHEN, W.; HUANG, Z.; WU, F.; ZHU, M.; GUAN, H.; MACIEJEWSKI, R. VAUD: A visual analysis approach for exploring spatio-temporal urban data. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 9, p. 2636–2648, 09 2018. Disponível em: <<https://doi.org/10.1109/tvcg.2017.2758362>>.
- CORRELL, M.; GLEICHER, M. Error bars considered harmful: Exploring alternate encodings for mean and error. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 20, n. 12, p. 2142–2151, 12 2014. Disponível em: <<https://doi.org/10.1109/tvcg.2014.2346298>>.
- CORRELL, M.; MORITZ, D.; HEER, J. Value-suppressing uncertainty palettes. In: *Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems - CHI '18*. ACM Press, 2018. Disponível em: <<https://doi.org/10.1145%2F3173574.3174216>>.
- COX, J.; HOUSE, D.; LINDELL, M. VISUALIZING UNCERTAINTY IN PREDICTED HURRICANE TRACKS. *International Journal for Uncertainty Quantification*, Begell House, v. 3, n. 2, p. 143–156, 2013. Disponível em: <<https://doi.org/10.1615%2Fint.j.uncertaintyquantification.2012003966>>.
- CUMMING, G.; FINCH, S. Inference by eye: confidence intervals and how to read pictures of data. *American psychologist*, American Psychological Association, v. 60, n. 2, p. 170, 2005. Disponível em: <<https://doi.org/10.1037/0003-066X.60.2.170>>.
- FERNANDES, M.; WALLS, L.; MUNSON, S.; HULLMAN, J.; KAY, M. Uncertainty displays using quantile dotplots or CDFs improve transit decision-making. In: *ACM. Proceedings of the 2018 CHI Conference on Human Factors in Computing Systems - CHI '18*. ACM Press, 2018. p. 1–12. Disponível em: <<https://doi.org/10.1145/3173574.3173718>>.
- FERREIRA, N.; FISHER, D.; KONIG, A. C. Sample-oriented task-driven visualizations. In: *ACM. Proceedings of the 32nd annual ACM conference on Human factors in computing systems - CHI '14*. ACM Press, 2014. p. 571–580. ISBN 978-1-4503-2473-1. Disponível em: <<https://doi.org/10.1145/2556288.2557131>>.

FERREIRA, N.; LINS, L.; FINK, D.; KELLING, S.; WOOD, C.; FREIRE, J.; SILVA, C. BirdVis: Visualizing and understanding bird populations. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 17, n. 12, p. 2374–2383, 12 2011. Disponível em: <<https://doi.org/10.1109/tvcg.2011.176>>.

FERREIRA, N.; POCO, J.; VO, H. T.; FREIRE, J.; SILVA, C. T. Visual exploration of big spatio-temporal urban data: A study of new york city taxi trips. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 19, n. 12, p. 2149–2158, 12 2013. Disponível em: <<https://doi.org/10.1109/tvcg.2013.226>>.

FISHER, D.; POPOV, I.; DRUCKER, S.; SCHRAEFEL, M. Trust me, i'm partially right: incremental visualization lets analysts explore large datasets faster. In: *Proceedings of the SIGCHI Conference on Human Factors in Computing Systems*. [s.n.], 2012. p. 1673–1682. Disponível em: <<https://doi.org/10.1145/2207676.2208294>>.

FREIFELD, C. C.; MANDL, K. D.; REIS, B. Y.; BROWNSTEIN, J. S. HealthMap: Global infectious disease monitoring through automated classification and visualization of internet media reports. *Journal of the American Medical Informatics Association*, Oxford University Press (OUP), v. 15, n. 2, p. 150–157, mar. 2008. Disponível em: <<https://doi.org/10.1197/jamia.m2544>>.

HUANG, Z.; LU, Y.; MACK, E.; CHEN, W.; MACIEJEWSKI, R. Exploring the sensitivity of choropleths under attribute uncertainty. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), p. 1–1, 2019. Disponível em: <<https://doi.org/10.1109/tvcg.2019.2892483>>.

HULLMAN, J. Why authors don't visualize uncertainty. *IEEE transactions on visualization and computer graphics*, IEEE, v. 26, n. 1, p. 130–139, 2019. Disponível em: <<https://doi.org/10.1109/TVCG.2019.2934287>>.

HULLMAN, J.; RESNICK, P.; ADAR, E. Hypothetical outcome plots outperform error bars and violin plots for inferences about reliability of variable ordering. *PLOS ONE*, Public Library of Science (PLoS), v. 10, n. 11, p. 1–23, 11 2015. Disponível em: <<https://doi.org/10.1371/journal.pone.0142444>>.

KALE, A.; KAY, M.; HULLMAN, J. Decision-making under uncertainty in research synthesis. In: *Proceedings of the 2019 CHI Conference on Human Factors in Computing Systems - CHI '19*. ACM Press, 2019. Disponível em: <<https://doi.org/10.1145/2019.2934287>>.

KARDOS, J.; MOORE, A.; BENWELL, G. Expressing attribute uncertainty in spatial data using blinking regions. In: *In Proceedings of the 7th International Symposium on Spatial Accuracy Assessment in Natural Resources and Environmental Sciences*. [s.n.], 2006. p. 814–824. Disponível em: <<http://www.spatial-accuracy.org/system/files/Kardos2006accuracy.pdf>>.

KAY, M.; KOLA, T.; HULLMAN, J. R.; MUNSON, S. A. When (ish) is my bus? user-centered visualizations of uncertainty in everyday, mobile predictive systems. In: *Proceedings of the 2016 CHI Conference on Human Factors in Computing Systems - CHI '16*. ACM Press, 2016. Disponível em: <<https://doi.org/10.1145/2858036.2858558>>.

KESSLER, C.; LOTSTEIN, E. Animation as a visual indicator of positional uncertainty in geographic information. In: SPRINGER. *Lecture Notes in Geoinformation and Cartography*. Springer International Publishing, 2018. p. 365–382. ISBN 978-3-319-78207-2. Disponível em: <https://doi.org/10.1007/978-3-319-78208-9_19>.

KIMERLING, A. J. Dotting the dot map, revisited. *Cartography and Geographic Information Science*, Informa UK Limited, v. 36, n. 2, p. 165–182, 01 2009. Disponível em: <<https://doi.org/10.1559/152304009788188754>>.

KINKELDEY, C.; MACEACHREN, A. M.; RIVEIRO, M.; SCHIEWE, J. Evaluating the effect of visually represented geodata uncertainty on decision-making: systematic review, lessons learned, and recommendations. *Cartography and Geographic Information Science*, Informa UK Limited, v. 44, n. 1, p. 1–21, 09 2015. Disponível em: <<https://doi.org/10.1080/15230406.2015.1089792>>.

KINKELDEY, C.; MACEACHREN, A. M.; SCHIEWE, J. How to assess visual communication of uncertainty? a systematic review of geospatial uncertainty visualisation user studies. *The Cartographic Journal*, Informa UK Limited, v. 51, n. 4, p. 372–386, 09 2014. Disponível em: <<https://doi.org/10.1179/1743277414y.0000000099>>.

LEHNHART, E. D. R.; LÖBLER, M. L.; TAGLIAPIETRA, R. D. DISCUSSÃO e APLICAÇÃO DO PROTOCOLO THINK ALOUD EM PESQUISAS SOBRE PROCESSO DECISÓRIO. *Revista Alcance*, Editora UNIVALI, v. 26, n. 1(Jan/Abr), p. 013, may 2019. Disponível em: <<https://doi.org/10.14210%2Falcance.v26n1%28jan%2Fabr%29.p013-029>>.

MACEACHREN, A. M.; ROBINSON, A.; HOPPER, S.; GARDNER, S.; MURRAY, R.; GAHEGAN, M.; HETZLER, E. Visualizing geospatial information uncertainty: What we know and what we need to know. *Cartography and Geographic Information Science*, Informa UK Limited, v. 32, n. 3, p. 139–160, 01 2005. Disponível em: <<https://doi.org/10.1559/1523040054738936>>.

MATEJKA, J.; FITZMAURICE, G. Same stats, different graphs. In: *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems - CHI '17*. ACM Press, 2017. Disponível em: <<https://doi.org/10.1145/3025453.3025912>>.

MAYHUA, A.; GOMEZ-NIETO, E.; HEER, J.; POCO, J. Extracting visual encodings from map chart images with color-encoded scalar values. In: *2018 31st SIBGRAP Conference on Graphics, Patterns and Images (SIBGRAP)*. IEEE, 2018. Disponível em: <<https://doi.org/10.1109/sibgrapi.2018.00025>>.

MORITZ, D.; FISHER, D. What users don't expect about exploratory data analysis on approximate query processing systems. In: ACM. *Proceedings of the 2nd Workshop on Human-In-the-Loop Data Analytics - HILDA '17*. ACM Press, 2017. p. 1–4. Disponível em: <<https://doi.org/10.1145/3077257.3077258>>.

MORITZ, D.; FISHER, D.; DING, B.; WANG, C. Trust, but verify: Optimistic visualizations of approximate queries for exploring big data. In: *Proceedings of the 2017 CHI conference on human factors in computing systems*. [S.l.: s.n.], 2017. p. 2904–2915.

NUSRAT, S.; KOBOUROV, S. G. Visualizing cartograms: Goals and task taxonomy. *CoRR*, abs/1502.07792, 2015. Disponível em: <<http://arxiv.org/abs/1502.07792>>.

PAHINS, C. A. de L.; FERREIRA, N.; COMBA, J. Real-time exploration of large spatiotemporal datasets based on order statistics. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), p. 1–1, 2019. Disponível em: <<https://doi.org/10.1109/tvcg.2019.2914446>>.

POCO, J.; DASGUPTA, A.; WEI, Y.; HARGROVE, W.; SCHWALM, C.; COOK, R.; BERTINI, E.; SILVA, C. Similarity explorer: A visual inter-comparison tool for multifaceted climate data. In: WILEY ONLINE LIBRARY. *Computer Graphics Forum*. 2014. v. 33, n. 3, p. 341–350. Disponível em: <<https://doi.org/10.1111/cgf.12390>>.

POCO, J.; MAYHUA, A.; HEER, J. Extracting and retargeting color mappings from bitmap images of visualizations. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 1, p. 637–646, 01 2018. Disponível em: <<https://doi.org/10.1109/tvcg.2017.2744320>>.

POTTER, K.; GERBER, S.; ANDERSON, E. W. Visualization of uncertainty without a mean. *IEEE computer graphics and applications*, IEEE, v. 33, n. 1, p. 75–79, 01 2013. Disponível em: <<https://doi.org/10.1109/MCG.2013.14>>.

ROUSSELET, G. A.; FOXE, J. J.; BOLAM, J. P. A Few Simple Steps to Improve the Description of Group Results in Neuroscience. *European Journal of Neuroscience*, Wiley Online Library, v. 44, n. 9, p. 2647–2651, 2016. Disponível em: <<https://doi.org/10.1111/ejn.13400>>.

SARIKAYA, A.; GLEICHER, M. Scatterplots: Tasks, data, and designs. *IEEE Transactions on Visualization and Computer Graphics*, Institute of Electrical and Electronics Engineers (IEEE), v. 24, n. 1, p. 402–412, 01 2018. Disponível em: <<https://doi.org/10.1109/tvcg.2017.2744184>>.

SCHOLZ, R.; LU, Y. Uncertainty in geographic data on bivariate maps: An examination of visualization preference and decision making. *ISPRS International Journal of Geo-Information*, MDPI AG, v. 3, n. 4, p. 1180–1197, oct 2014. Disponível em: <<https://doi.org/10.3390%2Fijgi3041180>>.

SEVERTSON, D. J.; VATOVEC, C. The theory-based influence of map features on risk beliefs: Self-reports of what is seen and understood for maps depicting an environmental health hazard. *Journal of Health Communication*, Informa UK Limited, v. 17, n. 7, p. 836–856, 08 2012. Disponível em: <<https://doi.org/10.1080/10810730.2011.650933>>.

ŚLUSARSKI, M.; JURKIEWICZ, M. Visualisation of spatial data uncertainty. a case study of a database of topographic objects. *ISPRS International Journal of Geo-Information*, MDPI AG, v. 9, n. 1, p. 16, dec 2019. Disponível em: <<https://doi.org/10.3390%2Fijgi9010016>>.

WANG, Z.; FERREIRA, N.; WEI, Y.; BHASKAR, A. S.; SCHEIDEGGER, C. Gaussian cubes: Real-time modeling for visual exploration of large multidimensional datasets. *IEEE Transactions on Visualization and Computer Graphics*, IEEE, v. 23, n. 1, p. 681–690, 2016. Disponível em: <<https://doi.org/10.1109/TVCG.2016.2598694>>.

WEISSGERBER, T. L.; MILIC, N. M.; WINHAM, S. J.; GAROVIC, V. D. Beyond Bar and Line Graphs: Time for a New Data Presentation Paradigm. *PLoS Biology*, Public Library of Science, v. 13, n. 4, p. e1002128, 2015. Disponível em: <<https://doi.org/10.1371/journal.pbio.1002128>>.

WICKHAM, H.; STRYJEWSKI, L. 40 years of boxplots. had.co.nz, p. 1–17, 01 2011. Disponível em: <<http://vita.had.co.nz/papers/boxplots.pdf>>.

WILLIAMS, D. N.; BREMER, T.; DOUTRIAUX, C.; PATCHETT, J.; WILLIAMS, S.; SHIPMAN, G.; MILLER, R.; PUGMIRE, D. R.; SMITH, B.; STEED, C. et al. Ultrascale visualization of climate data. *Computer, IEEE*, v. 46, n. 9, p. 68–76, 2013. Disponível em: <<https://doi.org/10.1109/MC.2013.119>>.

ZHENG, Y.; WU, W.; CHEN, Y.; QU, H.; NI, L. M. Visual analytics in urban computing: An overview. *IEEE Transactions on Big Data*, Institute of Electrical and Electronics Engineers (IEEE), v. 2, n. 3, p. 276–296, 09 2016. Disponível em: <<https://doi.org/10.1109/tbdata.2016.2586447>>.