UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA CIVIL
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA CIVIL

VITOR BARBOSA MELO

APLICAÇÃO DE INFORMAÇÕES ESPACIAIS DE ALTA RESOLUÇÃO PARA ESTUDO DE OCORRÊNCIAS DE INUNDAÇÕES URBANAS

Recife
2021

VITOR BARBOSA MELO

APLICAÇÃO DE INFORMAÇÕES ESPACIAIS DE ALTA RESOLUÇÃO PARA ESTUDO DE OCORRÊNCIAS DE INUNDAÇÕES URBANAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial à obtenção do título de Mestre em Engenharia Civil.

Área de concentração: Tecnologia Ambiental e Recursos Hídricos

Orientador: Prof. Dr. Jose Almir Cirilo

Recife

2021

Catalogação na fonte

Bibliotecário Gabriel Luz, CRB-4 / 2222

M528a Melo, Vitor Barbosa

Aplicação de informações espaciais de alta resolução para estudo de ocorrências de inundações urbanas / Vitor Barbosa Melo – Recife, 2021.

218 f.: figs., tabs.

Orientador: Prof. Dr. Jose Almir Cirilo.

Dissertação (Mestrado) – Universidade Federal de Pernambuco. CTG. Programa de Pós-Graduação em Engenharia Civil, 2021.

Inclui referências e apêndices.

1. Engenharia Civil. 2. Mapas de inundação. 3. Krigagem ordinária. 4. HAND. 5. Curva Receiver Operator Characteristic. 6. Projeto Pernambuco Tridimensional. 7. Hidromapp. I. Cirilo, José Almir (Orientador). II. Título.

UFPE

624 CDD (22. ed.) BCTG / 2021 - 128

VITOR BARBOSA MELO

APLICAÇÃO DE INFORMAÇÕES ESPACIAIS DE ALTA RESOLUÇÃO PARA ESTUDO DE OCORRÊNCIAS DE INUNDAÇÕES URBANAS

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia Civil do Centro de Tecnologia e Geociências da Universidade Federal de Pernambuco, como requisito parcial à obtenção do título de Mestre em Engenharia Civil.

Aprovada em 18/02/2021

BANCA EXAMINADORA

_____

participação por videoconferência
Prof. Dr. Jose Almir Cirilo (orientador)
Universidade Federal de Pernambuco

_____

participação por videoconferência
Profª. Drª. Ana Lúcia Bezerra Candeias (examinadora externa)
Universidade Federal de Pernambuco

_____

participação por videoconferência
Prof. Dr. Alfredo Riberio Neto (examinador interno)
Universidade Federal de Pernambuco

AGRADECIMENTOS

Aos meus pais, Antônio e Maria, obrigado por todo amor, carinho, paciência e apoio incondicional em toda minha jornada. Tudo que sou hoje, agradeço a vocês. Transborda em mim toda a gratidão. Vocês são meus maiores exemplos.

À minha irmã, Ceci, ao meu cunhado, Bruno e a à minha sobrinha, Maria, que tanto amo, minha vida não é a mesma depois do seu nascimento. Agradeço aos três por serem sempre amor e luz na minha vida. Serei eternamente grato ao apoio nesses últimos anos.

À minha namorada, Bruna, por ter me apoiado em todos os momentos, principalmente naqueles em que eu duvidada da minha própria capacidade. Você é luz na minha vida. Obrigado por todo amor, carinho e sinceridade.

Ao meu orientador Almir Cirilo, que foi essencial na construção deste trabalho. Obrigado pela oportunidade, pela paciência, por ter me dado liberdade para o desenvolvimento desta pesquisa e por todo o auxílio ao longo dos últimos anos. É para mim uma honra ter sido orientado por um dos melhores profissionais do país na área de Recursos Hídricos.

À Rochelle e ao Gabriel, amigos e parceiros de artigos, à Jussara e Ana, pelo carinho e apoio de sempre. À Marcella e ao Yan, amigos conterrâneos que deixaram o mestrado ainda mais leve. Aos amigos que fiz durante a pós-graduação: Lívia, Larissa, Samara, Lucila, Gabriela, Tiago, Bruno e tantos outros.

Ao Gabriel e à Ayanne pelos dados do aplicativo colaborativo Hidromapp, que foi fundamental para evolução desta pesquisa.

Aos professores do departamento, em especial Alfredo, Anderson, Leidjane, Roberto e Suzana por todo o conhecimento transmitido.

Ao Serviço Geológico Brasileiro (CPRM) por toda a documentação disponibilizada, em particular ao técnico Anderson Luiz por toda atenção, acompanhamento em campo e informações transmitidas. Agradeço também a Fábio Araújo e a Cristiane Ribeiro pelo ponto de partida.

À Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pela oportunidade e pela bolsa. Muito obrigado.

“I say water no get enemy”
(Water no get enemy, Fela Kuti)

“O desejo profundo da humanidade pelo conhecimento é justificativa suficiente para nossa busca contínua”
(STEPHEN HAWKING).

RESUMO

Ao redor do mundo as inundações têm provocado perdas severas à sociedade, como mortes, danos ao meio ambiente e prejuízos econômicos. Em Pernambuco diversas cidades se estabeleceram ao longo das planícies inundáveis. Tal situação, em conjunto com as chuvas intensas e as particularidades físicas das bacias hidrográficas fomentaram desastres de maneira recorrente, notadamente na bacia do rio Una, na Zona da Mata Sul, onde as precipitações são mais elevadas. Neste século, destacam-se as inundações que ocorreram nos anos de 2000, 2010, 2011 e 2017, atingindo diversas cidades da bacia, a exemplo de Palmares e de Jaqueira, abordadas neste estudo. Diante deste cenário, dados de alta resolução espacial e mapas de inundação são essenciais na tomada de decisão baseadas em soluções de inteligência geográfica. Em 2014 o governo de Pernambuco desenvolveu o Projeto Pernambuco Tridimensional, promovendo grandes avanços no conhecimento topográfico do estado. Com relação aos mapas de vulnerabilidade às inundações, tradicionalmente eles têm sido gerados por meio de modelos hidrológicos e hidrodinâmicos. Esta abordagem apresenta entraves a respeito de bases hidrológicas deficientes e a necessidade de múltiplos dados, que podem estar indisponíveis ou apresentarem baixa precisão. Nas últimas décadas outras aplicações foram desenvolvidas pela ciência, que não exigem múltiplas fontes de dados, tais como ferramentas fundamentadas em descritores do terreno e em estimativas sobre processos pontuais. Neste contexto, o objetivo deste trabalho foi aplicar metodologias baseadas em três perspectivas: a inferência probabilística por meio da Krigagem Ordinária em relação às profundidades de inundação do município de Palmares em 2010 (levantamento pelo corpo de bombeiros) e de Jaqueira em 2017 (amostragem pelo aplicativo cooperativo Hidromapp); otimização do modelo HAND (descritor do terreno gerado por dados topográficos do Projeto Pernambuco Tridimensional) em relação ao evento de 2010 em Palmares segundo a análise da curva Receiver Operator Characteristic e métricas estatísticas de comparação entre modelos, tendo como referência o mapa obtido na primeira abordagem e; conexão do modelo HAND com a estação fluviométrica de Palmares. Concluiu-se que os resultados da inferência apresentaram forte correspondência nos pontos amostrados, com coeficiente de correlação igual a 99,98% e a 98,81% em Jaqueira e em Palmares, respectivamente. Nas áreas sem amostras (áreas não residenciais), a incerteza do modelo atingiu o máximo de 1,28m (Jaqueira) e de 1,64m (Palmares). A otimização do modelo HAND indicou um limiar ótimo (altura de corte da inundação) de 10,5m em relação ao evento de 2010. Esta predição apresentou uma taxa de acerto de 99%, entretanto apresentou taxa de alarme falso de 15%, indicando

superdimensionamento. A metodologia combinando o modelo HAND com as cotas fluviométricas promoveu o mapa de probabilidade de recorrência da cidade de Palmares e permitiu a estimativa de outros eventos no município como o de 2000, 2011 e 2017.

Palavras-chave: Mapas de inundação. Krigagem Ordinária. HAND. Curva Receiver Operator Characteristic. Projeto Pernambuco Tridimensional. Hidromapp.

ABSTRACT

Around the world the floods have caused severe losses to society, such as death, environmental damage and economic losses. In Pernambuco several cities have settled along the flood plains. This situation, added with the intense rainfall and the physical particularities of the watersheds, have fostered recurrent disasters, notably in the Una River basin, in the Zona da Mata Sul, where precipitation is highest. In this century, pointed out the floods that occurred in the years 2000, 2010, 2011 and 2017, which reached many cities in the basin, such as Palmares and Jaqueira, approached in this study. Given this scenario, high spatial resolution data and flood maps are essential in decision making based on geographic intelligence solutions. In 2014, the government of Pernambuco developed the Pernambuco Tridimensional Project, promoting great advances in state's topographic knowledge. Regarding flood vulnerability maps, traditionally They have been conceived through hydrological and hydrodynamic models. This approach presents obstacles on deficient hydrological bases and the need for multiple data, which may be unavailable or have low accuracy. In the last decades, other applications have been developed by science, which do not require multiple sources of data, such as tools based on land descriptors and spatial point patterns. In this context, the purpose of this work was to apply methodologies based on three perspectives: the probabilistic inference through the Ordinary Kriging in relation to the flood quotas of the municipality of Palmares in 2010 (survey carried off by the Fire Department) and Jaqueira in 2017 (sampling carried of by the cooperative app Hidromapp); optimization of the HAND model (land descriptor generated by topographic data from the Pernambuco Tridimensional Project) in relation to the 2010 event in Palmares according to the analysis of the ROC curve and statistical metrics of comparison between models, using the map data as a reference in the first approach and; connection of the HAND model with the Palmares fluviometric station. It was concluded that the inference results showed a strong correspondence in the sampled points, with a correlation coefficient equal to 99.98% and 98.81% in Jaqueira and Palmares, respectively. In areas without samples (non-residential areas), the model's uncertainty reached a maximum of 1.28m (Jaqueira) and 1.64m (Palmares). The optimization of the HAND model indicated an optimal threshold (flood cut-off height) of 10.5m in relation to the event of 2010. This prediction presented a hit rate of 99%, however it showed a false alarm rate of 15%, indicating oversizing. The methodology combining the HAND model with the fluviometric quotas promoted the map of probability of recurrence in the city of Palmares and allowed the estimation of other events in the municipality, such as 2000, 2011 and 2017.

Keywords: Flood Maps. Ordinary Kriging. HAND. Receiver Operator Characteristic Curve. Pernambuco Tridimensional Project. Hidromapp.

LISTA DE FIGURAS

Figura 1 - Número de mortes no mundo como resultado das inundações no período de 1960 a 2018 24

Figura 2 - Número de países atingidos por inundações (linha sólida) e número de eventos de inundação por nível de renda (barra) obtidos através do EM-DAT entre os anos de 1960 e 2013 25

Figura 3 - Ilustração do perfilamento a LASER aerotransportado e os componentes necessários (GPS receptor e base, SMI e o LASER escâner) para o mapeamento topográfico 35

Figura 4 - Primeiro e último retorno do LASER 36

Figura 5 - Representação gráfica do variograma e da covariância 45

Figura 6 - Amostras dispostas no espaço, relação entre duas variáveis z (x) e z (x+h) 47

Figura 7 - Esquema e parâmetros de busca dos pares amostrais distantes do vetor h para a determinação do variograma 48

Figura 8 - Parâmetros do semivariograma 49

Figura 9 - Semivariogramas teóricos 51

Figura 10 - Caracterização gráfica de fenômenos isotrópicos e anisotrópicos 52

Figura 11 - Mapa de localização da área de estudo 59

Figura 12 - Mapa da hidrografia da Bacia Hidrográfica do Rio Una 60

Figura 13 - Mapa das unidades climáticas da Bacia Hidrográfica do Rio Una 61

Figura 14 - Mapa da precipitação média anual da Bacia Hidrográfica do Rio Una 62

Figura 15 - Mapa das profundidades de inundação no município de Palmares em 2010 65

Figura 16 - Mapa das profundidades de inundação no município de Jaqueira em 2017 65

Figura 17 - Mapa de localização da estação fluviométrica Palmares 67

Figura 18 - Régua linimétrica da estação fluviométrica de Palmares, localização pós-cheia (2011 a 2014) 68

Figura 19 - Régua Linimétrica da Estação Fluviométrica de Palmares, Localização Atual 68

Figura 20 - Primeira etapa metodológica do modelo HAND 70

Figura 21 - Segunda etapa metodológica do modelo HAND 70
Figura 22 - Procedimento metodológico para geração de superfícies de inundação através da Geoestatística 84
Figura 23 - Representação das áreas simuladas e observadas e suas relações de acerto e erro 96
Figura 24 - Histograma e gráfico Q-Q para o logaritmo das transformadas (m) do evento de 2017 em Jaqueira 102
Figura 25 - Histograma e gráfico Q-Q para o Box-Cox das transformadas (m) do evento de 2010 em Palmares 104
Figura 26 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira para o cenário A 107
Figura 27 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira, após a exclusão de 7 pontos, cenário B 108
Figura 28 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2017 em Jaqueira para o cenário A e o cenário B 108
Figura 29 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário C 110
Figura 30 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário D 111
Figura 31 - Semivariogramas empíricos e teóricos para os resíduos de 2010 em Palmares para as direções de maior e de menor continuidade do modelo anisotrópico (cenário D) 111
Figura 32 - Mapa das profundidades de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B) 113
Figura 33 - Histograma das profundidades de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B) 114
Figura 34 - Mapa da superfície de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B) 114
Figura 35 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2017 em Jaqueira 116
Figura 36 - Mapa de incerteza do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B) 117

Figura 37 - Histograma da incerteza do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B) 117
Figura 38 - Mapa das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C) 119
Figura 39 - Mapa das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D) 120
Figura 40 - Mapa da superfície de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C) 121
Figura 41 - Mapa da superfície de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D) 122
Figura 42 - Histograma das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C) 122
Figura 43 - Histograma das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D) 123
Figura 44 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2010 em Palmares (cenário C) 124
Figura 45 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2010 em Palmares (cenário D) 124
Figura 46 - Mapa da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C) 125
Figura 47 - Mapa de incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D) 126
Figura 48 - Histograma da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C) 126
Figura 49 - Histograma da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D) 127
Figura 50 - Diferença da incerteza entre os cenários C e D do evento de 2010 em Palmares 128
Figura 51 - Histograma da diferença da incerteza entre os cenários C e D 128
Figura 52 - Curva ROC: otimização do modelo HAND em relação ao evento de 2010 em Palmares 130
Figura 53 - Comparação entre o modelo observado (Krigagem Ordinária) e o modelo simulado (corte de 10,5m no HAND) 132

Figura 54 - Máximos anuais da estação fluviométrica de Palmares 135
Figura 55 - Teste de Mann-Kendall Sequencial para estação fluviométrica de Palmares 136
Figura 56 - Distribuições de máximos anuais para a estação fluviométrica de Palmares 138
Figura 57 - Mapa de perigo do município de Palmares 140
Figura 58 - Simulação de eventos de inundação por meio do modelo HAND para os anos de 2000, 2010, 2011 e 2017 no município de Palmares 142

LISTA DE TABELAS

Tabela 1 - Distribuições de Máximos Anuais 83
Tabela 2 - Medidas de desempenho para o cenário B 115
Tabela 3 - Medidas de desempenho para os cenários C e D 123
Tabela 4 - Resumo das métricas estatísticas de desempenho do limiar de 10,5 m do HAND em comparação com o modelo krigado (observado) 133
Tabela 5 - Testes de homogeneidade, de independência e de estacionariedade para a estação fluviométrica de Palmares 136
Tabela 6 - Altura HAND vinculada à estação fluviométrica Palmares 139

SUMÁRIO

1	**INTRODUÇÃO**	17
1.1	OBJETIVOS	21
1.1.1	Objetivo geral	21
1.1.2	Objetivos específicos	21
2	**REFERENCIAL TEÓRICO**	23
2.1	INUNDAÇÕES FLUVIAIS: IMPACTOS E MEDIDAS MITIGADORAS ...	23
2.2	MODELAGEM DOS MAPAS DE INUNDAÇÃO	29
2.3	LIGHT DETECTION AND RANGING (LIDAR)	34
2.4	HEIGHT ABOVE THE NEAREST DRAINAGE (HAND)	37
2.5	A GEOESTATÍSTICA NA INFERÊNCIA DE SUPERFÍCIES CONTÍNUAS E NA QUANTIFICAÇÃO DE INCERTEZAS	40
2.5.1	Variograma (semivariograma)	46
2.5.2	Krigagem Ordinária	54
3	**METODOLOGIA**	58
3.1	CARACTERIZAÇÃO DA BACIA HIDROGRÁFICA DO RIO UNA	58
3.1.1	Localização	58
3.1.2	Hidrografia	59
3.1.3	Clima e precipitação	60
3.1.4	Outros aspectos da bacia	62
3.2	DADOS GEOGRÁFICOS E HIDROLÓGICOS	62
3.2.1	Modelo Digital do Terreno e Ortofoto	63
3.2.2	Profundidades de inundação	63
3.2.3	Estação fluviométrica	66
3.3	MÉTODOS	68
3.3.1	Modelo HAND	69
3.3.2	Geoestatística	83
3.3.3	Comparação entre mapas: HAND versus Krigagem Ordinária	95
4	**RESULTADOS E DISCUSSÕES**	100
4.1	ANÁLISE GEOESTATÍSTICA	100
4.1.1	Análise exploratória e transformação dos dados	100
4.1.2	Análise da estacionariedade e remoção de tendências	104

4.1.3 Semivariograma e a Validação Cruzada no processo de decisão 105
4.1.4 Mapas de inundação e de incerteza 112
4.2 MODELO HAND 129
4.2.1 Curva ROC - Predição do HAND 129
4.2.2 Métricas de comparação entre mapas: HAND versus Krigagem Ordinária 130
4.2.3 Mapa de Perigo 134
4.2.4 Simulação dos anos 2000, 2010, 2011 e 2017 141
4.3 CONSIDERAÇÕES FINAIS SOBRE OS MODELOS APLICADOS 144
5 CONCLUSÕES E RECOMENDASÕES 147
REFERÊNCIAS 152
ANEXO A – ÁREA DE ESTUDO (CONTINUAÇÃO) 168
ANEXO B – RESULTADOS E DISCUSSÕES DA GEOESTATÍSTICA (CONTINUAÇÃO) 178

1 INTRODUÇÃO

O desenvolvimento da maior parte das cidades do mundo ocorreu nas proximidades dos recursos hídricos (lagoas, rios e margens continentais), incialmente, em busca de alimentos e de água para necessidades básicas. Com o passar do tempo, a água passou a ter importância para a irrigação e a mobilidade de pessoas e de mercadorias. Atualmente, o recurso hídrico também tem sido utilizado para geração de energia elétrica e recreação. Além disso, mais especificamente nas áreas ribeirinhas, a agricultura e a disposição de resíduos são outros usos que também passaram a ser desfrutados pelo homem (SIMONOVIĆ, 2012).

Apesar desta necessidade de desenvolvimento e de sobrevivência, o estabelecimento de cidades, de assentamentos e de infraestruturas equivocado em áreas próximas aos corpos d'água tem provocado diversos impactos negativos sobre a sociedade mundial devido à ocorrência das inundações. Conforme Jonkman (2005) e o Intergovernmental Panel on Climate Change (IPCC) (2012), a inundação é um fenômeno em que a água transborda para além da capacidade natural de um corpo d'água, atingido porções de terras geralmente secas (não submersas). Dentre os vários tipos de inundação apresentadas pelos autores, destacam-se as costeiras, as fluviais e as urbanas.

As inundações costeiras ocorrem por causa do aumento anômalo do nível normal de água do mar em consequência de tempestades sob sistemas atmosféricos de baixa pressão, de mudança no nível médio do mar e de sismos geradores de tsunami (FREER *et al*., 2013; JONKMAN, 2005). As projeções climáticas indicam que o aquecimento global causará maiores riscos as inundações costeiras (DJALANTE, 2019). Por outro lado, as inundações urbanas são caracterizadas por chuvas intensas em bacias hidrográficas pequenas (áreas menores que 100 km²) com altas taxas de áreas impermeáveis, demasiadas barreiras e obstruções - resíduos sólidos e construções - ao escoamento superficial e artificial através de redes pluviais. Tais fatores em conjunto com poucas áreas de armazenamento (solo, vegetação, corpos d'água) promovem a falha do sistema de drenagem, gerando as inundações (TUCCI, 2008; KUNDZEWICZ *et al*., 2014).

Com relação às inundações fluviais, estas originam-se devido às precipitações elevadas, promovendo o excessivo volume de água no rio, atingindo as planícies inundáveis. Concomitante com as chuvas podem surgir outras causas como as movimentações de terra ou o rompimento de estruturas de contenção (barragens, diques), além do derretimento do gelo em áreas com elevadas latitudes. As inundações fluviais podem ainda ser categorizadas em inundações graduais (*slow rising*) ou bruscas (*flash floods*), as quais se diferem, basicamente,

quanto à velocidade e à força de escoamento. Nas graduais, o nível d'água sobe lentamente e de maneira previsível, facilitando a prevenção horas ou até dias antes do evento. Por outro lado, as bruscas transcorrem em bacias hidrográficas de relevos acidentados com escoamento de alta turbulência, caracterizados por um fluxo caótico com rápida ascensão e carregando sedimentos, árvores e até estruturas, o que as tornam mais perigosas. Estes tipos de inundações atingem rapidamente a população, o que dificulta a mitigação dos efeitos (CHOUDHURY, PAUL E PAUL, 2004; JONKMAN, 2005; FREER *et al*., 2013; KUNDZEWICZ *et al*., 2014).

De uma maneira geral, os principais fatores geradores das inundações são relativos às causas naturais como a dinâmica física e química da atmosfera, os diferentes tipos de sistemas precipitantes (El Niño, Monções, Zona de Convergência Intertropical e Ondas de Leste, dentre outros), as características físicas da bacia hidrográfica (declividade, propriedades dos canais e altitude, por exemplo), a cobertura vegetal (retardando o pico de vazão e atuando como reservatório), a capacidade de drenagem (infiltração, escoamento superficial e subterrâneo) e as particularidades do corpo d'água e do solo (permeabilidade, saturação, estrutura, outros) antes do evento (TUCCI 2004; SIMONOVIĆ, 2012; FREER *et al*., 2013; KUNDZEWICZ *et al*., 2014).

Além disso, as ações antrópicas têm agravado o fenômeno, produzindo impactos desastrosos em todo o mundo. O uso e a ocupação da terra sem critérios, a mudança e a exploração sem gerenciamento dos recursos hídricos, o desmatamento, a desertificação, o despejo de resíduos sólidos em locais inapropriados, as obras hidráulicas, os processos erosivos e o assoreamento são condicionantes antrópicas para o agravamento dos desastres hidrológicos. Tais ações são influenciadas pela urbanização desenfreada, falta e/ou baixo investimento em gerenciamentos de riscos e políticas ambientais, principalmente nas áreas ribeirinhas (ALBERTI *et al*., 2007; TUCCI, 2008; AMARAL E RIBEIRO, 2009; SIMONOVIĆ, 2012).

Estas características naturais e antrópicas estão presentes em diversos estados brasileiros. Em Pernambuco, apesar de maior parte do seu território estar incluído no semiárido nordestino e de sofrer com oferta deficiente de água, as inundações têm provocado perdas significativas, tendo os primeiros registros no século XVII na bacia hidrográfica do rio Capibaribe. Não obstante as experiências passadas, a partir da década de 1970 o fenômeno passou a ocorrer em outras bacias do estado (SANTOS, 2013; ANA, 2017).

Na bacia hidrográfica do rio Una, objeto de estudo deste trabalho, os dois eventos mais expressivos que ocorrem na região foram nos anos de 2000 e de 2010. Na primeira ocorrência, 9 municípios decretaram estado de calamidade pública e outros 8 em condição emergencial. Contabilizou-se 22 mortes e mais de 130 milhões de reais em prejuízos econômicos para o

estado na época. Além disso, cerca de 30 mil pessoas ficaram desabrigadas somente nas cidades da bacia (BRASIL, 2000). Passados dez anos, 9 cidades em outro evento decretaram estado de calamidade pública e 12 deliberaram situação emergencial. Em todo o estado pernambucano, morreram 20 pessoas e cerca de 80 mil ficaram desalojadas e outras 15 mil desabrigadas. Ademais, calculou-se uma perda aproximada de 3,4 bilhões de reais (BANCO MUNDIAL, 2012). Outras inundações recentes chamam atenção na bacia, a exemplo dos anos de 2004, 2005, 2011 e 2017.

Diante destes aspectos, torna-se fundamental desenvolver pesquisas e projetos que representem da melhor forma a intensidade e a distribuição espacial dos fenômenos hidrológicos, os quais podem ser sintetizados através de mapas. A geração destes mapas tem sido realizada por meio: de modelos hidrodinâmicos (BALDASSARE *et al*., 2010; RIBEIRO NETO *et al*., 2015); de soluções baseadas em Modelos Digitais do Terreno (MDT) (DEGIORGIS *et al*., 2012; NOBRE *et al*., 2015; JAFARZADEGAN E MERWADE, 2019); de profundidades pontuais utilizando técnicas de inferência probabilística (MELO *et al*. 2020); de interpoladores determinísticos (RIBEIRO *et al*. 2020); de algoritmos baseados em Inteligência Artificial combinando diferentes entradas de dados (CHOWDHURI, PAL E CHAKRABORTTY, 2020).

Embora existam diversas metodologias na literatura, o desenvolvimento destas perpassa por um inconveniente, a falta de dados, que dificulta a calibração, a validação e até a aplicação das ferramentas existentes (MELO *et al*, 2020). Conforme Brakenridge (2018), países em desenvolvimento dispõem apenas de base de dados hidrológicos deficitárias. Neste contexto, tem-se buscado soluções que não dependam de múltiplas fontes, mas que consigam descrever o fenômeno estudado de maneira coerente.

Como consequência da carência de dados precisos, sobretudo na descrição do terreno e motivados pelos impactos gerados pelas inundações de 2010, o governo do estado de Pernambuco desenvolveu o Projeto Pernambuco Tridimensional (PE3D), o qual mapeou todo o seu território através da aerofotogrametria, permitindo a geração de Ortoimagens e da tecnologia LIDAR (Light Detection and Ranging), concebendo modelos do terreno, imagens aéreas e outros produtos com alta resolução espacial e altimétrica (CIRILO *et al*., 2014; CIRILO *et al*., 2015). Este projeto tem possibilitado diversos avanços na área de modelagem de inundações.

Outra deficiência em relação à falta de dados está associada com a insuficiência das informações referentes às inundações. Diante disso, grupos de universidades e de órgãos da

defesa civil têm levantado profundidades reais das inundações pós-evento (FURDADA, CALDERÓN E MARQUÉS, 2008; REFOSCO *et al*., 2013). Em 2010, por exemplo, na cidade de Palmares - PE, o Corpo de Bombeiros coletou dados de marcas de inundação em 200 pontos. Também em Pernambuco, no evento que ocorreu em 2017 no município de Jaqueira, Ribeiro *et al* (2020) obtiveram 130 pontos por meio de entrevistas utilizando o aplicativo Hidromapp, plataforma cooperativa criada por Oliveira, Brito e Santos (2018). Neste sentido, há a possibilidade de gerar mapas de inundação por interpoladores determinísticos ou probabilísticos segundo pontos com atributos reais de eventos passados.

A partir desta perspectiva de aplicação diferentes trabalhos têm sido desenvolvidos, considerando as particularidades das inundações, tais como a multiplicidade e a complexidade na geração do fenômeno (incerteza), os danos causados à sociedade e a necessidade de precisão espacial na estimativa. Recorre-se à Geoestatística, que segundo Isaaks e Srivastava (1989), Cressie (1993), Camargo, Fucks e Câmara (2004) e Soares (2006), se constitui como a técnica de inferência probabilística que descreve a estrutura espacial das amostras por meio de medidas estatísticas (valor esperado e semivariograma) e possibilita medidas de acurácia e de precisão. Além disso, Melo *et al* (2020) comentam que a Geoestatística apresenta importante contribuição para a modelagem das inundações por aferir a incerteza do processo.

Por outro lado, tal aplicação se limita a um único evento, necessitando de outras ferramentas que modelem eventos passados e avaliem a vulnerabilidade das cidades atingidas. Dessa forma, uma recente abordagem tem se destacado: a combinação de análises de frequência de nível com o modelo *Height Above the Nearest Drainage* (HAND) (PÉREZ-MESA, 2014; SPECKHANN *et al*., 2018). O HAND é um descritor de terreno que normaliza a altimetria em relação ao nível do mar (referência do MDT) segundo técnicas de geoprocessamento e de processos hidrológicos, resultando em alturas relativas ao canal de drenagem mais próximo (RENNÓ *et al*., 2018; NOBRE *et al*., 2011). Este simples conceito possibilita indicar áreas com maior susceptibilidade à inundação (NOBRE *et al*., 2011; MOMO *et al*., 2016).

Devido aos estragos gerados pelas inundações e à possibilidade de aplicar diferentes abordagens, os mapas simulados devem ser validados e comparados a partir dos mapas produzidos por dados medidos (profundidades de inundação). Neste sentido, métricas estatísticas têm sido utilizadas, evidenciando o desempenho dos mapas simulados em relação aos observados segundo taxas de acerto, de omissão e de comissão. Estes índices indicam a capacidade das simulações em descrever o fenômeno, possibilitando análises espaciais e quantificações a respeito dos erros de super ou subdimensionamento (STEPHESON, 2000; MANFREDA *et al*. 2014;2015 MOMO *et al*. 2016; JAFARZADEGAN E MERWADE, 2017).

Por fim, ressalta-se que as profundidades de inundação produzidas mediante o uso do aplicativo colaborativo Hidromapp e a aplicação do modelo HAND em conjunto com dados fluviométricos viabilizam aplicações em larga escala. Pois, verifica-se o poder de abrangência da coleta de informações pelo Hidromapp em qualquer parte região do mundo, alado ao desenvolvimento dos *smartphones*, principalmente devido à melhora na precisão planimétrica destes dispositivos.

1.1 OBJETIVOS

Diante do contexto apresentado, este trabalho visou a produção de mapas de inundação através da inferência probabilística sobre dados pontuais levantados pelo aplicativo Hidromapp (evento de 2017 em Jaqueira) e pelo Corpo de Bombeiros (evento de 2010 em Palmares). Além disso, em Palmares, o modelo HAND foi usado segundo três procedimentos: limiar ótimo HAND com o uso da análise da curva *Receiver Operator Characteristic* (ROC) em relação ao mapa de 2010 obtido a partir da Geoestatística; produção de mapas de perigo com uma distribuição de máximos anuais; simulação de eventos passados através das cotas de medição da estação fluviométrica do município.

1.1.1 Objetivo geral

Gerar mapas de inundação nos municípios de Palmares e Jaqueira empregando ferramentas de geoprocessamento sobre modelos digitais de terreno de alta resolução espacial, procedimentos geoestatísticos em profundidades de inundação, comparação entre diferentes obtenções de dados e análises hidrológicas estatísticas segundo dados fluviométricos.

1.1.2 Objetivos específicos

- Retratar os principais aspectos naturais e antrópicos geradores das inundações na bacia hidrográfica do rio Una;
- Tratar, analisar e transformar as profundidades de inundação dos eventos que ocorreram em Palmares (2010) e em Jaqueira (2017), respeitando as condições necessárias para aplicação coerente da Geoestatística (Krigagem Ordinária);

- Verificar o desempenho do limiar HAND por meio de medidas estatísticas que indicam taxas de acerto, de omissão e de comissão em comparação ao modelo de referência;
- Produzir um mapa de perigo do município de Palmares combinando o algoritmo HAND com a distribuição de extremos;
- Simular eventos passados do município de Palmares através do HAND e de dados de nível oriundos da estação fluviométrica.

2 REFERENCIAL TÉORICO

Neste capítulo foram relatados os impactos das inundações fluviais ao redor do mundo sob o enfoque das perdas de vidas humanas e da relação entre o desastre hidrológico e a vulnerabilidade dos países mais pobres. Discutiram-se as causas para formação do fenômeno e os aspectos das mudanças climáticas como justificativa para o aumento da frequência e da intensidade das inundações. Além disso, comentaram-se as soluções para atenuar os impactos, destacando as múltiplas técnicas para o desenvolvimento dos mapas de inundações, foco deste trabalho.

No enfoque prático para a obtenção dos mapas de inundação, abordou-se o processo de obtenção dos MDT do projeto PE3D a partir da tecnologia LIDAR, evidenciando as vantagens e as desvantagens do produto gerado. O capítulo ainda introduz o uso do modelo HAND em diferentes áreas das ciências ambientais, destacando na literatura sua aplicação na produção dos mapas de inundação. Por fim, as especificidades, os fundamentos matemáticos e estatísticos, o semivariograma teórico e empírico e a Krigagem Ordinária na inferência de superfícies contínuas e na estimação da incerteza foram debatidas para entendimento teórico e prático da Geoestatística.

2.1 INUNDAÇÕES FLUVIAIS: IMPACTOS, CAUSAS E MEDIDAS MITIGADORAS

O grande inconveniente das inundações são suas significativas consequências, caracterizando o fenômeno como um dos piores desastres naturais do mundo (CHAPI *et al*., 2017). O evento promove diversos impactos negativos – mortes, prejuízos econômicos, danos físicos em propriedades privadas e públicas, paralização de sistemas de transporte, de água e de energia, dentre outros. O dano mais significativo provocado é a perda de vidas humanas. Na Figura 1, apresenta-se o número de mortes por ano causados pelas inundações no mundo todo entre 1960 e 2018, estas informações foram obtidas através do banco de dados *Emergency Events Database* (EM-DAT) desenvolvido pelo *Centre for Research on the Epidemology of Disasters* (CRED). Outros dados alarmantes provocados pelas inundações entre 1998 e 2017: 2 bilhões de pessoas atingidas e perda econômica de 656 bilhões de dólares (WALLEMACQ, CRED E UNISDIR, 2017).

Figura 1 - Número de mortes no mundo como resultado das inundações no período de 1960 a 2018

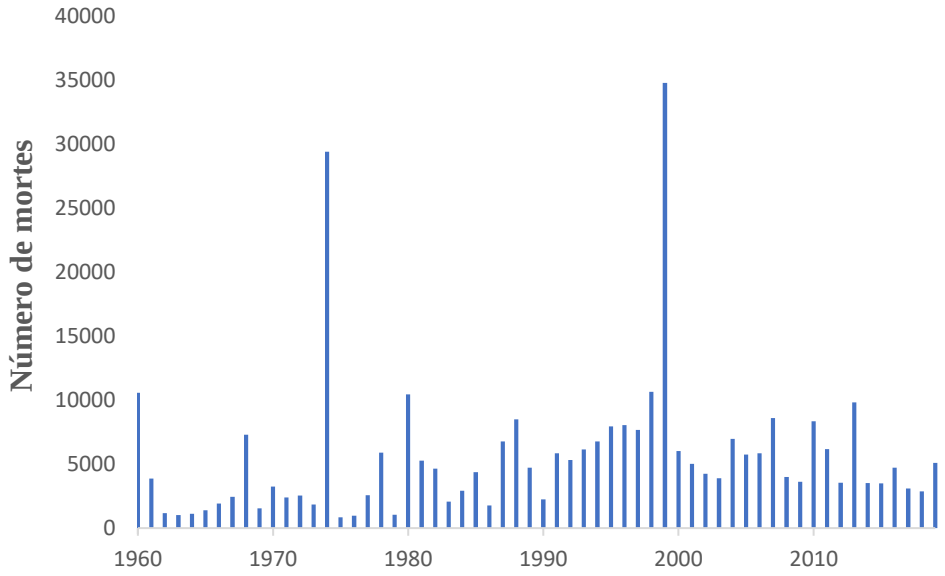

Fonte: EM-DAT (2020)

Os efeitos provocados pelas inundações têm ocorrido em diversas regiões do mundo. Na China, por exemplo, os Rios *Huang He* (Rio Amarelo), *Huia* e *Yangtze* computam os piores desastres relativos as inundações na história. Em 1931, ocorreu o pior evento de desastres naturais (excluindo epidemias e fome) já registrado pela humanidade, estima-se entre 1 e 4 milhões de mortes e 80 milhões de pessoas sem moradia (STOYNOV *et al*., 2017). Passados quase 1 século, em 2010, após um intenso evento hidrológico, a China contabilizou uma perda monetária de 51 bilhões de dólares (KUNDZEWICZ *et al*., 2014).

Em 2013, na Índia e no Nepal morreram 6648 pessoas (TANOVE *et al*., 2016). Bangladesh é considerado o país mais propenso as inundações no mundo, tendo problemas com inundações fluviais, costeiras e urbanas, em 1998, por exemplo, morreram 1100 pessoas e 30 milhões de desabrigados (KUNDZEWICZ *et al*., 2014). No ano de 2009, Taiwan sofreu com fortes chuvas (2777 mm) promovendo inundações que levaram a morte de aproximadamente 500 pessoas e um dano de 3,3 bilhões de dólares (SIMONOVIĆ, 2012). Tais evidências reforçam a ideia de Kundzewicz *et al*. (2014) que a Ásia é o continente com maiores danos causados por inundações.

Na Europa, em 2002, foram estimados um dano econômico de 7 bilhões de dólares. Até o Reino Unido, que raramente sofre com as inundações, vivenciou impactos em 2007, o evento foi considerado o mais nocivo depois da Segunda Guerra Mundial, em que morreram 13 pessoas, 48000 casas inundadas e bilhões de libras contabilizados (SIMONOVIĆ, 2012; FREER *et al*., 2013). Nos Estados Unidos, as inundações são responsáveis por mais mortes que

qualquer outro evento climático extremo. Em 2005, o Furacão Katrina provocou inundações que mataram 1836 pessoas, além de danos à propriedade estimados em 81 bilhões de dólares (SIMONOVIĆ, 2012). No Brasil entre 1985 e 2019 foram relatadas 3796 mortes e 3,5 milhões de desabrigados, estas informações foram obtidas por meio do banco de dados *Global Active Archive of Large Flood Events* do *Darthmouth Flood Observatory* (BRAKENRIDGE, 2020).

Como pode ser visto, as inundações causam danos em diversos países com características econômicas, populacionais e culturas distintas. Segundo Tanove *et al*. (2016), os países em desenvolvimento sofrem inundações mais frequentes e severas que os países desenvolvidos. Isto acontece, por causa da adoção de medidas preventivas que minimizam os prejuízos econômicos e as perdas humanas.

Reforçando a relação biunívoca entre o desastre hidrológico e a vulnerabilidade dos países mais pobres, na Figura 2 são apresentadas informações compiladas dos registros históricos globais de inundações por Tanove, *et al*. (2016), os autores utilizaram o banco de dados EM-DAT e classificaram a quantidade de eventos de inundação por Renda Nacional Bruta (RNB) per capita, categorizada em 4 classes pelo Banco Mundial. O Brasil, por exemplo, encontra-se na classe em laranja (*Upper-middle-income*) com RNB per capita variando entre 3,996 e 12,375 dólares. Com relação aos países mais pobres, o *low-income* com RNB per capita menor que 1,025 dólares e *lower-middle-income* com RNB entre 1,025 e 3,996 dólares, destaca-se a Índia, o Nepal, a Filipinas e Bangladesh, países fortemente atingidos pelas inundações.

Figura 2 - Número de países atingidos por inundações (linha sólida) e número de eventos de inundação por nível de renda (barra) obtidos através do EM-DAT entre os anos de 1960 e 2013

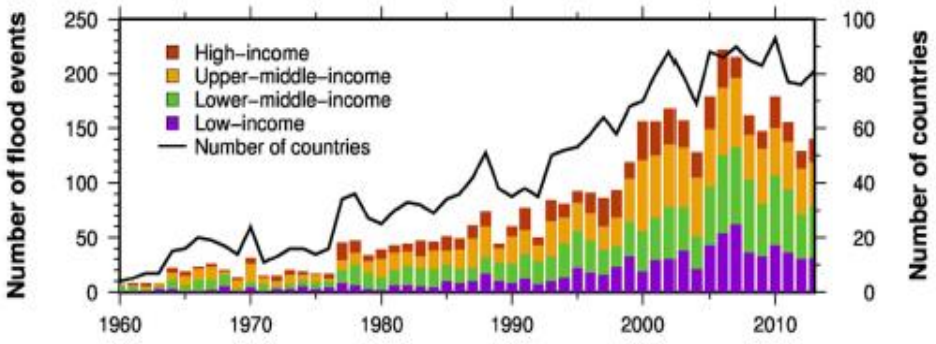

Fonte: Adaptado de Tanove *et al.* (2016)

Ainda segundo os autores, constatou-se um crescimento anual no número de inundações reportadas desde 1960, entretanto, eles ressaltam que esta tendência é compatível com a melhoria na coleta e na acessibilidade das informações. A título de exemplo, os países *low-income* atingidos tiveram um aumento de registros a partir da década de 90. Além disso, tal

evidência de crescimento também pode estar ligada às mudanças socioeconômicas como a expansão populacional nas áreas de risco.

Simonović (2012) comenta que o aumento dos riscos de desastres e os danos causados pelas inundações aconteceram em um período de crescimento econômico mundial, o que torna esta relação controversa, pois o desempenho econômico favorável poderia amortecer a vulnerabilidade da sociedade frente aos desastres. Entretanto, o próprio desenvolvimento pode ser o agente causador, atenuando a degradação ambiental, as mudanças climáticas e o aumento da desigualdade social.

Nas últimas décadas, as mudanças climáticas vêm despertando certa preocupação à sociedade global. Diversos cientistas afirmam que o aumento da frequência e da intensidade dos eventos extremos (ondas de calor, inundações, secas e outros) está sendo atribuído às mudanças climáticas. O termo, segundo o Intergovernmental Panel on Climate Change (IPCC), é definido como a alteração da condição média do clima e/ou na mudança de suas variáveis (precipitação, temperatura, umidade do ar, por exemplo), identificada por métodos estatísticos em período longo (décadas ou mais). As transformações no clima são originadas por processos naturais (alterações na radiação solar, vulcões em erupção e movimentações da órbita terrestre) e ações antropogênicas (degradação da terra que pode ser intensificada pela variabilidade climática e modificações na atmosfera terrestre por meio da emissão de gases do efeito estufa e aerossóis) (IPCC, 2012; 2014;2018; 2019).

A influência das mudanças climáticas, principalmente as causadas pelas ações do homem, sobre o aumento da frequência e da magnitude nas inundações se concentra na observação das variáveis do ciclo hidrológico. Kundzewicz *et al*. (2014) sustenta que a quantidade de vapor d'água na atmosfera e a distribuição no tempo e no espaço das chuvas intensas são os principais motivos climáticos para o risco a inundação. Simonović (2012) explica que na escala global, o aquecimento terrestre provoca o aumento da capacidade de retenção de água na atmosfera, resultando em alterações nos processos de redistribuição de umidade. O IPCC (2014) afirma com alta probabilidade que a umidade relativa do ar na troposfera tenha elevado desde a década de 70, modificando os padrões da precipitação, incidindo em algumas regiões precipitações elevadas mais intensas e frequentes.

Segundo o IPCC (2012; 2014), possivelmente (*likely*) há uma maior quantidade de regiões terrestres com um aumento significativo no número de ocorrências de precipitações elevadas do que um provável decaimento, entretanto, existem fatores regionais e locais que podem influenciar esta tendência. Na escala regional, a Europa e a América do Norte por possuírem estações meteorológicas bem distribuídas no tempo e no espaço, além de realizarem

constantes análises ao longo do tempo, estudos apontam para mudanças nas precipitações intensas com alta confiança. Em outros continentes como na África, na Ásia, na América Central, na América do Sul e na Oceania devido à escassez de dados e poucos estudos anteriores, foram verificadas tendências somente na escala local e, inclusive, na diminuição da frequência e da magnitude das precipitações intensas em algumas localidades, nestas regiões existe uma confiança de baixa para média na alteração das precipitações extremas.

Na escala local, no Brasil, por exemplo, dois estudos a respeito da detecção de mudanças climáticas relacionadas a precipitações extremas foram realizados: no estado de Pernambuco (SILVA, MONTENEGRO E SOUZA, 2017) e nos estados do Rio de Janeiro, de São Paulo, do Espírito Santo e do sudeste de Minas Gerais (ZILLI *et al*., 2017). Em Pernambuco foram aplicados índices de tendências (percentis, por exemplo) indicados pela Organização Meteorológica Mundial, (SILVA, MONTENEGRO E SOUZA, 2017) observaram evidências de tendências em todas as bacias do estado. Porém, os resultados foram mais expressivos nas bacias hidrográficas dos rios Ipanema, Brígida e Garças, as quais apresentação celeridade no processo de aridez, enquanto as bacias hidrográficas dos rios Mundaú, Sirinhaém e Garças mostraram um aumento na ocorrência de precipitações extremas.

Zilli *et al*. (2017) também aplicou os índices de detecção de mudanças do clima em conjunto com os testes estatísticos de Mann-Kendall e de Sen'Slopes para analisar a magnitude das tendências. As aplicações foram realizadas em postos pluviométricos e dados diários de precipitação em grade. Como resultado, concluiu-se que o estado de São Paulo apresentou quantidades de dias chuvosos maiores e eventos de precipitações extremas mais frequentes, em contrapartida o Rio de Janeiro e o Espírito Santo mostraram precipitações mais concentradas em menos eventos, indicando crescimento na magnitude da precipitação extrema. Por fim, os autores perceberam que espacialmente os padrões de tendências possuem interferências quanto a proximidade de áreas urbanas e características topográficas complexas.

De fato, as precipitações extremas desempenham papel fundamental na ocorrência das inundações, entretanto, percebe-se a dificuldade em estabelecer simplificações globais e regionais acerca de possíveis tendências. De maneira geral, a tendência de chuvas mais intensas em escala local apresentará possivelmente inundações mais frequentes e severas. Contudo, Simonović (2012) e Kundzewicz *et al*. (2014) alertam que as mudanças climáticas provocam alterações em outras variáveis do ciclo hidrológico, caso da evaporação, do processo de escoamento, das condições antes da inundação (teor de umidade do solo, nível de água superficial e subterrâneo), da geração de neve e do derretimento de gelo.

Apesar destes fatores, de acordo com Simonović (2012), IPCC (2012; 2014) e Kundzewicz *et al*. (2014), o crescimento da ocorrência e da magnitude das inundações fluviais não possuem relações estatísticas diretas e evidentes com as mudanças climáticas. Esta evidência é justificada pela baixa quantidade de estações fluviométricas dispostas no espaço, no curto período observado e interrupções na coleta de dados. Ademais, a ação do homem nas bacias hidrográficas (escala local/regional) por meio do uso da terra e da modificação na dinâmica dos rios dificultam o estabelecimento de relações entre as alterações de tendências das inundações fluviais com as mudanças climáticas.

Vale destacar ainda que entender as condicionantes climáticas tem sua relevância, porém o risco das inundações envolve quesitos essenciais relativos ao homem, destaca-se as características socioeconômicas, culturais e políticas; ao gerenciamento dos riscos; a participação dos diversos atores (instituições públicas e privadas, sociedade e academia); ao deslocamento populacional; a intervenção humana na topografia, no solo e na geologia das bacias hidrográficas. Os fatores citados podem gerar maior vulnerabilidade ao risco, incidindo no acréscimo da exposição de pessoas e de propriedades, gerando uma tendência no aumento na ocorrência de inundações catastróficas (SIMONOVIĆ, 2012; IPCC, 2014; TANOVE *et al*., 2016; ZHANG *et al*., 2018).

Como destacado, a inundação é um evento complexo dependente de diversas condicionantes e extremamente danoso, por este motivo, tem-se desenvolvido e utilizado medidas de gestão que minimizem os danos causados. Normalmente, a sociedade tem reduzido os efeitos através de medidas estruturais que utilizam intervenções físicas, modificando o fluxo da água, no caso das barragens, diques, dragagens, bacias de retenção, sistemas de drenagem, telhados verdes e asfalto poroso (HAGHIGHATAFSHAR et al., 2018; SARMAH E DAS, 2018; ZHANG *et al*., 2018).

Conforme Simonović (2012), barragens e diques, por exemplo, são soluções de vida útil curta que não contabilizam as necessidades das gerações futuras. Jha, Bloch e Lamond (2012) comenta que existem casos eficientes como a Barreira do Tâmisa em Londres e o sistema integrados dos rios Japoneses. Porém, as medidas estruturais podem sofrer eventos superiores ao que foram dimensionados a exemplo do catastrófico acidente no Japão em 2011, após uma Tsunami. Além disso, o impacto ambiental e a transferência de risco a inundação para outra localidade são informações relevantes que devem ser analisadas na tomada de decisão.

Quando o aporte financeiro é baixo para soluções de engenharia, a realocação da população atingida deve ser considerada (SIMONOVIĆ, 2012). Sendo esta solução derivada de medidas não-estruturais, as quais não precisam de aportes financeiros altos e concernem na

administração e prevenção dos riscos através da regulação do uso e ocupação do solo, da conscientização da população, da fiscalização em assentamentos ilegais e dos sistemas de previsão e alertas de inundação, dentre outros (JHA, BLOCH E LAMOND 2012; TINGSANCHALI *et al*., 2012).

Jha, Bloch e Lamond (2012) comenta que: "Medidas estruturais e não-estruturais não se opõe umas às outras, e as estratégias mais bem-sucedidas devem combinar ambos os tipos". Um exemplo de sucesso combinando as duas medidas foi realizado na cidade de Yangguan, no deserto da China, sendo caracterizada por ser uma região pobre, semiárida e fortemente atingida por inundações rápidas, gerando danos severos. O governo, a comunidade científica, uma empresa de aquicultura e a população afetada promoveram um projeto integrado que culminou na gestão do risco através de sistemas de alertas e de barragens, no desenvolvimento socioeconômico (geração de emprego, criação de indústrias, diminuição de mortes e construções de infraestruturas) e na restauração ambiental (crescimento de árvores frutíferas, prevenção da erosão do solo, melhoramento da umidade do solo e outros) (ZHANG *et al*., 2018).

Diante do exposto sobre as inundações, percebe-se que o evento hidrológico extremo é complexo e que para seu entendimento e minimização de impactos requer bases de dados eficientes com boa distribuição de informação no tempo e no espaço, promovendo análises e soluções baseadas em dados, maior inserção da sociedade e da academia nas tomadas de decisão, diminuição das desigualdades econômicas e socias da população, maior engajamento dos entes privados e públicos visando a sustentabilidade das cidades e sobretudo conviver de maneira harmoniosa com a água, entendendo e, principalmente, respeitando todo seu ciclo na superfície terrestre.

2.2 MODELAGEM DOS MAPAS DE INUNDAÇÃO

A partir do exposto anteriormente sobre as medidas de minimização dos impactos oriundos das inundações, para qualquer solução adotada pelos gestores públicos, análises da distribuição espacial são imprescindíveis e podem ser alcançadas através da modelagem dos mapas de inundação (ou manchas de inundação).

Segundo Merz, Thieken e Gocht (2007), Jha, Bloch e Lamond (2012) e Samanta, Pal e Palsamanta (2018), as manchas de inundação são mecanismos fundamentais no gerenciamento dos riscos, pois promovem: a entrega de informações objetivas e impactantes para a sociedade; um subsídio para tomadores de decisão; a conscientização da população em risco; a verificação

da efetividade do uso de estruturas hídricas ou de regulações; o auxílio do desenvolvimento urbano adequado; benefícios aos sistemas de previsão e; no entendimento dos eventos emergenciais.

Meyer, Thieken e Gocht (2007) classificam os mapas de inundação de três maneiras:

Mapas de Perigo: estão relacionados a uma probabilidade de excedência e a uma intensidade. Para retratar a análise estatística do evento de inundação, utiliza-se curvas de frequência associadas aos máximos anuais e a probabilidade de excedência ou seu inverso, o tempo de retorno. Geralmente, são criados cenários indicados pela curva de frequência. A intensidade é comumente associada a profundidade, extensão e velocidade.

Mapas de Vulnerabilidade: indicam os efeitos das inundações sobre os componentes humanos, construídos e ambientais. Estes mapas possibilitam a identificação de áreas mais vulneráveis aos danos em detrimento de um mesmo evento de inundação (probabilidade de excedência e intensidade).

Mapas de Risco: consolidados pela associação entre o mapa de perigo e de vulnerabilidade. Logo, a partir de um determinado tempo de retorno segundo certa intensidade e possíveis danos, tem-se o risco da área em estudo.

Usualmente, os mapas de perigo são os mais utilizados e estão associados a hidrologia estatística, a qual conforme Naghettini e Pinto (2007), é aplicada na inferência de vazões (ou cotas) relacionadas a um tempo de recorrência específico, sendo este igual a no máximo duas vezes o tempo de observação da estação fluviométrica. Para obtenção da estimação, recorre-se ao uso das distribuições de máximos anuais, normalmente, são usadas a distribuição Log-Normal, *Generalized Extreme Value* (GEV), Exponencial, Pearson tipo III, Log-Pearson tipo III e Gumbel.

Quando os mapas de perigo se apresentam sem a frequência de ocorrência, ou seja, somente com a distribuição espacial da água, estes são denominados de *flood danger maps*. Estes mapeiam extensões de áreas inundadas passadas (evento observado), profundidades da água (ou outra variável de intensidade) sobre um determinado evento, modelagem de situações hipotéticas como um rompimento de uma barragem ou uma circunstância hidrológica máxima (MEYER, THIEKEN E GOCHT, 2007).

Os mapas de inundação são desenvolvidos por meio de modelos que compõe técnicas matemáticas e processamento de dados, tendo como objetivo a abstração do mundo real, ou seja, a sintetização da realidade, desenvolvida em ambiente computacional. Jafarzadegan e Merwade (2019) comentam que diversos modelos determinísticos e probabilísticos foram formulados para a geração de mapas de inundação e a escolha para uma determinada localidade

é motivada por algumas razões, dentre elas, a resolução espacial almejada, a área da região analisada e o custo associado a modelagem computacional.

Uma primeira abordagem para criação das manchas de inundação pode ser realizada através da interpolação espacial de níveis de inundação observados (referências d'água pós-evento) por meio de métodos determinísticos (inverso do quadrado da distância e *spline*) e estatísticos (*kriging*). Segundo Furdada, Calderón e Marqués (2008), marcas em paredes, fotografias, documentos e entrevistas com a população são modos para levantamento destas referências, os autores ainda comentam que este tipo de levantamento possui vantagem sobre os métodos teóricos devido ao uso da profundidade real.

Com o auxílio do avanço dos *smartphones*, Oliveira, Brito e Santos (2018) desenvolveram um aplicativo de Informações Geográficas Voluntárias, o Hidromapp, ferramenta que possibilita o levantamento de informações colaborativas em pontos de inundação. Mídias sociais como o *Twitter* também têm levado progresso na aquisição de dados para interpolação de superfícies inundadas (BROUWER, 2016). As manchas de inundação nestes casos descrevem um evento específico, servindo, por exemplo, como o mapa base ou referencial para calibração de outros modelos.

Tradicionalmente, de acordo com Baldassarre *et al*. (2010), Degiorgis *et al*. (2012), Nobre *et al*. (2015), a simulação de áreas inundadas tem sido realizada primeiro por meio de modelos hidrológicos que simulam a relação chuva-vazão, buscando determinar os hidrogramas e as vazões de pico para diferentes tempos de retorno. Com isso, estas variáveis são introduzidas nos modelos hidrodinâmicos, responsáveis pela reprodução da propagação da onda no canal, resultando na distribuição espacial do fluído para as áreas inundadas em modelos numéricos topográficos.

A modelagem hidrodinâmica pode ser desenvolvida em um 1D, 2D, combinação entre o 1D/2D e 3D, sendo esta última menos utilizada devido à complexidade envolvida no processo numérico e a elevada quantidade de dados necessários para a calibração e a validação do sistema (NOBRE *et al*., 2015). Na união entre os modelos 1D e 2D, caso do LISFLOOD-FP, a superfície topográfica é o fator principal da simulação por causa de sua particularidade com os modelos hidráulicos. Basicamente, o escoamento no leito do rio é representado por deduções do modelo 1D, enquanto a planície de inundação é formulada segundo as características da onda 2D (BATES E ROO, 2000).

Os modelos 1D e 2D são regidos pelas equações simplificadas de continuidade e de momento de Saint-Venant. A diferença entre os dois concerne nos pressupostos adotados acerca das variáveis, os modelos 2D consideram que a velocidade e a profundidade variam nas duas

direções do canal, enquanto os modelos 1D apenas na direção longitudinal, de modo que a água se dispõe horizontalmente na direção perpendicular ao rio. Outra diferença está no desenvolvimento do fluxo sobre a superfície topográfica, as áreas inundadas no 1D são formuladas através da interpolação das seções transversais obtidas nos modelos topográficos, enquanto no 2D, o movimento do fluxo é simulado sobre os *pixels* da superfície topográfica digital (RIBEIRO NETO *et al*., 2015; NOBRE *et al*., 2015).

Como vantagem, os modelos hidrodinâmicos podem formar mapas com alta resolução espacial e temporal devido às características dinâmicas do fluxo implementadas no processo de cálculo, além disso, o comportamento da maré e dos dispositivos hidráulicos podem ser acoplados nos modelos, possibilitando melhoras na abstração do mundo real (ZHANG, DUTTA E VAZE, 2012).

Apesar de serem os mais indicados para simulação das inundações, a modelagem hidrológica e hidrodinâmica para sua performance satisfatória requer que as séries hidrológicas possuam resolução temporal adequada com boa distribuição no espaço. Brakenridge (2018) comenta que vários países em desenvolvimento possuem uma base hidrológica deficiente, dificultando o mapeamento das inundações segundo estes modelos. Bates (2004) destaca que, geralmente, poucas estações de medição estão acessíveis, porém distantes entre si, dificultando o processo de validação.

Outras dificuldades e erros podem causar incertezas na predição, destaca-se a etapa da calibração devido as diferentes entradas de dados, a falta de análises da não-estacionariedade dos parâmetros, incertezas na precipitação, na vazão e na geometria do rio, erros na calibração do coeficiente de rugosidade (manning) e a extrapolação do período de retorno em séries com baixa escala temporal. Além disso, estes modelos necessitam de desempenho computacional e de maior tempo para construção (MEYER, THIEKEN E GOCHT, 2007; BALDASSARRE *et al*., 2010; SPECKHANN *et al*., 2018; JAFARZADEGAN E MERWADE, 2019).

Por outro lado, nas últimas décadas, tem-se constatado o avanço da observação da terra no espaço por meio de variados sensores acoplados nos satélites espaciais e o progresso do processamento de imagem e dos Sistemas de Informação Geográfica (SIG). Com isso, novas possibilidades surgiram para a modelagem das áreas inundadas. Jafarzadegan e Merwade (2019) comentam sobre o crescimento de abordagens baseadas em Modelos Digitais de Elevação (MDE). Degiorgis *et al*. (2012) explicam que esta constatação ocorre devido à melhora no mapeamento da superfície, evidenciados através do desenvolvimento das geotecnologias, ressalta-se o *Global Positioning System* (GPS), *Synthetic Aperture Radar* (SAR), a Interferometric (InSAR) e Light Detection and Ranging (LIDAR).

Os MDE têm sido utilizados para a extração de particularidades hidrológicas e geomorfológicas (declividade, curvatura, índice topográfico, área de contribuição, altura acima da drenagem mais próxima, dentre outros) de maneira automática ou semiautomática nos SIG, promovendo resultados mais rápidos e acurados (MANFREDA, LEO E SOLE, 2011; DEGIORGIS *et al*., 2012; SPECKHANN *et al*., 2018; JAFARZADEGAN E MERWADE, 2019). Por meio destas particularidades em conjunto com dados pontuais de profundidades de inundação e/ou séries temporais hidrológicas e/ou imagens de sensores ópticos, diversos trabalhos apresentaram abordagens de mapas de inundação com análises de técnicas estatísticas, geoestatísticas e *machine learning* (ARCHFIELD *et al*., 2013; YAZDANI E SHEIKH, 2017; CHEN *et al*., 2019; CHOWDHURI, PAL E CHAKRABORTTY, 2020; GRIMALDI *et al*., 2020).

Combinação de dados geográficos obtidos por satélites também são evidenciados em Brakenridge (2018), o qual formulou uma nova metodologia para regiões com baixa disponibilidade de dados hidrológicos, o método combina hidrogramas obtidos por meio de micro-ondas passivas com imagens de sensores ópticos multiespectrais. Além de análises de multicritério, outras opções menos complexas como análises visuais, observação de histogramas das imagens para definição de limiares, detecção de mudanças nas imagens e algoritmos automáticos também vêm sendo aplicadas (SCHUMANN *et al*., 2009; SCHALAFFER *et al*., 2015).

De uma maneira geral, os dados derivados dos sensores ópticos e micro-ondas para o mapeamento das inundações tem grandes vantagens. Destaca-se a alta frequência de obtenção dos dados, a exemplo dos sensores Sentinel-1A e Sentinel-1B do *Copernicus Programme* com resolução temporal de 6 dias (TWELE *et al*., 2016) e aquisição dos dados em nível global, caso do projeto *Shuttle Radar Topography Mission* (SRTM), que mapeou a altimetria de aproximadamente 80% da superfície terrestre através da técnica InSAR (VALERIANO, 2004). Ademais, outro fator importante é a disponibilidade gratuita das imagens obtidas remotamente por satélites, ressalta-se as famílias CBERS e Sentinel, bem como os projetos LANDSAT, Terra, Aqua, Envisat, entre outros.

A geotecnologia SAR que opera na faixa das micro-ondas tem como vantagem no mapeamento das inundações em relação aos sensores ópticos, pois possibilita o registro das informações dia e noite, por serem sensores ativos, ou seja, não precisam da emissão da energia solar, além de penetrar as nuvens e as chuvas intensas (SCHUMANN *et al*., 2009; WESTERHOFF *et al*., 2013; SCHALAFFER *et al*., 2015). Entretanto, Westerhoff *et al*. (2013) e GIUSTARINI *et al*. (2015) comentam que a presença de ruídos nas imagens, problemas de

mapeamento sobre vegetações e topografias complexas, confusão entre os *pixels* de edificações e água, além das condições do vento são fontes de incertezas no mapeamento das inundações sobretudo através do SAR.

O maior inconveniente com o uso dos sensores ópticos e radares na modelagem dos mapas de inundação está centrado na baixa resolução espacial das imagens, principalmente para os bancos de dados de acesso livre. A aplicação dos modelos digitais topográficos nas análises de perigo, vulnerabilidade ou risco empregues em escalas locais, sobretudo nas cidades urbanas com alta densidade populacional e de propriedades susceptíveis ao dano, torna-se necessário o uso de imagens de alta resolução espacial (horizontal e vertical) para tomadas de decisão mais precisa (CIRILO *et al*., 2014). Para tanto, a geotecnologia LIDAR, descrita na próxima seção, se sobressai frente as técnicas de mapeamento por radar.

2.3 LIGHT DETECTION AND RANGING (LIDAR)

A geotecnologia LIDAR ou *Airborne Laser Scanner*, LASER escâner aerotransportado ou ainda Perfilamento a LASER aerotransportado tem se consolidado na geração de superfícies topográficas de alta precisão, sobretudo a partir da década de 90. Baltsavias (1999) e Brandalize (2004) reúnem diversas aplicações do produto cartográfico em projetos e pesquisas relacionadas a engenharia e ao meio ambiente, destaca-se: dutos de gás e óleo, redes de distribuição de água, estradas, linhas de transmissão de energia, potencial hidrelétrico, análises sedimentológicas, inventários florestais, indústria das telecomunicações para simulação da propagação de ondas eletromagnéticas, análises de riscos em eventos naturais, exploração mineral e monitoramento de tráfego.

Segundo Schumann *et al*. (2008), Bates (2012) e Freer *et al*. (2013), diversos pesquisadores têm verificado a possibilidade de diminuir as incertezas das condições de contorno, dos parâmetros e da estruturação dos modelos que sintetizam a inundação. Tais modelos são muito sensíveis à performance da topografa das áreas inundadas e, por este motivo, requerem dados mais precisos para a gerência destas incertezas. Percebeu-se, então, que a tecnologia LIDAR tem sido uma das principais fontes desta melhora.

O perfilamento a LASER aerotransportado, Figura 3, realiza uma varredura no terreno por meio da emissão de pulsos a laser na banda do infravermelho próximo (NIR) com alta frequência, que se propagam na velocidade da luz a partir de um conjunto ótico. Quando a radiação eletromagnética atinge os objetos terrestres e retorna ao sensor LASER, a intensidade do pulso e o tempo decorrente entre a emissão e a recepção do pulso são medidos. Sabendo do

tempo e da velocidade do pulso, a distância entre o sensor e o objeto para cada pulso é calculada. A altitude e a posição do sensor LIDAR, a inclinação dos pulsos, bem como a orientação da aeronave são obtidas através de um Sistema de Medição Inercial (SMI), um receptor GPS e outros componentes eletrônicos acoplados na aeronave. No terreno, faz-se necessário o uso de um GPS diferencial para retificação das diferenças posicionais entre os pontos calculados. Além disso, sistemas de imagens (câmera digitais ou analógicas) são utilizados para a geração de ortofotos (LOHR E EIBERT, 1995; BALTSAVIAS, 1999; BRANDALIZE, 2001; BATES 2012; LAJE *et al*., 2017).

Figura 3 - Ilustração do perfilamento a LASER aerotransportado e os componentes necessários (GPS receptor e base, SMI e o LASER escâner) para o mapeamento topográfico

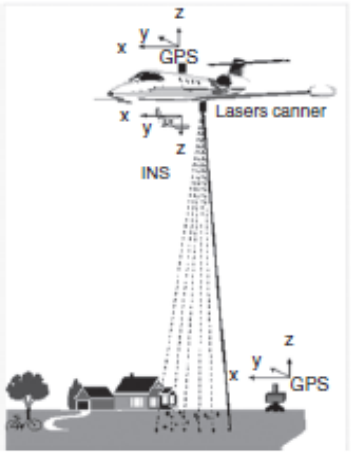

Fonte: Adaptado de Freer *et al*. (2013)

Um dos benefícios da tecnologia LIDAR é a capacidade de um pulso a laser registrar múltiplas reflexões dos alvos (Figura 4), permitindo a descrição de artefatos pequenos como fios e cabos acima do solo, além de penetrar vegetações, caracterizando o topo e o solo próximo a árvore, ou seja, quando o laser emitido pelo sensor atinge o topo da vegetação (primeiro alvo) se espalha, parcela da energia regressa a fonte e o restante atinge outros pontos da árvore (alvos intermediários) e, por fim, o solo (último alvo) (BALTSAVIAS, 1999; BRANDALIZE, 2001; KOBLER *et al*., 2007; LAJE *et al*., 2017).

Após extração dos dados brutos obtidos no GPS (receptor e base), no sensor LASER e no SMI, etapas de pós-processamento como verificação da dinâmica do voo, limpeza, correções específicas e associação dos dados são realizadas. Como produto, gera-se uma nuvem de pontos com coordenadas tridimensionais e medidas de intensidade dos alvos. Após técnicas de interpolação espacial e filtragem, os produtos cartográficos - modelos digitais e curvas de nível

- são criados com diferentes formatos de saída (BALTSAVIAS, 1999; LOHR E EIBERT, 1995; BRANDALIZE, 2001).

Figura 4 - Primeiro e último retorno do LASER

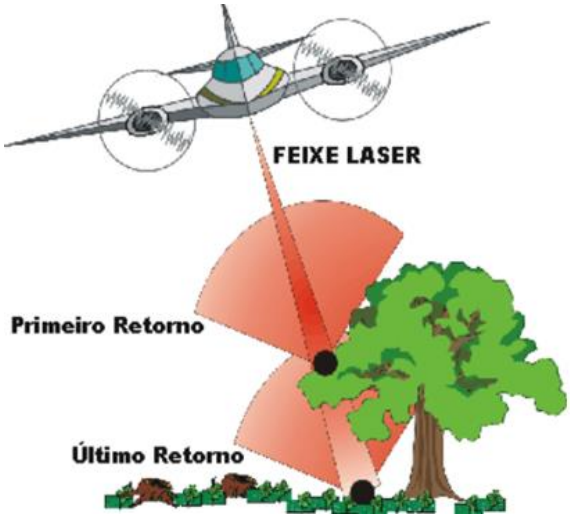

Fonte: Adaptado do Instituto de Fotogrametria e Sensoriamento Remoto/ Universidade Técnica Vienna (2003) apud Brandalize (2004)

Apesar de captar múltiplas reflexões, diversos pontos não atingem a superfície, sendo necessária a filtragem (classificação) dos pontos. Isto possibilita a criação do Modelo Digital do Terreno (MDT), em que os *pixels* fornecem a altimetria somente do solo, como o processo de classificação retira muitos pontos, principalmente em áreas de vegetação densa, faz-se necessária o uso de interpoladores. Sem a aplicação da filtragem, a superfície altimétrica descreve todos os objetos terrestres (edifícios, vegetação, cabos etc.), resultando no Modelo Digital de Superfície (MDS) (BRANDALIZE, 2001; KOBLER *et al*., 2007).

A vantagem de captar múltiplas informações em um único pulso a LASER é destacado em Bates (2004;2012), o autor comenta que a altura das árvores pode ser obtida pela diferença entre a primeira e a última onda refletida, sendo um importante atributo para análise da resistência do fluxo ocasionado pela vegetação nas zonas inundáveis, apesar de complexo. Mason *et al*. (2003) formulou uma proposta utilizando dados LIDAR para calcular o coeficiente de rugosidade distribuído no tempo e no espaço, variando segundo a altura da vegetação, a profundidade e a velocidade para um determinado instante.

Outra vantagem da tecnologia LIDAR é, assim como o SAR, um sensor ativo, podendo realizar mapeamentos independente do horário de operação. O perfilamento a LASER também gera produtos rápidos, tornando-se uma ferramenta valiosa para casos que precisam de agilidade na geração dos produtos. O ganho mais significativo na escolha dos sensores LIDAR

está na alta resolução espacial, com resolução horizontal variando de 0,25 a 2 m e acurácia vertical atingido cerca de 5 a 30 cm. Atualmente, a tecnologia LIDAR acoplada em veículos (*Lynx Mobile Mapper*) tem detalhado a superfície terrestre com ultra resolução (menor que 5 cm para resolução horizontal e vertical) (BRANDALIZE, 2001; MERCER, 2004; FEWTRELL *et al*., 2011; BATES, 2012; FREER *et al*., 2013; CIRILO *et al*., 2014). Por estes motivos, o sensor LIDAR tem apresentado melhores resultados na modelagem topográfica e, com isso, na hidrológica/ hidrodinâmica, prevendo a extensão e profundidade da inundação de forma mais acurada e precisa (BALTSAVIAS, 1999; PRIESTNALL, JAAFAR E DUNCAN, 2000; SCHUMANN *et al*., 2008; COOK E MERWADE, 2009; BATES, 2012).

Como desvantagens, diferentemente dos sensores radar, necessitam de condições meteorológicas propícias e, por isto, devem operar a baixas altitudes, geralmente de 20 a 6000m. O custo de levantamento também pode ser um entrave, por ser a tecnologia com o preço mais alto por m² em comparação a outras técnicas (BALTSAVIAS, 1999; BRANDALIZE, 2001).

Além disso, a tecnologia LIDAR nas planícies de inundação, nas áreas de vegetação e de construção representa adequadamente a estrutura topográfica do ambiente. Porém em regiões densamente vegetadas, as ondas eletromagnéticas não conseguem penetrar o dossel florestal. Outro ponto que deve ser evidenciado, sendo bastante discutido no meio científico é a batimetria dos ambientes aquáticos (rios, canais e oceanos) pelo LIDAR. O problema é que a água possui baixa reflectância no NIR, tornando o mapeamento abaixo da água ineficiente. Como solução se tem usado o LIDAR batimétrico que opera na banda do NIR e do verde, este último caracteriza toda a coluna d'água mapeando a superfície topográfica, o NIR é utilizado para extrair a superfície aquática e identificar áreas secas (QUADROS, COLLIER E FRASER, 2008; COOK E MERWADE, 2009; ALLOUIS *et al*., 2010; BATES, 2012; FREER *et al*., 2013).

2.4 HEIGHT ABOVE THE NEAREST DRAINAGE (HAND)

O *Height Above the Nearest Drainage* (HAND) ou altura acima da drenagem mais próxima é um modelo digital que descreve a superfície topográfica segundo potenciais gravitacionais relativos à rede de drenagem, sendo o resultado de técnicas de geoprocessamento combinadas com procedimentos hidrológicos sobre o MDT. Basicamente, a altimetria do MDT relativa ao nível do mar é transformada na diferença de altura entre a superfície do terreno e o

canal de drenagem mais próximo para cada célula da grade do modelo (RENNÓ *et al*., 2008 e NOBRE, A. *et al*., 2011).

O modelo HAND vem ganhando cada vez mais notoriedade pela sua simplicidade e rapidez de materialização. Diversas áreas como geomorfologia, hidrologia e ecologia tem-se beneficiado com sua a aplicação em conjunto com outras variáveis. O HAND tem auxiliado: na classificação de terrenos segundo propriedades do solo, da geomorfologia e da geologia, declividade, regime hidrológico conforme a profundidade da água subterrânea; na obtenção de mapas do solo e da vegetação para utilização em modelos hidrológicos distribuídos; modelagem de mapas de inundação e deslizamentos de terra; detecções do uso e ocupação do solo; previsões futuras com a expansão urbana; análises dinâmicas sobre parâmetros químicos e biológicos e suas interações com a topografia, dentre outras utilizações (RENNÓ *et al*., 2008; NOBRE, A. *et al*., 2011; NOBRE, C. *et al*., 2011; GHARARI *et al*., 2011; CUARTAS *et al*., 2012).

Na modelagem de áreas vulneráveis a inundação, tema de interesse desta pesquisa, o modelo HAND tem-se destacado devido às bases conceituais físicas e hidrológicas sobre a topografia, pois o modelo topográfico estabelece a relação entre a circulação da água e a rede de drenagem local, ou seja, o HAND desagrega o conceito da direção do fluxo da água do continente para o mar ao determinar trajetórias preferenciáveis locais para o escoamento da água até o canal de drenagem, o qual torna-se referência (zero) do modelo digital. Com isso, pontos mais próximos da rede de drenagem indicarão elevações menores, zonas saturadas, logo áreas sujeitas ou susceptíveis a inundação. O modelo, assim, indica regiões que acumulam água com a ocorrência das chuvas (NOBRE, A. *et al*., 2011).

Neste contexto, diversos trabalhos têm utilizado o modelo HAND para indicações de áreas vulneráveis. Inicialmente, Nobre, C. *et al*. (2011) aplicaram para a cidade de São Paulo o modelo HAND através de um MDT (resolução de 30 m) com o intuito de detectar zonas alagáveis e inundáveis, as quais foram validadas com pontos de inundação observados pós-evento. Além disso, foram analisadas regiões propensas a deslizamentos e estudos de vulnerabilidade para cenários futuros relacionados a expansão urbana, resultando em informações valiosas para o controle urbano e gerenciamento de riscos.

Nobre *et al*. (2015) desenvolveram a metodologia HAND *contour* que descreve o terreno segundo curvas de nível relativas à altura acima da drenagem mais próxima, indicando possíveis superfícies de inundação, destacando uma possível abordagem para análises de extensão da água nas planícies inundáveis, ademais os autores aplicaram a inversa do HAND, o que possibilitou a geração de profundidade da água no evento. A metodologia utilizou um

MDT com alta resolução espacial (0,39 m) e foi validada com o auxílio de um mapa de inundação no Rio Itajaí na cidade de Blumenau-SC, após interpolação (IDW) de 330 pontos levantados em campo (REFOSCO *et al*., 2013).

Os resultados indicaram que o HAND *contour* simulou toda área observada, porém apresentou superestimação em canais localizados fora da área de inundação. Os autores justificaram que tal evidência, provavelmente, ocorreu por considerarem redes de fluxo que não sofreram com a influência da propagação da onda e das características locais do escoamento (NOBRE *et al*., 2015).

Por meio do HAND *contour*, Momo *et al*. (2016) pesquisaram a mesma área que a do trabalho anterior verificando o desempenho do modelo segundo diferentes cotas de inundação da cidade. Os resultados foram comparados através de parâmetros de desempenhos (áreas de acerto, omissão e comissão). Como consequência, perceberam que na área de estudo, o modelo consegue resultados melhores à medida que aumenta a cota de inundação, concluindo que para cotas mais baixas efeitos hidrodinâmicos como o escoamento de refluxo podem influenciar na superestimação dos resultados.

Speckhann *et al*. (2018), definindo mapas de perigo de inundação, incrementaram ao algoritmo HAND análises de tempo de recorrência conforme distribuições de extremo em três municípios em que fluem as águas do Rio Itajaí. Os autores denominaram a metodologia de f2HAND e chegaram a atingir 92% de acerto ao comparar com mapas de eventos passados.

Na região Sul do Brasil, outros trabalhos aplicando o HAND na investigação das inundações podem ser vistos em Goerl, Michel e Kobiyama (2017) e Milanesi, Quadros e Lahm (2017). O primeiro verificou o desempenho do HAND para diferentes resoluções espaciais e limiares da área de contribuição. Os resultados obtidos indicaram que o HAND é mais vulnerável às modificações nos limites mínimos para a definição do canal de drenagem do que a variação da resolução espacial do dado topográfico. O segundo artigo apresentou resultados satisfatórios ao comparar o modelo HAND com dados pontuais obtidos através de reportagens: cerca de 98% dos eventos pontuais registrados foram correspondidos a alta susceptibilidade de inundação classificada pelos autores, indicando forte correlação entre as alturas HAND e terrenos sujeitos a inundação.

Afshari *et al* (2018) compararam a modelagem do HAND com a do HEC-RAS-2D em sub bacias do estado de Iowa e Alabama nos Estados Unidos, considerando diferentes modelos digitais, com e sem dique ou com batimetria ou com ambos. Os autores constataram que os dois modelos se comportaram de maneira similar na profundidade e na distribuição da extensão da inundação. Entretanto, o modelo HAND superestima áreas não inundadas quando estruturas

hidráulicas (barragens ou diques) estão presentes, visto que o algoritmo não consegue registrar mudanças físicas consideráveis nos terrenos. Além disso, o HAND pode não captar terrenos inundados em áreas densamente urbanizadas e planas por causa dos efeitos de marés oriundos dos controles hidráulicos.

2.5 A GEOESTATÍSTICA NA INFERÊNCIA DE SUPERFÍCIES CONTÍNUAS E NA QUANTIFICAÇÃO DE INCERTEZAS

A interpolação é definida como a técnica de estimação de pontos não conhecidos ao distribuir pesos segundo amostras coletadas em um determinado domínio. Nas ciências da terra são constados poucos processos físicos e químicos em que dados amostrais, provenientes de uma mesma população, conseguem explicar a formação/estimação de um determinado fenômeno com detalhes suficientes e conhecimentos a priori. Nestes casos, técnicas determinísticas (triangulação, inverso do quadrado da distância e polígonos de influência) podem explicar a ocorrência do evento através de uma combinação linear dos valores observados. Entretanto, na natureza, o mais comum é que uma determinada variável é originada segundo múltiplas causas que interagem entre si de maneira complexa, dificultando a quantificação do fenômeno (ISAAKS E SRIVASTAVA, 1989; CÂMARA *et al*., 2004).

Nestes últimos casos, deve ser admitida a hipótese de que a relação entre a geração do fenômeno e os resultados nos locais amostrados é incerta, inevitavelmente. Dessa forma, os métodos determinísticos (clássicos) não são indicados para estimação, justamente, por não quantificarem a incerteza no processo de inferência. Tais modelos desconsideram que existem erros de origem sistemática e aleatória decorrentes da amostragem dos dados ou da técnica empregada. Em suma, há incertezas, embora sejam mais significativas nos pontos não amostrados, os pontos levantados também estão associados a erros por causas determinísticas, instrumentais e humanas. Com isso, visando quantificar a incerteza da estimação, utilizam-se modelos probabilísticos (estocásticos) (ISAAKS E SRIVASTAVA, 1989; FELGUEIRAS, 2001).

Ao contrário dos métodos determinísticos, os valores observados são analisados como resultados de processos aleatórios. Conforme alertado anteriormente, o procedimento de criação de uma determinada variável é bastante complexo e o seu entendimento pode ser desprovido de conhecimento, base ou até informações (dados) suficientes para descrevê-lo. Por este motivo, entende-se que as variáveis são provenientes da aleatoriedade e de uma maneira geral, mesmo conhecendo a origem das variáveis e sua condição a priori, há infinitas

possibilidades para o desenvolvimento do processo, resultando em incertezas, as quais devem ser medidas para verificação da qualidade do modelo proposto (JOURNEL, 1988; ISAAKS E SRIVASTAVA, 1989; SOARES, 2006).

O grande ponto é que independente da natureza do fenômeno. Assume-se que o processo é randômico, sendo assim, a base metodológica para a inferência, sem a necessidade de descrever todo o processo. Logo, os modelos probabilísticos fornecem os mecanismos para modelar o processo estocástico a partir da parametrização de todos os dados amostrais, descrevendo o comportamento espacial entre eles. Neste cenário, a geoestatística manifesta-se como a técnica de inferência probabilística, caracterizando o padrão das amostras no espaço por meio de ferramentas estatísticas como o valor esperado e a correlação entre pares amostrais, além disso, fornece medidas de acurácia e precisão da estimação (ISAAKS E SRIVASTAVA, 1989; CÂMARA *et al*., 2004; CAMARGO, FUCKS E CÂMARA, 2004; SOARES, 2006).

Por meados da década de 50, o engenheiro de minas Krige e o estatístico Sichel, trabalhando com estimativas de concentrações de ouro na África do Sul, utilizaram a predição através de médias móveis com o intuito de diminuir a superestimação dos teores de ouro. Dessa forma, Krige e Sichel compreenderam a relação entre o volume e a variância das amostras, ou seja, a variabilidade entre as amostras dentro de um bloco é diferente da variabilidade entre blocos vizinhos. Tal ideia pode ser transferida para a variável tempo, isto é, a variação entre teores médios mensais é menor que a flutuação nas médias diárias. Neste contexto, eles perceberam que analisar meramente a variância das amostras era inequívoco, tornando necessária a introdução da análise espacial dos dados no processo de estimação, objetivando a otimização da produção nas minas de ouro (KRIGE, 1951; VIEIRA, 2000; CAMARGO, FUCKS E CÂMARA, 2004; LANDIM, 2006).

A partir destas considerações baseadas na estatística clássica, o matemático francês Matheron, na década de 60, implementou a Teoria das Variáveis Regionalizadas. Tal princípio representa a fundamentação teórica da geoestatística segundo a qual expressões matemáticas básicas não conseguem refletir a variação de um determinado fenômeno espalhado no espaço. De maneira que a continuidade espacial e a característica geométrica das observações sejam consideradas no processo de cálculo, ou seja, a posição espacial, o volume e a direção das amostras são relações fundamentais para descrever o processo aleatório. Como consequência, observa-se mais uma distinção entre a estática clássica (ou métodos determinísticos) e a geoestatística, a existência da dependência entre as amostras (MATHERON, 1966; 1970; CRESSIE, 1993; VIEIRA, 2000; CLARK, 2001; CAMARGO, FUCKS E CÂMARA, 2004).

Segundo Matheron (1966,1970), a Teoria das Variáveis Regionalizadas formaliza particularidades essenciais para descrever o fenômeno espacial por meio de uma função simplificada, o variograma (ou semivariograma). As características que formulam o suporte conceitual da teoria são a localização, a continuidade e a anisotropia, descritas a seguir:

Localização: associada com o suporte amostral, relação volume-variância. Na geologia, por exemplo, um furo de sondagem não representa todo o bloco maciço, embora ligações possam ser realizadas. Além disso, ao introduzir amostras pertencentes a outro volume amostral no processo de interpolação, diferente da teoria clássica, é incoerente na geoestatística, pois os dados são provenientes de amostras com distribuição de probabilidade e variâncias distintas.

Continuidade: reflete o padrão da variabilidade espacial, como se desenvolve a flutuação dos valores observados no espaço, caracterizando assim, a dependência ou independência entre as amostras. Na dependência, existe certa continuidade (correlação) entre as amostras, enquanto na independência não há estrutura espacial. Quando as amostras estão próximas (distância euclidiana) sem correlação espacial (independentes), este fenômeno é conhecido como efeito pepita. No geral, as observações tendem a ser mais "parecidas" quando próximas (dependentes) e quanto mais afastadas, independentes.

Anisotropia: discorre sobre a direção preferencial da variação dos dados, de modo que os valores mudam com maior ou menor intensidade segundo um determinado sentido. Logo, existirá uma direção com maior continuidade espacial (variação regular e lenta), a qual pode ser percebida e modelada por meio do semivariograma. Perpendicular a esta direção, tem-se variações irregulares com independência dos dados a curtas distâncias. Caso a anisotropia não seja verificada, o caso é isotrópico, não apresentando continuidade preferencial em uma dada direção.

Para a formalização matemática e estatística da teoria das variáveis regionalizadas e, com isso, da geoestatística, as particularidades introduzidas anteriormente devem ser abordadas na técnica de predição. Neste caso, a inferência deve ser realizada seguindo os pressupostos do processo estocástico (função aleatória) e da correlação na distribuição espacial entre as amostras. Landim (2006) comenta que esta relação é incompatível, pois o processo aleatório constitui a variabilidade e a incerteza entre as amostras e a dependência espacial implica que é plausível que as amostras mais próximas entre si, apresentem maiores relações do que realizações distantes.

A função aleatória na geoestatística, diferentemente na estatística clássica segundo a teoria das probabilidades, apresenta somente um evento $\mathbf{z(x_i)}$, o qual na prática não pode ser alcançado novamente. Logo, a realização $\mathbf{z(x_i)}$ é representada pelo conjunto das variáveis

aleatórias $\mathbf{Z(x_i)}$, $\mathbf{i = 1, 2, ..., N}$, dependentes espacialmente entre si. Como há somente um evento para cada variável aleatória, isto inviabiliza na produção de estatísticos que represente a variável ou a função. Com isso, deve-se ser introduzido a estacionaridade dos momentos da função aleatória, garantindo a inferência estatística (VIEIRA *et al*, 1983; SOARES, 2006).

Conforme Camargo, Fucks e Câmara (2004), a variabilidade espacial da variável regionalizada **Z(x)** a ser modelada pode ser expressa conforme a Equação 1:

$$\mathbf{Z(x) = \mu(x) + \varepsilon'(x) + \varepsilon''} \quad (1)$$

Em que:

μ(x): parcela determinística que representa o elemento estrutural Z no vetor x (posição no espaço);

ε'(x): função estocástica, caracteriza a correlação espacial entre as amostras e fornece a variação dos dados;

ε'': termo que analisa o erro residual, descrito por uma distribuição normal com média zero e variância mínima.

A formalização da função aleatória da geoestatística, explicada a seguir, foi retirada das seguintes obras: Matheron (1966,1970), Journel e Huijbregts (1978), Vieira *et al*. (1983), Isaaks e Srivastava, (1989), Cressie (1993), Vieira (2000), Camargo, Fucks e Câmara (2004), Landim (2006) e Soares (2006).

Os autores explicam que a Teoria das Variáveis Regionalizadas necessita levar em consideração a hipótese de estacionariedade do primeiro (valor esperado) e do segundo (variograma e covariância) momento da distribuição das amostras aleatórias, os quais traduzem as concepções estatísticas do suporte espacial das amostras. A estacionariedade do efeito de primeira ordem considera que para qualquer posição de **Z ($\mathbf{x_i}$)**, a esperança matemática $\mathbf{E[Z\,(xi)]}$ é igual a média das amostras (Equação 2), ou seja, as amostras provêm da mesma distribuição de probabilidade (princípio da estacionariedade). Desta forma, tal indicador pode ser obtido através da média aritmética **m ($\mathbf{x\alpha}$)** das observações, sem depender da posição espacial **xi** dos dados (Equação 3).

$$\mathbf{E[Z\,(x1)] = E[Z(x2)] = \cdots = E[Z(xn)] = E\,[Z(x)] = m} \quad (2)$$

$$\mathbf{m(x\alpha)} = \frac{\mathbf{1}}{\mathbf{N}} \sum_{\alpha}^{\mathbf{N}} \mathbf{Z(x\alpha)} = \mathbf{m} \quad (3)$$

O segundo momento trata sobre a estacionariedade da covariância **C** (Equação 4 e 5), a qual representa a esperança do produto entre **Z (x)** e **Z (x + h)** subtraída do produto da esperança das amostras na posição **(x)** e **(x + h)**. A covariância traduz a correlação entre duas amostras aleatórias, independentemente de suas localizações espaciais. Além disso, é exclusivamente reativa a distância entre elas segundo o vetor h, representado pela distância euclidiana **| h |** e a direção entre os pares observados.

$$\mathbf{C(h)} = \mathbf{C[Z(x), Z(x+h)]} = \mathbf{E[Z(x).Z(x+h)]} - \mathbf{E[Z(x)].E[Z(x+h)]} \quad (4)$$

Pelo princípio da estacionariedade do primeiro momento (Equação 2), tem-se:

$$\mathbf{C(h)} = \mathbf{E[Z(x).Z(x+h)]} - \mathbf{m^2} \quad (5)$$

Como a covariância possui relações matemáticas com a variância **σ**, Equação 6, assume-se, então, a estacionariedade da variância, ou melhor, se a covariância depende exclusivamente do vetor h, conclui-se que a variância de **Z(x)** também não depende de **x**, sendo constante em todo o domínio. Adicionalmente, a estacionariedade do primeiro momento, obtém-se a seguinte relação:

$$\begin{aligned} \boldsymbol{\sigma^2}\mathbf{[Z(x)]} = \mathbf{E}\,[\mathbf{Z(x)} - \mathbf{m}]^{\mathbf{2}} = \mathbf{E}\left[\mathbf{Z(x)^2}\right] - \mathbf{2E[Z(x)].m} + \mathbf{m^2} = \\ = \mathbf{E}\left[\mathbf{Z(x)^2}\right] - \mathbf{m^2} = \mathbf{C(0)} \end{aligned} \quad (6)$$

Onde:

C (0): variância a priori das amostras quando o vetor h é igual a zero. Ressalta-se que esta relação também pode ser extraída através da equação 5.

Corroborando com os pressupostos de estacionariedade em outros pontos do domínio, acrescidos do vetor h, isto permite descrever a variável regionalizada por meio de **C(h)**. Com isso, acrescenta-se o parâmetro estatístico variograma **γ** (ou semivariograma), sendo este definido como a medida de dispersão (continuidade) entre as amostras aleatórias distantes de **h**. O variograma (Equação 7) representa a esperança matemática do quadrado dos desvios:

$$2\gamma(\mathbf{h}) = 2\gamma[\mathbf{Z(x)}, \mathbf{Z(x+h)}] = \mathbf{E}[\mathbf{Z(x)} - \mathbf{Z(x+h)}]^{\mathbf{2}} =$$
$$= \mathbf{E}\left[\mathbf{Z(x)^2}\right] + \mathbf{E}\left[\mathbf{Z(x+h)^2}\right] - \mathbf{2}.\mathbf{E}[\mathbf{Z(x)}.\mathbf{Z(x+h)}] \quad (7)$$

Pela hipótese da estacionariedade, a esperança matemática das amostras é constante em todo o domínio e a variância é a mesma em todos os pontos, já que os eventos provêm da mesma distribuição de probabilidade, com isso $\mathbf{E}\left[\mathbf{Z(x)^2}\right] = \mathbf{E}\left[\mathbf{Z(x+h)^2}\right] = \mathbf{C(0)} + \mathbf{m^2}$. Complementarmente, introduzindo a Equação 5 na Equação 7, tem-se:

$$2\gamma(\mathbf{h}) = 2\mathbf{C(0)} + 2\mathbf{C(h)} \text{ ou } \gamma(\mathbf{h}) = \mathbf{C(0)} + \mathbf{C(h)} \quad (8)$$

Desta forma, após deduções matemáticas, percebe-se que a covariância e o semivariograma são medidas estatísticas que representam a variabilidade espacial e modelam a estrutura espacial entre amostras **Z** distantes de **h**. Dessa forma, o termo estocástico $\boldsymbol{\varepsilon'(x)}$ da Equação 1 pode ser representado por estes parâmetros.

Na Figura 5, apresenta-se a diferença gráfica entre o variograma e a covariância (correlograma) em relação a **h**. Intuitivamente, nota-se que para distâncias pequenas, próximas de zero, a covariância é máxima, enquanto a variância é mínima. Na medida em que há um incremento de **h**, a covariância diminui e a variância aumenta, corroborando com a hipótese da continuidade, ou melhor, quanto maior **h**, menor a dependência verificada. Para distâncias maiores que **a** (Figura 05), não existe mais continuidade espacial, logo confirma-se a independência entre os dados.

Figura 5 - Representação gráfica do variograma e da covariância

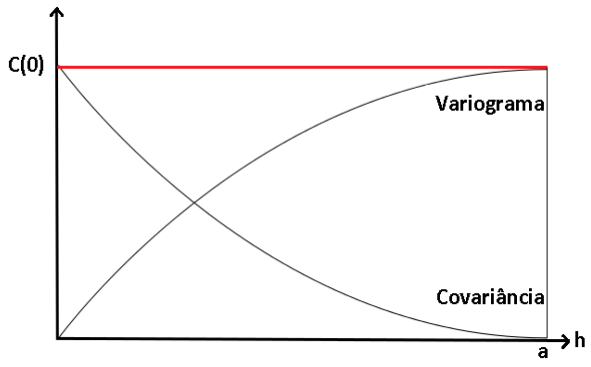

Fonte: O autor (2021)

Segundo Soares (2006), estas relações de estacionariedade do primeiro e do segundo momento estabelecem as seguintes relações: deduz-se que os valores estimados por meio de combinações lineares a partir de um conjunto de amostras aleatórias, caracteriza o dado inferido também como uma variável aleatória; a obtenção dos parâmetros estatísticos resulta na possibilidade de inferir outros eventos no espaço através da mesma média, variância e distribuição de probabilidade de Z (x); traduz-se a continuidade espacial conforme a modelagem do variograma ou da covariância.

Por fim, destaca-se que a covariância, geralmente, é mais utilizada em séries temporais, enquanto na geoestatística para descrever a predição de fenômenos naturais no espaço, comumente, utiliza-se a modelagem do variograma. No próximo item são descritas considerações gerais, modelo experimental e teórico, além de parâmetros associados a estrutura, construção e modelagem do variograma ou semivariograma.

2.5.1 Variograma (semivariograma)

Como visto anteriormente, o variograma (semivariograma) é uma das possibilidades de modelar a continuidade espacial e a correlação de amostras segundo suas posições no espaço. O variograma $\boldsymbol{\gamma}$ descreve o valor esperado do quadrado da diferença entre realizações dada uma possível orientação espacial. Em outras palavras, esta métrica estatística descreve a variabilidade das amostras regionalizadas.

Na Figura 6, demonstra-se a ideia da disposição no espaço das amostras e como o variograma é empiricamente calculado. Sejam duas amostras **z (x)** e **z (x + h)**, em que **x** é definida como a posição no plano ($\mathbf{x_1}$ e $\mathbf{y_1}$) e **h** o vetor que define a orientação entre as variáveis. A posição de **z (x + h)** no plano é ($\mathbf{x_2}$ e $\mathbf{y_2}$). Para determinação do semivariograma (Equação 9), tomado determinados valores **h**, todas as amostras nestes intervalos são combinadas em pares e o quadrado dos desvios calculados, os quais são somados e a média computada (CAMARGO, FUCKS E CÂMARA, 2004; SOARES, 2006).

Figura 6 - Amostras dispostas no espaço, relação entre duas variáveis z (x) e z (x + h)

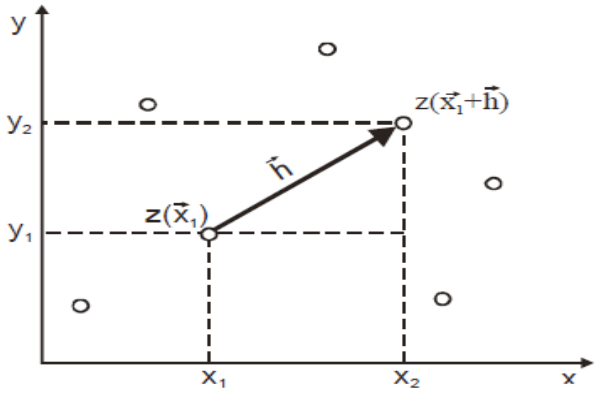

Fonte: Camargo, Fucks e Câmara (2004)

$$\boldsymbol{\gamma(h) = \frac{1}{2.N(h)} . \sum_{i=1}^{N(h)} [z(xi - z(xi + h)]^2} \quad (9)$$

Em que:

N (h): quantidade de pares computados para uma determinada distância h.

Procura dos pares amostrais

Para a montagem do gráfico de dispersão das amostras visando a compreensão da variabilidade espacial do fenômeno analisado, a busca por pares amostrais é realizada segundo a determinação de parâmetros relativos à distância e à direção, além de tolerâncias que sujeitam o vetor **h** a intervalos (classes) (Figura 7). Esta folga na pesquisa por pares amostrais em uma dada direção é necessária porque possibilita uma maior quantidade de pares analisados. Ademais, as amostras independentemente de serem organizadas regularmente, não possuem distâncias iguais entre si (ISAAKS E SRIVASTAVA, 1989; CAMARGO, 1998; LANDIM, 2006).

Como pode ser visto na Figura 7, as especificações dos intervalos de **h** são o ***lag***, **número de *lags***, a **tolerância do *lag***, a **direção do vetor h**, a **tolerância angular** e **a largura da banda (BW)**. Os conceitos declarados nos próximos parágrafos foram levantados a partir das seguintes obras: Isaaks e Srivastava (1989), Camargo (1998), Vieira (2000), Landim (2006) e Soares (2006).

Lag: intervalo de distância entre as classes;

Número de *lags*: quantidade de incrementos (classes);

Tolerância do *lag*: limite em que são procuradas as amostras distantes de (**h** ± tolerância de ***lag***), formando intervalos de procura;

Direção do *lag*: ângulo referente ao sentido horário a partir da direção Norte.

Tolerância angular: relacionada com o limite da classe segundo a direção.

Largura da banda (BW): largura máxima de procura por pares, os quais são delimitados até uma certa distância perpendicular à direção de **h**.

Figura 7 - Esquema e parâmetros de busca dos pares amostrais distantes do vetor h para a determinação do variograma

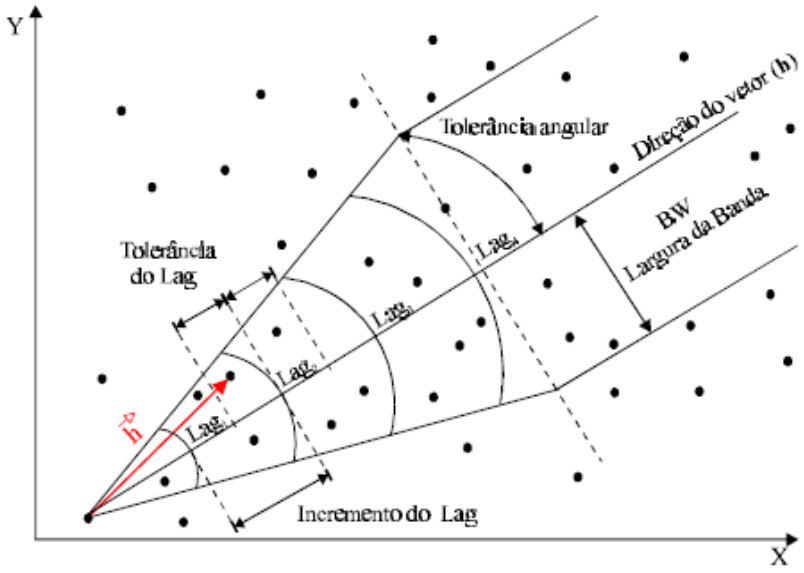

Fonte: Camargo (1998)

Modelos teóricos

Posteriormente a construção dos semivariogramas empíricos, necessita-se adequar um modelo matemático que corresponda ao formato ideal das variâncias calculadas segundo os valores de **h**. Para tanto a hipótese intrínseca da geoestatística - estacionariedade do primeiro e do segundo momento da função aleatória - deve ser admitida em tais modelos. Com isso, o semivariograma pode ser descrito segundo parâmetros teóricos que traduzam o comportamento da variabilidade (ou continuidade espacial) das amostras (Figura 8).

Como já comentado anteriormente, a relação entre a variância e a distância **h** é diretamente proporcional. À medida que as amostras se distanciam, a variância tende a aumentar até atingir um patamar (**C**) ou *sill*. Ao atingir este parâmetro, a variabilidade entre as amostras se apresenta estabilizada (constante) ou irregular (aumentando e diminuindo indefinidamente). Logo, este parâmetro indica que não existe mais correlação entre os pares

amostrais dada uma distância **h**. O patamar, na teoria, deve ser igual a variância a priori, **C (0)**. Além disso, a distância em que a variância atinge o patamar é conhecida como alcance - **a** -ou *range*, até esta distância existe a dependência espacial (continuidade) entre as amostras (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; CRESSIE, 1993; CAMARGO, 1998; SOARES, 2006).

Outra possibilidade é o semivariograma empírico indicar que a variância possui tendência de crescimento infinita, ou seja, não há presença do patamar. Neste caso, modelos teóricos sem patamares são utilizados para descrevê-lo, caso dos modelos de potência, os quais não foram retratados neste trabalho por se tratar de processos não-estacionários (JOURNEL E HUIJBREGTS, 1978; CAMARGO, 1998; SOARES, 2006).

Na origem, quando **h** = 0, a variância teoricamente deveria ser igual a zero, porém, na prática existe certa descontinuidade na pequena escala, ou seja, $\boldsymbol{\gamma(0) \neq 0}$. Quando a distância **h** é menor que a distância entre o par mais próximo, $\boldsymbol{\gamma(h)}$ tende a uma quantia positiva denominada de efeito pepita ($\mathbf{C_0}$) ou *nugget effect*. Tal efeito pode estar relacionado a erros sistemáticos ou a variância local em que as amostras não conseguiram reproduzi-la (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; CRESSIE, 1993; CAMARGO, 1998; SOARES, 2006).

A diferença entre o patamar e o efeito pepita resultam no parâmetro conhecido como contribuição ($\mathbf{C_1}$), sendo este o componente estruturado no espaço, a variância que possui correlação. Quando $\mathbf{C_1}$ é igual a zero, o semivariograma torna-se uma reta ($\mathbf{C_0 = C}$), diz-se, então, que há um efeito de pepita puro, pois não há correlação geométrica entre as observações, existe apenas aleatoriedade pura (ISAAKS E SRIVASTAVA, 1989; CRESSIE, 1993; CAMARGO, 1998; VIEIRA, 2000; CAMARGO, FUCKS E CÂMARA, 2004; LANDIM, 2006; SOARES, 2006).

Figura 8 - Parâmetros do semivariograma

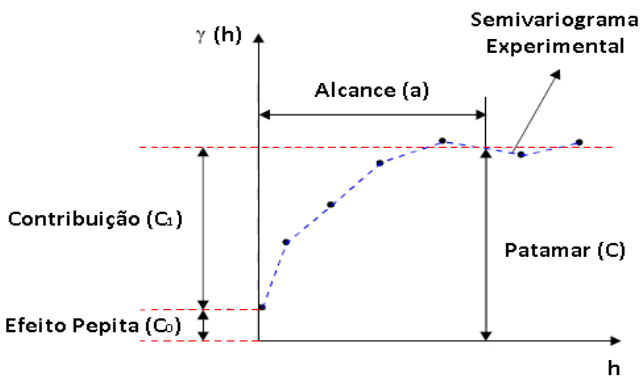

Fonte: Adaptado de Camargo (1998)

Neste contexto, após a geração do semivariograma empírico, conforme a Equação 9, representada pelo conjunto dos dados observados em um determinado domínio. Faz-se necessária a tradução para todos os valores dos variogramas calculados, que pode ser alcançada através da modelagem de uma equação matemática. Tal função com base nos parâmetros apresentados (**a**, $\mathbf{C_0}$, $\mathbf{C_1}$, **C**) deve ser capaz de descrever a dependência espacial de **Z (x)** em toda a área a ser inferida.

Segundo Vieira (2000), Landim (2006) e Soares (2006) esta fase é crucial para obtenção de uma inferência mais próxima da realidade por meio de um modelo singular e coeso que contemple todas as particularidades da ordenação espacial das amostras – continuidade, localização e anisotropia.

Conforme Vieira *et al*. (1983), Isaaks e Srivastava (1989), Camargo (1998), Vieira (2000), Camargo, Fucks e Câmara (2004), Landim (2006) e Soares (2006), inicialmente, determina-se a condição de positividade dos modelos teóricos, isto torna claro e inequívoco que a soma dos pesos para qualquer combinação deve ser positiva ou nula. Esta suposição deve ser válida para que a estimação resulte em valores coerentes com as amostras. Neste sentido, os modelos conceituais regidos por esta hipótese são os modelos esféricos (Equação 10), gaussianos (Equação 11) e exponenciais (Equação 12), apesar de existirem outros, os três modelos citados são os mais comuns (Figura 9).

$$\gamma\,(h)Esf = \begin{cases} \mathrm{C}.\left[1{,}5.\frac{|\,\mathrm{h}\,|}{\mathrm{a}} - 0{,}5.\left(\frac{|\,\mathrm{h}\,|}{\mathrm{a}}\right)^3\right] & \text{para } |\,\mathbf{h}\,| \leq \mathbf{a} \\ \mathrm{C} & \text{para } |\,\mathbf{h}\,| > \mathbf{a} \end{cases} \tag{10}$$

$$\gamma\,(h)Gau = C.\left[1 - \exp\left(\frac{-3.|\,h\,|^2}{a^2}\right)\right] \tag{11}$$

$$\gamma\,(h)Exp = C.\left[1 - e^{-3.|\,h\,|/a}\right] \tag{12}$$

Segundo Soares (2006), o modelo exponencial e o esférico se apresentam com um crescimento mais célere próximo à origem, sendo mais expressivo no caso do exponencial. Tal fenômeno, geralmente, acontece quando as amostras são ordenadas no espaço de maneira irregular. Caso contrário, quando a distribuição é regular, a variância cresce de forma mais gradual, demostrando uma configuração parabólica, a qual pode ser representada por modelos Gaussianos.

Figura 9 - Semivariogramas teóricos

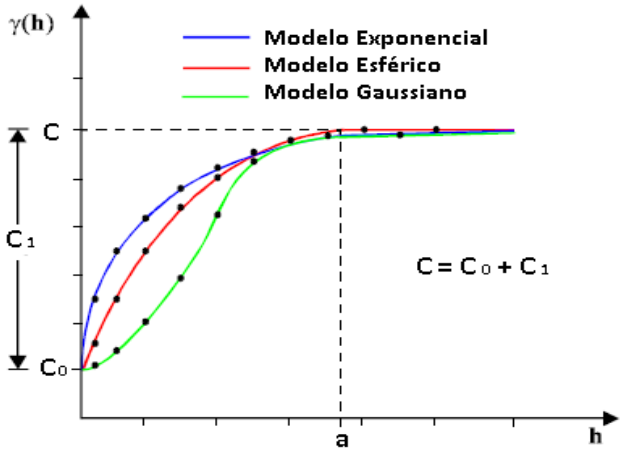

Fonte: Camargo (1998)

Com relação a valores de | **h** | maiores, o modelo gaussiano e o exponencial, teoricamente, atingem o alcance (**a**) quando a variância atinge 95% do patamar (**C**), Figura 9. O modelo exponencial, apesar de apresentar maior crescimento na origem, possibilita uma melhor caracterização do fenômeno para grandes distâncias, retratando maior dependência espacial. Logo, a função exponencial consegue estruturar a continuidade entre amostras mais distantes, beneficiando a inferência em grandes áreas, caracterizadas por poucas amostras irregulares no espaço (CAMARGO, FUCKS E CÂMARA, 2004; LANDIM, 2006; SOARES, 2006).

Modelos teóricos com anisotropia

Quando um fenômeno natural apresenta dependência espacial correlata em todas as direções, diz-se que o modelo é isotrópico, dependente meramente da distância | **h** | entre os pares amostrais. Conforme pode ser analisado na Figura 10.a), os semivariogramas empíricos para quatro orientações (0º, 45º, 90º e 135º) apresentam certa equivalência entre si. Com isso, estas configurações espaciais permitem estabelecer somente um modelo teórico, o qual descreve toda a continuidade espacial do fenômeno. O caso isotrópico em dados espaciais sobre a ótica analítica é menos frequente, entretanto na prática até certas distâncias **h** tais modelos conseguem descrever a estrutura espacial dos dados em todas as direções (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; VIEIRA, 2000; CAMARGO, FUCKS E CÂMARA, 2004; SOARES, 2006).

Por outro lado, a anisotropia, fenômeno representado por uma variabilidade mais regular em uma dada direção, apresenta sentido preferencial sobre a ótica da continuidade espacial. O

fenômeno anisotrópico é mais comum na natureza e pode ser verificado a partir da construção de semivariogramas em múltiplas direções ou através do semivariograma de superfície (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; CAMARGO, 1998; CAMARGO, FUCKS E CÂMARA, 2004).

Neste caso, a modelagem da anisotropia é retratada sobre a percepção de um único modelo, de maneira que os semivariogramas empíricos para a direção de maior e de menor continuidade espacial sejam ajustados e combinados em uma única função. Dessa forma, a estrutura espacial da anisotropia varia conforme a distância e a direção dos vetores **h**, os quais são processados por técnicas da geometria analítica, mais especificamente na translação e/ou rotação dos sistemas de coordenadas (VIEIRA, 2000; CAMARGO, FUCKS E CÂMARA, 2004; SOARES, 2006).

Existem três tipos de anisotropia: a geométrica, a zonal e a combinada. A anisotropia geométrica traduz dois semivariogramas com direções perpendiculares entre si, os quais quando modelados apresentam o mesmo patamar (**C**). Porém, apresentam alcances distintos (**a**), um maior e outro menor, tal relação pode ser configurada por um elipsoide (3D) ou uma elipse - Figura 10.b) - em que o maior eixo e o menor eixo são representados pelo maior e menor alcance, respectivamente. Diferentemente da geométrica, Figura 10.c), a anisotropia zonal apresenta semivariogramas com patamares diferentes para alcances iguais. Esta última é mais difícil de ser encontrada na natureza, sendo o mais comum a combinação entre a anisotropia geométrica e zonal, resultando na anisotropia combinada, Figura 10.d) (CAMARGO, 1998; CAMARGO, FUCKS E CÂMARA, 2004; LANDIM 2006; SOARES, 2006).

Figura 10 - Caracterização gráfica de fenômenos isotrópicos e anisotrópicos

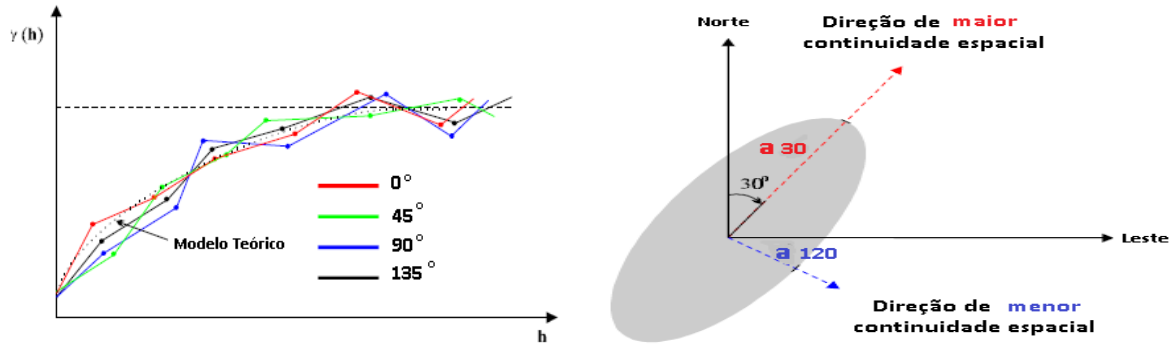

a) Fenômeno isotrópico

b) Anisotropia geométrica

Continuação: Figura 10 - Caracterização gráfica de fenômenos isotrópicos e anisotrópicos

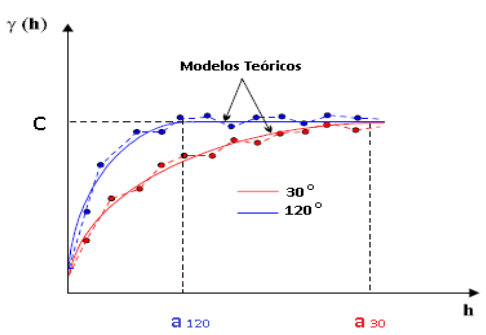

c) Fenômeno com anisotropia geométrica

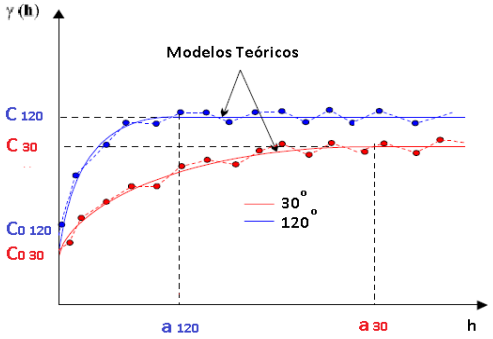

d) Fenômeno com anisotropia combinada

Fonte: a), c) e d) adaptados de Camargo (1998) e b) adaptado de Deutsch e Journel (1992) apud Camargo (1998)

As Figuras 10.b), c) e d) indicam análises em duas direções (30º e 120º), o ângulo que apresenta maior continuidade espacial (30º) é conhecido como o ângulo de anisotropia e a relação entre o ângulo de menor (120º) e de maior (30º) dependência é denominada de fator de anisotropia, sendo este menor que a unidade.

Para a criação de um modelo único que interprete a estrutura espacial anisotrópica, faz-se necessária a criação de semivariogramas empíricos em várias direções, comumente utilizam ângulos múltiplo de 22,5º ou 45º. Encontradas as duas direções que indicam a maior e a menor continuidade, estas são ajustadas segundo os modelos teóricos. Logo em seguida, combinam-se as duas estruturas espaciais ajustadas em um único modelo por meio da divisão da variância em faixas horizontais que variam conforme o vetor **h** (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; CAMARGO, 1998; VIEIRA, 2000).

Segundo Camargo, Fucks e Câmara (2004) e Soares (2006), o ajuste do modelo final deve ser construído de acordo com os alcances ($\mathbf{a_x}$ e $\mathbf{a_y}$) representando um único alcance **a**. Para tanto o vetor **h** deve passar por uma transformação geométrica das coordenadas (Equação 13). Se os eixos de maior e de menor continuidade da elipse não corresponderem aos eixos do sistema de coordenadas, então deve-se realizar uma rotação dos eixos (Equação 14) antes da modificação geométrica.

$$\mathbf{h} = \sqrt{\left(\frac{|\mathbf{hx}|}{\mathbf{ax}}\right)^2 \left(\frac{|\mathbf{hy}|}{\mathbf{ay}}\right)^2} \tag{13}$$

$$\begin{pmatrix} \boldsymbol{hx\alpha} \\ \boldsymbol{hy\alpha} \end{pmatrix} = \begin{bmatrix} \cos \boldsymbol{\alpha} & -\sin \boldsymbol{\alpha} \\ \sin \boldsymbol{\alpha} & \cos \boldsymbol{\alpha} \end{bmatrix} \begin{pmatrix} |\boldsymbol{hx}| \\ |\boldsymbol{hy}| \end{pmatrix} \tag{14}$$

Em que:

$\mathbf{h_x}$, $\mathbf{h_y}$: vetores - distância e orientação - representados pelos eixos de maior e de menor continuidade espacial, x e y podem também significar Norte e Leste, respectivamente;

$\mathbf{a_x}$, $\mathbf{a_y}$: alcances na direção de maior e de menor dependência espacial;

$\boldsymbol{\alpha}$: ângulo em relação a x (Norte);

$\mathbf{h_x}\,\boldsymbol{\alpha}$, $\mathbf{h_y}\,\boldsymbol{\alpha}$: vetores que sofreram rotação.

2.5.2 Krigagem Ordinária

A Krigagem ou Krigeagem foi formulada por Matheron (1963), o nome escolhido foi uma homenagem à Krige e é conhecida pela monograma B.L.U.E., *the Best Linear Unbiased Estimatior* ou o "melhor estimador linear sem viés" (ISAAKS E SRIVASTAVA, 1989). Apesar do termo usado, Soares (2006) alerta que condicionantes da estrutura espacial das amostras em um determinado domínio podem produzir resultados de estimação medianos ou até ruins. Por este motivo, a inferência necessita de um procedimento de calibração e de validação dos modelos variográficos a partir das amostras obtidas em campo, assegurando o objetivo de modelar a realidade da estrutura espacial do fenômeno.

"O melhor estimador linear sem viés" significa que a Krigagem é um estimador linear (Equação 15), pois utiliza técnicas de regressão linear, combinando pesos oriundos de amostras conhecidas para estimar valores em locais não amostrados. Tal aplicação é comum entre os interpoladores, porém a Krigagem se diferencia das demais por mesclar os pesos conforme uma estrutura espacial, o semivariograma. Além disso, caracteriza-se por ser um interpolador sem viés (não-enviesado), uma vez que no processo de cálculo, a média dos resíduos ou o valor esperado do erro deve ser zero (Equação 16). Por fim, é o melhor estimador, pois minimiza a variância do erro (Equação 17) (VIEIRA *et al*., 1983; VIRDEE E KOTTEGODA, 1984; ISAAKS E SRIVASTAVA, 1989; FELGUEIRAS, 2001; SOARES, 2006).

$$\mathbf{Z(x_0)}^* = \sum_{\alpha=1}^{N} \boldsymbol{\lambda_\alpha}.\,\mathbf{Z(x_\alpha)} \qquad (15)$$

Onde:

$\mathbf{Z(x_0)}^*$: valor estimado, ponto não amostrado, localizado em x_0;

$\mathbf{Z(x\alpha)}$: amostras conhecidas, localizadas em $x\alpha = 1, ..., N$, em que N é a quantidade de eventos;

$\boldsymbol{\lambda\alpha}$: ponderadores da combinação linear.

$$\mathbf{E}[\boldsymbol{\varepsilon}(\mathbf{x_0})] = \mathbf{E}[\mathbf{Z}(\mathbf{x_0})^* - \mathbf{Z}(\mathbf{x_0})] = \mathbf{0} \tag{16}$$

Em que:

Z(x₀): valor desconhecido, dito "real".

$\boldsymbol{\varepsilon}(\mathbf{x_0})$: erro ou desvio entre o valor estimado e o valor desconhecido "real".

$$\boldsymbol{\sigma^2\varepsilon} = \mathbf{var}[\boldsymbol{\varepsilon}(\mathbf{x_0})] = \mathbf{var}[\mathbf{Z}(\mathbf{x_0})^* - \mathbf{Z}(\mathbf{x_0})] = \mathbf{E}\left\{\left[\sum_{\alpha=1}^{N} \boldsymbol{\lambda_\alpha}.\mathbf{Z}(\mathbf{x_\alpha}) - \mathbf{Z}(\mathbf{x_0})\right]^2\right\} \tag{17}$$

A qualidade da inferência estabelecida pela Equação 16 fornece que a média (**m**) entre o valor desconhecido "real" e o valor estimado são iguais ou ainda segundo a estacionariedade do primeiro momento, em que a média é constante em todo o domínio.Pois, as amostras e os valores estimados provêm da mesma distribuição de probabilidade. A relação entre a Equação 15 e 16, gera a seguinte expressão:

$$\mathbf{E}[\mathbf{Z}(\mathbf{x_0})] = \mathbf{E}\left[\sum_{\alpha=1}^{N} \boldsymbol{\lambda_\alpha}.\mathbf{Z}(\mathbf{x_\alpha})\right] \therefore \boldsymbol{m} = \sum_{\alpha=1}^{N} \boldsymbol{\lambda_\alpha}.\mathbf{m} \tag{18}$$

Para que a igualdade da Equação 18 seja satisfeita, a soma dos pesos deve ser igual a unidade. Logo, $\sum_{\alpha=1}^{N} \boldsymbol{\lambda_\alpha} = \mathbf{1}$. Os ponderadores devem traduzir para uma estimação ideal os seguintes fatores: a "proximidade" entre as amostras, entende-se que o termo próximo não estabelece a ideia de distância, mas sim de um parâmetro estatístico, a covariância espacial; redundância entre as amostras, os pesos devem desagrupar (desclusterizar) agrupamentos preferenciais (*clusters*), visto que tal ocorrência nas amostras pode promover tendências na estimação; a anisotropia do fenômeno; e a magnitude das amostras (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; FELGUEIRAS, 2001; SOARES, 2006).

Destrinchando a Equação 17 segundo a aplicação dos produtos notáveis, substituindo os termos **Z(x₀)** * conforme a Equação 15 e introduzindo relações matemáticas da variância dos dados, da esperança e da covariância. Além da imposição de estacionariedade, obtém-se a Equação 19, a variância do erro do estimado. Tal equação traduz a incerteza da predição em cada ponto estimado, possibilitando a distribuição espacial do erro e, com isso, a confiança do modelo inferido (ISAAKS E SRIVASTAVA, 1989; FELGUEIRAS, 2001; CAMARGO, FUCKS E CÂMARA, 2004; SOARES, 2006).

$$\mathbf{var}[\boldsymbol{\varepsilon}(\mathbf{x_0})] = \mathbf{C}(\mathbf{0}) + \sum_{\alpha}\sum_{\beta} \boldsymbol{\lambda_\alpha}.\boldsymbol{\lambda_\beta}.\mathbf{C}(\mathbf{x_\alpha},\mathbf{x_\beta}) - \mathbf{2}.\sum_{\alpha} \boldsymbol{\lambda_\alpha}.\mathbf{C}(\mathbf{x_\alpha},\mathbf{x_0}) \tag{19}$$

Em que:

C (0): variância a priori dos dados;

$\mathbf{C}(\mathbf{x}_{\alpha},\mathbf{x}_{\beta})$: covariância entre as amostras, obtida através do correlograma (ou semivariograma);

$\mathbf{C}(\mathbf{x}_{\alpha},\mathbf{x}_{\mathbf{0}})$: covariância entre as amostras e o ponto a ser estimado, obtida através do correlograma (ou semivariograma);

$\boldsymbol{\lambda}_{\alpha}.\boldsymbol{\lambda}_{\beta}$: ponderadores (pesos), **N** incógnitas a serem determinadas.

Deseja-se que a variância do erro seja mínima, para tanto a equação acima deve ser igualada a zero para as **N** derivadas parciais em relação as **N** incógnitas (ponderadores) $\boldsymbol{\lambda}_{\boldsymbol{\alpha}}$. Porém, para minimização da Equação 19, a condição $\sum_{\alpha=1}^{N}\boldsymbol{\lambda}_{\alpha}=\mathbf{1}$ deve ser introduzida no sistema, resultando em **N**+1 equações. Com isso, existem mais equações que incógnitas, resultando em infinitas soluções. Contornando este problema matemático, acrescenta-se uma variável artificial lagrangeana, o parâmetro de Lagrange $\boldsymbol{\mu}$. Como consequência, o sistema é resolvido derivando as **N**+1 equações em relação aos **N** pesos e $\boldsymbol{\mu}$. Resultando na obtenção dos pesos das amostras que minimizam o erro da estimativa de $\mathbf{x_0}$ (VIEIRA *et al*., 1983; ISAAKS E SRIVASTAVA, 1989; CAMARGO, 1998; VIEIRA, 2000; LANDIM, 2006; SOARES, 2006).

Tem-se, então, o sistema de Krigagem:

$$\begin{cases}\sum_{\beta}\boldsymbol{\lambda}_{\beta}.\mathbf{C}(\mathbf{x}_{\alpha},\mathbf{x}_{\beta})-\boldsymbol{\mu}=\mathbf{C}(\mathbf{x}_{\alpha},\mathbf{x}_{0}),\boldsymbol{\alpha}=\mathbf{1},\ldots,\mathbf{N}\\ \sum_{\alpha}\boldsymbol{\lambda}_{\alpha}=\mathbf{1}\end{cases}\text{ ou }[\mathbf{K}].[\boldsymbol{\lambda}]=[\mathbf{M}] \qquad (20)$$

Onde:

[K] e **[M]** representam as matrizes de covariância entre as amostras e de covariância entre a amostra e o ponto a ser estimado, respectivamente.

$$[\mathbf{K}]=\begin{pmatrix}\mathbf{C}(\mathbf{x_1},\mathbf{x_1}) & \mathbf{C}(\mathbf{x_1}\mathbf{x_2}) & \ldots & \mathbf{C}(\mathbf{x_1},\mathbf{x_N}) & \mathbf{1}\\ \mathbf{C}(\mathbf{x_2},\mathbf{x_1}) & \mathbf{C}(\mathbf{x_2},\mathbf{x_2}) & \ldots & \mathbf{C}(\mathbf{x_2},\mathbf{x_N}) & \mathbf{1}\\ \vdots & \vdots & \vdots & \vdots & \vdots\\ \mathbf{C}(\mathbf{x_N},\mathbf{x_1}) & \mathbf{C}(\mathbf{x_N},\mathbf{x_2}) & \cdots & \mathbf{C}(\mathbf{x_N},\mathbf{x_N)} & \mathbf{1}\\ \mathbf{1} & \mathbf{1} & \cdots & \mathbf{1} & \mathbf{0}\end{pmatrix}$$

$$[\boldsymbol{\lambda}] = \begin{pmatrix} \lambda_1 \\ \lambda_2 \\ \vdots \\ \lambda_N \\ 1 \end{pmatrix} \quad [\mathbf{M}] = \begin{pmatrix} C(x_1,x_0) \\ C(x_2,x_0) \\ \vdots \\ C(x_N,x_0) \\ 1 \end{pmatrix}$$

Isolando a matriz dos pesos por meio da inversa da matriz de **[K]**, obtém-se:$[\boldsymbol{\lambda}] = [\mathbf{K}]^{-1}.[\mathbf{M}]$.

Ressalta-se que embora as equações tenham sido demonstradas através da covariância **(C)**, pela Equação 8 (relação entre o correlograma e o semivariograma), o variograma também representa as expressões descritas nesta seção.

Os fatores descritos sobre o comportamento dos pesos na estrutura espacial do fenômeno são representados matematicamente pelas matrizes **[K]** e **[M]**. Segundo Soares (2006), a matriz **[K]** desclusteriza agrupamentos preferencias, pois, quanto maior for a correlação entre as amostras, ou seja, a redundância entre os pares, menor será o valor do ponderador, evitando a superestimação ou subestimação de valores não conhecidos por causa de grupos amostrais similares. Com relação a matriz **[M]**, esta produz ponderadores maiores para amostras mais "próximas" estaticamente, além disso descreve a anisotropia e a magnitude da continuidade espacial.

Por fim, a variância da Krigagem (Equação 21), medida de incerteza, é resultado da substituição do sistema da Equação 20 na Equação 19 de variância da estimação.

$$\sigma_E^2(x_0) = C(0) - \sum_\alpha \lambda_\alpha C(x_\alpha x_0) - \mu \tag{21}$$

3 METODOLOGIA

A metodologia foi dividida em três itens: a descrição da Bacia Hidrográfica do Rio Una, contextualizando a localização, a hidrografia, o clima, a precipitação e outros aspectos apresentados no AXENO A; os dados geográficos e hidrológicos (MDT, ortofotos, profundidades de inundação e estação fluviométrica) utilizados para o desenvolvimento desta pesquisa; as metodologias aplicadas – modelo HAND, *flow frequency* HAND, análise de tendências de séries hidrológicas, estimativas de probabilidade de recorrência, o processo da Geoestatística e métricas de comparação entre mapas.

3.1 CARACTERIZAÇÃO DA BACIA HIDROGRÁFICA DO RIO UNA

Descrever os aspectos físicos da Bacia Hidrográfica do rio Una, onde estão localizadas as cidades de Palmares e de Jaqueira, torna-se fundamental para o entendimento do problema a ser investigado, principalmente devido à complexidade existente na progressão das inundações nas cidades atingidas, apesar deste trabalho ter sido elaborado em tais cidades sob perspectivas e dados locais.

3.1.1 Localização

O desenvolvimento deste trabalho foi realizado em dois aglomerados urbanos (sedes municipais) de Jaqueira e de Palmares (Figura 11), as quais estão inseridas na Bacia Hidrográfica do Rio Una (BHRU) ou Unidade de Planejamento Hídrico 05 (UP05). A BHRU se encontra a oeste do Oceano Atlântico e ao norte do estado de Alagoas. Em Pernambuco, abrange duas mesorregiões, o Agreste Pernambucano e a Mata Pernambucana (CONDEPE/FIDEM, 2006). A BHRU está inserida em Alagoas e Pernambuco, localizada entre as latitudes 8º’17’14’’S e 8º55’28’’S e as longitudes 35º07’48’’O e 36º42’10’’O. Sua extensão territorial total é de aproximadamente 6.740 km², deste total, a bacia apresenta cerca de 6.262 km² em território pernambucano (APAC, 2020).

Figura 11 - Mapa de localização da área de estudo

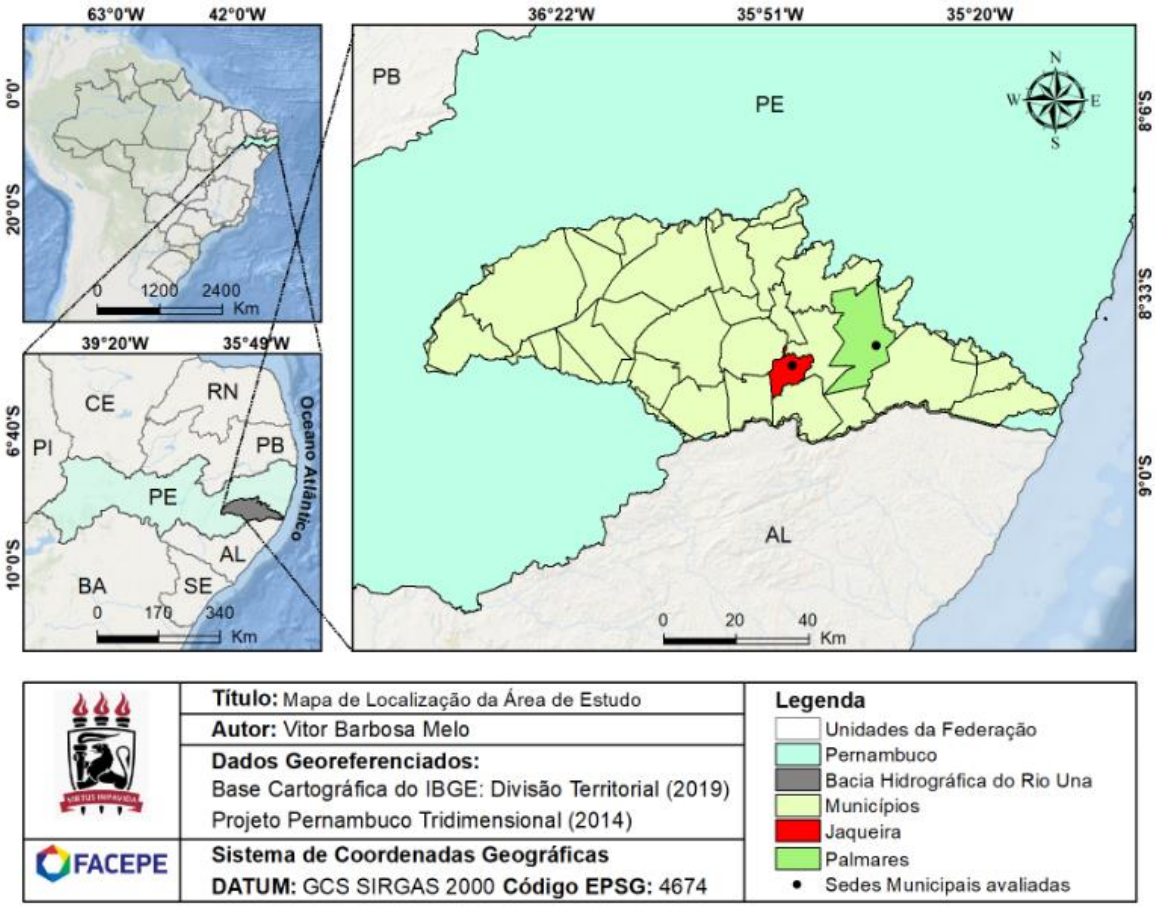

Fonte: Autor (2021)

3.1.2 Hidrografia

As cidades analisadas possuem certa similaridade devido à presença assentamentos urbanos próximos aos rios que fluem nas margens destas cidades, o rio Pirangi na cidade de Jaqueira e o rio Una na cidade de Palmares. O rio Una, Figura 12, é um dos principais rios do estado de Pernambuco, sua cabeceira está localizada na Serra da Boa Vista, no município de capoeiras a cerca de 900 m de altitude. Sua extensão é de aproximadamente 290 km até desemborcar no Oceano Atlântico, no município de São Jose da Cora Grande. Pela margem da direita, o rio Pirangi nasce no município de Quipapá com altitude em torno de 600 m, percorrendo cerca de 80 km até desaguar no rio Una, próximo à cidade de Palmares (CONDEPE/FIDEM, 2006; APAC, 2020).

Outros importantes afluentes do rio Una pela margem da direita são o riacho Salobro, o riacho Salgadinho, o rio da Chata e o Rio Jacuípe, este último fazendo divisa com o estado de Alagoas. Na margem esquerda destacam-se o rio Mentiroso, o rio Camevô e o riacho Gravatá.

Figura 12 - Mapa da hidrografia da Bacia Hidrográfica do Rio Una

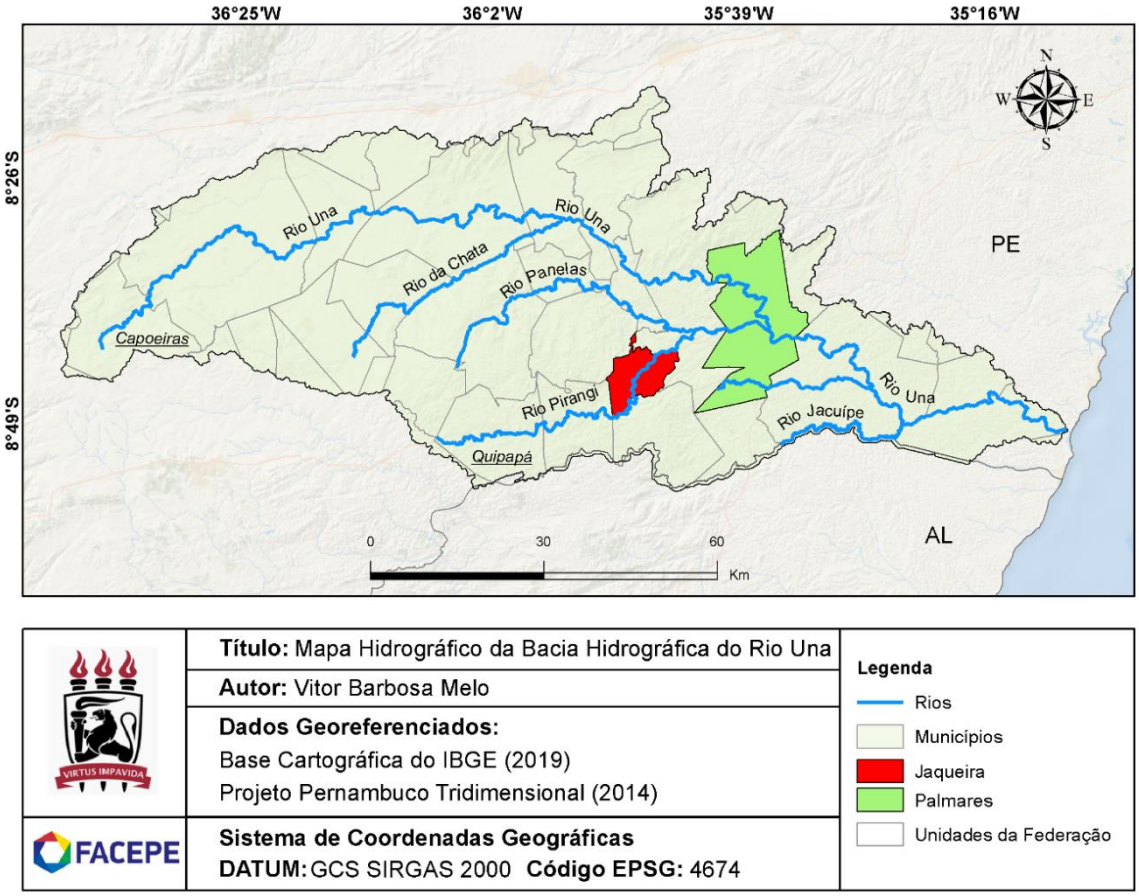

Fonte: Autor (2021)

3.1.3 Clima e precipitação

A BHRU está situada na zona climática tropical nordeste oriental, a qual é caracterizada por ventos alísios de sudeste e de leste, do anticiclone do Atlântico Sul que agem com maior regularidade nos períodos de baixa pluviometria (primavera e verão). Na estação chuvosa atuam sistemas instáveis, chuvas frontais e atuação de fenômenos naturais como o La Niña. Além disso, as ondas de leste, que representam relevância na geração das grandes inundações na bacia, como no evento extremo que ocorreu junho de 2010. A temperatura média na região varia de 24 a 26^{o}C. Em junho e julho, a temperatura diverge em torno de 20 a 24^{o}C, em altitudes elevadas como no Planalto da Borborema, registra-se temperaturas menores que 18^{o}C (IBGE, 1998; CONDEPE/FIDEM, 2006; CIRILO, 2011; MACHADO, 2012).

Com relação às unidades climáticas (Figura 13), a BHRU apresenta seis classificações distintas do litoral ao interior do continente. Mais a leste, na mesorregião da Mata Pernambucana, as unidades variam de superúmido (sem seca ou sub seca) e quente (temperatura média maior que 18^{o}C em todos os meses), passando por porções úmidas (1 a 2 meses secos ou

3 meses secos) e quente. Mais ao centro da bacia, o Agreste e a parte da Mata Pernambucana, a porção climática com maior extensão territorial na bacia é semiúmida (4 a 5 meses secos) e quente. Finalmente, o território situado na nascente do rio Una apresenta clima semiúmido (4 a 5 meses secos) e subquente (temperatura média entre 15 e 18ºC).

A pluviometria média anual da bacia, indicada na Figura 14, varia em torno de 500 a 2.200 mm. Na Mata Pernambucana, a precipitação varia de 1.200 a 2.200 mm com período chuvoso ocorrendo de março a julho/agosto. No Agreste, a região mais próxima à Mata Pernambucana possui pluviometria média anual entre 800 a 1.200 mm. Na porção leste, região mais próxima do Sertão Pernambucano, a pluviosidade alterna entre 400 a 800 mm com chuvas menos concentradas que no Sertão.

Figura 13 - Mapa das unidades climáticas da Bacia Hidrográfica do Rio Una

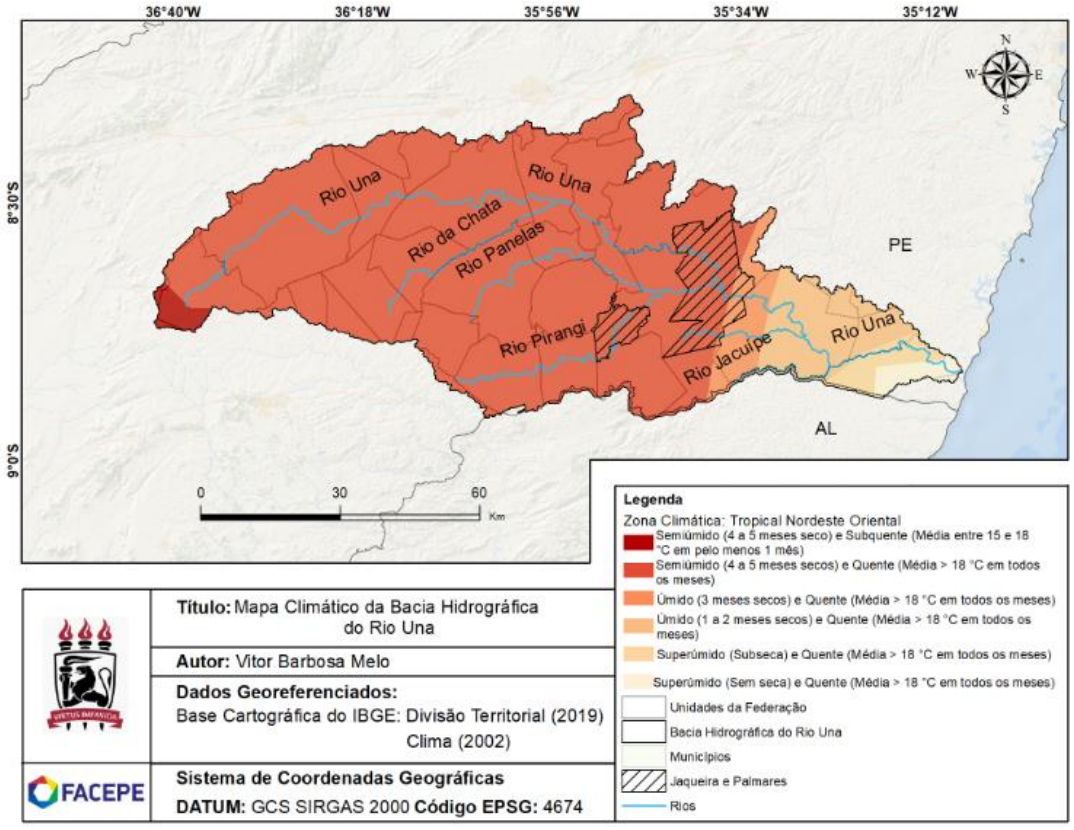

Fonte: Autor (2021)

Figura 14 - Mapa da precipitação média anual da Bacia Hidrográfica do Rio Una

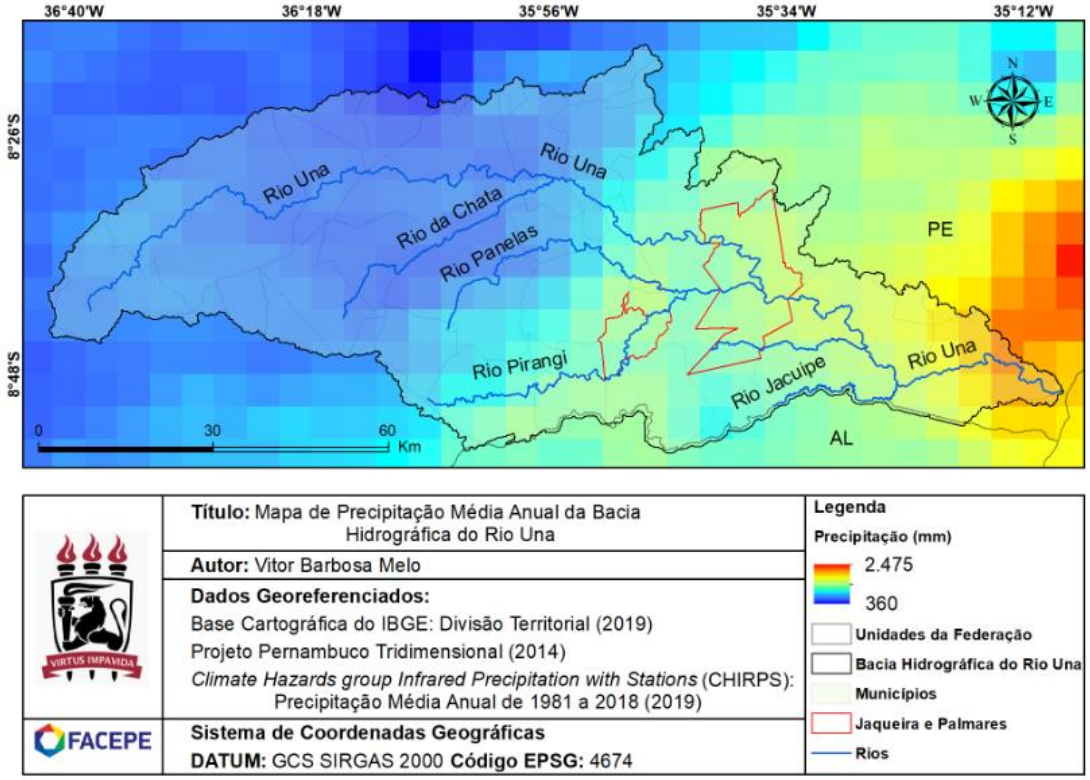

Fonte: Autor (2021)

3.1.4 Outros aspectos da bacia

A vegetação, a geologia, a pedologia e o uso e ocupação do solo podem ser visualizados no **ANEXO A**. Resumidamente, evidencia-se algumas particularidades que aumentam os picos de escoamento superficial, auxiliando na formação das inundações da BHRU: desmatamento para uso da agropecuária; baixa capacidade de infiltração (hidrogeologia e pedologia); baixa permeabilidade de solos com maior extensão territorial; amplitude altimétrica (mais de 1000 m); altas declividades que aumentam a energia cinética produzindo ondas mais rápidas.

3.2 DADOS GEOGRÁFICOS E HIDROLÓGICOS

Neste trabalho, todos os dados manipulados foram cuidadosamente analisados sobre a perspectiva espacial, inclusive para a estação fluviométrica. Os dados e informações provieram do Projeto Pernambuco Tridimensional (PE3D), do trabalho de Ribeiro *et al* (2020) operando o aplicativo Hidromapp (OLIVEIRA et al, 2018, 2019), de levantamento realizado pelo Corpo de Bombeiros, do Portal HidroWeb integrante do Sistema Nacional de Informações sobre

Recursos Hídricos (SNIRH) gerida pela Agência Nacional das Águas (ANA), de visita em campo no município de Palmares e do Serviço Geológico do Brasil (CPRM).

3.2.1 Modelo Digital do Terreno e Ortofoto

O Modelo Digital do Terreno (MDT) e a Ortofoto com resolução espacial de 1 m e 50 cm, na devida ordem, dos municípios avaliados foram coletados através do Projeto Pernambuco Tridimensional (www.pe3d.pe.gov.br/). O projeto PE3D foi desenvolvido em 2014 pelo Governo de Pernambuco por meio da antiga Secretaria de Recursos Hídricos e Energéticos (SRHE), o programa procedeu-se posteriormente a ocorrência de desastres hidrológicos que atingiram duramente cidades pernambucanas entre os anos de 2010 e 2011 (CIRILO *et al*., 2014; CIRILO *et al*., 2015; PERNAMBUCO, 2016).

O projeto promoveu o mapeamento de toda extensão territorial pernambucana a partir da aerofotogrametria, gerando ortoimagens na escala 1:1000 e 1:5000 com *Ground Sample Distance* de 12 e 50 cm, respectivamente. Além do levantamento a laser alicerçado pela tecnologia LIDAR, o qual concebeu modelos digitais de elevação, como o MDT, na escala de 1:1000 e 1:5000 apresentando imprecisão altimétrica menor que 10 e 25 cm, nesta ordem (CIRILO *et al*., 2014; CIRILO *et al*., 2015; PE3D, 2020).

Certamente o estado pernambucano, após as inundações, percebeu a necessidade de possuir em seu domínio uma base cartográfica confiável de alta resolução espacial, pretendendo melhorar a performance sobre a gestão territorial e a tomada de decisão, frente a escassez de dados e a fenômenos naturais e antrópicos impactantes.

Os produtos gerados têm promovido expressivos ganhos no desenvolvimento de projetos de engenharia na área de saneamento básico e de contenção de cheias através de barragens, de suporte para a transferência de populações atingidas (CIRILO *et al*., 2014; CIRILO *et al*., 2015), avaliações ambientais no reconhecimento e investigação da qualidade ambiental de nascentes (LEITE, 2019), aplicação em modelos matemáticos para diversos usos na área de recursos hídricos (ALVES, 2017; VERÇOSA, 2019; RIBEIRO *et al*., 2020), dentre outras ações.

3.2.2 Profundidades de inundação

No município de Palmares, o evento avaliado ocorreu em junho de 2010 e, a amostragem das profundidades de inundação em relação a superfície (Figura 15) foi executada por um grupo

de trabalho do Corpo de Bombeiros após o desastre. A equipe operando um GPS de navegação coletou 200 pontos segundo as marcas da cheia. Ademais, as amostras foram corrigidas em ambiente SIG através de ortoimagens adquiridas pelo Instituto de Tecnologia para o Desenvolvimento (LACTEC) (LACTEC, 2011; DANTAS, 2012).

Para o município de Jaqueira, o fenômeno estudado transcorreu em maio de 2017. O levantamento das profundidades de inundação (Figura 16) foi efetuado por Ribeiro (2019). A autora, em campo, utilizando um *smartphone*, obteve 130 amostras georreferenciadas e por meio de entrevistas com a população atingida levantou as profundidades para cada amostra. O processo de coleta de dados foi gerenciado mediante o aplicativo Hidromapp (RIBEIRO *et al*., 2020).

O *software* Hidromapp (www.hidromapp.com.br/) permite a obtenção de informações geográficas colaborativas acerca de tragédias hidrológicas de maneira pontual. O download gratuito do aplicativo pode ser realizado no serviço da Google Play para sistemas operacionais Android (OLIVEIRA, 2017; OLIVEIRA, BRITO E SANTOS, 2018; HIDROMAPP, 2020).

O fornecimento de dados colaborativos funciona através da inserção da localidade atingida (ou não) pelo usuário, o aplicativo solicita registros relevantes sobre o evento, dentre eles: a data do fenômeno; a profundidade da água em relação ao terreno; uma fotografia indicando a profundidade para posterior validação; os danos humanos e materiais e; se existe a presença de pessoas com dificuldades de locomoção no ponto levantado. O georreferenciamento das amostras é realizado por serviços de geocodificação e do próprio GPS acoplado nos dispositivos móveis. Há também o uso do *Street View* do Google Maps, possibilitando a visualização de imagens da região informada pelo usuário (OLIVEIRA, 2017; OLIVEIRA, BRITO E SANTOS, 2018; HIDROMAPP, 2020).

O aplicativo possui importante papel frente à falta de dados hidrológicos distribuídos no espaço. A plataforma permite aplicações baseadas em inteligência geográfica. Pois, promove melhorias nos processos de tomada de decisão por entidades públicas e privadas, visando a minimização dos impactos oriundos das inundações. Além disso, tais levantamentos propiciam ganhos nas etapas de calibração e de validação dos modelos hidrológicos e hidrodinâmicos, progresso de sistemas de previsão e alerta, geração de mapas de riscos e de vulnerabilidade, criação de manchas de inundação por meio de interpoladores empíricos e probabilístico, sendo este último um dos objetivos deste trabalho.

Figura 15 - Mapa das profundidades de inundação no município de Palmares em 2010

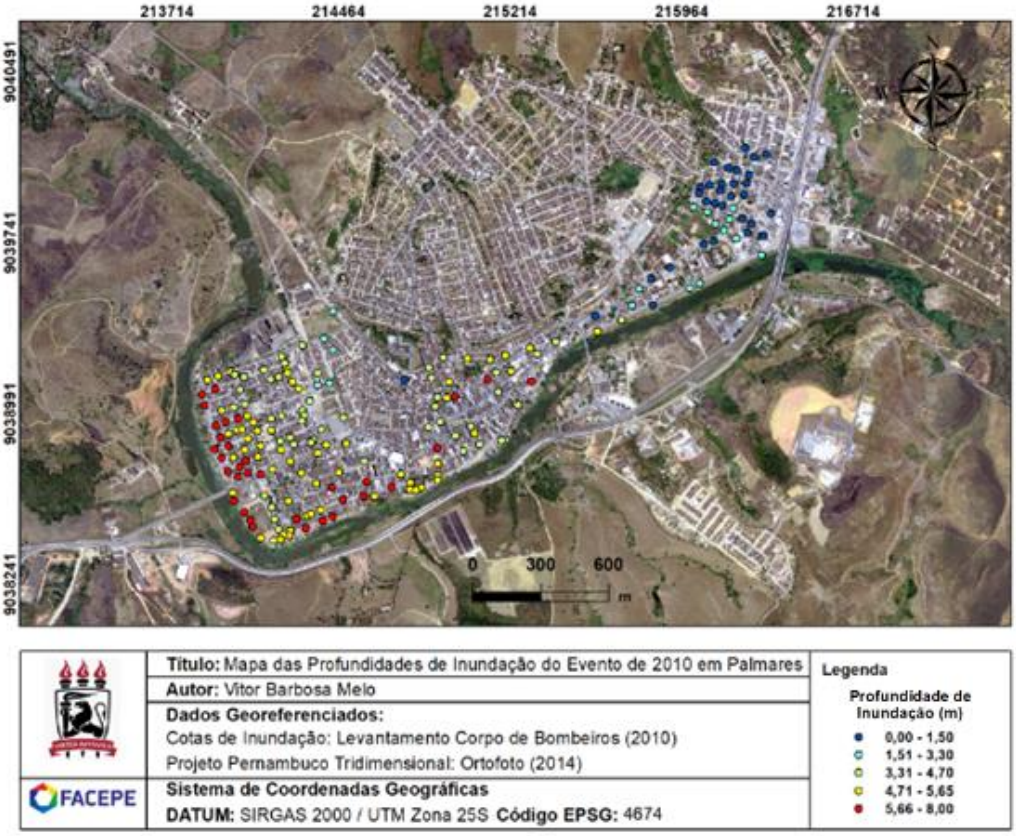

Fonte: Autor (2021)

Figura 16 - Mapa das profundidades de inundação no município de Jaqueira em 2017

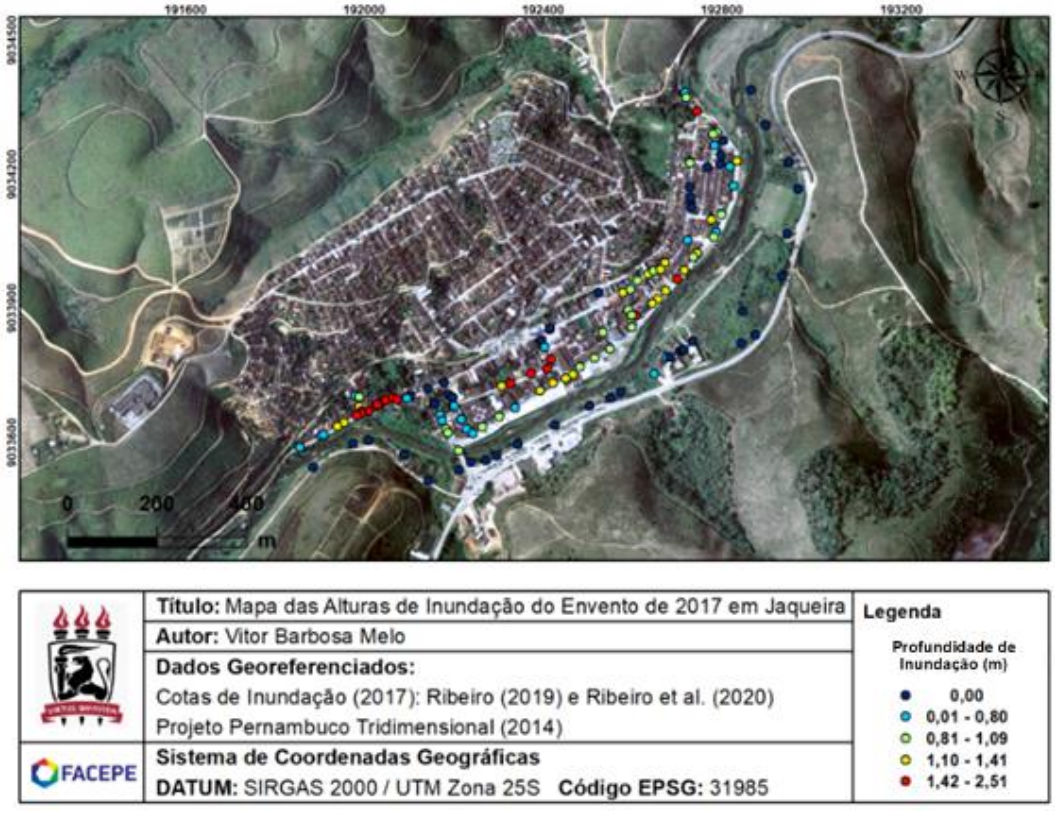

Fonte: Autor (2021)

3.2.3 Estação fluviométrica

A estação fluviométrica, localizada no município de Palmares[*] - Figura 17 -, utilizada neste trabalho para combinação do modelo HAND com análise de probabilidade de níveis extremos, foi identificada através do Portal HidroWeb da Agência Nacional das Águas (www.snirh.gov.br/hidroweb/).

Atualmente, a estação Palmares é operada pelo Serviço Geológico do Brasil (CPRM), tendo início de coleta dos dados fluviométricos a partir de março de 1967. A estação apresenta 53 anos de dados observados e, com isso, não há restrições para o cálculo de diferentes tempos de retorno (2, 5, 10, 25 e 100 anos). Visto que, segundo a Naguettini e Pinto (2007) a inferência de um dado período de retorno, necessariamente, precisa que o valor a ser calculado apresente no mínimo duas vezes o tamanho da série temporal.

Outro pré-requisito para a estação antes da aplicação do processo metodológico, concerne no conhecimento a priori da localização geográfica da estação fluviométrica. De preferência, o mais próximo de sua posição real, a qual pode ser alcançada através da aquisição de um ponto GPS ou dos registros das instituições que operam a estação. Conforme Pérez-Mesa (2014), Speckhann *et al*. (2018a) e Speckhann (2018b), esta etapa é essencial e caso seja desprezada, a estimação apresentará resultados incoerentes de subestimação ou superestimação, provocando erros na extensão do evento modelado.

Inicialmente, verificou-se a posição espacial da estação através das coordenadas informadas pela ANA. Porém, ao confrontar com a ortofoto de Palmares, as coordenadas da estação indicavam uma localização externa ao rio. Com isso, foi necessário levantar informações em campo e analisar registros históricos e fotográficos (com atributos de coordenadas), fichas descritivas, fichas de nivelamento geométrico e croquis de localização. Os documentos foram obtidos por meio do banco de dados do SNIRH (http://www.snirh.gov.br/fichadecampo/restrito/principal.jsf) e de técnicos da CPRM., que também colaboraram com esclarecimentos acerca da localização da estação fluviométrica ao longo do tempo.

De posse destes materiais, percebeu-se que ao longo do tempo, a estação fluviométrica Palmares sofreu mudanças em sua localização (Figura 17). A princípio, as réguas linimétricas

[*] Para a combinação do modelo HAND com a distribuição de probabilidades dos eventos máximos anuais, faz-se necessário que a estação fluviométrica esteja dentro da área analisada e que possua tempo de observação de pelo menos 25 anos. Estes dois critérios não foram atendidos para a estação mais próxima da área avaliada do município de Jaqueira e, por isto, somente para Palmares foi aplicado esta metodologia.

se localizavam dentro da região tracejada em amarelo de 1967 a 2010*. Durante a inundação de 2010, evento avaliado neste trabalho, o escoamento de alta turbulência promoveu a destruição das réguas linimétricas e da antiga ponte da BR-101. Logo, a estação foi alocada para o ponto em vermelho de 2011 até 2013, Figura 18. Já em 2014, a estação Palmares foi transferida para o ponto em azul, região onde está posicionada atualmente, Figura 19.

Como não se sabe a posição da estação no período inicial (1967 a 2010) e visando a diminuição da incerteza no processo de modelagem, optou-se por realizar uma análise exploratória sobre os *pixels* do modelo HAND na área em amarelo tracejado (Figura 17). Dessa forma, definir um valor que apresente maior frequência (média), diminuindo a chance do erro. Em relação às outras duas localizações, ponto vermelho e azul da Figura 17, as altimetrias HAND foram extraídas e comparadas com a do período maior.

Nesta etapa, foi definido se as cotas máximas anuais para os dois períodos pós-cheia de 2010 seriam corrigidas antes da análise de frequência de nível da série temporal. A decisão foi baseada na diferença entre os valores HAND dos três períodos, tendo o período inicial como referência por ser o mais longo dos três. Dessa forma, calculou-se a diferença altimétrica entre as alturas HAND dos períodos pós-cheia com o período de referência. Caso a diferença seja expressiva, utiliza-a para normalizar as cotas fluviométricas em relação ao período inicial (referência). Caso contrário, a série temporal não precisa ser corrigida.

Figura 17 - Mapa de localização da estação fluviométrica Palmares

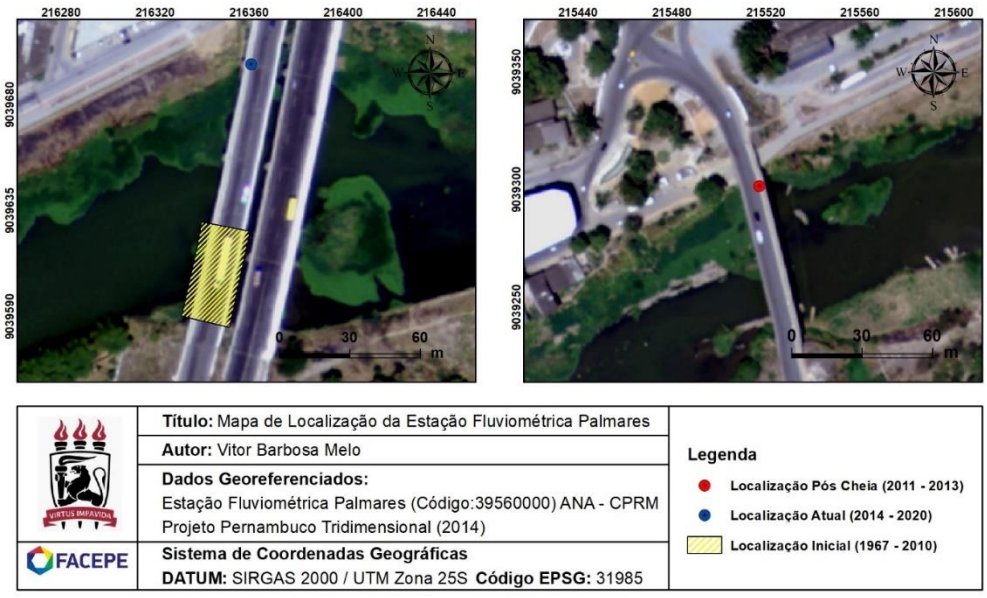

Fonte: Autor (2021)

* Ressalta-se que a coordenada geográfica documentada não permite indicação exata das réguas linimétricas, porém existem indícios através das informações levantadas que a estação se encontrava na margem direta do rio Una presas nos pilares da antiga ponte da BR-101.

Figura 18 - Régua linimétrica da estação fluviométrica de Palmares, localização pós-cheia (2011 a 2014)

Fonte: CPRM (2011)

Figura 19 - Régua Linimétrica da Estação Fluviométrica de Palmares, Localização Atual

Fonte: Autor (2021)

3.3 MÉTODOS

A seguir, foram explicadas as técnicas de geoprocessamento para obtenção do modelo HAND, os aspectos positivos e as limitações na aplicação deste dado para estudos de inundações; a combinação do algoritmo HAND com a série de cotas máximas anuais e as incertezas técnicas para este procedimento; análises de tendências e as estimativas de probabilidade de recorrência nas séries de dados fluviométricos; o procedimento Geoestatístico

e os pressupostos a serem respeitados para a correta prática da metodologia; por fim, as métricas de desempenho entre o modelo HAND e a Geoestatística.

3.3.1 Modelo HAND

Como visto na seção 2.4, o modelo HAND é um descritor de terreno representado por uma superfície altimétrica referenciada ao canal de drenagem mais próximo, após a normalização da elevação do Modelo Digital do Terreno (RENNÓ *et al*., 2008; NOBRE, A. *et al*., 2011). Segundo Nobre *et al*. (2015), esta normalização promove uma transformação do fluxo longitudinal ao rio no sentido do mar, característico do MDT, para fluxos laterais direcionados, condicionada pela topografia do modelo que direciona os fluxos para a nova referência, os rios, tornando-os uniformes e fixados em zero.

Sobre a perspectiva do HAND na construção de mapas de inundação, deve-se entender que o modelo tem como única condição o equilíbrio de pressão hidrostática lateral, resultando em uma superfície virtual plana e horizontal. Tal circunstância estabelece que para uma dada altura HAND inundada, as células com altimetria menor a ela também serão consideradas inundadas. Logo, o modelo HAND produz manchas de inundação estáticas vinculadas a um fenômeno passado, a uma probabilidade de ocorrência, além de fornecer a profundidade da água para a extensão simulada (NOBRE *et al*., 2015; SPECKHANN *et al*., 2018a).

Deve-se entender que o descritor mapeia o evento de modo estático, tendo como interesse a extensão máxima vinculada a um determinado fenômeno no passado ou a uma probabilidade de ocorrência extraída de análises de frequência sobre séries temporais de cotas (vazões). Além disso, pode ainda fornecer a profundidade da extensão máxima da inundação (PÉREZ-MESA, 2014; NOBRE *et al*. 2015; SPECKHANN *et al*., 2018a).

A aplicação da metodologia HAND foi desenvolvida a partir de Rennó *et al*. (2008) e Nobre, A. *et al*. (2011). Informações gerais sobre o projeto podem ser obtidas através do link http://handmodel.ccst.inpe.br/. A obtenção do modelo está centrada na execução de técnicas de geoprocessamento sobre o MDT segundo aspectos matemáticos e hidrológicos. O HAND é consolidado através de duas etapas, a primeira estabelece correções sobre o MDT, corrigindo incoerências dos *pixels* na matriz topográfica, determinando as direções de escoamento e delimitando o canal de drenagem (Figura 20). Na segunda etapa, as alturas HAND são calculadas por meio do processamento dos produtos obtidos na primeira etapa (Figura 21).

Figura 20 - Primeira etapa metodológica do modelo HAND

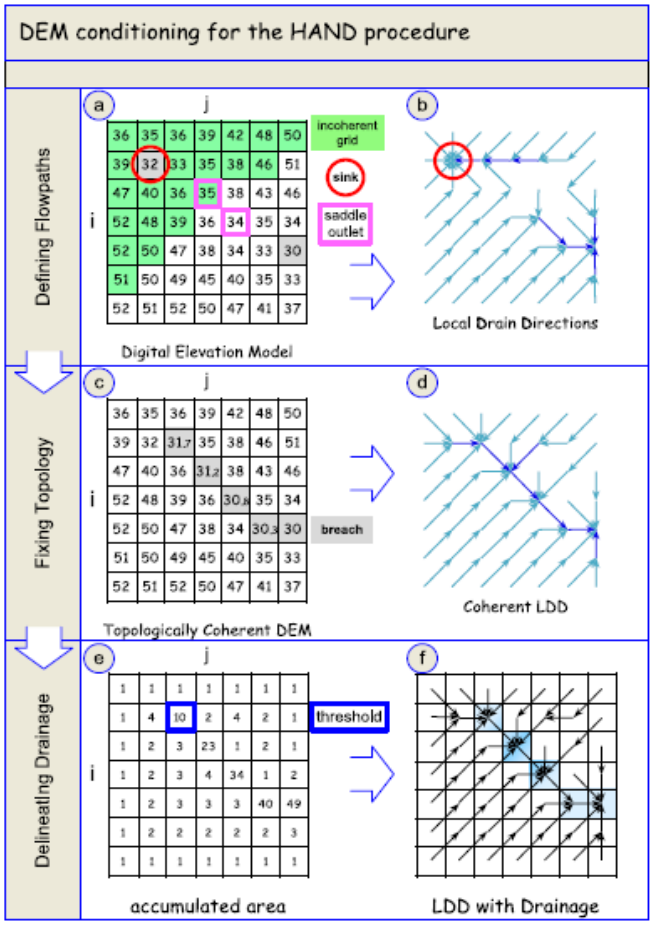

Fonte: Nobre, A. *et al*. (2011)

Figura 21 - Segunda etapa metodológica do modelo HAND

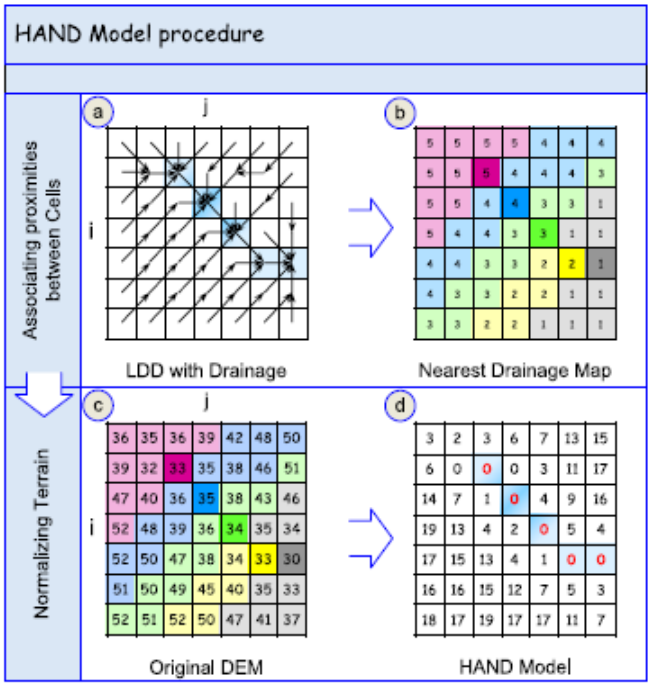

Fonte: Nobre, A. *et al*. (2011)

Incialmente, antes da aplicação do modelo HAND, o MDT foi analisado visualmente na busca de incongruências. No *raster* do município de Jaqueira percebeu-se que o modelo digital apresentava dados altimétricos de uma ponte. Porém, o MDT descreve as elevações do terreno, diferentemente do Modelo Digital de Elevação (MDE), que fornece informações dos objetos terrestres como pontes, edifícios e árvores. Sendo, então, necessário a extração da ponte, principalmente por promover a quebra do escoamento no canal de drenagem e, consequentemente, na inviabilidade da obtenção do modelo HAND.

Para a remoção da ponte, gerou-se a partir do MDT curvas de nível com intervalo de 1m. Dessa maneira, retificou-se manualmente os contornos para extração da ponte seguindo as particularidades do terreno, os quais foram observados pela ortofoto da região. Depois da correção das curvas, foram aplicadas sobre elas a ferramenta *Triangulated Irregular Network* (TIN), que foi transformada para dados matriciais (*raster*) logo em seguida. De posse do MDT corrigido (caso de Jaqueira), o procedimento para a obtenção do HAND foi gerado.

Conforme Nobre, A. *et al*. (2011), o cerne para a obtenção do modelo HAND está na construção adequada dos canais de drenagem por meio das direções do fluxo hidrológico. Visto que as redes de escoamento são o elo para a normalização das alturas da grade em relação ao canal mais próximo. Com isso, a rede de fluxo deve ser coesa, sem interrupções, visando a correta aplicação do algoritmo HAND.

Contudo, segundo Jenson e Domingue (1988), Martz e Garbrech (1998) e Lindsay e Creed (2005), existem depressões (*sink*) nos modelos digitais, as quais são representadas por *pixels* que apresentam todos os vizinhos com maior altimetria, ou seja, a depressão não possui uma célula seguinte com elevação inferior para que a água possa fluir, resultando em buracos no modelo digital, os quais bloqueiam as direções da rede de fluxo. Em decorrência disto, o MDT exibe regiões incoerentes, que não se conectam. Na prática, nestas regiões o fluxo converge para uma única área, caracterizada por baixas elevações (depressões).

As depressões podem ser visualizadas na Figura 20a através das células em cinza (altimetria igual a 32 e 30m). Percebe-se que em ambos os *pixels*, os vizinhos mais próximos apresentam maior elevação que eles. Portanto, toda a rede de drenagem (Figura 20b) converge para estas células, interrompendo o fluxo.

Estas depressões podem estar ligadas às feições particulares do terreno, ao processamento do modelo topográfico nas etapas de coleta dos dados e de geração do produto, erros aleatórios, inevitáveis, e as limitações da resolução horizontal e vertical do dado topográfico. De todo o modo, o refinamento do modelo digital não excluirá a presença dos

buracos, visto que são particularidades do próprio mosaico de superfícies contínuas (JENSON E DOMINGUE, 1988; MARTZ E GARBRECH, 1998; LINDSAY E CREED, 2005).

As áreas incoerentes do MDT são encontradas por meio da matriz de fluxo denominada de *Local Drain Directions* (LDD) ou *Flow Direction* (direção do fluxo), formulada através da técnica *Deterministic Eight-Neighbors* ou método D8. Esta metodologia fornece para cada célula da grade a direção do fluxo, representando a rede de drenagem do *raster*. A direção de um determinado *pixel* é indicada por oito valores de 1 a 128, múltiplos de 2, simbolizando o sentido do fluxo. Para cada célula, o vizinho que apresentar menor elevação será tomado como o sentido do canal (JENSON E DOMINGUE, 1988; MARTZ E GARBRECH, 1999).

Encontradas as áreas incoerentes, procura-se por possíveis candidatos (*pixels* localizados na borda das regiões irregulares) que funcionem como fluxo de saída, isto é, um ponto em que a água possa fluir para fora do buraco. Então, dentre os candidatos, escolhe-se aquele que possuir menor altimetria (Figura 20a), *pixels* selecionados em rosa (com altimetria 35 e 34 m), *saddle outlet* (RENNÓ *et al*., 2008). Dessa forma, o algoritmo HAND corrige as depressões destas grades por meio do método *breaching* (RENNÓ *et al*., 2008; NOBRE, A. *et al*., 2011).

Conforme Rennó *et al*. (2008), para corrigir os buracos no MDT, a ferramenta *breaching* concebe uma rede artificial que liga as depressões vizinhas (32 e 30) percorrendo pelos pontos de saída (35 e 34). A elevação do novo canal é reduzida por interpolação linear, criando certa declividade dentre os *pixels*, sem a promoção de áreas planas no MDT. Com isso, a região incoerente é corrigida, removendo a depressão do MDT e possibilitando direções de fluxo consistentes (Figuras 20c e 20d).

Com a grade de direção de fluxo (LDD) corrigida (Figura 20d), define-se a rede de drenagem do MDT através do algoritmo *flow acumulation* ou área de contribuição. O método calcula para cada *pixel* da matriz, a quantidade de células que fluem (drenam) para a célula avaliada por meio do LDD corrigido (Figura 20e), ou seja, as direções de fluxo seguem para células em posição inferior, as quais acumulam maior quantidade de *pixels* formulando uma superfície de contribuição de escoamento (JENSON E DOMINGUE, 1988; RENNÓ *et al*., 2008); NOBRE, A. *et al*., 2011).

Finalizando a primeira etapa, o canal de drenagem é estabelecido segundo um limiar que determina a partir de qual valor a rede se inicia (Figura 20f). Este limite está estritamente conectado com o resultado da extensão do canal, por um lado o seu aumento provoca a diminuição da densidade drenagem (JENSON E DOMINGUE, 1988), do outro lado sua diminuição produz canais com maior detalhamento (RENNÓ *et al*. 2008).

Limiares que promovem alta densidade de drenagem podem não promover a abstração coerente do evento hidrológico. Por exemplo, Pérez-Mesa (2014) extraiu (*burn*) os *pixels* referentes aos canais de drenagem de maior ordem, resultando na extensão de manchas mais precisas ao comparar a situação redes com maior densidade. Por outro lado, Nobre *et al* (2015) obtiveram resultados superestimados ao considerar canais secundários, não representativos da evolução da inundação.

Ressalta-se ainda que, apesar dos canais intermitentes (de maior ordem) contribuírem para a inundação segundo o escoamento originado pela pluviometria local, as cidades analisadas apresentam inundações que se originam a montante com ondas de fluxos rápidos e turbulentos. Como o HAND representa as alturas em relação ao canal de drenagem mais próximo, estabelecer conexões com os canais secundários haverá, inevitavelmente, superdimensionamento da mancha de inundação.

Por isso, é intuitivo que as alturas HAND descrevam melhor a extensão do evento a partir dos canais perenes (ou principais), nos quais se desenvolvem a inundação. Neste trabalho, o limiar foi escolhido após análises sobre os valores da área de contribuição dos canais (principais e secundários), tendo como meta, a exclusão pelo limiar dos canais secundários e que a referência do HAND fosse somente o canal principal, no qual evoluiu a inundação.

Na segunda etapa, tem-se a construção do modelo HAND. Incialmente, com a rede de drenagem (células em azul da Figura 21a) e o *raster* LDD (direções de fluxo da Figura 21a), atribui-se espacialmente os *pixels* mais próximos as células representadas pelo canal. Em outras palavras, como pode ser visto na Figura 21b, o número dos *pixels* em tonalidade clara indica a célula do canal de drenagem (tonalidade escura) mais próxima a ele. Note que a relação de distância não é a euclidiana, mas sim, a menor distância pelo comprimento da declividade (sentido do fluxo) até a célula mais próxima do canal de drenagem (RENNÓ *et al*. 2008; NOBRE, A. *et al*., 2011).

Finalmente, ocorre a normalização das elevações do terreno segundo o MDT original e o canal de drenagem estabelecido (Figura 21c). Para isto, as células referentes ao canal são atribuídas ao valor zero (Figura 21d), representando a referência do modelo HAND, com isso, calcula-se as alturas normalizadas para toda a grade. A altura HAND para cada célula é a altimetria original do *pixel* menos a elevação original do *pixel* relativo ao canal drenagem mais próximo (RENNÓ *et al*. 2008; NOBRE, A. *et al*., 2011).

Dessa forma, obtém-se uma superfície com potenciais gravitacionais em relação ao rio. De maneira simples, as alturas HAND indicam a possibilidade do risco de inundação, de modo que células com elevações baixas estão mais sujeitas ao evento hidrológico, maior

susceptibilidade. Caso contrário, menor risco associado por apresentarem uma distância vertical ao rio maior, isto é, menor possibilidade a inundação.

Flow Frequency – HAND

A utilização de modelos geomorfológicos na geração de mapas de inundação tem se tornado cada vez mais comum devido à falta de dados. Entretanto, a maioria destas aplicações não inserem a análise de frequência de nível no processo (Speckhann, 2018b). Com isso, Pérez-Mesa (2014) gerou mapas de perigo relacionado à probabilidade de ocorrência de máximos anuais no rio Magdalena na Colômbia, combinando com o modelo HAND. Posteriormente, Speckhann e*t al*. (2017a) sugeriram uma nova abordagem combinando tempos de recorrência de vazões máximas anuais com o descritor do terreno HAND, intitulada f2HAND (*flow frequency – Height Above the Nearest Drainage*).

Nestes trabalhos os autores comentam sobre a melhora nos resultados ao utilizar a análise de frequência de nível. Porém, alguns aspectos relacionados ao modelo digital e a série de máximos anuais devem ser comentados:

- O zero (referência) das réguas linimétricas pode possuir um sistema de referência global, facilitando a correspondência com o modelo HAND. Caso contrário, o nível zero deve ser definido a partir do registro do nível no mesmo dia do levantamento da topografia do Modelo Digital de Elevação (PÉREZ-MESA, 2014). O levantamento LIDAR convencional utilizado neste trabalho, como comentado na Seção 2.3, não consegue descrever de maneira precisa o terreno abaixo da água. Isto impõe certa similaridade com o viés descrito anteriormente, todavia a data de obtenção do dado topográfico não coincide com o local que apresenta maior observação de dados fluviométricos;
- Mudança do posicionamento da régua ao longo do tempo, como visto na estação Palmares (Seção 3.2.3), produzindo resultados espúrios ao combinar a estação com o modelo HAND;
- O máximo anual para um determinado ano pode não estar correlacionado com a maior régua da seção. Tal fator pode promover maior erro quando há mais de uma régua, contabiliza-se mais de uma posição espacial da estação, resultando em diferentes níveis de referência com o modelo HAND;

- Os fenômenos hidrológicos são dinâmicos e, inevitavelmente, aleatórios, os quais variam ao longo do tempo e do espaço. Estas mudanças são originadas por alterações no clima global e regional, nas propriedades geomorfológicas, no uso e ocupação do solo, na ocorrência de assoreamento ou de erosão nos rios e na intervenção dos corpos hídricos como na criação de barragens, modificando o regime das vazões no rio. Tais aspectos podem resultar em saltos, ciclos ou tendências nas séries hidrológicas e podem ser avaliados a partir de análises estatísticas sob hipóteses de homogeneidade, de independência e de estacionaridade. É de extrema importância a verificação de padrões em séries hidrológicas para qualquer que seja a aplicação na engenharia hidrológica (KOUTSOYIANNIS, 2006; NAGHETTINI E PINTO, 2007; READ E VOGEL, 2015).
- A linha de energia da estação fluviométrica é considerada constante para toda área analisada, ou seja, a mesma lâmina de água corresponde a todo o evento de inundação. Contudo, na prática, o nível da água varia devido as mudanças na geometria, na rugosidade e na inclinação do canal, principalmente nos casos de inundações rápidas em locais com altos declives (PÉREZ-MESA, 2014).

Neste contexto, decisões foram tomadas com o intuito de minimizar os erros provenientes dos aspectos mencionados anteriormente. A posição espacial da régua foi analisada do ponto de vista do valor altimétrico HAND, admitindo critérios (consultar Seção 3.2.3) com o intuito de obter um nível de referência, normalizando toda a série em relação ao HAND.

No tocante à verificação da estacionariedade na série de máximos anuais foi aplicada análises exploratórias e testes estatísticos, descritos no próximo subitem. Em seguida, gerou-se distribuições de extremo com o ajuste dos valores observados. Por fim, foram criados mapas de probabilidade de recorrência de 2, 5, 10, 25, 50 e 100 anos com a curva que apresentou melhor ajuste aos dados reais.

Análise de tendências

Na análise de tendência, técnicas descritivas podem facilmente identificar padrões – crescimento, decrescimento, variações cíclicas ou sazonais e *outliers* – nas séries temporais antes do uso de estatísticas mais robustas (EHLERS, 2007). Dentre as aplicações iniciais mais

comuns, destaca-se a análise gráfica e o ajuste dos dados observados por meio de uma regressão linear. Nesta última, a inclinação da reta obtida pode caracterizar o padrão global da série hidrológica, por exemplo. Para a série temporal de máximos anuais de Palmares, estes descritivos foram aplicados como uma primeira avaliação de tendência.

Detectada a presença de tendência na série, recorre-se aos testes estatísticos para descrever significância deste padrão, indicando se há evidências para a hipótese de não estacionaridade da série temporal. Pois, segundo Koutsoyiannis (2006), as séries podem apresentar tendência, mas não indicarem estacionariedade. Caso a hipótese de não estacionariedade seja aceita, esta tendência deve ser tratada.

Conforme Koutsoyiannis (2006), EHLERS (2007) e Naghettini e Pinto (2007), quando as variáveis aleatórias de um processo se exibem casualmente em torno de uma média constante e de uma variância que independe do tempo. Define-se, então, que a série temporal é estacionária. Ainda, diz-se que os eventos provêm de uma mesma distribuição de probabilidade.

De acordo com Read e Vogel (2015), no estudo de probabilidade de recorrência perante condições hidrológicas estacionárias, as realizações são condicionadas às séries temporais independentes com momentos e parâmetros de uma distribuição de probabilidade invariáveis. Como estas premissas são utilizadas para descrever a distribuição de probabilidade de excedência, foram aplicados testes de hipóteses para estabelecer a homogeneidade, a independência e a estacionaridade da série dos eventos extremos anuais da estação Palmares. Os testes foram extraídos das seguintes obras: Back (2001), Naghettini e Pinto (2007), Ahmad *et al* (2015) e Moreira e Naghettini (2015).

Com relação à homogeneidade de uma série hidrológica, questionam-se os níveis máximos anuais são provenientes da mesma população. Isto é, se as condições meteorológicas relativas as inundações (ou enchentes) são comuns ou se decorreram de processos particulares extremos, vistos como anormais. Para a verificação de homogeneidade, utilizou-se o teste não-paramétrico proposto em 1947 por Mann e Whitney (NAGHETTINI e PINTO, 2007).

Seja a série de máximos anuais com **N** elementos ($\mathbf{X_1}$, $\mathbf{X_2}$, ..., $\mathbf{X_N}$), separa-se a amostra em dois subconjuntos, um com $\mathbf{N_1}$ realizações ($\mathbf{X_1}$, $\mathbf{X_2}$, ..., $\mathbf{X_{N1}}$) e outro com $\mathbf{N_2}$ componentes ($\mathbf{X_{1+N1}}$, $\mathbf{X_{2+N2}}$, ..., $\mathbf{X_{N1+N2}}$), de maneira que: $\mathbf{N} = \mathbf{N_1} + \mathbf{N_2}$; $\mathbf{N_1} \leq \mathbf{N_2}$ e; $\mathbf{N_1} = \mathbf{N_2}$ (se **N** par) e $\mathbf{N_2} = \mathbf{N_1} + 1$ (se **N** ímpar). Depois, classifica-se o conjunto **N** em ordem crescente designando para cada elemento a ordem **m** de classificação distribuídas por sub-amostra (**N1** e **N2**). O teste indica se os dois subconjuntos são homogêneos por meio de suas ordens de classificação, caso sejam similares a série é dita homogênea, do contrário heterogêneas.

A estatística do teste **u** de Mann-Whitney é definida para o menor valor entre o $\mathbf{u_1}$ (Equação 22) e o $\mathbf{u_2}$ (Equação 23):

$$\mathbf{u_1 = N_1\, N_2 + \frac{N_1\,(N_1+1)}{2} - R_1} \quad (22)$$

$$\mathbf{u_2 = N_1\, N_2 - u_1} \quad (23)$$

Em que:

$\mathbf{R_1}$: soma das **m** ordens de classificação da sub-amostra $\mathbf{N_1}$.

Considerando a hipótese de homogeneidade e que $\mathbf{N_1}$ e $\mathbf{N_2}$ são maiores que 20, **u** segue uma distribuição normal com média E[u], Equação 24, e variância Var[u], Equação 25.

$$\mathbf{E[u]=\frac{N_1\, N_2}{2}} \quad (24)$$

$$\mathbf{Var[u]=\frac{N_1\, N_2\,(N_1+N_2+1)}{12}} \quad (25)$$

Por consequência, responde-se a hipótese de homogeneidade pela estatística do teste não-paramétrico padronizado T (Equação 26), o qual descreve o comportamento de uma distribuição normal padrão. O teste de homogeneidade é bilateral com nível de significância **α**, optou-se por aceitar a hipótese com nível de confiança de 95%, ou seja, significância **α** igual a 5%. Dessa forma, aceita-se a hipótese nula quando $|\mathbf{T}| < \boldsymbol{Z_{1-\alpha/2}}$, caso contrário, aceita-se a hipótese alternativa, a heterogeneidade do conjunto.

$$\mathbf{T=\frac{u - E(u)}{\sqrt{Var\,(u)}}} \quad (26)$$

No caso da independência das amostras, a hipótese nula deve responder se os eventos podem influenciar nas realizações seguintes. No cenário hidrológico, a presença de dependência é influenciada pela janela de tempo adotada. Logo, as séries de máximos anuais, provavelmente, apresentam independência entre os eventos, diferentemente, das séries de vazões diárias que tem maiores chances de serem dependentes, exceto para vazões de rios controladas por dispositivos hidráulicos (NAGHETTINI e PINTO, 2007).

O teste não-paramétrico de independência utilizado neste trabalho foi proposto em 1943 por Wald e Wolfowitz. Para o conjunto de **N** elementos ($\mathbf{X_1}$, $\mathbf{X_2}$, ..., $\mathbf{X_N}$), seja $\mathbf{X'_1}$, $\mathbf{X'_2}$, ..., $\mathbf{X'_N}$ as diferenças entre as realizações $\mathbf{X_i}$ e a média amostral $\bar{\mathbf{X}}$. A estatística do teste **R** (Equação 27) é formulada por:

$$\mathbf{R} = \sum_{i=1}^{N-1} \mathbf{X'_i}\,\mathbf{X'_{i+1}} + \mathbf{X'_1}\,\mathbf{X'_N} \tag{27}$$

Considerando a hipótese de que os máximos anuais são independentes, atesta-se que **R** advém de uma distribuição normal com média **E[R]** (Equação 28) e variância **Var [R]** (Equação 29). Os dois parâmetros são obtidos a partir dos momentos amostrais $\mathbf{m'_r}$ (Equação 30).

$$\mathbf{E[R]} = -\frac{\mathbf{S_2}}{\mathbf{N-1}} \tag{28}$$

$$\mathbf{Var[R]} = \frac{\mathbf{S^2_2 - S_4}}{\mathbf{N-1}} + \frac{\mathbf{S^2_2 - 2S_4}}{\mathbf{(N-1)(N-2)}} - \frac{\mathbf{s^2_2}}{\mathbf{(N-1)^2}} \tag{29}$$

$$\mathbf{S_r = N m'_r} \therefore \mathbf{m'_r} = \frac{\sum_{i=1}^{N} (X'_i)^r}{N} \tag{30}$$

Em que:
r: ordem dos momentos amostrais.

Para a resolução da hipótese de independência dos dados, utiliza-se o estatístico padronizado **T** (Equação 31), o qual descreve o comportamento de uma distribuição normal padrão. Escolheu-se a significância $\boldsymbol{\alpha}$ igual a 5%. Com isso, aceita-se a hipótese nula quando $|\mathbf{T}| < \boldsymbol{Z_{1-\alpha/2}}$, caso contrário, aceita-se a hipótese alternativa, a dependência do conjunto.

$$\mathbf{T} = \frac{\mathbf{R - E[R]}}{\sqrt{\mathbf{Var[R]}}} \tag{31}$$

Por fim, para a verificação da presença de estacionariedade foram utilizados dois testes não-paramétricos, o teste de Spearman, o teste de Mann-Kendall tradicional* e o sequencial. O

* Foram encontradas duas abordagens na literatura sobre o teste de Mann-Kendall. Embora os dois métodos sejam nomeados como teste de Mann-Kendall na maioria dos trabalhos ou Man-Kendall sequencial para o segundo, optou-se por designar a primeira abordagem em teste de Mann-Kendall tradicional.

teste de Spearmam analisa a presença de tendência temporal por meio da correlação das realizações $\mathbf{X_t}$ de tamanho **N** com a variável tempo **t**. Avalia-se a dependência entre as variáveis através do coeficiente de Spearman $\mathbf{r_s}$ (Equação 32), o qual estabelece a dependência entre a ordem crescente $\mathbf{m_t}$ dos eventos máximos anuais com os índices de tempo $\mathbf{T_t}$, (1, 2, 3, ..., **N**), relacionado ao ano **t**.

$$\mathbf{r_s = 1 - \frac{6 \sum_{t=1}^{N} (m_t - T_t)^2}{N^3 - N}} \tag{32}$$

Vincula-se o coeficiente $\mathbf{r_s}$ com uma distribuição normal de média $\mathbf{E[r_s] = 0}$ e de variância $\mathbf{Var\ [r_s] = 1/N\text{-}1}$. Com isso, a estatística padronizada do teste pode ser obtida por meio de **T** (Equação 33), que segue uma distribuição normal padrão. Decidiu-se por um teste com significância $\boldsymbol{\alpha}$ igual a 5%. A hipótese nula representada pela estacionaridade da série temporal é aceita quando $|\mathbf{T}| < \mathbf{Z_{1-\alpha/2}}$.

$$\mathbf{T} = \frac{\mathbf{r_s}}{\sqrt{\mathbf{Var[r_s]}}} \tag{33}$$

O teste de Mann-Kendall tem sido amplamente utilizado na análise de tendências em séries climatológicas. Pois, investiga as características de independência das amostras sucessivas e analisa a origem da distribuição de probabilidade, a qual deve ser única e aleatória em toda a série. Também indica aproximadamente, caso rejeitada a hipótese nula, o período inicial da tendência que se desenvolve de forma crescente ou decrescente (GOOSSENS E BERGER, 1986; BACK, 2001; AHMAD *et al*., 2015).

Para o teste de Mann-Kendall tradicional, seja uma série com **N** elementos $\mathbf{X_i}$, em que $\mathbf{1 \leq i \leq N}$, calcula-se a soma $\mathbf{S_i}$ (Equação 34) do sinal da diferença entre $\mathbf{X_j}$ e os seus antecessores $\mathbf{X_i}$, em que $\mathbf{j = i+1}$. Seguidamente, obtém-se o somatório **S** composto por todos $\mathbf{S_i}$, com isso, perante a condição de estacionariedade da série, a soma **S** segue uma distribuição normal com variância **Var[S]** (Equação 35). A estatística padronizada do teste é dada por **Z** (Equação 36), descarta-se a hipótese nula (estacionariedade) quando $|\mathbf{Z}| > \boldsymbol{Z_{1-\alpha/2}}$. O nível de significância $\boldsymbol{\alpha}$ adotado para o teste foi de 5%.

$$\mathbf{S_i} = \sum_{i=1}^{N-1} \sum_{j=i+1}^{N} \mathbf{sinal\ (X_j - X_i)} \tag{34}$$

$$\mathbf{Var\ [S]} = \frac{\mathbf{N(N-1)(2N+5)}}{\mathbf{18}} \tag{35}$$

$$\mathbf{Z} = \begin{cases} \frac{\mathbf{S-1}}{\sqrt{\mathbf{Var(S)}}} & \mathbf{para\ S>0} \\ \mathbf{0} & \mathbf{para\ S=0} \\ \frac{\mathbf{S+1}}{\sqrt{\mathbf{Var(S)}}} & \mathbf{para\ S<0} \end{cases} \tag{36}$$

Para o teste de Mann-Kendall sequencial, seja uma série temporal com $\mathbf{X_j}$ eventos em que $\mathbf{1 \leq j \leq n}$, o teste é dado pela soma $\mathbf{t_n}$ (Equação 37) relativa a quantidade de vezes $\mathbf{m_i}$ que o valor $\mathbf{X_i}$ for maior que os seus precedentes $\mathbf{X_j}$, dado que ($\mathbf{j<i}$) e $\mathbf{2 \leq i \leq n}$. Sob a condição de estacionaridade dada pela hipótese nula, tem-se que $\mathbf{t_n}$ segue uma distribuição normal com média $\mathbf{E[t_n]}$ (Equação 38) e variância $\mathbf{Var[t_n]}$ (Equação 39). O teste estatístico padronizado corresponde a **u(t)**, Equação 40, a hipótese pode ser rejeitada quando $|\mathbf{u[t]}| > \boldsymbol{Z_{1-\alpha/2}}$, o nível de significância $\boldsymbol{\alpha}$ admitido para o teste foi de 5%. Destaca-se também que o sinal de **u[t]** indica se a séria apresenta tendência crescente (positiva) ou decrescente (negativa).

$$\mathbf{t_n} = \sum_{\mathbf{i=1}}^{\mathbf{N-1}} \mathbf{m_i} \tag{37}$$

$$\mathbf{E[t_n]} = \frac{\mathbf{N(N-1)}}{\mathbf{4}} \tag{38}$$

$$\mathbf{Var[t_n]} = \frac{\mathbf{N(N-1)(2N+5)}}{\mathbf{72}} \tag{39}$$

$$\mathbf{u[t_n]} = \frac{\mathbf{(t_n - E(t_n))}}{\sqrt{\mathbf{VAR(t_n)}}} \tag{40}$$

O teste de Mann-Kendall sequencial distribui temporalmente os valores estatísticos de $\mathbf{u[t_n]}$ (Equação 40), com **n** variando de **i = 2** até **i = n**, percorrendo a série em sua ordem cronológica. Para a detecção do ponto de mudança de tendência, calcula-se a estatística $\mathbf{u^*[t_n]}$, representada pelo sentido inverso da série, ou seja, os valores são computados a partir de **i = n** até **i = 2**. Caso as duas curvas $\mathbf{u[t_n]}$ e $\mathbf{u^*[t_n]}$ se cruzem dentro do intervalo de confiança ($\mathbf{-Z_{1-\alpha/2}}$ a $\mathbf{Z_{1-\alpha/2}}$), tem-se, então, o início da tendência da série. Ressalta-se que mesmo a série apresentando tendência, a hipótese nula de estacionariedade pode ser aceita de acordo com a significância do teste.

Estimativas de probabilidade de recorrência

Na modelagem de cenários de cheias associados ao perigo de uma certa localidade, os hidrólogos têm recorrido a análises estatísticas mediante as séries de máximos anuais. Sobre a variável aleatória são associados tempos de retorno (ou períodos de recorrência), os quais exprimem o tempo médio que uma realização pode ser igualada ou superada. Esta noção de probabilidade combinada as cotas (vazões) máximas possibilita, com maior embasamento matemático e estatístico, a extrapolação de eventos extremos associados a maiores tempos de retorno, os quais devem ser analisados. Pois, promovem consequências mais drásticas e, assim, medidas de minimização podem ser tomadas com maior efetividade (NAGHETTINI E PINTO, 2007; ROGGER *et al*., 2012; ONEN E BAGATUR, 2017).

Para a determinação de previsões futuras (extrapolações) dos tempos de retorno associados aos valores reais, recorre-se as distribuições de probabilidade da variável aleatória, descritas segundo modelos probabilísticos (matemáticos), gerados através de parâmetros que são ajustados por meio dos dados observados (NAGHETTINI E PINTO, 2007; ONEN E BAGATUR, 2017). Neste trabalho foram utilizadas as seguintes distribuições de probabilidade: a Log-Normal, a de Gumbel, a exponencial, a Generalizada de Valores Extremos (GEV), a Log Pearson III e a Pearson III.

Na tabela 1 podem ser visualizadas as funções de densidade de probabilidade (FDP) – **f(x)** – para cada distribuição utilizada. A Equação 41, integral da FDP, permite o cálculo das funções de distribuições acumuladas (FDA) – **F(x)** – possibilitando o cálculo do período de retorno (**Tr**). Para a obtenção das cotas relacionadas a tempos de retorno específicos (2, 5, 10, 25, 50 e 100 anos), recorre-se a função inversa da FDA. Esta aproximação foi desenvolvida por Chow (1964), em que retorna os quantis ($\mathbf{X_{Tr}}$), Equação 42, associados a probabilidade de não-excedência (**P**), equivalente ao **Tr** desejado, **Tr = 1 / (1-P)** (NAGHETTINI E PINTO, 2007).

$$\mathbf{F(x) = P\,[X<x] = \int_{-\infty}^{x} f(x)dx(x)} \tag{41}$$

$$\mathbf{X_{Tr} = \mu_x + k\sigma_x} \tag{42}$$

Em que:

$\boldsymbol{\mu_x}$: média amostral;

$\boldsymbol{\sigma_x}$: desvio padrão amostral;

k: fator de frequência (ou de probabilidade), dependente de **P** e da distribuição estatística.

Inicialmente, para a resolução das FDP, das FDA, dos quantis e dos tempos de recorrência, faz-se necessária a estimação dos parâmetros de posição, de escala e de forma. Estes parâmetros são obtidos através de inferências estatísticas sobre as amostras, de modo que possam representar a população (variável aleatória), a qual é descrita pela função teórica de densidade de probabilidade.

Para a estimações dos parâmetros, os métodos mais comuns são o Método da Máxima Verossimilhança (MVS), do Método dos Momentos-L (MML) e do Método dos Momentos (MOM), dentre outras aplicações. Na literatura, tem-se que o MVS apresenta, geralmente, resultados mais precisos, pois minimiza a variância dos estimadores. Porém, em certos contextos, a estimação é eficaz somente na assíntota horizontal (tempos de recorrência altos) e em séries pequenas pode produzir estimadores enviesados. O MOM, dentre os outros dois, é o mais utilizado. Entretanto, frequentemente exibe resultados de baixa qualidade, sobretudo na estimação de 3 ou mais parâmetros. Por outro lado, o MML produz estimadores menos tendenciosos, principalmente, para amostragens pequenas quando comparado a outros métodos, porque é menos sensível à possíveis *outliers* e mudanças na distribuição modelada (CUNNANE, 1989; MILLINGTON, DAS E SIMONOVIC, 2011; AHMAD, SHABRI E ZAKARIA, 2011).

Por tais motivos, optou-se pelo método dos momentos L, o qual se baseia em momentos ponderados por probabilidades. Os estimadores não tendenciosos são calculados por funções lineares sobre amostras dispostas em ordem crescente. As equações e informações metodológicas do MML podem ser verificadas em Cunnane (1989), Naghettini e Pinto (2007) e Millington, Das e Simonovic (2011).

Para análise do ajuste das distribuições teóricas de extremo utilizou-se as probabilidades empíricas de excedência indicada pela distribuição empírica, **F**, segundo a Equação 43. Geralmente, emprega-se a distribuição de Weibul (w=0) ou de Cunnane (w=0,4). Ambas são usadas para verificação da qualidade de qualquer distribuição teórica. Para a escolha da distribuição de extremo, analisou-se visualmente as distribuições empíricas e teóricas, aplicou-se dois testes de aderência (testes de hipóteses), o Kolmogorov-Smirnov e o Qui-Quadrado, verificações da quantidade de parâmetros (princípio da parcimônia) e possíveis limites superiores nos valores extremos da série de máximos anuais (NAGHETTINI E PINTO, 2007).

$$\mathbf{F = \frac{i-w}{N+1-2w}} \quad (43)$$

Onde:

i: ordem da observação, as amostras são dispostas em ordem decrescente, com $1 \leq i \leq N$;

N: quantidade de observações;

w: constante que varia entre 0 e 1, determinada para diferentes probabilidades empíricas.

Tabela 1 - Distribuições de máximos anuais

Distribuição	Variável	Função de Densidade de Probabilidade	Parâmetro		
			Posição	Escala	Forma
Log-Normal	$\mathbf{y = \log x}$	$\mathbf{f(y) = \frac{1}{x\sigma_y\sqrt{2\pi}} \exp\left[-\frac{1}{2}\left(\frac{y-\mu_y}{\sigma_y}\right)^2\right]}$	$\boldsymbol{\mu_y}$	$\boldsymbol{\sigma_y}$	-
Gumbel	$\mathbf{x}$	$\mathbf{f(x) = \frac{1}{\alpha} \exp\left[-\frac{x-\beta}{\alpha} - \exp\left(\frac{x-\beta}{\alpha}\right)^2\right]}$	$\boldsymbol{\beta}$	$\boldsymbol{\alpha}$	-
Exponencial	$\mathbf{x}$	$\mathbf{f(x) = \frac{1}{\theta} \exp\left[-\frac{x}{\theta}\right]}$	-	$\boldsymbol{\theta}$	-
Pearson III	$\mathbf{x}$	$\mathbf{f(x) = \frac{1}{\lvert\alpha\rvert\Gamma(\beta_y)} \left(\frac{x-\delta}{\alpha}\right)^{\beta_y - 1} \exp\left(-\frac{x-\delta}{\alpha}\right)}$	$\boldsymbol{\delta}$	$\boldsymbol{\alpha}$	$\boldsymbol{\beta}$
Log-Pearson III	$\mathbf{y = \log x}$	$\mathbf{f(y) = \frac{1}{\lvert\alpha_y\rvert\Gamma(\beta_y)} \left(\frac{y-\delta_y}{\alpha_y}\right)^{\beta_y - 1} \exp\left(-\frac{y-\delta_y}{\alpha_y}\right)}$	$\boldsymbol{\delta_y}$	$\boldsymbol{\alpha_y}$	$\boldsymbol{\beta_y}$
GEV	$\mathbf{x}$	$\mathbf{f(x) = \frac{1}{\alpha}\left[1 - k\left(\frac{x-\beta}{\alpha}\right)\right]^{1/k-1} exp\left\{-\left[1k\left(\frac{x-\beta}{\alpha}\right)\right]^{1/k}\right\}}$	$\boldsymbol{\beta}$	$\boldsymbol{\alpha}$	$\mathbf{k}$

Fonte: Adaptado de Naghettini e Pinto (2007)

3.3.2 Geoestatística

O processo metodológico para obtenção de superfícies contínuas através da Geoestatística consistiu na série de procedimentos visualizada na Figura 22. Inicialmente, recorreu-se às análises exploratórias sobre as observações (profundidades de inundação) a serem modeladas. As estatísticas descritivas do conjunto serviram de base para a transformação dos dados e a remoção de tendências.

Com as mudanças nos dados originais, denominadas de resíduos, obteve-se o semivariograma empírico, que foi ajustado por meio de um semivariograma teórico. Para a verificação da qualidade da escolha do semivariograma utilizou-se a *Croos Validation* (Validação Cruzada) e métricas de erros. Quando tais análises apontaram para baixa qualidade dos resultados, calibrou-se novamente os semivariogramas até a obtenção de resultados

satisfatórios. Por fim, a inferência foi realizada através da Krigagem Ordinária, gerando o mapa de inundação e de incerteza. Para verificação dos mapas produzidos, parâmetros de desempenho foram aplicados. A escolha do modelo final foi realizada quando os resultados apontaram performance adequada.

Figura 22 - Procedimento metodológico para geração de superfícies de inundação através da Geoestatística

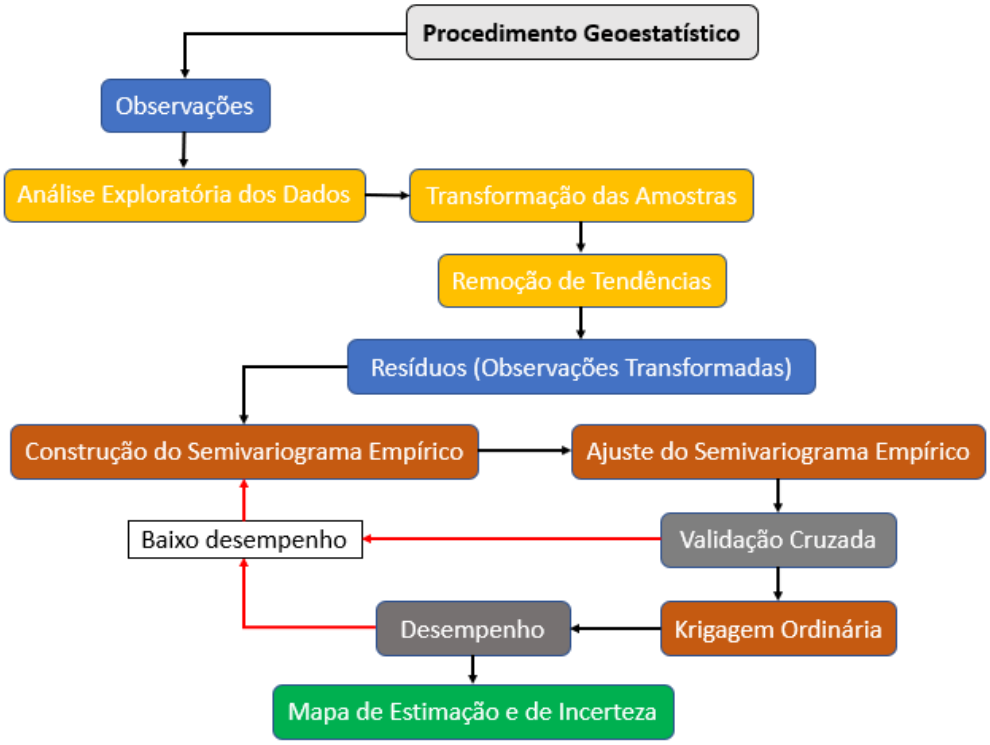

Fonte: Autor (2021)

Análise exploratória dos dados

Como visto na revisão teórica sobre a Geoestatística, certas hipóteses são consideradas na construção e na aplicação da inferência através da Krigagem Ordinária. Tais suposições não podem ser consideradas apenas como artifícios matemáticos e estatísticos para obtenção do sistema de equação final, mas sim como fundamento, respeitando as condições impostas e, obrigatoriamente, verificando-as e pondo-as como exercício prático para correta aplicação da metodologia.

Logo, aplicam-se análises exploratórias sobre as amostras, descrevendo suas características matemáticas e estatísticas através de interpretações gráficas e métricas que auxiliam no entendimento da disposição do conjunto, na análise de tendências espaciais, verificação de *outliers* e suporte estatístico para a necessidade de transformação dos dados por meio de testes de hipóteses. Ressalta-se ainda que as análises são processos necessários e

contínuos em cada etapa, não se limitando às amostras iniciais, ou seja, as amostras brutas, as amostras transformadas, os resíduos, a validação cruzada e os resultados passaram por tais análises - descritas em cada item -, objetivando melhores resultados.

Para análises preliminares nos dados brutos foram utilizadas estatísticas descritivas de posição (média, moda, mediana, valor máximo e valor mínimo), de dispersão (desvio padrão amostral e variância), de forma (coeficiente de assimetria, de variação e de curtose), análises de frequência (histograma), diagrama de caixa (*box-plot*), gráfico de probabilidades (Q-Q plot), testes de normalidade (Shapiro-Wilk, Anderson-Darling, Lilliefors e Jarque-Bera) e análises exploratórias espaciais (gráficos de tendência e análise de *cluster* locais).

Transformação dos dados

Um dos grandes pontos da inferência através da geoestatística está na amostragem do fenômeno. Questões como a densidade, a distribuição espacial e a presença de *clusters* ou de *outliers* nos dados podem promover enviesamento no entendimento e na modelagem da estrutura espacial. No caso das inundações, as particularidades do rio, o fenômeno em si e a disposição da cidade relacionada às estruturas que servem de referência das observações podem afetar o desempenho da interpolação espacial, além disso, a própria subjetividade intrínseca da equipe no levantamento das amostras.

Especificamente em relação às profundidades de inundação, existem certas tendências na amostragem do evento, a exemplo do levantamento nas bordas (profundidade igual a zero), tanto por motivos práticos devido a extensão da superfície, quanto pela dificuldade de extrair informações em campo nas áreas atingida. Tal questão influência diretamente na variância das profundidades, na promoção de distribuições assimétricas (excesso de valores próximos a zero), na densidade e na distribuição espacial dos pontos, podendo promover viés indesejáveis.

A subjetividade no levantamento do evento é notória nas duas aplicações utilizadas neste trabalho, porém isso não necessariamente foi algo planejado. Ressalta-se, novamente, as singularidades da pesquisa em campo. Em Palmares, por exemplo, os pontos só foram levantados na margem esquerda do rio Una, sem levantamentos na margem direita. Já em Jaqueira, a coleta priorizou as duas margens. Provavelmente, a equipe entendeu ser a melhor opção para a construção do evento.

Note que a problemática levantada neste último parágrafo não está questionando qual o melhor procedimento, apenas que existe subjetividade (particularidades) em qualquer amostragem que podem (ou não) resultar na ocorrência de padrões preferenciais. Isso indica a

necessidade de análises exploratórias sobre os dados, dando suporte para possíveis transformações. Para Oliver e Webster (2014), a geoestatística considera a aleatoriedade intrínseca do fenômeno: apesar da amostragem não precisar ser rigorosa, o enviesamento deve ser evitado.

O primeiro passo antes de aplicar qualquer transformação nos dados originais é verificar as necessidades inerentes à metodologia, o fenômeno e o tipo do resultado a ser alcançado. Com relação às caraterísticas metodológicas, apesar de não ser uma regra, Cressie (1993), Landim (2006), Wu, Norvell e Welch (2006) e Li e Heap (2011) comentam que a não-normalidade dos dados pode ocasionar resultados espúrios, sendo preferível dados com distribuição normal, principalmente, nos casos em que há assimetria positiva, ou seja, alta frequência de valores próximos ao mínimo. Cressie e Hawkins (1980) discorrem também por possíveis problemas no caso de *outliers*, vistos em distribuições não normais.

Exceto com o uso da transformação Gaussiana, nem sempre é possível a obtenção de uma distribuição normal. Neste contexto, para reduzir possíveis efeitos negativos na inferência. Almeja-se que a distribuição seja simétrica, visto que dessa forma os dados estão igualmente distribuídos ao redor do valor médio, baixa variabilidade dos dados (estabilizada) e correção de dados discrepantes. Além disso, variações irregulares do semivariograma devem ser evitadas (YAMAMOTO, 2020).

Em relação ao fenômeno e ao mapa final, como se trata de análise de risco, um aspecto crucial no desastre hidrológico se refere à extensão máxima do evento, cujo limite é representado pelas profundidades de inundação iguais (ou próximas) a zero. Entretanto, o limite fica restrito aos pontos amostrados, tornando difícil a estimação das bordas do fenômeno. Isto acontece porque para cada *pixel* inferido na fronteira, o raio de busca pelos vizinhos mais próximos abrange amostras com profundidade diferente de zero. Logo, as profundidades destas regiões possivelmente resultarão em valores maiores que zero, não sendo possível estabelecer a extensão do fenômeno.

Para este caso, uma alternativa sem a imposição da transformação é o uso da Krigagem Indicadora, que trabalha com a função da distribuição condicional acumulada. Porém, esta técnica apresenta desvantagens, as quais podem ser evitadas a partir de variações da metodologia – mais informações podem ser obtidas em Tolosana-Delgado, Pawlowsky-Glahn e Egozcue (2008). Porém, o inconveniente desta aplicação está em seu resultado que gera um mapa binário através de probabilidades de corte, sem a obtenção das profundidades do evento, tornando-a limitada neste quesito. Assim, para a presente pesquisa concentrou-se na Krigagem Ordinária.

Para contornar o problema da extensão recorreu-se ao artifício utilizado em Poser e Dransch (2010) e Ribeiro Neto *et al*. (2015). Nos dois artigos os autores interpolaram as profundidades de inundação somadas às elevações do terreno – extraídas através de um MDT. Diferentemente destes autores, neste trabalho foram utilizadas as elevações do modelo HAND, pois conceitualmente as alturas HAND representam melhor o fenômeno avaliado.

Neste contexto, a primeira transformação da profundidade de inundação foi a adição da altura HAND. Em sequência, caso a normalidade dos dados não fosse verificada, aplicou-se nova transformação, sendo testadas a logarítmica, a *box-cox* e Arcsin. Optou-se pela transformação que melhor ajustou os dados a uma distribuição normal.

Remoção de tendências

Como apresentado no referencial teórico, para resolução da função aleatória no caso particular da Krigagem Ordinária (KO) torna-se necessária na estimação a condição de estacionariedade das hipóteses intrínsecas, representada por amostras com média constante e desconhecida em todo o domínio e com variância dos pares amostrais (semivariograma) independentes de suas posições espaciais, mas inerentes à distância e à direção entre as observações.

Apesar de ser uma condição imprescindível para execução correta da KO, não é incomum na literatura encontrar-se aplicações sem o uso de análises que averiguem a estacionariedade das hipóteses intrínsecas. Na prática, os fenômenos podem apresentar tendências globais no comportamento espacial das amostras, ou seja, verifica-se a presença de heterogeneidade das amostras no domínio avaliado.

Como só existe uma realização (conjunto das observações) da função aleatória, não existe possibilidade para legitimar ou contrapor a estacionaridade da média, até porque as amostras não representam de maneira clara e inequívoca o fenômeno. Entretanto, deve-se considerar pertinente ou não a hipótese de estacionariedade na prática a partir da homogeneidade das observações na área avaliada (SOARES, 2006).

Para verificação da presença de estacionariedade das hipóteses intrínsecas, recorre-se ao estudo de gráficos de tendências, em que se avalia a distribuição dos valores contínuos da variável aleatória nos eixos x e y (coordenadas), os quais devem ser visualizados com diferentes rotações sobre os eixos, procura-se, então, tendências globais. A presença de variações significativas da posição das amostras no espaço são indícios de tendências nos dados.

Segundo Vieira *et al*. (2002) e Oliver e Webster (2014), outro modo de perceber a não-estacionariedade do conjunto pode ser através da análise do semivariograma das amostras, pois quando as variâncias crescem constantemente, sem apresentar um limite superior, há evidências da existência de um certo padrão em uma dada direção.

Quando detectada a presença de tendências globais sobre o conjunto, deve-se ajustá-la por meio de uma superfície de tendência, descrita por uma função polinomial. Este padrão global determinístico deve ser extraído das amostras e a função aleatória (semivariograma empírico) desenvolvida sobre as variações locais, denominadas de resíduos (*drift*), que respeitam as condições de estacionaridade intrínsecas e, com isso, possibilitam o uso coerente da KO (CRESSIE 1986; CRESSIE, 1993; VIEIRA, 2000; JOHANNESSON E CRESSIE, 2004; CAMARGO, FUCKS E CÂMARA, 2004; VIEIRA *et al*., 2010).

Embora não tenha sido utilizado neste trabalho, destaca-se que há uma outra abordagem possível a ser utilizada na inferência considerando a presença de uma estrutura global variável, ou seja, um conjunto não-estacionário é estimado considerando a tendência. Porém, calcula-se a variação global internamente, dependente das coordenadas, que são representadas por uma função polinomial de ordem **k**. Este método é conhecido como Krigagem Universal (KU), onde, diferentemente da Krigagem Ordinária, considera-se que a média é inconstante e a variância dependente da posição espacial das amostras (heterogeneidade) (CRESSIE, 1986; MYERS, 1991a; MENG, LIU E BORDERS, 2013).

Certos problemas são encontrados na KU, principalmente, porque o polinômio de ordem **k** não é conhecido e deve ser previsto, além do que os resíduos são calculados pela diferença entre os dados brutos menos o polinômio "adivinhado", o que promove certo problema operacional (CRESSIE, 1986). Neste trabalho, por este motivo e devido a utilização da KO ser mais comum na literatura, preferiu-se a correção dos dados e aplicação da Krigagem Ordinária sobre os resíduos (variância local) após o ajuste de uma função polinomial (variância global).

Com isso, respeitando as hipóteses intrínsecas, padrões foram avaliados através dos gráficos de tendências e análises sobre o semivariograma empírico. Quando encontradas variações globais significativas, estas foram removidas por meio de funções polinomiais de primeiro, de segundo ou de terceiro grau.

Semivariograma empírico e teórico

O cerne do modelo Geoestatístico está centrado na construção da função aleatória, o semivariograma empírico, o qual é ajustado pelo semivariograma teórico. Inicialmente, para

entendimento do processo metodológico, ressalta-se que não existe o mais correto ou o melhor semivariograma para representar o fenômeno analisado. Na realidade, esta etapa passa por questões interpretativas do operador sobre apontamentos gerais, tendo a subjetividade como relação intrínseca de sua criação, bem como condições que podem promover melhores resultados.

A prática comum da modelagem do semivariograma requer conjuntas interpretações, tanto subjetivas, quanto estatísticas, como o uso da *Cross Validation* (Validação Cruzada) (MYERS, 1991a). Tal processo é dinâmico e deve ser sempre analisado em conjunto com o resultado da krigagem, verificando a concordância com as características inerentes ao fenômeno.

Para a construção do semivariograma empírico é estritamente necessária a utilização de critérios que possam conduzir a resultados satisfatórios, os quais devem sempre ser analisados, validados e questionados, pois há uma infinidade de possíveis respostas. Sobre a Equação 9 do semivariograma e os critérios de busca dos pares amostrais representados pelo **lag**, **quantidade de lags**, **tolerância do lag**, **direção do lag** e **tolerância angular** (item 2.5.1 Variograma) do semivariograma, os seguintes critérios foram levados em consideração sobre a modelagem do semivariograma:

- quantos mais pontos amostrados, melhor o comportamento sequencial do variograma empírico, visto que os pontos tendem a apresentar maior continuidade e disposição gráfica semelhante às curvas matemáticas, representadas pelo semivariograma teórico[*](OLIVER E WEBSTER, 2014);
- o modelo semivariográfico deve atender à condição de positividade (SOARES, 2006; OLIVER E WEBSTER, 2014);
- nem todos os pontos (semivariância empírica) promovem confiabilidade ou importância para o semivariograma (OLIVER E WEBSTER, 2014);
- devido à existência do efeito pepita (descontinuidade do semivariograma para distâncias curtas) resultante de erros aleatórios e sistemáticos, prefere-se que a modelagem do semivariograma descreva adequadamente a semivariância para distâncias pequenas, pois são as regiões que apresentam maior criticidade (peso) para a krigagem (WARRICK E MYERS, 1987; MYERS, 1991b; OLIVER E WEBSTER, 2014). Para isto, opta-se por considerar uma quantidade de pares

[*] Note que dividir os dados em dois conjuntos, um de validação e outro de calibração, prática comum na utilização de modelos, não é adequado para a modelagem do semivariograma empírico. Pois, diminui a quantidade de amostras disponíveis.

razoáveis nas curtas distâncias, os quais são fundamentais para o ajuste do modelo teórico;

- quantos mais pontos (semivariância empírica) na região de dependência espacial melhor para o ajuste do semivariograma teórico. Porém, deve-se avaliar a quantidade de pares em cada **lag** (OLIVER E WEBSTER, 2014);
- o **lag** e a **tolerância do lag** quando tomados por baixos valores, poucos pares são contabilizados, promovendo erros e gerando um semivariograma irregular. Caso contrário, altos valores resultam em poucos pontos no gráfico, dificultando o ajuste do variograma teórico (OLIVER E WEBSTER, 2014);
- normalmente, a **tolerância do lag** é tomada como a metade da distância **lag** estabelecida;
- a verificação da presença de anisotropia nos dados pode ser avaliada conforme a construção do mapa (ou superfície) de semivariograma ou de variogramas para diferentes **direções do lag**. Os variogramas devem ser calculados para diferentes orientações, variando de 45 em 45 graus ou 22,5 em 22,5 graus ou 11,25 em 11,25 graus, dependendo da amplitude das semivariâncias empíricas. Com isso, o objetivo é identificar os sentidos de maior ou menor continuidade espacial, caso do modelo anisotrópico. Quando não há preferência espacial, se estabelece o variograma isotrópico, o qual depende apenas da distância |**h**|;
- geralmente, a tolerância angular é estabelecida como 22,5 graus;
- finalmente, as decisões foram tomadas analisando o modelo semivariográfico em conjunto com a superfície do semivariograma, sendo esta última representada por um gráfico bidimensional que calcula para cada célula da superfície a semivariância. O mapa da semivariância permite análises da variabilidade espacial para diferentes direções, possibilitando a verificação da presença de anisotropia nos dados de maneira mais inteligível (CAMARGO, FUCKS E CÂMARA, 2004; YANAMOTO, 2020). A superfície de variância também foi utilizada para verificação da presença de ruídos a partir dos parâmetros definidos.

De um modo geral, incialmente, foram verificados o comportamento do gráfico e da superfície do semivariograma com valores baixos e altos do **lag**, objetivando o entendimento do comportamento dos extremos. Valores intermediários foram analisados de modo dinâmico

até serem obtidos os critérios comentados anteriormente. Ressalta-se que a construção do semivariograma não foi absoluta e restrita, pois nem todas as considerações conseguem de fato ser atingidas com parâmetros estáticos. Porém buscou-se, principalmente, evitar a presença de ruídos no semivariograma de superfície, uma quantidade de pares consideráveis nos primeiros **lags**, pelo menos 3 pontos antes da presença de descontinuidade espacial e as variâncias dispostas sequencialmente semelhantes às curvas matemáticas.

A próxima etapa consistiu no ajuste dos pontos teóricos através de uma curva contínua que descreve as principais nuances da sequência, de maneira que as variações (distância) entre os pontos e a curva devem ser ignoradas, devido à dificuldade em ajustar todos os pontos. Para tanto foram empregadas funções contínuas positivas, as quais satisfazem a disposição dos pontos experimentais. Testou-se as expressões mais utilizadas na modelagem do semivariograma, no caso, a esférica, a exponencial e a gaussiana (equações 10, 11 e 12 – item 2.5.1 Variograma), visando o ajuste da curva aos pontos.

Com relação ao ajuste, Soares (2006) comenta que o uso métodos automáticos segundo a otimização de parâmetros estatísticos podem promover erros quando pontos sem importância ou enviesados influenciam no ajuste da curva. O autor considera este procedimento "totalmente desaconselhável" e indica que o ajuste deve ser manual levando as características do fenômeno em consideração na escolha dos parâmetros da curva teórica.

Contrariamente à Soares (2006), Oliver e Webster (2014) criticam a prática de ajuste manual devido às variações da semivariância empírica, à flutuação da precisão das semivariâncias e à mudança promovida por diferentes direções (caso anisotrópico). Dentre estas e outras desvantagens, os autores indicam o uso de parâmetros automáticos em conjunto ou separado como o método dos mínimos quadrados e/ou o critério de Akaike.

Como comentado anteriormente, não há espaço para interpretações absolutas: se por um lado os ajustes automáticos facilitam o procedimento e podem promover melhor coerência matemática e estatística entre o semivariograma teórico e as variâncias experimentais, por outro lado, caso o semivariograma se apresente irregular, o ajuste pode não promover resultados confiáveis. De todo o modo, a supervisão pelo operador é essencial na assertividade do modelo.

Neste trabalho a modelagem do semivariograma foi averiguada de ambas as formas. Um apontamento necessário para tal fase ocorreu quando diferentes modelos matemáticos (esférico, exponencial e gaussiano) apresentaram semelhança na curva e, com isso, utilizou-se o ajuste automático pelo método dos mínimos quadrados para obtenção dos parâmetros de interesse traduzidos pelo alcance (*range*), pelo patamar (*sill*) e pelo efeito pepita (*nugget effect*). Por fim, destaca-se que todos os testes foram avaliados pela validação cruzada, explicada a seguir.

Validação Cruzada

As transformações dos dados, a remoção de tendências, a escolha dos parâmetros do semivariograma empírico e a seleção do modelo matemático que retrata todo o domínio avaliado são caminhos escolhidos pelo operador que internamente interferem positivamente ou negativamente nos resultados inferidos. Como visto, há subjetividade nestes processos, por isso apela-se exaustivamente por parâmetros que indiquem o desempenho e a coerência do modelo proposto, bem como auxiliem na comparação entre modelos selecionados.

Neste contexto, a Validação Cruzada é a ferramenta adequada para tais análises. Conforme Soares (2006) e Oliver e Webster (2014), a metodologia se desenvolve da seguinte forma: para cada amostra no campo, seu valor é excluído do conjunto e estimado pela Krigagem Ordinária (Equação 20 – item 2.5.2 Krigagem Ordinária) segundo o modelo do semivariograma teórico escolhido. Verifica-se assim o quanto o modelo construído consegue predizer um valor de uma amostra existente.

Com isso, a Validação Cruzada tem por objetivo comparar os valores reais (medidos, observados) com os estimados de acordo com análises estatísticas sobre o erro (estimado menos observado) e avaliar o erro padronizado que é calculado pela raiz da variância da Krigagem. Comumente são utilizados parâmetros de desempenho e interpretações gráficas. Neste sentido, para as métricas foram empregadas a Média do Erro (ME), a Variância do Erro (Var) e a Raiz Quadrada Média dos Quadrados dos Erros (RMSE) para análises sobre o erro da estimação e, a Média dos Erros Padronizados (ASE), Média dos Erros Normalizados (MSE2) e a Raiz Quadrada Média dos Quadrados dos Erros Normalizados (RMSSE) para investigações acerca dos erros da variância da Krigagem. Com relação aos gráficos, criou-se o histograma do erro, o gráfico de dispersão dos valores estimados versus medidos e o gráfico de probabilidade normal (Q-Q *plot*) para os erros normalizados.

O ideal é que o histograma do erro apresente similaridade com uma distribuição normal com Média do Erro (ME) próxima a zero e com Variância do Erro (Var) mínima. A reta da regressão linear ajustada ao gráfico de dispersão deve ser próxima da reta 1:1 (medido = estimado). Para o Q-Q *plot*, os pontos plotados devem estar próximos da reta da distribuição normal teórica. A respeito dos parâmetros, o RMSE e o ASE devem ser minimizados e próximos quando comparados, pois medem a consistência da modelagem da incerteza. O MSE2 deve ser próximo de zero, e o RMSSE próximo a unidade.

Por fim, destacam-se três importantes considerações. A primeira é que o RMSE e o RMSSE se apresentam como os parâmetros estatísticos para comparação entre os modelos

admitidos. A segunda, o gráfico de probabilidade normal e o de dispersão indicam os pontos que estão sendo superestimados ou subestimados na inferência, indicando amostras que podem ser retiradas do conjunto para realização de novos semivariogramas e, com isso, nova modelagem. A terceira, destaca-se que a validação cruzada tem sua importância, mas pode ser refutável de acordo com o resultado da inferência realizada pela Krigagem. Dessa forma, os mapas finais devem nortear a qualidade do modelo proposto, ou seja, se a realidade do fenômeno não for representada pelo modelo final e/ou a confiança seja incoerente, a ferramenta se torna inválida.

Krigagem Ordinária

Satisfeitas as condições impostas para aplicação da Krigagem Ordinária sobre os resíduos e de posse dos semivariogramas teóricos, que apresentaram as circunstâncias próximas às ideais e de resultados coerentes para as métricas de desempenho e para as análises gráficas na etapa da Validação Cruzada. Executa-se a inferência estatística, a qual promove dois resultados, o mapa com as profundidades de inundação geradas por meio do sistema de krigagem, Equação 20, e o mapa da incerteza produzido pela Equação 21 (Ver item 2.5.2 Krigagem Ordinária).

Os resultados produzidos pela krigagem ocorrem de maneira automática, porém certas condições devem ser definidas anteriormente à inferência. O primeiro ponto a ser escolhido é o tipo de janela a ser interpolada. Para tanto existem duas opções, a krigagem pontual, em que cada ponto inferido representa o centro da célula da grade ou a krigagem por blocos, de modo que cada bloco é centrado em um ponto da grade e o seu valor é calculado segundo a média da estimação de pontos distribuídos no bloco.

As duas aplicações divergem e possuem suas particularidades positivas e negativas, porém a escolha depende do objetivo e do fenômeno avaliado. No contexto das características da inundação, optou-se pelo uso da estimativa sobre a krigagem pontual, visto que a variabilidade do fenômeno é brusca, principalmente, no sentido perpendicular ao rio. Além disso, apesar da krigagem por blocos tender a suavizar a estimação, tal efeito poderia incluir áreas não atingidas pela água em regiões inundadas e vice-versa. Ressalta-se que como o valor em cada bloco se refere a uma média, esta pode ser influenciada na presença de valores extremos.

Outra motivação para o uso da krigagem por pontos está relacionada com o processo metodológico, pois como o modelo HAND foi incluído na subtração do modelo krigado para

obtenção apenas das profundidades de inundação. Dessa forma, ao se utilizar a krigagem por blocos, o resultado caso apresentado ponto a ponto estaria enviesado pelo valor médio do bloco, aumentando regiões superestimadas ou subestimadas. Caso opte-se por resultados através de áreas, análises visuais seriam prejudicadas, bem como sobre os parâmetros de desempenho.

Segundo Oliver e Webster (2014), em certos estudos geoestatísticos como na mineração para quantificação de metais, na ciência dos solos para aplicações de produtos químicos na agricultura e na proteção ambiental para indicações de áreas a serem remediadas na presença de altas concentrações de poluentes, normalmente a krigagem por blocos é a mais indicada. Percebe-se, nitidamente, que as peculiaridades e os objetivos finais destes fenômenos influenciam na escolha do tipo de estimação, sendo primordial tais considerações.

O segundo ponto a ser definido está na vizinhança dos pontos a serem inferidos. Isto retrata as considerações acerca da procura das amostras em termos de quantidades e de direções. Como comentado por Oliver e Webster (2014), a krigagem é um interpolador local e somente as observações mais próximas recebem maiores pesos, principalmente, se a variância do efeito pepita for pequena em relação a variância total. Com isso, o sistema de krigagem é calculado com um número bem menor de equações, aumentando o desempenho computacional.

Outro comentário interessante descrito pelos pesquisadores é que por ser um preditor local, a interpolação por vizinhos facilita a coerência da estacionaridade sobre as parcelas do domínio. Além disso, ressaltam a importância de ajustar corretamente com maior precisão o modelo semivariográfico teórico para as primeiras variâncias empíricas. Pois, na prática são as curtas distâncias que apresentam maiores pesos, principalmente, se os dados forem bem densos e regulares.

Diante destes argumentos, deve-se decidir sobre: a quantidade de pontos no mínimo e no máximo a serem interpolados; a necessidade de dividir a circunferência (caso isotrópico) ou a elipse (caso anisotrópico) em 4 ou 8 setores; no caso anisotrópico pode-se ainda escolher a direção dos setores; o tamanho do raio de busca, se igual ao alcance, geralmente, escolhe-se esta opção quando a densidade das amostras é alta, ou o raio maior que o alcance, quando as amostras se encontram irregulares e dispersas, ou seja, quando há regiões dentro do domínio sem a presença de uma quantidade de informações (observações) razoáveis próximas.

Neste contexto, a inferência foi realizada sobre os resíduos de acordo com os modelos semivariográficos escolhidos e os parâmetros de buscas sobre a vizinhança foram testados de diferentes formas, buscando a otimização do resultado. Todos os mapas krigados (referentes à superfície da profundidade e da incerteza) passaram por análises posteriores.

Dentre as métricas de desempenho foram aplicadas: investigações visuais em buscas de ruídos e de incoerências como a presença de padrões circulares ou elípticos sobre a superfície krigada, que deve ser evitada; comparações entre os valores observados e preditos (análises dos erros e coeficientes de correlação, R, e de Pearson, R^2); confrontações entre as incertezas dos modelos através de técnicas de álgebras de mapas.

Com isso, após a verificação dos modelos que melhor se comportaram dentre os preferíveis, foram executadas metodologias de comparação entre *raster*, descritas a seguir. Neste caso, o modelo HAND e o modelo geoestatístico foram comparados, de maneira que o modelo krigado é definido como observado ("real") e o HAND, o modelo a ser validado, isto é, questiona-se o poder de acerto do HAND para determinação de mapas de inundação (extensão).

3.3.3 Comparação entre mapas: HAND versus Krigagem Ordinária

Os parâmetros de desempenho para análise dos *raster* foram utilizados em duas abordagens. Na primeira, utilizou-se a curva *Receiver Operating Characteristics* (**ROC**) para definição da altura HAND, em que se desejou a busca por um limiar ótimo (altura HAND de corte), visando melhor performance em relação ao modelo preditivo geoestatístico. Na segunda aplicação, foram empregados o *Bias* (**B**), o *Fit Index* (**F**), o *False Alarm Ratio* (**FARatio**), o *False Negative Rate* ($\mathbf{r_{fn}}$) e o *True Negative Rate* ($\mathbf{r_{tn}}$) como complemento para análise do desempenho do limiar ótimo alcançado na primeira metodologia.

Inicialmente, para entendimento da métricas utilizadas, faz-se necessária a apresentação das variáveis manipuladas. Na Figura 23, verifica-se de maneira simplificada como sucede a representação do *raster* HAND (Modelo Simulado – **MS** – em laranja e verde), do *raster* geoestatístico (Modelo Observado – **MO** – em amarelo e verde), da intersecção entre os modelos (área de acerto – **MSO –** em verde) e na região em que não houve inundação (áreas secas, em cinza), as áreas destes são representadas por $\mathbf{A_{MS}}$, $\mathbf{A_{MO}}$, $\mathbf{A_{MSO}}$ e $\mathbf{A_{Seca}}$, respectivamente.

Para a curva **ROC**, a interação entre os dois modelos é representada por testes de classificação binário (positivo, 1, ou negativo, 0). Neste caso, existem 4 possíveis resultados representados similarmente como visto na Figura 23. Divide-se as 4 classes em: Verdadeiros Positivos (**VP** – em verde), os Verdadeiros Negativos, (**VN** – em cinza), os Falsos Positivos (**FP** – em laranja) e os Falsos Negativos (**FN** – em amarelo). Como explicado em Stephenson (2000) e Manfreda *et al* (2014):

- **VP**: *hit* (acerto), células classificadas como inundação em ambos os modelos;
- **VN**: *correct rejection* (correta rejeição), células classificadas como áreas seca em ambos os modelos;
- **FP**: *false alarm* (falso alarme - comissão), células classificadas como inundadas no modelo simulado, mas que foram designadas como regiões secas pelo modelo de referência;
- **FN**: *miss* (falha - omissão), células classificadas como inundadas no modelo observado, porém definidas como áreas secas pelo modelo simulado.

Figura 23 - Representação das áreas simuladas e observadas e suas relações de acerto e erro

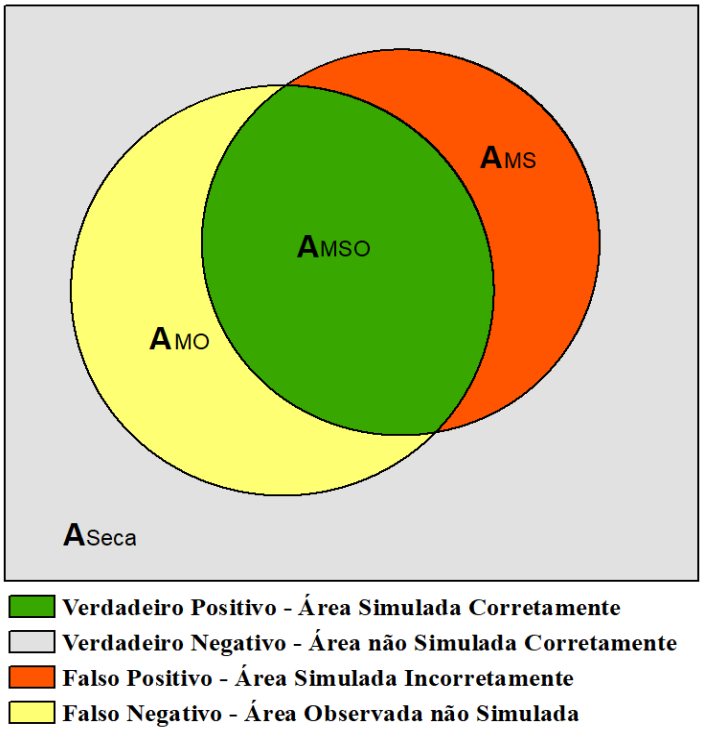

Fonte: Autor (2021)

Curva ROC

A curva **ROC** é uma métrica gráfica estatística que mede a associação entre modelos observados e simulados referentes a uma determinada característica. A simulação desta característica indica resultados positivos (**VP** ou **FP**) ou negativos (**VN** ou **FN**), os quais dependem do valor da variável simulada a partir de um determinado limite. A curva **ROC** é construída sobre cada limite estabelecido, computando dois possíveis valores: *true positive rate* $\mathbf{r_{tp}}$ (taxa de acerto), Equação 44, e *true false positive* $\mathbf{r_{fp}}$ (taxa de alarme falso), Equação 45 (PONTIUS JR E SI, 2014; MANFREDA *et al*., 2014; 2015).

$$\mathbf{r_{tp}} = \frac{\mathbf{hit}}{\mathbf{hit+misses}} = \frac{\mathbf{VP}}{\mathbf{VP+FN}} \tag{44}$$

$$\mathbf{r_{fp}} = \frac{\mathbf{false\ alarms}}{\mathbf{false\ alarms + correct\ rejections}} = \frac{\mathbf{FP}}{\mathbf{FP+VN}} \tag{45}$$

Conforme Manfreda *et al*. (2014), $\mathbf{r_{tp}}$ indica a capacidade do mapa simulado identificar os *pixels* inundados preditos pelo mapa de referência. Por outro lado, o $\mathbf{r_{fp}}$ mede o desempenho do modelo simulado na estimação de regiões inundadas incorretamente, dado que no modelo observado tal região foi assinalada como não-inundada.

No contexto das inundações e deste trabalho, o mapa de inundação gerado por meio da geoestatística (valores observados) foi transformado em um mapa binário, servindo de modelo referência para calibração de um limite ótimo para o modelo HAND (valores simulados).

Como resposta, a curva **ROC** é analisada da seguinte forma: caso os valores computados apresentem valores próximos entre si ($\mathbf{r_{tp} = r_{fp}}$), formando uma reta, tal resultado indica aleatoriedade na técnica abordada. Por outro lado, caso os pares se distribuam na parte superior esquerda da reta $\mathbf{r_{tp} = r_{fp}}$, o modelo simulado indica resultados mais satisfatórios, em que quanto mais distantes (parte superior a esquerda) da reta aleatória, melhor. Outra forma de medir o desempenho através da curva **ROC** é por meio do cálculo da área abaixo da curva, denominada *Area Under the Curve* (**AUC**), valor que quanto mais próximo da unidade, melhor indica o desempenho do modelo. (MANFREDA *et al*., 2014, 2015).

A taxa $\mathbf{r_{tp}}$ também pode ser traduzida pelo coeficiente C, conhecido como *Correct index* ou *Overall Acuracy* (STEPHESON, 2000; YU e LANE, 2006; JAFARZADEGAN e MERWADE, 2017). A taxa $\mathbf{r_{fp}}$ é igualmente conhecida por *False Alarm Rate* ou *Probability of False Detection* (STEPHESON, 2000; BARNES *et al*., 2009). Geralmente, estes parâmetros são utilizados isoladamente, sem o uso da Curva **ROC**, quando o mapa simulado já está construído, a exemplo da comparação entre mapas hidrodinâmicos, determinísticos, estatísticos e geomorfológicos.

Pontius Jr e Si (2014) comentam que pesquisadores têm criticado na literatura o uso da curva **ROC** e do desempenho geral do modelo simulado segundo a **AUC** desacompanhados de outras métricas. Pois, as diferentes aplicações divergem na escolha do erro mais prejudicial da modelagem e que a curva **ROC** ignora os valores absolutos dos resultados na comparação dos modelos, dificultando o entendimento do tamanho dos erros gerados e qual limite promove mais o erro indesejável. No contexto dos desastres, Stepheson (2000) e Simmons e Sutter (2009)

discutem que o erro cometido pelos falsos negativos (*misses*) pode ocasionar maiores impactos no enfretamento de um fenômeno desastroso, em comparação ao erro dos falsos positivos.

De um modo geral, percebe-se que a análise deve ser dinâmica em busca de um modelo preditivo coerente em todos os aspectos, diminuindo os falsos negativos e falsos positivos, em busca da otimização dos verdadeiros positivos. Por isto, entendeu-se que, após a escolha do limite ótimo dado pelo modelo HAND, outros parâmetros devem ser utilizados para verificação completa da modelagem.

Bias (**B**)

O coeficiente **B**, bias, Equação 46, verifica em termos de área, a igualdade entre o modelo simulado e o modelo observado (STEPHESON, 2000). Percebe-se facilmente a limitação deste parâmetro, pois comparar valores absolutos de área dos modelos não significa correta predição em termos de verdadeiros positivos. Entretanto, essa métrica é interessante por possibilitar a presença de tendências na modelagem.

$$\mathbf{B} = \frac{\mathbf{FP+VP}}{\mathbf{FN+VP}} = \frac{\mathbf{A_{MS}}}{\mathbf{A_{MO}}} \tag{46}$$

Coeficiente F

Ao contrário da taxa $\mathbf{r_{tp}}$ (ou coeficiente C) que considera o acerto, negligenciando casos de superestimação, o coeficiente **F** ou Fit (%) (BATES E ROO, 2000; HORRITT E BATES, 2002; TAYEFI, 2007; COOK E MERWADE, 2009) inclui possíveis vulnerabilidades do modelo simulado em relação a sub ou a superestimação (JAFARZADEGAN E MERWADE, 2017). Visto que, em seu cálculo, Equação 47, o denominador representado pela área total (união entre dos modelos) assegura que, independentemente do modelo ter simulado muitos Verdadeiros Positivos, é penalizado caso indique altos valores de Falsos Positivos e/ou Falsos Negativos. O coeficiente **F,** quanto mais próximo da unidade, melhor o desempenho do modelo simulado.

$$\mathbf{F} = \frac{\boldsymbol{VP}}{\boldsymbol{VP+FP+FN}} = \frac{\mathbf{A_{MO} \cap A_{MS}}}{\mathbf{A_{MO} \cup A_{MS}}} \tag{47}$$

False Alarm Ratio (**FARatio**)

A métrica de desempenho *False Alarm Ratio* (**FARatio**) ou *Probability of False Alarm*, Equação 48, diferentemente do coeficiente *False Alarm Rate* (**r_{fp}**), mede a razão entre a região de f*alse alarms* sobre a área total inundada do modelo simulado, indicando a predição incorreta do mapa simulado. Um valor ideal para este parâmetro é zero, porém, assim como os outros indicadores estatísticos, dificilmente é alcançado devido às incertezas e particularidades de cada modelo, além da aleatoriedade inevitável (BARNES *et al*., 2007; 2009).

$$\mathbf{FARatio} = \frac{\mathbf{FP}}{\mathbf{FP+VP}} = \frac{\mathbf{A_{MS} - A_{MS0}}}{\mathbf{A_{MS}}} \tag{48}$$

False Negative Rate (r_{fn})

O parâmetro *False Negative Rate* (**r_{fn}**), definido pela Equação 49, indica a taxa de superestimação do erro indesejável, representado pelos falsos negativos em relação a área total do modelo observado. Essa métrica quantifica a porcentagem dos valores *misses*, não preditos pelo mapa simulado como célula inundada. Quanto mais próximo de zero, mais o mapa simulado conseguiu acertar os valores "reais" (MANFREDA *et al*., 2014).

$$\mathbf{r_{fn}} = \frac{\mathbf{FN}}{\mathbf{FN+VP}} = \frac{\mathbf{A_{MO} - A_{MS0}}}{\mathbf{A_{MO}}} \tag{49}$$

True Negative Rate (r_{tn})

O estatístico *True Negative Rate* (**r_{tn}**), calculado por meio da Equação 50, fornece o poder do mapa simulado em predizer as áreas não inundadas (áreas secas), sendo penalizado pelos *pixels* que apresentam falsos negativos. O desejável é atingir valor próximo a unidade (MANFREDA *et al*., 2014).

$$\mathbf{r_{tn}} = \frac{\mathbf{VN}}{\mathbf{VN+FN}} = \frac{\mathbf{A_{SECA}}}{\mathbf{A_{SECA} \cup (A_{MO} - A_{MS0})}} \tag{50}$$

4 RESULTADOS E DISCUSSÕES

O procedimento Geoestatístico foi aplicado nas profundidades de inundação dos eventos de 2010 na cidade de Palmares e de 2017 na cidade de Jaqueira. Para os dados de Palmares, otimizou-se o modelo HAND através da curva ROC, tendo como referência o mapa inferido pela Krigagem Ordinária. Além disso, o desempenho do mapa otimizado pelo modelo HAND foi verificado por meio de métricas estatísticas. Na série de máximos anuais de nível, foram aplicadas análises de tendências e estimativas de probabilidade de recorrência. Com isso, períodos de retorno específicos foram combinados com o modelo HAND, gerando um mapa de perigo. Finalmente, outros eventos ocorridos em Palmares nos anos de 2000, 2011 e 2017 foram simulados segundo as cotas de nível da estação fluviométrica e o algoritmo HAND.

4.1 ANÁLISE GEOESTATÍSTICA

As profundidades de inundação dos eventos de 2010 em Palmares e de 2017 em Jaqueira passaram pelos seguintes procedimentos: limpeza e validação; análises exploratórias e transformação; análise da estacionariedade e remoção de tendências; construção do semivariograma empírico e teórico; validação cruzada e; inferência por meio da Krigagem Ordinária. Ressalta-se que tais processos geraram uma superfície de inundação e de incerteza.

4.1.1 Análise exploratória e transformação dos Dados

Como comentado na sessão metodológica da Geoestatística, a modificação das cotas deve produzir de preferência uma distribuição normal ou pelo menos simétrica com baixa variabilidade dos dados, além de evitar a presença de valores extremos (atípicos). Tais considerações visam preservar-se do enviesamento da inferência causado pela presença de *outliers* ou padrões incertos com alta variabilidade e assimetria. Outro ponto é a redução das variações estatísticas presentes nos semivariogramas. Além disso, há que se considerar a possibilidade de reproduzir o evento da inundação, entendendo a extensão do fenômeno (até onde a água atinge) e a profundidade estática da água.

Dessa forma, percebeu-se como fundamental o uso exaustivo da estatística descritiva por meio de métricas, de gráficos e de testes estatísticos sobre o comportamento dos dados. Tais performances foram essenciais para tomadas de decisão, sendo subsídio para descrever as

particularidades do fenômeno, a distribuição dos conjuntos e o comportamento das amostras no espaço, este último verificando possíveis tendências globais das profundidades de inundação.

Ressalta-se que não há receita pronta e para os eventos modelados foram desenvolvidas ações diferentes, o que torna o processo subjetivo e dependente da amostragem e das características do fenômeno. Outro ponto importante a ser mencionado é que outros caminhos foram seguidos, porém o semivariograma, a validação cruzada, o desempenho da Krigagem Ordinária e as propriedades da inundação não foram melhores que os apresentados adiante.

Neste item apresenta-se um resumo sobre as análises exploratórias e as transformações dos dados realizadas nas profundidades de inundação do aplicativo colaborativo Hidromapp (Jaqueira) e do levantamento realizado pelo Corpo de Bombeiros (Palmares). Os resultados das métricas descritivas e dos gráficos, bem como a discussão detalhada em relação às decisões tomadas se encontram no **ANEXO B**.

Para ambos os conjuntos de dados e para as transformações executadas foram obtidas métricas de posição e de dispersão dos dados brutos e das duas transformações aplicadas, além de análises gráficas verificando a distribuição, a frequência e a presença de *outliers* através do histograma, do gráfico Q-Q e do Boxplot. A normalidade dos dados foi verificada através de quatro testes de hipóteses: Shapiro-Wilk e Anderson-Darling, considerados mais robustos e precisos; Lilliefors e Jarque-Bera, utilizados como testes estatísticos de referência.

Jaqueira

Com relação às profundidades de inundação do evento ocorrido em maio de 2017 no município de Jaqueira, a primeira transformação foi realizada por motivos práticos, em que para cada profundidade se adicionou a elevação do modelo HAND. Entretanto, percebeu-se que a distribuição das transformadas (profundidade de inundação mais altura HAND) apresentava uma assimetria positiva e os testes estatísticos rejeitaram a normalidade dos dados, bem como a presença de *outliers*. Dessa forma, testou-se a transformação logarítmica, a *box-cox* e a Arcsin com o objetivo de modificar tais características para uma distribuição simétrica e normal.

A transformação escolhida foi a logarítmica, pois nos quatro testes houve uma rejeição de não-normalidade dos dados. O histograma apresentou características de uma distribuição normal (Figura 24a) e, com isso, simétrica. Além disso, segundo o gráfico Q-Q (Figura 24b), o comportamento das transformadas variaram em torno da reta sem variações (desvios) significativas, minimizando possíveis tendências.

Figura 24 - Histograma e gráfico Q-Q para o logaritmo das transformadas (m) do evento de 2017 em Jaqueira

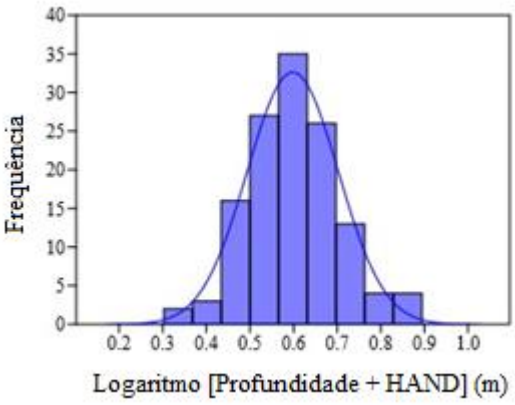

a) Histograma

b) Q-Q *plot*

Fonte: Autor (2021)

Palmares

Antes de qualquer análise sobre a distribuição dos dados acerca do evento de junho de 2010 que ocorreu em Palmares, sublinha-se que diferentemente da amostragem de Jaqueira, a base de dados de Palmares passou por um processo de limpeza e de validação. A princípio, a modelagem prosseguiu sem nenhuma verificação ponto a ponto. Entretanto, no final da modelagem, incoerências foram encontradas no mapa de inundação final, principalmente na superestimação da extensão do evento. Além disso, as métricas de desempenho não indicavam resultados adequados.

Pelos motivos expostos, as 200 amostras foram avaliadas sob dois aspectos. O primeiro é relativo à localização espacial dos pontos, onde verificou-se o endereço de cada ponto com o auxílio das plataformas *Google Earth* e *Google Maps*, dos mapas de setores censitários do IBGE, de sites diversos e de imagens e de vídeos do evento em si. A correção espacial dos pontos foi realizada em *software* SIG, tendo como referência a Ortofoto do PE3D. Outro pormenor estudado relaciona-se às profundidades em relação aos seus vizinhos e às características do fenômeno, buscando profundidades atípicas localmente, as quais poderiam produzir viés local.

Ao todo foram extraídos 12 pontos devido à ocorrência de valores altos em comparação aos vizinhos mais próximos (1 amostra) e amostras sem validação da posição espacial (1 amostra). A maioria dos pontos (10 amostras) excluídos apresentou a seguinte condição: amostra com profundidade igual a zero em regiões altas da cidade, onde já havia amostragem de pontos não inundados (zero), isto é, presença de pontos redundantes.

Por serem pontos não inundados (profundidade igual a zero), estes auxiliam na obtenção da extensão do evento. Entretanto, no processo de amostragem o levantamento continuou em regiões mais altas (não inundadas), introduzindo novos pontos com profundidade zero. Estes pontos aumentavam a variabilidade para distâncias curtas, produzindo semivariogramas irregulares, dificultando o ajuste da função teórica. Como as profundidades foram somadas às alturas HAND, os pontos mais altos (com profundidade de inundação igual a zero) produziram agrupamentos nestas regiões, tendo como resultado a simulação de áreas superestimadas, em que regiões não atingidas eram classificadas como áreas inundadas.

Dessa forma percebe-se que o processo metodológico é intrinsicamente subjetivo. No entanto, indícios para os melhores caminhos a serem tomados podem surgir no semivariograma, na validação cruzada ou até no final da modelagem. Portanto, a calibração e a validação neste processo é continua para reprodução de mapas de inundação coesos e mais próximos da realidade do fenômeno. Por motivos óbvios, a análise exploratória foi realizada somente nos dados que produziram o resultado krigado escolhido.

Após à exclusão dos 12 pontos e da correção da posição espacial das amostras, novas análises exploratórias foram realizadas. Para o conjunto de Palmares, após a soma entre as alturas HAND e as profundidades de inundação, o histograma das transformadas indicou a presença de uma distribuição bimodal, que foi verificada por meio da ocorrência de dois picos.

Verificada a presença de duas possíveis distribuições, as profundidades foram estudadas por região. Comprovou-se que na porção leste da cidade as profundidades foram menores em relação à parte oeste. Dessa forma, realizou-se análises através dos histogramas sobre os dois conjuntos, separando-os espacialmente e, de fato, encontraram-se distribuições distintas. Apesar de existir sentido matemático e estatístico ao dividir o conjunto em dois subconjuntos e modelá-los por setores, optou-se por um desenvolvimento único, principalmente por causa da quantidade de amostras, visto que o semivariograma é melhor representado quanto mais pontos forem utilizados no processo. Cabe comentar também que esta perspectiva evidencia que espacialmente as profundidades de inundação do evento de 2010 ocorrido em Palmares são não estacionárias.

Com a presença de uma distribuição bimodal, percebeu-se que improvavelmente as transformadas apresentariam uma distribuição normal. Decerto, como comentado anteriormente, a normalidade dos dados não é um pressuposto para o uso da Krigagem Ordinária e apesar de não ter sido atingida, buscou-se uma nova transformação. Neste sentido, optou-se pela transformação *box-cox* com parâmetro de potência igual a 2,39. Embora, a distribuição tenha permanecido bimodal (Figura 25a), certos aspectos positivos foram

alcançados: destaca-se a diminuição da variabilidade dos dados e da assimetria negativa, remoção de valores extremos atípicos e da minimização das distâncias das profundidades em relação à reta (em vermelho), apresentado no gráfico Q-Q (Figura 25b).

Figura 25 - Histograma e gráfico Q-Q para o Box-Cox das transformadas (m) do evento de 2010 em Palmares

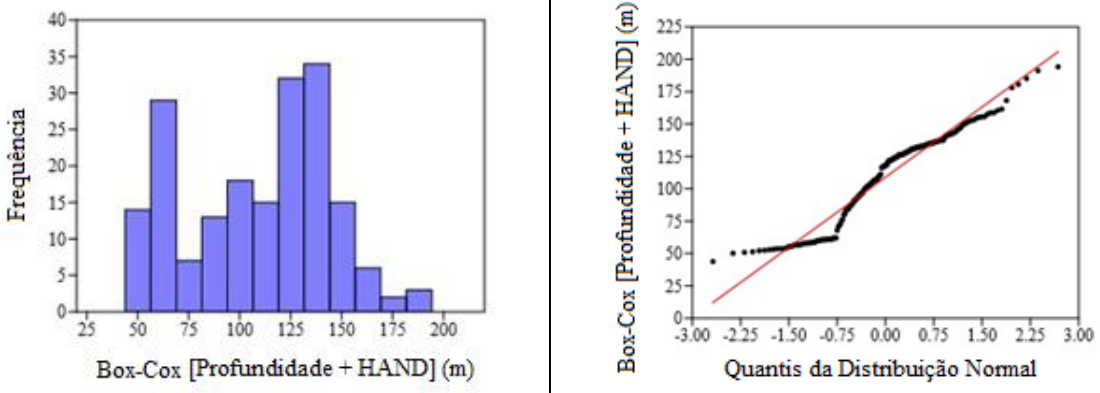

a) Histograma b) Q-Q *plot*

Fonte: Autor (2021)

4.1.2 Análise da estacionariedade e remoção de tendências

Como abordado, o efeito da estacionariedade das hipóteses intrínsecas é condição elementar na inferência probabilística através da geoestatística, porém sua investigação perpassa um problema singular: há somente um acontecimento da função aleatória. Esta simples condição promove a impossibilidade de legitimar (ou não) a estacionaridade na prática, contudo existem indicativos concedidos pelas amostras no domínio estudado que impõem pistas sobre o fenômeno.

Tais indícios são subjetivos e, assim como na análise exploratória, existem decisões que podem produzir (ou não) semivariogramas estáveis e, com isso, inferências confiáveis com precisão adequada e baixa incerteza. Novamente salienta-se que os desempenhos nas etapas subsequentes podem apontar coerência no julgamento do analista. A estacionariedade das hipóteses intrínsecas foi investigada por meio dos gráficos de tendências, em que as profundidades (eixo Z) são plotadas nos planos XZ e YZ para diferentes rotações, verificando-se a presença de padrões globais através de polinômios que podem assumir o primeiro, o segundo e o terceiro grau.

De antemão, a estacionaridade observada em gráficos de tendência indica semelhança no comportamento de séries temporais – entendimento mais comum. Com isso, espera-se que as amostras flutuem aleatoriamente em torno de uma média constante, sem apresentar

tendências para uma dada direção. Na contraparte da estacionariedade, a média varia no espaço (tempo – ideia similar), de modo que as oscilações do atributo percorram valores centrais que se desenvolvem segundo curvas lineares, parabólicas ou cúbicas.

Buscou-se verificar o comportamento regional das superfícies de tendências, as quais devem ser explicadas pelos valores das amostras. Foram realizadas interpretações visuais em relação ao padrão espacial dos dados segundo polinômios. Dessa forma, visando o melhor ajuste às amostras, escolheu-se o polinômio de terceiro e de segundo grau para as profundidades de inundação de Jaqueira e de Palmares, respectivamente. Ressalta-se que os gráficos de tendência e o mapa de superfície de tendência, bem como explicações sobre o procedimento adotado podem ser consultados no **ANEXO B**.

As superfícies de tendência construídas possibilitam o tratamento da não estacionariedade ao retirar a variação global dos dados. Desse modo, os resíduos (variações locais) estacionários podem ser modelados para criação do semivariograma e inferência probabilística.

4.1.3 Semivariograma e a Validação Cruzada no processo de decisão

Com exceção dos semivariogramas empíricos e teóricos, os parâmetros de busca e da curva teórica, o mapa do semivariograma, as métricas e os gráficos obtidos na Validação Cruzada podem ser visualizados no **ANEXO B**.

Jaqueira

O resultado da modelagem do semivariograma empírico e teórico dos resíduos dos dados de Jaqueira foi realizado em dois cenários A e B. No primeiro momento, as 130 amostras foram utilizadas, porém como será visto adiante, percebeu-se certas inconsistências no semivariograma e na etapa da Validação Cruzada (VC). Com isso, foram excluídas 7 amostras do conjunto e por meio das 123 restantes construiu-se o cenário B. Isto implicou em uma melhora no semivariograma e nas métricas de performance da Validação Cruzada. Além disso, nos mapas finais da Krigagem houve uma diminuição da variância (incerteza) e desempenhos melhores foram obtidos no mapa da profundidade de inundação.

O semivariograma empírico e teórico do cenário A e B foi construído seguindo as regras descritas no item Semivariograma Empírico e Teórico são indicados no item 3.3.2. Escolhidos os parâmetros de procura das semivariâncias empíricas e a curva que visualmente explicou as

nuances das semivariâncias médias, o semivariograma teórico foi ajustado automaticamente pelo método dos mínimos quadrados, produzindo o gráfico do semivariograma (Figuras 26 e 27), a superfície de semivariância e os parâmetros do modelo ajustado.

Para os dois cenários, os semivariogramas empíricos mostraram a existência da continuidade espacial (correlação), porque as semivariâncias cresceram com o aumento da distância e, no geral, este efeito é o mais esperado devido à regularidade das semivariâncias e evidências da presença de estacionariedade da covariância (variância), resultando no melhor ajustamento da curva matemática teórica.

Os semivariogramas teóricos (curva em azul) das curvas esférica (Figura 26) e exponencial (Figura 27) conseguiram descrever as particularidades da dependência espacial dos resíduos segundo o ajuste do modelo em relação às semivariâncias empíricas (cruzetas em azul).

Apesar do bom ajuste do modelo para o cenário A, algumas flutuações irregulares foram encontradas nas semivariâncias médias (cruzetas azuis), a exemplo do quinto ponto (por volta de 70 metros) e do oitavo ponto (em torno de 120 metros) da esquerda para direita. Estas variações são causadas por pares amostrais de alta variabilidade que aumentam ou diminuem a semivariância média, principalmente pelos dados extremos. Outro aspecto a ser destacado é que o oitavo ponto está na região de descontinuidade espacial (sem correlação). Esta anormalidade pode ter ocasionado o alcance relativamente pequeno (90 metros), visto que depois da correlação espacial, o sétimo ponto ainda indica certa regularidade, o que torna o oitavo ponto, possivelmente, o responsável por iniciar a desarmonia gráfica (sobe e desce das semivariâncias médias).

Do ponto de vista das semivariâncias empíricas por células (pontos em vermelho), verifica-se de maneira mais clara as regiões que comprometem o semivariograma do cenário A, gerando flutuações indesejadas. Como pode ser visto no semivariograma (Figura 26), os pontos vermelhos com semivariâncias altas podem causar enviesamento da curva teórica e, consequentemente, no modelo final. Alguns exemplos podem ser visualizados acima da segunda, da quarta, da sexta e da sétima semivariância média (cruzetas em azul).

Devido à presença de irregularidades no semivariograma, prosseguiu-se para a etapa da Validação Cruzada em busca de indicativos dos pontos que instabilizaram o semivariograma. Apesar da VC ser passível de análises incoerentes, visto que a própria variabilidade do fenômeno pode causar erros inevitáveis, a exemplo de pontos discrepantes em regiões de *clusters*. Retirar conclusões fundamentadas nos dados e no processo de Krigagem, ainda que indiretamente, é mais sofisticado e compreensível do que deduzir sem metodologias consolidadas.

Dentre as métricas obtidas na VC, a análise do erro normalizado (divisão entre o erro dos valores medidos e estimados sobre a raiz quadrada da variância da Krigagem) por meio do gráfico Q-Q foi a opção mais clara dos pontos que produziram maior enviesamento e interferências sobre o semivariograma do cenário A. Com isso, os pontos que apresentaram baixa confiança e que influenciaram as semivariâncias altas na curta distância e na regularidade das semivariâncias médias foram excluídos do processo de modelagem do semivariograma, gerando o cenário B. O gráfico Q-Q para os cenários A e B podem ser visualizados nas Figuras 28a e 28b, respectivamente. Analisando os dois gráficos, percebeu-se que houve uma melhora significativa no ajuste dos erros normalizados a uma distribuição normal, principalmente nos extremos.

Para o cenário B, os parâmetros de busca escolhidos evidenciaram o comportamento desejável do semivariograma empírico (Figura 27), destacando a presença de correlação espacial, da estacionariedade, da regularidade das semivariâncias médias, principalmente na variabilidade das curtas distâncias. Este padrão promoveu melhora no ajuste do semivariograma teórico (Figura 27) através dos mínimos quadrados, em que se observou a minimização dos desvios das semivariâncias empíricas em relação à curva teórica.

Com a retirada das amostras foi evidenciado: um efeito pepita igual a zero (ideal) indicando que a decisão tomada surtiu efeito positivo; nas distâncias próximas a 70 e 120 metros (flutuações irregulares do cenário A) ocorreu uma melhora significativa das semivariâncias médias, apesar de ainda ter sido verificado variâncias por células altas; um aumento da continuidade espacial representada pelo alcance do semivariograma teórico.

Figura 26 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira para o cenário A

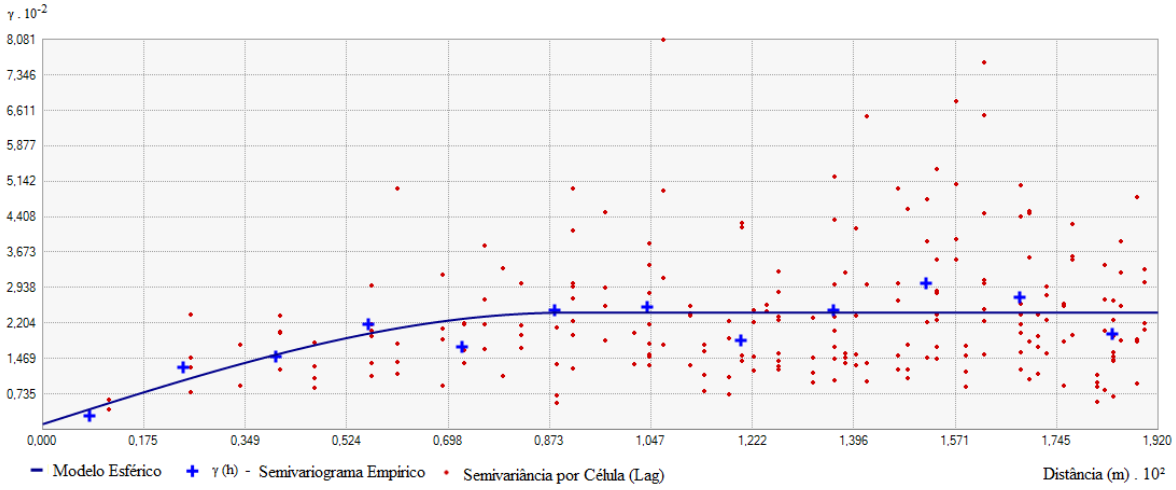

Fonte: Autor (2021)

Figura 27 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira, após a exclusão de 7 pontos, cenário B

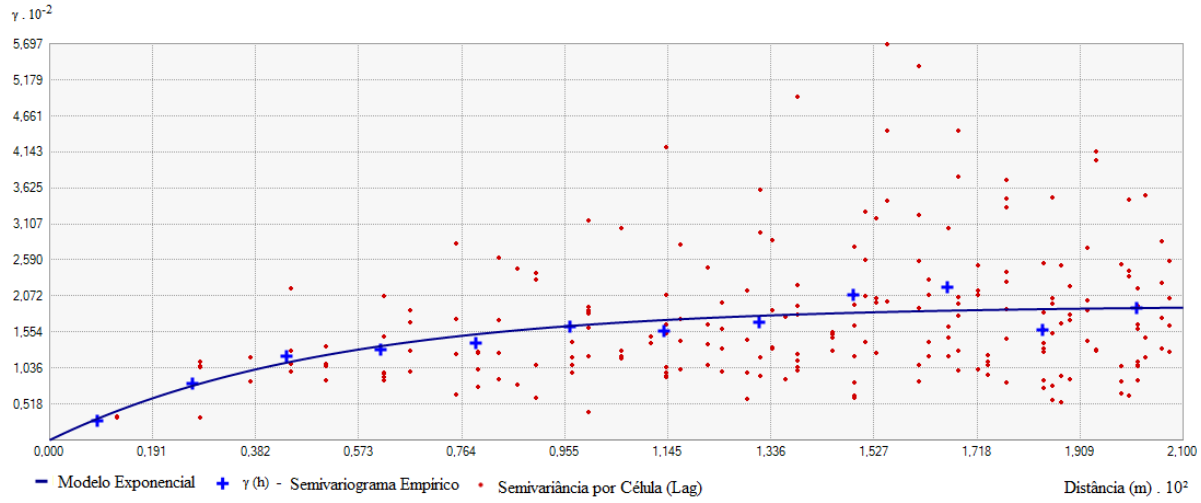

Fonte: Autor (2021)

Figura 28 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2017 em Jaqueira para o cenário A e o cenário B

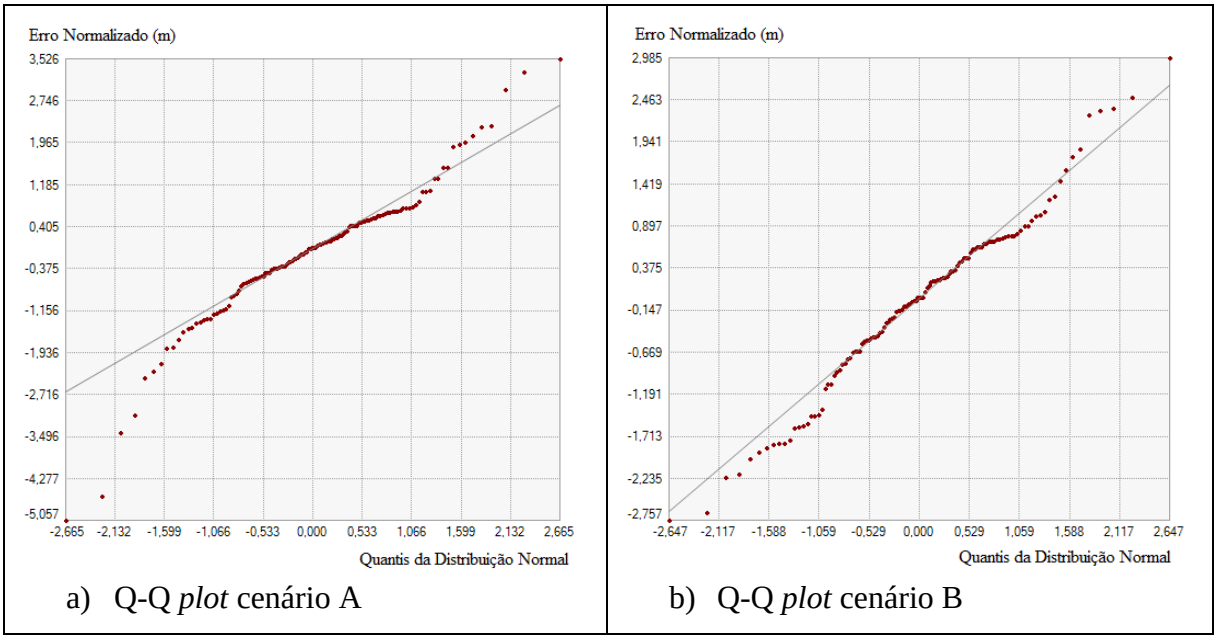

a) Q-Q *plot* cenário A

b) Q-Q *plot* cenário B

Fonte: Autor (2021)

Palmares

No caso de Palmares foram gerados dois cenários, um isotrópico (cenário C) e outro anisotrópico (cenário D). Distintamente dos dados de Jaqueira, o modelo com os 188 resíduos mostrou semivariâncias regulares, não sendo necessário realizar o mesmo procedimento de exclusão de amostras na etapa de construção do modelo semivariográfico.

Os semivariogramas dos cenários C e D podem ser visualizados nas Figuras 29 e 30, nesta ordem. Os indícios sobre a decisão de avaliar o desempenho dos resíduos através de um modelo anisotrópico (cenário D) foram descritos no **ANEXO B**.

No cenário C, analisando a estrutura do semivariograma empírico, percebeu-se o comportamento desejável da estrutura espacial através do crescimento da variabilidade conforme o aumento das distâncias entre as amostras. Observou-se também a presença de poucas semivariâncias na pequena escala que é indesejável, porém o uso de lags menores apresentaram flutuações irregulares no gráfico, o que prejudicou o ajuste automático do semivariograma teórico, além de ter produzido pequenas distâncias (alcance) para continuidade espacial. Outra constatação foi que dentro da estrutura espacial até 200 metros as semivariâncias por célula e médias se apresentaram próximas entre si, indicando a possibilidade coerente para geração de um modelo isotrópico. Por fim, depois de 200 metros, as semivariâncias por célula passaram a exibir valores baixos e altos de forma regular, revelando existir possível anisotropia.

Sobre o efeito pepita, verificou-se que não existem semivariâncias próximas a zero. Entretanto isto está relacionado com a amostragem das profundidades de inundação, de modo que as distâncias entre os pontos coletados não puderam descrever a variabilidade na pequena escala. Ressalta-se que os pontos das semivariâncias na curta distância indicaram a existência de um efeito pepita alto e possibilitaram coerente ajuste para obtenção do valor deste parâmetro.

Com relação ao cenário D, o ajuste das curvas teóricas sobre as semivariâncias empíricas para o caso anisotrópico ocorreu por meio da geração de 16 direções, variando os ângulos em 11,25º a partir do 0º(norte) até 180º(sul). As curvas teóricas em azul (Figura 30) apontaram um modelo gaussiano com anisotropia geométrica, ou seja, quando o patamar é igual em todas as direções. O eixo de maior continuidade espacial encontrado foi o de 143º (curva com menor semivariância) e o de menor correlação espacial 53º (curva com maior variabilidade). Além de apontar a menor variância, o eixo de maior dependência espacial apresenta maior alcance (745 m).

Os semivariogramas empíricos e teóricos para a direção de maior (Figura 31a) e de menor (Figura 31b) dependência espacial foram consolidados por meio do ajuste das semivariâncias por célula (em vermelho). Por se tratar de um modelo anisotrópico geométrico, o ajuste da curva depende somente do alcance. Dessa forma, quanto menor a distância de correlação espacial maior a inclinação da curva, captando semivariâncias altas. O contrário promoverá menor variabilidade, ou seja, modelo teórico de maior continuidade espacial.

Outros aspectos verificados foram a regularidade das semivariâncias para o eixo de maior dependência espacial, onde houve um crescimento da variância de modo brando,

enquanto a variabilidade no sentido de menor correlação cresceu com maior rapidez, resultando em certa irregularidade. Além disso, como era esperado, os pontos de semivariâncias foram melhor ajustados para a direção de 143º, visto que esta direção foi a mais importante para o semivariograma por apresentar maior continuidade espacial.

Apesar das métricas extraídas da Validação Cruzada (**ANEXO B**) apontarem na maioria delas, que o cenário C apresentou melhor performance, escolher o modelo somente com os resultados da VC pode ser uma decisão precipitada. Isso porque as análises referentes ao processo metodológico ocorrem sobre pontos conhecidos, desprezando todo o domínio. Assim, torna-se necessária a visualização e a interpretação de desempenhos estatísticos sobre as inferências (profundidades de inundação e confiança) nas regiões não amostradas, em busca de resultados mais precisos. Por estes motivos, os cenários C e D foram utilizados para a construção dos mapas de inundação e o de incerteza, apresentados no próximo item.

Figura 29 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário C

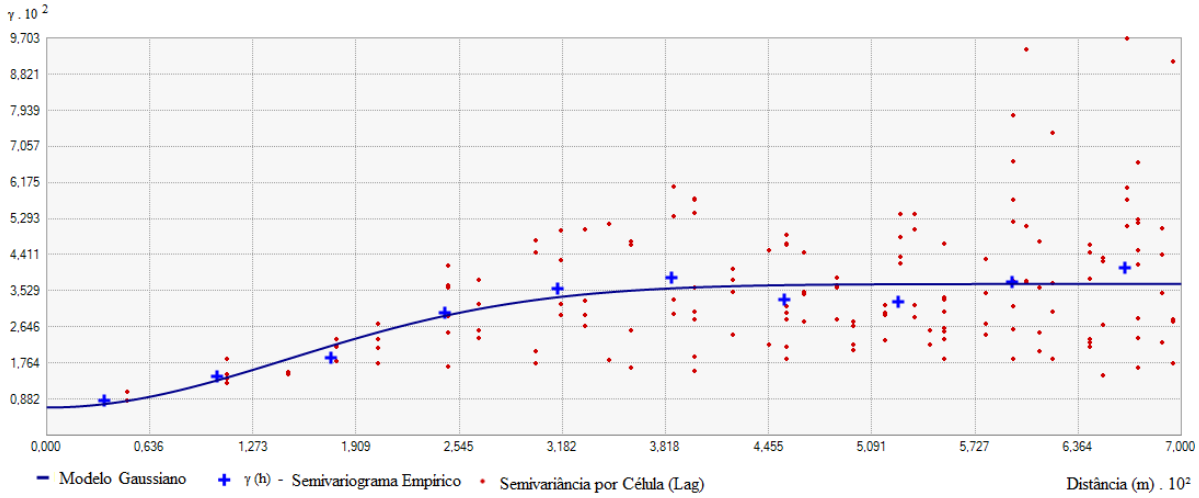

Fonte: Autor (2021)

Figura 30 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário D

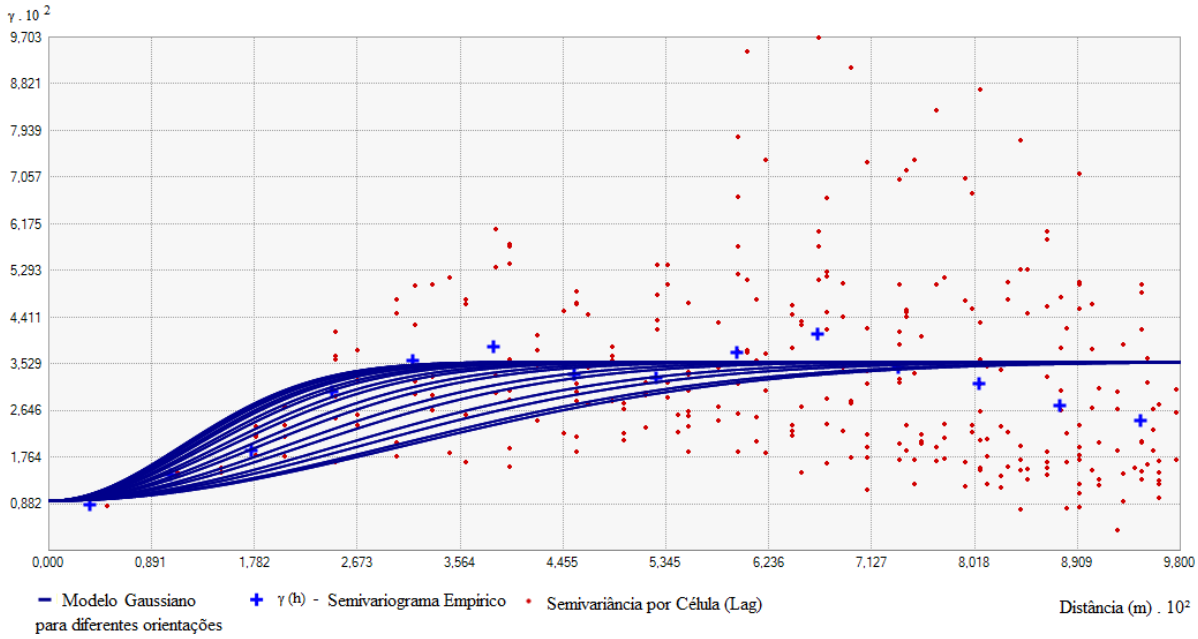

Fonte: Autor (2021)

Figura 31 - Semivariogramas empíricos e teóricos para os resíduos de 2010 em Palmares para as direções de maior e de menor continuidade do modelo anisotrópico (cenário D)

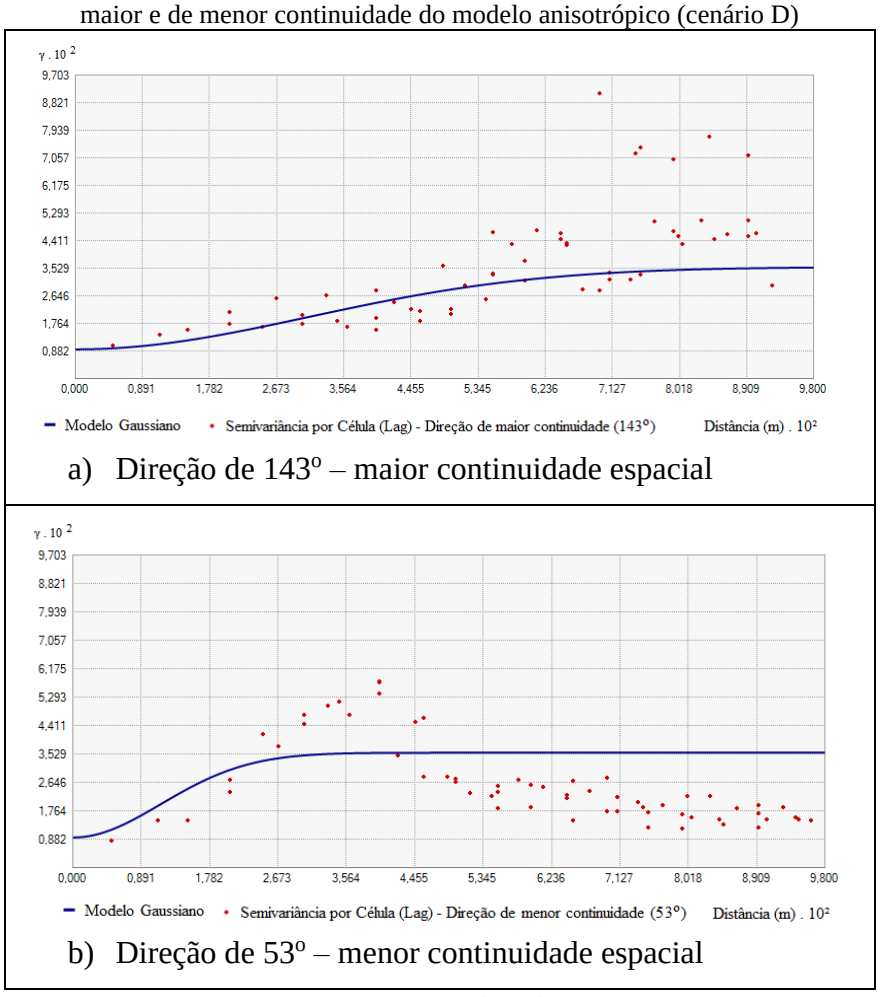

Fonte: Autor (2021)

4.1.4 Mapas de inundação e de incerteza

Na aplicação da inferência probabilística por meio da Krigagem Ordinária foram decididos os seguintes aspectos: estimação por *pixel* com resolução espacial de 1m; circunferência (caso isotrópico) e elipse (caso anisotrópico) com 4 setores rotacionados em 45º. Escolheu-se no mínimo 2 e no máximo 5 vizinhos mais próximos para cada setor e adotou-se raio de busca flexível (em certas regiões maior que o alcance) devido à irregularidade da amostragem.

Jaqueira

A inferência das amostras do evento de 2017 em Jaqueira para o cenário B sobre as condições descritas anteriormente produziu o mapa das profundidades de inundação (Figura 32). Inicialmente, a condição mais comum esperada dos eventos de cheia foi representada adequadamente, visto que as profundidades mais altas ocorreram no rio e diminuíram no sentido perpendicular a direção do fluxo.

Nas profundidades sobre o canal (células em azul escuro) percebeu-se uma concentração de valores mais altos nas regiões Sudoeste e Nordeste com diminuição das profundidades no rio entre elas. Isto acontece por causa do enviesamento da amostragem, falta de observações sob o rio e da particularidade causada pelo modelo HAND, o qual é influenciado pela baixa qualidade da tecnologia LIDAR no levantamento de dados do terreno abaixo da água.

Outro ponto interessante observado foram os *pixels* aglomerados formando “ilhas” no centro da imagem, tanto para os *pixels* secos (ao redor de áreas inundadas), quanto para as celuladas inundadas (com vizinhos secos), que apesar de pequenas devem ser comentadas. Tal ocorrência pode ter sido originada pelas condições da amostragem, da modelagem, do evento, da superfície topográfica, bem como dos dados de entrada.

Analisando a distribuição das estimativas (Figura 33), percebe-se que houve mudanças em comparação com a distribuição amostral. Segundo Yamamoto (2020), a Krigagem Ordinária pode reproduzir a suavização da estimativa, de modo que as distribuições sejam dispares, dificultando análises mais acuradas, principalmente nos extremos. O autor comenta que há uma perda na precisão global, porém que existem técnicas para a correção da suavização da KO.

Apesar da não similaridade entre as duas distribuições no caso estudado, isto ocorreu por causa da introdução do modelo HAND na modelagem. Na realidade, tal situação era

prevista, por causa da combinação de dados (profundidades de inundação e altura HAND) com diferentes distribuições. Porém, em virtude dos pormenores práticos que motivaram o uso do modelo digital na transformação dos dados, aceitou-se esta condição como possível desvantagem, posto que corrigir o efeito de suavização segundo a distribuição amostral pode causar enviesamento, especialmente nas regiões em que a amostragem não foi possível ser realizada.

De um modo geral, as profundidades forneceram a intensidade do evento sobre a sede municipal do município de Jaqueira em 2017, tendo como maior preocupação a inferência na margem esquerda do rio Piranji. Nesta porção territorial, milhares de pessoas ficaram desabrigadas devido à cheia de 2017. Para se ter uma noção do possível dano causado, na Figura 34 se verifica a extensão da superfície inundada.

Figura 32 - Mapa das profundidades de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B)

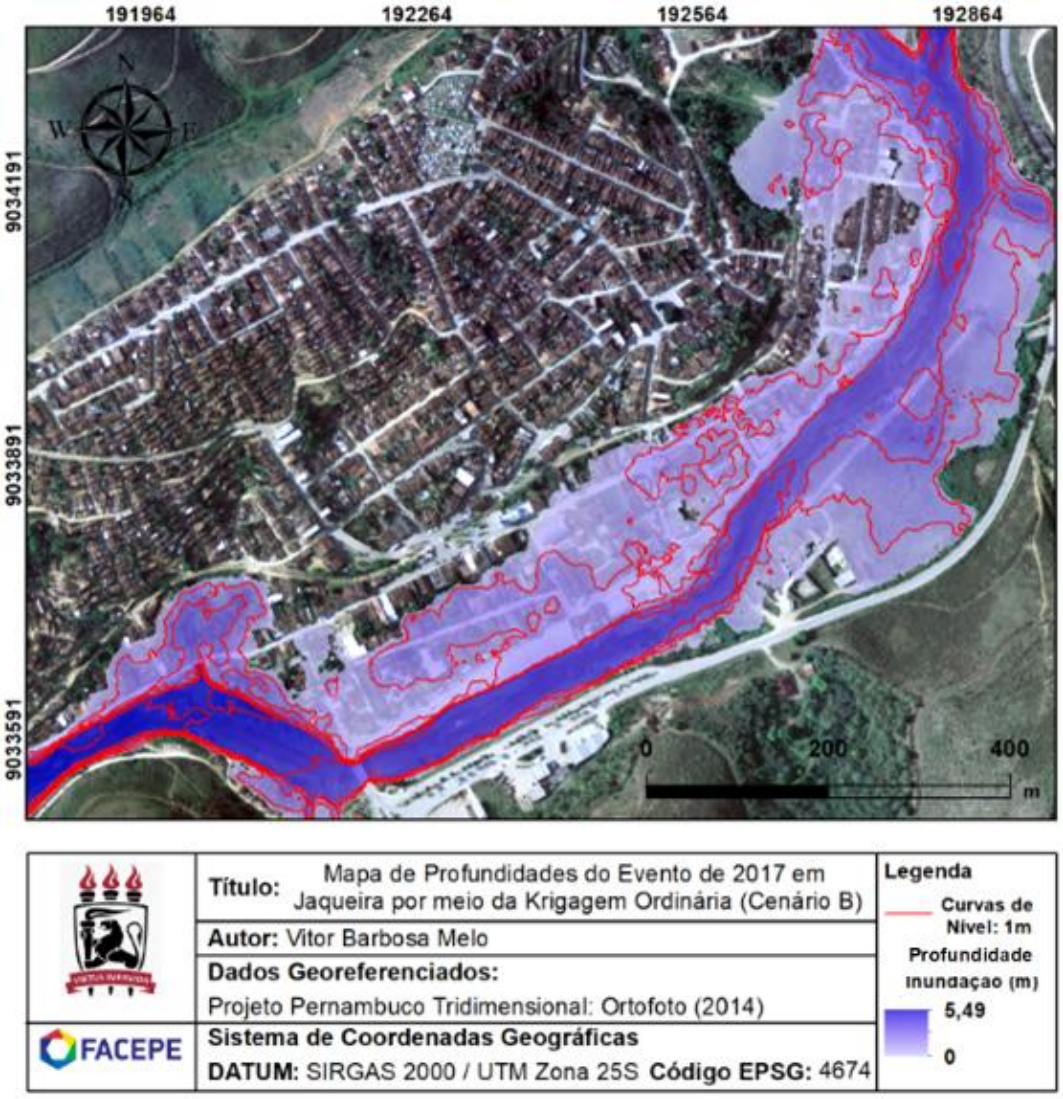

Fonte: Autor (2021)

Figura 33 - Histograma das profundidades de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B)

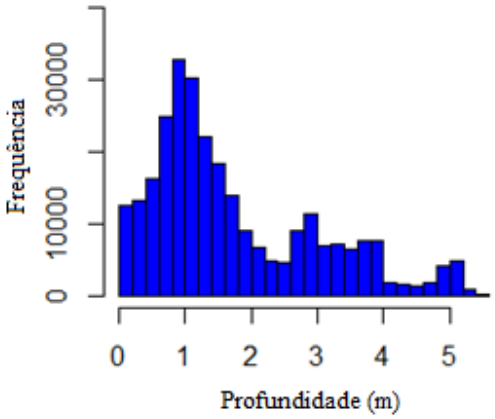

Fonte: Autor (2021)

Figura 34 - Mapa da superfície de inundação do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B)

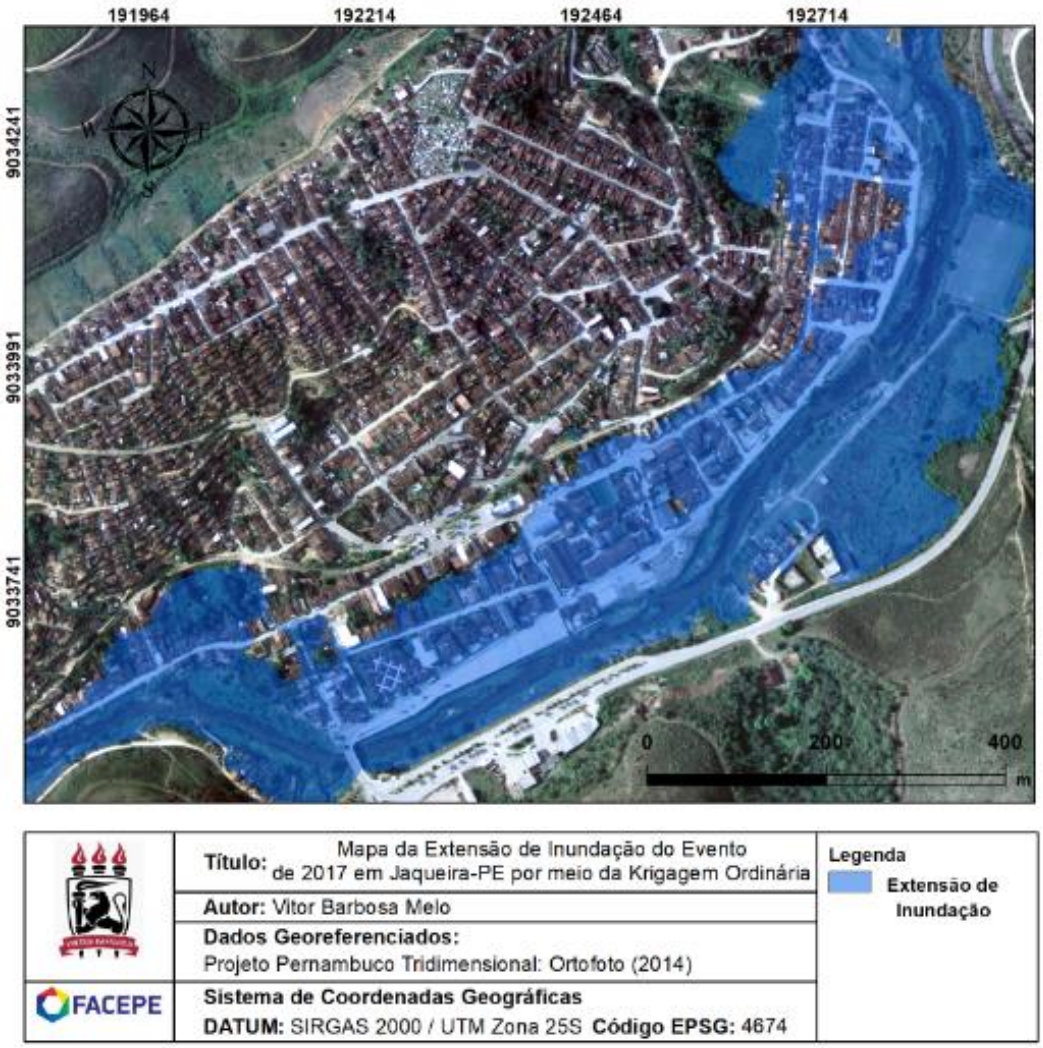

Fonte: Autor (2021)

Com relação ao desempenho nos pontos conhecidos, a KO se apresentou como um preditor exato localmente. Na tabela 2, aponta-se o resumo dos indicadores estatísticos sobre o erro da inferência e a correlação entre a estimativa e os valores medidos.

Os 5 primeiros parâmetros relacionados ao erro indicaram proximidade a zero, o que representa bons resultados sobre a acurácia do modelo. Conforme Li e Heap (2011), a **ME** deve ser verificada cautelosamente, visto que os valores positivos e negativos podem equilibrar o resultado, sendo mais utilizado como medida de viés ou bias. A **RMSE** mostra o tamanho do erro em média, entretanto são sensíveis aos erros extremos. Em contrapartida, a **MAE** é menos susceptível aos *outliers* e estabelece até que ponto a estimativa pode estar incorreta, visto que os erros são absolutos.

Tendo isso em mente, apura-se que: a **ME** indica um ínfimo viés em média de subestimação; a variância dos erros foi minimizada, sendo este um dos pressupostos para a otimização da Krigagem; a estimativa em média errou aproximadamente 1 cm (**MAE**); o **RMSE** foi adequado, não havendo a presença de extremos que provocasse seu aumento, o que pode ser comprovado pela pequena variância dos erros.

Como apresentado previamente, a distribuição global não foi análoga à distribuição amostral. No entanto, localmente a inferência apresentou comportamento similar. Percebe-se que a variância das estimativas foi próxima à variabilidade das amostras observadas (**RVar** aproximadamente igual à unidade). Do ponto de vista da qualidade da capacidade de predição do modelo, o resultado do coeficiente de correlação indica que KO conseguiu predizer os valores das amostras de maneira quase perfeita (**R** = 1) e, o coeficiente de determinação ($\mathbf{R^2}$) exibiu que cerca de 100% da estimativa do modelo explicou a variância dos valores medidos em torno de sua média. Graficamente, a relação entre os valores medidos e observados podem ser vistos na Figura 35.

Tabela 2 - Medidas de desempenho para o cenário B

Média dos Erros (ME)	-0,0042
Variância dos Erros (Var)	0,0002
Média dos Erros Absolutos (MAE)	0,0091
Raiz Média dos Quadrados dos Erros (RMSE)	0,0147
Variância dos Estimados (Var)	0,4635
Relação entre as Variâncias (RVar)	0,9892
Coeficiente de Correlação (R)	0,9998

Continuação: Tabela 2 - Medidas de desempenho para o cenário B

Coeficiente de Determinação (R^2)	99,96%

Fonte: Autor (2021)

Figura 35 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2017 em Jaqueira

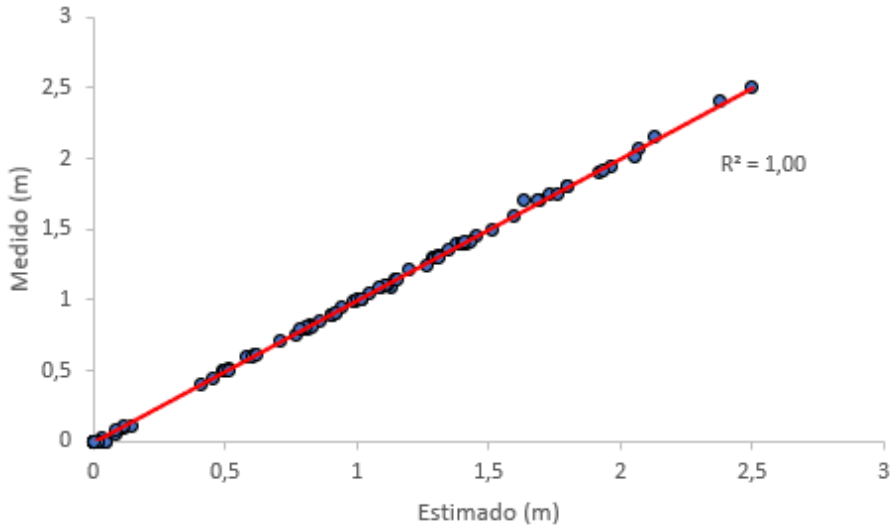

Fonte: Autor (2021)

No que concerne à confiança do modelo retratada pela variância da Krigagem, indicada na Figura 36 (o recorte da incerteza foi dado para uma área correspondente à extensão do evento mais um prolongamento de 30 m), tem-se localmente boa precisão da estimação que pode ser evidenciada pelas células em vermelho escuro, principalmente nos locais próximos a amostras. Além disso, nas regiões ricas em amostras, a incerteza tende a ser menor.

Analisando o mapa, percebeu-se que o erro foi mais significativo na porção sudoeste e central. Nestes espaços, apesar de exibir uma quantidade de observações coerente, o levantamento foi clusterizado, isto é, pouco espaçado. Tais indícios refletem a necessidade de novos pontos, devido à presença de populações (áreas de riscos) e, com isso, a minimização da incerteza.

Por fim, evidencia-se a distribuição do erro da predição por meio do histograma da Figura 37. A incerteza das estimativas foi mais recorrente no intervalo entre 0,3 a 0,5 m. Embora se deseje que o modelo apresente maior frequência próximo a zero, particularidades da amostragem e da modelagem do semivariograma impossibilitam reduções no valor global da incerteza da inferência.

Figura 36 - Mapa de incerteza do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B)

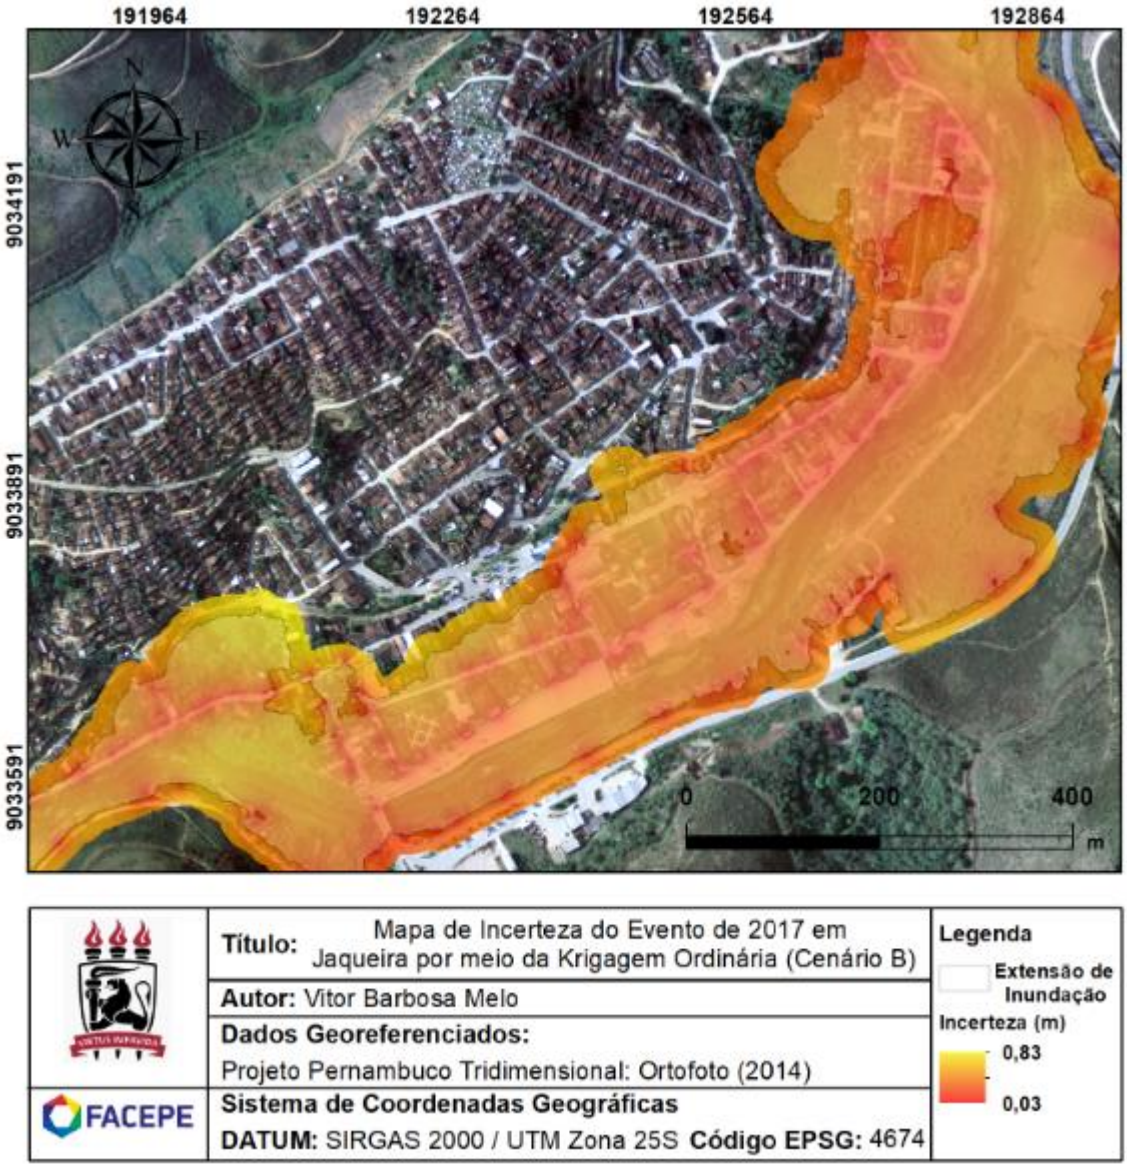

Fonte: Autor (2021)

Figura 37 - Histograma da incerteza do evento de 2017 em Jaqueira por meio da Krigagem Ordinária (cenário B)

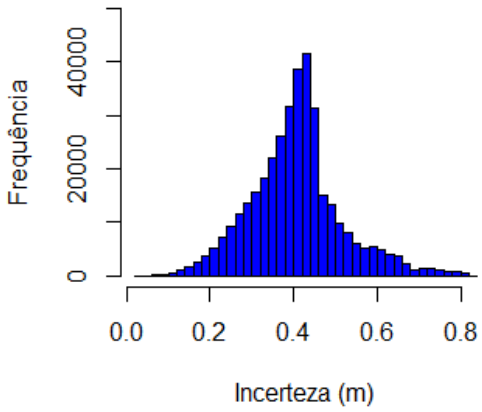

Fonte: Autor (2021)

Palmares

No evento de 2010 em Palmares foram analisados o cenário C e o Cenário D. A decisão para a escolha do modelo final se baseou nos desempenhos estatísticos locais como analisado no modelo de Jaqueira e na diferença entre a incerteza da Krigagem dos modelos. Inicialmente, o resultado das estimativas da Krigagem Ordinária para os cenários C e D podem ser visualizados nas Figuras 38 e 39, respectivamente. Visualmente, o fenômeno pôde ser representado devidamente em ambos os casos, exceto por causa da ocorrência das "ilhas" de *pixels*. Certamente este problema está vinculado com as propriedades da amostragem, da modelagem e do Modelo HAND.

Além disso, após à inundação, a cidade passou por transformações como a retirada de propriedades em áreas de risco, a construção de uma orla fluvial e a dragagem do rio Una, readaptando o terreno fluvial (ALVES, 2017). Tais situações geraram movimentações de terra e, com isso, a topografia do terreno em 2014 (levantamento do PE3D) representada pelo MDT apresenta diferenças em relação ao estado da superfície em 2010. Este aspecto influencia no MDT e consequentemente no modelo HAND e no mapa final krigado, visto que promoveram alterações na referência tanto dos pontos da amostragem (coleta em 2010, pós-evento), quanto na altimetria do MDT.

A inundação de 2010 chegou a encobrir vários imóveis. Para algumas áreas residenciais e comerciais, a água elevou-se a mais de 3 m, profundidade suficiente para promover a submersão de propriedades (residências e estabelecimentos comerciais térreos). Nas regiões mais próximas ao rio Una, principalmente nas porções oeste e sudoeste dos mapas, a água atingiu mais de 7 metros. O estrago possivelmente não foi maior, porque há uma barreira natural – maiores elevações – na chegada do rio à cidade. Destaca-se ainda a extensão do evento para o cenário C (Figura 40) e D (Figura 41), permitindo a percepção do alcance da água, atingindo boa parte da área urbana do município de Palmares.

Comparando os mapas das profundidades e da extensão para os dois modelos, os resultados foram relativamente próximos com duas diferenças mais claras. A primeira foi a ocorrência de profundidades maiores no cenário C, tendo o valor máximo cerca de 25 cm maior. A segunda foi sobre a extensão do cenário C que exibiu uma área levemente maior que o modelo D, em torno de 0,3 km².

A respeito das distribuições dos cenários C (Figura 42) e D (Figura 43), verifica-se que apesar de apresentarem formas similares, o cenário C indicou maiores frequências nos intervalos de 2 a 4m e de 4 a 6m, enquanto o cenário D foi mais recorrente para as profundidades

nos intervalos de 0 a 2m e de 6 a 8 m. Tais dissimilaridades ocorrem em consequência do semivariograma, do aspecto anisotrópico e do raio de busca das amostras mais próximas, no caso do cenário D simbolizada por uma elipse.

Ainda que as diferenças globais entre os modelos analisados possam ser mensuradas e avaliadas, a escolha do melhor cenário sobre este ponto de vista não possibilita uma decisão evidente, pois a distribuição amostral foi modificada pela presença do modelo HAND, impedindo a comparação e por causa do desconhecimento dos valores reais sobre os pontos inferidos. Dessa forma, recorreu-se às análises locais e aos mapas de incerteza da Krigagem como descrito adiante.

Figura 38 - Mapa das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C)

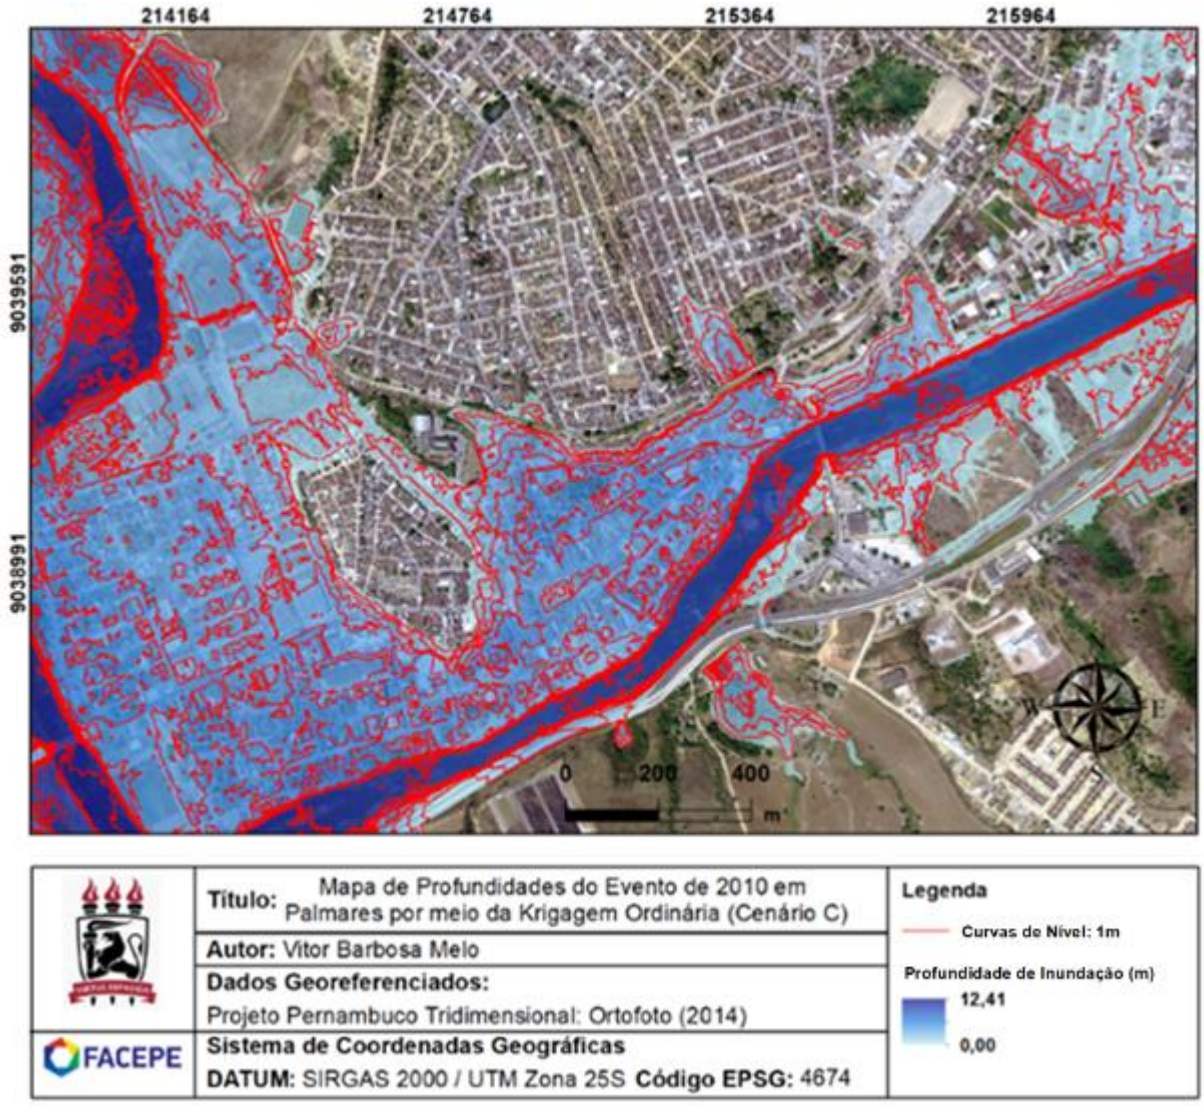

Fonte: Autor (2021)

Figura 39 - Mapa das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D)

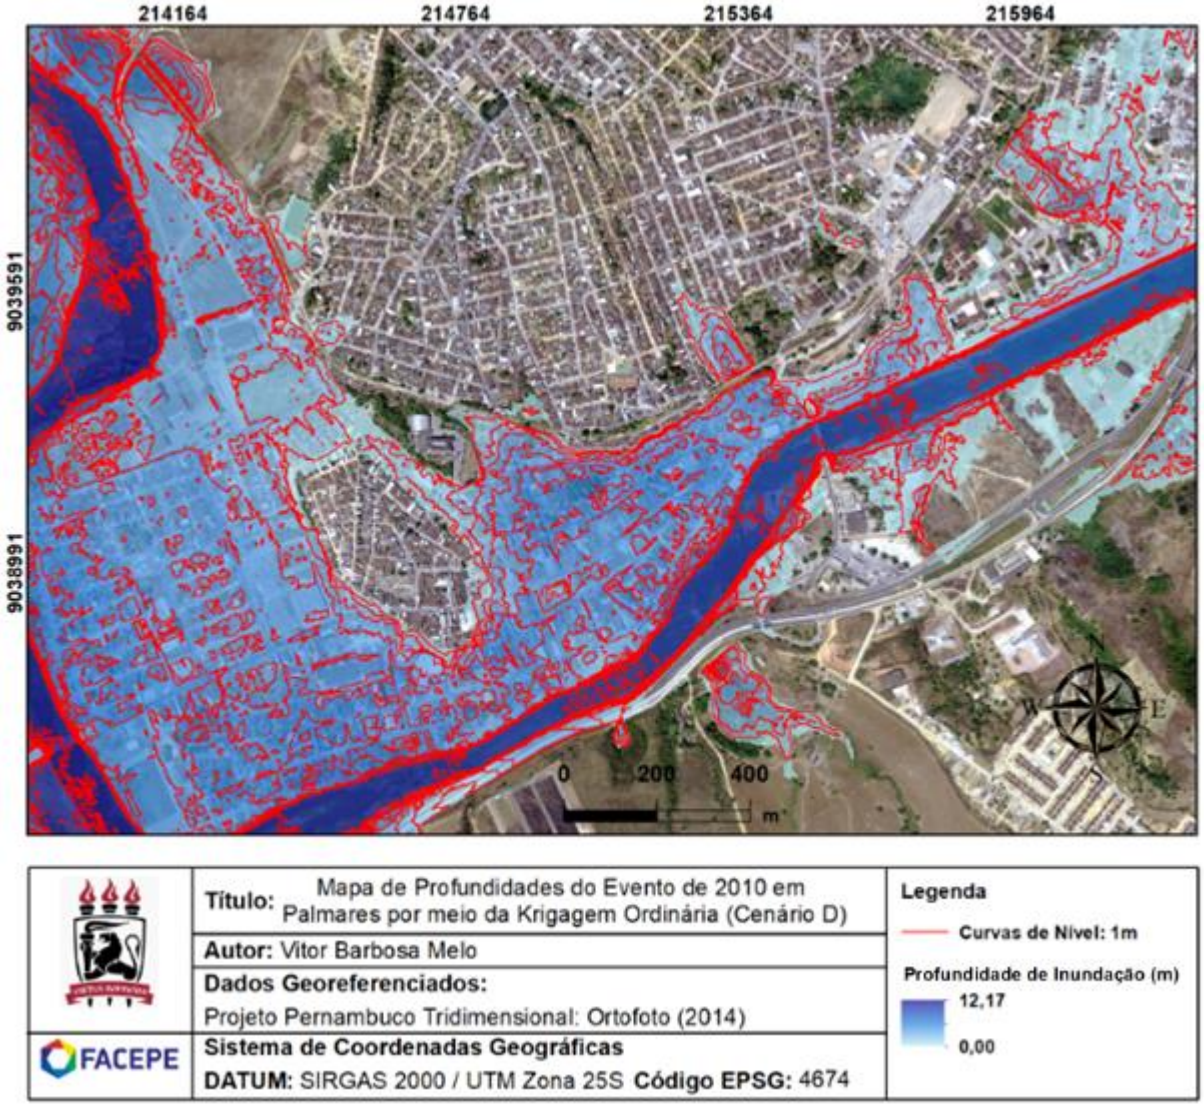

Fonte: Autor (2021)

Figura 40 - Mapa da superfície de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C)

Fonte: Autor (2021)

Figura 41 - Mapa da superfície de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D)

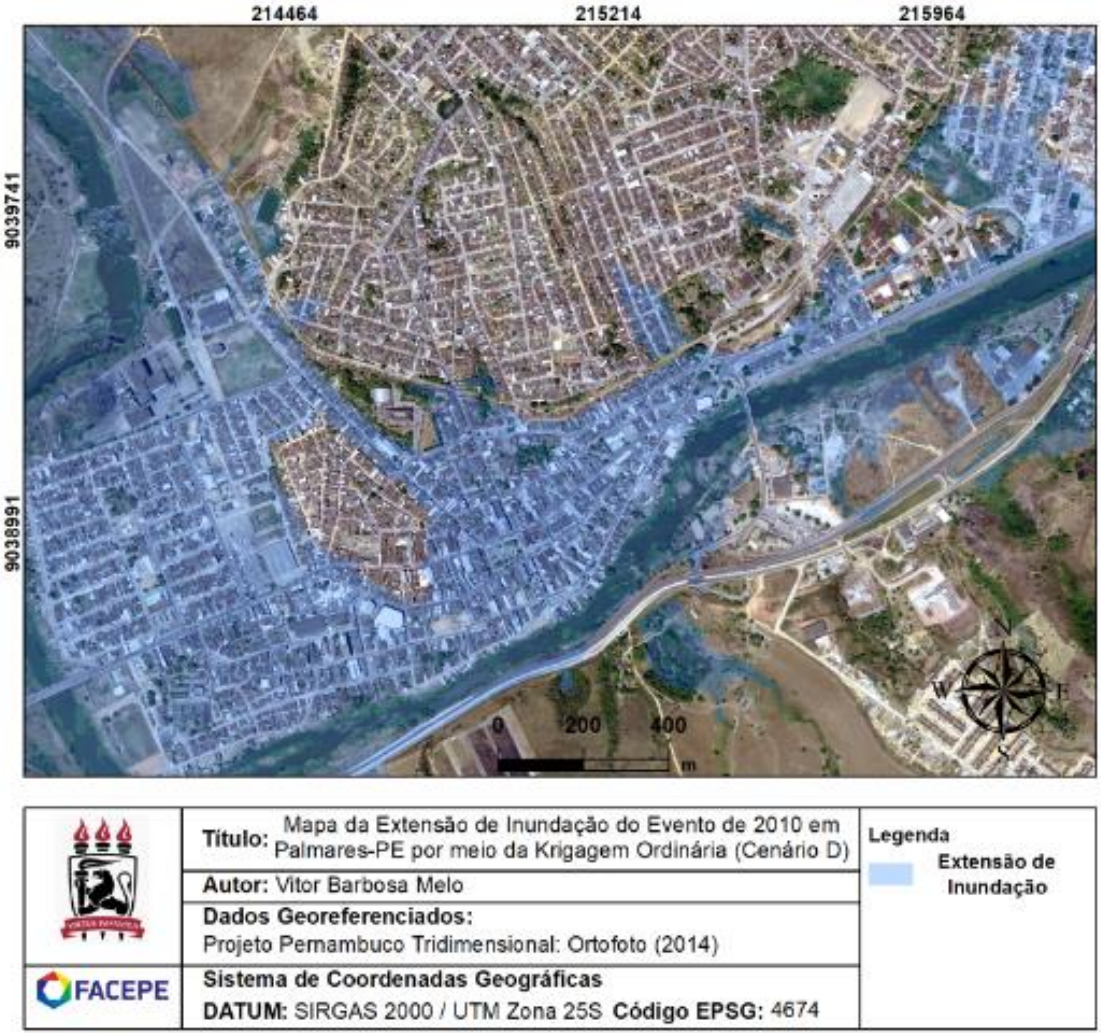

Fonte: Autor (2021)

Figura 42 - Histograma das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C)

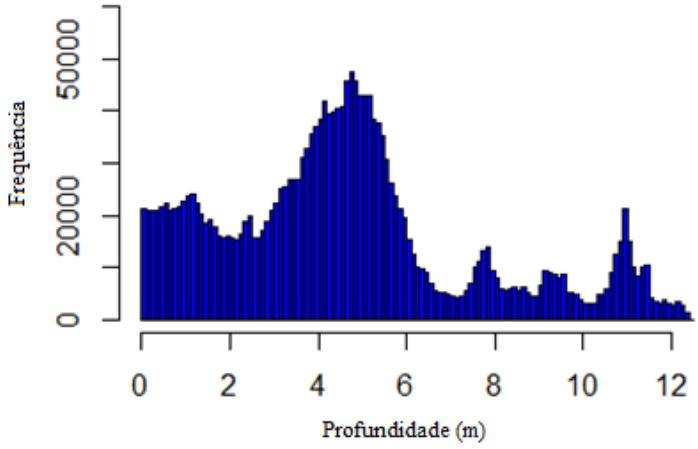

Fonte: Autor (2021)

Figura 43 - Histograma das profundidades de inundação do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D)

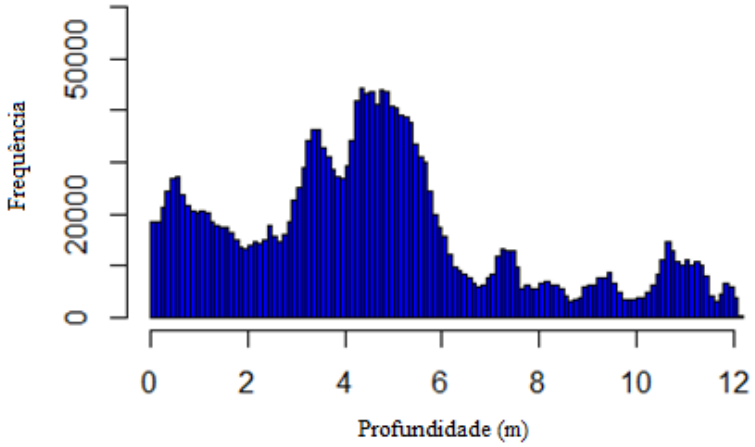

Fonte: Autor (2021)

Localmente, o desempenho sobre o erro e a estimativa das inferências nos modelos C e D são indicados na Tabela 3. A performance local de ambos os modelos apontou adequada estimativa, sendo o cenário D um pouco menos acurado. Tal acontecimento ocorreu por causa do maior erro sobre algumas estimativas, que provocaram o aumento da variabilidade dos erros e da média dos erros absolutos e dos erros ao quadrado. Visualmente o gráfico de dispersão do cenário D (Figura 44) levam em certos pontos (em azul) a maiores desvios em relação à reta exata (em vermelho) em comparação ao cenário C (Figura 45). Além disso, a variância dos valores estimados do cenário C foi ligeiramente maior, o que fortalece a ocorrência de maiores profundidades no mapa krigado deste cenário como discutido anteriormente.

Tabela 3 - Medidas de desempenho para os cenários C e D

Parâmetros de Desempenho	Cenário C	Cenário D
Média dos Erros (ME)	0,0097	0,0120
Variância dos Erros (Var)	0,0821	0,1121
Média dos Erros Absolutos (MAE)	0,2138	0,2504
Raiz Média dos Quadrados dos Erros (RMSE)	0,2859	0,3341
Variância dos Estimados (Var)	3,3484	3,3277
Relação entre as Variâncias (RVar)	0,9655	0,9596
Coeficiente de Correlação (R)	0,9881	0,9837
Coeficiente de Determinação (R^2)	97,64%	96,77%

Fonte: Autor (2021)

Figura 44 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2010 em Palmares (cenário C)

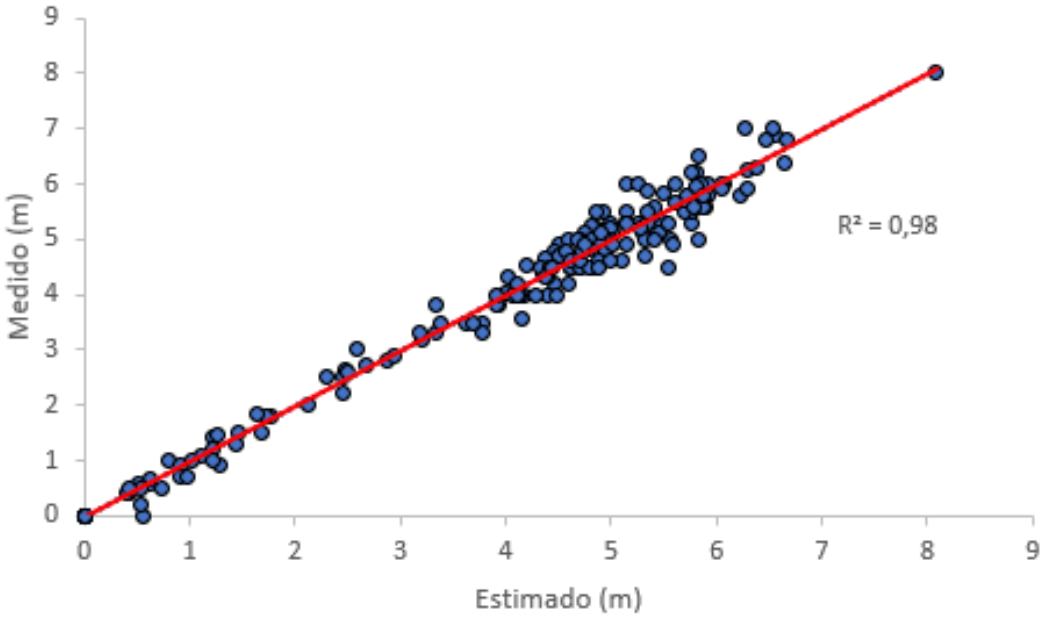

Fonte: Autor (2021)

Figura 45 - Gráfico de dispersão, medido versus estimado para as profundidades de inundação do evento de 2010 em Palmares (cenário D)

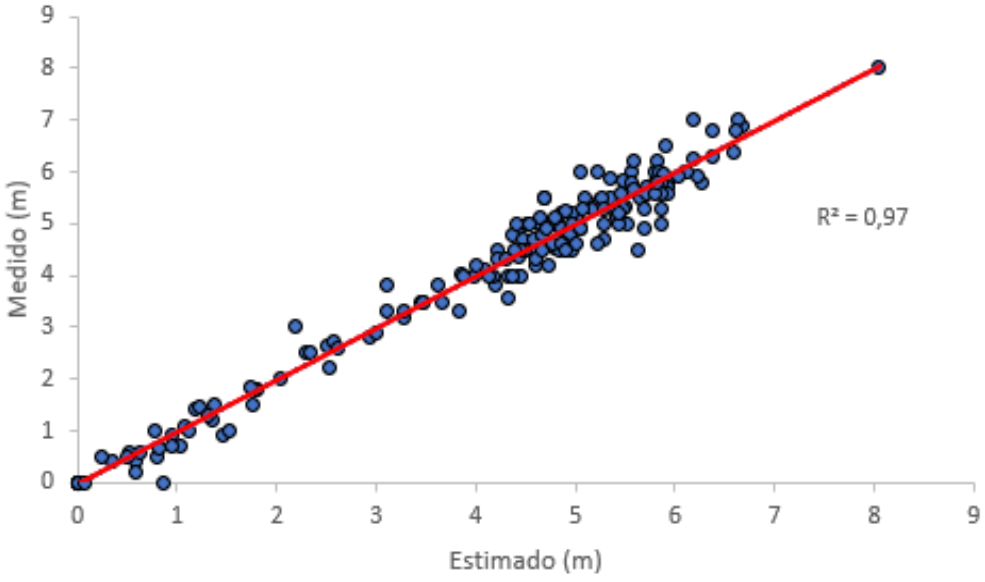

Fonte: Autor (2021)

Por fim, a incerteza na predição do cenário C e D se encontra representada nas Figuras 46 e 47, respectivamente. No geral, as zonas de confiança entre os modelos foram semelhantes do ponto de vista espacial, visto que nos espaços com amostras a incerteza foi pequena (em vermelho), por outro lado nas áreas sem amostragem, obteve-se uma incerteza média (em

laranja), especialmente na região noroeste e maiores incertezas na margem direita do rio Una, justificada pela baixa presença de dados.

Nas zonas de maior erro, o cenário C exibiu menor desempenho em relação ao modelo D, onde a variância da Krigagem máxima foi maior, em torno de 35 cm. Do ponto de vista das distribuições (Figura 48 e 49), houve um maior espalhamento (variabilidade) do modelo C, porém no todo apresentaram proximidade entre si.

Figura 46 - Mapa da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C)

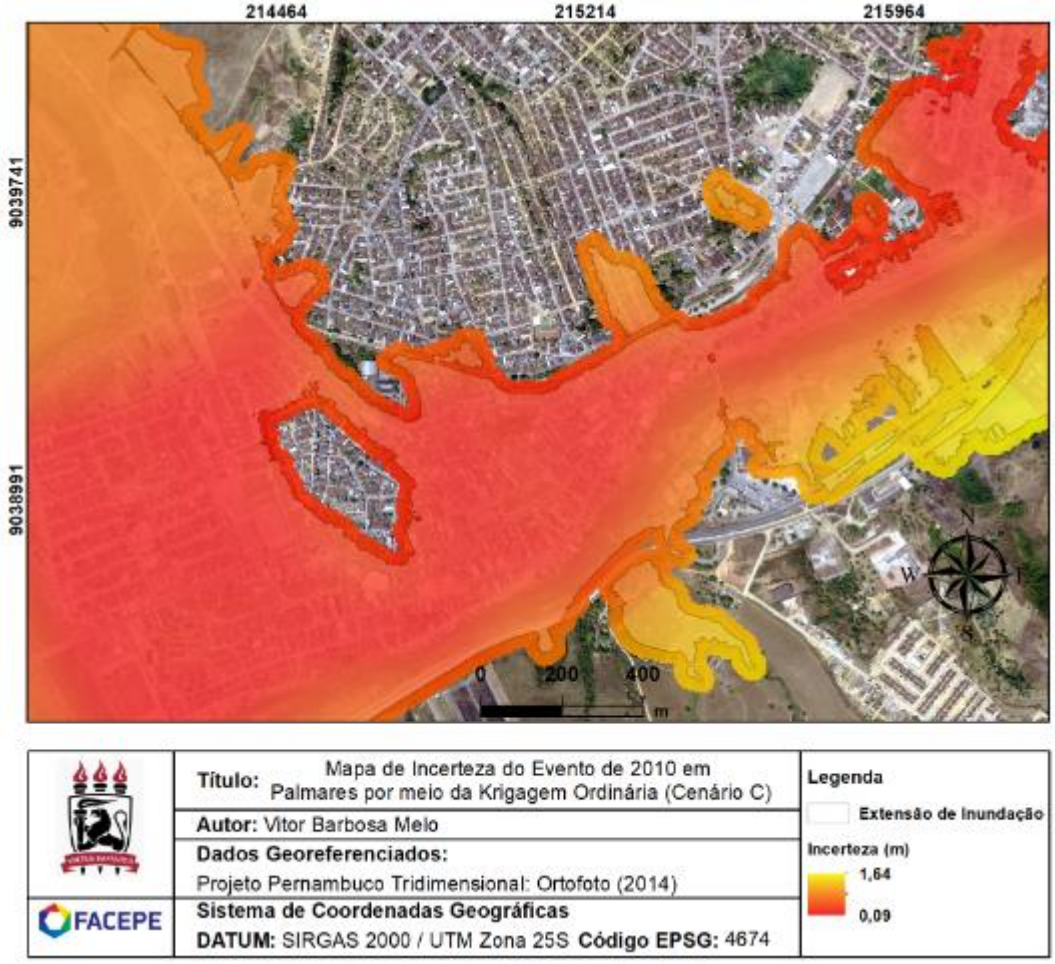

Fonte: Autor (2021)

Figura 47 - Mapa de incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D)

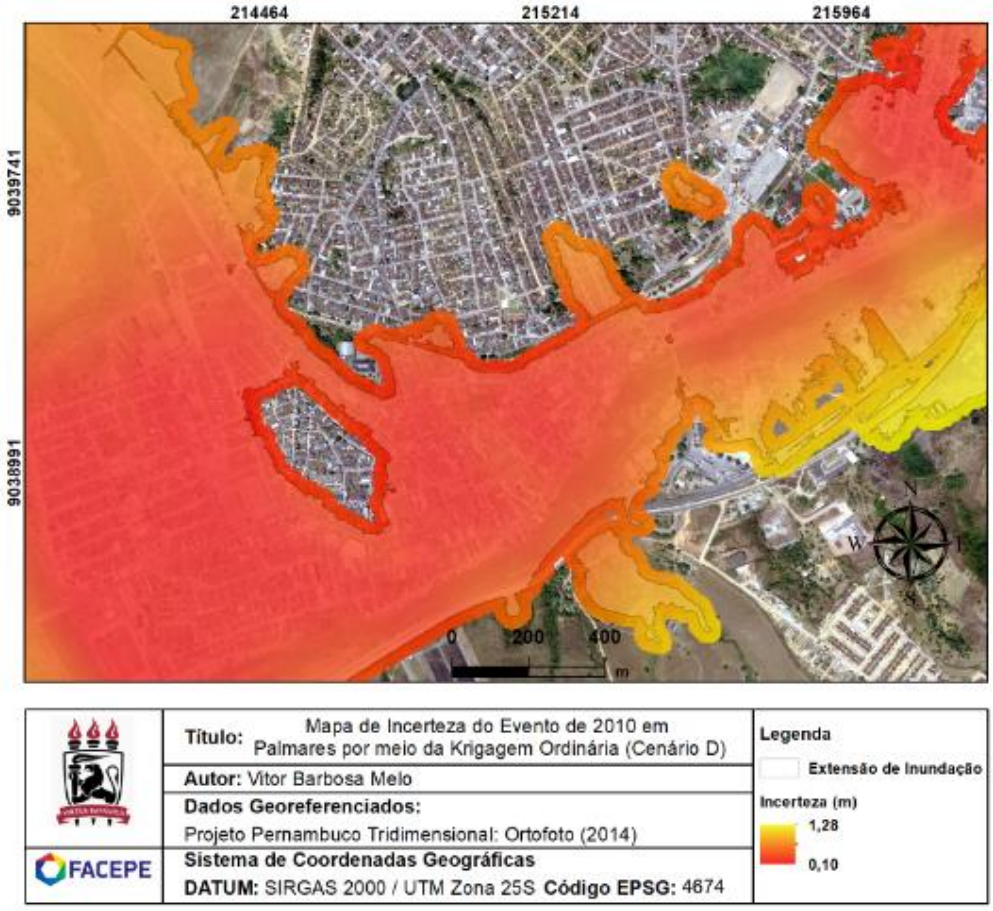

Fonte: Autor (2021)

Figura 48 - Histograma da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário C)

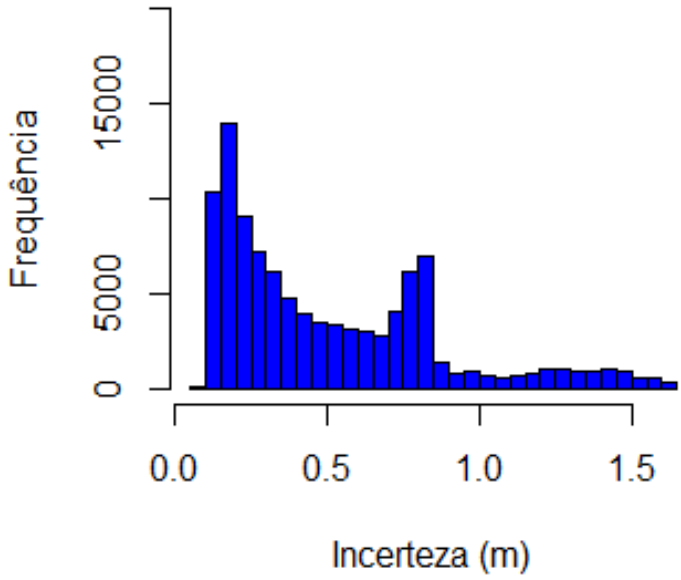

Fonte: Autor (2021)

Figura 49 - Histograma da incerteza do evento de 2010 em Palmares por meio da Krigagem Ordinária (cenário D)

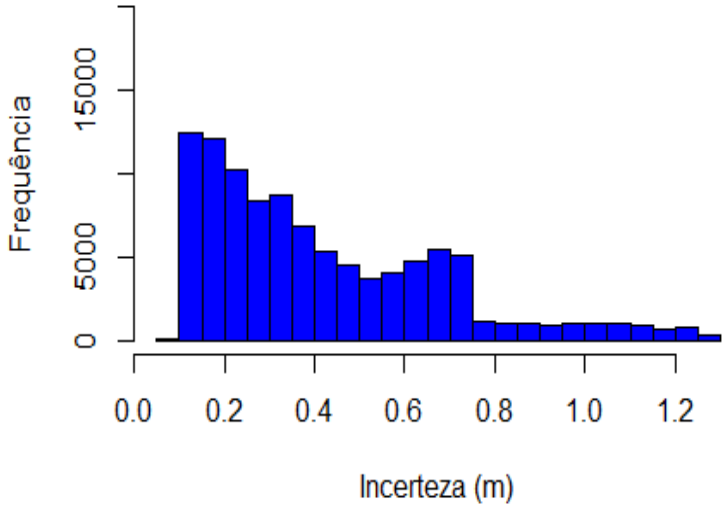

Fonte: Autor (2021)

Por se tratar de análise de fenômenos que geram riscos à humanidade, a incerteza deve ser minimizada preferivelmente nas áreas urbanas. Com isso, espacialmente foi investigado onde um modelo se sobressaiu em relação ao outro. Para tanto se aplicou a diferença entre a variância da Krigagem dos cenários estudados, representados na Figura 50 e avaliações a respeito da frequência dessas diferenças (Figura 51).

Considerando que os valores negativos do histograma representam maior assertividade do cenário C em relação ao D e as diferenças positivas o contrário, tem-se, então, menores incertezas para o segundo modelo, pois uma maior recorrência foi obtida para as diferenças positivas, isto é, quando o cenário C é menos confiável que o modelo D. Entretanto, nas regiões de maior risco para a população de Palmares, o cenário C foi superior ao D.

Assim, devido à assertividade nas áreas de maior interesse (localização da população), ao melhor desempenho estatístico nos pontos conhecidos e às maiores profundidades e extensão da inundação, optou-se pelo cenário C como modelo final para aplicação das etapas sobre o modelo HAND visualizada na próxima seção.

Figura 50 - Diferença da incerteza entre os cenários C e D do evento de 2010 em Palmares

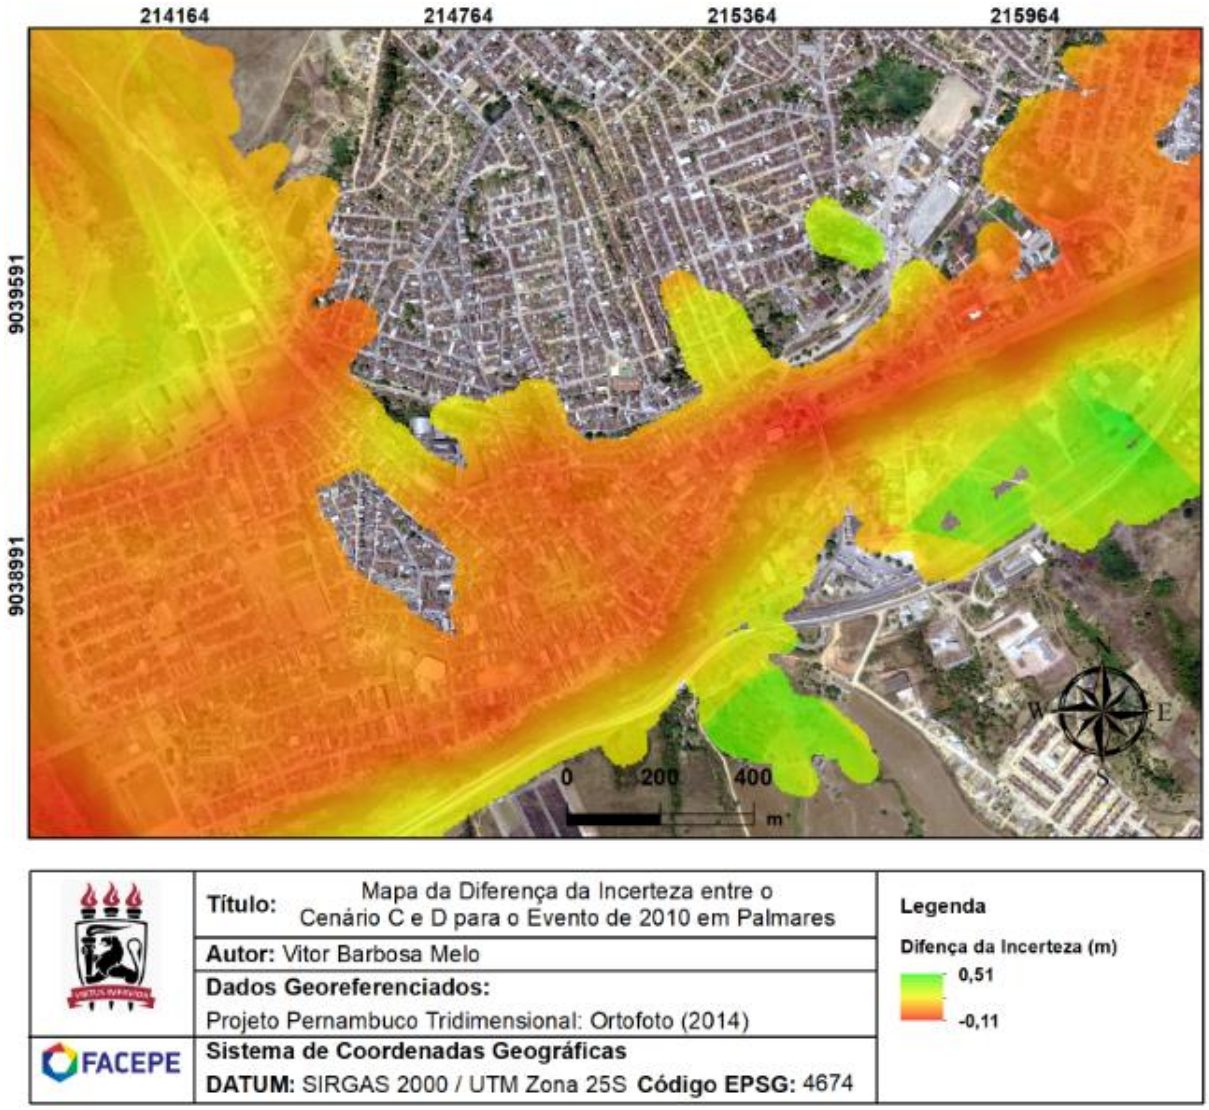

Fonte: Autor (2021)

Figura 51 - Histograma da diferença da incerteza entre os cenários C e D

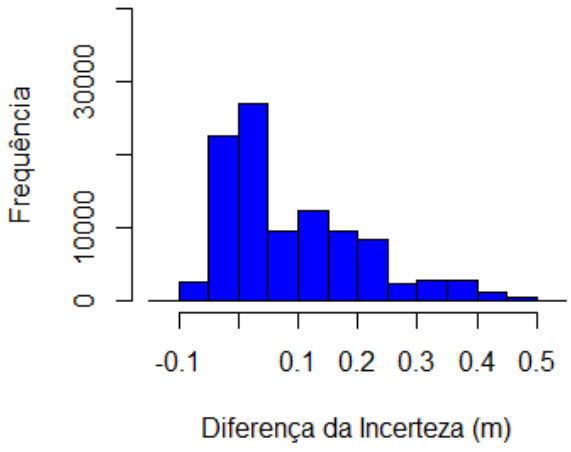

Fonte: Autor (2021)

4.2 MODELO HAND

A inundação do ponto de vista do modelo HAND é controlada por estágios da altura HAND, em que a água excedente do canal mais próximo flui para regiões vizinhas mais altas. Dessa forma, os canais que controlam as inundações respeitam as condições de equilíbrio hidrostático lateral (NOBRE *et al*., 2015; MOMO *et al*., 2016). Assim, o modelo HAND constitui-se como uma metodologia robusta de fácil entendimento, permitindo uma simples relação entre as alturas do algoritmo com a vulnerabilidade às inundações.

Na prática, a predição do modelo tem sido alcançada pela definição de uma altura HAND de corte (limiar), possibilitando a geração da superfície máxima de inundação em relação a um certo limite escolhido (elevação HAND). Entretanto, a principal desvantagem do descritor de terreno é estabelecer uma associação entre a altimetria e o evento de inundação.

Para superar esta dificuldade, aplica-se em conjunto com o modelo outra informação relacionada ao evento, buscando-se a obtenção de uma altura que descreva toda a inundação na área avalaida. Na literatura se tem visto o uso de pontos de inundação ou de alagamento, de mapas de eventos passados obtidos por interpolação ou por modelos hidrodinâmicos. Logo, essas variáveis são utilizadas como referência para determinar uma altura HAND. Neste trabalho, utilizou-se o mapa krigado e a altura de corte do modelo foi desenvolvida com o auxílio da curva **ROC**, conforme procedimento descrito a seguir.

4.2.1 Curva ROC - Predição do HAND

Com o objetivo de otimizar o modelo HAND como preditor das áreas inundáveis e estender o fenômeno na sede municipal de Palmares para o evento de 2010, recorreu-se à análise da curva **ROC** (Figura 52). No gráfico, a curva em vermelho indica o desempenho do modelo HAND em relação à taxa de acerto e de alarme falso quando comparando ao mapa binário produzido pela Krigagem Ordinária no evento de 2010.

A **AUC**, área abaixo da curva vermelha (**ROC**), foi igual a 0,98, próxima à unidade que é considerada a tradução para um modelo perfeito. A linha tracejada em azul (**AUC** = 0,5) sinaliza um modelo meramente aleatório, sem indicar correlação entre os limites de classificação e o mapa binário. Destaca-se também que a **AUC** demonstra a qualidade de previsão do modelo analisado, independente do limiar escolhido, fornecendo um desempenho geral sobre todos os limiares.

Figura 52 - Curva ROC: otimização do modelo HAND em relação ao evento de 2010 em Palmares

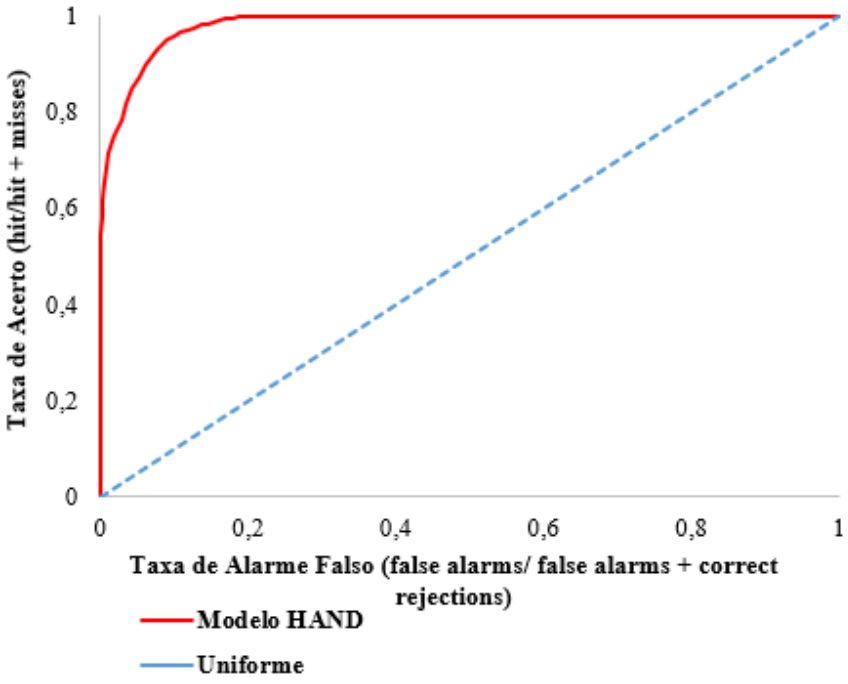

Fonte: Autor (2021)

Como se deseja aumentar a taxa de acerto e minimizar a taxa de alarme falso, a escolha da altura HAND deve ser baseada nesta condição e como pode ser visto a relação entre as duas taxas é proporcional, de modo que, aumentando o acerto, mais *pixels* são classificados como alarmes falsos. Entretanto, deve-se ter em mente que o pior erro de previsão está vinculado com a não inclusão da inundação, quando for observada como tal, isto é, os falsos negativos (falha).

Neste sentido, o limiar de 10,5 m foi escolhido para o modelo HAND, indicando 99% e 15% para as taxas de acerto ($\mathbf{r_{tp}}$) e de alarme falso ($\mathbf{r_{fp}}$), respectivamente. Quando tais mapas são usados para tomadas de decisão frente ao gerenciamento de riscos, os *pixels* classificados como alarme falso podem gerar maiores custos e planejamentos "exagerados" em áreas não atingidas. Porém, o pior erro cometido nos modelos está vinculado aos falsos negativos, que foram minimizados. Com isso, o modelo HAND possibilita uma previsão adequada frente à subestimação do fenômeno, situação que coloca a população em risco.

4.2.2 Métricas de comparação entre Mapas: HAND versus Krigagem Ordinária

Como citado na metodologia (Seção 3.3.3.), o uso da curva ROC de maneira individual impossibilita análises gerais do modelo simulado. Neste contexto, o modelo HAND com limiar de 10,5 m (obtido pela curva **ROC**) foi comparado com o modelo observado (inferido pela Krigagem Ordinária) utilizando outras ferramentas.

Inicialmente, na Figura 53, visualiza-se espacialmente o desempenho do modelo simulado em relação ao modelo observado. De uma maneira geral, o modelo HAND simulou adequadamente o evento. Como pode ser visto, as maiores áreas (azul e branco) foram classificadas como verdadeiras, sendo o azul (área simulada corretamente – verdadeiros positivos) e o branco (área não simulada corretamente – verdadeiros negativos).

Embora em menor expressão, a simulação classificou células falsas. Na parte oeste do evento, em vermelho (área não simulada incorretamente – falsos negativos), foram observados *pixels* na borda do evento. Este tipo de classificação é indesejada, devido ao maior risco associado. Foi analisado nestas áreas, em seguida, o mapa de profundidades obtido pela Krigagem Ordinária (Figura 39), concluindo-se, então, que as regiões classficadas em vermelho indicam profundidades pequenas, não apresentando grandes riscos à população. Na parte leste, em laranja (área simulada incorretamente – falsos positivos), percebeu-se maior quantidade de células em comparação com os falsos negativos. Embora os falsos negativos tenham sido minimizados, a ocorrência de falsos positivos podem gerar prepação em exesso do evento, promovendo maiores custos e planejamentos inadequados. Por este motivos, os falsos positivos não podem ser ignorados.

Diante do exposto, importantes relações podem ser encontradas a respeito das metologidas utilizadas e do fenômeno que ocorreu em 2010 na cidade de Palmares. De antemão, destaca-se que o modelo HAND consegue predizer satisfatoriamente as inundações. Isto porque, o modelo físico topográfico normaliza as células em relação ao rio, estabelecendo virtualmente os caminhos de fluxo ao canal de drenagem mais próximo.

Entretanto, na ocorrência das inundações bruscas (caso do evento de 2010 em Palmares), o modelo HAND não consegue predizer corretamente (sem erros) todo o modelo observado. Isto acontece, porque o comportamento conceitual do modelo HAND, descrito anteriormente, não consegue reproduzir plenamente a dinâmica do escoamento altamente turbulento. Conforme Nobre *et al*. 2015, há superestimação nas regiões distantes da onda de cheia.

Complementarmente, o modelo HAND é dependente dos estágios da altura HAND, tornando-o limitado (NOBRE *et al*. 2015). Neste sentido, como as inundações não são homogêneas – ocorrência de fluxos e refluxos localizados, particularidades físicas da cidade e aspectos relacionados ao fenômeno –, a altura de corte (limiar) usada para descrever toda área analisada, inevitavelmente, produzirá classificações falsas. Inclusive, a própria amostragem sobreleva a diferença das profundidades de montante (porção leste) e jusante (região oeste), sendo maiores a montante. Logo, é plausível que na chegada da onda, a montante da cidade, as

condições hidrodinâmicas foram mais expressivas. Isto pode significar que a onda atingiu velocidades e pressões mais elevadas na porção oeste e foi perdendo energia a jusante da cidade, atingindo profundidades menores. Dessa forma, como o modelo HAND estima a inundação uniformemente, características hidrodinâmicas distintas na área de estudo impossibilitam que o HAND descreva a inundação de maneira completa.

Figura 53 - Comparação entre o modelo observado (Krigagem Ordinária) e o modelo simulado (corte de 10,5m no HAND)

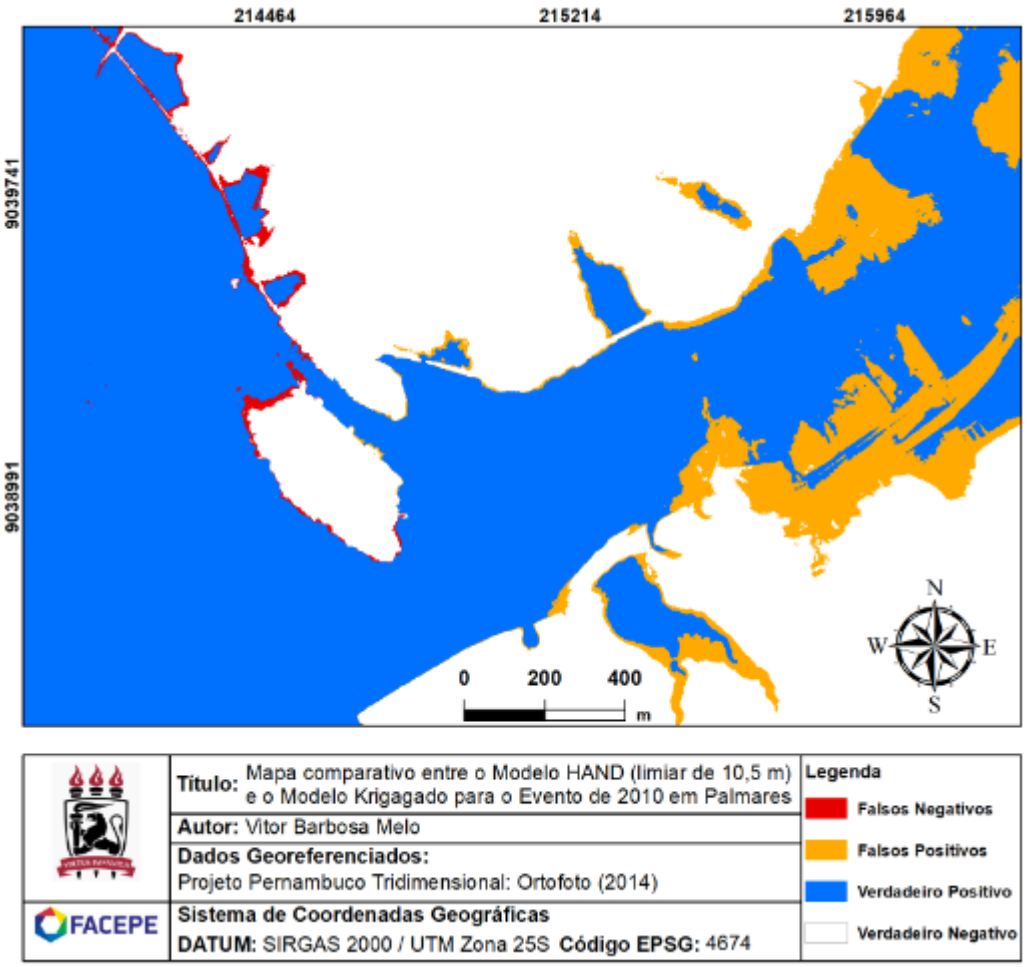

Fonte: Autor (2021)

No exemplo deste trabalho, na medida que o limiar HAND diminui, há um aumento na área dos falsos negativos e uma diminuição dos verdadeiros positivos e dos falsos positivos. Na prática, deve-se optar pela superestimação, ainda que a área classificada como falso positivo seja significativa.

Outro ponto importante a ser destacado sobre os dois modelos está relacionado com o aspecto temporal. O fato é que tanto na amostragem (profundidades máximas, não se sabe o

momento), quanto no HAND (modelo estático), não existe a consideração da dimensão temporal, a qual pode ser evidenciada somente nos modelos hidrodinâmicos.

Por fim, foram avaliadas outras métricas de desempenho (Tabela 4). A taxa de acerto (0,99) e a taxa de alarme falso (0,15), usados na construção da curva **ROC**, possibilitaram verificar o acerto das áreas inundadas observadas (verdadeiros positivos) e a comissão sobre as áreas não inundadas observadas (falsos positivos). Por outro lado, o *Bias* indicou uma tendência de superestimação (maior que a unidade) do modelo simulado, pois mais *pixels* foram classificados como inundação em relação ao modelo de referência.

A importância do uso de outras métricas foi evidenciada, principalmente, com o uso do *Fit Index*. O **F** indica o desempenho do modelo de forma geral, penalizando as vulnerabilidades (sub ou superestimação) da simulação. O valor encontrado (85%) expõe que o modelo apresentou falhas, apesar do bom desempenho obtido.

O *False Alarm Ratio* mostrou similaridade com a taxa $\mathbf{r_{fp}}$. Ressalta-se que ambas são semelhantes, pois tratam do desempenho dos falsos positivos. Entretanto, o primeiro compara a relação entre a área inundada simulada (os verdadeiros e os falsos positivos), enquanto o segundo sobre a área seca observada (falsos positivos e verdadeiros negativos). Os resultados foram similares, pois a área dos verdadeiros positivos (2,07 km²) é próxima dos verdadeiros negativos (1,88 km²).

Além disso, as métricas apresentaram duas características positivas a respeito da simulação do modelo HAND. O *False Negative Rate* e o *True Negative Rate* foram iguais a 0,01 e 0,99, respectivamente. Isto demonstra o poder do desempenho do limiar adotado extraído pela curva **ROC**, visto que houve a minimização dos falsos negativos ($\mathbf{r_{fn}}$ próximo a zero) e a correta predição das áreas não inundadas ($\mathbf{r_{tn}}$ próximo à unidade). Todavia, destaca-se que a segunda métrica não penaliza os falsos positivos (0,34 km²) subestimando o desempenho do modelo simulado nas porções secas.

Tabela 4 - Resumo das métricas estatísticas de desempenho do limiar de 10,5 m do HAND em comparação com o modelo krigado (observado)

Área Total Avaliada	4,32 km²
Verdadeiro Positivo (**VP**)	2,07 km²
Verdadeiro Negativo (**VN**)	1,88 km²
Falso Positivo (**FP**)	0,34 km²
Falso Negativo (**FN**)	0,03 km²
Taxa de Acerto ($\mathbf{r_{tp}}$)	0,99

Continuação: Tabela 4 - Resumo das métricas estatísticas de desempenho do limiar de 10,5m do HAND em comparação com o modelo krigado (observado)

Taxa de Alarme Falso (**r_{fp}**)	0,15
Bias (**B**)	1,15
Fit Index (**F**)	0,85
False Alarm Ratio (**FARatio**)	0,14
False Negative Rate (**r_{fn}**)	0,01
True Negative Rate (**r_{tn}**)	0,99

Fonte: Autor (2021)

4.2.3 Mapa de perigo

O mapa de perigo define a distribuição espacial de potenciais eventos de inundação associada a uma determinada intensidade e probabilidade de excedência. Geralmente, os mapas de perigo têm sido utilizados para a geração de cenários relacionados a um certo período de retorno. Neste trabalho, tal mapa foi desenvolvido através da simulação do modelo HAND para diferentes tempos de recorrência, os quais foram gerados através da análise de frequência de extremos.

Inicialmente foi necessário aplicar estudos de tendências sobre a série hidrológica de Palmares. Isto porque a aplicação da estimativa de probabilidade de recorrência em séries não corrigidas, caso apresente não estacionariedade, pode provocar erros significativos na predição. Logo, como os mapas de perigo podem ser utilizados na tomada de decisão a respeito de medidas de enfrentamento das inundações, torna-se fundamental a verificação da tendência, da homogeneidade, da independência e da estacionariedade das series temporais hidrológicas.

Análises de tendência

No estudo sobre análises de tendências de séries temporais em hidrologia, recorreu-se preliminarmente a uma verificação básica da disposição das cotas máximas registradas na calha fluvial, estação Palmares, de 1967 a 2019, com exceção de 2010 (Figura 54). Com o ajuste de uma reta de regressão linear, verificou-se uma leve tendência de crescimento das cotas máximas. Este fato foi evidenciado através da análise gráfica (inclinação da reta vermelha) e do coeficiente angular positivo proveniente da regressão, este último indicando um aumento de 2,1 cm/ano.

Figura 54 - Máximos anuais da estação fluviométrica de Palmares

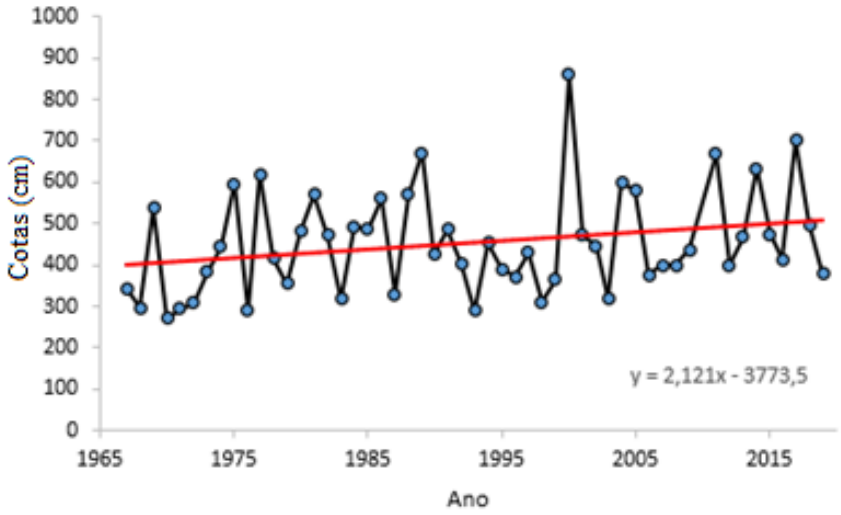

Fonte: Autor (2021)

Percebeu-se que existe certa possibilidade de a série ser não estacionária. Com isso, métodos estatísticos foram utilizados para confrontar tal hipótese, que nem sempre é verificada, apesar da tendência de crescimento. Outros pontos importantes devem ser destacados: a série sofreu mudanças em sua posição espacial ao longo do tempo, apresentando três pontos distintos desde o início de sua operação (1967); o maior evento que ocorreu em 2010 não foi registrado, tendo em vista que as réguas foram arrastadas pela força da água; a implementação concluída em 2016 da barragem de Serro Azul, localizada cerca de 18km a montante da entrada da cidade, promoveu alterações no escoamento a jusante.

Tais aspectos promovem diferenças na referência das réguas e nos valores máximos contabilizados. Devido a isto, a verificação de tendências na série temporal se torna comprometida devido às incertezas introduzidas e à falta de informações mais precisas para análises mais assertivas. Entretanto, independentemente de existirem estes inconvenientes, os estudos de estacionariedade devem ser aplicados.

Os testes estatísticos, indicados na Tabela 5, indicaram que as cotas máximas da estação fluviométrica de Palmares são: homogêneas, indicando que as amostras provêm da mesma população; independentes, pois não há influência entre máximos anuais consecutivos; estacionária, ou seja, a média e a variância dos eventos não mudam ao longo do tempo em um certo nível de confiança. Ressalta-se que a hipótese nula foi aceita com um nível de significância de 5%.

Tabela 5 - Testes de homogeneidade, de independência e de estacionariedade para a estação fluviométrica de Palmares

Teste	Estatística do Teste	Hipótese Nula	Condição
Homogeneidade	|T| = 0,52	Homogênea	Aceita-se
Independência	|T| = 0,43	Independente	Aceita-se
Estacionariedade (Spearman)	|T| = 1,84	Estacionária	Aceita-se
Estacionariedade (Mann-Kendall)	|Z| = 1,88	Estacionária	Aceita-se

Fonte: Autor (2021)

Para o teste de Mann-Kendall Sequencial (Figura 55), as curvas de **u(Tn)** – série crescente em relação ao tempo – e **u*(Tn)** – série decrescente em relação ao tempo – se cruzaram em 1973, indicando uma mudança de tendência, neste caso de crescimento dos máximos anuais. Além disso, percebe-se que os indicadores estatísticos ultrapassaram os valores críticos em 1986 e de 1988 até 1992 na ordem crescente da série, o que não ocorreu no sentido inverso.

Como se pode ver, a série temporal apresentou tendência de crescimento. Porém, o teste estatístico rejeitou a hipótese alternativa de não estacionaridade. Apesar destes aspectos, Vogel, Rosner e Kirshen (2013), Rosner, Vogel e Kirshen (2014) e Morreira e Naghettini (2016) comentam que os testes de significância de hipótese nula, incluindo os testes não-paramétricos usados neste trabalho, podem apresentar o erro do Tipo II. Esta situação ocorre quando a hipótese nula não é rejeitada corretamente.

Figura 55 - Teste de Mann-Kendall Sequencial para estação fluviométrica de Palmares

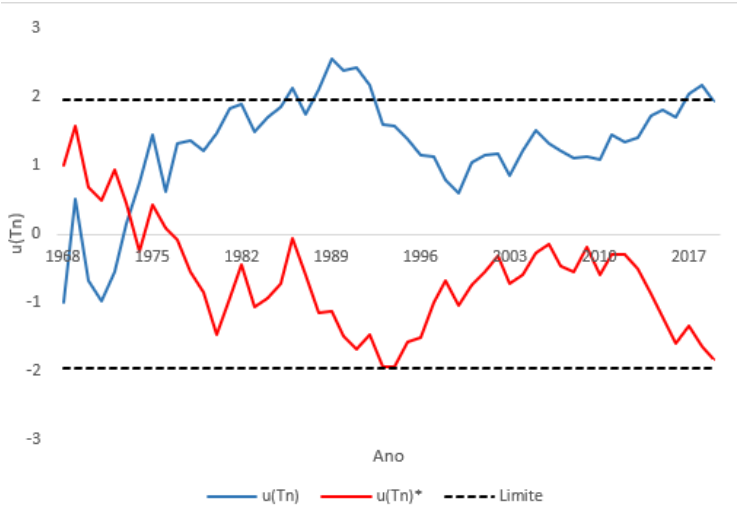

Fonte: Autor (2021)

Os pesquisadores apontam que uma imprecisão desta natureza pode promover planejamento equivocado. Visto que, na tomada de decisão, o erro do Tipo II promove a adoção de submedidas no enfrentamento dos riscos da inundação e, com isso, aumenta-se a probabilidade de perdas humanas, econômicas e ambientais. Neste sentido, para amenizar esta incerteza, deve-se recorrer ao uso de outros testes estatísticos, como o teste de Petit e o de Sen's Slope, além de metodologias que combinem métricas de probabilidade dos erros do Tipo I (hipótese nula rejeitada falsamente) e do Tipo II.

Estimativas de probabilidade de recorrência

As distribuições de extremos Gumbel, Pearson 3P, Exponencial, LogNormal 2P, GEV e LogPearson 3P construídas pelo Método dos Momentos-L (MML) podem ser visualizadas na Figura 56. Diante de seis possibilidades distintas, a decisão do modelo final perpassou por aspectos relacionados às interpretações subjetivas (análises visuais), ao princípio da parcimônia, aos parâmetros de forma, de posição e de escala das distribuições e às métricas estatísticas de aderência e de correlação.

Com relação aos testes de aderência, todas as distribuições aceitaram a hipótese nula de que as distribuições se ajustam adequadamente aos dados amostrais, não apresentando desvios estatisticamente significativos. Entretanto, Naghettini e Portela (2011) sinalizam que os testes de consistência não exibem a aderência da curva para tempos de recorrência extremos (cauda superior), pois há poucas amostras nestes intervalos. Ademais, não possibilitam a indicação da melhor curva ajustada.

Para o desempenho, todas as distribuições indicaram valores de correlação superiores a 0,98. A distribuição Exponencial foi a que apresentou menor correlação estatística, sendo assim descartada. Além disso, sua exclusão foi baseada em aspectos visuais: percebe-se que a curva Exponencial (em laranja) apresentou defasagem em comparação às outras distribuições e aos valores empíricos.

Outra curva excluída como possível candidata foi a distribuição GEV, visto que a positividade do parâmetro de forma impõe limite superior, o que segundo Naghettini e Pinto (2007) deve ser evitado no estudo de máximos anuais.

Pelo princípio da parcimônia de parâmetros, quando não há diferenças significativas entre distribuições, deve-se optar pelas curvas de dois parâmetros. Isso porque, segundo Naghettini e Portela (2011), a introdução de mais um parâmetro baseada na amostragem inevitavelmente implica em um aumento na incerteza do modelo, apesar do ganho no ajuste das

cotas máximas anuais. Com isso, foram descartadas as distribuições de Pearson e de LogPearson.

Finalmente, a distribuição de Gumbel foi escolhida para estimar a probabilidade de recorrência em relação aos máximos anuais da estação fluviométrica de Palmares. A decisão foi sustentada no melhor desempenho em comparação com a distribuição LogNormal 2P e por ser frequentemente utilizada nestas aplicações. Dessa forma, utilizou-se a distribuição de Gumbel para construção do mapa de perigo do município de Palmares baseada na simulação das alturas HAND.

Figura 56 - Distribuições de máximos anuais para a estação fluviométrica de Palmares

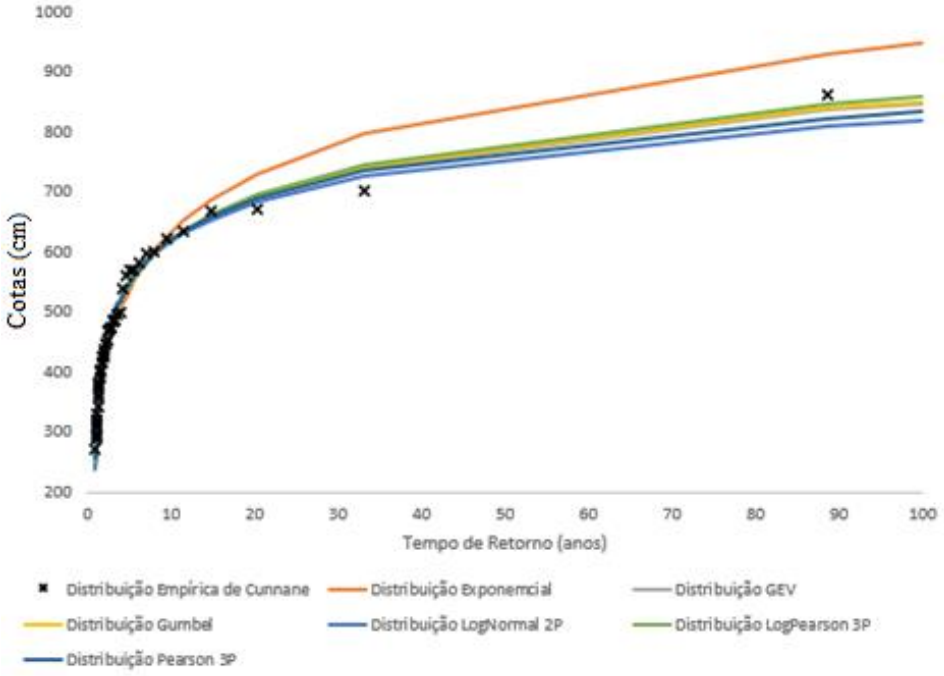

Fonte: Autor (2021)

Conectividade com o modelo HAND

Inicialmente, destaca-se que a conectividade entre a estação fluviométrica e o modelo HAND apresenta particularidades complexas e sobretudo incertas, principalmente, no caso de Palmares, em que não há informações exatas que minimizem tais problemas.

Atentando ao exposto no parágrafo anterior, a conexão entre o modelo HAND e a estação foi estabelecida através da escolha de uma altura que representasse todo o período, normalizando as cotas da régua. Os valores altimétricos HAND podem ser visualizados na Tabela 6. Percebe-se que nos dois primeiros períodos as alturas HAND foram próximas, apresentando diferença de apenas 9 cm. Por outro lado, na posição geográfica atual em que se

encontra a estação fluviométrica, houve uma diferença de 47cm e de 38 cm em relação ao primeiro e ao segundo período.

Ressalta-se que o primeiro período é o mais importante para a série devido à maior quantidade de informações. Por outro lado, é o mais incerto devido ao não conhecimento da posição espacial. Evidencia-se também que o valor de 28 cm está relacionado com o valor de maior frequência (média), aumentando as chances de acerto da posição espacial. Todavia, as alturas HAND obtidas variam de 0 a 1,34m.

Por causa dos motivos mencionados e tendo em vista toda a incerteza da exatidão espacial da estação fluviométrica de Palmares, optou-se por escolher uma altura HAND de 50cm para normalizar as cotas da estação fluviométrica com o descritor HAND. Destaca-se que a decisão foi baseada na subjetividade e, por isso, deve ser vista como duvidosa.

Tabela 6 - Altura HAND vinculada à estação fluviométrica Palmares

Período da Estação Fluviométrica	Altimetria HAND(m)
1967 - 2010	0,28*
2011 - 2013	0,37
2014 - 2020	0,75

*Valor médio. Os valores mínimo e máximo foram 0,00 e 1,34 m, respectivamente.

Fonte: Autor (2021)

Mapa de perigo (probabilidade de recorrência)

Após à construção da distribuição de máximos anuais e a conexão da estação fluviométrica com o modelo HAND, foram selecionadas as cotas relacionadas aos tempos de recorrência de 2, 5, 10, 25 e 100 anos, extraídas da distribuição Gumbel. A amarração com o HAND foi realizada através da subtração de 50 cm das cotas provenientes da estação. Com isso, gerou-se o mapa de perigo (Figura 57) do município de Palmares combinando os dados do modelo HAND com a análise de frequência de nível.

Analisando a Figura 57 percebe-se que para o tempo de recorrência de 2 anos (em vermelho escuro) algumas regiões na margem esquerda do rio Una (presença de residências) foram classificadas para esta probabilidade. Este acontecimento pode estar associado às particularidades da topografia da cidade, a exemplo de áreas baixas susceptíveis a alagamentos. Além disso, a extrapolação das cotas de inundação sobre toda a área urbana de Palmares, tendo

em mente que a estação fluviométrica está localizada na saída da cidade, gera certo enviesamento por causa da diferença do nível da água na cidade durante o evento.

Figura 57 - Mapa de perigo do município de Palmares

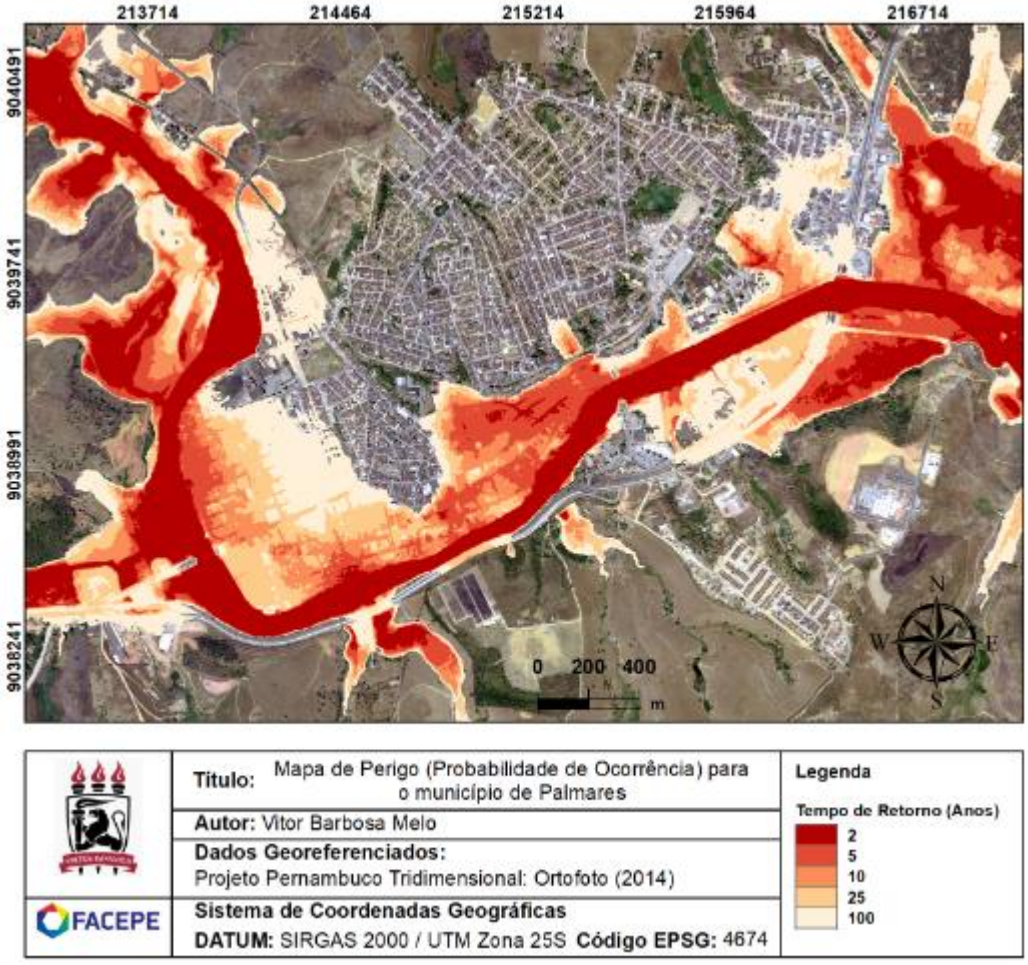

Fonte: Autor (2021)

Com relação aos demais tempos de retorno verificou-se um comportamento desejável, pois a tendência de diminuição da probabilidade de excedência acompanhou o crescimento da altimetria HAND. Porém, como não há dados observados que possibilitem a verificação da performance deste mapa de perigo e devido à incerteza na estimação dos períodos de retorno e à extrapolação de um único ponto para toda a área, a discussão se torna frágil em relação à exatidão do mapa.

Outro ponto a ser destacado está relacionado com o tempo de recorrência máximo utilizado, que foi de 100 anos. Isso porque existe uma limitação técnica relacionada à extrapolação do período de retorno, que para alguns pesquisadores deve ser no máximo de 2 vezes o período de coleta dos dados fluviométricos. Este aspecto impossibilitou estimar a possível cota da inundação de 2010 através da distribuição de extemos.

Esta observação também foi constatada por Ribeiro Neto *et al*. (2015). Os pesquisadores admitiram estimativas de vazões para diferentes tempos de retorno de até 3 vezes o tamanho da série e calcularam a vazão para 150 anos, porém o valor obtido não atingiu a vazão do pico da cheia de 2010 (uma estimativa feita por um flutuador durante o evento e outra por um modelo hidrodinâmico). Com isso, os autores comentaram a possibilidade do evento de 2010 ter atingido uma magnitude de 200 anos.

Percebe-se que a falta de um período maior de observação dos dados fluviométricos torna o processo de geração do tempo de recorrência da cheia de 2010 limitado, principalmente pela falta da cota fluviométrica durante o evento, visto que as réguas linimétricas foram carregadas.

4.2.4 Simulação dos anos 2000, 2010, 2011 e 2017

Por fim, escolheram-se as inundações de 2000, 2010, 2011 e 2017 para serem simuladas pelo modelo HAND, os resultados podem ser visualizados na Figura 58. Nos anos de 2000, 2011 e 2017, os mapas foram gerados a partir da cota obtida pela estação fluviométrica de Palmares menos 50cm estabelecido para a conexão entre o modelo HAND e a estação. Com relação à simulação do ano de 2010, a altura HAND foi obtida pela análise da curva ROC em que se utilizou o modelo krigado como referência. Esta otimização indicou uma altura HAND de 10,5m para o evento de 2010. Dessa forma, a inundação de 2010 foi extrapolada segundo esse limiar.

Dentre as quatro simulações, as duas menores ocorreram no ano de 2011 (área em azul) e de 2017 (linha em vermelho), apresentando cotas iguais a 668 e a 700cm, respectivamente. Devido à diferença de apenas 32cm entre os eventos, as extensões dos fenômenos foram praticamente iguais (Figura 58).

Por outro lado, as inundações mais drásticas do século XXI ocorreram nas simulações em 2000 (linha em amarelo) com cota fluviométrica de 860cm – maior evento já registrado – e em 2010 (linha laranja), a qual não apresenta medição na estação. Não obstante terem sido as cheias mais drásticas, verificou-se que na margem direita do rio Una os quatro eventos exibiram contornos muito similares, indicando assim a presença de barreiras físicas. Em contrapartida, na margem esquerda a água apresentou maior extensão para o ano de 2010, essencialmente nas regiões oeste e leste da área atingida.

Evidencia-se que nos eventos de 2000 e de 2017 os contornos não foram contínuos, indicando a presença de pequenas “ilhas” de *pixels*. Este aspecto pode estar relacionado com a

incerteza na conexão entre o HAND e a estação fluviométrica (altura do descritor de 0,5m), as particularidades do fenômeno e os aspectos do MDT, que incidem sobre o descritor de terreno.

Figura 58 - Simulação de eventos de inundação por meio do modelo HAND para os anos de 2000, 2010, 2011 e 2017 no município de Palmares

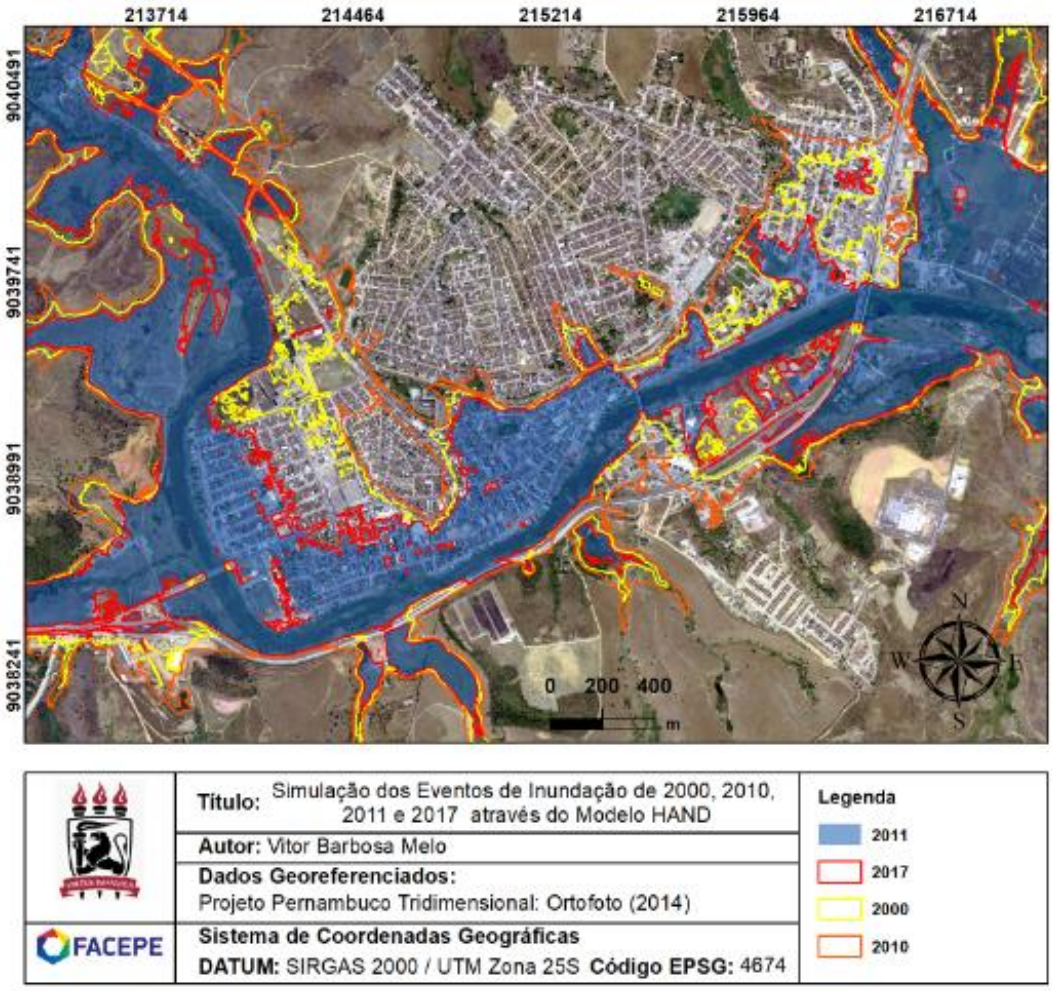

Fonte: Autor (2021)

Para verificação da performance dos anos simulados, recorreu-se às interpretações visuais sobre manchas de inundação obtidas por diferentes abordagens. Com isso, foram escolhidas as pesquisas de Dantas (2012) e de Alves *et al*. (2017). Embora existam outras aplicações na cidade de Palmares, para o objetivo desta etapa o recurso visual sobre mapas e as ferramentas usadas foram essenciais na decisão para escolha dos trabalhos.

Dantas (2012) apresentou o contorno da inundação de 2000 a partir de um levantamento manual realizado por equipes da antiga Fundação de Desenvolvimento Municipal (FIDEM) e pesquisadores da Universidade Federal de Pernambuco (UFPE). A mancha de inundação do evento de 2010 foi estimada através de um modelo determinístico (IDW), interpolando as profundidades de inundação obtidas pelo Corpo de Bombeiros. Para a extensão da cheia de

2011, desenvolvida pelo interpolador IDW, as profundidades do evento foram levantadas por parcerias entre a antiga SRHE, a APAC, a UFPE e a CPRM. Além disso, o pesquisador citado simulou a inundação para os anos de 2000 e de 2010 através de um modelo hidrológico e hidrodinâmico. Também utilizando tais modelos, Alves *et al*. (2017) recriaram a inundação de 2017.

No evento de 2000, o mapa simulado pelo modelo HAND combinado com a estação fluviométrica apresentou adequada correspondência com as duas extensões vistas em Dantas (2012). Analisando localmente em relação aos dois mapas, a simulação através do HAND apresentou em algumas áreas superdimensionamento e subdimensionamento na porção leste e oeste da área urbana de Palmares, nesta ordem.

Entretanto, ressalta-se que o levantamento da equipe formada pela FIDEM e pela UFPE foi realizado manualmente em campo sobre uma planta arquitetônica. Com isso, entende-se que há imprecisão por causa de falhas humanas e da baixa exatidão da planta de referência em comparação aos levantamentos por aerofotogrametria, por exemplo. Ademais, aparentemente, a porção leste foi desprezada no levantamento.

De outra forma, a simulação hidrodinâmica indicou maior semelhança na zona leste com o modelo HAND, porém com maior discrepância na região oeste. Como possível desvantagem, a validação do desempenho da vazão sintética gerada pelo modelo hidrológico levou a um valor do coeficiente de Nash e Sutcliffe igual a 0,61 para o período de 2000. Apesar de ser considerado um resultado aceitável nestes modelos, esta discrepância no ajuste pode promover padrões de superdimensionamento (ou sub) da mancha no modelo hidrodinâmico.

Em relação à simulação de 2010, percebeu-se que a extensão do evento pelo HAND foi mais próxima ao mapa produzido pelo modelo hidrodinâmico de Dantas (2012). Isso porque na região leste, que exibiu superdimensionamento do descritor de terreno em comparação ao modelo krigado (ver item 4.2.2), a simulação HAND apresentou maior similaridade em relação ao hidrodinâmico. Porém, nestas regiões foram amostradas pelo corpo de bombeiros profundidades iguais a zero, indicando superestimativa em ambas as metodologias. Tal evidência em conjunto com interpretações da simulação de 2000, possivelmente, indicam que houve uma tendência na predição de áreas maiores pelo contorno proposto por Dantas (2012), assim como evidenciado pelo modelo HAND, sobretudo na região leste.

Analisando visualmente a mancha de inundação de 2011 obtidas por interpolação sobre profundidades de inundação, verificou-se concordância com o modelo HAND. No entanto, o modelo topográfico demonstrou pequena superestimativa na região central e leste da cidade. Destaca-se que a amostragem foi realizada por meio de equipamentos com alta precisão, mas

em Dantas (2012) não foi indicada a quantidade de amostras levantadas, impossibilitando discussões mais assertivas a respeito da interpolação determinística usada.

Na comparação entre a extensão de inundação do modelo HAND com o contorno gerado por Alves *et al*. (2017), percebeu-se boa correlação entre ambos os mapas, com poucas exceções de divergências locais.

4.3. CONSIDERAÇÕES FINAIS SOBRE OS MODELOS APLICADOS

Sobre as profundidades de inundação do aplicativo colaborativo Hidromapp (Jaqueira) e do levantamento do corpo de bombeiros (Palmares) foram aplicadas a Krigagem Ordinária para estimativas da inundação em áreas desconhecidas. Apesar de não ter sido encontrados trabalhos usando a KO para inferir cheias passadas sobre processos pontuais, entende-se que a ferramenta tem potencial nesta funcionalidade sobre mapas de inundações, principalmente por ser um preditor exato local e fornecer uma estimativa de incerteza global.

Todavia, é importante tecer observações no tocante ao processo de modelagem e das incertezas constatadas. Destaca-se em todas as etapas da geoestatística o exercício criterioso e subjetivo, que podem ser minimizados através da exaustiva análise exploratória das amostras e posteriores validações dos resultados. Cabe também o respeito às condições de estacionariedade e de variabilidade dos dados, pois, apesar de ser considerado por diversos pesquisadores o "*Best linear Unbiased Estimator*" (melhor estimador linear sem viés), sob qualquer condição o resultado pode ser produzido e tal afirmativa se torna inválida.

A bem da verdade é que a fundamentação da Geoestatística se mostra como robusta. Porém, deve-se ter em mente que para representar qualquer fenômeno a melhor ferramenta é aquela que o descreve adequadamente, independentemente de qualquer pretexto, dos dados utilizados e da formulação matemática e estatística.

No contexto das inundações, os resultados foram coerentes. Contudo, percebeu-se enviesamento nos levantamentos, baixa precisão da localização espacial dos pontos levantados, essencialmente para a amostragem de Palmares que necessitou de validação ponto a ponto e, com isso, verificou-se discordâncias que são motivos de incertezas. Em Jaqueira, por outro lado, constatou-se a presença de *clusters* locais e tendências na margem direita do rio, o que pode ser prejudicial à predição. Além disso, a introdução de outro dado como o HAND pode promover enviesamento na inferência, visto que se adiciona imprecisões do MDT e do próprio processamento do descritor HAND.

Com relação ao modelo HAND, diante dos resultados produzidos, compreendeu-se que de maneira geral o algoritmo pôde desempenhar papel fundamental como preditor de inundações em regiões com baixa disponibilidade de dados hidrológicos, principalmente locais com estações de medição deficientes no tempo e no espaço.

Porém, é evidente que a aplicação depende dos dados topográficos disponíveis e da escala da área avaliada. Em cidades do porte de Jaqueira, o uso de modelos digitais de baixa resolução espacial e vertical – a exemplo do SRTM – podem ser absolutamente indevidos na tomada de decisão em relação à indicação de pontos vulneráveis à inundação. Na medida em que aumenta o domínio estudado (áreas urbanas como a de Palmares ou escalas de bacias hidrográficas), os modelos digitais com estas características podem ser úteis. No caso de Pernambuco, a precisão do PE3D foi essencial para o bom desempenho do modelo HAND obtido, sendo evidenciado na escala local para a cidade de Palmares.

Outra questão relativa ao modelo HAND está na indicação do limiar da área acumulada para definição do canal de drenagem. O adequado desempenho do algoritmo como preditor de inundações está estritamente relacionado com essa escolha. Durante o processamento, verificou-se que o analista deve ter um entendimento acerca da evolução do fenômeno hidrológico na região estudada. Isso porque a escolha dos canais de drenagem pode influenciar diretamente em super ou subestimativas.

No caso de Jaqueira[*] e de Palmares, o evento surge principalmente com intensas chuvas a montante. É claro e inequívoco que as condições antes do evento são fundamentais para uma área ser atingida. Entretanto, entender a causa principal do evento é primordial. Recorda-se que existem as cheias urbanas por falhas de dispositivos hidráulicos ou ainda características hidrodinâmicas de canais secundários. Dessa forma, nas duas cidades o limiar escolhido foi baseado no canal principal, ou seja, no rio Pirangi (Jaqueira) e no rio Una (Palmares).

Além disso, três pontos foram percebidos e devem ser, na medida do possível, analisados cuidadosamente. O primeiro é a definição de uma única altura para estimar a inundação em todo o domínio avaliado, promovendo super ou subestimativas. O segundo está relacionado com a necessidade de informações auxiliares da inundação, sendo indispensável para o estabelecimento da altura HAND para descrever o fenômeno hidrológico, tornando-o limitado quando não há qualquer dado do evento. O terceiro se refere ao HAND ser estático, impedindo análises relacionadas ao desenvolvimento do fluxo associado à dimensão temporal

[*] O HAND para Jaqueira foi utilizado somente para a inferência probabilística

e da presença de dispositivos hidráulicos (barragens, diques...) que não são captados pelo modelo HAND.

5 CONCLUSÕES E RECOMENDAÇÕES

Neste trabalho foi observado que a Krigagem Ordinária apresentou resultados satisfatórios na inferência de profundidades de inundação sobre as cidades avaliadas. Essa conclusão se baseia no coeficiente de correlação obtido de 99,98% e de 98,81% para Jaqueira e Palmares, respectivamente. Destaca-se também que outras medidas de comparação entre os valores medidos e estimados apontaram bom desempenho para os modelos escolhidos. Um dos objetivos da inferência através da Geoestatística é minimizar a variância do erro e igualar próximo a zero a média dos erros, sendo tal finalidade alcançada. Dessa forma, conclui-se que a Krigagem Ordinária de fato é um preditor com boa exatidão local.

Além disso, a possibilidade de medir a incerteza do processo tendo em vista o contexto dos danos causados pelas inundações é sem dúvida uma das grandes vantagens verificada na utilização de técnicas de Geoestatística. Para Palmares, a incerteza variou de 0,09 a 1,64 m no cenário C (modelo final), enquanto no cenário D oscilou entre 0,10 a 1,28 m. Entretanto, como a confiança do modelo é avaliada por *pixel*, escolhas mais inteligentes podem ser tomadas. Visto que o modelo final, apesar de apresentar maior variância foi escolhido por ter exibido maior exatidão nas áreas construídas da cidade de Palmares. Com relação a Jaqueira, a incerteza do modelo escolhido variou de 0,03 a 0,83 m. Ressalta-se também que nas células distantes das amostras (falta de dados) ou próximas às regiões de *clusters* produziram células com baixa confiança.

Avaliando os resultados em ambas as cidades, percebeu-se melhor desempenho no evento de Jaqueira. Isso foi verificado, possivelmente, por causa dos seguintes fatores: a quantidade de amostras e o tamanho da área inferida, os quais foram maiores em Palmares; a não-normalidade dos dados de entrada para Palmares, produzindo maiores erros na inferência; a destruição de parte da cidade de Palmares pode ter dificultado a amostragem, induzindo viés; não houve pós-processamento (correção) dos dados no levantamento planimétrico em Palmares; o levantamento de Jaqueira embora tenha sido realizado aproximadamente dois anos depois da ocorrência do fenômeno e as profundidades obtidas segundo entrevistas dos moradores, o que pode promover incertezas, a etapa de pós-processamento em ambiente SIG foi fundamental; além dos próprios quesitos subjetivos adotados nas etapas da Geoestatística.

Na modelagem em Jaqueira foi encontrado um procedimento que demonstra a importância de se analisar os dados de maneira parcimoniosa. A simples estratégia de extrair amostras na modelagem do semivariograma pôde produzir um semivariograma empírico mais

coeso, melhorando a inferência tanto na etapa da Validação Cruzada, quanto nas saídas dos mapas de inundação e de incerteza.

Outro ponto observado refere-se às particularidades de etapas da Geoestatística discutidas na literatura que foram essenciais para a obtenção de resultados coerentes que sintetizassem o fenômeno. Destacam-se, nesse sentido, a análise exploratória dos dados como fundamental para a transformação e a remoção das tendências globais das amostras; os aspectos da modelagem do semivariograma empírico em relação aos parâmetros de busca das observações, ao padrão da variabilidade para diferentes distâncias e à análise da variância por meio da superfície do semivariograma; o ajuste do semivariograma teórico de modo automático, facilitando o processo; a Validação Cruzada como técnica para verificar a concordância do modelo selecionado com os valores medidos.

Com relação ao modelo HAND, este foi essencial para a obtenção do mapa de inundação pela Krigagem Ordinária. O descritor possibilitou a transformação das profundidades de inundação para normalização dos dados, no caso de Jaqueira, e uma distribuição mais próxima possível da normalidade, circunstância observada na análise dos dados de Palmares. Ademais, o modelo HAND viabilizou a extensão dos eventos, o que não seria alcançado caso as estimativas fossem realizadas sobre as profundidades de inundação sem qualquer transformação.

Sobre a ótica da predição, o algoritmo HAND foi otimizado através da curva ROC, utilizando o mapa de referência obtido pela Krigagem Ordinária. Neste sentido, encontrou-se um limiar ótimo de 10,5m. Tal resultado apontou elevada taxa de acerto (99%), porém houve erros consideráveis na taxa de alarme falso (15%), ou seja, superestimação do modelo simulado (falsos positivos). Destaca-se que o erro considerável da taxa de alarme falso pode produzir planejamentos errôneos durante um possível evento com magnitude similar, além de maiores custos para preparação (segurança) das regiões falsamente simuladas, por isto os falsos positivos não podem ser negligenciados. Por este motivo, evidencia-se a importância de produzir mapas com dados reais e gerados segundo diferentes abordagens.

Além disso, foram aplicadas 5 métricas de desempenho em relação ao limiar de corte (10,5m) do modelo HAND em comparação com modelo Krigado. O estatístico *Fit Index* (85%) foi o que apresentou melhor coerência a respeito do desempenho global da simulação HAND. Tal parâmetro pune tanto os falsos positivos quanto os falsos negativos. Ressalta-se que o erro mais nocivo, os falsos negativos, foi quase desprezível (1%), evidenciando o poder de predição do modelo HAND.

Não obstante do bom desempenho encontrado pelo HAND, algumas limitações foram percebidas no processo. Caso não exista nenhuma informação complementar (mapas observados, estações fluviométricas e pontos de inundação, por exemplo), o modelo HAND se torna obsoleto, visto que não há conexão entre o fenômeno e a altura do descritor. Outra barreira encontrada está vinculada com os aspectos da dinâmica do escoamento, que podem não ser explicados pelo HAND, somente por modelos hidrodinâmicos. Além disso, um limiar de corte constante representando todo o evento produziu efeitos distintos a jusante e a montante da cidade de Palmares, justamente por causa das condições hidrodinâmicas. Por fim, destaca-se que o resultado é estático, limitando o aspecto temporal tão importante na evolução das inundações.

Para a obtenção do mapa de probabilidade de recorrência e simulação de eventos passados foi estabelecida uma conexão entre o modelo HAND e a estação fluviométrica Palmares. Inicialmente, a série temporal das cotas de máximos anuais passou por análises de regressão e de testes estatísticos. Foi encontrada uma tendência de crescimento dos níveis ao longo do tempo e os testes indicaram independência, homogeneidade e estacionariedade. Diante deste cenário, aplicou-se para as cotas de máximos anuais 6 distribuições de extremos, em que a de Gumbel foi selecionada.

Com isso, a estação foi amarrada ao modelo HAND após visitas em campo, avaliações sobre documentos alcançados junto à CPRM e ao site da SNIRH e análises acerca da altimetria HAND. Decidiu-se por retirar meio metro das cotas para estabelecer a normalização entre ambos. Dessa forma, obteve-se o mapa de perigo com tempos de recorrência de 2, 5, 10, 25 e 100 anos. Além disso, inundações passadas foram simuladas para os anos 2000, 2010, 2011 e 2017.

No contexto geral, as metodologias e os dados utilizados neste trabalho puderam descrever o fenômeno da inundação de maneira consistente. Destaca-se que as ferramentas usadas não necessitam de múltiplas fontes de dados e são de fácil compreensão e aplicação, apesar dos esforços exigidos na Krigagem Ordinária nas etapas da Geoestatística, bem como a subjetividade intrínseca. Ressalta-se também que o desenvolvimento do projeto PE3D possibilitou um conhecimento de alta resolução sobre a topografia e o imageamento do estado de Pernambuco, resultando em aplicações inteligíveis e fundamentais como as apresentadas neste trabalho.

Entenda-se, por outro lado, que as metodologias se basearam em levantamentos de campo sujeitos às imprecisões. O levantamento das marcas de cheia pelo Corpo de Bombeiros identificou profundidades em relação ao solo e com o suporte do HAND, foram estimadas as

profundidades nas regiões avaliadas. No caso do Hidromapp o procedimento foi similar, no entanto em diversos pontos a partir de informações dos moradores. Além disso, ressalta-se a inexatidão da posição espacial da estação fluviométrica e suas imprecisões associadas à medição. Para os três casos podem ocorrer erros aleatórios, sistemáticos e grosseiros, gerando incertezas. Isso, porém não invalida os procedimentos utilizados, apenas se destaca que as imprecisões podem se refletir nas manchas de inundação avaliadas.

Por fim, recomenda-se para pesquisas futuras:

- No aspecto da Krigagem Ordinária sobre as profundidades de inundação das cidades examinadas: aplicar a exclusão de pontos para obtenção de distribuições normais mais rigorosas (aceitas nos testes estatísticos); utilizar o MDT para transformação das profundidades dos eventos ao invés do algoritmo HAND; executar diferentes curvas para remoção das tendências globais; testar outros modelos teóricos, tais como o circular, o *stable*, o *J-Bessel*, o *K-Bessel*, o *Hole Effect*, o *Rational Quadratic* e o *Tetrasphérical*, dentre outros; ajustar o modelo teórico manualmente; aplicar o *jackknife* ao contrário da Validação Cruzada.
- No contexto da Geoestatística, aplicar sobre as profundidades de inundação outras técnicas como a Krigagem Universal, a Krigagem Indicativa, a Krigagem multi-Gaussiana e a Cokriging (adicionando o modelo HAND como variável secundária ou outra abordagem baseada em parâmetros físicos ou MDT;
- Gerar o modelo HAND através de outras fontes de obtenção do MDT como os projetos globais: SRTM, ASTER, VERTEX e ALOS World 3D. Tais avaliações poderão indicar vantagens e desvantagens em relação ao uso de dados LIDAR utilizados.
- Dividir a metodologia HAND em duas regiões (oeste e leste) na cidade de Palmares. Com isso, aplicar a curva ROC com o objetivo de obter limiares ótimos para cada área, aumentando o desempenho do HAND.
- Comparar: as manchas de inundação da Krigagem Ordinária e do modelo HAND com resultados de simulação obtidos com modelos hidrológicos e hidrodinâmicos; os resultados obtidos pela Krigagem Ordinária com outros interpoladores probabilísticos e determinísticos; as simulações do HAND em Palmares com mapas observados levantados em outras épocas como para os anos de 2000 e de 2017; os mapas de profundidades obtidos pela Krigagem Ordinária e por simulações hidrológicas e hidrodinâmicas.

- Analisar outros testes de estacionaridade sobre a estação fluviométrica de Palmares como o Sen’s Slope e o teste de Petit. Ademais, aplicar metodologias que exprimam a probabilidade dos erros do Tipo I e do Tipo II.
- Através das profundidades de inundação e outros dados espaciais, aplicar técnicas de multicritério, de regressão logística e de algoritmos voltados para *machine learning*.
- Empregar outros descritores de terreno (declividade, índice topográfico, distância mais próxima ao corpo d’água e curvatura) tendo em vista o potencial do projeto PE3D para todo o estado de Pernambuco.
- Devido à limitação da tecnologia LIDAR em mapear terrenos abaixo da superfície de água, aconselha-se aos órgãos públicos de Pernambuco que nas cidades frequentemente atingidas pelas inundações sejam realizados levantamentos batimétricos pelo menos nos trechos da calha fluvial que são interceptados pela mancha urbana.
- Uso e divulgação do aplicativo Hidromapp por equipes que trabalham em prol da defesa civil com participação das Universidades, promovendo incentivos aos alunos de graduação e de pós-graduação para pesquisa, do ensino secundário e dos agentes públicos. A participação colaborativa da sociedade pode ser uma fonte importante de dados para estudos e projetos e tomada de decisão por parte do poder público.

REFERÊNCIAS

AFSHARI, S. *et al*. Comparison of new generation low-complexity flood inundation mapping tools with a hydrodynamic model. **Journal of Hydrology**, v. 556, p. 539 - 556, 2018.

AGÊNCIA NACIONAL DAS ÁGUAS (ANA). **Conjuntura dos recursos hídricos no Brasil 2017**: relatório pleno. Brasília - DF. 169 p. 2017.

AGÊNCIA NACIONAL DAS ÁGUAS (ANA). **HIDROWEB**. Versão 3.1.1. Dados Fluviométricos. 2019. Disponível em: www.snirh.gov.br/hidroweb/. Acesso em: 20 de jun. 2019.

AGÊNCIA NACIONAL DAS ÁGUAS (ANA). **Ficha de Campo**. Versão 2.0.0.4. Documentos de Campo sobre Dados Fluviométricos. 2019. Disponível em: http://www.snirh.gov.br/fichadecampo/restrito/principal.jsf. Acesso em: 17 ago. 2019.

AGÊNCIA ESTADUAL DE PLANEJAMENTO E PESQUISAS DE PERNAMBUCO (CONDEPE/FIDEM). **Bacia Hidrográfica do rio Una, GL4 e GL5**: Séries Bacias Hidrográficas de Pernambuco nº 3. Recife, Pernambuco, 85 p., 2006.

AGÊNCIA PERNAMBUCANA DE ÁGUAS E CLIMA (APAC). **Bacia Hidrográfica do rio Una**. Disponível em: http://200.238.107.184/bacias-hidrograficas/40-bacias-hidrograficas/209-bacia-do-rio-una. Acesso em: 02 mar. 2020.

AHMAD, I. *et al*. Precipitation trends over time using Mann-Kendall and spearman's rho tests in swat river basin, Pakistan. **Advances in Meteorology**, v. 2015, p. 1 - 15. 2015.

AHMAD, U. N.; SHABRI, A.; ZAKARIA, Z. A. Flood frequency analysis of annual maximum stream flows using L-moments and TL-moments approach. **Applied Mathematical Sciences**, v. 5, n. 5, p. 243-253, 2011.

ALBERTI, M. *et al*. The impacto f urban patterns on aquatic ecosystems: An empirical analysis in puget lowland sub-basins. **Landscape and Urban Planning**, v.80, p.345 - 361, 2007.

ALLOUIS, T. *et al*. Comparison of LiDAR waveform processing methods for very shallow water bathymetry using Raman, near-infrared and green signals. **Earth Surface Processes and Landforms: The Journal of the British Geomorphological Research Group**, v. 35, n. 6, p. 640 - 650, 2010.

ALVES, F. H. B. **Sistema de previsão de enchentes: integração de modelos de previsão de chuva, simulação hidrológica e hidrodinâmica.** 2017. Dissertação de Mestrado. Universidade Federal de Pernambuco. 2017.

AMARAL, R.; RIBEIRO, R.R. Inundações e Enchentes. In: TOMINAGA, L.K.; SANTORO, J.; AMARAL, R (Org.). **Desastres Naturais**: Conhecer para prevenir. São Paulo: Instituo Geológico, p.39 - 52, 2009.

ARCHFIELD, S.A. *et al*. Topological and canonical kriging for design flood prediction in ungauged catchments: an improvement over a traditional regional regression approach? **Hydrology and Earth System Sciences**, v. 17, n. 4, p. 1575, 2013.

BACK, A. J. Aplicação de análise estatística para identificação de tendências climáticas. **Pesquisa agropecuária brasileira**, v. 36, n. 5, p. 717-726, 2001.

BALDASSARRE, G.D. *et al*. Flood-plain mapping: a critical discussion of deterministic and probabilistic approaches. **Hydrological Sciences Journal – Journal des Sciences Hydrologiques**, v.55, n.3, p.364 – 376, 2010.

BALTSAVIAS, E. P. A comparison between photogrammetry and laser scanning. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 54, n. 2 – 3, p. 83 – 94, 1999.

BANCO MUNDIAL. Avaliação de Perdas e Danos: Inundações Bruscas em Pernambuco - junho de 2010. Relatório elaborado pelo Banco Mundial com apoio do Governo do Estado de Pernambuco. Brasília - DF, 76 p. 2012.

BARNES, L. R. *et al*. Corrigendum: False alarm rate or false alarm ratio? **Weather and Forecasting**, v. 24, n. 5, p. 1452-1454, 2009.

BARNES, L. R. *et al*. False alarms and close calls: A conceptual model of warning accuracy. **Weather and Forecasting**, v. 22, n. 5, p. 1140-1147, 2007.

BATES, P. D. Integrating remote sensing data with flood inundation models: how far have we got?. H**ydrological processes**, v. 26, n. 16, p. 2515-2521, 2012.

BATES, P.D. Remote sensing and flood inundation modelling. **Hydrological Processes**, v.18, n.13, p. 2593-2597, 2004.

BATES, P.D.; ROO, A.P.J. A simple raster-based model for flood inundation simulation. **Journal of Hydrology**, v.236, n. 1-2, p.54-77, 2000.

BRAKENRIDGE, G.R. Flood risk mapping from orbital remote sensing. **Global flood hazard: Applications in modeling, mapping, and forecasting**, p.43 – 54, 2018.

BRAKENRIDGE, G.R. **Global Active Archive of Large Flood Events**. Dartmouth Flood Observatory, University of Colorado, 2020. Disponível em: https://floodobservatory.colorado.edu/Archives/index.html. Acesso em: 10 jan. 2020.

BRANDALIZE, M. C. B. *et al*. **A qualidade cartográfica dos resultados do laserscanner aerotransportado**. Tese de Doutorado, Universidade Federal de Santa Catarina, 2004.

BRANDALIZE, A. A. Perfilamento a LASER: comparação com métodos Fotogramétricos. In: **XX congresso Brasileiro de Cartografia**, Rio Grande do Sul, 2001.

BRASIL. Comissão especial externa, criada por intermédio do requerimento Nº 426, de 2000-SF "Destinada a acompanhar o drama das enchentes nos estados de Pernambuco e Alagoas, que já ocasionaram morte de vítimas". Congresso Brasileiro, Câmera do Senado, Brasília – DF, p. 34.

BRASIL. Relatório Final da Comissão Externa das Chuvas em Alagoas e Pernambuco. Congresso Brasileiro, Câmera dos Deputados, Brasília - DF, p.51. 2017.

BROUWER, T. **Potential of Twiter derived flood maps: comparing interpolation methods and assessing uncertainties**. Dissertação de Mestrado, Univesity of Twente, 2016.

CÂMARA, G. *et al*. Análise Espacial e Geoprocessamento. **Análise espacial de dados geográficos.** Brasília: EMBRAPA, cap.1, 2004.

CAMARGO, E. C. G.; FUCKS, S. D.; CÂMARA, G. Análise Espacial de Superfícies. **Análise espacial de dados geográficos.** Brasília: EMBRAPA, cap.3, p.79 – 122, 2004.

CAMARGO, E. C. G. Geoestatística: fundamentos e aplicações. **Geoprocessamento para Projetos Ambientais.** São José dos Campos: INPE, cap.5, 1998.

CHAPI, K. *et al*. A novel hybrid artificial intelligence approach for flood suscptibility assessment. **Environmental Modelling & Software**, v. 95, p. 229 – 245, 2017.

CHEN, W. *et al*. Flood susceptibility modelling using novel hybrid approach of reduced-error pruning trees with bagging and random subspace ensembles. **Journal of Hydrology**, v. 575, p. 864-873, 2019.

CHIRPS: Rainfall Estimates from Rain Gauge and Satellite Observations. **Produtos CHIRPS-2.0 – Precipitação Média Annual Global**. Disponível em: https://data.chc.ucsb.edu/products/CHIRPS-2.0/global_annual/. Acesso em: 10 mar. 2020.

CHOUDHURY, N.Y.; PAUL, A.; PAUL, B.K. Impacto f costal embankment on the flash flood in Bangladesh: A case study. **Applied Geography**, v.24, p. 241 - 258, 2004.

CHOWDHURI, I; PAL, S.C.; CHAKRABORTTY, R. Flood susceptibility mapping by ensemble evidential belief function and binomial logistic regression model on river basin of eastern India. **Advances in Space Research**, v. 65, n. 5, p. 1466-1489, 2020.

CHOW, Ven T. Statistical and probability analysis of hydrologic data. **Handbook of aApplied Hydrology**, v. 8, n. 1, 1964.

CIRILO, J. A. *et al*. Cntrol and forecasting in the state of Pernambuco, Brazil: hydrological aspects and actions for reconstruction; In: **XIV World Water Congress**, Porto de Galinhas, Ipojuca, Pernambuco, 2011.

CIRILO, J.A. *et al*. Pernambuco Tridimensional: base de dados espaciais para planejamento urbano e gestão territorial. **SILUSBA – Simpósio de Hidráulica e Recursos Hídricos dos Países de Língua Portuguesa, 12**, 2015.

CIRILO, J.A. *et al*. Suporte de Informações Georreferenciadas de Alta Resolução para Implantação de Infraestrutura e Planejamento Territorial. **Revista Brasileira de Geografia Física**, v. 7, n. 4, p. 755-763, 2014.

CLARK, I. **Practical geostatistics**.119 p, 2001. ISBN 0-97033-17-03. Disponível em: http://www.kriging.com/PG1979/PG1979.pdf. Acesso em: 15 jan. 2020.

COOK, A.; MERWADE, V. Effect of topographic data, geometric configuration and modeling approach on flood inundation mapping. **Journal of hydrology**, v. 377, n. 1 - 2, p. 131-142, 2009.

CRESSIE, N.; HAWKINS, D. M. Robust estimation of the variogram: I. **Journal of the International Association for Mathematical Geology**, v. 12, n. 2, p. 115-125, 1980.

CRESSIE, N. Kriging nonstationary data. **Journal of the American Statistical Association**, v. 81, n. 395, p. 625-634, 1986.

CRESSIE, N. **Statistics for spatial data**. John Willy and Sons, Inc. New York, 900 p., 1993.

CUARTAS, L. A. *et al*. Distributed hydrological modeling of a micro-scale rainforest watershed in Amazonia: Model evaluation and advances in calibration using the new HAND terrain model. **Journal of Hydrology**, v. 462, p. 15 – 27, 2012.

CUNNANE, C. Statistical distributions for flood frequency analysis. **Operational Hydrology Report** (WMO), 1989.

DANTAS, C.E.O. **Previsão e controle de inundações em meio urbano com suporte de informações espaciais de alta resolução**. 2012. Tese de Doutorado. Universidade Federal de Pernambuco.

DEGIORGIS, M. *et al*. Classifiers for the detection of flood-prone areas using remote sensed elevation data. **Journal of Hydrology**, v.470, p.302 -315, 2012.

DJALANTE, R. Key assessments from the IPCC special report on global warming of 1.5 ºC and the implications for the Sendai framework for disaster risk reduction. **Progress in Disaster Science**, v.1, p. 01 - 05, 2019.

EHLERS, R.S. Análise de Séries Temporais. **Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná**, p. 118, 2007.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Súmula da 10. Reunião Técnica de Levantamento de Solos**. Serviço Nacional de Levantamento e Conservação de Solos, Rio de Janeiro, 83 p., 1979.

EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA (EMBRAPA). **Sistema Brasileiro de Classificação de Solos**. 5 ed., Brasília, Distrito Federal, 356 p., 2018.

EMERGENCY EVENTS DATABASE (CENTER FOR RESEARCH ON THE EPIDEMIOLOGY OF DISASTERS). **Total number of deaths as a result of natural disasters**. School of Public Health, University Catholique de Louvain, Bruxelas, Bélgica. 2020. Disponível em: https://www.emdat.be/. Acesso em: 10 jan. 2020.

FELGUEIRAS, C. A. **Modelagem ambiental com tratamento de incertezas em sistemas de informação geográfica: o paradigma geoestatístico por indicação**. Tese de Doutorado. São José dos Campos: INPE, 213.p, 2001.

FEWTRELL, T. J. *et al*. Benchmarking urban flood models of varying complexity and scale using high resolution terrestrial LiDAR data. **Physics and Chemistry of the Earth**, v. 36, n. 7 – 8, p. 281 – 291, 2011.

FREER, J. *et al*. Flood risk and uncertainty. In: ROUGIER, J.; SPARKS, S.; HILL, L. (Org.). **Risk and Uncertainty Assessment for Natural Hazards**. Cambridge: Cambridge University Press. p. 190 - 233, 2013.

FURDADA, G.; CALDERÓN, L.E.; MARQUÉS, M.A. Flood hazard map of la Trinidad (NW Nicaragua. Method and results. **Natural Hazards**, v.45, n.2, p. 183 – 195, 2008.

GHARARI, S. *et al*. Hydrological landscape classification: investigating the performance of HAND based landscape classifications in a central European meso-scale catchment. **Hydrology & Earth System Sciences**, v. 15, n. 11, p. 3275 – 3291, 2011.

GIUSTARINI, L. *et al*. Accounting for image uncertainty in SAR-based flood mapping. **International journal of applied earth observation and geoinformation**, v. 34, p. 70-77, 2015.

GOERL, R.; MICHEL, G. P.; KOBIYAMA, M. Mapeamento de áreas susceptíveis a inundação com o modelo HAND e análise do seu desempenho em diferentes resoluções espaciais. **Revista Brasileira de Cartografia**, v. 69, n. 1, p. 61 - 69, 2017.

GRIMALDI, S. *et al*. Flood mapping under vegetation using single SAR acquisitions. **Remote Sensing of Environment**, v. 237, p. 1 - 20, 2020.

GOOSSENS, C.; BERGER, A. Annual and seasonal climatic variations over the northern hemisphere and Europe during the last century. **In: Annales Geophysicae**. 1986. p. 385.

HAGHIGHATAFSHAR, S. *et al*. Efficiency of blue-green stormwater retrofits for flood mitigation – Conclusions drawm from a case study in Malmö, Sweden. **Journal of Environmental Management**, v.207, p. 60 - 69, 2018.

HORRITT, M. S.; BATES, P. D. Evaluation of 1D and 2D numerical models for predicting river flood inundation. **Journal of hydrology**, v. 268, n. 1-4, p. 87-99, 2002.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Anuário Estatístico do Brasil**: 1997. Rio de Janeiro, v.57, 1998.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **BC250 – Base Cartográfica Contínua do Brasil – 1:250 000**. Rio de Janeiro, 2019. Disponível em: https://portaldemapas.ibge.gov.br/portal.php#mapa222602. Acesso em: 8 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Brasil – Geologia – 1:250 000**. Rio de Janeiro, 2019. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/geologia/levantamento_geologico/vetores/escala_250_mil/versao_2019/. Acesso em: 9 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Brasil – Geomorfologia – 1:250 000**. Rio de Janeiro, 2019. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/geomorfologia/vetores/escala_250_mil/versao_2019/. Acesso em: 9 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Nordeste – Hidrogeologia – 1:250 000**. Rio de Janeiro, 2019. Disponível em: https://www.ibge.gov.br/geociencias/informacoes-ambientais/geologia/15824-hidrogeologia.html?=&t=downloads. Acesso em: 10 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Brasil – Pedologia – 1:250 000**. Rio de Janeiro, 2019. Disponível em: https://geoftp.ibge.gov.br/informacoes_ambientais/pedologia/vetores/escala_250_mil/versao_2019/. Acesso em: 10 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Brasil – Vegetação – 1:250 000**. Rio de Janeiro, 2019. Disponível em:

https://geoftp.ibge.gov.br/informacoes_ambientais/vegetacao/vetores/escala_250_mil/versao_2019/. Acesso em: 9 mar. 2020.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Classificação da vegetação brasileira, adaptada a um sistema universal**. Rio de Janeiro, 1991.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual técnico da vegetação brasileira**: Sistema fitogeográfico inventário das formações florestais e campestres, Técnicas e manejo de coleções botânicas e Procedimentos para mapeamentos. 2 ed., Rio de Janeiro, 2012.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Manual técnico de geomorfologia**. 2 ed., Rio de Janeiro, 2009.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Mapa Brasil Climas – 1: 5 000 000**. Rio de Janeiro, 2002. Disponível em: https://www.ibge.gov.br/geociencias/informacoes-ambientais/climatologia/15817-clima.html?=&t=downloads. Acesso em: 8 mar. 2020.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE); CENTRO NACIONAL DE MONITORAMENTO E ALERTAS DE DESASTRES NATURAIS (Cemaden). **HAND model:** a new look over the landscape. Versão 0.8.1. 2019. Disponível em: http://handmodel.ccst.inpe.br/. Acesso em: 20 jul. 2019.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change 2014**: Impacts, Adaptation, and Vulnerability. In: FIELD, C.B. *et al*. (Org.). Part A:Global and Sectoral Aspects. Working Group II Contribution to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, p.1132, 2014.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Climate Change and Land**:An IPCC Special Report on Climate Change, Desertification, Land
Degradation, Sustainable Land Management, Food Security, and Greenhouse gas fluxes in Terrestrial Ecosystems In: Shukla, P.R. *et al*. (Org.). Sumary for Policymakers. In Press, 2019.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Global Warming of 1.5ºC**: An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate povertyIn: MASSON-DELMONTE, P.*et al*. (Org.). Sumary for Policymakers. Genebra: World Meteorological Organization, p.32, 2018

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE (IPCC). **Mananging the risks of extreme events and disasters to advance climate change**

adaptation. In: FIELD, C.B. *et al*. (Org.). Special Report of Working Groups I and II of the Intergovernmental Panel on Climate Change. Cambridge: Cambridge University Press, p.582, 2012.

ISAAKS, E. H.; SRIVASTAVA, M. R. **Applied geostatistics**. Oxford University Press, 1989.

JAFARZADEGAN, K.; MERWADE, V. A DEM-based approach for large-scale floodplain mapping in ungauged watersheds. **Journal of Hydrology**, v. 550, p. 650-662, 2017.

JAFARZADEGAN, K.; MERWADE, V. Probabilistic floodplain mapping using HAND-based statistical approach. **Geomorphology**, v.324, p. 48-61, 2019.

JENSON, S. K.; DOMINGUE, J. O. Extracting topographic structure from digital elevation data for geographic information system analysis. **Photogrammetric Engineering and Remote Sensing**, v. 54, n. 11, p. 1593-1600, 1988.

JHA, A.K.; BLOCH, R.; LAMOND, J. **Cidade e Inundações**: Um guia para a Gestão Integrada do Risco de Inundação Urbana para o Século XXI. Brasília: Ed. Joaquin Toro e Frederico Ferreira Pedroso. Banco Mundial e Global Facility for Disaster Reduction and Recovery. p. 54, 2012.

JOHANNESSON, G.; CRESSIE, N. Finding large-scale spatial trends in massive, global, environmental datasets. **Environmetrics: The official journal of the International Environmetrics Society**, v. 15, n. 1, p. 1-44, 2004.

JONKMAN, S.N. **Global Perspectives on Loss of Human Life Caused by Floods**. Natural Hazards, v.34, p. 151 - 175, 2005.

JOURNEL, A. G.; HUIJBREGTS, C. J. **Mining geostatistics**. London: Academic press, 1978.

JOURNEL, A. G. New distance measures: The route toward truly non-Gaussian geostatistics. **Mathematical Geology**, v. 20, n. 4, p. 459 – 475, 1988.

KOBLER, A. *et al*. Repetitive interpolation: A robust algorithm for DTM generation from Aerial Laser Scanner Data in forested terrain. **Remote sensing of environment**, v. 108, n. 1, p. 9 - 23, 2007.

KOCH, G. S.; LINK, R. F. **Statistical analysis of geological data**. John Willey e Sons Inc, Ney York, EUA, 1971.

KOUTSOYIANNIS, D. Nonstationarity versus scaling in hydrology. **Journal of Hydrology**, v. 324, n. 1-4, p. 239-254, 2006.

KRIGE, D. G. A statistical approach to some basic mine valuation problems on the Witwatersrand. **Journal of the Southern African Institute of Mining and Metallurgy**, v. 52, n. 6, p. 119 – 139, 1951.

KUNDZEWICZ, Z. W. *et al*. Flood risk and climate change: global and regional perspectives. **Hydrological Sciences Journal**, v. 59:1, p. 1 - 28, 2014.

LACTEC. **Mapeamento Digital a Laser e Ortofotos Digitais em Área de 1.235 km² no Estado de Pernambuco**. Curitiba – PR, p. 47, 2011.

LAGE, M.O. *et al*. MODELAGEM DE PARÂMETROS DE UM VANT EQUIPADO COM LIDAR EM APLICAÇÕES DE MONITORAMENTO DE LINHAS DE TRANSMISSÃO DE ENERGIA ELÉTRICA. **Revista Brasileira de Cartografia**, v. 69, n. 6, 2017.

LANDIM, Paulo M. Barbosa. Sobre geoestatística e mapas. **Terrae Didatica**, v. 2, n. 1, p. 19-33, 2006.

LEITE, A.C.C. **Identificação e levantamento do estado de conservação de nascentes a partir de índices ambientais utilizando dados espaciais de alta resolução do Projeto Pernambuco Tridimensional (PE3D)**. 2019. Dissertação de Mestrado. Universidade Federal de Pernambuco, Recife - PE.

LI, J.; HEAP, A. D. A review of comparative studies of spatial interpolation methods in environmental sciences: Performance and impact factors. **Ecological Informatics**, v. 6, n. 3-4, p. 228-241, 2011.

LINDSAY, J. B.; CREED, I. F. Removal of artifact depressions from digital elevation models: towards a minimum impact approach. **Hydrological Processes**, v. 19, n. 16, p. 3113-3126, 2005.

LOHR, U.; EIBERT, M. The TopoSys laser scanner-system. In: **Photogrammetric Week**, 1995. p. 263-268.

MACHADO, C. C. C. *et al*. Distúrbio Ondulatório de Leste como condicionante a eventos extremos de precipitação em Pernambuco. **Revista Brasileira de Climatologia**, v. 11, 2012.

MANFREDA, S. *et al*. Flood-prone areas assessment using linear binary classifiers based on flood maps obtained from 1D and 2D hydraulic models. **Natural Hazards**, v. 79, n. 2, p. 735-754, 2015.

MANFREDA, S. *et al*. Investigation on the use of geomorphic approaches for the delineation of flood prone areas. **Journal of hydrology**, v. 517, p. 863-876, 2014.

MANFREDA, S.; LEO, M.D.; SOLE, A. Detection of flood-prone areas using digital elevation models. **Journal of Hydrologic Engineering**, v.16, n.10, p.781-790, 2011.

MAPBIOMAS. **Projeto MapBiomas – Coleção v.05 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil**. Brasil, 2020. Disponível em: https://plataforma.brasil.mapbiomas.org/. Acesso em: 10 mar. 2020.

MARTZ, L. W.; GARBRECHT, J. The treatment of flat areas and depressions in automated drainage analysis of raster digital elevation models. **Hydrological Processes**, v. 12, n. 6, p. 843-855, 1998.

MASON, D. C. *et al*. Floodplain friction parameterization in two-dimensional river flood models using vegetation heights derived from airborne scanning laser altimetry. **Hydrological Processes**, v. 17, n. 9, p. 1711-1732, 2003.

MATHEREON, G. La théorie des variables régionalisées et ses applications. **Cah Cent Morphol Math**, v. 5, p. 1-212, 1970.

MATHERON, G. Présentation des variables régionalisées. **Journal de la société française de statistique**, v. 107, p. 263-275, 1966.

MELO, V.B. *et al*. Inferência Probabilística por meio da Krigagem Ordinária sobre alturas de inundação no município de Jaqueira em Pernambuco. *In*: Simpósio de Recursos Hídricos dos Nordeste, 15., 2020, Caruaru. **Anais** [...]. Associação Brasileira de Recursos Hídricos, p. 1 - 10. 2020.

MENG, Q.; LIU, Z.; BORDERS, B. E. Assessment of regression kriging for spatial interpolation–comparisons of seven GIS interpolation methods. **Cartography and geographic information science**, v. 40, n. 1, p. 28-39, 2013.

MERCER, B. *et al*. DEMs created from airborne IFSAR – an update. **International Archives of Photogrammetry and Remote Sensing**, v. 35, 2004.

MERZ, B.; THIEKEN, A.H.; GOCHT, M. Flood risk mapping at the local scale: concepts and challenges. **Flood risk management in Europe**, Springer, Dordrecht, Neatherlands, p.231 – 251, 2007.

MILANESI, J.; QUADROS, E. L. L.; LAHM, R. A. UTILIZAÇÃO DO MODELO HAND NO RECONHECIMENTO DOS TERRENOS SUJEITOS A INUNDAÇÃO-PORTO ALEGRE/RS. **Revista Brasileira de Cartografia**, v. 69, n. 4, 2017.

MILLINGTON, N.; DAS, S.; SIMONOVIC, S. P. The comparison of GEV, log-Pearson type 3 and Gumbel distributions in the Upper Thames River watershed under global climate models **Water Resources Research Report**. 54p. 2011.

MOMO, M. R. *et al*. Desempenho do modelo HAND no mapeamento de áreas suscetíveis à inundação usando dados de alta resolução espacial. **Revista Brasileira de Recursos Hídricos**, v. 21, n. 1, p. 200 - 208, 2016.

MOREIRA, J. G. V.; NAGHETTINI, M. Detecção de tendências monotônicas temporais e relação com erros dos tipos I e II: estudo de caso em séries de precipitações diárias máximas anuais do estado do Acre. **Revista Brasileira de Meteorologia**, v. 31, n. 4, p. 394-402, 2016.

MYERS, D. E. Interpolation and estimation wit h spatially located data. **Chemometrics and Intelligent Laboratory Systems**, v. 11, n. 3, p. 209-228, 1991a.

MYERS, D. E. On variogram estimation. **The frontiers of statistical scientific theory & industrial applications**, v. 2, p. 261-266, 1991b.

NAGHETTINI, M.; PINTO, E.J.A. **Hidrologia Estatística**, CPRM, Belo Horizonte - MG, 552 p., 2007.

NAGHETTINI, M.; PORTELA, M. M. **Probabilidade e estatística aplicadas à hidrologia**. Texto de apoio à unidade curricular Hidrologia e Recursos Hídricos do 3º ano do Mestrado Integrado em Engenharia Civil, 2011.

NOBRE, A.D. *et al*. HAND contour: a new proxy predictor of inundation extent. **Hydrological Processes**, v.30, n.2, p.320 - 333, 2015.

NOBRE, A. D. *et al*. Height Above the Nearest Drainage - a hydrologically relevant new terrain model. **Journal of Hydrology**, v. 404, n. 1 - 2, p. 13 - 29, 2011.

NOBRE, C. A. *et al*. Vulnerabilidades das megacidades brasileiras às mudanças climáticas: região metropolitana de São Paulo, Relatório Final. **São Paulo**, 2011.

OLIVEIRA, G.A. **Aplicativo Hidromapp**. 2020. Disponível em: www.hidromapp.com.br/. Acesso em: 23/07/2019.

OLIVEIRA, G.A.; BRITO, P.L.; SANTOS, S.M. Mapeamento de risco hidrológicos utilizando Informações Geográficas Voluntárias: Estudo de caso no município de Riachão do Jacuípe - Bahia. **Revista Brasileira de Geografia Física**, v.11, n.01, p. 297 - 311, 2018.

OLIVEIRA, G.A.; CIRILO, J.A.; BRITO, P. L.; NASR, N.E. Qualidade do Posicionamento em Aplicativos VGI Obtido por Sensores de Localização em Smartphones. RBC. **REVISTA BRASILEIRA DE CARTOGRAFIA** (ONLINE), v.71, p.806 - 831, 2019.

OLIVEIRA, G. A. **Desastres Hidrológicos e Informações Geográficas Voluntárias:** concepção de sistema colaborativo para o mapeamento de áreas de riscos. 2017. Dissertação de Mestrado. Universidade Federal da Bahia. 2017.

OLIVER, M. A.; WEBSTER, R. A tutorial guide to geostatistics: Computing and modelling variograms and kriging. **Catena**, v. 113, p. 56-69, 2014.

ONEN, F.; BAGATUR, T. Prediction of flood frequency factor for Gumbel distribution using regression and GEP model**. Arabian Journal for Science and Engineering**, v. 42, n. 9, p. 3895-3906, 2017.

PÉREZ-MESA, G.J. **Propuesta Metodológica para la Estimación de Zonas de Inundación con Información Escasa por Medio de Descriptores**

Geomorfométricos Derivados de Modelos Digitales de Elevación. 2014. Dissertação de Mestrado. Universidade Nacional da Colômbia. 2014.

PERNAMBUCO. **PROJETO PERNAMBUCO TRIDIMENSIONAL:** PE3D. Secretária de Desenvolvimento Econômico - SDEC. 2016. Disponível em: www.pe3d.pe.gov.br/, Acesso em: 20/06/2019.

PONTIUS JR, R.; SI, K. The total operating characteristic to measure diagnostic ability for multiple thresholds. **International Journal of Geographical Information Science**, v. 28, n. 3, p. 570-583, 2014.

POSER, K.; DRANSCH, D. Volunteered geographic information for disaster management with application to rapid flood damage estimation. **Geomatica**, v. 64, n. 1, p. 89-98, 2010.

PRIESTNALL, G.; JAAFAR, J.; DUNCAN, A. Extracting urban features from LiDAR digital surface models. **Computers, Environment and Urban Systems**, v. 24, n. 2, p. 65 - 78, 2000.

QUADROS, N. D.; COLLIER, P. A.; FRASER, C. S. Integration of bathymetric and topographic LiDAR: a preliminary investigation. **The International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 36, p.1299 - 1304, 2008.

READ, L. K.; VOGEL, R. M. Reliability, return periods, and risk under nonstationarity. **Water Resources Research**, v. 51, n. 8, p. 6381-6398, 2015.

REFOSCO, J. C. *et al*. Mapas de inundação a partir de geoprocessamento e georreferenciamento - o caso de Blumenau (SC). **XVI Simpósio Brasileiro de Sensoriamento Remoto**, p. 13 - 18, 2013.

RENNÓ, C. D. *et al*. HAND, a new terrain descriptor using SRTM-DEM: Mapping terra-firme rainforest environments in Amazonia. **Remote Sensing of Environment**, v. 112, n. 9, p. 3469 - 3481, 2008.

RIBEIRO, A. A. S. **Aplicação de Smartphones na Engenharia: Levantamento de Manchas de Inundação Utilizando o Aplicativo Hidromapp**. 2019. Trabalho de Conclusão de Curso. Departamento de Engenharia Civil. Universidade Federal de Pernambuco Campus Agrestes, Caruaru-PE. 2019.

RIBEIRO, A. A. S. *et al*. Floodplain reconstitution based on data collected via smartphones: a methodological approach to hydrological risk mapping. RBRH, v. 25, 2020.

RIBEIRO NETO, A. *et al*. Caracterização da formação de cheias na bacia do rio Una em Pernambuco: simulação hidrológica-hidrodinâmica. **Revista Brasileira de Recursos Hídricos**, v.20, n.2, p.394 - 403, 2015.

ROGGER, M. *et al*. Runoff models and flood frequency statistics for design flood estimation in Austria - Do they tell a consistent story? **Journal of Hydrology**, v. 456, p. 30-43, 2012.

ROSNER, A.; VOGEL, R. M.; KIRSHEN, P. H. A risk-based approach to flood management decisions in a nonstationary world. **Water Resources Research**, v. 50, n. 3, p. 1928-1942, 2014.

SAMANTA, S.; PAL, D.K.; PALSAMANTA, B. Flood susceptibility analysis through remote sensing, GIS and frequency ratio model. **Applied Water Science**, v.8, n.2, p.66 (1 - 14), 2018.

SANTOS, K. A. **Modelagem do acompanhamento e controle de cheias em bacias hidrográficas de grande variação de altitude. Estudo de caso: Bacia do Rio Mundaú**. 2013. Dissertação de Mestrado. Universidade Federal de Pernambuco. 2013.

SARMAH, T.; DAS, S. Urban flood mitigation planning for Guwahati: A case of Bharalu basin. **Journal of Environmental Management**. v.206, p.1155 - 1165, 2018.

SCHLAFFER, S. *et al*. Flood detection from multi-temporal SAR data using harmonic analysis and change detection. **International Journal of Applied Earth Observation and Geoinformation**, v. 38, p. 15 - 24, 2015.

SCHUMANN, G *et al*. Comparison of remotely sensed water stages from LiDAR, topographic contours and SRTM. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 63, n. 3, p. 283-296, 2008.

SCHUMANN, G. *et al*. Progress in integration of remote sensing – derived flood extent and stage data and hydraulic models. **Reviews of Geophysics**, v. 47, n. 4, 2009.

SERVIÇO GEOLÓGICO BRASILEIRO (CPRM). [**Correspondência**]. Destinatário: Vitor Barbosa Melo. Recife, 27 set. 2019. Informações, documentos e fotografias sobre a estação fluviométrica Palmares. E-mail.

SERVIÇO GEOLÓGICO BRASILEIRO (CPRM). **Manual de Cartografia Hidrogeológica**. Recife, Pernambuco, 119 p., 2014.

SERVIÇO GEOLÓGICO BRASILEIRO (CPRM). **Geodiversidade de Pernambuco**. Pernambuco, 2010. Disponível em: http://rigeo.cprm.gov.br/jspui/handle/doc/14707?mode=full. Acesso em: 10 mar. 2020.

SIMMONS, K. M.; SUTTER, D. False alarms, tornado warnings, and tornado casualties. **Weather, Climate, and Society**, v. 1, n. 1, p. 38-53, 2009.

SIMONOVIĆ, S. Climate change and risk of flooding. In: **Floods in a Changing Climate: Risk Management** (International Hydrology Series). Cambridge: Cambridge University Press. p. 17 - 30, 2012.

SIMONOVIĆ, S. Flood risk management. In: **Floods in a Changing Climate: Risk Management**: International Hydrology Series. Cambridge: Cambridge University Press. p. 7 - 16, 2012.

SILVA, R.O.B.; MONTENEGRO, S.M.G.L.; SOUZA, W.M. Tendências de mudanças climáticas na precipitação pluviométrica nas bacias hidrográficas de Pernambuco. **Engenharia Sanitária Ambiental**, v.22, n. 03, p.579-589, 2017.

SOARES, A. **Geoestatística para as ciências da terra e do ambiente**. Instituto Superior Técnico Press, Lisboa, Portugal, 214 p., 2006.

SPECKHANN, G.A. *et al*. Flood hazard mapping in Southern Brazil: a combination of flow frequency analysis and the HAND model. **Hydrological Sciences Journal**, v.63, n.1, p. 87-100, 2018a.

SPECKHANN, G.A. **Uma proposta de mapeamento de risco de inundação na bacia do Rio Itajaí utilizando descritores de terreno**. 2018. Dissertação de Mestrado. Universidade Federal de Santa Catarina. 2018b.

STEPHENSON, D. B. Use of the “odds ratio” for diagnosing forecast skill. **Weather and Forecasting**, v. 15, n. 2, p. 221-232, 2000.

STOYNOV, P. *et al*. Modelling of major flood arrivals on Chinese rivers by switch-time processes. In: **Proceedings of the IOP Conference Series: Earth and Environmental Science**, v. 68, 2017.

TANOVE, M.; HIRABAYASHI, Y.; IKEUCHI, H. **Global-scale river flood vulnerability in the last 50 years**. Scientific Reports, v.6, p. 01 - 09, 2016.

TAYEFI, V. et al. A comparison of one-and two-dimensional approaches to modelling flood inundation over complex upland floodplains. **Hydrological Processes**, v. 21, n. 23, p. 3190-3202, 2007.

TINGSANCHALI, T. Urban flood disaster management. **Procedia Engineering**, v.32, p. 25 - 37, 2012.

TOLOSANA-DELGADO, R.; PAWLOWSKY-GLAHN, V.; EGOZCUE, J. J. Indicator kriging without order relation violations. **Mathematical geosciences**, v. 40, n. 3, p. 327-347, 2008.

TUCCI, C.E.M. Águas Urbanas. **Estudos Avançados**, v. 22, n.63, p. 97 - 112, 2008.

TUCCI, C.E.M. (Org.). **Hidrologia**: Ciência e Aplicação. 3. ed. Porto Alegre: Ed. Universidade/UFRGS; ABRH, p. 943, 2004.

TWELE, A. *et al*. Sentinel-1-based flood mapping: a fully automated processing chain. **International Journal of Remote Sensing**, v. 37, n. 13, p. 2990 - 3004, 2016.

VALERIANO, M. de M. **Modelo digital de elevação com dados SRTM disponíveis para a América do Sul**. São José dos Campos: INPE, 72 p. 2004.

VERÇOSA, L. F. M. **Modelagem hidrológica e hidrodinâmica aplicada à avaliação da ocorrência de inundações na cidade de Recife, PE**. 2019. Dissertação de Mestrado. Universidade Federal de Pernambuco. 2019.

VIEIRA, S. R. *et al*. Detrending non stationary data for geostatistical applications. **Bragantia**, v. 69, p. 01-08, 2010.

VIEIRA, S. R. *et al*. Geoestatística em estudos de variabilidade espacial do solo. **Tópicos em ciência do solo.** Viçosa: Sociedade Brasileira de Ciência do Solo, v. 1, p. 1-53, 2000.

VIEIRA, S. R. *et al*. Handbook for geostatistical analysis of variability in soil and climate data. **Tópicos em ciência do solo**, v. 2, p. 1-45, 2002.

VIEIRA, S. R. J. L. *et al*. Geostatistical theory and application to variability of some agronomical properties. **Hilgardia**, v. 51, n. 3, p. 1-75, 1983.

VIRDEE, T. S.; KOTTEGODA, N. T. A brief review of kriging and its application to optimal interpolation and observation well selection. **Hydrological sciences journal**, v. 29, n. 4, p. 367 - 387, 1984.

VOGEL, R. M.; ROSNER, A.; KIRSHEN, P. H. Brief Communication: Likelihood of societal preparedness for global change: trend detection. **Natural Hazards and Earth System Sciences**, v. 13, n. 7, p. 1773-1778, 2013.

WALLEMACQ, P. CENTRE FOR RESEARCH ON THE EPIDEMIOLOGY OF DISASTERS & UNITED NATIONS OFFICE FOR DISASTER RISK REDUCTION. **Economic, Losses, Poverty & Disasters**: 1998-2017.

WARRICK, A. W.; MYERS, D. E. Optimization of sampling locations for variogram calculations. **Water Resources Research**, v. 23, n. 3, p. 496-500, 1987.

WESTERHOFF, R. S. *et al*. Automated global water mapping based on wide-swath orbital synthetic-aperture radar. **Hydrology & Earth System Sciences**, v. 17, n. 1, 2013.

YAMAMOTO, J. K. **Estatística, Análise e Interpolação de Dados Geoespaciais**. Gráfica Paulos, 1 ed. São Paulo – SP, 2020.

WU, J.; NORVELL, W. A.; WELCH, R. M. Kriging on highly skewed data for DTPA-extractable soil Zn with auxiliary information for pH and organic carbon. **Geoderma**, v. 134, n. 1-2, p. 187-199, 2006.

YAZDANI, M. R.; SHEIKH, Z. Applying geostatistical methods for analyzing regional flood frequency in North of Iran (Case Study: Mazandaran Catchments). **Journal of Agricultural Science and Technology**, v.19, n.4, p.861 – 875, 2017.

YU, D.; LANE, S.N. Urban fluvial flood modelling using a two-dimensional diffusion-wave treatment, part 1: mesh resolution effects. **Hydrological Processes: An International Journal**, v. 20, n. 7, p. 1541-1565, 2006.

ZHANG, J. *et al*. TRANSFORMING FLASH FLOODS INTO RESOURCES IN ARID CHINA. **Land Use Policy**, v. 76, p. 746 - 753, 2018.

ZHANG, Y.; DUTTA, D.; VAZE, J. Rapid inundation modelling using LiDAR-DEM in the Mid Murrumbidgee floodplain. In: **Hydrologic and Water Resources Symposium**. Engineers Austalia, p.528, 2012.

ZILLI, M.T.; CARVALHO, L.M.V.; LIEBMANN, B.; DIAS, M.A.S. A comprehensive analysis of trends in extreme precipitation over southeastern coast of Brazil. **International Journal of Climatology**, v.37, n.5, p. 2269 - 2279, 2017

ANEXO A - ÁREA DE ESUTODO (CONTINUAÇÃO)

Vegetação

A cobertura vegetal savana estépica tem predomínio a oeste da BHRU (Figura A1) é característica das regiões semiáridas em que está situado parte do agreste pernambucano. Esta região exibe espécies xerófilas, cactáceas e bromeliáceas. Nas áreas a oeste e ao centro da bacia, a classificação Ecótóno é qualificada pela combinação da cobertura savana estépica e da floresta estacional, funcionando como transição entre as duas classes distintas, designada por tensão ecológica. Na porção central, a bacia exibe a floresta estacional semidecidual, associada ao bioma da mata atlântica. A leste da bacia, encontra-se: a floresta ombrófila densa que é identificada pela mata perenifólia (sempre perene) em regiões tropicais e pela alta densidade de árvores; a floresta ombrófila aberta, a qual possui quatro faciações florísticas e regime pluviométrico com mais de 60 dias seco dentro de um ano e; as formações pioneiras, influenciadas por rios e por interações fluviomarinhas, evidenciadas por mangues, restingas e coqueiros. Por fim, destaca-se que, principalmente, a leste da bacia, as florestas foram sendo desmatadas para a plantação e exploração da cana de açúcar (IBGE, 1991; CONDEPE/FIDEM, 2006; IBGE, 2012).

Figura A1 - Cobertura vegetal da Bacia Hidrográfica do Rio Una

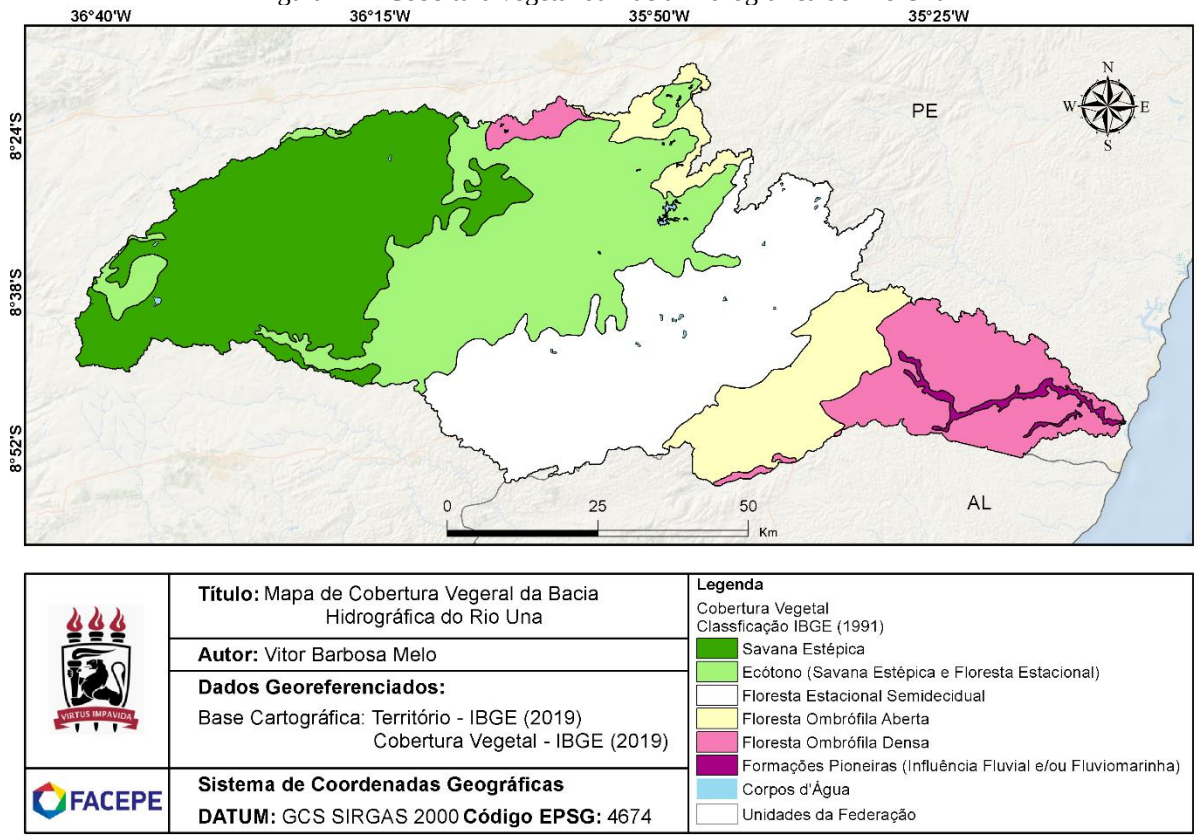

Fonte: Autor (2021)

Geologia e geomorfologia

A geologia da BHRU (Figura A2) é caracterizada por ambientes marinho costeiro na região próxima à costa litorânea pernambucana com sedimentos que variam de inconsolidados a moderadamente consolidados do período geológico cenozoico (aproximadamente 11 km²). Nestas porções há forte existência de arenitos. As rochas do período neoproterozoico cobrem uma extensão de 1.633 km² da bacia nas regiões leste, central e norte. Tais rochas apresentam-se na forma de granitóides deformados (rochas ígneas e metamórficas/ígneas), de gnaisse-migmáticas e de granulitos (rochas metamórficas). Por fim, a existência mais significativa na bacia ocorre em relação as rochas do período mesoproterozoico (4.851 km²), exibem-se rochas sedimentares metamorfizadas, vulcanossedimentares metamorfizadas, gnaisse-migmáticas, granulitos e granitóides não deformados (rochas metamórficas) e granitóides deformados (rochas ígneas/metamórficas).

Figura A2 - Mapa geológico da Bacia Hidrográfica do Rio Una

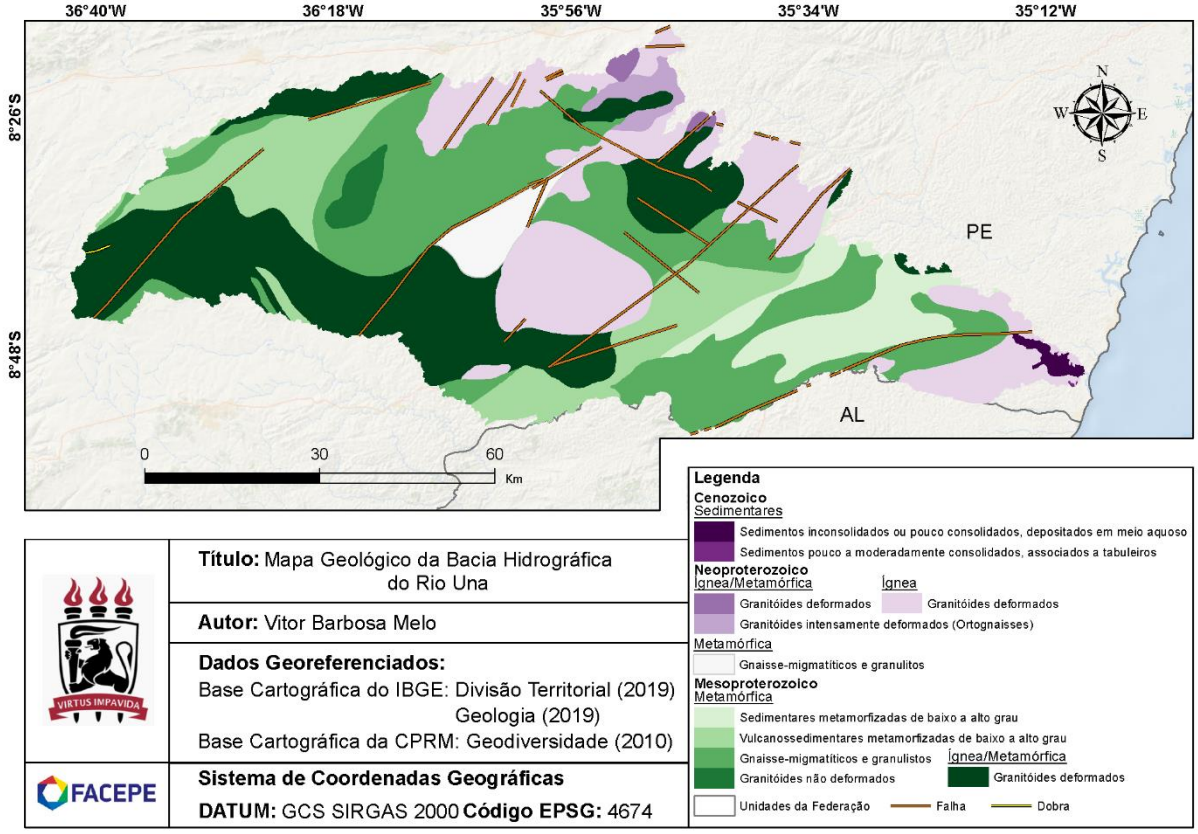

Fonte: Autor (2021)

A BHRU apresenta três domínios hidrogeológicos. Os metassedimentos/metavulcânicas com maior extensão dentre os três, percorre da região oeste até a região central da bacia. Tal domínio está relacionado com o comportamento hidrogeológico fissural e tem como desvantagem a baixa produção (vazão) de água. O cristalino, visualizado nas porções norte e leste da bacia, possui o mesmo comportamento que os metassedimentos/metavulcânicas. Entretanto, diferem-se devido a classificação reológica e, geralmente, dispõe-se de vazões ainda mais baixas. Por fim, os depósitos cenozoicos detêm pequena porção territorial na região leste da bacia, o aquífero é poroso e tem produtividade moderada. O mapa hidrogeológico da bacia é apresentado na Figura A3. No aspecto do ciclo hidrológico, a hidrogeologia é um dos fatores que influenciam na infiltração da água. Na bacia, percebe-se um comportamento hidrogeológico desfavorável à infiltração da água nos reservatórios subterrâneos, promovendo aumento nos picos do escoamento superficial e, com isso, na formação das inundações.

Figura A3 - Mapa hidrogeológico da Bacia Hidrográfica do Rio Una

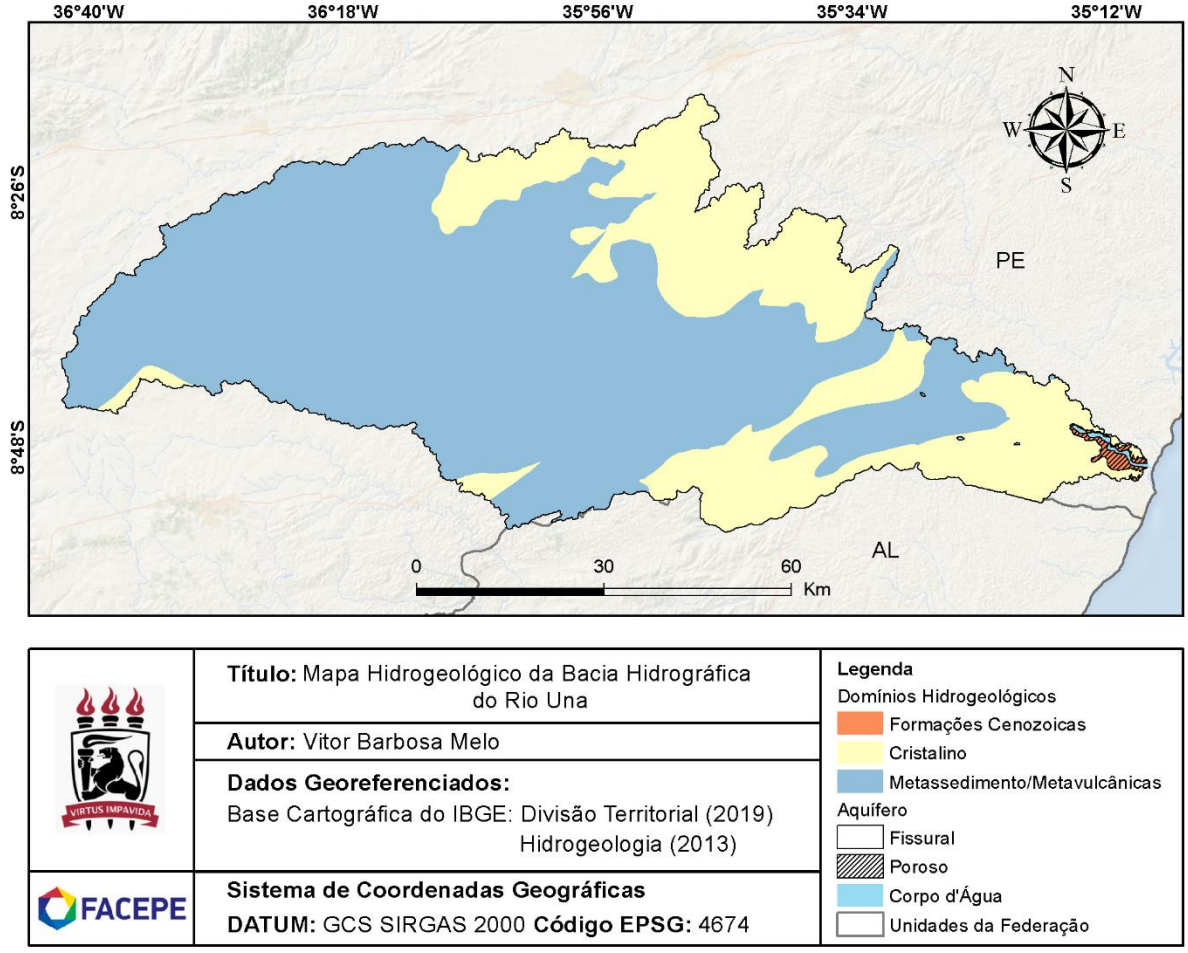

Fonte: Autor (2021)

Com relação às formas do relevo, a geomorfologia da bacia é descrita de acordo com dois critérios de classificação, os domínios morfoestruturais e as unidades geomorfológicas. O primeiro representa a natureza das rochas e a placa tectônica em que o relevo está inserido, enquanto o segundo indica regiões com feições altimétricas e fisionomicamente similares (IBGE, 2009). Na BHRU, Figura A4, dois domínios morfoestruturais são verificados, os depósitos sedimentares quaternários e os cinturões móveis neoproterozoicos. Dentro dos depósitos sedimentares, a unidade geomorfológica evidenciada é a planície litorânea, já os cinturões móveis, tem-se a região geomorfológica conhecida como o Planalto da Borborema, em que as unidades inseridas são o pediplano central, as encostas orientais e o piemonte oriental.

Figura A4 - Mapa geomorfológico da Bacia Hidrográfica do Rio Una

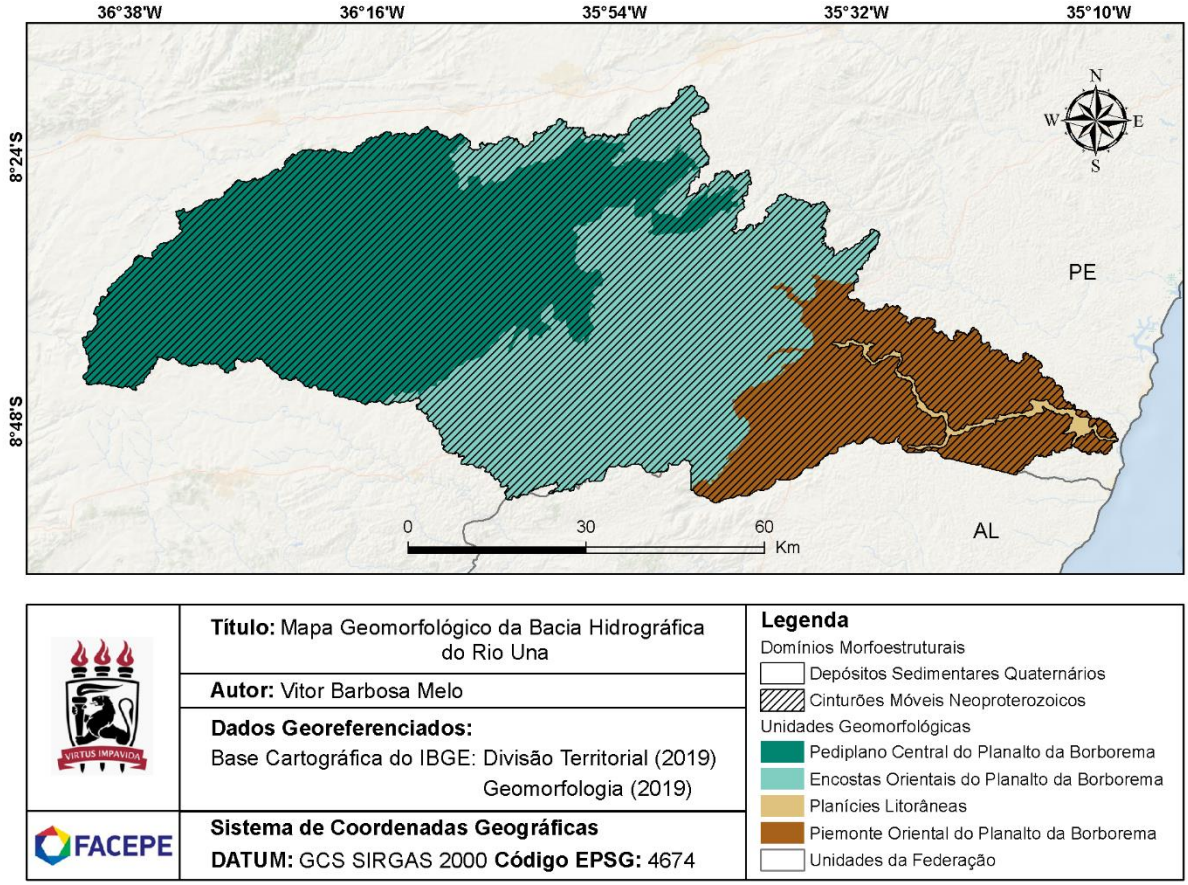

Fonte: Autor (2021)

Outra característica desfavorável da bacia para formação das inundações está na amplitude da altimetria da bacia, um pouco mais de 1.000 m. Como pode ser visto no mapa hipsométrico (Figura A5), a elevação mínima e máxima da BHRU em relação ao mar é de 0,52 e 1.025,68 m, respectivamente. Conforme Cirilo *et al*. (2011), a declividade do rio Una foi um dos fatores para os estragos oriundos do evento extremo em junho de 2010 em municípios da bacia, principalmente, porque a elevada inclinação promove o aumento da energia cinética da água e, com isso, surgem ondas mais rápidas.

Figura A5 - Mapa hipsométrico da Bacia Hidrográfica do Rio Una

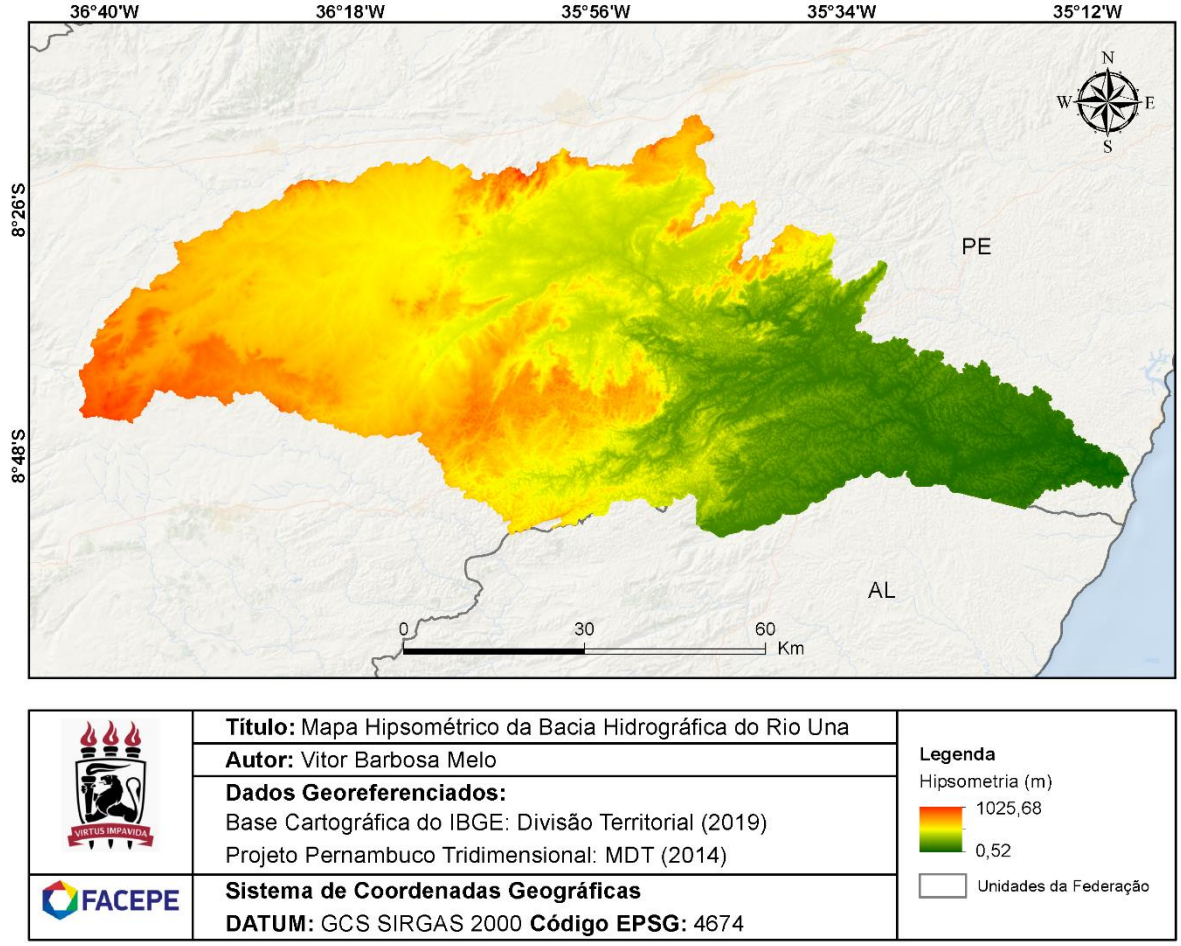

Fonte: Autor (2021)

A declividade da BHRU, Figura A6, foi classificada segundo EMBRAPA (1979). O cálculo foi obtido em ambiente SIG por operações sobre o Modelo Digital do Terreno do Projeto Pernambuco Tridimensional (3DPE)*. De uma maneira geral, a bacia apresenta três grupos bem evidentes: o Plano (0 - 3%), o Suave Ondulado (3 - 8%) e o Ondulado (8 - 20%). Em grande parte da região oeste da bacia, o relevo plano é identificado com maior intensidade e homogeneidade, o que torna uma área propícia para certas atividades econômicas, como a pecuária (Ver Mapa do Uso e Ocupação do solo). Tal evidência pode ser um indicador da degradação da terra e do aumento dos picos de vazão, influenciando negativamente na dinâmica do ciclo hidrológico e promovendo inundações mais drásticas.

Ainda com relação ao relevo plano, destaca-se também a forte evidência desta classe sobre os rios, principalmente no sentido leste/oeste. Vale destacar que um dos motivos para esta constatação ocorre devido ao mapeamento da tecnologia LIDAR convencional. Pois, ao

* É importante comentar que o modelo digital apresenta alta resolução espacial, com isso as declividades calculadas tendem a ser mais suaves.

descrever as particularidades do terreno sob a água, a altimetria dos pixels é classificada em relação à água e não ao terreno, gerando elevações próximas e, com isso, pequena inclinação (declividade). A classe de relevo plana apresenta-se com área aproximada de 3.453 km² (53% da área total).

O relevo suave ondulado e o ondulado apresentaram 1.833 (28%) e 1.203 (18%) km², respectivamente. Na medida em que as porções terrestres se afastam da rede de drenagem, maiores declividades são verificadas, favorecendo ao acúmulo de água nas regiões de várzea plana. A tendência de altas inclinações em direção à planície alagada pode agravar a inundação, visto que há um aumento na velocidade do escoamento, consequência direta da declividade. Destaca-se também que a bacia apresenta declividades mais acentuadas na porção central ao sul e a nordeste, bem como na região noroeste da bacia. Por fim, apenas 6 km² correspondem as classes Forte Ondulado (20 - 45%), Montanhoso (45 - 75%) e Forte Montanhoso (75 - 100%), sendo mais evidente para o relevo Forte Ondulado (5,8 km²).

Figura A6 - Mapa de declividade da Bacia Hidrográfica do Rio Una

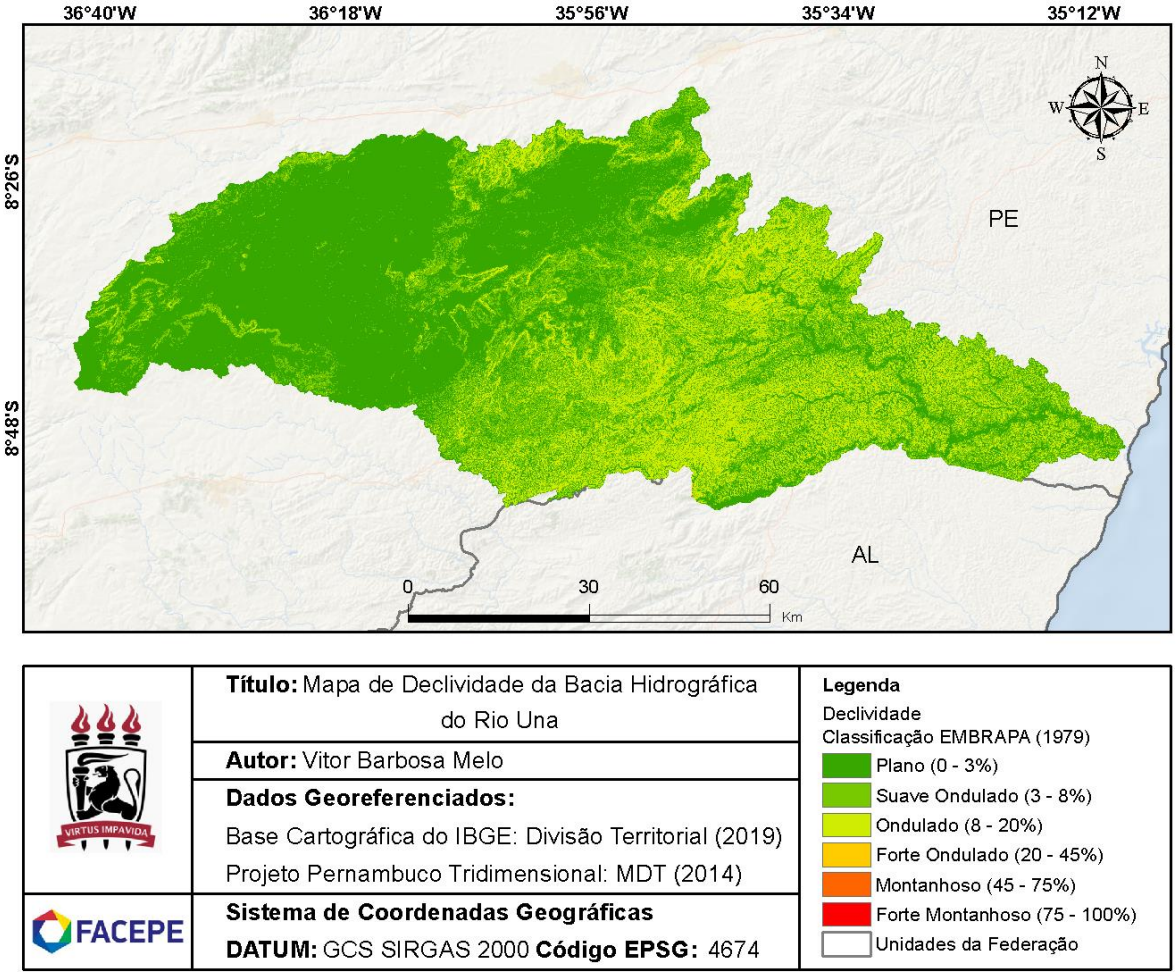

Fonte: Autor (2021)

Pedologia

Com relação a pedologia da BHRU (Figura A7), utilizou-se os dois primeiros níveis (ordem e classe) do Sistema Brasileiro de Classificação dos Solos (SiBCS) para desagregação espacial dos tipos de solos. A região compreendida do litoral até a porção central e parte do norte da bacia é caracterizada pela presença dos solos argissolo vermelho-amarelo, latossolo vermelho-amarelo, latossolo amarelo, o neossolo flúvico e o quartzarênicos. Os três primeiros possuem maior concentração de argila em sua composição, porém os latossolos são ricos em minerais e bem desenvolvidos, além de possuírem melhores condições para a drenagem da água, diferentemente dos argissolos. O argissolo é o solo com maior extensão territorial da bacia, um dos atributos desses solos é a baixa infiltração da água no solo, indicando possível fator para formação das inundações. Os neossolos são poucos desenvolvidos, na bacia se encontram os flúvicos que tem como particularidade a sua evolução a partir das aluviões, apresentando camadas variadas com diferentes granulometrias e os quartzarênicos com pequena presença na foz do rio Una, estes solos são arenoquartzosos profundos a muito profundos com elevada capacidade drenante. Finalmente, na porção oeste, a bacia expõe os seguintes solos: o neossolo regolítico, o neossolo litólico e o planossolo háplico. Os regolíticos são pouco profundos a profundos e arenosos com presença de minerais primários. Os litólicos são solos rasos com baixa capacidade de armazenamento de água, promovendo influência no aumento dos picos de escoamento superficial nos períodos de chuva. Os planossolos háplicos possuem baixa permeabilidade, apresentando uma mudança brusca entre a camada superficial e as adjacentes, caracterizada por um bloqueio com infiltração muito lenta, quase impermeável. No período chuvoso possui elevada retenção de água (CONDEPE/FIDEN, 2006; CPRM, 2014; EMBRAPA, 2018).

Figura A7 - Mapa Pedológico da Bacia Hidrográfica do Rio Una

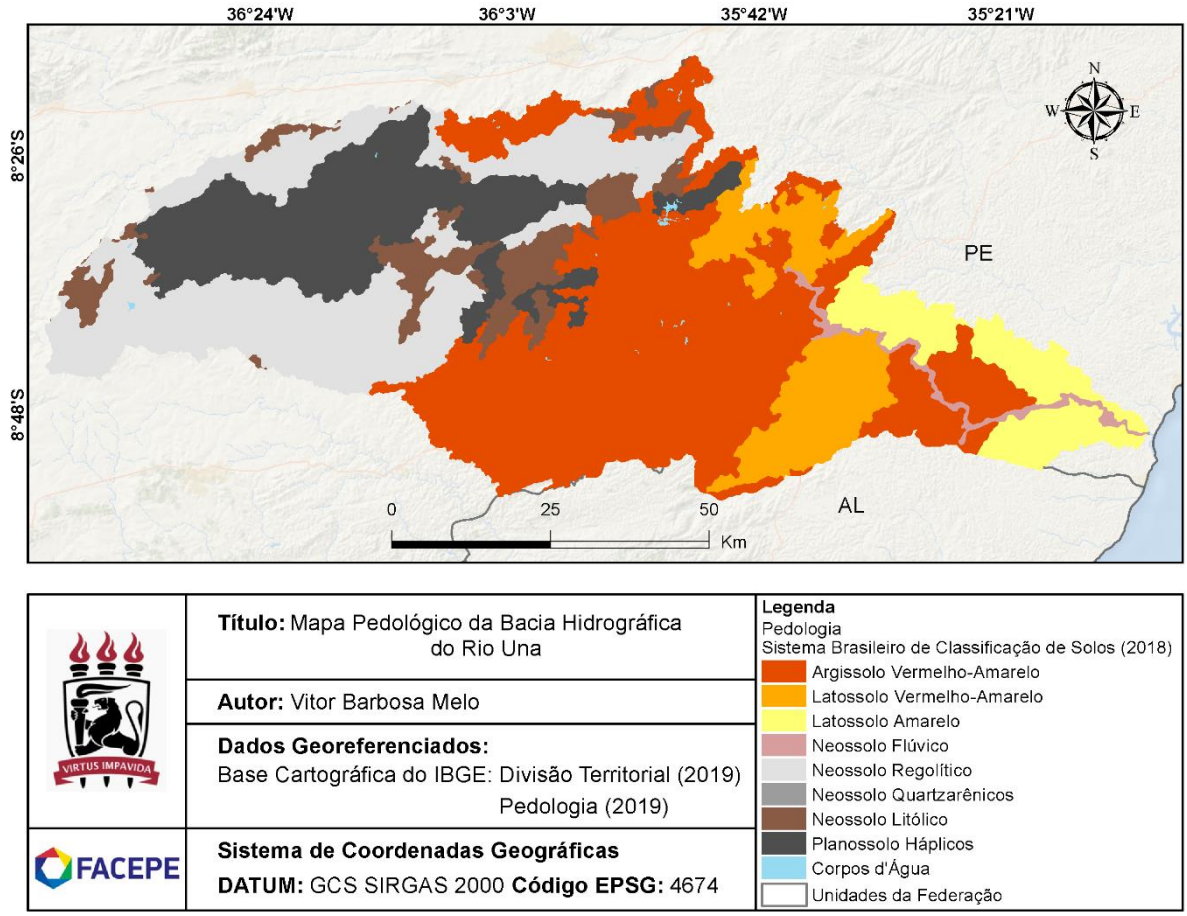

Fonte: Autor (2021)

Uso e ocupação do Solo

O mapa de uso e ocupação do solo da BHRU pode ser visto na Figura A8. Nota-se que a bacia apresenta baixa porção territorial com relação a presença de núcleos urbanos. Entretanto o uso do solo para fins econômicos é expressivo através da vasta extensão para a pastagem (criação de gado) e a agricultura (cana-de-açúcar). Na tabela A1 são indicados os quantitativos em termos de área* e seu respectivo percentual para cada classe verificada na BHRU. Ressalta-se que a degradação da terra é um dos fatores significativos para alterações ciclo hidrológico, principalmente, na relação precipitação e escoamento superficial

* O recorte da bacia foi realizado pelo *shape* obtido através do Modelo Digital do Terreno do 3DPE, a área total é de 6.437 km² (diferentemente do valor fornecido pelo site da APAC). Entretanto, ressalta-se que o intuito da apresentação desta tabela é apenas de caráter informativo, apesar de maior, indica coerentemente os usos e ocupações dos solos da BHRU.

Figura A8 - Uso e ocupação do solo da Bacia Hidrográfica do Rio Una

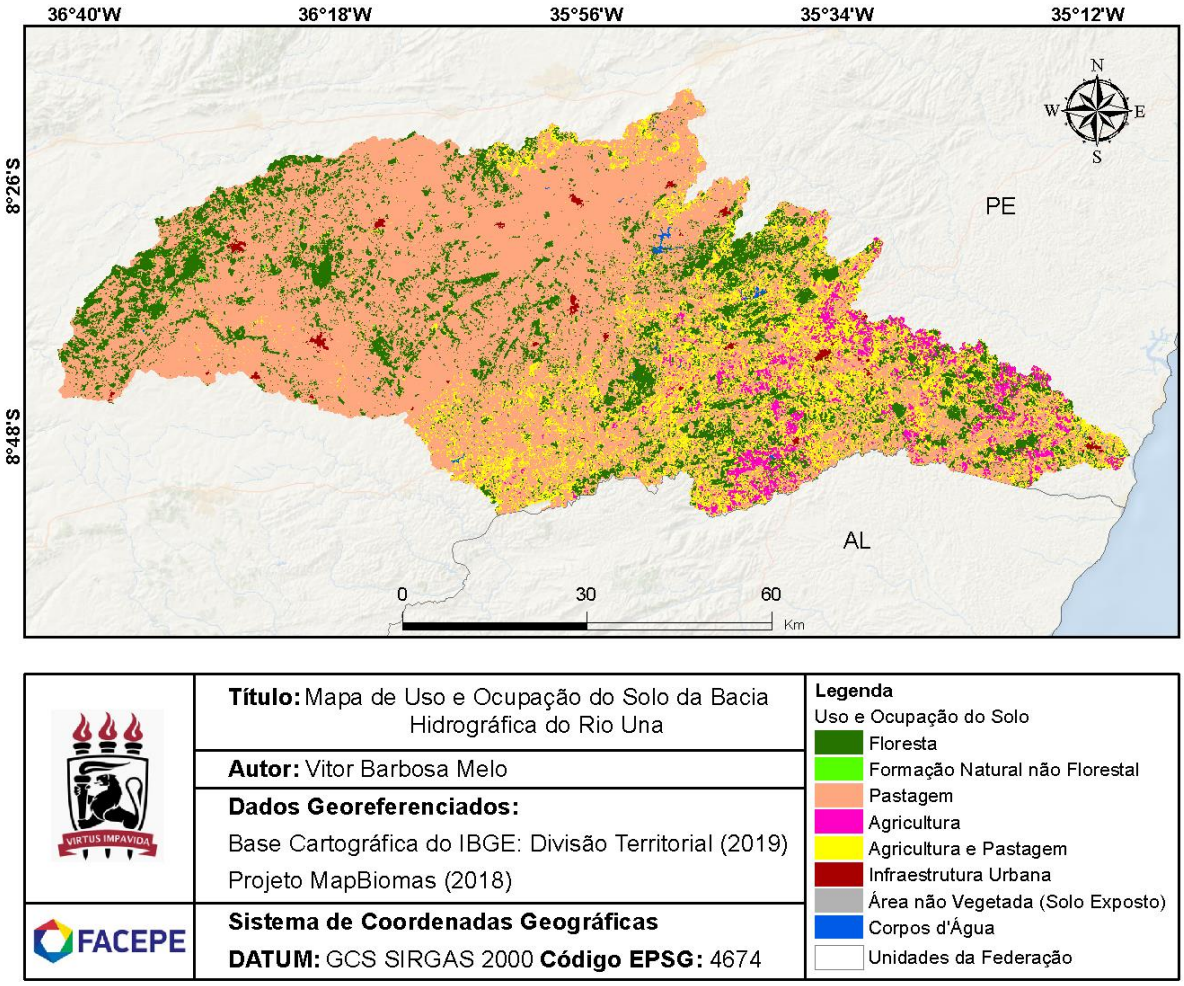

Fonte: Autor (2021)

Tabela A1 - Área e percentual do tipo de cobertura da terra da Bacia Hidrográfica do Rio Una segundo o MapBiomas em 2018

Uso e Ocupação do Solo	Área (km²)	Percentual (%)
Floresta	1201	18,7
Formação Natural não Florestal	7	0,1
Pastagem	3.983	61,9
Agricultura	256	4,0
Agricultura e Pastagem	935	14,5
Infraestrutura Urbana	38	0,6
Área não vegetada (Solo Exposto)	3	0,0
Corpo d'água	14	0,2

Fonte: Autor (2021)

ANEXO B - RESULTADOS E DISCUSSÕES DA GEOESTATÍSTICA (CONTINUAÇÃO)

Análise exploratória e transformação dos dados (Continuação)

Jaqueira

Com relação às profundidades de inundação do evento ocorrido em maio de 2017 no município de Jaqueira foram realizadas análises exploratórias sobre as três distribuições: as profundidades de inundação; as transformadas (profundidades de inundação + altura do HAND) e; o logaritmo das transformadas.

Foram obtidas métricas de posição (Tabela B1) e de dispersão (Tabela B2) dos dados brutos e das duas transformações aplicadas, além de análises gráficas verificando a distribuição, a frequência e a presença de *outliers* através do histograma, do gráfico Q-Q e do Boxplot. A normalidade dos dados foi verificada através de quatro testes de hipóteses (Tabela B3). Destaca-se que os testes de Shapiro-Wilk e Anderson-Darling, mais robustos e considerados acurados que os estatísticos Lilliefors e Jarque-Bera, utilizados como segurança (referência).

Tabela B1 - Estatísticas descritivas de posição para as profundidades de inundação (m) e suas transformadas (m) do evento de 2017 em Jaqueira

Amostras	Mínimo	Máximo	Média	Mediana	Percentil (25%)	Percentil (75%)
Profundidades de inundação	0,00	2,51	0,71	0,73	0,00	1,26
Transformadas[1]	2,01	7,84	4,08	3,92	3,37	4,61
Logaritmo da Transformada	0,30	0,89	0,60	0,59	0,53	0,66

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Tabela B2 - Estatísticas descritivas de dispersão e de forma para as profundidades de inundação (m) e suas transformadas (m) do evento de 2017 em Jaqueira

Amostras	Variância	Desvio Padrão	Coeficiente de Variação	Curtose	Assimetria
Profundidades de inundação	0,47	0,68	96,45	-0,82	0,49
Transformadas[1]	1,06	1,03	25,21	2,02	1,11
Logaritmo das Transformadas	0,01	0,10	17,46	0,56	0,22

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Tabela B3 - Testes de normalidade para as profundidades de inundação e suas transformadas do evento de 2017 em Jaqueira

Amostras	Shapiro-Wilk		Anderson-Darling		Lilliefors		Jarque-Bera	
	W	p	A	p	L	p	JB	p
Profundidades de inundação	0,88	$6*10^{-9}$	5,67	$5*10^{-14}$	0,21	$1*10^{-4}$	8,91	0,01
Transformadas[1]	0,94	$1*10^{-5}$	1,85	$9*10^{-5}$	0,09	0,02	45,76	$1*10^{-10}$
Logaritmo da Transformada	0,99	0,46	0,34	0,48	0,04	0,88	2,31	0,31

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Com relação às profundidades de inundação, as métricas de posição indicam alta frequência de valores iguais (ou próximos) a zero, isto porque o primeiro percentil (Q25%) foi igual ao valor mínimo (zero), ou seja, pelo menos 25% das profundidades são nulas. Por outro lado, o terceiro quartil (Q75%) apresentou 25% dos dados variando entre 1,26 e 2,51 m, indicando outro padrão para os valores altos. Apesar da média ser aproximadamente igual à mediana – possível indício de simetria dos dados – a distância dos percentis e dos valores mínimos e máximos em relação à média tornam claro e inequívoco que a distribuição das profundidades de inundação não segue uma curva normal, por se tratar de uma curva assimétrica com a cauda para a esquerda.

Outras evidências foram encontradas por meio das medidas de dispersão. Percebeu-se valores altos do desvio padrão e da variância em relação à média e por este motivo o Coeficiente de Variação (CV) foi expressivo, indicando alta variabilidade dos dados. Há ainda os

parâmetros de forma que também exprimem a dispersão (espalhamento) das amostras, a exemplo da Curtose que mede o achatamento da distribuição. Para o caso das profundidades de inundação a medida foi negativa, isto é, maior achatamento que uma curva normal. Com isso, a função da distribuição é conhecida como Platicúrtica. Para o coeficiente de assimetria, o valor positivo indica uma assimetria positiva, quando o pico da curva está próximo dos valores baixos.

As discussões anteriores sobre os dados também podem ser evidenciadas graficamente. Verifica-se a alta frequência de valores próximos a zero pelo histograma (Figura B1), mas certo espalhamento e achatamento em relação a uma curva normal. A variação dos dados, analisada sob a perspectiva do Boxplot (Figura B2), ressalta a distância nula entre o primeiro quartil e o valor mínimo, que diferentemente da amplitude entre o terceiro quartil e o valor máximo apresentou um alto valor, inclusive maior que a distância interquartil, indicando assim assimetria positiva com a cauda para esquerda.

Para análise dos resultados e discussão em torno da normalidade dos dados foram utilizados dois caminhos. O primeiro foi o uso dos testes de hipóteses com nível de confiança de 5%, de modo que valores do p(normal) menores que 0,05 indicam a não normalidade dos dados. Para as profundidades de inundação do município de Jaqueira houve rejeição de normalidade para todos os testes. A segunda possibilidade é avaliar os quantis da distribuição normal teórica em relação à distribuição das profundidades através do gráfico de probabilidades Q-Q (Figura B3). O desejável para tal diagrama é que os pontos (em preto) estejam sobre (ou próximos) a reta (em vermelho), apontando similaridade. Independentemente dos valores médios e altos estarem na condição “esperada”, os valores baixos (quantis negativos) estão dispersos, distantes da reta.

Figura B1 - Histograma para as profundidades de inundação do evento de 2017 em Jaqueira

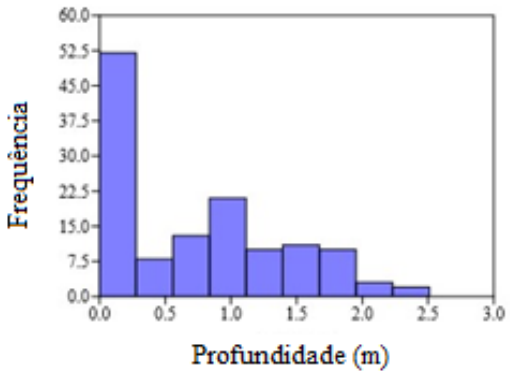

Fonte: Autor (2021)

Figura B2 - Boxplot para as profundidades de inundação do evento de 2017 em Jaqueira

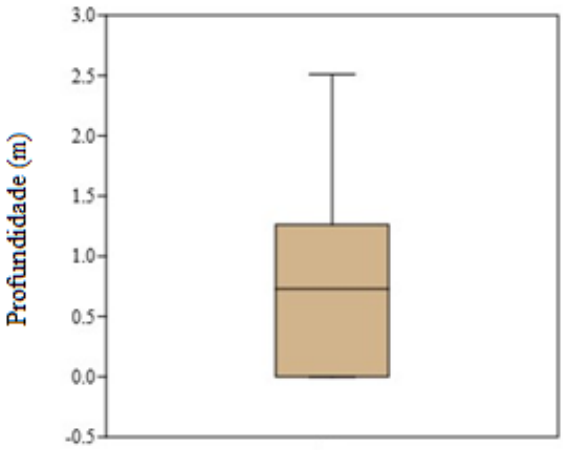

Fonte: Autor (2021)

Figura B3 - Gráfico Q-Q para as profundidades de inundação do evento de 2017 em Jaqueira

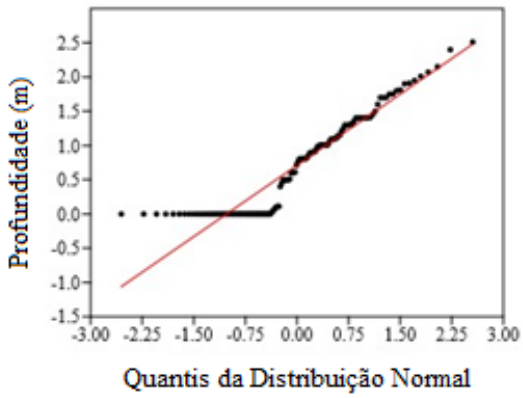

Fonte: Autor (2021)

Como desejou-se corrigir a assimetria da distribuição, diminuindo a intensidade de valores próximos a zero e estabilizar a variabilidade dos dados, além dos motivos práticos na obtenção da extensão do evento, as profundidades de inundação foram somadas à altura HAND. Analisando as métricas de posição para as transformadas, verificou-se a diminuição da concentração dos valores baixos, indicados pela amplitude entre o valor mínimo, o primeiro quartil (Q25%) e a média. Este comportamento também pode ser visualizado segundo o histograma (Figura B4).

Outro padrão encontrado na distribuição de frequência foi a evidência de assimetria positiva da distribuição com a cauda para esquerda. Houve ainda um aumento do coeficiente de assimetria (indesejável). A curva das frequências indicou certa semelhança com a curva normal teórica, embora a barra com maior frequência encontre-se deslocada para a esquerda e a curva alongada, ou seja, a distribuição pode ser classificada como leptocúrtica (coeficiente de

Curtose maior que zero). Ademais há uma frequência significativa na cauda direita, indicando prováveis *outliers*, que devem ser corrigidos para a normalidade dos dados.

Figura B4 - Histograma para as transformadas do evento de 2017 em Jaqueira

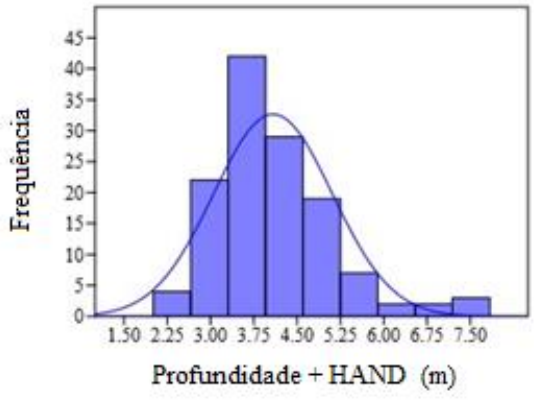

Fonte: Autor (2021)

No aspecto da dispersão, o desvio padrão e a variância indicaram menor expressividade em comparação com a média, refletindo na queda do Coeficiente de Variação. Apesar de isto ser um fator positivo para minimização da dispersão dos dados, foram encontrados 5 pontos atípicos pelo limite de detecção do Boxplot (Figura B5) dado por 1,5 x distância interquartil. Este valor é subtraído do primeiro quartil e somado ao terceiro quartil para verificação de possíveis *outliers* que ultrapassem essa margem.

Figura B5 - Boxplot para as transformadas do evento de 2017 em Jaqueira

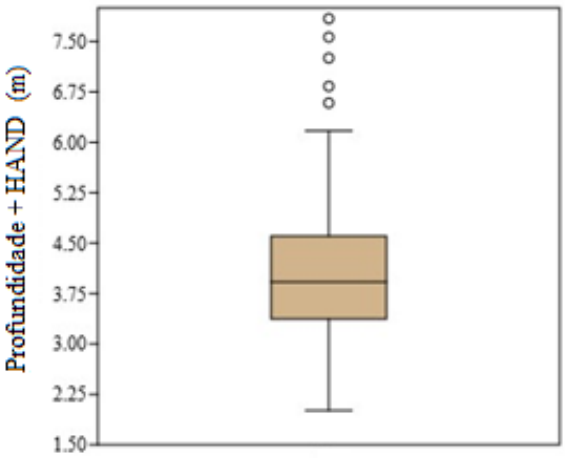

Fonte: Autor (2021)

Como comentado a respeito da normalidade dos dados não ser uma hipótese obrigatória para inferência da Krigagem Ordinária, alguns analistas poderiam assumir que os dados atípicos

são integrantes da amostragem e do fenômeno e prosseguir para a interpolação. Entretanto, a presença destes valores altos pode produzir modelos espúrios, prejudicando no resultado krigado. Outro ponto é assimetria dos dados, que preferencialmente deve ser tratada. Com isso, buscou-se avaliar novas transformações para tratar tais incoerências.

De certo, os testes de normalidade rejeitaram a hipótese nula como esperado. No gráfico Q-Q (Figura B6) é evidente a fuga da normalidade nos dois extremos, principalmente para os altos valores, onde foram encontrados os *outliers*. Novamente salienta-se que a distância entre os pontos (em preto) para a curva reta (em vermelho) deve ser a menor possível, mesmo que os testes estatísticos rejeitem a normalidade dos dados.

Figura B6 - Gráfico Q-Q para as transformadas do evento de 2017 em Jaqueira

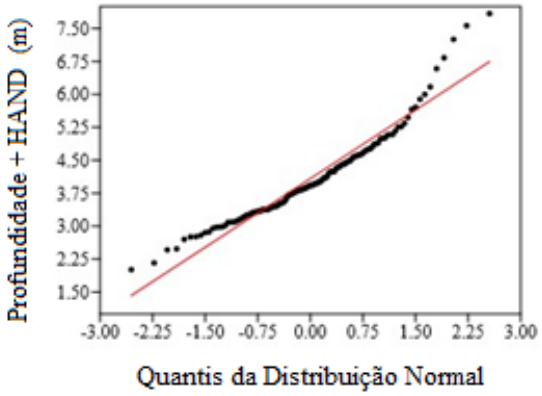

Fonte: Autor (2021)

Dentre as funções disponíveis para a transformação, a função logarítmica foi a que melhor ajustou os dados a uma distribuição normal. Inicialmente evidencia-se que as medidas de posição e de dispersão do logaritmo das transformadas indicaram valores com indícios para simetria e normalidade da distribuição: a média aproximadamente igual à mediana; o desvio padrão e a variância inexpressivos em relação à média; diminuição da dispersão dos dados; o Coeficiente de Variação foi pequeno (17%) e de acordo com Koch e Link (1971), o CV menor que 30% indica uma distribuição aproximadamente normal; as amplitudes entre os quartis, os extremos e a média foram próximas, sugerindo normalidade dos dados.

Os resultados comentados anteriormente são reforçados pelo Histograma (Figura B7), a distribuição de frequências. As barras seguem uma curva normal com concentração de valores próximos à média e diminuição em direção aos extremos, evidenciados pelo coeficiente de assimetria próximo a zero. Há ainda um leve alongamento na curva captado pela Curtose, porém inexpressivo, indicando uma distribuição mesocúrtica (nem chata, nem longa).

Figura B7 - Histograma para o logaritmo das transformadas do evento de 2017 em Jaqueira

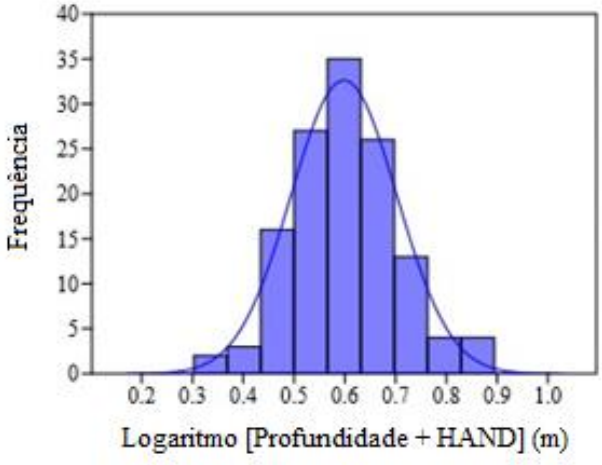

Fonte: Autor (2021)

Posto que existem indícios para a normalidade, frisa-se a presença de valores extremos que sugerem certo desvio em relação à curva normal. O Boxplot (Figura B8) captou dados atípicos, porém com distâncias pequenas em relação ao limite. Tais pontos foram analisados localmente e comparados com valores próximos manualmente. Não havendo sinais claros e fortes para exclusão destes, entendeu-se que estes pontos são integrantes do fenômeno e foram utilizados na modelagem.

Figura B8 - Histograma para o logaritmo das transformadas do evento de 2017 em Jaqueira

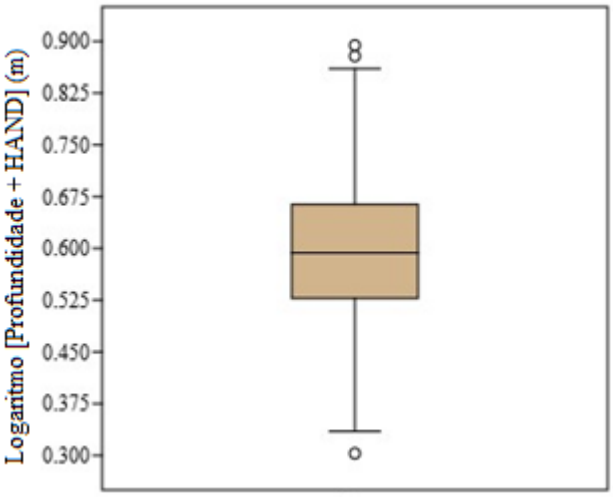

Fonte: Autor (2021)

Por fim, ressalta-se que os quatro testes estatísticos aceitaram a hipótese de normalidade dos dados, o que torna mais confiável a utilização das amostras dadas como atípicas. Além disso, segundo o gráfico Q-Q (Figura B9), o comportamento do logaritmo das transformadas

variaram em torno da reta sem variações (desvios) significativas, minimizando possíveis tendências/enviesamento na inferência probabilística.

Figura B9 - Gráfico Q-Q para o logaritmo das transformadas do evento de 2017 em Jaqueira

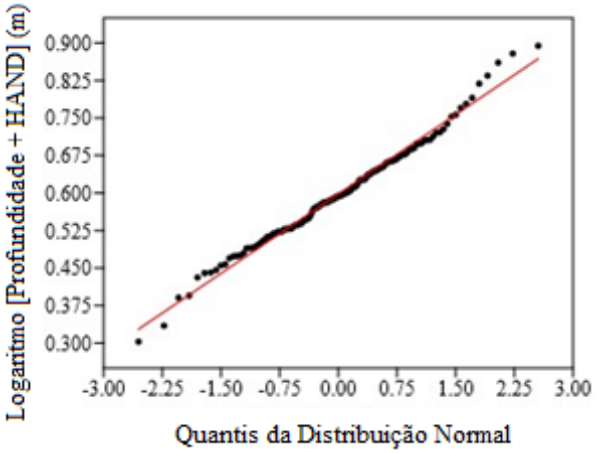

Fonte: Autor (2021)

Palmares

Após a exclusão dos 12 pontos e da correção da posição espacial das amostras, novas análises exploratórias foram realizadas, as quais podem ser vistas através das métricas de posição (Tabela B4) e de dispersão (Tabela B5) sobre as profundidades de inundação e suas transformadas. As distribuições foram analisadas segundo o histograma, o gráfico Q-Q e o Boxplot, além dos quatros testes de hipóteses de normalidade e os testes de normalidade (Tabela B6) assim como realizado nos dados do município de Jaqueira.

Tabela B4 - Estatísticas descritivas de posição para as profundidades de inundação (m) e suas transformadas (m) do evento de 2010 em Palmares

Amostras	Mínimo	Máximo	Média	Mediana	Percentil (25%)	Percentil (75%)
Profundidades de inundação	0,00	8,00	4,13	4,67	3,30	5,42
Transformadas[1]	7,01	13,02	10,08	10,58	8,79	11,18
Box-Cox da Transformada	43,79	194,17	108,93	118,09	75,69	134,74

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Tabela B5 - Estatísticas descritivas de dispersão e de forma para as profundidades de inundação (m) e suas transformadas (m) do evento de 2010 em Palmares

Amostras	Variância	Desvio Padrão	Coeficiente de Variação	Curtose	Assimetria
Profundidades de inundação	3,47	1,86	45,07	-0,17	-0,88
Transformadas[1]	2,18	1,48	14,65	-1,01	-0,42
Box-Cox das Transformadas	1281,26	35,79	32,86	-0,93	-0,14

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Tabela B6 - Testes de normalidade para as profundidades de inundação e suas transformadas do evento de 2010 em Palmares

Amostras	Shapiro-Wilk		Anderson-Darling		Lilliefors		Jarque-Bera	
	W	p	A	p	L	p	JB	p
Profundidades de inundação	0,89	2,21	8,15	$6*10^{-65}$	0,19	$1*10^{-4}$	24,43	$5*10^{-6}$
Transformadas[1]	0,92	$2*10^{-8}$	5,83	$2*10^{-14}$	0,14	$1*10^{-4}$	13,31	$1*10^{-3}$
Box-Cox da Transformada	0,94	$9*10^{-7}$	4,02	$4*10^{-10}$	0,13	$1*10^{-4}$	7,47	0,02

1 Transformadas: soma entre a profundidade de inundação e a elevação do modelo HAND.

Fonte: Autor (2021)

Inicialmente, analisando as métricas de posição e de dispersão da distribuição das profundidades de inundação do evento de 2010 em Palmares, percebeu-se indicativos de assimetria negativa nos dados. Devido à mediana maior que a média, ao coeficiente de assimetria negativo e à proximidade da mediana ao terceiro quartil e à intermediária variabilidade nos dados com o coeficiente de variação em torno de 45%, demonstrando certa consistência na dispersão das profundidades em relação à média.

Distintivamente das profundidades de Jaqueira, as métricas de posição e de dispersão não acusaram, de modo direto, inconsistência nas distribuições. Não obstante, analisando o histograma (Figura B10) e o Boxplot (Figura B11) fica evidente a presença significativa de valores baixos na cauda esquerda, indicando *outliers* pelo limite (1,5 x amplitude interquartil) do diagrama de caixa, além de alta frequência para valores acima da média, promovendo a assimetria negativa.

Figura B10 - Histograma para as profundidades de inundação (m) do evento de 2010 em Palmares

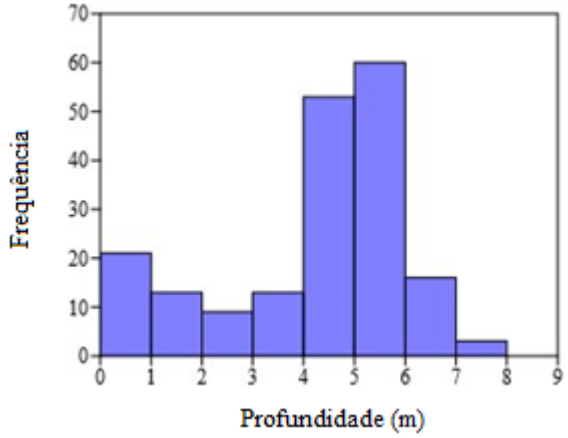

Fonte: Autor (2021)

Figura B11 - Boxplot para as profundidades de inundação (m) do evento de 2010 em Palmares

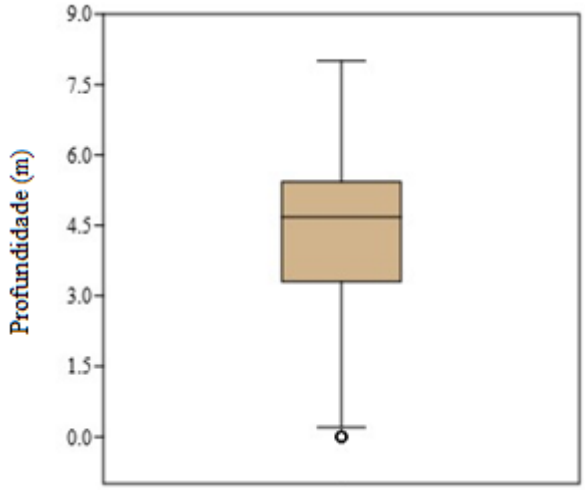

Fonte: Autor (2021)

Como esperado, a hipótese nula de normalidade dos dados foi rejeitada em todos os testes. Para o gráfico Q-Q (Figura B12), verificam-se desvios significativos nos valores extremos e médias em referência à reta de ajuste. Pretende-se, com as transformações, minimizar o afastamento dos dados da reta de quantis teóricos da normal nas regiões dos três quartis.

Figura B12 - Gráfico Q-Q para as profundidades de inundação (m) do evento de 2010 em Palmares

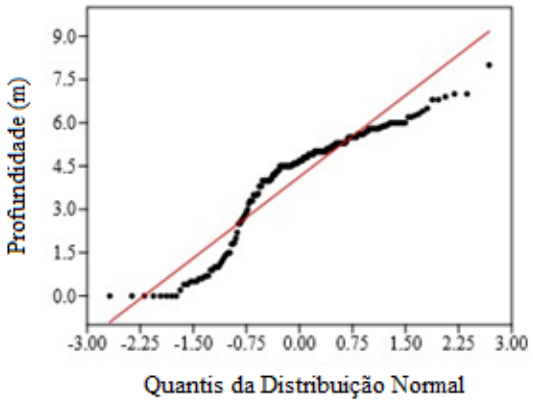

Fonte: Autor (2021)

Ao somar a altimetria HAND às profundidades de inundação, as métricas de posição e de dispersão indicaram os seguintes aspectos para a nova distribuição: diminuição da relação entre o desvio padrão e a média, impondo um coeficiente de variação de 14%; continuidade na assimetria negativa com diminuição no coeficiente, porém mais evidenciada pela proximidade da mediana com o terceiro quartil; distribuição Platicúrtica, indicando achatamento mais notório pelo valor da Curtose.

Ao avaliar o histograma (Figura B13), compreende-se que houve uma redução da frequência dos valores mais próximos ao mínimo, corrigindo a distância do valor mínimo para o primeiro quartil, evitando assim dados discrepantes pela regra do Boxplot (Figura B14), porém a mediana se manteve afastada do primeiro quartil. Visualmente, a distribuição aparenta ser mista, ou seja, os dados provêm de duas ou mais populações: esta ocorrência é designada por distribuição bimodal.

Verificada a presença de duas possíveis distribuições, as profundidades foram estudadas por região. Comprovou-se que na porção leste da cidade as profundidades foram menores em relação à parte oeste. Dessa forma, análises foram realizadas através dos histogramas sobre os dois conjuntos, separando-os espacialmente e, de fato, foram encontradas distribuições distintas. Apesar de existir sentido matemático e estatístico ao dividir o conjunto em dois subconjuntos e modelá-los por setores, optou-se por um desenvolvimento único, principalmente por causa da quantidade de amostras, visto que o semivariograma é melhor representado quanto mais pontos forem utilizados no processo. Cabe comentar também que esta perspectiva evidencia que espacialmente as profundidades de inundação do evento de 2010 ocorrido em Palmares são não estacionárias.

Figura B13 - Histograma para as transformadas (m) do evento de 2010 em Palmares

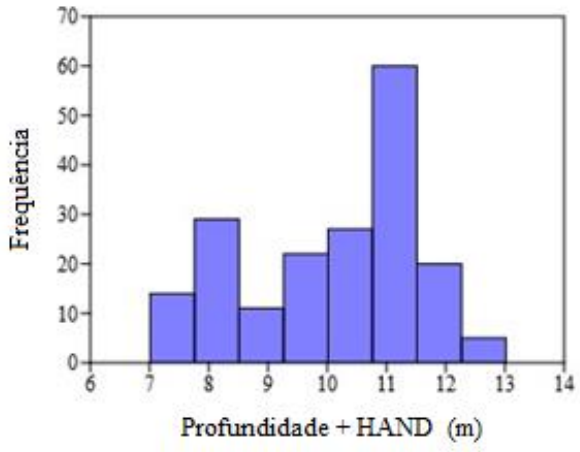

Fonte: Autor (2021)

Figura B14 - Boxplot para as transformadas (m) do evento de 2010 em Palmares

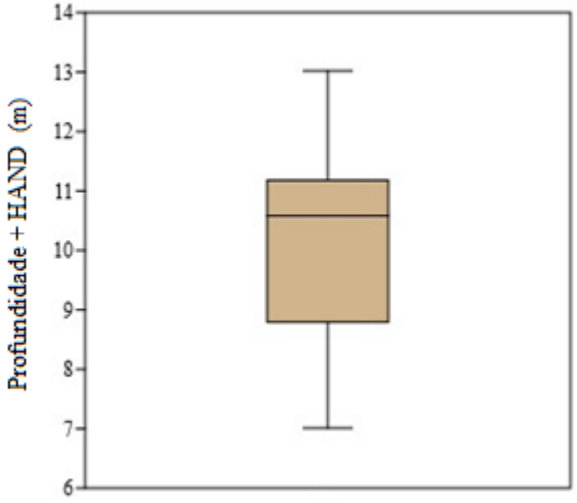

Fonte: Autor (2021)

Do ponto de vista dos quantis da distribuição normal verificados no gráfico Q-Q (Figura B15) houve uma leve melhora dos desvios em relação à reta nos quantis médios e nos valores altos. Para correção destes desvios recorreu-se a funções matemáticas (logarítmica, Box-Cox e Arcsin) para transformação dos dados, tendo como objetivo ajustar as transformadas sobre a reta normal do gráfico Q-Q, ou em outras palavras produzir valores mais próximos da normalidade. Além disso, buscou-se manter a variabilidade dos dados baixa e diminuir a assimetria da distribuição.

Figura B15 - Gráfico Q-Q para as transformadas (m) do evento de 2010 em Palmares

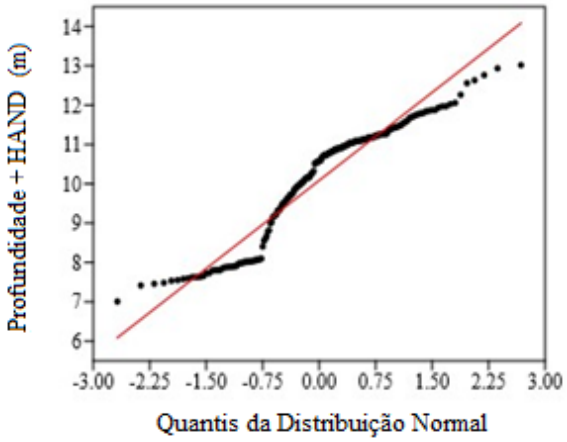

Fonte: Autor (2021)

A função matemática usada para transformação que melhor aproximou a distribuição da normalidade dos dados foi a Box-Cox e o parâmetro de transformação, conhecido como parâmetro de potência, foi obtido através da função de máxima verossimilhança, resultando em um valor de 2,39.

Com relação à análise exploratória do Box-Cox das profundidades transformadas, as medidas de posição e de variabilidade aumentaram devido ao alto valor imposto pelo parâmetro da transformada Box-Cox, provocando um maior afastamento da média em relação a mediana e aumentando o desvio padrão. Entretanto este último se manteve pequeno em relação à média, indicando um Coeficiente de Variação em torno de 30%. A distribuição permaneceu Platicúrtica (Curtose menor que zero) e quase simétrica, pois o coeficiente de assimetria (-0,14) foi próximo de 0. A assimetria persistiu especialmente pela baixa amplitude entre a mediana e o terceiro quartil (Ver Boxplot, Figura B16), destaca-se ainda que este padrão foi encontrado nas três distribuições. Analisando o histograma (Figura B17) fica claro e evidente a presença de dois picos, isto é, uma distribuição bimodal.

Figura B16 - Histograma para o Box-Cox das transformadas (m) do evento de 2010 em Palmares

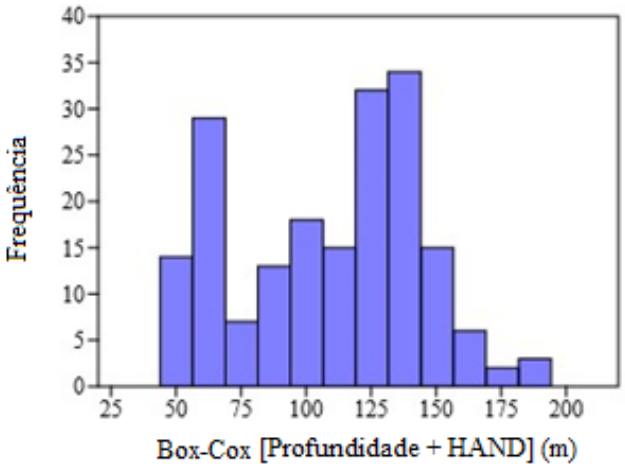

Fonte: Autor (2021)

Figura B17 - Boxplot para o Box-Cox das transformadas (m) do evento de 2010 em Palmares

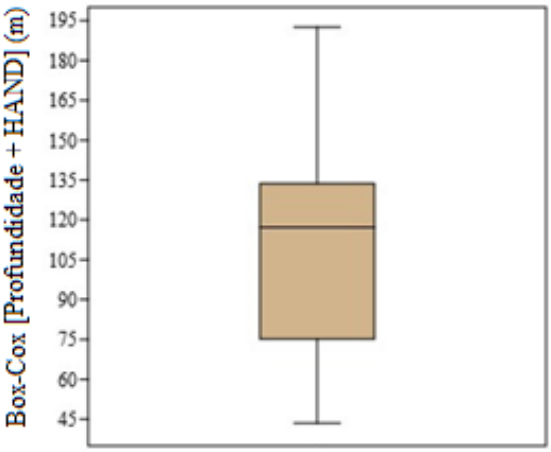

Fonte: Autor (2021)

Finalmente, os testes de hipótese rejeitaram a normalidade dos dados: embora tenha ocorrido um aumento nos parâmetros dos testes e no valor p, a probabilidade de significância (5%) não foi atingida. Decerto, como comentado anteriormente, a normalidade dos dados não é um pressuposto para o uso da Krigagem Ordinária e apesar de não ter sido atingida, certos aspectos foram alcançados: destaca-se a diminuição da variabilidade dos dados e da assimetria negativa inicial, remoção de valores extremos e da minimização das distâncias do Box-Cox das profundidades transformadas em relação à reta (em vermelho), apresentado no gráfico Q-Q (Figura B18).

Figura B18 - Gráfico Q-Q para o Box-Cox das transformadas (m) do evento de 2010 em Palmares

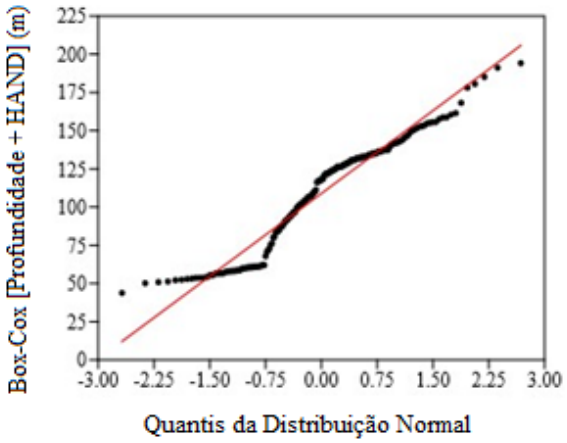

Fonte: Autor (2021)

Análise da estacionariedade e a remoção das tendências globais (Continuação)

Jaqueira

Para as profundidades de inundação do município de Jaqueira escolheu-se o polinômio cúbico para representar a tendência global das amostras. A curva de terceiro grau ajustada às amostras nos planos XZ e YZ pode ser visualizada na Figura B19.

Decerto, esta decisão é subjetiva e outros analistas poderiam assumir uma curva parabólica (segundo grau), por exemplo. Isto acontece porque as curvas dificilmente representam o comportamento local dos pontos em verde e em azul nos planos XZ e YZ, respectivamente. No entanto, é coerente que isto não ocorra, pois, a superfície de tendência tem como objetivo descrever a tendência global (não estacionária) das amostras e não o padrão ponto a ponto das profundidades.

Diante disto, almeja-se que visualmente os pontos devem variar sobre a curva com certa simetria na quantidade de pontos acima e abaixo da curva e capturar a tendência de constância, de aumento ou de queda das amostras. Mas como comentado anteriormente, a curva pode não representar as variações locais. Neste sentido, destacam-se a seguir três exemplos em que a função não conseguiu se ajustar as flutuações dos dados:

- Gráfico “a” (rotação de 0º): no plano XZ, verifica-se no início da curva verde da esquerda para a direita há uma concentração de pontos abaixo da curva e em seguida pontos mais altos e dispersos. Neste caso, a superfície descreveu um padrão quase linear e constate, o que difere do comportamento das amostras nessa região;

- Gráfico “b” (rotação de 45º): no plano YZ, percebe-se que no início da curva azul da esquerda para a direita existem valore extemos altos que não foram ajustados e no fim o crescimento da curva foi gerado pela presença de somente uma única amostra;
- Gráfico “d” (rotação de 135º): no plano XZ, acurva verde não consegue descrever o comportamento dos valores altos, ou seja, os extremos não “puxam” o pico da curva.

Figura B19 - Gráficos de tendência em relação aos planos XZ e YZ para diferentes rotações das amostras e o ajuste de uma curva de grau 3 para o logaritmo das profundidades transformadas do evento de 2017 em Jaqueira

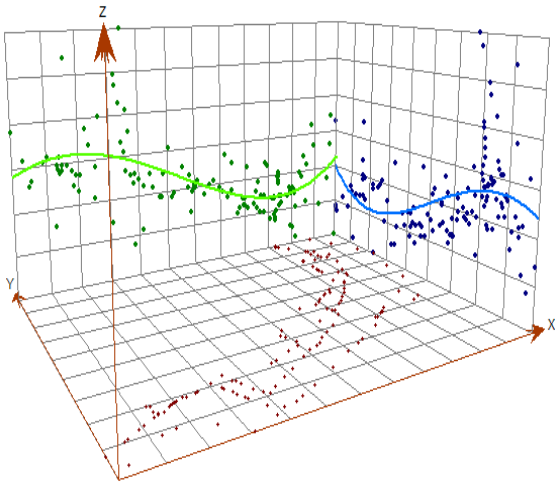

a) Rotação de 0º

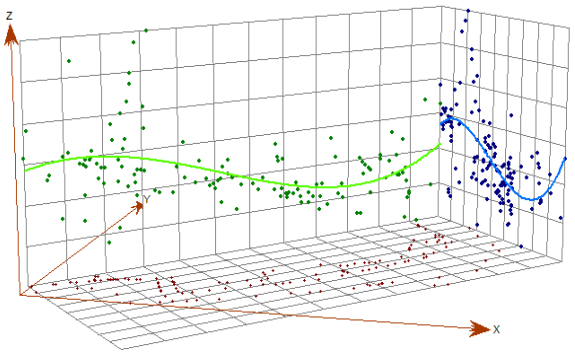

b) Rotação de 45º

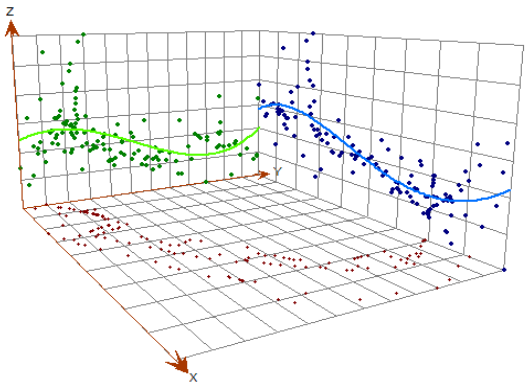

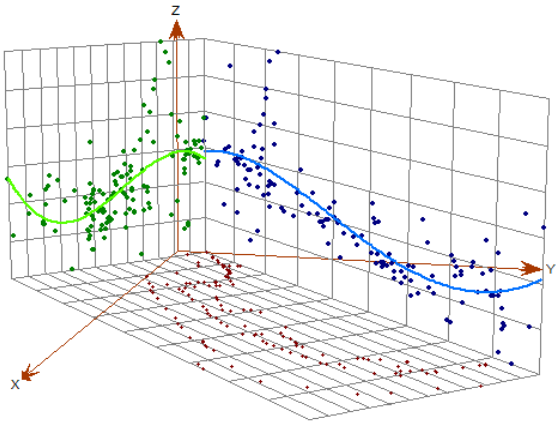

Continuação: Figura B19 - Gráficos de tendência em relação aos planos XZ e YZ para diferentes rotações das amostras e o ajuste de uma curva de grau 3 para o logaritmo das profundidades transformadas do evento de 2017 em Jaqueira.

c) Rotação de 90º

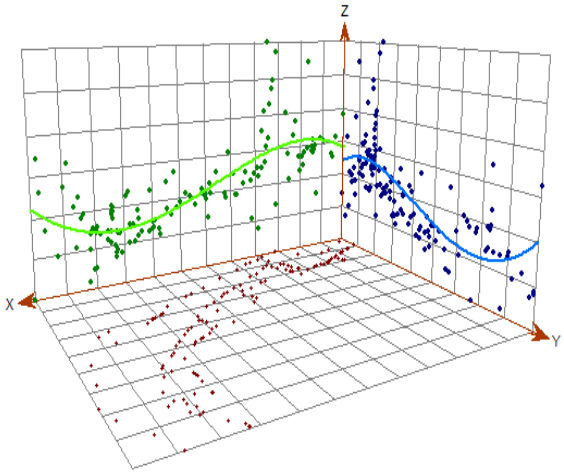

d) Rotação de 135º

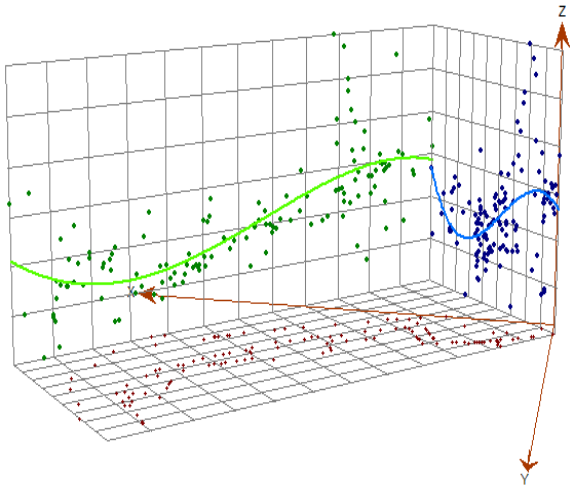

e) Rotação de 180º

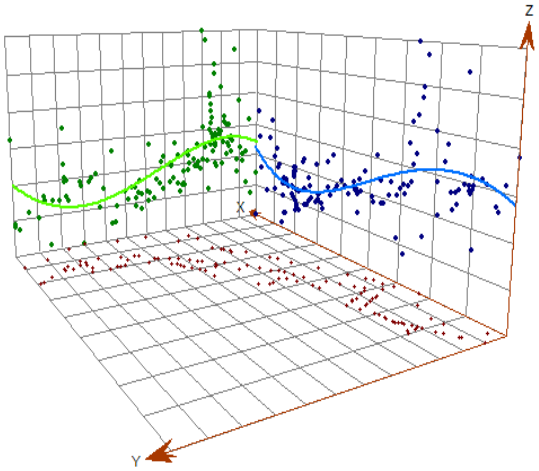

f) Rotação 225º

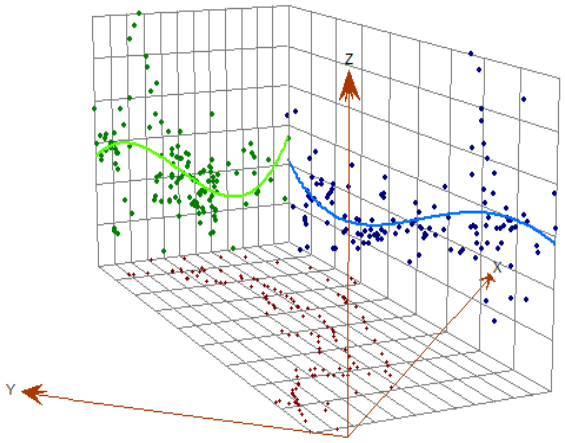

g) Rotação de 270º

h) Rotação de 315º

Fonte: Autor (2021)

Escolhida a ordem do polinômio de terceiro grau, os dados foram interpolados, resultado na superfície de tendência da Figura B20. Dessa forma, percebe-se o padrão global dos dados capturados pela função polinomial cúbica, com *clusters* de valores altos na região sudoeste do *raster* (cor laranja escura) apresentando tendência de diminuição das profundidades no sentido nordeste, região com valores baixos (cor azul clara).

Ressalta-se que nas áreas não amostradas (noroeste e sudeste), a estrutura não foi coerente e, por isto, deve-se ter atenção especial no final da inferência. Extraindo a superfície

global (superfície de tendência de grau 3) das amostras obtém-se resíduos estacionários, promovendo fundamentos essenciais para a aplicação da Krigagem Ordinária.

Figura B20 - Superfície de tendência para o logaritmo das profundidades transformadas do evento de 2017 em Jaqueira

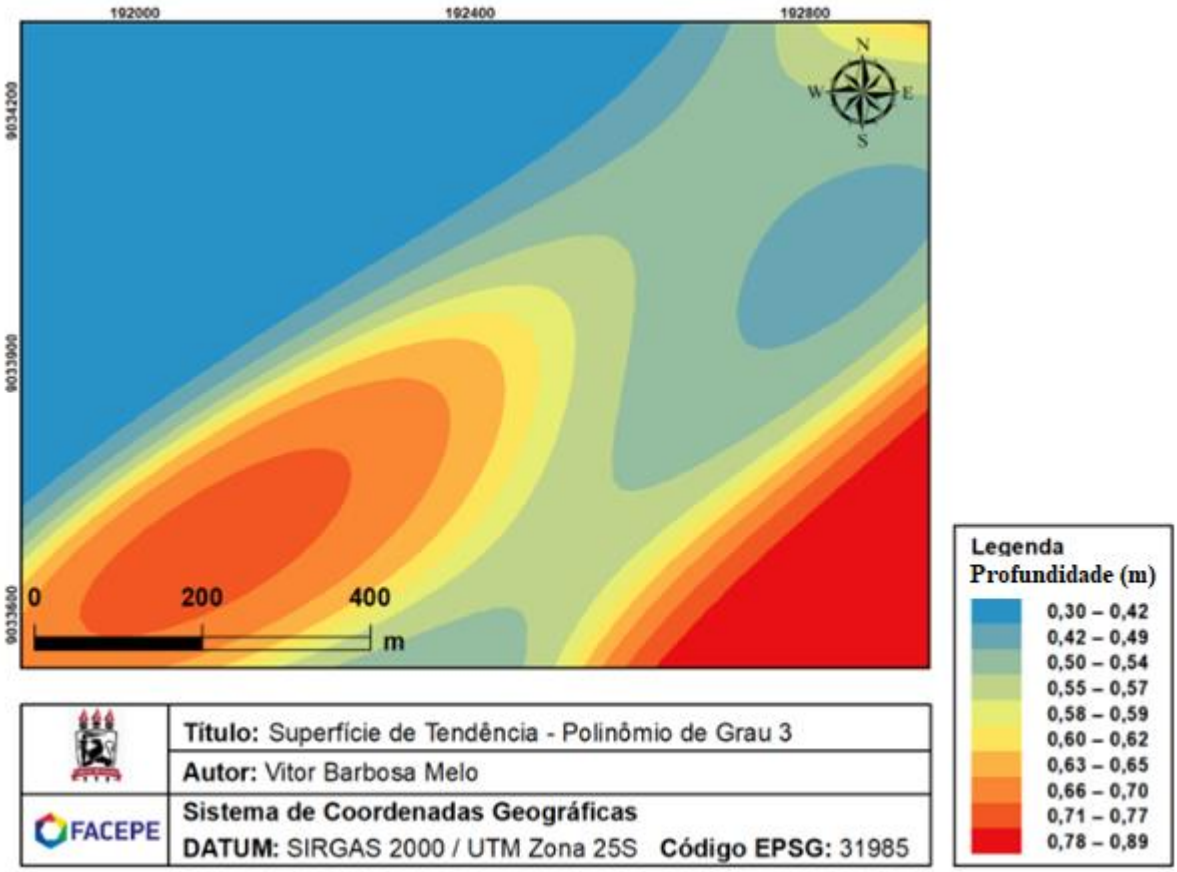

Fonte: Autor (2021)

Palmares

Para o caso de Palmares, também foi verificada a não estacionaridade dos dados espaciais. Neste caso, a estrutura global das profundidades foi mais bem ajustada por um polinômio de segunda ordem. Os gráficos de tendência podem ser visualizados na Figura B21 para diferentes rotações. A curva parabólica conseguiu representar as flutuações em quase todas as regiões dos gráficos para todas as rotações, exceto nas seguintes ocasiões:

- Gráficos “a”, “c”, “e”, “g”: na parte central ocorreu uma concentração de pontos abaixo de ambas as curvas (azul e verde), as quais não conseguiram explicar tais ocorrências;

- Gráficos “b” e “f”: na curva azul para as regiões com valores extremos baixos, apesar de capturar o decaimento dos pontos, percebe-se que ocorre de maneira brusca sem acompanhar o comportamento destas regiões.

Figura B21 - Gráficos de tendência em relação aos planos XZ e YZ para diferentes rotações e o ajuste de uma curva de grau 2 para o box-cos das profundidades transformadas do evento de 2010 em Palmares

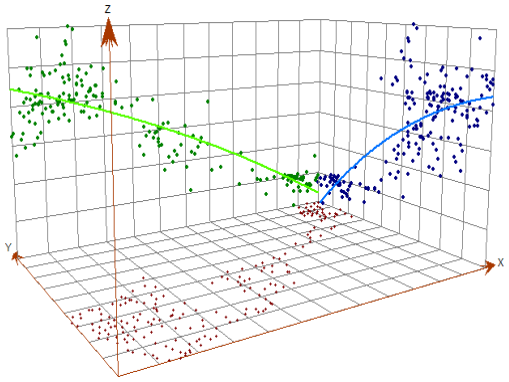

a) Rotação de 0º

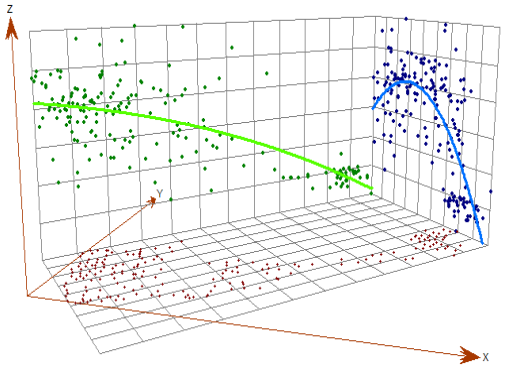

b) Rotação de 45º

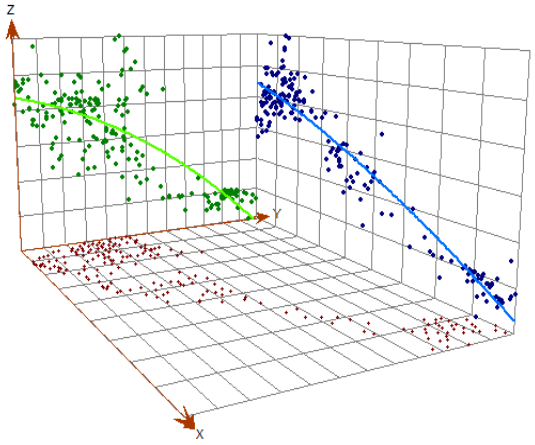

c) Rotação de 90º

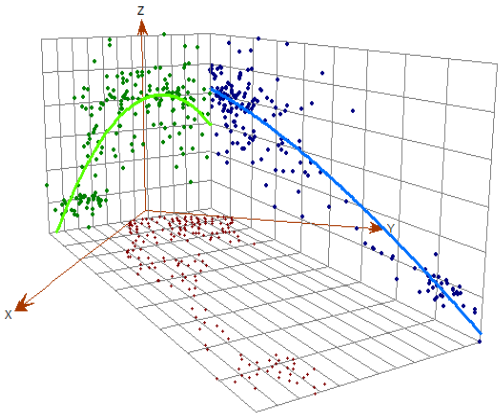

d) Rotação de 135º

Continuação: Tabela B.21 - Gráficos de tendência em relação aos planos XZ e YZ para diferentes rotações e o ajuste de uma curva de grau 2 para o box-cos das profundidades transformadas do evento de 2010 em Palmares

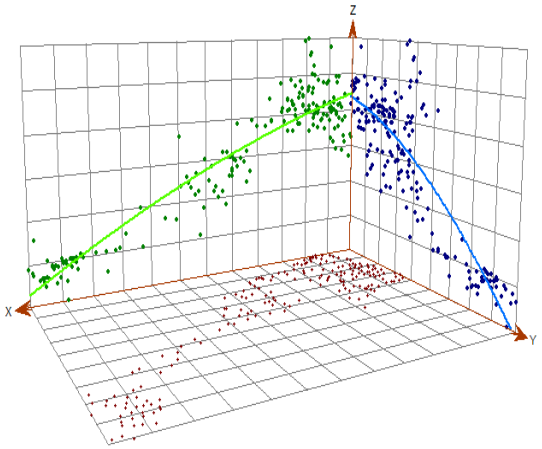

e) Rotação de 180º

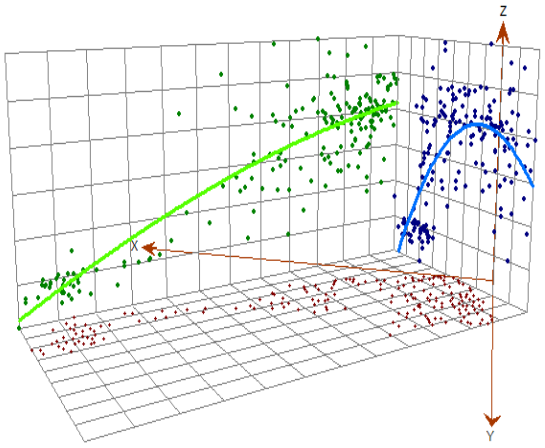

f) Rotação de 225º

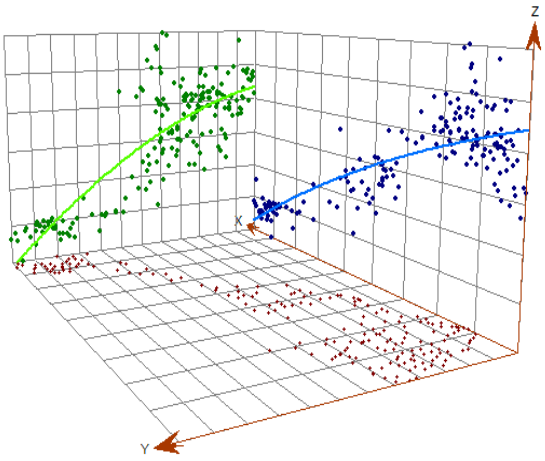

g) Rotação de 270º

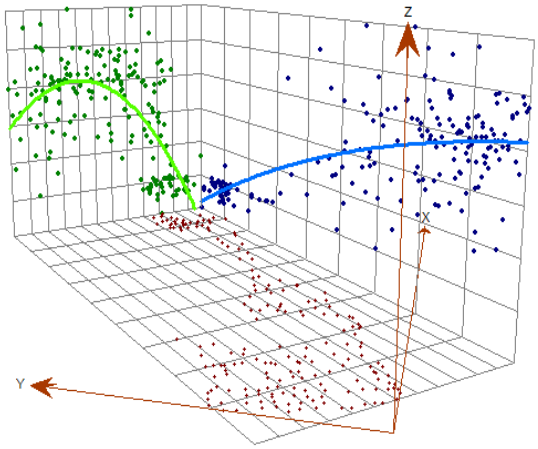

h) Rotação de 315º

Fonte: Autor (2021)

Na Figura B22 representa-se a superfície de tendência de grau 2 para o Box-Cox das profundidades transformadas. Como pode ser visto, os dados apresentam um padrão regional de decaimento no sentido oeste/leste e sudoeste/nordeste, investigados nas regiões amostradas. Esta superfície possibilita o tratamento da não estacionariedade ao retirar a variação global dos dados, desse modo os resíduos (variações locais) estacionários podem ser modelados para criação do semivariograma e inferência probabilística.

Figura B22 - Superfície de tendência para o Box-Cox das profundidades transformadas do evento de 2010 em Palmares

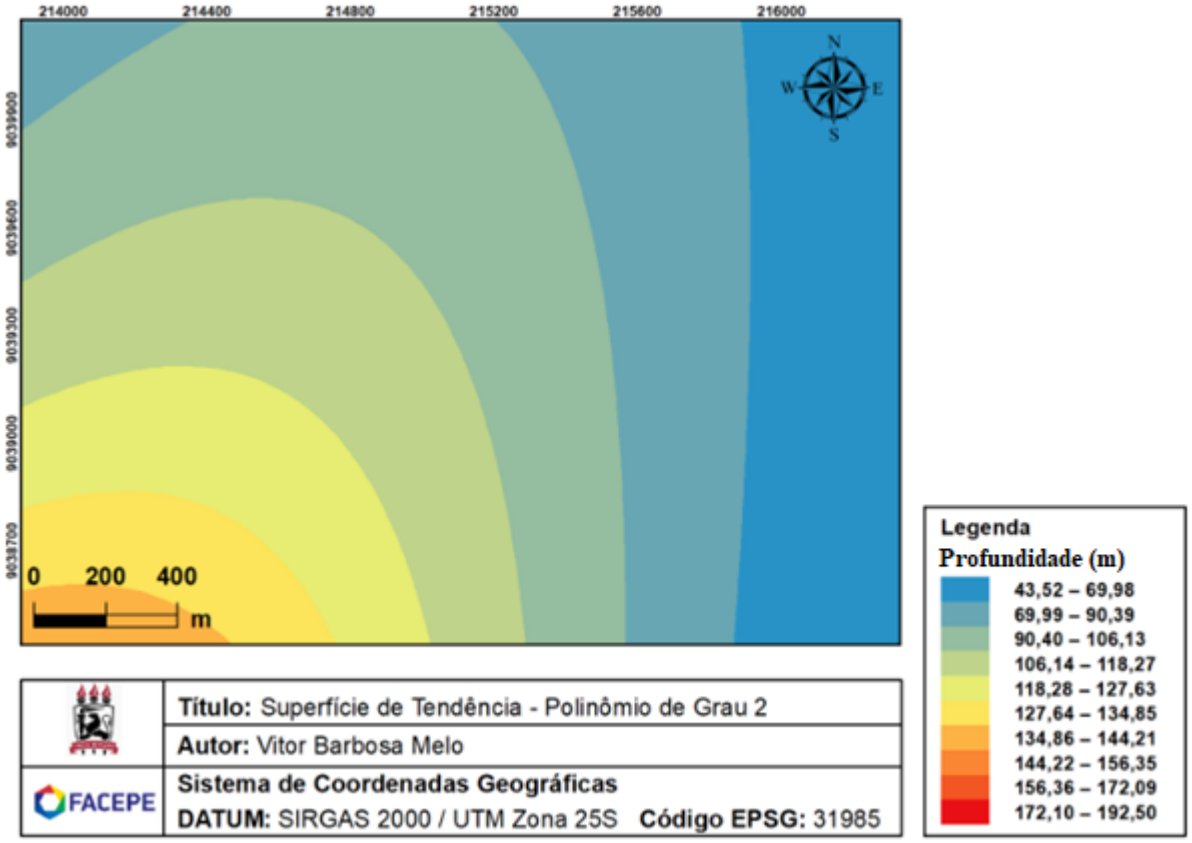

Fonte: Autor (2021)

Semivariograma e a Validação Cruzada no processo de decisão (Continuação)

Jaqueira

O semivariograma empírico e teórico do cenário A e B foi construído seguindo as regras descritas no item Semivariograma Empírico e Teórico na sessão 3.3.2. Escolhidos os parâmetros de procura das semivariâncias empíricas e a curva que visualmente explicou as nuances das semivariâncias médias, o semivariograma teórico foi ajustado automaticamente pelo método dos mínimos quadrados, produzindo o gráfico do semivariograma, a superfície de semivariância e os parâmetros do modelo ajustado.

Para o cenário A, os valores selecionados dos parâmetros de procura dos pares amostrais (Tabela B7), utilizados para a construção do semivariograma empírico (Figura B23), foram adequados. O semivariograma empírico mostrou a existência da continuidade espacial (correlação), porque a semivariância cresceu com o aumento da distância e, no geral, este efeito é o mais esperado devido à regularidade das semivariâncias e evidências da presença de

estacionariedade da covariância (variância), resultando no melhor ajustamento da curva matemática teórica.

Outro enforque importante está na aceitável representação da variabilidade na pequena escala. Ressalta-se que neste espaço há certa criticidade para a modelagem devido à quantidade de pares amostrais ser pequena e ao cálculo dos ponderadores, pois atribuem-se maiores pesos para amostras mais próximas. Além disso, a variância local (descrita pelo efeito pepita) proveniente de erros aleatórios ou sistemáticos pode enviesar a inferência. Note-se que, dependendo da escolha da curva, o efeito pepita pode assumir valores significativamente distintos.

Tabela B7 - Parâmetros para a construção do semivariograma empírico para os resíduos do evento de 2017 em Jaqueira no cenário A

Parâmetros	Lag	Número de Lags	Modelo
Semivariograma Empírico	16	12	Isotrópico

Fonte: Autor (2021)

Figura B23 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira para o cenário A

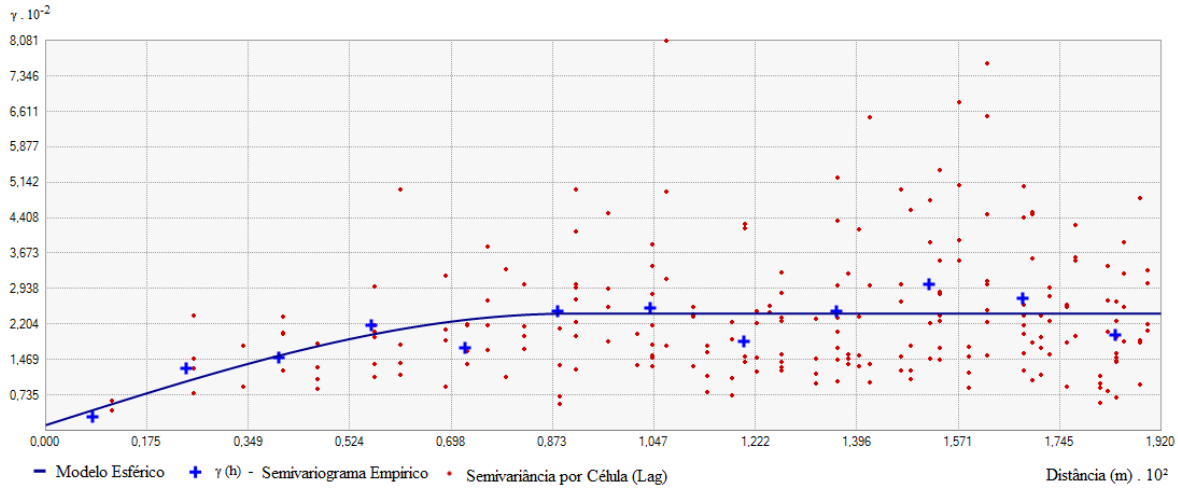

Fonte: Autor (2021)

O semivariograma teórico (curva azul da Figura B23), representado pelos parâmetros (Tabela B8) da curva esférica, conseguiu descrever as particularidades da dependência espacial dos resíduos segundo o ajuste do modelo em relação às semivariâncias empíricas. Certamente, a curva gaussiana e a exponencial também foram testadas, entretanto, a gaussiana visualmente não moldou adequadamente as primeiras semivariâncias médias e apresentou uma região de continuidade espacial muito curta (alcance). Por outro lado, a exponencial exibiu semelhanças

com a curva esférica, porém esta última nas métricas de desempenho (validação cruzada, incerteza e particularidades do fenômeno) produziu resultados mais satisfatórios.

Tabela B8 - Parâmetros do semivariograma teórico para os resíduos do evento de 2017 em Jaqueira no cenário A

Parâmetros	**Modelo**	**Efeito Pepita**	**Patamar**	**Alcance**
Semivariograma Teórico	Esférico	0,0011	0,0231	90,3625

Fonte: Autor (2021)

A respeito do efeito pepita, tal parâmetro foi calculado automaticamente pelo método dos mínimos quadrados, implicando um ajuste baseado na dependência espacial das semivariâncias dos primeiros lags, dado por distâncias curtas entre as amostras. De todo modo, este valor depende da variação local (pequena escala) dos dados e do conhecimento sobre o levantamento. Um exemplo comum para determinadas variáveis é o erro indicado pelo equipamento de medição. Na prática há incertezas de diferentes naturezas e, com isso, a exatidão do efeito pepita é incomum, o que torna sua escolha subjetiva.

Apesar do bom ajuste do modelo, algumas flutuações irregulares foram encontradas nas semivariâncias médias (cruzetas azuis), a exemplo do quinto ponto (por volta de 70 metros) e do oitavo ponto (em torno de 120 metros) da esquerda para direita. Estas variações são causadas por pares amostrais de alta variabilidade que aumentam ou diminuem a semivariância média, principalmente pelos dados extremos. Outro aspecto a ser destacado é que o oitavo ponto está na região de descontinuidade espacial (sem correlação). Esta anormalidade pode ter ocasionado o alcance relativamente pequeno (90 metros), visto que depois da correlação espacial, o sétimo ponto ainda indica certa regularidade, o que torna o oitavo ponto, possivelmente, o responsável por iniciar a desarmonia gráfica (sobe e desce das semivariâncias médias).

Do ponto de vista das semivariâncias empíricas por células (pontos em vermelho), verifica-se de maneira mais clara as regiões que comprometem o semivariograma, gerando flutuações indesejadas. Como pode ser visto no semivariograma (Figura B23), os pontos vermelhos com semivariâncias altas podem causar enviesamento da curva teórica e, consequentemente, no modelo final. Alguns exemplos podem ser visualizados acima da segunda, da quarta, da sexta e da sétima semivariância média.

Analisando o mapa de semivariância (Figura B24), a região do modelo isotrópico (círculo em azul) abrangeu somente as células de baixa a média variabilidade, evitando os valores altos de semivariância (*pixels* em vermelho e laranja). Percebe-se também que existe uma orientação no espaço de menor variabilidade espacial (maior correlação), concedido pelo

ângulo de 45º no sentido horário a partir do Norte. Esta evidência indica a possibilidade de um modelo anisotrópico. Todavia, o modelo isotrópico esférico apresentou métricas preferíveis em relação aos modelos anisotrópicos testados.

Figura B24 - Mapa de semivariograma para os resíduos do evento de 2017 em Jaqueira no cenário A

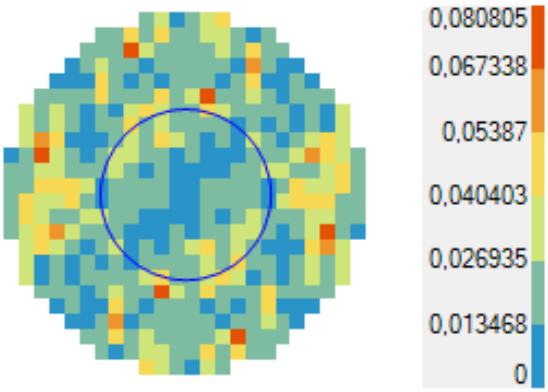

Fonte: Autor (2021)

Devido à presença de irregularidades no semivariograma, prosseguiu-se para a etapa da Validação Cruzada em busca de indicativos dos pontos que instabilizaram o semivariograma. Apesar da VC ser passível de análises incoerentes, visto que a própria variabilidade do fenômeno pode causar erros inevitáveis, a exemplo de pontos discrepantes em regiões de *clusters*, retirar conclusões fundamentadas nos dados e no processo de Krigagem, ainda que indiretamente, é mais sofisticado e compreensível do que deduzir sem metodologias consolidadas.

Inicialmente, comparou-se os valores estimados em relação aos medidos através do gráfico de dispersão da Figura B25. Avalia-se o modelo de Krigagem através da proximidade da reta de regressão linear (azul) ajustada pelos pontos em vermelho com a reta 1:1 de referência (em cinza). Embora, na prática seja impraticável a correspondência perfeita do modelo, os dados inferidos pela VC comparados com os reais indicam que existe correlação, tornando aceitável o modelo de Krigagem escolhido. Porém certas evidências foram observadas: percebeu-se pontos dessemelhantes à reta cinza, ou seja, mais afastados da reta 1:1. Provavelmente isto ocorreu devido às flutuações locais (amostras atípicas localmente) e às particularidades identificadas no semivariograma em certas regiões estimadas. Ademais, a reta de ajuste do modelo iniciou com a superestimação dos valores baixos. Antes de atingir os valores médios cruzou a reta de referência, o que evidenciou mais amostras subestimadas no todo, com ênfase nos valores médios e altos, tendo o extremo apresentado erros maiores.

A ocorrência de mais erros subestimados também foi verificada através do histograma do erro (Figura B26), onde nitidamente houve maiores frequências para valores negativos, isto é, assimetria a direita. Para efeitos do desempenho do modelo a distribuição do erro deve apresentar características de uma distribuição normal com média próxima a zero, indicando a exatidão do modelo e a minimização da variação do erro, apontando a precisão da Krigagem. Estes aspectos foram confirmados pela distribuição de frequência, pela média igual a -0,0244 e pela variância igual a 0,4623 (Tabela B9).

Figura B25 - Gráfico inferido versus medido para a Validação Cruzada do evento de 2017 em Jaqueira no cenário A

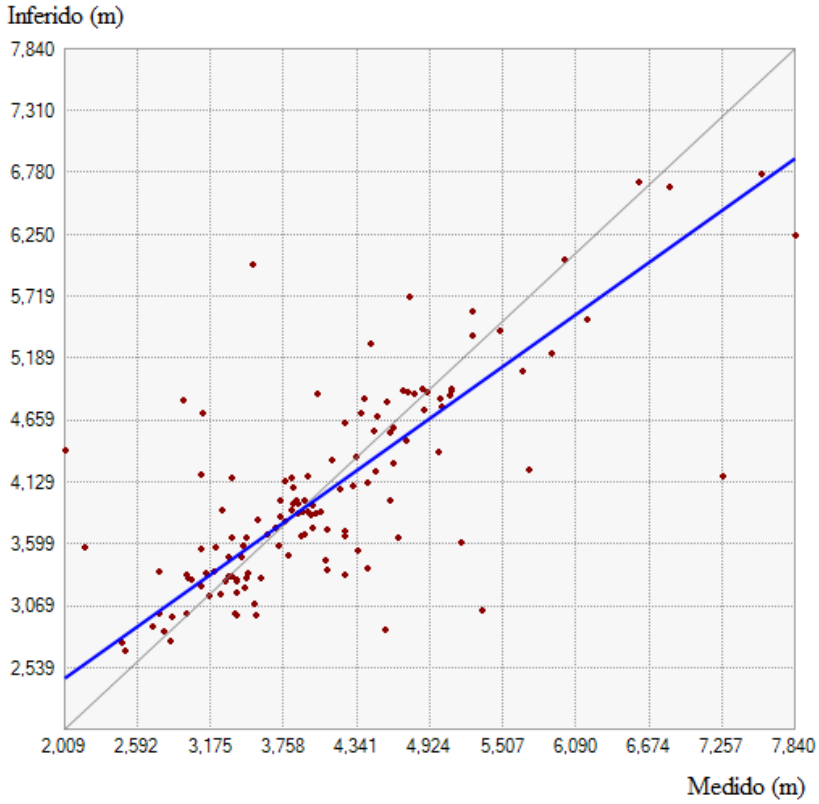

Fonte: Autor (2021)

Figura B26 - Histograma dos erros para a Validação Cruzada do evento de 2017 em Jaqueira no cenário A

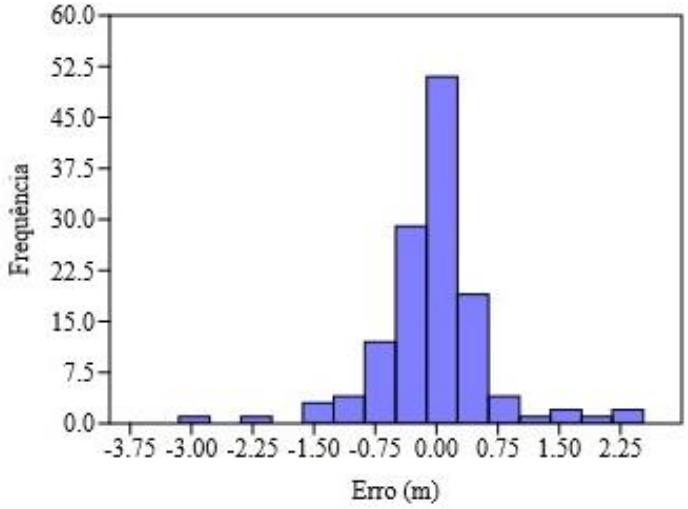

Fonte: Autor (2021)

Tabela B9 - Métricas de desempenho da Validação Cruzada para o evento de 2017 em Jaqueira no cenário A

Média dos Erros (ME)	-0,0244
Variância dos Erros (Var)	0,4623
Raiz Quadrada Média dos Quadrados dos Erros (RMSE)	0,6778
Média dos Erros Padronizados (ASE)	0,4674
Média dos Erros Normalizados (MSE2)	-0,0673
Raiz Quadrada Média dos Quadrados dos Erros Normalizados (RMSSE)	1,2362

Fonte: Autor (2021)

Outras métricas foram usadas para verificar o desempenho do modelo para o cenário A (Tabela B9). A Raiz Quadrada Média dos Quadrados dos Erros (RMSE) indica o ajuste da previsão em relação aos valores estimados a partir dos erros: quanto menor (mais próximo de zero) melhor o ajuste. Destaca-se que este parâmetro é dependente da escala dos dados, tornando-o apropriado para comparações entre modelos para um mesmo conjunto de amostras. O valor ficou relativamente próximo a zero, entretanto foi mais bem empregado na comparação com o cenário B (visto mais adiante).

O erro padronizado é medido através da raiz quadrada da variância da Krigagem para cada ponto inferido no processo de VC, possibilitando também verificar a incerteza da Krigagem em cada amostra. A média dos erros padronizados (ASE), assim como o RMSE, deve ser minimizada para que o modelo aponte baixa incerteza da predição, além disso ambas as métricas devem ser próximas, apesar de indicarem a confiança da estimativa para diferentes medidas. Como visto, a diferença entre o ASE e RMSE foi relativamente significativa (0,21).

Em relação a escala, este valor indicou certa dissimilaridade entre a incerteza da estimativa e do erro padronizado (variância da Krigagem).

Por outro lado, por meio do erro normalizado que é derivado da divisão entre o erro (valores medidos menos estimados/calculados) e o erro padronizado obteve-se o MSE2 e RMSSE. O primeiro parâmetro foi próximo a zero e negativo, indicando bom ajuste dos erros normalizados e subestimação da incerteza através da VC, respectivamente. O RMSSE foi maior que 1, indicando assim uma tendência a minimizar o erro normalizado: o valor desejável para este parâmetro é a unidade, porém é mais indicado para comparação entre modelos. Além do mais, os erros normalizados devem seguir uma distribuição normal e por este motivo são avaliados através do Gráfico Q-Q (Figura 27). Nitidamente, valores extremos apresentaram alto desvio em relação à normal.

Figura B27 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2017 em Jaqueira no cenário A

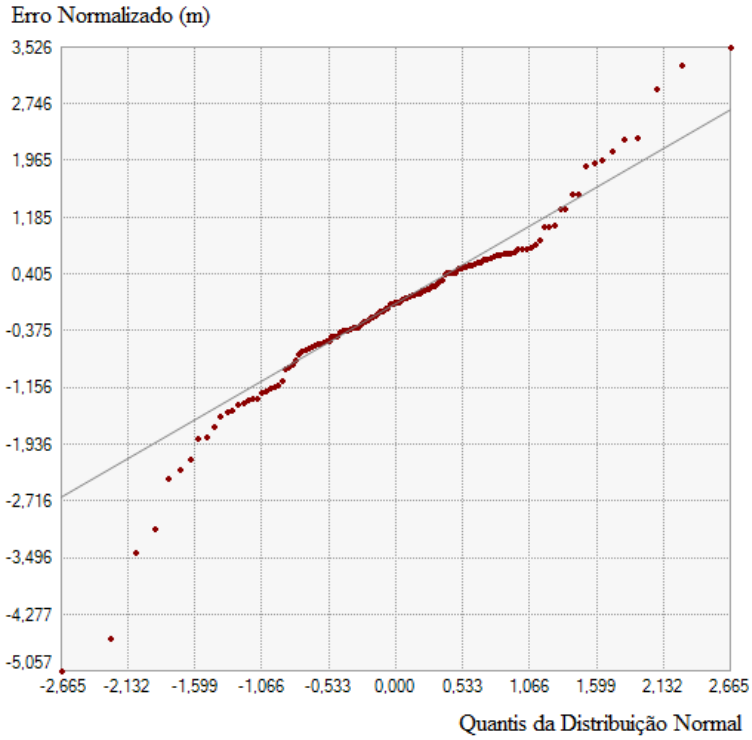

Fonte: Autor (2021)

No geral, o desempenho foi aceitável com certas ressalvas sobre o comportamento irregular do semivariograma na região de continuidade espacial e amostras que apresentaram alta incerteza nas estimativas da profundidade e da variância da Krigagem (erro padrão) no processo de Validação Cruzada. Por tais motivos, os pontos que apresentaram baixa confiança e que influenciaram em semivariâncias altas na curta distância e na regularidade das

semivariâncias médias foram excluídos do processo de modelagem do semivariograma, gerando o cenário B.

Para o cenário B, os parâmetros de busca (Tabela B10) escolhidos, evidenciaram o comportamento desejável do semivariograma empírico (Figura B28), destacando a presença de correlação espacial, da estacionariedade, da regularidade das semivariâncias médias, principalmente, na variabilidade das curtas distâncias. Este padrão promoveu melhora no ajuste do semivariograma teórico (Figura B28 e Tabela B11) através dos mínimos quadrados, em que se observou a minimização dos desvios das semivariâncias empíricas a curva teórica. Ademais, a curva exponencial foi selecionada por ter exposto resultados melhores dentre as outras curvas experimentadas (gaussiana e esférica).

Com a retirada das amostras foi evidenciado: um efeito pepita igual a zero (ideal) indicando efeito positivo. Visto que nas distâncias próximas a 70 e 120 metros (flutuações irregulares do cenário A) ocorreu uma melhora significativa das semivariâncias médias, apesar de ainda ter sido verificado variâncias por células altas, além de um aumento da continuidade espacial representada pelo alcance do semivariograma teórico.

Tabela B10 - Construção do semivariograma empírico para os resíduos do evento de 2017 em Jaqueira no cenário B

Parâmetros	Lag	Número de Lags	Modelo
Semivariograma Empírico	17,5	12	Isotrópico

Fonte: Autor (2021)

Figura B28 - Semivariograma empírico e teórico para os resíduos do evento de 2017 em Jaqueira, após a exclusão de 7 pontos, cenário B

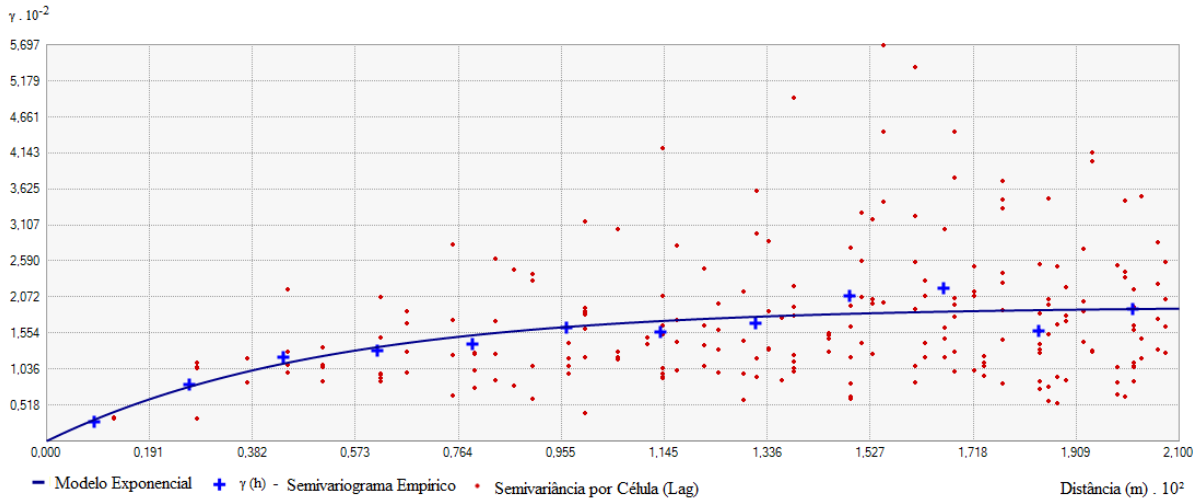

Fonte: Autor (2021)

Tabela B11 - Parâmetros do semivariograma teórico para os resíduos do evento de 2017 em Jaqueira no cenário B

Parâmetros	Modelo	Efeito Pepita	Patamar	Alcance
Semivariograma Teórico	Exponencial	0,0000	0,0193	153,8414

Fonte: Autor (2021)

Do ponto de vista da superfície do semivariograma (Figura B29), verificou-se uma diminuição significativa da variabilidade para diferentes orientações, permitindo um aumento do alcance realizado pelo modelo teórico (círculo azul). Independentemente de ter sido identificadas variâncias mais altas (*pixels* em vermelho e laranja) na área de correlação espacial, os valores em si são médios em relação às semivariâncias do cenário A e distantes da pequena escala, sendo observados no limite da continuidade espacial. Ainda, assim como observado no cenário A, percebeu-se certa anisotropia com menor variabilidade para a direção de 45º. Entretanto, o semivariograma isotrópico exponencial apresentou resultados superiores em todos os aspectos, quando comparado a modelos que consideraram a anisotropia.

Na etapa da Validação Cruzada, o cenário B apresentou algumas considerações similares ao cenário A. No que concerne à comparação entre os valores medidos e estimados, o gráfico de dispersão (Figura B30) indica melhora devido à correção das estimativas discrepantes (*outliers*), minimizando os desvios e promovendo evolução na sobreposição entre a reta ajustada (azul) e a reta que indica exatidão do modelo (cinza).

Figura B29 - Mapa de semivariograma para os resíduos do evento de 2017 em Jaqueira no cenário B

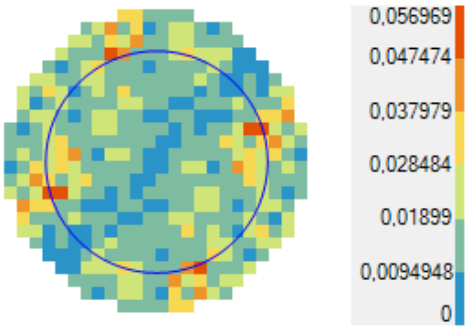

Fonte: Autor (2021)

Figura B30 - Gráfico inferido versus medido para a Validação Cruzada do evento de 2017 em Jaqueira no cenário B

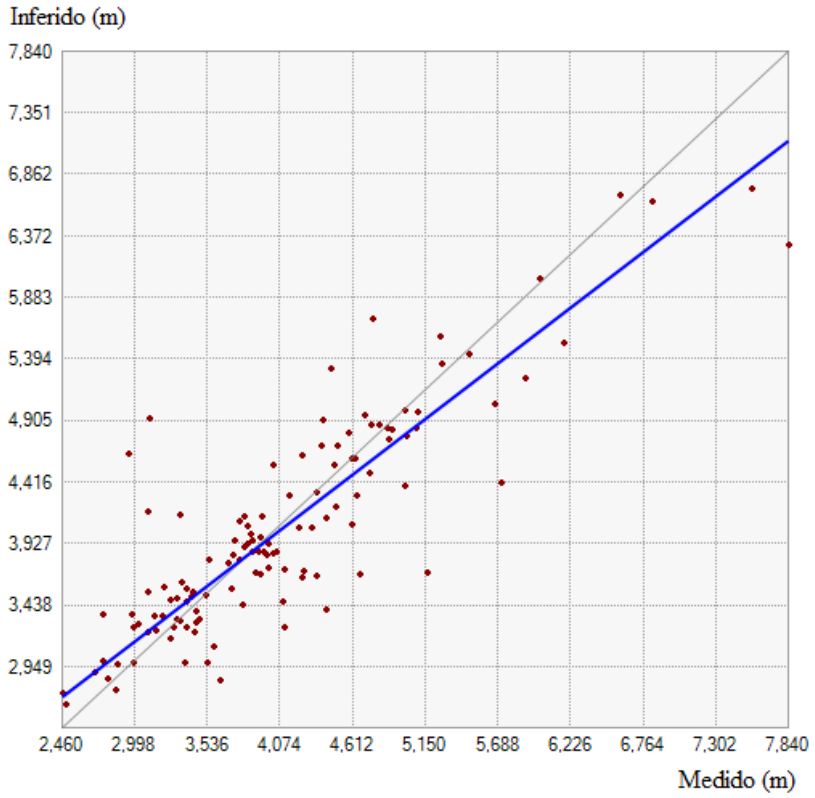

Fonte: Autor (2021)

A superestimação das estimativas baixas e a subestimação dos valores médios e altos também foram evidenciados no cenário B, indicando leve assimetria positiva (menor que no cenário A), como verificado no histograma dos erros (Figura B31). A subestimação global também foi verificada nos valores negativos para a média dos erros absolutos (ME) e dos erros normalizados (MSE2) (Tabela B12), e no RMSSE, que resultou em um valor acima da unidade.

Percebeu-se também a diminuição da média e da variância do erro em relação ao cenário A. A minimização destes parâmetros indicou aperfeiçoamento nas estimativas da profundidade transformada para a etapa da VC. Nos indicadores estatísticos para comparação de modelos, o cenário B exibiu menor RMSE e RMSSE e, com isso, apresentou resultados mais satisfatórios nas estimativas da amostra e da confiança da Krigagem. Além disso, a diferença entre o RMSE e ASE caiu pela metade (0,1), mostrando que a incerteza foi estimada de maneira consistente. Finalmente, em relação ao gráfico Q-Q (Figura B32), houve uma melhora no ajuste dos erros normalizados a uma distribuição normal, principalmente nos extremos.

Figura B31 - Histograma dos erros para a Validação Cruzada do evento de 2017 em Jaqueira no cenário B

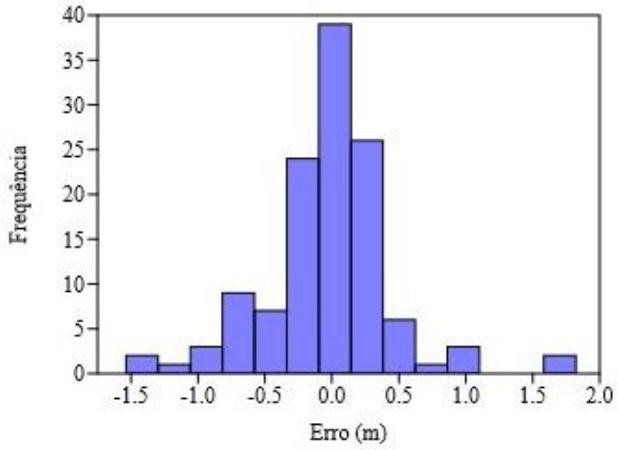

Fonte: Autor (2021)

Tabela B12 - Métricas de desempenho da Validação Cruzada para o evento de 2017 em Jaqueira no cenário B

Média dos Erros (ME)	-0,0235
Variância dos Erros (Var)	0,2319
Raiz Quadrada Média dos Quadrados dos Erros (RMSE)	0,4802
Média dos Erros Padronizados (ASE)	0,3795
Média dos Erros Normalizados (MSE2)	-0,0479
Raiz Quadrada Média dos Quadrados dos Erros Normalizados (RMSSE)	1,0816

Fonte: Autor (2021)

Figura B32 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2017 em Jaqueira no cenário B

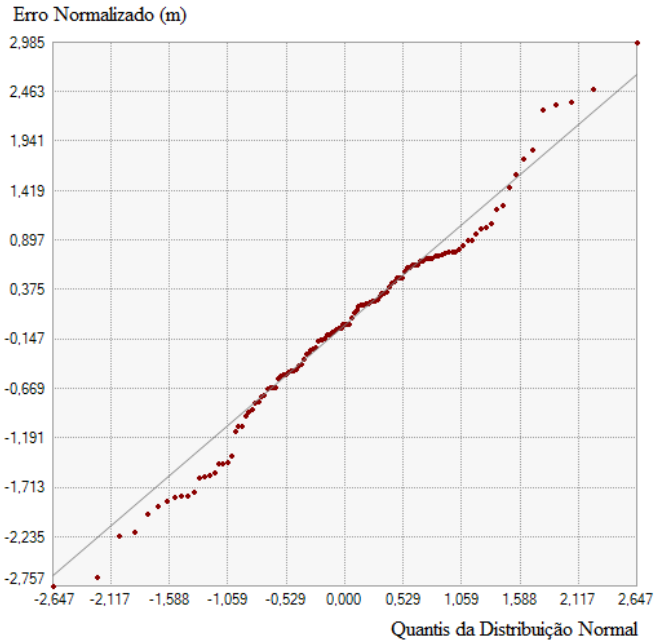

Fonte: Autor (2021)

Palmares

No caso de Palmares foram gerados dois cenários, um isotrópico (cenário C) e outro anisotrópico (cenário D). Distintamente dos dados de Jaqueira, o modelo com os 188 resíduos mostrou semivariâncias regulares, não sendo necessário realizar o mesmo procedimento de exclusão de amostras na etapa de construção do modelo semivariográfico.

A princípio, o semivariograma empírico do cenário C foi testado para diferentes parâmetros de busca dos pares amostrais e avaliando as evidências almejadas das semivariâncias e da VC, optou-se pelos parâmetros indicados na Tabela B13, resultando no semivariograma empírico da Figura B33.

Analisando a estrutura do semivariograma empírico, percebeu-se o comportamento desejável da estrutura espacial através do crescimento da variabilidade conforme o aumento das distâncias entre as amostras. Observou-se também a presença de poucas semivariâncias na pequena escala, porém o uso de lags menores apresentaram flutuações irregulares no gráfico, o que prejudicou o ajuste automático do semivariograma teórico, além de produzir pequenas distâncias (alcance) para continuidade espacial. Outra constatação foi que dentro da estrutura espacial até 200 metros as semivariâncias por célula e médias se apresentaram próximas entre si, indicando a possibilidade coerente para geração de um modelo isotrópico. Por fim, depois de 200 metros, as semivariâncias por célula passaram a exibir valores baixos e altos de forma regular, revelando existir possível anisotropia.

Este indicativo de uma orientação preferencial para correlação espacial dos resíduos foi corroborado com o mapa de semivariância (Figura B34). Observou-se que na direção de 135º (o 0º representa o Norte) existe uma variabilidade espacial menor em comparação a sua perpendicular (direção de 45º), a qual apresenta variâncias mais altas. Percebeu-se, então, que um modelo semivariográfico anisotrópico representado por uma elipse poderia explicar adequadamente o comportamento espacial dos resíduos para o evento estudado.

Do ponto de vista do semivariograma teórico, a curva matemática gaussiana e seus respetivos parâmetros (Tabela B14) ajustaram corretamente o comportamento das semivariâncias médias, em que 5 pontos médios descreveram a região de correlação espacial. Inicialmente destaca-se que o valor alto do efeito pepita e do patamar calculados faz parte das transformações realizadas sobre os dados e que esta escala não prejudicou os resultados.

Sobre o efeito pepita, verificou-se que não existem semivariâncias próximas a zero. Entretanto isto está relacionado com a amostragem das profundidades de inundação, de modo que as distâncias entre os pontos coletados não puderam descrever a variabilidade na pequena

escala. Ressalta-se que os pontos das semivariâncias na curta distância indicaram a existência de um efeito pepita alto e possibilitaram coerente ajuste para obtenção do valor deste parâmetro.

Com relação ao alcance, as semivariâncias médias a partir de 365 metros apresentaram comportamento constante (a variabilidade não possui aumento), indicando assim a descontinuidade espacial. Com isso, o alcance calculado foi pequeno. Apesar de ter sido observado através da superfície de semivariância, uma baixa variabilidade espacial para distâncias maiores, como explicado anteriormente.

Tabela B13 - Construção do semivariograma empírico para os resíduos do evento de 2010 em Palmares no cenário C

Parâmetros	Lag	Número de Lags	Modelo
Semivariograma Empírico	70	10	Isotrópico

Fonte: Autor (2021)

Figura B33 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário C

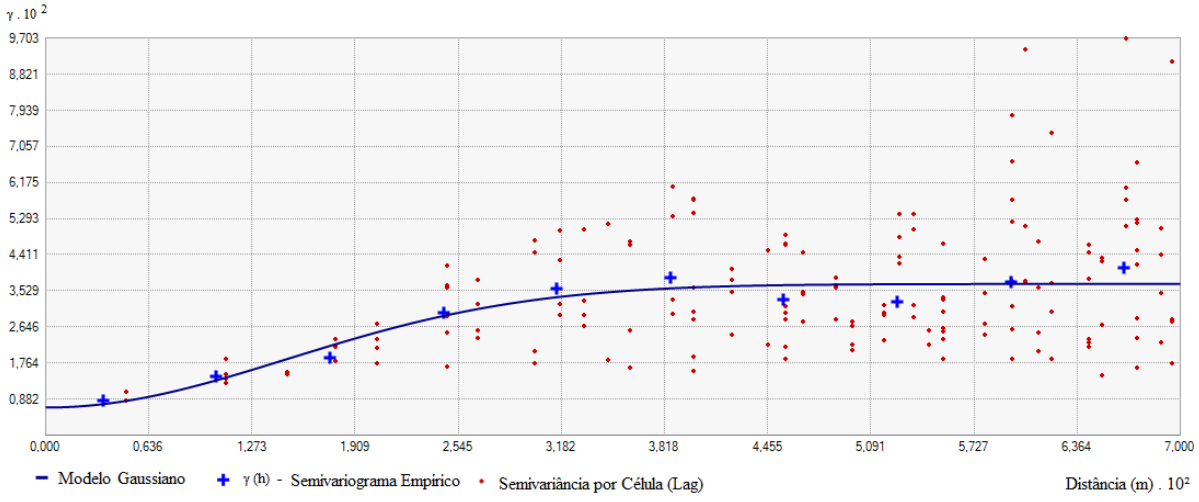

Fonte: Autor (2021)

Tabela B14 - Parâmetros do semivariograma teórico para os resíduos do evento de 2010 em Palmares no cenário C

Parâmetros	Modelo	Efeito Pepita	Patamar	Alcance
Semivariograma Teórico	Gaussiano	67,6854	369,4380	365,3506

Fonte: Autor (2021)

Figura B.34 - Mapa de semivariograma para os resíduos do evento de 2010 em Palmares no cenário C

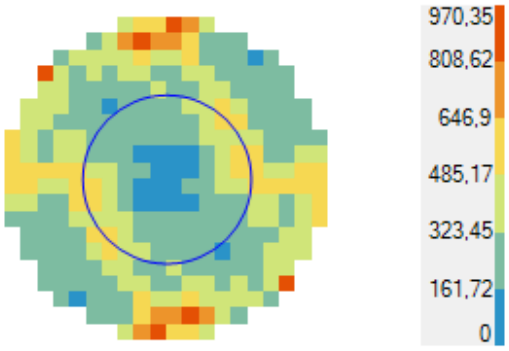

Fonte: Autor (2021)

Na etapa da Validação Cruzada, o modelo krigado segundo o cenário C apresentou bom ajuste, pois percebeu-se claramente a correlação entre os valores estimados e medidos (Figura B35) devido à proximidade entre a linha ajustada (azul) e a linha cinza (modelo ideal). Com isso, verificou-se que os desvios em relação à reta cinza foram quase simétricos, indicando que em média houve leve superestimação (extremos baixos) e subestimação (extremos altos). Ressalta-se que isto não quer dizer que o modelo seja perfeito, mas que no geral tende a errar na média. Esta evidência também pôde ser visualizada através do histograma dos erros (Figura B36).

Figura B35 - Gráfico inferido versus medido para a Validação Cruzada do evento de 2010 em Palmares no cenário C

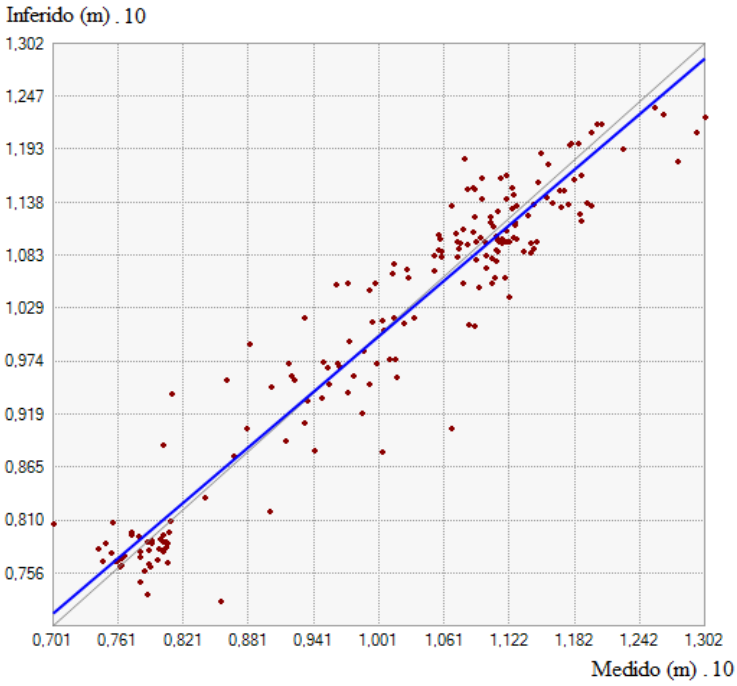

Fonte: Autor (2021)

Figura B36 - Histograma dos erros para a Validação Cruzada do evento de 2010 em Palmares no cenário C

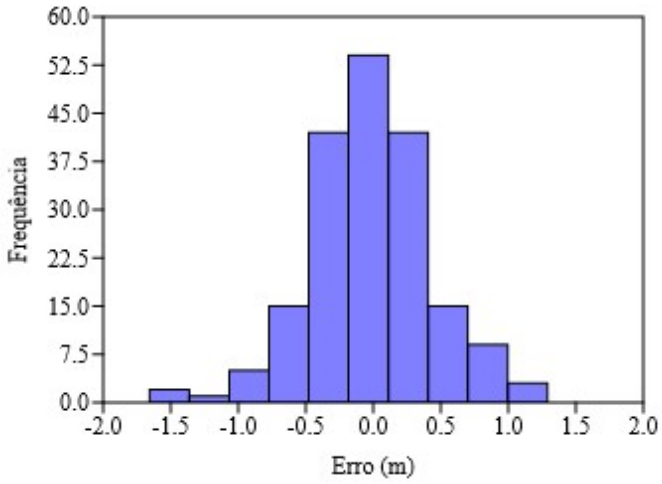

Fonte: Autor (2021)

A respeito das métricas de desempenho (Tabela B15), a média e a variância do erro foram coerentes, o valor negativo da média apontando certa subestimação no geral. A diferença entre o RMSE e o ASE foi pequena, cerca de 0,009, quase desprezível. Tal similaridade entre os dois parâmetros evidencia que a incerteza da inferência das profundidades transformadas e da confiança do modelo está sendo estimada consistentemente. Além disso, os resultados da média, do MSE2 e do RMSSE indicam em média subestimação.

Para o gráfico Q-Q (Figura B37), os erros normalizados apresentaram desvios significativos nos extremos em relação a reta cinza (distribuição teórica normal), principalmente para a subestimação nos extremos baixos. Com exceção deste contraponto, os erros normalizados médios mostraram-se com baixos desvios em relação a reta cinza, isto é, indicação de aspectos pertencentes a uma distribuição normal.

Tabela B15 - Métricas de desempenho da Validação Cruzada para o evento de 2010 em Palmares no cenário C

Média dos Erros (ME)	-0,0116
Variância dos Erros (Var)	0,1950
Raiz Quadrada Média dos Quadrados dos Erros (RMSE)	0,4385
Média dos Erros Padronizados (ASE)	0,4298
Média dos Erros Normalizados (MSE2)	-0,0043
Raiz Quadrada Média dos Quadrados dos Erros Normalizados (RMSSE)	1,1147

Fonte: Autor (2021)

Figura B37 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2010 em Palmares no cenário C

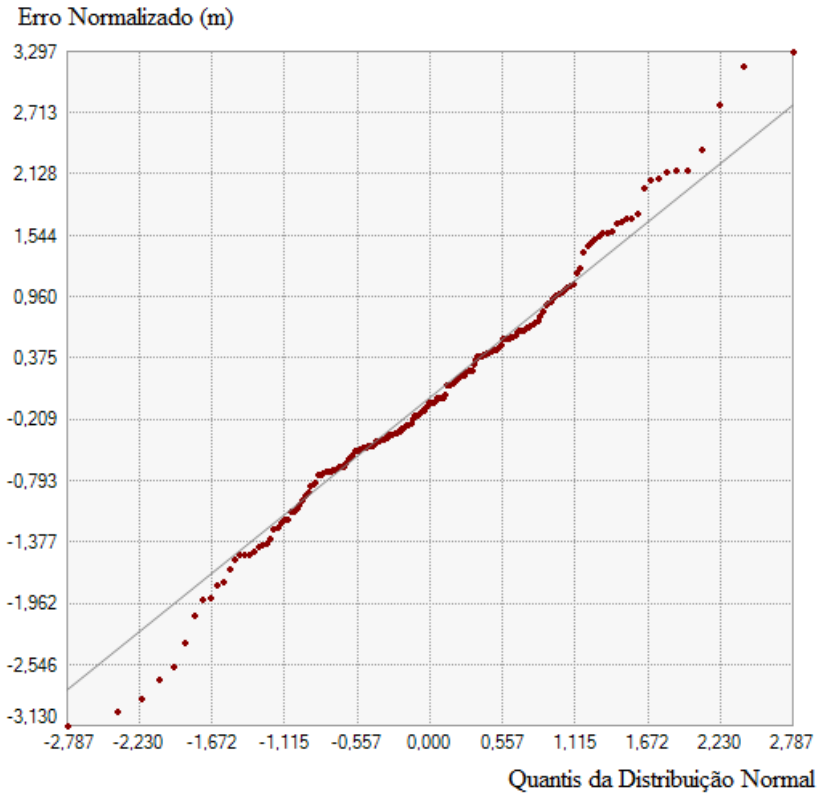

Fonte: Autor (2021)

Para a construção do semivariograma empírico (Figura B38) do cenário D através da busca por pares amostrais, recorreu-se aos parâmetros da Tabela B16. Destaca-se que as semivariâncias plotadas na Figura B.38 exibem a variabilidade para todas as direções (modelo isotrópico).

O ajuste das curvas teóricas sobre as semivariâncias empíricas para o caso anisotrópico ocorreu por meio da geração de 16 direções, variando os ângulos em 11,25º a partir do 0º(norte) até 180º(sul). As curvas teóricas em azul (Figura B38), representadas pelos parâmetros da Tabela B17, apontaram um modelo gaussiano com anisotropia geométrica, ou seja, quando o patamar é igual em todas as direções. O eixo de maior continuidade espacial encontrado foi o de 143º (curva com menor semivariância) e o de menor correlação espacial 53º (curva com maior variabilidade). Além de apontar a menor variância, o eixo de maior dependência espacial apresenta maior alcance (745 m).

Com diferentes alcances, o semivariograma teórico é representado por uma elipse como pode ser visto na superfície de semivariogramas (Figura B39), a elipse concentra as células de menor variabilidade espacial, alcançando maiores distâncias na direção de 143º e evitando *pixels* com média ou alta semivariância. Também nesta figura observa-se o cone de procura dos

pares amostrais para a direção de maior continuidade espacial (143^0) com 22,5º de tolerância angular e 14 lags de 70 m com largura de banda igual a 210 m.

Deslocando o cone de procura dos pares para outras direções no sentido anti-horário, as semivariâncias aumentam, gerando novas curvas até à direção de 53º que representou o eixo de menor dependência espacial (ortogonal ao eixo de maior correlação). Destaca-se a amplitude entre os semivariogramas teóricos de maior e de menor correlação, apontando assim a coerente anisotropia dos dados.

Tabela B16 - Construção do semivariograma empírico para os resíduos do evento de 2010 em Palmares no cenário D

Parâmetros	Lag	Número de Lags	Modelo
Semivariograma Empírico	70	14	Anisotrópico

Fonte: Autor (2021)

Figura B38 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário D

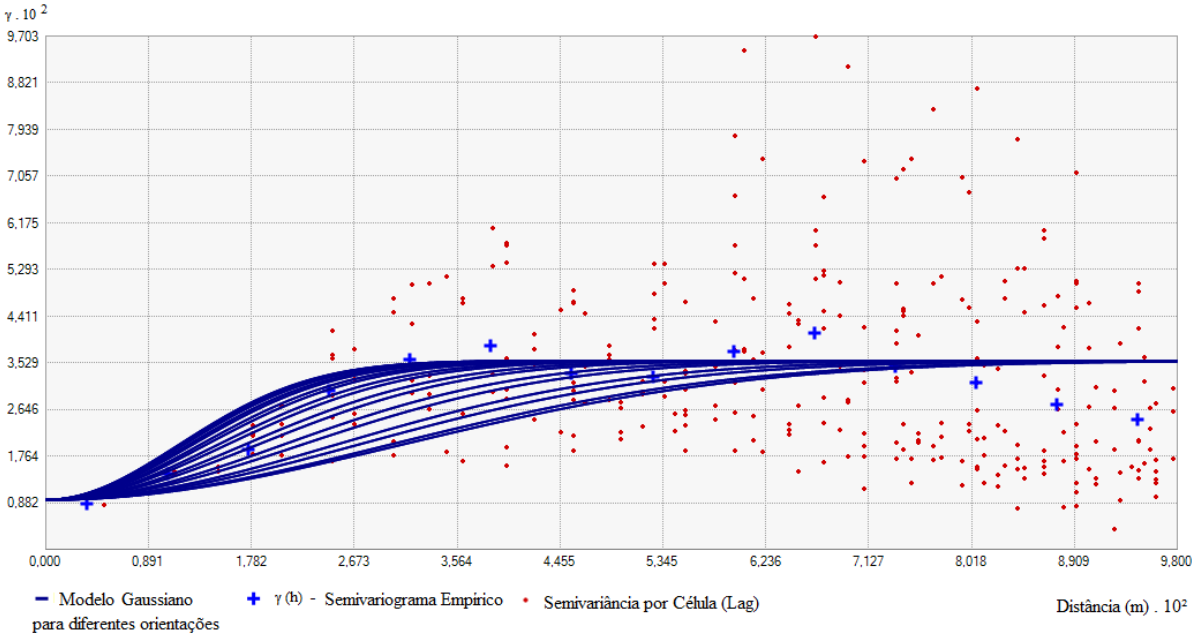

Fonte: Autor (2021)

Tabela B17 - Parâmetros do semivariograma teórico para os resíduos do evento de 2010 em Palmares no cenário D

Parâmetros	Modelo	Efeito Pepita	Patamar	Direção*	Maior Alcance	Menor Alcance
Semivariograma Teórico	Gaussiano	67,6854	356,6643	143º	745,4443	282,1730

*Direção de maior continuidade espacial. O ângulo de menor correlação encontra-se a 90º, ou seja, 53º.

Fonte: Autor (2021)

Figura B39 - Mapa de semivariograma e a janela de busca por pares amostrais para os resíduos do evento de 2010 em Palmares no cenário D

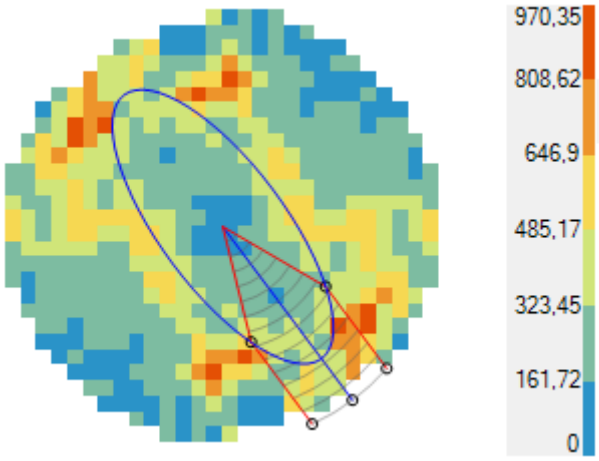

Fonte: Autor (2021)

Os semivariogramas empíricos e teóricos para a direção de maior (Figura B40) e de menor (Figura B41) dependência espacial foram consolidados por meio do ajuste das semivariâncias por célula (em vermelho). Por se tratar de um modelo anisotrópico geométrico, o ajuste da curva depende somente do alcance. Dessa forma, quanto menor a distância de correlação espacial maior a inclinação da curva, captando semivariâncias altas. O contrário promoverá menor variabilidade, ou seja, modelo teórico de maior continuidade espacial.

Outros aspectos verificados foram a regularidade das semivariâncias para o eixo de maior dependência espacial, onde houve um crescimento da variância de modo brando, enquanto a variabilidade no sentido de menor correlação cresceu com maior rapidez, resultando em certa irregularidade. Além disso, como era esperado, os pontos de semivariâncias foram melhor ajustados para a direção de 143º, visto que esta direção foi a mais importante para o semivariograma por apresentar maior continuidade espacial.

Figura B40 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário D

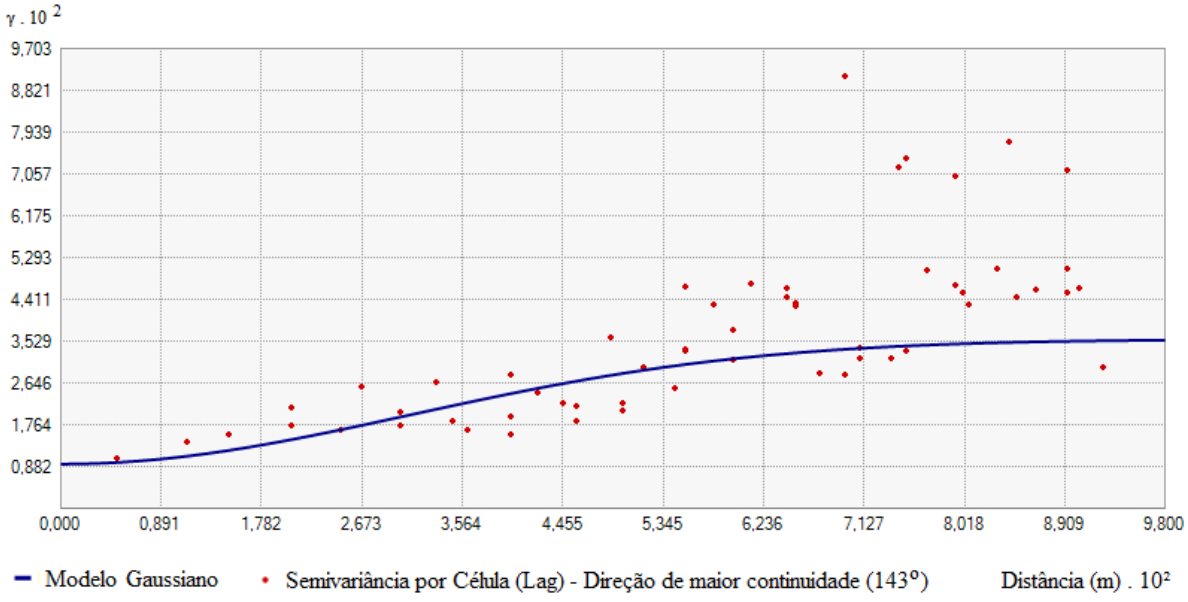

Fonte: Autor (2021)

Figura B41 - Semivariograma empírico e teórico para os resíduos do evento de 2010 em Palmares para o cenário D

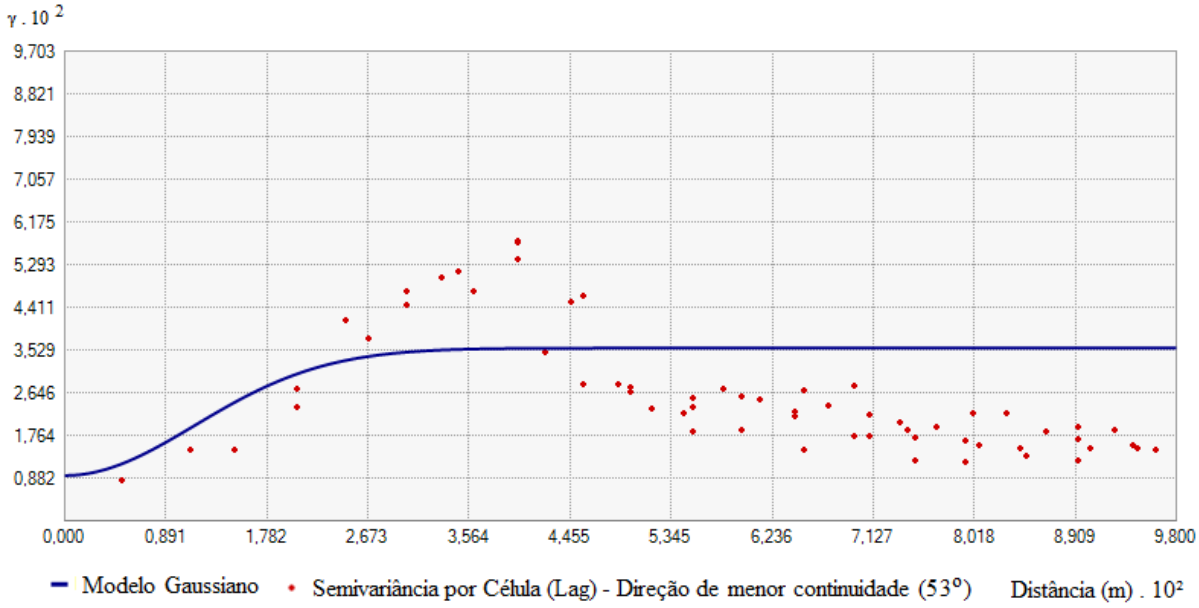

Fonte: Autor (2021)

A VC no cenário D apresentou os seguintes pormenores: o gráfico de dispersão (Figura B42) apresentou bom ajuste do modelo em relação ao erro de estimação das profundidades transformadas, indicando semelhanças com o cenário C; visualmente a distribuição dos erros (Figura B43) não apontou aspectos evidentes para uma distribuição normal (ao contrário do cenário C), além de ter indicado leve assimetria positiva; as métricas de desempenho (Tabela B18) foram próximas para os dois cenários, tendo o cenário D assinalado pequenas

desvantagens. Por outro lado, os parâmetros de comparação de modelos, o RMSE e o RMSSE, no cenário D destacaram a incerteza do erro da variância de krigagem (erro padronizado), enquanto no cenário C apontou-se menor incerteza para o erro de previsão das profundidades transformadas. Ademais, a consistência, diferença entre o RMSE e o ASE, entre os modelos de predição das incertezas foi mais ajustada para o cenário C e o gráfico Q-Q (Figura B

44) para o erro normalizado indicou dados mais próximos à distribuição normal com menores desvios em relação à reta de cor cinza 1:1.

Apesar dos apontamentos realizados no parágrafo anterior apresentarem indícios favoráveis ao cenário C, escolher o modelo somente com os resultados da VC pode ser uma decisão precipitada. Isso porque as análises referentes ao processo metodológico ocorrem sobre pontos conhecidos, desprezando todo o domínio. Assim, torna-se necessária a visualização e a interpretação de desempenhos estatísticos sobre as inferências (profundidades de inundação e confiança) nas regiões não amostradas, em busca de resultados mais precisos. Por estes motivos, os cenários C e D foram utilizados para a construção do mapa de inundação e o de incerteza, vistos na próxima sessão.

Figura B42 - Gráfico inferido versus medido para a Validação Cruzada do evento de 2010 em Palmares no cenário D

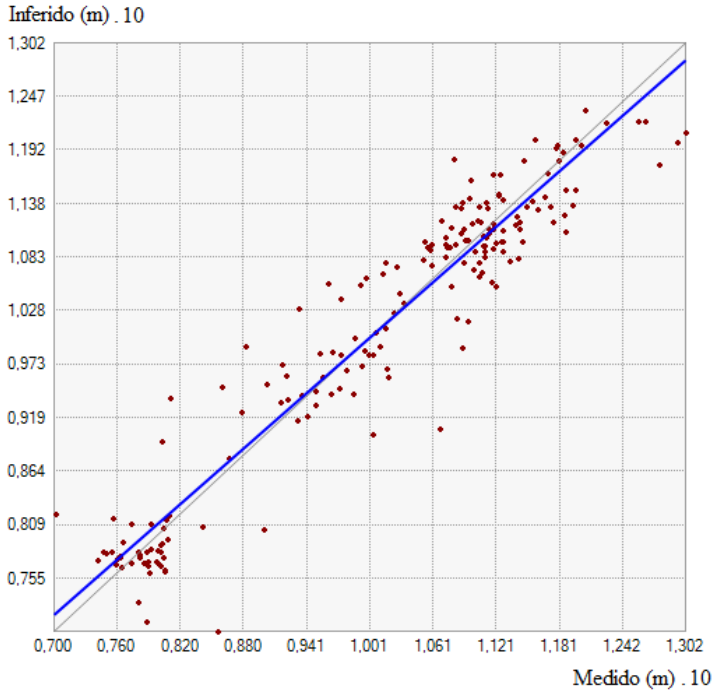

Fonte: Autor (2021)

Figura B43 - Histograma dos erros para a Validação Cruzada do evento de 2010 em Palmares no cenário D

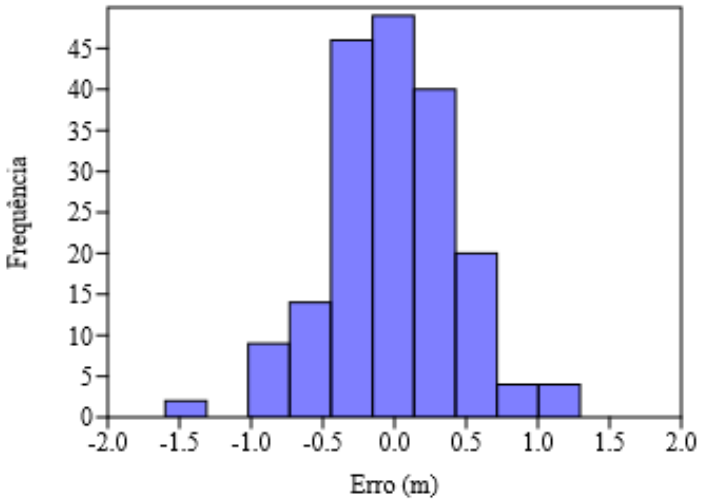

Fonte: Autor (2021)

Tabela B18 - Métricas de desempenho da Validação Cruzada para o evento de 2010 em Palmares no cenário D

Média dos Erros (ME)	-0,0137
Variância dos Erros (Var)	0,2030
Raiz Quadrada Média dos Quadrados dos Erros (RMSE)	0,4496
Média dos Erros Padronizados (ASE)	0,4812
Média dos Erros Normalizados (MSE2)	-0,0097
Raiz Quadrada Média dos Quadrados dos Erros Normalizados (RMSSE)	1,0125

Fonte: Autor (2021)

Figura B44 - Gráfico Q-Q para o erro normalizado da Validação Cruzada do evento de 2010 em Palmares no cenário D

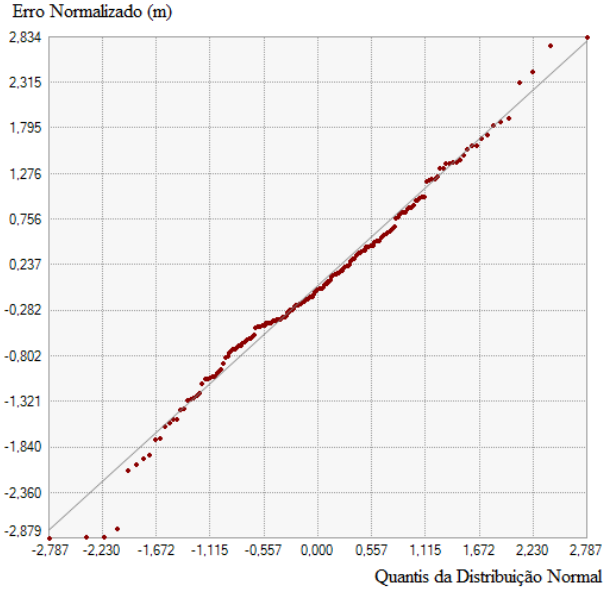

Fonte: Autor (2021)