

UNIVERSIDADE FEDERAL DE SANTA MARIA
COLÉGIO POLITÉCNICO DA UFSM
CURSO DE ESPECIALIZAÇÃO EM GEOMÁTICA

Pablo Francisco Benitez Baratto

**ANÁLISE DE INTERPOLADORES ESPACIAIS PARA O
MAPEAMENTO DE CHUVAS MENSAIS NA BACIA HIDROGRÁFICA
DO RIO IJUÍ**

Santa Maria, RS
2022

Pablo Francisco Benitez Baratto

**ANÁLISE DE INTERPOLADORES ESPACIAIS PARA O MAPEAMENTO DE CHUVAS
MENSAIS NA BACIA HIDROGRÁFICA DO RIO IJUÍ**

Monografia apresentada ao Curso de Especialização em Geomática da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Especialista em Geomática**.

Orientadora: Prof^ª. Dr^ª. Ana Caroline Paim Benedetti

Santa Maria, RS
2022

Pablo Francisco Benitez Baratto

**ANÁLISE DE INTERPOLADORES ESPACIAIS PARA O MAPEAMENTO DE CHUVAS
MENSAIS NA BACIA HIDROGRÁFICA DO RIO IJUÍ**

Monografia apresentada ao Curso de Especialização em Geomática da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Especialista em Geomática**.

Aprovado em 17 de agosto de 2022:

Prof^a. Dr^a. Ana Caroline Paim Benedetti (UFSM)
(Presidente/Orientador)

Prof. Dr. Alessandro Carvalho Miola (UFSM)

Prof. Dr. Diogo Belmonte Lippert (UFSM)

DEDICATÓRIA

Dedico esta monografia ao meu pai, que por infortúnio do destino não se encontra mais presente neste plano. Tudo começou com você, que estudou na UFSM e me inspirou a sempre estudar. Me inspirou a ser a pessoa que sou hoje, alguém em constante melhoria, alguém melhor. Me mostrou que o mais importante na vida é a família e, que é o conhecimento é aquilo nos permite ir além.

AGRADECIMENTOS

A concretização deste trabalho ocorreu com auxílio e apoio de algumas pessoas.

Agradeço imensamente a compreensão da minha orientadora professora Ana Caroline Paim Benedetti, por ter aceitado ser minha orientadora e sempre me auxiliado com todas as burocracias pertinentes.

Agradeço os órgãos governamentais, como Instituto Brasileiro de Geografia e Estatística (IBGE), Agência Nacional de Águas e Saneamento Básico (ANA), Instituto Nacional de Meteorologia (INMET), Fundação Estadual de Proteção Ambiental Henrique Luis Roessler (FEPAM), *University of California*, Santa Barbara (US SANTA BARBARA) e ao Instituto Nacional de Pesquisas Espaciais (INPE) pela disponibilidade online de informações espaciais gratuitas, as quais permitiram que fosse executado este projeto de pesquisa, resultando em minha monografia de defesa para obtenção do título de Especialista em Geomática.

Agradeço a minha esposa e aos meus pais, por tudo que fizeram até aqui, permitindo que eu me tornasse quem sou hoje, acreditando em mim, sempre.

Por fim, agradeço a Universidade Federal de Santa Maria, em especial ao Colégio Politécnico, por me proporcionar a oportunidade de realizar um excelente curso de pós-graduação, de qualidade e gratuito.

“Ninguém que já deu o seu melhor se arrependeu.”

George Halas

RESUMO

ANÁLISE DE INTERPOLADORES ESPACIAIS PARA O MAPEAMENTO DE CHUVAS MENSAIS NA BACIA HIDROGRÁFICA DO RIO IJUÍ

AUTOR: Pablo Francisco Benitez Baratto
ORIENTADOR: Ana Caroline Paim Benedetti

Nas últimas décadas as pesquisas relacionadas à escassez hídrica aumentaram significativamente, principalmente devido às mudanças climáticas, que preocupa grande parte da comunidade científica. Nesse contexto, o estudo das variáveis que fazem parte do ciclo hidrológico torna-se cada vez mais pertinente. Todavia, percebe-se uma carência de dados hidrológicos confiáveis, uma vez que existe um grande número de dados falhos e poucas estações de medição *in loco*. Por isso, é importante que formas de contornar a escassez de dados hidrológicos sejam amplamente exploradas pela comunidade científica. Nesse sentido, o uso de interpolação espacial permite contornar o problema da continuidade espacial dos dados hidrológicos. Para uma gestão mais eficiente de informações, a avaliação de diferentes interpoladores permite que o melhor interpolador espacial seja eleito, para espacialização de um dado fenômeno, neste estudo, a precipitação. Interpolações espaciais podem ser executadas em *softwares* de Sistemas de Informações Geográficas (SIG) como o ArcGIS e o QGIS. Por isso, além de eleger qual é a melhor técnica de interpolação espacial de precipitação pluvial, determinar qual dos dois softwares SIG mais utilizados no mundo possui o melhor desempenho também é relevante. Diante do exposto, este trabalho consistiu em espacializar chuvas acumuladas mensais sobre o perímetro da bacia hidrográfica do rio Ijuí, localizada nos biomas Pampa e Mata Atlântica, no estado do Rio Grande do Sul. As interpolações foram realizadas para os meses de janeiro e agosto dos anos de 1990, 2000, 2010 e 2020. Utilizando oito interpoladores espaciais, quatro processos foram realizados no QGIS, sendo estes: Distância Angular Ponderada (ADW), Inverso da Distância Ponderada (IDW), Rede de Triângulos Irregulares (TIN) e Krigagem Ordinária (OK) com variograma exponencial; os outros quatro processos foram realizados no ArcGIS, sendo estes os métodos do Vizinho Natural (Nat), Spline Cúbica (Spline), *Topo to Raster* (Top) e Tendência (TREND). A fim de validar a eficiência dos diferentes interpoladores, os resultados das espacializações foram comparados com as informações da base de dados *Climate Hazards group Infrared Precipitation with Stations* (CHIRPS), que possui alta resolução espacial, se tratando de bases de dados globais de precipitação. Essa comparação foi realizada por meio do Índice de concordância de Willmott (d), Raiz do erro médio quadrático (REMQ), Erro absoluto médio (EAM) e o Erro Percentual absoluto médio (EPAM). O trabalho concluiu que o melhor interpolador espacial foi o IDW, que está presente em ambos os *softwares*. Por fim, a base de dados constituída de mapas espacializados de precipitação pluvial acumulada mensal, em formato raster foi disponibilizada via sítio específico, com resolução espacial de 0,25km².

Palavras-chave: Espacialização. Precipitação. Mudanças climáticas.

ABSTRACT

ANALYSIS OF SPATIAL INTERPOLATORS FOR MAPPING MONTHLY RAIN IN THE IJUÍ RIVER HYDROGRAPHIC BASIN

AUTHOR: Pablo Francisco Benitez Baratto

ADVISOR: Ana Caroline Paim Benedetti

In recent decades, research related to water scarcity has increased significantly, mainly due to climate change, which worries a large part of the scientific community. In this context, the control and study of the variables that are part of the hydrological cycle becomes increasingly relevant. However, there is a lack of reliable hydrological data, since there is a large number of flawed data and few on-site measurement stations. Therefore, it is important that ways to circumvent the scarcity of hydrological data are widely explored. In this sense, the use of spatial interpolation makes it possible to circumvent the problem of spatial continuity of hydrological data. For a more efficient management of information, the evaluation of different interpolators allows the best spatial interpolator to be chosen, for spatialization of a given phenomenon, in this work, precipitation. Spatial interpolations can be performed in geographic information systems software such as ArcGIS and QGIS. Therefore, in addition to choosing the best technique for spatial interpolation of rainfall, determining which of the two most used GIS software in the world has the best performance is also relevant. Therefore, this work consisted of spatializing accumulated monthly rainfall over the perimeter of the Ijuí river basin, located in the Pampa and Atlantic Forest biomes, in the state of Rio Grande do Sul. The interpolations were carried out for the months of January and August of the years 1990, 2000, 2010 and 2020. Using eight spatial interpolators, four processes were carried out in QGIS, these being the Weighted Angular Distance (ADW), inverse of the weighted distance (IDW), Irregular Triangle Network (TIN) and Ordinary Kriging (OK) with exponential variogram; the other four processes were performed in ArcGIS, these being the Natural Neighbor (Nat), Cubic Spline (Spline), Top to Raster (Top) and Trend (TREND) methods. In order to validate the efficiency of the different interpolators, the spatialization results were compared with information from the Climate Hazards group Infrared Precipitation with Stations (CHIRPS) database, which has high spatial resolution, in the case of global precipitation databases. This comparison was performed using the Willmott Agreement Index (d), Root Mean Square Error (REMQ), Mean Absolute Error (AME) and Mean Absolute Percentage Error (EPAM). The work concluded that the best spatial interpolator was IDW, which is present in both software. Finally, data consisting of spatial maps of the location of monthly accumulated rainfall data, in a specific format, with a spatial resolution of 0.25km².

Keywords: Spatialization. Precipitation. Climate changes.

LISTA DE FIGURAS

Figura 1 – Ciclo Hidrológico.....	18
Figura 2 – Exemplo de Interpolação espacial (especialização).....	21
Figura 3 – Países com mais publicações na área de interpolação espacial de precipitação.	23
Figura 4 – Mapa com dados de precipitação mensal oriundos do CHIRPS, para o mês de janeiro de 2020	24
Figura 5 – Mapa de localização da bacia hidrográfica do rio Ijuí	26
Figura 6 – Mapa de estações pluviométricas e meteorológicas cobrindo a região da bacia do rio Ijuí.	29
Figura 7 – Fluxograma do trabalho de espacialização	30
Figura 8 – Exemplo do interpolador TIN	34
Figura 9 – Criação de nós do interpolador Nat.....	35
Figura 10 – Exemplo do método de espacialização Spline	37
Figura 11 – Exemplo do interpolador <i>Topo to Raster</i>	37
Figura 12 – Exemplo do interpolador Superfície de Tendência (Trend)	39
Figura 13 – Percentual dos meses em que cada interpolador apresentou o melhor desempenho	40
Figura 14 – Variação dos valores médios mensais do índice d em todos os anos.....	41
Figura 15 – Variação dos valores médios mensais do REMQ em todos os anos	41
Figura 16 – Variação dos valores médios mensais de EAM em todos os anos	42
Figura 17 – Variação dos valores médios mensais de EPAM em todos os anos	42
Figura 18 – Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em janeiro de 1990	44
Figura 19 – Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em janeiro de 2020.	45
Figura 20 – Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em agosto de 1990	46
Figura 21 – Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em agosto de 2020.	47
Figura 22 – Espacialização de Precipitação mensal de janeiro de 1990 (verão).....	49
Figura 23 – Espacialização de Precipitação mensal de janeiro de 2020 (verão).	50
Figura 24 – Espacialização de Precipitação mensal de agosto de 1990 (inverno)	51
Figura 25 – Espacialização de Precipitação mensal de agosto de 2020 (inverno)	52

LISTA DE TABELAS

Tabela 1 - Estações Pluviométricas da ANA e INMET.....	28
Tabela 2 - Centroide dos municípios pertencentes à Bacia do Rio Ijuí.....	31
Tabela 3 - Resultados estatísticos médios finais.....	40

LISTA DE ABREVIATURAS E SIGLAS

ADW - Distância angular ponderada

ANA - Agência Nacional de Águas e Saneamento Básico

BDE - Bases de dados espaciais

BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa

Cfa – Clima subtropical

CHIRPS - *Climate Hazards group Infrared Precipitation with Stations*

d - Índice de concordância de Willmott

EAM – Erro Absoluto médio

EPAM – Erro percentual absoluto médio

FEPAM - Fundação Estadual de Proteção Ambiental Henrique Luis Roessler

GIS – Sistema de informações geográficas

IBGE - Instituto Brasileiro de Geografia e Estatística

IDW - Inverso da distância ponderada

INMET – Instituto Nacional de Meteorologia

INPE - Instituto Nacional de Pesquisas Espaciais

mm - milímetros

MMA – Ministério do Meio Ambiente

Nat - Vizinho natural

OK – Krigagem Ordinária

RBF - Funções de base radial (RBF)

REMQ - Raíz do Erro médio quadrático

SEMARS - Secretaria do Meio Ambiente e Infraestrutura do Rio Grande do Sul

SGDB's – Sistemas Gerenciadores de Bancos de Dados

SIRGAS 2000 - Sistema de Referência Geocêntrico para as Américas

Spline - Curvatura Mínima

TIN - Rede de triângulos irregulares

Top – *Topo to Raster*

TREND - Superfície de Tendência

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	16
2.1	OBJETIVO GERAL.....	16
2.2	OBJETIVOS ESPECÍFICOS	16
3	FUNDAMENTAÇÃO TEÓRICA	17
3.1	MUDANÇAS CLIMÁTICAS.....	17
3.2	CICLO HIDROLÓGICO	17
3.2.1.	Precipitação	18
3.3	GEOPROCESSAMENTO E DADOS ESPACIAIS	20
3.3.1	Espacialização	21
3.3.2	Base de dados espaciais de Precipitação	23
4	METODOLOGIA	25
4.1	ÁREA DE ESTUDO	25
4.2	OBTENÇÃO DE DADOS	27
4.3	ANÁLISE DOS INTERPOLADORES ESPACIAIS.....	30
4.3.1	Métodos de interpolação espacial utilizados no QGIS	32
4.3.1.1	Inverso da Distância Ponderada (IDW).....	32
4.3.1.2	Distância Angular Ponderada (ADW).....	32
4.3.1.3	Krigagem Ordinária (OK).....	33
4.3.1.4	Rede de Triângulos Irregulares (TIN)	34
4.3.2	Métodos de interpolação espacial utilizados no ArcGIS	35
4.3.2.1	Vizinhos naturais (Nat).....	35
4.3.2.2	Curvatura Mínima (Spline)	36
4.3.2.3	Topo to Raster (TOP)	37
4.3.2.4	Superfície de Tendência (TREND)	38
4.4	DISPONIBILIDADE DOS DADOS	39
5	RESULTADOS E DISCUSSÕES	40
5.1	RESULTADOS.....	40
5.2	DISCUSSÕES	53
6	CONCLUSÕES	58
	REFERÊNCIAS	59

1 INTRODUÇÃO

A escassez hídrica é um tema que vem ganhando notoriedade no meio científico nas últimas décadas (MANCOSU et al., 2015; GOSLING & ARNELL, 2016; DAMKJAER & TAYLOR, 2017; ROSA et al., 2020). Principalmente pelos baixos índices pluviométricos durante os períodos de temperaturas mais elevadas (MARENGO et al., 2015).

A fim de ter-se um controle maior da água, que é um recurso natural indispensável para a o desenvolvimento sustentável da vida (Mekonnen & Hoekstra, 2016), torna-se cada vez mais pertinente o emprego de dados hidrológicos confiáveis (Schneider et al., 2016; Westerberg et al., 2016), que estejam, preferencialmente disponíveis livremente para uso e avaliação de tendências de extremos climáticos (Bressiani et al., 2015), devido à capacidade destes extremos climáticos impactarem a disponibilidade hídrica para agricultura (STEDUTO et al., 2009; XAVIER et al., 2015). Por isso, é grande a preocupação quanto à confiabilidade dos dados hidrológicos, tanto na gestão de água urbana quanto rural (YU & COULTHARD, 2015; TUO et al., 2016).

As mudanças climáticas possuem influência direta nas variáveis hidrológicas (Jehanzaib et al., 2019), que por sua vez, possuem extrema importância no estudo e modelagem de distribuição da água na superfície terrestre e sua dinâmica (PIANOSI & WAGENER, 2016; VIANA et al., 2018).

Como é de conhecimento comum, o principal meio pelo qual a água atinge a superfície é pela precipitação (Fraga et al, 2016) - definida como a liberação da água da atmosfera até a superfície do planeta, podendo ocorrer na forma de chuva, neve ou granizo (ARAÚJO et al., 2008). Embora os registros de precipitação sejam relativamente fáceis de medir e, são usados para estudos de tendências e variabilidades climáticas, gerenciamento dos recursos hídricos e projeção de eventos extremos (Jiang et al., 2012; Liu et al., 2017; Sun et al., 2017), encontrar séries históricas de chuvas sem falhas, com precisão e confiabilidade, é muito raro (OLIVEIRA et al., 2010; CALDEIRA et al., 2015; MELLO et al., 2017).

Mesmo que as principais e mais confiáveis fontes de dados hidrológicos (precipitação) são aquelas medidas diretamente em pluviômetros e estações meteorológicas (Limberger et al., 2018; Silva et al., 2019), no Brasil, existem grandes áreas sem pluviômetros ou estações meteorológicas (MORAES et al., 2015; DUARTE & SILVA FILHO, 2019). Além disso, a qualidade dos dados muitas vezes é ruim, com grande número de falhas (XAVIER et al., 2015).

Em contrapartida, a demanda de informações espaciais no Brasil é grande (Amaral et

al., 2019; Sena et al., 2020), principalmente de variáveis climáticas como a precipitação (SOBRAL et al., 2018; MEDEIROS et al., 2022; PESSI et al., 2019). Ademais, a precipitação é um elemento meteorológico de difícil modelagem (Pinheiro et al., 2020), pois apresenta alta heterogeneidade espacial e de magnitude, quando observada por um determinado período (SILVA, 2017, HE et al., 2020).

Devido à precipitação ser um dos principais elementos constituintes do Ciclo Hidrológico (Carvalho; Mello & Silva, 2007), seu estudo pode viabilizar ações capazes de atenuar as consequências causadas por eventos extremos de chuva (CALDANA et al., 2020).

Nesse sentido, devido ao pequeno número de estações de medição de chuvas *in loco* (Moraes et al., 2015) e, ausência de dados presentes nas séries históricas (Mello et al., 2017), uma alternativa que vem sendo amplamente utilizada é espacialização destas informações pontuais (Yang et al., 2015; Chen et al., 2017; Silva et al., 2018), a fim de criar uma superfície espacial, contendo informações geográficas e de precipitação. Essa superfície possui formato matricial, ou seja, torna contínuo aquilo que estava disponível pontualmente (em formato vetorial) (QGIS, 2022).

Grande parte das interpolações são realizadas por meio de scripts/códigos em diversas *Integrated Development Environment* (IDE) (Kulmatov et al., 2021), entretanto, elas também são realizadas em *softwares* de *Geographic Information System* (GIS), como o ArcGIS e QGIS (FERREIRA FILHO et al., 2019; FUNG et al., 2022).

Sabe-se que o ArcGIS é um *software* proprietário pertencente à empresa norte americana ESRI e, conseqüentemente, sua licença não é gratuita, exceto licenças educacionais e períodos de teste (CRUZ et al., 2017). Em contrapartida, o QGIS é um projeto oficial da *Open Source Geospatial Foundation* (OSGeo), ou seja, é um *software* totalmente gratuito e não possui licenças comerciais (DUARTE et al., 2021).

Diante disto, comparar todos os interpoladores presentes nos dois *softwares* de GIS mais utilizados no mundo, para avaliar qual é o melhor na espacialização de chuvas, é uma tarefa promissora.

2 OBJETIVOS

2.1 OBJETIVO GERAL

Este trabalho tem como objetivo geral a espacialização de chuvas mensais de janeiro e agosto, nos anos de 1990, 2000, 2010 e 2020, na bacia hidrográfica do Rio Ijuí, situada entre os biomas Pampa e Mata Atlântica, no estado do Rio Grande do Sul, Brasil.

2.2 OBJETIVOS ESPECÍFICOS

1. Criar mapas de chuvas mensais de oito interpoladores espaciais, com resolução espacial de 0,25km² (ou 250.000m²).
2. Disponibilizar online e gratuitamente os mapas de chuvas mensais espacializados.
3. Comparar os resultados obtidos pelas espacializações com uma base de dados composta por informações oriundas de Sensoriamento Remoto em conjunto com estações *in situ*.
4. Eleger o melhor interpolador espacial para espacialização de chuvas mensais na área em estudo, utilizando quatro indicadores estatísticos.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 MUDANÇAS CLIMÁTICAS

As mudanças climáticas já são uma realidade, e estão afetando a biodiversidade em todo o mundo, modificando o habitat natural de animais e plantas (XU et al., 2009; THOMAS et al., 2004). Além disso, a instabilidade climática pode colocar em risco à saúde humana, devido ao aumento de exposição a temperaturas extremas (HAYES et al., 2018). Entretanto, evidências dos impactos diretos do clima em seres humanos são limitadas (Gasparrini et al., 2017), devido à problemas inerentes à modelos que tem dificuldade em prever relações epidemiológicas complexas, pois ocorrem de forma imprevisível em diferentes populações e climas (MARTENS, 1998).

De modo geral, o estudo das mudanças climáticas recentes complementa as previsões de longo prazo, que apontam para as populações que já estão em maior risco. Desde a década de 1970, a temperatura da superfície global aqueceu uma média de 0,16 - 0,18 °C por década (IPCC, 2007). Já no intervalo entre 1975 - 2005, a temperatura média global da superfície aumentou um total de 0,6 °C (KAZMI et al., 2022). Além disso, neste mesmo período houve um aumento mais significativo na temperatura média do Himalaia, cerca de 1,5°C, que é superior à média global acumulada durante o século XX (0,8 °C) (SHRESTHA et al., 2012).

As alterações climáticas são reféns das emissões de gases de efeito estufa que ocorrerem hoje e no futuro, enfatizando a importância de adoção de políticas climáticas, com a finalidade de impedir o contínuo aumento do aquecimento global (MOSS et al., 2010; GASPARRINI et al., 2017).

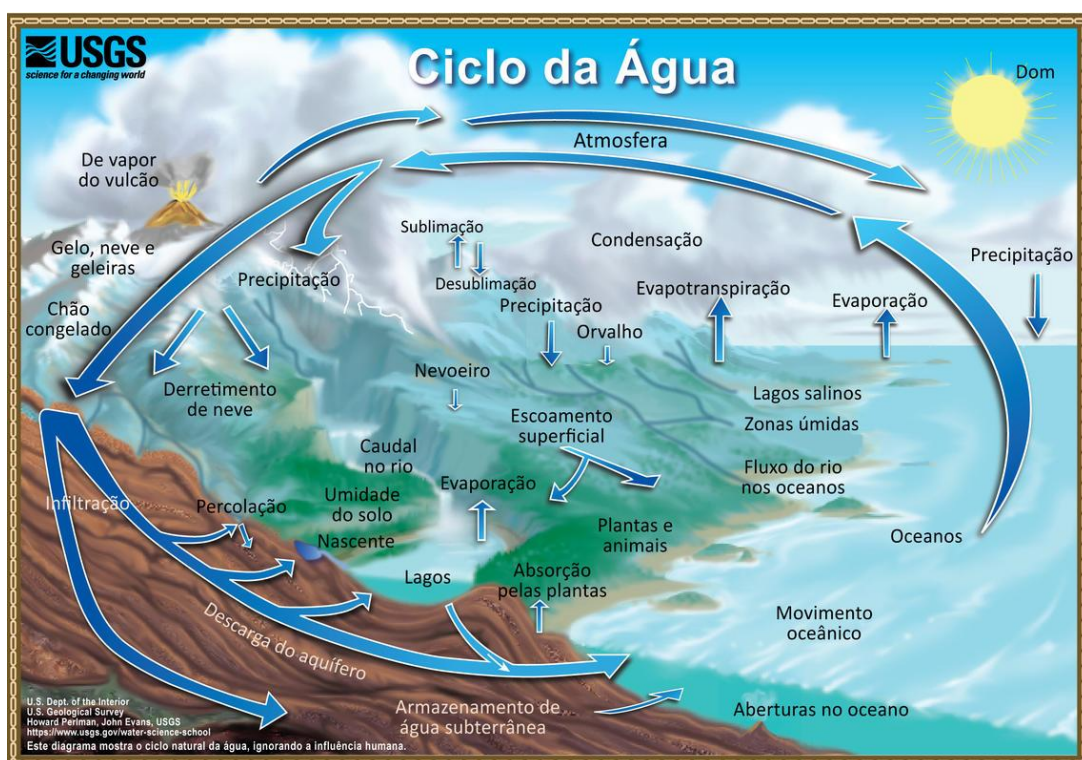
3.2 CICLO HIDROLÓGICO

O ciclo hidrológico também conhecido como “ciclo da água” (Singh et al., 2021), é o sistema normal de reciclagem de água na Terra (Figura 1). Devido à radiação solar, a água evapora, geralmente dos oceanos, lagos, rios etc. (MARSHALL et al., 2013). Ao mesmo tempo, a água também evapora das folhas das plantas através do mecanismo de transpiração (CARVALHO, MELLO & SILVA, 2007). À medida que o vapor sobe na atmosfera, ele é resfriado, condensado e retornado à terra e ao mar como precipitação. A precipitação cai sobre a terra, sendo capaz de moldar a superfície, criando assim correntes de água que resultam em lagos e rios (ROBERTSON et al., 2019). Uma parte da água precipitada infiltra no solo e

desce pelos poros do terreno, formando aquíferos. Finalmente, uma parte da água superficial e subterrânea escoam até o mar. Durante esta viagem, a água é convertida em todas as fases: gasosa, líquida e sólida (MIRANDA et al., 2010). A água sempre muda de estado entre sólido, líquido e gasoso, porém, esses processos podem acontecer em um piscar de olhos ou ao longo de milhões de anos (CHAKRAVARTY & KUMAR, 2019; INGLEZAKIS et al., 2016).

No entanto, o ciclo hidrológico começou a se alterar devido aos efeitos adversos das mudanças climáticas e do aumento das temperaturas globais (SINGH et al., 2021). Os processos que estão envolvidos no ciclo hidrológico são altamente dependentes da temperatura (INGLEZAKIS et al., 2016). O aquecimento do sistema climático nas últimas décadas é uma realidade (Moon et al., 2018), sendo evidenciado por meio de observações de aumentos nas temperaturas médias globais do ar e do oceano, derretimento generalizado de neve e gelo e aumento do nível do mar em todo o mundo (GOLLEDGE, 2021).

Figura 1 – Ciclo Hidrológico.



Fonte: USGS (2019).

3.2.1. Precipitação

A precipitação é entendida como qualquer forma de água proveniente da atmosfera que atinge a superfície terrestre, como, por exemplo, neve, granizo, chuva, orvalho, geada,

etc. O que diferencia as várias formas de precipitação é o estado em que a água se encontra (PAZ, 2004).

Segundo Santos (2002) cada tipo de precipitação pode ser definido da seguinte forma:

- a) Saraiva: é a precipitação sob a forma de pequenas pedras de gelo arredondadas com diâmetro em torno de 5 mm.
- b) Granizo: é a precipitação sob a forma de pedras de gelo, podendo ser de forma arredondada ou irregular, porém com diâmetro superior a 5 mm.
- c) Neve: é a precipitação sob a forma de cristais de gelo que durante a queda coalescem formando blocos de dimensões e formas variadas.
- d) Orvalho: é a condensação do vapor d'água do ar sobre objetos expostos ao ambiente durante a noite, devido a redução da temperatura do ar até o ponto de orvalho.
- e) Geadas: é a formação de cristais de gelo a partir do vapor d'água, de maneira semelhante ao orvalho, porém à temperatura inferior a 0 °C.
- f) Chuvisco, neblina e garoa: são formas de precipitação da água na fase líquida muito fina e de baixa intensidade.
- g) Chuva: é a ocorrência da precipitação na forma líquida com intensidades superiores à anterior.

A chuva propriamente dita, é resultado do processo de transformação do estado físico-químico da água, sendo um dos elementos climáticos obtidos pela atuação dinâmica da atmosfera sobre a superfície. Quanto à origem, as chuvas são classificadas de três de 3 maneiras distintas: frontais, convectivas e orográficas (MARQUES et al., 1999).

As chuvas frontais se formam a partir do contato das superfícies entre massas de ar quentes ou frias (Santos et al., 2018); as convectivas originam-se de nuvens formadas a partir de correntes convectivas (térmicas) que se resfriam adiabaticamente ao se elevarem, resultando em nuvens de grande desenvolvimento vertical (cumuliformes) (Pereira et al., 2007); já as chuvas orográficas ocorrem em regiões montanhosas, onde o relevo força a subida da massa de ar úmida (SANTOS et al., 2018). Essa subida forçada é equivalente ao processo de convecção livre, resultando nos mesmos fenômenos atmosféricos, ou seja, a massa de ar resfria-se adiabaticamente, condensando e precipitando (STEINKE, 2012).

A precipitação pode ser medida por meio de instrumentos chamados pluviômetros ou pluviógrafos (Pereira et al., 2007), estes instrumentos situam-se em postos de medição, de diversas agências governamentais ou privadas, distribuídos pelo país. As observações de

chuvas são realizadas diariamente e os dados enviados aos laboratórios de meteorologia, para sua consistência e disponibilização ao público geral (MOURA et al., 2007).

A disponibilidade de precipitação numa bacia hidrográfica durante o ano é um fator determinante para quantificar, entre outros, a necessidade de irrigação de culturas e o abastecimento de água doméstico e industrial. A determinação da intensidade de precipitação é importante para o controle de inundação e da erosão do solo (BERTONI & TUCCI, 1993).

3.3 GEOPROCESSAMENTO E DADOS ESPACIAIS

O termo “geoprocessamento” pode ser separado em geo (terra – superfície – espaço) e processamento (de informações – informática) (PIROLI, 2010). Em suma, pode ser definido como uma tecnologia ou conjunto de instrumentos necessários para obtenção, manipulação e armazenamento de dados espaciais georreferenciados, com o intuito de transformá-los em informação relevante e de fácil manuseio através de imagens gráficas (XAVIER-DA-SILVA, 2009). Ademais, a utilização dos dados georreferenciados possibilita planejar e monitorar questões ligadas ao espaço físico geográfico através de arquivos digitais contendo mapas, gráficos, tabelas, entre outros (CÂMARA et al., 2001).

Ambientes de geoprocessamento são destinados ao processamento de dados referenciados geograficamente (ou georreferenciados), desde a sua coleta até a geração de saídas na forma de mapas convencionais, relatórios, arquivos digitais etc.; devendo prever recursos para sua estocagem, gerenciamento, manipulação e análise (SPRING, 2022). Nesse contexto, análises geoespaciais são formas de tratar as informações geográficas, dando-as finalidade, por meio de um objetivo (Marques et al., 2018), mas antes disso, é importante conhecer os tipos de formatos de dados espaciais.

Os dados espaciais podem ser divididos em dois formatos: vetoriais e matriciais. As estruturas vetoriais são representadas por pontos, linhas e áreas, já as estruturas matriciais são representadas pelos pixels que constituem uma imagem (FERREIRA, 2006). Existem fenômenos que embora sejam contínuos, são mensurados de forma pontual, como precipitação, temperatura, pressão atmosférica etc. (DINIZ, 2000). Esses fenômenos são definidos como um conjunto de pontos irregularmente distribuídos em um terreno, cuja localização foi gerada por um mecanismo estocástico (CARVALHO & CÂMARA, 2004).

Uma forma de integrar dados espaciais é fazendo uso de técnicas de análise espacial para eventos discretos, associados a ocorrências pontuais (CAMARGO et al., 2004). A fim de gerar superfícies que aproximem o fenômeno estudado à uma forma realista, se faz necessário

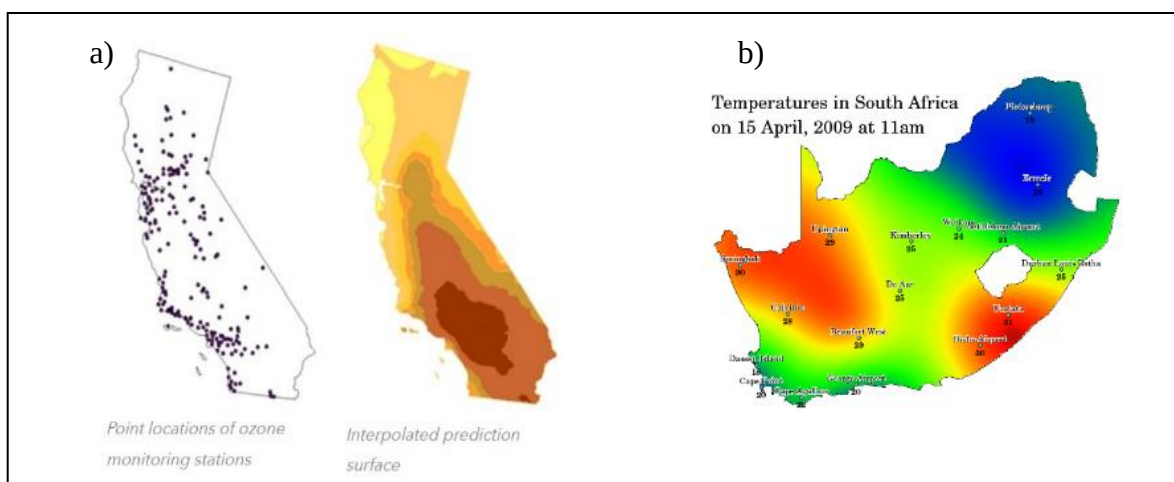
modelar sua variabilidade espacial. Para tal, existem modelos cujo objetivo é transformar informações pontuais em superfícies contínuas, tais modelos são chamados de interpolação espacial (ou espacialização), de forma geral, representam a variável em estudo como uma combinação da variabilidade em diferentes escalas (CARVALHO & CÂMARA, 2004).

Outra forma de integrar dados espaciais, é utilizando dados obtidos diretamente por sensores acoplado em satélites, ou por fotogrametria, por meio de veículos aéreos não tripulados (ZHANG et al., 2021). Estas informações podem constituir bases de dados espaciais, as quais ficam limitadas às resoluções: espacial, espectral, radiométrica e temporal (KHANAL et al., 2017).

3.3.1 Espacialização

A interpolação espacial (espacialização) é um processo que consiste em usar pontos com valores conhecidos para estimar valores em outros pontos desconhecidos (QGIS, 2022), ou seja, a interpolação espacial converte dados de observações pontuais em campos contínuos, produzindo padrões espaciais que podem ser comparados com outras entidades espaciais contínuas (CARVALHO et al., 2012). O raciocínio que está na base da interpolação espacial é que, em média, os valores do atributo tendem a ser similares em locais mais próximos do que em locais mais afastados (Câmara & Medeiros, 1998), conforme está demonstrado na Figura 2.

Figura 2 – Exemplo de Interpolação espacial (espacialização).



Fonte: a) ArcGIS (2022); b) QGIS (2022)

Segundo Marcuzzo et al. (2010) e Teegavarapu et al. (2017), em estudos de precipitação pluviométrica, a interpolação é uma técnica extremamente necessária para áreas com escassez de postos pluviométricos ou regiões com estações irregularmente distribuídas.

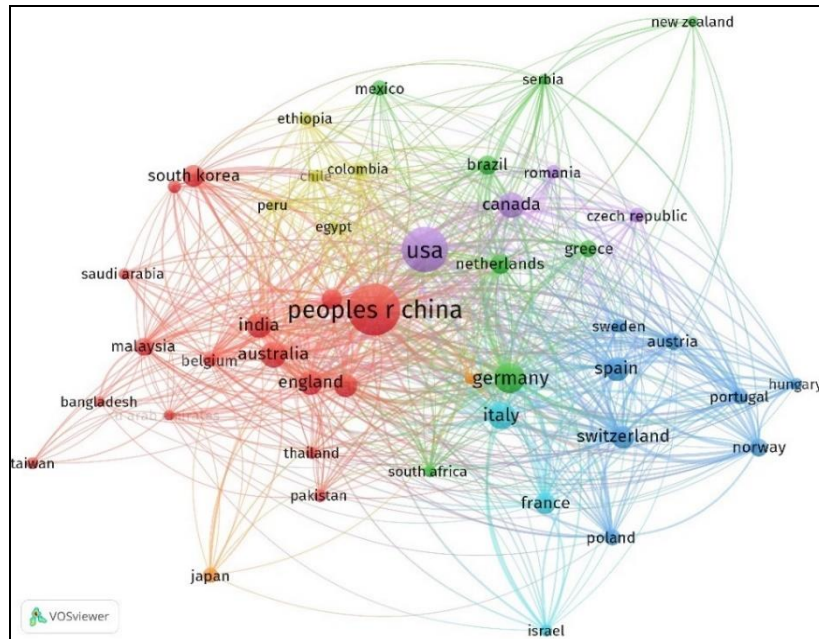
Existem diferenças conceituais e técnicas entre os diferentes tipos de interpoladores. Isto ocorre pois existem interpoladores estocásticos (ou geoestatísticos) e interpoladores determinísticos (MAZZINI et al., 2009; SARAIVA et al., 2017). A Krigagem e Cokrigagem são exemplos de interpoladores geoestatísticos (Longley et al. 2013; Rata et al., 2020), enquanto o Inverso da Distância Ponderada (IDW), Distância Angular Ponderada (ADW), Rede de Triângulos Irregulares (TIN), Vizinho Natural (Nat), Curvatura Mínima (Spline), *Topo To Raster*, Superfície de Tendência (TREND) e Funções de Base Radial (RBF), são todos interpoladores determinísticos (CERÓN et al., 2021; KODONG & FAJAR, 2019; SEKULIC et al., 2020).

Além disso, é válido destacar que cada interpolador é eficaz para ser aplicado a determinado evento estudado em uma determinada área de estudo (FARIAS et al., 2017). Desta forma, é importante verificar se o método de interpolação está adequado ao estudo através da comparação dos dados estimados e os observados bem como da análise da distribuição espacial do evento na superfície interpolada (LANDIM, 2000).

Atualmente os avanços computacionais e o aprimoramento nas técnicas de mapeamento têm nos permitido uma avaliação cada vez mais precisa da qualidade dos atributos mapeados (Anjos et al., 2017), principalmente por meio da detecção de erros associados aos processos representação espacial, como a espacialização de dados. Nesse contexto, a necessidade de implantar em sistemas GIS métodos de interpolação espacial aumentou (LUCAS et al., 2013).

Contudo, o Brasil ainda está atrás de outros países, segundo a base de dados *Web of Science*. Na última década (2013-2022) o Brasil publicou apenas 34 artigos na área de espacialização de precipitação, conforme as redes bibliométricas geradas pelo *software* VOSviewer e, apresentadas na Figura 3.

Figura 3 – Países com mais publicações na área de interpolação espacial de precipitação.



Fonte: Adaptado do VOSviewer (2022).

3.3.2 Base de dados espaciais de Precipitação

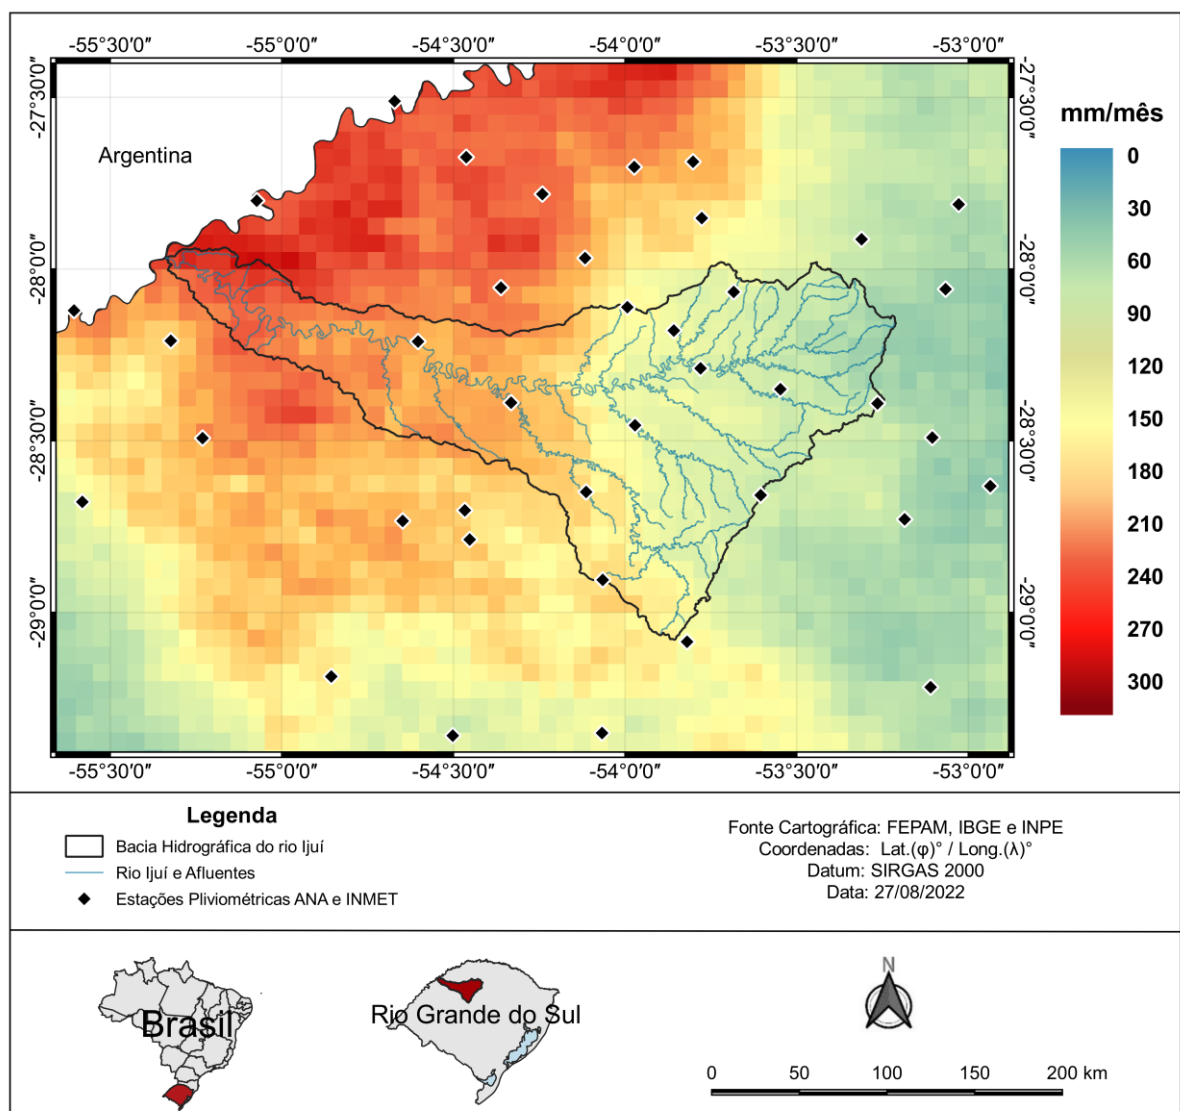
As bases de dados espaciais (BDE), de forma generalizada, são compostas de dados espaciais, que podem ser coletados de diferentes fontes (CORREIA & SÁ, 2010). Em resumo, representa um repositório de informações contendo tanto os dados geográficos quanto os seus modelos de estrutura e organização. Um banco de dados pode ser materializado em diferentes Sistemas Gerenciadores de Bancos de Dados (SGDB's), comerciais ou de domínio público (VINHAS & FERREIRA, 2005).

Nesse contexto, a fim de obter dados de cobertura global, foram criadas bases de dados espaciais de precipitação, ao longo dos anos (TAPIADOR et al., 2011). Dentre elas, uma que ganhou destaque, devido à sua alta resolução espacial (menor tamanho de pixel), foi a *Climate Hazards group Infrared Precipitation with Stations - Precipitação Infravermelha do Centro de Riscos Climáticos (CHIRPS)* (Funk et al., 2015) – oriunda de satélites e em conjunto com estações *in situ*, contempla mapas de precipitação diária, mensal e anual, em formato raster, com cobertura global e, com alta resolução espacial $0,05^\circ \times 0,05^\circ$ (aproximadamente $30,98\text{km}^2$), sendo um dos menores tamanhos de pixels para dados climáticos de precipitação contendo série histórica, com cobertura global (DUAN et al., 2016; GAO et al., 2018).

A base de dados CHIRPS, tem sido revalidada e utilizada em diversos estudos de alto rigor científico nos últimos anos, a exemplo de Katsantos et al. (2015), Dinku et al. (2018), Ngoma et al. (2021), Harrison et al. (2022), Upadhyay et al. (2022).

Na Figura 4 é possível visualizar a variabilidade espacial dos dados de precipitação mensal disponíveis pelo CHIRPS, na área em estudo – a bacia hidrográfica do Rio Ijuí. Os dados matriciais utilizados na Figura 4, oriundos do CHIRPS, podem ser acessados no link <https://data.chc.ucsb.edu/products/CHIRPS-2.0/>.

Figura 4 - Mapa com dados de precipitação mensal oriundos do CHIRPS, para o mês de janeiro de 2020.



Fonte: O autor (2022).

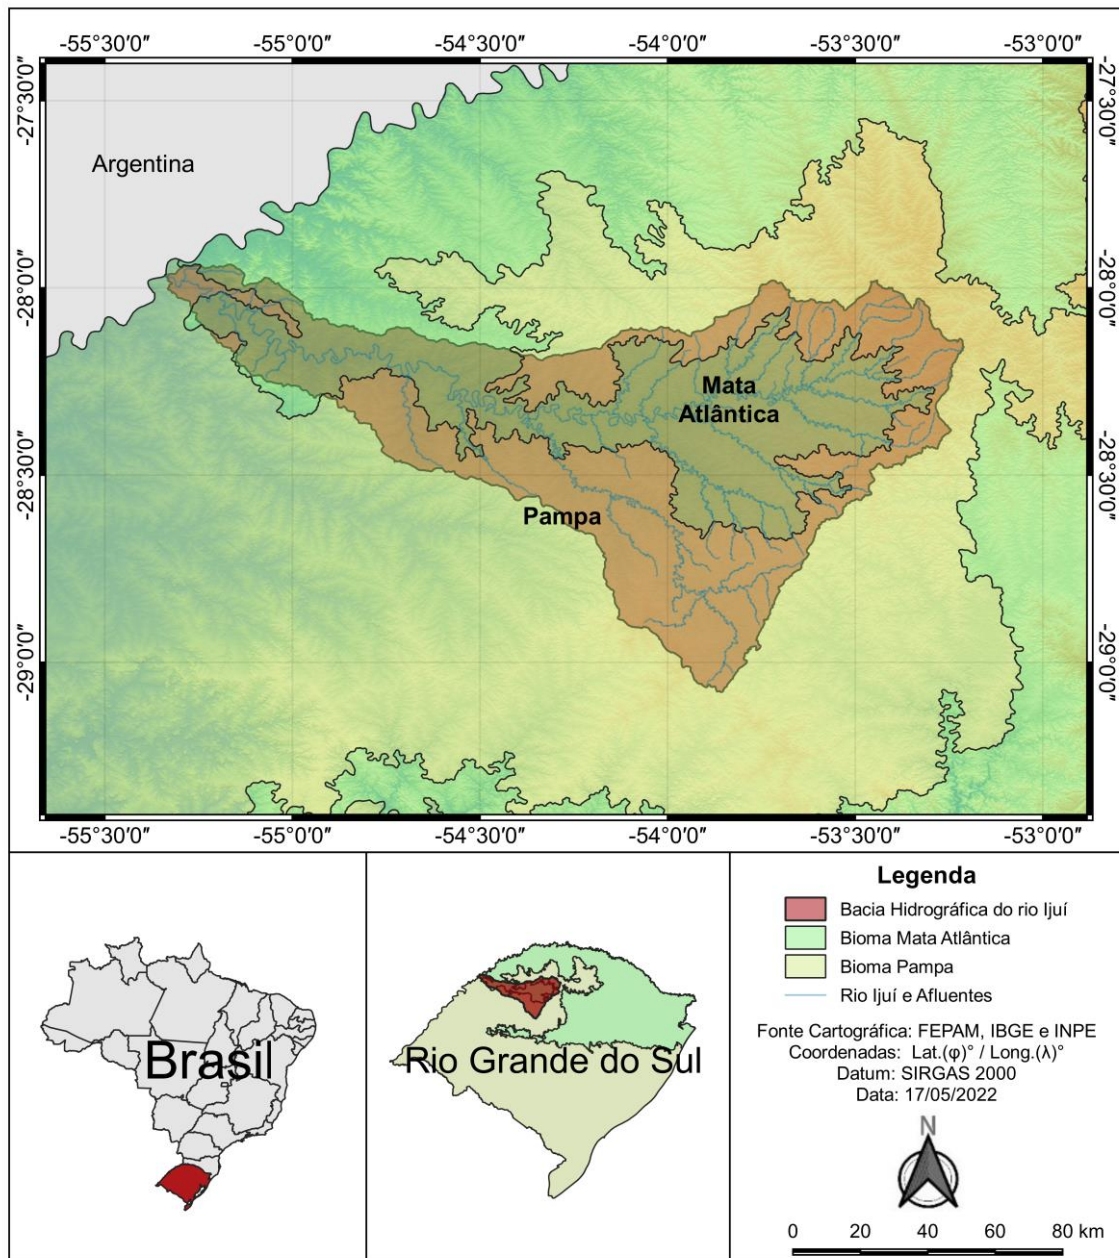
4 METODOLOGIA

4.1 ÁREA DE ESTUDO

A área de estudo compreende a bacia hidrográfica do Rio Ijuí, situada entre o norte e noroeste do Rio Grande do Sul, entre as coordenadas 27°45' e 26°15' de latitude Sul e 53°15' e 56°45' de longitude Oeste (SEMA-RS, 2012). Possui uma área de drenagem de 10.649,13 km², cobrindo (totalmente ou parcialmente) cerca de 35 municípios e possui 337.249 habitantes. Seus principais afluentes são os rios: Ijuizinho, Conceição, Potiribu, Caxambu, Faxinal, Fiúza e Palmeira. As atividades econômicas desta bacia estão diretamente ligadas ao setor primário, predominando a cultura da soja (FEPAM, 2022). Ademais, faz parte da Bacia Hidrográfica do Uruguai, tendo exutório no Rio Uruguai.

A bacia do Rio Ijuí está localizada entre os biomas Pampa e Mata Atlântica, sendo que cerca de 52% da área da bacia pertence ao bioma Pampa e 48% à Mata Atlântica, conforme apresenta a Figura 5.

Figura 5 – Mapa de localização da bacia hidrográfica do rio Ijuí.



Fonte: O autor (2022).

A Mata Atlântica é um dos principais biomas do mundo, tendo uma vegetação muito diversificada, chegando a 20 mil espécies vegetais que representam 35% das espécies existente no Brasil (Conceição et al., 2020; Silva et al., 2022), além da grande diversidade de fauna com elevado número de espécies endêmicas (CARDOSO, 2016). Este bioma possui cerca de mais de 1,1 milhões de km², cerca de 13% de todo o território nacional (IBGE, 2004), e está presente em 17 estados do território brasileiro (Jesus et al., 2020), possuindo

algumas das florestas com maior número de espécies de animais e plantas por unidade de área (MMA, 2010; MARQUES et al., 2016).

Já o bioma Pampa possui uma extensão de 178.243 km², que corresponde a pouco mais de 2% do território nacional e 63% do território do Rio Grande do Sul (IBGE 2004). Esse bioma apresenta uma grande diversidade de formações vegetais, incluindo campos, florestas estacionais e formações pioneiras (KUPLICH et al., 2018; MARCHI et al., 2018). O Pampa também apresenta um papel significativo na conservação da biodiversidade, pois apresenta riqueza de flora e fauna ainda pouco pesquisadas (ECHER et al., 2015). Segundo Boldrini et al. (2010) e existem mais de 2.200 espécies campestres, constituindo um patrimônio genético notável até então negligenciado (DEVELEY et al., 2008; MATEI & FILIPPI, 2011).

O relevo da região que compreende a bacia do Rio Ijuí varia entre 70 – 600 m de altitude em relação ao nível médio dos mares (SCHEREN & ROBAINA, 2019). Estas variações de altitude acabam influenciando o clima da região, que é definido por Köppen-Geiger como subtropical (Cfa), com verão quente, onde as temperaturas são superiores a 22°C no verão (Gollfari et al., 1978) e temperatura média anual entre 16 – 20 °C (ALVARES et al., 2013). Precipitação superior à 30 mm nos meses mais secos (Embrapa, 2022), e precipitação média anual entre 1900 – 2200 mm (ALVARES et al., 2013).

4.2 OBTENÇÃO DE DADOS

A medida de precipitação é realizada diretamente nas estações pluviométricas da Agência Nacional de Águas e Saneamento Básico (ANA) e meteorológicas do Instituto Nacional de Meteorologia (INMET). Nesse sentido, as informações digitais (em formato de tabelas) foram obtidas diretamente no portal HidroWeb da ANA (2022) e, através do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP) do INMET (2022), onde foram obtidas as lâminas de chuvas diárias em mm, e posteriormente, transformadas em precipitação acumulada mensal. Essa transformação dos dados de precipitação diária em precipitação mensal, foi realizada no *software* livre RStudio, onde após a realização do download das planilhas em formato CSV no site da ANA e formato TXT do INMET, foram criadas planilhas unificadas, contendo as chuvas acumuladas mensalmente em cada estação, para cada mês/ano, utilizados neste estudo.

Para este estudo, foram utilizados dados de 46 estações pluviométricas da ANA e INMET, com o intuito de espacializar a precipitação mensal de janeiro e agosto, nos anos de

1990, 2000, 2010 e 2020, conforme está apresentado na Tabela 1. Além disso, neste trabalho foram priorizados os dados consistidos pela ANA. A utilização de dados brutos ocorreu somente na ausência de dados consistidos.

Tabela 1. Estações Pluviométricas da ANA e INMET.

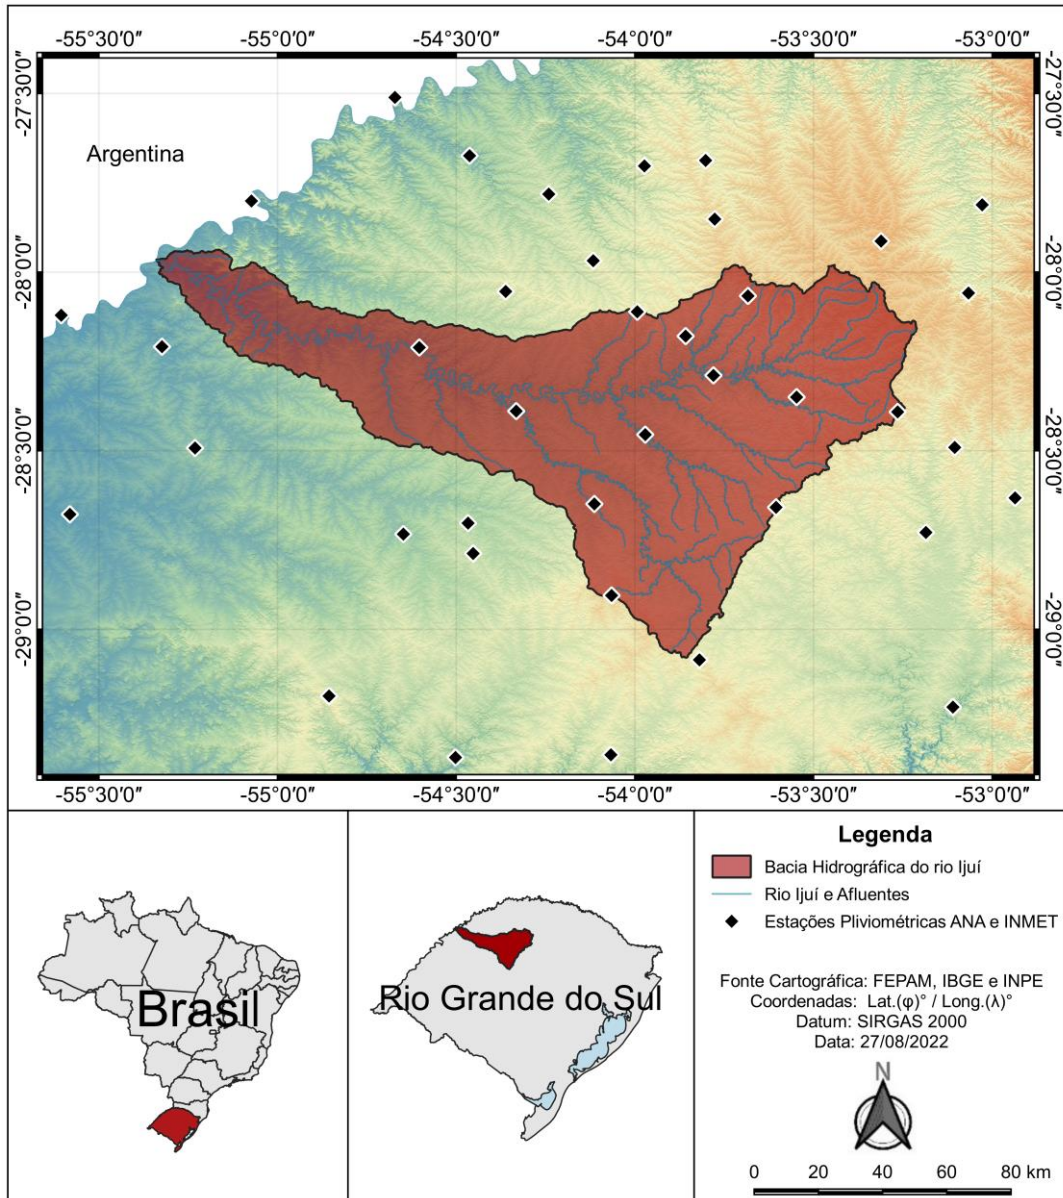
Estação	Lat.(φ)°	Long. (λ)°	Altit. (m)	Período	Estação	Lat.(φ)°	Long. (λ)°	Altit. (m)	Período
2753004	-27,8117	-53,0278	350,00	1990-2020	2853034	-28,3500	-53,5472	480,00	2010-2020
2753007	-27,8517	-53,7764	520,00	1990-2020	2853035	-28,0667	-53,6833	533,00	2010-2020
2753015	-27,9133	-53,3108	610,00	1990-2020	2853037	-28,4908	-53,1047	400,00	2010-2020
2753025	-27,6875	-53,8019	475,00	2010-2020	2853040	-28,1792	-53,8578	256,00	2020
2754007	-27,7817	-54,2408	403,00	1990-2020	2854001	-28,1111	-53,9931	447,00	1990-2020
2754009	-27,6742	-54,4625	120,00	1990-2020	2854003	-28,0542	-54,3614	400,00	1990-2020
2754010	-27,9681	-54,1164	400,00	1990-2020	2854005	-28,7336	-54,6478	160,00	1990-2020
2754014	-27,7028	-53,9731	448,00	2010-2020	2854006	-28,2111	-54,6031	160,00	1990-2020
2754014	-27,7028	-53,9731	448,00	2010	2854012	-28,7878	-54,4525	300,00	1990-2020
2754015	-27,5900	-54,6636	303,00	2010-2020	2854013	-28,9053	-54,0650	530,00	1990-2020
2755001	-27,8544	-55,0236	100,00	1990-2020	2854018	-28,6492	-54,1133	314,00	2010-2020
2850019	-28,7028	-54,4667	309,00	2010-2020	2855001	-28,1878	-55,6369	60,00	1990-2020
2852007	-28,1892	-52,7458	593,00	1990-2020	2855002	-28,2089	-55,3233	80,00	1990-2020
2852050	-28,4553	-52,8158	491,00	1990-2020	2855004	-28,6781	-55,5811	50,00	1990-2020
2852050	-28,4553	-52,8158	491,00	2010	2855007	-28,4925	-55,2308	200,00	1990-2020
2852054	-28,6322	-52,9358	381,00	2010-2020	2953007	-29,1942	-52,9522	440,00	2010
2853003	-28,4550	-53,9708	160,00	1990-2020	2953008	-29,6244	-53,3519	25,00	1990 2000 2020
2853010	-28,2892	-53,7800	200,00	1990-2020	2953030	-29,0856	-53,8192	469,00	1990 2000 2020
2853014	-28,7289	-53,1853	390,00	1990-2020	2953036	-29,2178	-53,1097	409,00	2020
2853023	-28,3892	-54,3319	440,00	1990-2020	2954005	-29,3589	-54,5019	300,00	2020
2853026	-28,0586	-53,0661	450,00	1990-2020	2954019	-29,3514	-54,0669	408,00	1990 2000 2020
2853028	-28,6586	-53,6047	440,00	1990-2020	2954020	-29,1867	-54,8558	420,00	1990-2020
2853033	-28,3914	-53,2644	500,00	2010-2020	A833	-29,1900	-54,8900	426,00	2010

Fonte: O autor.

As estações pluviométricas e meteorológicas encontram-se dentro e fora da área da bacia hidrográfica do rio Ijuí. Fora da área da bacia, optou-se por utilizar estações localizadas até 70 km do perímetro, com a finalidade de obter um resultado melhor na espacialização das extremidades da bacia hidrográfica, conforme a Figura 6.

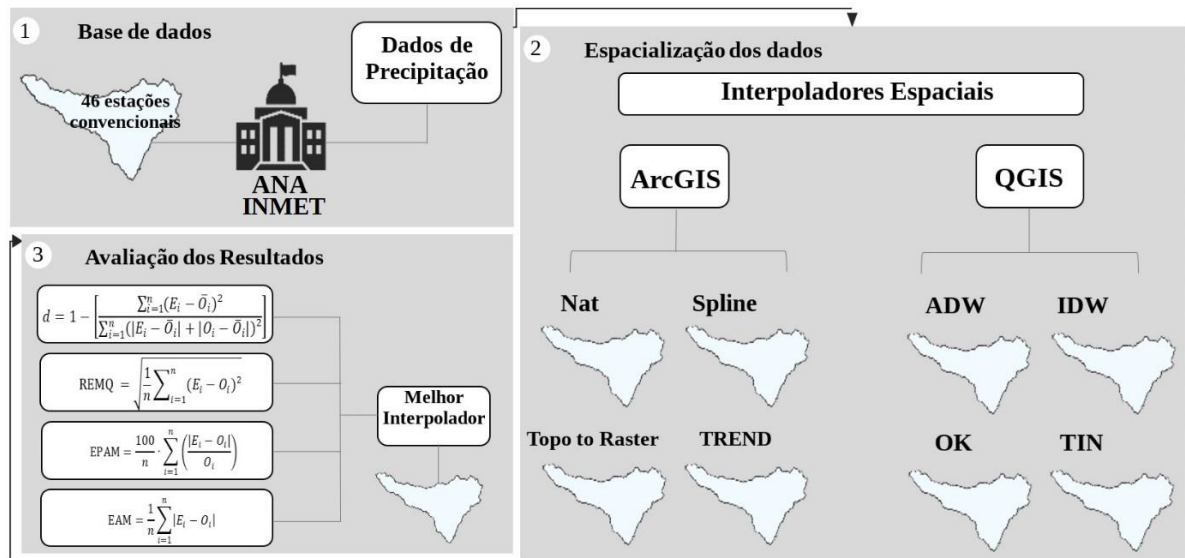
O processo metodológico pode ser visualizado integralmente na Figura 7.

Figura 6 – Mapa de estações pluviométricas e meteorológicas na região da bacia do Rio Ijuí.



Fonte: O autor (2022).

Figura 7 – Fluxograma do trabalho de espacialização.



Fonte: O autor

4.3 ANÁLISE DOS INTERPOLADORES ESPACIAIS

O objetivo da interpolação de dados espaciais é estimar valores em áreas não contempladas pela amostragem, ou seja, criar dados de superfície com base em um conjunto de pontos amostrados (WU & HUNG, 2016). Entretanto, sempre é necessário verificar a qualidade dos dados interpolados. A fim de ter um *feedback* dos resultados, é interessante comparar as espacializações de chuvas com bases de dados em formato raster já consolidadas (NASTOS et al., 2016; DIEULIN et al., 2019).

Nesse sentido, para a avaliação dos interpoladores, foram utilizados quatro indicadores estatísticos, conforme o método descrito em Schumacher et al. (2020), para comparação entre bases de dados espaciais em formato *grid*, a fim de eleger o melhor método de espacialização de precipitação mensal na área em estudo.

Os valores de precipitação mensal observados são da base de dados CHIRPS (O_i) – testemunha, e os valores estimados foram àqueles obtidos pelos diferentes métodos de espacialização (E_i). A localização dos pontos de controle e comparação entre as interpolações e a base de dados CHIRPS, foi o centroide de cada município pertencente à Bacia do rio Ijuí (conforme Tabela 2). Por fim, calcularam-se as estatísticas de desempenho descritas nas equações 1 a 4 (CECCHERINI et al., 2015; MACHADO et al., 2015; SANTOS et al., 2019).

$$d = 1 - \left[\frac{\sum_{i=1}^n (E_i - \bar{O}_i)^2}{\sum_{i=1}^n (|E_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \right] \quad (1)$$

$$REM\text{Q} = \sqrt{\frac{1}{n} \sum_{i=1}^n (E_i - O_i)^2} \quad (2)$$

$$EPAM = \frac{100}{n} \cdot \sum_{i=1}^n \left(\frac{|E_i - O_i|}{O_i} \right) \quad (3)$$

$$EAM = \frac{1}{n} \sum_{i=1}^n |E_i - O_i| \quad (4)$$

Sendo d , o índice de concordância de Willmott, adimensional; $REM\text{Q}$ é a Raiz do Quadrado Médio do Erro, mm; $EPAM$ é o Erro Percentual Absoluto Médio, em porcentagem (%); EAM é o Erro Absoluto Médio, em mm. E_i são as precipitações mensais interpoladas, mm; O_i são as precipitações mensais observadas, mm; O é a média dos valores observados, mm; e n indica o número total de estações pluviométricas e meteorológicas.

Tabela 2. Centroide dos municípios pertencentes à Bacia do Rio Ijuí.

Municípios	Latit. (φ)°	Long. (λ)°	Código do IBGE	Municípios	Latit. (φ)°	Long. (λ)°	Código do IBGE
Ajuricaba	-28,239	-53,771	4300208	Palmeira das Missões	-27,899	-53,314	4313706
Augusto Pestana	-28,517	-53,992	4301503	Panambi	-28,293	-53,502	4313904
Boa Vista do Cadeado	-28,607	-53,815	4302220	Pé juçara	-28,423	-53,656	4314308
Bozano	-28,368	-53,771	4302584	Priapó	-28,045	-55,199	4314555
Caibaté	-28,288	-54,638	4303301	Porto Xavier	-27,906	-55,138	4315107
Catuípe	-28,25	-54,012	4305009	Rolador	-28,258	-54,818	4315958
Cerro largo	-28,149	-54,738	4305207	Roque Gonzales	-28,131	-55,026	4316303
Condor	-28,208	-53,487	4305702	Salvador das Missões	-28,126	-54,835	4316477
Coronel Barros	-28,383	-54,066	4305871	Santa Barbara do Sul	-28,358	-53,247	4316709
Cruz Alta	-28,639	-53,606	4306106	Santo Ângelo	-28,299	-54,263	4317509
Dezesseis de Novembro	-28,213	-55,068	4306353	São Luiz Gonzaga	-28,408	-54,961	4318903
Entre-Ijuís	-28,36	-54,268	4306932	São Miguel das Missões	-28,563	-54,554	4319158

Eugenio de Castro	-28,525	-54,149	4307831	São Paulo das Missões	-28,021	-54,936	4319307
Guarani das Missões	-28,141	-54,558	4309506	São Pedro do Butiá	-28,124	-54,887	4319372
Ijuí	-28,388	-53,915	4310207	Sete de Setembro	-28,131	-54,463	4320578
Jóia	-28,647	-54,122	4311155	Tupanciretã	-29,081	-53,836	4322202
Mato Queimado	-28,256	-54,616	4312179	Vitoria das Missões	-28,351	-54,496	4323754
Nova Ramada	-28,064	-53,697	4313334				

Fonte: O autor.

4.3.1 Métodos de interpolação espacial utilizados no QGIS

4.3.1.1 Inverso da Distância Ponderada (IDW)

Esta técnica é baseada no algoritmo SYMAP de Shepard (1968), relaciona o valor desconhecido de variável com os valores da mesma variável medida em outros locais. Esta influência é expressa através de um peso (w) (CAMERA et al., 2014; SHEPARD, 1968):

$$w_i(x) = \frac{1}{d(x,x_i)^p} \quad (5)$$

onde x é o ponto da estimativa é desejada; x_i é um dos pontos em que as observações estão disponíveis; d é a distância entre os dois locais e p é um expoente que permite dar formas diferentes à função de ponderação (CAMERA et al., 2014; MENDEZ et al., 2017).

No presente trabalho foi utilizado o expoente $p = 1$.

4.3.1.2 Distância Angular Ponderada (ADW)

O método de espacialização da Distância Angular Ponderada (ADW) é uma abordagem semelhante ao método IDW, onde o intuito é espacializar dados dispostos em uma rede irregular de observações, transformando-as em uma grade regular. O método ADW comumente emprega a distância de decaimento de correlação (CDD) para selecionar estações que devem contribuir para cada estimativa do ponto de grade e definir o componente de distância dos pesos das estações (HOFSTRA & NEW, 2009). Esta ponderação das estações vizinhas é calculada usando as distâncias e os ângulos entre as estações vizinhas (O_k) e a estação desconhecida (E_k) (XAVIER et al., 2015; BARATTO et al., 2022). O ângulo, a

distância e os pesos foram combinados para chegar a um peso de distância angular (W_{E_k}) para estação E_k (NEW et al., 2000):

$$W_{E_k} = w_k(1 - a_k) \quad (6)$$

O peso a_k é calculado na Equação (7) e está associado a cada estação de apoio para interpolação. Este peso foi determinado pelo isolamento direcional (angular) de cada um dos n_j pontos dos dados selecionados; $\theta_j(k, l)$ é o ângulo formado pelas estações O_l e O_k com o vértice no ponto de interpolação de interesse (E_j); w_l é o peso da distância nos pontos de dados observados (O_l e O_k). Outro fator associado ao peso da distância é o peso angular (um k , Eq. 7) para cada uma das $n_j = 4$ (utilizado neste trabalho) estações selecionadas para a interpolação:

$$a_k = \frac{\sum_{l=1}^{n_j} w_l(1 - \cos \theta_j(k, l))}{\sum_{l=1}^{n_j} w_l}, l \neq k \quad (7)$$

O peso w_k é calculado utilizando a eq. (8). O peso decai na medida que m aumenta. O valor m é o expoente utilizado para cada variável que será interpolada, nesse trabalho foi utilizado $m = 2$.

$$w_k = r^m \quad (8)$$

O peso da distância é calculado pela função de CDD; x é a distância do ponto em grade de interesse (dado que será estimado) e uma estação meteorológica nas proximidades (dados observados); (r) é a correlação para cada estação interpoladas em todas as outras estações (Eq. 9).

$$r = e^{-x/CDD} \quad (9)$$

Neste trabalho, ADW foi executada no software QGIS, utilizando o plugin SAGA GIS.

4.3.1.3 Krigagem Ordinária (OK)

O método de espacialização da Krigagem utiliza informações a partir de um semivariograma para encontrar os pesos ótimos a serem associados às amostras com valores conhecidos que irão estimar pontos desconhecidos (CAI et al., 2019; PEZZONI FILHO et al., 2018). Neste trabalho, foi utilizada a Krigagem Ordinária, com modelo exponencial.

$$\hat{Z}_{ko}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (10)$$

Onde \hat{Z}_{ko} = ponto estimado; $\lambda_{i,i=1,n}$ = pesos associados aos n dados e, (x_i) = ponto amostrado. (PEZZONI FILHO et al., 2018; LUNDGREN et al., 2017).

Os dados da OK devem ser submetidos a análise do semivariograma, por meio da seguinte equação:

$$\hat{\gamma} = \frac{1}{2N(h)} \sum_{i=1}^{N(h)} [Z(x_i) - Z(x_i - h)]^2 \quad (11)$$


Onde $\hat{\gamma}(h)$ = bins do gráfico semivariograma em função do vetor h , $N(h)$ = número de pares de valores medidos $Z(x_i)$, $Z(x_i + h)$, e h = vetor de separação dos pares.

Neste trabalho, OK foi executada no software QGIS, utilizando o plugin SAGA GIS.

4.3.1.4 Rede de Triângulos Irregulares (TIN)

A Rede de Triângulos Irregulares (TIN), se baseia na triangulação de Delaunay é executada para formar triângulos (LAURINI, 2017). Então, TIN utiliza os pontos amostrais para constituir muitos triângulos não sobrepostos que cobrem toda a região de acordo com um conjunto de regras estipuladas. A superfície interpolada é descrita por meio da aproximação destes triângulos (Liang & Wang, 2020), conforme está apresentado na Figura 8.

Figura 8 – Exemplo do interpolador TIN.



Fonte: QGIS (2022).

Essa abordagem é frequentemente usada para produzir mapas de contorno e de relevos sombreados, pois é um método de interpolação espacial simples e, geralmente mais rápido no

cálculo (LAM, 2009). Dessa forma, a TIN é definido por uma triangulação a partir de um conjunto de pontos amostrais irregularmente distribuídos nas coordenadas (x, y), com respectivos valores a serem interpolados em z (PENHA & COELHO, 2021). Possuem capacidade de adaptação às mudanças associadas à heterogeneidade das amostras que serão interpoladas (WASKLEWICZ et al., 2013).

4.3.2 Métodos de interpolação espacial utilizados no ArcGIS


4.3.2.1 Vizinhos naturais (Nat)

Surgido no início dos anos 80, por Sibson (1980), o conceito de *Natural Neighbors*, (Vizinhos Naturais) permite impor uma conectividade nodal celular (Dinis et al., 2011), traduzindo-se no conjunto de nós mais próximos do nó, que se deseja estimar.

O método de espacialização, Vizinho natural (Nat) é um interpolador determinístico local, que relaciona um subgrupo amostral de entrada a um ponto de consulta e aplica pesos a eles, baseando-se em áreas proporcionais, ou seja, a interpolação é feita através da média ponderada dos pontos próximos em cujos pesos são proporcionais às áreas proporcionais (PAVÃO et al., 2012).

O grande diferencial do Nat é que eles representam um conjunto de 'nós circundantes mais próximos', cujo número e posições são determinados meramente pela distribuição nodal local, conforme apresenta a Figura 9 (CAI & ZHU, 2005; FENG & PENG, 2018).

Figura 9 – Criação de nós do interpolador Nat.



Fonte: FENG & PENG (2018).

Segundo Moreira et al. (2014), vizinhos naturais são determinados recorrendo ao diagrama de Voronoï, sendo que este é constituído por um conjunto de células de Voronoï. A cada uma dessas células está associado apenas um nó, para além do conjunto de todos os pontos que estão mais próximos desse nó do que de qualquer outro, ele é, portanto, candidato ideal para nós de um esquema de interpolação local (FENG & PENG, 2018).

Esta é uma técnica diferente, pois não extrapola valores, resolvendo a interpolação apenas para dentro do domínio dos dados (PAVÃO et al., 2012).

Os cálculos estão descritos corretamente em Sibson (1981) e Watson (1992).

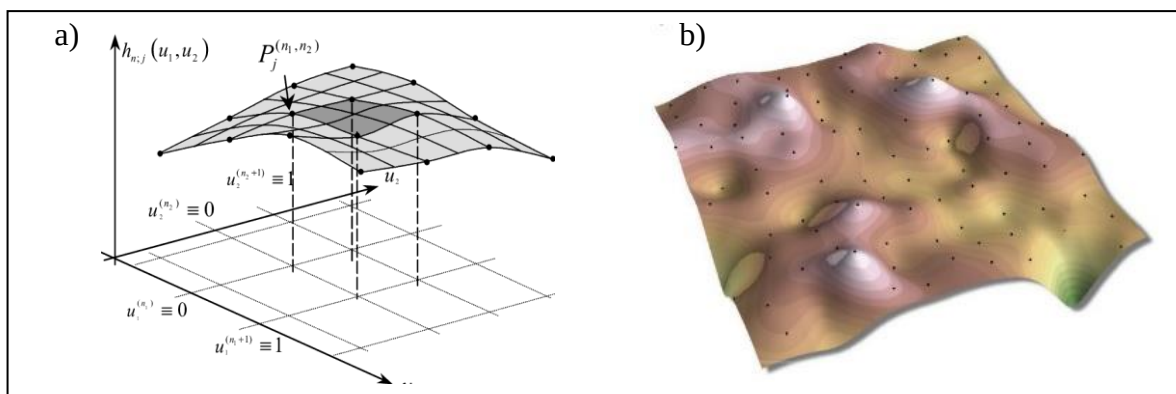
4.3.2.2 Curvatura Mínima (Spline)

O método de curvatura mínima, ou simplesmente Spline, é um método de interpolação muito aceito e utilizado atualmente. Distinto de outros métodos de interpolações polinomiais, pois não utiliza apenas um polinômio de grande ordem para interpolação de todo o conjunto de dados (Mazzini & Schettini, 2009), mas sim divide a série de dados em subconjuntos e utiliza polinômios de pequenas ordens para cada subconjunto. A soma ou junção deles é que forma a interpolação sobre todo o domínio (PAVÃO et al., 2012).

O método é classificado como suavizador e tenta dar crédito aos dados ao máximo, conforme está apresentado na Figura 10. Nesse processo, os cálculos de derivação são feitos repetidamente até o alcance de uma diferença (convergência ou tolerância) entre valores amostrados ou estimados (BRUBACHER et al., 2020). Cada estação é omitida da estimativa da superfície ajustada e o erro quadrático médio é encontrado. Isso é repetido para um intervalo de valores de um parâmetro de suavização; então o valor que minimiza o erro quadrático médio é tomado para fornecer a suavização ótima (TAIT & WOODS, 2007).

Neste trabalho foi utilizado o método Spline cúbica, devido sua alta performance, como menciona Fletcher (2017). Todos os cálculos estão corretamente descritos em FRANKE (1982) e MITAS (1988).

Figura 10 – Exemplo do método de espacialização Spline.



Fonte: a) Solazzi & Uncini (2000); b) CHILDS (2004).

4.3.2.3 Topo to Raster (TOP)

O método de interpolação espacial *Topo to Raster* foi baseado nos trabalhos desenvolvidos por Hutchinson em seu programa ANUDEM (CARMO et al., 2015; MARCUZZO et al., 2011). Este método permite que além de arquivos de pontos, podem ser usados outros formatos de arquivos como: curvas de nível, delimitações de rios ou lagos, contorno de penhascos e delimitações de bacias (ESRI, 2022; HUTCHINSON, 1989).


O método foi inicialmente desenvolvido especificamente feito para a criação de Modelos de Elevação Digital (DEM) hidrológicamente corretos (HUTCHINSON et al., 2009).

Segundo Cardoso e Marcuzzo (2014), o programa interpola os dados de elevação em uma grade regular, de modo iterativo, gerando grades sucessivamente menores, minimizando a soma de uma de penalização de rugosidade e a soma dos quadrados dos resíduos (diferenças das elevações medidas e calculadas pela função), conforme pode ser visto na Figura 11 (MARCUIZZO et al., 2011).

Essa técnica de interpolação faz uso da eficiência computacional da interpolação local, como ponderação do inverso da distância, sem perder a continuidade superficial dos métodos global de interpolação, como Krigagem e Spline (GARDIMAN JUNIOR, 2012).

A descrição detalhada do método está corretamente apresentada em Marcuzzo et al. (2011).

Figura 11 – Exemplo do interpolador Topo to Raster.



Fonte: TYC GIS (2015).

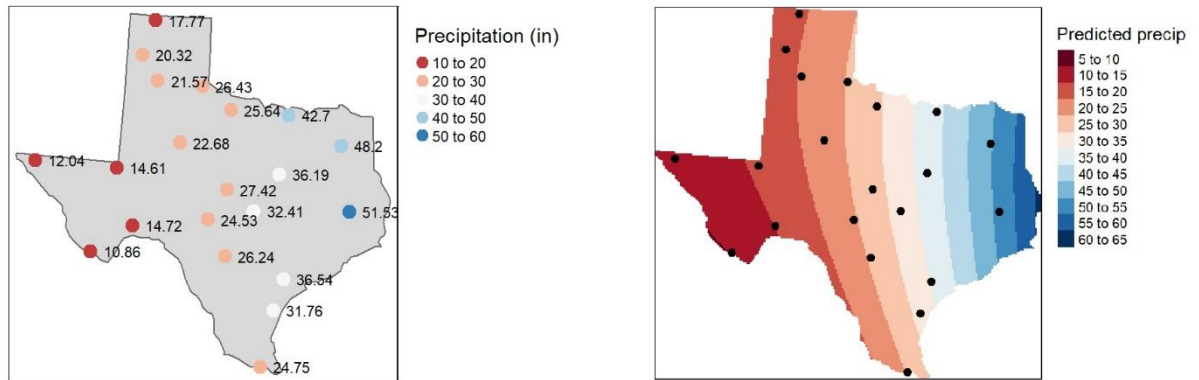
4.3.2.4 Superfície de Tendência (TREND)

A interpolação por superfície de tendência polinomial, ou TREND, é um método que busca encontrar as tendências regionais dos dados (MARTELI & PIROLI, 2015). A tendência é ajustada através de polinômios de ordens diversas. Esses polinômios são gerados por critérios de regressão por mínimos quadrados (LANDIM, 2000). Em resumo, o método TREND visa minimização a variância da superfície em relação aos valores de entrada (ESRI, 2022a). Por isso, a superfície é construída de modo que para cada ponto de entrada, o total das diferenças entre os valores reais e os valores estimados (ou seja, a variância) seja o menor possível (CHILDS, 2004).

Além disso, esta técnica é capaz de interpolar valores, extrapolar a sequência de dados, inferir sobre a presença de tendências ou estimar características de interesse sobre os dados (GOMES, et al., 2014; LANDIM, 2003). Um exemplo da interpolação espacial utilizando TREND pode ser vista na Figura 12.

A descrição detalhada do método está corretamente apresentada em GOMES, et al. (2014).

Figura 12 – Exemplo do interpolador Superfície de Tendência (Trend).



Fonte: Gimond (2022).

4.4 DISPONIBILIDADE DOS DADOS

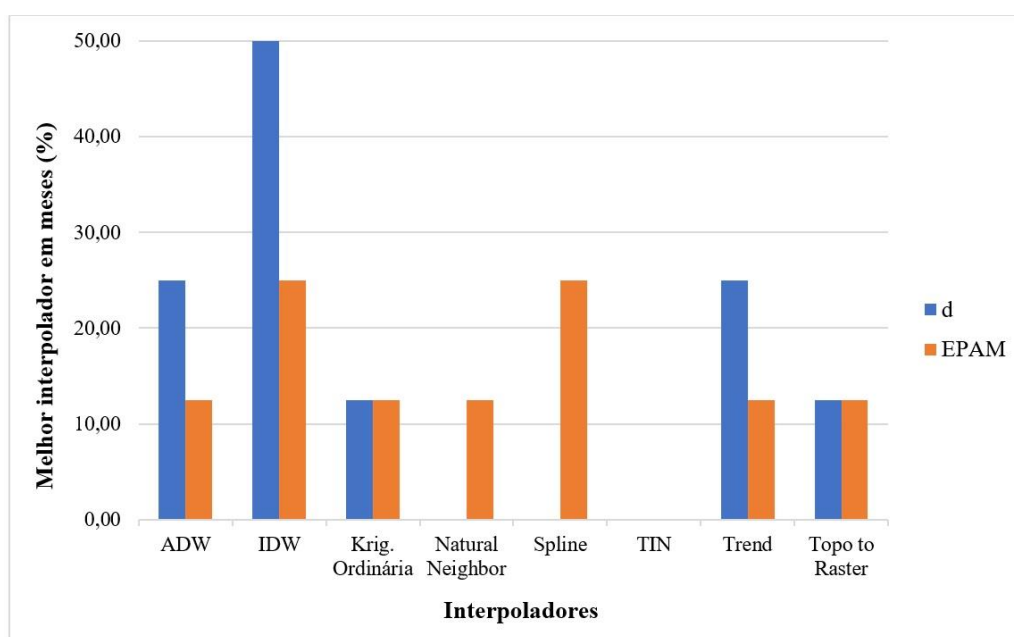
Após a avaliação visual e estatística dos interpoladores espaciais e escolha do interpolador com melhor desempenho, foi elaborado uma base de dados espacializada de precipitação mensal, com resolução espacial de 0,25km² (ou 250.000m²), para uma série temporal de 30 anos, compreendendo os meses de janeiro e agosto dos anos 1990, 2000, 2010 e 2020.

5 RESULTADOS E DISCUSSÕES

5.1 RESULTADOS

Na Figura 13 apresenta-se o percentual de meses, durante a série utilizada no estudo, em que cada interpolador apresentou melhor desempenho, de acordo com os índices estatísticos “d” e “EPAM”. Sendo que foram analisados quatro anos distintos e dois meses em cada ano.

Figura 13 – Percentual dos meses em que cada interpolador apresentou o melhor desempenho.



Fonte: O autor (2022).

Na Tabela 3 são apresentados os resultados, contabilizando todos os meses e anos em estudo.

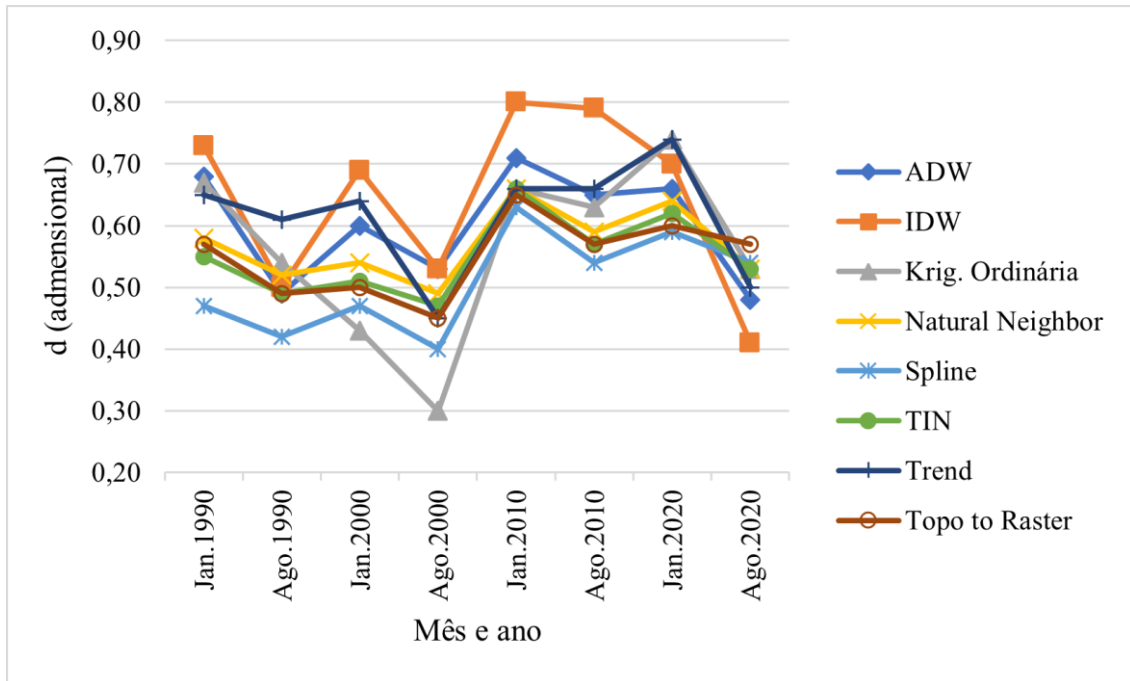
Tabela 3. Resultados estatísticos médios finais.

Índice estatístico	ADW	IDW	Krig. Ordinária	Natural Neighbor	Spline	TIN	Topo to Raster	Trend
d (adimensional)	0,60	0,64	0,56	0,57	0,51	0,55	0,55	0,61
EAM (mm)	13,43	14,96	17,78	12,98	13,94	13,74	14,19	13,59
EPAM (dec. %)	0,37	0,41	0,47	0,35	0,34	0,37	0,37	0,38
RMSE (mm)	4,36	4,10	5,54	4,77	6,60	5,08	5,52	4,04

Fonte: O autor (2022).


Nas Figuras 14 a 17, apresenta-se a variação dos valores médios mensais das estatísticas nos anos que foram estudados neste trabalho.

Figura 14. Variação dos valores médios mensais do índice d em todos os anos.




Fonte: O autor (2022).

Figura 15. Variação dos valores médios mensais do REMQ em todos os anos.




Fonte: O autor (2022).

Figura 16. Variação dos valores médios mensais de EAM em todos os anos.



Fonte: O autor (2022).

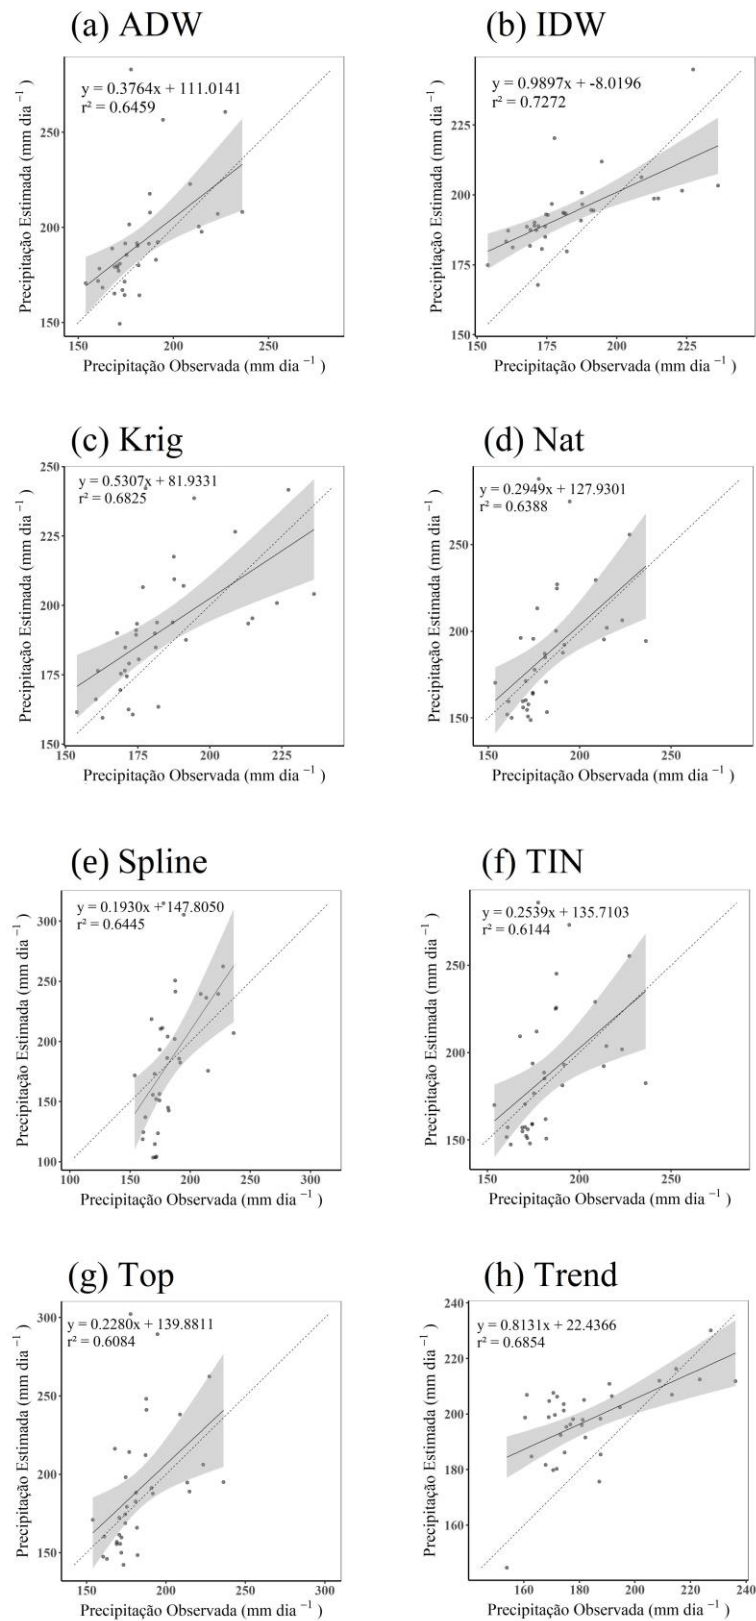
Figura 17. Variação dos valores médios mensais de EPAM em todos os anos.



Fonte: O autor (2022).

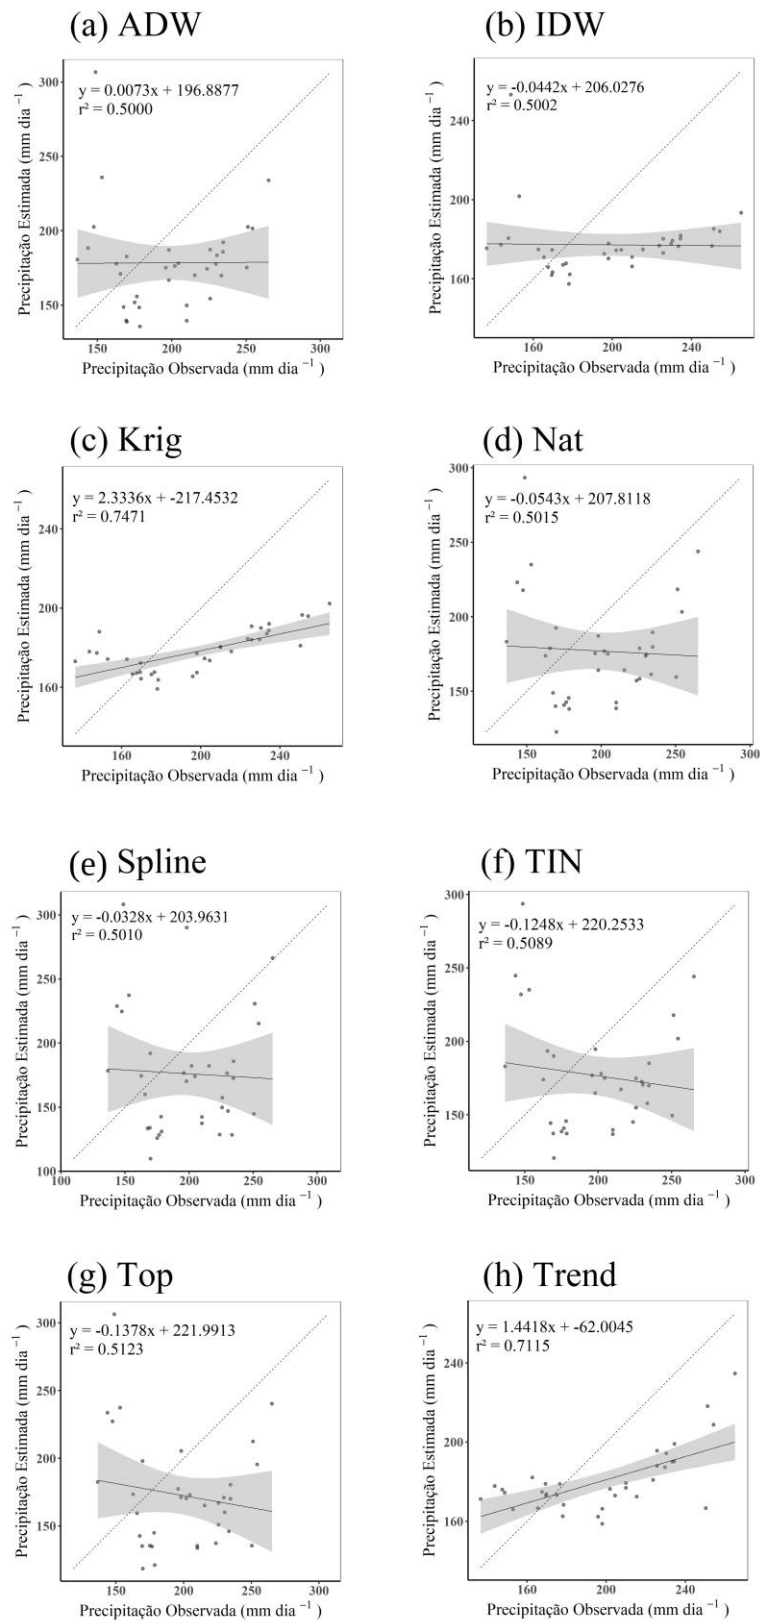
Nas Figuras 18, 19, 20 e 21 são apresentados os gráficos de dispersão (valores observados vs. valores estimados) de todos os interpoladores para os meses de janeiro de 1990 e 2020, e para os meses de agosto de 1990 e 2020, respectivamente. Esses anos foram escolhidos no intuito de considerar e comparar o ano de início e fim da série temporal.

Figura 18. Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em janeiro de 1990. Disponível em: <https://imgbox.com/5i4BNik7>.



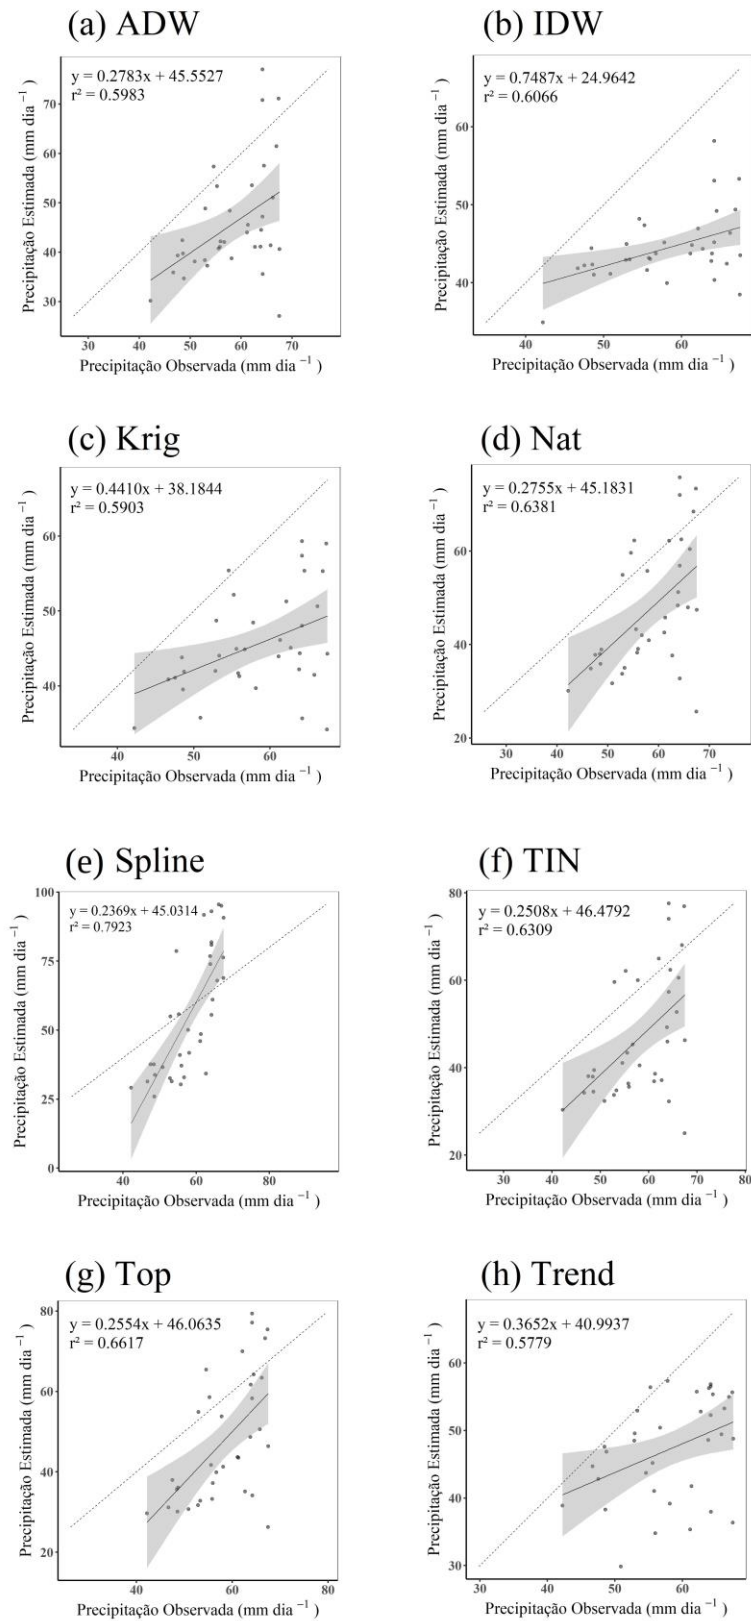
Fonte: O autor (2022).

Figura 19. Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em janeiro de 2020. Disponível em: <https://imgbox.com/WUxahSYY>.



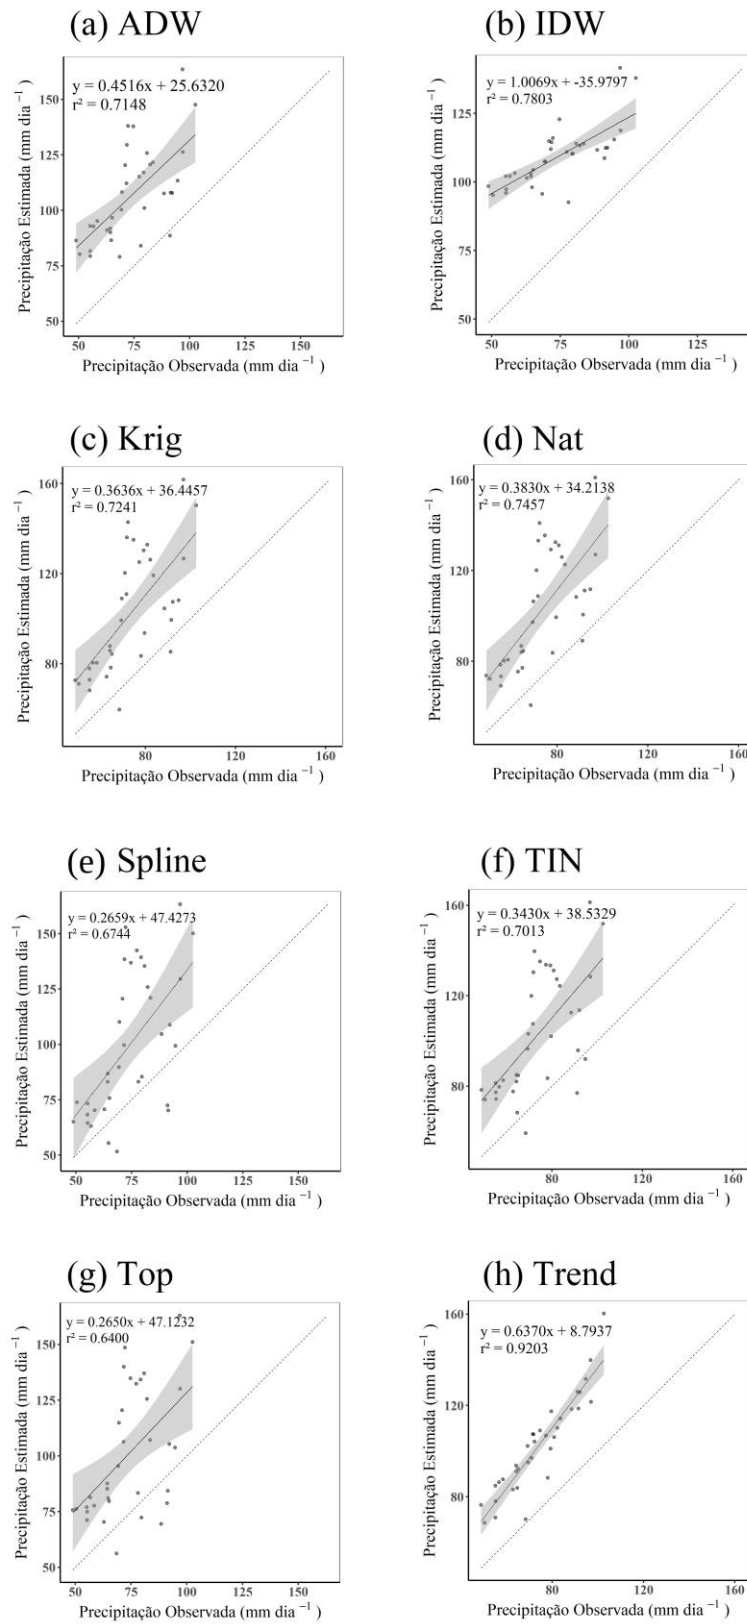
Fonte: O autor (2022).

Figura 20. Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em agosto de 1990. Disponível em: <https://imgbox.com/aGAdjIhV>.



Fonte: O autor (2022).

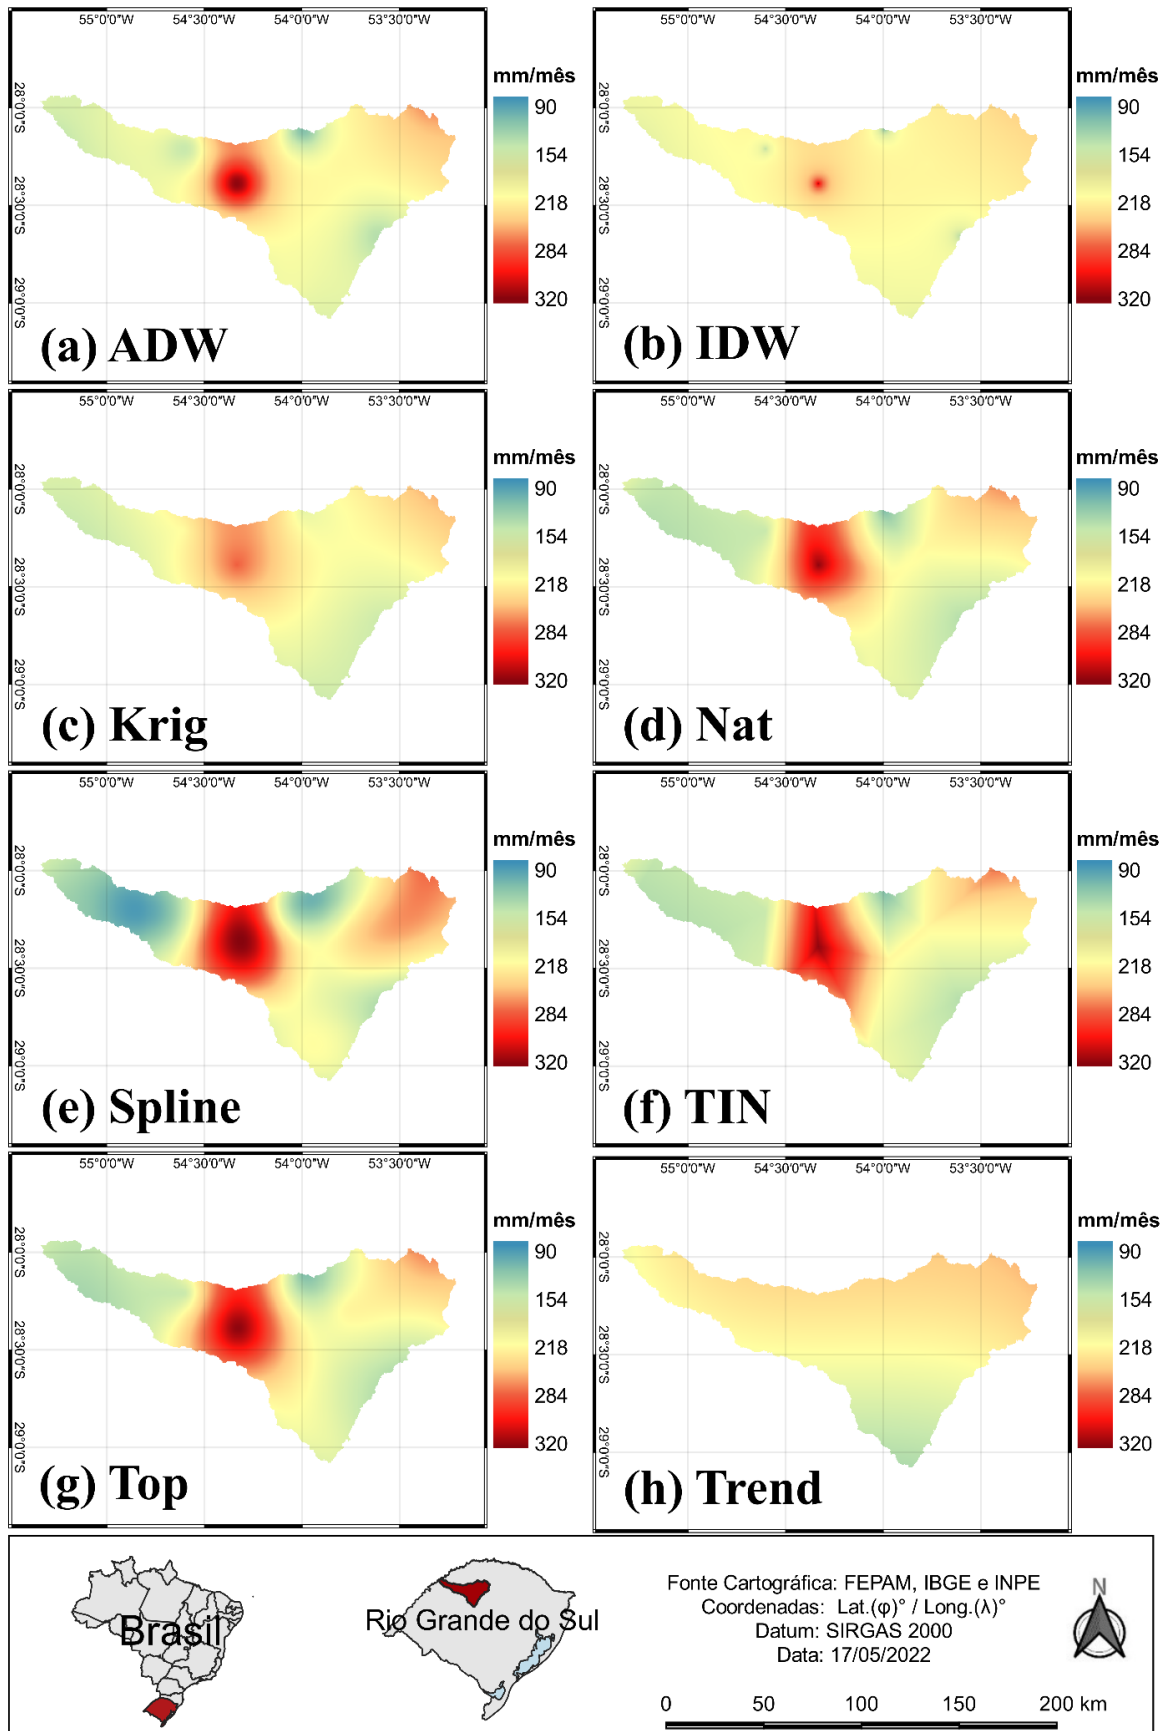
Figura 21. Gráfico de dispersão de dados observados (CHIRPS) e estimados (interpolados) em agosto de 2020. Disponível em: <https://imgbox.com/8dGrPuVl>.



Fonte: O autor (2022).

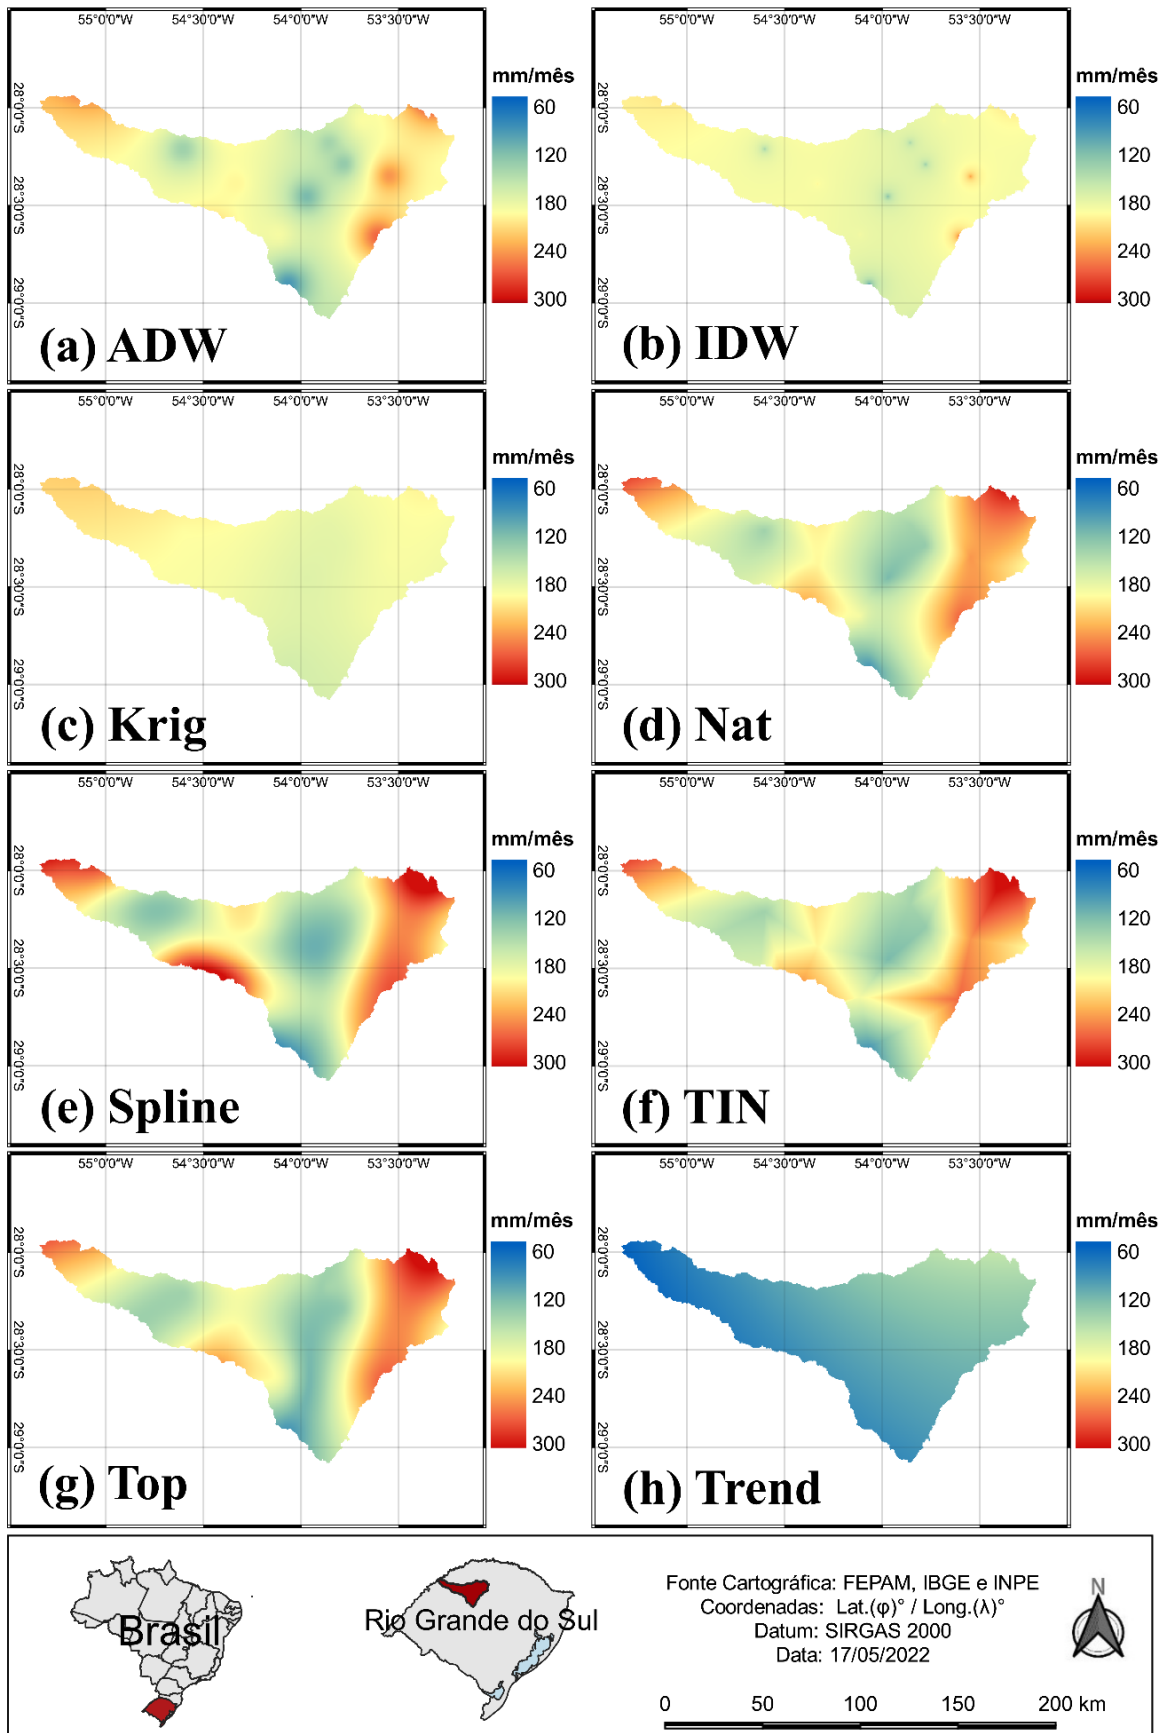
Nas Figuras 22, 23, 24 e 25 são apresentadas as espacializações da precipitação de todos os interpoladores na área em estudo, para os meses de janeiro de 1990 e 2020, e para os meses de agosto de 1990 e 2020, respectivamente.

Figura 22. Espacialização de Precipitação mensal de janeiro de 1990 (verão).



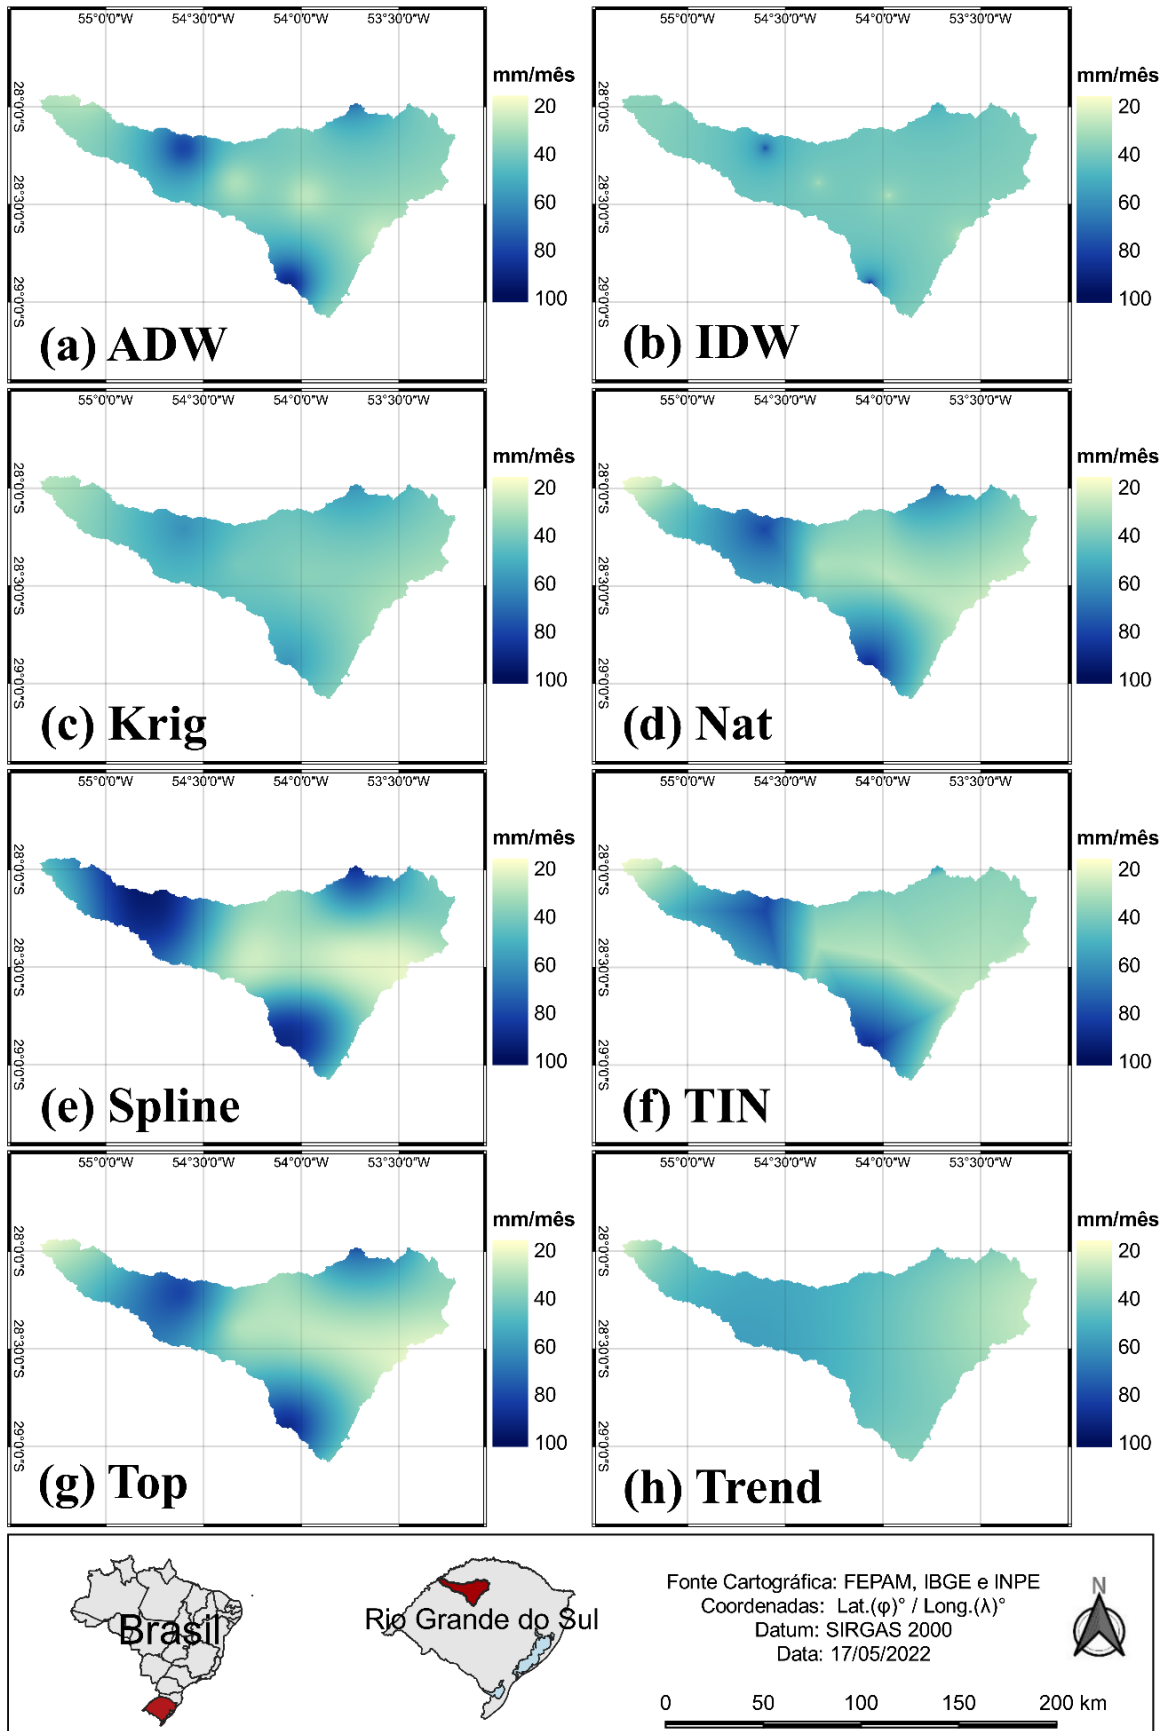
Fonte: O autor (2022).

Figura 23. Espacialização de Precipitação mensal de janeiro de 2020 (verão).



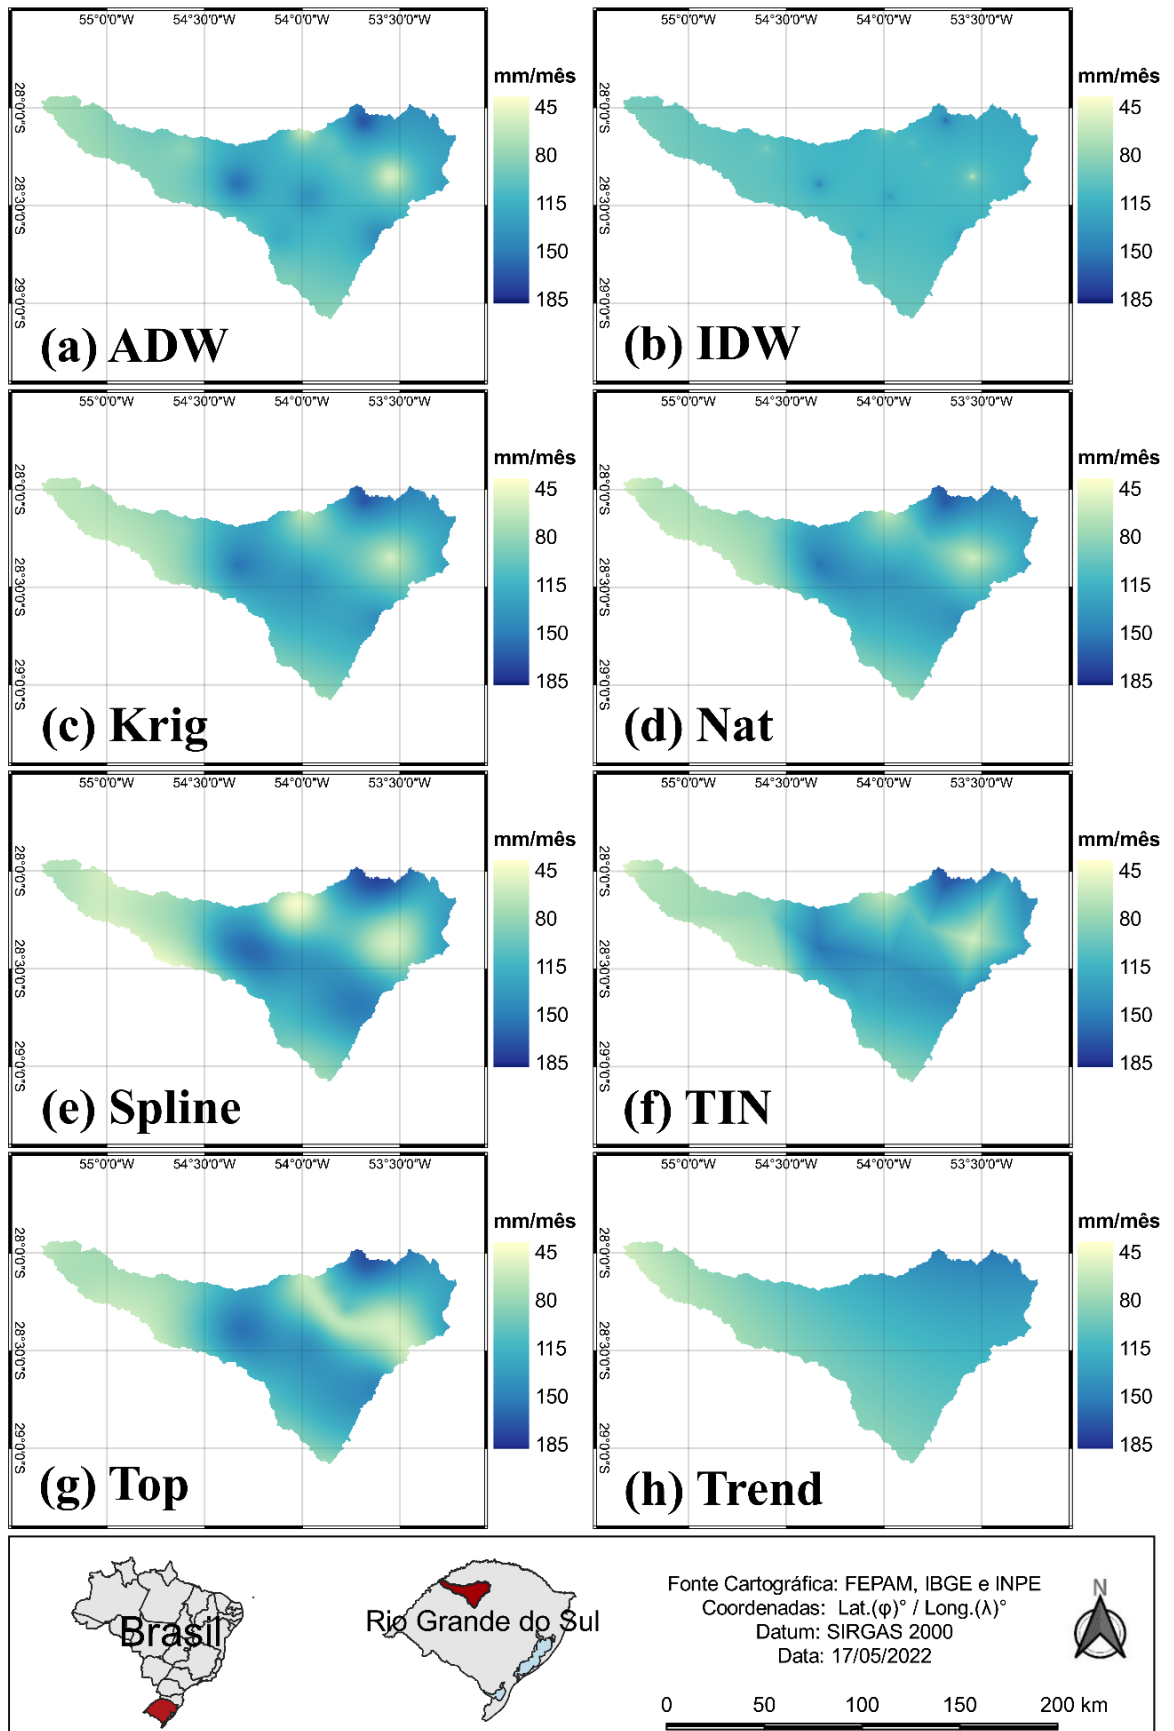
Fonte: O autor (2022).

Figura 24. Espacialização de Precipitação mensal de agosto de 1990 (inverno).



Fonte: O autor (2022).

Figura 25. Espacialização de Precipitação mensal de agosto de 2020 (inverno).



Fonte: O autor (2022).

5.2 DISCUSSÕES

Na figura 13 evidencia que o interpolador IDW apresentou os melhores resultados para espacialização de chuvas mensais, em 50% dos meses analisados neste estudo, de acordo com o índice “d”. Contudo, quando se analisa o índice EPAM, o método IDW encontra-se empatado com o método Spline, uma vez que ambos obtiveram os melhores resultados em 25% dos meses estudados. Nesse sentido, é possível inferir que o método IDW foi globalmente melhor que os demais interpoladores.

Na sequência, observando a Tabela 3, que traz o resumo de todos os resultados estatísticos médios finais, é possível notar que no quesito REMQ o interpolador Trend foi o que mais se destacou, enquanto *Natural Neighbor* foi o método de maior destaque segundo o EAM. Todavia, é válido destacar que REMQ possui uma grande variação dos resultados, principalmente nos meses de verão, onde magnitude faz com que a amplitude dos resultados seja maior. Sendo assim, o índice REMQ sozinho não é eficaz para determinar o melhor interpolador, REMQ foi utilizado para verificar se o erro é semelhante com os demais trabalhos encontrados na literatura, ficando ($<7\text{mm mês}^{-1}$), como Adhikary et al. (2017) que espacializaram precipitação mensal na bacia do rio Middle Yarra e na bacia do rio Ovens em Victoria, Austrália, utilizando 61 estações pluviométricas; e Jacquin e Soto-Sandoval (2013) que espacializaram precipitação média mensal na sub-bacia superior do rio Aconcágua, nos Andes do Chile Central.

Na mesma lógica do REMQ, o índice EAM, foi utilizado para comparação dos resultados com a literatura, onde obteve-se faixas semelhantes ($<20\text{mm}$) em Viola et al. (2010) que espacializaram precipitação média mensal, em todo o território do estado de Minas Gerais, utilizando informações de 232 postos pluviométricos para modelagem e de 70 para validação; e Gardiman Junior et al. (2012) que realizaram a espacialização de precipitação pluviométrica média mensal, para o território da Bacia Hidrográfica do Itapemirim, no estado do Espírito Santo.

O índice EPAM, serviu para avaliar a amplitude dos valores de chuva especializados. EPAM variou cerca de 34-41%, isso ocorreu devido à alguns picos de valores elevados, principalmente em agosto de 2020 (conforme Figura 14). Por isto, a faixa do EPAM é pouco superior aos trabalhos encontrados na literatura, em que o EPAM ficou pouco acima de 30%, conforme Mello & Silva (2009) que realizaram a predição da precipitação média mensal, para

o estado de Minas Gerais, utilizando 209 estações meteorológicas; e Wanderley et al. (2014) que interpolaram dados médios de precipitação pluviométrica mensal, no Estado de Alagoas utilizando cerca de 245 estações pluviométricas.

Já o índice de concordância de Willmott (d), que varia de 0 a 1, onde os valores mais próximos de 1 representam os melhores resultados de interpolação (Willmott et al. 1985), foi utilizado como principal índice estatístico para validação dos interpoladores utilizados nesse trabalho. O índice “ d ” é frequentemente usado por pesquisadores brasileiros como norteador nas análises de desempenho de espacialização de dados climáticos, principalmente precipitação (SALDANHA et al., 2015; SILVA et al., 2016; TOSTES et al., 2017).

Embora os valores de “ d ” neste trabalho possam parecer baixos ($>0,75$), pois variaram entre (0,51 a 0,64), resultados semelhantes já foram encontrados no Brasil, para espacialização de precipitação pluviométrica mensal, como em Gardiman Junior et al. (2012); e Gherardi (2008). Além disso, os valores de “ d ” foram comparados diretamente com outra base de dados em formato *grid* de precipitação diária, ou seja, sem a aplicação da técnica de validação cruzada.

As Figuras 14,15,16 e 17, permitem uma visualização temporal dos resultados, onde é possível verificar em quais meses houver uma discrepância maior entre os valores de precipitações pluviométricas acumuladas mensais e os interpoladores espaciais. Onde o índice “ d ” (Figura 14) teve os melhores resultados nos meses de verão; REMQ foi menor nos meses de inverno (Figura 15), possivelmente devido às menores amplitudes de lâminas precipitadas); EAM (Figura 16), foi menor em agosto de 2010, mas pior nos meses de janeiro e agosto de 2020, exceto pela Krigagem Ordinária, que apresentou os piores desempenhos nos anos de 2000 e 2020; EPAM (Figura 17) diferentemente do EAM, teve uma sequência de melhores desempenhos nos meses de janeiro, possuindo desempenho superior apenas em agosto de 2010, e um pico de péssimo desempenho em agosto de 2020.

Nas Figuras 18 e 19 (meses de janeiro de 1990 e 2020), e 20 e 21 (meses de agosto de 1990 e 2020), são apresentados os gráficos de dispersão, onde é possível dizer que os resultados foram inconclusivos, uma vez que o maior r^2 foi do IDW (Figura 18), Krigagem Ordinária (Figura 19), Spline (Figura 20) e Trend (Figura 21).

Ainda em relação aos gráficos de dispersão é possível afirmar que não houve muito ajuste entre os valores observados (CHIRPS) e preditos (interpoladores). Todavia, isso não é novidade em trabalhos que tratam de precipitação pluviométrica, a exemplo de Viola et al. (2010), Lam et al. (2015) e Adhikary et al. (2017) e Nogueira et al. (2020), devido à grande variabilidade espaço-temporal de eventos hidrológicos (HARTMANN et al., 2011;

SANCHES et al., 2013; BARATTO et al., 2022). Mesmo assim, dados de precipitação pluviométrica mensal podem ser úteis na detecção de mudanças climáticas (Salviano et al., 2016; Trenberth, 2011), estudos de inundações (Madsen et al., 2014; Schumacher, 2016), modelagem hidrológica, e principalmente no manejo integrado de bacias hidrográficas, onde a disputa de produção de água é mais sensível e transparente (ROMERO & ORTIZ, 2008; TUNDISI, 2008).

Por fim, nas Figuras 22, 23, 24 e 25 é possível visualizar as espacializações nos anos de janeiro de 1990 e 2020 (Figuras 22-23) e agosto de 1990 e 2020 (Figuras 24-25).

Na Figura 22, o método IDW conseguiu fazer uma representação dos locais onde a precipitação variou e onde permaneceu constante. Na sequência o método da Krigagem obteve um bom resultado visual não extrapolando valores máximos extremos para regiões mais distantes da real precipitação. Seguida pelo método ADW, Vizinhos Naturais, *Topo to Raster*, Spline, TIN e Trend, que por sua vez suavizou demais a superfície precipitada, embora as estimativas foram assertivas em grande parte da bacia hidrográfica, houve eventos pontuais de chuvas em alguns municípios, que acabaram sendo desprezados pelo método.

Na Figura 23 os melhores resultados foram visualizados pelo método IDW, Krigagem e ADW, pela capacidade de representar as superfícies com pouca variação de chuva e pontualmente os eventos nos municípios em que houve precipitação (exceto pela Krigagem que suavizou a superfície, mas não perdeu desempenho). Na sequência os melhores interpoladores foram Vizinhos Naturais e TIN, que geraram uma espacialização semelhante ao método ADW. Já os métodos *Topo to Raster* e Spline espacializaram valores extremos em uma região maior do que a ocorrência, e por fim, Trend, subestimou muito as precipitações, obtendo um desempenho que não condiz com a realidade.

Na figura 24, os métodos IDW e Krigagem conseguiram bons desempenhos, principalmente por conseguir representar uma superfície constante onde não houve notável variação na média das precipitações, com destaque maior ao IDW que conseguiu representar as precipitações pontuais. Na sequência, os métodos com melhores desempenhos foram ADW, Vizinhos Naturais, *Topo to Raster*, TIN, Spline e Trend, pelos mesmos motivos da figura 20.

Já na Figura 25 os melhores desempenhos ficaram com os métodos ADW e IDW, onde conseguiram representar bem os eventos pontuais onde houve uma concentração de precipitação. Na sequência os melhores resultados foram obtidos por Krigagem, Vizinhos Naturais, TIN, Spline, *Topo to Raster* e Trend.

Esses resultados podem ter ocorrido devido às diferenças cruciais entre os métodos de interpolação. Começando pelo método do IDW, que é melhor em representar os locais onde

houve um maior acúmulo mensal de precipitação, também, devido à ponderação ($p=1$) utilizada nesta pesquisa, diminuindo a importância dos resultados mais distantes (Barbosa et al., 2014; Santos et al., 2020), além de obter os melhores resultados com certa frequência na literatura (CHEN & LIU, 2012; DAS et al., 2017; JAYA et al., 2021). Já o método ADW, tem sempre um desempenho semelhante ao IDW, devido ser uma variação deste método, ele é melhor em representar superfícies maiores, também sendo limitado a distância, neste caso angular, gerando um bom desempenho na espacialização de nuvens, mesmo com estações distribuídas de forma irregular (NEW et al., 2000; XAVIER et al., 2015).

Os métodos Krigagem Ordinária, Spline e Trend acabaram por gerar uma suavização na representação dos dados interpolados. Os métodos Krigagem e Trend acabam superestimando valores pequenos e subestimando os valores maiores, evitando a extrapolação de valores além do interior do domínio dos dados (YAMAMOTO, 2005; CASTRO et al., 2010). Isso ocorre devido aos métodos buscarem a variância mínima em suas estimativas (CRESSIE, 1983). Já o método Spline embora gera uma superfície suavizada, também pode gerar valores fora do domínio de amostragem (BRUBACHER et al., 2020). De modo geral, isso aumenta a assertividade em séries com dados mais homogêneos e diminui na presença de eventos extremos, nos três interpoladores.

O método Vizinho Natural, se baseia em criar polígonos para obtenção dos resultados, com bons desempenhos visuais, devido à metodologia intrínseca do método. Em contrapartida, numericamente não obteve bons resultados, semelhantemente ao que foi encontrado por Gardiman Junior et al. (2012) e Nogueira et al. (2020), isso pode ter ocorrido em detrimento do método utilizar apenas a estação pluviométrica mais próxima em cada direção é ponderada no processo de interpolação (BRUBACHER et al., 2020).

O método TIN possui limitações devido à triangulação gerar certa restrição neste método, principalmente quando realiza interpolação de pontos muito distantes entre si, gerando triângulos maiores, que não conseguem representar corretamente fenômenos naturais (BÖHNER & BECHTEL, 2018). O método Spline foca em gerar uma superfície ajustada a um polinômio específico, gerando uma grande suavização da superfície, que pode acabar deteriorando o resultado na ocorrência de eventos extremos (FARIAS et al., 2017; BORGES et al., 2016). O método *Topo to Raster*, utiliza o inverso da distância ponderada, porém, extrapola e generaliza a área de ocorrência de eventos extremos, prejudicando seus resultados (WIJEMANNAGE et al., 2016). Por fim, o método Trend, em tradução literal, superfície de tendência, faz uso de tendências regionais dos dados e visa minimização a variância da superfície em relação aos valores de entrada, ou seja, busca gerar uma superfície média do

local (Marteli & Piroli, 2015), contudo, mesmo que a média seja o valor mais próximo de todos os pontos, também pode nunca representar um valor real, devido à dificuldade de uma superfície média expressar dados com grande amplitude de valores.

6 CONCLUSÕES

Com base no presente trabalho foi possível eleger quais foram os melhores interpoladores espaciais, sendo IDW, TREND e ADW, respectivamente, seguidos por Vizinho Natural (*Natural Neighbor*), TIN, *Topo to Raster*, Krigagem e Spline. No geral, os resultados de todos os interpoladores não possuíram grandes variações nos índices REMQ, EAM e EPAM, em comparação com a base de dados CHIRPS.

Os dados espaciais interpolados foram disponibilizados online, na plataforma Mendeley Data: <http://dx.doi.org/10.17632/9939fxtprc.1>, em formato *raster*, com resolução espacial de 0,25km² (ou 250.000m²), possibilitando o uso destes mapas em quaisquer *softwares* GIS, de acordo com o interesse de cada pesquisador.

Em suma, o melhor método de interpolação espacial de chuvas foi o IDW, que conseguiu representar de forma mais adequada o fenômeno estudado (precipitação pluvial), de acordo com suas características sazonais.

REFERÊNCIAS

- ADHIKARY, S. K.; MUTTIL, N.; YILMAZ, A. G. Cokriging for enhanced spatial interpolation of rainfall in two Australian catchments. **Hydrological Processes**, v. 31, n. 12, 2017.
- ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C.; GONÇALVES, J. L. M.; SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2014.
- ANJOS, R. S.; CANDEIAS, A. L. B.; NÓBREGA, RANYÉRE SILVA. Mapeamento da Precipitação Estimada e Observada no Semiárido Pernambucano e sua relação com a Modelagem de Dados Espaciais. **Revista Brasileira de Cartografia**, v. 69, p. 447-462, 2017.
- ARAÚJO, L. E.; SOUSA, F. A. S.; RIBEIRO, M. A. F. M.; SANTOS, A. S.; MEDEIROS, P. C. Análise estatística de chuvas intensas na bacia hidrográfica do Rio Paraíba. **Revista Brasileira de Meteorologia**, v. 23, n. 2, p. 162-169, 2008.
- ArcGIS. **Understanding interpolation analysis**. Disponível em: <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/understanding-interpolation-analysis.htm>. Acesso em 20 mai. 2022.
- BARATTO, P. F. B. *et al.* Random Forest for spatialization of daily evapotranspiration (ET₀) in watersheds in the Atlantic Forest. **Environmental Monitoring and Assessment**, v. 194, n. 6, p. 449, 2022.
- BARBOSA, C. S. *et al.* EPIDEMIOLOGIA DA ESQUISTOSSOMOSE NO LITORAL DE PERNAMBUCO. **Revista de Patologia Tropical**, v. 43, n. 4, 2015.
- BERTONI, J.C.; TUCCI, C.E.M. **Precipitação**. In: Hidrologia ciência e aplicação. Porto Alegre: ABRH, 1993. p.177-242.
- BÖHNER, J.; BECHTEL, B. GIS in Climatology and Meteorology. **Comprehensive Geographic Information Systems**, v. 3, p. 196–235, 2018.
- BOLDRINI, I. I.; FERREIRA, P. M. A.; ANDRADE, B. O.; SCHNEIDER, A. A.; SETUBAL, R. B.; TREVISAN, R; FREITAS, E.M. **Bioma Pampa: diversidade florística e fisionômica**. Porto Alegre: editora Pallotti, 2010. 64 p.
- BORGES, P. de A. *et al.* Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal, Brazil. **Theoretical and Applied Climatology**, v. 123, n. 1–2, 2016.
- BRESSIANI, D. A.; SRINIVASAN, R.; JONES C. A.; MENDIONDO, E. M. Effects of spatial and temporal weather data resolutions on streamflow modeling of a semi-arid basin, Northeast **Brazil**. **Int J Agric & Biol Eng**, v.8, n.3, p.125-139, 2015.
- BRUBACHER, J. P.; OLIVEIRA, G. G. de; GUASSELLI, L. A. Preenchimento de Falhas e Espacialização de Dados Pluviométricos: Desafios e Perspectivas. **Revista Brasileira de Meteorologia**, v. 35, n. 4, p. 615–629, 2020.
- CAI, X. *et al.* Evaluation of Gridded Precipitation Data and Interpolation Methods for Forest Fire Danger Rating in Alberta, Canada. **Journal of Geophysical Research: Atmospheres**, v. 124, n. 1, 2019.

- CAI, Y.; ZHU, H. A local search algorithm for natural neighbours in the natural element method. **International Journal of Solids and Structures**, v. 42, n. 23, p. 6059–6070, 2005.
- CALDANA, N. F. S.; MARTELÓCIO, A. C.; RUDKE, A. P.; NITSCHKE, P. R. Eventos Extremos e variabilidade Pluviométrica em Londrina – PR: Estudo de caso das Chuvas de 11 de janeiro de 2016. **Geografia em Questão**, v. 12, n. 2, 2019.
- CALDEIRA, T. L. *et al.* Modelagem probabilística de eventos de precipitação extrema no estado do Rio Grande do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 19, n. 3, p. 197–203, 2015.
- CÂMARA, G.; DAVIS, C.; MONTEIRO, A. M. V. **Introdução à Ciência da Geoinformação**. São José dos Campos: INPE, 2001.
- CÂMARA, G.; MEDEIROS, J. S. **Princípios básicos em geoprocessamento**. In: Sistemas de informações geográficas: aplicações na agricultura. 2. ed. ver. ampl. Brasília, DF: Embrapa-SPI: Embrapa-CPAC, pp.3-11, 1998.
- CAMARGO, E.; DRUCK, S.; CÂMARA, G. Análise de Superfícies por Geoestatística Linear. In: DRUCK, Suzana; CARVALHO, Marília Sá; CÂMARA, Gilberto; MONTEIRO, Antônio Miguel Vieira (ed.). **Análise Espacial de Dados Geográficos**. Brasília: Embrapa, 2004. Cap. 3.
- CAMARGO, L. de S. *et al.* Map of areas susceptible to forest fires in the municipality of petrópolis–RJ. **Anuario do Instituto de Geociencias**, v. 42, n. 1, 2019.
- CAMERA, C. *et al.* Evaluation of interpolation techniques for the creation of gridded daily precipitation (1×1 km²); Cyprus, 1980–2010. **Journal of Geophysical Research**, v. 119, n. 2, 2014.
- CARDOSO, J. T. A Mata Atlântica e sua conservação. **Revista Encontros Teológicos**, v. 31, n. 3, 2016.
- CARDOSO, M. R. D.; MARCUZZO, F. F. N.; BARROS, J. R. Climatic Classification of Köppen-Geiger for the State of Goiás and Federal District. **Acta Geográfica**, v. 8, n. 16, 2014.
- CARMO, E. J.; RODRIGUES, D. D.; DOS SANTOS, G. R. Avaliação dos interpoladores krigagem e topo to raster para geração de modelos digitais de elevação a partir de um “as built”. **Boletim de Ciências Geodesicas**, v. 21, n. 4, 2015.
- CARVALHO, D. F.; MELLO, J. L. P.; SILVA, L. D. B. **Hidrologia**. IT 115 – Irrigação e Drenagem. 2007. 86p.
- CARVALHO, J. R. P. de; ASSAD, E. D.; PINTO, H. S. Interpoladores geoestatísticos na análise da distribuição espacial da precipitação anual e de sua relação com altitude. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1235–1242, 2012.
- CARVALHO, M. S.; CÂMARA, G. Análise de Eventos Pontuais. In: DRUCK, Suzana; CARVALHO, Marília Sá; CÂMARA, Gilberto; MONTEIRO, Antônio Miguel Vieira (ed.). **Análise Espacial de Dados Geográficos**. Brasília: Embrapa, 2004. Cap. 2.
- CASTRO, F. da S. *et al.* Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 8, 2010.

- CECCHERINI, G. *et al.* High-resolution precipitation datasets in South America and West Africa based on satellite-derived rainfall, enhanced vegetation index and digital elevation model. **Remote Sensing**, v. 7, n. 5, 2015.
- CERÓN, W. L. *et al.* Comparison of spatial interpolation methods for annual and seasonal rainfall in two hotspots of biodiversity in South America. **Anais da Academia Brasileira de Ciências**, v. 93, n. 1, 2021.
- CHAKRAVARTY, P.; KUMAR, M. Floral Species in Pollution Remediation and Augmentation of Micrometeorological Conditions and Microclimate: An Integrated Approach. **Phytomanagement of Polluted Sites: Market Opportunities in Sustainable Phytoremediation**, p. 203–219, 2019.
- CHEN, T. *et al.* Comparison of spatial interpolation schemes for rainfall data and application in hydrological modeling. **Water (Switzerland)**, v. 9, n. 5, 2017.
- CHEN, F. W.; LIU, C. W. Estimation of the spatial rainfall distribution using inverse distance weighting (IDW) in the middle of Taiwan. **Paddy and Water Environment**, v. 10, n. 3, 2012.
- CHILDS, C. Interpolating Surfaces in ArcGIS Spatial Analyst, **ArcUser**, p.32-35, 2004.
- CONCEIÇÃO, M. M.; CONCEICAO, J. T. P.; FIRIGATO, E. IMPORTANTES BIOMAS QUE DEVEM SER PROTEGIDOS DA MATA ATLANTICA. **Agroecologia no Semiárido**, v. 4, p. 77-97, 2020.
- CORREIA, A. C. S.; SÁ, L. A.C. M. Mapas mentais na construção do conhecimento para geração de bases de dados espaciais. **Boletim de Ciências Geodésicas**, v.16, n.1, 2010.
- CRESSIE, N. Kriging Nonstationary Data. **Journal of the American Statistical Association**, v. 81, n. 395, 1986.
- CRUZ, P.; SOUZA, J.; PAGANI, C. ANÁLISE AMBIENTAL A PARTIR DO NOVO CÓDIGO FLORESTAL BRASILEIRO DE 12.651/12: UM ESTUDO DA ÁREA DE PRESERVAÇÃO PERMANENTE NA BACIA HIDROGRÁFICA DO RIO JARU NO MUNICÍPIO DE JARU-RO. v. 03, p. 513–536, 2017.
- DAMKJAER, S.; TAYLOR, R. **The measurement of water scarcity: Defining a meaningful indicator**. 2017.
- DAS, M. *et al.* Comparison of spatial interpolation methods for estimation of weekly rainfall in West Bengal, India. **Mausam**, v. 68, n. 1, 2017.
- DEVELEY, P. F.; SETUBAL, R. B.; DIAS, R. A.; BENCKE, G. A. Conservação das aves e da biodiversidade no bioma Pampa aliada a sistemas de produção animal. **Revista Brasileira de Ornitologia**, v. 16, n. 4, p. 308-315, 2008.
- DIEULIN, C. *et al.* A new 60-year 1940/1999 monthly-gridded rainfall data set for Africa. **Water (Switzerland)**, v. 11, n. 2, 2019.
- DINIS, L. M.J.S.; NATAL JORGE, R. M.; BELINHA, J. A natural neighbour meshless method with a 3D shell-like approach in the dynamic analysis of thin 3D structures. **Thin-Walled Structures**, v. 49, n. 1, p. 185–196, 2011.
- DINIZ, A. M. A. **Geoprocessamento: Estatística Espacial**. Belo Horizonte: UFMG, 2000. 15p.

DINKU, T.; FUNK, C.; PETERSON, P.; MAIDMENT, R.; TADESSE, T.; GADAIN, H.; CECCATO, P. Validation of the CHIRPS satellite rainfall estimates over eastern Africa **Q. J. R. Meteorol. Soc.**, v.144, p.292-312, 2018.

DUAN, Z. *et al.* Evaluation of eight high spatial resolution gridded precipitation products in Adige Basin (Italy) at multiple temporal and spatial scales. **Science of The Total Environment**, v. 573, p. 1536–1553, 2016.

DUARTE, L.; QUEIRÓS, C.; TEODORO, A. C. Comparative analysis of four QGIS plugins for web maps creation. **Granja**, v. 34, n. 2, 2022.

DUARTE, M. L.; SILVA FILHO, E. P. da. Estimativa da erosividade da chuva na bacia hidrográfica do rio Juma com base em dados do satélite TRMM / Estimation of rain erosion in the Juma river basin based on TRMM satellite data. **Caderno de Geografia**, v. 29, n. 56, 2019.

ECHER, R. *et al.* Usos da terra e ameaças para a conservação da biodiversidade no bioma Pampa, Rio Grande do Sul. **Revista Thema**, v. 12, n. 2, 2016.

EMBRAPA. Empresa Brasileira de Pesquisa Agropecuária. **Clima**. Disponível em: <https://www.cnpf.embrapa.br/pesquisa/efb/clima.htm>. Acesso em 18 mai. 2022.

ESRI. **How Topo to Raster works**. Disponível em: <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/3d-analyst/how-topo-to-raster-works.htm>. Acesso em 20 mai. 2022.

ESRI. **How Trend works**. Disponível em: <https://pro.arcgis.com/en/pro-app/2.8/tool-reference/spatial-analyst/how-trend-works.htm#:~:text=The%20Trend%20tool%20uses%20a,scale%20patterns%20in%20the%20data>. Acesso em 20 mai. 2022a.

FARIAS, O. G.; FRANCISCO, C. N.; SENNA, M. C. A. AVALIAÇÃO DE MÉTODOS DE INTERPOLAÇÃO ESPACIAL APLICADOS À PLUVIOSIDADE EM REGIÃO MONTANHOSO NO LITORAL SUL DO ESTADO RIO DE JANEIRO. **Revista Brasileira de Climatologia**, v. 21, 2017.

FENG, R.; PENG, S. Quasi-interpolation scheme for arbitrary dimensional scattered data approximation based on natural neighbors and RBF interpolation. **Journal of Computational and Applied Mathematics**, v. 329, p. 95–105, 2018.

FEPAM. Fundação Estadual de Proteção Ambiental Henrique Luis Roessler. **U090 IJUÍ**. Disponível em: http://www.fepam.rs.gov.br/qualidade/bacia_uru_ijui.asp. Acesso em 16 mai. 2022.

FERREIRA FILHO, D. F. *et al.* APLICAÇÃO DE TÉCNICAS DE INTERPOLAÇÃO PARA ESPACIALIZAÇÃO DE CHUVAS DA REDE HIDROGRÁFICA: ESTUDO DE CASO CALHA NORTE – PA. **Revista Brasileira de Climatologia**, v. 24, 2019.

FERREIRA, N. C. **Apostila de Sistema de Informações Geográficas**. Goiânia: CEFET-GO, 2006. 111p.

FLETCHER, S. J. Introduction to Semi-Lagrangian Advection Methods. **Data Assimilation for the Geosciences**, p. 361–441, 2017.

FRAGA, Y. S. B.; DORTAS, I. S.; MOTA, W. V.; COSTA CASTRO, C. K.; PEREIRA SANTOS, L. H. A Influência da Evapotranspiração na Engenharia Civil. **Caderno de Graduação - Ciências Exatas e Tecnológicas - UNIT**, v. 3, n. 3, 2016.

FRANKE, R. Smooth interpolation of scattered data by local thin plate splines. **Computers and Mathematics with Applications**, v. 8, n. 4, 1982.

FUNG, K. F. *et al.* Evaluation of spatial interpolation methods and spatiotemporal modeling of rainfall distribution in Peninsular Malaysia. **Ain Shams Engineering Journal**, v. 13, n. 2, p. 101571, 2022.

FUNK, C. *et al.* The climate hazards infrared precipitation with stations - A new environmental record for monitoring extremes. **Scientific Data**, v. 2, 2015.

GAO, F. *et al.* Evaluation of CHIRPS and its application for drought monitoring over the Haihe River Basin, China. **Natural Hazards**, v. 92, n. 1, 2018.

GARDIMAN JUNIOR, B. S. *et al.* Análise de técnicas de interpolação para espacialização da precipitação pluvial na bacia do rio Itapemirim (ES) / Analysis of interpolation techniques for spatial rainfall distribution in river basin Itapemirim (ES). **Revista Ambientia**, v. 8, n. 1, 2012.

GASPARRINI, A. *et al.* Projections of temperature-related excess mortality under climate change scenarios. **The Lancet Planetary Health**, v. 1, n. 9, p. e360–e367, 2017.

GHERARDI, Bruno. **Caracterização espacial e temporal de parâmetros climáticos no estado de Mato Grosso**. 2008. 120 f. Dissertação (Mestrado) - Curso de Mestrado em Agronomia, Escola Superior de Agricultura “Luiz de Queiroz”, Universidade de São Paulo, Piracicaba, 2008.

GIMOND, M. **Intro to GIS and Spatial Analysis**. 2022. Disponível em: <https://mgimond.github.io/Spatial/spatial-interpolation.html>. Acesso em 20 mai. 2022.

GOLLEDGE, N. R. Long-term projections of sea-level rise from ice sheets. **Wiley Interdisciplinary Reviews: Climate Change**, v. 11, n. 2, 2020.

GOLLFARI, L.; CASER, R. L.; MOURA, V. P. G. Zoneamento ecológico esquemático para reflorestamento no Brasil: segunda aproximação. **Série técnica PRODEPEF**, n.11, p.1-66, 1978.

GOSLING, S. N.; ARNELL, N. W. A global assessment of the impact of climate change on water scarcity. **Climatic Change**, v. 134, n. 3, 2016.

HARRISON, L.; LANDSFELD, M.; HUSAK, G.; DAVENPORT, F.; SHUKLA, S.; TURNER, W.; PETERSON, P.; FUNK, C. Advancing early warning capabilities with CHIRPS-compatible NCEP GEFS precipitation forecasts. **Sci Data**, v.9, n.375, 2022.

HARTMANN, M.; MOALA, F. A.; MENDONÇA, M. A. Estudo das precipitações máximas anuais em Presidente Prudente. **Revista Brasileira de Meteorologia**, v. 26, n. 4, 2011.

HAYES, K., BLASHKI, G., WISEMAN, J. *et al.* Climate change and mental health: risks, impacts and priority actions. **International Journal of Mental Health Systems**, v.12, n.28 2018. <https://doi.org/10.1186/s13033-018-0210-6>.

HE, J. *et al.* The first high-resolution meteorological forcing dataset for land process studies over China. **Scientific Data**, v. 7, n. 1, 2020.

HOFSTRA, N.; NEW, M. Spatial variability in correlation decay distance and influence on angular-distance weighting interpolation of daily precipitation over Europe. **International Journal of Climatology**, v. 29, n. 12, 2009.

HUTCHINSON, M. F.; STEIN, JOHN A.; STEIN, JANET L.; XU, T. Locally Adaptive Gridding of Noisy High Resolution Topographic Data. **18th World IMACS / MODSIM Congress**, 2009.

HUTCHINSON, M. F. A new procedure for gridding elevation and stream line data with automatic removal of spurious pits. **Journal of Hydrology**, v.106, p.211-232, 1989

IBGE, Instituto Brasileiro de Geografia e Estatística. **Território**. 2004. Disponível em < <https://brasilemsintese.ibge.gov.br/territorio.html>>. Acesso em 20 mai. 2022.

INGLEZAKIS, V. J. *et al.* Aquatic Environment. **Environment and Development**, p. 137-212, 2016.

IPCC. Intergovernmental Panel on Climate Change. **Contribution of working group I to the fourth assessment report of the intergovernmental panel on climate change**. In: Solomon S, Qin D, Manning M, Chen Z, Marquis M, et al., editors. Cambridge: Cambridge Univ Press, 2007.

JACQUIN, A. P.; SOTO-SANDOVAL, J. C. Interpolation of monthly precipitation amounts in mountainous catchments with sparse precipitation networks. **Chilean Journal of Agricultural Research**, v. 73, n. 4, 2013.

JAYA, I. G.N.M. *et al.* Comparison of IDW and GP models with application to spatiotemporal interpolation of rainfall in Bali Province, Indonesia. *In: , 2021. Journal of Physics: Conference Series*, 2021.

JEHANZAI, M. *et al.* Investigating effect of climate change on drought propagation from meteorological to hydrological drought using multi-model ensemble projections. **Stochastic Environmental Research and Risk Assessment**, v. 34, n. 1, 2020.

JESUS, J. B. *et al.* Analysis of the temporal, spatial and trend incidence of fire in biomes and conservation units of Brazil. **Ciencia Florestal**, v. 30, n. 1, 2020.

JIANG, S. *et al.* Comprehensive evaluation of multi-satellite precipitation products with a dense rain gauge network and optimally merging their simulated hydrological flows using the Bayesian model averaging method. **Journal of Hydrology**, v. 452–453, 2012.

KATSANOS, D.; RETALIS, A.; MICHAELIDES, S. Validation of a high-resolution precipitation database (CHIRPS) over Cyprus for a 30-year period, **Atmospheric Research**, v.169, p.459-464, 2016.

KAZMI, F. A. *et al.* Ecological impacts of climate change on the snow leopard (*Panthera unica*) in South Asia. **Brazilian Journal of Biology**, v. 82, 2022.

KHANAL, S.; FULTON, J.; SHEARER, S. An overview of current and potential applications of thermal remote sensing in precision agriculture, **Computers and Electronics in Agriculture**, v. 139, 2017.

KODONG, F. R.; FAJAR, J. Prediction of wind disaster using kriging spatial interpolation and internet of things. *In: , 2019. IOP Conference Series: Materials Science and Engineering*. 2019.

KULMATOV, R. *et al.* Assessment of the Space-Time Dynamics of Soil Salinity in Irrigated Areas Under Climate Change: a Case Study in Sirdarya Province, Uzbekistan. **Water, Air, and Soil Pollution**, v. 232, n. 5, 2021.

LAM, N. S. Spatial Interpolation. **International Encyclopedia of Human Geography**, p.

369-376, 2009.

LAM, K. C.; BRYANT, R. G.; WAINRIGHT, J. Application of spatial interpolation method for estimating the spatial variability of rainfall in Semiarid New Mexico, USA. **Mediterranean Journal of Social Sciences**, v. 6, n. 4S3, 2015.

LANDIM, P.M.B. **Introdução aos métodos de estimação espacial para confecção de mapas**. Rio Claro: UNESP, 2000. 20p.

LANDIM, P. M. B. **Análise estatística de dados geológicos**. 2ed. São Paulo: Unesp, 2003. 154p.

LAURINI, R. Geographic Objects. **Geographic Knowledge Infrastructure**, p.61–82, 2017.

LIANG, S.; WANG, J. **Advanced Remote Sensing: Terrestrial Information Extraction and Applications**. 2ed. Cambridge: Academic Press, 2020. 1010p.

LIMBERGER, L.; SILVA, M. E. S. PRECIPITAÇÃO OBSERVADA NA AMAZÔNIA BRASILEIRA: REDES CONVENCIONAIS E DADOS DA REANÁLISE I DO NCEP/NCAR, CRU E GPCC. **Revista Brasileira de Climatologia**, v. 22, 2018.

LIU, X. *et al.* Evaluating the streamflow simulation capability of PERSIANN-CDR daily rainfall products in two river basins on the Tibetan Plateau. **Hydrology and Earth System Sciences**, v. 21, n. 1, 2017.

LONGLEY, P.A.; GOODCHILD, M.F.; MAGUIRE, D.J.; RHIND, D.W. **Sistemas e ciência da informação geográfica**. Porto Alegre: Bookman, 2013. 540p.

LUCAS, T.P.B.; PLEC, D.; ABREU, M. L.; PARIZZI, M. G. Identificação de interpoladores adequados a dados de chuva a partir de parâmetros estatísticos. **Revista Brasileira de Climatologia**, v.13, p.7-21, 2013.

LUNDGREN, W. J. C.; DA SILVA, J. A. A.; FERREIRA, R. L. C. Estimating of the Volume of Eucalyptus with Kriging and Cokriging in Semi-arid of Pernambuco. **Floresta e Ambiente**, v. 24, 2017.

MACHADO, N. G. *et al.* ESTIMATION OF RAINFALL BY NEURAL NETWORK OVER A NEOTROPICAL REGION (ESTIMATIVA DE CHUVAS PELA REDE NEURAL SOBRE A REGIÃO NEOTROPICAL). **Revista Brasileira de Climatologia**, v. 17, 2015.

MADSEN, H. *et al.* Review of trend analysis and climate change projections of extreme precipitation and floods in Europe. **Journal of Hydrology**, v. 519, n. PD, 2014.

MAINAR DE MEDEIROS, R. *et al.* COMPARATIVO DA EROSIVIDADE PLUVIAL NO PERÍODO 1980-2017 COM O ANO 2017 EM CABO DE SANTO AGOSTINHO - PE, BRASIL. **RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218**, v. 3, n. 1, 2021.

MANCOSU, N. *et al.* Water Scarcity and Future Challenges for Food Production. **Water**, v. 7, n. 3, p. 975–992, 2015.

MARCHI, M. M. *et al.* Herbaceous and subshrubby flora associated with palm grove ecosystem in the Pampas Biome. **Rodriguesia**, v. 69, n. 2, 2018.

MARCUZZO, F. F. N.; CARDOSO, M. R. D.; MELLO, L. T. A. Uso dos Métodos de Krigagem e Spline de Tensão no Mapeamento de Chuvas na Região Metropolitana de Goiânia e Seu Entorno. **Repositório Institucional de Geociências**, v. 1. p. 128-128, 2010.

- MARCUZZO, F.; ANDRADE, L.; MELO, D. Métodos de Interpolação Matemática no Mapeamento de Chuvas do Estado do Mato Grosso (Interpolation Methods in Mathematics of Rainfall Mapping of the State of Mato Grosso). **Revista Brasileira de Geografia Física**, v. 4, n. 4, 2012.
- MARENGO, J. A.; NOBRE, C. A.; SELUCHI, M. E.; CUARTAS, A.; ALVES, L. M.; MENDIONDO, E. M.; OBREGÓN, G.; SAMPAIO, G. A seca e a crise hídrica de 2014-2015 em São Paulo. **Revista USP**. n. 106, p. 31-44, 2015.
- MARQUES, J.; PINHEIRO, F. M. A.; MONTANHA, A. C. F. E.; VIANNA, L. G. Estudo das chuvas na região salineira do Estado do Rio de Janeiro. **Geografia**, v. 4, n.1, p. 7-25, 1999.
- MARQUES, M. C. M.; LINS-E-SILVA, A. C. B.; RAJAO, H.; ROSADO, B. H. P.; BARROS, C. F.; OLIVEIRA, J. A.; FINOTTI, R.; NECKEL-OLIVEIRA, S.; AMORIM, A. M. A.; CERQUEIRA, R.; BERGALLO, H. G. Mata Atlântica - O desafio de transformar um passado de devastação em um futuro de conhecimento e conservação. In: **Conhecendo a biodiversidade. Brasília: PPBio**, 2016, p. 50-67.
- MARQUES, M. L.; SILVA, M. C.; DE CAMARGO, D. M. ANÁLISE GEOESPACIAL NO MAPEAMENTO DA VULNERABILIDADE SOCIOAMBIENTAL EM CAMPINAS, SP. **Revista Brasileira de Cartografia**, v. 69, n. 9, 2018.
- MARSHALL, S. J. Hydrology. **Reference Module in Earth Systems and Environmental Sciences**, 2013.
- MARTELI, A. N.; PIROLI, E. L. Análise do desempenho de interpoladores para a elaboração de mapas de pH para a agricultura familiar. **Revista Brasileira de Tecnologia Aplicada nas Ciências Agrárias**, v. 8, 2015.
- MARTENS, W. J. M. **Health impacts of climate change and ozone depletion: An ecoepidemiologic modeling approach**. 1998.
- MATEI, A. P.; FILIPPI, E. E. O bioma pampa e o desenvolvimento socioeconômico em Santa Vitória do Palmar. **Ensaio FEE**, v. 34, p. 739-764, 2013.
- MAZZINI, P. L. F.; SCHETTINI, C. A. F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quase-sinóticos. **Brazilian Journal of Aquatic Science and Technology**, v. 13, n. 1, 2009.
- MEKONNEN, M. M.; HOEKSTRA, A. Y. Sustainability: Four billion people facing severe water scarcity. **Science Advances**, v. 2, n. 2, 2016.
- MELLO, Y. R. de; KOHLS, W.; OLIVEIRA, T. M. N. de. USO DE DIFERENTES MÉTODOS PARA O PREENCHIMENTO DE FALHAS EM ESTAÇÕES PLUVIOMÉTRICAS. **Boletim de Geografia**, v. 35, n. 1, 2017.
- MELLO, C. R. de; SILVA, A. M. da. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, n. 1, 2009.
- MENDEZ, M. *et al.* Generation of monthly precipitation climatologies for Costa Rica using irregular rain-gauge observational networks. **Water (Switzerland)**, v. 11, n. 1, 2019.
- MIRANDA, R. A. C.; S. O., M. V.; Ferreira S. D. Ciclo Hidrológico Planetário: abordagens e conceitos. **Geo UERJ**, v. 1, p. 109-119, 2010.

MITÁŠ, L.; MITÁŠOVÁ, H. General variational approach to the interpolation problem. **Computers and Mathematics with Applications**, v. 16, n. 12, 1988.

MMA. Ministério do Meio Ambiente. **Mata Atlântica**. Disponível em: https://www.mma.gov.br/estruturas/202/_arquivos/adequao_ambiental_publicacao_web_202.pdf. Acesso em: 20 mai. 2022.

MOON, T. *et al.* **Rising Oceans Guaranteed: Arctic Land Ice Loss and Sea Level Rise**. 2018.

MORAES, B. C.; SODRÉ, G. R. C.; SOUZA, E. B.; RIBEIRO, J. B. M.; FILHO, L. G. M.; FERREIRA, D. B. S.; OLIVEIRA, J. V. Climatologia da precipitação na Amazônia. **Revista Brasileira de Geografia Física**, Recife, v. 8 n. 5, p. 1359-1373, 2015.

MOREIRA, S. *et al.* Análise de vigas laminadas utilizando o natural neighbour radial point interpolation method. **Revista Internacional de Métodos Numéricos para Cálculo y Diseño en Ingeniería**, v. 30, n. 2, p. 108–120, 2014.

MOSS, R.; EDMONDS, J.; HIBBARD, K. *et al.* The next generation of scenarios for climate change research and assessment. **Nature**, v.463, p.747–756, 2010. <https://doi.org/10.1038/nature08823>.

MOURA, M. S. B.; GALVÍNCIO, J. D.; BRITO, L. T. L.; SOUZA, L. S.B.; SÁ, I. I. S.; SILVA, T. G. F. **Clima e água de chuva no Semi-Árido**. In: **Potencialidades da água de chuva no Semi-Árido brasileiro**. 1ed. Petrolina: Embrapa Semi-Árido, 2007, v.1, p.37-59.

NASTOS, P. T.; KAPSOMENAKIS, J.; PHILANDRAS, K. M. Evaluation of the TRMM 3B43 gridded precipitation estimates over Greece. **Atmospheric Research**, v. 169, p. 497–514, 2016.

NEW, M.; HULME, M.; JONES, P. Representing twentieth-century space-time climate variability. Part II: Development of 1901-96 monthly grids of terrestrial surface climate. **Journal of Climate**, v. 13, n. 13, 2000.

NGOMA, H.; WEN, W.; OJARA, M.; AYUGI, B. Assessing current and future spatiotemporal precipitation variability and trends over Uganda, East Africa, based on CHIRPS and regional climate model datasets. **Meteorol Atmos Phys**, v.133, p.823–843, 2021.

NOGUEIRA, D. B.; DA SILVA, A. O.; DA SILVA, A. P. N. Comparison of spatial interpolation methods for the estimation of precipitation distribution in Ceará-Brazil. **IRRIGA**, v. 25, n. 1, 2020.

OLIVEIRA, L. F. C.; FIOREZE, A. P.; MEDEIROS, A. M. M.; SILVA, M. A. S. Comparação de metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, n.11, p.1186–1192, 2010.

PAVÃO, C. G. *et al.* Spatial Interpolation Applied a Crustal Thickness in Brazil. **Journal of Geographic Information System**, v. 04, n. 02, 2012.

PAZ, A. R. **Hidrologia Aplicada**. 1ed. Caxias do Sul: UFRGS, 2004. 138p.

PENHA, A. de L. T.; COELHO, V. B. N. Simulação de Monte Carlo em redes triangulares irregulares / Monte Carlo simulation in triangular irregular networks. **Brazilian Journal of Development**, v. 7, n. 10, 2021.

PEREIRA, A. R.; ANGELOCCI, L. R.; SENTELHAS, P. C. **Meteorologia Agrícola**.

Piracicaba: USP, 2007, 192p.

PESSI, D. D. *et al.* Validação das estimativas de precipitação do satélite TRMM no Estado de Mato Grosso, Brasil. **Revista de Ciências Agrárias**, v. 42, n. 1, 2019.

PEZZONI-FILHO, J. C. *et al.* Meloidogyne exigua (Meloidogynidae) in rubber tree clones during two periods of the year. **Corpoica Ciencia y Tecnologia Agropecuaria**, v. 19, n. 3, 2018.

PIANOSI, F.; WAGENER, T. Understanding the time-varying importance of different uncertainty sources in hydrological modelling using global sensitivity analysis. **Hydrological Processes**, v. 30, n. 22, 2016.

PINHEIRO, F. da S. *et al.* Precipitation and air temperature numerical simulations through ETA/CPTEC-HADCM3 model in Rio de Janeiro. **Revista Brasileira de Geografia Física**, v. 13, n. 5, 2020.

PIROLI, E. L. **Introdução ao Geoprocessamento**. Ourinhos: Unesp, 2010. 46p.

QGIS. **Spatial Analysis (Interpolation)**. Disponível em: https://docs.qgis.org/2.18/en/docs/gentle_gis_introduction/spatial_analysis_interpolation.html. Acesso em: 21 mai. 2022.

RATA, M. *et al.* Comparison of geostatistical interpolation methods to map annual rainfall in the Chélif watershed, Algeria. **Theoretical and Applied Climatology**, v. 141, n. 3–4, 2020.

ROBERTSON, D. M.; PERLMAN, H. A.; NARISIMHAN, T. N. Hydrological Cycle and Water Budgets. **Encyclopedia of Inland Waters**, p. 19–27, 2022.

ROMERO, H. A. I.; ORTIZ, L. F. AJUSTE METODOLÓGICO AL ÍNDICE DE ESCASEZ DE AGUA PROPUESTO POR EL IDEAM EN EL PLAN DE ORDENACIÓN Y MANEJO DE LA CUENCA DEL RÍO PAMPLONITA, NORTE DE SANTANDER, COLOMBIA. **Colombia Forestal**, v. 11, n. 1, p. 165–173, 2008.

ROSA, L. *et al.* Global agricultural economic water scarcity. **Science Advances**, v. 6, n. 18, 2020.

SALDANHA, C. B. *et al.* Comparação dos dados de precipitação gerados pelo gpcp vs observados para o estado do Rio Grande do Sul. **Revista Brasileira de Meteorologia**, v. 30, n. 4, 2015.

SALVIANO, M. F.; GROppo, J. D.; PELLEGRINO, G. Q. Análise de tendências em dados de precipitação e temperatura no Brasil. **Revista Brasileira de Meteorologia**, v. 31, n. 1, 2016.

SANCHES, F. de O.; VERDUM, R.; FISCH, G. Estudo de tendência de chuvas de longo prazo. **Revista Ambiente e Água**, v. 8, n. 3, 2013.

SANTOS, A. R. **Climatologia**. 1ed. Vitória: UFES, 2002. 244p.

SANTOS, B. C. *et al.* ANÁLISE DO EFEITO OROGRÁFICO POR MEIO DA INTERPOLAÇÃO DE ÍNDICES CLIMÁTICOS. **Revista de Geografia - PPGeo - UFJF**, v. 8, n. 2, 2019.

SANTOS, L. O. F. dos *et al.* Validation of rainfall data estimated by GPM satellite on Southern Amazon region. **Revista Ambiente e Água**, v. 14, n. 1, 2019.

SANTOS, T.; SANTOS, L. Putting in Check the Brazilian Moves in the Climate Chessboard. **Contexto Internacional**, v. 43, n. 1, p. 99–119, 2021.

SARAIVA, G. S.; BONOMO, R.; DE SOUZA, J. M. Avaliação de interpoladores geoestatísticos e determinísticos da evapotranspiração de referência diária para o estado do Espírito Santo. **REVISTA AGRO@MBIENTE ON-LINE**, v. 11, n. 1, 2017.

SCHEREN, R. S.; ROBAINA, L. E. de S. Classificação geomorfométrica da bacia hidrográfica do rio Ijuí, RS. **Geografia Ensino & Pesquisa**, v. 23, 2019.

SCHNEIDER, U. *et al.* The new portfolio of global precipitation data products of the Global Precipitation Climatology Centre suitable to assess and quantify the global water cycle and resources. *In:* , 2016. **Proceedings of the International Association of Hydrological Sciences**. 2016.

SCHUMACHER, R. S. The studies of precipitation, flooding, and rainfall extremes across disciplines (SPREAD) workshop: An interdisciplinary research and education initiative. *In:* , 2016. **Bulletin of the American Meteorological Society**. 2016.

SCHUMACHER, V.; JUSTINO, F.; FERNÁNDEZ, A.; MESEGUER'RUIZ, O.; SARRICOLEA, P.; COMIN, A.; VENANCIO, L. P.; ALTHOFF, D. Comparison between observations and gridded datasets over complex terrain in the Chilean Andes: precipitation and temperature. **International Journal of Climatology**, v.1, 2020.

SEKULIĆ, A. *et al.* Random forest spatial interpolation. **Remote Sensing**, v. 12, n. 10, 2020.

SEMARS. Secretaria do Meio Ambiente e Infraestrutura do Rio Grande do Sul. **U090 - Bacia Hidrográfica do Rio Ijuí**. Disponível em: <https://sema.rs.gov.br/u090-bh-ijui#:~:text=A%20Bacia%20Hidrogr%C3%A1fica%20do%20Rio,est%C3%A3o%20no%20final%20desta%20p%C3%A1gina>. Acesso em 16 mai. 2022.

SHEPARD, D. A two-dimensional interpolation function for irregularly-spaced data. *In:* , 1968. **Proceedings of the 1968 23rd ACM National Conference, ACM 1968**. 1968.

SHRESTHA, U.B.; GAUTAM, S.; BAWA, K.S. Widespread climate change in the Himalayas and associated changes in local ecosystems. **PLoS One**, v.7, n.5, 2012.

SIBSON, R. A vector identity for the dirichlet tessellation. **Mathematical Proceedings of the Cambridge Philosophical Society**, v. 87, n. 1, 1980.

SIBSON, R. **Interpolating Multivariate Data: Chapter 2: A Brief Description of Natural Neighbor Interpolation**, Nova York: John Wiley & Sons, 1981. p.21-36.

SILVA, E. C.; CABRAL, J. J. S. P.; FERNANDES, R. C.; GUSMÃO, L. O.; AZEVEDO, J. R. G. Spatial variability of precipitation correlated with relief in Recife metropolitan region and surrounding areas. **J. Hyperspectral Remote Sens**. v.6, p.225-234, 2016.

SILVA, É. L. *et al.* A escassez hídrica na zona rural: o consumo de água sob a perspectiva dos agricultores de um assentamento no município de Pombal-PB. **Research, Society and Development**, v. 8, n. 6, p. 1–14, 2019.

SILVA, C. B. *et al.* PRECIPITAÇÃO NA AMÉRICA DO SUL – DADOS OBTIDOS POR ESTAÇÕES METEOROLÓGICAS AUTOMÁTICAS E POR SISTEMAS ORBITAIS. **Revista Brasileira de Climatologia**, v. 25, 2019.

SILVA, J. G. M. da; VILELA, L. O.; SILVA, J. M. S. da. Espécies frutíferas nativas do bioma Mata Atlântica: Panorama dos estudos sobre a temática no período de 2014 - 2021. **Research**,

Society and Development, v. 11, n. 3, 2022.

SINGH, A. A.; SINGH, A. K. Climatic controls on water resources and its management: challenges and prospects of sustainable development in Indian perspective. **Water Conservation in the Era of Global Climate Change**, p. 121–145, 2021.

SOBRAL, Maria do Carmo Martins et al. Impacto das Mudanças Climáticas nos recursos Hídricos no submédio da Bacia Hidrográfica do rio São Francisco – Brasil. **REDE - Revista Eletrônica do PRODEMA**, Fortaleza, v. 12, n. 03, p. 95-106, ago. 2018.

SOLAZZI, M.; UNCINI, A. Artificial neural networks with adaptive multidimensional spline activation functions. *In*: 2000. **Proceedings of the International Joint Conference on Neural Networks**. 2000.

SPRING. **Introdução ao Geoprocessamento**. Disponível em: http://www.dpi.inpe.br/spring/portugues/tutorial/introducao_geo.html . Acesso em: 23 jul. 2022.

STEDUTO, Pasquale et al. AquaCrop—The FAO Crop Model to Simulate Yield: Response to Water: I. Concepts and Underlying Principles. **Agronomy Journal**, v. 101, n. 3, p. 426-437, 2009.

STEINKE, E. T. **Climatologia Fácil**. São Paulo: Oficina de Textos, 2012. 144p.

SUN, Q. *et al.* A Review of Global Precipitation Data Sets: Data Sources, Estimation, and Intercomparisons. **Reviews of Geophysics**, v. 56, n. 1, 2018.

TAIT, A.; WOODS, R. Spatial interpolation of daily potential evapotranspiration for New Zealand using a spline model. **Journal of Hydrometeorology**, v. 8, n. 3, 2007.

TAPIADOR, F. J.; TURK, F. J.; PETERSEN, W.; HOU, A. Y.; GARCÍA-ORTEGA, E.; MACHADO, L.A.T.; ANGELIS, C. F.; SALIO, P.; KIDD, C.; HUFFMAN, G. J.; CASTRO, M. Global precipitation measurement: Methods, datasets and applications, **Atmospheric Research**, v.105, p.70-97, 2012.

TEEGAVARAPU, R. S. V. *et al.* Infilling missing precipitation records using variants of spatial interpolation and data-driven methods: use of optimal weighting parameters and nearest neighbour-based corrections. **International Journal of Climatology**, v. 38, n. 2, 2018.

THOMAS, C., CAMERON, A., GREEN, R. *et al.* Extinction risk from climate change. **Nature**, v. 427, p.145–148, 2004. <https://doi.org/10.1038/nature02121>

TOSTES, J. O. *et al.* Assessment of gridded precipitation and air temperature products for the State of Acre, southwestern Amazonia, Brazil. **Environmental Earth Sciences**, v. 76, n. 4, 2017.

TRENBERTH, K. E. Changes in precipitation with climate change. **Climate Research**, v. 47, n. 1–2, 2011.

TUNDISI, J. G. Recursos hídricos no futuro: Problemas e soluções. **Estudos Avancados**, v. 22, n. 63, 2008.

TUO, Y. *et al.* Evaluation of precipitation input for SWAT modeling in Alpine catchment: A case study in the Adige river basin (Italy). **Science of The Total Environment**, v. 573, p. 66–82, 2016.

UPADHYAY, S.; SILWAL, P.; PRAJAPATI, R.; TALCHABHADEL, R.; SHRESTHA, S.; DUWAL, S.; LAKHE, H. Evaluating Magnitude Agreement and Occurrence Consistency of CHIRPS Product with Ground-Based Observations over Medium-Sized River Basins in Nepal. **Hydrology**. v.9, n.146, 2022.

USGS. United States Geological Survey. **O Ciclo d'água, The water cycle, Portuguese**. 2019. Disponível em: <https://www.usgs.gov/special-topics/water-science-school/science/o-ciclo-dagua-water-cycle-portuguese>. Acesso em: 27 ago. 2022.

VIANA, J. F. de S. *et al.* Modelagem Hidrológica da Bacia Hidrográfica do Rio Pirapama – PE utilizando o modelo SWAT. **Journal of Environmental Analysis and Progress**, v. 3, n. 1, 2018.

VINHAS, L.; FERREIRA, K. R. **Descrição da TerraLib**. In: Marco Antonio Casanova; Gilberto Câmara; Clodoveu A. Davis Jr.; Lúbia Vinhas; Gilberto Ribeiro de Queiroz. (Org.). Bancos de Dados Geográficos. 1ed. Curitiba: Mundo Geo, 2005.

VIOLA, M. R. *et al.* Métodos de interpolação espacial para o mapeamento da precipitação pluvial. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 9, 2010.

WANDERLEY, H. S.; DE AMORIM, R. F. C.; DE CARVALHO, F. O. Interpolação espacial de dados médios mensais pluviométricos com Redes Neurais Artificiais. **Revista Brasileira de Meteorologia**, v. 29, n. 3, 2014.

WASKLEWICZ, T. *et al.* 3.6 Digital Terrain Modeling. **Treatise on Geomorphology**, v. 3, p. 130–161, 2013.

WATSON, D. Contouring: **A Guide to the Analysis and Display of Spatial Data**, Londres: Pergamon Press, 1992. 340p.

WIJEMANNAGE, A.L.K.; RANAGALAGE, M.; PERERA, E.N.C. Comparison of spatial interpolation methods for rainfall data over Sri Lanka. In **Proceedings of the Asian Conference in Remote Sensing 2016, Colombo, Sri Lanka**, p.1723-1732, 2016.

WILLMOTT, C. J. On the validation of models. **Physical Geography**, v.2, p.184-194, 1981.

WESTERBERG, I. K. *et al.* Uncertainty in hydrological signatures for gauged and ungauged catchments. **Water Resources Research**, v. 52, n. 3, 2016.

WU, Y.-H. (Eva); HUNG, M.-C. Comparison of Spatial Interpolation Techniques Using Visualization and Quantitative Assessment. In: APPLICATIONS OF SPATIAL STATISTICS. 2016.

XAVIER, A. C.; KING, C. W.; SCANLON, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Meteorology**. v.36, ed.6, p.2644-2659, 2015.

XAVIER-DA-SILVA, J. O que é Geoprocessamento?. **Revista CREA RJ**, Rio de Janeiro, p. 42 - 44, 30 out. 2009.

XU, J., GRUMBINE, R.E., SHRESTHA, A., ERIKSSON, M., YANG, X., WANG, Y. and WILKES, A. The Melting Himalayas: Cascading Effects of Climate Change on Water, Biodiversity, and Livelihoods. **Conservation Biology**, v.23, p.520-530, 2009. <https://doi.org/10.1111/j.1523-1739.2009.01237.x>

YAMAMOTO, J. K. Correcting the smoothing effect of ordinary kriging estimates. **Mathematical Geology**, v. 37, n. 1, 2005.

YANG, X. *et al.* Spatial Interpolation of Daily Rainfall Data for Local Climate Impact Assessment over Greater Sydney Region. **Advances in Meteorology**, v. 2015, 2015.

YU, D.; COULTHARD, T. J. Evaluating the importance of catchment hydrological parameters for urban surface water flood modelling using a simple hydro-inundation model. **Journal of Hydrology**, v. 524, p. 385–400, 201.

ZHANG, J.; GUO, W.; ZHOU, B.; OKIN, G.S. Drone-Based Remote Sensing for Research on Wind Erosion in Drylands: Possible Applications. **Remote Sens.** v. 13, n.2, 2021.