

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL  
CENTRO ESTADUAL DE PESQUISAS EM SENSORIAMENTO REMOTO E METEOROLOGIA  
PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO

JOÃO PAULO BRUBACHER

**BANCO DE DADOS DE PRECIPITAÇÃO PARA ANÁLISE ESPAÇO-TEMPORAL  
INTEGRADA PARA O ESTADO DO RIO GRANDE DO SUL, BRASIL**

PORTO ALEGRE

2021

JOÃO PAULO BRUBACHER

**BANCO DE DADOS DE PRECIPITAÇÃO PARA ANÁLISE ESPAÇO-TEMPORAL  
INTEGRADA PARA O ESTADO DO RIO GRANDE DO SUL, BRASIL**

Tese de doutorado apresentada ao Programa de Pós-Graduação em Sensoriamento Remoto como requisito parcial para a obtenção do título de Doutor em Sensoriamento Remoto e Geoprocessamento.

**Orientador:** Prof. Dr. Laurindo Antonio Guasselli

**Coorientador:** Prof. Dr. Guilherme Garcia de Oliveira

PORTO ALEGRE

2021

## CIP - Catalogação na Publicação

Brubacher, João Paulo  
BANCO DE DADOS DE PRECIPITAÇÃO PARA ANÁLISE  
ESPAÇO-TEMPORAL INTEGRADA PARA O ESTADO DO RIO GRANDE  
DO SUL, BRASIL / João Paulo Brubacher. -- 2021.  
174 f.  
Orientador: Laurindo Antonio Guasselli.

Coorientador: Guilherme Garcia de Oliveira.

Tese (Doutorado) -- Universidade Federal do Rio  
Grande do Sul, Centro Estadual de Pesquisas em  
Sensoriamento Remoto e Meteorologia, Programa de  
Pós-Graduação em Sensoriamento Remoto, Porto Alegre,  
BR-RS, 2021.

1. Interpolação espacial. 2. Preenchimento de  
falhas. 3. SIG. I. Guasselli, Laurindo Antonio,  
orient. II. Oliveira, Guilherme Garcia de, coorient.  
III. Título.

**PROGRAMA DE PÓS-GRADUAÇÃO EM SENSORIAMENTO REMOTO**

**TESE**

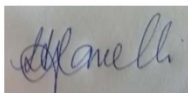
Submetida como parte dos requisitos  
para obtenção do Grau de

**DOCTOR EM SENSORIAMENTO REMOTO E GEOPROCESSAMENTO**

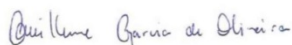
Programa de Pós-Graduação em Sensoriamento Remoto (PPGSR)  
Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia (CEPRSM)  
Universidade Federal do Rio Grande do Sul (UFRGS)  
Porto Alegre, RS, Brasil.

Aprovada em: 22/03/2021  
Pela Banca Examinadora:

Homologada em: 31/05/2021  
Por:



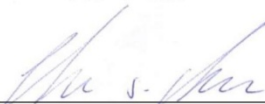
**Prof. Dr. Laurindo Antonio Guasselli**  
Orientador




---

**Prof. Dr. Guilherme Garcia de Oliveira**  
Coordenador do Programa de  
Pós-Graduação em Sensoriamento  
Remoto


**Prof. Dr. Guilherme Garcia de Oliveira**  
Coorientador



**Prof. Dr. Eliseu José Weber**  
(PPGSR/UFRGS)



**Prof. Dr. Alfonso Risso**  
(IPH/UFRGS)



**Profa. Dra. Eliana Valeda Klering**  
(UFPEL)

Dedico este trabalho a minha mãe, Emeri Maria dos Santos, pelo apoio no início de minha trajetória; e a minha linda esposa Agatha Xavier Brubacher, pelo apoio incondicional de todas as horas.

## **AGRADECIMENTOS**

Agradeço à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pela concessão da bolsa de doutorado.

Ao Programa de Pós-Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul (PPGSR) pelo apoio acadêmico, sem os quais esse estudo não teria ocorrido.

À Universidade Federal do Rio Grande do Sul, pelo espaço de formação, gratuito e de qualidade.

À minha mãe Emerí Maria dos Santos, e a minha avó, Evanede José dos Santos, por me darem a possibilidade de estudar e me manter em uma Universidade Federal.

Aos meus orientadores Laurindo Antonio Guasselli e Guilherme Garcia de Oliveira, pessoas fantásticas e pacientes, além de excelentes profissionais.

À minha esposa Agatha Xavier Brubacher, pelo apoio incondicional, paciência, companheirismo de todas as horas e por sempre acreditar no meu potencial.

Aos meu sogros Jefferson Almeida Xavier e Marta Almeida Xavier.

Aos colegas do Laboratório de Geoprocessamento e Análise Ambiental (LAGAM). Em especial a Luiz Chimelo Ruiz, Renata Pacheco Quevedo, Cecília Balsamo Etchelar, Fabiana Rauber Sirângelo e João Paulo Delapasse, cujo auxílio e parceria ultrapassaram o âmbito acadêmico.

Aos colegas da Geografia, que tiveram importante participação na minha trajetória: Lucas Silveira Ferreira, Raquel Chites e Pablo Leandro Proença Ferreira.

“Em tempos de crise, os sábios constroem pontes, enquanto os tolos constroem muros”.

Pantera Negra

## RESUMO

A obtenção de séries históricas de precipitação é essencial em diversas áreas do conhecimento, entre as quais, destacam-se climatologia, hidrologia e agricultura. No entanto, a limitação na densidade das estações pluviométricas e a escassez de dados, trazem dificuldades aos usuários. Ainda são necessárias uma série de processamentos, como o preenchimento das falhas, a interpolação e a estimativa da precipitação para área de interesse. Esta tese teve como objetivo gerar um Banco de Dados espacial com séries históricas de precipitação para o Rio Grande do Sul, que permite a consulta a índices e séries temporais de precipitação por bacia, município ou coordenadas geográficas, sem a necessidade de pós-processamento. A metodologia da pesquisa foi dividida em cinco etapas: a) aquisição, organização e preenchimento de falhas das séries históricas de precipitação das 287 estações pluviométricas utilizadas no estudo, por meio dos métodos de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA); b) interpolação espacial de dados de precipitação para uma malha regular com resolução espacial de 20 km, por meio do método Inverso da Potência da Distância (IPD); c) cálculo e processamento de índices de precipitação (Tempo de Retorno, Chuva Média Mensal e Anual, Índice de Anomalia de Chuvas, Número de dias de Precipitação); d) divisão e otocodificação de bacias hidrográficas a partir do Modelo Digital de Elevação (MDI); e) organização de tabelas e matrizes, e desenvolvimento de um algoritmo para consultas ao Banco de Dados. O produto 3IMERGM, oriundo da Missão *Global Precipitation Measurement* (GPM), foi comparado com o Banco de Dados gerado. Os dados de precipitação estimados pelo produto 3IMERGM se mostraram compatíveis com o Banco de Dados, mas superestimaram os valores em 9,15%. A disponibilização do Banco de Dados em um site na internet, com um arquivo de saída compatível com programas de modelagem hidrológica, representa um ganho significativo para áreas que necessitem de longas séries temporais de precipitação. A partir do Banco de Dados desenvolvido nesta tese, o usuário terá acesso a um extenso conjunto de dados de precipitação do RS, incluindo o código desenvolvido no software MATLAB, as tabelas e matrizes das séries históricas de precipitação e os arquivos vetoriais de consulta das bacias hidrográficas e dos municípios.

**Palavras-chave:** Interpolação espacial. Preenchimento de falhas. SIG.



## ABSTRACT

Obtaining historical precipitation series is essential in several areas of knowledge, among which are climatology, hydrology and agriculture. However, the limitation in the density of pluviometric stations and the scarcity of data, bringing difficulties to users. A series of processing is still required, such as gap filling, interpolation and estimating precipitation for the area of interest. This thesis aimed to generate a spatial database with historical precipitation series for Rio Grande do Sul, which allows the query of precipitation indexes and time series by basin, city or geographic coordinates, without the need for post-processing. The research methodology was divided into five stages: a) acquisition, organization and gap filling in the historical precipitation series of the 287 pluviometric stations used in the study, by the methods of Multiple Linear Regression (MLR) and Artificial Neural Networks (ANN) ; b) spatial interpolation of precipitation data for a regular grid with a spatial resolution of 20 km, by the method Distance Power Inverse (DPI); c) calculation and processing of precipitation indices (Return Time, Average Monthly and Annual Rain, Rain Anomaly Index, Number of Precipitation Days); d) division and ottocodification of hydrographic basins using the Digital Elevation Model (DEM); e) organization of tables and matrices, and development of an algorithm for queries to the database. The product 3IMERGM, from the Global Precipitation Measurement Mission (GPM), was compared with the database. The precipitation data estimated by the product 3IMERGM proved to be compatible with the database, but overestimated the values by 9.15%. The availability of the database on a website, with an output file compatible with hydrological modeling software, represents a significant gain for areas that need long time series of precipitation. From the database developed in this thesis, the user will have access to an extensive set of precipitation data from RS, including the code developed in the MATLAB software, the tables and matrices of the historical precipitation series and the vector consultation files of the basins hydrographic and municipalities.

**Keywords:** Spatial interpolation. Gap Fillings. SIG.

## SUMÁRIO

<b>1</b>	<b>INTRODUÇÃO</b> .....	9
<b>1.1</b>	<b>Objetivo geral</b> .....	13
<b>1.2</b>	<b>Objetivos específico</b> .....	13
<b>1.3</b>	<b>Área de estudo</b> .....	13
1.3.1	Localização e aspectos gerais.....	13
1.3.2	Clima do Rio Grande do Sul.....	14
1.3.3	Hydrografia.....	20
1.3.4	Caracterização do relevo.....	21
<b>1.4</b>	<b>Estrutura da tese</b> .....	24
<b>2</b>	<b>Referencial teórico</b> .....	25
<b>2.1</b>	<b>Preenchimento de falhas e interpolação</b> .....	25
2.1.1	Funções gerais de regressão entre variáveis.....	26
2.1.2	Inteligência artificial e aprendizagem de máquinas.....	27
2.1.3	Interpolação espacial ponderada.....	29
<b>2.2</b>	<b>Estimativa de precipitação por sensoriamento remoto</b> .....	33
<b>3</b>	<b>DESENVOLVIMENTO</b> .....	37
<b>3.1</b>	<b>ARTIGO 1 - Preenchimento de Falhas e Espacialização de Dados Pluviométricos: Desafios e Perspectivas</b> .....	37
<b>3.2</b>	<b>ARTIGO 2 - Preenchimento de Falhas em Séries Temporais de Precipitação Diária no Rio Grande Do Sul</b> .....	61
<b>3.3</b>	<b>ARTIGO 3 - Banco de Dados espacial de precipitação do estado do Rio Grande do Sul</b> .....	76
<b>3.3</b>	<b>ARTIGO 4 - Comparação entre Banco de Dados de precipitação e produtos 3IMERGM, estado do Rio Grande do Sul</b> .....	126
<b>4</b>	<b>CONSIDERAÇÕES FINAIS</b> .....	154
	<b>FINANCIAMENTO</b> .....	155
	<b>REFERÊNCIAS</b> .....	155
	<b>ANEXO A – Relação de estações pluviométricas</b> .....	166

## 1 INTRODUÇÃO

Quanto maior a quantidade de informações disponíveis sobre um determinado local, maiores são as chances de aliar desenvolvimento e qualidade de vida. Esses dois fatores estão intimamente relacionados à capacidade de resiliência de uma população, ou seja, à possibilidade de uma cidade, comunidade ou sistema de suportar, adaptar-se ou se recuperar rapidamente dos impactos causados por um evento extremo, mantendo ou retomando as suas funções (BRASIL, 2016).

Torna-se determinante, portanto, o conhecimento acerca do regime hídrico de uma bacia hidrográfica, tanto como base para diferentes projetos em relação ao uso da água e planejamento urbano (SANTOS, 2009), quanto para evitar desastres de origem pluviométrica, como inundações, enxurradas, movimentos de massa, além dos desastres provocados pela falta de chuvas, como estiagens e secas (OLIVEIRA *et al.*, 2005; SANTOS, 2015; SILVA *et al.*, 2016).

No Brasil, mais especificamente na região Sul, os riscos de enxurradas e inundações, associados a grandes volumes de precipitação em curto espaço de tempo, são responsáveis pelas principais ocorrências de desastres (IPCC, 2007). Os problemas estruturais em conjunto com a ocupação de áreas próximas aos rios e arroios, assim como a urbanização e a consequente impermeabilização do solo, são agravantes dos riscos descritos (PORTO *et al.*, 2001; CUNHA, 2004; OLIVEIRA, 2010).

Estudos com viés ambiental, de previsão do tempo, modelagem e variabilidade climática, por exemplo, principalmente no que se refere a análises de longo prazo, como simulação de represas e inundações demandam de grande disponibilidade de dados de precipitação e vazão (MATEUS, 2006; PAZ, 2010). Nesse sentido, a Agência Nacional de Águas (ANA), criada em 17 de julho de 2000, tem a atribuição de manter e disponibilizar o cadastro atualizado das estações hidrometeorológicas brasileiro (ANA, 2017).

A existência de uma rede comum de monitoramento hidrológico de chuvas, cotas e vazões, unificando em um mesmo sítio eletrônico a possibilidade de pesquisa das redes hidrometeorológicas, como foi idealizado no portal HidroWeb da ANA é uma importante ferramenta para o desenvolvimento de estudos e definição de políticas públicas. Esse banco de dados reúne as informações coletadas de

dados sobre cotas, vazões, chuvas, evaporação, perfil do rio, qualidade da água e sedimentos (ANA, 2017; VIANNA *et al.*, 2017).

No entanto, as redes de monitoramento existentes em território nacional podem apresentar lacunas nas séries de dados, principalmente no que se refere às séries mais antigas. Esses problemas podem ocorrer por falha humana, nos equipamentos, no processamento ou por perda de dados. Assim, é necessário que essas falhas sejam preenchidas, devido à necessidade de se trabalhar com séries contínuas (WISSMAN *et al.*, 2006; OLIVEIRA *et al.*, 2010; SILVA, 2011; VESPUCCI *et al.*, 2016). Além disso, para muitas aplicações, tais como simulação ou previsão hidrológica, a ausência de séries contínuas pode reduzir o desempenho de modelos ou até mesmo inviabilizar a sua aplicação.

Os dados disponíveis no portal HidroWeb são uma compilação de um grande volume de dados de precipitação, cota e vazão (ANA, 2017). Entretanto, quando há a necessidade de espacialização dos dados para uma determinada bacia hidrográfica e a obtenção de índices ou estatísticas de mínimas, médias e máximas, as etapas a serem seguidas, como preenchimento de falhas, espacialização e análise estatística, dificultam ou tornam o trabalho mais oneroso e devem ser realizadas pelos pesquisadores.

Uma das prerrogativas desse estudo é de que é necessário sistematizar esses dados, analisar a sua consistência, viabilizar maior disponibilidade de séries históricas de precipitação, de modo a possibilitar a extração de índices e estatísticas espaciais e temporais. Para uma abordagem espacial, é importante que esses dados sejam disponibilizados em diferentes escalas de análise, por coordenada geográfica, bacia hidrográfica ou áreas municipais, para o estado do Rio Grande do Sul.

Atualmente, por exemplo, ainda não está disponível um produto espacial com as precipitações diárias registradas no HidroWeb. O usuário precisa obter os dados e analisar pontualmente a precipitação (por estação pluviométrica). Caso necessite realizar uma modelagem hidrológica, por exemplo, é necessário interpolar a chuva diária para a área de uma bacia hidrográfica.

Organizar esses dados a partir de um banco de dados espacial, como se propõe nesta tese, vai permitir, por exemplo, uma série de análises integradas sobre

chuvas intensas ou secas prolongadas no estado do Rio Grande do Sul e suas regiões hidrográficas. Conforme Rossato (2011), estudos climáticos em escala regional possuem significativa importância como forma de produzir elementos essenciais para a organização do espaço geográfico do estado. E segundo Paz (2010), é importante poder prever o comportamento hidrológico de um sistema de rios e planícies, de modo a compreender os possíveis impactos de seu comportamento futuro. A modelagem matemática é uma ferramenta ideal para esse propósito.

O estudo de métodos para o preenchimento de falhas em séries temporais busca contribuir para o avanço de pesquisas na compreensão da variação climática e na previsão de fenômenos que venham a se repetir por influência do clima (FERNANDEZ, 2007). Há cerca de 100 anos não existiam muitas estações pluviométricas disponíveis, dessa forma, esse tipo de pesquisa torna-se necessária de modo a aproveitar longas séries de precipitação, evitando que, em função de algumas falhas, sejam descartadas (VILLAZÓN e WILLENS, 2010; BRUBACHER *et al.*, 2012, BIER e FERRAZ, 2017).

A espacialização dos dados de precipitação se dá como complemento aos estudos da dinâmica do meio físico, de modo a inferir valores de precipitação em áreas sem estações pluviométricas (REICHENBACH *et al.*, 1998; MARCUZZO *et al.*, 2011; OLIVEIRA *et al.*, 2012; FARIAS *et al.*, 2017). Utilizar técnicas de extrapolação/interpolação permite estimar a precipitação para áreas mais distantes dos pontos medidos sem qualquer indício físico real sobre a quantidade de precipitação verdadeiramente ocorrida (CONTI, 2002).

Esse processo se dá em um ambiente de um Sistema de Informações Geográficas (SIG), sendo que as técnicas de geoprocessamento são aplicadas para espacializar as variáveis de entrada do modelo (VIOLA *et al.*, 2009). Além disso, segundo Deroo e Jetten (1999) a principal razão para se usar SIG é que o processo varia espacialmente e, assim, células de informação devem ser usadas para que a variação espacial seja levada em consideração. A utilização de técnicas de espacialização facilita a verificação de como as variáveis observadas nas séries históricas se distribuem no espaço e no tempo (SILVA *et al.*, 2007).

Técnicas de sensoriamento remoto contribuem para o acesso a dados de precipitação estimados por satélites meteorológicos, permitindo a observação e

monitoramento contínuo do tempo e do clima em nível global (STEPHENS e KUMMEROW, 2007; MOREIRA *et al.*, 2017). Em 2014, a missão *Global Precipitation Measurement* (GPM), desenvolvida pela *National Aeronautics and Space Administration* (NASA) e pela *Japanese Exploration Agency* (JAXA) lançou o Satélite Observatório Central (SKOFRONICK-JACKSON *et al.*, 2016).

Ainda que não sejam tão precisos quanto os dados medidos em estações pluviométricas automáticas, esse tipo de estimativa tem como vantagem o registro da distribuição espacial da precipitação, segundo Collischonn *et al.* (2007). O IMERG (*Intercalibrated Merged Retrievals for GPM*) é um dos diversos produtos disponíveis para estimativa de precipitação, e destaca-se por sintetizar as vantagens de algoritmos de precipitação obtidas por outros satélites (SKOFRONICK-JACKSON *et al.*, 2017) e permite a validação das medições *in situ* e a atribuição de dados de precipitação em áreas com baixa densidade de estações pluviométricas.

A organização de um banco de dados espacial e temporal se justifica como meio de complementar as análises derivadas de dados de precipitação. A complementação da rede existente, com preenchimento de falhas utilizando uma grade regular visa contribuir para que diferentes tipos de projetos possam ter, de forma rápida e eficiente, acesso a tendências temporais e padrões climáticos.

A disponibilização desse banco de dados, de uma forma que permita o acesso a séries históricas e índices de precipitação, para todo o estado do Rio Grande do Sul, representa um ganho importante para pesquisadores de diversas áreas que utilizam esse tipo de dado.

## 1.1 Objetivo geral

O objetivo deste estudo é criar um banco de dados espacial de precipitação no estado do Rio Grande do Sul, tendo como base as séries históricas no período entre 1987 e 2016, que possibilite a consulta e a obtenção de séries temporais e índices de precipitação por coordenadas e por unidade territorial (bacia hidrográfica ou município).

## 1.2 Objetivos específicos

- Revisar os métodos de preenchimento de falhas e de interpolação espacial de dados de precipitação, com viés na testagem dos métodos e abordagens, identificando as vantagens e desvantagens de cada método;
- Propor um algoritmo para preencher falhas em séries históricas de precipitação diária para o estado do Rio Grande do Sul, utilizando todas as estações pluviométricas com dados disponíveis, comparando a aplicação dos métodos RLM e RNA;
- Gerar um banco de dados espacial com séries históricas de chuvas, que permite consultar os índices de precipitação, por meio de uma malha regular de células, abrangendo bacias hidrográficas e municípios do Rio Grande do Sul, de acesso rápido e prático, sem a necessidade de pós-processamento;
- Comparar dados de precipitação da Missão GPM, a partir do produto 3IMERGM, com dados de estações pluviométricas organizados em um banco de dados espacial para o estado do Rio Grande do Sul.

## 1.3 Área de estudo

### 1.3.1 Localização e aspectos gerais

O estado do Rio Grande do Sul localiza-se na região Sul do Brasil, faz fronteira ao norte com o estado de Santa Catarina, ao leste com o Oceano Atlântico, a oeste com Argentina e ao sul com Uruguai (Figura 1). Possui uma área de 281.737 km<sup>2</sup> e

uma população estimada de 10.693.929 pessoas (IBGE, 2017), sendo que, aproximadamente, 80,8% é população urbana.

Figura 1 – Localização, Região Hidrográfica (RH) e altimetria do estado do Rio Grande do Sul



Fonte: Elaboração própria.

### 1.3.2 Clima do Rio Grande do Sul

O Rio Grande do Sul é afetado por sistemas atmosféricos de escala sinótica e sub-sinótica, influenciados tanto por fatores associados à circulação de grande escala quanto às circulações locais, de origem tropical e extratropical (INPE, 1986).



O estado encontra-se em uma zona climática de transição, e suas principais características climáticas refletem a participação de Sistemas Atmosféricos Extratropicais (massas e frentes polares) e Sistemas Intertropicais (massas tropicais e correntes perturbadas). Embora os primeiros exerçam o controle dos tipos de tempo em 90% dos dias do ano, proporcionando também a distribuição mensal e anual das chuvas (SARTORI, 2003).

A posição subtropical faz com que o Rio Grande do Sul seja área de confronto entre forças opostas, provocado pelo avanço dos sistemas atmosféricos de origem polar em direção aos polares tropicalizados (Massa Polar Velha) ou aos sistemas de origem tropical (Ta - Massa Tropical Atlântica; Tc - Massa Tropical Continental), decorrentes das sucessivas passagens de massa frontais, de forma que a distribuição da precipitação anual não é suficiente para caracterizar uma estação seca (SARTORI, 2003).

No sistema de classificação climática global de Köppen, o clima do Rio Grande do Sul se caracteriza por ser do tipo Cfa (subtropical) e Cfb (temperado) (STRAHLER, 1984; TREWARTHA, 1943). Com base nessa definição, o estado teria como características principais chuvas durante todos os meses do ano e temperatura média acima de 22°C, no mês mais quente, e superior a 3°C e temperatura média do mês mais quente inferior a 22° e do mês mais frio superior a 3°C.

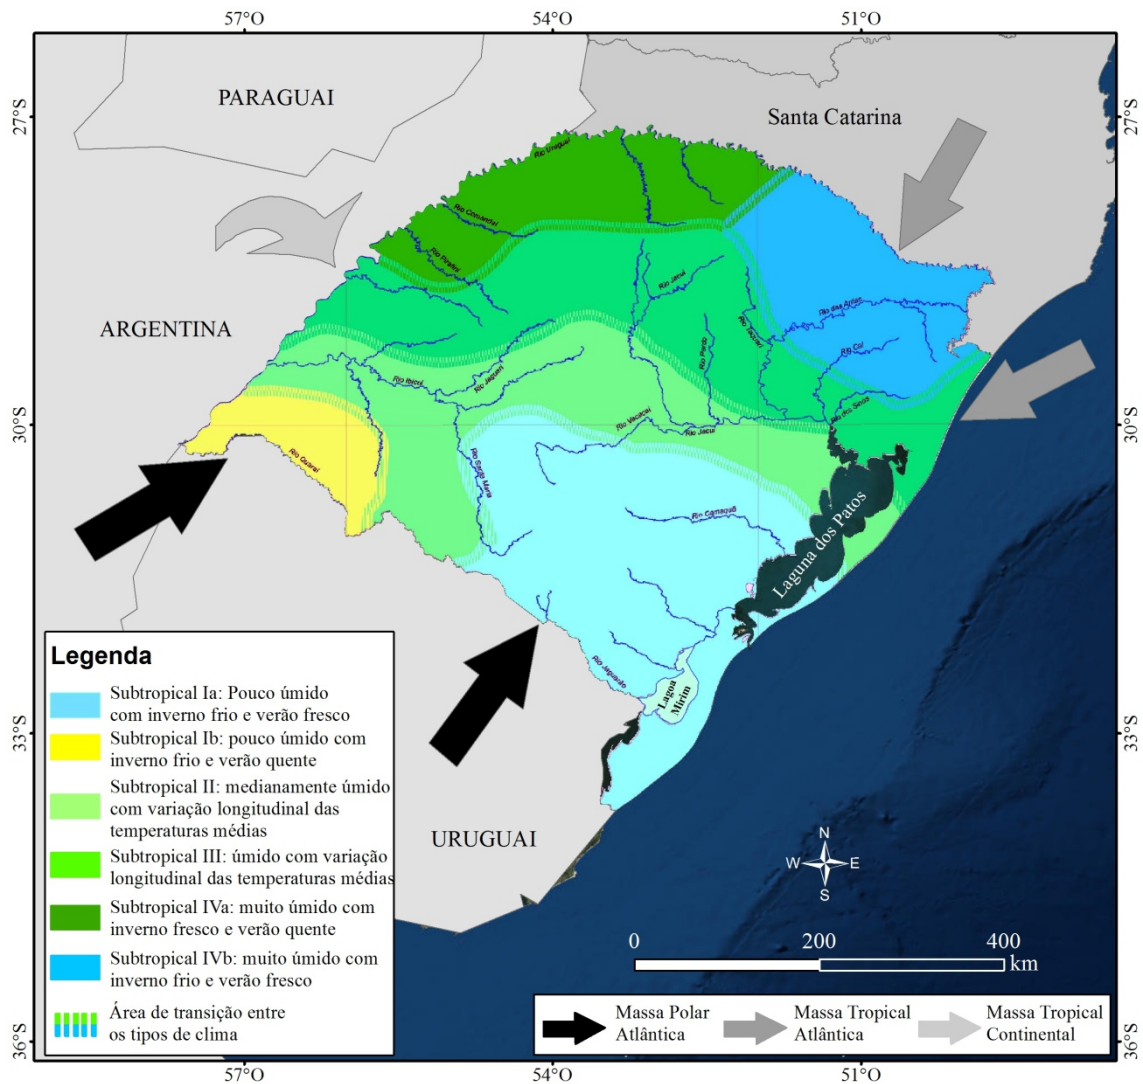
Segundo Rossato (2011), a classificação de Köppen, quando utilizada para caracterização do clima em escalas locais e regionais, mascara diferenças regionais importantes. No sul do Brasil, por exemplo, os episódios chuvosos encontram-se melhor distribuídos nos meses de inverno e com distribuição desigual no verão, além da diferença significativa da precipitação acumulada anual nas áreas geográficas menos chuvosas (1290 mm anuais) e mais chuvosas (2000 mm anuais).

Na classificação regional de Rossato (2011) ocorrem quatro tipos climáticos para o estado do Rio Grande do Sul, dois deles com subdivisões, que são os seguintes (Figura 2):

- Subtropical I - Pouco úmido: Subtropical Ia - Pouco úmido com inverno frio e verão fresco, e Subtropical Ib - Pouco úmido com inverno frio e verão quente;

- Subtropical II - Medianamente úmido com variação longitudinal das temperaturas médias;
- Subtropical III - Úmido com variação longitudinal das temperaturas médias;
- Subtropical IV - Muito úmido: Subtropical IVa - Muito úmido com inverno fresco e verão quente, e Subtropical IVb - Muito úmido com inverno frio e verão fresco.

Figura 2 - Tipologia climática do estado do Rio Grande do Sul.



Fonte: Adaptado de Rossato, 2011.

O regime pluviométrico é caracterizado pela interação dos sistemas meteorológicos com os elementos da paisagem geográfica, como o relevo, a latitude, a maritimidade e a continentalidade. A pluviosidade é condicionada principalmente pela dinâmica atmosférica em relação ao relevo que, através de sua

compartimentação, promove a distribuição espacial da precipitação (BRITTO *et al.*, 2006).

Os totais médios anuais da precipitação pluvial se distribuem, de modo geral, de 1200 mm, na faixa litorânea, até 1900 mm, no norte do Estado. Na borda da escarpa, como em São Francisco de Paula, chegam a mais de 2000 mm (NIMER, 1990).

Segundo Britto *et al.* (2008) foram observados no Rio Grande do Sul quatro sub-regiões com valores de pluviosidade total semelhantes. No inverno, chove mais na sub-região do litoral e no centro-sul, em função da atuação do sistema atmosférico frontal; na primavera, chove mais na sub-região noroeste, onde dominam os Complexos Convectivos de Mesoescala (CCMs); no verão chove mais na sub-região nordeste atingida por chuvas convectivas associadas às Zonas de Convergência do Atlântico Sul (ZCAS); no outono chove mais na sub-região sudoeste do Estado e o sistema dinâmico mais influente é o bloqueio atmosférico.

Diferentemente de outras regiões brasileiras, há no Rio Grande do Sul uma uniformidade na distribuição da chuva ao longo do ano (TEIXEIRA e PRIETO, 2020). No entanto, a variabilidade interanual da precipitação no estado é muito influenciada pelo fenômeno ENOS (*El Niño* Oscilação Sul).

O ENOS é um fenômeno de grande escala que resulta da interação entre oceano e atmosfera, caracterizado por anomalias na temperatura da superfície do mar (TSM) no Oceano Pacífico Equatorial e que envolve duas fases extremas: fase quente, também conhecida como *El Niño*, e fase fria, conhecida como *La Niña* (BERLATO e FONTANA, 2003; MATZENAUER *et al.*, 2017).

Segundo Fontana e Berlato (1997), Diaz *et al.* (1998) e Puchalski (2000), nos anos associados a *La Niña* ocorre diminuição na precipitação, principalmente entre a primavera e o verão. Em anos de *El Niño*, a tendência é de aumento da precipitação, inclusive, com a possibilidade de ocorrência de eventos extremos.

De acordo com Matzenauer *et al.* (2017), em estudo realizado em 28 localidades no estado do Rio Grande do Sul, a média de precipitação nos anos de *El Niño* foi de 1858 mm, e nos anos de *La Niña* a média foi de 1480 mm. Entre as regiões mais afetadas do estado destaca-se a região noroeste. Nos meses entre primavera e verão, quando são sentidos os principais efeitos dos fenômenos, a

anomalia positiva, em anos de *El Niño*, chega a 60 mm. Com padrão semelhante, em anos de *La Niña*, a anomalia negativa também fica em torno de 60 mm (FONTANA e BERLATO, 2003), o que pode causar sérios prejuízos para a agricultura e abastecimento de água (SANTOS, 2017).

Alguns autores estudaram a influência do *El Niño* e *La Niña* na produtividade agrícola no estado do Rio Grande do Sul: Berlato *et al.* (2005); Pavan *et al.* (2013); Arsego *et al.* (2018); Santos (2017); Matzenauer *et al.* (2018).

Outros estudaram a relação entre a ocorrência de eventos extremos relacionados ao *El Niño* e desastres no estado do Rio Grande do Sul: Sausen (2011); Brubacher *et al.* (2012); Sanches *et al.* (2014); Caldeira *et al.* (2015); Cera e Ferraz (2015); Gross e Casol (2015); Cardoso (2017); Valente (2018); Teixeira e Prietto (2020).

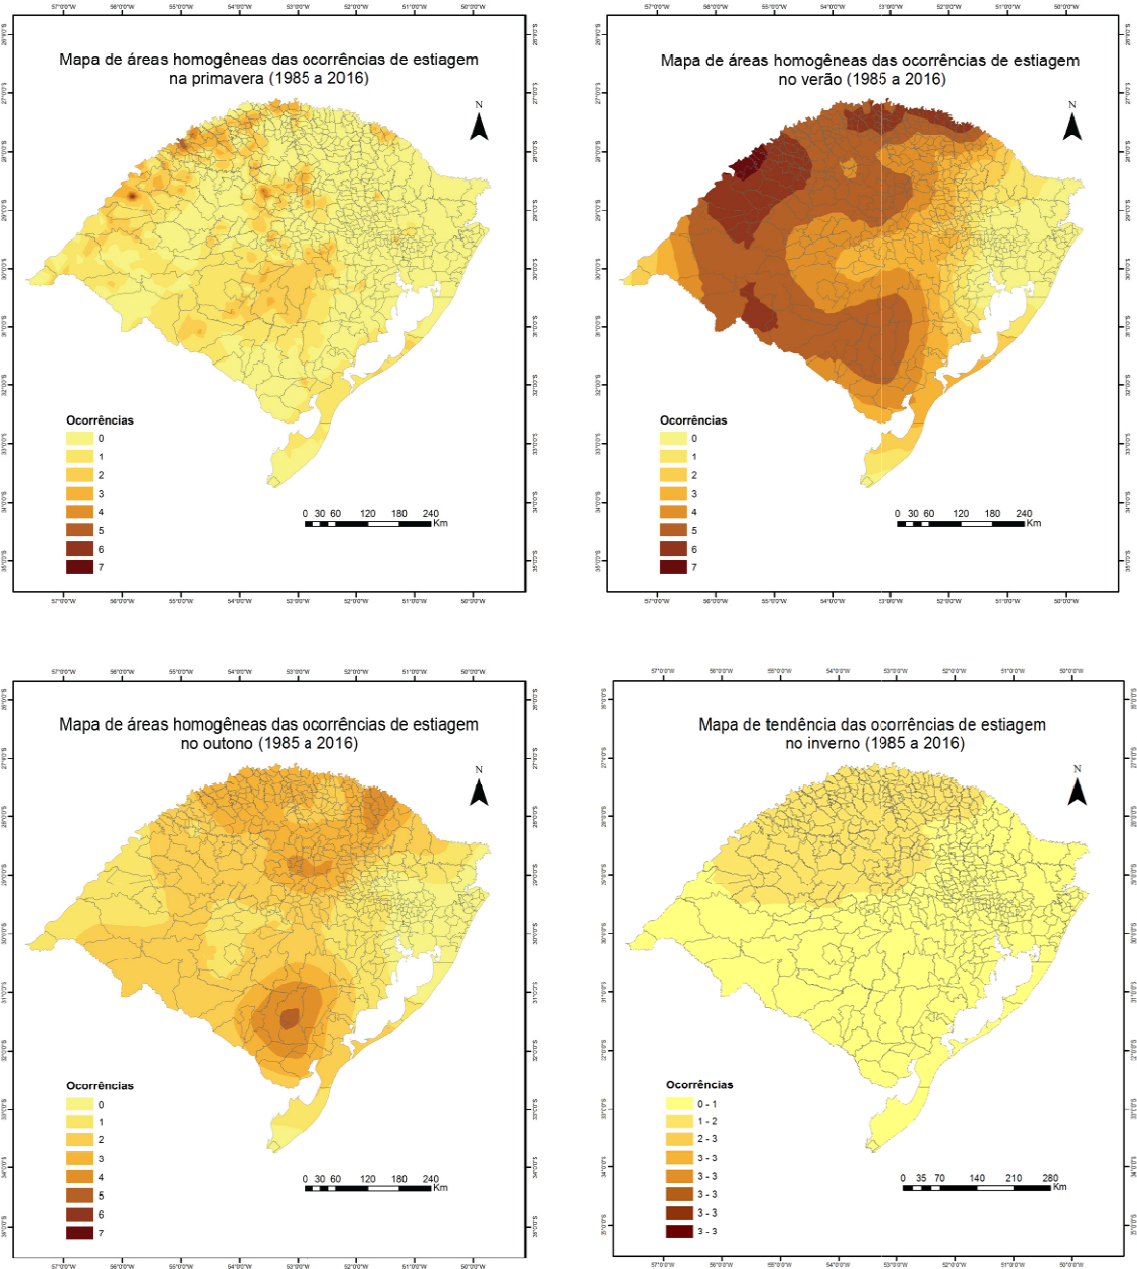
De acordo com Sausen *et al.* (2018) desastres associados a eventos de precipitação se distribuem da porção Leste (a menos afetada) para a porção Oeste do estado, principalmente as de estiagem, vendaval e inundação. E no sentido Norte (a mais afetada) para o Sul (a menos afetada) principalmente eventos de enxurrada e granizo, este último com tendências a porção Noroeste.

Enquanto a estiagem representa uma deficiência da precipitação durante períodos prolongados que resultam em escassez de água para algumas atividades (SAUSEN *et al.*, 2018), a inundação se relaciona ao aumento do nível dos rios além da sua vazão normal, quando ocorre o transbordamento de suas águas sobre as áreas próximas a ele (KOBAYAMA *et al.*, 2006).

Em eventos extremos, cidades como Porto Alegre, apresentam problemas no escoamento das águas pluviais, concentrando alagamentos em diversos pontos da cidade. Em algumas cidades devido ao acúmulo de lixo e limpeza deficiente dos canais, os pequenos arroios não conseguem dar conta do fluxo e são frequentes os transbordamentos de suas águas para as áreas adjacentes (TUCCI, 2007; VAZ, 2015).

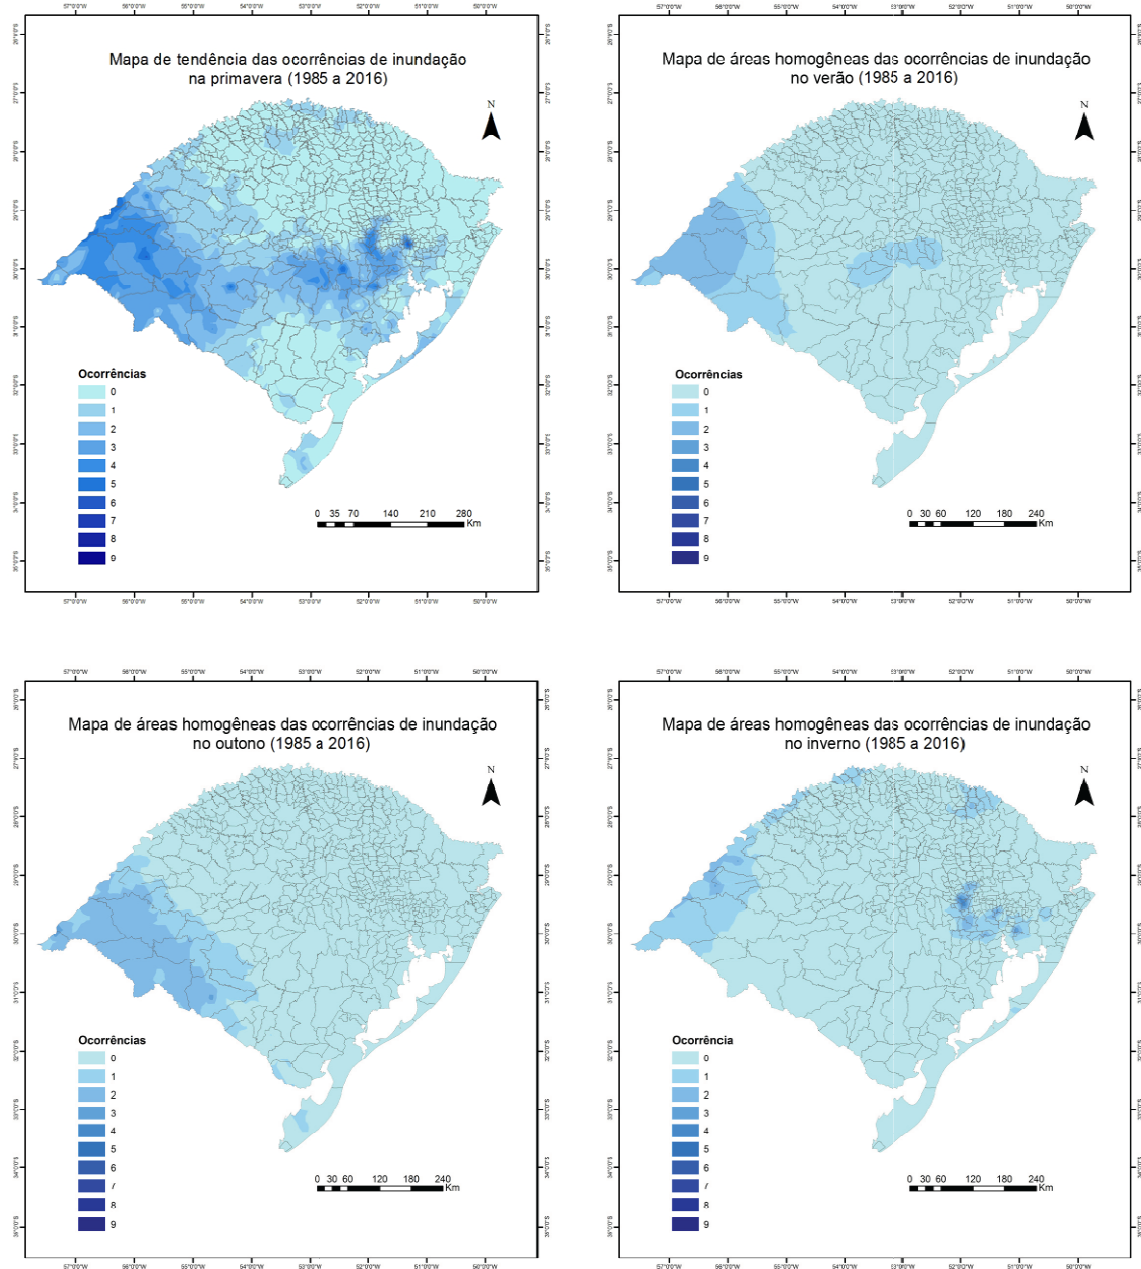
A Figura 3 demonstra os mapas sazonais (primavera, verão, outono e inverno) das áreas de tendência de ocorrência de estiagem no estado do Rio Grande do Sul, no período de 1985 a 2016; a Figura 4 apresenta a tendência de ocorrência de inundação.

Figura 3 - Mapas sazonais (primavera, verão, outono e inverno) das áreas de Tendências de Ocorrências (ATO) de estiagem, período de 1985-2016, Rio Grande do Sul.



Fonte: SAUSEN *et al.*, 2018.

Figura 4 - Mapas sazonais (primavera, verão, outono e inverno) das áreas de Tendências de Ocorrências (ATO) de inundação, período de 1985-2016, Rio Grande do Sul.



Fonte: SAUSEN *et al.*, 2018.

### 1.3.3 Hidrografia

O Rio Grande do Sul se divide em duas grandes áreas hidrográficas distintas: a primeira é representada pelas águas que se dirigem para o norte e para o oeste,

desaguando no rio Uruguai; a outra pelas seguem para leste e para o sul, sendo tributárias do litoral lagunar ou diretamente no Atlântico. Devido a inclinação dos derrames basálticos a maioria dos cursos de água do planalto escoam em direção oposta ao Oceano Atlântico (CURTIS *et al.*, 1959).

Segundo o Atlas da Fundação de Economia e Estatística FEE (PESSOA, 2017), o Rio Grande do Sul possui umas das redes hidrográficas com maior disponibilidade de água do Brasil, com densa malha hidrográfica superficial, dividida em três grandes bacias: a bacia do Uruguai, que drena cerca de 57% da área total do estado; a do Guaíba, 30%; e a Litorânea, abrangendo cerca de 13% do território (Figura 1). Essas três grandes Regiões Hidrográficas (RH) se diferem entre si de acordo com a altimetria, características geomorfológicas e direção do fluxo.

Em períodos de grande precipitação, as bacias que possuem suas nascentes nas escarpas do Planalto da Serra Geral concentram os principais casos de enxurradas, em locais de relevo acidentado e com pouca área de drenagem, e de inundações, principalmente em locais mais próximos a foz (OLIVEIRA, 2010). Em função da predominância da agricultura e da pecuária, no oeste e na metade sul, podem ser perdidas lavouras inteiras nesses períodos, atingindo a economia de diversos municípios dependentes dessas atividades (CUNHA *et al.*, 1998). Em outras áreas do estado, as secas e estiagens têm como principal consequência a diminuição dos níveis dos reservatórios, prejudicando a distribuição de água potável, bem como o setor hidrelétrico (ALBUQUERQUE, 2010).

#### 1.3.4 Caracterização do Relevo

Ao caracterizar o relevo do Rio Grande do Sul, com base na proposta de Ab'Saber (1964), Gonçalves e Santos (1985), propuseram uma classificação considerando critérios morfoestruturais e topográficos, e suas respectiva localização geográfica, e consideraram os seguintes compartimentos:

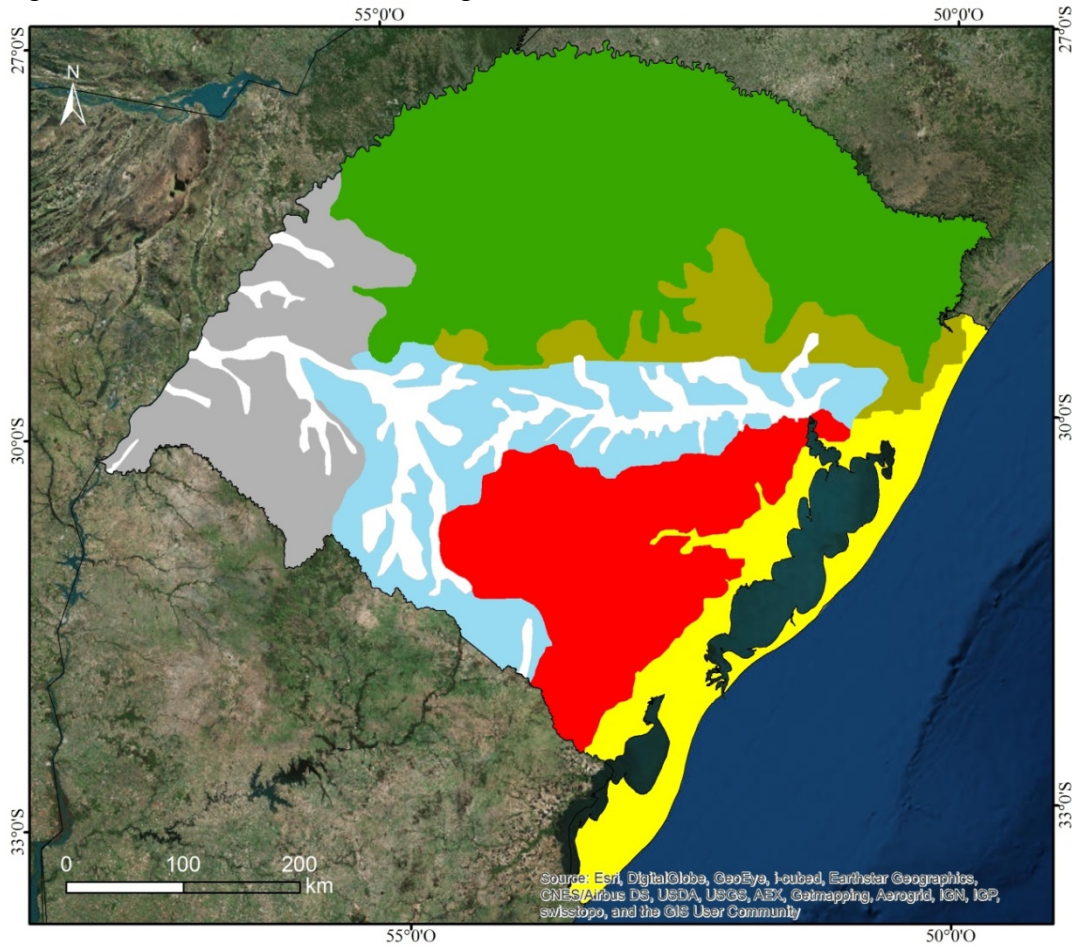
- Planalto Sul-Rio-Grandense: localizado no setor sudoeste do estado, formado por rochas cristalinas que pertencem ao escudo uruguaio sul-rio-grandense e que possuem altitudes na ordem de 200 a 400 m;

- Depressão Central: é a unidade que ocupa o setor central do estado. Tem na sua composição terrenos sedimentares da Bacia do Paraná e as altitudes são inferiores a 200 m e o relevo é predominantemente suave e colinoso;
- Planalto Setentrional: é parte integrante da bacia sedimentar do Paraná. Possui sensíveis diferenças topográficas em função da maior ou menor espessura do capeamento basáltico. As altitudes oscilam entre 200 e mais de 1000 m;
- Planícies e Terras Baixas e Costeiras: situam-se na faixa que vai desde o arroio Chuí, ao Sul, até o rio Mampituba, ao norte do estado. É uma bacia sedimentar pertencente à bacia de Pelotas, abrangendo o conjunto de terras mais baixas do estado.

A classificação do relevo do estado do Rio Grande do Sul elaborado por Hermann e Rosa (1990), foi gerada com base nos mapas geomorfológicos da série de levantamento de recursos naturais do Projeto RADAMBRASIL, publicado parcialmente em 1986, na escala 1:1.000.000 (IBGE, 1986). Nesse levantamento, a metodologia utilizada compreende três táxons: (1) o domínio morfoestrutural, que é definido pelo agrupamento de fatos geomorfológicos provenientes de amplos aspectos geológicos; (2) o subdomínio morfoestrutural, que se caracteriza por uma compartimentação reconhecida regionalmente; (3) as unidades de relevo e refere-se aos compartimentos bastante individualizados, apresentando formas de relevo fisionomicamente semelhantes em seus tipos de modelados (Figura 5).



Figura 5 - Unidades Geomorfológicas do Estado do Rio Grande do Sul



Domínios Morfoestruturais	Subdomínios Morfoestruturais	Unidades de Relevô
Depósitos Sedimentares Quaternários	Dep. Sedimentares Litorâneos	UR Planície Gaucha
	Dep. Sedimentares Interioranos	UR Planície dos rios Jacuí-Ibicuí
Bacias e Coberturas Sedimentares	Bacias e Depósitos Sedimentares do Paraná	UR Depressões Periféricas da rio Paraná
		UR Patamares da bacia do Paraná
		UR Planalto das Araucárias
		UR Planalto da Campanha Gaúcha
Embasamentos em Estilos Complexos	Embasamentos do Sul	UR Planalto sul-rio-grandense

Fonte: Adaptado de HERRMAN e ROSA, 1990.

#### 1.4 Dados utilizados

Para a elaboração da tese, foram utilizados os seguintes dados:

- Dados de precipitação de 287 Estações pluviométricas da ANA e do INMET (Ver Anexo 1);
- Produto de Sensoriamento Remoto para precipitação 3IMERGM, período de 2011-2016;

- Modelo Digital de Elevação com resolução de 30m (TOPODATA);

## 1.5 Estrutura da Tese

Esta tese foi estruturada em formato de artigos científicos. É composta por quatro artigos, sendo que o primeiro artigo apresenta uma revisão teórica sobre os métodos de preenchimento de falhas e interpolação espacial de dados de precipitação, de modo a conceituar as abordagens dos principais métodos, bem como identificar as suas vantagens e desvantagens.

O segundo artigo aborda os métodos utilizados para o preenchimento de falhas das séries temporais, Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA), e a comparação entre os resultados obtidos por cada método.

O terceiro artigo tem como foco principal a criação e estruturação do banco de dados espacial de precipitação para o estado do Rio Grande do Sul. É discutido o método utilizado para interpolar os dados de precipitação, a extração dos índices de precipitação e a codificação dos municípios e bacias hidrográficas, de modo a possibilitar a consulta ao banco de dados.

O quarto artigo compara os dados de precipitação estimados pelo produto 3IMERGM da missão GPM, com o Banco de Dados, e avaliados as possibilidades e limitações desse tipo de estimativa de precipitação.

## 2 REFERENCIAL TEÓRICO

A revisão teórica aborda os principais conceitos e suas respectivas utilizações, de forma a se comprovar a importância dos mesmos para este estudo. Para tanto, foram definidos dois tópicos que apresentam as referências teórico-metodológicas desse trabalho: preenchimento de falhas, interpolação e espacialização da precipitação e estimativas de precipitação por sensoriamento remoto.

### 2.1 Preenchimento de falhas e interpolação espacial

A disponibilidade de séries temporais de dados confiáveis de precipitação é essencial para estudos com viés ambiental de previsão do tempo, de modelagem e de variabilidade climática, simulação de inundações e dimensionamento de barragens, por exemplo (MATEUS, 2006; PAZ, 2010).

No entanto, as redes hidrometeorológicas de monitoramento existentes, não só no Brasil, mas no mundo (VILLAZÓN E WILLEMS; 2010), tiveram diferentes períodos de funcionamento, sendo que algumas funcionam há mais de um século, enquanto outras funcionaram por poucos anos ou em períodos escalonados. No Brasil, por exemplo, poucas estações possuem mais de cem anos de dados disponíveis (BIER e FERRAZ, 2017).

Essas falhas pluviométricas e hidrológicas podem ocorrer por erro humano, por falha nos aparelhos, no processamento, por perda de dados ou ainda por interrupção da operação. Para trabalhar com séries contínuas torna-se necessário que essas falhas sejam preenchidas (OLIVEIRA *et al.*, 2010).

Os processos de preenchimento de séries de precipitação costumam ser incômodos porque restrições físicas e técnicas, como terrenos complexos e baixa densidade de estações meteorológicas, limitam a capacidade de melhorar o desempenho (KIM e RYU, 2016).

Em simulações ou previsões hidrológicas, este processo dificulta o ajuste de distribuições estatísticas aos dados históricos, reduz o desempenho de modelos hidrológicos ou até mesmo inviabiliza suas aplicações. Dessa forma, há a

necessidade de se realizar o preenchimento de falhas e verificar a consistência dos dados após o preenchimento (BÁRDOSSY e PEGRAM, 2014; DEPINÉ *et al.*, 2014).

Preencher falhas de dados ausentes consiste em estimar os valores, modelando o comportamento do fenômeno baseado em dados históricos (BONFANTE *et al.*, 2013; VENTURA, 2015). Segundo Zeilhofer *et al.* (2003), para preenchimento de falhas em séries históricas é necessário utilizar pares de pontos com máxima correlação.

Leivas *et al.* (2006) recomendam a seleção de estações meteorológicas da mesma região ecoclimática e altitude semelhantes, caracterizando-a como hidrologicamente homogênea. Essa escolha se mostra coerente, pois aumenta a possibilidade de que os dados pluviométricos sejam semelhantes entre as estações, e maior a probabilidade de boa correlação em relação às lacunas existentes, determinante na escolha da técnica de interpolação.

Como os padrões espaços-temporais das chuvas são complexos, não lineares e altamente variáveis, a distribuição espacial das estações pluviométricas e a distância entre elas tem grande influência no preenchimento de falhas e interpolação de dados, visando gerar superfícies homogêneas de precipitação (Depiné *et al.*, 2014).

Observa-se na literatura científica uma série de métodos que podem ser utilizados para o preenchimento de falhas como, por exemplo: i) ponderação a partir de Regressão Linear Simples ou Múltipla; ii) modelos matemáticos baseados em aprendizagem de máquinas, tais como as Redes Neurais Artificiais; iii) interpoladores espaciais para o preenchimento de falhas (Inverso da Distância, Vizinho Natural, Krigagem).

### **2.1.1 Funções gerais de Regressão entre variáveis**

Nas técnicas de Regressão Linear Simples (RLS) ou Regressão Linear Múltipla (RLM), a precipitação no posto com falhas é correlacionada estatisticamente com a precipitação em um posto vizinho com dados, no caso da regressão simples, ou vários postos vizinhos, no caso da regressão múltipla. Segundo Tucci (2002) e Bertoni e Tucci (2007) no método RLS, as estimativas dos parâmetros são obtidas

graficamente ou por meio dos mínimos quadrados para calibração dos valores de forma iterativa.

Na regressão múltipla, as informações pluviométricas do posto  $Y$  são correlacionadas com as observações correspondentes de vários postos vizinhos, por meio de uma equação linear (Equação 1) ou por outros tipos de relação, como a potencial (Equação 2). A segunda expressão pode ser linearizada por meio dos logaritmos dos valores das variáveis envolvidas.

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \beta_i \cdot X_i + \varepsilon \quad (01)$$

$$Yc = a_1 \cdot x1_i^{a_2} \cdot x2_i^{a_3} \cdot x3_i^{a_4} \dots xn_i^{a_n} \quad (02)$$

Em que:  $Y$  é a variável dependente, nesse caso, a precipitação estimada;  $X_1, X_2, \dots, X_i$ , são os as variáveis independentes, nesse caso os postos considerados;  $\beta_0, \beta_1, \beta_2, \dots, \beta_{2i}$ , são os coeficientes da regressão; e  $\varepsilon$  indica o erro residual.

Apesar da aparente limitação, uma das vantagens do método é permitir interpretar o fenômeno sem grande esforço computacional e simples interpretação. As RLM são muito utilizadas, e produzem bons resultados sempre que a variável a ser estimada depende fortemente de dois ou mais atributos ou variáveis preditivas (FONSECA *et al.*, 2012).

Entre os autores que utilizaram esses métodos para preenchimento de falhas estão: Nascimento *et al.* (2009); Oliveira *et al.* (2010); Bier e Ferraz (2017); Souza *et al.* (2017); Malfatti *et al.* (2018).

### 2.1.2 Inteligência artificial e aprendizagem de máquinas

Entre os métodos utilizados para o preenchimento de falhas, aqueles relacionados à aprendizagem de máquinas e uso inteligência artificial possuem uma concepção mais complexa que RLS e RLM e demandam um maior esforço computacional para realizar a regressão entre as variáveis de entrada e a saída (MAYER e DANDY, 2001). Entre esses métodos destacam-se as Redes Neurais Artificiais (RNA) e a Máquina de Vetores de Suporte (MVS).

A RNA é um modelo computacional inspirado no comportamento dos neurônios biológicos e consiste em um grande número de processamentos simples com muitas interconexões (GUPTA, 2013). São algoritmos que utilizam técnicas de inteligência artificial, e a aprendizagem é de forma iterativa, sem a interferência direta do usuário ou pesquisador. As RNA multicamadas contêm um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas intermediárias, também chamadas camadas ocultas (GUARNIERI, 2006).

Os dados são recebidos por meio dos neurônios na primeira camada (os atributos ou variáveis de entrada), produzem sinais de saída e estimulam os neurônios na camada intermediária, até a camada de saída (a variável a ser modelada).

Uma RNA é composta por um conjunto de elementos computacionais, denominados neurônios artificiais, que relacionam os valores de saída e de entrada por uma equação genérica, tipo a Equação 3:

$$y^{ij} = f \left( \sum_{i'}^n y^{i'(j-1)} w_{i'}^{ij} + b^{ij} \right) \quad (03)$$

Em que:  $y^{ij}$  é o valor de saída do neurônio  $i$  da camada  $j$ ;  $n$  é o número de neurônios da camada anterior;  $y^{i'(j-1)}$  é o valor de saída do neurônio  $i'$  da camada anterior;  $w_{i'}^{ij}$  é o valor do peso sináptico do neurônio  $i$  da camada  $j$ , ativado pelo neurônio  $i'$  da camada anterior;  $b^{ij}$  é o valor de compensação do neurônio  $i$  da camada  $j$ ;  $f$  é a função de ativação do neurônio  $i$ , podendo ser linear, sigmoideal ou outra.

Um dos algoritmos mais utilizados para modelar dados numéricos usando RNA é o método retropropagativo com múltiplas camadas (RUMELHART *et al.*, 1986), usando a Regra Delta (WIDROW e HOFF, 1960) para atualização dos pesos sinápticos da rede. Os valores dos atributos de entrada costumam ser escalonados a partir de transformações lineares, já que a diferença de unidades de medidas entre as entradas pode influenciar no desempenho da rede.

Entre os autores que utilizaram esses métodos para preenchimento de falhas estão Lucio *et al.* (2006); Carvalho (2007); Depiné *et al.* (2014); Correia *et al.* (2016).

Outro método que se destaca é a Máquina de Vetores de Suporte (MVS), que representa um conjunto de métodos de aprendizagem supervisionados para

classificação e regressão. O classificador MVS mapeia os vetores de características das amostras (pixels, por exemplo), como entrada para o algoritmo em um espaço de maior dimensão, onde se supõe que elas sejam separáveis linearmente (Freitas *et al.*, 2010). Segundo Schölkopf e Smola (2002), ele tem uma fundamentação mais sólida do que as RNA, sendo capazes de substituí-las com desempenho semelhante. Para Weigend *et al.* (1995), com sua extensão para o tratamento de problemas de regressão, a MVS mostra-se altamente competitiva, com destaque para as aplicações envolvendo predição de séries temporais.

A aplicação de MVS como técnica de regressão se dá pela introdução de uma função de perda (SCHÖLKOPF e SMOLA, 2002) na qual, segundo Lima (2004), ocorre uma reversão de propósito quando comparado ao tratamento adotado junto a problemas de classificação binária, com o objetivo de maximizar a capacidade de generalização. As MVS possuem diferentes núcleos que caracterizam o seu reconhecimento de padrões, entre os quais: Linear, Polinomial, Gaussiano e Sigmoidal.

Uma das principais vantagens das MVS é a elevada capacidade de generalização, ou seja, se trata de uma medida da eficiência na previsão de dados que não pertençam ao conjunto utilizado para o treinamento, evitando-se o superajustamento, situação na qual se obtêm baixos erros no conjunto de treinamento e erros elevados no conjunto de previsão (FERRÃO *et al.*, 2007).

### **2.1.3 Interpolação espacial ponderada**

O terceiro grupo de métodos utilizados no preenchimento de dados de precipitação se refere aos interpoladores espaciais. Embora nem sempre apresentem os melhores índices de desempenho e acurácia, sua vantagem para estimar e preencher falhas históricas se deve ao contexto espacial, isto é, utiliza a localização para ponderar o peso de cada estação na estimativa (CASTRO *et al.*, 2010; WAGNER *et al.*, 2012).

A interpolação espacial é um procedimento matemático e/ou geoestatístico de ajuste de uma função para estimar valores de uma variável em um local a partir de pontos amostrais, derivando uma superfície contínua que representa a grandeza do

evento analisado, denominada como modelo digital ou modelo numérico (LANDIM, 2000). Se diferencia dos anteriores por sua capacidade de ponderar pontos amostrais pela distância ou pela localização e tem a grande vantagem de facilitar a distribuição espacial de dados pontuais, estimando os dados recorrentes entre as amostras (GIACOMIN *et al.*, 2014).

Entre as técnicas de interpolação espacial de precipitação, pode-se destacar: Inverso da Potência da Distância (IPD); Vizinho Natural (VN); *Spline* (SPL); *Krigagem* (KRG). De modo geral, esses métodos permitem adotar critérios de busca de pontos amostrais vizinhos ao local onde se deseja estimar a precipitação. Os mais comuns são: i) raio de alcance da amostragem; ii) número máximo de pontos amostrais; iii) busca de amostras com limite por quadrante ou octante (VALENTE, 1995).

O IPD é adotado em estudos do clima, para interpolar precipitação diária em bacias hidrográficas, ou parâmetros de equações de chuvas intensas para locais desprovidos de dados pluviométricos, utilizando estações meteorológicas adjacentes (Assad e Evangelista, 1994). De acordo com Lam (1983) é um ponderador versátil, fácil de programar e bastante preciso. Sua formulação (Equação 04) estabelece que o peso de uma estação ou ponto amostral é inversamente proporcional a sua distância (elevada a uma determinada potência) do local onde se deseja estimar o valor. O IPD é um interpolador determinístico univariado de médias ponderadas (MELLO *et al.*, 2009).

$$xp = \frac{\sum_{i=1}^n \left( \frac{1}{d_i^p} \cdot x_i \right)}{\sum_{i=1}^n \left( \frac{1}{d_i^p} \right)} \quad (04)$$

Em que:  $x_p$  é o atributo interpolado;  $x_i$  é o valor do atributo do  $i$ -ésimo ponto de amostragem;  $d_i$  é a distância euclidiana entre o  $i$ -ésimo ponto de vizinhança e o ponto amostrado;  $n$  é o número de amostras;  $p$  é a potência escolhida.

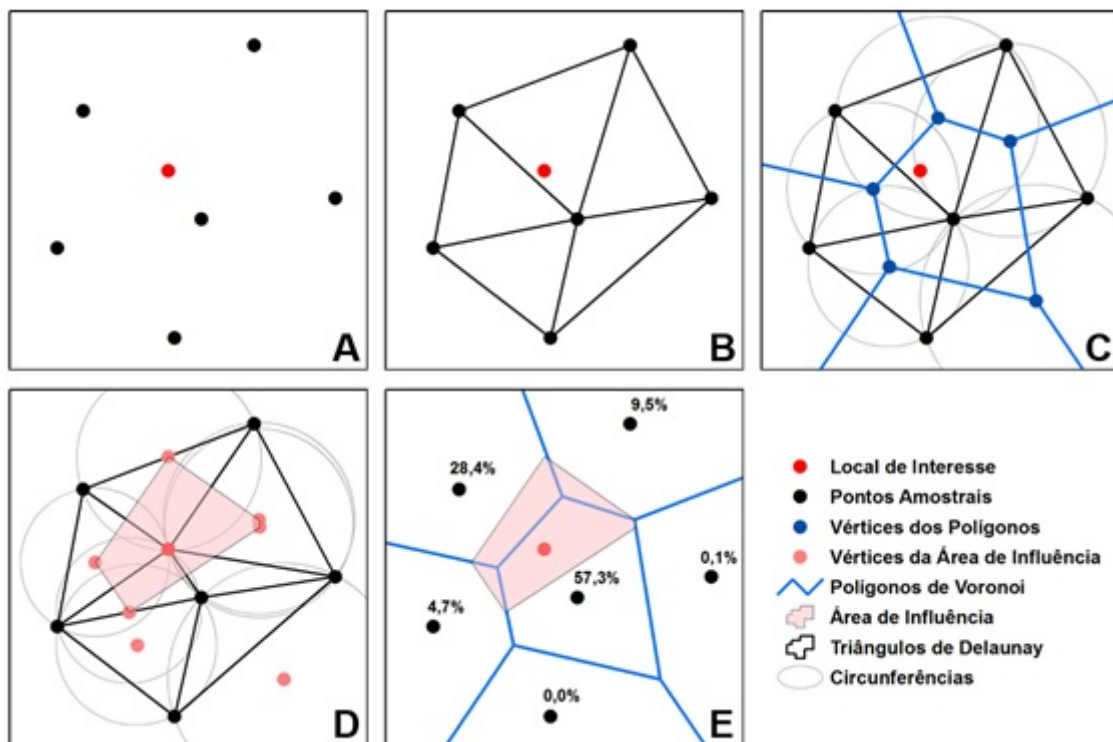
O método do Vizinho Natural (VN) utiliza a triangulação de Delaunay e o diagrama de Voronoi para descobrir a vizinhança mais apropriada para obter o valor de precipitação em um dado ponto, a partir de um conjunto amostral (Figura 6A). É adequado tanto para malhas regulares como irregulares (WATSON, 1999). O VN



não extrapola valores, resolvendo a interpolação somente para o interior do domínio dos dados, assim como o IPD.

Os polígonos de Voronoi são construídos a partir da triangulação de Delaunay (Figura 6B). Uma propriedade da triangulação é de que uma circunferência qualquer definida pelos três vértices de um triângulo não pode conter qualquer outro ponto amostral no seu interior. Os polígonos são construídos, considerando como vértices o centro das circunferências que envolvem os triângulos, formando áreas irregulares (Figura 6C). A técnica de Voronoi é aplicada novamente, porém considerando o local de interesse na triangulação, para identificar a área de influência do local de interpolação (Figura 6D). Por fim, a área de intersecção entre os polígonos de Voronoi (um polígono para cada estação pluviométrica) e a área de influência do ponto a ter o valor interpolado revela o peso de cada estação na estimativa da precipitação (Figura 6E) (SIBSON, 1981; LANÇA, 2004; MAZZINI e SCHETTINI, 2009; SMITH, 2009).

Figura 6 – Processo de interpolação pelo método do vizinho natural, baseado na triangulação de Delaunay e no diagrama de Voronoi.



Fonte: Elaboração própria.

O método *Spline* (SPL), também considerado como mínima curvatura, utiliza um polinômio para gerar uma superfície que minimize a curvatura da mesma, resultando em uma superfície suavizada que passa através dos pontos amostrados reproduzindo os valores de cada variável (ANDRIOTTI, 2005). O autor destaca que isto não ocorre sempre, e não pode ser considerado um interpolador exato, pois o polinômio pode gerar valores fora do domínio de amostragem.

A interpolação por *Splines* origina anomalias na superfície da interpolação, em função da aplicação de polinômios de ordens maiores, não condizentes com os valores amostrais e superfície esperada (LANCASTER e SALKAUSKAS, 1975, *apud* LAM, 1983). Para Souza *et al.* (2011) não é um modelo adequado para espacializar a pluviosidade, suaviza o resultado e não contempla mudanças bruscas do fenômeno, gera erros na malha e prejudica a qualidade da superfície de chuva modelada e do preenchimento de falhas históricas nos dados pluviométricos.

Segundo Marcuzzo *et al.* (2011), uma função *Spline*  $S(x)$ , Equação 5, deve preencher a condição de que  $S(x)$  para os pontos medidos deve ser igual a  $z(x)$  e ao mesmo tempo a seminorma de suavização  $I(S)$ , Equação 6, deve ser o menor possível.

$$S(x_j) = z(x_j) \quad (05)$$

$$I(S) = \min \quad (06)$$

Em que:  $z(x_j)$  são valores das variáveis nos pontos  $x_j$  amostrados; e  $I(S)$  é uma função que mede a suavização de  $S$ , chamada de seminorma de suavização. Um ponto  $x$  é definido pelos valores  $(x_1$  e  $x_2)$  sendo  $x_1$  a localização na coordenada  $x$  cartesiana e  $x_2$  a coordenada  $y$  cartesiana.

*Krigagem* (KRG) é o nome genérico, adaptado pela geoestatística para a família de algoritmos de regressão de mínimos quadrados generalizados (GOOVAERTS, 1997). Tem a capacidade de produzir melhores estimativas, porque está embasada em duas premissas: não-tendenciosidade do estimador e variância mínima das estimativas (THOMPSON, 1992). O KRG é considerado, segundo Mello *et al.* (2003) e Remacre *et al.* (2008), um dos mais eficientes em interpolações espaciais. Estima a variável interpolada na posição  $p(X_p)$ , a partir do

estabelecimento do peso de *Krigagem* ( $\lambda$ ), de cada uma das  $n$  observações vizinhas ( $X_i$ ), de acordo com sequência de cálculos, Equações 07 e 08, (THOMPSON, 1992):

$$[A]^{-1} \cdot [b] = [\lambda] \quad (07)$$

Em que:  $[A]^{-1}$  é a matriz inversa de semivariância entre as localidades da vizinhança de um ponto, determinada pelo modelo de semivariograma com base nas distâncias euclidianas entre as localidades;  $[b]$  é a matriz de semivariância entre as localidades vizinhas (com a variável estimada) e o ponto para o qual a variável será interpolada, também determinado pelo modelo de semivariograma, com base nas distâncias pelo entre as localidades vizinhas e o ponto a ser interpolado;  $[\lambda]$  é a matriz de pesos da *Krigagem*.

$$X_p = \sum_{i=1}^n \lambda_i \cdot X_i \quad (08)$$

Em que:  $X_p$  é a variável interpolada;  $\lambda_i$  é o peso da  $i$ -ésima localidade vizinha;  $X_i$  é o valor da variável para a  $i$ -ésima localidade;  $n$  é o número de localidades vizinhas empregadas para interpolação do ponto.

## 2.2 Estimativa de precipitação por sensoriamento remoto

Nas últimas décadas, técnicas de sensoriamento remoto possibilitaram o acesso a dados de precipitação estimados por satélites meteorológicos, permitindo a observação e monitoramento contínuo do tempo e do clima em nível global (STEPHENS e KUMMEROW, 2007; MOREIRA *et al.*, 2017).

A utilização de sensores orbitais pode ser de grande auxílio para contornar as dificuldades de monitoramento, pois através de técnicas de sensoriamento remoto é possível obter informações de variabilidade da precipitação, sendo vantajoso especialmente em localidades nas quais é inviável a instalação de estações meteorológicas (LI *et al.*, 2012).

Embora menos precisas quando comparadas com medidas pontuais obtidos *in situ*, por meio de estações pluviométricas automáticas (COLLISCHONN *et al.*, 2007), as estimativas por sensoriamento remoto apresentam a vantagem de registrar a distribuição espacial da precipitação (PRAKASH *et al.*, 2016; SIUKI *et al.*, 2016; ZHANG *et al.*, 2018; SILVA LELIS *et al.*, 2020).

Uma das desvantagens das medições de precipitação baseadas em satélite incluem incertezas em relação a padrões não homogêneos em diversas regiões, devido ao método de medição indireta (CHEN *et al.*, 2013). Condições de nuvem, algoritmos de recuperação e propriedades da superfície da terra podem induzir erros na estimativa final da precipitação (KUMMEROW *et al.*, 2000).

A ideia de medir a precipitação do espaço usando um complemento de instrumentos combinado de instrumentos de micro-ondas passivos e ativos (radar) foi gerada no início dos anos 1980. Em setembro de 1984, uma proposta intitulada “Missão de medição da chuva tropical” (KUMMEROW *et al.*, 2000).

Os vôos conjuntos de aeronaves com um radar experimental sugeriram que a precisão do instrumento era promissora. A baixa órbita da Terra necessária para realizar tais medições de uma plataforma espacial, no entanto, imediatamente levantou preocupações sobre a adequação da amostragem de tal satélite (MENEGHINI *et al.*, 1992).

Garantir a credibilidade das medições de precipitação por sensoriamento remoto também foi uma preocupação desde o início, sendo estabelecida a necessidade de observações confiáveis baseadas na superfície terrestre para validar as medições do satélite TRMM (KUMMEROW *et al.*, 2000).

Com o objetivo de monitorar as características globais de precipitação nos trópicos e subtropicais, foi lançado em 1997, o TRMM (*Tropical Rainfall Measuring Mission*), um projeto conjunto entre a *National Aeronautics and Space Administration* (NASA) e a *Japan Aerospace and Exploration Agency* (JAXA). Segundo Kummerow *et al.* (2000) os produtos do TRMM contribuem para obter informações em regiões com baixa densidade de rede de observações pluviométricas.

O TRMM destaca-se por coletar informações sobre a precipitação em uma área do globo compreendida entre as latitudes 40°N e 40°S, possuindo dois sensores principais: *precipitation Radar* (PR) e o TRMM Microwave Imager (TMI) (FISHER, 2004; JI, 2006; HUFFMAN *et al.*, 2007).

Stocker *et al.* (2018), destacam que o reprocessamento de dados é parte importante das missões científicas orientadas pela NASA (*National Aeronautics and Space Administration*). Dessa forma, o último reprocessamento de todos os dados

de precipitação do TRMM foi realizado já com algoritmos de recuperação baseados nos algoritmos da missão GPM.

Em 2014 a missão *Global Precipitation Measurement* (GPM), desenvolvida pela *National Aeronautics and Space Administration* (NASA) e pela *Japanese Exploration Agency* (JAXA) lançou o Satélite Observatório Central (SOC) (SKOFRONICK-JACKSON *et al.* (2016). A missão GPM é uma constelação internacional de satélites e consiste em um SOC e cerca de dez satélites parceiros (BEAUFORT *et al.*, 2018), com resoluções temporais e espaciais mais detalhadas que seu antecessor (LIU e ZIPSER, 2015).

O produto IMERG (*Intercalibrated Merged Retrievals for GPM*) é um dos muitos disponíveis para estimar a precipitação no planeta, com dados de vários satélites mesclados (GADELHA, 2018). Esse algoritmo permite acessar uma coleção de dados de precipitação acumulada (mm), em diferentes discretizações temporais (desde a precipitação acumulada a cada 3 horas até a precipitação mensal), e resolução espacial de, aproximadamente, 10 km. Sintetiza as vantagens de algoritmos de precipitação anteriores (SKOFRONICK-JACKSON *et al.*, 2017), o que torna o GPM mais sensível do que o TRMM na medição de precipitação (LIU e ZIPSER, 2015).

Tang *et al.* (2016) compararam os dados das missões TRMM e GPM. Mesmo com a baixa disponibilidade de dados do GPM no momento do estudo, os resultados foram promissores, destacando que o produto IMERG (um dos produtos de precipitação diária da missão GPM), pode substituir adequadamente os produtos do TRMM, tendo reduzido significativamente a superestimação dos produtos TRMM em relação aos dados de referência.

Fang *et al.* (2019), ao comparar o produto IMERG com o produto TRMM 3B42, constatou que, embora ambos apresentem dificuldade em detectar eventos extremos, em quase todas as métricas de avaliação o produto da missão GPM foi superior em relação ao produto do TRMM.

Jaber (2020), comparando produtos TRMM e GPM concluiu que o GPM IMERG é superior em relação ao seu predecessor. Para esse autor, a necessidade de correção do Viés é menor nos produtos IMERG. Soto-Alvarez *et al.* (2020) também

argumentam que, os produtos 3IMERGM apresentaram respostas mais precisas que o TRMM.

Rozante *et al.* (2018), compararam produtos da missão GPM (IMERG) e TRMM (TMPA) para o território brasileiro, com o objetivo de verificar se o produto IMERG pode substituir adequadamente o TMPA. Os resultados indicaram comportamento semelhante para os produtos IMERG e TMPA, mostrando que eles superestimam a precipitação. No entanto, como o IMERG apresenta uma melhor resolução espacial e temporal, o mesmo se destaca como um bom substituto.

### **3. DESENVOLVIMENTO**

#### **3.1 ARTIGO 1 - Preenchimento de Falhas e Espacialização de Dados Pluviométricos: Desafios e Perspectivas**

Artigo publicado na Revista Brasileira de Meteorologia.



Revista Brasileira de Meteorologia, v. 35, n. 4, 615-629, 2020  
 DOI: <http://dx.doi.org/10.1590/0102-7786354006>

## Preenchimento de Falhas e Espacialização de Dados Pluviométricos: Desafios e Perspectivas

João Paulo Brubacher<sup>1</sup>, Guilherme Garcia de Oliveira<sup>1</sup>, Laurindo Antonio Guasselli<sup>1</sup>

*<sup>1</sup>Laboratório de Geoprocessamento e Análise Ambiental, Programa de Pós-Graduação em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil.*

Recebido em: 20 de agosto de 2019 - Aceito em: 23 de Março de 2020

### Resumo

A precipitação é uma das variáveis climáticas mais importantes para o planejamento urbano e rural, para monitorar eventos extremos que possam causar impactos na sociedade e auxiliar em projetos de drenagem urbana, a fim de reduzir os riscos inerentes a inundações e alagamentos, ou mesmo obras de engenharia, como dimensionamento de barragens. No entanto, as falhas em séries extensas prejudicam esses estudos, sendo necessário utilizar modelos para o seu preenchimento. O presente estudo tem como objetivo revisar os métodos de preenchimento de falhas e de interpolação espacial de dados de precipitação. A revisão dos métodos foi realizada a partir da pesquisa e leitura de materiais bibliográficos, de modo a conceituar as abordagens, identificar vantagens e desvantagens de cada método e apresentar como estudos recentes, nacionais e internacionais, têm inovado ao comparar o desempenho em diferentes áreas de estudo. Com base nessa revisão, os principais métodos para o preenchimento de falhas são os seguintes: i) ponderação a partir de Regressão Linear Simples ou Múltipla; ii) modelos matemáticos baseados em aprendizagem de máquinas, tais como as Redes Neurais Artificiais; iii) interpoladores espaciais para o preenchimento de falhas (Inverso da Distância, Vizinho Natural, Krigagem). Por fim, foi verificada uma evolução das técnicas de interpolação e de preenchimento de falhas nas últimas décadas, em decorrência da evolução da capacidade computacional e tecnológica.

**Palavras-chave:** precipitação, regressão, interpolação espacial, geoprocessamento.

## Gap Filling and Pluviometrics Spacialization Data: Challenges and perspectives

### Abstract

Precipitation is one of the most important climatic variables for urban and rural planning, to monitor extreme events that may have an impact on society and to assist in urban drainage projects, in order to reduce the risks of floods, or even engineering works, such as dams dimensioning. However, failures in extensive series hamper these studies, and it is necessary to use models to fill them. The present study aims to review the methods of filling in gaps and spatial interpolation of precipitation data. The review of the methods was carried out from the research and reading of bibliographic materials, in order to conceptualize the approaches, identify the advantages and disadvantages of each method and present how recent studies, national and international, have innovated when comparing the performance in different areas of study. Based on this review, the main methods for filling gaps are as follows: i) weighting from Simple or Multiple Linear Regression; ii) mathematical models based on machine learning, such as Artificial Neural Networks; iii) spatial interpolators for filling gaps (Distance Inverse, Natural Neighbor, Krigagem). Finally, there was an evolution in the interpolation and fault filling techniques in the last decades, due to the evolution of computational and technological capacity.

**Keywords:** precipitation, regression, spatial interpolation, geoprocessing.



## 1. INTRODUÇÃO

O debate sobre mudanças climáticas globais coloca a variável precipitação no centro da discussão, sendo um parâmetro-chave no estudo do clima. Por se tratar de um importante componente do ciclo hidrológico, os processos resultantes da movimentação e armazenamento de água estão relacionados a diversos setores da sociedade, como abastecimento de água e irrigação, de forma que alterações no regime pluviométrico afetam o ambiente e a população como um todo (Mekis *et al.*, 2018).

Conhecer o regime pluviométrico de uma bacia hidrográfica é determinante em projetos relacionados ao uso da água e de planejamento urbano (Henrichs *et al.*, 2018), tanto para mitigar desastres relacionados a eventos extremos de precipitação, como inundações, enxurradas, alagamentos e movimentos de massa; quanto as dificuldades provocadas pela falta de chuvas, como as estiagens e as secas (Oliveira *et al.*, 2005; Trenberth, 2011; Santos, 2015; Raghavendra *et al.*, 2019; Zhao *et al.*, 2019).

O monitoramento da precipitação e a organização de um banco de dados históricos ajudam a compreender a complexidade desses fenômenos, tanto para verificação de médias históricas quanto para espacialização e modelagem de eventos futuros (Zarekarizi *et al.*, 2018). Estudos com viés ambiental de previsão do tempo, de modelagem e de variabilidade climática, por exemplo, principalmente no que se refere a análises de longo prazo, como simulação de inundações e dimensionamento de barragens, necessitam de séries temporais confiáveis de precipitação e vazão (Mateus, 2006; Li *et al.*, 2010; Paz, 2010).

No Brasil, as redes de monitoramento são operadas pela Agência Nacional de Águas - ANA, que desenvolve e opera sistemas de alertas contra cheias em áreas

críticas, além de produzir estudos em áreas específicas. No entanto, as estações pluviométricas existentes, não só no Brasil, mas no mundo (Villazón e Willems; 2010), podem apresentar lacunas nas séries de dados, especialmente no que se refere às séries mais longas.

O preenchimento de séries de precipitação costuma ser incômodo porque restrições físicas, como terrenos complexos e baixa densidade de estações meteorológicas, limitam o seu desempenho (Kim e Ryu, 2016). Falhas pluviométricas e hidrológicas podem ocorrer por erro humano, por falha nos aparelhos, no processamento ou por perda de dados. Para trabalhar com séries contínuas torna-se necessário que essas falhas sejam preenchidas (Oliveira *et al.*, 2010). Em simulações ou previsão hidrológicas, dificultam o ajuste de distribuições estatísticas aos dados históricos, reduz o desempenho de modelos hidrológicos ou até mesmo inviabiliza suas aplicações. Dessa forma, há a necessidade de preenchimento de falhas e verificar a consistência dos dados após o preenchimento (Bárdossy e Pegram, 2014; Depiné *et al.*, 2014).

Existem diversos métodos para o preenchimento de lacunas em dados de precipitação. Boa parte deles se baseia na proposta de interpolação espacial, frequentemente aplicada com auxílio de ferramentas de geoprocessamento em *softwares* que manipulam dados georreferenciados, como os Sistemas de Informações Geográficas (SIG).

A integração entre modelos hidrológicos e SIG se apresenta como uma forma viável de descrever os processos hidrológicos em bacias hidrográficas (Baumgartner e Apfl, 1996; Collischonn *et al.*, 2007, Melo *et al.*, 2008). No entanto, limitações na manipulação de dados hidrológicos ocorrem devido à quantidade de dados relacionados com a variabilidade espacial e temporal das características que descrevem a heterogeneidade do seu

comportamento, quando essa variabilidade implica em limitações na aplicação dos modelos (Machado, 2002).

Guimarães *et al.* (2017) utilizaram o software ArcGIS 10.2 e dados do Atlas Pluviométrico do Brasil, publicado pelo Serviço Geológico do Brasil, cuja série histórica é de 1977 a 2006, ou seja, 30 anos de dados, com o objetivo de realizar a espacialização pluviométrica na parte brasileira da bacia do rio Uruguai. Marcuzzo (2019) realizou o mesmo tipo de estudo para a região metropolitana de Teresina/PI, utilizando ainda o interpolador Topo to Raster. Ambos estudos demonstram a importância de conhecer o comportamento das chuvas de uma região, visando um contexto de sistema de alerta de eventos extremos.

Em linhas gerais, o monitoramento da precipitação é realizado a partir de pluviômetros e estações meteorológicas, com coleta pontual da precipitação. Neste caso, são aplicados métodos de interpolação para espacializar as chuvas (Cecílio e Pruski, 2003; Carvalho e Assad, 2005). O mapeamento da precipitação pluvial e de outras variáveis ambientais é de fundamental importância na pesquisa científica em recursos hídricos e hidrologia (Silva, 2011; Ly *et al.*, 2013), agricultura e florestas (Viola *et al.*, 2010; Fibbi *et al.*, 2016), climatologia e meteorologia (Yang *et al.*, 2015; Kim e Ryu, 2016; Gundogdu, 2017; Zhou, 2019).

Nesse contexto, o presente estudo tem como objetivo revisar os métodos de preenchimento de falhas e de interpolação espacial de dados de precipitação, conceituar as abordagens, identificar as vantagens e desvantagens de cada método e apresentar estudos nacionais e internacionais que têm feito inovações por meio de estudos comparativos com indicação de desempenho em diferentes áreas de estudo.

## 2. A Concepção dos Métodos de Preenchimento de Falhas e Interpolação Espacial

As redes hidrometeorológicas de monitoramento no mundo tiveram diferentes períodos de funcionamento, algumas funcionam há mais de um século, outras funcionaram por poucos anos ou em períodos escalonados. No Brasil, poucas estações possuem mais de cem anos de dados disponíveis (Bier e Ferraz, 2017). No entanto, tanto as redes mais antigas quanto as mais novas e modernas, podem apresentar lacunas nas séries.

O aumento da disponibilidade de dados, segundo Mekis *et al.* (2018), inclusive de estações manuais de longa duração, beneficiam os usuários. A restrita cobertura espacial e a qualidade dos dados são problemas a serem enfrentados. Dependendo da aplicação, séries de dados com falhas podem, ter seu uso descartado, devido à necessidade de confiabilidade. Caso isso não aconteça, a espacialização e a análise estatística relacionados à frequência e à distribuição de eventos extremos podem ter seus resultados prejudicados.

Uma importante restrição deve ser seguida para o preenchimento de falhas, que se refere à seleção de estações meteorológicas ou pluviométricas utilizadas. Segundo Zeilhofer *et al.* (2003), para preenchimento de falhas é necessário utilizar pares de pontos com máxima correlação. Leivas *et al.* (2006) recomendam a seleção de estações meteorológicas da mesma região ecoclimática e altitude semelhantes, caracterizando-a como hidrológicamente homogênea. Essa escolha se mostra coerente, pois aumenta a possibilidade de que os dados pluviométricos sejam semelhantes entre as estações, e maior a probabilidade de boa correlação em relação às lacunas existentes, determinante na escolha da técnica de interpolação.

A análise de eventos de precipitação engloba processos hidrológicos estocásticos, governados por leis de probabilidade, porém com componentes aleatórios que estão acima das regularidades eventualmente explicáveis (Naghattini e Pinto, 2007). Seguindo essa lógica, Junior e Vanzela (2016) avaliaram a influência do relevo na distribuição espacial das precipitações médias anuais e mensais de Caraguatatuba, SP, e concluíram que o relevo exerce influência significativa sobre a distribuição espacial das precipitações. Segundo Groisman e Legates (1993) e Viola *et al.* (2010) a altitude é um parâmetro relevante como variável secundária no processo de interpolação espacial, devendo ser incorporada à análise para obtenção de mapeamentos mais precisos e realistas da precipitação.

Como os padrões espaços-temporais das chuvas são complexos, não lineares e altamente variáveis, a distribuição espacial das estações pluviométricas e a distância entre elas tem grande influência no preenchimento de falhas e interpolação de dados, visando gerar superfícies homogêneas de precipitação (Depiné *et al.*, 2014).

Observa-se na literatura científica uma série de métodos utilizados para o preenchimento de falhas como, por exemplo: i) ponderação a partir de Regressão Linear Simples ou Múltipla; ii) modelos matemáticos baseados em aprendizagem de máquinas, tais como as Redes Neurais Artificiais; iii) interpoladores espaciais para o preenchimento de falhas (Inverso da Distância, Vizinho Natural, Krigagem).

Na Regressão Linear Simples (RLS) ou Regressão Linear Múltipla (RLM), a precipitação no posto com falhas é correlacionada estatisticamente com a precipitação em um posto vizinho com dados, no caso da regressão simples, ou vários postos vizinhos, no caso da regressão múltipla. Segundo Tucci (2002)

e Bertoni e Tucci (2007) no método RLS, as estimativas dos parâmetros são obtidas graficamente ou por meio dos mínimos quadrados para calibração dos valores de forma iterativa.

Na regressão múltipla, as informações pluviométricas do posto  $Y$  são correlacionadas com as observações correspondentes de vários postos vizinhos, por meio de uma equação linear (Eq. (1)) ou por outros tipos de relação, como a potencial (Eq. (2)). A segunda expressão pode ser linearizada por meio dos logaritmos dos valores das variáveis envolvidas.

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_i \cdot X_i + \varepsilon \quad (1)$$

$$Yc = a_1 \cdot x1_i^{a_2} \cdot x2_i^{a_3} \cdot x3_i^{a_4} \dots \cdot xn_i^{a_n} \quad (2)$$

Em que:  $Y$  é a variável dependente, nesse caso, a precipitação estimada;  $X_1, X_2, \dots, X_i$ , são as variáveis independentes, nesse caso os postos considerados;  $\beta_0, \beta_1, \beta_2, \dots, \beta_{2i}$ , são os coeficientes da regressão; e  $\varepsilon$  indica o erro residual.

Apesar da aparente limitação, uma das vantagens do método é permitir interpretar o fenômeno sem grande esforço computacional e simples interpretação. As RLM são muito utilizadas, e produzem bons resultados sempre que a variável a ser estimada depende fortemente de dois ou mais atributos ou variáveis preditivas (Fonseca *et al.*, 2012).


Um segundo conjunto de métodos, relacionado à aprendizagem de máquina e uso de inteligência artificial, é mais complexo e demanda um esforço computacional maior para realizar a regressão entre as variáveis de entrada e a saída. Os avanços recentes na computação e no geoprocessamento, são utilizados para estimar variáveis numéricas da natureza, tais como a precipitação. Destacam-se as

Redes Neurais Artificiais (RNA) e a Máquina de Vetores de Suporte (MVS).

A RNA é um modelo computacional inspirado no comportamento dos neurônios biológicos e consiste em um grande número de processamentos simples com muitas interconexões (Gupta, 2013). São algoritmos que utilizam técnicas de inteligência artificial, e a aprendizagem é de forma iterativa, sem a interferência direta do usuário ou pesquisador. As RNA multicamadas contêm um conjunto de neurônios de entrada, uma camada de saída e uma ou mais camadas intermediárias,

também chamadas camadas ocultas (Guarnieri, 2006).

Os dados são recebidos por meio dos neurônios na primeira camada (os atributos ou variáveis de entrada), produzem sinais de saída e estimulam os neurônios na camada intermediária, até a camada de saída (a variável a ser modelada). A Fig. 1 mostra a arquitetura de uma RNA com três entradas, duas camadas intermediárias com quatro neurônios cada e uma camada de saída com um neurônio, produzindo uma única informação de saída.



**Figura 1:** Exemplo da estrutura de funcionamento de uma rede neural artificial. Fonte: Adaptado de Haykin, 2008.

Uma RNA é composta por um conjunto de elementos computacionais, denominados neurônios artificiais, que relacionam os valores de saída e de entrada por uma equação generica (Eq. (3)):

$$y^{ij} = f\left(\sum_{i'}^n y^{i'(j-1)} w_{i'j}^{ij} + b^{ij}\right) \quad (3)$$

Em que  $y^{ij}$  é o valor de saída do neurônio  $i$  da camada  $j$ ;  $n$  é o número de neurônios da camada anterior;  $y^{i'(j-1)}$  é o valor de saída do neurônio  $i'$  da camada anterior;  $w_{i'j}^{ij}$  é o valor do peso sináptico do neurônio  $i$  da camada  $j$ , ativado pelo neurônio  $i'$  da camada anterior;  $b^{ij}$  é o valor de compensação do neurônio  $i$  da camada  $j$ ;  $f$

é a função de ativação do neurônio  $i$ , podendo ser linear, sigmoidal ou outra.

Um dos algoritmos mais utilizados para modelar dados numéricos usando RNA é o método retropropagativo com múltiplas camadas (Rumelhart *et al.*, 1986), usando a Regra Delta (Widrow e Hoff, 1960) para atualização dos pesos sinápticos da rede. Os valores dos atributos de entrada costumam ser escalonados a partir de transformações lineares, já que a diferença de unidades de medidas entre as entradas pode influenciar no desempenho da rede.

Nas RNA, se utiliza uma série de validação cruzada paralela à série de treinamento e um número limitado de ciclos de aprendizagem, evitando o

superajustamento do modelo e garantindo uma boa capacidade de generalização da rede para a estimativa dos valores de precipitação. É comum testar conjuntos de atributos de entrada e número de neurônios na camada intermediária da rede, para adequar a arquitetura de RNA para o problema modelado. Uma vez que a inicialização dos pesos é aleatória, um conjunto de iterações também é necessário para cada configuração do modelo, pois não há garantia de que já na primeira tentativa se atinja um ótimo ajuste dos pesos sinápticos da rede (Oliveira *et al.*, 2015).

As RNA aprendem de modo iterativo e generalizam, ou seja, aprendem de forma autônoma, extraem informações de amostras dos valores de entrada e suas saídas e generalizam através da sua capacidade de responder a situações não previstas durante a aprendizagem (Dornelles *et al.*, 2013). Uma das principais vantagens das RNA é a sua capacidade de solucionar problemas, por meio da aprendizagem a partir de exemplos, e generalizar a informação fornecida (Zanata, 2005), e são potencialmente capazes de tratar relações não-lineares entre as variáveis independentes (Matsumoto, 2008).

De acordo com Sárközy (1999) podem ser usadas como ferramentas de interpolação. Sua capacidade de aprendizado para diferentes parâmetros de entrada a torna capaz de resolver problemas complexos, incluindo a estimativa de precipitação a partir dos valores observados em postos vizinhos. Para previsão espacial de chuvas intensas (French *et al.*, 1992), as RNA são capazes de modelar relações não-lineares sem a necessidade de assumir previamente uma distribuição básica para os dados, além da possibilidade de trabalhar com uma grande quantidade de dados (Valença, 1999). É potencialmente útil em situações nas quais as relações dos processos físicos ainda não

são completamente compreendidas (Sousa e Souza, 2010).

Outro método que se destaca é a Máquina de Vetores de Suporte (MVS), que representa um conjunto de métodos de aprendizagem supervisionados para classificação e regressão. O classificador MVS mapeia os vetores de características das amostras (pixels, por exemplo), como entrada para o algoritmo em um espaço de maior dimensão, onde se supõe que elas sejam separáveis linearmente (Freitas *et al.*, 2010). Segundo Schölkopf e Smola (2002) tem uma fundamentação mais sólida do que as RNA, sendo capazes de substituí-las com desempenho semelhante. Para Weigend *et al.* (1995), com sua extensão para o tratamento de problemas de regressão, a MVS mostra-se altamente competitiva, com destaque para as aplicações envolvendo previsão de séries temporais.

A aplicação de MVS como técnica de regressão se dá pela introdução de uma função de perda (Schölkopf e Smola, 2002) na qual, segundo Lima (2004), ocorre uma reversão de propósito quando comparado ao tratamento adotado junto a problemas de classificação binária, com o objetivo de maximizar a capacidade de generalização. As MVS possuem diferentes núcleos que caracterizam o seu reconhecimento de padrões, entre os quais: Linear, Polinomial, Gaussiano e Sigmoidal.

Uma das principais vantagens das MVS é a elevada capacidade de generalização, ou seja, se trata de uma medida da eficiência na previsão de dados que não pertençam ao conjunto utilizado para o treinamento, evitando-se o superajustamento, situação na qual se obtêm baixos erros no conjunto de treinamento e erros elevados no conjunto de previsão (Ferrão *et al.*, 2007).

O terceiro grupo de métodos utilizados no preenchimento de dados de precipitação se refere aos interpoladores espaciais. Embora nem sempre apresentem os melhores índices de desempenho e

acurácia, sua vantagem para estimar e preencher falhas históricas se deve ao contexto espacial, isto é, utiliza a localização para ponderar o peso de cada estação na estimativa (Castro *et al.*, 2010; Wagner *et al.*, 2012).

A interpolação espacial é um procedimento matemático e/ou geostatístico de ajuste de uma função para estimar valores de uma variável em um local a partir de pontos amostrais, derivando uma superfície contínua que representa a grandeza do evento analisado, denominada como modelo digital ou modelo numérico (Landim, 2000). Se diferencia dos anteriores por sua capacidade de ponderar pontos amostrais pela distância ou pela localização e tem a grande vantagem de facilitar a distribuição espacial de dados pontuais, estimando os dados recorrentes entre as amostras (Giacomin *et al.*, 2014).

Em ambiente SIG, técnicas de geoprocessamento são aplicadas para espacializar as variáveis de entrada do modelo (Viola *et al.*, 2009). Segundo Deroo e Jetten (1999) razão do uso do SIG é que o processo varia espacialmente e, assim, células de informação devem ser usadas para que a variação espacial seja considerada. Essa técnica facilita verificar a forma de distribuição espaço e no tempo das variáveis observadas nas séries históricas (SILVA *et al.*, 2007).

Na interpolação são usadas funções matemáticas, produzidas por modelos determinísticos, que podem não representar os fenômenos físicos através de conjunto de fatores que estão na sua formação. Seu objetivo é interpolar espacialmente os valores observados (Burrough, 1986; Soares, 2000). Alguns interpoladores são utilizados como técnicas para espacializar dados de precipitação, o que permite reconhecer o fenômeno de precipitação analisado, seja em períodos mais chuvosos ou mais secos, mesmo em áreas que não possuem estações pluviométricas ou para o

preenchimento de falhas em locais monitorados.

Entre as técnicas de interpolação espacial, pode-se destacar: Inverso da Potência da Distância (IPD); Vizinho Natural (VN); *Spline* (SPL); *Krigagem* (KRG). Esses métodos permitem adotar critérios de busca de pontos amostrais vizinhos ao local onde se deseja estimar a precipitação. Os mais comuns são: i) raio de alcance da amostragem; ii) número máximo de pontos amostrais; iii) busca de amostras com limite por quadrante ou octante (Valente, 1995).

O IPD é adotado em estudos do clima, para interpolar precipitação diária em bacias hidrográficas, ou parâmetros de equações de chuvas intensas para locais desprovidos de dados pluviométricos, utilizando estações meteorológicas adjacentes (Assad e Evangelista, 1994). De acordo com Lam (2013) é um ponderador versátil, fácil de programar e bastante preciso. Sua formulação (Eq. (4)) estabelece que o peso de uma estação ou ponto amostral é inversamente proporcional a sua distância (elevada a uma determinada potência) do local onde se deseja estimar o valor. O IPD é um interpolador determinístico univariado de médias ponderadas (Mello *et al.*, 2009).

$$xp = \frac{\sum_{i=1}^n \left( \frac{1}{d_i^p} \cdot x_i \right)}{\sum_{i=1}^n \left( \frac{1}{d_i^p} \right)} \quad (4)$$

Em que:  $xp$  é o atributo interpolado;  $x_i$  é o valor do atributo do  $i$ -ésimo ponto de amostragem;  $d_i$  é a distância euclidiana entre o  $i$ -ésimo ponto de vizinhança e o ponto amostrado;  $n$  é o número de amostras;  $p$  é a potência escolhida.

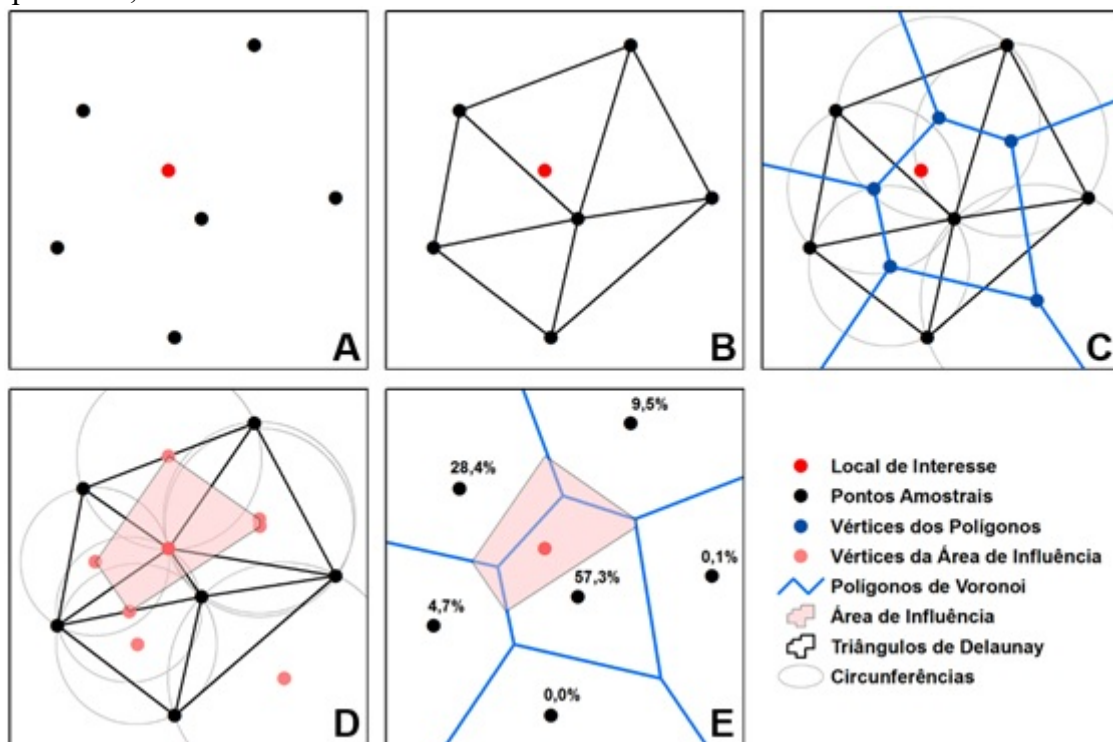
O IPD limita a interpolação ao intervalo dos valores utilizados, isto é, não

gera uma resposta de saída fora do domínio de valores de entrada dos postos pluviométricos vizinhos. Os pesos são avaliados durante o processo de interpolação, tal que a influência de cada ponto é inversamente proporcional à distância do nó da grade de interpolação. É considerado um interpolador exato ou suavizante no ponto amostral (Mazzini e Schettini, 2009). Os resultados são melhores quando a amostragem é suficientemente densa em relação à variação local que se está interpolando. Se a amostragem for escassa ou desigual, os resultados podem não representar suficientemente a superfície desejada (Dirks *et al.*, 1998; Mello *et al.*, 2003).

A sua principal vantagem é a simplicidade, além de levar a resultados

razoáveis para uma ampla variedade de dados (Caruso e Quarta, 1998). Por outro lado, o método é muito sensível à função de ponderação, ou seja, o método pode ser afetado pela distribuição desigual dos dados.

O método do Vizinho Natural (VN) utiliza a triangulação de Delaunay e o diagrama de Voronoi para descobrir a vizinhança mais apropriada para obter o valor de precipitação em um dado ponto, a partir de um conjunto amostral (Fig. 2A). É adequado tanto para malhas regulares como irregulares (Watson, 1999). O VN não extrapola valores, resolvendo a interpolação somente para o interior do domínio dos dados, assim como o IPD.



**Figura 2** – Processo de interpolação pelo método do vizinho natural, baseado na triangulação de Delaunay e no diagrama de Voronoi. Fonte: próprio autor.

Os polígonos de Voronoi são construídos a partir da triangulação de Delaunay (Fig. 2B). Uma propriedade da triangulação é de que uma circunferência qualquer definida pelos três vértices de um triângulo não pode conter qualquer outro ponto amostral no seu interior. Os

polígonos são construídos, considerando como vértices o centro das circunferências que envolvem os triângulos, formando áreas irregulares (Fig. 2C). A técnica de Voronoi é aplicada novamente, porém considerando o local de interesse na triangulação, para identificar a área de

influência do local de interpolação (Fig. 2D). Por fim, a área de intersecção entre os polígonos de Voronoi (um polígono para cada estação pluviométrica) e a área de influência do ponto a ter o valor interpolado revela o peso de cada estação na estimativa da precipitação (Fig. 2E) (Sibson, 1981; Lança, 2004; Mazzini e Schettini, 2009; Smith, 2009).

A principal diferença entre VN e IPD, é que o VN leva em consideração não apenas a distância entre as estações pluviométricas e os nós da grade de interpolação, mas também a direção e a geometria gerada pela malha de estações amostrais (Sibson, 1981). No método VN, apenas a estação pluviométrica mais próxima em cada direção é ponderada no processo de interpolação.

O *Spline* (SPL), também considerado como mínima curvatura, utiliza um polinômio para gerar uma superfície que minimize a curvatura da mesma, resultando em uma superfície suavizada através dos pontos amostrados reproduzindo os valores de cada variável (Andriotti, 2005). O autor destaca que isto não ocorre sempre, e não pode ser considerado um interpolador exato, pois o polinômio pode gerar valores fora do domínio de amostragem.

O SPL se distingue de outros métodos de interpolações polinomiais, por não utilizar apenas um polinômio de grande ordem para a interpolação do conjunto de dados. Divide a série em subconjuntos e utiliza polinômios de pequenas ordens para cada subconjunto (Mazzini e Schettini, 2009). Gera um novo *grid* de pontos e aplica sucessivamente o modelo de regressão por mínimos quadrados sobre a grade de modo iterativo, de forma que a cada passagem consiga atingir um melhor nível de suavização (Medina, 2008).

A interpolação por *Splines* origina anomalias na superfície da interpolação, em função da aplicação de polinômios de ordens maiores, não condizentes com os

valores amostrais e superfície esperada (Lancaster e Salkauskas, 1975, *apud* Lam, 1983). Para Souza *et al.* (2011) não é um modelo adequado para espacializar a pluviosidade, suaviza o resultado e não contempla mudanças bruscas do fenômeno, gera erros na malha e prejudica a qualidade da superfície de chuva modelada e do preenchimento de falhas históricas nos dados pluviométricos.

Segundo Marcuzzo *et al.* (2011), uma função *Spline*  $S(x)$  (Eq. (5)), deve preencher a condição de que  $S(x)$  para os pontos medidos deve ser igual a  $z(x)$  e ao mesmo tempo a seminorma de suavização  $I(S)$  (Eq. (6)), deve ser o menor possível.

$$S(x_j) = z(x_j) \quad (5)$$

$$I(S) = \min \quad (6)$$

em que  $z(x_j)$  são valores das variáveis nos pontos  $x_j$  amostrados; e  $I(S)$  é uma função que mede a suavização de  $S$ , chamada de seminorma de suavização. Um ponto  $x$  é definido pelos valores  $(x_1$  e  $x_2)$  sendo  $x_1$  a localização na coordenada  $x$  cartesiana e  $x_2$  a coordenada  $y$  cartesiana.

No caso da *Spline* de Tensão,  $T(x)=a_1$ , as constantes  $a_1$  e  $\lambda_j$  são determinadas resolvendo o sistema (Eq. (7) e Eq. (8)):

$$a_1 + N \sum_{j=1}^N \lambda_j r(x_1, x_j) = z_1, i = 1, \dots, N \quad (7)$$

$$\sum_{j=1}^N \lambda_j = 0 \quad (8)$$

em que  $x_i$  e  $x_j$  são os pontos amostrados; e  $z_1$  é o valor de  $z$  no local de  $x_i$ .

*Krigagem* (KRG) é o nome genérico, adaptado pela geoestatística para a família de algoritmos de regressão de mínimos



quadrados generalizados (Goovaerts, 1997). Tem a capacidade de produzir melhores estimativas, porque está embasada em duas premissas: não-tendenciosidade do estimador e variância mínima das estimativas (Thompson, 1992). A KRG é considerada, segundo Mello *et al.* (2003) e Remacre *et al.* (2008), um dos mais eficientes em interpolações espaciais. Estima a variável interpolada na posição  $p(X_p)$ , a partir do estabelecimento do peso de *Krigagem* ( $\lambda$ ), de cada uma das  $n$  observações vizinhas ( $X_i$ ), de acordo com sequência de cálculos (Eq. (9) e Eq. (10)) (Thompson, 1992):

$$[A]^{-1} \cdot [b] = [\lambda] \quad (9)$$

Em que  $[A]^{-1}$  é a matriz inversa de semivariância entre as localidades da vizinhança de um ponto, determinada pelo modelo de semivariograma com base nas distâncias euclidianas entre as localidades;  $[b]$  é a matriz de semivariância entre as localidades vizinhas (com a variável estimada) e o ponto para o qual a variável será interpolada, também determinado pelo modelo de semivariograma, com base nas distâncias pelo entre as localidades vizinhas e o ponto a ser interpolado;  $[\lambda]$  é a matriz de pesos da *Krigagem*.

$$X_p = \sum_{i=1}^n \lambda_i \cdot X_i \quad (10)$$

Em que  $X_p$  é a variável interpolada;  $\lambda_i$  é o peso da  $i$ -ésima localidade vizinha;  $X_i$  é o valor da variável para a  $i$ -ésima localidade;  $n$  é o número de localidades vizinhas empregadas para interpolação do ponto.

A extensão multivariada da *Krigagem*, conhecida como *Cokrigagem*, é um procedimento geoestatístico, no qual diversas variáveis regionalizadas podem ser estimadas em conjunto, com base na correlação espacial cruzada entre a variável primária e a variável secundária (Isaaks e Srivastava, 1989). A grande diferença em

relação à *Krigagem* ordinária está na modelagem da estrutura espacial do fenômeno por um modelo multivariado (variograma cruzado ou modelo multivariado de covariância) (Lam, 1983).

O semivariograma expressa o grau de dependência espacial entre amostras, dentro de um campo experimental, e estima os parâmetros com os quais os valores não amostrados são estimados por meio da *Krigagem*. Permite a construção de mapas de isolinhas ou tridimensionais para exame e interpretação da variabilidade espacial (Carvalho e Queiroz, 2002).

Utilizando-se *Cokrigagem Ordinária*, segundo Vieira (2000) e Viola *et al.* (2010), para se estimar um valor  $Z_{OC}^*$  em qualquer local  $x_0$ , o valor estimado resulta de uma relação linear de  $z_1$  e  $z_2$  (Eq. (11) e Eq. (12)):

$$z_{OC}^*(x_0) = \sum_{i=1}^{N_1} \lambda_{1i} z_1(x_{1i}) + \sum_{j=1}^{N_2} \lambda_{2j} z_2(x_{2j}) \quad (11)$$

em que  $N_1$  e  $N_2$  são os números de vizinhos  $Z_1$  e  $Z_2$ , respectivamente, e  $\lambda_1$  e  $\lambda_2$  são os pesos associados a cada valor de  $Z_1$  e  $Z_2$ . Ao se tomar  $Z_1(x_{1i})$  e  $Z_2(x_{2j})$  como sendo a realização das funções aleatórias  $Z_1(x_{1i})$  e  $Z_2(x_{2j})$ , respectivamente, e ao se assumir estacionaridade de ordem 2, o estimador pode ser reescrito como:

$$z_{OC}^*(x_0) = \sum_{i=1}^{N_1} \lambda_{1i} Z_1(x_{1i}) + \sum_{j=1}^{N_2} \lambda_{2j} Z_2(x_{2j}) \quad (12)$$

Esta equação expressa a estimativa da variável  $Z_{OC}^*$  deve ser uma combinação linear  $Z_1$  e  $Z_2$ : com os pesos  $\lambda_1$  e  $\lambda_2$  distribuídos de acordo com a dependência espacial de cada uma das variáveis entre si e com a correlação cruzada entre elas.

O Quadro 1 resume os principais métodos de preenchimento de falhas e interpolação utilizados para análise da precipitação.

**Quadro 1.** Principais métodos para preenchimento de falhas e interpolação da precipitação

	<b>Métodos</b>	<b>Referências</b>	<b>Vantagens</b>	<b>Desvantagens</b>
Funções gerais de regressão entre variáveis	Regressão Linear Simples (RLS), Regressão Linear Múltipla (RLM) e demais ajustes de curvas ou superfícies por meio de funções matemáticas.	Wilks, 2006; Fernandez, 2007; Tucci, 2009; Villazón e Willems, 2010; Bier e Ferraz, 2017; Souza <i>et al.</i> , 2017; Malfatti <i>et al.</i> , 2018.	Modelos de simples utilização e interpretação; não necessitam de grande esforço computacional; extensas bibliotecas de funções disponíveis em softwares para uso, fácil ajuste e validação.	Baixa capacidade de generalização dos dados, muitas vezes, desconsiderando relações não-lineares entre as variáveis.
Inteligência artificial e aprendizagem de máquinas	Redes Neurais Artificiais (RNA), Máquina de Vetores de Suporte (MVS) e demais técnicas e algoritmos de aprendizagem autômata.	Boser, 1992; Assad e Evangelista, 1994; Pinto, 1999; Umehara <i>et al.</i> 2005; Gupta, 2013; Mekanik <i>et al.</i> , 2013; Cerri e Carvalho, 2017; Sulaiman e Wahab, 2017.	Grande capacidade de aprendizado, adaptabilidade e de generalização, principalmente em situações complexas; modelos costumam apresentar melhor desempenho e acurácia.	Requer maior esforço computacional; grande volume de dados gerados; maior dificuldade de interpretação dos resultados.
Interpolação espacial ponderada pela localização e/ou outras variáveis espaciais	Inverso da Potência da Distância (IPD), Vizinho Natural (VN), <i>Splines</i> (SPL), <i>Krigagem</i> (KRG) e demais métodos geoestatísticos para estimativa de valores no espaço.	Sibson, 1981; Isaaks e Srivastava, 1989; Phillips <i>et al.</i> , 1992; Thompson, 1992; Gong <i>et al.</i> , 2014; Giacomini <i>et al.</i> , 2014; Ali <i>et al.</i> , 2017; Javari, 2017; Batista <i>et al.</i> , 2018.	Os pesos são determinados considerando contexto espacial e não de forma indireta como nas demais técnicas; costuma ser mais eficiente para regiões com alta densidade de amostras; não necessitam de grande esforço computacional.	O desempenho desses modelos é prejudicado pela distribuição irregular de pontos amostrais; alguns métodos não consideram a correlação das variáveis, resultando em erros maiores na estimativa dos valores.

### 3. Estudos Comparativos de Métodos de Preenchimento de Falhas e Interpolação Espacial da Precipitação

Castro *et al.* (2010) avaliaram o desempenho dos métodos de interpolação IPD e KRG para especializar as seguintes variáveis meteorológicas: precipitação, deficiência hídrica, excedente hídrico, evapotranspiração potencial, evapotranspiração real e disponibilidade hídrica. O método KRG foi mais eficiente para especializar os parâmetros climáticos, com base no menor valor da Raiz do Erro Médio Quadrático (REM<sub>Q</sub>) e outros

parâmetros que auxiliaram na escolha do melhor modelo.

Gardiman Jr. *et al.* (2012) compararam o desempenho de cinco métodos de interpolação: Inverso da Quadrado da Distância (IPD), *Krigagem* esférica (KRG), Vizinho Natural (VN), *Spline* regularizada e *Topo to Raster*, para analisar dados pluviométricos numa bacia hidrográfica, em um período de 30 anos. Nesse caso, KRG obteve o melhor desempenho nas métricas de Erro Quadrado Médio (EQM), Percentual de Eficiência (EF%), Erro Médio Absoluto (EMA), Coeficiente de Determinação (R<sup>2</sup>) e Estimativa do Erro Padrão (EEP). A diferença entre os valores observados e

estimados pelo método KRG foi menor, se comparado aos outros quatro métodos, representando melhor a distribuição espacial da precipitação pluvial média mensal para a bacia.

Em estudo comparativo entre métodos para espacialização de precipitação, Borges *et al.* (2016) aplicaram Regressão Múltipla, Cokrigagem, KRG, IPD e SPL, em dados de seis estações pluviométricas, e analisaram qual método foi mais realista ao estimar as precipitações sazonais e anuais. A diferença entre os métodos foi pequena e diminuiu conforme a rede de observação aumenta. De modo geral, os resultados foram semelhantes onde as redes de observações são densas, com maior confiabilidade dos métodos IPD, KRG e Regressão Múltipla.

Xu *et al.* (2015) testaram métodos de interpolação para produzir superfícies de chuva, com base na observação da precipitação diária em 43 estações meteorológicas com KRG, Cokrigagem e IPD. A Krigagem e Cokrigagem registraram menor erro médio que o IPD. A Cokrigagem apresentou os melhores resultados, uma vez que o método considerou as características topográficas do terreno. Em áreas mais complexas, com alta elevação e declividade, a Cokrigagem melhorou a precisão da interpolação espacial das chuvas.

Os métodos IPD e variações de KRG: *krigagem* ordinária (OK), a *krigagem* simples (SK), *Krigagem* universal (UK), *Krigagem* do indicador (IK), a *Krigagem* da probabilidade (PK), a *Krigagem* disjuntiva (DK) e a *Krigagem* bayesiana empírica (EBK), foram avaliados por Javari (2017) utilizando precipitação mensal para um período de 40 anos, em 140 estações. Os menores valores para a Raiz do Erro Médio Quadrático (REM<sub>Q</sub>) foram encontrados para IPD (0,497), OK (0,37), UK (0,398) e EBK (0,189), fazendo com que esses métodos fossem considerados os mais adequados.

Três técnicas de interpolação espacial (KRG, IPD e SPL) foram avaliadas por Das *et al.* (2017), para identificar a técnica mais eficiente, utilizando dados de precipitação no período entre 1901 e 1985. Os erros das três interpolações foram analisados com base no desvio absoluto médio mínimo (MAD) e critério mínimo de desvio médio quadrático (MSD), indicando o IPD com os melhores índices de desempenho.

Coulibaly e Becker (2009) avaliou o desempenho de quatro métodos de interpolação espacial (IPD, Krigagem, Krigagem ordinário, Krigagem Universal e Cokrigagem) usando a precipitação coletada de 545 estações. A KRG demonstrou melhor desempenho em comparação com os outros métodos.

Para o preenchimento de falhas em séries de precipitação, Wanderley *et al.* (2012) utilizaram Krigagem, em dados de 63 estações pluviométricas, entre os anos de 1965 a 1980. A geoestatística com a análise variográfica mostrou que as características estruturais da precipitação estão correlacionadas e apresentam forte dependência espacial. A estimativa da precipitação apresentou resultados satisfatórios, para a distribuição espacial da precipitação, bem como para o preenchimento de falhas.

Ao testar RNA para o preenchimento de falhas, Depiné *et al.* (2014) utilizaram uma série de dados pluviométricos de nove estações. Foram experimentadas três alternativas: séries longas de treinamento e verificação, com aproximadamente 365 dias; séries curtas de treinamento com aproximadamente 12 a 30 dias, e várias séries também curtas de verificação, independentes da estação climática; séries curtas, porém com verificação do preenchimento somente em períodos próximos ao treinamento. Os melhores resultados foram obtidos coeficientes de Nash-Sutcliffe (NS) superiores a 0,9.

Correia *et al.* (2016) preencheram falhas de séries de precipitação utilizando

RNA, aplicado a quatro estações pluviométricas. A RNA, no cálculo de preenchimento de falhas em dados mensais de pluviosidade foi eficaz com 7% de falha nos dados, apresentando valores de NSE e  $R^2$  superiores a 0,8. A aplicação das mesmas redes em banco de dados com falhas de 15 e 30%, não foi satisfatório.

Visando o preenchimento de falhas de precipitação, aplicados a séries de dados mensais para estações meteorológicas, Bier e Ferraz (2017) compararam seis métodos: Regressão Linear Múltipla (RLM), Ponderação Regional (PR), Inverso da Potência da Distância (IPD), Método da razão normal (MRN), *Krigagem* Universal (KRG), Média aritmética simples (MA). Os métodos foram aplicados e comparados com estações meteorológicas utilizadas como testes. Foi retirado o período de um ano de dados mensais da série original para validação dos resultados. Nenhum método se sobressaiu, apenas MA e MRN apresentaram pequena vantagem.

De acordo com a área de interesse e a distribuição dos dados, tanto no tempo quanto no espaço, um método pode se sobrepor a outro em relação a acurácia. Dessa forma, não existe um consenso entre os autores em relação a quais métodos se utilizar em cada situação. Esse é um dos fatos que explicam os estudos comparativos, muitas vezes com base em vários métodos, a fim de se extrair os melhores resultados de preenchimento de falhas.

#### 4. Geoprocessamento e SIG na Espacialização da Precipitação

A utilização de geoprocessamento e SIG para espacialização da precipitação estão bem consolidadas. De acordo com Câmara e Davis (2001), essa realidade era muito difícil de ocorrer na década de 1960, portanto, ainda é recente a sua utilização para obtenção e espacialização de variáveis hidrometeorológicas. A disponibilidade gratuita de diversos produtos de Sensoriamento Remoto e de softwares de Geoprocessamento tornou possível qualquer pessoa ou instituição produzir dados de qualidade a baixo custo (Crepani, 2004).

Os SIGs mais utilizados da atualidade, sejam de código aberto ou pagos, possuem ferramentas para interpolação de dados de precipitação, muitos dos quais citados nesse artigo, de modo que essas técnicas contribuem para qualificar os métodos utilizados visando tanto o preenchimento de dados quanto a interpolação espacial. O Quadro 2 apresenta alguns dos principais SIGs e os métodos de interpolação que podem ser utilizados.

Quadro 2 - Principais SIGs e disponibilidade de interpoladores

SIGs	Métodos de interpolação disponíveis
ArcGIS	IDW, Krigagem, Spline, Spline com Barreiras, Vizinho Natural, Topo para Raster, RNA
QGIS	IDW, TIN, Spline, Vizinho Natural, Regressão Polinomial, Krigagem, Superfície de Tendência
SURFER	IDW, TIN, Spline, Vizinho Natural, Regressão Polinomial, Krigagem, Regressão Polinomial, Triangulação Linear, Triangulação de Delaunay, Polígonos de Voronoi
IDRISI	IDW, Krigagem, TIN, Vizinho Natural, Vizinho mais próximo
SPRING	TIN, Krigagem, Vizinho mais próximo

Para Marcuzzo *et al.* (2011), a análise correta da distribuição espacial das precipitações é de suma importância para o planejamento dos recursos hídricos em bacias hidrográficas, além de suporte a estudos climatológicos e meteorológicos. As técnicas de espacialização facilitam entender os fenômenos de precipitação no espaço e no tempo, ou seja, levando em conta grandes ou pequenas bacias hidrográficas e diferentes períodos de análise. Podem dar suporte e permitir a relação entre a precipitação e fatores ambientais, assim como desastres desencadeados por eventos extremos de precipitação (Castro *et al.*, 2010).

Na análise espacial, SIG ultrapassa a técnica analógica de armazenar informações geográficas em mapas, transferindo-as para um ambiente digital. Facilita a representação visual e a comparação de um conjunto de variantes, tais como sobreposição de camadas (Alves, 2011). Permitem integrar diferentes aspectos do ambiente, de forma rápida, principal motivo de sua utilização pelos pesquisadores para análise espacial de precipitação em bacias hidrográficas (Melo *et al.*, 2008; Safre, 2015, Hu *et al.*, 2016).

As técnicas de interpolação apresentam precisão e agilidade e permitem desenvolver práticas, como medidas mitigadoras em relação a suscetibilidade a desastres e a manutenção das atividades implantadas em uma localidade, onde o clima influencia diretamente na vida das população (Gardiman Junior *et al.*, 2012).

Segundo Caruso e Quarta (1998), diferentes técnicas oferecem diferentes desempenhos, de acordo com as características dos dados de entrada. É necessário avaliar qual técnica melhor se adapta aos dados, bem como a quantidade de variáveis acrescentadas ao modelo. Com base nesses fatores, estabelece-se o método a ser aplicado que, no caso da espacialização da precipitação, vai ser

diretamente relacionado com a qualidade dos dados de entrada.

Para Deroo e Jetten (1999), células de informação devem ser usadas para que a variação espacial seja levada em consideração no cálculo de precipitação. Técnicas de espacialização facilitam a verificação da forma como as variáveis nas séries históricas se distribuem no espaço e no tempo (Silva *et al.*, 2011).

Para entender a variabilidade espacial e temporal das chuvas, Gimenez (2017) utilizou SIG no estudo de desastres naturais. Para o preenchimento de falhas, utilizou o método RNA e para interpolação dos dados de precipitação pluvial, a técnica de Krigagem. Dirks *et al.* (1998), Mello *et al.* (2003), Haylock *et al.* (2008), Santos *et al.* (2009), Marcuzzo *et al.* (2011), Brubacher *et al.* (2012) e Farias *et al.* (2017), utilizaram métodos de interpolação visando a espacialização da distribuição de dados de precipitação.

A importância do Geoprocessamento e do SIG na espacialização da precipitação se justifica tanto do ponto de vista econômico, social e ambiental. Além disso, cabe destacar que mesmo áreas remotas, com baixa densidade de estações pluviométricas, a precipitação pode ser estimada por meio de satélites e radares meteorológicos. Entre os satélites meteorológicos, destacam-se o GOES e o NOAA - AVHRR (EUA), o Meteosat (Europeu), o MTSAT (Japão), o FY-1 e FY-2 (China), o GOMS, o Meteor (Rússia) e o KALPANA (Índia) (MOREIRA *et al.*, 2017).

Entre os radares, o TRMM é o resultado de uma parceria entre a NASA e a JAXA (Agência Japonesa de Exploração Aeroespacial), cuja grande vantagem deste produto em especial é sua alta resolução temporal, de 3 horas, e espacial, de 0.25°, na faixa entre 50° S e 50° N (Kummerow *et al.*, 2000). O GPM (Global Precipitation Measurement), desenvolvido em conjunto pela NASA e JAXA, entre outros, visa

monitorar globalmente, por meio de satélites, as precipitações na atmosfera, em alta resolução temporal de até 3 horas entre as observações (Hou *et al.*, 2014), podendo chegar a 0,1° e 1 hora (Huffman *et al.*, 2014).

O princípio da estimativa de precipitação por meio do sensoriamento em bandas no visível é o fato de que o brilho da luz do sol refletida por nuvens pode ser uma indicação de sua espessura e conseqüentemente do volume de água em seu interior (Petty, 1995). Uma das vantagens da utilização das estimativas de precipitação por satélite é o número insignificante de falhas nas séries temporais, chegando a 0,1% da extensão total, dificilmente afetando toda a rede simultaneamente.

Serrão *et al.* (2016), demonstram a importância desse tipo de produto na região amazônica que, devido a sua grande extensão, tem dificultada a geração de informações para o monitoramento contínuo dessa área. Nesse estudo, os autores realizaram uma análise estatística para comparar os dados gerados pelo algoritmo IMERG N3 do GPM em relação ao algoritmo 3B43 V7 do TRMM. Entre os principais resultados, foi constatado excelentes resultados em todos os meses estudados em relação a precipitação medida nas estações meteorológicas do INMET.

## 5. Considerações Finais

O preenchimento de falhas nas séries pluviométricas disponíveis para o território brasileiro é de fundamental importância principalmente no que se refere a análises de longo prazo, como simulação de inundações e dimensionamento de barragens, devido a necessidade de grande disponibilidade de dados de precipitação.

Embora ao longo dos anos tenham sido utilizados uma série de métodos para

o preenchimento de falhas, trabalhos mais recentes, a nível nacional e mundial, tem se concentrado em métodos estatísticos e estocásticos. Nas Regressões Múltiplas, a simplicidade em utilizar e interpretar os dados se mostrou adequada. Por outro lado, as Redes Neurais Artificiais também se mostraram eficientes em áreas de maior complexidade no quesito quantidade e diversidade dos dados a serem corrigidos.

A evolução das técnicas de interpolação e preenchimento de falhas deu um salto nas últimas décadas, em decorrência da evolução da capacidade computacional e tecnológica. Dessa forma, diversos métodos foram potencializados devido a memória disponível, o que amplia o potencial de dados a ser utilizados.

O futuro das pesquisas na área poderia se debruçar em verificar melhorias nesses métodos, além de levar em conta o aspecto do relevo e possível influência no processo de preenchimento de dados, algo ainda pouco citado nas referências analisadas. Além disso, uma das dificuldades ao se trabalhar com esses dados diz respeito a necessidade de se realizar esses processamentos a cada novo estudo, de forma que o desenvolvimento de um modo organizado de divulgar dados preenchidos de estações, considerando amplas áreas de cobertura, ampliaria as possibilidades de estudos nessa área do conhecimento.

## AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001; e da FAPERGS, processo 17/2551-0000894-4, Edital 01/2017.

## REFERÊNCIAS

- Agência Nacional de Águas e Saneamento Básico. Disponível em: <https://www.ana.gov.br/>. Acesso em: 11 set. 2019.
- ALI, S.; RAHMAN, A.; SALINAS, J.; GUNTER BLOSCHL, G. Applicability of Kriging to Regional Flood Estimation Problem in Eastern Australia. In: **International Conference on Engineering Research and Practice**, Dhaka, Bangladesh, p. 82-89, 2017.
- ALVES, F.R. Avaliação de interpoladores para a espacialização de variáveis de precipitação na bacia hidrográfica do rio Ivaí. In: **XV Simpósio Brasileiro de Sensoriamento Remoto**, Curitiba, p. 4070-4077, 2011.
- ANDRIOTTI, J.L.S. **Fundamentos de Estatística e Geoestatística**. Ed. UNISINOS: São Leopoldo. 2ª reimpressão, 166 p., 2005.
- ASSAD, E.D.; EVANGELISTA, B.A. Análise freqüencial da precipitação Pluviométrica. In: ASSAD, E.D. *et al.*, **Chuva nos cerrados: análise e espacialização**. Brasília: EMBRAPA-SPI, Cap. II, p. 25-41, 1994.
- BÁRDOSSY, A.; PEGRAM, G. Infilling missing precipitation records - A comparison of a new copula-based method with other techniques. **J. Hidr.**, v. 519, Part. A, p. 1162-1170, 2014.
- BATISTA, M.L.; COELHO, G.; TEIXEIRA, M.B.R.; OLIVEIRA, M.S. Estimadores de semivariância: análise de desempenho no mapeamento da precipitação anual para o estado de minas gerais. **Rev. Sci. Agr.**, v. 19, n. 1, p. 64-74, 2018.
- BAUMGARTNER, M.F.; APFL, G.M. Remote Sensing and Geographic Information Systems. **Hydrological Sciences Journal**, v. 41, n. 4, p. 592-607, 1996.
- BERTONI, J.C.; TUCCI, C.E.M. Precipitação. In: TUCCI, C.E.M. **Hidrologia: Ciência e Aplicação**. Porto Alegre: UFRGS, p. 177-241, 2007.
- BIER, A.A; FERRAZ, S.E.T. Comparação de Metodologias de Preenchimento de Falhas em Dados Meteorológicos para Estações no Sul do Brasil. **Rev. Bras. Met.**, v. 32, n. 2, p. 215-226, 2017.
- BORGES, P.A.; FRANKE, J.; ANUNCIACÃO, Y.M.T.; WEISS, H.; BERNHOFER, C. Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal, Brazil. **Theoretical and Applied Climatology Journal**, v. 123, p. 335-348, 2016.
- BOSER, B.E.; GUYON, I.M.; VAPNIK, V.N. A training algorithm for optimal margin classifiers. In: **V Workshop on Computational Learning Theory**, Pittsburgh, Pennsylvania, United States, p. 144-152, 1992.
- BRUBACHER, J.P.; OLIVEIRA, G.G.; GUASSELLI, L.A. Identificação e análise de eventos extremos de precipitação na bacia hidrográfica do rio dos Sinos/RS. In: **I Congresso Brasileiro Sobre Desastres Naturais**, Rio Claro, 2012.
- BURROUGH, P.A. **Principals of Geographical Information Systems for Land Resources Assessment**. Oxford, Clarendon Press, 194 p., 1986.
- CARUSO, C.; QUARTA, F. Interpolation Methods Comparison. **Computers Math. Appl.**, v. 35, n. 12, p. 109-126, 1998.
- CARVALHO, J.R.P de; ASSAD, E.D. Análise espacial da precipitação pluviométrica no estado de São Paulo: Comparação de métodos de interpolação. **Rev. Eng. Agríc.**, v. 25, n. 2, p. 377-384, 2005.
- CARVALHO, J.R.P. de; QUEIROZ, E.F. de. Uso de cokrigagem colocalizada na determinação da distribuição espacial de precipitação. **Boletim Técnico**, EMBRAPA, 2002.

- CASTRO, F.; PEZZOPANE, J.E.M.; CECÍLIO, R.A.; PEZZOPANE, J.R.M.; XAVIER, A.C. Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 14, n. 8, p. 871-880, 2010.
- CECÍLIO, R. A.; PRUSKI, F. F. Interpolação dos parâmetros da equação de chuvas intensas com uso do inverso de potências da distância. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 7, n. 3, p. 501-504, 2003.
- CERRI, R.; CARVALHO, A.C.P.L.F. Aprendizado de máquina: breve introdução e aplicações. **Cadernos de Ciência & Tecnologia**, Brasília, v. 34, n. 3, p. 297-313, 2017.
- COLLISCHONN, B.; ALLASIA, D.; COLLISCHONN, W.; TUCCI, C.E.M. Desempenho do satélite TRMM na estimativa de precipitação sobre a bacia do Paraguai Superior. **Rev. Bras. Cart.**, v. 59, n. 1, p. 93-99, 2007.
- COULIBALY, M.; BECKER, S. Spatial Interpolation of Annual Precipitation in South Africa-Comparison and Evaluation of Methods. **J. Wat. Inter.**, v. 32, n. 3, p. 494-502, 2009.
- CORREIA, T.P.; DOHLER, R.E.; DAMBROZ, C.S.; BINOTI, H.B. Aplicação de redes neurais artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Revista Geociências**, v. 35, n. 4, p. 560-567, 2016.
- CREPANI, E.; MEDEIROS J.S. **Imagens Fotográficas Derivadas de MNT do Projeto SRTM para Fotointerpretação na Geologia, Geomorfologia e Pedologia**. São José dos Campos: INPE, 40 p., 2004.
- CREUTIN, J.D.; OBLED, C. Objective analysis and mapping techniques for rainfalls fields: An objective comparison. **Water Resources Research**, v. 18, n. 2, p. 413-431, 1982.
- DEPINÉ, H.; CASTRO, N.M.R.; PINHEIRO, A.; PEDROLLO, O. Preenchimento de Falhas de Dados Horários de Precipitação Utilizando Redes Neurais Artificiais. **Rev. Bras. Rec. Hídr.**, v. 19, n. 1, p. 51-63, 2014.
- DIRKS, K.N.; HAY, J.E.; STOW, C.D.; HARRIS, D. High-resolution studies of rainfall on Norfolk Island Part II: Interpolation of rainfall data. **J. Hídr.**, v. 208, n. 3-4, p. 187-193, 1998.
- DORNELLES, F.; GOLDENFUM, J.A.; PEDROLLO, O.C. Artificial Neural Network Methods Applied to Forecasting River Levels. **Rev. Bras. Rec. Hídr.**, v. 18, n. 4, p. 45-54, 2013.
- FERRÃO, M.F.; MELLO, C.; BORIN, A.; MARETTO, A.; POPPI, R.J. LS-SVM: Uma nova ferramenta quimiométrica para regressão multivariada, comparação de modelos de regressão LS-SVM e PLS na quantificação de adulterantes em leite em pó empregando NIR. **Revista Química Nova**, v. 30, n. 4, p. 852-859, 2007.
- FIBBI, L.; CHIESI, M.; MORIONDO, M.; BINDI, M.; CHIRICI, G.; PAPALE, D.; GOZZINI, B.; MASELLI, F. Correction of a 1 km daily rainfall dataset for modelling forest ecosystem processes in Italy. **Meteorological Applications**, v. 23, n. 2, p. 294-303, 2016.
- FONSECA, J. S.; MARTINS, G. A.; TOLEDO, G. L. **Estatística Aplicada**. 2. ed., 267 p., 2012.
- FREITAS, G.M.; PAPA, J.P.; AVILA, A.M.H.; FALCÃO, A.X.; PINTO, H.S. Estimativa de ocorrência de precipitação em áreas agrícolas utilizando floresta de caminhos ótimos. **Rev. Bras. Met.**, v. 25, n. 1, p. 13-23, 2010.
- FRENCH, M.N.; KRAJEWSKI, W.F.; CUYKENDAL, R.R. Rainfall Forecasting in space and time using a neural network. **J. Hídr.**, v. 1367, n. 1-4, p. 1-37, 1992.
- GARDIMAN JUNIOR, B.S.; MAGALHÃES, I.A.L.; FREITAS, C.A.A. CECÍLIO, R.A. Análise de técnicas de



- interpolação para espacialização da precipitação pluvial na bacia do rio Itapemirim (ES). **Revista Ambiente**, v. 8, n. 1, p. 61-71, 2012.
- GIACOMIN, G.; CARVALHO, M.B.; SANTOS, A.P.; MEDEIROS, N.C.; FERRAZ, A.S. Análise comparativa entre métodos interpoladores de modelos de superfícies. **Rev. Bras. Cart.**, v. 66, n. 6, p. 1315-1329, 2014. GIMENEZ, D.F.S. **Análise da Precipitação Pluvial e Ocorrências de Desastres Naturais no Estado de São Paulo (1976–2012)**. Dissertação (Mestrado em Geografia) - Universidade Estadual de Campinas, Campinas, 98 p., 2017.
- GONG, G.; MATTEVADA, S.; O'BRIANT, S. Comparison of the accuracy of kriging and IDW interpolations in estimating groundwater arsenic concentrations in Texas. **Environ. Res.**, v. 130, p. 59-69, 2014.
- GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University, 496 p., 1997.
- GROISMAN, P.Y.; LEGATES, D.R. The Accuracy of United States Precipitation Data. **Bulletin of the American Meteorological Society**, v. 75, n. 3, p. 215-298, 1993.
- GUARNIERI, R.A. **Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no refinamento das previsões de radiação solar do modelo ETA**. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 171 p., 2006.
- GUIMARÃES, G.M.; FINCK, J.S.; MARCUZZO, F.F.N. Espacialização pluviométrica da precipitação média mensal na parte brasileira da bacia do rio Uruguai. In: **XXIX Congresso Brasileiros de Engenharia Sanitária e Ambiental, Congresso ABES-FENASAN**, p. 1-11, São Paulo, 2017.
- GUNDOGDU, I.B. Usage of multivariate geostatistics in interpolation processes for meteorological precipitation maps. **Theoretical and applied climatology**, v. 127, n. 1-2, p. 81-86, 2017.
- GUPTA, N. Artificial Neural Network. **Network and Complex Systems**, v. 3, n. 1, p. 24-28, 2013.
- HAYKIN, S.O. **Neural networks and learning machines**. 3<sup>a</sup> ed. Upper Saddle River, Nova Jersey: Prentice Hall, 906 p., 2008.
- HAYLOCK, M.R.; HOFSTRA, N.; KLEIN TANK, A.M.G.; KLOKE, J.; JONES, P.D.; NEW, M. A European Daily High-resolution gridded data set of surface temperature and precipitation for 1950-2006. **J. Geophys. Res.**, v. 113, D20119, 2008.
- HENRICHS, M.; STEINBRICH, A.; LEISTERT, H.; SCHERER, I.; SCHUETZ, T.; UHL, M.; WEILER, M. Model Based Estimation of a Natural Water Balance as Reference for Planning in Urban Areas. In: **XI International Conference on Urban Drainage Modelling, Palermo**, p. 953-957, 2018.
- HOU, A.Y.; KAKAR, R.K.; NEECK, S.; AZARBARZIN, A.; KUMMEROW, C.D.; KOJIMA, M.; OKI, R.; NAKAMURA, K.; IGUCHI, T. The Global Precipitation Measurement Mission. **Bull. Amer. Meteor. Soc.**, v. 95, n. 5, p. 701-722, 2014.
- HUFFMAN, G.J.; ADLER, R.F.; BOLVIN, D.T.; NELKIN, E.J. The TRMM Multi-satellite Precipitation Analysis (TMPA). In: **Satellite Rainfall Applications for Surface Hydrology**, Dordrecht, p. 3-22, 2010.
- HU, Z.; HU, Q.; ZANGH, C., CHEN, X., Li, Q. Evaluation of reanalysis, spatially interpolated and satellite remotely sensed precipitation data sets in central Asia. **J. of Geophys. Res.**, v. 121, n. 10, p. 5648-5663, 2016.

- ISAAKS, E.H.; SRIVASTAVA, R.M. **Applied geostatistics**. New York: Oxford University Press, 561 p., 1989.
- JAVARI, M. Comparison of interpolation methods for modeling spatial variations of Precipitation in Iran. **International Journal of Environmental e Science Education**, v. 12, n. 5, p. 1037-1054, 2017.
- JUNIOR, H.N.; VANZELA, L.S. Influência do relevo sobre a distribuição espacial da precipitação no Araguatutuba - SP. In: **XII Simpósio Brasileiro de Climatologia geográfica**, Goiânia, p. 2011-2024. 2016.
- KIM, J.; RYU, J.H. **A Heuristic Gap Filling Method for Daily Precipitation Series**. *Water Resources Management*, v. 30, n. 7, p. 2275-2294, 2016.
- KUMMEROW, C. *et al.* The status of the Tropical Rainfall Measuring Mission (TRMM) after two years in orbit. **Journal of Applied Meteorology**, v. 39, n. 12, p. 1965-1982, 2000.
- LAM, N.S. Spatial Interpolation Methods: A Review. **The American Cartographer**, n. 10, v. 2, p. 129-149, 1983.
- LANCASTER, P., SALKAUSKAS, K. **An introduction to curve and surface fitting**. Unpublished manuscript, Division of Applied Mathematics, University of Calgary, 114 p, 1975.
- LANÇA, R. Desenvolvimento de um modelo hidrológico de superfície à escala da bacia hidrográfica. **TecnoVisão**, v. 16, p. 1-10, 2004.
- LANDIM, P.M.B. **Introdução aos métodos de estimação espacial para confecção de mapas**. UNESP/Rio Claro, Laboratório de Geomatematica, Texto Didático 02, 20 p., 2000.
- LEDRA, L. **Métodos de Preenchimento de Falhas de Dados Pluviométricos: Comparações Para Dados de 24 Horas na Cidade de Joinville, SC**. Mestrado (Dissertação em Engenharia Civil), UESC, Joinville, 157 p., 2017.
- LEIVAS, J.F.; BERLATO, M.A.; FONTANA, D.C. Risco de deficiência hídrica decendial na metade sul do Estado do Rio Grande do Sul. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 10, n. 2, p. 397-407, 2006.
- LI, M.; SHAO, Q.; ZHANG, L.; CHIEW, F.H.S. A new regionalization approach and its application to predict flow duration curve in ungauged basins. **J. hidr.**, v. 389, n. 1-2, p. 137-145, 2010.
- LIMA, C.A.M. Comitê de Máquinas: Uma abordagem Unificada Empregando Máquinas de Vetores de Suporte. **Tese (Doutorado em Engenharia Elétrica)**, Universidade Estadual de Campinas, Campinas, SP, 378 p., 2004.
- LY, S.; CHARLES, C.; DEGRÉ, A. Different methods for spatial interpolation of rainfall data for operational hydrology and hydrological modeling at watershed scale: A review. **Biotechnol. Agron. Soc. Environ**, v, 17, n. 2, p. 392-406, 2013.
- MACHADO R. E. **Simulação de Escoamento e de Produção de Sedimentos em uma Microbacia Hidrográfica Utilizando Técnicas de Modelagem e Geoprocessamento**. Tese (Doutorado em Agronomia). USP, Piracicaba, 166 p., 2002.
- MALFATTI, M.G.L.; CARDOSO, A.O.; HAMBURGUER, D.S. Modelo Empírico Linear para Previsão de Vazão de Rios na Usina Hidrelétrica de Itaipu – Bacia do Rio Paraná. **Rev. Bras. Met.**, v. 33, n. 2, p. 257-268, 2018.
- MARCUZZO, F.N; ANDRADE, L. R.; MELO, D.C.R. Métodos de Interpolação matemática no mapeamento de mhuvas do estado do Mato Grosso. **Rev. Bras. Geog. Fís.**, v. 4, n. 4, p. 793-804, 2011.
- MARCUZZO, F. Mapas da espacialização trimestral de chuva e hietrograma trimestral da região metropolitana de Teresina/PI. In: **XIX Simpósio Brasileiro**

- de Sensoriamento Remoto, Santos, p. 515-518, 2019.
- MEKANIK, F., IMTEAZ, M.A., GATO-TRINIDAD, S., ELMAHDI, A. Multiple regression and artificial neural network for long-term rainfall forecasting using large scale climate modes. **J. hidr.**, v. 503, p. 11-21, 2013.
- MATEUS, R.S. **Modelo Hidrológico da Bacia Hidrográfica da Represa Guarapiranga**. Dissertação (Mestrado em Geografia Física), USP, São Paulo, 154 p., 2006.
- MAZZINI, P.L.F.; SCHETTINI, C.A.F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quasesinóticos. **Brazilian Journal of Aquatic Science and Technology**, v. 13, n. 1, p. 53-64, 2009.
- MEDINA, A.S.; QUINTAS, M.C.L. O Método de Interpolação de Curvatura Mínima. **II Simpósio Brasileiro de Ciências Geodésicas E Tecnologias da Geoinformação**, Recife, 2008.
- MEKIS, E.; DONALDSON, N.; REID, J.; ZUCCONI, A.; JEFFERY, H.; LI, Q.; NITU, R.; MELO, S. An Overview of Surface-Based Precipitation Observations at Environment and Climate Change Canada. **Atmosphere-Ocean**, v. 56, n. 2, p. 71-95, 2018.
- MELO, H.A.; CUNHA, J.E.B.L.; NÓBREGA, R.L.B.; RUFINO, I.A.A.; GALVÃO, C.O. *Modelos Hidrológicos e Sistemas de Informação Geográfica (SIG): Integração Possível*. In: **IX Simpósio de Recursos Hídricos do Nordeste**, Salvador, p. 1-14, 2008.
- MELLO, C.R.; SILVA, A.M. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 13, n. 1, p. 68-74, 2009.
- MORALES, R.A.V.; ARAUJO, C.E.S. Avaliação e Comparação de Dois Métodos de Qualificação de Dados Diários de Precipitação no Estado de Santa Catarina. **Rev. Bras. Met.**, v. 32, n. 1, p. 65-75, 2017.
- MOREIRA, A.; FONTANA, D.C.; KUPLICH, T.M.; CARDOSO, M.A. Dados meteorológicos estimados em condições de clima subtropical e a relação com Índices de Vegetação. **Rev. Bras. Cart**, v. 70, n. 4, p. 1409-1436, 2017.
- NAGHETTINI, M.; PINTO, E.J. de A. **Hidrologia Estatística**. Belo Horizonte, CPRM, 552 p., 2007.
- OLIVEIRA, V.P.S., ZANETTI, S.S., PRUSKI, F.F. CLIMABR Parte I: Modelo para a geração de séries sintéticas de precipitação. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 9, n. 3, p. 348-355, 2005
- 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. **Rev. Bras. Eng. Agríc. e Ambient**, v. 14, n. 11, p. 1186-1192, 2010.
- OLIVEIRA, G.G.; PEDROLLO, O.C.; CASTRO, N.M.R. Simplifying artificial neural network models of river basin behaviour by an automated procedure for input variable selection. **Engineering Applications of Artificial Intelligence**, v. 40, p. 47-61, 2015.
- PAZ, A.R. **Simulação Hidrológica de Rios com Grandes Planícies de Inundação**. Tese de Doutorado - Programa de Pós-Graduação em Recursos Hídricos e Saneamento Ambiental, IPH, UFRGS, Porto Alegre, 258 p., 2010.
- PETTY, G.W. The Status of Satellite-Based Rainfall Estimation over Land. **Remote Sensing of Environment**, v. 51, n. 1, p. 125-137, 1995.
- PHILLIPS, D.L.; DOLPH, J.; MARKS, D. A comparison of geostatistical procedures for spatial analysis of precipitations in mountainous terrain. **Agriculture and Forest Meteorology**, v. 58, n. 1-2, p. 119-141, 1992.

- RAGHAVENDRA, A.; DAI, A.; MILRAD, S.M.; CLOUTIER-BISBEE, S.R. Floridian heatwaves and extreme precipitation: future climate projections. **Climate Dynamics**, v. 52, p. 495-508, 2019.
- REMACRE, A.Z.; NORMANDO, M.N.; SANCEVERO, S.S. Krigagem das proporções utilizando a krigagem da média: uma ferramenta auxiliar na modelagem de reservatórios. **Rev. Bras. Geoc.**, v. 38 (suplemento), p. 82-87, 2008.
- RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by backpropagating errors. **Nature**, v. 323, p. 533-536, 1986.
- SAFRE, A.L.S. **Estimativa e Análise da Precipitação do Ano de 2013 na Bacia do Rio Pardo Utilizando Técnicas de Geoprocessamento**. Trabalho de Conclusão de Curso (Bacharelado em Geografia) - Universidade Estadual Paulista Julio de Mesquita Filho, Ourinhos, 72 p., 2015.
- SANTOS, D.M. **Zoneamento das Áreas Suscetíveis a Movimentos de Massa, Enxurradas e Inundações no Município de Sarques de Souza - RS**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia Ambiental). UNIVATES, Lajeado, 135 p., 2015.
- SANTOS, G.G.; FIGUEIREDO, C.C. de; OLIVEIRA, L.F.C.; GRIEBELER, N.P. Intensidade-duração-frequência de chuvas para o Estado de Mato Grosso do Sul. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 13 (suplemento), p. 899-905, 2009.
- SÁRKÖZY, F. Gis functions - Interpolation. **Periodica Polytechnica Engineering**, v. 43. n. 1, p. 63-87, 1999.
- SCHÖLKOPF, B., SMOLA, A.J. **Learning with Kernels**. MIT Press, 626 p., 2002.
- SERRÃO, E.A.O.; WANZELER, R.T.S.; SANTOS, C.A.; GONÇALVES, L.J.M.; LIMA, A.M.M.; ROCHA, E.J.P. Avaliação estatística entre as estimativas de precipitação da constelação GPM com satélite TRMM: Uma análise a bacia Hidrográfica do rio Solimões. **Rev. Bras. Climat.** v. 18, p. 256-275, 2016.
- SIBSON, R. A Brief Description of Natural Neighbor Interpolation. In: BARNETT, V. **Interpreting Multivariate Data**, John Wiley e Sons, New York, p. 21-36, 1981.
- SILVA, J.C.; HELDWIN, A.B.; MARTINS, F.B.; TRENTIN, G.; GRIMM, E.L. Análise de distribuição de chuva para Santa Maria, RS. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 11, n. 1, p. 67-72, 2007.
- SILVA, R.M.; PEREIRA E SILVA, L.; MONTENEGRO, S.M.G.L.; SANTOS, C.A.G. Análise da Variabilidade Espaço-Temporal e Identificação do Padrão da Precipitação na Bacia do Rio Tapacurá, Pernambuco. **Sociedade e Natureza**, v. 22, n. 2, p. 357-372, 2010.
- SILVA, V.S.V. **Estimativa de precipitação pontual em diferentes escalas para uso em modelo concentrado chuva-vazão**. Dissertação (Mestrado em Recursos Hídricos e Saneamento Ambiental), UFRGS, Porto Alegre, 139p., 2011.
- SMITH, M.J.; GOODCHILD, M.F.; LONGLEY, A.P. **Geospatial Analsis: A comprehensive guide to principles, techniques and software tools.** , 3. ed., 516 p., 2009.
- SOARES, A. **Geoestatística Aplicada às Ciências da Terra e do Ambiente**. Instituto Superior Técnico, IST-PRESS, 3ª ed., Portugal, 206p., 2000.
- SOUSA, W.S.; SOUSA, F.A.S. Rede neural artificial aplicada à previsão de vazão da Bacia Hidrográfica do Rio Piancó. **Rev. Bras. Eng. Agríc. Ambient**, v. 14, n. 2, p.173-180, 2010.
- SOUZA J.L.L.L.; GOMES, T.S.; DIAS, R.S.; OLIVEIRA, G.M.A.; SANTOS, R.L. Avaliação de métodos de interpolação aplicados à espacialização das chuvas no território identidade Portal do

- Sertão/Bahia. **XV Simpósio Brasileiro de Sensoriamento Remoto**, Curitiba, p. 4295-4302, 2011.
- SOUZA, A.; SANTOS, D.A.S.; ARISTONE, F.; KOVA-ANDRI, E.; MATASOVI, B.; PIRES, J.C.; IKEFUTI, P.V. Impacto de fatores meteorológicos sobre as concentrações de ozônio modelados por análise de séries temporais e métodos estatísticos multivariados. **Revista Holos**, v. 5, p. 2-16, 2017.
- SULAIMAN, J.; WAHAB, S.H. Heavy Rainfall Forecasting Model Using Artificial Neural Network for Flood Prone Area. In: KIM K., KIM H., BAEK N. **IT Convergence and Security**, v. 449, p. 68-76, 2018.
- THOMPSON, S.K. **Sampling**. Interscience Publication, New York, 343p., 1992.
- TRENBERTH, K.E. **Changes in precipitation with climate change**. Climate research, v. 47, p. 123-138, 2011.
- TUCCI, C. E. M. **Regionalização de vazão**. Porto Alegre: UFRGS, 256p., 2002.
- TUCCI, C.E.M. **Hidrologia: Ciência e Aplicação**, 4ª ed., ABRH/Editora UFRGS, Porto Alegre, 944p., 2009.
- UMEHARA, S.; YAMAZAKI, T.; SUGAI, Y. A. Precipitation Estimation System Based on Support Vector Machine and Neural Network. In: **Electronics and communications in Japan, Part. 3: Fundamental Electronic Science**, v. 89, n. 3, p. 38-47, 2006.
- VALENÇA, M.J.S. **Análise e projeto de redes neurais com abordagem construtiva para modelagem de sistemas complexos**. Tese de Doutorado em Ciências da Computação, UFP, Recife, 223 p., 1999.
- VALENTE, A.L.S. **Desenvolvimento de uma metodologia para planejamento urbano, utilizando técnicas de sensoriamento remoto, Modelagem Numérica do Terreno (MNT) e Sistema de Informações Geográficas (SIG)**. Dissertação de Mestrado em Sensoriamento Remoto, UFRGS, Porto Alegre, 200 p, 1995.
- VESPUCCI, A.G.; SANTOS, J.G.R.; BAYER, M. Estações fluviométricas do estado de Goiás: qualificação dos dados hidrológicos disponíveis na base HIDROWEB/ANA. **Revista Ateliê Geográfico**, v. 10, n. 3, p. 89-108, 2016.
- VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAIS, R.F *et al.* **Tópicos em ciência do solo**. Sociedade Brasileira de Ciência do Solo, Viçosa, p.1-53, 2000.
- VILLAZÓN, M.F.; WILLEMS, P. Filling Gaps and Daily Disaccumulation of Precipitation Data for Rainfall-Runoff Model. In: **IV International Scientific Conference on Water Observation and Information Systems for Decision Support**, Ohrid, Republic of Macedonia, 2010.
- VIOLA M.R.; MELLO, C.R.; ACERBI Jr., F.W.; SILVA, A.M. Modelagem hidrológica na bacia hidrográfica do Rio Aiuruoca, MG. **Rev. Bras. Eng. Agríc. Ambient**, v. 13, n. 5, p. 581-590, 2009.
- VIOLA, M.R.; MELLO, C.R.; PINTO, D.B.F.; MELLO, J.M.; ÁVILA, L.F. Métodos de interpolação espacial para o mapeamento da precipitação pluvial. **Rev. Bras. Eng. Agríc. Ambient.**, v. 14, n. 9, p. 970-978, 2010.
- WAGNER, P.D.; FIENER, P.; WILKJEN, F.; KUMAR, S.; CHNEIDER, K. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. **J. Hydr.**, v. 464, p. 388-400, 2012.
- WATSON, D. The natural neighbor series manuals and source codes. **Computers e Geosciences**, v. 25, n. 4, p. 463-466, 1999.
- WEIGEND, A. S.; MANGEAS, M.; SRISTAVA, A. N. Nonlinear gated experts for time series: Discovering regimes and avoiding over fitting. **International**

**Journal of Neural Systems**, v. 6, n. 4, p. 373-399, 1995.

WIDROW, B.; HOFF, M.E. **Adaptive Switching Circuits**. Ire Wescon Convention Record, New York, p. 96-104, 1960.

XU, W.; ZOU, Y.; ZHANG, G.; LINDERMAN, M. A comparison among spatial interpolation techniques for daily rainfall data in Sichuan Province, China. **Int. J. Clim.**, v. 35, n. 10, p. 2898-2907, 2015.

YANG, X., XIE, X., LIU, D. L., JI, F., e WANG, L. Spatial interpolation of daily rainfall data for local climate impact assessment over greater Sydney region. **Advances in Meteorology**, v. 2015, p. 1-12, 2015.

ZANATA, D.R.F. **Desenvolvimento de Sensor Virtual Empregando Redes Neurais Para Medição da Composição em Coluna de Destilação**. Dissertação de Mestrado, Escola Politécnica da USP, 209 p., 2005.

ZEILHOFER, P.; LIMA, E.B.R.; SANTOS, F.M.; RIGO JÚNIOR, L. O. Um Ambiente SIG para Modelagem Integrada da Qualidade da Água utilizando QUAL2e. **Revista Caminhos da Geografia**, v. 4, n. 10, p. 107-125, 2003.

WANDERLEY, H.S.; AMORIM, R.F.C.; CARVALHO, F.O. Variabilidade espacial e preenchimento de falhas de dados pluviométricos para o estado de Alagoas.

**Rev. Bras. Met.**, v. 27, n. 3, p. 347-354, 2012.

WATSON, D.F., PHILIP, G.M. A refinement of inverse distance weighted interpolation. **Geoprocessing**, v. 2, n. 4, p. 315-327, 1985.

WILKS, D.S. Statistical Methods in the Atmospheric Sciences. **International Geophysics Series**, v. 91, 2. ed., Philadelphia, Elsevier Academic Press Publications, 649 p., 2006.

ZAREKARIZI, M.; RANA, A.; MORADKHANI, H. Precipitation extremes and their relation to climatic indices in the Pacific Northwest USA. **Climate Dynamics**, v. 50, n. 11, p. 4519-4537, 2018.

ZHAO, Y.; YANG, Z.; WEI, Y.; HU, B.; CAO, Q.; TONG, K.; LIANG, Y. Eight Hundred Years of Drought and Flood Disasters and Precipitation Sequence Reconstruction in Wuzhou City, Southwest China. **Water**, v. 11, n. 219, P. 1-11, 2019.

ZHOU, Y.; LAU, W.K.M.; HUFFMAN, G.J. Mapping TRMM TMPA into Average Recurrence Interval for Monitoring Extreme Precipitation Events. **J. Appl. Climatology**, v. 54, p. 979-995, 2015.

### **3.2 ARTIGO 2: Preenchimento de Falhas em Séries Temporais de Precipitação Diária no Rio Grande Do Sul**

Artigo publicado na Revista Brasileira de Meteorologia.



## Preenchimento de Falhas em Séries Temporais de Precipitação Diária no Rio Grande Do Sul

João Paulo Brubacher<sup>1</sup>, Guilherme Garcia de Oliveira<sup>1</sup>, Laurindo Antonio Guasselli<sup>1</sup>

*<sup>1</sup>Laboratório de Geoprocessamento e Análise Ambiental, Programa de Pós-Graduação em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil.*

Recebido em: 27 de Maio de 2019 - Revisado em: 19 de Novembro de 2019 - Aceito em: 22 de Março de 2020

### Resumo

O preenchimento de falhas em séries temporais de precipitação é um importante processo para aplicações em hidrologia, visando o aproveitamento de longas séries, evitando que as mesmas sejam descartadas. Desse modo, este estudo teve como objetivo realizar o preenchimento de falhas em séries históricas de precipitação diária no Rio Grande do Sul (RS), auxiliando no aproveitamento desses dados em estudos que necessitem de análises de longo prazo. Para tanto, foram utilizadas séries históricas de 287 estações, no período entre 1987 e 2016 e aplicados os métodos de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA), comparando e avaliando os valores preenchidos. Um algoritmo foi desenvolvido para realizar as seguintes operações: i) identificar os dias com falhas em cada estação; ii) identificar as estações que podem ser utilizadas para o preenchimento de cada falha; iii) identificar todas as combinações de entrada para o preenchimento de falhas em cada estação; iv) realizar o ajuste/treinamento dos modelos RLM e RNA; v) realizar a validação dos modelos com base no período sem falhas de cada estação. Os principais resultados indicam que a maior densidade de estações pluviométricas favorece o processo de preenchimento de falhas em séries históricas de precipitação, melhorando a qualidade da série preenchida. O preenchimento de falhas apresentou maior coeficiente de determinação e menor erro médio absoluto usando o modelo RLM em relação às RNA, possivelmente em função da forte correlação linear entre os dados de precipitação de cada local em relação a sua vizinhança. O modelo de RLM apresentou um coeficiente de determinação ( $R^2$ ) médio de 0,697, enquanto que o modelo RNA obteve média de 0,675. Levando-se em conta a análise por meio do erro médio absoluto (EMA), a média dos valores foi de 2,27 mm para a RLM, enquanto para a RNA o erro ficou em 2,31 mm. Conclui-se, considerando o conjunto de dados de precipitação diária do RS, que houve uma pequena superioridade do método RLM em relação à RNA.

**Palavras-chave:** regressão linear múltipla, redes neurais artificiais, estações pluviométricas.

## Gap Filling in Historical Data of Daily Precipitation in Rio Grande do Sul

### Abstract

The gap filling in time series of precipitation is an important process for applications in hydrology, aiming the use of long series, avoiding that they are discarded. Thus, this study had as objective to gap filling in historical series of daily precipitation in Rio Grande do Sul, assisting in the use of these data in studies that require long term analysis. For that, we used historical series of 287 stations in the period between 1987 and 2016 and comparing the Multiple Linear Regression (MLR) and Artificial Neural Networks (ANN) methods, comparing to evaluating the filled values. An algorithm was developed to perform the following operations: i) identify the days with missing datas in each station; ii) identify the stations that can be used to fill each missing data; iii) identify all combinations of input to fill in failures in each station; iv) perform the adjustment/training of the MLR and ANN models; v) perform validation of the models based on the period without failure of each station. The main results indicate that the higher density of rainfall stations favors the process of filling of faults in historical series of precipitation, improving the quality of the filled series. Gap filling showed a higher coefficient of determination and lower mean absolute error using the MLR model in relation to RNA, possibly due to the strong linear correlation of the precipitation data of each site in relation to their neighborhood. The MLR model presented an average coefficient of determination ( $R^2$ ) of 0.697, while the RNA model obtained an



average of 0.675. Considering the analysis by means of the mean absolute error (MAE), the mean values were 2.27 mm for MLR, while for RNA the error was 2.31 mm. It is concluded, considering the daily rainfall data set of RS, that there was a slight superiority of the RLM method in relation to RNA.

**Keywords:** multiple regression, artificial neural networks, rainfall stations.

## 1. Introdução

Estudos com séries temporais de precipitação para espacializar chuvas são cada vez mais importantes considerando suas aplicações em estudos hidrológicos, fundamentais para o desenvolvimento social e econômico (Ichiyanagi *et al.*, 2018; Ballari *et al.*, 2018). Séries de precipitação têm aplicações diretas em climatologia, agricultura, hidrologia e gestão de desastres, bem como no planejamento e gestão de recursos ambientais e urbanos (Mekis *et al.*, 2018).

Estudos de previsão hídrica, modelagem, variações e tendências climáticas, por exemplo, principalmente no que se refere a análises de longo prazo, fazem com que a utilização de séries temporais de dados (séries contínuas e sem falhas) seja uma condição fundamental para a execução de uma análise consistente e confiável (Costa *et al.*, 2013). Métodos para preencher falhas podem contribuir na compreensão da variação climática e na previsão de fenômenos que venham a se repetir por influência do clima (Fernandez, 2007). O preenchimento de falhas é necessário para aproveitar séries longas de precipitação, evitando que as mesmas sejam descartadas (Brubacher *et al.*, 2012).

Entre os métodos para o preenchimento de falhas destacam-se a ponderação a partir de Regressão Linear Múltipla (RLM), em que a precipitação no posto com falhas é correlacionada estatisticamente com a precipitação de postos vizinhos. A RLM é um modelo estatístico adequada no tratamento de séries temporais de dados, configurando-se como uma metodologia estatística de previsão de valores de uma ou mais variáveis de resposta (variáveis dependentes) a partir de um conjunto de

variáveis explicativas independentes (Naghattini e Andrade Pinto, 2007).

A técnica de RLM correlaciona as observações correspondentes entre vários pontos vizinhos, e as estimativas dos parâmetros da equação podem ser obtidas graficamente ou por meio de critérios de mínimos quadrados para calibração dos valores de forma iterativa (Bertoni e Tucci, 2001). Mello *et al.* (2017) utilizaram Regressão Linear Múltipla para o preenchimento de falhas, com valores obtidos mais próximos do real em comparação com outros métodos, tendo o resultado mais próximo do real em 60,7% das análises e um desvio relativo médio de 14,4%.

Outro método é o modelo de Redes Neurais Artificiais (RNA), uma abordagem computacional alternativa inspirada em estudos do cérebro e sistema nervoso (Haykin, 2008). Baseia-se nas estruturas de armazenamento e processamento do sistema nervoso biológico, que consistem em um grande número de processamentos simples com muitas interconexões (Leahy *et al.*, 2008). São modelos matemáticos empíricos, com capacidade de armazenar e disponibilizar conhecimento experimental, por meio de treinamento e de resposta aos estímulos (variáveis de entrada) (Tokar e Markus, 2000; Gupta, 2013).

Coutinho *et al.* (2018) aplicaram RNA para estimar e preencher falhas em séries de dados meteorológicos, comparando as variáveis mensais com modelos de Regressões Múltiplas. Os resultados obtidos por meio da RNA mostram alta correlação linear ( $r$ ) com os dados registrados de temperatura máxima do ar ( $r$  de 0,94 a 0,98), obtendo-se um erro médio percentual (EMP) entre 1,05%

e 2,32%. Em relação à umidade relativa do ar, o coeficiente  $r$  se manteve entre 0,77 e 0,94, sendo que o uso de RNA para a estimativa dessa variável resultou em um EMP entre 1,85% e 2,41%. Esses resultados destacam a MLP como sendo eficaz para as variáveis testadas.

Depiné *et al.* (2014) aplicaram RNA para preenchimento de falhas horárias em séries históricas de precipitação, e analisaram o desempenho dos modelos a partir do coeficiente de *Nash-Sutcliffe* (NS) e do quantil 95% dos erros (E95). Os coeficientes de *Nash-Sutcliffe* variaram entre 0,91 e 0,99 para o treinamento dos modelos e entre 0,90 e 0,99 para a verificação. O quantil 95% dos erros foi no máximo de 1,5 mm no treinamento e de 1,4 mm na verificação.

Diversos autores trabalham com preenchimento de falhas de precipitação utilizando diversos métodos: (a) RLM (Ramos-Calzado *et al.*, 2008; Presti *et al.*, 2010; Simolo *et al.*, 2010; Tardivo e Berti, 2012; Woldesenbet *et al.*, 2017; Vieira *et al.*, 2018); (b) RNA (Teegavarapu e Chandramouli, 2005; Bustami *et al.* 2007; Aly *et al.*, 2009; Oliveira *et al.*, 2014; Correia *et al.*, 2016; Gimenez, 2017). No entanto, na maioria das aplicações, as áreas analisadas se restringem a poucas estações pluviométricas envolvidas, tanto pelas dificuldades na obtenção de dados quanto pelo tamanho da área de estudo. Quem tem a intenção de trabalhar com esse tipo de dado enfrenta dificuldades semelhantes.

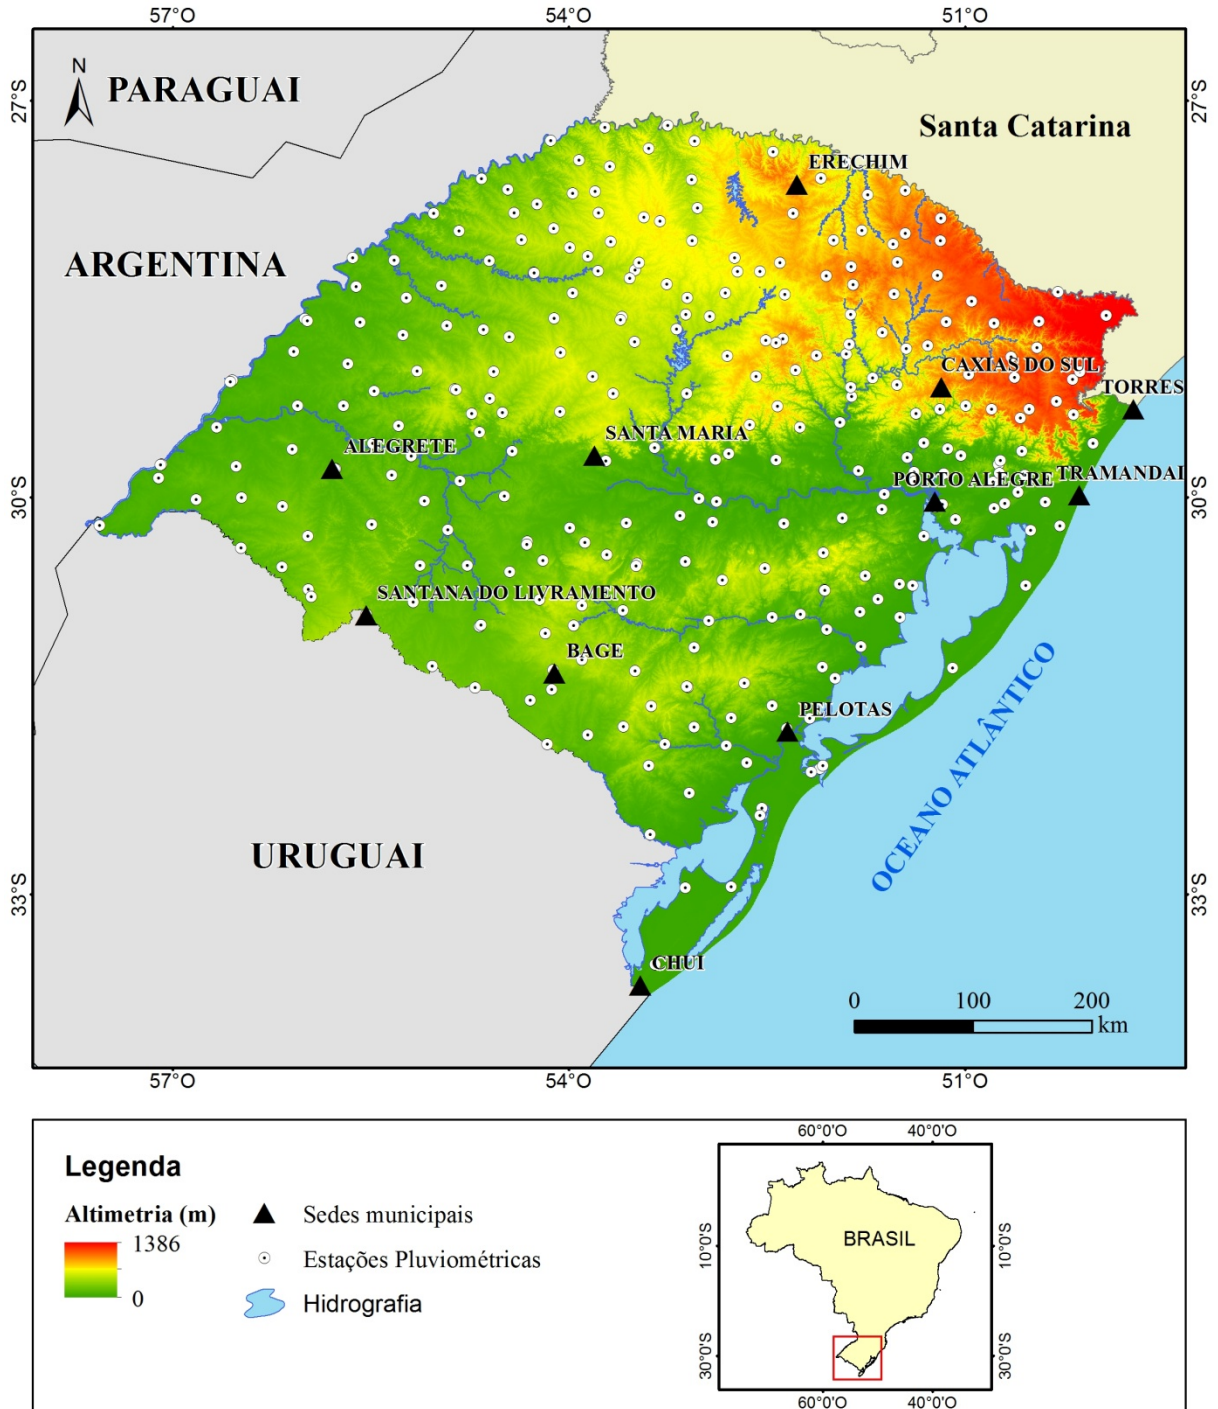
Os resultados promissores obtidos por técnicas de RLM e RNA justificam a escolha desses métodos. Entretanto, diferentemente de outros autores, esse estudo teve como objetivo propor um

algoritmo para preencher falhas em séries históricas de precipitação diária para o estado do Rio Grande do Sul, utilizando todas as estações pluviométricas com dados disponíveis, comparando a aplicação dos métodos RLM e RNA. A maior contribuição do algoritmo criado se refere à: i) capacidade de identificar, automaticamente, para cada estação, as falhas e as estações vizinhas disponíveis para o preenchimento de falhas nos dados diários; ii) aplicação de dois modelos utilizando o maior conjunto de dados disponíveis para cada dia, considerando restrições pré-estabelecidas de distância, para evitar que se use dados de precipitação diária de estações muito distantes, e que não fazem parte da mesma região climática.

## 2. Materiais e métodos

### 2.1. Área de estudo

O estado do Rio Grande do Sul (RS) localiza-se na região Sul do Brasil, faz fronteira ao norte com o estado de Santa Catarina, a oeste com Argentina e ao sul com Uruguai. O RS possui uma área de 281,7 mil km<sup>2</sup> (Fig. 1). Situa-se em uma zona climática de transição, em que as principais características climáticas refletem a participação de Sistemas Atmosféricos Extratropicais (massas e frentes polares) e Sistemas Intertropicais (massas tropicais e correntes perturbadas). Embora os primeiros exerçam o controle dos tipos de tempo em 90% dos dias do ano, proporcionando também a distribuição mensal e anual das chuvas (Rossato, 2011).



**Figura 1.** Área de estudo, e localização das estações pluviométricas sobre imagem de altimetria.

Segundo Britto *et al.* (2008) o regime pluviométrico no RS é caracterizado pela interação dos sistemas meteorológicos com os elementos da paisagem geográfica, como o relevo, a latitude, a maritimidade e a continentalidade. A pluviosidade é condicionada principalmente pela dinâmica atmosférica em relação ao relevo que, através de sua compartimentação, promove

a distribuição espacial da precipitação. No Estado, ocorrem quatro sub-regiões com valores de pluviosidade total semelhantes. No inverno, chove mais na sub-região do litoral e no centro-sul, relacionado ao sistema atmosférico frontal; na primavera, chove mais na sub-região noroeste, onde dominam os Complexos Convectivos de Mesoescala (CCMs); no verão, chove mais

na sub-região nordeste associado a chuvas convectivas relacionadas às Zonas de Convergência do Atlântico Sul (ZCAS); no outono, chove mais na sub-região sudoeste e o sistema dinâmico mais influente é o bloqueio atmosférico. Registram-se, dessa forma, segundo Rossato (2011), significativas diferenças entre os valores de precipitação das áreas geográficas menos chuvosas (1290 mm anuais) e áreas mais chuvosas (2000 mm anuais)

## 2.2. Métodos

Para atingir o objetivo proposto, a primeira etapa consistiu na aquisição e organização dos dados de precipitação disponíveis no Hidroweb, da Agência Nacional de Águas (ANA, 2019), e no Instituto Nacional de Meteorologia. Foram utilizados dados de 287 estações pluviométricas (Fig. 1), com séries completas ou parciais no período entre 01/01/1987 e 31/12/2016, totalizando 30 anos de registros. Os dados foram organizados em uma matriz, em que cada linha representa um dia e cada coluna uma estação.

Foi desenvolvido um algoritmo no *software* MATLAB© para o preenchimento de falhas usando os métodos RLM e RNA. Visando comparar os dois métodos e limitar o preenchimento para estações com disponibilidade de dados em locais próximos (reduzindo as chances de buscar valores de precipitações em outras regiões climáticas), foram definidas regras e critérios: i) para uma estação vizinha ser considerada apta para o preenchimento de falhas, o coeficiente de correlação linear ( $r$ ) da precipitação ocorrida nos dois locais deve ser igual ou superior a 0,6 e a distância máxima entre as estações não pode ultrapassar 100 km; ii) o número mínimo de estações vizinhas para executar o processo de preenchimento é três; iii) o conjunto amostral de treinamento e de validação dos modelos de

RLM e RNA, em cada estação, é sempre o mesmo, visando uma comparação idônea entre os métodos utilizados. É importante destacar também que o preenchimento de falhas só foi realizado nas séries históricas com ao menos 85% dos dados disponíveis.

O algoritmo proposto possui as seguintes operações: i) identifica os dias com falhas em cada estação; ii) identifica as estações que podem ser utilizadas para o preenchimento de cada falha, iii) identifica todas as possíveis combinações de entrada para o preenchimento de falhas em cada estação; iv) realiza o ajuste de um modelo RLM; v) realiza o treinamento de uma RNA; vi) realiza a validação dos modelos com base no período sem falhas da estação, identificando a melhor combinação de variáveis explicativas e o modelo mais adequado para cada estação, de acordo com o índice de desempenho desejado.

Para a Regressão Linear Múltipla, as informações pluviométricas do posto  $Y$  são correlacionadas com as observações correspondentes de vários postos vizinhos, por meio de uma equação linear (Eq. 1).

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_i \cdot X_i + \varepsilon_0 \quad (1)$$

Em que:  $Y$  é a variável dependente, nesse caso, a precipitação estimada;  $X_1, X_2, \dots, X_i$ , são as variáveis independentes, nesse caso os postos considerados;  $\beta_0, \beta_1, \beta_2, \dots, \beta_{2i}$ , são os coeficientes da regressão; e  $\varepsilon$  indica o erro residual.

O treinamento da RNA foi realizado pelo método retropropagativo com múltiplas camadas (Rumelhart *et al.*, 1986), usando a Regra Delta (Widrow e Hoff, 1960) para atualizar os pesos sinápticos da rede. Os valores dos atributos de entrada foram escalonados a partir de transformações lineares (Eq. 2).

$$\frac{(y_t - p_o)}{s_o} = RNA \left( \frac{(x_t - p_i)}{s_i} \right) \quad (2)$$

Em que:  $x_t$  e  $y_t$  são a entrada e a saída das variáveis, respectivamente;  $S_o$  e  $p_o$  são a escala e a posição dos parâmetros de saída do modelo;  $S_i$  e  $p_i$  são a escala e a posição dos parâmetros de entrada do modelo; RNA é a Rede Neural Artificial.

A função de ativação para os neurônios foi a sigmoide unipolar, não linear, contínua e derivável em todo o seu domínio. Uma série de validação cruzada paralela à série de treinamento foi utilizada para evitar o superajustamento do modelo. O modelo de RNA utilizado é representado pela Eq. 3.

$$RNA\left(\frac{(x_t - p_i)}{s_i}\right) = f_o\left(\sum_h w_o f_h \sum_i w_h \left(\frac{x_t - p_i}{s_i}\right) + b_h\right) + b_o + e_o \quad (3)$$

Em que:  $w_h, b_h, f_h, w_o, b_o$  e  $f_o$  são os pesos sinápticos ( $w$ ); tendência ( $b$ ); funções de ativação ( $f$ ), respectivamente, das camadas ocultas ( $h$ ); das camadas de saída ( $o$ );  $e_o$  é o erro esperado da camada de saída.

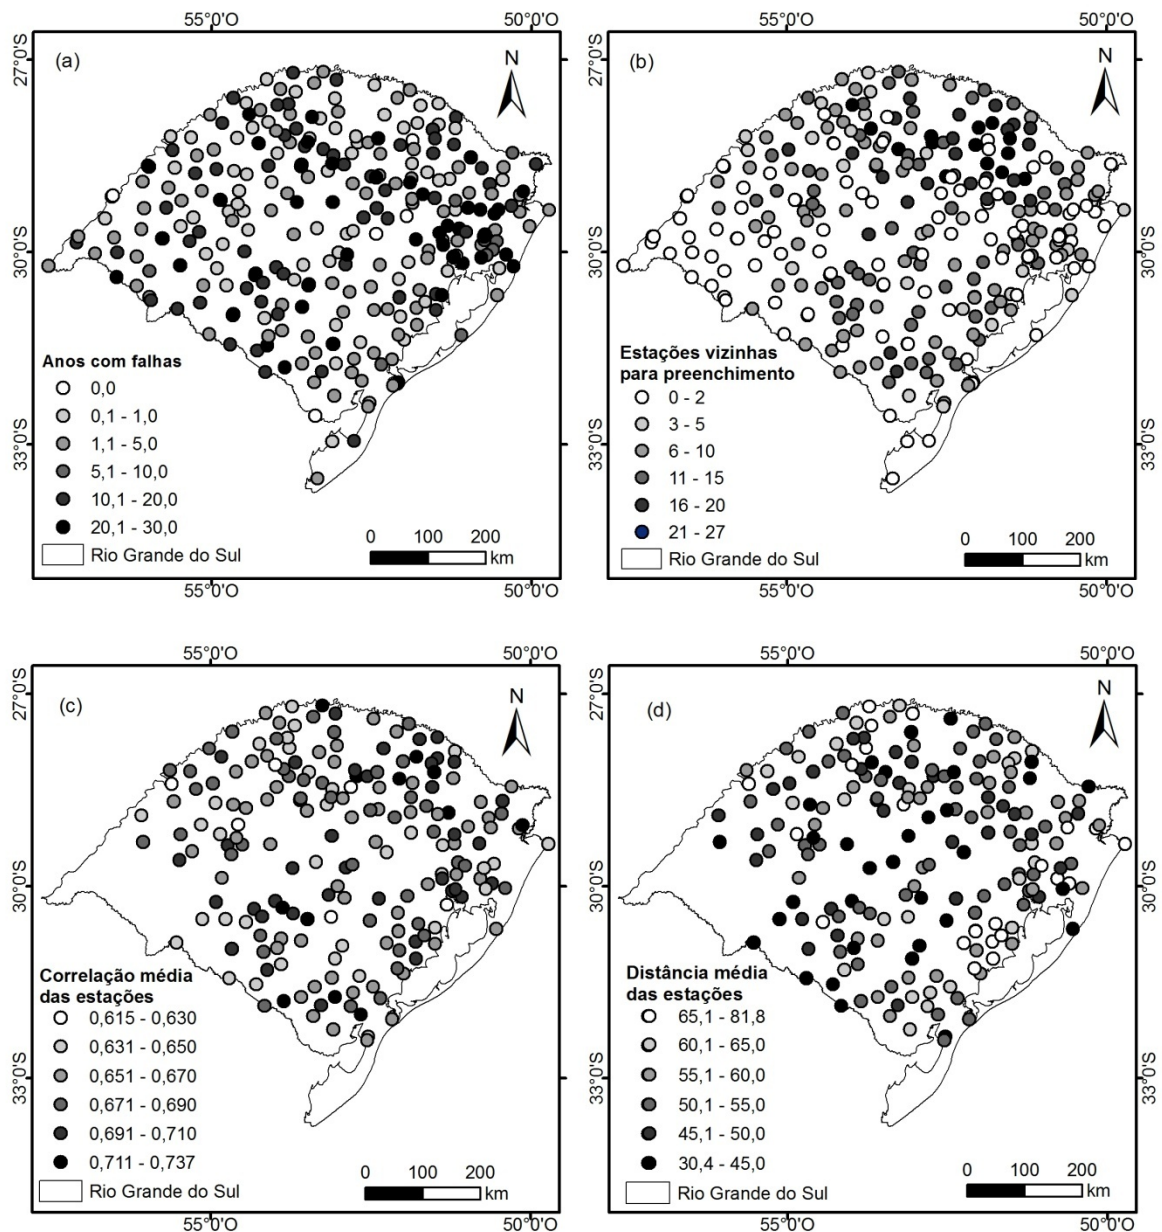
Foi escolhida a estrutura de RNA com apenas uma camada oculta, assim como nos estudos de Depiné *et al.* (2014) e Oliveira *et al.* (2014), tendo em vista que essa arquitetura de RNA tem a capacidade de solucionar problemas complexos e gerar uma grande quantidade de conexões sinápticas, conforme o teorema apresentado por Hetch-Nielsen (1987) e reforçado por Hornik *et al.* (1989). O número de neurônios na camada oculta foi testado, variando entre  $ni-2$  e  $ni+4$  para cada configuração de dados de entrada ( $ni$  = número de *inputs*). Essa variação de número de neurônios foi escolhida com base em aplicações anteriores de RNA em hidrologia, como em Oliveira *et al.* (2013) e Depiné *et al.* (2014).

Uma vez que a inicialização dos pesos é aleatória, foram executadas 20 iterações para cada configuração, com taxa de aprendizagem redefinida para 0,01 no início de cada uma. Isso é necessário para minimizar a chance do treinamento estacionar em um mínimo local. A aceleração da convergência ocorre pela variação da taxa de aprendizado durante os ciclos de treinamento, a partir das soluções apresentadas em Vogl *et al.* (1988). Foi definido um número máximo de 5.000 ciclos de aprendizagem para interrupção, caso a rede não atinja o limiar de convergência pré-estabelecido.

Os resultados foram analisados para identificar a distribuição espacial das falhas por estações, os locais com maior número de estações vizinhas para o preenchimento, e o desempenho dos modelos RLM e RNA medido pelo coeficiente de determinação ( $R^2$ ) e pelo erro médio absoluto (EMA) para cada estação.

### 3. Resultados E Discussões

A distribuição espacial das estações pluviométricas, Fig. 2, considera o total de falhas por estação (2a), a quantidade de estações vizinhas que atendem aos critérios mínimos para o preenchimento em cada local (2b), a correlação (2c) e a distância média entre as estações vizinhas (2d) e o local a ser realizado o preenchimento, quando atendidos os requisitos estipulados na metodologia. As Fig. 2c e 2d mostram apenas as estações em que foi realizado o processo de preenchimento de falhas.



**Figura 2.** Distribuição espacial das estações pluviométricas no RS, conforme: (a) quantidade de anos com falhas em cada estação; (b) número de estações vizinhas utilizadas para o preenchimento de falhas; (c) o coeficiente de correlação linear de Pearson média entre a precipitação das estações vizinhas em relação a cada local; (d) a distância média das estações vizinhas em relação a cada local.

Em relação às falhas, apenas 7 estações das 287 analisadas, ou seja, apenas 2,4%, apresentaram séries completas no período de 30 anos. A maioria das estações (60,3%) apresentam menos de 5 anos de falhas e 16,4% das estações apresentam menos de 10 anos de dados no período entre 1987 e 2016.

Em relação à distribuição espacial das estações, de acordo com a Fig. 2b, na região nordeste do RS há uma rede mais

densa de estações que atendem aos critérios mínimos estabelecidos para o preenchimento de falhas. No sudoeste (Campanha Gaúcha), há um número menor de estações vizinhas que atendam aos critérios estabelecidos, não permitindo realizar o preenchimento de falhas. Deste modo, essas estações foram excluídas nos mapas de correlação e distância (2c e 2d). Em média, para cada estação, existem sete estações vizinhas que podem ser utilizadas no preenchimento de falhas. Na porção

nordeste, em alguns casos, foram utilizadas mais de 20 estações vizinhas no preenchimento.

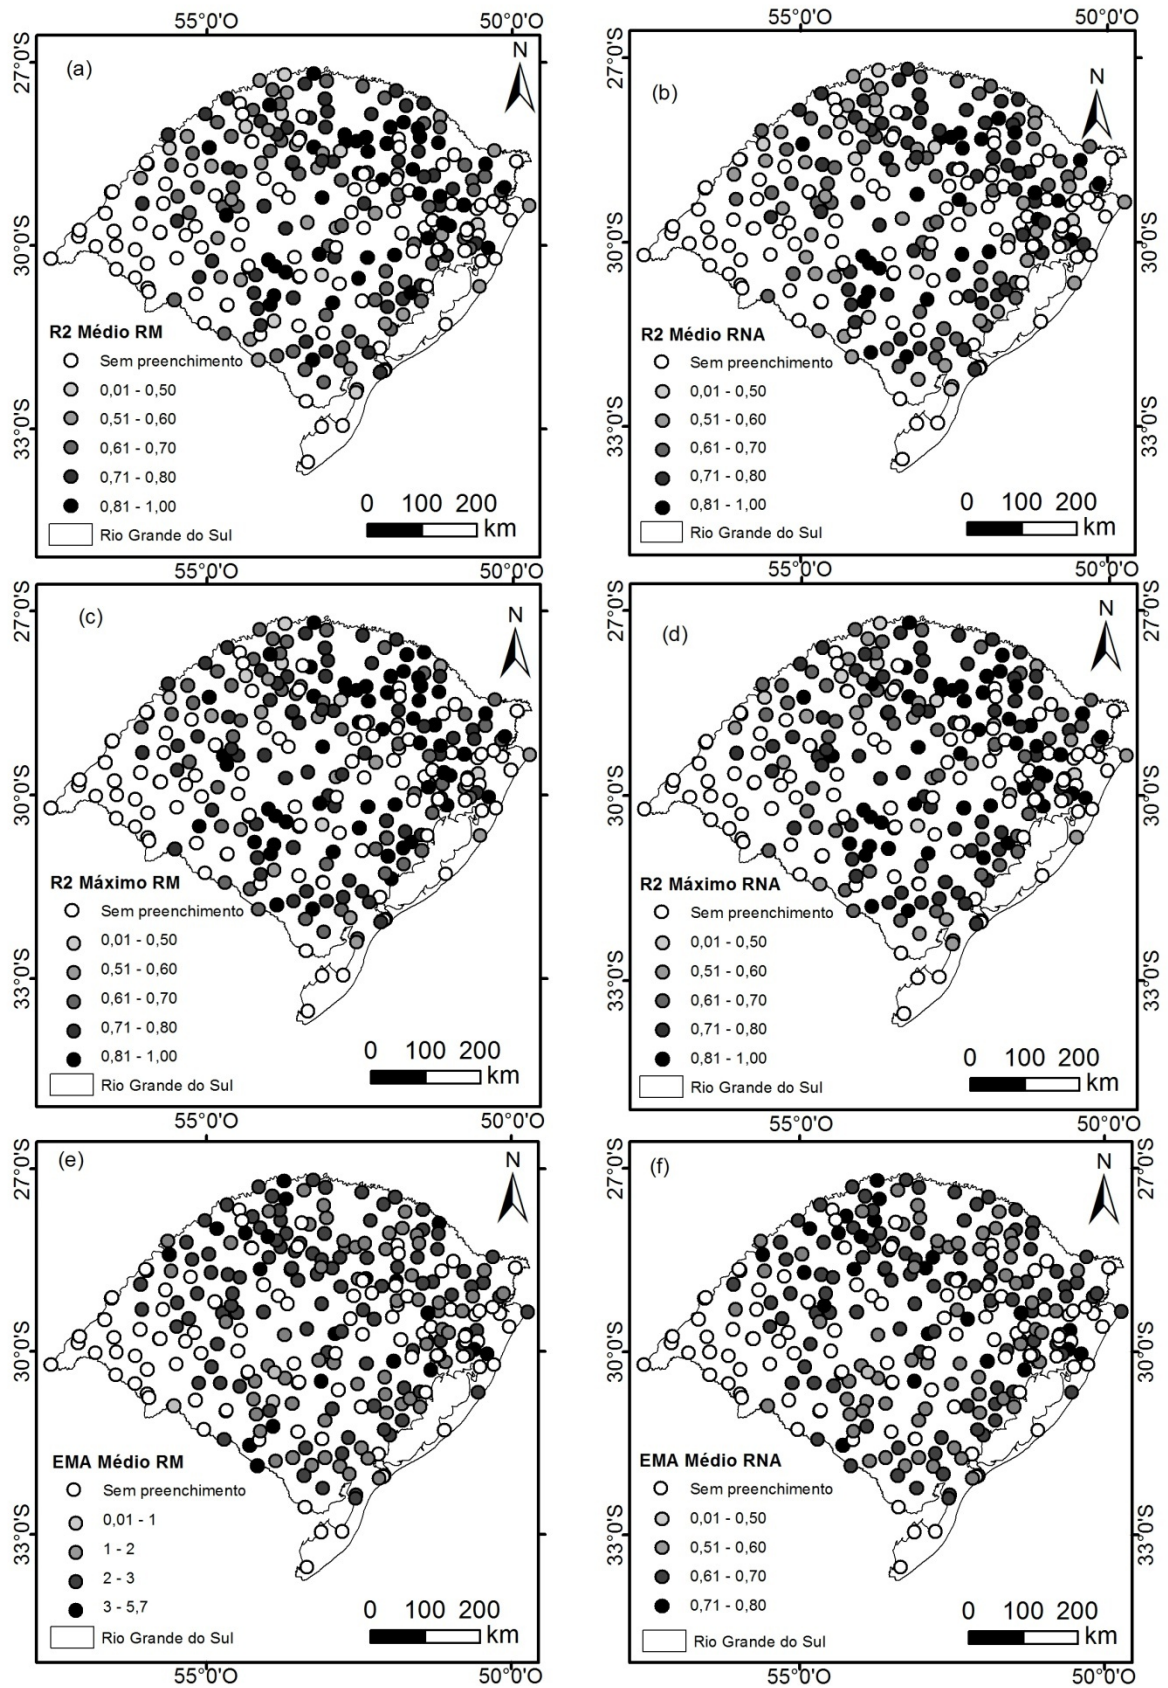
As estações que apresentam coeficiente médio de correlação linear superior a 0,7, ao relacionar sua precipitação diária com a registrada em estações vizinhas (Fig. 2c), representam 30 estações do conjunto amostrado, ou seja, cerca de 15,3%. A correlação média da precipitação diária entre as estações está associada principalmente à flexibilidade dos critérios utilizados no processo de preenchimento, permitindo o uso de estações distantes até 100 km. A variabilidade das condições pluviométricas associadas às características do relevo do Rio Grande do Sul faz com que os dados diários apresentem diferenças consideráveis entre estações, sendo que nos dados mensais essa característica acaba sendo compensada, aumentando a correlação espacial dos dados.

Segundo Britto *et al.* (2008), os meses de inverno são os mais chuvosos no litoral e no centro-sul do RS, devido à passagem de sistemas frontais, enquanto no sudoeste, o outono é mais chuvoso, devido à configuração de bloqueios atmosféricos. No noroeste chove mais nos meses de primavera, por consequência dos complexos convectivos de mesoescala. Essa análise trata dos padrões sazonais de precipitação no estado, que tende a

apresentar uma homogeneidade maior que a chuva diária, caracterizada por grande aleatoriedade dentro uma mesma cidade.

Na distância média das estações, Fig. 2d, a proporção das estações vizinhas que apresentaram distância média menor que 50 km ficou em 25,1%, o equivalente a 49 estações. Há uma maior correlação linear dos dados de precipitação quanto mais próxima for a relação com a sua vizinhança, de modo que as estações localizadas mais próximas ajudam a explicar os resultados obtidos.

O desempenho médio dos modelos RLM (Fig. 3a) e RNA (Fig. 3b) tem como base o coeficiente de determinação ( $R^2$ ) entre a série preenchida e a série original, e considera o mesmo conjunto de validação por estação. No caso dos modelos de RLM, a proporção de estações que apresentaram  $R^2$  superior a 0,6 foi de 53,6%, enquanto que para os modelos baseados em RNAs (Fig. 3b) foi 48,8%. O resultado do preenchimento de falhas foi superior a 0,8 em 15,3% das estações, considerando RLM, e 10,1%, nos modelos baseados em RNA. Em relação EMA Médio para RLM (Fig. 3e) e EMA Médio para RNA (Fig. 3f), as estações apresentaram resultados semelhantes, no entanto os menores erros foram encontrados no método de RLM, de forma que, das estações preenchidas, 75% das estações apresentaram erros menores que o RNA.



**Figura 3.** Desempenho dos modelos RLM e RNA no processo de preenchimento de falhas nas estações pluviométricas do RS: (a) R<sup>2</sup> médio RLM; (b) R<sup>2</sup> médio RNA; (c) R<sup>2</sup> máximo RLM; (d) R<sup>2</sup> máximo RNA; (e) EMA Médio RLM; (f) EMA Médio RNA.

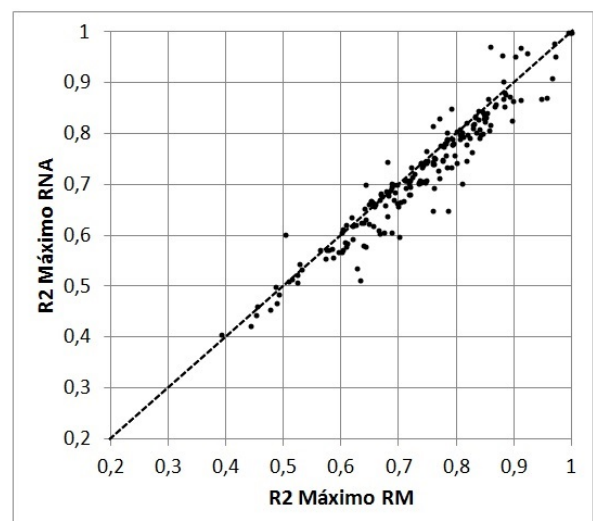
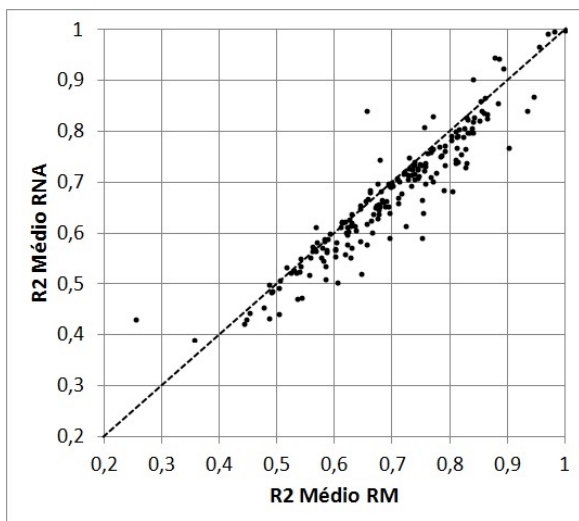


Em relação aos valores máximos de RLM (Fig. 3c) e RNA (Fig. 3d), as estimativas acompanham os valores médios, ou seja, também nesse parâmetro a RLM apresentou valores superiores a RNA. Dessa forma, mesmo que em determinadas estações a discrepância não seja tão evidente, a superioridade da RLM foi predominante.

No contexto espacial, o desempenho do preenchimento de falhas foi superior na porção nordeste do RS. Ainda que o relevo nessa área se apresente com vales mais profundos e linhas de escarpas erosivas, com maior declividade do terreno, o que favorece mudanças mais abruptas nos valores de precipitação, a maior densidade das estações fez com que o processo de

transferência de dados entre as estações apresentasse maior precisão.

Das 287 estações, o preenchimento foi realizado em 195, em função das restrições definidas na metodologia. O desempenho do modelo RLM foi superior às RNA em 76% dos locais (Fig. 4). Em relação aos valores médios de  $R^2$ , o modelo de RLM apresentou o valor de 0,697, enquanto a média dos valores para o modelo RNA foi de 0,675. Levando-se em conta a análise por meio do EMA, a média dos valores foi de 2,27 para RLM, enquanto para o RNA o erro ficou em 2,31. Ou seja, para esse tipo de estimativa há uma superioridade do método RLM em relação ao método RNA, para esse conjunto de dados e área de estudo.



**Figura 4.** Dispersão do coeficiente de determinação ( $R^2$ ) Médio e Máximo no preenchimento de falhas com RLM e com RNA.

Quando consideradas as médias de chuvas mensais, os valores de preenchimento por meio de RNA apresentaram semelhanças com os dados obtidos em estações vizinhas. Esses resultados podem ter sido decorrência de que, ao avaliar mensalmente os dados de chuva, as discrepâncias relativas ao relevo e ao tipo de chuva são suavizadas (Depinê *et al.*, 2014).

Mello *et al.* (2017) desaconselham o preenchimento de falhas quando da análise da distribuição de eventos extremos, dados diários ou de um evento específico. O

preenchimento pode gerar um dado não condizente com o registrado no evento analisado. No entanto, os modelos RLM e RNA demonstraram que quanto mais densa for a rede pluviométrica, o preenchimento de falhas pode permitir a utilização de séries que, anteriormente, teriam de ser descartadas.

A alta variabilidade das chuvas e as muitas formas em que a precipitação pode ocorrer são extremamente desafiadoras (Mekis *et al.*, 2018). Então, ao mensurar o preenchimento de dados faltantes em estações, deve-se levar em conta a

capacidade de cada método em lidar com as discrepâncias espaciais.

Não se trata apenas de decidir qual o melhor método, mas sim, com base na análise dos dados, verificar a eficiência do método para a complexidade espacial. Considerando a estrutura das RNA e sua alta capacidade para solucionar problemas complexos e não-lineares, o resultado obtido foi diferente do esperado. A hipótese inicial era de que as RNA apresentassem um valor de preenchimento de precipitação mais próximo das estações de validação, ainda que resultasse em um conjunto extenso de pesos sinápticos na rede.

Nos testes realizados por Ventura *et al.* (2013), os coeficientes de correlação variaram entre 0,79 e 0,96 e o erro médio absoluto entre de 0,62 e 1,22, mostrando um bom desempenho da rede neural para uma série de dados com valores ausentes. Nesse trabalho, os valores ficaram entre 0,43 e 0,73, o que demonstra que a área de estudo pode influenciar nos resultados, justificando o uso do RNA.

A estrutura simplificada de parâmetros do modelo RLM foi capaz de obter resultados mais próximos ao esperado. O que pode ser explicado pelos altos índices espaciais de correlação linear entre as estações, principalmente na região nordeste. O que indica não ser necessário usar um modelo complexo para estimar valores de precipitação em um local a partir de estações vizinhas. Resultados semelhantes foram encontrados por Oliveira *et al.* (2010) com o método RLM obtendo melhor desempenho no preenchimento de falhas em relação aos demais métodos testados. No entanto, ressaltam não poder afirmar que essa metodologia possa ser aplicada sem prévia análise regional de desempenho.

Junqueira *et al.* (2018) também observaram melhores resultados no método RLM, em comparação com outros métodos, sendo o que mais se aproximou dos valores utilizados para validação. Esse

método, mais simples em comparação com IDW (utilizado pelos autores) ou RNA, tem se mostrado eficiente em relação a esse tipo de demanda.

No entanto, em relação a estudos com outras variáveis meteorológicas, como precipitação e umidade do ar, Coutinho *et al.* (2018) identificaram que as RNA foram responsáveis pelos melhores resultados para o preenchimento de falhas, evidenciando que o seu uso não deve ser descartado, mas sim avaliado de acordo com a necessidade.

Em áreas com grande densidade de estações, os dois métodos demonstraram bons resultados, com  $R^2$  médio acima de 0,8. Ainda assim, o padrão foi superior para o  $R^2$  médio, tendo em vista que o relevo não foi relevante em relação aos dois métodos utilizados. O RLM apresentou o melhor desempenho, com os melhores resultados nas estações analisadas.

Uma das principais contribuições desse estudo é o desenvolvimento de uma abordagem que considera os melhores resultados obtidos por meio dos dois métodos utilizados, sendo que aplicação se deu em uma larga área de estudo com complexidade de sistemas atmosféricos atuantes e que são diretamente influenciados pelo relevo, fatores que dificultam o preenchimento de dados faltantes, mas ainda assim obteve resultados satisfatórios na maioria das lacunas.

A importância dessa pesquisa diz respeito a proposição de um método para o preenchimento confiável de falhas, mesmo com a complexidade dos sistemas atmosféricos atuantes e da influência do relevo, o que permite uma série de estudos com base nesses dados. Com essa finalidade, o método utilizado se mostrou útil, mesmo que o resultado tenha sido diferente do esperado.

A hipótese inicial era de que as RNA apresentariam valor de  $R^2$  superior a RLM,

ou seja, que os valores corrigidos apresentassem maior correlação com a série de validação, devido a sua capacidade de aprendizagem e possibilidade de lidar com dados complexos. No entanto, para o Rio Grande do Sul e com base nos critérios adotados, o método RLM apresentou valores superiores em relação  $R^2$ .

#### 4. Considerações finais

Com base nos objetivos propostos e nos resultados obtidos, pode-se concluir que:

- A maior densidade de estações pluviométricas na porção nordeste do RS favoreceu preenchimento de falhas em séries históricas, melhorando a qualidade da série preenchida;

- O preenchimento de falhas em dados diários de precipitação apresentou maior coeficiente de determinação com o modelo RLM em relação às RNA, possivelmente em função da alta correlação linear espacial entre os valores de precipitação de estações vizinhas, indicando não ser necessário usar um modelo mais complexo.

- Destaca-se o estudo contemplando todo o estado do Rio Grande do Sul, com uma área de mais de 281 mil km<sup>2</sup>, o que diverge de trabalhos que preenchem falhas de precipitação em escalas normalmente em bacias hidrográficas. Além disso, o preenchimento de falhas das séries de precipitação em grandes escalas amplia as possibilidades de estudos hidrológicos regionais.

#### AGRADECIMENTOS

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001;

e da FAPERGS, processo 17/2551-0000894-4, Edital 01/2017.

#### Referências

ALY, A.; PATHAK, C.; TEEGAVARAPU, R.S.V.; ALQUIST, J.; FUELBERG, H. Evaluation of improvised spatial interpolation methods for infilling missing precipitation records. In: **World Environment Water Resources Congress 2009: Great Rivers**, Kansas City, Missouri, USA, p. 5914-5923, 2009.

BALLARI, D.; GIRALDO, R.; CAMPOZANO, L.; SAMANIEGO, E. Spatial function al data analysis for regionalizing precipitation seasonality and intensity in a sparsely monitored region: Unveiling the spatio-temporal dependencies of precipitation in Ecuador. **Int. J. Clim.** v.38, p.3337-3354, 2018.

BERTONI, J.C.; TUCCI, C.E.M. Precipitação. In: Tucci, C.E.M. (Org.) **Hidrologia: Ciência e aplicação**. Porto Alegre: Universidade Federal do Rio Grande do Sul, ABRH, p. 177-242, 2001.

BRITTO, F.; BARLETTA, R.; MENDONÇA, M. Regionalização sazonal e mensal da precipitação pluvial máxima no estado do Rio Grande do Sul. **Rev. bras. clim**, v.2, n.2, p.83-99, 2008.

BRUBACHER, J.P.; OLIVEIRA, G.G.; GUASSELLI, L.A. Identificação e análise de eventos extremos de precipitação na bacia hidrográfica do rio dos Sinos/RS. In: I CONGRESSO BRASILEIRO SOBRE DESASTRES NATURAIS, Rio Claro, 2012. **1CD-ROM**.

BUSTAMI, R.; BESSAIH, N.; BONG, C.; SUHAILI, S. Artificial Neural Network for Precipitation and Water Level Predictions of Bedup River. **Int. J. Comput. Sci**, v. 34, n. 2, p. 228-233, 2017.

COUTINHO, E.R. Aplicação de Redes Neurais Artificiais (RNAs) no Preenchimento de Falhas de Séries

- Temporais Meteorológicas. **Rev. bras. meteor.**, v. 33, n. 2, p. 317-328, 2018.
- CORREIA, T.P.; DOHLER, R.E.; DAMBROZ, C.S.; BINNOT, D.H.B. Aplicação de redes neurais artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Revista Geociências**, São Paulo, UNESP, v. 35, n. 4, p. 560-567, 2016.
- COSTA, M.N.M.; BECKER, C.T.; BRITO, J.I.B. Análise das séries temporais de precipitação do semiárido paraibano em um período de 100 anos - 1911 a 2010. **Rev. bras. geogr. física**, v. 6, n. 4, p. 680-696, 2013.
- DEPINÉ, H.; CASTRO, N.M.R.; PINHEIRO, A.; PEDROLO, O. Preenchimento de falhas de dados horários de precipitação utilizando redes neurais artificiais. **Rev. bras. recur. hídricos**, v. 19, n. 1, p. 51-63, 2014.
- FERNANDEZ, M.N. **Preenchimento de Falhas em Séries Temporais**. Dissertação (mestrado em Engenharia Oceânica) - Fundação Federal Universidade de Rio Grande, Rio Grande, 106 p., 2007.
- GIMENEZ, D.F.S. **Análise da precipitação pluvial e ocorrências de desastres naturais no estado de São Paulo (1976 – 2012)**. Dissertação (mestrado em Geografia) - Universidade Estadual de Campinas, Campinas, 98 p., 2017
- GUPTA, N. Artificial neural network. **Network and Complex Systems**, v. 3, n. 1, p. 24-28, 2013.
- HAYKIN, S.O. **Neural networks and learning machines**. 3.ed. Upper Saddle River, New Jersey: Prentice Hall, 889 p. 2008.
- HECHT-NIELSEN, R. **Kolmogorov's mapping neural network existence theorem**. Proceedings of the First IEEE-International Joint Conference on Neural Networks, San Diego, California, p. 11-14, 1987.
- HORNIK, K.; STINCHCOMBE, M.; WHITE, H. Multilayer feedforward networks are universal approximators. **Neural networks**, v. 2, n. 5, p. 359-366, 1989.
- ICHIYANAGI, K.; YAMANAKA, M.D.; MURAJI, Y.; VAIDYA, B.K. Precipitation in Nepal between 1987 and 1996. **Int. J. Clim.**, v. 27, p. 1753-1762, 2018.
- JUNQUEIRA, R.; AMORIM, J.S.; OLIVEIRA, A.S. Comparação entre diferentes metodologias para preenchimento de falhas em dados pluviométricos. **Sustentare**, v. 2, n. 1, p. 198-210, 2018.
- LEAHY, P.; KIELY, G.; CORCORAN, G. Structural optimisation and input selection of an artificial neural network for river level prediction. **J. Hydrol.**, v. 355, p. 192-201, 2008.
- MEKIS, E.; DONALDSON, N.; REID, J.; ZUCCONI, A.; JEFFERY, H.; LI, Q.; NITU, R.; MELO, S. An Overview of Surface-Based Precipitation Observations at Environment and Climate Change Canada. **Atmosphere-Ocean journal**. v. 56, p. 1-25, 2018.
- MELLO, Y.R.; KOHLS, W.; OLIVEIRA, T.M.N. Uso de diferentes métodos para o preenchimento de falhas em estações pluviométricas. **Boletim de Geografia**, Maringá, v. 35, n. 1, p. 112-121, 2017.
- NAGHETTINI, M.; ANDRADE PINTO, E.J. Serviço Geológico do Brasil. **Hidrologia estatística**. Belo Horizonte, 552 p., 2007.
- OLIVEIRA, L.F.C.; FIORENZE, A.P.; MEDEIROS, A.M.M.; SILVA, M.A.S. Comparação de Metodologias de preenchimento de falhas de séries históricas de precipitação pluvial anual. **Rev. bras. eng. agríc. ambient.**, v. 14, n. 11, p. 1186-1192, 2010.
- OLIVEIRA, G. G., PEDROLLO, O. C., CASTRO, N. M. R., BRAVO, J. M. Simulações hidrológicas com diferentes proporções de área controlada na bacia

- hidrográfica. **Rev. bras. recur. hídricos**, v. 18, n. 3, p. 193-204, 2013.
- OLIVEIRA, G.G.; PEDROLLO, O.C.; CASTRO, N.M.R. O Desempenho das Redes Neurais Artificiais (RNAs) para Simulação Hidrológica Mensal. **Rev. bras. recur. hídricos**, v. 19, n. 2, p. 251-265, 2014.
- PRESTI, R.L.; BARCA, E.; PASSARELLA, G. A methodology for treating missing data applied to daily rainfall data in the Candelaro River Basin. **Environ. Monit. Assess.**, v. 160, p. 1-22, 2010.
- RAMOS-CALZADO, P; CAMACHO J.G.; PÉREZ-BERNAL, F; PITA, M.F. A novel approach to precipitation series completion in climatological datasets: application to Andalusia. **Int. J. Clim.**, v. 28, n. 11, p. 1525-1534, 2008.
- ROSSATO, M. S. **Os climas do Rio Grande do Sul: variabilidade, tendências e tipologia**. Tese (Doutorado em Geografia) – Universidade Federal do Rio Grande do Sul, Porto Alegre, 253 p., 2011.
- RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors. **Nature**, n. 323, p. 533-536, 1986.
- SIMOLO, C; BRUNETTI, M; MAUGERI, M; NANNI T. Improving estimation of missing values in daily precipitation series by a probability density function-preserving approach. **Int. J. Clim.**, v. 30, n. 10, p. 1564-1576, 2010.
- TARDIVO, G.; BERTI A. A dynamic method for gap filling in daily temperature datasets. **J. Appl. Meteorol. Climatol.**, v. 51, n. 6, p. 1079-1086, 2012.
- TEEGAVARAPU, R.S.V.; CHANDRAMOULI, V. Improved weighting methods, deterministic and stochastic data-driven models for estimation of missing precipitation records. **J. Hydrol.**, v. 312, p. 191–206, 2005.
- TOKAR, S.; MARKUS, M. precipitation-runoff modeling using artificial neural networks and conceptual models. **J. Hydrol. Eng.** v. 5, n. 2, p. 156-161, 2000.
- VENTURA, T.M.; OLIVEIRAM A.G.; MARQUES, H.O.; OLIVEIRA, R.S.; MARTINS, C.A.; FIGUEIREDO, J.M.; BONFANTE, A.G. Uma abordagem computacional para preenchimento de falhas em dados micro meteorológicos. **Rev. bras. ciênc. ambientais**, n. 27, p. 61-70, 2013.
- VIEIRA, S.A.; OSORIO, D.M.M.; QUEVEDO, D.M.; ADAM, K.N.; PEREIRA, N.A.F. Metodologia de imputação de dados hidrometeorológicos para análise de séries históricas – bacia do rio dos Sinos, RS, Brasil. **Rev. bras. clim.**, v. 23, p. 189-204, 2018.
- VOGL, T.P.; MANGIS, J.K.; ZIGLER, A.K.; ZINK, W.T.; ALKON, D.L. Accelerating the convergence of the backpropagation method. **Bio. Cybern.**, v. 59, p. 256-264, 1988.
- WIDROW, B.; HOFF, M.E. **Adaptive Switching Circuits**. 4 IRE Wescon Conv. Record, New York: v. 4, p. 96-104, 1960.
- WOLDESENBET, T.A.; ELAGIB, N.A.; RIBBE, L.; HEINRICH, J. Gap filling and homogenization of climatological datasets in the headwater region of the Upper Blue Nile Basin, Ethiopia. **Int. J. Clim.**, v. 37, n. 4, p. 2122-2140, 2017.

#### Endereços de internet

ANA - AGÊNCIA NACIONAL DE ÁGUAS. **Portal Hidroweb**: Sistema Nacional de Informações sobre Recursos Hídricos. Disponível em: <https://www.snirh.gov.br/hidroweb/>. Acesso em: 18 out. 2018.

### **3.3 ARTIGO 3: Banco de dados espacial de precipitação do estado do Rio Grande do Sul**

Submetido para a Revista Brasileira de Meteorologia.

Dear Sr. Brubacher:

Your manuscript entitled "Banco de dados espacial de precipitação do estado do Rio Grande do Sul" has been successfully submitted online and is presently being given full consideration for publication in the Revista Brasileira de Meteorologia.

Your manuscript ID is RBMET-2021-0009.

Please mention the above manuscript ID in all future correspondence or when calling the office for questions. If there are any changes in your street address or e-mail address, please log in to ScholarOne Manuscripts at <https://mc04.manuscriptcentral.com/rbmet-scielo> and edit your user information as appropriate.

You can also view the status of your manuscript at any time by checking your Author Center after logging in to <https://mc04.manuscriptcentral.com/rbmet-scielo>.

Thank you for submitting your manuscript to the Revista Brasileira de Meteorologia.

Sincerely,  
Revista Brasileira de Meteorologia Editorial Office

## **Banco de dados espacial de precipitação do estado do Rio Grande do Sul**

João Paulo Brubacher<sup>1</sup>, Guilherme Garcia de Oliveira<sup>1</sup>, Laurindo Antonio Guasselli<sup>1</sup>

*<sup>1</sup>Laboratório de Geoprocessamento e Análise Ambiental, Programa de Pós-Graduação em Sensoriamento Remoto, Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, RS, Brasil.*

### **Resumo**

Atualmente, ao obter séries históricas de precipitação, é necessário realizar o preenchimento de falhas, interpolar e estimar a precipitação para área de interesse, principalmente em locais com baixa densidade de estações pluviométricas. Então, este estudo teve como objetivo gerar um Banco de Dados espacial com séries históricas de precipitação para o estado do Rio Grande do Sul, que permita a consulta a índices de precipitação por bacia, por município e por coordenadas geográficas, sem a necessidade de pós-processamento. A metodologia foi estruturada em cinco etapas: adquirir, organizar e preencher falhas das séries históricas de precipitação; interpolar, por meio do método Inverso da Potência da Distância (IPD), dados de chuva para uma malha regular com resolução espacial de 20 km; calcular índices de precipitação (Tempo de Retorno, Chuva Média Mensal e Anual, Índice de Anomalia de Chuvas (IAC), Número de dias de Precipitação); codificar e dividir bacias hidrográficas a partir do Modelo Digital de Elevação (MDE); gerar Banco de Dados: organizar matrizes e tabelas para consultas. A validação cruzada da interpolação apresentou um EMA (Erro Médio Absoluto) que variou entre 1,02 e 3,20 mm, enquanto o EMQ (Erro Médio Quadrático) variou entre 6,4 e 8,4 mm. A disponibilização desse Banco de Dados na internet, com um arquivo de saída compatível com a maioria dos softwares de SIG, representa um ganho importante em pesquisas que necessitem utilizar longas séries temporais.

**Palavras-chave:** Séries temporais. Preenchimento de falhas. Interpolação espacial. Ottocodificação.

## Spatial database of precipitation of Rio Grande do Sul

### Abstract

Currently, when getting time series of precipitation, it is necessary to perform gap filling, interpolate and estimate precipitation for the study area, mainly in areas where there is a low density of rainfall stations. This study aimed to generate a spatial database with historical time series of precipitation for the state of Rio Grande do Sul, that allows the consultation of precipitation indexes by watershed, by municipality and by geographic coordinates. The methodology was structured in five stages: acquisition, organization and gap filling in time series of precipitation; interpolation, by the method Inverse Distance weighting (IDW), rain data for a regular grid with spatial resolution of 20 km; calculate precipitation rates (precipitation return, average monthly and annual rain, Rainfall Anomaly Index (RAI), number of rainy days); coding and dividing river basins from the Digital Elevation Model (DEM); generate database: organize matrices and tables to consult. The cross validation of the interpolation presented Mean Absolute Error (MAE) that varied between 1,02 and 3,20 mm, while the Mean Square Error (MSE) varied between 6,4 and 8,4mm. The availability of this database on the internet, with an output file compatible with most GIS software, represents an important gain in research that needs to use long time series.

**Keywords:** Historical time series. Gap filling. Spatial interpolation. Pfafstetter code.



## 1 Introdução

A análise da variabilidade espacial e temporal do regime de precipitação é essencial em estudos que envolvem desde obras de engenharia até medidas mitigadoras relacionadas a eventos extremos. Além de fundamentais para a nossa compreensão das bacias hidrográficas e dos processos hidrológicos (Goodrich *et al.*, 2008), é uma das variáveis climáticas de maior influência no meio ambiente, na economia e na sociedade (Minuzzi e Lopez, 2014).

Embora as análises das variações climáticas se destaquem em nível mundial (Dore, 2005; Wang *et al.*, 2018; Ghumman *et al.*, 2020; Tabari, 2020), a importância do monitoramento e o registro de séries temporais de precipitação permitem que projetos técnicos sejam viabilizados, no planejamento e prevenção de desastres (Chou *et al.*, 2013; Barcellos *et al.*, 2016; Liu *et al.*, 2021), normais climatológicas (Arguez *et al.*, 2012; Reboita e Kruche, 2018; Vieira *et al.*, 2018), projetos agrícolas e de engenharia hidráulica (Beijo *et al.*, 2005; Menezes *et al.*, 2010; Costa, 2016), entre outros. Esses estudos demandam séries longas de precipitação para serem viáveis, no entanto, dificuldades na sua obtenção e no seu processamento são recorrentes (Trenberth, 2011; Brubacher *et al.*, 2020; Veber *et al.*, 2020).

O Guia de Práticas Hidrológicas da Organização Meteorológica Mundial (OMM) (WMO, 2008) destaca a necessidade de maior coordenação dos esforços para que a coleta de dados atenda às necessidades dos gestores de água no futuro. Problemas relacionados à acessibilidade de dados, compatibilidade e confiabilidade terão que ser resolvidos para atender a essas necessidades.

Para tornar viáveis as propostas da OMM, no entanto é necessário considerar a realidade que se impõe a países de proporções continentais, como o Brasil. No estado do Rio Grande do Sul, assim como em outros estados brasileiros, as principais limitações em relação aos dados disponíveis se devem à baixa densidade da rede pluviométrica e ao pequeno período de observações disponível (Silva *et al.*, 2002).

Atualmente, as principais fontes de obtenção de dados de precipitação no Brasil, são as plataformas *Hidroweb* e o Banco de Dados Meteorológicos para

Ensino e Pesquisa (BDMEP). O *Hidroweb* é uma ferramenta do Sistema Nacional de Informações sobre Recursos Hídricos (SNIRH) e oferece acesso ao banco de dados das informações coletadas pela Rede Hidrometeorológica Nacional (RHN), reúne dados de níveis fluviais, vazões, chuvas, climatologia, qualidade da água e sedimentos. Segundo dados da Agência Nacional de Águas (ANA), o sistema conta com 2767 estações que monitoram, principalmente, as chuvas. O BDMEP do Instituto Nacional de Meteorologia (INMET) permite o acesso ao banco de dados meteorológicos, que inclui mais de 400 estações. Pesquisadores em todo o Brasil fazem uso desses bancos de dados (Vianna *et al.*, 2017; Silva *et al.*, 2020).

Em nível mundial, a OMM define normas técnicas internacionais, com recomendações para as instituições usuárias e mantenedoras para gerenciamento e identificação das redes de estações meteorológicas por meio de códigos (WMO, 2015). No caso das análises geradas por interpolação ou por equações de regressão, é fundamental conhecer o processo de geração dos dados meteorológicos pontuais (Vianna *et al.*, 2017). Parte desse conhecimento está armazenado nos metadados das estações meteorológicas, composto pelas informações ou parâmetros auxiliares aos dados coletados (WMO, 2017).

Embora os constantes problemas de continuidade de medição afetem a formação de um banco de dados (Geraldi, 2017), as estações existentes permitem a sua consulta pontual. No entanto, caso o pesquisador tenha interesse em obter índices de precipitação (médias, máximas, etc.) por unidade territorial, como municípios ou bacias hidrográficas, é necessário o pós-processamento desses dados.

Criar bancos de dados (Goodrich *et al.*, 2008), que além da localização das estações pluviométricas possam expandir essas informações, por meio de malhas regulares, que sejam de acesso prático a índices pluviométricos, sem necessidade de pós-processamento, pode agilizar estudos científicos e técnicos nas áreas da climatologia, meteorologia e hidrologia.

Visando auxiliar o acesso a séries temporais de precipitação, este trabalho teve como objetivo gerar um banco de dados espacial com série histórica de chuvas, que permite consultar os índices de precipitação, por meio de uma malha regular de células, abrangendo bacias hidrográficas e municípios do Rio Grande do Sul, de acesso rápido e prático, sem a necessidade de pós-processamento.

## 2 Materiais e Métodos

### 2.1 Área de estudo

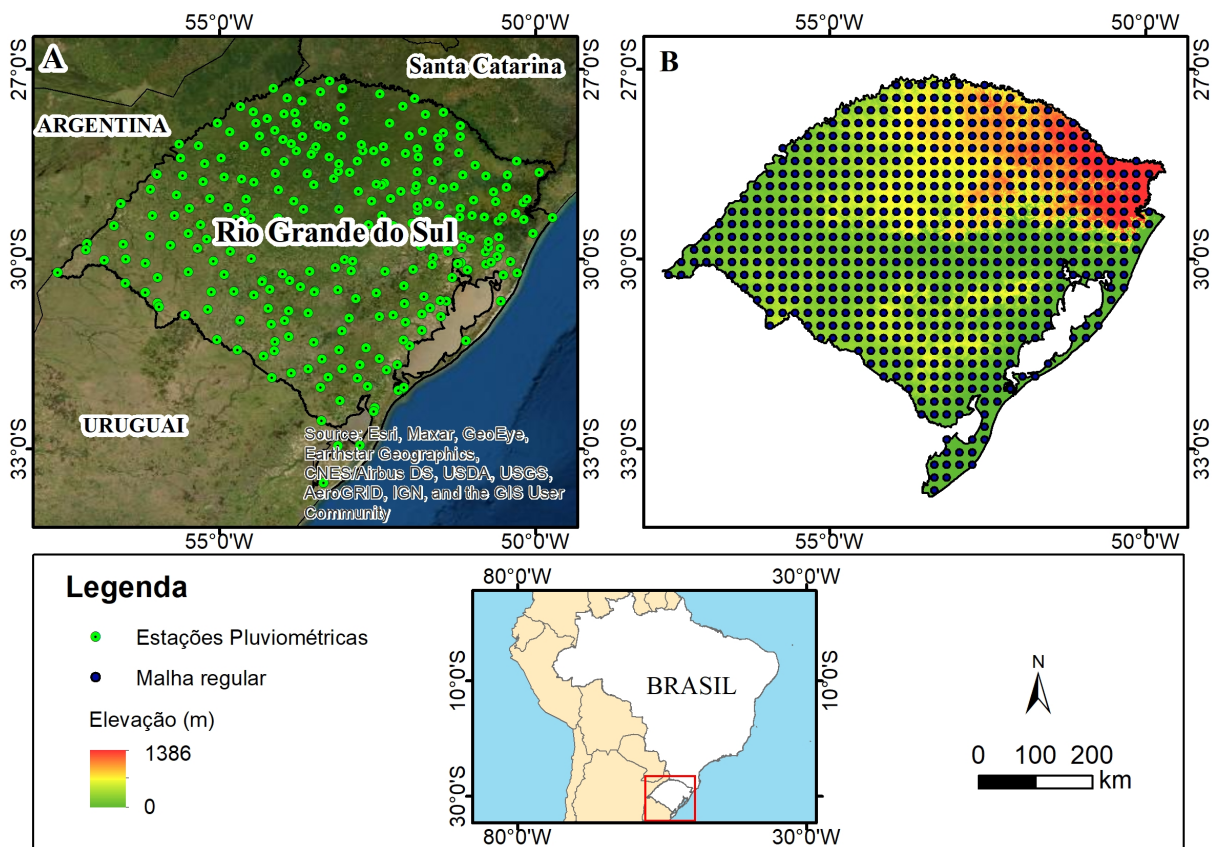
O estado do Rio Grande do Sul localiza-se no sul do Brasil, divisa com o estado de Santa Catarina a nordeste, Argentina a noroeste, Uruguai a sudoeste e Oceano Atlântico ao leste (Figura 1). Essa localização coloca o estado em uma zona climática de transição submetida, ciclicamente, a centros de pressão e sistemas atmosféricos atuantes no sul da América do Sul, com a participação de Sistemas Atmosféricos Extratropicais (massas e frentes polares) e Sistemas Intertropicais (massas tropicais e correntes perturbadas) (SARTORI, 2003; REBOITA e KRUCHE, 2018; BORSATO e MENDONÇA, 2015). A principal característica dessa influência condiz ao fato de o estado registrar grandes variações de precipitação entre as áreas geográficas menos chuvosas (1200 mm anuais) e mais chuvosas (2000 mm anuais) (ROSSATO, 2011).

O regime pluviométrico no estado do Rio Grande do Sul não é homogêneo (KAHN e KIM, 2008; FORGIARINI *et al.*, 2013). As particularidades do relevo sul-riograndense mostram diferentes comportamentos de precipitação (SARTORI, 2003). A pluviosidade é condicionada principalmente pela dinâmica atmosférica em relação ao relevo que, através de sua compartimentação, promove a distribuição espacial da precipitação (BRITTO *et al.*, 2006; BARATO e WOLMANN, 2015).

Em relação à variabilidade sazonal da precipitação no estado do Rio Grande do Sul, Teixeira *et al.* (2013) verificaram, no período entre 1913 e 2009, que os meses mais chuvosos foram setembro e outubro, com 153,36 e 151,02 mm; e entre fevereiro e agosto os menos chuvosos, com 123,65 mm e 128,26 mm.

Segundo Rossato (2011), as características variam entre as regiões. Na região Centro-Sul do estado, por exemplo, chove entre 1200 e 1700 mm anuais, distribuídos em 70-100 dias de chuva, e na região Centro-Norte chove entre 1700 e 2000 mm anuais em 110-150 dias de chuva.

Figura 1. A) Estações pluviométricas; B) malha regular de células, para interpolação espacial das precipitações diárias de Pixels, e variação da elevação do terreno, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

## 2.2 Métodos

Para atingir o objetivo proposto, esse estudo foi estruturado em 5 etapas: a) adquirir, organizar e preencher falhas das séries históricas de precipitação; b) interpolar espacialmente dados de chuva para uma malha regular com resolução espacial de 20 km; c) calcular os índices de precipitação (Tempo de Retorno, Chuva Média Mensal e Anual, Índice de Anomalia de Chuvas, Número de dias de Chuvas); d) otocodificar e dividir as bacias hidrográficas a partir do Modelo Digital de Elevação; e) gerar Banco de Dados: organizar matrizes e tabelas para consultas.

### 2.2.1 Aquisição, organização de séries históricas e preenchimento de falhas

A primeira etapa consistiu na aquisição e organização dos dados de precipitação disponíveis no Hidroweb, da Agência Nacional de Águas (ANA, 2019), e do Instituto Nacional de Meteorologia (INMET), obtidos por meio do Banco de Dados Meteorológicos para Ensino e Pesquisa (BDMEP). Foram utilizados dados de 287 estações pluviométricas (Figura 1), com séries completas ou parciais no período entre 01/01/1987 e 31/12/2016, totalizando 30 anos de registros. Os dados foram organizados em uma matriz, em que cada linha representa um dia e cada coluna uma estação.

Para o preenchimento das falhas foram utilizados dois métodos: Regressão Linear Múltipla (RLM), em que a precipitação no posto com falhas é correlacionada estatisticamente com a precipitação de postos vizinhos (NAGHETTINI e ANDRADE PINTO, 2007); e Redes Neurais Artificiais (RNA), modelos matemáticos empíricos, com capacidade de armazenar e disponibilizar conhecimento experimental, por meio de treinamento e de resposta aos estímulos (variáveis de entrada), segundo Tokar e Markus (2000).

Para a Regressão Linear Múltipla, as informações pluviométricas do posto  $Y$  são correlacionadas com as observações correspondentes de vários postos vizinhos, por meio de uma equação linear (Eq. 1).

$$Y = \beta_0 + \beta_1 \cdot X_1 + \beta_2 \cdot X_2 + \dots + \beta_i \cdot X_i + \varepsilon \quad \text{Eq. 1}$$

Em que:  $Y$  é a variável dependente, nesse caso, a precipitação estimada;  $X_1, X_2, \dots, X_i$ , são as variáveis independentes, nesse caso os postos considerados;  $\beta_0, \beta_1, \beta_2, \dots, \beta_{2i}$ , são os coeficientes da regressão; e  $\varepsilon$  indica o erro residual.

O treinamento da RNA foi realizado pelo método retropropagativo com múltiplas camadas (Rumelhart *et al.*, 1986), usando a Regra Delta (Widrow e Hoff, 1960) para atualizar os pesos sinápticos da rede. A função de ativação para os neurônios foi a sigmoide unipolar, não linear, contínua e derivável em todo o seu domínio. Uma série de validação cruzada paralela à série de treinamento foi utilizada

para evitar o superajustamento do modelo. O modelo de RNA utilizado é representado pela Eq. 2.

$$RNA\left(\frac{(x_t - p_i)}{s_i}\right) = f_o\left(\sum_h w_o f_h \sum_i w_h \left(\frac{x_t - p_i}{s_i}\right) + b_h\right) + b_o + e_o \quad \text{Eq. 2}$$

Em que:  $w_h, b_h, f_h, w_o, b_o$  e  $f_o$  são os pesos sinápticos ( $w$ ); tendência ( $b$ ); funções de ativação ( $f$ ), respectivamente, das camadas ocultas ( $h$ ); das camadas de saída ( $o$ );  $e_o$  é o erro esperado da camada de saída.

Foi escolhida a estrutura de RNA com apenas uma camada oculta, assim como nos estudos de Depiné *et al.* (2014) e Oliveira *et al.* (2014), tendo em vista que essa arquitetura de RNA tem a capacidade de solucionar problemas complexos e gerar uma grande quantidade de conexões sinápticas, conforme o teorema apresentado por Hetch-Nielsen (1987) e reforçado por Hornik *et al.* (1989). O número de neurônios na camada oculta foi testado, variando entre  $ni-2$  e  $ni+4$  para cada configuração de dados de entrada ( $ni$  = número de *inputs*). Essa variação de número de neurônios foi escolhida com base em aplicações anteriores de RNA em hidrologia, como em Oliveira *et al.* (2013) e Depiné *et al.* (2014).

Uma vez que a inicialização dos pesos é aleatória, foram executadas 20 iterações para cada configuração, com taxa de aprendizagem redefinida para 0,01 no início de cada uma. Isso é necessário para minimizar a chance do treinamento estacionar em um mínimo local. A aceleração da convergência ocorre pela variação da taxa de aprendizado durante os ciclos de treinamento, a partir das soluções apresentadas em Vogl *et al.* (1988). Foi definido um número máximo de 5.000 ciclos de aprendizagem para interrupção, caso a rede não atinja o limiar de convergência pré-estabelecido.

Visando comparar os dois métodos, foi desenvolvido um algoritmo no *software* MATLAB, com os seguintes critérios: i) para uma estação vizinha ser considerada apta para o preenchimento de falhas, o coeficiente de correlação linear ( $r$ ) da precipitação nos dois locais deve ser igual ou superior a 0,6 e a distância máxima entre as estações não pode ultrapassar 100 km; ii) três é o número mínimo de estações vizinhas para executar o processo de preenchimento; iii) o conjunto amostral de treinamento e de validação dos modelos de RLM e RNA, em cada

estação, é sempre o mesmo. Esses critérios foram propostos em Brubacher *et al.* (2020).

### 2.2.2 Interpolação pelo método IPD

A interpolação dos dados de precipitação foi realizada em ambiente MATLAB, com base em uma grade regular com resolução espacial de 20 km, abrangendo o estado do Rio Grande do Sul, totalizando 627 pontos de grade (células) (Figura 1).

A interpolação pelo método Inverso da Potência da Distância (IPD) é uma alternativa viável para interpolar a precipitação diária em bacias hidrográficas ou locais sem dados pluviométricos, utilizando estações meteorológicas adjacentes (ASSAD e EVANGELISTA, 1994; VIOLA *et al.*, 2009; SILVA *et al.*, 2011; WANDERLEY *et al.*, 2012).

O IPD limita a interpolação ao intervalo dos valores utilizados, isto é, não gera uma resposta de saída fora do domínio de valores de entrada dos postos pluviométricos vizinhos. Os pesos são avaliados durante o processo de interpolação, tal que a influência de cada ponto é inversamente proporcional à distância do nó da grade. É um ponderador versátil, fácil de programar e bastante preciso (LAM, 1983). Estabelece que o peso de uma estação ou ponto amostral é inversamente proporcional a sua distância (elevada a uma determinada potência) do local onde se deseja estimar o valor (Eq. 1).

$$xp = \frac{\sum_{i=1}^n \left( \frac{1}{d_i^p} \cdot x_i \right)}{\sum_{i=1}^n \left( \frac{1}{d_i^p} \right)} \quad \text{Eq.1}$$

Em que:  $x_p$  é o atributo interpolado;  $x_i$  é o valor do atributo do  $i$ -ésimo ponto de amostragem;  $d_i$  é a distância euclidiana entre o  $i$ -ésimo ponto de vizinhança e o ponto amostrado;  $n$  é o número de amostras;  $p$  é a potência escolhida.

Para chegar a melhor combinação de variáveis, foram testadas 60 combinações de interpolação, variando raio de procura, potência, quantidade de estações por quadrante (nordeste, sudeste, sudoeste e noroeste) e número mínimo de quadrantes com estações que atendem os critérios para uso (Quadro 1).

Quadro 1 - Combinações de valores testados para interpolação pelo método IPD

Potência	Raio (graus decimais)	Nº máximo de estações por quadrante	Nº mínimo de quadrantes com dados disponíveis
1,0; 1,5; 2,0; 2,5; 3,0	0,3°; 0,6°; 1,0°	2; 3	3; 4
Total de combinações: 60			

Fonte: Elaboração própria.

Para análise da melhor combinação, foram escolhidas 35 estações pluviométricas, de forma aleatória (Figura 2). Dois índices estatísticos foram utilizados para mensurar a melhor combinação: Erro Médio Absoluto (EMA) (Eq. 2); e Erro Médio Quadrático (EMQ) (Eq. 3).

$$EMA = \left( \sum_i^n \frac{E-O}{O} \right) \cdot \frac{1}{n} \quad \text{Eq. 2}$$

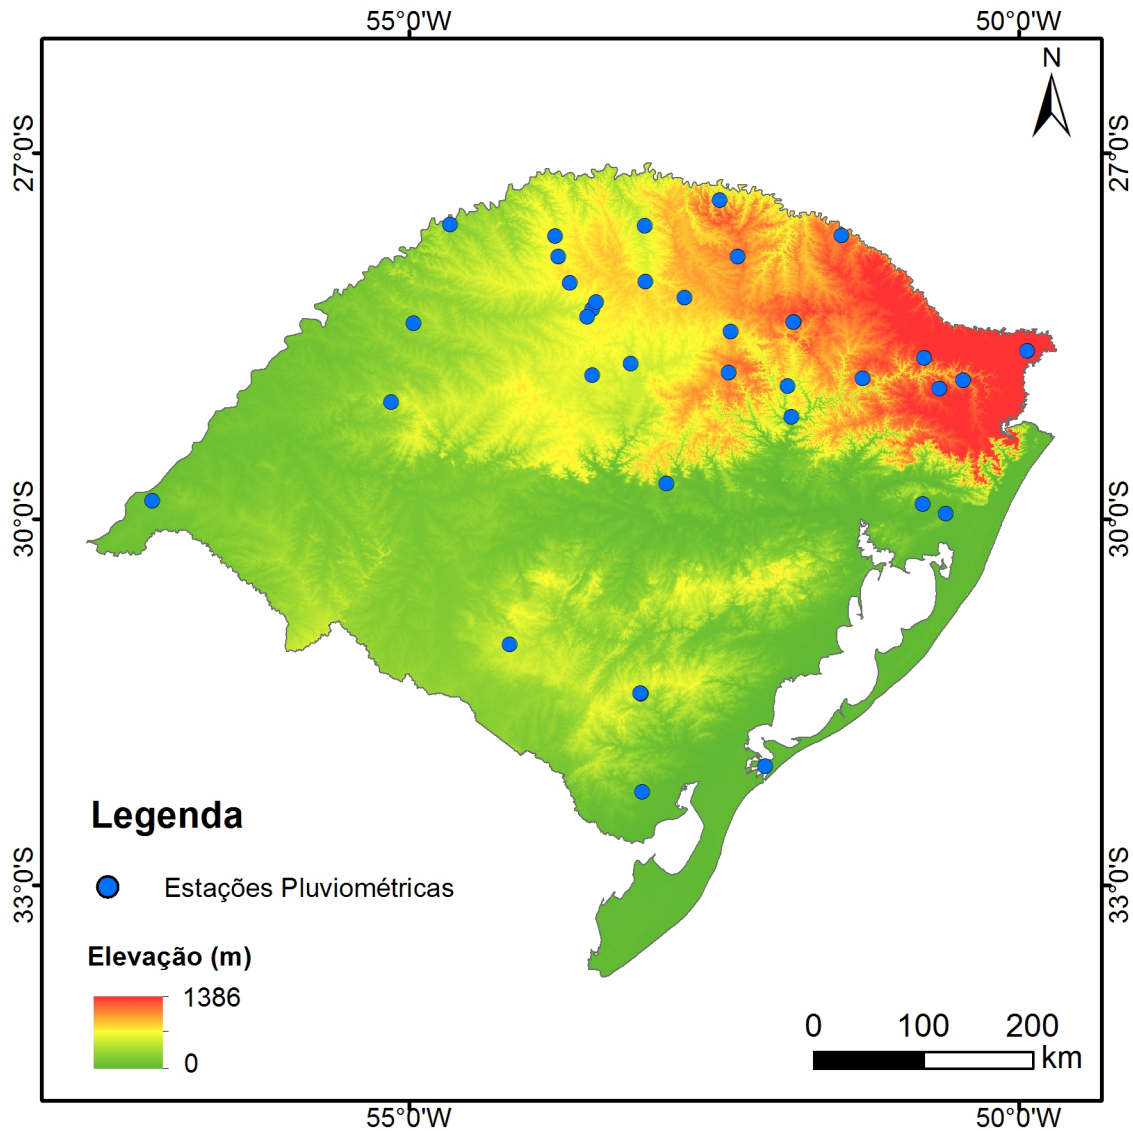
Em que: EMA = Erro Médio Absoluto; E = Valor estimado pela interpolação; O = Valor observado; n = Número de observações.

$$EMQ = \sum \frac{(E-O)^2}{n} \quad \text{Eq. 3}$$

Em que: EMQ = Erro Médio Quadrático; E = Valor estimado pela interpolação; O = Valor observado; n = Número de observações.



Figura 2 - Estações pluviométricas utilizadas para validação.



Fonte: Elaboração própria.

### 2.2.3 Cálculo dos índices de precipitação

A partir da interpolação, foram atribuídos dados de chuva para cada uma das 627 células. Foram calculados dados agregados para o período entre 1987 e 2016: a) médias mensais; b) acumulados anuais; c) acumulados mensais; d) Índice de Anomalia de Chuva (IAC); e) tempo de retorno (TR); e) número de dias de precipitação.

O IAC pode ser utilizado para avaliar a variabilidade temporal da precipitação, destacando os anos mais úmidos e mais secos da série temporal. Foi desenvolvido

por Rooy (1965) e apresenta duas equações gerais, uma utilizada para períodos de anomalias positivas (Eq. 4) e outra para anomalias negativas (Eq. 5):

$$IAC = 3 \left[ \left( \frac{N - \bar{N}}{\bar{M} - \bar{N}} \right) \right], \text{ anomalias positivas.} \quad \text{Eq. 4}$$

$$IAC = -3 \left[ \left( \frac{N - \bar{N}}{\bar{X} - \bar{N}} \right) \right], \text{ anomalias negativas.} \quad \text{Eq. 5}$$

Em que: N = Precipitação atual;  $\bar{N}$  = Precipitação média da série histórica;  $\bar{M}$  = Média das dez maiores precipitações;  $\bar{X}$  = Média das dez menores precipitações da série.

A classificação de anos mais secos e de mais úmidos segue a metodologia utilizada por Freitas (2004) e Araújo (2009) que consideram o seguinte (Tabela 1):

Tabela 1. Classes de Intensidade do Índice de Anomalia de Chuva.

<b>Índice de Anomalia de Chuva (IAC)</b>	<b>Faixa do IAC</b>	<b>Classe de Intensidade</b>
		>4
	2 a 4	Muito úmido
	0 a 2	Úmido
	0 a -2	Seco
	-2 a -4	Muito Seco
	<-4	Extremamente Seco

Fonte: Freitas (2004) e Araújo (2009)

Para a análise do tempo de retorno (TR), é necessário determinar as precipitações máximas anuais, com diferentes durações de chuva. Foram considerados TR de 2, 5, 10, 20, 50, 100 e 1000 anos, e ajustada à distribuição de probabilidades de Gumbel, indicada para valores extremos (GUMBEL, 1958).

A distribuição de Gumbel, conhecida como distribuição do valor extremo, é muito utilizada em estudos de precipitação, pela sua adequação às séries de

precipitações máximas e pela simplicidade dos cálculos para estimação de seus parâmetros (MILLINGTON *et al.*, 2011). Beijo *et al.* (2003), Alves *et al.* (2013) e Hartmann *et al.* (2020) estimaram a precipitação máxima utilizando esse método.

A análise de Gumbel delimita valores máximos e mínimos (valores extremos) de uma amostra de variáveis aleatórias independentes, identicamente distribuídas, quando o tamanho da amostra aumenta. Para o ajuste desta distribuição de probabilidades, é necessário extrair a média ( $\mu$ ) e a variância ( $s^2$ ) do conjunto amostral de precipitações para calcular os parâmetros de escala ( $\vartheta$ ) (Eq. 6), e de forma ( $\beta$ ), (Eq. 7). Para qualquer probabilidade de ocorrência ( $P$ ) é possível calcular a Precipitação máxima ( $P_{max}$ ) utilizando a (Eq. 8).

$$\vartheta = \frac{\sqrt{6s^2}}{\pi} \quad \text{Eq. 6}$$

$$\beta = \mu - 0,5772\vartheta \quad \text{Eq. 7}$$

$$P_{max} = \beta - \vartheta \cdot \ln[-\ln(1 - P)] \quad \text{Eq. 8}$$

Em que:  $\mu$  = Média das precipitações diárias máximas anuais;  $s^2$  = Variância das precipitações diárias máximas anuais;  $\vartheta$  e  $\beta$  = Parâmetros do modelo de distribuição de probabilidades de Gumbel;  $P$  = probabilidade de ocorrência (1/TR);  $P_{max}$  = Precipitação Máxima.

#### 2.2.4 Ottocodificação e divisão de bacias hidrográficas


A extração de bacias hidrográficas foi realizada a partir dos dados *Shuttle Radar Topography Mission* (SRTM), um Modelo Digital de Elevação (MDE) disponibilizado pela *National Aeronautics and Space Administration* (NASA), em 2003, para a América do Sul, com resolução espacial de 90 m, refinado pelo Projeto TOPODATA, do Instituto Nacional de Pesquisas Espaciais (INPE), para 30 m.

Os dados foram obtidos do site do INPE (<http://www.dsr.inpe.br/topodata/>) e processados no *software ArcGIS 10.3*, com os seguintes procedimentos: filtragem (para remoção de informações discrepantes); direções de fluxo (JENSON e DOMINGUE, 1988); áreas acumuladas de drenagem, em que cada pixel tem valor correspondente à soma das áreas dos pixels que deságuam nele (JENSON e DOMINGUE, 1988; TARBOTON *et al.*, 1991); e extração automática da drenagem

de acordo a hierarquia (STRAHLER, 1952) (Figura 3), com base nas direções de fluxo e na grade de áreas acumuladas.

Segundo Strahler (1952), os canais sem tributários são designados de primeira ordem, os canais de segunda ordem são os que se originam da confluência de dois canais de primeira ordem e assim por diante. Na extração automática de drenagem, foram definidos patamares considerando-se desde as bacias de 4ª ordem até as grandes bacias hidrográficas de 8ª ordem, do estado do Rio Grande do Sul (Guaíba e Uruguai).

Figura 3 - Diagrama do sistema de ordenação de fluxo, baseado em Strahler (1952)



Fonte: Adaptação de Strahler, 1952.

A codificação das bacias foi baseada no método Pfafstetter (1989) com cada sub-bacia associada a uma superfície de drenagem denominada ottobacia. No sistema de ottocodificação original, para diferenciação entre rio principal e tributário se utiliza a respectiva área de drenagem como variável de decisão (SILVA *et al.*, 2008). A ottocodificação da ANA (2015) considera apenas duas grandes áreas hidrográficas no RS. Entretanto, a metodologia proposta nesse estudo considerou 3 grandes bacias hidrográficas: rio Uruguai, lago Guaíba e Litorânea. A bacia Litorânea apresenta significativas diferenças com relação as demais, como apresentar baixa amplitude altimétrica e desaguar diretamente no Oceano Atlântico, no território do RS.

O processo de codificação e divisão das bacias foi realizado a partir das bacias de maior ordem. O primeiro dígito do código de uma bacia hidrográfica qualquer se refere à bacia de ordem maior a qual ela pertence. Após classificar as bacias de maior ordem, passa-se à divisão de bacias da ordem imediatamente inferior, sendo atribuído, assim, um segundo dígito ao código. A partir da codificação das bacias de sexta ordem foram inseridos dois dígitos, pois algumas bacias superiores resultaram em mais de 10 sub-bacias. A codificação segue sucessivamente até a menor ordem desejada.

Nesse estudo, as bacias foram divididas da 8ª ordem até a 4ª ordem, resultando em 1.052 sub-bacias de 4ª ordem, codificadas com 8 dígitos numéricos. Para exemplificar a codificação, utilizamos uma bacia de quarta ordem, com o seguinte código sequencial: 14040412. A partir desse código, é possível afirmar que essa sub-bacia pertence a bacia 1 (oitava ordem), bacia 14 (sétima ordem), bacia 1404 (sexta ordem), bacia 140404 (quinta ordem) e, por fim, 14040412 (quarta ordem).

#### 2.2.5 Criação do Banco de Dados

O Banco de Dados gerado consiste em um conjunto de arquivos vetoriais, tabelas e matrizes, estruturadas e armazenadas de modo a permitir consultas a séries temporais e índices de precipitação por unidades territoriais do RS. Para acesso às informações do Banco de Dados, foi criado o sítio eletrônico: <https://sites.google.com/view/bdchuvars>.

Os arquivos vetoriais disponíveis no banco se referem: i) a grade de interpolação, na geometria de pontos, com 627 células regularmente distribuídas sobre o território do RS; ii) aos polígonos das bacias hidrográficas ottocodificadas, com 1053 unidades em cinco diferentes ordens hierárquicas de drenagem; iii) aos limites municipais, na forma de polígonos, obtidos do Instituto Brasileiro de Geografia e Estatísticas (IBGE, 2019), em formato *shapefile*, que permite sua abertura em Sistemas de Informações Geográficas.

A partir de operações espaciais, como junção de tabelas por localização e estatísticas zonais, foram extraídas e organizadas tabelas e planilhas com extensão

“.xlsx”, para consultas nos *softwares* Microsoft Excel e MATLAB. As seguintes tabelas estão disponíveis no Banco de Dados:

i) Tabela de precipitação diária. Planilha com a precipitação diária em cada célula da grade de interpolação. Cada linha corresponde a um dia do período entre 01/01/1987 e 31/12/2016, e cada coluna uma célula localizada no RS;

ii) Tabela de localização das células. Planilha com o código identificador de cada célula da grade de interpolação, contendo latitude, longitude, código da bacia na qual a célula está inserida e o código do município no qual está inserido;

iii) Tabela de bacias e células mais próximas. Planilha com a indicação da célula mais próxima, e se refere apenas às bacias de 4ª ordem que não possuem nenhuma célula no seu interior;

iv) Tabela de municípios e células mais próximas. Planilha com a indicação da célula mais próxima de municípios com pequena área territorial, e que não possuem nenhuma célula no seu interior.

Essas planilhas foram importadas para o MATLAB, e foi criado um arquivo com extensão “.mat”, resultando em um Banco de Dados organizado em matrizes para consulta a partir de um *script*, desenvolvido no editor de códigos do próprio software. O usuário necessita apenas indicar: a data inicial e final da consulta; o tipo de recorte espacial (por bacia, por município ou coordenadas geográficas); e o código identificador da bacia/município ou coordenadas geográficas do ponto de interesse.

A partir da consulta, o algoritmo faz os seguintes procedimentos: identifica as células da grade de interpolação associadas ao recorte espacial selecionado pelo usuário; realiza o recorte temporal dos dados considerando as datas selecionadas; e gera as seguintes saídas para a área de interesse: i) séries temporais de precipitação média diária, mensal e anual; ii) séries temporais de precipitação máxima diária e anual; iii) séries temporais mensais e anuais de número de dias com precipitação; iv) série temporal com desvio de precipitação mensal em relação à normal de precipitação no período; v) normais climatológicas de precipitação acumulada mensal e número de dias com chuva; vi) precipitação acumulada anual média histórica; vii) precipitação máxima diária por TR. As saídas são salvas em formato “.xlsx”, permitindo o acesso a planilhas eletrônicas, como o Microsoft Excel.

### 3 Resultados

Os resultados foram organizados em 3 partes: a interpolação e os índices de precipitação resultantes, com base na malha regular; a delimitação e a codificação de bacias; e o Banco de Dados. Inicialmente, são apresentados os parâmetros utilizados para a interpolação da precipitação, depois os índices de precipitação, com mapas e gráficos das precipitações mensais e anuais, do Tempo de Retorno (TR) e do Índice de Anomalia de Chuvas (IAC). A última parte dos resultados refere-se ao acesso e estrutura do Banco de Dados.

#### 3.1 Interpolação

Para analisar as 60 combinações de variáveis com o método IPD (Quadro 1), foram considerados diferentes expoentes, raios de abrangência, número máximo de estações por quadrante e número mínimo de quadrantes com estações. A validação cruzada foi realizada em 35 estações pluviométricas distribuídas no estado (Figura 2).

De modo geral, o Erro Médio Absoluto (EMA) da interpolação da chuva diária aumenta à medida que a potência utilizada é maior, ainda que esse não tenha sido o parâmetro de maior sensibilidade. O EMA das combinações com potência 1 (inverso da distância simples) foi de 2,41 mm/dia, enquanto ao usar a potência 3 (inverso da distância ao cubo) foi de 2,46 mm/dia.


O parâmetro de maior sensibilidade é o raio de busca para as estações vizinhas utilizadas na interpolação. De modo geral, quanto menor o raio de busca, menor é o EMA, variando de 1,74 mm/dia para o raio de  $0,3^\circ$  até 3,11 mm/dia para o raio de  $1^\circ$ . Porém, ao usar um raio mais rigoroso e restritivo de busca, a interpolação acaba não sendo realizada por falta de estações em muitos locais e datas, inviabilizando a construção do banco de dados espacial.

A escolha entre usar até 2 ou 3 estações por quadrante não resultou em diferença significativa de erro no processo de interpolação. Aceitando até 3 estações pluviométricas vizinhas por quadrante, o EMA reduziu de 2,43 mm/dia para 2,42 mm/dia. Por sua vez, ao aceitar a interpolação em locais sem estações pluviométricas em um dos quadrantes, incrementa-se o erro no processo de

interpolação espacial. O EMA considerando pelo menos 1 estação em cada um dos quadrantes foi de 2,25 mm/dia, enquanto ao flexibilizar e aceitar um quadrante sem estações vizinhas o EMA foi de 2,61 mm/dia.

Considerando esses resultados e a perspectiva de interpolar a chuva diária para uma grade regular no estado do RS, foi escolhida a seguinte combinação de parâmetros: potência = 1; raio de abrangência = 0,6°; número máximo de estações por quadrante = 3; número mínimo de quadrantes com estações = 4. Essa combinação resultou em EMA de 2,39 mm/dia. A Figura 4 mostra o gráfico de probabilidade acumulada do EMA ao interpolar a precipitação diária, considerando as 35 estações usadas no processo de validação cruzada.

Figura 4 - Gráfico da probabilidade acumulada do erro médio absoluto no processo de interpolação diária para 35 estações pluviométricas do RS usadas na validação cruzada.



Fonte: Elaboração própria.

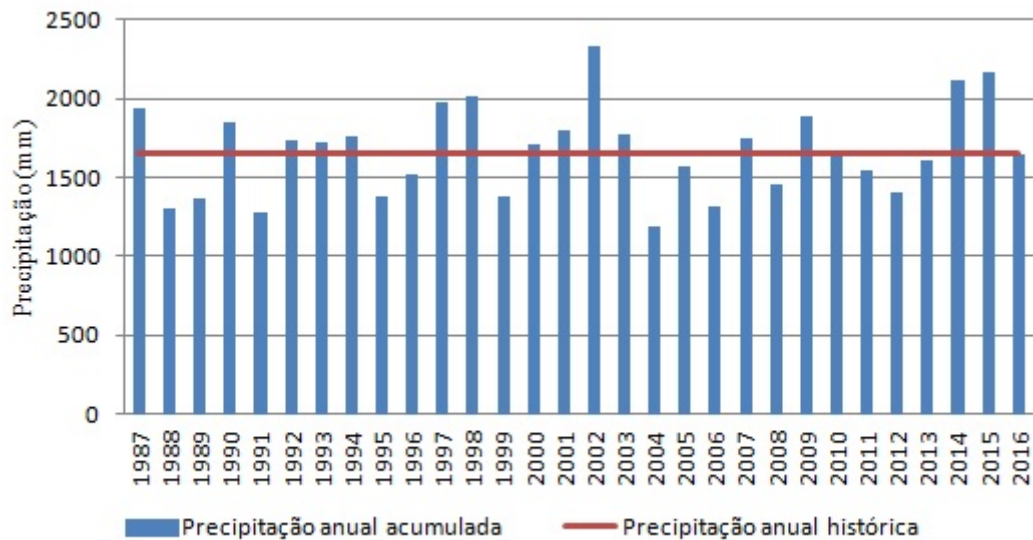
### 3.2 Índices de precipitação

Com base na interpolação dos dados de precipitação entre 1987 e 2016, foram calculados dados relativos à precipitação para o estado do Rio Grande do Sul, considerando a interpolação das 627 células da malha regular. O gráfico da precipitação anual acumulada e da precipitação anual média (Figura 5) mostra que a



média do total acumulado anual foi de 1656 mm, que o menor valor do total acumulado foi de 1188 mm em 1991, e que o maior valor do foi de 2328 mm em 2002.

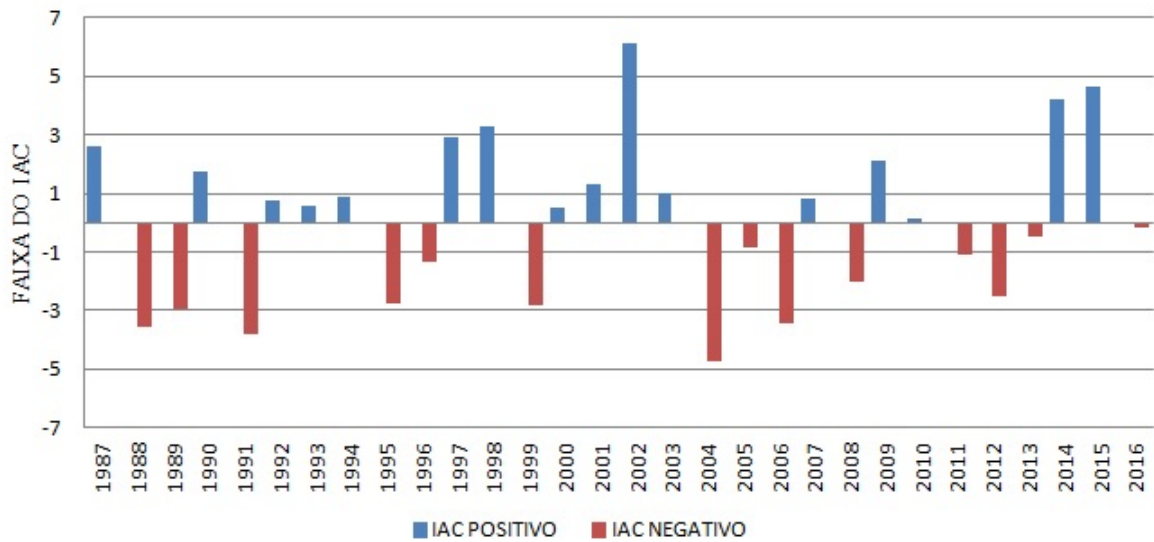
Figura 5. Gráfico da precipitação anual acumulada e da precipitação anual média, entre 1987 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

O Índice de Anomalia de Chuvas (IAC), quando aplicado para a variação anual, mostra alternância entre valores positivos e negativos (Figura 6). Foram considerados como muito úmidos, os anos de 2002, com o maior IAC (6,1) do período analisado, e os anos de 2014 e 2015 com IAC de 4,2 e 4,6, respectivamente. Foram considerados como precipitação abaixo da média os anos de 2004, extremamente seco com IAC (-4,7) e os anos de 1988, 1991 e 2006 com IAC de -3,5, -3,8 e -3,44, respectivamente.

Figura 6. Índice de anomalia de chuvas (IAC), entre 1987 e 2016, estado do Rio Grande do Sul.




Fonte: Elaboração própria.

Quando a análise do IAC se aplica para a variação mensal, o gráfico da Figura 7 auxilia na compreensão dos anos mais e menos chuvosos. O mês de novembro de 2009 apresenta um IAC positivo (10,9), o maior do período analisado. A precipitação em novembro de 2009 ajuda a explicar o acumulado anual e o alto valor de IAC daquele ano. Outros meses considerados extremamente úmidos foram junho de 2014, outubro de 1997 e julho de 1987 (7,6; 7,4 e 7,3, respectivamente).

Em relação ao IAC negativo, em 2013, os meses de julho e dezembro foram extremamente secos (-6,8 e -6,9, respectivamente), assim como junho de 2016 e março de 1997 (-6,9 e -6,8).

Figura 7. Índice de Anomalia de Chuvas Mensal (IAC), entre 1987 e 2016, estado do Rio Grande do Sul

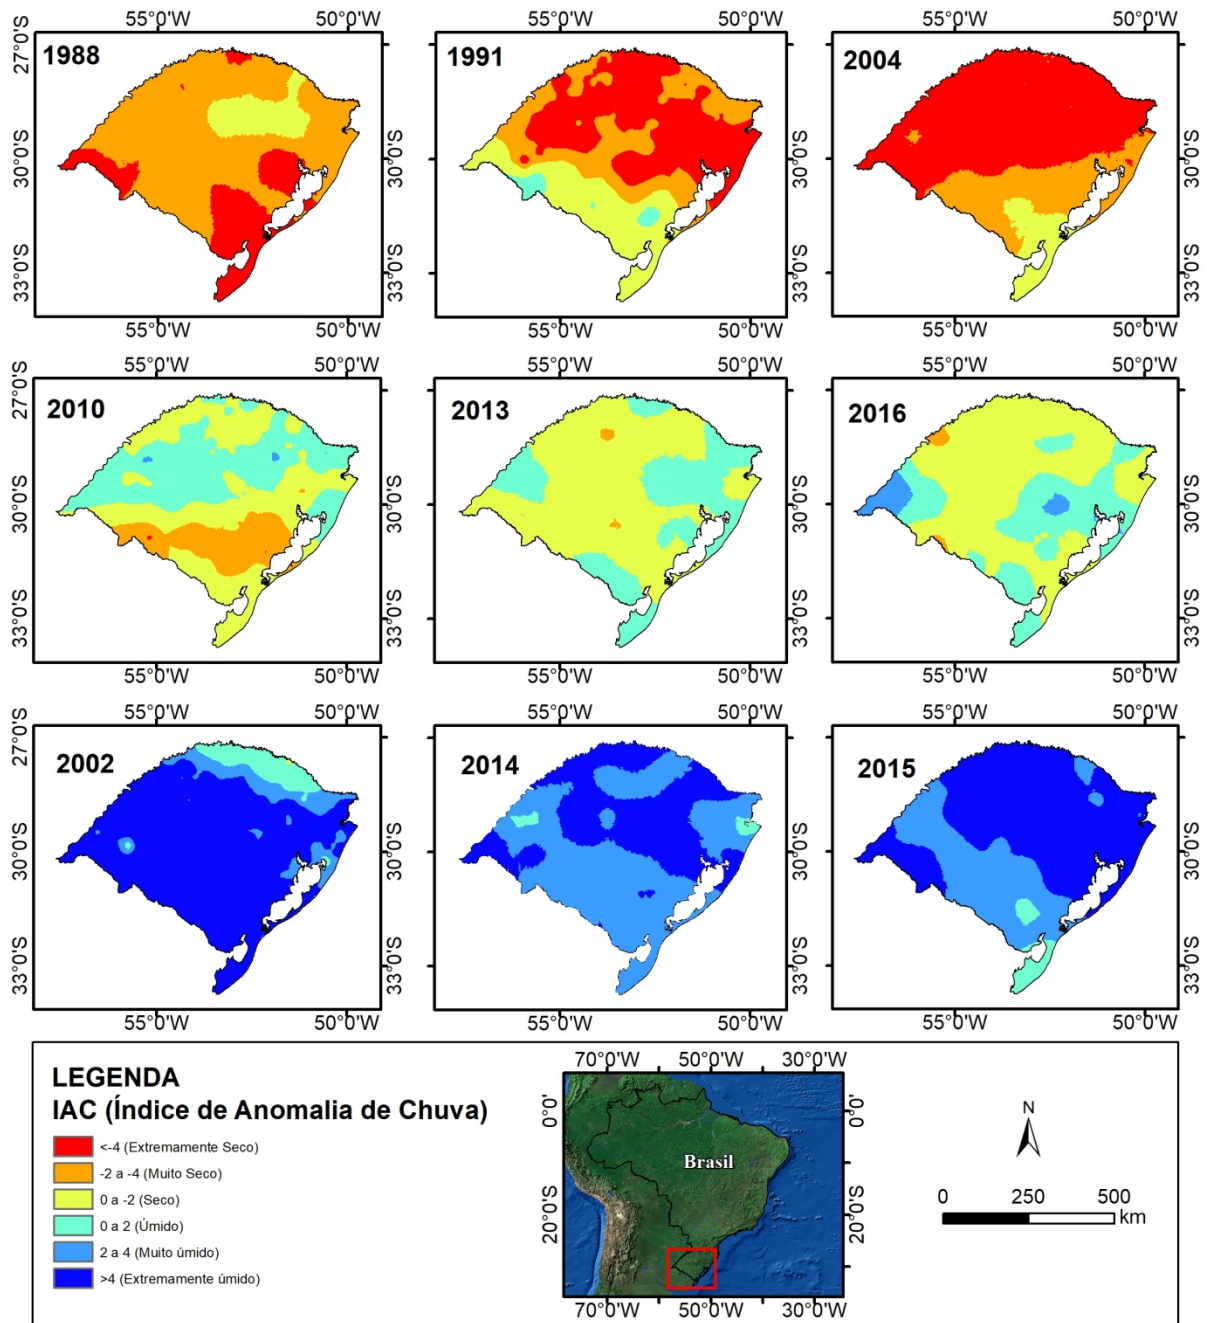


Fonte: Elaboração própria.

Para entender a dinâmica espacial do IAC, a Figura 8 apresenta os três anos mais secos (1988, 1991, 2004), de acordo com a média das células, e os três anos mais chuvosos (2002, 2014, 2015). Os anos de 2010, 2013 e 2016 apresentam valores de IAC mais próximos de zero, ou seja, mais próximos da média para o estado do Rio Grande do Sul.

Entre os anos mais secos, há regiões que se destacam como extremamente secas ( $IAC < -4$ ) e muito secas ( $-2$  a  $-4$ ). Na média, 1991 foi um dos anos mais secos do período analisado, ainda assim, as regiões sul e sudoeste apresentaram áreas mais úmidas do que o restante do estado. Entre os anos mais chuvosos, a variação vai de úmido ( $0$  a  $2$ ) a extremamente úmido ( $>4$ ), com destaque para o ano de 2002, quando praticamente todo o estado foi considerado extremamente úmido ( $>4$ ).

Figura 8. Espacialização do IAC dos três anos mais secos (1988, 1991 e 2004), dos três anos com IAC mais próximos de zero (2010, 2013 e 2016) e dos três anos mais chuvosos (2002, 2014 e 2015), entre 1987 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

Na espacialização do TR, aplicado para as precipitações diárias, Tabela 2, os maiores valores ocorrem nas regiões noroeste e norte do estado, que se destacam devido à maior possibilidade de ocorrências de precipitações diárias acima da média, Figura 9.

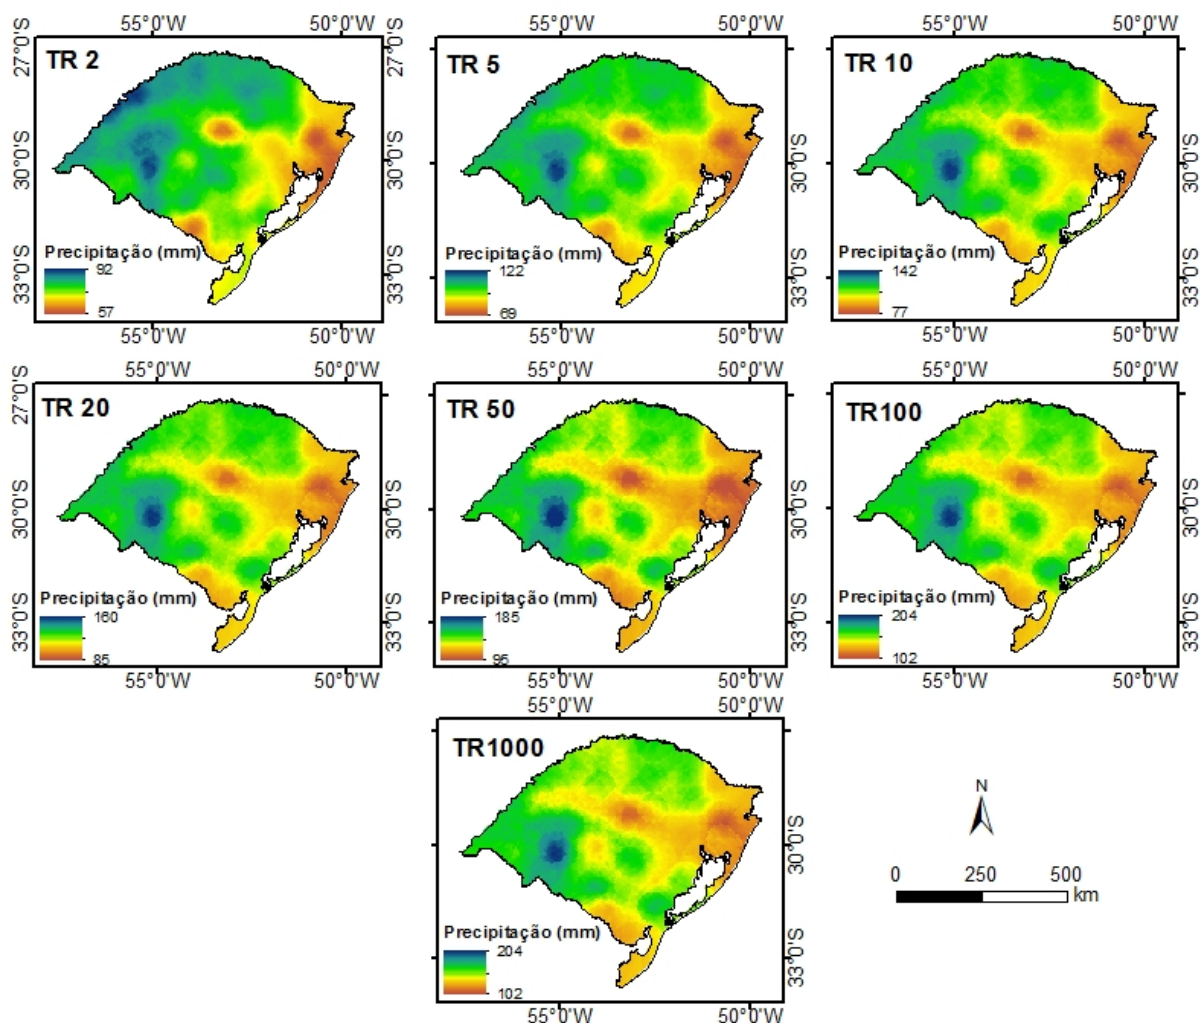
Na região oeste, há um ponto que apresenta uma variabilidade discrepante em relação às células do entorno. Esse fenômeno faz com que essa região apresente os maiores valores de Tempo de Retorno considerando a área do estado. Com essa discrepância, no processo de preenchimento de falhas, uma das estações apresentou valores superiores às demais, destacando-se também nas células daquela região, no processo de interpolação espacial.

Tabela 2 - Valores de Precipitação para diferentes Tempos de Retorno, estado do Rio Grande do Sul.

TR (anos)	Precipitação (mm)
2	77,7
5	96,8
10	109,4
20	121,5
50	137,2
100	149,0
1000	187,8

Fonte: Elaboração própria.

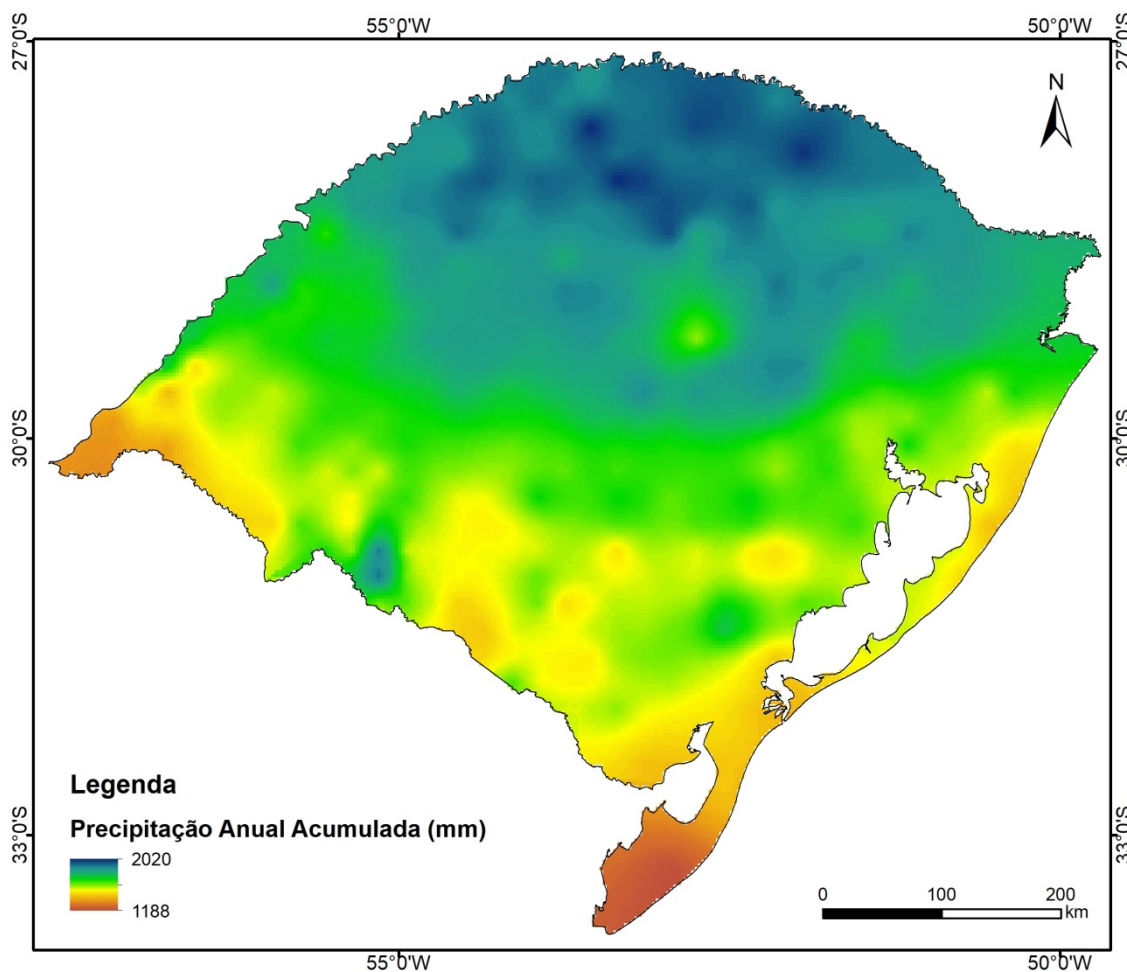
Figura 9 - Espacialização dos Tempos de Retorno (2, 5, 10, 20, 50, 100 e 1000 anos), estado do Rio Grande do Sul.



Fonte: Elaboração própria.

A distribuição anual da precipitação demonstra diferenças entre as regiões sul e norte, para o período entre 1987 e 2016. O extremo sul do estado apresenta os índices mais baixos de precipitação, com uma média de 1188 mm, enquanto a região norte apresenta os maiores índices do estado, com média de 2020 mm (Figura 10).

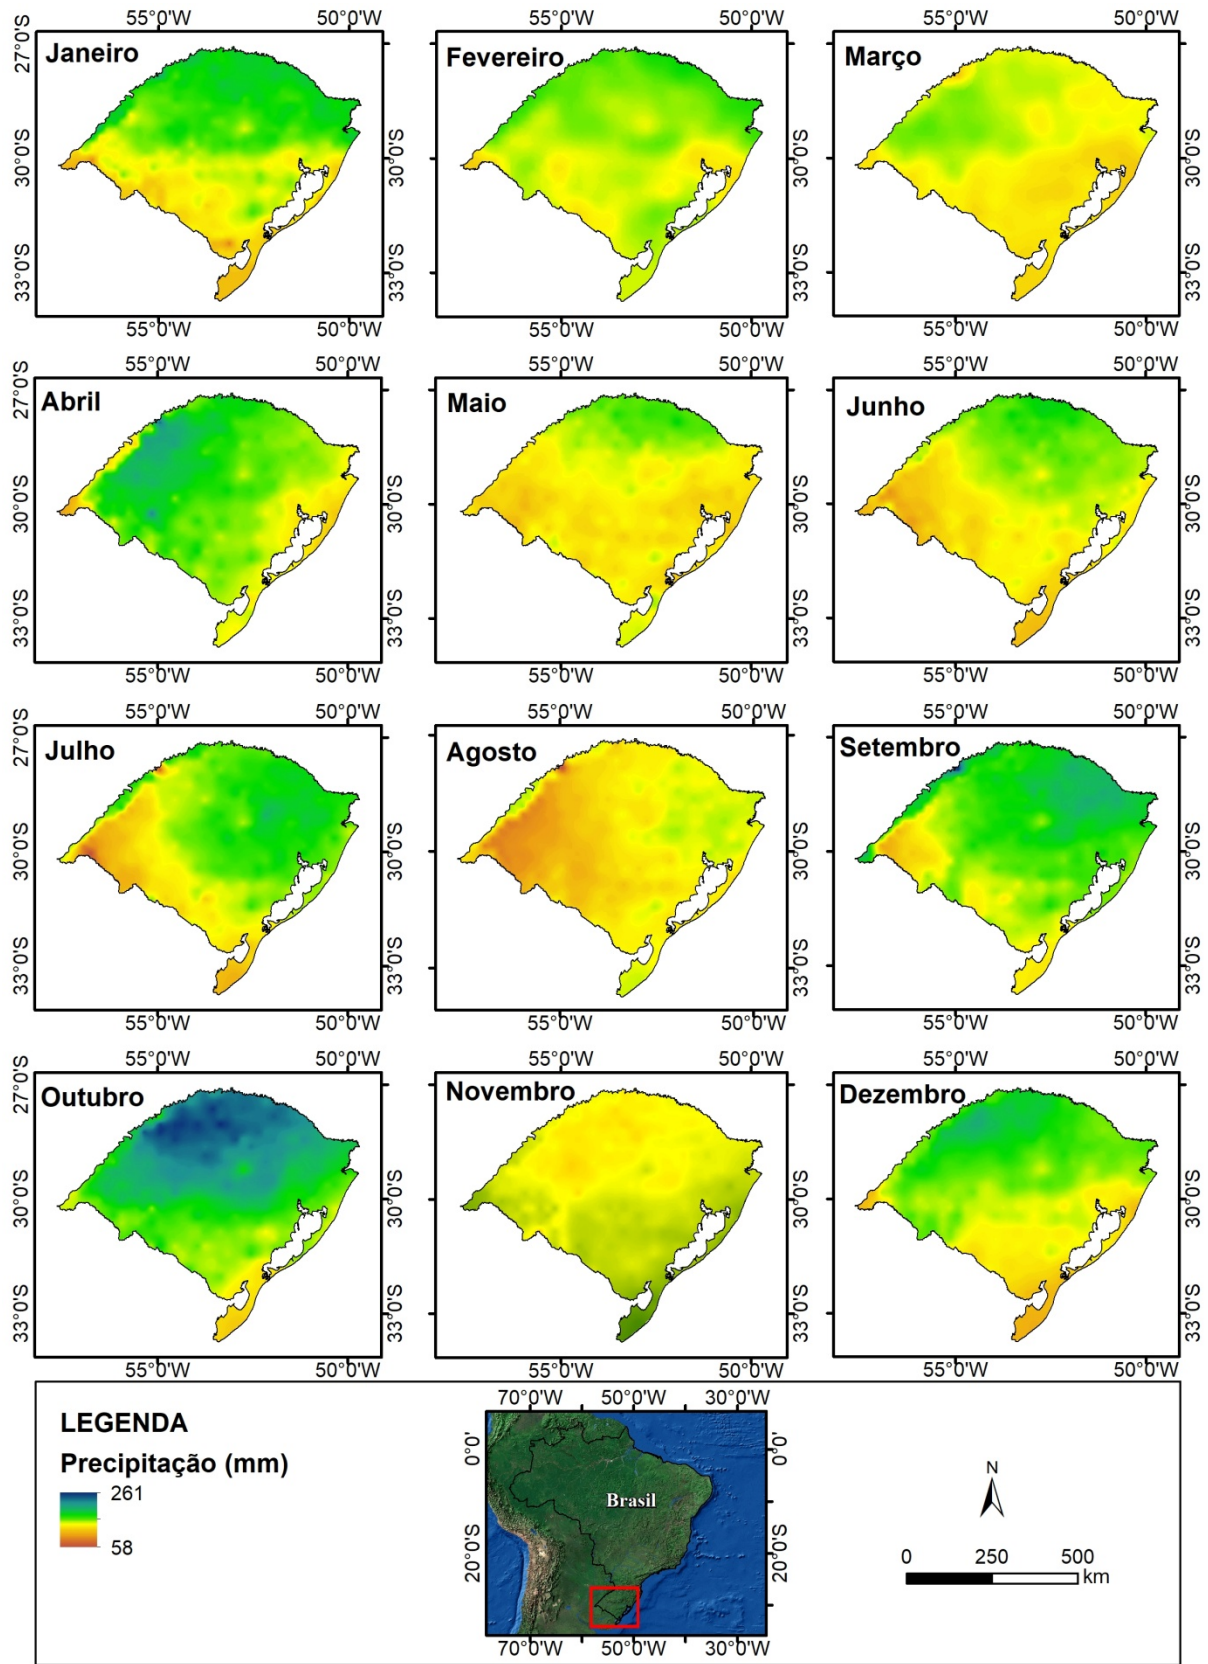
Figura 10 - Espacialização da precipitação anual acumulada, entre 1987 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

Em relação à distribuição mensal das precipitações (Figura 11), destacam-se como os meses mais chuvosos setembro e outubro, e como meses menos chuvosos maio e agosto. A distribuição espacial também se mostra relevante, pois as maiores médias ocorrem na metade norte, enquanto na metade sul ocorrem as menores médias, com exceção do mês de novembro.

Figura 11 - Média mensal das precipitações, entre 1987 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.



### 3.2 Delimitações e codificação das bacias hidrográficas

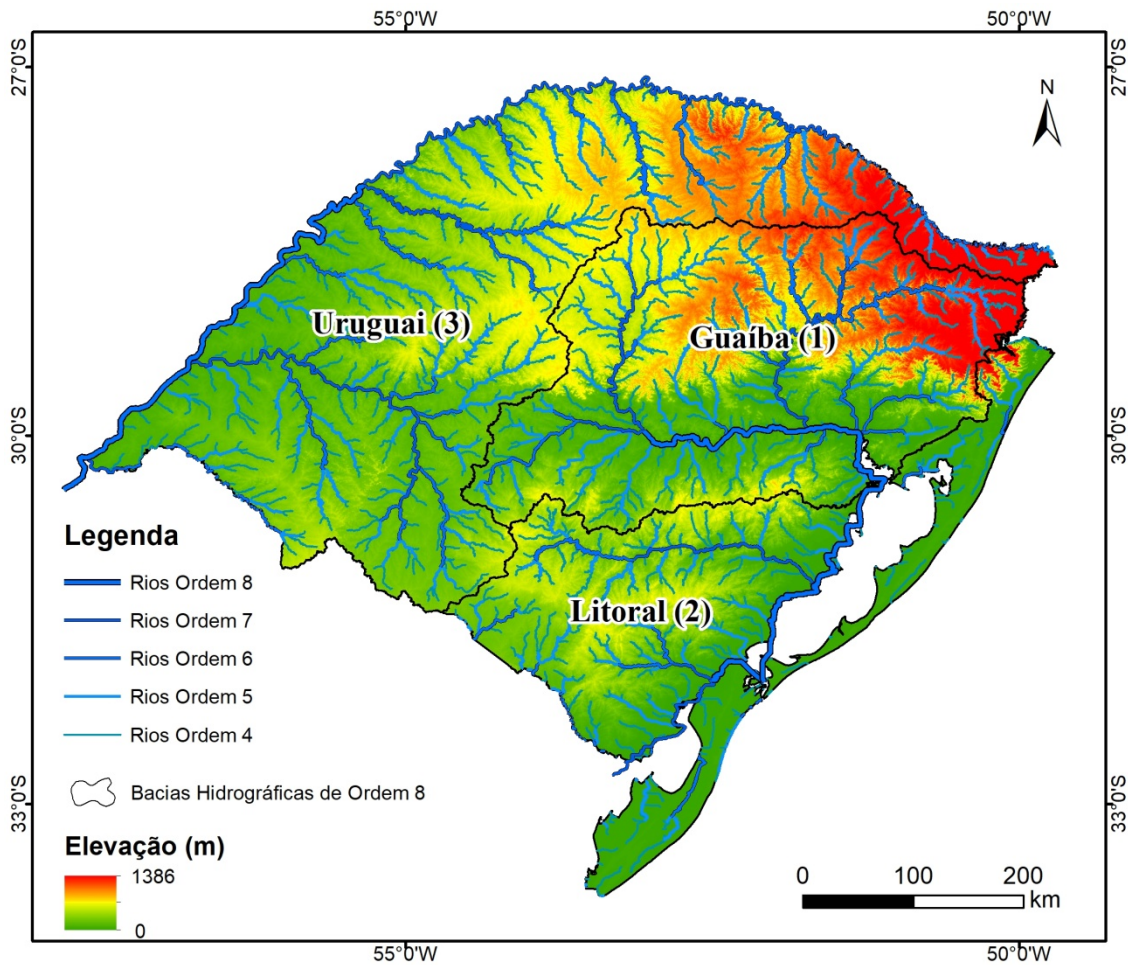
As bacias Guaíba, Uruguai e Litoral são consideradas de oitava ordem (Figura 12). A bacia do Litoral foi definida, mesmo que o MDE em áreas de baixa amplitude altimétrica apresente limitação para interpolação em áreas muito planas e para definição de sub-bacias (BRUBACHER *et al.*, 2012). A Tabela 3 mostra a quantidade de sub-bacias, de cada ordem, dentro das 3 grandes bacias hidrográficas.

Tabela 3 - Quantidade de sub-bacias delimitadas pelo método de Strahler.

BH 8ª Ordem	7ª Ordem	6ª Ordem	5ª Ordem	4ª Ordem
Guaíba	4	19	240	351
Litoral	5	8	48	191
Uruguai	5	26	115	511
Total	14	53	403	1053

Fonte: Elaboração própria.

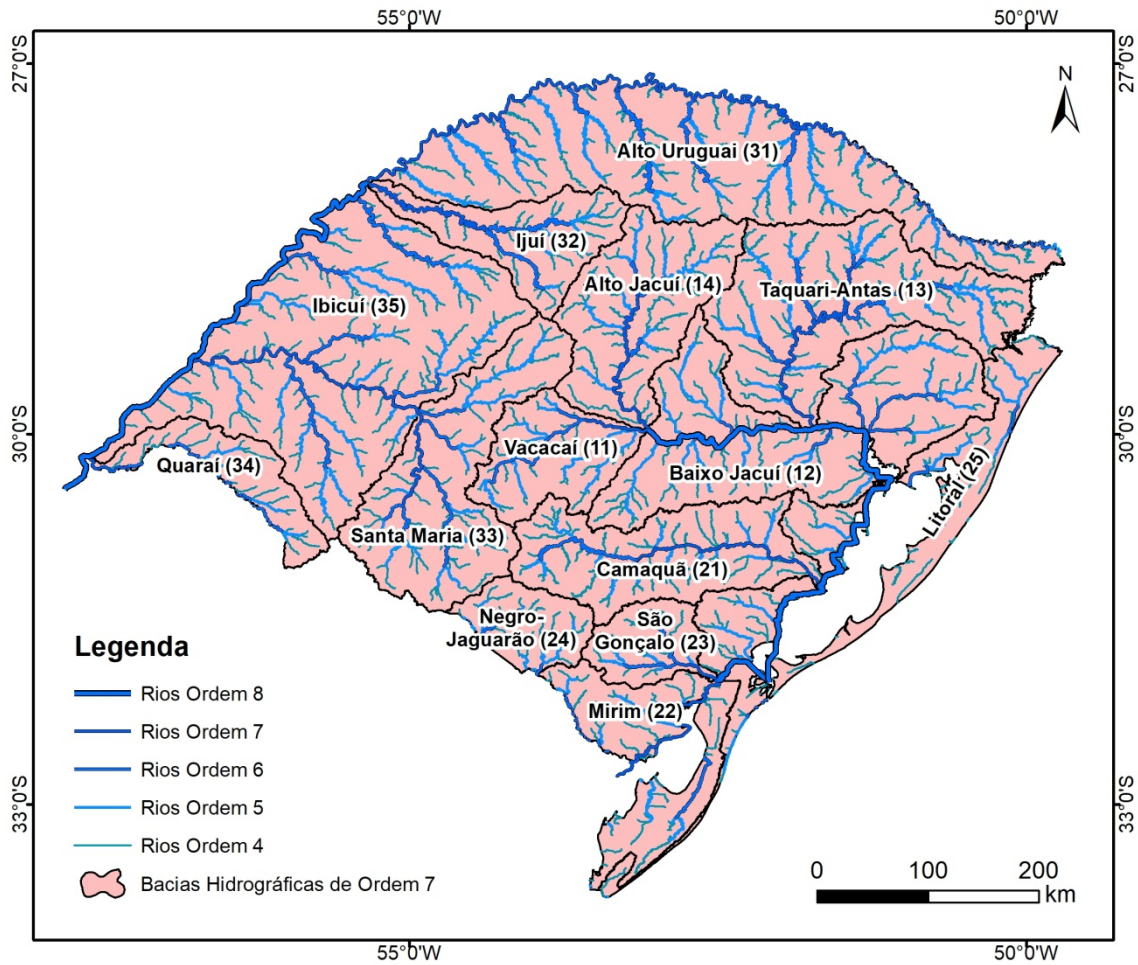
Figura 12 - Regiões hidrográficas, bacias de oitava ordem, e Modelo Altimétrico de Elevação, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

Com a delimitação das bacias de sétima ordem, foram delimitadas 14 bacias: 4 pertencentes à bacia hidrográfica do Guaíba, 5 à bacia hidrográfica do Litoral e 5 à bacia hidrográfica do rio Uruguai (Figura 13).


Figura 13 - Bacias Hidrográficas de 7ª Ordem, Rio Grande do Sul.



Fonte: Elaboração própria.

Com a delimitação das bacias de sexta ordem, optou-se por nomear as bacias de acordo com a hidrografia oficial do Rio Grande do Sul. Alguns dos principais rios do estado são de sexta ordem e, portanto, podem ser importantes para trabalhos futuros. Ao todo, foram delimitadas 53 sub-bacias (Figura 14). Devido às dificuldades relacionadas ao MNT para delimitação das sub-bacias litorâneas, optou-se por manter parte da planície costeira como uma única sub-bacia.

Figura 14 - Bacias Hidrográficas de 6ª Ordem, estado do Rio Grande do Sul.

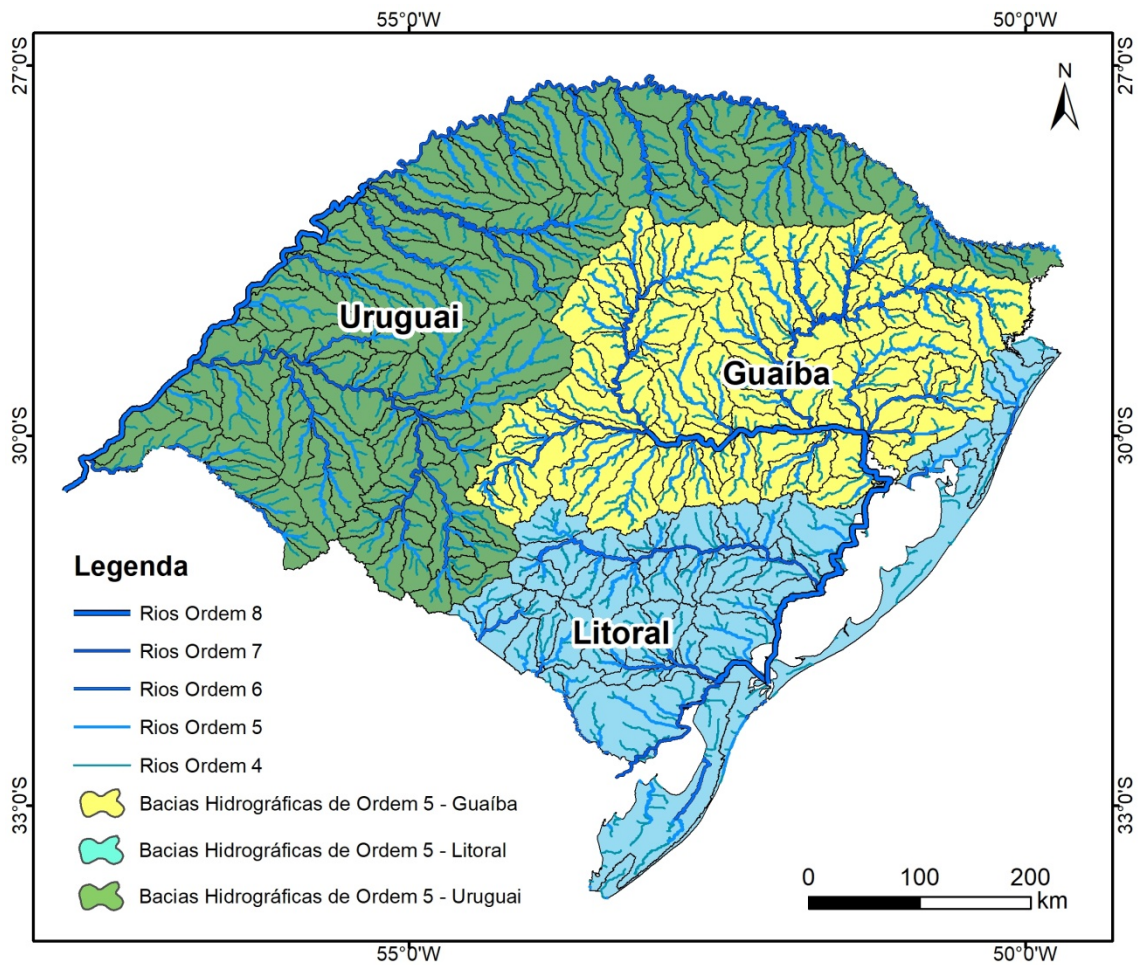


<b>Legenda</b>			
	Rios Ordem 8	1207, Baixo Jacuí	2302, Arroio Basilio
	Rios Ordem 7	1301, Turvo	2401, Negro
	Rios Ordem 6	1302, Telha	2402, Jaguarão
	Rios Ordem 5	1303, Forqueta	2501, Litoral I
	Rios Ordem 4	1304, Carreiro	2502, Litoral II
	BH Ordem 6	1305, Alto Antas	<b>RH Uruguai (3)</b>
<b>RH Guaíba (1)</b>		1306, Taquari	3203, Ijuí
1101, Alto Vacacaí	1401, Alto Jacuí I	1402, Alto Jacuí II	3301, Alto Ibicuí
1102, Arroio do Arenal	1403, Jacuizinho	1404, Alto Jacuí	3302, Cacequi
1103, Vacacaí	<b>RH Litoral (2)</b>		3303, Alto Santa Maria I
1201, Pardo	2101, Alto Camaquã	2102, Alto Camaquã II	3304, Alto Santa Maria III
1202, Caí	2103, Baixo Camaquã	2201, Mirim	3305, Alto Santa Maria II
1203, Sinos	2301, Piratini	2302, Arroio Iruí	3306, Baixo Santa Maria
1204, Gravataí	3101, Várzea	3102, Guarita	3401, Quaraí
1205, Arroio dos Ratos	3103, Apuê	3104, Buricá	3501, Piratini
1206, Arroio Iruí	3105, Dourado	3106, Médio Uruguai 3	3502, Icamaquã
	3107, Médio Uruguai 2	3108, Médio Uruguai 1	3503, Itu
	3109, Alto Uruguai	3110, Passo Fundo	3504, Jaguari
	3201, Alto Ijuí	3202, Ijuizinho	3505, Ibirapuitã
			3506, Piratini
			3507, Baixo Uruguai
			3508, Médio Uruguai 4

Fonte: Elaboração própria.

Em relação às sub-bacias de quinta ordem, foram delimitadas 240 sub-bacias. Dessas, 77 fazem parte da bacia hidrográfica do Lago Guaíba; 48 da bacia hidrográfica do Litoral e 115 da bacia hidrográfica do rio Uruguai (Figura 15).

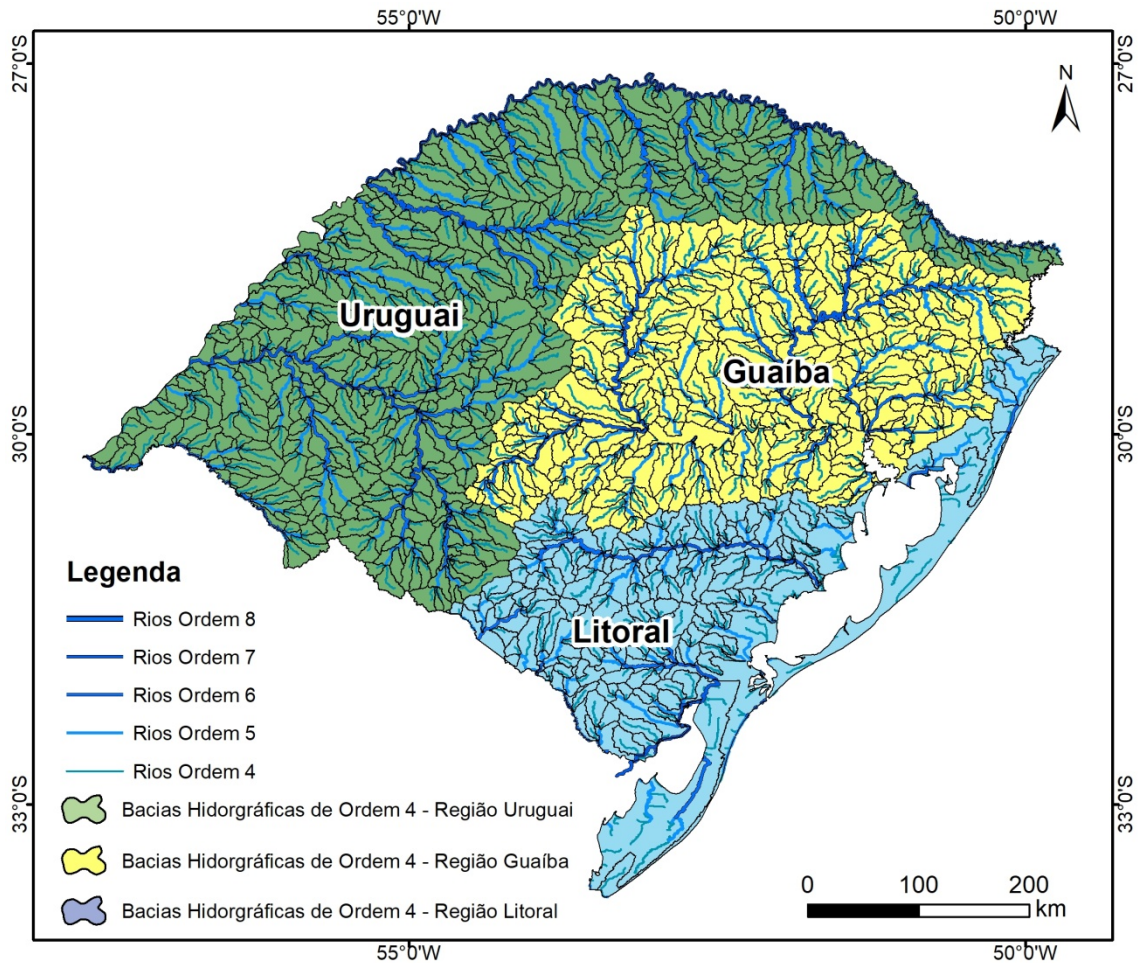
Figura 15 - Bacias Hidrográficas de 5ª Ordem, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

As sub-bacias de quarta ordem apresentam um grau maior de detalhamento. Ao todo, foram delimitadas 1053 sub-bacias (Figura 16). Esse nível de detalhamento permite o acesso, no Banco de Dados, a bacias inferiores a 50 km<sup>2</sup>. Até mesmo bacias relativas a pequenos afluentes estão contemplados, cada um deles com uma célula da malha regular relacionada com uma série histórica de 30 anos.

Figura 16 - Bacias Hidrográficas de 4ª Ordem, estado do Rio Grande do Sul.

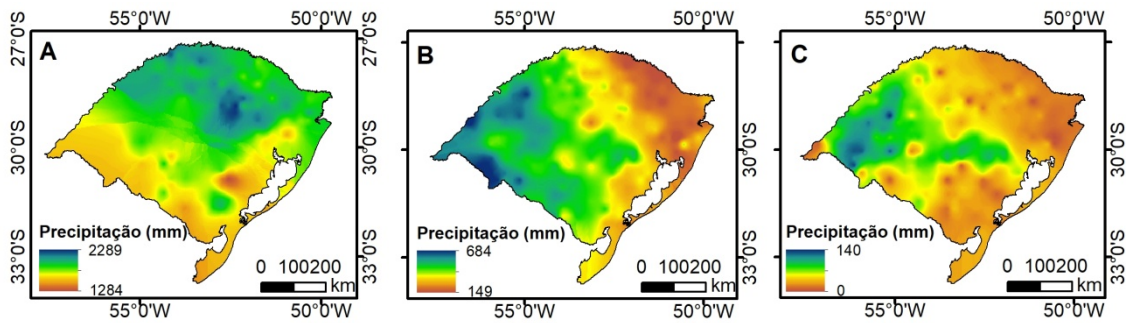


Fonte: Elaboração própria.

### 3.3 Banco de dados

A estrutura do Banco de Dados permite extrair a precipitação diária, mensal e anual para o estado do Rio Grande do Sul. A Figura 17 mostra um exemplo anual (2009), mensal (Nov/2009) e diário (29/11/2009). Nessa data ocorreu precipitação acima da média no estado, concentrada, no entanto, na região noroeste (Figura 17C) (Sausen, 2011). Em algumas células a precipitação chegou a 142,9 mm em um dia, refletindo na precipitação mensal (Figura 17B), com mais de 600 mm em alguns pontos e na precipitação acumulada anual (Figura 17C), com 2289 mm. Esse exemplo de consulta foi realizado considerando todo o estado, mas poderia ter sido aplicada a um município ou a uma das sub-bacias apenas.


Figura 17 - Espacialização da precipitação: (A) do ano de 2009; (B) do mês de novembro de 2009; (C) do dia 29 de novembro de 2009, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

Ao utilizar o *script* para o MATLAB, o usuário pode acessar os dados médios de uma série de índices por município, por bacia ou por coordenada geográfica. O Gráfico da Figura 18 demonstra a precipitação acumulada para a bacia do rio dos Sinos, de ordem 6 (Código: 1203), localizada na porção leste do estado do Rio Grande do Sul, para o período de 1987-2016, extraídos por meio do MATLAB.


Figura 18 - Precipitação Anual Média, bacia hidrográfica do rio dos Sinos.



Fonte: Elaboração própria.

A segunda forma de acesso ao Banco de Dados é a extração dos dados por município. O gráfico da Figura 19 demonstra o número de dias de chuva (variável possível de ser extraída por meio do Banco de Dados) no período entre 1987 e 2016, para o município de Porto Alegre.

Figura 19 - Número de dias de precipitação, entre 1987 e 2016, município de Porto Alegre.




Fonte: Elaboração própria.

A terceira forma de acesso ao Banco de Dados é por Coordenada Geográfica. Para exemplificar, inserimos a Coordenada correspondente ao município de Santa Maria (Lat: 29° 41' 29", Long: 53° 48' 3"), localizado na região central do estado. O gráfico da Figura 20 mostra a média de precipitação e a média de dias de precipitação mensal, entre 1987 e 2016.



Figura 20 - Média mensal de precipitação e média mensal do número de dias de precipitação por coordenada geográfica, entre 1987 e 2016, município de Santa Maria.



Fonte: Elaboração própria.

#### 4 Discussão

Em relação ao processo de interpolação, foram testadas 60 combinações de parâmetros, envolvendo a potência, o raio de abrangência e restrições em relação aos quadrantes. Fica evidente pelos resultados apresentados que o processo de interpolação espacial foi mais sensível ao raio de abrangência e à exigência de pelo menos uma estação em cada um dos quadrantes.

Ampliar o raio de busca, aceitando interpolar a chuva diária em locais com estações vizinhas cada vez mais distantes, viabiliza o processo de interpolação em áreas remotas, com pouca disponibilidade espacial de estações pluviométricas. Porém, isso incrementa consideravelmente os erros no processo. Mas esse resultado está de acordo com o esperado, uma vez que a variabilidade espacial da precipitação em um dia qualquer costuma ser alta, e buscar dados de estações muito distante introduz erros e incertezas no processo (Bega *et al.*, 2005; Caldana *et al.*, 2019; Silva *et al.*; 2019).

Entretanto, restringir demais o raio de busca limita o processo de interpolação apenas a locais com muitas estações vizinhas e próximas, e inviabiliza a construção do banco de dados proposto. Assim, a escolha de um raio intermediário ( $0,6^\circ$ ) para a interpolação espacial e elaboração do banco de dados espacial se deve ao compromisso de reduzir os erros da interpolação, mas ao mesmo tempo garantir que a grade resultante tenha os valores interpolados de precipitação de forma contínua, espacial e temporal.

Com a combinação escolhida, o EMA foi de 2,39 mm/dia nas 35 estações de validação cruzada. O EMQ foi de 6,82 mm/dia e o erro, não ultrapassado em 90% das estações, foi de aproximadamente 4 mm/dia. Ao analisar a interpolação diária em duas datas distintas, com base nesse método, Lucas *et al.* (2013) calcularam um EMQ de 5,7 e 7,6, respectivamente; Silva *et al.* (2011), interpolaram dados de precipitação com EMP (Erro Médio Percentual) variando de 7,9 a 14,6%.; e Cecílio e Pruski (2003), obtiveram um EMP que variou de 10,5 a 12,93%.

Segundo Ly *et al.* (2013) o sucesso da interpolação espacial varia de acordo com o tipo de modelo escolhido, seu modo de gestão geográfica e a resolução utilizada. A qualidade de um resultado é determinada pela qualidade do espaço contínuo de precipitação, que resulta do método de interpolação utilizado. Chen *et al.* (2017) alertam que o uso de diferentes esquemas de interpolação numa mesma bacia pode gerar diferenças significativas e desvios da distribuição espacial real da chuva.

O método de interpolação por Inverso da Potência da Distância (IPD) é uma alternativa viável para interpolar precipitação diária em bacias hidrográficas. Segundo Farias *et al.* (2017) o método IPD apresenta desempenho superior aos demais métodos, com menores valores de erro médio, menores diferenças individuais entre os valores observados e estimados, além de um menor erro médio em relação a superestimação e subestimação dos valores estimados.

Ao aplicar o método IPD é possível definir o valor do expoente. Esse estudo testou 6 expoentes diferentes, buscando avaliar qual apresentava o menor erro em relação aos dados de campo. O expoente que apresentou os menores EMA e EMQ foi com a potência "1". Esse valor da potência pode variar, na busca de melhor ajuste à superfície desejada. Além disso, esse método é mais simples que outros métodos (Dirks *et al.*, 1998; Xavier *et al.*, 2016).

A utilização desse método permitiu um melhor ajuste dos valores armazenados no banco de dados com as séries pluviométricas utilizadas. Desse modo, a atribuição de dados à malha regular supre as necessidades de pesquisadores ao utilizar esses dados em sub-bacias ou pequenas cidades.

A espacialização da precipitação anual acumulada, no período entre 1987 e 2016, se mostrou compatível com o proposto por Rossato (2011). A autora utilizou o método *Krigagem* para regionalizar a precipitação. A variação espacial da precipitação acumulada anual varia entre 1200 e 1500 mm anuais, no centro-sul do estado, e entre 1700 e 1900 mm na região norte. Segundo a autora, essa diferença ocorre devido à influência conjugada dos sistemas atmosféricos, formas de relevo, altitude e às correntes marítimas.

Kanh e Kim (2008) classificaram a variação das precipitações no Rio Grande do Sul em regiões, pelo método de agrupamento. A região norte apresenta as maiores normais mensais de precipitação, o que se deve, entre outros aspectos, ao efeito orográfico. As regiões sul e litorânea, sem obstáculos físicos, explicam a passagem das frentes, e apresentam as menores médias.

Em relação aos índices de precipitação, estudos analisaram a precipitação média acumulada no Sul do Brasil, e encontraram valores semelhantes. Nimer (1979) analisou o período entre 1914 e 1938, e encontrou valores entre 1250 e 2000 mm ao ano, assim como Mendonça e Danni-Oliveira (2007), que analisaram o período entre 1961 e 2000. Severo (2007), utilizando o método de agrupamento, encontrou valores entre 1450 e 2100 mm no período entre 1979 e 2002.

Entretanto, Ly *et al.* (2013) alertam que a avaliação precisa da variabilidade espaço-temporal da precipitação na escala de bacia hidrográfica representa um problema complexo devido ao pequeno número de medidores de precipitação, e à variação extrema de precipitação no espaço e no tempo. Além disso, a avaliação precisa da precipitação espacial e temporal é crucial para simular processos hidrológicos (Cheng *et al.*, 2017).

A concordância entre as séries de precipitação organizadas no banco de dados e os valores encontrados para diferentes variáveis em outros estudos, no Brasil e no Rio Grande do Sul, demonstra que os métodos de interpolação e a espacialização

das variáveis apresentaram um melhor ajuste em relação aos valores reais, e reforçam a confiabilidade dos dados disponíveis no banco de dados.

Em Rossato (2011), além de 2004, os anos de 1988 e 1991 apresentaram precipitações anuais abaixo da média, o que condiz com o IAC negativo dos respectivos anos (-3,5 e -3,8). Já os anos de 1997, 1998 e 2002 foram considerados os mais chuvosos no período analisado. Ao se comparar com o IAC obtido para esses anos, temos 1997 e 1998 como anos úmidos (2,9 e 3,3).

Fontana e Berlato (1997); Chechi e Sanches (2003) encontraram boa correlação entre os anos enquadrados como úmidos e muito úmidos com os anos sob influência do fenômeno *El Niño*. Brito *et al.* (2006), analisaram os anos entre 1967 e 1998, em que os anos considerados normais ou de *La Niña*, apresentaram totais pluviométricos relativamente inferiores à média para o período.

Os anos caracterizados pelo *El Niño* são os mais chuvosos (BRITTO *et al.*, 2008). Em comparação ao IAC, Fig. 6, os anos 1997 e 1998 foram anos de forte ocorrência do fenômeno, enquanto 2002, embora com maior IAC em relação aos anos citados, foi de moderada ocorrência.

Os anos com IAC próximos à zero ou negativos, Fig. 6, não apresentaram relação direta com o fenômeno ENOS. Os anos de 1988 e 1991 foram anos de *El Niño* de moderado a forte, com IAC negativos. O ano de 2004, também com IAC negativo foi considerado um ano neutro, sem alterações representativas da temperatura do Oceano Pacífico. Entre os anos com IAC próximos a zero, foi verificado que 2013 e 2016, eram anos neutros. Por outro lado, 2010 foi um ano de *La Niña* moderada.

O método IAC foi aplicado por Chechi e Sanches (2003) para a região norte do Rio Grande do Sul. Tanto nos anos mais secos quanto nos anos mais úmidos, os resultados encontrados são coerentes ao exposto neste estudo. No entanto, a região norte apresentou os maiores acumulados de precipitação, de forma que alguns dos anos mais úmidos apresentaram um IAC maior que a média considerando todo o RS.

Em relação à distribuição mensal de precipitação, de acordo com Viana (2009), a primavera apresenta os maiores volumes de precipitação, predominantemente na região norte do Rio Grande do Sul. Segundo o autor, há grande relevância da

contribuição da precipitação da estação para o acumulado observado na média anual.

Segundo Britto *et al.* (2006), que analisaram a precipitação entre 1967 e 1998, no sudoeste do estado o outono é mais chuvoso, devido à atuação de bloqueios atmosféricos. No noroeste os meses de primavera são os mais chuvosos, devido à formação dos CCM's (Complexos Convectivos de Mesoescala), e no nordeste o verão é mais chuvoso, em função das chuvas convectivas associadas a sistemas atmosféricos como a Zona de Convergência Atlântico Sul. Em comparação a Fig. 11, a principal divergência se dá em relação à região sudoeste, na qual os meses mais chuvosos ocorrem entre primavera e verão, e não no outono. Outros estudos encontraram valores semelhantes para diferentes regiões do Rio Grande do Sul (Brubacher *et al.*, 2012; Forgiarini *et al.* 2013; Marcuzo *et al.*, 2015; Melati *et al.* 2015, Sanches *et al.*, 2016).

A otocodificação realizada neste estudo foi diferente da disponibilizada pela ANA, e está relacionada à necessidade de incorporar as sub-bacias visando a aplicabilidade do banco de dados. A utilização do método foi eficaz para codificar as bacias e sub-bacias, algo essencial para a construção do banco de dados. Silva (2008) e Rolim (2020) utilizaram esse método em bacias hidrográficas no Rio Grande do Sul, no entanto, sem o nível de detalhamento como o apresentado neste estudo.

O Banco de Dados permite acesso às séries temporais de precipitação e normais climatológicas para o estado do Rio Grande do Sul. Atualmente, o processo mais comum aos pesquisadores é realizar o *download*, via *hidroweb* ou BDMEP, dos dados por estação meteorológica e depois realizar o preenchimento de falhas, interpolação e extração dos índices.

Além disso, o arquivo de saída está no mesmo formato que a maioria dos *softwares* operam, ou seja, cada linha representa um dia e a chuva média em determinada área. Esse tipo de dado é essencial em estudos de climatologia, agricultura, modelagem hidrológica e gestão de desastres.

## 5 Considerações Finais

O objetivo deste estudo foi produzir um Banco de Dados que permita que usuários tenham acesso a séries temporais de precipitação, sem a necessidade de pós-processamento. A partir desse Banco de Dados é possível extrair uma série de produtos de acordo com a área de estudo em questão, seja um município ou uma bacia hidrográfica, para o estado do Rio Grande do Sul.

Mesmo se considerarmos municípios pequenos, com área inferior a 50 km<sup>2</sup>, ou mesmo sub-bacias de 4<sup>a</sup> ordem, as quais foram delimitadas neste estudo, o Banco de Dados tem ao menos uma célula vinculada a essa área, o que permite que o usuário tenha acesso a uma série de 30 anos de dados de chuva, interpolada e revisada.

A disponibilização desse serviço pela internet, com um arquivo de saída compatível com a maioria dos softwares de SIG, representa um ganho importante para trabalhos que necessitem a utilização de longas séries temporais, como climatologia, agricultura, modelagem hidrológica e gestão de desastres.

Entre as melhorias previstas para a sua organização, destacam-se a possibilidade de ampliação da série temporal disponível e o cálculo de outros índices pluviométricos. Nesse momento, o banco está programado para que a seleção de informações e *download* seja para o período mínimo de um ano. Posteriormente será ajustado para períodos menores. Atualmente, o Banco de Dados deverá ser acessado exclusivamente pelo *software* MATLAB. No futuro, é previsto que também seja divulgado em linguagem de computação aberta.

## Agradecimentos

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001; da FAPERGS, processo 17/2551-0000894-4, Edital 01/2017; e da Bolsa de Produtividade CNPq.

## Referências

AFONSO, A.; SILVA, T.M. **Geomorfologia Geral**. Rio de Janeiro: CEDERJ, v. 2, 294, p., 2014.

ANA - AGÊNCIA NACIONAL DE ÁGUAS. Base Hidrográfica Ottocodificada. 2015, 17p. Disponível em: <<https://metadados.ana.gov.br/geonetwork/srv/pt/metadata.show?id=587&currTab=distribution>>. Acesso em: 03 set. 2020.

ANA - AGÊNCIA NACIONAL DE ÁGUAS. Portal Hidroweb: Sistema Nacional de Informações sobre Recursos Hídricos, 2019. Disponível em: <https://www.snirh.gov.br/hidroweb/>. Acesso em: 18 out. 2019.

ALVES, A.V.P.; SANTOS, G.B.S.; MENEZES FILHO, F.C.M.; SANCHES, L. Análise Dos Métodos De Estimativa para os Parâmetros das Distribuições de Gumbel E GEV Em Eventos de Precipitações Máximas na cidade de Cuiabá-MT. **Revista Eletrônica de Engenharia Civil**, v. 6, n. 1, p. 32-34, 2013.

ARAUJO, L.E.; MORAES NETO, J.M.; SOUZA, F.A.S. Classificação de Precipitação anual e da quadra chuvosa da bacia do rio Paraíba utilizando Índice de Anomalia de Chuvas (IAC). **Revista Ambi-Água**, v. 4, n. 3, p. 93-110, 2009.

ARGUEZ, A.; I. DURRE, S.; APPLEQUIST, R.S.; VOSE, M.F; SQUIRES, X. YIN, R.R.; HEIM, OWEN, T.W. NOAA's 1981–2010 U.S. Climate Normals: An Overview. **Bull. Amer. Meteor. Soc.**, v. 93, n. 11, p. 1687-1697, 2012.

ASSAD, E.D.; EVANGELISTA, B.A. Análise freqüencial da precipitação Pluviométrica. In: ASSAD, E.D. *et al.*, **Chuva nos cerrados: análise e espacialização**. Brasília: EMBRAPA-SPI, Cap. II, p. 25-41, 1994.

BARCELLOS, P.C.L.; SILVA, F.P.; VISSIRINI, F.S.B.; MAGALHÃES, C.A.; TERRA, J.M.; DUTRA, M.R.F.; AMARAL, I.C.F.A. Diagnóstico Meteorológico dos Desastres Naturais Ocorridos nos Últimos 20 Anos na Cidade de Duque de Caxias. **Rev. bras. Meteorol.**, v. 31, n. 3, p. 319-329, 2016.

BARATTO, J.; WOLMANN, C. Perfil topo-oro-pluviométrico do estado do Rio Grande do Sul, Brasil. **Revista Interface**, v. 10, p. 40-55, 2015.

BEIJO, L. A.; MUNIZ, J. A.; NETO, P. C. Tempo de retorno das precipitações máximas de Lavras (MG) pela distribuição dos valores extremos do tipo i. **Ciência Agrotécnica**, Lavras, v. 29, n. 3, p. 657-667, 2005.

BEIJO, L.A.; MUNIZ, J.A.; VOLPE, C.A.; PEREIRA, G.T. Estudo da precipitação máxima em Jaboticabal (SP) pela distribuição de Gumbel utilizando dois métodos de estimação dos parâmetros. **Revista Brasileira de Agrometeorologia**, v. 11, n. 1, p. 141-147, 2003.

BEGA, R.M.; VIEIRA, S.R.; MARIA, I.C.; DECHEN, S.C.F.; CASTRO, O.M. Variabilidade espacial das precipitações pluviais diárias em uma estação experimental, em Pindorama, SP. **Bragantia**, v. 64, n. 1, p. 149-156, 2005.

BORSATO, V. A.; MENDONÇA, F. A. A espacialização dos sistemas atmosféricos e a análise rítmica para o centro-sul do Brasil. **GEOUSP Espaço e Tempo**, v. 19, n. 3, p. 585-604, 2015.

BRITTO, F.; BARLETTA, R.; MENDONÇA, M. Regionalização sazonal e mensal da precipitação pluvial máxima no estado do Rio Grande do Sul. **Rev. bras. clim**, v. 2, p. 35-51, 2006.

BRITTO, F. P.; BARLETTA, R.; MENDONÇA, M.: Variabilidade espacial e temporal da precipitação pluvial no Rio Grande do Sul: Influência do Fenômeno El Niño Oscilação Sul. **Rev. bras. clim**, v. 3, p. 37- 48, 2008.

BRUBACHER, J.P.; OLIVEIRA, G.G.; GUASSELLI, L.A.; LUERCE, T.D. Avaliação de bases SRTM para extração de variáveis morfométricas e de drenagem. São Paulo, UNESP, **Geociências**, v. 31, n. 3, p. 381-393, 2012.

BRUBACHER, J.P.; OLIVEIRA, G.G.; GUASSELLI, L.A. Preenchimento de Falhas em Séries Temporais de Precipitação Diária no Rio Grande do Sul. **Rev. bras. meteorol.**, v. 35, n. 2, p. 335-344, 2020.

CALDANA, N.F.S.; MARTELÓCIO, A.C.; RUDKE, A.P.; NITSCHKE, P.R.; CARAMORI, P.H. Frequência, Intensidade e Variabilidade Pluviométrica na Mesoregião Sudoeste Paranaense. **Rev. Bras. Clim.**, v. 25, p. 161-181, 2019.

CECÍLIO, R. A.; PRUSKI, F. F. Interpolação dos parâmetros da equação de chuvas intensas com uso do inverso de potências da distância. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 7, n. 3, p. 501-504, 2003.



CHECHI, L.; SANCHES, F.O. O Uso do Índice de Anomalia de Chuva (IAC) na avaliação do Fenômeno do El Niño Oscilação Sul (ENOS) no Alto Uruguai Gaúcho entre 1957-2012. **Revista Brasileira de Geografia Física**, v. 6, n. 6, p. 1586-1597, 2013.

CHEN, T.; LILIANG REN, L.; YUAN, F.; YANG, X.; JIANG, S.; TANG, T.; LIU, Y.; ZHAO, C.; ZHANG, L. Comparison of Spatial Interpolation Schemes for Rainfall Data and Application in Hydrological Modeling. **Water**, v. 9, n. 5, 2017.

CHENG, M.; WANG, Y.; ENGEL, B.; ZHANG, W.; PENG, H.; CHEN, X.; XIA, H. Performance Assessment of Spatial Interpolation of Precipitation for Hydrological Process Simulation in the Three Gorges Basin. **Water**, v. 9, n. 11, 2017.

CHOU, J.S.; YANG, K.H.; CHENG, M.Y.; TU, W.T. Identification and assessment of heavy rainfall-induced disaster potentials in Taipei City. **Nat. Hazards**, v. 66, p. 167-190, 2013.

COSTA, L.C. **Dimensionamento de reservatórios para sistemas de abastecimento de água pluvial para a região dos campos gerais tendo em vista cenários de mudanças climáticas.** Dissertação (Mestrado em Saneamento Ambiental e Recursos Hídricos), Universidade Estadual de Ponta Grossa, Ponta Grossa, 76p, 2016.

DIRKS, K.N.; HAY, J.E.; STOW, C.D. e HARRIS, D. High-resolution studies of rainfall on Norfolk Island Part II: Interpolation of rainfall data. **J. Hidr.**, v. 208, n. 3-4, p. 187-193, 1998.

DORE, M. Climate change and changes in global precipitation patterns: What do we know? **Environment International**, v. 31, p. 1167-1181, 2005.

FARIAS, O.G.; FRANCISCO, C.N.; SENNA, M.C.A. Avaliação de métodos de interpolação espacial aplicados a pluviosidade em região montanhosa no litoral sul do estado do Rio de Janeiro. **Revista Brasileira de Climatologia**, v. 21, p. 172-185, 2017.

FONTANA, D.; BERLATO, M., E; A., Influência do El Niño oscilação sul sobre a precipitação pluvial no estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, n. 1, p. 127-132, 1997.

FORGIARINI, F.R.; VENDRUSCOLO, D.S.; RIZZI, E.S. Análise de chuvas orográficas no centro do estado do rio grande do sul. **Rev. bras. clim**, v.13, p. 107-119, 2013.

FREITAS, M.A.S. Um sistema de suporte à decisão para o monitoramento de secas meteorológicas em regiões semi-áridas. **Revista Tecnologia**, Fortaleza, v. suplement., p. 84-95, 2004.

GERALDI, M.S. **Influência do tamanho de séries temporais de precipitação em simulações de sistemas de aproveitamento de água pluvial em edificações**. Dissertação (mestrado em Engenharia Civil), Universidade Federal de Santa Catarina, Florianópolis, 251 p., 2017.

GOODRICH, D.C.; KEEFER, T.O; UNKRICH, C.L.; NICHOLS, M.H.; OSBORN, H.B.; STONE, J.J.; SMITH, J.R. Long-term precipitation database, Walnut Gulch Experimental Watershed, Arizona, United States. **Water Resources Research**, v. 44, n. 5, 2008.

GHUMMAN, A.R.; RAUF, A.; HAIDER, H.; SHAFIQUZAMMAN, M. Functional data analysis of models for predicting temperature and precipitation under climate change scenarios. **J. Water Clim. Change**, v. 11, n.4, p. 1748-1765, 2020.

GUMBEL, E.J. Statistical Theory of Floods and Droughts. **Journal of the Institution of Water Engineers and Scientists**, v. 12, p. 1-28, 1985.

HARTMANN, M.; MOALA, F.A.; MENDONÇA, M.A. Estudo das precipitações máximas anuais em Presidente Prudente. **Rev. bras. meteorol.**, v.26, n. 4, p. 561-568, 2020.

INSITITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Malha Municipal 2019. 2019. Acesso em: 20 de março de 2020. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/15774-malhas.html?=&t=downloads>.

JENSON, S. K.; DOMINGUE, J. O. Extracting Topographic Structure from Digital Elevation Data for Geographic Information System Analysis. **Photogrammetric Engineering and Remote Sensing**. v. 54, n. 11, p. 1593-1600, 1988.

KHAN, V.; KIM, I. A Análise de Agrupamento Pluviométrico nos Estados do Rio Grande do Sul e Santa Catarina. In: **X Congresso Brasileiro de Meteorologia**, Brasília, 1998.

LAM, N.S. Spatial Interpolation Methods: A Review. **The American Cartographer**, v. 2, n. 10, p. 129-149, 1983.

LIU, J.; YANG, L.; JINGCHAO, J.; YUAN, W.; DUAN, Z. Mapping diurnal cycles of precipitation over China through clustering, **Journal of Hydrology**, v. 592, p. 125804-125811, 2021.

LUCAS, T.P.B. Identificação de interpoladores adequados a dados de chuva a partir de parâmetros estatísticos. **Rev. Bras. Clim.**, v. 13, p. 7-21, 2013.

LY, S.; CHARLES, C.; DEGRÉ, A. Different methods for spatial interpolation of rainfall data for operational hydrology and hydrological modeling at watershed scale. A review. **Biotechnol. Agron. Soc. Environ.**, v. 17, n. 2, p.392-406, 2013.

MARCUZZO, F.F.N.; MELATI, M.D., Precipitação pluviométrica mensal nas sub-bacias que integram à Bacia do Atlântico - Trecho Sudeste, **XXI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS**, Anais... Brasília, 2015.

MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia**: noções básicas e climas do Brasil. 1. ed., São Paulo/SP: Oficina de Textos, 206 p., 2007.

MELATI, M.D.; MARCUZZO, F.F.N. Influência da altitude na precipitação média anual das sub-bacias pertencentes à bacia do rio Uruguai. **XXI SIMPÓSIO BRASILEIRO DE RECURSOS HÍDRICOS**, Brasília, Anais... , 2015.

MENEZES, H.E.A.; BRITO, J.I.B.; LIMA, R.A.F.A. Veranico e a produção agrícola no Estado da Paraíba, Brasil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n. 2, p. 181-186, 2010.

MILLINGTON, N; DAS, S.; SIMONOVIC, S.P. The Comparison of GEV, Log-Pearson Type 3 and Gumbel Distributions in the Upper Thames River Watershed under Global Climate Models, **Water Resources Research Report**, v. 40, 2011.

MINUZZI, R.B.; LOPEZ, F.Z. Variabilidade de índices de chuva nos estados de Santa Catarina e Rio Grande do Sul. **Biosci. J.**, v. 30, n. 3, p. 697-706, 2014.

NAGHETTINI, M.; ANDRADE PINTO, E.J. Serviço Geológico do Brasil. **Hidrologia estatística**. Belo Horizonte, 552 p., 2007.

NIMER, E. **Climatologia do Brasil**. Rio de Janeiro: IBGE. 422 p., 1979.

PFASTETTER, O. Classificação de bacias hidrográficas: metodologia de codificação. Rio de Janeiro, Rio de Janeiro, Brasil: Departamento Nacional de Obras e Saneamento, 1989. (Manuscrito não publicado). Disponível em: <[https://drive.google.com/file/d/0B6T7sNg\\_aVgObEhKLWdDZVIXaGM/view](https://drive.google.com/file/d/0B6T7sNg_aVgObEhKLWdDZVIXaGM/view)>. Acesso em: 21 out. 2020.

REBOITA, M. S.; KRUCHE, N. Normais Climatológicas Provisórias de 1991 a 2010 para Rio Grande, RS. **Rev. bras. meteorol.**, vol. 33, n. 1, p. 165-179, 2018.

ROLIM, F.E.; MULLER, Y.T.; MARCUZZO, F.F.N. Ottocodificação e análise altimétrica e da precipitação pluviométrica da bacia hidrográfica do rio Canoas na fronteira entre o Rio Grande do Sul e Santa Catarina. **TECNO-LÓGICA**, v. 24, n. 1, p. 64-73, 2020.

ROOY, M.P.V. A Rainfall Anomaly Index Independent of Time and Space. **Notes**, v. 14, p. 43, 1965.

ROSSATO, M. S. **Os climas do Rio Grande do Sul: variabilidade, tendências e tipologia**. Tese (Doutorado em Geografia). Universidade Federal do Rio Grande do Sul, Porto Alegre, 253 p., 2011.

SANCHES, F.O.; MAY, G.C.; SILVA, R.V.; FERREIRA, R.V. Chuvas no norte gaúcho: um estudo sobre a tendência das chuvas e mudanças climáticas. **Rev. bras. clim**, v. 18, p. 349-360, 2016.

SARTORI, M.G.B. **A Dinâmica do Clima do Rio Grande do Sul: indução empírica e conhecimento científico**. Terra Livre, São Paulo, ano 19, v.1, n. 20, p. 27-49, 2003.

SAUSEN, T.M. Uso de geotecnologias para análise e avaliação dos prejuízos causados pelas inundações no Rio Grande do Sul – Setembro de 2009 a Janeiro de

2010. **XV Simpósio Brasileiro de Sensoriamento Remoto – SBSR**, Curitiba, p. 6050-6057, 2011.

SEVERO, D. L. **Padrões de circulação anômala associados a episódios úmidos e secos no sul do Brasil**. Tese (Doutorado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 224 p., 2007.

SILVA, D.D.S.; GOMES FILHO, R.R.; PRUSKI, F.F.; PEREIRA, S.B., NOVAES, L.F. de. Chuvas intensas no Estado da Bahia. **Rev. bras. eng. agríc. ambient.**, v. 6, n. 2, p. 362-367, 2002.

SILVA, N.S.; RIBEIRO, C.A.A.S.R.; BARROSO, W.R.; RIBEIRO, P.E.A.; SOARES, V.P.; SILCA, E. Sistema de otto-codificação modificado para endereçamento de redes hidrográficas. **Rev. Árvore**, v. 32, n. 5, p. 891-897, 2008.

SILVA, K.R.; CECÍLIO, R.A.; XAVIER, A.C.; PEZZOPANE, J.R.M.; GARCIA, G.O. Interpolação Espacial da Precipitação no Estado do Espírito Santo. **Floresta e Ambiente**, v. 18, n. 4, p. 417-427, 2011.

SILVA, C.B.; SILVA, M.A.S.; AMBRIZZI, T.; TOMAZZELLI, J.T.G.; PATUCCI, N.N.; MATAVELI, G.A.V.; LIMA, B.S.; CORREA, W.C. Precipitação na América do Sul – Dados Obtidos em Estações Meteorológicas Automáticas e Sistemas Orbitais. **Rev. Bras. Clim.**, v. 25, p. 54-79, 2019.

SILVA, A.E.F.; GOMES; D.T.; SILVEIRA, C.S.; SAKAMOTO, M.S. Desempenho das Simulações do Projeto Cordex Quanto à Representação dos Padrões de Variação da Precipitação no Século XX sobre o Município de Fortaleza, Ceará. **Rev. bras. meteorol.**, v. 35, n. 3, p. 387-396, 2020.

STRAHLER, A. N. **Dynamic basis of Geomorphology**. Geological Society of America Bulletin, v.63, p. 923-938, 1952.

TABARI, H. Climate change impact on flood and extreme precipitation increases with water availability. **Sci. Rep.**, v. 10, p. 13768-13778, 2020.

TARBOTON, D. G.; BRAS, R. L.; RODRIGUEZ-ITURBE, I. On the Extraction of Channel Networks from Digital Elevation Data. **Hydrological Processes**, n. 5, p. 81-100, 1991.

TEIXEIRA, C.F.A. *et al.* Estatística de Mallows na seleção de modelos de predição da precipitação média mensal e anual no Rio Grande do Sul. **Revista Agro@ambiente**, v. 7, n. 2, p. 145-153, 2013.

TOKAR, S.; MARKUS, M. precipitation-runoff modeling using artificial neural networks and conceptual models. **J. Hydrol. Eng.** v. 5, n. 2, p. 156-161, 2000.

TRENBERTH, K. E. Changes in precipitation with climate change. **Clim. Res.**, v. 47, p. 123–138, 2011.

VEBER, P.M.; TEIXEIRA-GANDRA, C.F.A.; DAMÉ, R.C.F.; SIMONETE, M.A.; KARSBURG, R.M.; CHAGAS NETA, M.C.C.; CUNHA, P.R.B. Validação do banco de dados Brazil Gridded Meteorological Data em algumas estações pluviométricas do estado do Rio grande do Sul. **Braz. J. of Develop.**, v. 6, n. 4, p. 16792-16801, 2020.

VIANA, D.R.; *et al.* Mesoscale convective complexes in Rio Grande do Sul between October and December of 2003 and associated precipitation. **Rev. bras. meteorol.**, v. 24, n. 3, p. 276-291, 2009.

VIANNA, L.F.N.; PERIN, E.B.; RICCE, A.M.M.; PANDOLFO, C. Bancos de Dados Meteorológicos: Análise dos Metadados das Estações Meteorológicas no Estado de Santa Catarina, Brasil. **Rev. bras. meteorol.**, v. 32, n. 1, p. 53-64, 2017.

VIEIRA, S.A.; OSORIO, D.M.M.; QUEVEDO, D.M.; ADAM, K.N.; PEREIRA, M.A.F. Metodologia de imputação de dados hidrometeorológicos para análise de séries históricas para avaliação de impactos das mudanças climáticas – bacia do rio dos Sinos, RS, Brasil. **Rev. bras. clim.**, v. 23, p. 189-204, 2018.

VIOLA M.R.; MELLO, C.R.; ACERBI Jr., F.W.; SILVA, A.M. Modelagem hidrológica na bacia hidrográfica do Rio Aiuruoca, MG. **Rev. Bras. Eng. Agríc. Ambient**, v. 13, n. 5, p. 581-590, 2009.

VOGL, T.P., MANGIS, J.K., RIGLER, A.K. *et al.* Accelerating the convergence of the back-propagation method. **Biol. Cybern.** v. 59, p. 257–263, 1988.

XAVIER, A. C.; KINGB, C. W.; SCANLONC, B. R. Daily gridded meteorological variables in Brazil (1980–2013). **International Journal of Climatology**, v. 36, p. 2644-2659, 2016.

WANDERLEY, H.S.; AMORIM, R.F.C.; CARVALHO, F.O. Variabilidade espacial e preenchimento de falhas de dados pluviométricos para o estado de Alagoas. **Rev. Bras. Met.**, v. 27, n. 3, p. 347-354, 2012.

WANG, T.; MIAO, J.P.; SUN, J.Q.; FU, Y.H. Intensified East Asian summer monsoon and associated precipitation modeshift under the 1.5°C global warming target. **Advances in Climate Change Research**, v. 9, p. 102-111, 2018.

WMO - WORLD METEOROLOGICAL ORGANIZATION. **Guide to the Global Observing System**, n. 488, 3ª ed., Genebra, Suíça, 228 p., 2017.

WMO - WORLD METEOROLOGICAL ORGANIZATION. **Methods of observation**. In: Guide to Hydrological Practices: hydrology from measurement to hydrological information, v. 1, n. 68, Geneva, Switzerland, 296 p., 2008. Disponível em: <[http://www.whycos.org/chy/guide/168\\_Vol\\_I\\_en.pdf](http://www.whycos.org/chy/guide/168_Vol_I_en.pdf)>. Acesso em: 13 ago. 2020.

WMO - WORLD METEOROLOGICAL ORGANIZATION. **Manual on Codes - International Codes**, Volume I.1: part A- Alphanumeric Codes, Geneva, Switzerland, 466 p, 2015.

### 3.4 ARTIGO 4: Comparação entre Banco de Dados de precipitação e produto 3IMERGM, Estado do Rio Grande do Sul

#### RESUMO

Nas últimas décadas, técnicas de sensoriamento remoto possibilitaram a estimativa de dados de precipitação por satélites meteorológicos, permitindo a observação e monitoramento contínuo do tempo e do clima em nível global. Esse estudo, tem como objetivo comparar dados de precipitação da Missão *Global Precipitation Measurement* GPM, produto *Integrated Multi-Satellite Retrievals for GPM Monthly* (3IMERGM), com dados de estações pluviométricas organizados em um Banco de Dados espacial para o estado do Rio Grande do Sul. A estruturação do Banco de Dados consistiu em: a) adquirir, organizar e preencher falhas das séries históricas de precipitação; b) interpolar espacialmente dados de precipitação para uma malha regular com resolução espacial de 20 km. A comparação foi realizada espacialmente, por meio de índices mensais e anuais de precipitação. Para a análise dos resultados, foram medidos: 1) Coeficiente de Correlação de Pearson; 2) Viés; 3) Diferença Simples e Diferença Relativa. Os dados de precipitação estimados pelo produto 3IMERGM se mostraram compatíveis com o Banco de Dados, mas superestimaram os valores em 9,15%. Dos 198 meses analisados, 186 meses apresentaram coeficiente superior a 0,5. Desses, 175 (88%) apresentaram coeficiente superior a 0,75, o que indica que a precipitação mensal estimada pelo produto IMERG, tem boa correlação linear com a precipitação mensal interpolada a partir de dados de estações pluviométricas.

**Palavras-chave:** Satélite. GPM. Correlação.



## ABSTRACT

In the last decades, remote sensing techniques have made it possible to precipitation data estimated by meteorological satellites, allowing the observation and continuous monitoring of weather and climate at a global level. This study aims to compare precipitation data from the Global Precipitation Measurement GPM Mission, an Integrated Multi-Satellite Retrievals for GPM Monthly (3IMERGM) product, with data from rainfall stations organized in a spatial database for the state of Rio Grande do Sul. The structuring of the database consisted of: a) acquiring, organizing and gaps filling in the historical precipitation series; b) spatially interpolate precipitation data for a regular grid with a spatial resolution of 20 km. The comparison was performed spatially, using monthly and annual precipitation indices. For the analysis of the results, the following were measured: 1) Pearson's Correlation Coefficient; 2) Bias; 3) Simple Difference and Relative Difference. The precipitation data estimated by the product 3IMERGM proved to be compatible with the database, but overestimated the values by 9.15%. Of the 198 months analyzed, 186 months had a coefficient greater than 0.5. Of these, 175 (88%) had a coefficient greater than 0.75, which indicates that the monthly precipitation estimated by the product IMERG, has a good linear correlation with the monthly precipitation interpolated from data from pluviometric stations.

**Keywords:** Satellite. GPM. Correlation.

## 1. Introdução

Estimativas mais precisas de precipitação, independente da escala de trabalho, são imprescindíveis, sejam na previsão hidrológica, na gestão de riscos de inundação ou em estudos meteorológicos (BIGG, 1991; WU *et al.*, 2013; YONG *et al.*, 2015; LIU *et al.*, 2020). Entretanto, ainda que existam no mundo áreas com alta densidade de pluviômetros, regiões menos povoadas e, principalmente, partes de países em desenvolvimento, carecem de medições adequadas de índices de precipitação (KIDD *et al.*, 2017).

Nas últimas décadas, técnicas de sensoriamento remoto possibilitaram o acesso a dados de precipitação estimados por satélites meteorológicos, permitindo a observação e monitoramento contínuo do tempo e do clima em nível global (STEPHENS e KUMMEROW, 2007; MOREIRA *et al.*, 2017). Como exemplo, o satélite *Tropical Rainfall Measurement Mission* (TRMM), um instrumento remoto de aferição de chuva, lançado em 1997 e que funcionou até 2015 (SILVA LELIS, 2018).

Em 2014 a missão *Global Precipitation Measurement* (GPM), desenvolvida pela *National Aeronautics and Space Administration* (NASA) e pela *Japanese Exploration Agency* (JAXA) lançou o Satélite Observatório Central (SKOFRONICK-JACKSON *et al.*, 2016). A missão GPM é uma constelação internacional de satélites e consiste em um Satélite Observatório Central e cerca de dez satélites parceiros (BEAUFORT *et al.*, 2018), com resoluções temporais e espaciais mais detalhadas que seu antecessor (LIU e ZIPSER, 2015).

O produto *Intercalibrated Merged Retrievals for GPM* (IMERG) é um dos muitos disponíveis para estimar a precipitação no planeta, com dados de vários satélites mesclados (GADELHA, 2018). Esse algoritmo permite acessar uma coleção de dados de precipitação acumulada (mm), em diferentes discretizações temporais (desde a precipitação acumulada a cada 3 horas até a precipitação mensal), e resolução espacial de, aproximadamente, 10 km. Sintetiza as vantagens de algoritmos de precipitação anteriores (SKOFRONICK-JACKSON *et al.*, 2017), o que torna o GPM mais sensível do que o TRMM na medição de precipitação (LIU e ZIPSER, 2015).

Embora menos precisas quando comparadas com medidas pontuais obtidos *in situ*, por meio de estações pluviométricas automáticas (COLLISCHONN *et al.*, 2007),

as estimativas por sensoriamento remoto apresentam a vantagem da distribuição espacial da precipitação (PRAKASH *et al.*, 2016; SIUKI *et al.*, 2016; ZHANG *et al.*, 2018; SILVA LELIS *et al.*, 2020).

Conti (2002) ressalta que a melhor estratégia para o difícil problema de estimar a precipitação é o uso conjunto dos dados disponíveis em solo, radar e satélite. Collischonn (2006) mostrou que além de bons resultados, a estimativa por satélite pode ajudar a identificar pluviômetros com problemas ou mal localizados, constituindo-se em ferramenta para consistência de dados.

Entre os estudos que evidenciam a validação dos produtos GPM para o território brasileiro destacamos: Oliveira *et al.* (2016) avaliaram que o GPM, para a região norte, superestimou chuvas fortes e chuvas convectivas isoladas; Rozante *et al.* (2018) que o GPM superestimou, em todas as regiões, os dados de precipitação, com exceção do litoral nordestino; Freitas (2019) que o GPM incorreu em Erros Médios Absolutos (EMA), para todo o território nacional, em pelo menos 50%, mas que a região Sul apresentou as melhores correlações, mesmo com tendências de superestimação.

Analisar dados precipitação derivados de sensoriamento remoto e avaliar sua precisão, é importante principalmente em áreas com baixa disponibilidade de séries históricas. Comparar produtos 3IMERGM e Bancos de Dados gerado com dados de estações pluviométricas interpoladas, a partir análise espacial pode permitir essa avaliação.

A comparação entre uma análise espacial a partir do produto 3IMERGM e um Banco de Dados, gerado com dados de estações pluviométricas interpoladas, permitirá avaliar a importância e a precisão de dados de sensoriamento remoto, principalmente em áreas com baixa disponibilidade de séries históricas de precipitação.

Assim, o objetivo desse estudo é comparar dados de precipitação da Missão GPM, a partir do produto 3IMERGM, com dados de estações pluviométricas organizados em um Banco de Dados espacial para o estado do Rio Grande do Sul, no sul do Brasil.

## 2. Materiais e Métodos

### 2.1 Área de estudo

Como estudo de caso foi adotado o estado do Rio Grande do Sul (RS), extremo sul do Brasil (Figura 1). Segundo Rossato (2011) no RS o regime climático se divide em Subtropical I (pouco úmido), Subtropical II (medianamente úmido com variação longitudinal das temperaturas médias), Subtropical III (úmido com variação longitudinal das temperaturas médias) e Subtropical IV (muito úmido).

O tipo climático Subtropical I ocorre na metade sul do estado, com precipitações anuais entre 1200 e 1700 mm, distribuídos em 80-100 dias. Na região central ocorrem os tipos Subtropical II e III, com precipitações anuais entre 1400 e 1800 mm, distribuídos em 90-120 dias. Na região norte, o tipo Subtropical IV, é mais úmida com precipitações anuais entre 1700 e 2000 mm, distribuídos em 110-150 dias (ROSSATO, 2011).

A precipitação média mensal é distribuída ao longo do ano, no entanto os maiores valores ocorrem nos meses de setembro e outubro (Primavera no Hemisfério Sul), e de março a junho (outono no Hemisfério Sul) relativamente mais secos, predominante na metade sul do estado. O RS é influenciado pelo fenômeno *El Niño*, que exerce influência importante sobre as precipitações pluviométricas, tanto no que se refere ao excesso quanto à estiagem (FONTANA e BERLATO, 1997; BERLATO *et al.*, 2005; ROSSATO, 2011), influenciando na variabilidade interanual da precipitação.

Figura 1 - Localização, malha regular de interpolação e estações pluviométricas, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

## 2.2 Métodos

### 2.2.1 Aquisição e organização do Banco de Dados pluviométricos

Os dados de precipitação de referência foram obtidos nas seguintes etapas:

(1) aquisição e organização dos dados de precipitação disponíveis no Hidroweb, da Agência Nacional de Águas (ANA, 2019), e do Instituto Nacional de

Meteorologia (INMET), a partir do banco de dados Meteorológicos para Ensino e Pesquisa (BDMEP). Foram utilizados dados de 287 estações pluviométricas (Figura 1), com séries completas ou parciais no período entre 01/01/1987 e 31/12/2016, totalizando 30 anos de registros;

(2) preenchimento de falhas utilizando métodos de Regressão Linear Múltipla (RLM) e Redes Neurais Artificiais (RNA), em que a precipitação no posto com falhas é uma função matemática da precipitação acumulada em postos vizinhos (NAGHETTINI e ANDRADE PINTO, 2007). Ambos os modelos são matemáticos e empíricos, com capacidade de armazenar e disponibilizar conhecimento experimental, por meio de treinamento e de resposta aos estímulos (variáveis de entrada) (TOKAR e MARKUS, 2000). Foi utilizado para o preenchimento de falhas o método aplicado em Brubacher *et al.* (2020);

(3) interpolação dos dados pelo método do Inverso da Potência da Distância (IPD), com base em uma malha regular de resolução espacial de 20 km, abrangendo o estado do Rio Grande do Sul, com 627 pontos de grade (células), Figura 1. O Banco de Dados (BD) contém dados de precipitação para 627 células, no período entre 1987 e 2006. Foram testados diversos critérios para interpolação dos dados, variando o raio de procura de estações vizinhas, a potência da distância e o número de estações por quadrantes, totalizando 60 combinações de critérios para escolha da interpolação mais adequada para a distribuição espacial dos dados. Para análise da melhor combinação, foram selecionadas 35 estações pluviométricas, de forma aleatória, com abrangência no território do RS. Dois índices estatísticos foram utilizados para mensurar a melhor combinação: Erro Médio Absoluto (EMA) e Erro Médio Quadrático (EMQ).

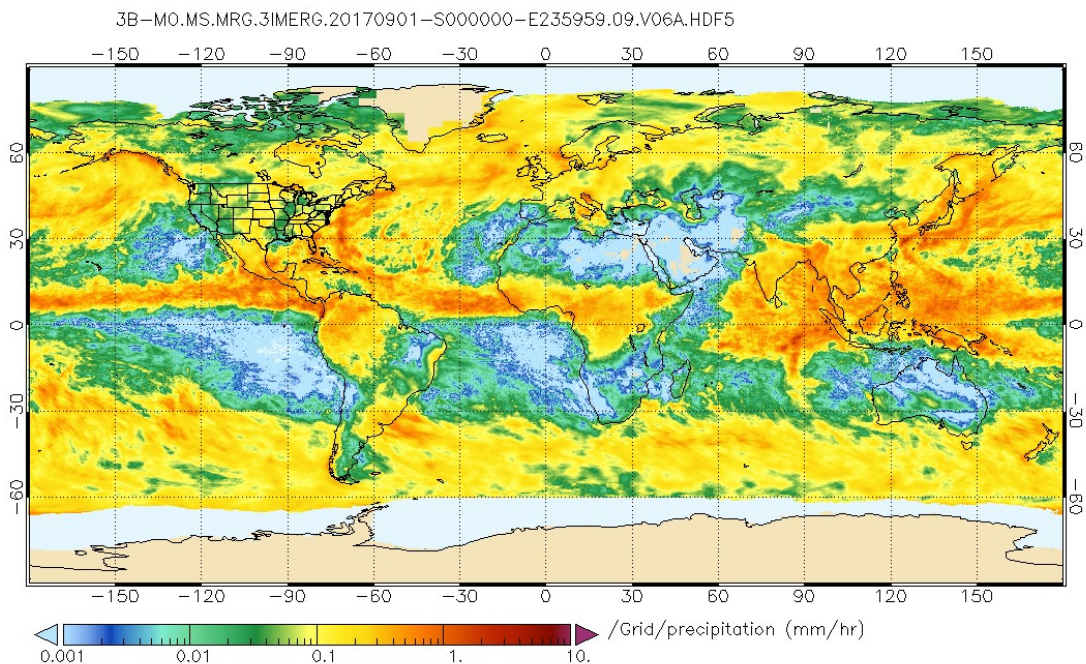
### 2.2.2 Precipitação por satélite - 3IMERGM

O algoritmo IMERG combina informações da constelação de satélites GPM para estimar a precipitação sobre a maior parte da superfície da Terra (HUFMANN, 2019). A missão GPM é uma constelação de observações de precipitação, formadas de forma independente pela NASA e pela JAXA para compartilhar dados de satélite, medições de validação de solo e perícia científica (HOU *et al.*, 2014).

A Missão GPM gera uma série de produtos, categorizados em 4 níveis (Nível-0, Nível-1; Nível-2 e Nível-3) (HUFMANN, 2019). Esses produtos permitem investigações detalhadas, de como e onde a precipitação é distribuída e das mudanças desses padrões ao longo dos dias, estações e anos (KIRSCHBAUM e PATEL, 2017). O produto de maior precisão é o Nível-3 (GPM-IMERG) (LIU, 2020). O 3IMERGM é um conjunto de produtos de precipitação de múltiplos sensores orbitais, resolução espacial de  $0,1^\circ$  e temporal de 3 h, de abrangência mundial (Figura 2).

Foram utilizados dados mensais de precipitação, obtidos do site da NASA (<https://pmm.nasa.gov/data-access/downloads/gpm>), entre junho/2001 e dezembro/2016. Os dados foram recortados para a área do estado do Rio Grande do Sul, e convertidos da escala original (de  $10^{-4}$  m), dividindo por 10 para se obter a precipitação (mm). Foram atribuídos valores de precipitação para cada uma das 627 células, permitindo comparar o Banco de Dados espacial a partir de interpolação espacial da precipitação acumulada em estações pluviométricas e o produto 3IMERGM.

Figura 2 - Exemplo de representação da variação de precipitação superficial e área de abrangência do Satélite GPM IMERG.



Fonte: HUFFMAN *et al.*, 2019.

### 2.1.1 Análise de dados

Foi utilizado o método estatístico Coeficiente de Correlação de Pearson (Eq. 1), que representa uma medida numérica do grau de concordância (similaridade) entre duas ou mais variáveis; segundo a qual os valores são considerados aceitáveis quando entre 0,36 a 0,75 e bons para valores acima de 0,75 (COLLISCHONN, 2001).

$$r = \frac{\sum_1^n (SRE - \overline{SRE})(P - \overline{P})^2}{(n-1) \sigma_{SRE} \sigma_P} \quad \text{Eq. 1}$$

Em que: SRE = Produto de Sensoriamento Remoto; P=Precipitação *in situ*;  $\overline{SRE}$  e  $\overline{P}$ = médias do desvio padrão dos dados estimados e observados; n=total de dados.

O Viés (*BIAS*) é definido como a média das diferenças calculadas entre produtos de sensoriamento remoto e os pluviômetros *in situ* (Eq 2). Viés positivo significa que o modelo superestima os dados, e Viés negativo significa que o modelo subestima os dados. Técnicas para correção do Viés da precipitação do produto 3IMERG têm o intuito de aproximar a precipitação do 3IMERG das observações *in situ* (BEAUFORT, 2018; OLIVEIRA, 2019; LIU *et al.*, 2020).

$$VIÉS = \frac{\sum_{i=1}^n (SRE_i - P_i)}{\sum_{i=1}^n P_i} \quad \text{Eq. 2}$$

Em que: SRE = Produto de Sensoriamento Remoto; P=Precipitação *in situ*; n=Número de medições.

A espacialização das diferenças entre os dois produtos permite demonstrar regiões onde ocorrem as maiores discrepâncias. Então, foi calculada a Diferença Simples (DS) entre cada célula e A Diferença Relativa (DR), permitindo a identificar regiões onde ocorre variação de similaridade entre a precipitação medida pelos diferentes produtos.



$$DS = P - SER \quad \text{Eq. 3}$$

$$DR = \frac{P-SER}{P} * 100 \quad \text{Eq. 4}$$

Em que: DS é a Diferença Simples; DR é A Diferença Relativa; P é a precipitação do Banco de Dados; SER é a precipitação obtida pelo produto.


Os dados estatísticos foram espacializados no software ArcGIS 10.5, por meio do método de Krigagem, adaptado pela geoestatística para a família de algoritmos de regressão de mínimos quadrados generalizados (GOOVAERTS, 1997), que produz melhores estimativas, porque está embasada em duas premissas: não-tendenciosidade do estimador e variância mínima das estimativas (THOMPSON, 1992).

### **3. Resultados**

#### **3.1 Médias Mensais e Anuais**

Para comparar os dois produtos de precipitação, foi calculada a média mensal para o período entre 2001 e 2016 (Figura 3), para o RS. A comparação mostrou que a precipitação estimada pelo produto 3IMERGM superestimou, em todos os meses do ano, a precipitação interpolada e armazenada no Banco de Dados, em média 9,15%.


Figura 3 - Gráfico da comparação entre as médias mensais da precipitação do Banco de Dados e do 3IMERGM, entre 2000 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

O Coeficiente de Correlação de Pearson foi calculado para cada mês, considerando as células da grade de interpolação. Dos 198 meses analisados, 186 meses apresentaram coeficiente superior a 0,5. Desses, 175 (88%) apresentaram coeficiente superior a 0,75, histograma da Figura 4. O que indica que a precipitação mensal estimada pelo produto IMERG, tem boa correlação linear com a precipitação mensal interpolada a partir de dados de estações pluviométricas.

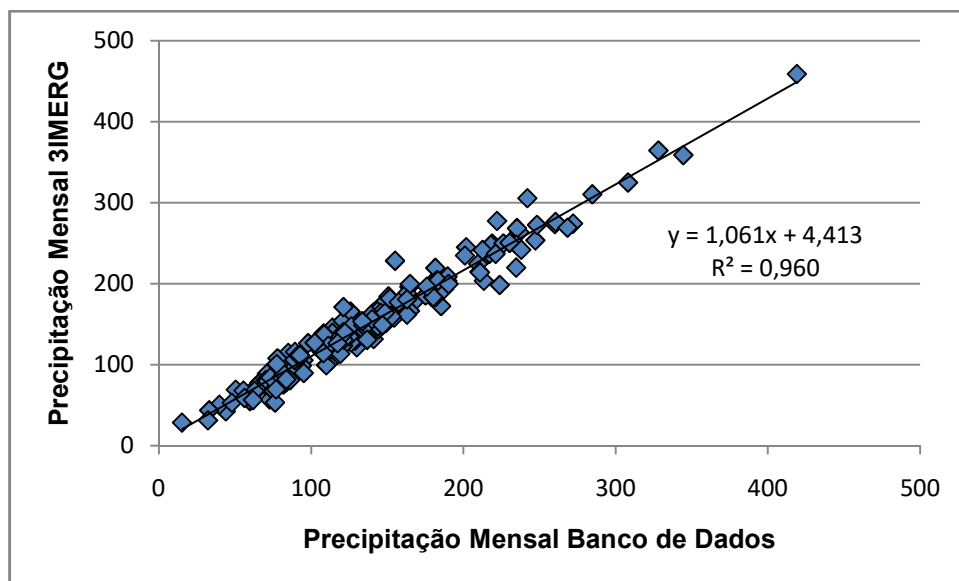
Figura 4 - Histograma das estimativas do Coeficiente de Correlação de Pearson ponderado entre a precipitação mensal do Banco de Dados e do produto 3IMERGM.



Fonte: Elaboração própria.

Na relação entre a precipitação estimada pelo produto IMERG e pelo Banco de Dados, Figura 5, é possível observar uma concordância de 96% entre os dados estimados pelo produto 3IMERGM e o Banco de Dados.

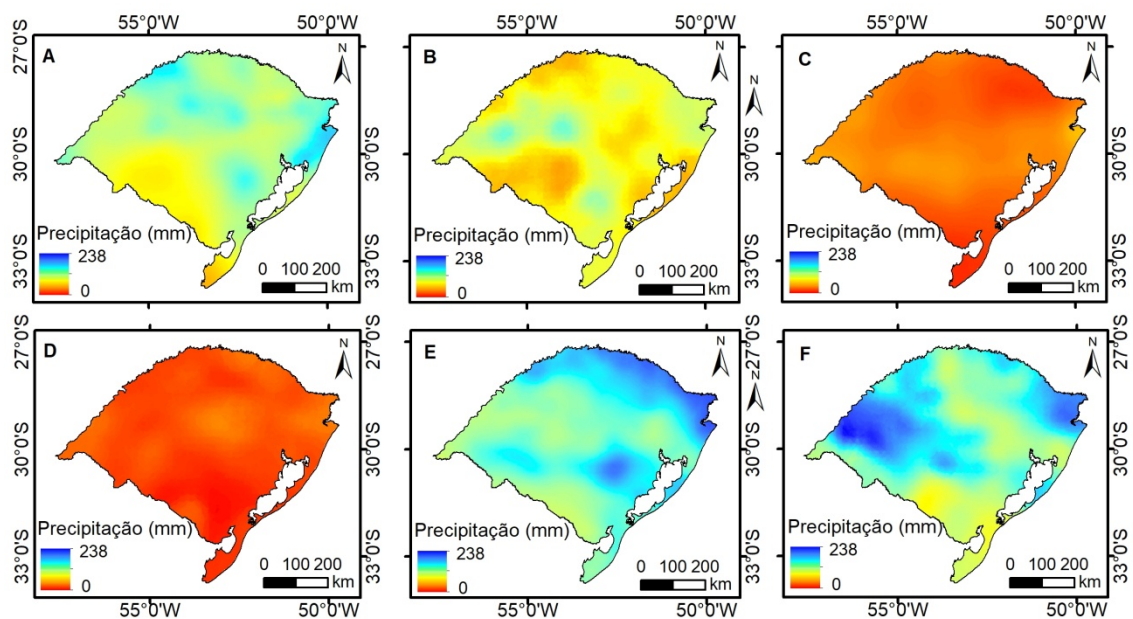
Figura 5. Relação entre os dados mensais de precipitação, entre 2001 e 2016 (significante a  $p < 0,05$ ; teste *t-student*).



Fonte: Elaboração própria.

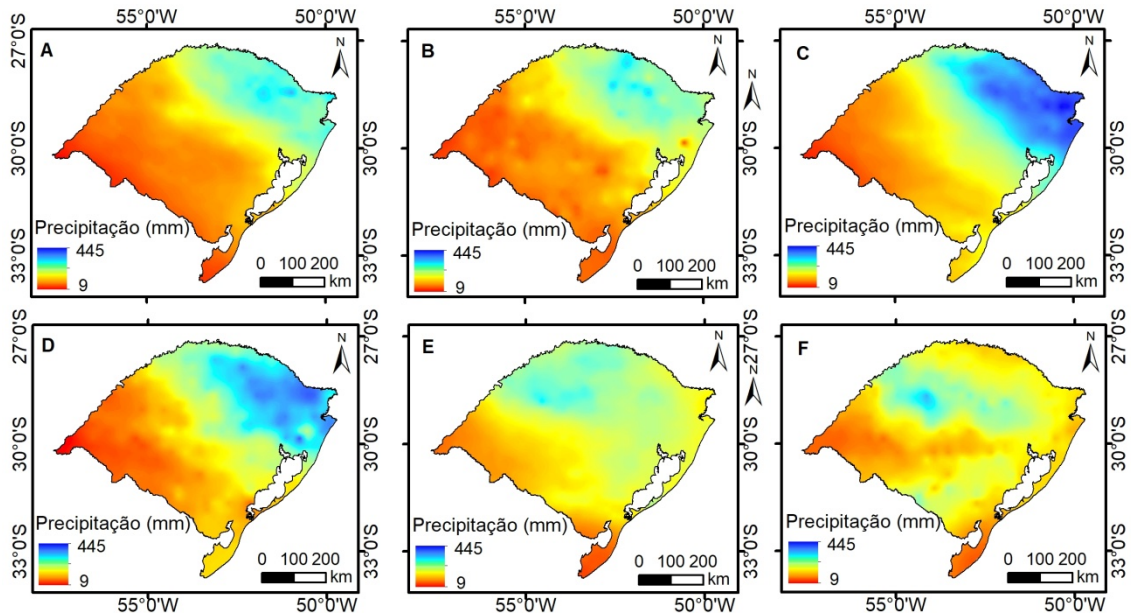
A espacialização dos meses com maiores e menores valores de correlação linear, Figura 6 e Figura 7, auxiliam no entendimento da relação entre os produtos de satélite e do Banco de Dados. A espacialização da precipitação nos meses que apresentaram menor correlação entre as duas fontes de dados, Figura 6, destaca abril/2019 (0,09), dezembro/2016 (0,15) e janeiro/2018 (0,18). O mês de abril/2009 foi o mês mais seco do período analisado, com precipitação média mensal de 15 mm. Os meses de maior correlação linear (Figura 6) têm em comum baixa precipitação nas regiões sul e sudoeste e maior precipitação nas regiões norte e nordeste.

Figura 6 - Espacialização da precipitação acumulada dos meses com menores valores de correlação linear entre os produtos do satélite 3IMERGM e o Banco de Dados espacial com precipitação interpolada para o estado do Rio Grande do Sul. **A)** Janeiro/2008 (3IMERGM); **B)** Janeiro/2008 (Banco de Dados); **C)** Abril/2009 (3IMERGM); **D)** Abril/2009 (Banco de Dados); **E)** Dezembro/2016 (3IMERGM); **F)** Dezembro/2016 (Banco de Dados).



Fonte: Elaboração própria.

Figura 7 - Espacialização da precipitação acumulada dos meses com maiores valores de correlação linear entre os produtos do satélite 3IMERGM e o Banco de Dados espacial com precipitação interpolada para o estado do Rio Grande do Sul. **A)** Julho/2007 (3IMERGM); **B)** Julho/2007 (Banco de Dados); **C)** Agosto/2013 (3IMERGM); **D)** Agosto/2013 (Banco de Dados); **E)** Junho/2015 (3IMERGM); **F)** Junho/2015 (Banco de Dados).




Fonte: Elaboração própria.

### 3.2 Correção de Viés

A tendência de superestimação dos dados de precipitação por meio do IMERG em relação ao Banco de Dados foi de 9,15%. Então, em todas as células o Viés corrigido. A comparação entre os gráficos da Figura 8 e da Figura 3 mostra que as médias mensais do Banco de Dados espacial e do 3IMERGM, com Viés corrigido, são muito mais próximas, inclusive nos meses em que os valores foram subestimados.

Figura 8 - Gráfico da comparação entre as médias mensais da precipitação do Banco de Dados espacial interpolado e do 3IMERGM com Viés corrigido, entre 2001 e 2016, estado do Rio Grande do Sul.




Fonte: Elaboração própria.

A precipitação acumulada anual do Banco de Dados, do 3IMERGM e da precipitação anual acumulada como o Viés do produto 3IMERGM corrigido, para o período entre 2001 e 2016, são apresentadas na Figura 9. Embora os anos mais e menos secos possam ser destacados nos dois produtos, o 3IMERGM superestimou os valores de precipitação em todos os anos da série temporal analisada.

Com a correção do Viés, os acumulados anuais ficaram mais próximos, inclusive, sendo subestimados em alguns anos. No entanto, é possível compreender o comportamento da precipitação no Rio Grande do Sul apenas com a utilização do produto 3IMERGM, mesmo que os dados em campo sejam desconhecidos.

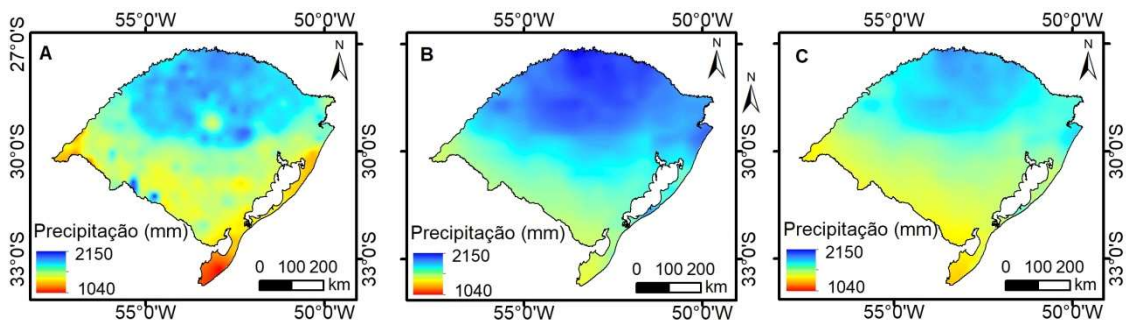
Figura 9 - Gráfico da comparação entre os acumulados anuais da precipitação do Banco de Dados espacial interpolado, do 3IMERGM e do 3IMERGM com Viés corrigido, entre 2001 e 2016, estado do Rio Grande do Sul.



Fonte: Elaboração própria.

A comparação entre a espacialização da precipitação anual, Figura 9A (Banco de Dados) e a Figura 9B (3IMERGM), mostra superestimação em praticamente todas as regiões. Apesar de a Fig. 9B mostrar que nas regiões sul e sudoeste a precipitação é relativamente menor que na região centro-norte, a Fig. 9C, com o Viés corrigido, mostra maior similaridade com a precipitação interpolada das estações pluviométricas.

Figura 10 - Distribuição espacial do total anual médio da precipitação, entre 2001 e 2016: A) Banco de Dados; B) 3IMERGM; C) 3IMERGM com Viés Corrigido.



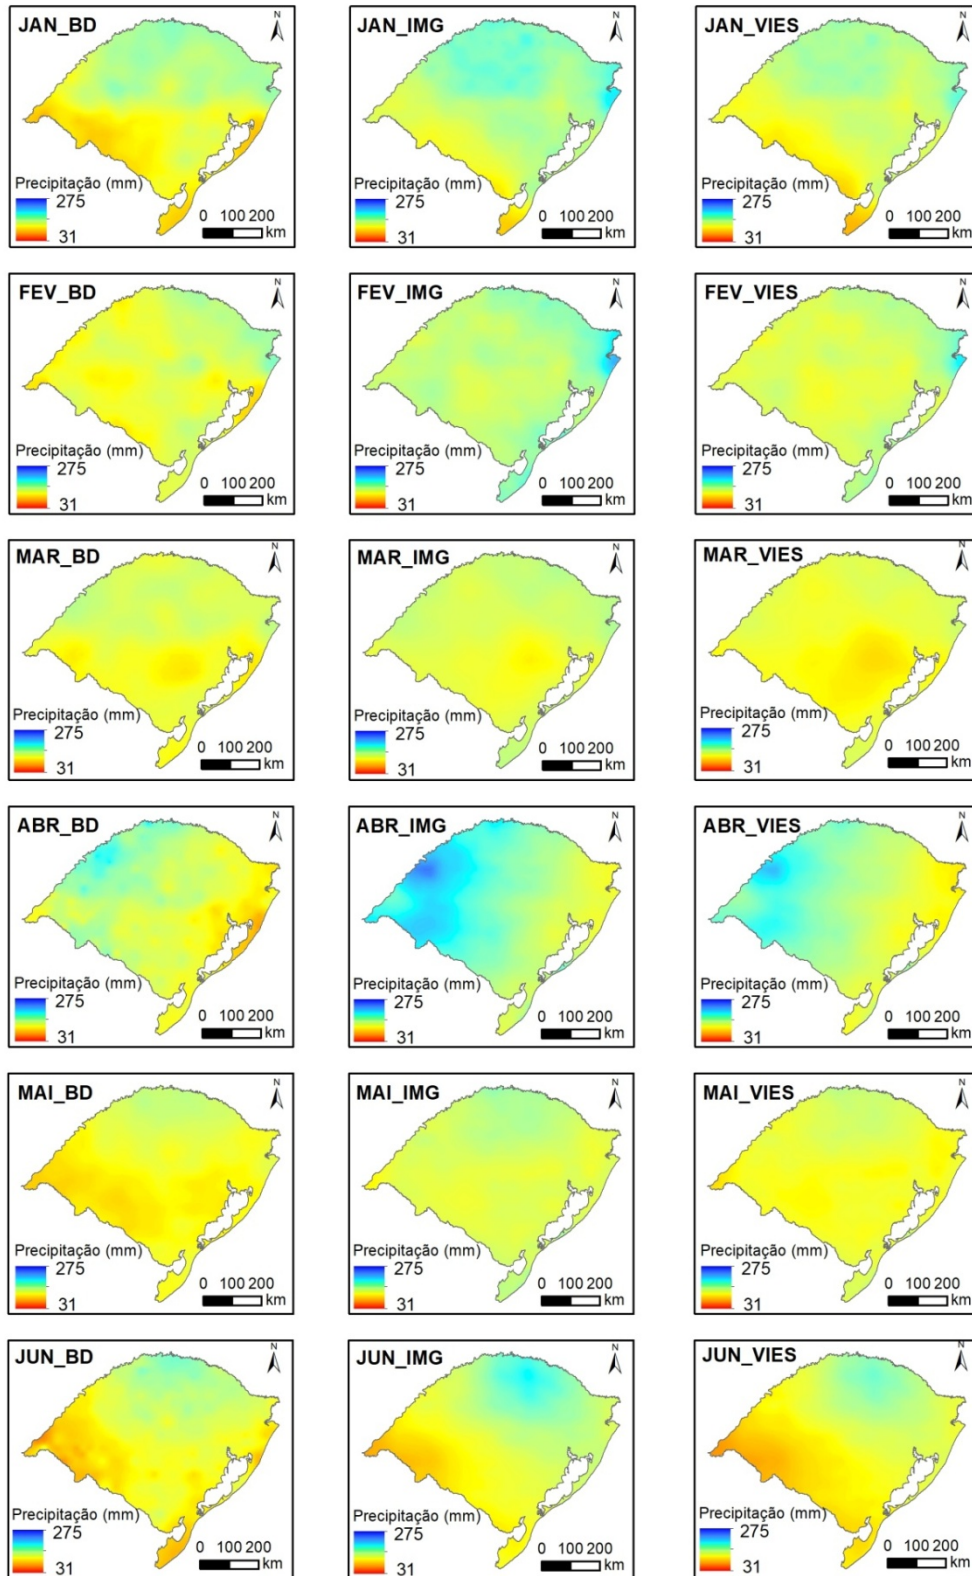
Fonte: Elaboração própria.

A espacialização da precipitação mensal do Banco de Dados, do 3IMERGM e do 3IMERGM com Viés corrigido, Figuras 11 e 12, mostra a superestimativa da precipitação estimada pelo 3IMERGM, em relação ao Banco de Dados.

Nos meses de abril, junho e setembro o produto 3IMERGM superestima consideravelmente a precipitação em relação ao Banco de Dados, e a correção do Viés faz com que essa discrepância seja menos acentuada.

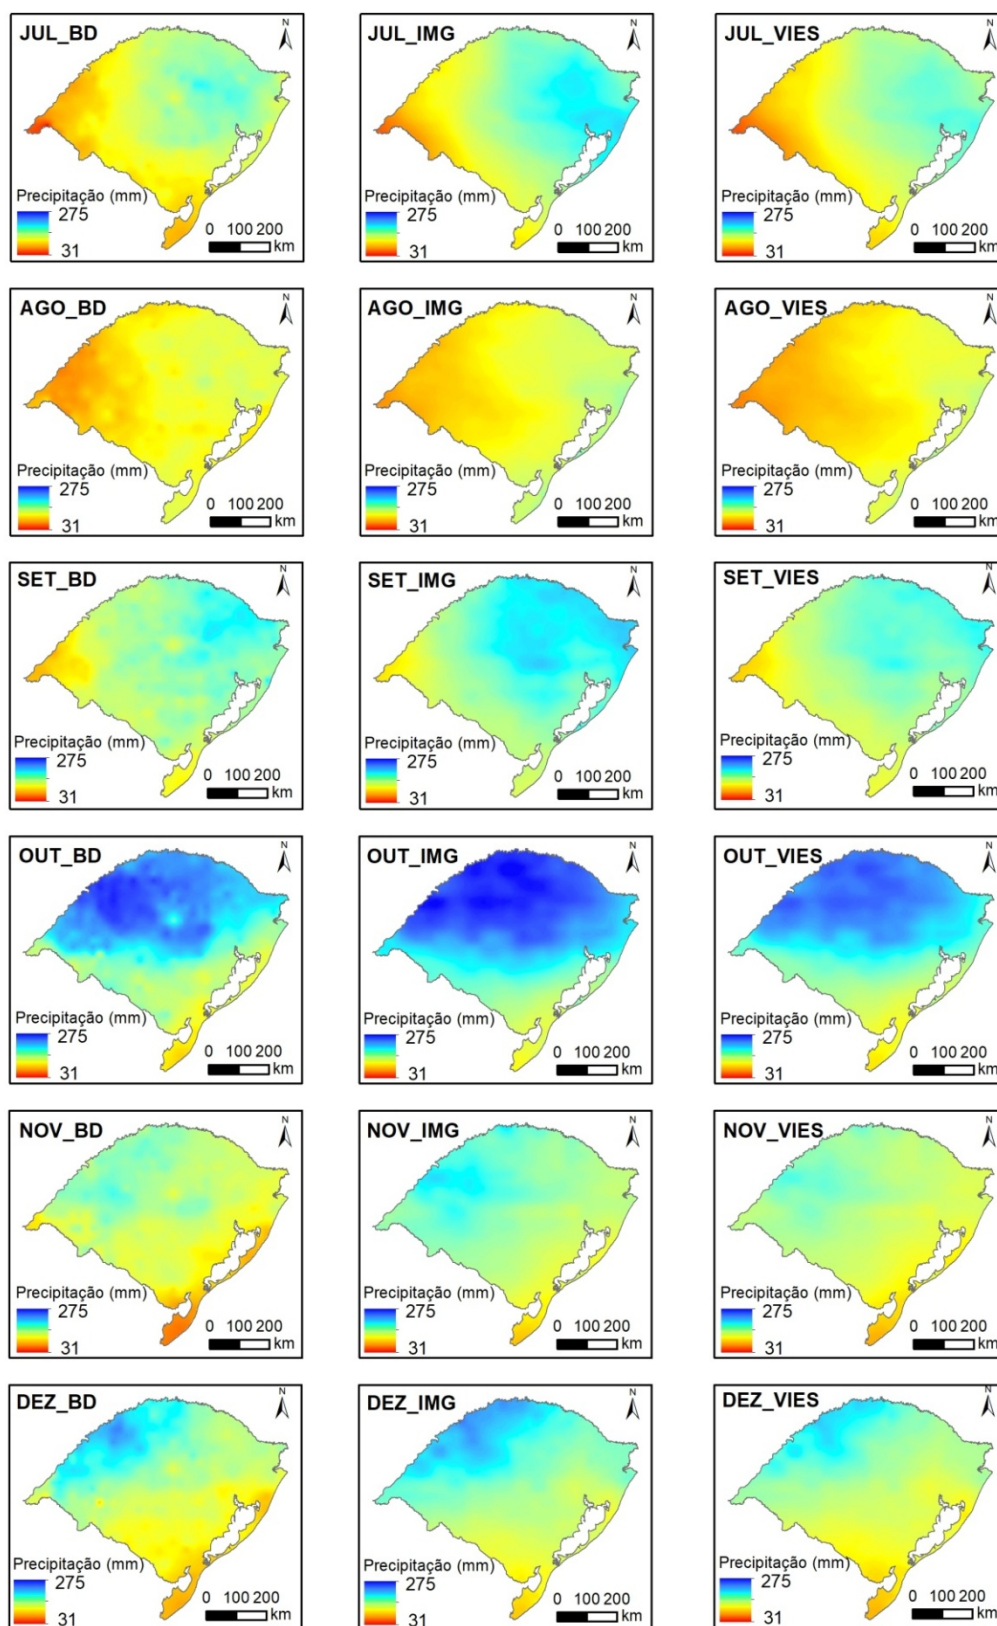


Figura 11 - Variação da distribuição espacial da precipitação média, entre Janeiro e Junho, do Banco de Dados (BD), do 3IMERGM (IMG) e do 3IMERGM com Viés corrigido (VIES).



Fonte: Elaboração própria.

Figura 12. Variação da distribuição espacial da precipitação média, entre Julho e Dezembro, do Banco de Dados (BD), do 3IMERGM (IMG) e do 3IMERGM com Viés corrigido (VIES).



Fonte: Elaboração própria.

### 3.3 Diferenças

Para comparar os dois produtos, o mapa de diferença (Fig. 13), apresenta a diferença simples em relação ao banco de dados e o 3IMERGM, e a diferença do banco de dados e o 3IMERGM com Viés corrigido.

Espacialmente, os meses analisados apresentaram regiões com: (a) maior diferença positiva, o 3IMERGM subestima os dados em relação ao banco de dados; (b) maior diferença negativa, o 3IMERGM superestima os dados em relação ao banco de dados; (c) diferença nula, quando 3IMERGM e banco de dados possuem os mesmos valores de precipitação.

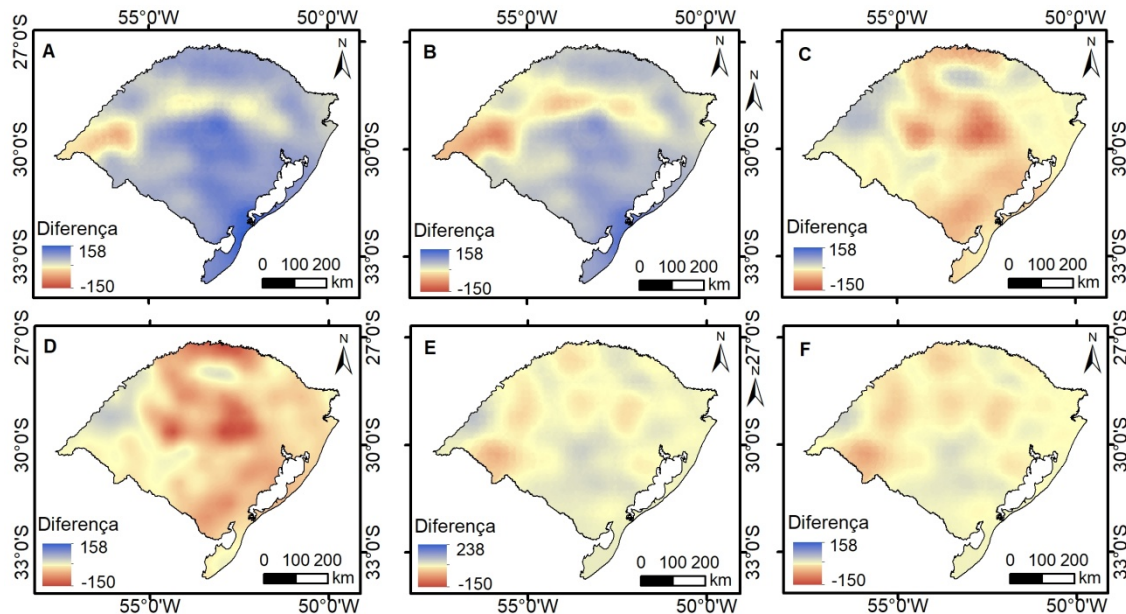
A distribuição espacial da diferença entre a precipitação do banco de dados (BD) e do produto 3IMERGM, Fig. 13, destaca os meses de Dezembro/12, Junho/14 e Dezembro/05. Na Fig. 13A (Dezembro/2012) o 3IMERGM subestima os dados de precipitação em praticamente todas as regiões, com exceção da região oeste, com diferença positiva.

No entanto, na diferença entre o 3IMERGM com Viés corrigido e o banco de dados (Fig. 13B), algumas regiões superestimaram os dados, o que supõe uma menor diferença entre os produtos.

O produto 3IMERGM, Fig. 10C (Junho/2014), superestima o banco de dados. Com a correção do Viés (Fig. 13D), a superestimativa aumenta, acentuando as diferenças envolvidas na estimativa de precipitação desse mês.

Na Fig. 13E (Dezembro/2005) boa parte da espacialização apresenta diferença próxima de zero, o que seria o ideal. Nesse caso, a correção do Viés (Fig. 13F) faz com que o produto 3IMERGM passe a superestimar algumas áreas.

Figura 13 - Distribuição espacial da Diferença entre a precipitação do Banco de Dados (BD) e do produto 3IMERGM: **A)** Diferença entre BD e 3IMERGM em Dezembro/12; **B)** Diferença entre BD e 3IMERGM com Viés Corrigido em Dezembro/12; **C)** Diferença entre BD e 3IMERGM em Junho/14; **D)** Diferença entre BD e 3IMERGM com Viés Corrigido em Junho/14; **E)** Diferença entre BD e 3IMERGM em Dezembro/05; **F)** Diferença entre BD e 3IMERGM com Viés Corrigido em Dezembro/05.

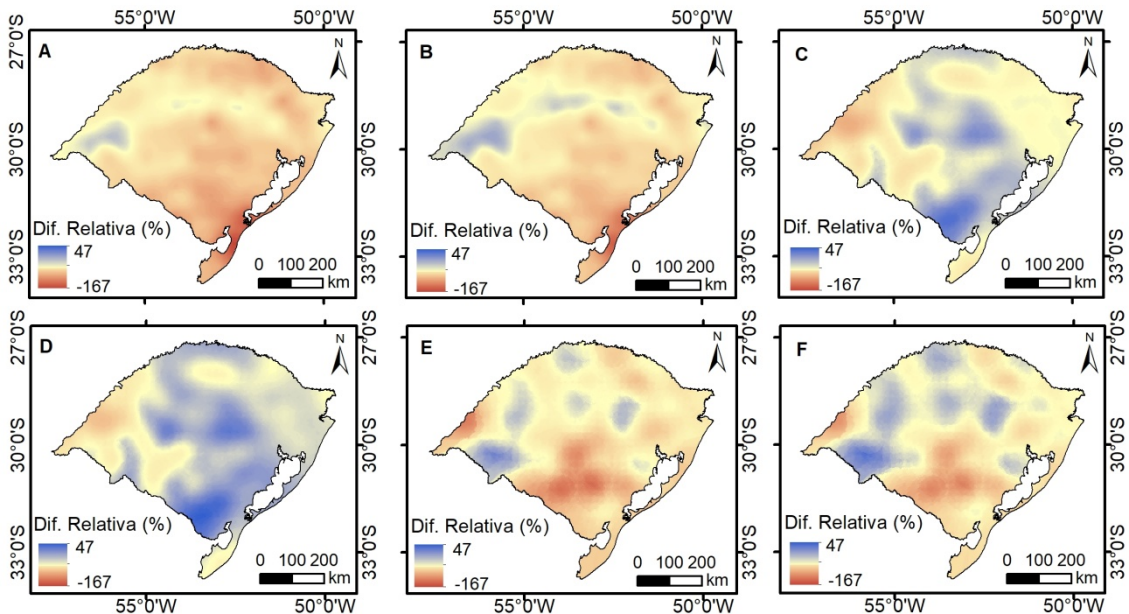


Fonte: Elaboração própria.

A espacialização da Diferença Relativa (DR) (Figura 14) mostra os pontos de maior discrepância entre os dados. Na Figura 14A (Dezembro/2012) a Diferença Relativa na região Sul chega a -167%. Ou seja, o 3IMERGM subestimou em 167% o valor da precipitação. Na região Oeste, a DR chega a 45%. Com a Correção do Viés (Figura 14B) em boa parte do estado, os valores são mais próximos de zero.

A DR na Figura 14C permanece alta, no entanto, com valores menos discrepantes que na Figura 14A, e oscilam entre 45% e -45%. Ainda assim, ocorrem diferenças entre os dois produtos, de modo que a DR não é uniforme no estado. As Figuras 14E e 14F (Dezembro/2005) apresentam pouca discrepância entre o produto 3IMERGM e o Banco de Dados. A DR ressalta que o 3IMERGM subestima o Banco de Dados na região Centro-Sul do estado e superestima em pontos da região Centro-Norte.

Figura 14. Distribuição espacial da Diferença Relativa entre a precipitação do Banco de Dados (BD) e do produto 3IMERGM: **A)** Diferença Relativa entre BD e 3IMERGM em Dezembro/12; **B)** Diferença Relativa entre BD e 3IMERGM com Viés Corrigido em Dezembro/12; **C)** Diferença Relativa entre BD e 3IMERGM em Junho/14; **D)** Diferença Relativa entre BD e 3IMERGM com Viés Corrigido em Junho/14; **E)** Diferença entre BD e 3IMERGM em Dezembro/05; **F)** Diferença Relativa entre BD e 3IMERGM com Viés Corrigido, em Dezembro/05.



Fonte: Elaboração própria.

#### 4 Discussão

Entre os produtos para estimar a precipitação global por satélites, se destacam o TRMM e o GPM. Nesse estudo, a escolha do produto GPM se deu com base em estudos que o apontam como superiores ao TRMM (ZHANG *et al.*, 2018; JABER, 2020; SOTO ALVAREZ *et al.*, 2020).

No Rio Grande do Sul a precipitação média anual é superior a 1000 mm, e chega a 2000 mm em algumas regiões. Mas no estado, ou em partes dele, também são recorrentes períodos de estiagem (BRAZ *et al.*, 2017), segundo Kulman *et al.* (2014) a maior ocorrência de estiagem concentra-se na porção sudoeste do Estado.

Segundo Lu *et al.* (2008), há maior dificuldade de estimativa de precipitação por satélites em regiões áridas. Embora o estado não se enquadre nessa classificação,

foi nos meses mais secos como, por exemplo, abril/2009 que ocorreram as maiores divergências entre medições *in situ* e de satélite.

Em relação a comparação entre os produtos para estimar a precipitação, Zhang *et al.* (2018), destacam que os produtos GPM superestimam menos os dados de precipitação em várias escalas de tempo. Jaber (2020), comparando produtos TRMM e GPM conclui que o GPM IMERG é superior em relação ao seu predecessor. Para esse autor, a necessidade de correção do Viés é menor nos produtos IMERG. Para Soto Alvarez *et al.* (2020) os produtos 3IMERGM apresentaram respostas mais precisas que o TRMM.

Tan e Duan (2017) destacam os bons resultados obtidos pelo satélite GPM, e a superioridade dos produtos IMERG em relação a outros satélites, apesar de superestimar eventos de precipitação moderada (1 - 20 mm/dia) e subestimar eventos de precipitação leve (0 - 0,1mm/dia) e forte (>20 mm/dia).

Ao comparar dados de satélite GPM e TRMM, Serrão *et al.* (2016) observaram que nos períodos menos chuvosos ocorreram as maiores variações. A correlação para o mês de abril/2009, por exemplo, foi a mais baixa do período analisado, e diversas células apresentaram valores baixos de precipitação. No entanto, em alguns pontos do estado, os valores chegaram a 60 mm acumulados no mês.

Quando analisados mensalmente, as maiores correlações ocorreram nos meses com grandes acumulados de precipitação, por exemplo: julho/2009 (0,95), agosto/2013 (0,97) e Junho/2015 (0,96). Li *et al.* (2019) obtiveram coeficientes de correlação de Pearson entre 0,91 e 0,99, durante eventos extremos de precipitação. O que permite o uso de estimativas baseadas no GPM para simulação de eventos extremos de precipitação (LI *et al.*, 2019; GETIRANA *et al.*, 2020; LIU *et al.*, 2020).

Segundo Saouabe *et al.* (2020) em termos de capacidade de detecção de precipitação, o IMERG-E tem melhor desempenho na reprodução do diferentes estatísticas de precipitação. E que estimativas de precipitação GPM-IMERG-E podem ser utilizadas para modelagem de inundações em regiões semiáridas, e fornecem uma alternativa valiosa para medições de precipitação.

Em estudo comparativo entre 3IMERGM e medições *in situ*, Lu *et al.* (2018) encontraram correlação de 0,68. No nosso estudo, a correlação média foi de 0,76,

mas devido a ocorrência de alguns meses mais secos, com precipitação esparsa e irregular, a média da correlação diminuiu.

A precipitação estimada por satélite apresenta uma tendência de superestimação em relação aos dados obtidos *in situ* (ROZANTE *et al.*, 2010; PEREIRA *et al.*, 2013; FERRÃO *et al.*, 2016; THANG *et al.*, 2016; LU *et al.*, 2018).

No estado do Rio Grande do Sul, a média mensal foi superestimada em todos os meses. Ao estimar dados meteorológicos Moreira *et al.* (2017) avaliaram que o uso do TRMM, do ERA Interim e de dados observados nas estações meteorológicas são aceitáveis e consistentes e indicam o seu uso como alternativa para minimizar a ausência de informações sobre precipitação pluvial e temperatura do ar obtidas em rede de estações de superfície. Assim, podemos considerar, conforme Soto Alvarez *et al.* (2020) que dados de precipitação de satélites são fontes de dados fundamentais para zonas remotas ou áreas de difícil acesso para instalar estações meteorológicas.

## 5 Considerações finais

A comparação entre os dados de precipitação da Missão GPM, a partir do produto 3IMERGM, com dados de estações pluviométricas organizados em um Banco de Dados espacial para o estado do Rio Grande do Sul, mostrou que dos 198 meses analisados, 186 meses apresentaram coeficiente superior a 0,5. Desses, 175 (88%) apresentaram coeficiente superior a 0,75, o que indica que a precipitação mensal estimada pelo produto IMERG, tem boa correlação linear com a precipitação mensal interpolada a partir de dados de estações pluviométricas.

Os dados de precipitação obtidos pelo produto 3IMERGM se mostraram compatíveis com o Banco de Dados, mas superestimaram os valores em 9,15%. No período entre 2001 e 2016, dos 198 meses analisados, a correlação entre o Banco de Dados e os produtos 3IMERGM foi superior a 0,5 em 93,9%. Desses, 88% apresentaram correlação superior a 0,75. Os meses mais secos da série destacam-se em relação aos menores valores de correlação. Os maiores valores de correlação foram encontrados em meses com grandes acumulados de chuva em uma região específica.

Os dados do produto 3IMERGM tiveram médias, mensais e anuais, muito semelhantes ao Banco de Dados. Embora os mapas de Diferença reforcem discrepâncias pontuais, os dados médios permitem o uso do sensoriamento remoto de precipitação para a correção de eventuais falhas no processo de aquisição dos dados medidos em solo.

Mesmo com divergências em meses específicos, o padrão e a normal climatológica, estimados pelos produtos de Sensoriamento Remoto, apresentam resultados compatíveis com o Banco de Dados, se mostrando uma alternativa viável para locais em que há escassez de dados.

## REFERÊNCIAS

BEAUFORT, A.; GIBIER, F.; PALANY, P. Assessment and correction of three satellite rainfall estimate products for improving flood prevention in French Guiana. **International Journal of Remote Sensing**, v. 40, n. 1, p. 171-196, 2018.

BERLATO, M.A. et al. Associação entre *El Niño* oscilação Sul e a produtividade de milho no Estado do Rio Grande do Sul. **Pesquisa Agropecuária Brasileira**, v.40, p.423-432, 2005.

BIGG, G.R.; Kriging and intraregional rainfall variability in England. **International Journal of Climatology** v.11, p.663–675, 1991.

BRAZ, D.F.; PINTO, L.B.; CAMPOS, C.R.J. ocorrência de eventos severos em regiões agrícolas do Rio Grande do Sul. São Paulo, UNESP, **Geociências**, v. 36, n. 1, p. 89-99, 2017.

CONTI, G.N. **Estimativa da precipitação através de técnicas de sensoriamento remoto: Estudo de caso para o estado do Rio Grande do Sul**. Dissertação de mestrado, IPH-UFRGS, 2002.

COLLISCHONN, W. **Simulação Hidrológica de Grandes Bacias**. Tese (Doutorado em Engenharia). Programa de Pós-Graduação em Engenharia de Recursos Hídricos e Saneamento Ambiental, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2001.

COLLISCHONN, B.; ALLASIA, D. Desempenho do satélite TRMM na estimativa de precipitação sobre a bacia do Paraguai superior. **Revista Brasileira de Cartografia**, v.59, p. 93-99, 2007.

FONTANA, D.C.; BERLATO, M.A. Influência do *El Niño* Oscilação Sul sobre a precipitação do Estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v.5, n.1, p.127-132, 1997.



FREITAS, E.S. **Avaliação do uso do IMERG (Integrated Multi-Satellite Retrievals for GPM) para determinação de eventos chuvosos e suas propriedades no Brasil: Uma análise na escala subsidiária.** Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Federal da Paraíba, João Pessoa, 2019.

GADELHA, A.N. **Análise da Missão GPM (Global Precipitation Measurement) na estimativa da precipitação sobre o território brasileiro.** Dissertação (Mestrado em Engenharia Civil e Ambiental). Universidade Federal da Paraíba, João Pessoa, 2018.

GETIRANA, A.; KIRSCHBAUM, D.; MANDARINO, F.; OTTONI, M.; KHAN, S.; KRISTI ARSENAULT, K. Potential of GPM IMERG Precipitation Estimates to Monitor Natural Disaster Triggers in Urban Areas: The Case of Rio de Janeiro, Brazil. **Remote Sens.**, 2020, 12, 4095; doi:10.3390/rs12244095.

GOOVAERTS, P. **Geostatistics for natural resources evaluation.** New York: Oxford University, 496 p., 1997.

HOU, A.Y., and Coauthors, 2014: The Global Precipitation Measurement mission. **Bull. Amer. Meteor. Soc.**, v. 95, p. 701-722, 2014.

HUFFMAN, G.J.; STOCKER E.F.; BOLVIN, D.T.; NELKIN, E.J.; TAN, J. GPM IMERG Final Precipitation L3 1 month 0.1 degree x 0.1 degree V06, Greenbelt, MD, Goddard. **Earth Sciences Data and Information Services Center (GES DISC)**, 2019.

HUFFMAN, G.J.; BOLVIN, D.T.; NELKIN, E.J.; TAN, J. Integrated Multi-satellite Retrievals for GPM (IMERG). **Technical Documentation.** Tech Doc., NASA GSFC, 47 p, 2020.

JABER, S.M. Comparative evaluation of statistically downscaling Tropical Rainfall Measuring Mission (TRMM) and Global Precipitation Measurement (GPM) mission precipitation data: evidence from a typical semi-arid to arid environment. **Spat. Inf. Res.**, 2020.

KIDD, C.A.; BECKER, G.J.; HUFFMAN, C.L.; MULLER, P.; JOE, G. Skofronick-Jackson, D. B. Kirschbaum, 2017: So, how much of the Earth's surface is covered by rain gauges? **Bull. Amer. Meteor. Soc.**, v. 98, p. 69-78, 2017.

KIRSCHBAUM, D.B.; PATEL, K. Precipitation data key to food security and public health. **Eos, Trans. Amer. Geophys. Union**, v. 97, 2016.

KULMAN, D.; REIS, J.T.; SOUZA, A. C.; PIRES, C.A.F.; SAUSEN, T.M. Ocorrência de Estiagem no Rio Grande do Sul no Período de 1981 à 2011. **Ciência e Natura**, v. 36 n. 3, p. 441-449, 2014.

KUMMEROW, C.; SIMPSON, J.; THIELE, O.; BARNES, W.; CHANG, A.T.C.; STOCKER, E.; ADLER, R.F.; HOU, A.; KAKAR, R.; WENTZ, F.; ASHCROFT, P.; KOZU, T.; HONG, Y.; OKAMOTO, K.; IGUCHI, T.; KUROIWA, H.; IM, E.; HADDAD, Z.; HUFFMAN, G.; FERRIER, B.; OLSON, W.S.; ZIPSER, E.; SMITH, E.A.; WILHEIT, T.T.; NORTH, G.; KRISHNAMURTI, T.; NAKAMURA, K. The status of the

Tropical Rainfall Measuring Mission (TRMM) after two years in orbit. **Journal of Applied Meteorology**, v. 39, n. 12, p. 1965-1982, 2000.

LELIS, L.C.S.; BOSQUILIA, R.W.D.; DUARTE, S.N. Assessment of Precipitation Data Generated by GPM and TRMM Satellites. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 153-163, 2018.

LIU, C.; ZIPSER, E. The global distribution of largest, deepest, and most intense precipitation systems. **Geophys Res Lett.** v. 42, n. 9, p. 3591–3595, 2015.

LIU, J.; JUAN DU, J.; YANG, Y.; WANG, Y. Evaluating extreme precipitation estimations based on the GPM IMERG products over the Yangtze River Basin, China. *Geomatics, Natural Hazards and Risk*, v.11, n.1, p. 601-618, 2020.

LU, X.; WEI, M.; TANG, G.; ZHANG, Y. Evaluation and correction of the TRMM 3B43V7 and GPM 3IMERGM satellite precipitation products by use of ground-based data over Xinjiang, China. *Environ Earth Sci* **77**, 209 (2018).

LU, X.; TANG, G.; WANG, X.; LIU, Y.; JIA, L.; XIE, G.; ... ZHANG, Y. *Correcting GPM IMERG precipitation data over the Tianshan Mountains in China. Journal of Hydrology*, 575, p.1239-1252, 2019.

MOREIRA, A; FONTANA, D.C.; KUPLICH, T.M.; CARDOSO, M.A. Dados meteorológicos estimados em condições de clima subtropical e a relação com Índices de vegetação. *Revista Brasileira de Cartografia*, v. 69, n.6, p. 1075-1091, 2017.

OLIVEIRA, R. et al. Characteristics and diurnal cycle of GPM rainfall estimates over the Central Amazon region. **Remote Sensing**, v. 8, n. 7, 2016.

OLIVEIRA, F.H.P. Caracterização das diferenças entre precipitações estimadas por satélite e obtidas por pluviômetros. **Tese (Doutorado em Saneamento, Meio ambiente e Recursos Hídricos)**, Escola de Engenharia da UFMG, 134 p., 2019.

PEREIRA, G.; SILVA, M.E.S.; MORAES, E.C.; CARDOZO, F.S. Avaliação dos dados de precipitação estimados pelo satélite TRMM para o Brasil. **Revista Brasileira de Recursos Hídricos**, v. 18, n. 3, p. 139-148, 2013.

PRAKASH, S.; MITRA, A.K.; PAI, D.; AGHAKOUCHAK, A. From TRMM to GPM: How well can heavy rainfall be detected from space? **Adv. Water Resour**, v. 88, p. 1-7, 2016.

ROZANTE, J.R.; MOREIRA, D.S.; GONÇALVES, L.G.G.; VILA, D. Combining TRMM and surface observation of precipitation: technique and validation over South America. **Weather and Forecasting**, v. 25, p. 885-894, 2010.

ROZANTE, J. et al. Evaluation of TRMM/GPM Blended Daily Products over Brazil. **Remote Sensing**, v. 10, n. 6, p. 882, 2018.

SERRÃO, E.A.O.; WANZELER, R.T.S.; SANTOS, C.A.; GONÇALVES, L.J.M.; LIMA, A.M.M.; ROCHA, E.J.P. Avaliação Estatística entre as estimativas de precipitação da

constelação GPM com Satélite TRMM: uma análise a bacia hidrográfica do rio Solimões. **Revista Brasileira de Climatologia**, v.18, p. 256-275, 2016.

SAOUABE, T.; EL MAHDI EL KHALKI, M. E.; SAIDI, M E.M.; NAJMI, A.; HADRI, A.; RACHIDI, S.; JADOUD, M.; TRAMBLAY, Y. Evaluation of the GPM-IMERG Precipitation Product for Flood Modeling in a Semi-Arid Mountainous Basin in Morocco. *Water*, v. 12, 2516, 2020. doi:10.3390/w12092516.

SIUKI, S.K.; SAGHAFIAN, B.; MOAZAMI, S. Comprehensive evaluation of 3-hourly TRMM and half-hourly GPM-IMERG satellite precipitation products. **International Journal of Remote Sensing**, v. 38, n. 2, p. 558-571, 2016.

SOTO-ALVAREZ, M.; ALCAYAGA, H.; ALARCON, V.; CAAMAÑO, D.; PALMA, S.; ESCANILLA, R. Evaluation of products 3B42 v7 and 3IMERG for the hydroclimatic regions of Chile. **Journal of South America Earth Sciences**, v. 104, 2020.

STEPHENS, G.L.; KUMMEROW, C.D. The Remote Sensing of Clouds and Precipitation from Space: A Review. **Journal of The Atmospheric Sciences**, v. 64, p. 3742-3765, 2007.

#### 4. CONSIDERAÇÕES FINAIS

O objetivo desta Tese foi criar um Banco de Dados espacial de precipitação para o estado do Rio Grande do Sul, tendo como base as séries históricas de precipitação no período entre 1987 e 2016, que possibilite a consulta e a obtenção de séries temporais e de índices de precipitação a partir de coordenadas e por unidade territorial (bacia hidrográfica ou município).

Essa abordagem representa uma evolução em relação ao sistema adotado e amplamente utilizado até esse momento, no qual há a necessidade de aquisição pontual dos dados, por meio dos sistemas da ANA e do INMET, além de uma série de pós-processamentos para uso em aplicações como modelagem hidrológica.

Diferentes áreas do conhecimento podem ser beneficiadas com o Banco de Dados estruturado nessa tese. Análises de desastres, sejam eventos de inundação, ou secas e estiagens, terão um ganho significativo, já que a base de dados permite o *download*, para períodos ou mesmo áreas específicas.

Estudos de caracterização do clima, seja de abrangência local ou regional, também poderão ser desenvolvidos de modo mais célere, já que no Banco de Dados também estão disponibilizadas as normais de precipitação. Dessa forma, tanto sub-bacias como municípios com área menor que 50 km<sup>2</sup> terão, ao menos, uma célula com 30 anos de dados de precipitação disponíveis. Por outro lado, o acesso ao Banco de Dados permite, também, estudos de grandes regiões hidrográficas e de municípios com maior área.

Entre as melhoras previstas para o Banco de Dados, destacam-se a possibilidade de ampliação da série temporal disponível, e o cálculo de outros índices pluviométricos. Atualmente, o banco está programado para que o *download* tenha período mínimo de um ano, no entanto, posteriormente deverá ser ajustado para períodos menores.

A consulta aos dados de precipitação por bacia hidrográfica, unidade territorial ou coordenada geográfica, nesse momento, deverá ser acessada única e exclusivamente pelo *software* MATLAB. Futuramente, está previsto que o banco seja divulgado em linguagem de computação aberta.

## FINANCIAMENTO

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

## REFERÊNCIAS

AB'SABER, A.N. **O Relevo Brasileiro e seus Problemas**. In: Brasil a Terra e o Homem, vol. 1, cap. III, Editora Nacional, São Paulo, 1964.

ALBUQUERQUE, T.M.A. **Estudo dos processos de gestão de seca**: Aplicação no estado do Rio Grande do Sul. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

ANA - Agência Nacional de Águas. **Sistema de Informações Hidrológicas**. Disponível em: <<http://www2.ana.gov.br/Paginas/servicos/informacoeshidrologicas/redehidro.aspx>> Acesso em: 22 dez. 2017.

ANDRIOTTI, J.L.S. **Fundamentos de Estatística e Geoestatística**. Ed. UNISINOS: São Leopoldo. 2ª reimpressão, 166 p., 2005.

ARSEGO, D.A.; FERRAZ, S.E.T.; STRECK, N.A.; CARDOSO, A.O.; ZANON, A.J. Estudo do impacto de diferentes índices associados ao El Niño Oscilação Sul na produtividade de soja no Rio Grande do Sul. **Ciência e Natura**, v. 40, p. 82-87, 2018.

ASSAD, E.D.; EVANGELISTA, B.A. Análise freqüencial da precipitação Pluviométrica. In: ASSAD, E.D. *et al.*, **Chuva nos cerrados: análise e espacialização**. Brasília: EMBRAPA-SPI, Cap. II, p. 25-41, 1994.

BÁRDOSSY, A.; PEGRAM, G. Infilling missing precipitation records - A comparison of a new copula-based method with other techniques. **J. Hídr.**, v. 519, Part A, p. 1162-1170, 2014.

BEAUFORT, A.; GIBIER, F.; PALANY, P. Assessment and correction of three satellite rainfall estimate products for improving flood prevention in French Guiana. *International Journal of Remote Sensing*, v. 40, n. 1, p. 171-196, 2018.

BERLATO, M.A.; FONTANA, D.C. **El Niño e La Niña**: impactos no clima, na vegetação e na agricultura do Rio Grande do Sul; aplicações de previsões climáticas na agricultura. Porto Alegre: Editora da UFRGS, 2003.

BERLATO, M.A.; FARENZENA, H.; FONTANA, D.C. Associação entre El Niño Oscilação Sul e a produtividade do milho no Estado do Rio Grande do Sul. **Pesq. agropec. bras.**, v. 40, n. 5, p. 423-432, 2005.

BERTONI, J.C.; TUCCI, C.E.M. Precipitação. In.: TUCCI, C.E.M. **Hidrologia: Ciência e Aplicação**. Porto Alegre: UFRGS, p. 177-241, 2007.

BIER, A.A; FERRAZ, S.E.T. Comparação de metodologias de preenchimento de falhas em dados meteorológicos para estações no Sul do Brasil. **Rev. Bras. Met**, v. 32, n. 2, p. 215-226, 2017.

BONFANTE, A., VENTURA, T., OLIVEIRA, A., MARQUES, H., OLIVEIRA, R., MARTINS, C., FIGUEIREDO, J. Uma abordagem computacional para preenchimento de falhas em dados micro meteorológicos. **Brazilian Journal of Environmental Sciences**, v. 27, p. 61-70, 2013.

BRASIL. Ministério da Integração Nacional. Secretaria Nacional de Defesa Civil. Universidade Federal do Rio Grande do Sul. Centro Universitário de Estudos e Pesquisas sobre Desastres (CEPED). **Capacitação em Gestão de Riscos**. 2ª ed. Porto Alegre, 2016.

BRITTO, F.; BARLETTA, R.; MENDONÇA, M. Regionalização sazonal e mensal da precipitação pluvial máxima no estado do Rio Grande do Sul. **Revista Brasileira de Climatologia**, v. 2, n. 2, p. 35-51, 2006.

BRITTO, F.P.; BARLETTA, R.; MENDONÇA, M. Variabilidade Espacial e Temporal Da Precipitação Pluvial No Rio Grande Do Sul: Influência Do Fenômeno El Niño Oscilação Sul. **Revista Brasileira de Climatologia**, v. 3, p. 37-48, 2008.

BRUBACHER, J. P.; OLIVEIRA, G. G.; GUASSELLI, L. A. Identificação e análise de eventos extremos de precipitação na bacia hidrográfica do rio dos Sinos/RS. In: CONGRESSO BRASILEIRO SOBRE DESASTRES NATURAIS, Rio Claro. **Anais...**, 2012.

CALDEIRA, T.L.; BESKOW, S.; MELLO, C.R.; FARIA, L.C.; SOUZA, M.R.; GUEDES, H.A.S. 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.

CARDOSO, C.S. **Abrangência e persistência de eventos extremos de precipitação no sul do Brasil**: El Niño Oscilação Sul e padrões atmosféricos. Tese (Doutorado em Geografia), Universidade Federal de Santa Catarina, Florianópolis, 2017.

CARVALHO, A. C. A. **Caracterização da rede pluviométrica do Estado de Sergipe e aplicação das redes neurais para preenchimento de falhas**. Dissertação (Mestrado em Desenvolvimento e Meio Ambiente) - Universidade Federal do Sergipe, Aracaju, 2007.

CASTRO, F.; PEZZOPANE, J.E.M.; CECÍLIO, R.A.; PEZZOPANE, J.R.M.; XAVIER, A.C. Avaliação do desempenho dos diferentes métodos de interpoladores para

parâmetros do balanço hídrico climatológico. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 14, n. 8, p. 871-880, 2010.

CERA, J.C.; FERRAZ, S.E.T. Variações climáticas na precipitação no sul do Brasil no clima presente e futuro. **Revista Brasileira de Meteorologia**, v. 30, n. 1, p. 81-88, 2015.

CHEN, Y.; EBERT, E.E.; WALSH, K.J.; DAVIDSON, N.E. Evaluation of TMPA 3B42 daily precipitation estimates of tropical cyclone rainfall over Australia. **J. Geophys. Res.: Atmospheres**, v. 118, n. 21, p. 11966-11978, 2013.

COLLISCHONN, B.; ALLASIA, D.; COLLISCHONN, W.; TUCCI, C.E.M. Desempenho do satélite TRMM na estimativa de precipitação sobre a bacia do Paraguai Superior. **Rev. Bras. Cart.**, v. 59, n. 1, p. 93-99, 2007.

CONTI, G.N. **Estimativas de precipitação através de técnicas de sensoriamento remoto**: Estudo de caso para o estado do Rio Grande do Sul. Dissertação (Mestrado em Recursos Hídricos) – Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2002.

CORREIA, T.P.; DOHLER, R.E.; DAMBROZ, C.S.; BINOTI, H.B. Aplicação de redes neurais artificiais no preenchimento de falhas de precipitação mensal na região serrana do Espírito Santo. **Revista Geociências**, v. 35, n. 4, p. 560-567, 2016.

CUNHA, G.R.; HAAS, J.C.; DALMAGO, G.A.; PASINATO, A. Perda de rendimento potencial em soja no Rio Grande do Sul por deficiência hídrica. **Revista Brasileira de Agrometeorologia**, v. 6, n. 1, p. 111-119, 1998.

CUNHA, L. K. **Sistemas avançados de previsão hidrológica e operação hidráulica em tempo real**. Dissertação (Mestrado em Engenharia de Recursos Hídricos e Ambiental) – Universidade Federal do Paraná, Curitiba, 2004.

CURTIS, M.L.L.; MORENO, J.A.; THOFERN, H.A. Bacias Hidrográficas do Rio Grande do Sul. **Boletim Geográfico do Rio Grande do Sul**, n. 9-10, p. 60-62, 1959.

DE ROO, A.P.J.; JETTEN, V.G. Calibrating and validating the LISEM model for two data sets from the Netherlands and South Africa. **Catena**, v. 37, p. 477-493, 1999.

DEPINÉ, H.; CASTRO, N.M.R.; PINHEIRO, A.; PEDROLO, O. Preenchimento de falhas de dados horários de precipitação utilizando redes neurais artificiais. **Rev. bras. recur. hídricos**, v. 19, n. 1, p. 51-63, 2014.

DIAZ, A.E.; STUDZINSKI, C.D.; MECHOSO, C.R. Relationships between precipitation anomalies in Uruguay and Southern Brazil and sea Surface temperature in the Pacific and Atlantic Oceans. **Journal of Climate**, v. 11, n. 2, p. 251-271, 1998.

FANG, I; YANG, W.; LUAN, Y.; DU, J.; LIN, A.; ZHAO, L. Evaluation of the TRMM 3B42 and GPM IMERG products for extreme precipitation analysis over China, **Atmospheric Research**, v. 223, p. 24-38, 2019.

FARIAS, O.G. de; FRANCISCO, C.N.; SENNA, M.C.A. Avaliação de métodos de interpolação espacial aplicados à pluviosidade em região montanhosa no litoral sul

do estado Rio de Janeiro. **Revista Brasileira de Climatologia**, v. 21, p. 172-185, 2017.

FERNANDEZ, M.N. **Preenchimento de Falhas em Séries Temporais**. Dissertação (Mestrado em Engenharia Oceânica) - Fundação Federal Universidade de Rio Grande, Rio Grande, 2007.

FERRÃO, M.F.; MELLO, C.; BORIN, A.; MARETTO, A.; POPPI, R.J. LS-SVM: Uma nova ferramenta quimiométrica para regressão multivariada, comparação de modelos de regressão LS-SVM e PLS na quantificação de adulterantes em leite em pó empregando NIR. **Revista Química Nova**, v. 30, n. 4, p. 852-859, 2007.

FISHER, B. L. Climatological validation of TRMM TMI and PR monthly rain products over Oklahoma. **Journal of Applied Meteorology**, v. 43, n. 3, p. 519-535, 2004.

FONSECA, J. S.; MARTINS, G. A.; TOLEDO, G. L. **Estatística Aplicada**. 2. ed., 267 p., 2012.

FONTANA, D.C.; BERLATO, M.A. A influência do El Niño Oscilação Sul sobre a precipitação pluvial no estado do Rio Grande do Sul. **Revista Brasileira de Agrometeorologia**, v. 5, n. 1, p. 127-132, 1997.

FREITAS, G.M.; PAPA, J.P.; AVILA, A.M.H.; FALCÃO, A.X.; PINTO, H.S. Estimativa de ocorrência de precipitação em áreas agrícolas utilizando floresta de caminhos ótimos. **Rev. Bras. Met.**, v. 25, n. 1, p. 13-23, 2010.

GADELHA, A.N. **Análise da Missão GPM (Global Precipitation Measurement) na estimativa da precipitação sobre o território brasileiro**. Dissertação (Mestrado em Engenharia Civil e Ambiental) - Universidade Federal da Paraíba, João Pessoa, 2018.

GIACOMIN, G.; CARVALHO, M.B.; SANTOS, A.P.; MEDEIROS, N.C.; FERRAZ, A.S. Análise comparativa entre métodos interpoladores de modelos de superfícies. **Rev. Bras. Cart.**, v. 66, n. 6, p. 1315-1329, 2014.

GONÇALVES, J. M. S.; SANTOS, N.M. Análise das Classificações do Relevo para o Rio Grande do Sul. **Boletim Gaúcho de Geografia**, v. 13, p. 3-20, 1985.

GOOVAERTS, P. **Geostatistics for natural resources evaluation**. New York: Oxford University, 496 p., 1997.

GUARNIERI, R.A. **Emprego de Redes Neurais Artificiais e Regressão Linear Múltipla no refinamento das previsões de radiação solar do modelo ETA**. Dissertação (Mestrado em Meteorologia) - Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2006.

GUPTA, N. Artificial Neural Network. **Network and Complex Systems**, v. 3, n. 1, p. 24-28, 2013.

HERMANN, M. L. P, ROSA, R. Relevo. In: IBGE. Fundação Instituto Brasileiro de Geografia e Estatística. **Geografia do Brasil: Região Sul**. Rio de Janeiro, p. 59-83, 1990.



HUFFMAN, G. J.; ADLER, R. F.; BOLVIN, D. T.; GU, G.; NELKIN, E. J.; BOWMAN, K. P.; HONG, Y.; STOCKER, E. F.; WOLFF, D. B. The TRMM Multisatellite Precipitation Analysis (TMPA): quasi-global, multiyear, combined-sensor precipitation estimates at fine scale. **Journal of Hydrometeorology**, v. 8, p. 38-55, 2007.

IBGE. **Levantamenbto de recursos naturais**. Instituto Brasileiro de Geografia e Estatística, Rio de Janeiro, CD-ROM, 1986.

IBGE. **Censo Demográfico 2010**. Instituto Brasileiro de Geografia e Estatística, 2017.

INPE. **CLIMANÁLISE**: Número especial. São José dos Campos: INPE, 1986.

INTERGOVENMENTAL PAINEL ON CLIMATE CHANGE (IPCC). **Climate Change 2007: Impacts, Adaptation and Vulnerability**. 8th Session of Working Group II of the IPCC, Brussels, April 2007.

JABER, S.M. Comparative evaluation of statistically downscaling Tropical Rainfall Measuring Mission (TRMM) and Global Precipitation Measurement (GPM) mission precipitation data: evidence from a typical semi-arid to arid environment. **Spatial Information Research**, 2020.

JI, Y. Validation of diurnal cycle and intra-seasonal variability of TRMM Satellite Rainfall. **Piers Online**, v. 2, n. 6, p. 628-632, 2006.

KIM, J.; RYU, J.H. A Heuristic Gap Filling Method for Daily Precipitation Series. **Water Ressources Management**, v. 30, n. 7, p. 2275-2294, 2016.

KOBIYAMA, M.; MENDONÇA, M.; MORENO, D.A.; MARCELINO, I.P.V.O.; MARCELINO, E.V.; GONÇALVES, E.F.; BRAZATTI, L.L.P.; GOERL, R.F.; MOLLERI, G.S.F.; RUDORFF, F.M. **Prevenção de desastres naturais**: conceitos básicos, Ed. Organic Trading, 2006.

KUMMEROW, C. *et al.* The status of the Tropical Rainfall Measuring Mission (TRMM) after two years in orbit. **Journal of Applied Meteorology**, v. 39, n. 12, p. 1965-1982, 2000.

LAM, N.S. Spatial Interpolation Methods: A Review. **The American Cartographer**, v. 2, n. 10, p. 129-149, 1983.

LANCASTER, P., SALKAUSKAS, K. **An introduction to curve and surface fitting**. Unpublished manuscript, Division of Applied Mathematics, University of Calgary, 114 p, 1975.

LANÇA, R. Desenvolvimento de um modelo hidrológico de superfície à escala da bacia hidrográfica. **TecnoVisão**, v. 16, p. 1-10, 2004.

LANDIM, P.M.B. **Introdução aos métodos de estimação espacial para confecção de mapas**. UNESP/Rio Claro, Laboratório de Geomatématica, Texto Didático 02, 20 p., 2000.

LEIVAS, J.F.; BERLATO, M.A.; FONTANA, D.C. Risco de deficiência hídrica decendial na metade sul do Estado do Rio Grande do Sul. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 10, n. 2, p. 397-407, 2006.

LI, X.H.; ZHANG, Q.; XU, C.Y. Suitability of the TRMM satellite rainfalls in driving a distributed hydrological model for water balance computations in Xinjiang catchment, Poyang lake basin. **Journal of Hydrology**, v. 426-427, p. 28-38, 2012.

LIU, C.; ZIPSER, E. The global distribution of largest, deepest, and most intense precipitation systems. **Geophys Res Lett.** v. 42, n. 9, p. 3591–3595, 2015.

LIMA, C.A.M. Comitê de Máquinas: Uma abordagem Unificada Empregando Máquinas de Vetores de Suporte. **Tese (Doutorado em Engenharia Elétrica)** - Universidade Estadual de Campinas, Campinas, 2004.

LUCIO, P. S., CONDE, F. C., CAVALCANTI, I. F. A.; RAMOS, A. M., CARDOSO, A. O. Reconstrução de séries meteorológicas via redes neurais artificiais. In: XIV CONGRESSO BRASILEIRO DE METEOROLOGIA. Florianópolis-SC, **Anais...** 2006.

MAIER, H., DANDY, G. Neural networks for the predictions and forecasting of water resources variables: review of modeling issues and applications. **Environmental Modelling & Software**, v. 15, n. 1, p. 101-124, 2000.

MALFATTI, M.G.L.; CARDOSO, A.O.; HAMBURGUER, D.S. Modelo Empírico Linear para Previsão de Vazão de Rios na Usina Hidrelétrica de Itaipu – Bacia do Rio Paraná. **Rev. Bras. Met.**, v. 33, n. 2, p. 257-268, 2018.

MARCUZZO, F. F. N.; ANDRADE, L. R.; MELO, D. C. R. 2011. Métodos de interpolação matemática no mapeamento de chuvas do Estado do Mato Grosso. **Revista Brasileira de Geografia Física**, v. 4, n. 4, p. 793-804, 2011.

MATEUS, R.S. **Modelo Hidrológico da Bacia Hidrográfica da Represa Guarapiranga**. Dissertação (Mestrado em Geografia Física) - Programa de Pós-Graduação em Geografia Física, Faculdade de Filosofia, Letras e Ciências Humanas, Universidade de São Paulo, São Paulo, 2006.

MATZENAUER, R.; RADIN, B.; MALUF, J.R.T. O fenômeno ENOS e o regime de chuvas no Rio Grande do Sul. **Agrometeoros**, v. 25, n. 2, p. 323-331, 2017.

MATZENAUER, R.; RADIN, B.; CARGNELUTTI FILHO, A. Rendimento de grãos de soja e de milho, no Rio Grande do Sul, não difere entre eventos El Niño Oscilação Sul. **Agrometeoros**, v. 26, n. 1, p. 123-129, 2018.

MAZZINI, P.L.F.; SCHETTINI, C.A.F. Avaliação de metodologias de interpolação espacial aplicadas a dados hidrográficos costeiros quasesinóticos. **Brazilian Journal of Aquatic Science and Technology**, v. 13, n. 1, p. 53-64, 2009.

MELLO, C.R.; SILVA, A.M. Modelagem estatística da precipitação mensal e anual e no período seco para o estado de Minas Gerais. **Rev. Bras. Eng. Agríc. e Ambient.**, v. 13, n. 1, p. 68-74, 2009.

MELLO, C.R.; LIMA, J.M.; SILVA, A.M.; MELLO, J.M.; OLIVEIRA, M.S. Krigagem e Inverso do Quadrado da Distância para interpolação dos parâmetros da equação de chuvas intensas. *Sociedade Brasileira de Ciência do Solo*, v. 27, n. 5, p. 925-933, 2003.

MENEGHINI, R., T. KOZU, H. KUMAGAI, AND W. C. BONCYK. A study of rain estimation methods from space using dual-wavelength radar measurements at near-nadir incidence over ocean. *J. Atmos. Oceanic Technol.*, v. 9, 364–382, 1992.

MOREIRA, A; FONTANA, D.C.; KUPLICH, T.M.; CARDOSO, M.A. Dados meteorológicos estimados em condições de clima subtropical e a relação com Índices de vegetação. *Revista Brasileira de Cartografia*, v. 69, n.6, p. 1075-1091, 2017.

NASCIMENTO, T.S. do; SARAIVA, J.M.B.; SENNA, R.; AGUIAR, F.E.O. Preenchimento de falhas em banco de dados pluviométricos com base em dados do CPC (Climate Prediction Center): estudo de caso do rio Solimões-Amazonas. *Revista Brasileira de Climatologia*, 2009. v. 7, p. 143-158, 2009.

NIMER, E. **Geografia do Brasil: Região Sul**. Rio de Janeiro: Instituto Brasileiro de Geografia e Estatística, v. 2, p. 151-187, 1990.

OLIVEIRA, V.P.S., ZANETTI, S.S., PRUSKI, F.F. CLIMABR Parte I: Modelo para a geração de séries sintéticas de precipitação. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 9, n. 3, p. 348-355, 2005.

OLIVEIRA, G.G. **Modelos para previsão, espacialização e análise das áreas inundáveis na bacia hidrográfica do rio Caí, RS**. Dissertação (Mestrado em Sensoriamento Remoto) - Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

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.

OLIVEIRA, G.G., BRUBACHER, J.P., QUEVEDO, P.Q., GUASSELLI, L.A. Limiares de Chuva para a Ocorrência de Desastres na Bacia Hidrográfica do Rio dos Sinos, RS. In: XVII CONGRESSO BRASILEIRO DE METEOROLOGIA, Gramado-RS. **Anais...**, 2012.

PAVAN, M.; PEDRASSANI, M.; PAULA, G.M.; ROCKENBACH, A.P.; ELLI, E.F.; OLIVEIRA, D.M.; SCHIEVENIN, L.; MONTEIRO, G. Influência do fenômeno enos na produtividade da cultura da soja de 1990 a 2010 no estado do Rio Grande do Sul. In: XVIII CONGRESSO BRASILEIRO DE AGROMETEOROLOGIA, Belém-PA. **Anais...**, 2013.

PAZ, A.R. **Simulação Hidrológica de Rios com Grandes Planícies de Inundação**. Tese (Doutorado em Recursos Hídricos e Saneamento Ambiental) - Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2010.

PESSOA, M.L. (Org.) **Bacias hidrográficas do RS**. In: Atlas FEE. Porto Alegre: FEE, 2017. Disponível em: < <http://atlas.fee.tche.br/rio-grande-do-sul/territorio/bacias-hidrograficas-do-rs/> >. Acesso em: 28 de janeiro de 2021.

PORTO, R. *et al.* **Drenagem Urbana**. In: Hidrologia: ciência e aplicação. TUCCI, C. E. M. (Org). 2ª Ed., Porto Alegre, Ed. Universidade/UFRGS: ABRH. pp. 805-847, 2001.

PRAKASH, S.; MITRA, A.K.; PAI, D.; AGHAKOUCHAK, A. From TRMM to GPM: How well can heavy rainfall be detected from space? **Adv. Water Resour**, v. 88, p. 1-7, 2016.

PUCHALSKI, L.A. **Efeitos Associados ao El Niño e La Niña na Temperatura Média, Precipitação Pluvial e Déficit Hídrico no estado do Rio Grande do Sul**. Dissertação (Mestrado em Fitotecnia), Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

REICHENBACH, P.; CARDINALI, M.; DE VITA, P.; GUZZETTI, F. Regional Hydrological thresholds for landslides and floods in the Tiber River Basin (Central Italy). **Environmental Geology**, v. 35, p. 146-159, 1998.

REMACRE, A.Z.; NORMANDO, M.N.; SANCEVERO, S.S. Krigagem das proporções utilizando a krigagem da média: uma ferramenta auxiliar na modelagem de reservatórios. **Rev. Bras. Geoc.**, v. 38 (suplemento), p. 82-87, 2008.

ROSSATO, M.S. **Os Climas do Rio Grande do Sul: Variabilidade, Tendências e Tipologia**. Tese (Doutorado em Geografia) - Instituto de Geociências, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

ROZANTE, J.R.; VILA, D.A.; CHIQUETTO, J.B.; FERNANDES, A.D.A.; ALVIM, D.S. Evaluation of TRMM/GPM Blended Daily Products over Brazil. **Remote Sens.**, v. 10, n. 6, p. 882. 2018.

RUMELHART, D.E.; HINTON, G.E.; WILLIAMS, R.J. Learning representations by backpropagating errors. **Nature**, v. 323, p. 533-536, 1986.

SANCHES, F.O.; VERDUM, R.; FISCH, G. Tendência de longo prazo das chuvas diárias no sudoeste do Rio Grande do Sul: os eventos extremos e a arenização. **Revista Brasileira de Geografia Física**, v. 7, n. 6, p. 1100-1109, 2014.

SANTOS, G.G.; FIGUEIREDO, C.C. de; OLIVEIRA, L.F.C.; GRIEBELER, N.P. Intensidade-duração-frequência de chuvas para o Estado de Mato Grosso do Sul. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 13, p. 899-905, 2009.

SANTOS, D.M. **Zoneamento das Áreas Suscetíveis a Movimentos de Massa, Enxurradas e Inundações no Município de Sarques de Souza – RS**. Monografia (Graduação em Engenharia Ambiental) – Universidade do Vale do Taquari (UNIVATES), Lajeado, 2015.

SANTOS, R.M. **A influência do fenômeno El Niño Oscilação Sul em lavouras de verão no Corede Produção, Rio Grande do Sul, entre 2006 e 2016**. Monografia

(Graduação em Geografia) – Universidade Federal do Rio Grande do Sul, Porto ALEGRE, 2017.

SARTORI, M.G.B. **A Dinâmica do Clima do Rio Grande do Sul: indução empírica e conhecimento científico.** Terra Livre, São Paulo, ano 19, v.1, n. 20, p. 27 - 49, 2003.

SIBSON, R.A. Brief Description of Natural Neighbor Interpolation. In: BARNETT, V. **Interpreting Multivariate Data**, John Wiley e Sons, New York, p. 21-36, 1981.

SILVA, K. R.; PAIVA, Y. G.; CECÍLIO, R. A.; PEZZOPANE, J. E. M. Avaliação de interpoladores para a espacialização de variáveis climáticas na bacia do rio Itapemirim-ES. In: Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, p. 3141-3146, **Anais...**, 2007.

SILVA, V.S.V. **Estimativa de Precipitação Pontual em Diferentes Escalas para uso em Modelo Concentrado Chuva-Vazão.** Dissertação (Mestrado em Recursos Hídricos) - Programa de Pós-Graduação em Recursos Hídricos, Instituto de Pesquisas Hidráulicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2011.

SCHÖLKOPF, B., SMOLA, A.J. **Learning with Kernels.** MIT Press, 626 p., 2002.

SILVA LELIS, L.C.S.; BOSQUILIA, R.W.D.; DUARTE, S.N. Assessment of Precipitation Data Generated by GPM and TRMM Satellites. **Revista Brasileira de Meteorologia**, v. 33, n. 1, p. 153-163, 2018.

SILVA, M.R.S.; SANTOS, L.B.L.S.; SCOFIELD, G.B.; COTIVO, F.D. Utilização de Redes Neurais Artificiais em Alertas Hidrológicos: Estudo de Caso na Bacia do Rio Claro em Caraguatatuba, Estado de São Paulo. **Anuário do Instituto de Geociências**, v. 39, n. 1, p. 23-31, 2016.

SIUKI, S.K.; SAGHAFIAN, B.; MOAZAMI, S. Comprehensive evaluation of 3-hourly TRMM and half-hourly GPM-IMERG satellite precipitation products. **International Journal of Remote Sensing**, v. 38, n. 2, p. 558-571, 2016.

SKOFRONICK-JACKSON, G.; PETERSEN, W.; BERG, W.; KIDD, C.; STOCKER, E.; KIRSCHBAUM, D.; KAKAR, R.; BRAUN, S.; HUFFMAN, G.; IGUCHI, T.; KIRSTETTER, P.; KUMMEROW, C.; MENEGHINI, R.; OKI, R.; OLSON, W.; TAKAYABU, Y.; FURUKAWA, K.; WILHEIT, T. The Global Precipitation Measurement (GPM) mission for science and society. **Bull. Am. Meteorol. Soc.**, v. 98, p. 1679-1695, 2016.

SMITH, M.J.; GOODCHILD, M.F.; LONGLEY, A.P. **Geospatial Analysis: A comprehensive guide to principles, techniques and software tools.** , 3. ed., 516 p., 2009.

SOUZA J.L.L.L.; GOMES, T.S.; DIAS, R.S.; OLIVEIRA, G.M.A.; SANTOS, R.L. Avaliação de métodos de interpolação aplicados à espacialização das chuvas no território identidade Portal do Sertão/Bahia. XV SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, Curitiba, **Anais...**, p. 4295-4302, 2011.

SOUZA, A.; SANTOS, D.A.S.; ARISTONE, F.; KOVA-ANDRI, E.; MATASOVI, B.; PIRES, J.C.; IKEFUTI, P.V. Impacto de fatores meteorológicos sobre as concentrações de ozônio modelados por análise de séries temporais e métodos estatísticos multivariados. **Revista Holos**, v. 5, p. 2-16, 2017.

SOUZA, D.O.; LINO, J.F.L.; BERNARDES, T.; SATO, E.N.; FIRMINO, M.B.M. Padrões meteorológicos e morfológicos associados à eventos de inundação na bacia do rio uruguai: estudo de caso para o município de Uruguaiana-RS. **Revista Brasileira de Cartografia**, v. 69, n. 4, p. 621-633, 2017.

STEPHENS, G.L.; KUMMEROW, C.D. The Remote Sensing of Clouds and Precipitation from Space: A Review. **Journal of The Atmospheric Sciences**, v. 64, p. 3742-3765, 2007.

STOCKER, E.F.; ALQUAIED, F.; BILANOW, S.; JI, Y.; JONES, L. TRMM Version 8 Reprocessing Improvements and Incorporation into the GPM Data Suite. **Journal of The Atmospheric and Oceanic Technology**, v. 35, n. 6, p. 1181-1199, 2018.

STRAHLER, A. N. **Geografía Física**. Barcelona: Ediciones Omega S. A., 1984.

TANG, G.; ZENG, Z.; LONG, D.; GUO, X.; YONG, B.; ZHANG, W.; HONG, Y. Statistical and Hydrological Comparisons between TRMM and GPM Level-3 Products over a Midlatitude Basin: Is Day-1 IMERG a Good Successor for TMPA 3B42V7? **Journal of Hydrometeorology**, v. 17, n. 1, p. 121-137, 2016.

TEIXEIRA, M. S.; PRIETO, R.B. Eventos Extremos de Chuva no Estado do Rio Grande do Sul, Brasil, entre 2004 e 2013. Parte 1: Definição dos Eventos e Estatísticas. **Rev. bras. meteorol.**, v. 35, n. 1, p. 45-52, 2020.

THOMPSON, S.K. **Sampling**. Interscience Publication, New York, 343p., 1992.

TREWARTHA, G. T. **An introduction to weather and climate**. McGraw-Hill, 1943.

TUCCI, C. E. M. **Regionalização de vazão**. Porto Alegre: UFRGS, 2002.

TUCCI, C.E.M. **Inundações Urbanas**. 2007.

VALENTE, A.L.S. **Desenvolvimento de uma metodologia para planejamento urbano, utilizando técnicas de sensoriamento remoto, Modelagem Numérica do Terreno (MNT) e Sistema de Informações Geográficas (SIG)**. Dissertação (Mestrado em Sensoriamento Remoto) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 1995.

VALENTE, P.T. **Eventos extremos de precipitação no Rio Grande do Sul no Século XX a partir de dados de reanálise e registros históricos**. Dissertação (Mestrado em Geografia) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2018.

VAZ, V.B. **Avaliação do custo de risco de inundações urbanas: estudo de caso dos danos de inundação**. Dissertação (Mestrado em Planejamento Urbano e Regional) - Universidade Federal do Rio Grande do Sul, Porto Alegre, 2015.

VENTURA, T.M. **Criação de um ambiente computacional para detecção de outliers e preenchimento de falhas em dados meteorológicos**. Tese (Doutorado em Física Ambiental) - Universidade Federal do Mato Grosso, Cuiabá, 2015.

VESPUCCI, A.G.; SANTOS, J.G.R.; BAYER, M. Estações fluviométricas do estado de Goiás: qualificação dos dados hidrológicos disponíveis na base HIDROWEB/ANA. **Revista Ateliê Geográfico**, v. 10, n. 3, p. 89-108, 2016.

VIANNA, L.F.N.; PERIN, E.B.; RICCE, A.M.M.; PANDOLFO, C. Bancos de Dados Meteorológicos: Análise dos Metadados das Estações Meteorológicas no Estado de Santa Catarina, Brasil. **Rev. bras. meteorol.**, v. 32, n. 1, p. 53-64, 2017.

VILLAZÓN, M.F.; WILLEMS, P. Filling gaps and daily disaccumulation of precipitation data for rainfall-runoff model. In: **IV International Scientific Conference on Water Observation and Information Systems for Decision Support**, Ohrid, Republic of Macedonia, 2010.

VIOLA M.R.; MELLO, C.R.; ACERBI Jr., F.W.; SILVA, A.M. Modelagem hidrológica na bacia hidrográfica do Rio Aiuruoca, MG. **Rev. Bras. Eng. Agríc. Ambient**, v. 13, n. 5, p. 581-590, 2009.

WAGNER, P.D.; FIENER, P.; WILKJEN, F.; KUMAR, S.; CHNEIDER, K. Comparison and evaluation of spatial interpolation schemes for daily rainfall in data scarce regions. **J. Hydr.**, v. 464, p. 388-400, 2012.

WATSON, D. The natural neighbor series manuals and source codes. **Computers e Geosciences**, v. 25, n. 4, p. 463-466, 1999.

WEIGEND, A. S.; MANGEAS, M.; SRISTAVA, A. N. Nonlinear gated experts for time series: Discovering regimes and avoiding over fitting. **International Journal of Neural Systems**, v. 6, n. 4, p. 373-399, 1995.

WIDROW, B.; HOFF, M.E. **Adaptive Switching Circuits**. Ire Wescon Convention Record, New York, p. 96-104, 1960.

WISSMAN, J.A.; TAMPELINI, L.G.; FEIL, A.C.; SAMPAIO, S.C.; SUSZEK, M. Ferramenta computacional para análise de consistência de dados pluviométricos. **Revista Varia Scientia**, v. 06, n. 11, p. 99-106, 2006.

ZEILHOFER, P.; LIMA, E.B.R.; SANTOS, F.M.; RIGO JÚNIOR, L. O. Um Ambiente SIG para Modelagem Integrada da Qualidade da Água utilizando QUAL2e. **Revista Caminhos da Geografia**, v. 4, n. 10, p. 107-125, 2003.

ZHANG, S., WANG, D., QIN, Z.; ZHENH, Y; GUO, J. Assessment of the GPM and TRMM Precipitation Products Using the Rain Gauge Network over the Tibetan Plateau. **J. Meteorol. Res.**, v. 32, p. 324–336, 2018.

**ANEXO A – Relação de estações pluviométricas**



<b>ESTAÇÃO PLUVIOMÉTRICA</b>	<b>LAT</b>	<b>LONG</b>	<b>CODIGO</b>	<b>SIGLA</b>	<b>OPER</b>
PAIM FILHO	-27,7125	-51,7378	2751006	ANA	CPRM
SANANDUVA	-27,9828	-51,7836	2751007	ANA	CPRM
BARRACÃO	-27,6786	-51,4547	2751015	ANA	CPRM
CLEMENTE ARGOLO	-28,0058	-51,4544	2751017	ANA	CPRM
MARCELINO RAMOS	-27,4647	-51,9031	2751018	ANA	CPRM
PINHAL DA SERRA	-27,8908	-51,1836	2751025	ANA	CPRM
EREBANGO	-27,8542	-52,3047	2752006	ANA	CPRM
ITATIBA DO SUL	-27,3889	-52,4544	2752017	ANA	CPRM
GAURAMA	-27,5872	-52,0933	2752021	ANA	CPRM
FREDERICO WESTPHALEN	-27,3608	-53,3975	2753002	ANA	CPRM
IRAÍ	-27,1888	-53,2533	2753003	INMET	INMET
LINHA CESCO	-27,8117	-53,0278	2753004	ANA	CPRM
PALMEIRAS DAS MISSÕES	-27,8833	-53,4333	2753005	INMET	INMET
SANTO AUGUSTO	-27,8517	-53,7764	2753007	ANA	CPRM
TRÊS PASSOS	-27,4514	-53,925	2753009	ANA	CPRM
LIBERATO SALZANO	-27,5992	-53,0714	2753014	ANA	CPRM
PALMEIRA DAS MISSÕES	-27,9133	-53,3108	2753015	ANA	CPRM
MIRAGUAI	-27,5008	-53,6925	2753016	ANA	CPRM
IRAÍ	-27,1889	-53,2533	2753019	ANA	CPRM
BARRA DO GUARITA	-27,2033	-53,7297	2753024	ANA	CPRM
CAMPO NOVO	-27,6875	-53,8019	2753025	ANA	CPRM
PLANALTO	-27,3083	-53,0483	2753026	ANA	CPRM
ALTO URUGUAI	-27,3019	-54,1394	2754001	ANA	CPRM
SANTA ROSA	-27,85	-54,4166	2754005	INMET	INMET
TRÊS DE MAIO	-27,7817	-54,2408	2754007	ANA	CPRM
TUCUNDUVA	-27,6742	-54,4625	2754009	ANA	CPRM
ESQUINA ARAUJO	-27,9681	-54,1164	2754010	ANA	CPRM
CAMPINA DAS MISSÕES	-27,9875	-54,8336	2754013	ANA	CPRM
SÃO MARTINHO	-27,7028	-53,9731	2754014	ANA	CPRM
PORTO MAUÁ	-27,59	-54,6636	2754015	ANA	CPRM
PORTO LUCENA	-27,8544	-55,0236	2755001	ANA	CPRM
SILVEIRA	-28,6264	-49,9339	2849035	ANA	CPRM
BOM JESUS	-28,6686	-50,4419	2850001	INMET	INMET
CAPELA SÃO JOSÉ DOS AUSENTES	-29,0942	-50,6275	2850002	ANA	CPRM
INVERNADA VELHA	-28,4494	-50,2964	2850006	ANA	CPRM
PASSO TAINHAS	-28,8675	-50,4561	2850009	ANA	CPRM
VACARIA	-28,5166	-50,95	2850011	INMET	INMET
CAZUZA FERREIRA	-28,9375	-50,6542	2850016	ANA	CPRM
BOSSOROCA	-28,7028	-54,9244	2850019	ANA	CPRM
MONTE ALEGRE DOS CAMPOS	-28,6839	-50,7808	2850020	ANA	CPRM
ANTÔNIO PRADO	-28,8533	-51,2844	2851003	ANA	CPRM
FAZENDA ROSEIRA	-28,6733	-51,1428	2851010	ANA	CPRM
GUAPORÉ	-28,9166	-51,9	2851011	INMET	INMET
LAGOA VERMELHA	-28,2219	-51,5125	2851014	INMET	INMET
PASSO DAS PEDRAS	-28,2556	-51,8619	2851020	ANA	CPRM

PASSO DO PRATA	-28,8775	-51,4483	2851021	ANA	CPRM
PASSO MIGLIAVACA	-28,6194	-51,8667	2851022	ANA	CPRM
PRATA	-28,7561	-51,6283	2851024	ANA	CPRM
TRINTA E CINCO	-28,3911	-51,8489	2851028	ANA	CPRM
ESMERALDA	-28,0592	-51,1881	2851043	ANA	CPRM
GUAPORÉ	-28,8444	-51,8792	2851044	ANA	CPRM
CAPÃO DO CEDRO	-28,0878	-51,5444	2851050	ANA	CPRM
MUITOS CAPÕES	-28,3239	-51,2111	2851051	ANA	CPRM
NOSSA SENHORA DE FÁTIMA	-28,4619	-51,5378	2851052	ANA	CPRM
AULER	-28,8039	-52,3817	2852004	ANA	CPRM
CARAZINHO	-28,2933	-52,7242	2852006	ANA	CPRM
COLÔNIA XADREZ	-28,1892	-52,7458	2852007	ANA	CPRM
DEPÓSITO	-28,9331	-52,8	2852009	ANA	CPRM
ILÓPOLIS	-28,9283	-52,1275	2852014	ANA	CPRM
PASSO FUNDO	-28,2258	-52,4033	2852020	INMET	INMET
PULADOR	-28,2931	-52,555	2852024	ANA	CPRM
VILA TRÊS PASSOS	-28,4667	-52,3667	2852031	ANA	CPRM
SOLEDADE	-28,8333	-52,4333	2852045	INMET	INMET
TAPEJARA	-28,0575	-51,9961	2852046	ANA	CPRM
NÃO-ME-TOQUE	-28,4553	-52,8158	2852050	ANA	CPRM
CAMPO DO MEIO	-28,3264	-52,0536	2852052	ANA	CPRM
SOLEDADE	-28,8131	-52,5114	2852053	ANA	CPRM
SELBACH	-28,6322	-52,9358	2852054	ANA	CPRM
CONCEIÇÃO	-28,4561	-53,9717	2853003	ANA	CPRM
CRUZ ALTA	-28,6363	-53,5994	2853005	INMET	INMET
PASSO FAXINAL	-28,2894	-53,7794	2853010	ANA	CPRM
SANTA CLARA DO INGAI	-28,7289	-53,1853	2853014	ANA	CPRM
TRÊS CAPÕES	-28,8264	-53,5019	2853015	ANA	CPRM
PANAMBI (PINDORAMA)	-28,2833	-53,5	2853022	INMET	INMET
CONDOR	-28,2256	-53,4703	2853023	ANA	CPRM
CHAPADA	-28,0586	-53,0661	2853026	ANA	CPRM
IBIRUBA	-28,6166	-53,1166	2853027	INMET	INMET
ANDERSON CLAYTON	-28,6578	-53,6089	2853028	ANA	CPRM
SANTA BÁRBARA DO SUL	-28,3883	-53,2586	2853033	ANA	CPRM
PANAMBI	-28,3444	-53,5417	2853034	ANA	CPRM
NOVA RAMADA	-28,0667	-53,6833	2853035	ANA	CPRM
CAMPINAS	-28,4908	-53,1047	2853037	ANA	CPRM
MAUÁ	-28,1792	-53,8578	2853040	ANA	CPRM
BOA VISTA	-28,1111	-53,9931	2854001	ANA	CPRM
GIRUA	-28,0542	-54,3614	2854003	ANA	CPRM
PASSO MAJOR ZEFERINO	-28,7336	-54,6478	2854005	ANA	CPRM
PASSO VIOLA	-28,2111	-54,6031	2854006	ANA	CPRM
SANTO ANGELO	-28,3	-54,2666	2854007	INMET	INMET
SÃO LUIZ GONZAGA	-28,4	-54,9666	2854011	INMET	INMET
COIMBRA	-28,7878	-54,4525	2854012	ANA	CPRM
SÃO BERNARDO	-28,9053	-54,065	2854013	ANA	CPRM

SANTO ANGELO (IPAGRO)	-28,3036	-54,2625	2854014	INMET	INMET
JÓIA	-28,6492	-54,1133	2854018	ANA	CPRM
GARRUCHOS	-28,1878	-55,6369	2855001	ANA	CPRM
PASSO DO SARMENTO	-28,2089	-55,3233	2855002	ANA	CPRM
PASSO DO NOVO	-28,6781	-55,5811	2855004	ANA	CPRM
FAZENDA SANTA CECÍLIA DO BUTUI	-28,9897	-55,6742	2855005	ANA	CPRM
SANTO ANTÔNIO DAS MISSÕES	-28,4925	-55,2308	2855007	ANA	CPRM
ITACUMBI	-28,7739	-55,2572	2855008	ANA	CPRM
SAMBURÁ	-28,4056	-55,6103	2855012	ANA	CPRM
SÃO BORJA	-28,65	-56	2856003	INMET	INMET
PASSO SÃO BORJA	-28,6664	-55,9797	2856006	ANA	CPRM
CUNHA	-28,8975	-56,085	2856007	ANA	CPRM
TORRES	-29,3447	-49,728	2949002	INMET	INMET
CAMISAS	-29,1083	-50,1875	2950008	ANA	CPRM
CAPÃO DOS COXOS	-29,4	-50,5833	2950010	ANA	CPRM
GLORINHA	-29,8828	-50,7889	2950016	ANA	CPRM
LAJEADO GRANDE	-29,0942	-50,6275	2950019	ANA	CPRM
ROLANTE	-29,6508	-50,5728	2950028	ANA	CPRM
SÃO FRANCISCO DE PAULA	-29,3333	-50,5166	2950032	INMET	INMET
SECA	-29,0719	-50,9739	2950033	ANA	CPRM
SERRA DO PINTO	-29,3758	-50,1803	2950034	ANA	CPRM
TAQUARA	-29,75	-50,75	2950036	INMET	INMET
TERRA DE AREIA	-29,5911	-50,0336	2950038	ANA	CPRM
CANELA	-29,3333	-50,8	2950042	INMET	INMET
LINHA GONZAGA	-29,3072	-50,9953	2950050	ANA	CPRM
CAMBARÁ DO SUL	-29,05	-50,1333	2950054	INMET	INMET
AGROPECUÁRIA ANJU	-29,8167	-50,7425	2950059	ANA	CPRM
SANTO ANTÔNIO DA PATRULHA	-29,8317	-50,5486	2950060	ANA	CPRM
FAZENDA NOSSA SENHORA					
CONCEIÇÃO	-29,9608	-50,5994	2950062	ANA	CPRM
VILA TAINHAS	-29,2769	-50,3106	2950063	ANA	CPRM
TAQUARA MONTANTE	-29,7208	-50,735	2950068	ANA	CPRM
BENTO GONÇALVES	-29,15	-51,5166	2951003	INMET	INMET
CAXIAS DO SUL	-29,1963	-51,1863	2951008	INMET	INMET
ENCANTADO	-29,2378	-51,8594	2951010	ANA	CPRM
JANSEN	-28,3908	-51,8489	2951017	ANA	CPRM
NOVA PALMIRA	-29,335	-51,1903	2951022	ANA	CPRM
PORTO GARIBALDI	-29,8117	-51,3869	2951024	ANA	CPRM
SÃO VENDELINO	-29,3664	-51,3711	2951027	ANA	CPRM
SAPUCAIA DO SUL	-29,82	-51,1611	2951028	ANA	CPRM
TAQUARI	-29,8	-51,81	2951030	INMET	INMET
LAJEADO	-29,4333	-51,95	2951063	INMET	INMET
NOVO HMABURGO	-29,6333	-51,1333	2951064	INMET	INMET
TRIUNFO	-29,8805	-51,3827	2951065	INMET	INMET
CHARQUEADAS	-29,9758	-51,6119	2951067	ANA	CPRM
CAMPO BOM	-29,6833	-51,0333	2951069	INMET	INMET
MUÇUM	-29,1664	-51,8681	2951070	ANA	CPRM

PASSO MONTENEGRO	-29,7008	-51,44	2951080	ANA	CPRM
COSTA DO RIO CADEIA - MONTANTE	-29,5897	-51,3136	2951081	ANA	CPRM
LINHA JOSÉ JÚLIO	-29,0978	-51,6997	2951092	ANA	CPRM
BARROS CASSAL	-29,085	-52,5844	2952001	ANA	CPRM
BOTUCARAI	-29,7128	-52,89	2952003	ANA	CPRM
SANTA CRUZ DO SUL	-29,7166	-52,4333	2952012	INMET	INMET
CANDELÁRIA	-29,6694	-52,7903	2952034	ANA	CPRM
HERVEIRAS	-29,4539	-52,6325	2952035	ANA	CPRM
BOQUEIRÃO DO LEÃO	-29,3125	-52,4225	2952036	ANA	CPRM
DEODORO	-29,4703	-52,2497	2952037	ANA	CPRM
SÃO JOSÉ DO HERVAL	-29,0406	-52,2847	2952038	ANA	CPRM
DONA FRANCISCA	-29,6244	-53,3519	2953008	ANA	CPRM
JÚLIO DE CASTILHOS	-29,2166	-53,6666	2953011	INMET	INMET
SANTA MARIA	-29,7241	-53,72	2953017	INMET	INMET
TUPANCIRETÃ	-29,0856	-53,8192	2953030	ANA	CPRM
PASSO ESTRELA	-29,2178	-53,1097	2953036	ANA	CPRM
PASSO SÃO LOURENÇO	-30,0089	-53,015	2953037	ANA	CPRM
CACEQUI	-29,8786	-54,8253	2954001	ANA	CPRM
ERNESTO ALVES	-29,3661	-54,7356	2954004	ANA	CPRM
FURNAS DO SEGREDO	-29,3589	-54,5019	2954005	ANA	CPRM
JAGUARI	-29,5069	-54,6775	2954007	ANA	CPRM
SANTIAGO	-29,1833	-54,8666	2954011	INMET	INMET
QUEVEDOS	-29,3514	-54,0669	2954019	ANA	CPRM
SANTIAGO	-29,1867	-54,8558	2954020	ANA	CPRM
FLORIDA	-29,2517	-54,5983	2954030	ANA	CPRM
ESQUINA DOS LIMA (STA. BARBARA)	-29,0481	-54,5708	2954031	ANA	CPRM
PONTE TOROPI II	-29,6533	-54,4314	2954032	ANA	CPRM
BOM RETIRO	-29,9897	-54,4886	2954033	ANA	CPRM
ALEGRETE	-29,7833	-55,7666	2955001	INMET	INMET
CACHOEIRA SANTA CECÍLIA	-29,1961	-55,4753	2955002	ANA	CPRM
PONTE DO MIRACATU	-29,4592	-55,2911	2955006	ANA	CPRM
UNISTALDA	-29,0475	-55,1511	2955007	ANA	CPRM
MANOEL VIANA	-29,5939	-55,4858	2955008	ANA	CPRM
ALEGRETE	-29,7844	-55,7739	2955013	ANA	CPRM
PASSO DA CACHOEIRA	-29,3078	-55,7089	2955014	ANA	CPRM
JACAQUA	-29,6869	-55,1958	2955016	ANA	CPRM
SÃO JOÃO	-29,8319	-55,3433	2955017	ANA	CPRM
ITAQUI	-29,1166	-56,55	2956004	INMET	INMET
ITAQUI	-29,1275	-56,5625	2956005	ANA	CPRM
PASSO MARIANO PINTO	-29,3089	-56,0553	2956006	ANA	CPRM
PLANO ALTO	-29,7653	-56,5214	2956007	ANA	CPRM
JOÃO ARREGUI	-29,4711	-56,6678	2956008	ANA	CPRM
FAZENDA TRÊS CAPÕES	-29,6358	-56,0947	2956009	ANA	CPRM
URUGUAIANA	-29,75	-57,0833	2957001	INMET	INMET
URUGUAIANA	-29,7564	-57,0936	2957003	ANA	CPRM
CABANHA ALCEU NEVES	-29,8533	-57,1072	2957008	ANA	CPRM

PALMARES DO SUL	-30,2514	-50,5058	3050002	ANA	CPRM
VIAMÃO	-30,0833	-50,7833	3050006	INMET	INMET
SOLIDÃO	-30,6683	-50,5408	3050007	ANA	CPRM
LOMBAS	-30,0467	-50,7019	3050008	ANA	CPRM
PINHAL	-30,215	-50,2817	3050009	ANA	CPRM
PASSINHOS	-30,0367	-50,3939	3050010	ANA	CPRM
CERRO GRANDE	-30,5939	-51,7567	3051004	ANA	CPRM
GUAÍBA COUNTRY CLUB	-30,0897	-51,6306	3051005	ANA	CPRM
PORTO ALEGRE	-30,0536	-51,1733	3051011	INMET	INMET
TAPES	-30,6666	-51,4	3051013	INMET	INMET
PORTO ALEGRE (STA TERESA-839)	-30,0666	-51,2166	3051015	INMET	INMET
CAMAQUÃ	-30,8658	-51,7958	3051016	ANA	CPRM
FAZENDA DA BOA VISTA	-30,7719	-51,6603	3051017	ANA	CPRM
BARRA DO RIBEIRO	-30,295	-51,3144	3051023	ANA	CPRM
BUTIA	-30,1589	-51,9311	3051031	ANA	CPRM
ARAMBARÉ	-30,9056	-51,4944	3051038	ANA	CPRM
TAPES	-30,6561	-51,4972	3051039	ANA	CPRM
PORTO ALEGRE - CPRM	-30,0722	-51,2281	3051043	ANA	CPRM
ARROIO DO SALSO	-30,1692	-51,0739	3051045	ANA	CPRM
CACHOEIRA DO SUL	-30,0333	-52,8833	3052002	INMET	INMET
DOM FELICIANO	-30,7	-52,0667	3052004	ANA	CPRM
ENCRUZILHADA DO SUL	-30,5361	-52,5166	3052005	INMET	INMET
PASSO DA GUARDA	-30,9064	-52,4619	3052007	ANA	CPRM
PASSO SÃO JOSÉ	-30,8864	-52,2486	3052009	ANA	CPRM
PORTO TARUMÃ	-30,9342	-52,9428	3052010	ANA	CPRM
QUITERIA	-30,4189	-52,0736	3052011	ANA	CPRM
SERRA DOS PEDROSAS	-30,6253	-52,84	3052012	ANA	CPRM
DOM FELICIANO	-30,7031	-52,0647	3052013	ANA	CPRM
PANTANO GRANDE	-30,1983	-52,3725	3052016	ANA	CPRM
BARRAGEM CAPANÉ	-30,1869	-52,9133	3052017	ANA	CPRM
CAÇAPAVA DO SUL	-30,5	-53,4833	3053002	INMET	INMET
PASSO DO ROCHA	-30,2325	-53,9933	3053004	ANA	CPRM
LAVRAS DO SUL	-30,8175	-53,9014	3053007	ANA	CPRM
PASSO DOS FREIRES	-30,4353	-53,7125	3053017	ANA	CPRM
IRAPUAZINHO	-30,4872	-53,1183	3053018	ANA	CPRM
SÃO SEPÉ MONTANTE	-30,1936	-53,5644	3053020	ANA	CPRM
BARRO VERMELHO	-30,1406	-53,1589	3053021	ANA	CPRM
CAÇAPAVA DO SUL	-30,5194	-53,4917	3053022	ANA	CPRM
TRÊS PASSOS II	-30,9689	-53,965	3053023	ANA	CPRM
VILA NOVA	-30,3425	-53,8803	3053024	ANA	CPRM
PASSO DOS ENFORCADOS	-30,8542	-53,5933	3053028	ANA	CPRM
DOM PEDRITO	-30,9781	-54,6758	3054002	ANA	CPRM
ROSÁRIO DO SUL	-30,2469	-54,9175	3054007	ANA	CPRM
SÃO GABRIEL	-30,3333	-54,3166	3054011	INMET	INMET
DOM PEDRITO	-30,9666	-54,6666	3054014	INMET	INMET
GRANJA UMBU	-30,5144	-54,7703	3054016	ANA	CPRM

SÃO GABRIEL	-30,3575	-54,3181	3054018	ANA	CPRM
IBARE	-30,7744	-54,2247	3054019	ANA	CPRM
RS-473	-30,4806	-54,1983	3054020	ANA	CPRM
CERRO BATOVI	-30,5633	-54,4492	3054021	ANA	CPRM
SANTANA DO LIVRAMENTO	-30,8833	-55,5333	3055001	INMET	INMET
FAZENDA ENCERRA	-30,6956	-55,9744	3055003	ANA	CPRM
SAICA	-30,0294	-55,0936	3055004	ANA	CPRM
SANTA RITA	-30,5164	-55,1267	3055005	ANA	CPRM
SÃO CARLOS	-30,2042	-55,4919	3055007	ANA	CPRM
PASSO DA GUARDA	-30,2939	-55,9756	3055008	ANA	CPRM
BR-293	-30,7917	-55,1792	3055009	ANA	CPRM
ALTO QUARAÍ	-30,7503	-55,9514	3055011	ANA	CPRM
QUARAÍ	-30,3833	-56,4833	3056003	ANA	CPRM
FAZENDA JUNCO	-30,0189	-56,8214	3056004	ANA	CPRM
HARMONIA	-30,0686	-56,1703	3056006	ANA	CPRM
CATY	-30,5256	-56,1722	3056007	ANA	CPRM
OLHO D'ÁGUA	-30,0039	-56,4797	3056010	ANA	CPRM
BARRA DO QUARAÍ	-30,2133	-57,5533	3057002	ANA	CPRM
PACHECA	-31,1303	-51,7886	3151002	ANA	CPRM
SÃO LOURENÇO DO SUL	-31,3675	-51,9867	3151003	ANA	CPRM
TAVARES	-31,29	-51,0956	3151004	ANA	CPRM
BOQUEIRÃO	-31,2839	-52,0831	3152002	ANA	CPRM
CANGUÇU	-31,4044	-52,6733	3152003	ANA	CPRM
VILA FREIRE	-31,6694	-52,7728	3152005	ANA	CPRM
GRANJA SÃO PEDRO	-31,6728	-52,1778	3152008	ANA	CPRM
PASSO DO MENDONÇA	-31,0006	-52,0492	3152011	ANA	CPRM
PEDRO OSÓRIO	-31,8797	-52,8103	3152013	ANA	CPRM
PELOTAS	-31,75	-52,35	3152014	INMET	INMET
PONTE CORDEIRO DE FARIAS	-31,5739	-52,4631	3152016	ANA	CPRM
PARAÍSO	-31,2267	-53,9014	3153003	ANA	CPRM
FERRARIA	-31,7375	-53,0539	3153004	ANA	CPRM
PASSO DA CAPELA	-31,1342	-53,0539	3153006	ANA	CPRM
PEDRAS ALTAS	-31,7333	-53,5881	3153007	ANA	CPRM
PINHEIRO MACHADO	-31,5775	-53,3769	3153008	ANA	CPRM
PIRATINI	-31,4333	-53,1	3153009	INMET	INMET
TORRINHAS	-31,3142	-53,4994	3153017	ANA	CPRM
ESTAÇÃO EXPERIMENTAL DE PIRATINI	-31,4308	-53,1078	3153021	ANA	CPRM
CERRO CHATO	-31,8656	-53,2744	3153022	ANA	CPRM
MADRUGADA	-31,7964	-53,8594	3153030	ANA	CPRM
BAGÉ	-31,3047	-54,1197	3154001	INMET	INMET
TORQUATO SEVERO	-31,0283	-54,1789	3154003	ANA	CPRM
ESTÂNCIA DO ESPANTOSO	-31,5339	-54,2947	3154006	ANA	CPRM
ACEGUÁ	-31,8689	-54,1639	3154007	ANA	CPRM
SERRILHADA	-31,4375	-54,7117	3154008	ANA	CPRM
FAZENDA SÃO JORGE	-31,4533	-54,13	3154010	ANA	CPRM
TRÊS VENDAS	-31,2753	-55,0372	3155001	ANA	CPRM

BARRA DO RIO GRANDE	-32,05	-52,1	3252002	INMET	INMET
GRANJA CORONEL PEDRO OSÓRIO	-32,0061	-52,6528	3252005	ANA	CPRM
GRANJA CERRITO	-32,3506	-52,54	3252006	ANA	CPRM
GRANJA SANTA MARIA	-32,4044	-52,5558	3252008	ANA	CPRM
RIO GRANDE	-32,0788	-52,1666	3252020	INMET	INMET
RIO GRANDE/REGATAS	-32,03	-52,0792	3252024	ANA	CPRM
CURRAL ALTO	-32,9444	-52,7733	3252025	ANA	CPRM
ARROIO GRANDE	-32,2372	-53,0897	3253001	ANA	CPRM
GRANJA OSÓRIO	-32,9539	-53,1189	3253003	ANA	CPRM
HERVAL	-32,0286	-53,3978	3253004	ANA	CPRM
JAGUARÃO	-32,55	-53,3833	3253005	INMET	INMET
SANTA VITÓRIA DO PALMAR	-33,5325	-53,3494	3353007	INMET	INMET