

**UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA AMBIENTAL**

Alana Pisoni

**A VARIÂNCIA DE KRIGAGEM NA COMPREENSÃO DO
COMPORTAMENTO DA PRECIPITAÇÃO PLUVIOMÉTRICA NO
BRASIL SUBTROPICAL**

Santa Maria, RS
2020

Alana Pisoni

A variância de krigagem na compreensão do comportamento da precipitação pluviométrica no Brasil subtropical

Dissertação apresentada ao Curso de Pós-graduação em Engenharia Ambiental, da Universidade Federal de Santa Maria (UFSM, RS), como requisito parcial para obtenção do título de **Mestre em Engenharia Ambiental**.

Orientador: Prof. Dr. Enio Júnior Seidel

Santa Maria, RS
2020

Pisoni, Alana

A variância de krigagem na compreensão do comportamento da precipitação pluviométrica no Brasil subtropical / Alana Pisoni.- 2020.

52 p.; 30 cm

Orientador: Enio Júnior Seidel

Dissertação (mestrado) - Universidade Federal de Santa Maria, Centro de Tecnologia, Programa de Pós-Graduação em Engenharia Ambiental, RS, 2020

1. Estações pluviométricas 2. Variância da krigagem 3. GAMLSS 4. Rio Grande do Sul I. Seidel, Enio Júnior II. Título.

Sistema de geração automática de ficha catalográfica da UFSM. Dados fornecidos pelo autor(a). Sob supervisão da Direção da Divisão de Processos Técnicos da Biblioteca Central. Bibliotecária responsável Paula Schoenfeldt Patta CRB 10/1728.

© 2020

Todos os direitos autorais reservados a Alana Pisoni. A reprodução de partes ou do todo deste trabalho só poderá ser feita mediante a citação da fonte.


E-mail: alanapisoni@hotmail.com

Alana Pisoni

A variância de krigagem na compreensão do comportamento da precipitação pluviométrica no Brasil subtropical

Dissertação apresentada ao Curso de Pós-graduação em Engenharia Ambiental, da Universidade Federal de Santa Maria (UFSM, RS), como requisito para obtenção do título de **Mestre em Engenharia Ambiental**.

Aprovado em 09 de julho de 2020:



Enio Júnior Seidel, Dr. (UFSM)
(Presidente/Orientador)



Daniel Gustavo Allasia Picilli, Dr. (UFSM)



Diogo Francisco Rossoni, Dr. (UEM)

Santa Maria, RS
2020

RESUMO

A VARIÂNCIA DE KRIGAGEM NA COMPREENSÃO DO COMPORTAMENTO DA PRECIPITAÇÃO PLUVIOMÉTRICA NO BRASIL SUBTROPICAL

AUTORA: Alana Pisoni

ORIENTADOR: Enio Júnior Seidel

A precipitação pluviométrica apresenta grande variabilidade espacial, e é um fenômeno caracterizado por sua distribuição irregular. Seus dados estão disponíveis a partir de um número limitado de estações, que fornecem apenas medições pontuais. Sendo a configuração de uma rede de estações pluviométrica é um dos fatores mais importantes para precisão dos dados, é necessário a otimização das redes. O objetivo do trabalho é analisar a variância da krigagem como indicador para determinar possíveis locais que necessitam de novas estações pluviométricas no Rio Grande do Sul, e para compreender os aspectos que influenciam a variabilidade da precipitação pluviométrica. A Agência Nacional de Águas (ANA) e o Instituto Nacional de Meteorologia (INMET) são órgãos que realizam o monitoramento pluviométrico no estado do Rio Grande do Sul e disponibilizam os dados. Para o estudo foram selecionadas somente as estações que possuíam dados disponíveis para um período de 30 anos (de 1989 até 2018), e que continham 5 anos ou mais de dados consecutivos, visando ter mais que 10% dos anos e o mínimo de confiabilidade dos dados, a fim de não perder a representatividade espacial da variabilidade da chuva. Com isso foram selecionadas 259 estações da ANA e 18 do INMET, totalizando 277 estações pluviométricas. Após a obtenção dos dados diários de precipitação, foi realizada a média climatológica mensal. A partir do método de interpolação da krigagem, estimou-se a variância da krigagem, para verificar regiões que apresentam maior variabilidade, onde poderiam ser inseridas mais estações, melhorando a área de amostragem. Foram realizadas reduções sistemáticas das estações de 100% para 95%, 90%, 75% e 50%, com a intenção de modelar a variância de krigagem máxima em função do número de estações e dos meses do ano. A modelagem por modelos aditivos generalizados de posição, escala e forma (*GAMLSS*) foi usada para verificar a relação da variância de krigagem máxima em função do número de estações e dos meses do ano. Através da variância da krigagem foi possível observar os locais com maior variabilidade, que necessitam de estações pluviométricas em cada mês do ano e no geral. E por meio da modelagem de *GAMLSS*, foi verificado que não há relação evidente da variância máxima da krigagem com o número de estações, de modo que não necessariamente o aumento de estações de medição, sem a reorganização da malha espacial, causaria uma melhora significativa nas predições.

Palavras-chave: Estações pluviométricas. Variância da krigagem. *GAMLSS*.

ABSTRACT

THE KRIGING VARIANCE FOR UNDERSTANDING THE PLUVIOMETRIC PRECIPITATION BEHAVIOR IN SUBTROPICAL BRAZIL

**AUTHOR: ALANA PISONI
ADVISOR: ENIO JÚNIOR SEIDEL**

The pluviometric precipitation presents a large spatial variability and it is a phenomenon characterized by its irregular distribution. Its data are available from a limited number of stations that provide only punctuations mediations. Being the setting of a pluviometric stations' net it is one of the most important factor to data accuracy, is necessary the net's optimization. This work aims to analyze the kriging variance as an indicator to determine possible places that need new pluviometric stations in Rio Grande do Sul and to understand the aspect that influence the variability of the pluviometric precipitation. The National Water Agency (ANA) and National Institute of Meteorology (INMET) are organs that make the pluviometric monitoring at Rio Grande do Sul State and available these data. For the study were selected only the stations that had available data for 30 years period (from 1989 to 2018), and containing 5 years or more of consecutive data, aiming to have more than 10% of the years and the minimum of data reliability in order to do not lose the spatial representativeness of raining variability. Thereby it were selected 259 ANA stations and 18 INMET stations, totalizing 277 pluviometric stations. After obtaining the daily precipitation data, the monthly climatological average was performed. From the kriging interpolation method estimated the kriging variance to verify regions that present larger variability, where could be inserted more stations becoming better the sampling area. It were done systemic reductions of the stations from 100% to 95%, 90% and 50% intending to modulate the maximum kriging variance in function of the stations number and the months of the year. The modeling by generalized additive models of position, scale and shape (GAMLSS) was used to verify the relationship of the maximum kriging variance as a function of the number of seasons and the months of the year. Through the kriging variance it was possible to observe the places with larger variability that need of pluviometric stations every month of the year. And through the GAMLSS modulations, it was verified that there isn't evident relation of the kriging maximum variance with the stations number, so that not necessarily the increase of measurement stations, without the reorganization of the spatial mesh, would cause a significant improvement in predictions.

Keywords: Pluviometric stations. Kriging variance. GAMLSS.

LISTA DE ILUSTRAÇÕES

Figura 1 - Unidades Geomorfológicas e Hipsometria do Rio Grande do Sul	22
Figura 2 - Temperatura média anual do Rio Grande do Sul.....	23
Figura 3 - Precipitação média anual do Rio Grande do Sul	24
Figura 4 - Mapa da distribuição espacial das estações pluviométricas do Rio Grande do Sul	28
Figura 5 - Estações pluviométricas em 95% (a), 90% (b), 75% (c) e 50% (d) das estações....	32
Figura 6 - Mapas da variância da krigagem para os meses de janeiro (a), fevereiro (b), março (c), abril (d), maio (e), junho (f), julho (g), agosto (h), setembro (i), outubro (j), novembro (k) e dezembro (l), em escala maior de cores.	37
Figura 7 - Mapas da variância da krigagem para os meses de janeiro (a), fevereiro (b), março (c), abril (d), maio (e), junho (f), julho (g), agosto (h), setembro (i), outubro (j), novembro (k) e dezembro (l), em escala menor de cores.	38
Figura 8 - Mapa geral da variância da krigagem.	39
Figura 9 - Relacionamento entre a variância de krigagem máxima em função do número de estações (a) e em função dos meses do ano (b).....	42
Figura 10 - Efeitos dos meses do ano no comportamento da variância máxima de krigagem, no modelo de regressão para a distribuição Gaussiana inversa.	44
Figura 11 - Gráfico worm plot do modelo de regressão para a distribuição Gaussiana inversa.	45

SUMÁRIO

1	INTRODUÇÃO	8
2	OBJETIVO	10
3	REFERENCIAL TEÓRICO	11
3.1	PLUVIOMETRIA	11
3.2	SISTEMAS ATMOSFÉRICOS ATUANTES DO RIO GRANDE DO SUL.....	13
3.3	INTERPOLAÇÃO ESPACIAL	15
3.3.1	Krigagem	16
3.3.1.1	<i>Variância da krigagem</i>	18
3.4	MODELAGEM GAMLSS	20
4	METODOLOGIA	21
4.1	CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	21
4.1.1	Precipitação no Rio Grande do Sul	24
4.1.2	Pluviometria	26
4.2	AQUISIÇÃO DOS DADOS	27
4.2.1	Ajuste dos dados pluviométricos	28
4.2.2	Manipulação dos dados no Software R	29
4.3	AVALIAÇÃO DA VARIÂNCIA DA KRIGAGEM.....	30
4.4	REDUÇÃO DA DENSIDADE DE AMOSTRAS PARA MODELAGEM GAMLSS.....	31
4.5	AVALIAÇÃO DOS RESULTADOS POR MODELAGEM GAMLSS	32
5	RESULTADOS E DISCUSSÃO	34
5.1	ANÁLISE DOS DADOS	34
5.2	ANÁLISE DA VARIÂNCIA DA KRIGAGEM.....	35
5.3	ANÁLISE DO MODELO DE REGRESSÃO.....	41
6	CONCLUSÃO	46
	REFERÊNCIAS BIBLIOGRÁFICAS	47

1 INTRODUÇÃO

A precipitação pluviométrica apresenta grande variabilidade espacial e é um fenômeno caracterizado por sua distribuição irregular (PELLICONE et al., 2018). Os dados de precipitação pluviométrica estão disponíveis a partir de um número limitado de estações (HOFIERKA et al. 2002), pois economicamente e tecnicamente não é possível obter dados em toda a superfície (OZTURK; KILIC, 2016; LI; HEAP, 2011). As redes pluviométricas, muitas vezes, não são densas e adequadamente distribuídas, e fornecem apenas medições pontuais. Com isso, nem sempre há dados espacialmente distribuídos de precipitação disponíveis (VICENTE-SERRANO et al., 2003; MIRÁS-AVALOS et al., 2007; KEBLOUT et al., 2012).

A distribuição espacial de variáveis climáticas, dentre elas a precipitação pluviométrica pode ser estimada aplicando métodos de interpolação. A interpolação espacial é um método que estima os valores em locais onde nenhum valor medido está disponível, a partir de observações existentes em locais vizinhos (GOOVAERTS, 2000; LANZA et al. 2001; TVEITO et al. 2008; DI PIAZZA et al. 2011; LI; HEAP, 2011; KEBLOUT et al., 2012; BERNDT; HABERLANDT, 2018).

O desempenho da estimativa depende não somente do método de interpolação usado, mas também da configuração da rede de estações, variabilidade espacial da variável na região, resolução de dados temporais e incorporação de outras variáveis no procedimento de interpolação (BERNDT; HABERLANDT, 2018). Segundo Frazier et al. (2016) a densidade da rede de estações também influencia o desempenho da interpolação. Uma rede de pluviômetros bem projetada, com um número ideal de pluviômetros, é capaz de fornecer estimativas precisas de precipitação (SALLEH et al., 2019).

O principal objetivo de uma rede de pluviômetro é coletar e fornecer os dados de precipitação necessários com precisão. Para alcançar essa precisão nas estimativas visando o menor custo, é necessária uma análise abrangente da quantidade e da localização dos pluviômetros (PARDO-IGÚZQUIZA, 1998). A densidade de uma rede pluviométrica e sua distribuição em uma região, interfere na precisão da estimativa de precipitação. Uma rede mais densa envolve mais custos, devido a instalação de um pluviômetro requerer mão de obra e investimentos, incluindo construção, operação e manutenção. Portanto é desejável otimizar uma rede pluviométrica, com o menor número de estações possíveis, e com uma distribuição adequada (MAHMOUDI-MEIMAND et al., 2015), onde devem ser levados em conta aspectos como acessibilidade, facilidade de manutenção e aspectos topográficos.

Diversos estudos avaliaram distintos métodos para otimização de redes pluviométricas, dentre os quais: Shih (1982) desenvolveu uma metodologia usando o fator de covariância; Bastin et al. (1984); Papamichail e Metaxa (1996); St-Hilaire et al. (2003); Chebbi et al. (2011) utilizaram a variância da krigagem; Pardo-Igúzquiza (1998) apresenta o método da variância da krigagem em combinação com o simulated annealing; Barca et al. (2008) propôs técnicas de geoestatística e probabilística combinadas com instrumentos GIS; Chen et al. (2008); Awadallah (2012); Mahmoudi-Meimand et al. (2015) avaliaram a krigagem e a entropia; Shaghaghian e Abedini (2013) usaram a geoestatística e análise fatorial, juntamente com uma técnica de agrupamento.

Percebe-se que a configuração de uma rede de estações pluviométrica é um dos fatores mais importantes para precisão dos dados. Com isso, destaca-se a importância e necessidade da otimização das redes existentes, reorganizando, adicionando ou retirando estações. Para que assim, a configuração da rede pluviométrica forneça maior precisão nos dados, em relação ao número de estações.

Contudo, na maioria das regiões, a rede de estações pluviométricas, não atende os valores recomendados pela Organização Mundial de Meteorologia. Há limitações para a instalação de novas estações, como o custo de instalação e manutenção, os locais nos quais as mesmas são instaladas devem ser de fácil acesso e sem obstruções próximas ao posto de observação, é necessário também ter pessoas que façam a leitura corretamente dos dados. Sendo assim, é importante o uso de métodos que permitam compreender os aspectos que influenciam a precipitação pluviométrica e otimizar a distribuição espacial dos dados pluviométricos. Para isso, foi estudada a variância de krigagem e seu comportamento em função da quantidade de estações pluviométricas e em função dos meses do ano.

2 OBJETIVO

Avaliar a variância da krigagem como indicador de possíveis locais que necessitam de novas estações pluviométricas no Rio Grande do Sul, e para compreender os aspectos que influenciam as médias climatológicas mensais da precipitação pluviométrica.

2.1 OBJETIVOS ESPECÍFICOS

- Identificar possíveis regiões, com maior variabilidade nas previsões por krigagem, como candidatos para instalação de estações pluviométricas.
- Avaliar o comportamento da variância máxima de krigagem para distintas densidades de amostragem.
- Compor uma modelagem GAMLSS para relacionar a variância de krigagem, a quantidade de estações pluviométricas e a variabilidade existente nos meses do ano.

3 REFERENCIAL TEÓRICO

3.1 PLUVIOMETRIA

Os pluviômetros e pluviógrafos recolhem amostras pequenas de chuva, considerando-se que sua superfície de exposição varia de 500 cm² a 200 cm². Eles são colocados a uma altura que varia de 1,0 m a 1,5 m acima do nível solo. O equipamento deve ser instalado longe de qualquer obstáculo natural ou artificial. As leituras dos pluviômetros são feitas manualmente, com isso, necessita-se de um observador para realizá-las em intervalos de tempo fixos, geralmente de 24 horas. Quanto aos pluviógrafos, esses possibilitam o registro de chuva de forma automatizada em menores intervalos de tempo (HOLTZ, 1976; TUCCI, 2012). Esse aparelho é visitado periodicamente por um observador ou equipe que controla a rede de aparelhos (TUCCI, 2012).

Sendo que os pluviômetros e pluviógrafos cobrem pequenas áreas, para conseguir um monitoramento detalhado em grandes áreas é necessário que haja uma densa rede de pluviômetros (FENSTERSEIFER, 2013). Muitas vezes esta rede é inexistente, devido aos altos custos de instalação e manutenção (BERNARDI, 2016). Uma rede de pluviômetros bem projetada é capaz de fornecer estimativas precisas de precipitação, com um número ideal de pluviômetros (SALLEH et al., 2019).

Os métodos tradicionais de quantificar a chuva são sujeitos a falta de descrição de eventos, pois a precipitação pode apresentar grande variação temporal e espacial e os postos pluviométricos realizam medidas pontuais. Há também erros e incertezas relacionados ao monitoramento pluviométrico, visto que obstáculos e o próprio vento são capazes de influenciar nas medidas dos equipamentos (BERNARDI, 2016).

O objetivo de uma estação pluviométrica é adquirir uma série contínua de precipitações ao longo dos anos. Porém, podem ocorrer períodos com falhas nas observações ou sem observações. As causas podem ser causadas pela danificação do aparelho ou problemas mecânicos no registrador gráfico, crescimento de vegetação ou alguma outra obstrução próxima ao posto de observação, quando a precipitação é muito alta pode haver soma errada do número de provetas, pode haver erro no valor estimado pelo observador, quando o mesmo não se encontra no local no dia da amostragem, preenchimento errado do valor na caderneta de campo (TUCCI, 2012).

A Organização Meteorológica Mundial (OMM) (2008) recomenda que os postos pluviométricos estejam uniformemente distribuídos conforme as necessidades de dados e a localização de observadores que fazem as leituras. É difícil manter o funcionamento de muitos postos pluviométricos em regiões que apresentem zonas de difícil acesso ou com uma população local pequena, em razão da dificuldade de encontrar pessoas que façam a observação das medidas. As áreas urbanizadas apresentam grande densidade populacional, o que demanda a existência de uma rede pluviométrica mais densa, por exemplo, para a gestão e controle de drenagem.

A OMM (2008) indica que deve haver uma estação a cada 900 km² em regiões costeiras, a cada 250 km² em regiões montanhosas e a cada 575 km² em áreas planícies interiores ou morros, o que indica que de acordo com Bernardi (2016), o Estado encontra-se em situação precária no monitoramento de chuvas. Uma rede de monitoramento de qualidade pode auxiliar na validação de informações provenientes de radares e outros sensores, o que assegura que possam ser realizadas estimativas de qualidade em locais de difícil acesso, onde não se consegue realizar monitoramento (BERNARDI, 2016).

O conhecimento da distribuição espacial da precipitação é essencial para diversas áreas, como a modelagem hidrológica, previsão de desastres e manejo de bacias (LY et al., 2011; FRAZIER et al., 2016). Dados de precipitação são necessários para projetos hidrológicos (GOOVAERTS, 2000). Mapas de precipitação em diferentes escalas de tempo podem ser utilizados na simulação de crescimento de culturas e em modelos hidrológicos para previsão de cheias (DELBARI et al., 2013).

As climatologias de precipitação são importantes para a pesquisa em hidrologia, clima e impactos regionais de mudanças globais. A compreensão do comportamento da precipitação é essencial para o planejamento dos recursos hídricos, como em lugares onde a água é escassa e dependente das chuvas locais. (FRAZIER et al., 2016). Como a maioria dos parâmetros climatológicos, geralmente são medidos em pontos fixos, como as estações meteorológicas e os pluviômetros (BORGES et al., 2016), as estimativas de alta resolução da variabilidade espacial de precipitação são necessárias para, por exemplo, serem usadas na identificação de tempestades locais intensas que podem levar a inundações (GOOVAERTS, 2000).

Um rede de estações pluviométricas deve representar espacialmente e temporalmente as chuvas. Estudos são realizados para estimar a localização, distribuição e prioridade das estações pluviométricas, para que haja um planejamento do número mínimo de estações necessárias e da localização ideal das mesmas. Uma rede pluviométrica deve ser bem planejada, para fornecer dados confiáveis e com precisão. Esses dados são usados, por

exemplo, para projeção e construção de estruturas hidráulicas, como drenagem e prevenção de inundações. A instalação das estações e seu ajuste influenciam na qualidade dos dados hidrológicos. Vários fatores devem ser considerados em um projeto de rede de chuvas, como a topografia do local, características da bacia, padronização da precipitação, orçamento. A mesma deve representar as características locais da precipitação. A quantidade necessária de estações pode variar de uma área para outra (YEH, 2011).

3.2 SISTEMAS ATMOSFÉRICOS ATUANTES DO RIO GRANDE DO SUL

No Rio Grande do Sul não há uma estação chuvosa definida. A precipitação é uniformemente distribuída durante o ano. Geralmente, as chuvas são causadas pelos Sistemas Convectivos de Mesoescala (SCM) e pelos Sistemas Frontais (SF) (TEIXEIRA, 2010).

Os SF são responsáveis por estruturar a convecção, ocasionando grandes taxas de precipitação, e conforme a velocidade que deslocam-se, podem causar grandes acúmulos de chuva. Estes sistemas entram no continente sul-americano durante todo o ano, porém no inverno sua frequência é maior (TEIXEIRA, 2010; RAVIEL, 2019). Quando eles chegam, podem provocar chuvas intensas, e em seguida as precipitações apresentam uma menor intensidade, mas com longa duração (RAVIEL, 2019). Britto, Barletta e Mendonça (2006) e Teixeira (2010) definiram que as precipitações, durante o inverno, na região litorânea e no centro-sul do Estado ocorrem especialmente por causa dos SF.

Segundo Siqueira e Machado (2004) há três tipos de interação entre os SF e a convecção sobre a América do Sul. O primeiro tipo de interação está relacionado à passagem dos SF pelo continente, os mesmos vem das latitudes médias ou subtropicais. Eles interagem com a convecção tropical e se movem juntamente para norte, chegando ao centro do continente, ao sul do nordeste da América do Sul e a bacia Amazônica. São mais frequente na primavera e no verão. Já o segundo tipo de interação, é provocada pela interação entre o SF e a convecção tropical, formando de uma convecção estendida da bacia Amazônica até o Atlântico Sul, apresentando um aumento na sua extensão em direção ao sul. Essa interação é mais frequente no verão. E a terceira interação está ligada com os SF quase estacionários nas latitudes médias ou nos subtropicais, e mostram pouca interação com a convecção tropical.

No verão, os SF, atingem a costa da Região Sudeste e da maior extensão da convecção tropical para o sul, e provocam eventos de Zona de Convergência do Atlântico Sul (ZCAS). Essa zona ocorre devido a intensificação do calor e da umidade, na porção central do Brasil, decorrente do encontro de massas de ar quentes e úmidas vindas Amazônia e do Atlântico

Sul. Geralmente, uma ZCAS estende-se do sul da região Amazônica até a porção central do Atlântica Sul (MENDONÇA; DANNI-OLIVEIRA, 2007).

Os SF têm influência também na geração de SCM. Esses sistemas modulam o Jato de Baixos Níveis da América do Sul (JBNAS), que é uma longa e estreita faixa de ventos do norte que forma-se a leste da Cordilheira dos Andes (SAULO et al., 2000). O JBNAS é importante para a formação dos SCM, os quais são responsáveis pelas chuvas intensas no Sul do Brasil (TEIXEIRA, 2010). O JBNAS é responsável pelo transporte de ar quente e úmido, proveniente dos ventos que passam pela região amazônica e muda de direção por causa do bloqueio topográfico que acontece paralelamente aos Andes e dirige-se para a região Sul (BASSO, 2019). A forte convergência do fluxo de umidade e de calor, em conjunto com a presença de uma corrente de jato em altos níveis, possibilita condições favoráveis a convecção nestas regiões (TEIXEIRA, 2010).

Os SCM formam as precipitações convectivas que, na primavera, influenciam nas chuvas da região sudoeste do estado. Os sistemas convectivos também ocasionam grande volume de chuva, no verão, na região nordeste. É na região sudoeste que acontecem os maiores volumes precipitados em uma estação do ano, sendo que no outono ocorre o bloqueio atmosférico, o qual facilita o evento de vários dias seguidos de chuva (BASSO, 2019).

Segundo Salio et al. (2007), entre setembro de 2000 a maio de 2003, ao menos um SCM subtropical se desenvolveu em 41% dos dias com JBNAS em todas as estações do ano, enquanto que nos dias sem ocorrência do JBNAS foi observado o desenvolvimento de SCM em apenas 12% dos dias. Nas regiões onde o JBNAS produz elevados valores de convergência do fluxo de umidade e calor, são observados os Complexos Convectivos de Mesoescala (CCM). Esses complexos, geralmente formam-se sobre o norte da Argentina e Sul do Brasil, e durante o inverno deslocam-se para leste, na direção de uma determinada região, e no verão na direção sudoeste-nordeste (GUEDES et al., 1994). Velasco e Fritsch (1987) verificaram que estes CCM formam-se com maior regularidade de novembro a abril, e, normalmente, formam-se no final do dia, atingindo sua máxima intensidade durante a madrugada.

De acordo com Grimm (2009), os Complexos Convectivos de Mesoescala (CCM) acontecem em todas as estações do ano, mas há uma maior incidência no período quente de outubro até maio, causando grande parte da precipitação total no estado. Os CCM estão relacionados a eventos de precipitações intensas, vento fortes, descargas elétricas atmosféricas, e até granizo (FERREIRA, 2016).

3.3 INTERPOLAÇÃO ESPACIAL

A interpolação compreende o processo de determinar valores desconhecidos de um atributo contínuo, utilizando valores conhecidos, ou seja, que foram amostrados pontualmente (ANDRIOTTI, 2003; MIRANDA, 2015). Assim, pode-se representar um mapa de maneira contínua (ANDRIOTTI, 2003). Nesse processo define-se quais pontos são os vizinhos apropriados e os métodos através dos quais serão calculados os valores desconhecidos. Técnicas de interpolação globais buscam ajustar um modelo de superfície utilizando, simultaneamente, todos os pontos de dados conhecidos. Enquanto os interpoladores locais, usam apenas os dados de vizinhança para as estimativas, utilizando pequenas regiões nos arredores do ponto interpolado (MIRANDA, 2015).

A qualidade da interpolação depende do número e distribuição dos pontos amostrados, da precisão dos mesmos, e da qualidade da modelagem do fenômeno por meio de uma função matemática. Os valores de amostras mais próximas tem mais probabilidade de serem parecidos do que valores de amostras mais distantes (MIRANDA, 2015).

Geralmente é realizada uma comparação entre métodos de interpolação espacial determinísticos e geoestatísticos (BURROUGH; MCDONNELL, 1998). A interpolação determinística cria superfícies a partir de pontos medidos, com base na extensão da similaridade (ISAAKS; SRIVASTAVA, 1988), como por exemplo, no inverso do quadrado da distância. Métodos determinísticos não usam a teoria da probabilidade (SOARES, 2014). Já a interpolação geoestatística utiliza as propriedades estatísticas dos pontos medidos, permitindo utilizar a correlação espacial entre os pontos medidos para criar a configuração espacial dos pontos de amostra em torno do local de previsão, para prever valores de variáveis em locais não amostrados (GOOVAERTS, 2000).

A técnica de interpolação espacial é usada para obtenção de dados de precipitação em superfícies contínuas (GOOVAERTS, 2000; KEBLOUT, 2012). Na interpolação espacial estima-se o valor regionalizado para pontos não amostrados, por meio de uma ponderação dos valores regionalizados observados (LY et al., 2011). Para realizar uma estimativa mais precisa da distribuição espacial das chuvas, deve haver uma rede muito densa de instrumentos, o que gera custos operacionais e de instalação elevados. Também é necessário que o observador faça as leituras regularmente para que não haja falhas que podem resultar em densidades de amostragem ainda menores (GOOVAERTS, 2000).

A Geoestatística caracteriza a dispersão espacial e temporal de fenômenos espaciais que tenham uma estrutura no espaço e/ou no tempo, como a precipitação pluviométrica. A

Geoestatística também avalia as medidas de incertezas, levando em conta a qualidade das amostras e observações, o conhecimento do fenômeno e sua maior ou menor variabilidade e o tipo de método geoestatístico escolhido (SOARES, 2014).

Geralmente os fenômenos estudados na Geoestatística possuem um conjunto de amostras ou observações limitados (SOARES, 2014). A Geoestatística é um conjunto de técnicas que englobam análise exploratória, geração e modelagem de semivariogramas, validação do modelo e interpolação (MIRANDA, 2015). Fenômenos como a pluviometria de uma região têm duas características comuns, possuem uma estrutura, e suas informações disponíveis são insuficientes, o que gera a razão do uso dos modelos geoestatísticos (SOARES, 2014).

Há diversos métodos de interpolação de variáveis no espaço, como por exemplo, o inverso da potência das distâncias, a krigagem, co-krigagem, equações multiquadráticas, spline de tensão, entre outros. Neste estudo, utilizar-se-á o método da krigagem, visto que é um dos métodos mais utilizados na literatura, e permite gerar a variância da krigagem que é usada para indicar os locais onde há falta de amostras que possam melhorar o monitoramento.

3.3.1 Krigagem

Um dos métodos de interpolação geoestatística mais utilizados é a krigagem (WEBSTER; OLIVER, 2007). Baseia-se na estrutura espacial dos dados (FRAZIER et al., 2016), utilizando a correlação espacial das variáveis (WEBSTER; OLIVER, 2007). E assume que pontos de dados mais próximos são mais parecidos do que pontos mais distantes (FRAZIER et al., 2016), atribuindo assim, mais peso às estações próximas (WEBSTER; OLIVER, 2007). A krigagem fornece também uma estimativa de incerteza e é capaz de incorporar facilmente variáveis secundárias (FRAZIER et al., 2016).

A combinação linear dos valores encontrados na vizinhança próxima fornece a estimativa em um ponto não amostrado (YAMAMOTO; LANDIM, 2013). Os pesos ótimos são calculados de acordo com duas condições de restrições (JOURNEL; HUIJBREGTS, 1978): que o estimador não seja enviesado e que a variância de estimativa seja mínima. Na krigagem ordinária resolve-se um sistema de equações para determinar os pesos que minimizam a estimativa da variância (FRAZIER et al., 2016).

Na krigagem os valores medidos em locais próximos tem a probabilidade de serem estatisticamente mais relacionados que os valores mais distantes (TVEITO et al., 2008). Sendo um método probabilístico, a krigagem depende de relações espaciais e estatísticas para

prever valores em pontos não amostrados. Através do semivariograma avalia-se a autocorrelação espacial de conjuntos de dados (GOOVAERTS, 2000). Acredita-se que os pares mais próximos difiram menos do que os pares que são mais distantes um do outro. Para modelar a autocorrelação espacial dos dados, são testadas as funções estatísticas que melhor se adequam ao semivariograma (BORGES et al., 2016). O estimador da krigagem ordinária é (equação 1) (JOURNEL; HUIJBREGTS, 1978):

$$Z^*(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (1)$$

Sendo:

$Z(x_i)$ = variável observada no ponto x_i ;

n = número de vizinhos usados no cálculo da variável;

λ_i = peso associado a cada valor medido

O método da krigagem considera a maneira como uma variável varia no espaço, através do modelo de semivariograma (WEBSTER; OLIVER, 2007). O semivariograma é uma função da distância e da direção que pode explicar a variabilidade dependente da direção (anisotropia) (DI PIAZZA et al., 2011). O semivariograma é uma função intrínseca que representa a estrutura do fenômeno estudado.

O semivariograma representa quantitativamente a variação de um fenômeno no espaço (MIRANDA, 2015).

No semivariograma, com o aumento da distância entre os pontos, também há o aumento do valor da semivariância. Há um determinado momento em que a semivariância atinge o patamar e então permanece constante. A distância em que o semivariograma atinge o patamar é denominado de alcance. Nessa distância as amostras apresentam-se correlacionadas espacialmente.

As amostras que encontram-se separadas por distâncias menores que o alcance são correlacionadas umas às outras. Isso permite que façam-se interpolações para espaçamentos menores do que os amostrados (VIEIRA, 2000). Com isso, sendo que o alcance é a distância limite da dependência espacial entre as amostras, quanto menor o alcance, mais rápido é obtida a independência entre as amostras (SILVA et al., 2007).

Há uma descontinuidade no semivariograma que é considerada o efeito pepita (ISAAKS; SRIVASTAVA, 1989; VIEIRA, 2000). Para Wu et al. (2008), o efeito pepita

caracteriza o erro experimental e a variação do fenômeno no espaço, dentro das distâncias mínimas de amostragem.

De acordo com Yamamoto e Landim (2013), a função semivariograma mede a variância entre os pontos que são separados por uma distância. Com isso, para pontos próximos, sendo que a diferença entre eles é pequena, a semivariância também é. Conforme a distância aumenta, os valores dos pontos vão ficando mais diferentes, sendo assim, a semivariância aumenta. A partir de uma certa distância, a semivariância se estabiliza em torno da semivariância máxima. Assim, mesmo que a distância aumente, a função do semivariograma se mantém em torno da semivariância máxima, que é considerada patamar.

Após a construção dos semivariogramas experimentais, é necessário ajustá-los aos modelos teóricos conhecidos, como o esférico, exponencial e gaussiano (ANDRIOTTI, 2003). O modelo esférico é um dos modelos mais usuais da Geoestatística. Ele é função de dois parâmetros, o patamar e a amplitude. O patamar é o limite superior do qual aproximam-se os valores do semivariograma com o aumento dos valores. E o alcance é a distância na qual os valores param de crescer e tem o mesmo patamar, que é geralmente igual a variância (SOARES, 2014).

O modelo exponencial é uma função dos mesmos parâmetros do modelo esférico. Nesse modelo, o alcance é a distância em que se atinge 95% do patamar. Esse modelo se caracteriza por apresentar uma maior continuidade espacial, que é resultante das maiores correlações espaciais a grandes distâncias (SOARES, 2014).

Tanto o modelo esférico quanto o exponencial tem um crescimento rápido junto da origem, o que caracteriza um comportamento de fenômenos irregulares. No modelo gaussiano, há um crescimento lento caracterizado por um comportamento parabólico na origem. Esse modelo caracteriza fenômenos regulares e contínuos (SOARES, 2014).

Existem vários tipos de krigagem como a krigagem simples, krigagem da média, krigagem ordinária, krigagem universal, entre outros, sendo que o método mais usado é o da krigagem ordinária (YAMAMOTO; LANDIM, 2013).

3.3.1.1 Variância da krigagem

A krigagem fornece também uma estimativa de variação de erro. Essa variação depende do modelo de covariância (ou semivariância), onde a precisão da estimativa depende da complexidade da variabilidade espacial do atributo como modelos pela covariância. Depende também da configuração dos dados, onde são representadas a geometria relativa dos

locais de dados e suas distâncias para o local estimado. E independem dos valores dos dados, pois para um determinado modelo de covariância, independentemente de quais fossem os dados, duas configurações de dados idênticas produziriam a mesma variação de krigagem (GOOVAERTS, 1997).

Segundo GOOVAERTS (1997) a variância da krigagem é totalmente controlada pela configuração dos dados. A variância do erro é zero nos locais dos dados, aumenta conforme se afasta dos dados e atinge um valor máximo em uma situação de extrapolação, que vai além do ponto extremo. Portanto, a medida que a localização estimada se afasta dos locais de dados, tanto a covariância quanto o peso de krigagem diminuem, com isso a variância da krigagem aumenta.

A krigagem gera variações de erro semelhantes em locais com configurações de dados semelhantes. No entanto, espera-se que o potencial de erro seja maior em um local com dados muito diferentes do que em um local cercado por dados com valores semelhantes. A variância da krigagem (equação 2) não está condicionada aos valores de dados utilizados. Ela é definida como (YAMAMOTO; LANDIM, 2013):

$$\sigma^2 = \sum_{i=1}^n \lambda_i \gamma(h) + \mu \quad (2)$$

Sendo:

$\gamma(h)$ = valor do modelo de semivariograma;

λ_i = peso associado a cada valor medido;

μ = multiplicador de lagrange

Se as configurações dos dados, em locais diferentes, fossem as mesmas, a variância da krigagem seria uma estimativa da variação do erro. Porém, devido a média das realizações dos valores dos dados, a variância da krigagem utiliza apenas a geometria dos dados utilizados, e não os valores dos dados. Sendo assim, a variância da krigagem é um índice de classificação da geometria e tamanho dos dados, não uma medida da propagação local dos erros (GOOVAERTS, 1997).

3.4 MODELAGEM GAMLSS

A modelagem GAMLSS permite uma quantidade maior de distribuições de probabilidade para descrever o comportamento da variável de interesse, como por exemplo, distribuições contínuas, assimétricas, para contagens e outras, e é flexível na modelagem dos parâmetros das distribuições de probabilidade consideradas.

O preditor linear, no modelo GAMLSS, permite a inclusão de efeitos paramétricos e de efeitos não-paramétricos por meio de funções de suavização e de efeitos aleatórios. O modelo de regressão GAMLSS (equação 3) pode ser definido como (RIGBY, STASINOPOULOS, 2005; 2010):

$$g_k(\theta_k) = \eta_k = X_k \beta_k + \sum_{j=1}^{J_k} Z_{jk} \gamma_{jk} \quad (3)$$

em que $g_k(\cdot)$ é uma função de ligação para o k -ésimo parâmetro θ ; $k= 1, 2, \dots, K$; η é o preditor linear; β é o vetor de parâmetros de efeitos fixos do modelo linear; X é uma matriz experimental; γ é um vetor de efeitos aleatórios associados a variáveis e/ou fatores expressos na matriz experimental Z .

4 METODOLOGIA

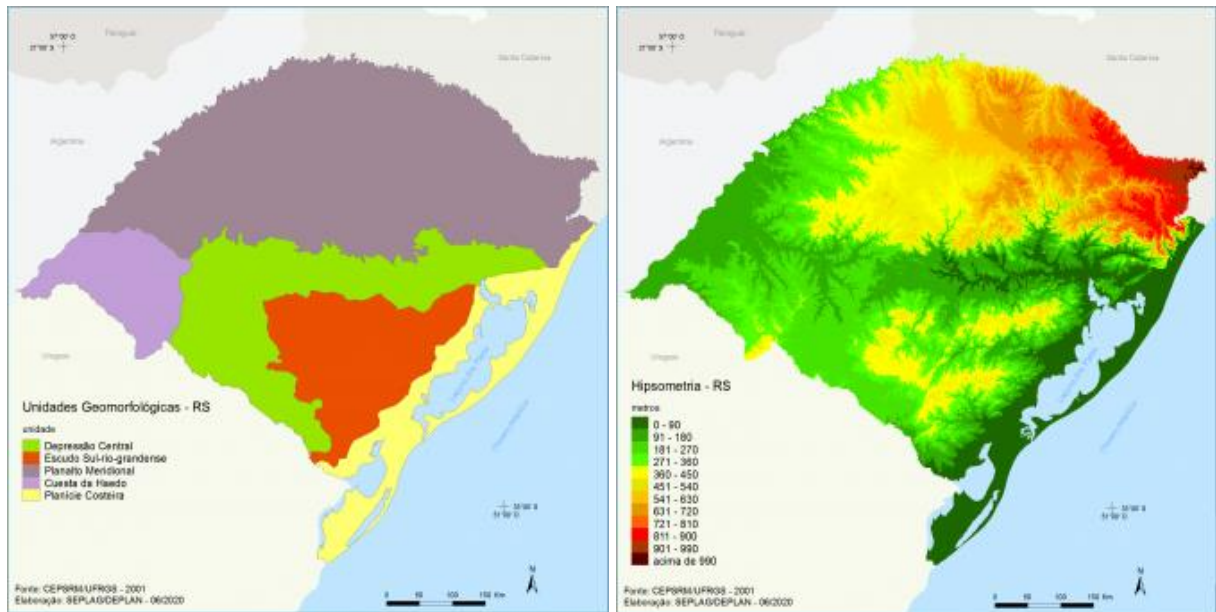
A pesquisa demanda uma série de etapas envolvendo manipulação e processamento dos dados. O estudo consiste em uma análise da variância de krigagem como indicador para pontuar locais que necessitam de estações pluviométricas, visando melhorar o monitoramento. E verificar se há relação da variância máxima da krigagem com o número de estações ou com a densidade de estações. O software usado para realizar as análises será o R (R CORE TEAM, 2019).

4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

O Rio Grande do Sul, localiza-se no Sul do Brasil, entre as coordenadas 27° e 34° de latitude Sul e 49° e 58° de longitude Oeste. Faz divisa com o estado de Santa Catarina ao norte, ao noroeste com a Argentina, sudoeste pelo Uruguai e ao sudeste pelo Oceano Atlântico. O estado possui 11.329.605 milhões de habitantes (IBGE, 2018) com uma extensão territorial de 281.730,2 km², resultando em uma densidade populacional de 40,21 hab/km² (RIO GRANDE DO SUL, 2018).

O território do estado do Rio Grande do Sul está localizado na zona temperada do Sul, que está compreendida entre o trópico de Capricórnio e o círculo polar Antártico. Por estar localizado a uma latitude média de 30° Sul, o estado encontra-se mais perto da linha do Equador, o que faz com que o território rio-grandense tenha uma posição subtropical. O relevo do estado é bem diversificado, possuindo 4 diferentes unidades geomorfológicas, cada qual com suas altitudes. São elas: o Planalto Sul Rio-Grandense, o Planalto Norte Rio-Grandense, a Depressão Central, e a Planície Litorânea (Figura 1) (MOREIRA, 2002).

Figura 1 - Unidades Geomorfológicas e Hipsometria do Rio Grande do Sul



Fonte: Atlas Socioeconômico do Rio Grande do Sul (2020).

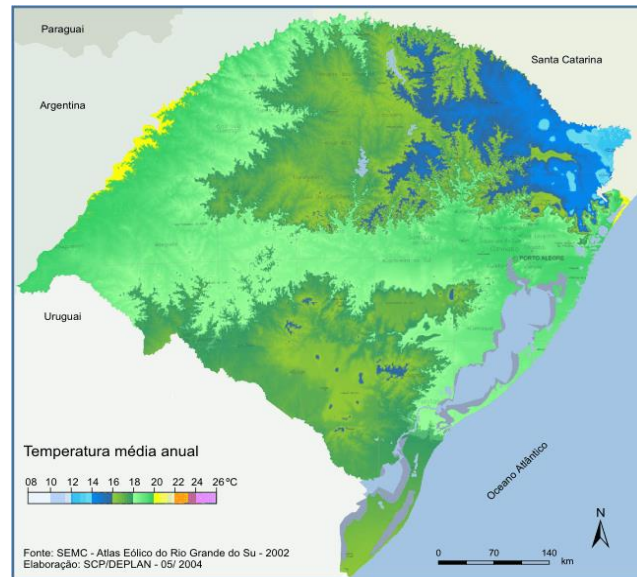
No Planalto Sul-Rio-Grandense somente em alguns lugares as altitudes ultrapassam 300 metros. Já o Planalto Norte-Rio-Grandense apresenta em sua parte leste e nordeste altitudes que chegam a mais de mil metros. As altitudes nesse Planalto diminuem aos poucos de leste para oeste, e em sua parte leste e sudeste, termina com uma encosta. Já a Depressão Central e a Planície Litorânea são compostas por uma faixa de terrenos mais baixos (MOREIRA, 2002).

O ar atmosférico no RS varia muito durante o ano, em consequência da posição geográfica do estado. No meses de verão, geralmente os ventos veem do norte. Esses ventos são quentes devido a sua origem em latitudes baixas. Com isso, ocasionam altas temperaturas, principalmente nos meses de dezembro e janeiro. Já nos meses de inverno, os ventos são de origem polar, o que faz com que sejam frios e provocam baixas temperaturas, especialmente nos meses de junho e julho (MOREIRA, 2002).

A oscilação da temperatura na região, é bem definida tanto espacial quanto temporalmente. As médias anuais da temperatura no estado encontram-se entre 14 e 22°C (Figura 2). Nas partes mais elevadas, onde ocorre queda de neve de inverno, as médias anuais de temperatura chegam a 10°C. No verão as temperaturas médias mensais são elevadas, oscilando entre 26 e 30 graus. Essa última é registrada, principalmente, ao norte e nas partes mais baixas. Nos vales interioranos podem atingir 40 graus. Já no inverno as médias mensais

variam de 10 a 15 graus, principalmente no mês de julho. Nessa época são registradas temperaturas negativas (MENDONÇA; DANNI-OLIVEIRA, 2007).

Figura 2 - Temperatura média anual do Rio Grande do Sul



Fonte: Atlas Socioeconômico do Rio Grande do Sul (2020).

O clima no estado sofre influência de fatores regionais como o relevo, latitude, distância do mar e altitude. Devido a influência do relevo, por exemplo, nas partes elevadas da Serra Geral chove um pouco mais que nas demais regiões do estado. Já a distância do mar interfere na temperatura, pois as altas diferenças de temperatura entre o verão e o inverno variam conforme aumenta a distância do mar, esse fator chama-se continentalidade (MOREIRA, 2002). Os efeitos de continentalidade e maritimidade interferem também no total de chuva precipitado. As regiões costeiras tem um índice maior de umidade e maior volume precipitado ao longo do ano. Já nas regiões mais distantes do litoral ocorre o contrário (GRIMM, 2009).

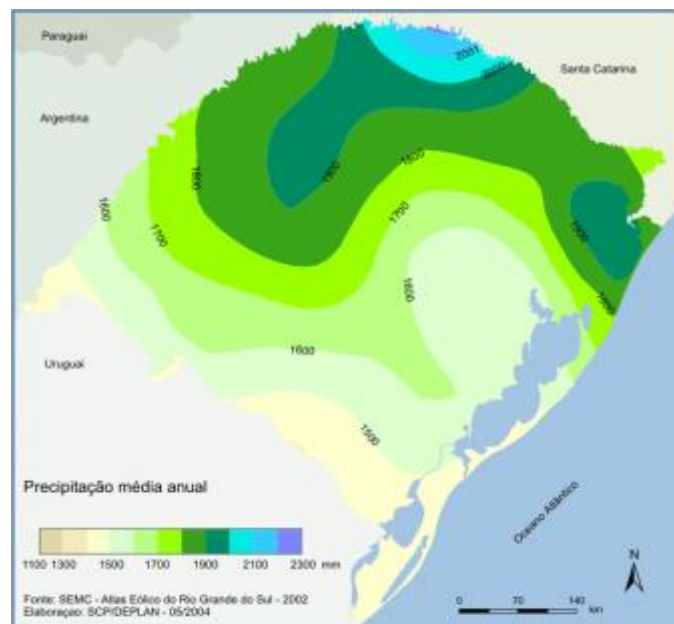
O clima do estado é do tipo subtropical úmido (RIO GRANDE DO SUL, 2018). Segundo a classificação de Köppen, há predominância do clima Cfa, com verões quentes e umidade em todas as estações (BERNARDI, 2016). Esse clima é caracterizado por apresentar a temperatura do mês mais quente superior a 22°C (FAVARETTO, 2016). Em uma pequena área na região nordeste do estado é encontrado o clima Cfb (BERNARDI, 2016), o qual é caracterizado por verões amenos, em que o mês mais quente deve possuir temperatura inferior a 22°C (FAVARETTO, 2016). A temperatura média anual varia de 14°C a 22°C (RIO

GRANDE DO SUL, 2018). O mês mais frio ocorre em julho, com temperatura entre 3 e 18 °C (FAVARETTO, 2016).

4.1.1 Precipitação no Rio Grande do Sul

A região Sul do Brasil apresenta características como a distribuição anual regular da pluviometria, entre 1250 e 2000 mm e as baixas temperaturas no inverno. Essas são as principais características que diferem o clima da região Sul das outras regiões do país. Elas são decorrentes do relevo da área, sua posição geográfica e da ação dos sistemas atmosféricos polares e intertropicais (MENDONÇA; DANNI-OLIVEIRA, 2007). No Rio Grande do Sul a precipitação é bem distribuída ao longo do ano, varia de 1000 a 2000 milímetros (Figura 3). As chuvas estão aumentando sua concentração em um curto espaço de tempo, alternadas com períodos de estiagem (RIO GRANDE DO SUL, 2018).

Figura 3 - Precipitação média anual do Rio Grande do Sul



Fonte: Atlas Socioeconômico do Rio Grande do Sul (2020).

O *El Niño* e a *La Niña* são irregularidades do sistema climático que caracterizam uma alteração no Oceano Pacífico tropical e na atmosfera, causando efeitos no tempo e no clima. O *El Niño* provoca o aquecimento incomum das águas superficiais e sub-superficiais do Oceano Pacífico Equatorial. Além disso, provoca mudanças na atmosfera próxima à superfície do oceano, devido ao enfraquecimento dos ventos alísios, que sopram de leste para

oeste, na região equatorial. Com o aquecimento do oceano e o enfraquecimento dos ventos, são verificadas mudanças da circulação da atmosfera nos níveis baixos e altos, definindo mudanças nos padrões de transporte de umidade, e com isso variações na distribuição das chuvas em regiões tropicais e de latitudes médias e altas (OLIVEIRA, 2001).

Os fenômenos *El Niño* e *La Niña* interferem no regime de precipitação da América do Sul. Quando o fenômeno do *El Niño* ocorre, a temperatura de superfície do oceano Pacífico aumenta, exceto na porção Oeste. Esse aumento da temperatura gera maior convecção atmosférica. Com isso, em anos de *El Niño*, a precipitação total anual tende a aumentar na região sul do Brasil, e diminuir na região nordeste. A *La Niña*, por sua vez, tem características e efeitos opostos ao *El Niño*. Assim, em anos de sua ocorrência, a precipitação na região sul diminui, enquanto na região nordeste fica acima da média (GRIMM, 2009).

As chuvas ocorrem em todos os meses do ano. Em sua maioria, elas ocorrem devido a influência do ar polar. O contato do ar frio, de origem polar, com o ar quente, de origem tropical, são as frentes, as quais, ao se deslocarem, ocasionam chuvas por onde passam. Devido às chuvas serem bem distribuídas ao longo do ano, o clima é classificado como úmido (MOREIRA, 2002).

Os regimes de precipitação no Sul do país apresentam um grande contraste. Isso deve-se, em parte, à situação geográfica da região, que possui um relevo acidentado e se localiza entre os trópicos e latitudes médias. Nos subtropicais, por exemplo, a situação geográfica ocasiona uma maior amplitude do ciclo anual de temperatura, havendo um maior contraste entre o inverno e o verão. Em latitudes mais altas há uma grande diferença entre radiação solar recebida no verão e no inverno (GRIMM, 2009).

O planalto meridional e as serras são as únicas regiões onde há precipitação em forma de neve, devido aos contrastes marcantes na distribuição de temperaturas. A topografia determina as regiões mais frias do Sul, e também é responsável pelo comportamento do gradiente da temperatura, típico de cada estação do ano. A concentração de precipitação é maior nos meses de agosto, setembro e outubro na maior parte do Rio Grande do Sul (GRIMM, 2009).

Em áreas de latitudes mais altas as temperaturas são menores devido a incidência da radiação solar. A metade norte do estado apresenta valores das médias mensais de precipitação maiores em comparação com a metade sul. Em relação a longitude, o leste do Estado é mais úmido e oeste menos úmido, a umidade favorece a ocorrência de chuvas (ROSSATO, 2011).

Reboita et al. (2012), determinaram que a altitude influencia na temperatura e na movimentação dos ventos na atmosfera, facilitando a formação das nuvens e da precipitação, o que acontece por causa da grande variedade do relevo do estado. A região leste do estado é uma das regiões mais declivosas do estado, com estações tanto em vales como em encostas, sofrendo forte influência orográfica (RAVIEL, 2019).

Na região Sul do Brasil no outono predominam totais de chuva entre 150 mm e 400 mm. No inverno o principal sistema meteorológico é a frente fria, o qual geralmente, é de fraca intensidade. Porém pode ocorrer a passagem de algum sistema frontal mais intenso, que causa chuvas em toda a Região Sul. Na primavera há poucas alterações nos totais mensais de chuva, onde a ocorrência de chuvas é praticamente uniforme ao longo de todo o ano. No entanto, pode ocorrer grande quantidade de chuva em períodos relativamente curtos, devido ao aumento na ocorrência de raios e de complexos convectivos nessa época. Na estação do verão, as variações rápidas do tempo levam ao regime de chuvas de pequena duração e forte intensidade, geralmente no período da tarde. Na Região Sul, as chuvas variam entre 300 mm e 500 mm (INPE, 2016).

4.1.2 Pluviometria

De acordo com informações da Agência Nacional de Águas (ANA) e do Instituto Nacional de Meteorologia (INMET), há 514 estações com dados de chuva cadastradas no banco de dados. Estas estações estão distribuídas em 281.730,22 km² do Estado do Rio Grande do Sul (RS), sendo assim o Estado conta com 1 estação pluviométrica para cada 548,11 km², (BERNARDI, 2016). De acordo com Basso (2019) a rede de monitoramento de estações pluviométricas, possuem séries históricas mais longas, do que a rede de monitoramento através de pluviógrafos.

Dentre as estações pluviométricas do Estado do Rio Grande do Sul, muitas não estão mais em funcionamento ou pararam de ser monitoradas. Apenas 290 postos localizados dentro dos limites do RS possuem dados monitorados desde 1998, passando a densidade de estações pluviométricas para 1 ponto a cada 971,48 km². Considerando o período de 1998 a 2013, muitos destes postos possuem menos que 75% das séries. Um exemplo é o ano de 2007, que apresenta somente 50 estações pluviométricas da ANA que dispõem da série anual com 10% ou menos de falhas (BERNARDI, 2016).

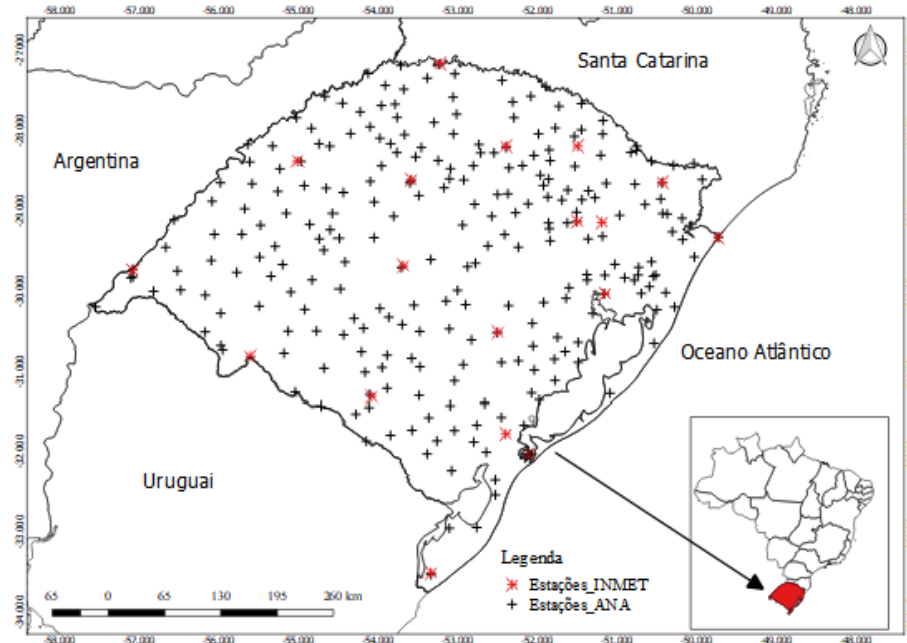
4.2 AQUISIÇÃO DOS DADOS

A ANA e o INMET são órgãos que realizam o monitoramento pluviométrico no estado do Rio Grande do Sul. A ANA é o principal banco de dados com informações sobre recursos hídricos do Brasil. Os dados do monitoramento realizado pela ANA são disponibilizados através de portais na internet, os quais são de livre acesso, como o Sistema de Informações Hidrológicas HidroWeb (ANA, 2019) e o Banco de Dados Meteorológicos para Ensino e Pesquisa BDMEP (INMET, 2019).

Para o estudo foram selecionadas somente as estações que possuíam dados disponíveis para um período de 30 anos. Esse período foi determinado para obter um tamanho grande de amostra. Considerando que 2018 é o último ano com dados completos, o intervalo selecionado para estudo foi então, de 1989 a 2018. No total são 316 estações com alguma informação nesses 30 anos.

Sendo que as séries diárias de precipitação de cada estação, compreendem diferentes períodos, foram selecionadas estações que tivessem um histórico de dados em um período de, pelo menos, 5 anos, visando ter mais que 10% dos anos e o mínimo de confiabilidade dos dados, a fim de não perder a representatividade espacial da variabilidade da chuva. Se essa quantidade de anos fosse aumentada, diminuiria muito o tamanho da amostra. Com isso foram usadas 259 estações da ANA e 18 do INMET, que podem ser observadas na Figura 1. Na pesquisa foram utilizados dados brutos de precipitação. A Figura 4 mostra a distribuição espacial das estações pluviométricas no Rio Grande do Sul.

Figura 4 - Mapa da distribuição espacial das estações pluviométricas do Rio Grande do Sul



Fonte: Autora (2019).

Primeiramente os dados foram baixados no portal HidroWeb da ANA e no INMET, para posterior análise no Software R. A obtenção dos dados no site da Hidroweb é feita manualmente, baixando os dados de estação por estação, um a um. Devido ao grande número de estações, foi solicitado a ANA a disponibilidade dos dados via e-mail. Já a aquisição de dados do INMET foi realizada de forma manual por serem somente 18 estações.

4.2.1 Ajuste dos dados pluviométricos

Primeiramente foram selecionadas os dados dos últimos 30 anos (de 1989 até 2018). Os mesmos foram copiados para uma planilha do Excel. Após, foi realizada a soma dos valores diários de cada mês, tendo então a estação pluviométrica com a soma correspondente a cada mês de cada ano. Depois disso, foi realizada a contagem, através do software R para verificar quais estações possuíam 5 anos ou mais de dados no período. Foram então, selecionadas as estações que atenderam a esse critério.

No total, foram 259 estações monitoradas pela ANA que possuíam, pelo menos, 5 anos de dados, e 18 estações do INMET, totalizando 277 estações pluviométricas. Foram somados os valores de cada mês em cada estação, obtendo assim para estação a soma dos valores de janeiro, fevereiro, e de todos os outros meses. Após ter os valores de soma dos

dados de cada estação, e a contagem de quantas vezes cada mês possuiu um valor, foi realizada a média da soma, obtendo desse modo a média climatológica de cada mês para cada uma das 277 estações. Esses foram os dados usados para a pesquisa.

4.2.2 Manipulação dos dados no Software R

A primeira análise realizada no software R foi verificar o comportamento dos dados, através de uma análise exploratória dos mesmos. Foram utilizados os dados das médias climatológicas mensais. Nesse comportamento foi verificado se os valores dos dados apresentavam ou não tendência significativas, para uma compreensão preliminar da variação espacial da precipitação. Essa avaliação possibilita o ajuste da superfície através dos dados observados. A análise de tendência foi feita por meio da geração de mapas, usando a análise gráfica disponível no pacote geoR (RIBEIRO JR; DIGGLE, 2001). Havendo a existência de tendência nos dados, a mesma é retirada e trabalha-se com os resíduos, que é a diferença entre os valores observados e os valores ajustados.

Por meio da análise de tendência dos dados é possível observar as mudanças no comportamento do fenômeno estudado e as regiões em que o mesmo vem sofrendo mudanças significativas ao longo do tempo.

Após foi realizada a análise variográfica, onde é analisado a variabilidade dos dados através de um gráfico chamado de semivariograma. A técnica de krigagem requer um modelo de semivariograma apropriado que define a estrutura espacial dos dados observados. Primeiramente, é derivado um semivariograma experimental a partir dos dados observados, depois um modelo de semivariograma funcional é então ajustado ao semivariograma experimental.

O semivariograma é usado na técnica da krigagem para representar quantitativamente a variação, da variável estudada, no espaço. Ele associa as semivariâncias com as distâncias entre pontos amostrados e suas direções. O modelo do semivariograma obtido conterá as informações necessárias para serem usadas na interpolação de krigagem dos dados observados. O ajuste e a seleção do modelo de semivariograma apropriado são realizados através da técnica de modelagem de semivariograma.

Sendo que as observações dos pontos geograficamente mais próximos devem ter um comportamento semelhante, do que pontos mais distantes, o valor da semivariância deve crescer à medida que aumenta a distância entre os pontos, até atingir o patamar, onde não há mais influência e as amostras se tornam independentes.

Considerou-se a isotropia, onde o comportamento dos dados é igual em todas as direções. Sendo assim, a determinação do semivariograma depende apenas da distância entre os pontos e não da direção entre elas. Na construção do gráfico do semivariograma foram testados 50%, 60%, 70% e 80% da distância máxima. E como estimadores foram testados o estimador clássico (Matheron, 1962) e o robusto (Cressie e Hawkins, 1980).

Após avaliar o estimador, no qual, a estrutura do semivariograma apresenta um comportamento melhor e a distância em que os pontos melhor se adequaram no semivariograma, ajusta-se um modelo matemático que represente o comportamento e a distribuição dos pontos, a fim de modelar a variabilidade do fenômeno observado e descrever o comportamento da dependência espacial. Os modelos testados foram o esférico, exponencial e Gaussiano. Esses modelos são ajustados e verificados visualmente conforme o modelo melhor se adequa, e pelo método dos Mínimos Quadrados Ponderados. A avaliação do desempenho dos modelos é baseado no valor do R^2 adaptado para modelos não-lineares. O modelo que apresentar um R^2 mais próximo de 1, é considerado o melhor ajustado.

A análise de dependência espacial foi avaliada pelo Índice de Dependência Espacial (IDE) proposto por Seidel e Oliveira (2014; 2016). No IDE, a classificação (Tabela 1) varia de acordo com o modelo.

Tabela 1 – Classificação do Índice de Dependência Espacial

Modelo	Fraco	Moderado	Forte
Esférico	$\leq 7\%$	$7\% < IDE \leq 15\%$	$> 15\%$
Exponencial	$\leq 6\%$	$6\% < IDE \leq 13\%$	$> 13\%$
Gaussiano	$\leq 9\%$	$9\% < IDE \leq 20\%$	$> 20\%$

Fonte: Seidel e Oliveira (2016).

4.3 AVALIAÇÃO DA VARIÂNCIA DA KRIGAGEM

Depois de definir um modelo de semivariograma apropriado para o conjunto de dados observado e avaliar o modelo, estima-se a krigagem para a geração de superfícies interpoladas. A partir da krigagem, estima-se a variância da krigagem, para verificar regiões onde há alta variabilidade e podem ser inseridas mais estações, melhorando a formatação de amostragem.

Os valores de variância máxima, apresentados no mapa, indicam os locais de maior variabilidade. Os mapas mostram a variabilidade em uma escala de cores, onde as áreas com

maior variabilidade são representadas pela cor em vermelho, que são as possíveis regiões candidatas a receber novas estações pluviométricas.

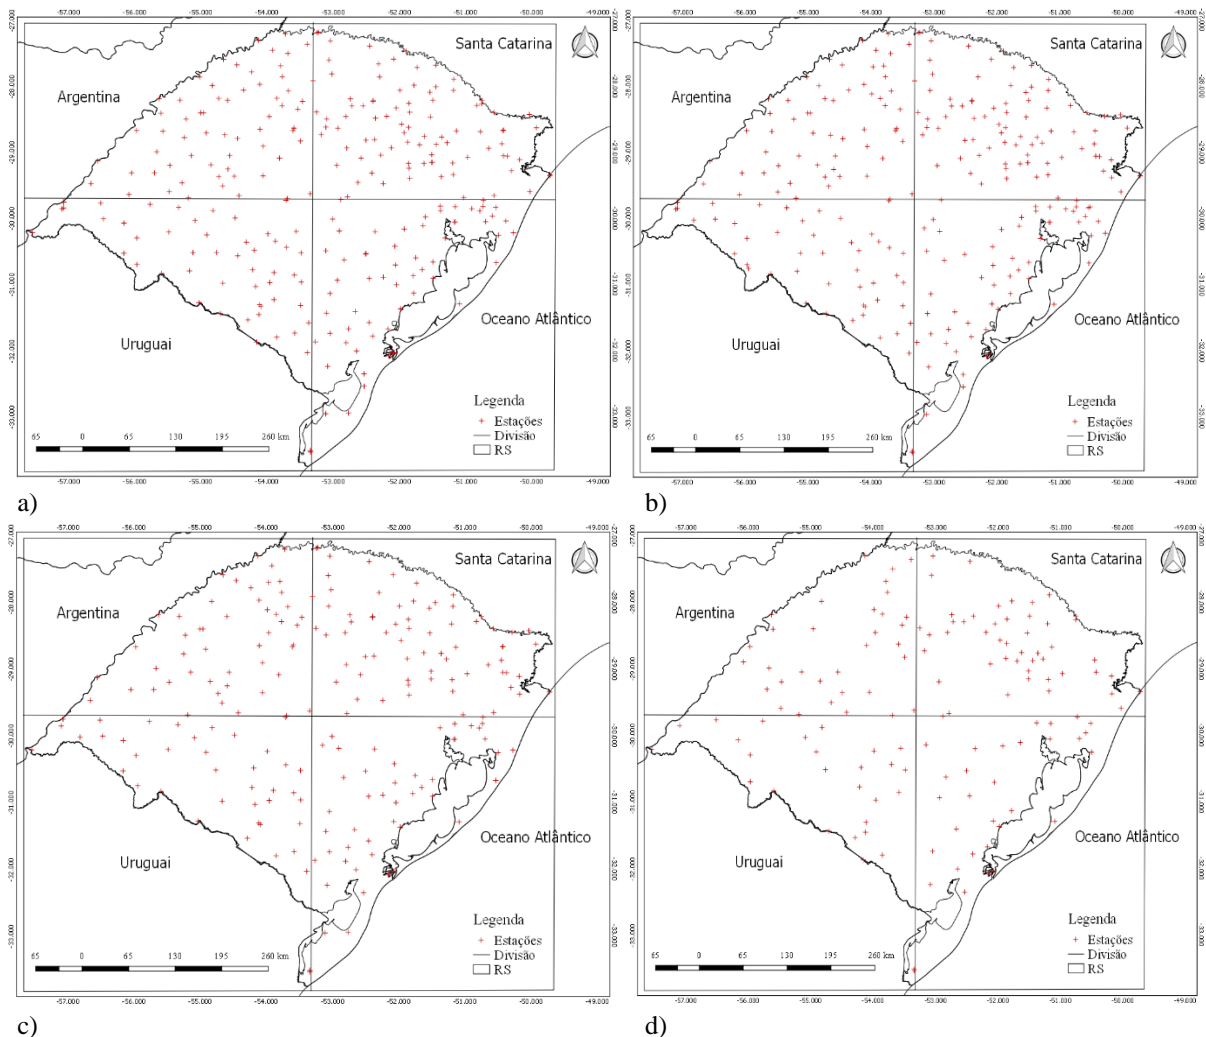
4.4 REDUÇÃO DA DENSIDADE DE AMOSTRAS PARA MODELAGEM GAMLSS

Os mapas foram gerados utilizando todas as estações. Após foi variada a porcentagem das mesmas a fim de verificar a influência que o número de estações acarreta na estimativa da variância de krigagem. A densidade das estações pluviométricas foi reduzida sistematicamente de 100% para 95%, 90%, 75% e 50%.

Para realizar essa redução do número de estações pluviométricas, o Estado do RS foi dividido em 4 quadrantes. Essa divisão foi feita para que as estações sejam eliminadas de forma mais proporcional. Sendo que o sorteio foi feito por quadrante. Os quadrantes foram definidos a partir do centroide do Estado.

Após obter as estações de cada quadrante, para a redução da quantidade de estações foi realizado um sorteio estratificado. Nesse sorteio foram mantidas 95% das estações de cada quadrante para manter a proporcionalidade do total. O mesmo processo de redução foi reproduzido considerando 90%, 75% e 50% das estações. Depois disso, foram utilizadas as estações sorteadas e realizado o mesmo processo de verificação que para os 100%. A figura 5 mostra como ficou a distribuição com 95%, 90%, 75% e 50% das estações.

Figura 5 - Estações pluviométricas em 95% (a), 90% (b), 75% (c) e 50% (d) das estações.



Fonte: Autora (2019).

4.5 AVALIAÇÃO DOS RESULTADOS POR MODELAGEM GAMLSS

Os dados coletados a partir dos cenários gerados da diminuição do número de estações (100%, 95%, 90%, 75% e 50%) foram submetidos à análise de modelos de regressão para a variância de krigagem máxima. Como a variância máxima da krigagem é uma medida positiva, a mínima variância seria zero e a máxima infinito, então foi necessário testar distribuições de probabilidade para variáveis positivas. Portanto, testaram-se, inicialmente, as distribuições Lognormal (LOGNO), Gaussiana inversa (IG) e Gama (GA).

O modelo GAMLSS considerado foi composto de um intercepto fixo, um efeito fixo do número de estações e o acréscimo de um efeito aleatório a nível de meses do ano, visto que

cada cenário foi avaliado em mais de um mês, gerando autocorrelação temporal, captando a autocorrelação temporal. O modelo de regressão GAMLSS utilizado é dado pela equação 4.

$$\begin{aligned}\log(\mu_i) &= \beta_{10} + \beta_{11}(N_Estações_i) + \gamma_{1i} \\ \log(\sigma_i) &= \beta_{20} + \beta_{21}(N_Estações_i) + \gamma_{2i}\end{aligned}\tag{4}$$

em que μ_i é o parâmetro de posição na i -ésima observação ($k=1$); σ_i é o parâmetro de dispersão na i -ésima observação ($k=2$); β_{k0} é o intercepto; β_{kj} é o coeficiente associado a j -ésima variável explicativa; $N_Estações_i$ é o número de estações na i -ésima observação; γ_i é o efeito aleatório para a i -ésima observação (efeito aleatório dos meses do ano), tal que $\gamma \sim N(0, \sigma_b)$.

A seleção do modelo mais adequado baseou-se nos critérios de informação de Akaike (AIC) e bayesiano (BIC). Utilizou-se o pacote `gamlss` (RIGBY; STASINOPOULOS, 2005), do software R (R CORE TEAM, 2019), para a realização das análises de regressão.

5 RESULTADOS E DISCUSSÃO

5.1 ANÁLISE DOS DADOS

A realização da análise de comportamento dos dados mostrou que os mesmos apresentaram tendência em todos os meses do ano, exceto em fevereiro. Assim, a mesma foi retirada, quando necessário, e trabalhou-se com estacionariedade de 1ª ordem. Em alguns casos houve tendência na direção norte-sul (janeiro, maio, junho, outubro, novembro, dezembro e na média climatológica do total mensal) e outros na leste-oeste (março, abril, julho, agosto, setembro). Após retirar-se a tendência, trabalhou-se com os resíduos, os quais foram usados para ajustar o modelo do semivariograma.

Considerou-se que o semivariograma é isotrópico, ou seja, não depende das direções entre as amostras (principalmente pelo fato de removerem-se as tendências de 1ª ordem), somente da distância entre elas. Pois, em algumas direções havia poucas estações, o que dificultava o ajuste do semivariograma.

Na construção do gráfico do semivariograma a distância usada variou conforme os meses. A mesma está apresentada na Tabela 2, juntamente com o R^2 e o modelo que obteve o melhor ajuste. Entre os estimadores testados, o estimador robusto de Cressie e Hawkins (1980) apresentou um comportamento melhor, sendo usado para todos os meses.

Tabela 2 – Resultados para máximas distâncias ($H_{máx}$), R^2 e modelo usado em cada mês.

Mês	$H_{máx}$	R^2	Modelo
Janeiro	50%	0.97	Gaussiano
Fevereiro	50%	0.96	Exponencial
Março	60%	0.54	Esférico
Abril	50%	0.95	Esférico
Maio	60%	0.98	Esférico
Junho	50%	0.99	Gaussiano
Julho	70%	0.99	Esférico
Agosto	50%	0.97	Gaussiano
Setembro	50%	0.97	Gaussiano
Outubro	50%	0.98	Exponencial
Novembro	50%	0.88	Gaussiano
Dezembro	50%	0.75	Esférico
Geral	50%	0.97	Exponencial

Fonte: Autora (2020).

O R^2 é definido como o coeficiente de determinação, sendo que quanto mais próximo de 1 mais explicativo é o modelo. Foram analisados os R^2 de todos os modelos, vendo qual possuía o maior valor, e também de acordo com o comportamento do modelo no semivariograma, avaliando os valores de alcance.

5.2 ANÁLISE DA VARIÂNCIA DA KRIGAGEM

Foi verificado o índice de dependência espacial (IDE), para caracterizar o grau de dependência entre as amostras e, após, a etapa seguinte refere-se à estimação de krigagem, onde são feitos os mapas de krigagem e calculada a variância máxima da krigagem. A Tabela 3 apresenta o IDE com sua respectiva classificação para cada modelo e a variância máxima da krigagem.

Tabela 3 - Resultados do IDE, sua classificação, variância máxima da krigagem e modelo

Mês	IDE	Classificação	Variância máxima da krigagem	Modelo
Janeiro	5.76	Fraca	315.2	Gaussiano
Fevereiro	12.14	Moderada	330.9	Exponencial
Março	3.11	Fraca	256.33	Esférico
Abril	33.60	Forte	257.9	Esférico
Mai	16.23	Forte	290.9	Esférico
Junho	29.58	Forte	191.2	Gaussiano
Julho	19.50	Forte	192.5	Esférico
Agosto	8.57	Fraca	183.8	Gaussiano
Setembro	12.85	Moderada	338.7	Gaussiano
Outubro	21.00	Forte	399.9	Exponencial
Novembro	4.16	Fraca	262	Gaussiano
Dezembro	4.43	Fraca	256.8	Esférico
Geral	19.32	Forte	109.42	Exponencial

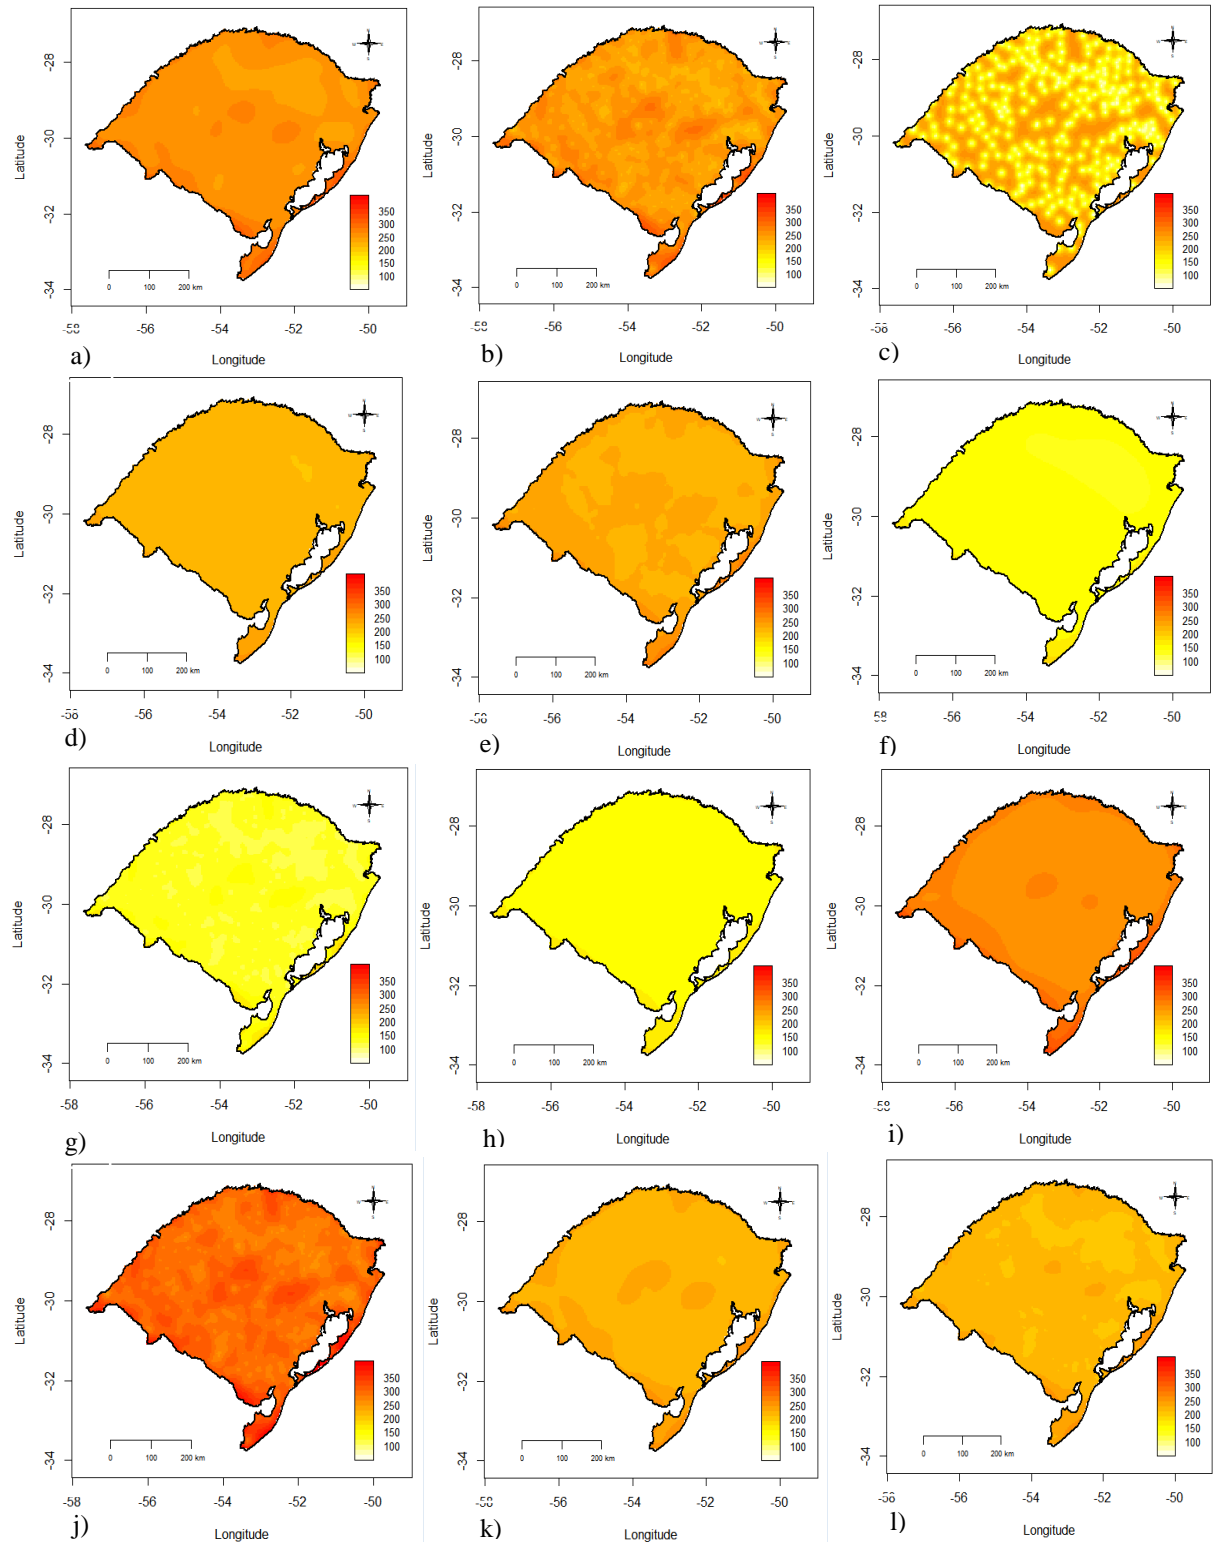
Fonte: Autora (2020).

O índice IDE compreende mais aspectos do semivariograma, comparado à outros índices já existentes. Ele considera uma medida de correlação espacial e também todos os parâmetros dos modelos da estrutura de dependência espacial, como o fator do modelo, o efeito pepita, a contribuição e o alcance (SEIDEL; OLIVEIRA; 2014). Quanto mais forte for o grau de dependência espacial, maior a dependência espacial entre as amostras.

Com exceção dos meses de fevereiro e outubro e no geral que tiveram ajuste de modelo exponencial, nos demais meses ocorreu ajustes de modelos esférico e Gaussiano, o que indica maior estrutura de variabilidade espacial (maior fator de modelo) (SEIDEL; OLIVEIRA, 2014) com uma maior continuidade espacial para a variância máxima de krigagem.

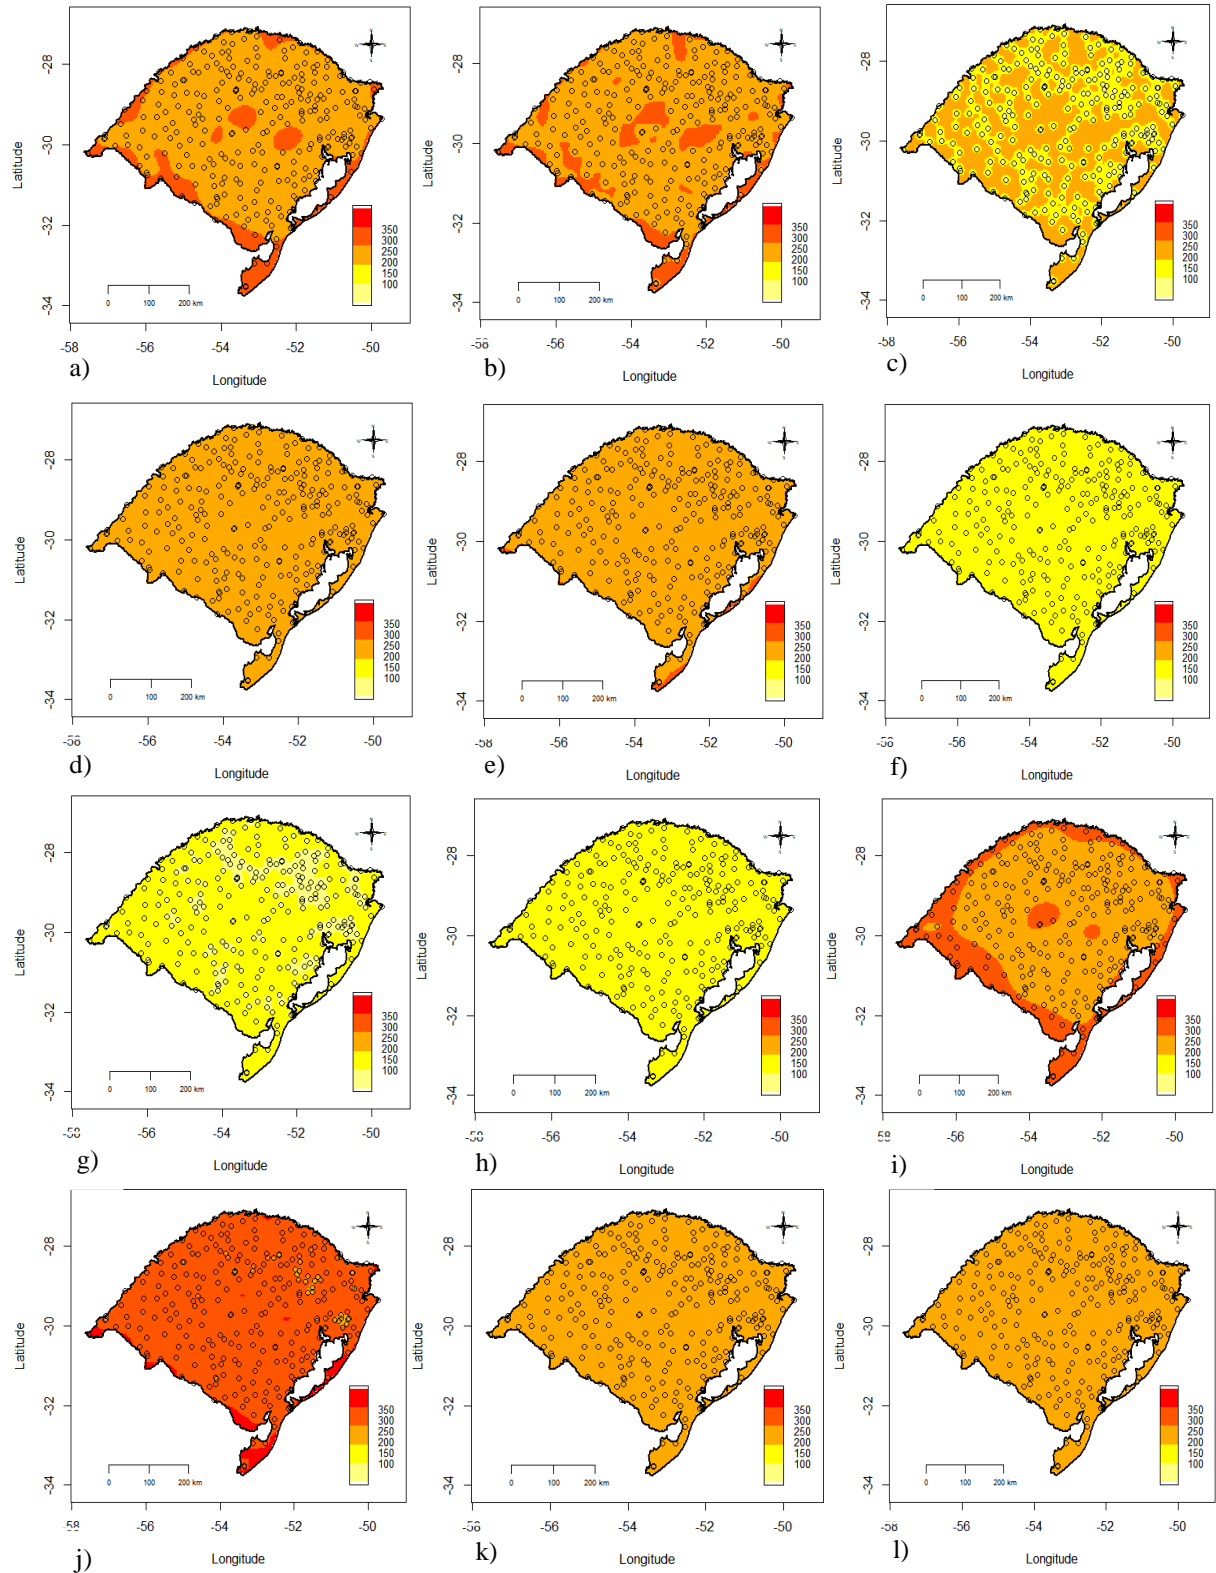
Os valores de variância máxima indicam o valor de maior variabilidade que estão apresentados nos mapas. Os mapas da Figura 6 mostram a variabilidade em uma escala maior de cores, enquanto que os mapas da Figura 7 com uma escala menor de cores, mostram a localização das estações pluviométricas e possíveis regiões candidatas para receber novas estações pluviométricas (locais com maior variabilidade). Na Figura 8 são apresentados os mapas com a média climatológica geral, onde em vermelho são circuladas as regiões com maior variabilidade.

Figura 6 - Mapas da variância da krigagem para os meses de janeiro (a), fevereiro (b), março (c), abril (d), maio (e), junho (f), julho (g), agosto (h), setembro (i), outubro (j), novembro (k) e dezembro (l), em escala maior de cores.



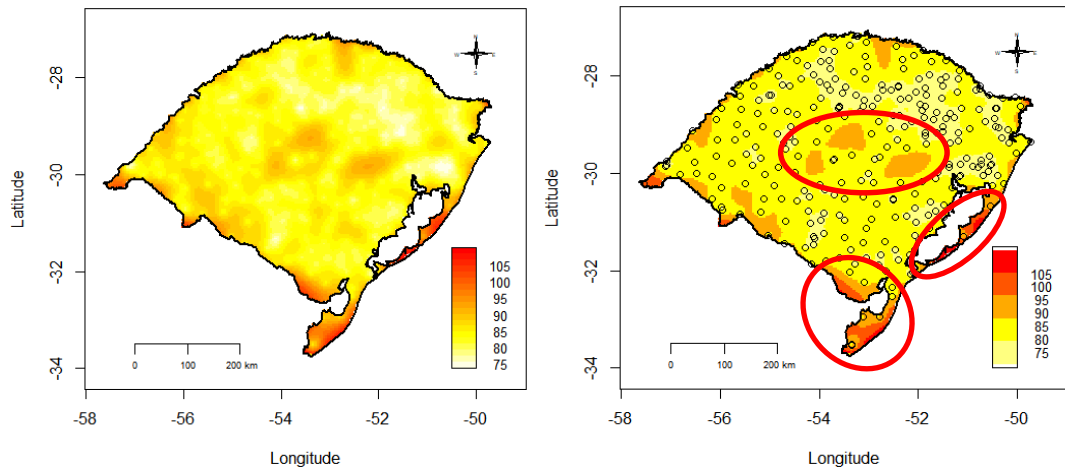
Fonte: Autora (2020).

Figura 7 - Mapas da variância da krigagem para os meses de janeiro (a), fevereiro (b), março (c), abril (d), maio (e), junho (f), julho (g), agosto (h), setembro (i), outubro (j), novembro (k) e dezembro (l), em escala menor de cores.



Fonte: Autora (2020).

Figura 8 - Mapa geral da variância da krigagem.



Fonte: Autora (2020).

Na Figura 6 pode-se observar que os meses de janeiro, fevereiro, setembro e outubro, foram os que apresentaram maior variância da krigagem e os meses de março, abril, maio, novembro e dezembro, uma variância da krigagem com valores mais intermediários. Esses valores de maior e média variância indicam os meses com uma maior variabilidade, ou seja, as chuvas são mais heterogêneas. Já nos meses junho, julho, agosto há uma diminuição da variância, mostrando que as chuvas nesses meses são mais homogêneas.

Percebe-se que os meses que compõem a primavera e o verão, são os meses que apresentam mais variabilidade nas chuvas, sendo que no verão ocorrem mudanças rápidas nas condições diárias do tempo, levando à ocorrência de chuvas de curta duração e forte intensidade, podendo as chuvas variarem entre 300 mm e 500 mm (INPE, 2016).

Os fenômenos convectivos atuantes no verão e na primavera podem explicar a maior variabilidade de chuvas nessas estações do ano. Rossato (2011) observou que o relevo da região central do estado influencia na ocorrência das chuvas convectivas, o que pode explicar a alta variabilidade de chuvas no verão e na primavera na região central, visto que estas, em sua maioria, são causadas pelos sistemas convectivos.

Outubro foi o mês que apresentou maior variabilidade de precipitação, visto que a primavera inicia-se no fim de setembro, essa grande variabilidade pode ser devido a transição de uma estação para outra. Sendo que na primavera há uma maior incidência dos complexos (GRIMM, 2009). Rossato (2011) relacionou os dados de dias de chuva com volume precipitado, e observou que em alguns meses grandes quantidades de chuva acumulam-se em poucos dias. Segundo o autor, o mês de outubro, foi o mês que registrou maior amplitude

entre as médias de precipitação e o mês com maior variabilidade do volume de precipitação, o que também foi observado neste estudo.

Os meses de inverno apresentaram menor variabilidade. De acordo com Rossato (2011), no inverno ocorrem as menores amplitudes do ano, o que indica que há uma melhor distribuição dos dias de chuva, principalmente no mês de julho. Os meses de abril e maio que compõem parte do outono apresentaram uma variância com valores mais intermediários, segundo Basso (2019) na região sudoeste do Estado no outono ocorre um bloqueio atmosférico, o qual facilita o evento de vários dias seguidos de chuva.

O mapa de variância da krigagem gerado pela krigagem tem o potencial de sugerir a localização de estações suplementares (XU et al., 2018). O posicionamento ideal de estações adicionais em zonas de alta variação reduzirá o erro de krigagem na rede e, com isso, melhorará o desempenho da rede (ADHIKARY et al., 2015). Locais próximos às estações mostram menor variância, enquanto locais em regiões que possuem relativamente menos estações, apresentam maior variância. Mais estações são necessárias em regiões esparsas e devem ser instaladas para tornar as estimativas de precipitação mais precisas (XU et al., 2018).

A Figura 7 demonstra que existe uma menor densidade de estações próximo ao centro do Estado, onde são observadas zonas de alta variação nos meses que apresentaram maior variância de krigagem. Observa-se que para alguns meses, os locais próximos a estações apresentam valores mais baixos, enquanto valores mais altos podem ser encontrados em áreas com menos estações pluviométricas. Nos locais que observa-se densidade da rede menor, requer a colocação de estações adicionais para reduzir a variância da krigagem.

Segundo Papamichail e Metaxa (1996) a variância de krigagem depende apenas da estrutura e da configuração geométrica das estações pluviométricas e do ponto a ser estimado, assim a mesma pode ser utilizada para a otimização da rede de medição. Com isso, as áreas de maior variabilidade são as que apresentam maior possibilidade de terem possíveis estações pluviométricas candidatas.

Na Figura 8 nota-se que as áreas próximas do litoral, ao Sul e no Centro do Estado, que estão circuladas de vermelho no mapa, são as que apresentam maior variância da krigagem, sendo assim os locais candidatos a ter uma nova estação pluviométrica, a qual pode ser também realocada dos locais que apresentam menor variância da krigagem.

Bernardi (2016) analisou o percentual de detecção dos dados de chuva através de satélite, e observou que nas regiões Sul e Litorânea, foram encontrados os menores valores de percentual de detecção, sendo que essas regiões também são as que apresentam baixa

densidade de postos pluviométricos, o que influencia no processo de interpolação dos dados observados. Isso evidencia a falta de estações nessas regiões, visto que para calibrar e validar dados de satélite são necessárias estações pluviométricas.

Ainda de acordo com Bernardi (2016), os melhores percentuais de detecção, dos dados de chuva por satélite, situaram-se nas porções Norte, Noroeste e Sudoeste do Estado, localizadas em regiões de planaltos. Em 80% do período as estimativas do satélite foram capazes de detectar de maneira correta a ocorrência ou não de chuva. Os melhores resultados em relação aos acertos em dias de chuva foram na porção Norte do Estado e também em alguns pixels sobre o Planalto Sul-Riograndense (área central). Na região Sul em 65% das ocorrências de chuva, as estimativas não detectaram precipitação. O que apresenta, como neste estudo, que as regiões que possuem mais estações pluviométricas tem melhores estimativas que as regiões com carência de estações, e mostra a necessidade de mais estações na região Sul do Estado.


Favaretto (2016) observou que o desempenho das estimativas de precipitação máxima, por meio da krigagem, está relacionado com a disponibilidade de estações, sendo que em regiões que a densidade de estações foi maior, as estimativas apresentaram melhores resultados, como é o caso da região nordeste do Estado. E as estimativas de chuva com menor desempenho ocorreram no extremos sul e na região oeste, do Estado.

5.3 ANÁLISE DO MODELO DE REGRESSÃO

A partir dos cenários gerados com a diminuição do número de estações, considerando 100%, 95%, 90%, 75% e 50% das estações, teve-se a intenção de modelar a variância de krigagem máxima em função do número de estações e em função de um efeito aleatório dos cenários ao longo dos meses.

A figura 9 apresenta o relacionamento entre a variância de krigagem máxima em função do número de estações (a) e em função dos meses do ano (b). Não parece haver uma evidente relação entre a variância de krigagem máxima e o número de estações pluviométricas consideradas. Já, em função dos meses do ano, parece que a variância de krigagem máxima varia conforme mudam as estações do ano.

Figura 9 - Relacionamento entre a variância de krigagem máxima em função do número de estações (a) e em função dos meses do ano (b).



Fonte: Autora (2020).

Assim como foi analisado nos mapas de variância da krigagem, percebe-se que os valores de variância máxima da krigagem dos meses são próximos em cada estação do ano. Os meses de primavera tem grande interferência dos sistemas convectivos, sendo setembro e outubro os meses com os maiores valores de variância máxima de krigagem.

Os meses de inverno (junho, julho e agosto) apresentam menor variabilidade, o que indica que há uma melhor distribuição dos dias de chuva. Esses meses são influenciados pelos sistemas frontais e são os meses com menores amplitudes do ano. Os meses do outono apresentam valores intermediários, nessa estação pode ocorrer o bloqueio atmosférico, o qual facilita o evento de vários dias seguidos de chuva.

Os meses de verão apresentam valores de variância máxima de krigagem mais elevados que no inverno, sendo que no verão ocorrem mudanças rápidas nas condições diárias do tempo, que levam a chuvas intensas e de curta duração. Percebe-se que os meses que compõem a primavera (setembro e outubro) e o verão (janeiro e fevereiro) são os meses que apresentam mais variabilidade nas chuvas.

Primeiramente, foi avaliada a distribuição de probabilidade que melhor descreve o comportamento da variância de krigagem máxima. A Tabela 4 apresenta os valores de AIC e BIC para avaliação do ajuste das distribuições variância de krigagem máxima com o ajuste da distribuição Lognormal, Gaussiana inversa e Gama. Percebe-se que a distribuição Gaussiana inversa parece ter melhor ajuste com menores valores de AIC e BIC. Assim, opta-se pela distribuição Gaussiana inversa para modelar a distribuição empírica da variância de krigagem máxima.

Tabela 4 – Valores de AIC e BIC para avaliação do ajuste das distribuições Lognormal, Gaussiana inversa e Gama na variância de krigagem máxima.

Critério	Lognormal	Gaussiana inversa	Gama
AIC	684,2	683,9	684,3
BIC	688,3	688,1	688,5

Fonte: Autora (2020).

A seguir, passa-se à modelagem GAMLSS para prever a variância de krigagem máxima em função do número de estações e dos meses do ano. A Tabela 5 apresenta os resultados do modelo de regressão para a distribuição Gaussiana inversa.

Tabela 5 – Estimativa dos parâmetros do modelo de regressão para a variância máxima de krigagem.

Covariável	Estimativa	Erro padrão	p-valor
Modelo para o parâmetro de posição [$\log(\mu)$]			
Intercepto	5,58	0,007	<0,0001
Efeito aleatório dos meses	0,24		
Modelo para o parâmetro de dispersão [$\log(\sigma)$]			
Intercepto	-3,20	0,49	<0,0001
Número de estações	-0,01	0,002	<0,0001
Efeito aleatório dos meses	0,17		
AIC	545,2		
BIC	580,2		


Fonte: Autora (2020).

Percebe-se pela Tabela 5 que, para o parâmetro de posição (com função de ligação logarítmica para μ), o modelo de regressão teve efeito apenas do intercepto. Os meses do ano foram incluídos no modelo como um efeito aleatório para captar o efeito da autocorrelação temporal. Além disso, verifica-se que o número de estações não exerceu efeito na variância de krigagem máxima.

Considerando especificamente o parâmetro μ da distribuição Gaussiana inversa, tem-se que ele é definido diretamente com a média da distribuição, de modo que, ao se modelar $\log(\mu)$, se está modelando o logaritmo da média da variância de krigagem máxima. O modelo de regressão, para o parâmetro de dispersão (com função de ligação logarítmica para σ), teve efeito negativo para o número de estações.

Em relação ao efeito dos meses do ano (Figura 10), em março, abril, junho, julho, agosto e dezembro ocorrem diminuição na variância de krigagem máxima, indicando que nestes meses a precipitação estimada é mais homogênea sem muita variabilidade, com volumes de chuva estimados semelhantes independentemente do número de estações considerado. Já nos meses de janeiro, fevereiro, maio, setembro, outubro e novembro ocorrem aumento na variância de krigagem máxima, indicando que nestes meses ocorre uma heterogeneidade na estimação da precipitação, com volumes de chuva estimados variando muito. De modo geral, percebe-se então que em janeiro, fevereiro, maio, setembro, outubro e novembro, as estimações de chuva podem ser menos precisas (maior variabilidade) do que nos meses de março, abril, junho, julho, agosto e dezembro.

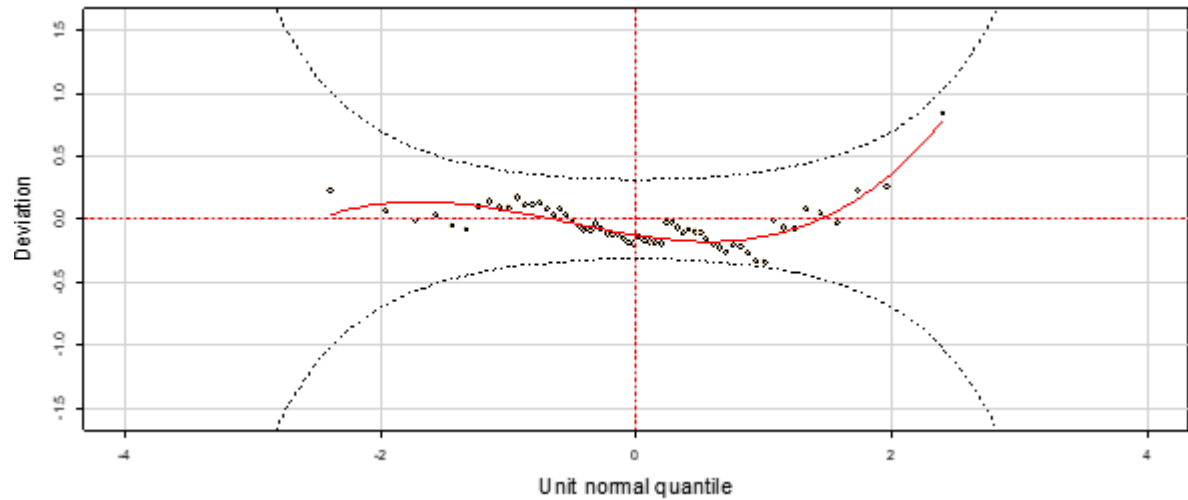
Figura 10 - Efeitos dos meses do ano no comportamento da variância máxima de krigagem, no modelo de regressão para a distribuição Gaussiana inversa.



Fonte: Autora (2020).

O efeito aleatório dos meses do ano teve desvio padrão estimado de 0,24 para o parâmetro de posição e de 0,27 para o parâmetro de dispersão (Tabela 5). Pela figura 11, verifica-se que os resíduos do modelo de regressão têm comportamento adequado, dentro do envelope do *worm plot*, o que indica que o modelo está bem ajustado.

Figura 11 - Gráfico worm plot do modelo de regressão para a distribuição Gaussiana inversa.



Fonte: Autora (2020).

6 CONCLUSÃO

A variância da krigagem foi usada para mostrar os locais, no estado do Rio Grande do Sul, que apresentam maior variabilidade nas predições da precipitação pluviométrica por krigagem. Verificaram-se possíveis locais candidatos para instalação (realocação) de uma nova estação pluviométrica, com maiores valores de variância de krigagem, melhorando o monitoramento.

Através da modelagem de regressão, foi observado que não há relação evidente da variância máxima da krigagem com o número de estações, de modo que não necessariamente o aumento de estações de medição, sem a reorganização da malha espacial, causaria uma melhora significativa nas predições.

Em termos de variabilidade ao longo do ano, fica evidente que em alguns meses do ano têm-se estimativas menos precisas da quantidade de chuvas, com maiores valores de variância máxima de krigagem. Estes resultados permitem entender como a variância de krigagem e variação temporal mensal se relacionam na descrição do comportamento da precipitação pluviométrica.

Porém mais pesquisas são necessárias para verificar onde seria o local mais adequado para instalar uma nova estação e quantas estações seriam necessárias, confirmando se as novas estações adicionam informações à distribuição espacial das chuvas no estado.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADHIKARY, S. K. MUTTIL, N. YILMAZ, A. G. Optimal design of rain gauge network in the Middle Yarra River catchment, Australia. **Hydrological Processes**. v. 29, p. 2582–2599, 2015.
- ANA. **Sistema de Informações Hidrológicas HidroWeb**. Banco de Dados. Disponível em: < <https://www.snirh.gov.br/hidroweb/serieshistoricas> >. Acesso em: 25 abril 2019.
- ANDRIOTTI, J. L. S. **Fundamentos de Estatística e Geoestatística**. 2003. Editora: UNISINOS. 1 ed. 165 p.
- ATLAS SOCIOECONÔMICO DO RIO GRANDE DO SUL. **Características do território**. Disponível em: <<https://atlassocioeconomico.rs.gov.br/inicial>>. Acessado em: 10 de agosto de 2020.
- AWADALLAH, A.G. Selecting optimum locations of rainfall stations using kriging and entropy. **International Journal of Civil and Environmental Engineering**. v. 12, n.1, 2012, p. 36–41.
- BASSO, R. E. **Estimativa de chuvas intensas em locais sem dados no Rio Grande do Sul**. 190 p. 2019. Tese (Doutorado em Engenharia Civil) - Universidade Federal de Santa Maria, 2019.
- BASTIN, G. et al. Optimal estimation of the average rainfall and optimal selection of raingauge locations. **Water Resources Research**. v. 20, n.4, 1984, p. 463–470.
- BARCA, E.; PASSARELLA, G.; URICCHIO, V. Optimal extension of the rain gauge monitoring network of the Apulian Regional Consortium for Crop Protection. **Environmental Monitoring and Assessment**. v. 145, n. 1–3, 2007. p. 375–386.
- BERNARDI, E. C. S. B. **Qualidade das estimativas de precipitação do satélite TRMM no Estado do Rio Grande do Sul**. 158 p. 2016. Dissertação (Mestrado em Engenharia Ambiental) - Universidade Federal de Santa Maria, 2016.
- BERNDT C.; HABERLANDT, U. Spatial interpolation of climate variables in Northern Germany—Influence of temporal resolution and network density. **Journal of Hydrology: Regional Studies**. v. 15, 2018, p. 184–202.
- BORGES, P. de A. et al. Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal, Brazil. **Theoretical and Applied Climatology**, v. 123, 2016, p. 335–348.
- BRITTO, F. P.; 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, p. 35-51, 2006.

BURROUGH, P.A.; MCDONNELL R.A. **Principles of Geographical Information Systems: Spatial Information Systems and Geostatistics**. NewYork: Oxford University Press. 1998.

CHEBBI, A., BARGAOUI, Z., CUNHA, M. Optimal extension of rain gauge monitoring network for rainfall intensity and erosivity index interpolation. **Journal of Hydrologic Engineering**. v. 16, n. 8, 2011, p. 665–676.

CHEN, Y. C.; CHIANG, W.; YEH, H. C. Rainfall network design using kriging and entropy. **Hydrological Processes**. v. 22, 2008, p. 340–346.

CHENG K-S.; LIN, Y. C.; KIOU, J. J. Rain-gauge network evaluation and augmentation using geostatistics. **Hydrological Processes**. v. 22, 2008, p. 2554–2564.

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

DELBARI, M.; AFRASIAB, P.; JAHANI, S. Spatial interpolation of monthly and annual rainfall in northeast of Iran. **Meteorology and Atmospheric Physics**, v. 122, 2013, p. 103–113.

DI PIAZZA, A. et al. Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. **International Journal of Applied Earth Observation and Geoinformation**. v. 13, 2011, p. 396–408.

FENSTERSEIFER, C. A. **Qualidade das Estimativas de Precipitações Derivadas de Satélites na Bacia do Alto Jacuí – RS**. 118 f. Dissertação (Mestrado em Engenharia Civil e Ambiental) – Universidade Federal de Santa Maria. Santa Maria, 2013.

FAVARETTO, J. R. **Análise de consistência e regionalização das precipitações máximas ocorridas no Rio Grande do Sul entre 1912-2014**. 764 p. 2016. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Santa Maria, 2016.

FERREIRA, R. C. **Estudo de sistemas convectivos de mesoescala com uso de assimilação de dados de radar**. Dissertação (Mestrado em Meteorologia) Instituto Nacional de Pesquisas Espaciais, São José dos Campos, p. 154, 2016.

FRAZIER, A.G. et al. Comparison of geostatistical approaches to spatially interpolate month–year rainfall for the Hawaiian Islands. **International Journal of Climatology**. v. 36, 2016, p. 1459–1470.

GARCEZ, L. N. ALVAREZ, G. A. **Hidrologia**. 2 ed. São Paulo, SP: Blucher, 1988. 291 p.

GOOVAERTS, P. Geostatistical approaches for incorporating elevation into the spatial interpolation of rainfall. **Journal of Hydrology**. V. 228, 2000, p. 113–129.

GOOVAERTS, P. **Geostatistics for Natural Resources Evaluation**. New York: Oxford. 1997.

GOVERNO DO ESTADO DO RIO GRANDE DO SUL. **Geografia**. Disponível em: <<https://estado.rs.gov.br/geografia>>. Acessado em: 01 de out de 2018.

GRIMM, A. Clima da Região Sul do Brasil. In CAVALCANTI, I. F. de A. et al. **Tempo e Clima no Brasil**. 1 ed. São Paulo: Oficina de Textos. 2009, p. 259-275.

GUEDES, R. L.; MACHADO, L. A. T.; SILVEIRA, J. M. B.; ALVES, M. A. S.; WALTZ, R. C. Trajetórias dos sistemas convectivos sobre o continente americano. In: CONGRESSO BRASILEIRO DE METEOROLOGIA, 8., 1994, Rio de Janeiro. **Anais ...** Rio de Janeiro: SBMet, 1994. p. 77-80.

HOFIERKA, J. et al. 2002. Multivariate interpolation of precipitation using regularized spline with tension. **Transactions GIS**. v. 6, n. 2, 2002, p. 135-150.

HOLTZ, A. C. T. Precipitação. In: PINTO, N. L. de S. et al. **Hidrologia básica**. São Paulo: Edgard Blücher, 1976. 279 p.

JOURNEL, A. G.; HUIJBREGTS, J. C. H. **Mining geostatistics**. New York: Academic Press, 1978. 600 p.

INMET. **Banco de Dados Meteorológicos para Ensino e Pesquisa do INMET - BDMEP**. Disponível em: < <http://www.inmet.gov.br/portal/index.php?r=bdmep/bdmep> >. Acesso em: 30 abril 2019

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Rio Grande do Sul – População**. 2018. Disponível em: <<https://cidades.ibge.gov.br/brasil/rs/panorama>>. Acessado em: 01 de out de 2018.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS – INPE. **Estações**. Disponível em: <<http://clima1.cptec.inpe.br/estacoes/pt>>. Acessado em: 01 de out. de 2018.

ISAAKS, E. H.; SRIVASTAVA, R. M. **An Introduction to Applied Geostatistics**. 1989 Oxford University Press, Inc. 561 p.

ISAAKS, E. H.; SRIVASTAVA, R. M. Spatial continuity measures for probabilistic and deterministic geostatistics. **Mathematical Geology**, v. 20, 1988, p. 313–341.

LANZA, L.; RAMÍREZ, J.; TODINI, E. Stochastic rainfall interpolation and downscaling. **Hydrology & Earth System Sciences**. v. 5, n. 2, 2001, p. 139–143.

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

LY, S.; CHARLES, C.; DEGRÉ, A. Geostatistical interpolation of daily rainfall at catchment scale: the use of several variogram models in the Ourthe and Ambleve catchments, Belgium. **Hydrology and Earth System Sciences**. v. 15, p. 2259–2274, 2011.

MAHMOUDI-MEIMAND, H. et al. An algorithm for optimisation of a rain gauge network based on geostatistics and entropy concepts using GIS. **Journal of Spatial Science**. 2015.

- MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, p. 1246-1266, 1963.
- MIRÁS-AVALOS, J. M. et al. Mapping monthly rainfall data in Galicia (NW Spain) using inverse distances and geostatistical methods. **Advances in Geosciences**. v. 10, 2007, p. 51–57.
- MENDONÇA, F. DANNI-OLIVEIRA, I. R. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Textos, 2009. 118 p.
- MIRANDA, J. I. **Fundamentos de sistemas de informações geográficas**. 4. ed. Brasília, DF: Embrapa, 2015. 399 p.
- MOREIRA, I. A. G. **O espaço rio-grandense**. 4. ed. São Paulo, SP: Ática, 2002. 96 p.
- OLIVEIRA, G. S. de. **O El Niño e Você - o fenômeno climático**. São José dos Campos (SP): Transtec. 2001.
- OMM – Organização Meteorológica Mundial. **Guide to Hydrological Practices**. 6 ed. v.1, 2008. 296 p.
- OZTURK, D.; KILIC, F. Geostatistical Approach for Spatial Interpolation of Meteorological Data. **Annals of the Brazilian Academy of Sciences**. v. 88, n. 884, 2016, p. 2121–2136.
- PAPAMICHAIL, D. M.; METAXA, I. G. Geostatistical analysis of spatial variability of rainfall and optimal design of a rain gauge network. **Water Resources Management**, v. 10, 1996, p. 107–127.
- PARDO-IGÚZQUIZA, E. Optimal selection of number and location of rainfall gauges for areal rainfall estimation using geostatistics and simulated annealing. **Journal Hydrology**. v. 210, 1998, p. 206–220.
- PELLICONE, G. et al. Application of several spatial interpolation techniques to monthly rainfall data in the Calabria region (southern Italy). **International Journal of Climatology**. v. 38, n. 9, 2018, p. 3651–3666.
- R Development Core Team (2019). **R: A language and environment for statistical computing**. R Foundation for Statistical Computing, Vienna, Austria. ISBN 3-900051-07-0, URL <http://www.R-project.org/>.
- RIBEIRO JÚNIOR, P. J.; DIGGLE, P. J. **GeoR: a package for geostatistical analysis**. R News, v. 1, n. 2, 2001, p. 15-18.
- RIGBY, R.A.; STASINOPOULOS, D.M. A flexible regression approach using GAMLSS in R. Notes for the Athens 2010 short course. <https://www.gamlss.com/books-articles/>. 2010.
- RIGBY, R. A.; STASINOPOULOS, D. M. Generalized additive models for location, scale and shape. **Journal of the Royal Statistical Society: Series C**. v. 54, n. 3, p. 507-554. 2005.

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 – RS. 2011. 240 p.

SALGUEIRO, J. H. P. de B. **Avaliação de rede pluviométrica e análise de variabilidade espacial da precipitação: estudo de caso na bacia do rio Ipojuca em Pernambuco.** 122 p. 2005. Dissertação (Mestrado em Engenharia Civil) - Universidade Federal de Pernambuco, 2005.

SALIO, P.; NICOLINI, M.; ZIPSER, E. J. Mesoscale convective systems over southeastern South America and their relationship with the South American low-level jet. **Monthly Weather Review**, v. 135, n. 4, 2007, p. 1290-1309.

SALLEH, N. S. A.; AZIZ, M. K. B. M.; ADZHAR, N. Optimal Design of a Rain Gauge Network Models: Review Paper. **Journal of Physics: Conference Series**. 2019.

SEIDEL, E. J.; OLIVEIRA, M.S. A classification for a geostatistical index of spatial dependence. **Revista Brasileira de Ciência do Solo**. v.40, 2016.

SEIDEL, E. J. OLIVEIRA, M. S. de. New geostatistical index for measuring spatial dependence. **Revista Brasileira de Ciência do Solo**. v. 38, n. 3, p.699-705. 2014.

SHAGHAGHIAN, M.R.; ABEDINI, M.J. Rain gauge network design using coupled geostatistical and multivariate techniques. **Scientia Iranica**. v. 20, n. 2, 2012, p. 259–269.

SHIH, S. F. Rainfall variation analysis and optimization of gauging systems. **Water Resources Research**. v. 18, n.4, 1982, p. 1269–1277

SILVA, F. M. et al. Efeitos da colheita manual na bienalidade do cafeeiro em Ijaci, Minas Gerais. **Ciência e Agrotecnologia**, Lavras, v. 34, n. 3, 2010, p. 625-632.

SIQUEIRA, J. R.; MACHADO, L. A. T. Influence of the frontal systems on the day-to-day convection variability over South America. **Journal of Climate**, v. 17, n. 9, 2004, p. 1754-1766.

SOARES, A. **Geostatística para as ciências da terra e do ambiente**. 3 ed. Editora: IST Press. 2014. 214 p.

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

ST-HILAIRE, A. et al. Assessment of the impact of meteorological network density on the estimation of basin precipitation and runoff: a case study. **Hydrological Processes**. v. 17, 2003, p. 3561–3580

TUCCI, C. E. M. **Hidrologia: ciência e aplicação**. 4 ed. Porto Alegre: Editora da UFRGS: ABRH: EDUSP, 2012. 952 p.

TVEITO, O. E. et al. **The use of geographic information systems in climatology and meteorology**. COST Office, EUR-OP, Luxembourg. 2008. 246 p.

VELASCO, I.; FRITSCH, J. M. Mesoscale convective complexes in the Americas. **Journal of Geophysical Research**, v. 92, n. 8, 1987, p. 9591- 9613.

VICENTE-SERRANO, S.M.; SAZ-SÁNCHEZ, M.A.; CUADRAT, J.M. Comparative analysis of interpolation methods in the middle Ebro Valley (Spain): application to annual precipitation and temperature. **Climate Research**, v. 24, 2003, p. 161–180.

VIEIRA, S. R. Geoestatística em estudos de variabilidade espacial do solo. In: NOVAES, R. F. et al. (Ed.). **Tópicos em ciência do solo**. Viçosa, MG: Sociedade Brasileira de Ciência do Solo, 2000. v. 1, p. 1-53.

XU, P. et al. A kriging and entropy-based approach to raingauge network design. **Environmental Research**. v.161, p. 61–75, 2018.

WEBSTER, R., OLIVER, M.A. **Geostatistics for Environmental Scientists**. 2 ed. West Sussex: John Wiley & Sons, UK, 2007. 315 p.

YAMAMOTO, J. K; LANDIM, P. M. B. **Geoestatística: conceitos e aplicações**. 1 ed. São Paulo: Oficina de Textos, 2013. 215 p.

YEH, H. C. et al. Entropy and Kriging approach to rainfall network design. **Paddy and Water Environment**. v. 9, 2011, p. 343–355.