



INTERPOLAÇÃO ESPACIAL: GEOPROCESSAMENTO APLICADO À DETECÇÃO DE MUDANÇAS CLIMÁTICAS EM SANTA CATARINA

*Spatial Interpolation: Geoprocessing Applied to the Detection
of Climate Change in Santa Catarina*

*Interpolación Espacial: Geoprocесamiento Aplicado a la
Detección de Cambios Climáticos en Santa Catarina*

Pablo Francisco Benítez Baratto  

Universidade do Estado de Santa Catarina

pablo.baratto@udesc.br

Jackson Adriano Albuquerque  

Universidade do Estado de Santa Catarina

jackson.albuquerque@udesc.br

Claudia Guimarães Camargo Campos  

Universidade do Estado de Santa Catarina

claudia.campos@udesc.br

Resumo: O estudo aborda a interpolação espacial como ferramenta essencial para mapear mudanças climáticas, especialmente em regiões com baixa densidade de estações meteorológicas. Diante da crescente ameaça climática e da necessidade de dados precisos para o planejamento agrícola e a gestão de recursos hídricos, torna-se fundamental mapear a variabilidade histórica da precipitação e evapotranspiração potencial em Santa Catarina. Nesse sentido, a interpolação espacial permite uma análise detalhada da influência do clima no estado. O estudo utiliza dados de precipitação e evapotranspiração de uma série histórica de 1960 a 2020, aplicando o interpolador IDW para espacialização. A validação do interpolador é realizada por meio de índices estatísticos, como RMSE, EAM e o índice de Willmott. Os resultados indicam uma variação sazonal significativa, com maior precipitação no verão e menor no inverno, enquanto padrões distintos são observados entre as regiões serranas e litorâneas, influenciadas pela altitude e circulação atmosférica. A validação comprova o alto desempenho do interpolador na estimativa das variáveis. Diante disso, a interpolação espacial se mostra uma técnica eficiente para representar com precisão as variações climáticas, contribuindo para a gestão hídrica e o planejamento agrícola. Os mapas gerados fornecem subsídios técnicos para mitigar os impactos das mudanças climáticas e otimizar práticas agrícolas em Santa Catarina.

Palavras-chave: Precipitação. Evapotranspiração. Espacialização.

Abstract: The study addresses spatial interpolation as an essential tool for mapping climate change, especially in regions with a low density of meteorological stations. Given the growing climate threat and the need for accurate data for agricultural planning and water resource management, mapping the historical variability of precipitation and potential evapotranspiration in Santa Catarina becomes crucial. In this context, spatial interpolation enables a detailed analysis of the climate's influence in the state. The study uses precipitation and evapotranspiration data from a historical series spanning 1960 to 2020, applying the IDW interpolator for spatialization. The validation of the interpolator is performed using statistical indices such as RMSE, EAM, and Willmott's index. The results indicate significant seasonal variation, with higher precipitation in summer and lower in winter, while distinct patterns are observed between mountainous and coastal regions, influenced by altitude and atmospheric circulation. The validation confirms the high performance of the interpolator in estimating variables. Thus, spatial interpolation proves to be an efficient technique for accurately representing climate variations, contributing to water management and agricultural planning. The generated maps provide technical support to mitigate the impacts of climate change and optimize agricultural practices in Santa Catarina.

Keywords: Precipitation. Evapotranspiration. Spatialization.

Resumen: El estudio aborda la interpolación espacial como una herramienta esencial para mapear el cambio climático, especialmente en regiones con baja densidad de estaciones meteorológicas. Ante la creciente amenaza climática y la necesidad de datos precisos para la planificación agrícola y la gestión de los recursos hídricos, se vuelve fundamental mapear la variabilidad histórica de la precipitación y la evapotranspiración potencial en Santa Catarina. En este sentido, la interpolación espacial permite un análisis detallado de la influencia del clima en el estado. El estudio utiliza datos de precipitación y evapotranspiración de una serie histórica que abarca de 1960 a 2020, aplicando el interpolador IDW para la espacialización. La validación del interpolador se realiza mediante índices estadísticos como RMSE, EAM y el índice de Willmott. Los resultados indican una variación estacional significativa, con mayor precipitación en verano y menor en invierno, mientras que se observan patrones distintos entre las regiones montañosas y costeras, influenciadas por la altitud y la circulación atmosférica. La validación confirma el alto desempeño del interpolador en la estimación de variables. Así, la interpolación espacial se presenta como una técnica eficiente para representar con precisión las variaciones climáticas, contribuyendo a la gestión hídrica y la planificación agrícola. Los mapas generados proporcionan apoyo técnico para mitigar los impactos del cambio climático y optimizar las prácticas agrícolas en Santa Catarina.

Palabras clave: Precipitación. Evapotranspiración. Espacialización.

Submetido em: 08/02/2025

Aceito para publicação em: 20/08/2025

Publicado em: 09/09/2025

1. INTRODUÇÃO

A mudança climática é reconhecida atualmente como a maior ameaça global do século XXI (Watts et al., 2015), em razão da evolução imprevisível do regime climático (Albuquerque, 2021). O relatório mais recente do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), apresentado na COP28 (IPCC, 2023), principal órgão internacional de avaliação das mudanças climáticas, estabeleceu que as emissões antropogênicas de gases de efeito estufa são a causa dominante do aquecimento global.

Além disso, segundo a *Food and Agriculture Organization* (FAO, 2002), um em cada cinco países em desenvolvimento sofrerá de escassez de água até o ano de 2030, com prejuízos à produção mundial de alimento. Por definição, o Brasil é um dos possíveis países a sofrer com a falta de água e segurança alimentar. Isto ocorrerá, pois, a maior parte do uso da água ocorre na produção agrícola (Du et al., 2015; FAO, 2017; Adrison; Ugaya, 2024).

As evidências científicas mostram que na última década ocorreram os anos mais quentes já registrados (WMO, 2024). O aquecimento global está cerca de 1°C acima da média do período de 1850-1900 (Allen et al., 2019; IPCC, 2021). Com o contínuo aumento da temperatura, ocorrerá com maior frequência, ondas de calor mais intensas (Perkins-Kirkpatrick; Gibson, 2017; Oliveira et al., 2021).

A interpolação espacial é uma ferramenta importante para entender as mudanças climáticas, principalmente em lugares onde os dados meteorológicos são poucos ou apresentam falhas. Com o aumento da variabilidade do clima e a frequência de eventos extremos, como secas, enchentes e ondas de calor, torna-se cada vez mais necessário contar com informações climáticas confiáveis e contínuas (Watts et al., 2015; IPCC, 2023). Através da interpolação, é possível estimar valores de temperatura, chuva e outras variáveis em locais onde não existem medições diretas, usando como base os dados coletados em estações próximas (Vianna et al., 2017; Brubacher et al., 2020). Esses dados interpolados ajudam a construir mapas climáticos mais precisos, que são fundamentais para o planejamento agrícola, o uso racional da água e ações de adaptação às mudanças do clima (Xavier et al., 2015).

No Brasil, a densidade de estações meteorológicas é relativamente baixa, e muitos dados apresentam falhas ou são descontínuos, o que dificulta a análise climática em escala regional (Cecílio et al., 2012; Zakhia et al., 2022). A interpolação espacial surge como uma

solução para preencher essas lacunas, permitindo a geração de informações climáticas contínuas e confiáveis. Além disso, a interpolação espacial é crucial para a análise de tendências climáticas, pois permite a identificação de padrões regionais de variabilidade e anomalias, auxiliando na tomada de decisões para a mitigação dos impactos das mudanças climáticas (Medeiros, 2020).

O objetivo deste trabalho é mapear a variabilidade histórica da temperatura, precipitação e evapotranspiração potencial no estado de Santa Catarina, com base em dados de estações meteorológicas e pluviométricas, por meio de técnicas de interpolação espacial. Além disso, busca-se identificar o interpolador mais adequado para cada variável hidroclimática, com base em índices estatísticos de validação cruzada leave-one-out, incluindo o índice de concordância de Willmott (d), o erro percentual absoluto médio (EPAM) e o erro médio absoluto (EAM). Por fim, pretende-se disponibilizar online uma base de dados com as espacializações em escala mensal e anual.

2. METODOLOGIA

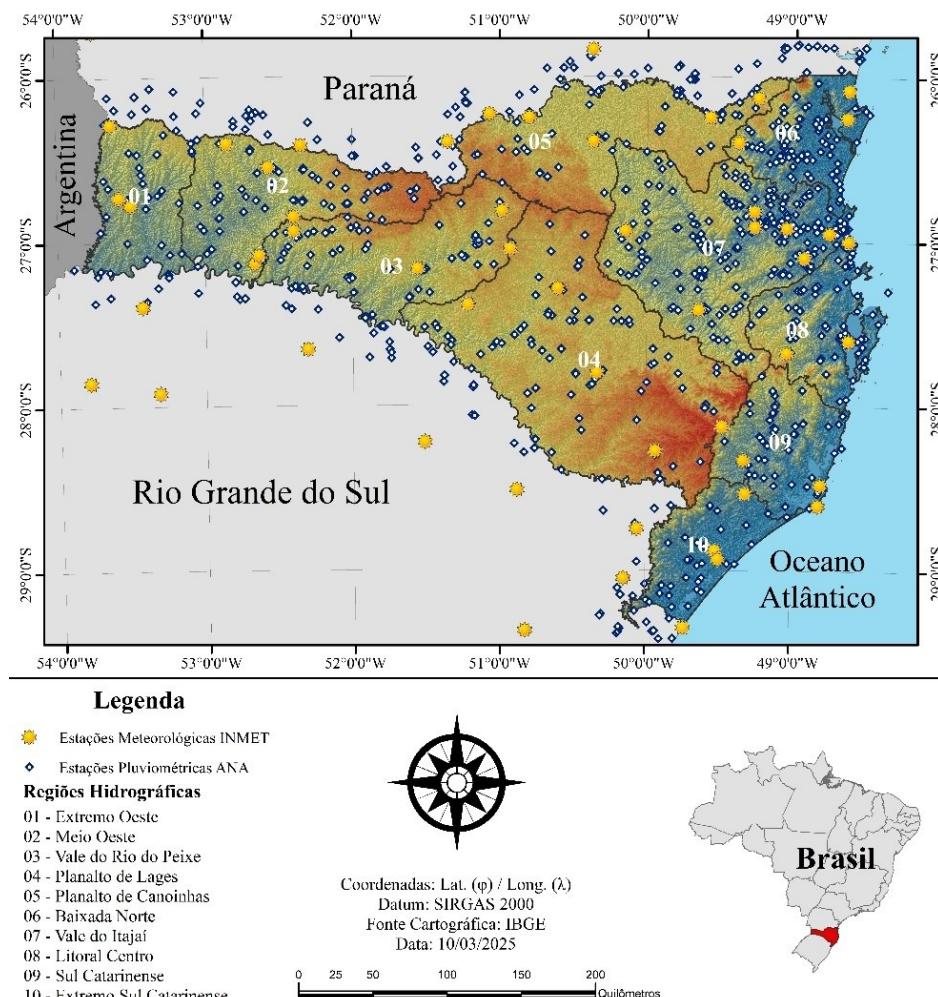
2.1. Área em estudo

O estudo foi realizado no estado de Santa Catarina, visando à regionalização dos dados climáticos. O estado localiza-se entre $25^{\circ}57'41''$ e $29^{\circ}23'55''$ de latitude sul e $48^{\circ}19'37''$ e $53^{\circ}50'00''$ de longitude oeste (IBGE, 2021), com área de 95.736 km^2 , equivalente a 1,12% do território brasileiro (GEPHI, 2014). Em função de sua extensão territorial relativamente pequena, apresenta duas classificações climáticas principais: subtropical úmido (Cfa), abrangendo 40% da área, e oceânico temperado (Cfb), com 60% (ALVARES et al., 2014). O relevo é dividido em três unidades: Planície Costeira (10–30 m), Planaltos e Serras do Leste (altitude média de 900 m) e Planalto Ocidental (300–1000 m) (VILL, 2021). A precipitação média anual varia entre 1300–1600 mm no sul, 1900–2200 mm no oeste e 1600–1900 mm nas demais regiões (Alvares et al., 2014).

2.2. Obtenção e análise de dados

As informações meteorológicas utilizadas neste estudo foram obtidas a partir dos registros diários de 1031 estações pluviométricas da ANA (ANA, 2022) e 68 estações meteorológicas do INMET (INMET, 2022), abrangendo o período de 1961 a 2020, de modo a contemplar as duas últimas normais climatológicas. Esses dados serviram de base para o cálculo dos valores mensais e anuais de precipitação e evapotranspiração potencial (ETP), bem como para a estimativa da temperatura média mensal, utilizados na interpolação espacial. A obtenção dos dados pluviométricos foi realizada por meio do plugin “ANA Data Acquisition v.1.0”, desenvolvido pelo grupo Hidrologia de Grande Escala do IPH/UFRGS, no software QGIS, permitindo o download em lote de arquivos (.xlsx) a partir da seleção da área de interesse. As estações utilizadas estão representadas na Figura 1.

Figura 1 – Mapa de estações pluviométricas e meteorológicas de superfície da ANA e INMET.



Fonte: Os autores (2025).

A estimativa dos valores de ETP foi realizada por meio da equação (1) (Allen et al., 1998). Na ausência de todos os parâmetros necessários para sua aplicação, utilizou-se como alternativa a equação (2) (Hargreaves; Samani, 1985). Para o cálculo, foram considerados os elementos meteorológicos medidos nas estações do INMET: temperatura máxima e mínima (Tmax e Tmin), radiação solar (Rs), velocidade do vento a 2 m de altura (u₂) e umidade relativa do ar (UR) (Xavier et al., 2015). As equações auxiliares necessárias ao cálculo dos parâmetros da equação (1) encontram-se em Allen et al. (1998), enquanto àquelas referentes à equação (2) estão descritas em Hargreaves e Samani (1985).

$$ETP = \frac{0,408\Delta(R_n - G) + \gamma \frac{900}{T+273} u_2 (e_s - e_a)}{\Delta + \gamma(1 + 0,34 u_2)} \quad (1)$$

$$ETP = 0,0023 \cdot R_0 (t_{\max} - t_{\min})^{0,5} (t_{\text{med}} + 17,8) \quad (2)$$

Onde ETP (mm d⁻¹); R_n - saldo de radiação à superfície da cultura (MJ m⁻² d⁻¹); G - densidade do fluxo de calor do solo (MJ m⁻² d⁻¹); T - temperatura do ar a 2 m de altura (°C); u₂ - velocidade de vento a 2 m de altura (m s⁻¹); e_s - pressão de vapor de saturação (kPa); e_a - pressão parcial de vapor (kPa); Δ - declividade da curva de pressão de vapor de saturação (kPa°C⁻¹) e γ - coeficiente psicrométrico (kPa°C⁻¹); R₀ - radiação extraterrestre (mm dia⁻¹); t_{max} - temperatura máxima (°C); t_{min} - temperatura mínima (°C); t - temperatura média (°C).

2.3. Interpoladores Espaciais

Foi gerada uma base de dados mensal e anual a partir da interpolação espacial das variáveis hidroclimáticas (precipitação, ETP e temperatura média). A escolha do método de interpolação considerou a acurácia de diferentes técnicas, tais como Inverso da Distância Ponderada (IDW), Krigagem Ordinária (KO), Random Forest (RF) e Regularized Tension Spline (Spline RT), sendo selecionado o que apresentou melhor desempenho estatístico para cada variável. A validação foi realizada por meio de métricas que compararam os valores interpolados com dados observados nas estações, permitindo uma avaliação quantitativa da

qualidade das estimativas (Cai et al., 2019). Todas as espacializações foram executadas no software RStudio®.

2.3.1 Inverso da Distância Ponderada (IDW)

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

$$w_i(x) = \frac{1}{d(x, x_i)^p} \quad (3)$$

Onde: x é o ponto da estimativa é desejada; x_i é um dos pontos em que as observações estão disponíveis; d é a distância entre os dois locais e p é um expoente que permite dar formas diferentes à função de ponderação. Quanto maior o p , menor a importância dada a observações mais remotas (Camera et al., 2014; Mendez et al., 2019).

No presente trabalho, o expoente p igual a 1 foi escolhido, devido ao grande número de pontos disponíveis para a espacialização.

2.3.2 Krigagem Ordinária (OK)

O método de espacialização da *Krigagem* utiliza informações provenientes de um semivariograma para determinar os pesos ótimos a serem atribuídos às amostras com valores conhecidos, os quais serão utilizados para estimar pontos desconhecidos (Cai et al., 2019). Neste trabalho, foi aplicada a *Krigagem* ordinária (OK), utilizando um modelo esférico.

$$\hat{Z}(x_0) = \sum_{i=1}^n \lambda_i Z(x_i) \quad (4)$$

Onde $\hat{Z}(x_0)$ é ponto estimado; λ_i (com $i = 1, n$) são os pesos associados aos n dados e, $Z(x_i)$ é o ponto amostrado (Lundgren et al., 2017).

Para a aplicação da OK com o modelo esférico, os dados devem ser submetidos à análise do semivariograma, com a seguinte equação para o modelo esférico:

$$\gamma(h) = \begin{cases} 0, & \text{se } h = 0 \\ C_0 + C_1 \left(\frac{3h}{2a} - \frac{h^3}{2ah^3} \right), & \text{se } 0 < h \leq a \\ C_0 + C_1, & \text{se } h > a \end{cases} \quad (5)$$

Onde $\gamma(h)$ é o semivariograma, h é o vetor de separação entre os pares de amostras, a é o alcance do modelo esférico, C_0 é o efeito nugget e C_1 é a diferença entre o valor assintótico e o valor nugget do semivariograma.

2.3.3 Regularized Tension Spline (*Spline RT*)

O *Regularized Tension Spline* (*Spline RT*) é um método de interpolação geoespacial que combina a suavização de superfícies com o controle de oscilações em regiões de dados esparsos. Derivado da *Thin Plate Spline* (TPS), proposta originalmente por Duchon (1976) para minimizar a energia de curvatura de uma superfície, o *Spline RT* introduz um parâmetro de tensão (λ) que regula a rigidez da interpolação. Enquanto a TPS clássica resolve a equação diferencial:

$$\nabla^2 f = 0 \quad (6)$$

Onde ∇^2 é o operador de Laplace, responsável por calcular a curvatura da função $f(x,y)$, sendo $f(x,y)$ a superfície interpolada, o *Spline RT* modifica essa equação para:

$$\nabla^2 f - \lambda^2 f = 0 \quad (7)$$

Onde: $\lambda^2 f$ é o parâmetro de tensão, que regula a rigidez da spline; se $\lambda = 0$, o método se reduz à *Thin Plate Spline* tradicional, resultando em uma superfície extremamente suave; se $\lambda > 0$, o termo de tensão suprime ondulações excessivas, aproximando-se qualitativamente de métodos locais como o IDW, mas mantendo a estrutura matemática global das Splines.

A solução do Spline RT é expressa por uma combinação de funções de base radial (RBF) e um polinômio de tendência. Formalmente, a superfície interpolada é dada por:

$$f(x,y) = \sum_{i=1}^n \omega_i R(r_i) + P(x,y) \quad (8)$$

Onde $r_i = \sqrt{(x-x_i)^2 + (y-y_i)^2}$ é a distância entre o ponto a ser interpolado e o ponto amostrado; $R(r) = K_0(\lambda r)$ a função de base radial, onde K_0 é a função de Bessel e λ controla o grau de suavização. O polinômio $P(x,y)$ captura as tendências globais e ω_i são os pesos ajustados para os pontos amostrais.

A formulação do Spline RT, popularizada por Mitášová e Mitáš (1993), combina a TPS de Duchon (1976) e métodos de regularização inspirados na geoestatística de Matheron (1963), com influências de Sandwell (1987). Ao integrar um termo de tensão, o Spline RT equilibra suavização e fidelidade aos dados, controlando a curvatura e evitando a suavização excessiva, comum nas abordagens clássicas como a TPS. Esse método é particularmente eficaz em cenários com dados esparsos, onde técnicas como a TPS podem gerar distorções ou onde uma rigidez excessiva comprometeria a representação de padrões espaciais.

2.3.4 Random Forest (RF)

O Random Forest (RF) é um método de aprendizado baseado em árvores de decisão, proposto por Breiman (2001), que utiliza bootstrap aggregating (bagging) para reduzir a variância e evitar sobreajuste. No bootstrap, cada árvore é treinada com um subconjunto gerado por amostragem com reposição, permitindo que algumas observações sejam repetidas enquanto outras fiquem de fora. Isso cria diversidade entre as árvores, tornando o modelo mais generalizável.

A previsão final do RF é a média das previsões individuais das árvores:

$$\hat{f}(x) = \frac{1}{B} \cdot \sum_{b=1}^B f_b(x) \quad (9)$$

Onde B é o número total de árvores na floresta, $f_b(x)$ é a previsão da b -ésima árvore de decisão treinada com uma amostra de bootstrap.

Cada árvore $fb(x)$ é ajustada a partir de um subconjunto de treinamento D_b contendo pares (x_k, y_k) .

$$D_b = \{(x_k, y_k) | k = 1, \dots, K\} \quad (10)$$

Onde x_k é o vetor de covariáveis e y_k a variável resposta correspondente.

Em cada nó das árvores, um subconjunto aleatório de variáveis preditoras é avaliado para determinar a melhor divisão, o que reduz a correlação entre as árvores e melhora a capacidade do modelo de generalizar para novos dados (Hengl et al., 2018). Essa abordagem permite capturar relações não lineares complexas entre as variáveis preditoras e a variável alvo, mesmo com intervenção mínima do usuário (Gharaei-Manesh et al., 2016; Baratto et al., 2022).

Neste estudo, utilizou-se a variável auxiliar altitude, proveniente do Modelo Digital de Elevação (MDE) da Shuttle Radar Topography Mission (SRTM), com resolução espacial de 30 m, obtido pelo Earth Explore (<https://earthexplorer.usgs.gov/>).

2.4. Avaliação da acurácia e precisão dos Interpoladores Espaciais

A precisão e acurácia dos interpoladores espaciais são essenciais para garantir a qualidade das estimativas (Nogueira et al., 2020). A validação cruzada leave-one-out (LOOCV) é um método amplamente utilizado, que consiste em remover sucessivamente um ponto do conjunto de dados, aplicar o interpolador aos dados restantes e comparar o valor estimado com o valor real removido (Isaaks; Srivastava, 1989; Wackernagel, 2003). Esse processo, repetido para todos os pontos, gera os valores estimados e observados usados para avaliar o desempenho dos interpoladores (Bronowicka-Mielniczuk et al., 2019).

Com base nessa abordagem, empregam-se indicadores como o erro médio absoluto (EAM), que mede a média dos erros absolutos entre valores estimados e observados, fornecendo uma métrica intuitiva da precisão (Wanderley; Amorim; Carvalho, 2014); o erro percentual absoluto médio (EPAM), que expressa os erros em termos percentuais, permitindo uma avaliação relativa; e o índice de concordância de Willmott (d), que quantifica a

similaridade entre estimados e observados, considerando tanto a magnitude quanto a distribuição dos erros (Baba; Vaz; Costa, 2014).

Para sintetizar a análise, foram selecionados três períodos de vinte anos (vintênios), abrangendo as médias mensais e anuais das variáveis hidroclimáticas. Os índices estatísticos foram aplicados a essas médias, de modo que os vintênios representem de forma concisa a série histórica e permitam a comparação assertiva dos interpoladores.

Os valores de precipitação, ETP e temperatura média foram avaliados pelos indicadores d (equação 11), EAM (equação 12) e EPAM (equação 13) (Ceccherini et al., 2015; Willmott, 1981; Machado et al., 2015).

$$d = 1 - \left[\frac{\sum_{i=1}^n (E_i - \bar{O}_i)^2}{\sum_{i=1}^n (|E_i - \bar{O}_i| + |O_i - \bar{O}_i|)^2} \right] \quad (11)$$

$$\text{EAM} = \frac{1}{n} \sum_{i=1}^n |E_i - O_i| \quad (12)$$

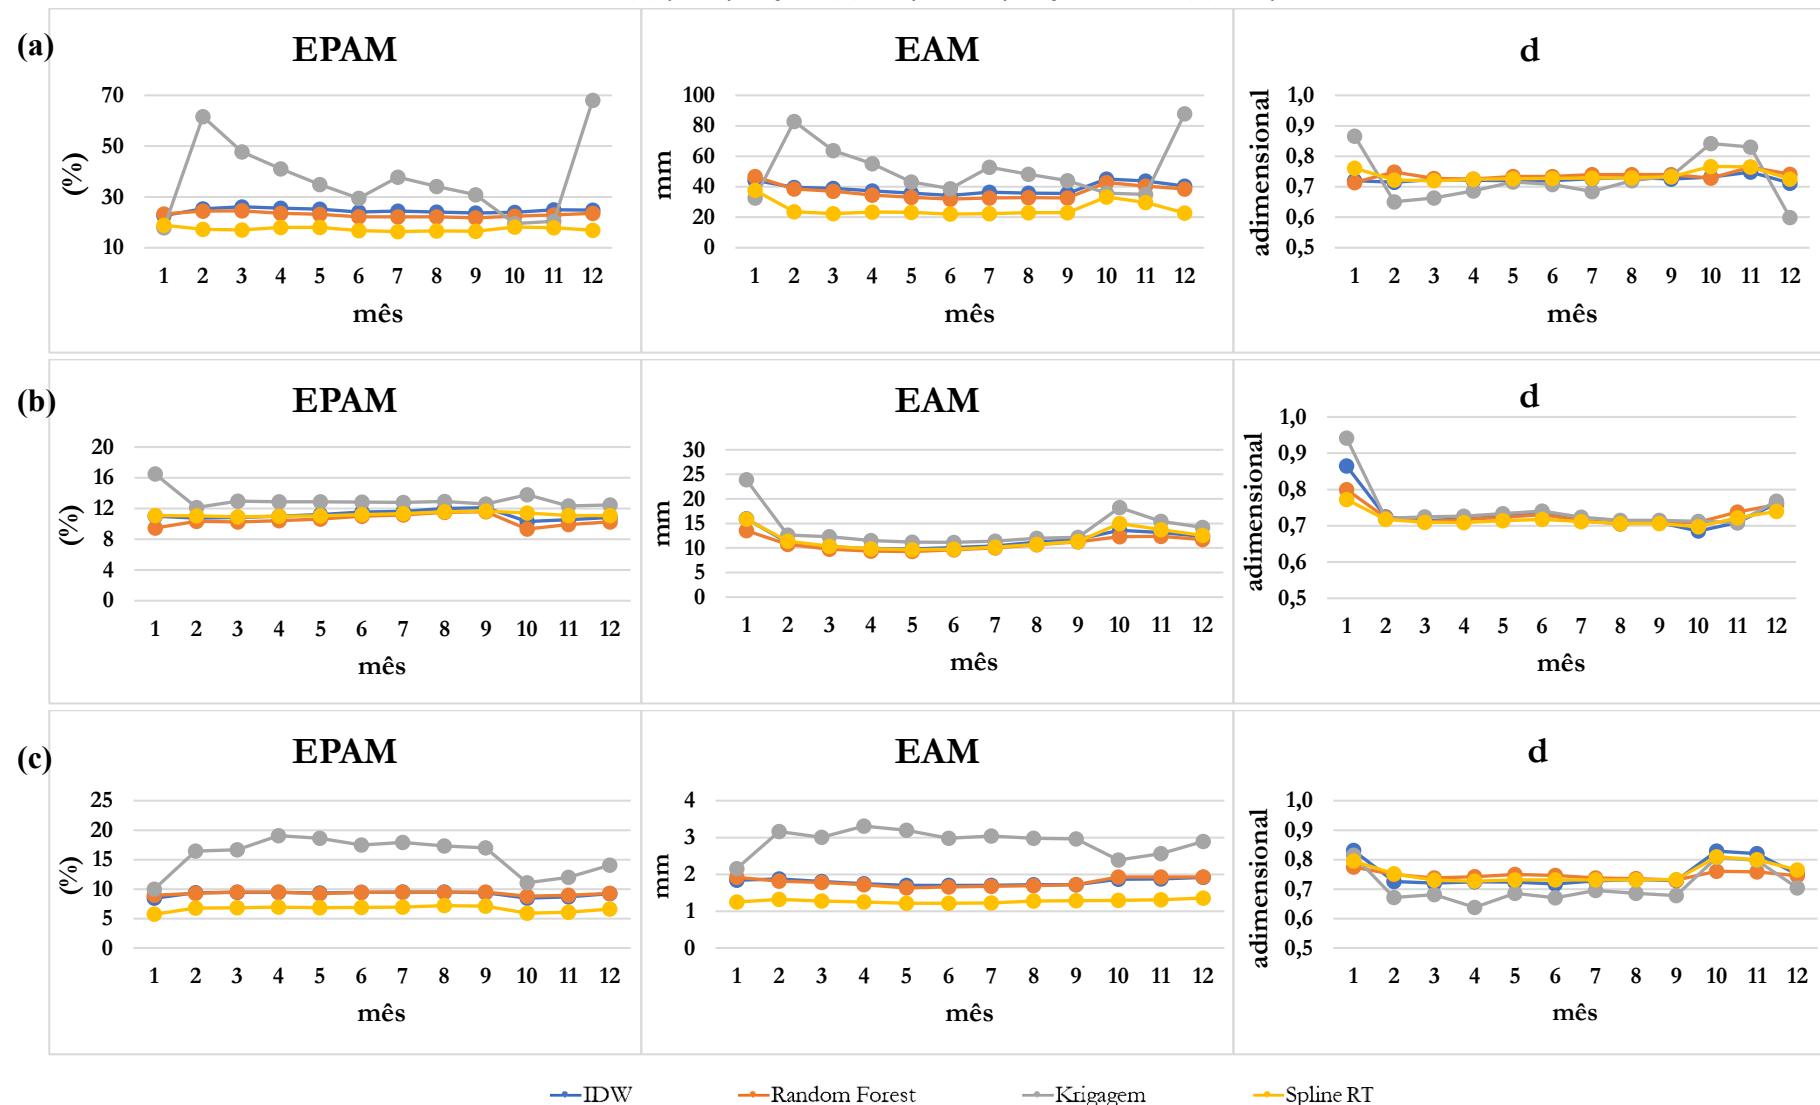
$$\text{EPAM} = \frac{1}{n} \sum_{i=1}^n \left| \frac{O_i - E_i}{O_i} \right| \cdot 100 \quad (13)$$

Onde E_i são valores estimados, O_i são valores observados, \bar{O} é a média dos valores observados, \bar{E} é a média dos estimados e n indica o número total de amostras.

3. RESULTADOS E DISCUSSÕES

O desempenho dos interpoladores na espacialização da precipitação, ETP e temperatura média foi avaliado por meio das métricas estatísticas o erro percentual absoluto médio (EPAM) e o erro médio absoluto (EAM) e o índice de concordância de Willmott (d). Os resultados mensais são apresentados na Figura 2, que sintetiza as médias dos três vintênios analisados. Já a Tabela 1 detalha os resultados anuais, incluindo tanto a média geral dos vintênios quanto os valores individuais de cada um.

Figura 2 - Indicadores estatísticos (EPAM, EAM e d) de desempenho dos interpoladores (IDW, OK, Spline RT e RF)** na espacialização das variáveis hidroclimáticas mensais: (a) precipitação; (b) evapotranspiração - ETP e (c) temperatura média - Tmed.



A Figura 2 mostra os resultados de EPAM, EAM e d obtidos pela validação cruzada LOOCV para cada interpolador espacial. Essa validação é fundamental para avaliar a precisão dos interpoladores, especialmente em regiões com alta variabilidade espacial das variáveis hidroclimáticas (Robinson; Metternicht, 2006; Amorim et al., 2008; Castro et al., 2010).

Na análise da precipitação mensal (Figura 2a), a OK apresentou os maiores erros médios (EPAM = 37%; EAM = 52 mm) e uma das menores concordâncias ($d = 0,73$). Esse desempenho pode ser explicado pela dificuldade em modelar o variograma devido à alta variabilidade espacial da precipitação. Embora preserve a média global, apresentando um índice d relativamente alto, erros locais comprometeram sua precisão. Resultados semelhantes foram observados por Rata et al. (2020) e Fung et al. (2022).

Os métodos IDW (EPAM = 25%; EAM = 39 mm; $d = 0,72$) e RF (EPAM = 23%; EAM = 37 mm; $d = 0,75$) tiveram desempenho mais consistente, com o RF se destacando pela maior concordância média. O Spline RT (EPAM = 17%; EAM = 25,5 mm; $d = 0,74$) foi o interpolador mais preciso, provavelmente devido ao controle de tensão que suaviza a superfície sem gerar oscilações irreais (Mitášová; Mitáš, 1993).

Apesar da OK não apresentar uma divergência significativa no índice d, sua limitação em capturar padrões locais reforça a necessidade de métodos como Spline RT e RF em cenários de alta variabilidade espacial. Os resultados gerais estão alinhados com a literatura, como mostrado por Ruezzene et al. (2021), Salleh et al. (2023) e Kanooni e Amogein (2025), confirmando a capacidade desses métodos em fornecer estimativas confiáveis em SC.

Para a ETP mensal (Figura 2b), as diferenças entre os interpoladores foram pequenas. A ordem do pior para o melhor desempenho, segundo os indicadores estatísticos, foi: Spline RT (EPAM = 11%; EAM = 11,7 mm; $d = 0,72$), IDW (EPAM = 11%; EAM = 11,6 mm; $d = 0,73$), OK (EPAM = 13%; EAM = 13,8 mm; $d = 0,74$) e RF (EPAM = 10%; EAM = 10,9 mm; $d = 0,73$). Assim, qualquer interpolador poderia preencher as lacunas das estações e gerar uma base confiável de ETP mensal, com resultados semelhantes aos descritos por Govay e Karim (2023) e Aschonitis et al. (2022).

Por fim, para a temperatura média (Figura 2c), a OK teve desempenho inferior, com EAM indicando desvios entre 1,1°C e 1,7°C em relação aos demais métodos.

Nesse contexto, os interpoladores apresentaram desempenhos semelhantes, principalmente ao expressar os indicadores estatísticos médios de todos os meses do ano. Isso permitiu ranquear os interpoladores do pior ao melhor: OK (EPAM = 16%; EAM = 2,9°C; d = 0,71), RF (EPAM = 9%; EAM = 1,8°C; d = 0,75), IDW (EPAM = 9%; EAM = 1,8°C; d = 0,75) e *Spline RT* (EPAM = 7%; EAM = 1,3°C; d = 0,75). Com esses indicadores estatísticos, semelhantemente ao que é encontrado na literatura atual, a exemplo de Saliba e Bărbulescu (2023) para EPAM, He et al. (2022) para EAM e Huerta et al. (2023) para d, fica claro que, para interpolação das temperaturas (Tmax, Tmed e Tmin), os quatro interpoladores estariam aptos a estimar os valores nas regiões onde não há estações meteorológicas com dados disponíveis.

Tabela 1 - Indicadores estatísticos (EAM, EPAM e d) de desempenho dos interpoladores (IDW, RF, OK e *Spline RT*) na espacialização das variáveis hidroclimáticas anuais: precipitação (PP), evapotranspiração (ETP) e temperatura – médias dos resultados (Tmed).

Variável	Vintênia	IDW			Random Forest (RF)			Krigagem (OK)			<i>Spline RT</i>		
		EAM	EPAM	d	EAM	EPAM	d	EAM	EPAM	d	EAM	EPAM	d
PP	1961-1980	208	12,9	0,74	165	10,1	0,74	181	12,6	0,64	236	16,2	0,75
	1981-2000	245	13,7	0,73	247	12,9	0,73	173	10,4	0,82	206	10,9	0,75
	2001-2020	239	13,6	0,75	185	10,7	0,82	273	15,2	0,96	129	7,2	0,72
Média		231	13,4	0,74	199	11,2	0,76	209	12,7	0,81	190	11,4	0,74
ETP	1961-1980	119	10,0	0,94	108	9,1	0,89	134	11,0	0,86	121	10,0	0,89
	1981-2000	78	7,3	0,86	84	7,8	0,85	111	11,0	0,70	80	7,7	0,80
	2001-2020	117	9,9	0,72	102	8,5	0,79	80	6,7	0,74	103	9,0	0,74
Média		105	9,1	0,84	98	8,5	0,85	109	9,6	0,77	101	8,9	0,81
Tmed	1961-1980	1,9	11,2	0,81	2,0	12,0	0,77	1,8	10,1	0,79	1,4	7,8	0,80
	1981-2000	2,1	12,0	0,89	2,1	12,8	0,75	1,7	10,0	0,83	1,6	9,4	0,86
	2001-2020	1,6	8,7	0,74	1,4	7,5	0,65	6,5	41,7	0,54	1,0	5,6	0,77
Média		1,9	10,7	0,81	1,9	10,8	0,73	3,3	20,6	0,72	1,3	7,6	0,81

A Tabela 1 mostra o desempenho dos interpoladores na espacialização das variáveis hidroclimáticas (precipitação, ETP e temperatura), indicando resultados similares entre eles,



exceto a OK, que apresentou desvio maior na temperatura (1,5 a 2,0 °C), especialmente no último vintênio. O Spline RT destacou-se para precipitação e temperatura (menores EPAM e EAM), enquanto o RF obteve o melhor desempenho para ETP, conforme o padrão mensal. Todos os métodos apresentaram alta precisão ($d \geq 0,70$) e erros compatíveis com a literatura (Mello et al., 2015; Lopes Sobrinho, 2024; Govay; Karim, 2024; Romero-Hernández et al., 2024; Di Piazza et al., 2015).

A base de dados gerada com esses interpoladores auxilia na gestão hídrica e em estudos climáticos, incluindo modelagem de eventos extremos, relevantes para a agricultura e setores urbanos de SC.

OK e IDW tiveram os piores desempenhos devido às limitações em capturar variações espaciais: OK sofre com a modelagem do variograma em áreas heterogêneas (Silva Junior et al., 2013; De Oliveira et al., 2024; Panosso, 2011), e IDW, por ser determinístico, gera suavização excessiva e efeitos indesejados em áreas com poucos dados (Pasin et al., 2015; Betzek, 2017).

Spline RT e RF foram mais eficientes na captura dos padrões espaciais. O Spline RT combina suavização e controle de oscilações, mantendo superfícies realistas mesmo com dados esparsos (De Oliveira et al., 2024). O RF, método de aprendizado de máquina, modela relações complexas sem pressupor estrutura espacial rígida, destacando-se na interpolação da ETP (Rigatti, 2016; Baratto et al., 2022).

Além disso, a análise regional foi feita com base em 10 regiões hidrográficas de SC (Figura 4), que consideram variações geográficas e climáticas locais.

As figuras 3, 4 e 5 apresentam mapas mensais das interpolações de precipitação, ETP e temperatura, respectivamente, por vintênio e região hidrográfica. As tabelas 2, 3 e 4 complementam esses mapas com médias quantitativas mensais, evidenciando variações espaciais e temporais das variáveis.

Figura 3 - Espacialização de precipitação média mensal por vintênios (1961-2020)

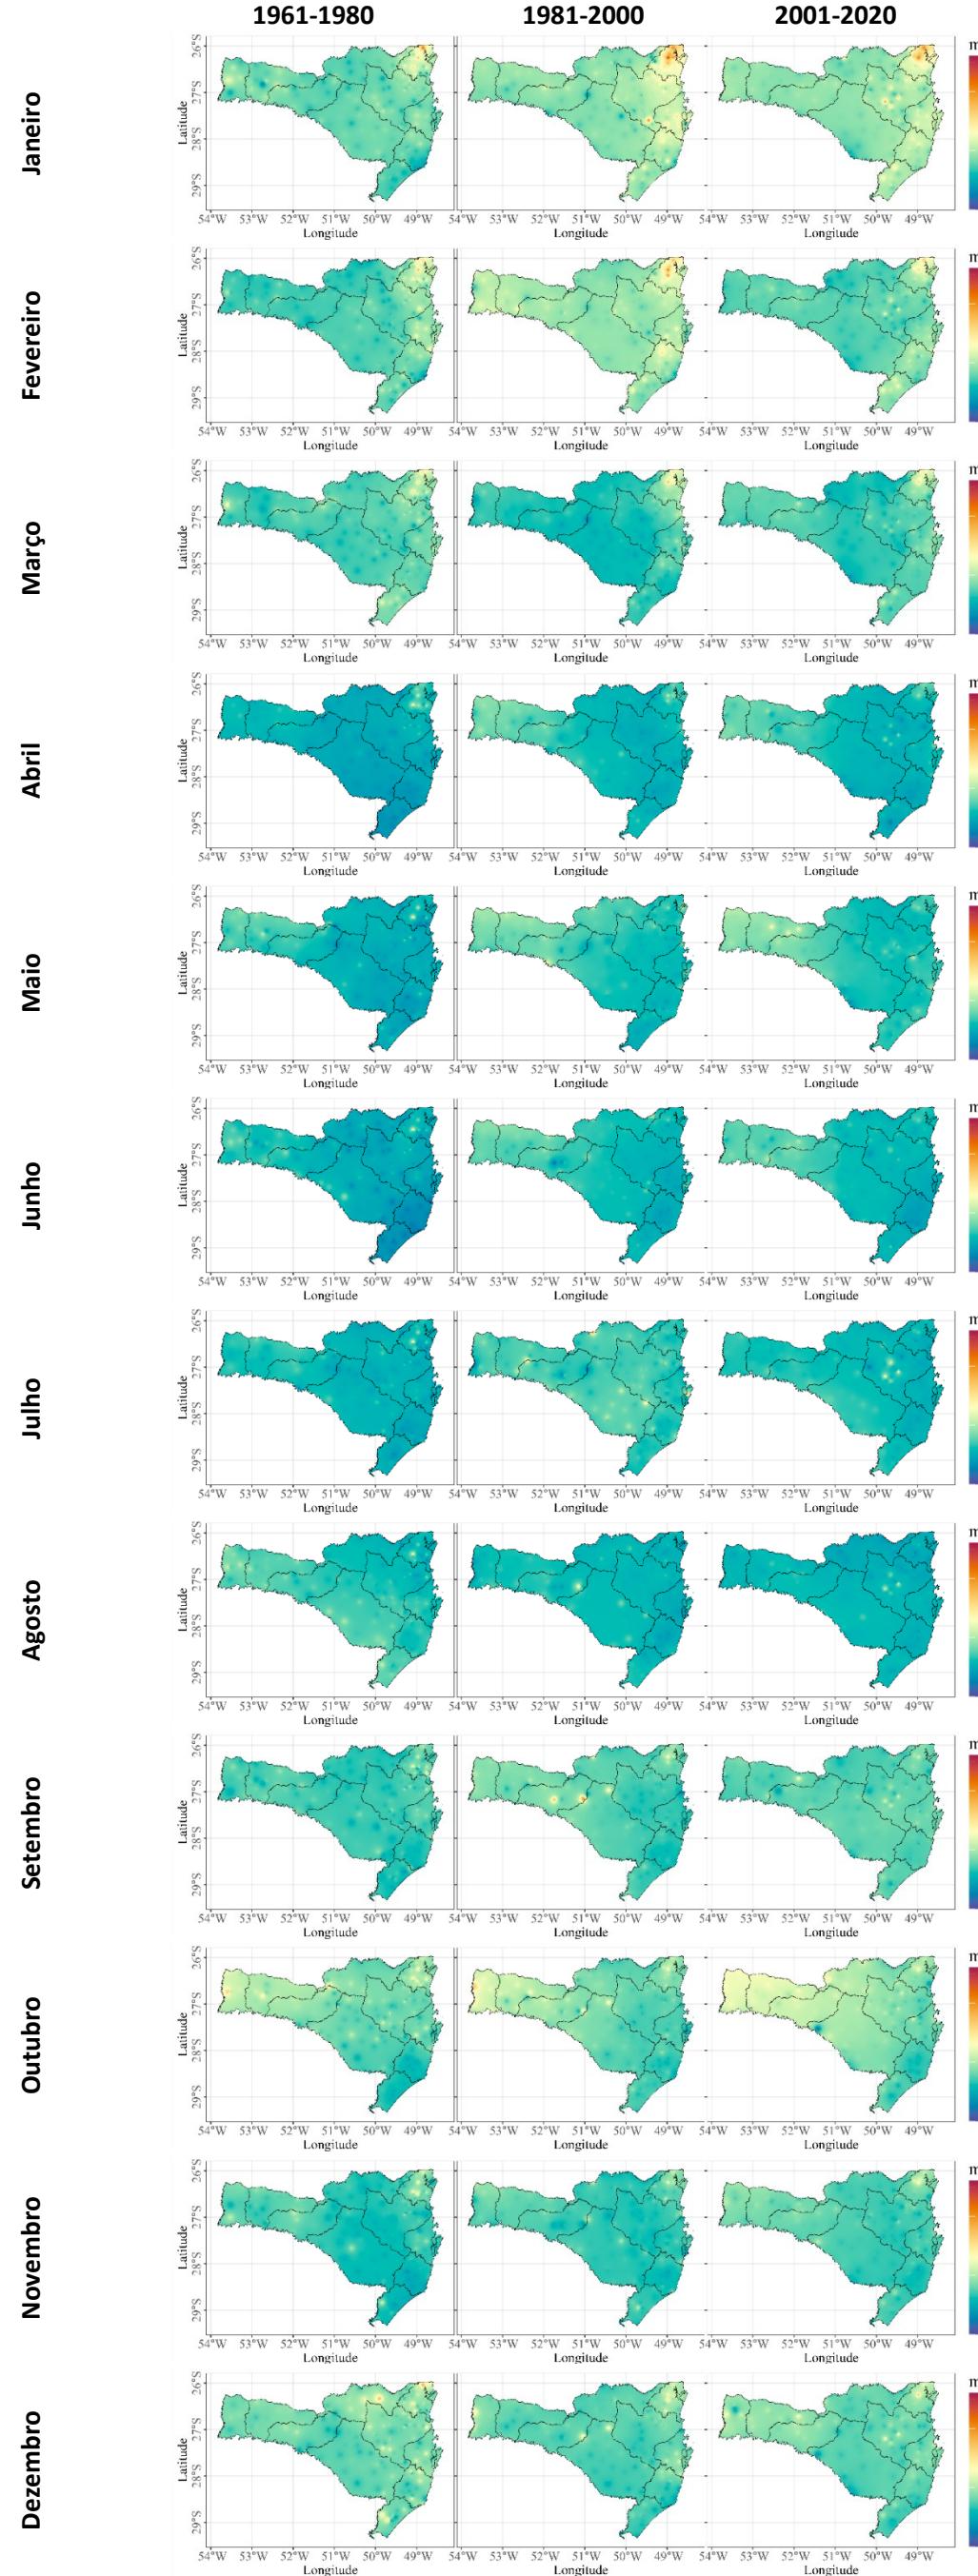


Figura 4 - Espacialização de ETP média mensal por vintênios (1961-2020)

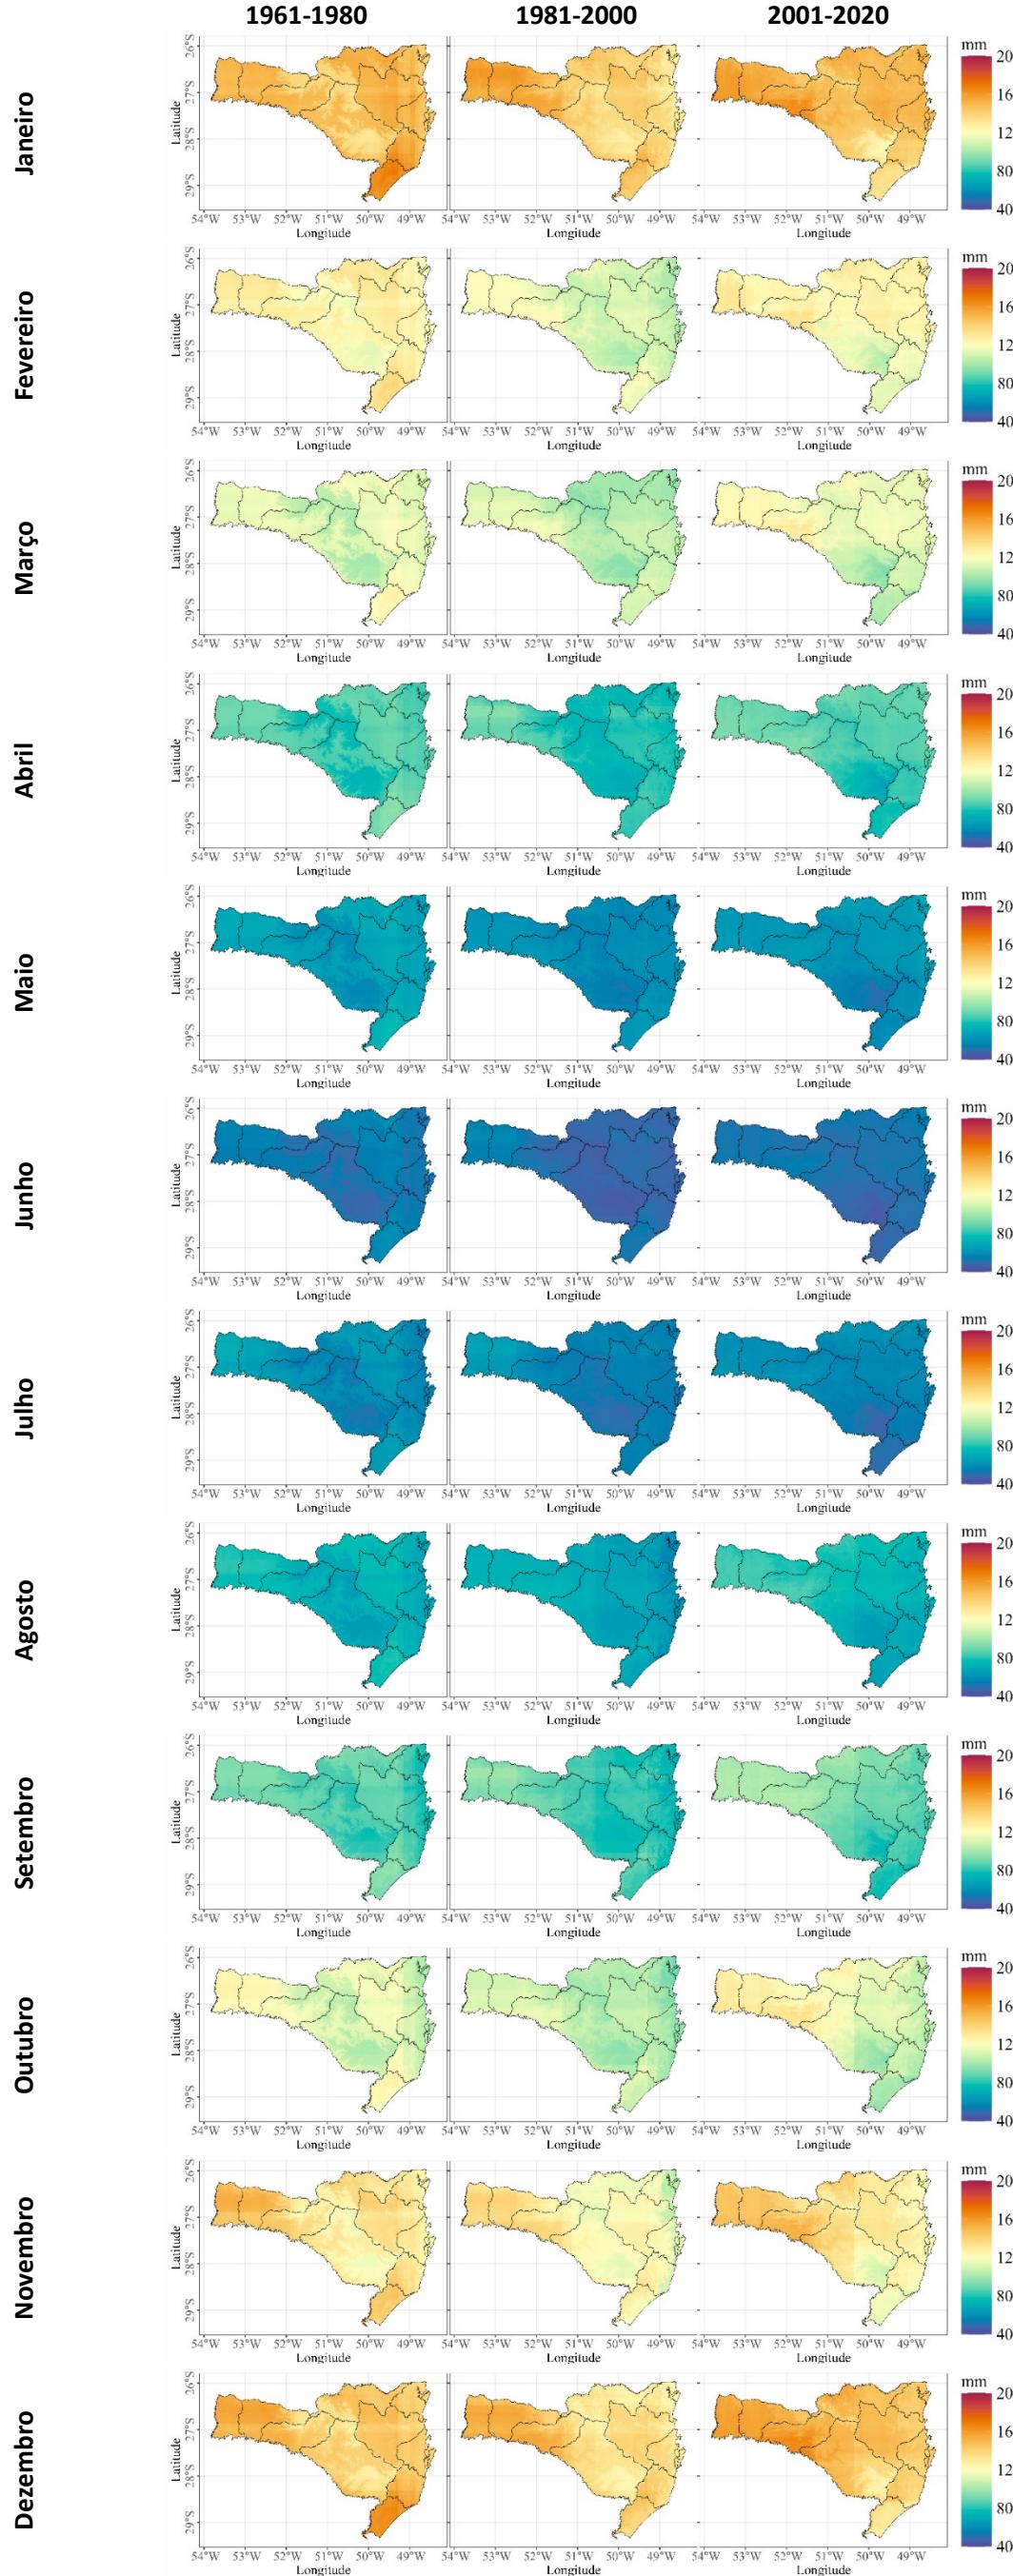


Figura 5 - Espacialização de Tmed média mensal por vintênios (1961-2020)

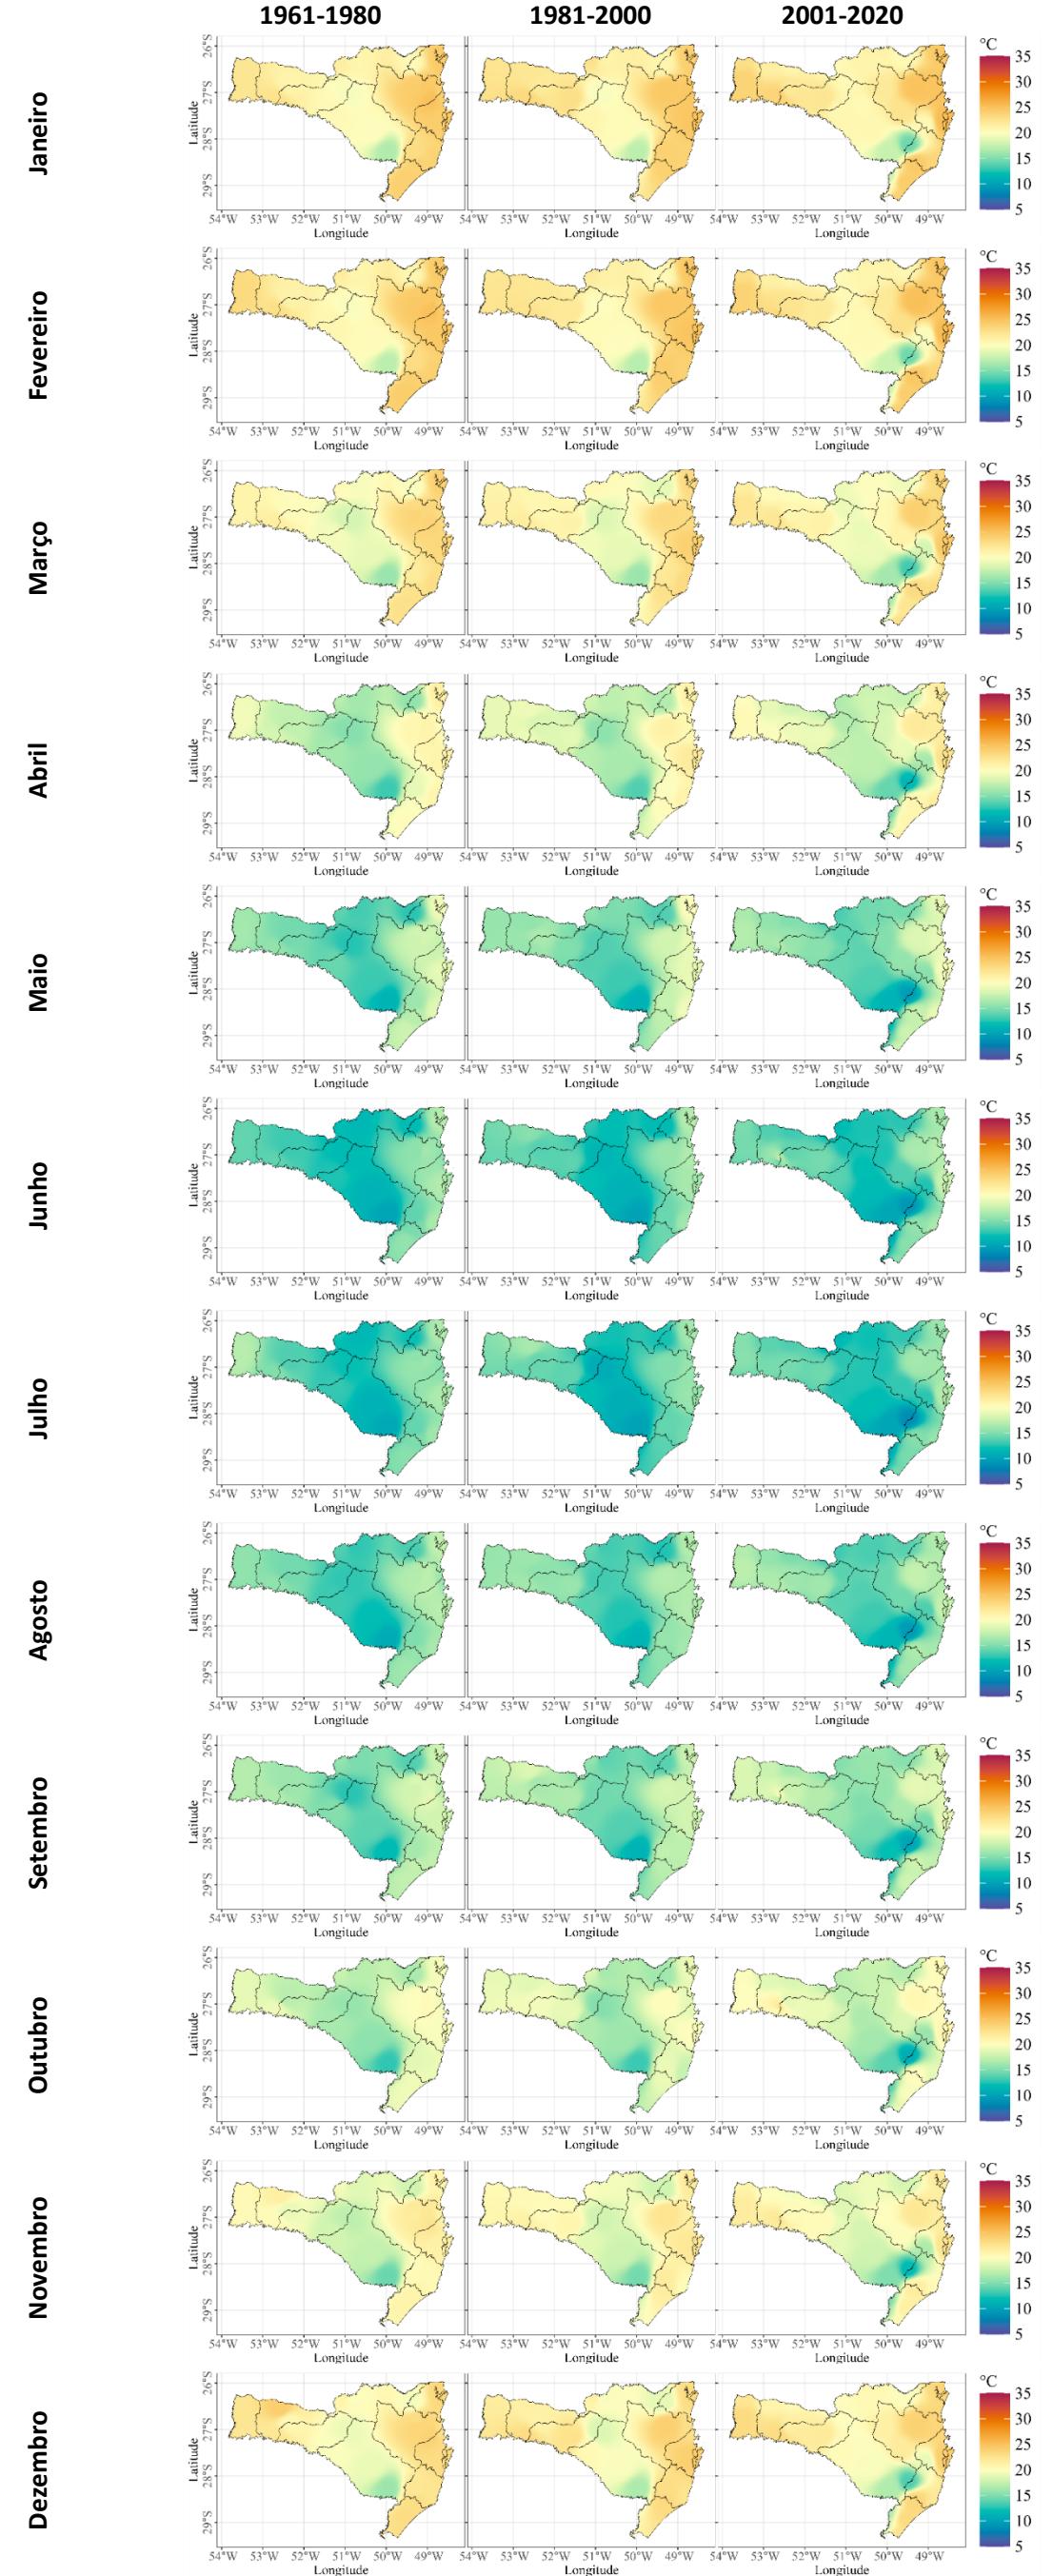


Tabela 2 - Médias mensais de precipitação por região hidrográfica (RH) para os vintênios entre 1961 e 2020.

RH1 (mm)			RH2 (mm)			RH3 (mm)			RH4 (mm)			RH5 (mm)			RH6 (mm)			RH7 (mm)			RH8 (mm)			RH9 (mm)			RH10 (mm)			
	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020			
Jan	174	183	189	167	183	182	159	178	183	161	178	179	160	182	181	224	272	259	168	208	198	171	225	211	153	203	206	144	192	206
Fev	141	211	150	140	200	158	140	190	156	148	184	150	141	178	145	215	246	210	161	193	159	188	200	174	163	202	181	162	186	191
Mar	150	138	153	139	129	153	149	121	147	143	116	132	152	128	125	196	202	192	156	135	144	163	149	163	157	138	152	176	137	157
Abr	116	169	160	113	156	150	101	135	135	88	117	109	94	109	112	130	128	124	99	105	106	95	107	115	82	100	98	74	112	100
Mai	151	171	183	145	170	179	121	152	159	99	127	130	108	144	123	109	130	127	99	123	122	99	118	134	90	111	128	95	105	131
Jun	136	162	153	124	156	154	113	137	145	99	123	119	94	128	118	110	115	120	96	110	113	86	100	101	66	97	88	67	108	106
Jul	128	141	130	129	146	126	119	140	127	109	151	127	107	143	113	113	132	108	107	143	115	103	130	105	94	132	104	98	128	121
Ago	160	119	109	151	125	116	139	126	117	144	120	114	116	112	95	116	106	98	122	111	108	126	100	108	129	102	103	151	117	112
Set	145	178	153	148	169	155	143	176	153	137	154	156	132	151	145	160	166	161	140	156	147	133	161	128	128	148	126	141	154	
Out	219	236	243	200	206	234	183	187	216	155	162	184	171	162	197	192	180	182	164	154	178	161	145	161	128	137	138	125	144	150
Nov	158	161	175	151	157	168	147	141	160	124	135	141	131	135	145	170	162	173	128	131	139	138	132	143	112	124	130	119	136	143
Dez	166	177	186	170	154	185	159	154	175	156	147	187	150	158	195	193	188	175	153	161	173	166	167	169	147	154	172	141	147	

Tabela 3 - Médias mensais de ETP por região hidrográfica por vintênios (1961-2020)

RH1 (mm)			RH2 (mm)			RH3 (mm)			RH4 (mm)			RH5 (mm)			RH6 (mm)			RH7 (mm)			RH8 (mm)			RH9 (mm)			RH10 (mm)				
	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020	1961-1980	1981-2000	2001-2020				
Jan	150	156	158	148	155	153	146	149	154	142	136	142	148	141	148	146	134	149	151	140	150	148	134	149	155	140	141	164	145	135	
Fev	129	120	129	127	118	124	125	116	126	121	108	116	127	110	125	124	105	126	128	111	125	124	108	123	128	111	117	135	117	114	
Mar	115	113	122	114	112	121	112	111	122	108	102	109	113	99	115	113	100	115	116	116	105	116	114	107	114	117	109	109	123	111	104
Abr	90	90	92	87	88	89	84	82	89	80	74	80	85	76	87	85	78	88	88	80	86	86	79	85	89	81	82	93	82	79	
Mai	68	62	64	67	61	63	65	60	63	62	57	57	66	58	63	67															

Analisando a figura 3 e a tabela 2, as regiões RH 1, 2, 3, 8 e 10 apresentaram maiores precipitações em pelo menos metade dos meses do último vintenário, enquanto RH 4, 7 e 9 aumentaram suas precipitações em relação aos períodos anteriores. Essa elevação está relacionada à localização geográfica, proximidade do litoral e efeito orográfico (Tavares; Ferreira, 2020). O fenômeno El Niño, ocorrido em anos específicos (Kayano et al., 2016; Agrosmart, 2016), também contribuiu para esse aumento.

As precipitações seguem padrão sazonal, menores no inverno e maiores no verão, com destaque para RH 6, que mantém as maiores chuvas nos meses de verão, influenciada pela alta pluviosidade de Joinville (NSC, 2021). Altos volumes no Oeste (RH 1 e 2), Vale do Itajaí (RH 7) e litoral (RH 8, 9 e 10) são associados à umidade relativa elevada e temperaturas mais altas (INMET, 2025).

A figura 4 e a tabela 3 mostram a sazonalidade da evapotranspiração, com maiores valores no verão devido às temperaturas elevadas e menor umidade no interior (Denski; Back, 2015). O método RF evidenciou influência da altitude, com menor evapotranspiração nas serras. RH 1, 2, 3, 4, 5 e 6 apresentaram aumento de até 5% na ETP no último vintenário, possivelmente ligado à urbanização e mudanças climáticas. Já RH 9 e 10, no litoral sul, mostraram redução na ETP, possivelmente devido à alta umidade local.

Na análise da temperatura média (figura 5 e tabela 4), RH 1, 2, 3 e 6 exibiram aumento em pelo menos metade dos meses do último vintenário, com acréscimos de até 1 °C, impactando ecossistemas e agricultura (Assad e Assad, 2024; IPCC, 2023). RH 8, 9 e 10 mostraram redução da temperatura, atribuída à influência marítima e maior preservação ambiental.

As variações sazonais são evidentes, com temperaturas mais amenas nas regiões serranas devido ao gradiente térmico de ~6,5°C por quilômetro de altitude (Miranda; Souza, 2012; Santos, 2016). Geadas frequentes nas serras no inverno exigem atenção agrícola (Climatempo, 2022; Borges et al., 2024). A interpolação espacial demonstrou eficácia para representar a variabilidade térmica, mesmo com número limitado de estações.

Finalmente, a figura 6 e tabela 5 apresentam as médias anuais das variáveis por região hidrográfica e vintenário, destacando áreas e períodos com maiores valores.

Figura 6 – Espacialização das variáveis hidroclimáticas com médias anuais por vintênios entre 1961 e 2020

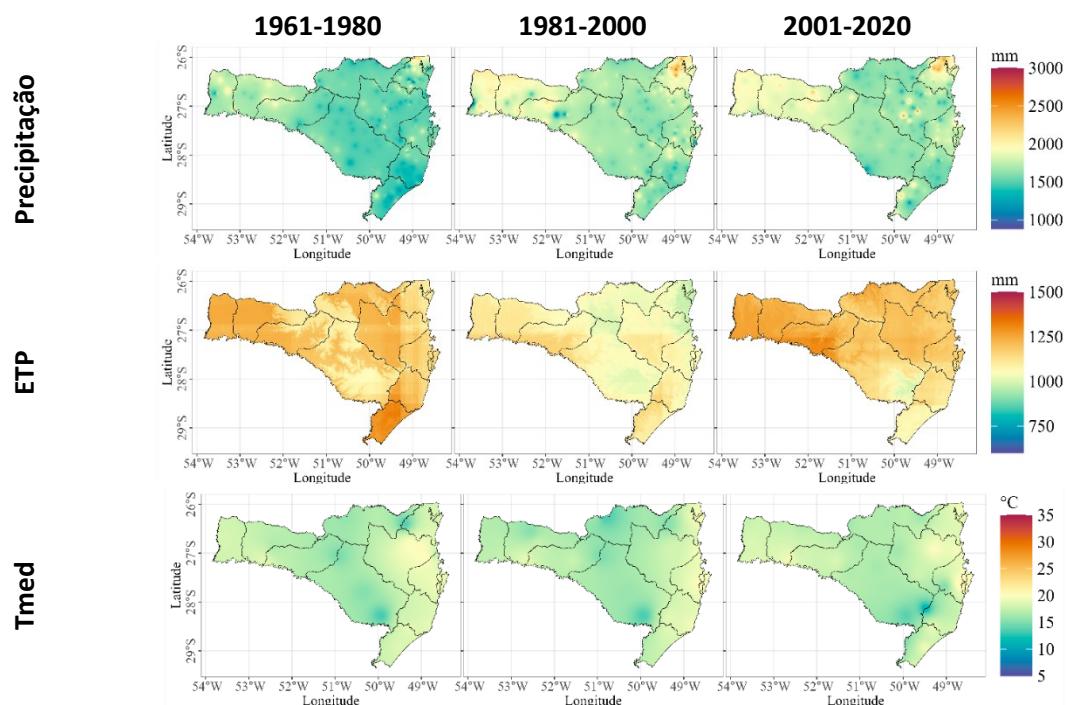


Tabela 5 – Resumo das variáveis anuais por regiões hidrográficas

Vintêniao		SC	RH1	RH2	RH3	RH4	RH5	RH6	RH7	RH8	RH9	RH10
Precipitação (mm)	1961-1980	1564	1721	1719	1622	1510	1538	1645	1524	1549	1457	1457
	1981-2000	1729*	1908	1882	1758	1677	1686	1939	1670	1697	1624	1635
	2001-2020	1722	1914	1886	1814	1652	1620	1890	1660	1735	1606	1671
ETP (mm)	1961-1980	1178	1233	1209	1177	1129	1172	1136	1198	1157	1198	1290
	1981-2000	1068	1114	1097	1105	1050	1032	1009	1064	1060	1085	1112
	2001-2020	1178	1249	1231	1241	1139	1196	1173	1191	1165	1117	1073
Tmed (°C)	1961-1980	17,2	17,9	17,3	16,6	16,1	16,3	17,6	18,4	18,9	18,3	18,1
	1981-2000	16,9	17,0	16,9	16,9	16,0	15,6	17,9	17,3	18,9	18,6	17,7
	2001-2020	17,3	18,1	17,8	17,6	16,1	16,9	18,4	17,8	18,3	16,8	17,6

* Números em **bold** indica o vintêniao com a maior média anual de cada variável meteorológica.

A análise anual das variáveis hidroclimáticas (precipitação, ETP e Tmed), conforme a Figura 9 e Tabela 5, fornece uma visão abrangente das condições em Santa Catarina. Os mapas

interpolados mostram que o Oeste (RH 1, 2, 3), litoral (RH 6) e Vale do Itajaí (RH 7) registram os maiores volumes de chuva (1900–2200 mm), enquanto o litoral sul (RH 9 e 10) e a Serra Catarinense (RH 4) têm os menores (1300–1600 mm), influenciados por altitude e circulação atmosférica (Gotado et al., 2018). O aumento de 10% na precipitação no período 2001–2020, comparado a 1961–1980, pode estar ligado a mudanças climáticas, embora mais análises sejam necessárias.

A ETP é mais elevada no litoral e Oeste (acima de 1200 mm), devido à maior radiação e temperatura, enquanto nas regiões serranas é menor (Pandolfo et al., 2002). As temperaturas médias anuais mantêm-se estáveis (16,9°C a 17,3°C), mas variam regionalmente: de 16 a 20°C no litoral e Oeste, e 12 a 15°C nas serras, impactando diretamente o ciclo das culturas (Bornhofen et al., 2015). As Serras (RH 10) apresentaram ligeira redução na ETP no último período.

A interpolação espacial melhora a estimativa das variáveis em áreas com baixa densidade de dados, auxiliando na identificação de possíveis mudanças climáticas (Brubacher et al., 2020). Os interpoladores apresentaram desempenho semelhante nas escalas mensal e anual, mas Spline RT foi o escolhido para precipitação e Tmed, e RF para ETP, com base na precisão e representação espacial. A base de dados final cobre a série 1961–2020 (exceto 1986 para ETP e temperatura), conforme detalhado no Quadro 1, que também inclui o link para download das especializações.

Quadro 1 – Base de dados de variáveis hidrológicas e climáticas de Santa Catarina com especificações

Mapas mensais			Mapas anuais	
Precipitação, ETP e Tmed http://dx.doi.org/10.17632/c889r6gc86.1			Precipitação, ETP e Tmed http://dx.doi.org/10.17632/2vd89dsxvs.1	
Formato	Série Histórica	Resolução espacial (largura do pixel)	Datum	SCR (Código EPSG)
GeoTIFF	1961-2020	500 m	Sirgas 2000	4674

4. CONCLUSÃO

Neste trabalho, foi realizado o mapeamento das variáveis hidroclimáticas — precipitação, evapotranspiração potencial e temperatura média — utilizando dados da ANA e

do INMET em Santa Catarina. Foram testados diferentes interpoladores espaciais (IDW, Spline RT, Krigagem ordinária e Random Forest), e selecionados os mais adequados por variável. O Spline RT apresentou melhor desempenho para precipitação e temperatura, enquanto o Random Forest se destacou na interpolação da evapotranspiração potencial, mostrando maior precisão ao lidar com dados complexos. A validação cruzada *leave one out* confirmou a confiabilidade das espacializações.

A base gerada oferece dados mensais e anuais com alta resolução (pixels de 500 m), cobrindo todo o estado, superando as limitações das redes de estações meteorológicas e das bases de satélite. Essa base, disponibilizada online, serve como apoio a estudos ambientais e agrícolas, permitindo análises históricas e subsidiando decisões em cenários de mudanças climáticas.

Por fim, as análises mostraram maiores volumes de precipitação no litoral e Oeste, influenciados por topografia e umidade. Temperatura média e evapotranspiração também foram mais altas no litoral Norte e Oeste, em razão da urbanização, insolação e altitude. As séries temporais indicam aumento de precipitação, temperatura e evapotranspiração no último vintémio, sinalizando possíveis impactos das mudanças climáticas.

AGRADECIMENTOS

Agradecemos a FAPESC, ao CNPq e à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) pelo apoio financeiro, por meio da concessão de bolsa de estudos.

REFERÊNCIAS

ADRISON, L. C.; UGAYA, C. Sustainable strategies for water security in Brazilian agriculture: a regionalized study. In: Forum for Sustainability through Life Cycle Innovation e.V., XIV, 2024, Gotemburgo. **Anais XIV Forum for Sustainability through Life Cycle Innovation e.V.**, Berlin: LCIC, 2024.

Agência Nacional de Águas (ANA). **HidroWeb**, Disponível em: <<https://www.snrh.gov.br/hidroweb/mapa>> acesso em 20 dez. de 2022.

AgroSmart. **El Niño E La Niña: Entenda Seus Impactos No Brasil**, 2016. Disponível em: <<https://agrosmart.com.br/blog/el-nino-e-la-nina-entenda-seus-impactos-no-brasil/>>. Acesso em: 30 mar. 2025.

ALBUQUERQUE, F. L. Climate politics and the crisis of the liberal international order. **Contexto Internacional**, v. 43, n. 2, p. 259–282, 2021.

ALLEN, M.; ANTWI-AGYEI, P.; ARAGON-DURAND, F.; BABIKER, M.; BERTOLDI, P.; BIND, M.; BROWN, S.; BUCKERIDGE, M.; CAMILLONI, I.; CARTWRIGHT, A.; CRAMER, W. **Technical Summary: Global warming of 1.5° C**. An IPCC Special Report on the impacts of global warming of 1.5° C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty. 2019.

ALLEN, R. G.; PEREIRA, D. R.; RAES, D.; SMITH, M. Crop Evapotranspiration: Guidelines for computing crop water requirements. In: _____. (org.). **FAO Penman-Monteith equation**. Rome: FAO. ed.1, 1998.

AMORIM, R. C. F.; RIBEIRO, A.; LEITE, C. C.; LEAL, B. G.; SILVA, J. B. G. Avaliação do desempenho de dos métodos de espacialização da precipitação pluvial para o estado de Alagoas. **Acta Scientiarum Technology**, v.30, n.1, p.87-91, 2008.

ASCHONITIS, V. et al. Correcting Thornthwaite potential evapotranspiration using a global grid of local coefficients to support temperature-based estimations of reference evapotranspiration and aridity indices. **Earth System Science Data**, v. 14, n. 1, p. 163–177, 20 jan. 2022.

ASSAD, E. D.; ASSAD, M. L. R. C. L. Mudanças do clima e agropecuária: impactos, mitigação e adaptação. Desafios e oportunidades. **Estudos Avançados**, v. 38, p. 271–292, 29 nov. 2024.

BABA, R. K.; VAZ, M. S. M. G.; COSTA, J. DA. Correção de dados agrometeorológicos utilizando métodos estatísticos. **Revista Brasileira de Meteorologia**, v. 29, p. 515–526, 2014.

BARATTO, P. F. B.; CECÍLIO, R. A.; SOUSA TEIXEIRA, D. B.; ZANETTI, S. S.; XAVIER, A. C. Random forest for spatialization of daily evapotranspiration (ETP) in watersheds in the Atlantic Forest. **Environmental Monitoring and Assessment**, v. 194, n. 6, p. 449, 2022.

BETZEK, N. M. **Módulos computacionais de análise geoestatística e retificação de zonas de manejo**. 2017. Tese (Doutorado em Engenharia Agrícola) – Centro de Ciências Exatas e Tecnológicas, Universidade Estadual Do Oeste Do Paraná, Cascavel, 2017.

BORGES, C.; FERNANDES, C.; CALDAS, J. Com 45 cidades abaixo de 0°C, SC tem lago congelado, estrada com sal e geada em meio a animais, 2024. **G1**. Disponível em: <<https://g1.globo.com/sc/santa-catarina/noticia/2024/07/01/sc-30-cidades-abixo-de-0oc-lago-congelado-estrada-com-sal-geada.ghml>>. Acesso em: 22 out. 2024.

BORNHOFEN, E.; BENIN, G.; GALVAN, D.; FLORES, M. F. Épocas de semeadura e desempenho qualitativo de sementes de soja. **Pesquisa Agropecuária Tropical**, v. 45, p. 46–55, 2015.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, ed. 1, p. 5–32, 2001.

BRONOWICKA-MIELNICZUK, U.; MIELNICZUK, J.; OBROŚLAK, R.; PRZYSTUPA, W. A comparison of some interpolation techniques for determining spatial distribution of nitrogen compounds in groundwater. **International Journal of Environmental Research**, v. 13, p. 679-687, 2019.

BRUBACHER, J. P.; OLIVEIRA, G. G. DE; GUASSELLI, L. A. Preenchimento de falhas e espacialização de dados pluviométricos: desafios e perspectivas. **Revista Brasileira de Meteorologia**, v. 35, p. 615-629, 2020.

CAI, X.; WANG, X.; JAIN, P.; FLANNIGAN, M. D. Evaluation of gridded precipitation data and interpolation methods for forest fire danger rating in Alberta, Canada. **Journal of Geophysical Research: Atmospheres**, v. 124, p. 3-17, 2019.

CAMERA, C.; BRUGGEMAN, A.; HADJINICOLAOU, P.; PASHIARDIS, S.; LANGE, M. A. Evaluation of interpolation techniques for the creation of gridded daily precipitation ($1 \times 1 \text{ km}^2$); Cyprus, 1980–2010. **Journal of Geophysical Research: Atmospheres**, v.119, ed.2, p.693-712, 2014.

CASTRO, F. S.; PEZZOPANE, J. E.M.; CECÍLIO, R. A.; PEZZOPANE, J. R. M.; XAVIER, A. C. Avaliação do desempenho dos diferentes métodos de interpoladores para parâmetros do balanço hídrico climatológico. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 14, n.8, 2010.

CECCHERINI, G.; AMEZTOY, I.; HERNÁNDEZ, C.P.R.; MORENO, C.C. High-resolution precipitation datasets in South America and West Africa based on satellite-derived rainfall, enhanced vegetation index and digital elevation model. **Remote Sensing**, v.7, ed. 5, p.6454-6488, 2015.

CECÍLIO, R. A. et al. Método para a espacialização dos elementos do balanço hídrico climatológico. **Pesquisa Agropecuária Brasileira**, v. 47, n. 4, p. 478–488, 2012.

CLIMATEMPO. Serra Catarinense registra menor temperatura do Brasil neste ano. **Climatempo**, 2022. Disponível em: <<https://www.climatempo.com.br/noticia/2022/05/20/serra-catarinense-registra-menor-temperatura-do-brasil-este-ano-5418>>. Acesso em: 22 out. 2024.

DE OLIVEIRA, P. V. A. DE et al. Estudo comparativo dos interpoladores espaciais IDW e SPLINE para dados pluviométricos no Norte de Minas Gerais. **Cadernos do Leste**, v. 24, n. 24, 2024.

DENSKI, A. P. N.; BACK, A. J. Tendência climatológica nos elementos meteorológicos e na evapotranspiração de referência de Urussanga-SC. **Revista Brasileira de Climatologia**, v. 17, 2015.

DI PIAZZA, A. et al. Comparative analysis of spatial interpolation methods in the Mediterranean area: application to temperature in Sicily. **Water**, v. 7, n. 5, p. 1866–1888, 2015.

DU, T.; KANG, S.; ZHANG, J.; DAVIES, W. J. Deficit irrigation and sustainable water-resource strategies in agriculture for China's food security, **Journal of Experimental Botany**, v. 66, n. 8, p.2253-2269, 2015.

DUCHON, J. **Splines minimizing rotation-invariant semi-norms in Sobolev spaces**. In: SCHUMAKER, L. L.; ZIEGLER, K. (Ed.). *Constructive theory of functions of several variables*. Berlin: Springer, 1976. p. 85-100.

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

Gerência de Planejamento de Recursos Hídricos (GEPHI). **Bacias_Hidrograficas do Estado de Santa Catarina,** Disponível em: <https://www.aguas.sc.gov.br/jsmallfib_top/DHRI/bacias_hidrograficas/bacias_hidrograficas_sc.pdf> acesso em 20 dez. de 2021.

GHARAEI-MANESH, S.; FATHZADEH, A.; TAGHIZADEH-MEHRJARDI, R. Comparison of artificial neural network and decision tree models in estimating spatial distribution of snow depth in a semi-arid region of Iran. **Cold Regions Science and Technology**, v.122, p.26-35, 2016.

GOTADO, R.; PIAZZA, G. A.; TORRES, E.; SEVERO, D. L.; KAUFMAN, V. Distribuição espacial e temporal das chuvas no estado de Santa Catarina. **Geosul**, v. 67, p. 253–276, 2018.

GOVAY, M. B. I.; KARIM, T. H. Trend analysis, modeling and interpolation of reference evapotranspiration time series in the semi-arid region of Duhok Governorate. **The Journal of University of Duhok**, v. 26, n. 2, p. 127–143, 24 dez. 2023.

GOVAY, M. B. I.; KARIM, T. H. Comparative analysis of different techniques for spatial interpolation of rainfall datasets in Duhok Governorate. **The seybold report**, v. 18, n. 01, p. 2541-2555, 2024.

HARGREAVES, G. H.; SAMANI, Z. A. Reference crop evapotranspiration from temperature. **Applied Engineering in Agriculture**, v.01, n.02, p.96-99, 1985.

HE, Q. et al. GPRChinaTemp1km: a high-resolution monthly air temperature data set for China (1951–2020) based on machine learning. **Earth System Science Data**, v. 14, n. 7, p. 3273–3292, 15 jul. 2022.

HENGL, T.; NUSSBAUM, M.; WRIGHT, M. N.; HEUVELINK, G. B.M.; GRÄLER, B. Random forest as a generic framework for predictive modeling of spatial and spatio-temporal variables. **PeerJ**. 2018.

HUERTA, A. et al. High-resolution grids of daily air temperature for Peru - the new PISCOt v1.2 dataset. **Scientific Data**, v. 10, n. 1, p. 847, 1 dez. 2023.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Santa Catarina**. 2021. Disponível em <<https://cidades.ibge.gov.br/brasil/sc>>. Acesso em 26 dez. 2021.

Instituto Nacional de Meteorologia (INMET). **BDMEP**, Disponível em: <<https://portal.inmet.gov.br/>> acesso em 20 dez. de 2022.

Instituto Nacional de Meteorologia (INMET). **Clima**. Disponível em: <<https://clima.inmet.gov.br/GraficosClimatologicos/>>. Acesso em: 30 mar. 2025.

Intergovernmental Panel on Climate Change (IPCC). **AR6 Synthesis Report**, 2023. Disponível em: <<https://www.ipcc.ch/report/ar6/syr/>>. Acesso em: 1 fev. 2025.

Intergovernmental Panel on Climate Change (IPCC). **Climate Change 2021: The Physical Science Basis**, 2023. Disponível em: <<https://www.ipcc.ch/report/sixth-assessment-report-working-group-i/>>. Acesso em: 4 jul. 2025

- ISAAKS, E. H.; SRIVASTAVA, R. M. **An introduction to applied geostatistics.** Oxford: Oxford University Press, 1989. 561 p.
- JONES, P. G.; THORNTON, P. K. The potential impacts of climate change on maize production in Africa and Latin America in 2055. **Global Environmental Change**, v. 13, n. 1, p. 51–59, 2003.
- KANOONI, A.; AMOGEIN, E. F. Comparison of sensitivity of interpolation methods by rain gauge network density. **Irrigation Sciences and Engineering**, v. 47, n. 4, 2025.
- KAYANO, M. T.; ANDREOLI, R. V.; SOUZA, R. A. F. de; GARCIA, S. R.; CALHEIROS, A. J. P. **El Niño e La Niña dos últimos 30 anos:** diferentes tipos, 2016.
- LOPES SOBRINHO, O. P.; LIMA CASTRO JÚNIOR, W.; ARRAIS CIPRIANO, D.; DE KÁSSIA PEREIRA CANTANHEDE, E.. Métodos empíricos de estimativa da evapotranspiração de referência para Codó, Maranhão, Brasil. **Revista Brasileira de Climatologia**, [S. I.], v. 34, n. 20, p. 265–287, 2024.
- LUNDGREN, W. J. C.; SILVA, J. A. A.; FERREIRA, R. L. C. Estimação do volume de eucaliptos por krigagem e cokrigagem no Semiárido Pernambucano. **Floresta e Ambiente**, v. 24, 2017.
- MACHADO, N. G.; MEIRELLES, T.; DANIELICHEN, V. H. M.; QUERINO, C. A. S.; BIUDES, M. S. Estimation of rainfall by neural network over a neotropical region. **Revista Brasileira de Climatologia**, v. 17, p.44-54, 2015.
- MATHERON, G. Principles of geostatistics. **Economic Geology**, v. 58, n. 8, p. 1246-1266, 1963.
- MEDEIROS, R. M. Balanço hídrico sequencial em São Bento do Una-Pe, Brasil, visando apoio a avicultura. **Revista de Geografia**, v. 37, n. 2, p. 318–342, 2020.
- MELLO, C. R. de; VIOLA, M. R.; OWENS, P. R.; MELLO, J. M. de; BESKOW, S. Interpolation methods for improving the RUSLE R-factor mapping in Brazil. **Journal of Soil and Water Conservation**, v. 70, n. 3, p. 182–197, 2015.
- MENDEZ, M.; CALVO-VALVERDE, L. A.; MAATHUIS, B.; ALVARADO-GAMBOA, L. F. Generation of monthly precipitation climatologies for Costa Rica using irregular raingauge observational networks. **Water**, v. 11, 2019.
- MIRANDA, R. A. C; SOUZA, L. **Climatologia geográfica.** Rio de Janeiro: Fundação CECIERJ, 2012. 246p.
- MITÁŠOVÁ, H.; MITÁŠ, L. Interpolation by regularized spline with tension: I. Theory and implementation. **Mathematical Geology**, v. 25, n. 6, p. 641-655, 1993.
- NOGUEIRA, D. B.; SILVA, A. O. DA; SILVA, A. P. N. DA. Comparação entre métodos de interpolação espacial para a estimativa da distribuição de precipitação no Ceará-Brasil. **Irriga**, v. 25, n. 1, p. 131–142, 2020.
- OLIVEIRA, D. S. DE et al. Hotter, longer and more frequent heatwaves: an observational study for the Brazilian city of Campinas, SP. **Revista Brasileira de Meteorologia**, v. 36, n. 2, p. 305–316, 2021.

PANDOLFO, C.; BRAGA, H.J.; SILVA JÚNIOR, V.P.; MASSIGNAN, A.M.; PEREIRA, E.S.; THOMÉ, V.M.R; VALCI, F.V. **Atlas climatológico do Estado de Santa Catarina**. Florianópolis: Epagri, 2002.

PANOSSO, A. R. **Variabilidade espacial da emissão de CO₂ e sua relação com propriedades do solo em área de cana-de-açúcar no sudeste do Brasil**. 2011. Tese (Doutorado em Ciências Agrárias e Veterinárias) – Faculdade de Ciências Agrárias e Veterinárias, Universidade Estadual Paulista, Jaboticabal, 2011.

PERKINS-KIRKPATRICK, S.E.; GIBSON, P.B. Changes in regional heatwave characteristics as a function of increasing global temperature. **Scientific Reports**, v.7, n. 1, p. 1-12, 2017.

RATA, M.; DOUAOUI, A.; LARID, M.; DOUAIK, A. Comparison of geostatistical interpolation methods to map annual rainfall in the Chélieff watershed, Algeria. **Theoretical and Applied Climatology**, v. 141, n. 3, p. 1009–1024, 2020.

RIGATTI, S. J. Random Forest. **Journal of Insurance Medicine**, v. 47, n. 1, p. 31–39, 2016.

ROBINSON, T. P.; METTERNICHT, G. Testing the performance of spatial interpolation techniques for mapping soil properties. **Computers and Electronics in Agriculture**, v.50, n.2, p.97-108, 2006.

ROMERO-HERNÁNDEZ, C. M. et al. Bias-corrected high-resolution precipitation datasets assessment over a tropical mountainous region in Colombia: A case of study in Upper Cauca River Basin. **Journal of South American Earth Sciences**, v. 140, p. 104898, 2024.

RStudio Team. **RStudio: Integrated Development for R**. RStudio, v. 4.2.3, PBC, Boston, MA. Disponível em: <http://www.rstudio.com/>. Acesso em 08 mar. 2023.

RUEZZENE, C. B. et al. Preenchimento de falhas em dados de precipitação através de métodos tradicionais e por inteligência artificial. **Revista Brasileira de Climatologia**, v. 29, p. 177–204, 2021.

SALIBA, Y.; BĂRBULESCU, A. A comparative evaluation of spatial interpolation techniques for maximum temperature series in the Montreal region, Canada. **Romanian Reports in Physics**, v. 76, n. 1, p. 701–701, 21 mar. 2024.

SALLEH, H. A.; RAHMAN, E. K. A.; RATNAYAKE, U. Assessing the applicability of rainfall index spatial interpolation in predicting landslide susceptibility: A study in Brunei Darussalam. **IOP Conference Series: Earth and Environmental Science**, v. 1369, n. 1, p. 012006, 2024.

SANDWELL, D. T. Biharmonic spline interpolation of GEOS-3 and SEASAT altimeter data. **Geophysical Research Letters**, v. 14, n. 2, p. 139-142, 1987.

SANTOS, L. O. **Troca estratosfera-troposfera e sua influência no conteúdo de ozônio sobre a região central do Rio Grande do Sul**. 2016. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Santa Maria, Centro de Ciências Naturais e Exatas, Santa Maria, 2016.

SHEPARD, D. S. A two-dimensional interpolation function for irregularly-spaced data. **Proceedings of the 1968 ACM National Conference**, p.517-524, 1968.

SILVA JUNIOR, J. F. DA et al. Métodos geoestatísticos na modelagem espacial do diâmetro médio do cristal da goethita. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 17, p. 1127–1134, 2013.

SOUZA, I. A. de; MACIEL NETTO, A.; AZEVEDO, J. R. G. Impacto do aquecimento global no balanço hídrico diário e suas consequências para a agricultura. **Revista Brasileira de Geografia Física**, v. 03, p. 558-571, 2012.

VIANNA, L. F. N.; PERIN, E. B.; RICCE, W. S.; MASSIGNAN, A. M.; PANDOLFO, C. Bancos de dados meteorológicos: análise dos metadados das estações meteorológicas no estado de Santa Catarina, Brasil. **Revista Brasileira de Meteorologia**, v.32, n.1, p.53-64, 2017.

VILL, J. **Geografia de Santa Catarina Aspectos Físicos**. Disponível em http://www.cfnp.com.br/documentos/aspectos_fisicos_de_santa_catarina_3serie_100315.pdf. Acesso em 26 dez. 2021.

WANDERLEY, H. S.; AMORIM, R. F. C. DE; CARVALHO, F. O. DE. Interpolação espacial de dados médios mensais pluviométricos com redes neurais artificiais. **Revista Brasileira de Meteorologia**, v. 29, p. 389–396, 2014.

WATTS, N.; ADGER, W. N.; AGNOLUCCI, P. Health and climate change: policy responses to protect public health. **The Lancet**, v. 386, n. 10006, p. 1861–1914, 7 2015.

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

World Meteorological Organization (WMO). **Climate change indicators reached record levels in 2023**, 2024. Disponível em: <<https://wmo.int/news/media-centre/climate-change-indicators-reached-record-levels-2023-wmo>>. Acesso em: 2 fev. 2025.

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

ZÁKHIA, E. M. S. et al. Impactos das mudanças climáticas em uma bacia hidrográfica no Sul do estado de Minas Gerais. **Revista Brasileira de Meteorologia**, v. 36, p. 667-681, 2022.