

PRECISÃO DOS MÉTODOS DE INTERPOLAÇÃO PARA ESPACIALIZAÇÃO DA PRECIPITAÇÃO NA REGIÃO SUDESTE DO BRASIL

José Reinaldo da Silva Cabral de Moraes¹, Lucas Eduardo de Oliveira Aparecido¹, Cicero
Teixeira Silva Costa¹

RESUMO: A previsão e a estimativa da precipitação é um dos desafios da comunidade científica no mundo, devido à alta variabilidade espacial e sazonal deste elemento meteorológico. Para tanto, metodologias que permitem a interpolação precisa desses elementos são de fundamental importância. Este trabalho tem como objetivo comparar o desempenho dos métodos de interpolação IDW e Krigagem, na espacialização da chuva no sudeste do Brasil, em diferentes épocas do ano. Dados mensais de chuva (mm) de 1961 a 1990 foram obtidos de 1505 estações pluviais da região Sudeste do Brasil, fornecidas pelo Instituto Nacional de Meteorologia (INMET). A comparação entre os dados interpolados e os dados reais de precipitação das estações meteorológicas de superfície foi realizada através dos seguintes índices estatísticos, Correlação de Pearson (r); coeficiente de determinação (R^2); Concordância de Wilmott (d); Erro Absoluto Médio Percentual (MAPE). O resultado da interpolação pela Krigagem apresentou um melhor desempenho que o IDW, no entanto, os dois interpoladores foram precisos e com baixa tendência na estimativa de precipitação. Os maiores erros na estimativa da distribuição espacial da precipitação ocorreram no inverno com R^2 0,84 pelo método IDW e 0,97 pela Krigagem e os menores no verão com R^2 de 0,99 em ambos interpoladores.

PALAVRAS-CHAVE: Distribuição espacial, Validação, Modelagem climática.

ACCURACY OF INTERPOLATION METHODS FOR SPACIALIZATION OF RAINFALL IN THE SOUTHEAST REGION OF BRAZIL

¹ Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso do Sul, *campus* Naviraí. CEP: 79950 - 000, Fone: (067) 3409 - 2501

ABSTRACT: Prediction and estimation of precipitation is one of the challenges of the scientific community in the world, due to the high spatial and seasonal variability of this meteorological element. For that, methodologies that allow the precise interpolation of these elements are of fundamental importance. Thus, we seek to compare the performance of IDW and Krigagem interpolation methods in rainfall spatialization in southeastern Brazil at different times of the year. Monthly rainfall data (mm) from 1961 to 1990 were obtained from 1505 rainfall stations in the Southeast region of Brazil, provided by the National Institute of Meteorology (INMET). The comparison between the interpolated data and the actual precipitation data of the surface meteorological stations was performed through the following statistical indices: Pearson's Correlation (r); coefficient of determination (R^2); Wilmott's concordance (d) and, Absolute Average Percentage Error (MAPE). The result of interpolation by Kriging presented better performance than IDW, however, the two interpolators were accurate and with a low tendency in the precipitation estimation. The largest errors in estimating the spatial distribution of precipitation occurred in winter with R^2 0.84 by the IDW method and 0.97 by Kriging and the lowest in summer with R^2 of 0.99 in both interpolators.

KEYWORDS: Spatial distribution, Validation, Climate modelling.

INTRODUÇÃO

A interpolação é uma técnica utilizada para a estimativa de uma variável numérica qualquer, em uma determinada posição geográfica não amostrada, a partir de pontos amostrados na mesma área ou região (LANZA et al., 2001; TVEITO et al., 2008; DI PIAZZA et al., 2011; BORGES et al., 2016). De maneira geral, a interpolação espacial converte dados de observações pontuais em campos contínuos, produzindo padrões espaciais que podem ser comparados com outras entidades espaciais contínuas (XAVIER et al., 2010).

Os métodos de interpolação mais utilizados estão baseados na primeira lei da Geografia ou Lei de Tobler (1970), que estabelece para efeitos de aplicação, que pontos vizinhos no espaço têm valores mais correlacionados que aqueles distantes (MESQUITA, 2009). Esse conceito fundamenta a base das relações espaciais entre fenômenos geográficos, utilizando a correlação espacial como meio de diferença dos atributos estimados (Câmara e Medeiros, 1998).

Na literatura são encontradas diversas abordagens matemáticas, estatísticas e geoestatísticas, usadas para a interpolação de dados, principalmente de precipitação,

(BARGAOUI e CHEBBI, 2009), visto que fornece informações sobre o clima para qualquer lugar a qualquer momento é uma tarefa desafiadora para os climatologistas (TVEITO et al., 2008; BORGES et al., 2016).

A escolha do método depende do objetivo do estudo, a variável climatológica, escala de tempo, resolução espacial, e contexto territorial da região (WACKERNAGEL, 2003; RENARD e COMBY, 2006; TVEITO et al., 2008; BORGES et al., 2016). Até pouco tempo atrás, não se levava em consideração a preocupação com a qualidade da estimativa, o que somente vem ocorrendo mais recentemente (FERNANDES e MENEZES, 2005). De acordo com Borges et al. (2016) os métodos tradicionais são baseados em critérios de distância, tais como os polígonos Thiessen, que correspondem ao definido homogênea áreas em que a variável climática é assumida para ser constante (THIESSEN 1911). Os métodos mais sofisticados, tais como redes neurais artificiais, têm sido aplicados para estimar o variabilidade espacial não-linear de variáveis climáticas (DEMYANOV et al., 1998; DI PIAZZA et al., 2011).

Ainda há pouca evidência de que um método seja mais adequado que outro, devido a uma variedade de condições, logo é importante determinar o melhor método para cada circunstância (LENNON e TURNER, 1995). A qualidade do estimador pode ser avaliada por meio da avaliação dos dados da tabulação cruzada, isto é, comparação entre os dados reais e suas respectivas estimativas (XAVIER et al., 2010).

Inúmeros métodos de interpolação estão disponíveis na literatura com diversos níveis de complexidade (GOOVAERTS, 1999; CARVALHO et al., 2002), e objetivos, mas os resultados não são conclusivos (BORGES et al., 2016). Alguns autores destacam a krigagem (CARVALHO e ASSAD, 2005; VIOLA et al., 2010). Enquanto outros autores mostraram que IDW foi o melhor método (GONG et al., 2014; KEBLOUTI et al., 2012).

A krigagem supõe que a variação espacial de um fenômeno é estatisticamente homogênea em uma área (Tveito et al., 2008; Borges et al., 2016). A variação espacial no método da Krigagem é quantificada por um semivariograma (TABIOS e SALAS 1985; PHILLIPS et al., 1992; GOOVAERTS 2000; DOBESCH et al., 2007). A krigagem se destaca porque possibilita a análise da variância dos dados através da análise variográfica, a qual expressa à descontinuidade espacial dos dados (BARGAOUI e CHEBBI, 2009).

Outra técnica de interpolação usada para pontos espalhados espacialmente é o Inverse Distance Weighted (IDW). A interpolação por IDW determina os valores dos pontos usando uma combinação linear ponderada dos pontos amostrados. O peso de cada ponto é o inverso de uma função da distância (Shepard 1968). A base teórica para adoção do IDW talvez seja

sua semelhança com a Lei de Gravitação Universal e Lei de Coulomb, ambas com enfraquecimento diretamente proporcional ao inverso da distância (Mello et al., 2003). O principal fator que afeta a precisão do IDW é o valor do parâmetro de energia. Com o aumento da distância ocorre à diminuição dos pesos, especialmente quando o valor do parâmetro de energia aumenta (Borges et al., 2016). Estações próximas têm maior peso e, portanto, exerce maior influência sobre a estimativa (Nalder e Wein 1998; Johnston, 2004).

Segundo Vieira (2000) e Thompson (1992), a krigagem tem capacidade de produzir melhores estimativas em termos de interpolação, porque está embasada em duas premissas: não-tendenciosidade do estimador e variância mínima das estimativas. Dirks et al. (1998) trabalharam com alguns interpoladores espaciais para chuvas anuais, mensais, diárias e horárias para a Ilha de Norfolk na Nova Zelândia. Ao final, concluíram que os métodos krigagem e inverso do quadrado da distância sobressaíram em relação a polígonos de Thiessen, splines cúbicas e inverso da distância.

Assim, objetivou-se testar diferentes métodos de interpolação matemática para o mapeamento da precipitação pluviométrica na região Sudeste do Brasil.

MATERIAL E MÉTODOS

Os dados meteorológicos mensais de precipitação pluvial (mm) entre 1961 e 1990 foram obtidos a partir de 1505 estações pluviométricas para atingir todo o Sudeste do Brasil (Latitude: -14.215 / -25.271, Longitude: -53.121 / -39.674) (Figura 1). Essa região corresponde a 53,2% do PIB brasileiro. O banco de dados foi obtido do Instituto Nacional de Meteorologia (INMET), Departamento Nacional de Obras do Brasil contra Secas (DNOCS) e da Organização para Agricultura e Alimentação das Nações Unidas (FAO / ONU) (FAO, 2001). A distribuição espacial das estações pluviométricas pode ser observada na Figura 1.

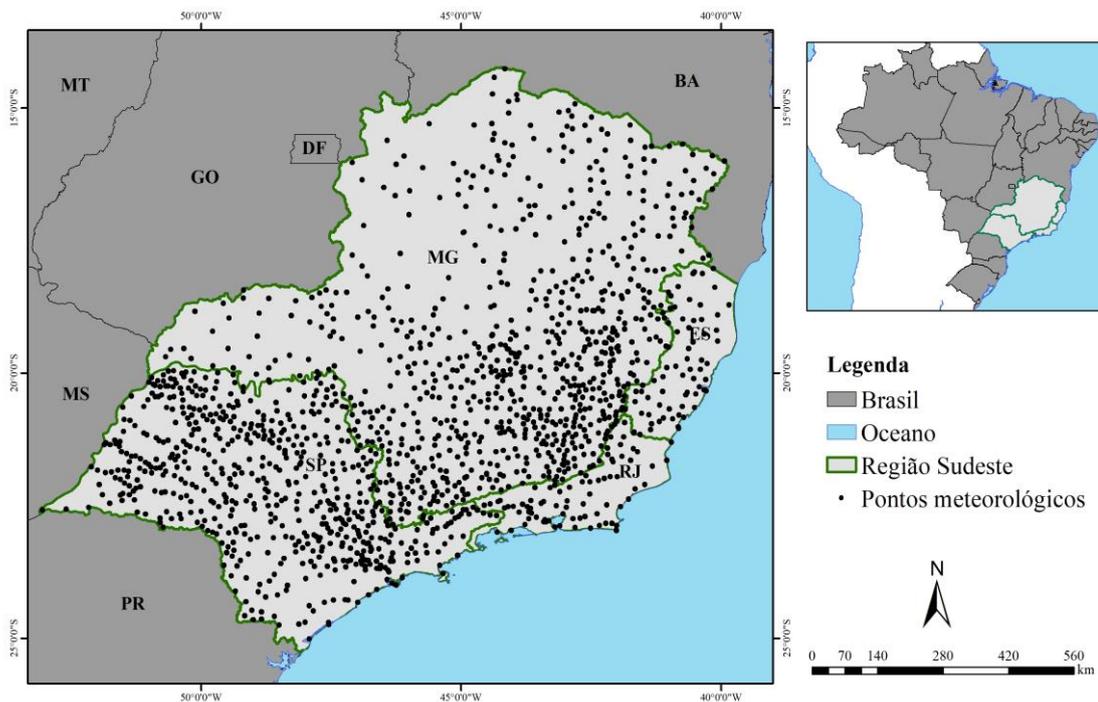


Figura 1. Mapa de localização da região Sudeste e dos pontos meteorológicos.

Foi utilizado o software ArcGIS 10.4, para execução dos métodos de interpolação. O interpolador univariado de médias ponderadas, Inverso do Quadrado da distância (IDW), (Isaaks & Srivastava, 1989) foi utilizado por meio da equação:

$$z^*(x_i) = \frac{\left(\sum_{i=1}^n \frac{z(x_i)}{h_i^2} \right)}{\left(\sum_{i=1}^n \frac{1}{h_i^2} \right)} \quad (1)$$

Onde: h_i é a distância entre os pares de observação x_i .

Para avaliar a variabilidade espacial dos dados estudados, foi utilizado o método geoestatístico da Krigagem (Vieira, 2000; Carvalho et al., 2002; Vieira & Dechen, 2010). A dependência espacial entre as observações foi expressa por meio do semivariograma.

Os dados de precipitação das estações pluviométricas foram vetorizados para um arquivo shapefile que, posteriormente, passou por uma série de testes de interpolação, para encontrar o método que interpole com maior acurácia e ainda detenha a melhor representação dos dados reais em questão de distribuição espacial dos valores. Em seguida os dados de precipitação foram padronizados por estações do ano, obedecendo aos seguintes critérios:

Tabela 1. Conversão para o período sazonal

Estação	Período
Psummer	1/3DEC + JAN + FEB + 2/3MAR
PAutumn	1/3MAR + APR + MAY + 1/3JUN
PWinter	2/3JUN + JUL + AUG + 1/3SEP
PSpring	1/3SEP + OCT + NOV + 2/3DEC

A comparação entre os dados interpolados e os dados reais das estações meteorológicas de superfície (dados reais) foram realizados por meio das seguintes análises: 1) correlação de Pearson (r); 2) Coeficiente de determinação (R^2); 3) Concordância de Wilmott (d); Erro Percentual Absoluto Médio (MAPE) (Equações 2 a 5), respectivamente. O desvio foi calculado subtraindo o valor previsto dos dados reais de superfície ($X_{REAL} - X_{EST}$).

$$r = \frac{\sum_{i=1}^n (Y_{obs_i} - \bar{Y}_{obs}) \times (Y_{est_i} - \bar{Y}_{est})}{\sqrt{\sum_{i=1}^n (Y_{obs_i} - \bar{Y}_{obs})^2} \times \sqrt{\sum_{i=1}^n (Y_{est_i} - \bar{Y}_{est})^2}} \quad (2)$$

$$R^2 \text{ adjusted} = \left[1 - \frac{(1-R^2) \times (n-1)}{N-k-1} \right] \quad (3)$$

$$d = 1 - \frac{\sum_{i=1}^N (Y_{obs_i} - Y_{est_i})^2}{\sum_{i=1}^N (|Y_{est_i} - \bar{Y}| + |Y_{obs_i} - \bar{Y}|)} \quad (4)$$

$$MAPE(\%) = \frac{\sum_{i=1}^n \left(\left| \frac{Y_{est_i} - Y_{obs_i}}{Y_{obs_i}} \right| \times 100 \right)}{N} \quad (5)$$

Onde: Y_{est_i} : variável interpolada; Y_{obs_i} : variável observada; N : número de dados e k : número de variáveis independentes na regressão.

RESULTADOS E DISCUSSÃO

Os mapas de precipitação apresentaram pequenas variações entre os interpoladores IDW e Krigagem, observando-se claramente que ambos os métodos seguiram de forma homogênea a mesma tendência espacial da variabilidade existente (Figura 2). No verão, estação com maior precipitação pluvial, é observado que a região sudoeste do estado de São Paulo e parte

da região norte em divisa com o estado de Minas gerais, ocorrem as maiores cotas pluviiais, com a mesma representação espacial entre os interpoladores Krigagem (Figura A1) e IDW (Figura A2), com precipitações na faixa de 750 a 900 mm. Variações semelhantes são observadas nas demais estações, outono, inverno e primavera (Figura B, C, D), respectivamente.

Esta homogeneidade existente na representação espacial da chuva, pode ser explicada pela grande densidade de pontos de pluviosidade para interpolação neste trabalho. Mostrando que dependendo do conjunto de dados existentes de uma certa região, métodos mais robustos e estatísticos como a Krigagem, se assemelham na estimação de valores desconhecidos, com os métodos mais simples, considerados empíricos, como o IDW.

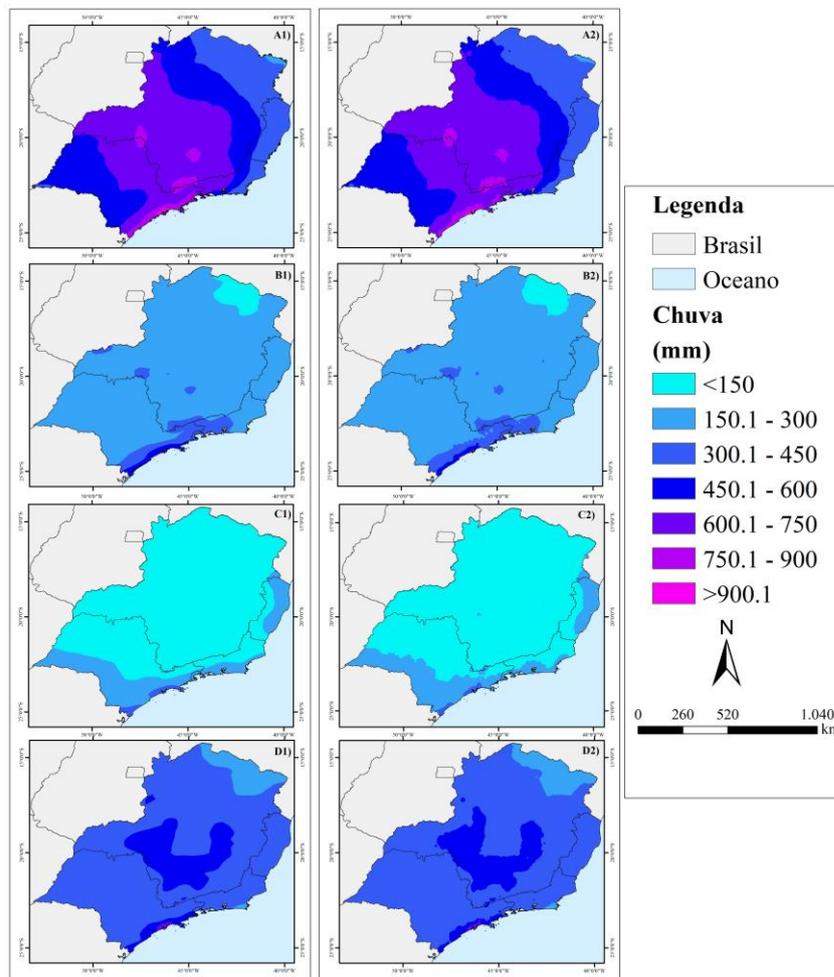


Figura 2. Mapas interpolados pelo método Krigagem e IDW de precipitação pluvial nas diferentes estações do ano na região Sudeste do Brasil. A1) Verão Krigagem; A2) Verão IDW; B1) Outono Krigagem; B2) Outono IDW; C1) Inverno Krigagem; C2) Inverno IDW; D1) Primavera Krigagem e D2) Primavera IDW.

Os métodos de interpolação IDW e Kriging demonstraram alta precisão e acurácia para estimar a precipitação para todas as estações do ano no Sudeste do Brasil (Figura 2), uma vez

que os R^2 ficaram acima de 0,90 e o MAPE com erro médio abaixo de 3% em todas as estações do ano (Tabela 2).

O Kriging destaca uma acurácia ligeiramente alta em relação ao IDW. O índice estatístico MAPE médio na Krigagem foi de 2,42% enquanto no IDW foi de 2,90%. No verão observa-se melhor precisão e acurácia com R^2 igual a 0,99 nos dois interpoladores e MAPE de 1,62 e 1,17 % no IDW e Krigagem, respectivamente. Considerando a precipitação média no verão igual a 595 mm, o erro médio da precipitação entre os interpoladores é na ordem de $\pm 8,30$ mm nesta estação do ano. De forma inversa, a menor precisão foi observada no inverno, com R^2 na krigagem de 0,97 e IDW de 0,86 e MAPE com erro de 5,7 no IDW e 5,27% na Krigagem (Tabela 2).

Carvalho e Assad (2005) e Viola et al. (2010) também consideram o método Kriging mais preciso em comparação com o IDW.

Tabela 2. Índices estatísticos usados para avaliar a precisão dos métodos de interpolação de IDW e Kriging.

Índice Estatístico	Verão		Outono		Inverno		Primavera		Média*	
	IDW	Kriging	IDW	Kriging	IDW	Kriging	IDW	Kriging	IDW	Kriging
r	0,99	0,99	0,96	0,98	0,86	0,97	0,94	0,95	0,94	0,97
R^2	0,98	0,98	0,93	0,96	0,84	0,93	0,89	0,9	0,91	0,94
d	0,99	1,0	0,98	0,99	0,9	0,98	0,97	0,97	0,96	0,99
MAPE	1,62	1,17	1,95	1,38	5,7	5,27	2,33	1,9	2,90	2,42

CONCLUSÕES

Os interpoladores IDW e Krigagem apresentaram desempenho satisfatório na estimativa da chuva, variando sua precisão e acurácia conforme a estação do ano;

Os maiores erros na estimativa da distribuição espacial da precipitação ocorreram no inverno e os menores no verão para ambos métodos de interpolação. A Krigagem apresenta melhor estimativa da precipitação.

REFERÊNCIAS BIBLIOGRÁFICAS

- APAYDIN, H.; SONMEZ, F. K.; YILDIRIM, Y. E (2004) Spatial interpolation techniques for climate data in the GAP region in Turkey. *Clim Res* 28: 31–40. doi:10.3354/cr028031.
- BARGAOUI, Z. K.; CHEBBI, A. Comparison of two kriging interpolation methods applied to spatiotemporal rainfall. *Journal of Hydrology*, 365(1-2): 56-73, 2009.
- BAÚ, A. L.; GOMES, B. M.; QUEIROZ, M. M. F. DE.; OPAZO, M. A. U.; SAMPAIO, S. C. Spatial behavior of probable monthly rainfall of the western mesoregion of the State of Paraná. *Irriga, Botucatu*, v. 11, n .2, p. 150 - 168, 2006.
- BORGES, P. A.; FRANKE, J.; ANUNCIAÇÃO, Y. M. T., WEISS, H.; BERNHOFER, C. Comparison of spatial interpolation methods for the estimation of precipitation distribution in Distrito Federal, Brazil. *Theor. Appl. Climatol* 2016, 123: 335-348.
- CAMARGO, A. P., SENTELHAS, P. C. Evaluation of the performance of different methods of estimation of potential evapotranspiration in the state of São Paulo, Brasil. *Revista Brasileira de Agrometeorologia*, Santa Maria, v. 5, n. 1, p. 89-97, 1997.
- Chahine, M. T. The hydrological cycle and its influence on climate. *Nature*, v. 359, n. 6394, p. 373, 1992.
- Carvalho, J. R. P., Assad, E. D. Spatial Analysis of precipitation data in São Paulo state: Comparison of interpolation methods. *Engenharia Agrícola*, Jaboticabal, v. 25, n. 2, 377 - 384, 2005.
- CARVALHO, J. R. P. DE; ASSAD, E. D.; PINTO, H. S. Geostatistical interpolation in the analysis of spatial distribution of annual rainfall and of its relationship to altitude. *Pesquisa Agropecuária Brasileira*, v.47, p.1235-1242, 2012.
- Di Piazza A.; Conti F. L.; Noto, L.; Viola, F.; La, L. G. Comparative analysis of different techniques for spatial interpolation of rainfall data to create a serially complete monthly time series of precipitation for Sicily, Italy. *Int J Appl Earth Obs Geoinform* 13:396–408, 2011. doi: 10.1016/j.jag.2011.01.005.
- Goyal, R. K. Sensitivity of evapotranspiration to global warming: a case study of arid zone of Rajasthan (India). *Agricultural Water Management*, v. 69, n. 1, p. 1-11, 2004.

Gong G, Mattevada S, O'Bryant SE (2014) Comparison of the accuracy of kriging and IDW interpolations in estimating groundwater arsenic concentrations in Texas. *Environ Res* 130:59–69. doi:10.1016/j.envres.2013.12.005

Javari, M. (2017). Spatial Monitoring and Variability of Daily Rainfall in Iran. *International Journal of Applied Environmental Sciences*, 12 (5), 801-824.

Javari, M. Geostatistical and Spatial Statistical Modelling of Precipitation Variations in Iran. *Journal of Civil and Environmental Engineering*, v. 6, n. 3, 2016.

Keblouti M, Ouerdachi L, Boutaghane H (2012) Spatial interpolation of annual precipitation in Annaba-Algeria—comparison and evaluation of methods. *Energy Procedia* 18:468–475. doi:10.1016/j.egypro.2012.05.058

Lanza L, Ramírez J, Todini E, others (2001) Stochastic rainfall interpolation and downscaling. *Hydrol Earth Syst Sci* 5(2):139–143. doi: 10.5194/hess-5-139-2001

Mello, C. R.; Lima, J. M.; Silva, A. M.; Mello, J. M.; Oliveira, M. S. 2003. Kriging and inverse-square-distance for the interpolation of rainfall equation parameters. *R. Bras. Ci. Solo* 27: 925-933.

Mello, Y. R.; Oliveira, T. M. N. Statistical and Geostatistical Analysis of the Average Rainfall in the Municipality of Joinville (SC). *Revista Brasileira de Meteorologia*, v. 31, n. 2, p. 229-239, 2016.

Nalder IA, Wein RW (1998) Spatial interpolation of climatic normals: test of a new method in the Canadian boreal forest. *Agric For Meteorol* 92:211–225. doi:10.1016/S0168-1923(98)00102-6.

Renard F, Comby J (2006) Evaluation de techniques d'interpolation spatiale de la pluie en milieu urbain pour une meilleure gestion d'événements extrêmes: le cas du Grand Lyon. *La Houille Blanche* 73–78. doi:10.1051/lhb:2006104

Shepard D (1968) A two-dimensional interpolation function for irregularly-spaced data. *ACM Press*, pp 517–524

Tveito OE, Wegehenkel M, van der Wel F, Dobesch H (2008) COST Action 719: the use of geographic information systems in climatology and meteorology. EUR-OP, Luxembourg

Viola, M.R.; Mello, C.R. De; Pinto, D.B.F.; Mello, J.M. De; Ávila, L.F. Spatial interpolation methods for mapping of rainfall. *Revista Brasileira de Engenharia Agrícola e Ambiental*, v. 14, p.970-978, 2010.

Wackernagel H (2003) *Multivariate geostatistics: an introduction with applications*. Springer, New York.

Yamamoto, J. K.; Landim, P. B. *Geoestatística: conceitos e aplicações*. São Paulo: Oficina de Textos, 2013. 215p.