

AVALIAÇÃO DE MÉTODOS DE INTERPOLAÇÃO ESPACIAL PARA VARIÁVEIS SOCIOECONÔMICAS

<https://doi.org/10.4215/rm2026.e25007>

Melo, S.N. ^{a*} - Nascimento, E. ^b

(a) Doutor em Geografia

ORCID: <https://orcid.org/0000-0003-3363-5208>. **LATTES:** <https://lattes.cnpq.br/9875457749739729>.

(b) Doutor em Geografia

ORCID: <https://orcid.org/0000-0002-3697-5200>. **LATTES:** <https://lattes.cnpq.br/4129536624525275>.

Article history:

Received 02 December, 2025

Accepted 28 December, 2025

Published 10 April, 2026

(*) CORRESPONDING AUTHOR

Address: UEMA. Cidade Universitária Paulo VI, Tirirical, CEP: 65055970, São Luís (MA), Brasil. Tel: (+55 98) 3245-6141

E-mail: silasmelo@professor.uema.br

Resumo

Em Cartografia, os métodos de interpolação são utilizados para identificar o arranjo espacial de uma variável, por meio da estimação de valores desconhecidos com base em pontos amostrais. Apesar de serem cada vez mais utilizados nas ciências sociais e humanas, em geral, nesses campos do conhecimento, não há uma preocupação quanto ao uso do interpolador ideal. Tendo em vista essa questão de pesquisa, o presente trabalho apresenta uma avaliação dos três métodos mais utilizados para a interpolação espacial de variáveis socioeconômicas: Inverso da Distância Ponderada (IDW), Thin Plate Spline (TPS) e Krigagem. São comparadas as performances dos três métodos para a interpolação de uma variável socioeconômica real (preços médios de terrenos por metro quadro em uma cidade brasileira) aos respectivos resultados para uma variável física (hipsometria por pontos cotados). A avaliação dos interpoladores foi realizada com base em análise visual da espacialização, e com estatísticas de validação cruzada utilizando duas métricas de erro (Erro Médio Absoluto e Erro Quadrático Médio). De modo geral, os resultados indicam que a variável socioeconômica foi interpolada de maneira mais eficiente pelo método de Krigagem, enquanto que os interpoladores IDW e Spline apresentaram melhor desempenho para a variável física.

Palavras-chave: Variáveis socioeconômicas, Interpolação espacial, Inverso da Distância Ponderada, Thin Plate Spline, Krigagem.

Abstract / Resumen

EVALUATION OF SPATIAL INTERPOLATION METHODS FOR SOCIOECONOMIC VARIABLES

In Cartography, interpolation methods are used to identify the spatial arrangement of a variable by estimating unknown values based on sample points. Although they are increasingly used in social and human sciences, in general, in these fields of knowledge, there is no concern regarding the use of the ideal interpolator. Considering this research question, this paper presents an evaluation of the three most used methods for the spatial interpolation of socioeconomic variables: Inverse Distance Weighting (IDW), Thin Plate Spline (TPS) and Kriging. The performances of the three methods for interpolating a real socioeconomic variable (average land prices per square meter in a Brazilian city) are compared to the respective results for a physical variable (hypometry by quoted points). The evaluation of the interpolators was performed based on visual analysis of the spatialization, and with cross-validation statistics using two error metrics (Mean Absolute Error and Root Mean Squared Error). In general, the results indicate that the socioeconomic variable was interpolated more efficiently by the Kriging method, while the IDW and Spline interpolators performed better for the physical variable.

Keywords: Socioeconomic Variables, Spatial Interpolation, Inverse Distance Weighting, Thin Plate Spline, Kriging.

EVALUACIÓN DE MÉTODOS DE INTERPOLACIÓN ESPACIAL PARA VARIABLES SOCIOECONÓMICAS

En Cartografía, los métodos de interpolación se utilizan para identificar la distribución espacial de una variable, mediante la estimación de valores desconocidos a partir de puntos muestrales. Aunque su uso es cada vez más frecuente en las ciencias sociales y humanas, en general, en estos campos no existe una preocupación por emplear el interpolador ideal. Ante esta problemática, el presente trabajo evalúa los tres métodos más utilizados para la interpolación espacial de variables socioeconómicas: Inverso de la Distancia Ponderada (IDW), Thin Plate Spline (TPS) y Kriging. Se comparó el desempeño de los tres métodos en la interpolación de una variable socioeconómica real (precios medios de terrenos por metro cuadrado en una ciudad brasileña) con los resultados obtenidos para una variable física (hipsometría por puntos cotados). La evaluación se basó en análisis visual de la espacialización y validación cruzada con dos métricas de error (Error Medio Absoluto y Error Cuadrático Medio). Los resultados indican que la variable socioeconómica se interpoló con mayor eficiencia mediante Kriging, mientras que IDW y Spline mostraron mejor desempeño para la variable física.

Palabras-clave: Variables Socioeconómicas, Interpolación Espacial, Inverso de la Distancia Ponderada, Thin Plate Spline, Kriging.

INTRODUÇÃO

Em uma definição ampla, interpolação é o processo de construção de um novo conjunto de dados a partir de valores pontuais discretos previamente conhecidos. Na Cartografia se torna uma ferramenta poderosa, pois a partir de amostragem e coleta de dados de alguns pontos referentes a uma variável geográfica, é possível empregar algum interpolador e, a partir dele, identificar o arranjo espacial da referida variável (Stein, 2012). Em outras palavras, os métodos de interpolação espacial são usados para estimar valores de uma variável em locais não amostrados com base em pontos conhecidos. A literatura mostra que eles são amplamente utilizados em pesquisas nas ciências da natureza, em áreas como geologia (Liu et al., 2021), climatologia (Farias et al., 2017), pedologia (Silva et al., 2010), batimetria (Ferreira et al., 2013), topografia (Barbosa et al., 2008), agronomia (Corá et al., 2004), entre outras.

Embora alguns estudos utilizem métodos de interpolação espacial para pesquisas de fenômenos sociais e humanos, como enfermidades, riscos sociais, criminalidade e desigualdade de renda (Folharini et al., 2023; Nascimento et al., 2020; Ramos & Melo, 2022; Silva et al., 2020), em geral não há uma preocupação quanto à qualidade do emprego do interpolador ideal. Ou seja, existe uma lacuna de pesquisas que apliquem os métodos de interpolação espacial para variáveis sociais, demográficas e econômicas. Será que interpoladores aplicados a variáveis físicas apresentam o mesmo desempenho quando utilizados para variáveis socioeconômicas em uma mesma área? Se não, quais seriam as principais diferenças tendenciais?

Com o intuito de fornecer respostas a estas questões de pesquisa, o presente estudo realiza uma análise dos três métodos mais utilizados para a interpolação espacial de dados socioeconômicos (Inverso da Distância Ponderada, Spline e Krigagem), comparando suas performances na predição de valores de uma variável socioeconômica real (preços de terrenos) com os respectivos resultados para uma variável física (pontos cotados) em uma mesma área. Para além disso, pautando-se no princípio da reprodutibilidade da ciência, a pesquisa apresenta ainda um script elaborado em linguagem R, que possibilita a replicação do presente experimento para qualquer conjunto de dados espaciais.

O texto, doravante, está organizado em três partes. Na primeira delas, a seguir, é realizada uma caracterização dos métodos de interpolação utilizados na pesquisa com base em literatura especializada. O texto se completa, na sequência, com o encaminhamento metodológico e os resultados da pesquisa, seguidos das considerações finais.

INTERPOLADORES ESPACIAIS

Os métodos de interpolação espacial são bastante numerosos e variados. Mas de modo geral, eles podem ser diferenciados em dois grupos, em função do mecanismo matemático da interpolação: os chamados determinísticos, que utilizam funções matemáticas predefinidas para a estimação de valores, e os estocásticos, que consideram a dependência espacial existente entre os dados (Stein, 2012). Esses métodos diferem entre si na forma como tratam a variabilidade dos dados e na consideração da incerteza associada às estimativas espaciais. No presente estudo, foram selecionados três interpoladores amplamente utilizados na literatura por sua aplicabilidade em diferentes contextos espaciais. Dois deles são determinísticos, o Inverso da Distância Ponderada (Inverse Distance Weighting - IDW) e o Thin Plate Spline (TPS); e outro estocástico, a Krigagem.

O interpolador IDW estima valores a partir da ponderação das distâncias entre o ponto a ser conhecido e os pontos vizinhos conhecidos dentro de uma determinada área de abrangência. Esse método baseia-se na premissa de que as coisas que estão mais próximas tendem a ser mais parecidas entre si do que as que estão mais distantes (Canãda Torrecilla, 2007), razão pela qual pontos mais próximos de um local desconhecido exercem maior influência sobre a estimativa do que pontos mais afastados (Panigrahi, 2023). A estimativa de um valor $Z(x_0)$ em um ponto desconhecido x_0 é dada por:

$$Z(x_0) = \frac{\sum_{i=1}^N w_i Z(x_i)}{\sum_{i=1}^N w_i} \quad (1)$$

onde:

$Z(x_0)$ é o valor estimado no ponto x_0 ;

$Z(x_i)$ são os valores conhecidos nos pontos vizinhos x_i ;

N é o número de pontos vizinhos considerados na interpolação;

w_i são os pesos atribuídos a cada ponto x_i , calculados com base na distância d_i até x_0 .

Já o método de interpolação Spline ajusta uma função polinomial suave, de base radial, que intercepta cada um dos pontos amostrais, garantindo uma transição suave entre eles. O intuito é minimizar a curvatura da superfície interpolada. A função radial mais comum para aplicações em mapeamento é a TPS (Akima, 1970), cuja equação é definida por:

$$S(x, y) = \sum_{i=1}^N w_i \varphi(d_i) \quad (2)$$

onde:

$S(x, y)$ é a superfície interpolada;

w_i são pesos ajustados para os pontos conhecidos;

d_i é a distância entre o ponto interpolado e o ponto i .

$\varphi(d) = d^2 \ln(d)$ é a função de base radial que controla a suavidade da superfície.

A interpolação Spline é frequentemente utilizada para calcular superfícies suavizadas a partir de um número elevado de dados amostrais. Conforme Cañada Torrecilla (2007), esse método apresenta bons resultados quando a superfície varia moderadamente, mas tende a ser menos apropriado quando há grande variação de valores em distâncias curtas em sentido horizontal, ou quando se suspeita que a amostra é propensa a erros ou certa incerteza.

Por fim, a Krigagem assume que os dados seguem o princípio da variabilidade espacial e que existe uma autocorrelação entre pontos próximos. O método utiliza o semivariograma, uma função que descreve como a variabilidade dos dados muda com a distância. Essa interpolação estocástica possui muitas variações que podem ser encontradas na literatura (Yamamoto & Landim, 2013). No nosso estudo empregamos a Krigagem Ordinária:

$$Z(x_0) = \sum_{i=1}^N \lambda_i Z(x_i) \quad (3)$$

onde:

$Z(x_0)$ é o valor estimado no ponto desconhecido x_0 ;

$Z(x_i)$ são os valores conhecidos nos pontos vizinhos x_i ;

λ_i são os pesos atribuídos a cada ponto x_i , calculados com base na dependência espacial determinada pelo semivariograma;

N é o número de pontos considerados na interpolação;

Os pesos λ_i são determinados resolvendo o sistema de equações da Krigagem, que minimiza o erro quadrático médio da estimativa:

$$\sum_{j=1}^N \lambda_j \gamma(x_i, x_j) + \mu = \gamma(x_i, x_0) \quad (4)$$

$$\sum_{j=1}^N \lambda_j = 1 \quad (5)$$

onde:

$\gamma(x_i, x_j)$ é o semivariograma, que mede a variabilidade espacial entre os pontos x_i e x_j ;

$\gamma(x_i, x_0)$ é o semivariograma entre os pontos conhecidos x_i e o ponto a ser interpolado x_0 ;

μ é um parâmetro de Lagrange, necessário para garantir que a soma dos pesos seja 1.

O semivariograma é essencial na Krigagem e define a relação entre a variabilidade dos dados e a distância. Também pode ser ajustado por um modelo teórico, como esférico, exponencial e Gaussiano (Yamamoto & Landim, 2013).

ASPECTOS METODOLÓGICOS

VARIÁVEIS UTILIZADAS

Para análise empírica, dois conjuntos de dados foram coletados para representar um elemento físico-territorial e um aspecto socioeconômico de uma cidade – no caso, a área urbana do município de Chapecó, situado no oeste de Santa Catarina (sul do Brasil), com população estimada, em 2025, de aproximadamente 282 mil habitantes.

Como variável física, utilizou-se dados pontuais de altitudes do terreno (datum vertical de Imbituba), registradas em campo com uso de receptor GNSS, derivado da base cartográfica digital municipal. Trata-se, portanto, de uma variável espacial contínua, cuja natureza frequentemente requer sua representação na forma de dados amostrais (pontuais) de campo (Longley et al, 2015).

Já a variável socioeconômica adotada foi o preço médio do metro quadrado de terrenos urbanos desocupados, calculada a partir da compilação de dados (metragem quadrada e preço) constantes em anúncios de venda, disponíveis em websites de empresas imobiliárias e em classificados on line, no ano de 2024. Esta, por sua vez, corresponde a uma variável pontual discreta (Longley et al, 2015), visto que cada terreno possui um preço único, embora este seja influenciado por um conjunto de fatores externos (infraestrutura e serviços disponíveis, valores médios dos terrenos nas proximidades, topografia, entre outros).

Optou-se por utilizar dados reais de uma área urbana brasileira em vez de realizar uma simulação, pois assim temos situações mais condizentes com as pesquisas que empregam os métodos de interpolação.

A seguir, a Tabela 1 reúne as estatísticas descritivas das variáveis utilizadas, enquanto que a Figura 1 apresenta a respectiva espacialização.

Variável	Número de amostras	Valor mínimo	Valor máximo	Média	Desvio padrão
Preço do terreno por m ²	240	53,90	7.901,26	1.010,12	1.045,399
Ponto cotado	76	530	826	704,1	63,851

Tabela 1 – Estatísticas descritiva das variáveis. Fonte: Elaborado pelos autores.




Figura 1- Distribuição espacial dos pontos amostrais utilizados nos testes de interpolação

Foram geradas superfícies de interpolação testando-se os três interpoladores já mencionados – IDW, Spline e Krigagem Ordinária – utilizando o software R Studio®, e com emprego adicional do software ArcGIS ArcMap® (módulo Geostatistical Analyst) para edição cartográfica final. Ressalta-se a disponibilização do script em linguagem R resultante dos experimentos, com o qual é possível reproduzi-los com outras variáveis e de outros contextos espaciais.

AVALIAÇÃO DAS INTERPOLAÇÕES

A análise da eficácia dos métodos de interpolação espacial depende de vários fatores, como a distribuição dos dados e variabilidade espacial (Bohling, 2005). Para avaliar os interpoladores foi essencial comparar diferentes técnicas, utilizando análise visual e estatísticas de validação cruzada. No aspecto visual, avaliou-se a qualidade do mapa da superfície interpolada (se os padrões eram coerentes com a distribuição dos dados) e o gráfico de resíduos (se os erros estavam distribuídos de forma aleatória). Contudo, modelos de superfície espacial não podem ser avaliados apenas visualmente, sendo necessárias as métricas estatísticas para retirar qualquer possível viés da percepção.

A técnica de validação cruzada tem sido usada de maneira mais frequente em modelos de aprendizagem de máquinas (Ramos et al., 2023). Consiste na avaliação de modelos ao separar os dados em partes e treinando algoritmos em cada uma delas. Assim, dividiu-se 80% dos dados de preço da terra e pontos cotados como treinamento; os 20% dos dados restantes foram utilizados como validação da interpolação. A ideia foi comparar os valores de treinamento interpolados com os valores reais usando métricas de erro. Para tanto, foram empregadas duas métricas já consolidadas pela literatura (Oliveira et al., 2015), quais sejam: Erro Médio Absoluto (MAE - Mean Absolute Error) e Erro Quadrático Médio (RMSE - Root Mean Squared Error).

O Erro Médio Absoluto (MAE) mede a diferença média entre os valores observados $Z(x_i)$ e os valores estimados $\hat{Z}(x_i)$:

$$MAE = \frac{1}{N} \sum_{i=1}^N |Z(x_i) - \hat{Z}(x_i)| \quad (6)$$

Já o Erro Quadrático Médio (RMSE) penaliza erros maiores e mede a precisão da interpolação:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (Z(x_i) - \hat{Z}(x_i))^2} \quad (7)$$

Tanto o MAE quanto o RMSE que apresentem valores menores indicam um melhor resultado na validação.

RESULTADOS E DISCUSSÃO

As Figuras 2 e 3 apresentam as superfícies interpoladas das variáveis “preço do terreno por m²”, gerando uma superfície de valores do solo urbano, e “pontos cotados”, resultando em um mapa hipsométrico.

Visualmente, o exemplo de variável socioeconômica é mais concentrado no espaço do que a variável física. Uma síntese das representações revela que o método IDW apresentou uma superfície mais segmentada, com transições abruptas entre as áreas interpoladas, refletindo a forte influência dos pontos amostrais mais próximos. Em alguns pontos isso gerou o que se conhece coloquialmente como “olho de peixe”. Já o interpolador Spline gerou uma superfície mais suavizada, com transições mais gradativas, mas também apresentou valores extrapolados em áreas com poucas amostras. Por sua vez, a Krigagem manteve um padrão espacial com gradações suaves ante a variabilidade espacial, mas, por outro lado, suavizou excessivamente alguns trechos.

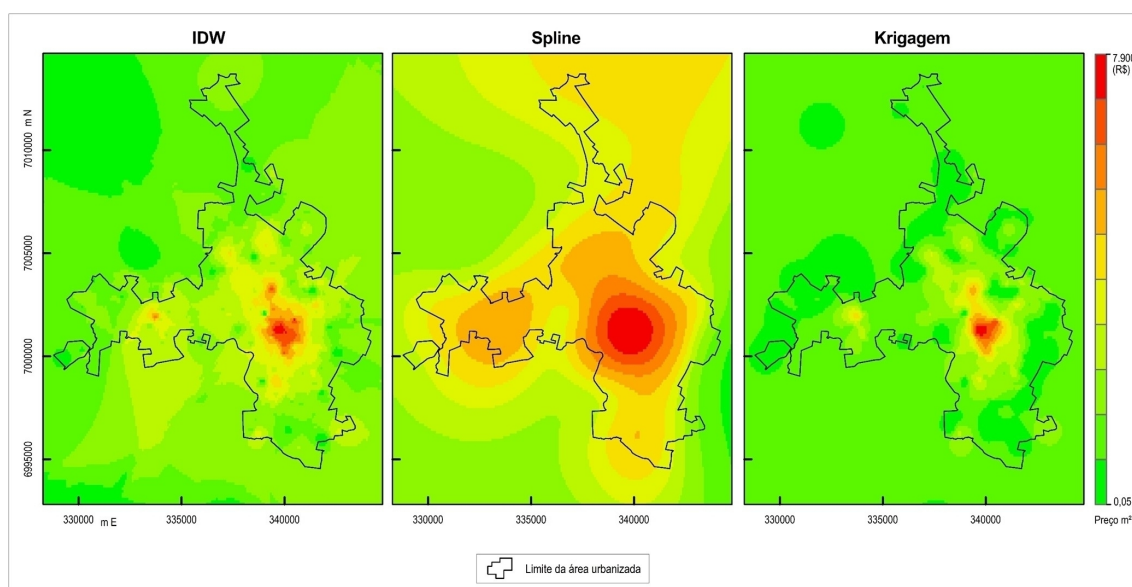


Figura 2 – Diferentes interpolações espaciais para a variável preço do metro quadrado de terreno.

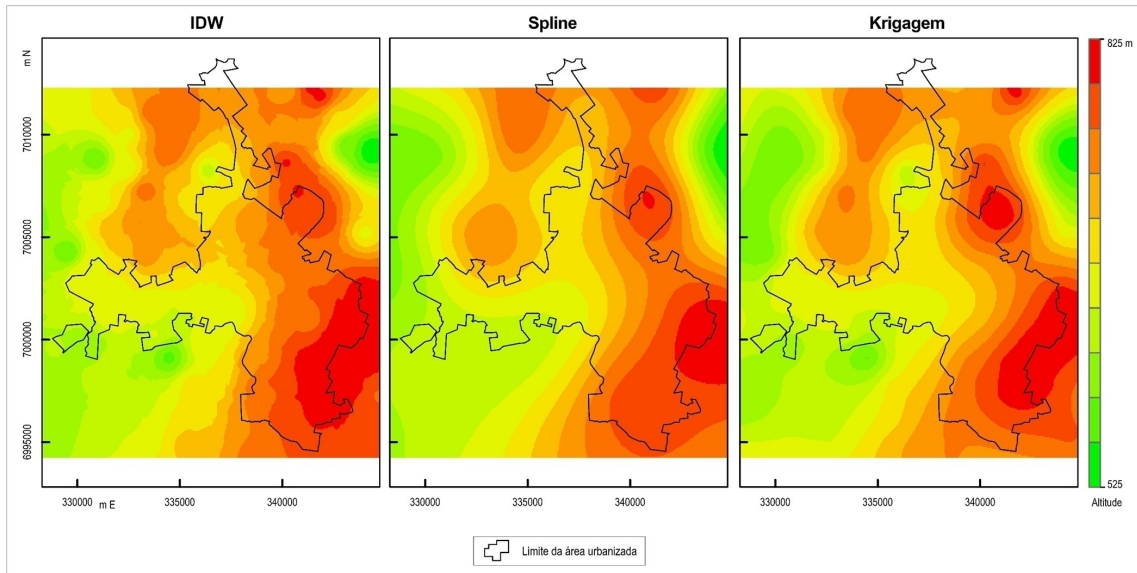


Figura 3 – Diferentes interpolações espaciais para a variável ponto cotado. Fonte: os autores (2025).

A Tabela 2 apresenta os resultados das métricas de erro. Segundo o Erro Quadrático Médio (RMSE) e o Erro Médio Absoluto (MAE), o melhor interpolador para preço do terreno por m² é a Krigagem, seguido do IDW e Spline. Já para a hipsometria, o RMSE e MAE apontam como melhor modelo o IDW, seguido das interpolações da Krigagem e Spline. Os resultados explicitam que a escolha do interpolador adequado é fundamental para a redução de resíduos na representação da superfície gerada. Por exemplo, segundo o RMSE da variável socioeconômica, a Krigagem reduziu o erro em 18,53% em comparação com o IDW.

Variável interpolada	Medida de Erro	<i>Spline</i>	IDW	Krigagem
Preço do terreno por m ²	RMSE	965,0718	943,0169	768,3174
	MAE	478,8806	486,9618	404,7592
Pontos cotados	RMSE	60,9189	41,7260	48,2884
	MAE	38,7243	34,1379	36,2115

Tabela 2 – Medidas de Erro dos diferentes tipos de interpolação espacial para as variáveis analisadas. Fonte: os autores (2025).

Corroborando com os resultados, a Figura 4 permite ver o comparativo de resíduos. A Krigagem apresenta menor dispersão ao longo da reta ideal (onde os valores observados seriam iguais aos valores estimados) em comparação com o IDW e o Spline, indicando uma melhor capacidade de capturar a estrutura espacial da variável de preços de terrenos.

De uma maneira geral, o estudo indica que os métodos determinísticos (IDW e Spline) são mais simples e rápidos de serem processados, sem necessidades de uma amostra robusta e forte grau de dependência espacial. Já o método estocástico (Krigagem) é mais preciso para variáveis com maior autocorrelação espacial, como é, em geral, o caso de variáveis socioeconômicas, especialmente em áreas urbanas. Entretanto, há necessidade de mais recurso computacional e análise estatística prévia, que inclui, por exemplo, a construção do semivariograma.

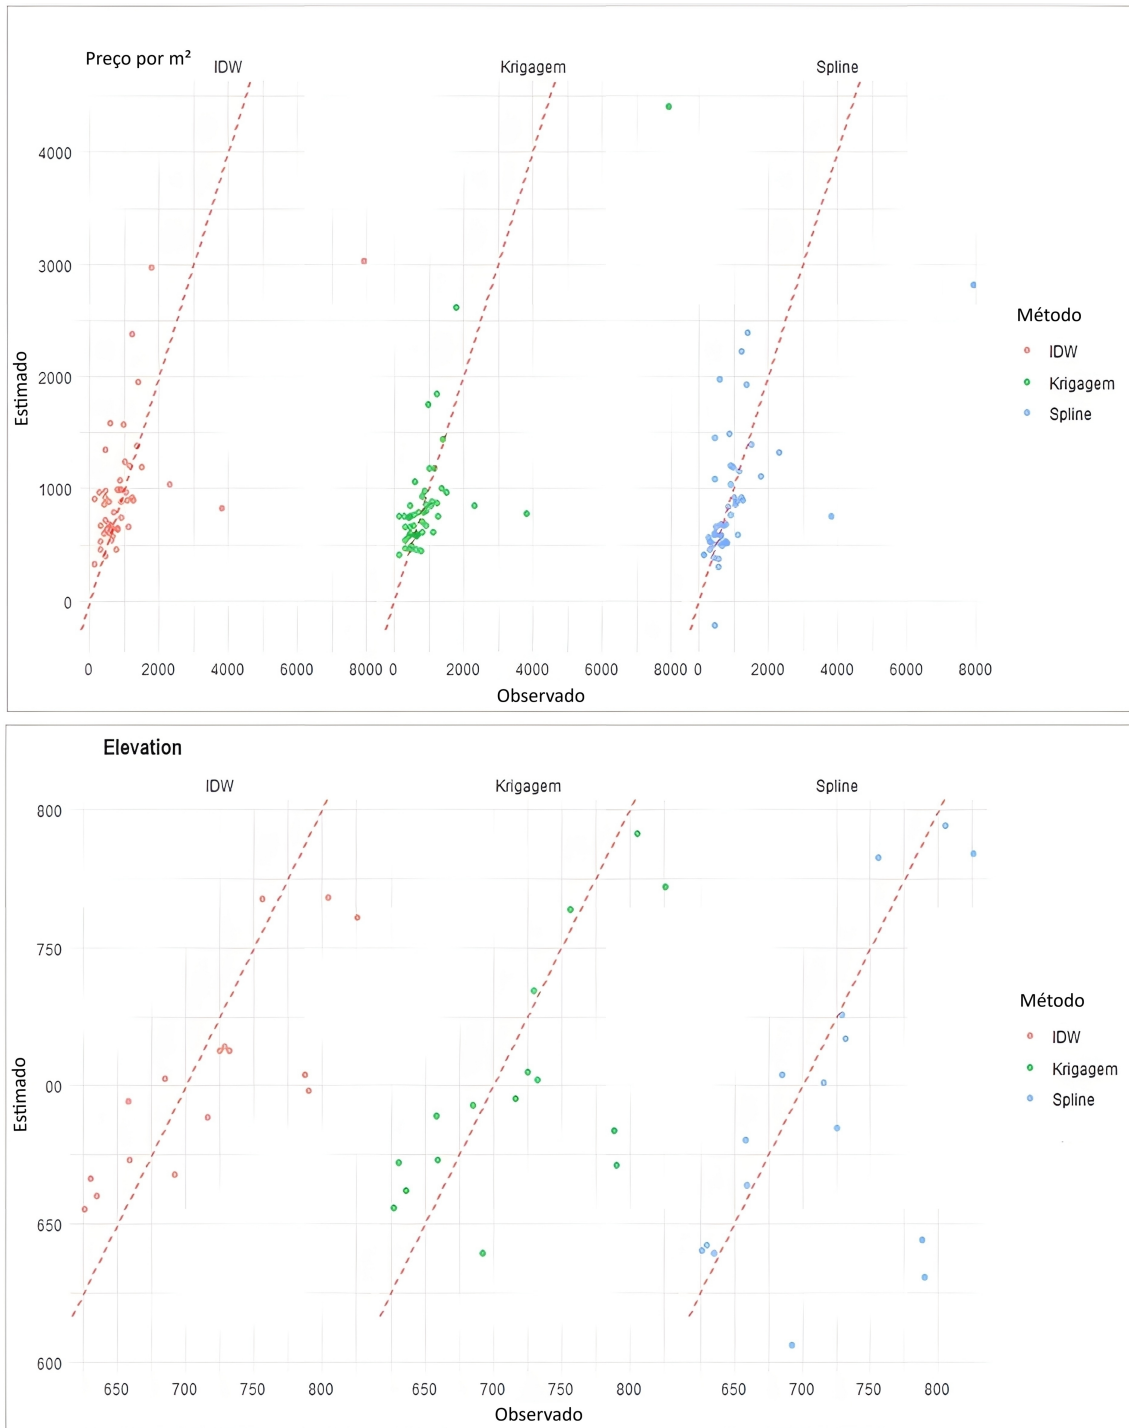


Figura 4 – Relação entre valores observados e estimados da validação cruzada dos interpoladores.
Fonte: os autores.

O estudo precisa ser entendido, também, no contexto de suas especificidades e limitações. Primeiramente, é importante considerar que os resultados foram obtidos a partir de um conjunto de dados específico, de modo que a extrapolação para outras áreas pode exigir ajustes nos parâmetros dos interpoladores. Estudos futuros podem explorar diferentes variáveis socioeconômicas e avaliar o impacto de diferentes densidades amostrais nos resultados.

Além disso, o estudo considerou apenas três métodos de interpolação, deixando de fora técnicas mais avançadas que possam considerar uma modelagem com mais variáveis – tais como Co-Krigagem

(Angelico, 2006), Random Forest (Sekulić et al., 2020) e Redes Neurais (Wanderley et al., 2014) – e, com isso, possivelmente, melhorar a precisão em certas condições. Pesquisas futuras de avaliação de desempenho de interpoladores espaciais de variáveis socioeconômicas devem levar em consideração outras variáveis.

CONCLUSÃO

O objetivo deste trabalho foi avaliar os métodos mais tradicionais de interpolação espacial (Inverso da Distância Ponderada – IDW, Thin Plate Spline e Krigagem) para variáveis socioeconômicas e comparar os resultados com os de uma variável física. Como exemplo empírico, comparou-se as predições para a variável espacial “preço de terreno por metro quadrado” em uma área urbana, de natureza socioeconômica, com as realizadas para dados hipsométricos da mesma área. Os resultados indicam que a variável socioeconômica foi interpolada de maneira mais eficiente pelo método de Krigagem, enquanto a variável física apresentou um melhor desempenho com os interpoladores determinísticos (IDW e Spline).

O estudo não tem o intuito de afirmar que um interpolador é melhor do que o outro – não obstante um deles tenha performado melhor para o nosso conjunto de dados – mas, sim, enfatizar que mais de um interpolador deve ser empregado a fim de produzir a melhor representação espacial. Além disso, os resultados são relevantes para estudos de mapeamento de fenômenos urbanos e políticas públicas que necessitam de estimativas confiáveis, para planejamento territorial e avaliação de desigualdades e diferenciações socioespaciais.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal da Fronteira Sul, pelo apoio científico ao desenvolvimento desta pesquisa (processo PES-2025-0472).

DISPONIBILIDADE DE DADOS

<https://www.dropbox.com/scl/fi/aq2qx9ul25sk30nrc8e0g/Script.R?rlkey=r1nk9ge8737lg7ch2obfrfjli&st=qlnzaulr&dl=0>

REFERÊNCIAS

- AKIMA, H. A new method of interpolation and smooth curve fitting based on local procedures. *Journal of the ACM (JACM)*, v. 17, n. 4, p. 589-602, 1970. <https://doi.org/10.1145/321607.321609>.
- ANGELICO, J. C. Desempenho da co-krigagem na determinação da variabilidade de atributos do solo. *Revista Brasileira de Ciência do Solo*, v. 30, p. 931-936, 2006. <https://doi.org/10.1590/S0100-06832006000600002>.
- BARBOSA, R. L.; MENEGUETTE JÚNIOR.; M.; SILVA, J. F. C.; GALLIS, R. B. A.; ITAME, O. I. Análise estatística da qualidade de um modelo digital do terreno gerado com Thin Plate Spline. *Revista Brasileira de Cartografia*, v. 60, n. 2, 127-132, 2008. <https://doi.org/10.14393/rbcv60n2-44875>.
- BOHLING, G. Introduction to geostatistics and variogram analysis. *Kansas Geological Survey*, v. 1, n. 10, p. 1-20, 2005.
- CAÑADA TORRECILLA, M. R. Técnicas de interpolación espacial deterministas y exactas: media ponderada por el inverso de la distancia y funciones de base radial. In: MORENO JIMÉNEZ, Antonio (ed.). *Sistemas y análisis de la información geográfica*. 2. ed. Madrid: Ra-Ma, 2007. p. 791-820.
- CORÁ, J. E.; ARAUJO, A. V.; PEREIRA, G. T.; BERBALDO, J. M. G. Variabilidade espacial de atributos do solo para adoção do sistema de agricultura de precisão na cultura de cana-de-açúcar. *Revista*

Brasileira de Ciência do Solo, v. 28, n. 6, p. 1013-1021, 2024. <https://doi.org/10.1590/S0100-06832004000600010>.

FARIAS, O. G.; FRANCISCO, C. N.; ALVES, M. C. Avaliação de métodos de interpolação espacial aplicados à pluviosidade em região montanhosa no litoral sul do estado do Rio de Janeiro. *Revista Brasileira de Climatologia*, v. 13, p. 21, p. 172-185, 2017. <https://doi.org/10.5380/abclima.v21i0.52065>.

FERREIRA, I. O.; SANTOS, G.; RODRIGUES, D. D. Estudo sobre a utilização adequada da krigagem na representação computacional de superfícies batimétricas. *Revista Brasileira de Cartografia*, v. 65, n. 5, p. 831-842, 2013. <https://doi.org/10.14393/rbcv65n5-43864>.

FOLHARINI, S. O.; MELO, S. N.; RAMOS, R. G.; BROWN, J. C. Land use and green crime: Assessing the edge effect. *Land Use Policy*, v. 129, e106636, 2023. <https://doi.org/10.1016/j.landusepol.2023.106636>.

LIU, Z.; ZHANG, Z.; ZHOU, C.; MING, W.; DU, Z. An adaptive inverse-distance weighting interpolation method considering spatial differentiation in 3D geological modeling. *Geosciences*, v. 11, p. 2, p. 51, 2021. <https://doi.org/10.3390/geosciences11020051>.

LONGLEY, P.; GOODCHILD, M. F.; MAGUIRRE, D. J.; RHIND, D. W. *Geographic Information Science & Systems*. 5. ed. New York: Wiley, 2015.

NASCIMENTO, E.; TOMBINI, L. H. T.; RIPPLINGER, F. Espacialização da Covid-19 no Sul do Brasil: a interiorização da doença e o caso da mesorregião Grande Fronteira do Mercosul. *Finisterra*, n. 27, p. 115, p. 27-35, 2020. <https://doi.org/10.18055/finis20367>.

OLIVEIRA, J. P. B.; CECÍLIO, R. A.; PRUSKI, F. F.; ZANETTI, S. S. Espacialização da erosividade das chuvas no Brasil a partir de séries sintéticas de precipitação. *Revista Brasileira de Ciências Agrárias*, v. 10, n. 40, p. 558-563, 2015. <https://doi.org/10.5039/agraria.v10i4a4998>.

PANIGRAHI, N. Inverse Distance Weight. In: SAGAR, B. S. D.; CHENG, Q.; MCKINLEY, J.; AGTERBERG, F. (eds.). *Encyclopedia of Mathematical Geosciences*. New York: Springer International Publishing, 2023, p. 1-7.

RAMOS, M. D.; MERINO, E. R.; MONTES, C. R.; MELFI, A. J. Avaliação do uso integrado de imagens de nanossatélites e classificadores baseados em aprendizado de máquina para estudos da dinâmica hidrológica na região da Nhecolândia (Pantanal). *Revista Brasileira de Cartografia*, v. 75, n. 1, 2023. <https://doi.org/10.14393/rbcv75n0a-67656>.

RAMOS, R. G.; MELO, S. N. Income inequality and the geography of residential burglaries: A spatial model applied to Campinas, Brazil. *Applied Geography*, 147, e102787, 2022. <https://doi.org/10.1016/j.apgeog.2022.102787>.

SEKULIĆ, A.; KILIBARDA, M.; HEUVELINK, G. B. M.; NIKOLIĆ, M.; BAJAT, B. Random forest spatial interpolation. *Remote Sensing*, n. 12, p. 1687, 2020. <https://doi.org/10.3390/rs12101687>.

SILVA, A. F.; LIMA, J. S. S.; OLIVEIRA, R. B. Métodos de interpolação para estimar o pH em solo sob dois manejos de café arábica. *Idesia (Arica)*, v. 28, n. 2, p. 61-66, 2010. <http://dx.doi.org/10.4067/S0718-34292010000200007>.

SILVA, C., MELO, S., SANTOS, A., ALMEIDA JÚNIOR, P., SATO, S., SANTIAGO, K., SÁ, L. Spatial modeling for homicide rates estimation in Pernambuco State - Brazil. *International Journal of Geo-Information*, v. 9, n. 12, p. 740, 2020. <https://doi.org/10.3390/ijgi9120740>.

STEIN, M. L. *Interpolation of spatial data: some theory for kriging*. New York: Springer Science & Business Media, 2012.

WANDERLEY, H. S.; AMORIM, R. F. C.; CARVALHO, F. O. Interpolação espacial de dados médios mensais pluviométricos com redes neurais artificiais. *Revista Brasileira de Meteorologia*, v. 29, n. 3, p. 389-396, 2014. <https://doi.org/10.1590/0102-778620130639>.

YAMAMOTO, J. K.; LANDIM, P. M. B. Geostatística: conceitos e aplicações. São Paulo: Oficina de Textos, 2013.

Afiliação dos Autores

Melo, S.N. - Professor da Universidade Estadual do Maranhão, São Luís (MA), Brasil.

Nascimento, E. - Professor da Universidade Federal da Fronteira Sul, Chapecó (SC), Brasil.

Contribuição dos Autores

Melo, S.N. - O autor contribuiu para a elaboração, realização e manipulação dos dados e para a redação.

Nascimento, E. - O autor contribuiu para a elaboração, realização e manipulação dos dados e para a redação.

Editores Responsáveis

Alexandra Maria Oliveira

Alexandre Queiroz Pereira

Eduardo Von Dentz