

# Modelagem da temperatura da superfície terrestre com técnicas geoestatísticas e variograma experimental: estudo de caso em Acaraú-CE

## RESUMO

Este artigo apresenta uma adaptação de técnicas geoestatísticas para a geração de modelos de Temperatura da Superfície Terrestre (Land Surface Temperature [LST]) baseado no cálculo do variograma experimental, tendo como zona de estudo a área centro-norte do município de Acaraú - CE. O objetivo desta pesquisa é encontrar o modelo que melhor se adapte às mudanças de direção e distâncias entre amostras no espaço. Foram utilizados os algoritmos para cálculo da Temperatura da Superfície Terrestre dos sensores Modis e Landsat 8, utilizando a plataforma Google Earth Engine. Foi gerada uma amostragem aleatória de 144 pontos na área de estudo para extrapolar ou estimar os valores da temperatura, sendo definida a estacionalidade total dos dados através das direções e distâncias entre pares (h) por meio do cálculo de variograma experimental. Logo, foram calculados os valores ausentes das temperaturas através do método de interpolação krigagem, utilizando as observações feitas pelo variograma. Foi analisada a relação entre os valores observados e os valores preditivos através da regressão linear. Como resultado, o sensor MODIS apresentou maior acurácia, explicando 60% dos valores observados, enquanto o modelo Landsat 8 explicou apenas 1,8%, mostrando um desempenho inferior entre os modelos.

**PALAVRAS-CHAVE:** Estatística Inferencial. Modelagem Geoestatística. Nordeste do Brasil. Processamento Digital de Imagens. Sensoriamento Remoto.

**Jack Endrick Pastrana Mojica**  
[pastrana061931@gmail.com](mailto:pastrana061931@gmail.com)  
[orcid.org/0009-0003-9539-1381](https://orcid.org/0009-0003-9539-1381)  
Universidade Federal Rio Grande do Sul,  
Porto Alegre, Rio Grande do Sul, Brasil.

**Jader de Oliveira Santos**  
[jader.santos@ufc.br](mailto:jader.santos@ufc.br)  
[orcid.org/0000-0003-2977-7086](https://orcid.org/0000-0003-2977-7086)  
Universidade Federal do Ceará, Fortaleza,  
Ceará, Brasil.

## INTRODUÇÃO

A geoestatística, de maneira prática, permite encontrar a correlação espacial entre diferentes variáveis e estimar novos valores associados ao comportamento dessas. Ela calcula informações inexistentes a partir do variograma experimental, o que permite uma continuidade espacial nas incertezas dos dados (ISAACS e SRIVASTAVA, 1989; LACIAK *et al.*, 2021).

Essa técnica foi desenvolvida por George Matheron (LACIAK *et al.*, 2021) nos anos 60, a partir do trabalho de D. G. Krige, pioneiro no uso da correlação espacial para fins de previsão. Matheron nomeou a krigagem em homenagem a Krige (OLIVER; WEBSTER, 2015).

Inicialmente desenvolvida para problemas de estimativa de reserva de minério na indústria de mineração, evoluiu extremamente, incluindo muitos métodos, técnicas e abordagens para modelagem espacial de fenômenos, inclusive no âmbito ambiental ciência do solo e climatologia.

Como evidência disso, trabalhos como o de Zhang *et al.*, (2011), Allen (2022), utilizaram dados de temperatura com o auxílio de sensores remotos, o que permitiu caracterizar a variabilidade espacial da temperatura, com intuito de contribuir a estudos epidemiológicos e intervenções de saúde pública em eventos de calor extremo.

Visando o aprofundamento dessa abordagem, a análise variográfica ou estrutural é um dos temas mais importantes da geoestatística, pois é responsável pela caracterização da estrutura espacial de uma propriedade ou fenômeno. É o processo em que um modelo geoestatístico é obtido para a função aleatória que está sendo estudada para estimar e modelar uma função que reflita a correlação espacial da variável regionalizada. (ISAACS *et al.*, 1989; VIERA, 2002).

Autores como Shtiliyanova *et al.*, (2017) e Allen (2022) mencionaram que, para obter valores associados a áreas com ausência de dados, a partir da noção de continuidade do ambiente estudado, a krigagem é um método de interpolação relativamente novo e pouco utilizado quando se trabalha com dados climatológicos. Embora possa ser considerado o Melhor Estimador Linear Imparcial, apresenta-se como ideal na investigação, oferecendo estimativas sólidas dos erros, minimizando-os, além de fornecer previsões mais precisas em regiões locais.

Diferentemente dos modelos baseados em Sistemas de Informação Geográficos (SIG), como a triangulação e média local das amostras, e interpolação local (TIN), que não levam em conta a continuidade espacial e desconsideram a anisotropia, a krigagem se destaca justamente por considerar essas variáveis essenciais. Portanto, desenvolver um modelo utilizando a metodologia de modelagem do variograma experimental, que melhor se adapte às mudanças de direção e às distâncias entre amostras no espaço, permite modelar qualquer parâmetro com um menor número de incertezas nos valores estimados.

Nesse contexto, o uso de imagens de satélite surge como uma ferramenta complementar essencial, permitindo abranger uma maior área geográfica para estimar a variação espaço-temporal do balanço de energia na superfície, o que é crucial para caracterizar o comportamento termodinâmico (Hu *et al.*, 2024). Esse comportamento é utilizado para estudar a saúde da vegetação, a umidade do solo

e, atualmente, para avaliar a exposição da população às ondas de calor (ZHAN et al., 2019; ALLEN, 2022).

Assim, obter dados de LST dos sensores Landsat 8 e MODIS, variáveis obtidas através da emissividade da superfície da Terra na faixa do Thermal Infrared Sensor (TIR), é fundamental nesta pesquisa. Essas observações permitiram modelar tanto o comportamento no variograma experimental quanto a construção dos modelos preditivos. Autores como Wan e Liang (1997) desenvolveram o algoritmo que registra a energia emitida pela superfície da Terra para o sensor MODIS. Por outro lado, para a plataforma Landsat, foram obtidos parâmetros físicos, como a conversão dos níveis de cinza em reflectância, a calibração radiométrica das faixas termais e os valores de emissividade para a temperatura (CHANDER e MARKHAM, 2003).

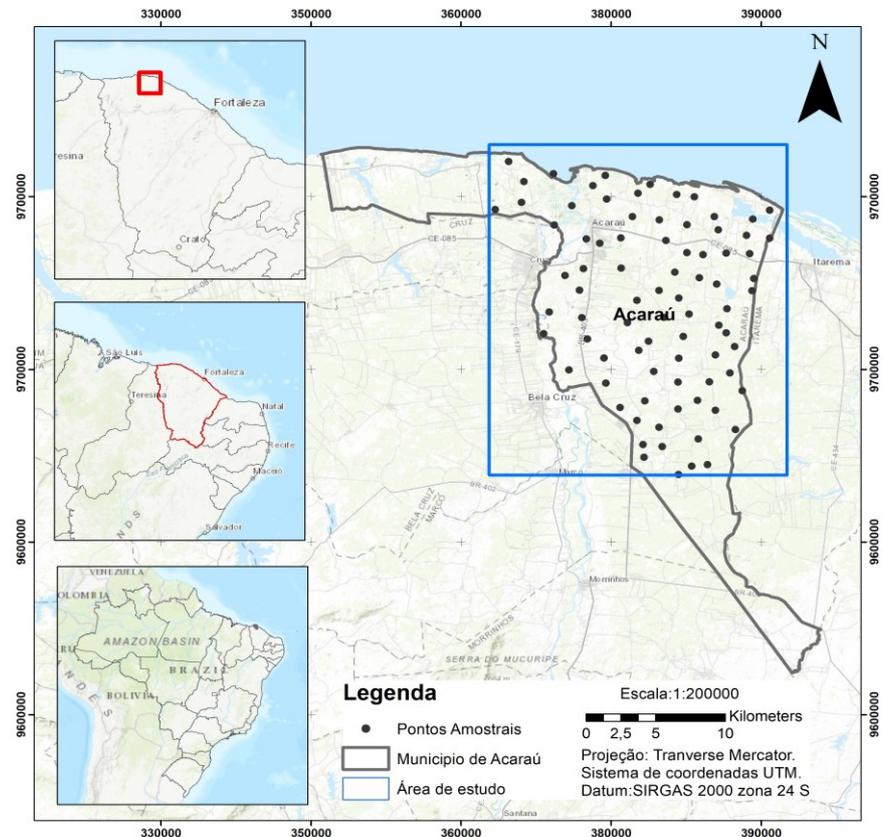
Diante dos aspectos anteriormente mencionados, a pesquisa objetiva a elaboração de modelos de Temperatura da Superfície Terrestre (LST), tendo em vista o cálculo do variograma experimental, o modelo Kriging e sua relação com os valores de temperatura. Esses elementos, nesta pesquisa, permitem contribuir com novas metodologias de conhecimento no modelamento da temperatura, sendo um fator estudado nos modelos globais de mudanças climáticas e podendo até contribuir em novas linhas de pesquisa, como a determinação das áreas mais propensas a ondas de calor, aspecto importante para a saúde pública.

## **MATERIAL E METODOS**

O estudo foi desenvolvido no município de Acaraú localizado a noroeste do estado do Ceará, a 248 Km da capital Fortaleza, abrangendo uma área de 842,88 km<sup>2</sup>, com uma zona costeira de aproximadamente 50 km (MORAES et al., 2015). A região apresenta condições edafoclimáticas específicas, estando incluída no perímetro semiárido nordestino, com pluviosidade média anual de 1.139,7 mm, concentrada no período chuvoso entre os meses de janeiro e abril (IPECE, 2017). O município faz parte na bacia do Baixo Acaraú, o que justifica as principais atividades econômicas como pesca, carcinicultura em cativeiro, agropecuárias e geração de energia eólica (NASCIMENTO, 2006), favorecidas pela disponibilidade de recursos hídricos.

De acordo com a Figura 1, a área de estudo corresponde à porção centro-norte do município, uma região com maior heterogeneidade de tipos de uso e cobertura da terra, incluindo cultivos, urbanização, carcinicultura e manguezais. Essas características refletem diferenciações na LST, definindo problemáticas inerentes ao conforto e desconforto térmico, à desertificação e à degradação do solo. As condições climáticas e vegetacional associadas ao uso antropogênico resultam em mudanças térmicas no ambiente.

Figura 1 – Área de estudo com os pontos da amostragem. Acaraú- Ceará.



Fonte: Autoria própria (2023).

## DADOS MODIS - AQUA LAND E LANDSAT 8

Para a adaptação dos dados de temperatura, foi utilizada a plataforma Google Earth Engine (GEE) (GORELICK, 2017). Foi utilizado o acervo de dados do sensor MODIS, que consiste em imagens de alta resolução espacial (1 km) e uma frequência temporal diária, fornecendo imagens desde julho de 2002 até a atualidade.

O fluxo de trabalho se iniciou, selecionando o dataset MYD11A1, disponibilizado pela plataforma GEE, através da camada LST\_Day\_1km (Day Land Surface Temperature). Para a conversão dos valores de LST, os valores de cinza nas imagens foram multiplicados pelo fator de escala de 0,02 e, subtraiu-se 273 do valor resultante. Com isso, foi possível obter 19 registros de temperatura em graus Celsius para o mês de agosto de 2022 no município de Acaraú. Em seguida, calculou-se a média das observações para o recorte espacial definido.

Para o pré-processamento das imagens Landsat 8, consideradas de escala média com resolução espacial de 60 metros, foi possível extrair a LST através da conversão dos níveis de cinza da imagem para valores de radiância espectral (RODRIGUES, 2020). A radiância espectral representa a energia emitida pelos alvos da superfície e é a medição física utilizada para obter a temperatura de brilho (USGS, 2021).

Esse parâmetro está associado nos metadados das bandas 10 ou 11 e é necessário para a aplicação do algoritmo. Os dados Landsat 8 estão disponíveis na Plataforma GEE, através da camada LANDSAT/LC08/C01/T1\_SR, e podem ser acessados por meio de código aberto em JavaScript.

$$T = \frac{K_2}{\ln\left(\frac{K_1}{L\lambda}\right)+1} \quad (1)$$

onde: T = Temperatura de brilho (Kelvin). L λ = Radiância espectral (Watts/m<sup>2</sup>\*sr\*μm). K<sub>1</sub>= constante de conversão térmica (K1\_CONSTANT\_BAND\_X, donde x é o número da banda, 10 ou 11) Informação disponibilizada nos metadados da imagem. K<sup>2</sup> = Constante de conversão térmica (K2\_CONSTANT\_BAND\_X, donde x é o número da banda, 10 ou 11) Informação disponibilizada nos metadados da imagem.

Neste trabalho, a imagem utilizada para a captura dos dados de LST corresponde ao mês de agosto de 2021. Para a conversão de Kelvin para graus Celsius (°C), foi subtraído (-273) dos valores de cinza na imagem, sendo assim possível obter as observações de LST

## CONSTRUÇÃO DO VARIOGRAMA EXPERIMENTAL

A maior vantagem deste método é estimar e modelar uma função que reflita a correlação espacial da variável regionalizada. Oliver e Webster (2015) consideram que o variograma experimental é adaptado para determinar o comportamento da variável pesquisada, mas ele deve ser preciso para que o modelo descreva a variação de forma mais confiável. Essa análise permite a geração de modelos clássicos, como o Kriging, com maior precisão, possibilitando obter variações mínimas no modelamento (DIAZ & BARANDELA, 2002; LACIAK et al., 2021).

Como ratificado por Laciak *et al.*, (2021), a primeira tarefa da análise estrutural geoestatística é calcular um conjunto de valores de variograma experimental para múltiplos da classe vetorial h, que juntos formam uma curva discreta do variograma experimental direcional resultante. Este modelo é entendido como uma definição de novas estimativas para diferentes distâncias e em diferentes direções do espaço estudado (TOULLIER et al., 2020). Assim, h é a função de semivariância e é definida pela seguinte equação:

$$Y(h) = \frac{1}{2m(h)} \sum_{i=1}^{m(h)} \{Z(X_i) - Z(X_i + h)\}^2 \quad (2)$$

onde:

Y = variograma estimado.

m (h) = número de medidos, separados por o vetor de distância **h**.

z(xi) e z (xi + h) = valores observados de z nos lugares **xi e xi + h**.

## GERAÇÃO MODELO DE TEMPERATURA POR MEIO DO MÉTODO SIMPLE KRIGING

Para o método kriging na área de estudo, foi necessário primeiro construir o variograma experimental com a menor variância de estimativa nas observações, usando informações de dados vizinhos, a fim de ser utilizado para estimar valores desconhecidos em locais não amostrados para cada um dos sensores utilizados (SHTILYANOVA *et al.*, 2017; LACIAK *et al.*, 2021).

Essa interpretação só ocorre porque são levados em consideração fatores como o número de amostras, sua localização, a distância entre as amostras e o ponto ou bloco a ser estimado, além da qualidade do variograma espacial (TOULLIER *et al.*, 2020). Esses fatores são classificados de acordo com a tabela 1.

Tabela 1 –Classificação de Kriging

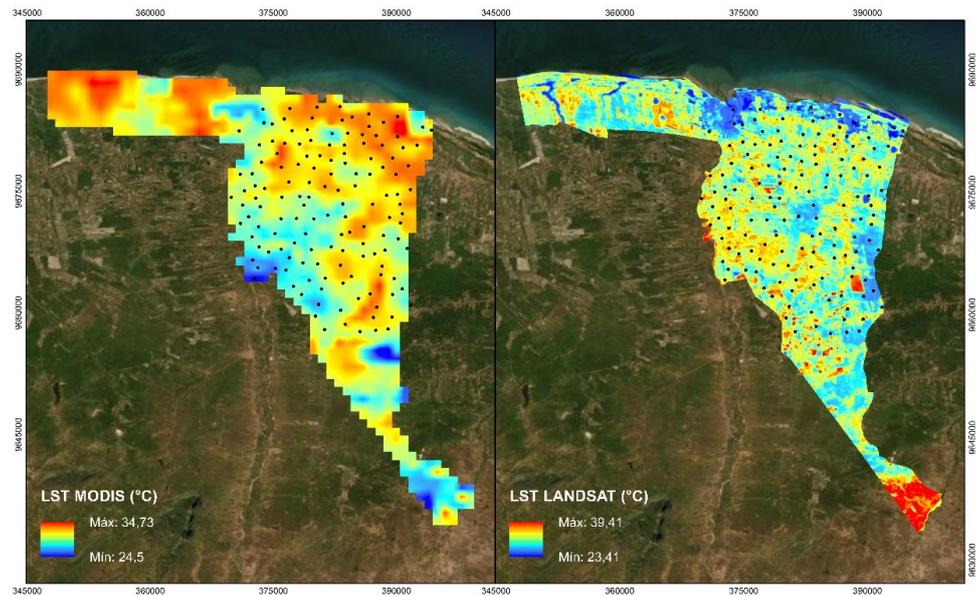
Classificação	Tipos	
De acordo com o suporte da medição dos dados	Pontual Blocos	
De acordo com a forma do estimador	Linear: -Simples -Ordinário -Universal -Residual	Não linear -Disjuntivo -Indicador -Probabilístico
De acordo com a suposição da distribuição de probabilidades	Paramétrico: - Multigaussiano - Disjuntivo - Lognormal	Não paramétrico: - Simples - Universal - Ordinário - Indicador - Residual - Probabilístico

Fonte: Adaptado de Viera (2002).

## RESULTADOS E DISCUSSÃO

Os resultados obtidos a partir dos dados de LST do MODIS e LANDSAT 8 são apresentados na Figura 2. Observa-se uma visível heterogeneidade na distribuição das temperaturas entre ambos, destacando-se principalmente pela diferença nas escalas espectral e espacial. Essa variação permite identificar as diferenças nos parâmetros técnicos intrínsecos de cada sensor.

Figura 2. Temperatura Superficial Terrestre (LST) - MODIS e LANDSAT 8 – Acaraú/CE



Fonte: Autoria própria (2023).

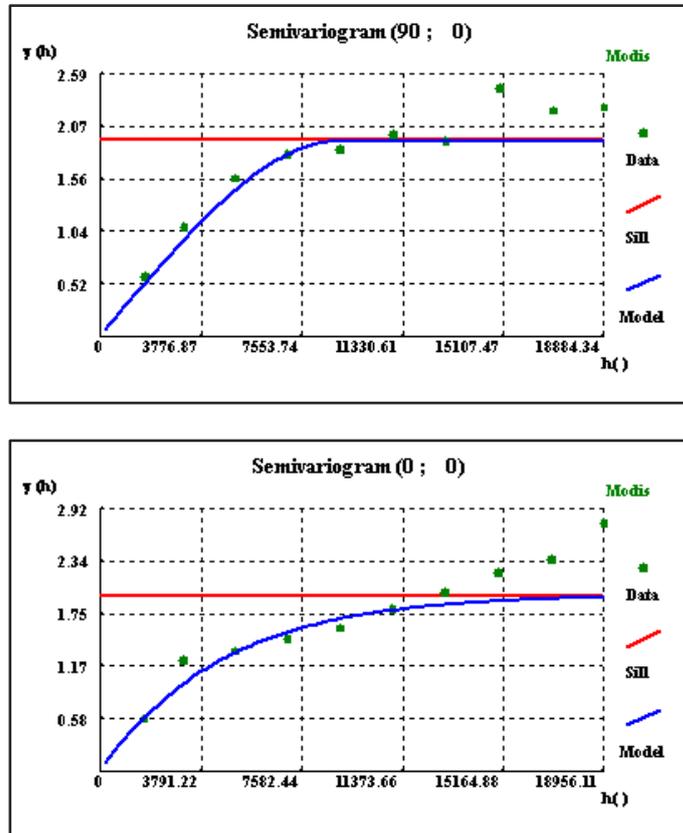
Os pontos de amostragem selecionados aleatoriamente dentro do município permitiram modelar o comportamento da variável em uma determinada direção. As covariâncias dos dados mostram uma estacionalidade em torno da variância.

Nesse contexto, os pontos no variograma apresentados na Figura 3 referem-se ao número de pares extrapolados de acordo com a direção e a distância definidas no software GeoMS, em relação à distribuição dos dados. A covariância, por sua vez, está mais diretamente relacionada à variância dos dados do que à distribuição espacial (TOULLIER *et al.*, 2020).

As diferentes medições feitas através do variograma permitiram analisar os parâmetros estudados (OLIVER; WEBSTER, 2015), ou seja, as variações direcionais que modelaram a LST observada com uma determinada geometria de medição.

Para o MODIS, foi utilizada uma medição geométrica simples, com um variograma em 0° e 90° para formar uma ortogonal, permitindo assim a extrapolação dos dados a partir de um modelo omnidimensional (Figura 3). Observa-se que a partir de aproximadamente 18 km houve uma correlação espacial em h).

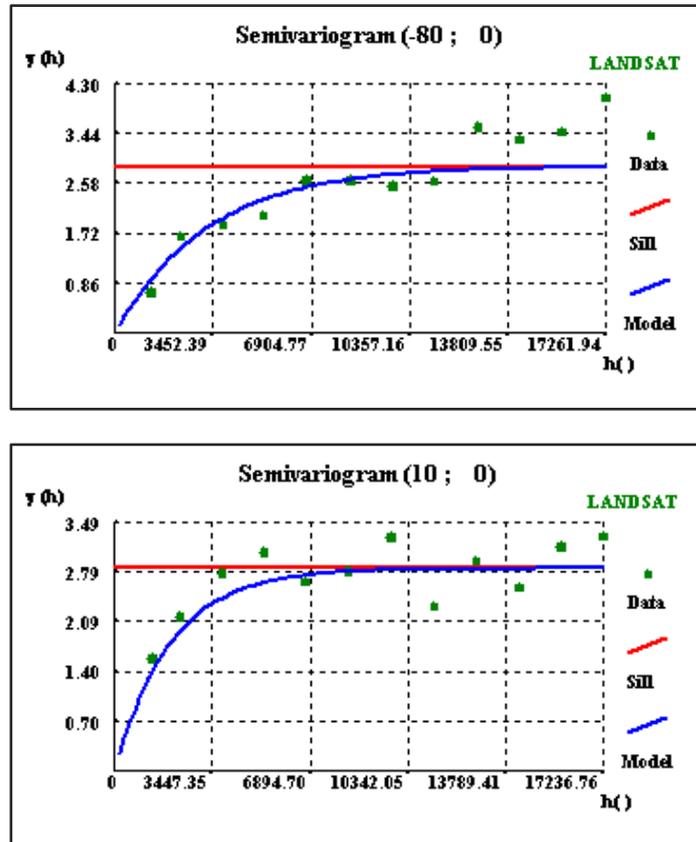
Figura 3 - Cálculo do Variograma teórico com direção 0°, ângulo de tolerância de 180° e 90°, ângulo de tolerância de 30° para valores observados do Sensor Modis, ajustado por um modelo esférico e exponencial respectivamente. Com alcance máximo de 20.000 metros e variância total de 1.76 e (h).



Fonte: Autoria própria (2023).

Para a modelagem das observações do Landsat 8, foi utilizado um variograma com -80° e 10° para analisar o comportamento da variável LST, com base em um modelo anisotrópico ou bidirecional. Na Figura 4, observa-se que a correlação espacial foi obtida a partir de aproximadamente 7 km em h( ).

Figura 4 - Cálculo do Variograma teórico com direção 10 °, ângulo de tolerância de 20 ° e -80 °, ângulo de tolerância de 45 ° para valores observados do Sensor Landsat 8, ajustado por um modelo exponencial e esférico respectivamente. Com alcance máximo de 18.000 metros e variância total dos dados de 2.79  $\gamma(h)$ .



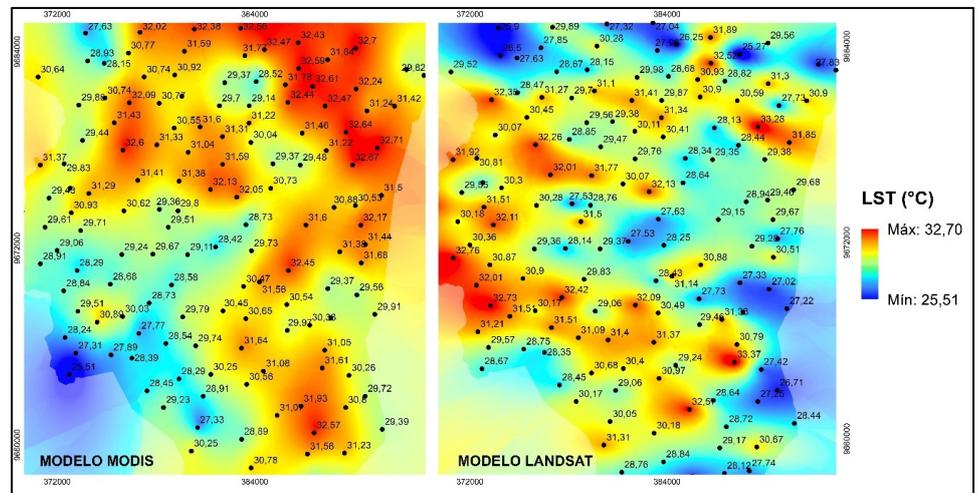
Fonte: Autoria própria (2023).

Cada ponto do variograma representa o número de pares obtidos no GeoMS, valor que é refletido em  $\gamma(h)$  utilizando o método da diferença dos  $dZ^2=(Z_i-Z_j)^2$ . Foi definida uma distância ( $d$ ) entre pares de 2000 m, com o intuito de abranger a maior quantidade de amostras para a modelagem. Portanto, esses gráficos permitiram extrapolar informações para modelar a distância e a direção em que as 144 amostras capturadas pelos sensores estão correlacionadas. Esses variogramas experimentais foram utilizados para gerar o Simple Kriging (SHTILYANOVA et al., 2017) no módulo geoKRIG do GeoMS.

Como resultado, foi possível obter dados distribuídos espacialmente em toda a área de interesse, permitindo a interpolação dos dados, como a Krigagem, o que supre a deficiência de informações de dados de temperatura em estudos que utilizam a coleta de dados locais para a análise climática e saúde pública. (ALLEN, 2022).

A krigagem (Figura 5), realizada com base nos variogramas, permitiu verificar que os modelos gerados indicaram uma continuidade nos dados de amostragem. Esse método mostrou-se eficaz para estimar as observações da variável, refletindo a continuidade espacial das medições e aprimorando a precisão das estimativas.

Figura 5. Modelos de Temperatura da Superfície Terrestre (LST) - MODIS e LANDSAT - Acaraú/CE



Fonte: Autoria própria (2023).

Para avaliar a qualidade do modelo, foi realizada uma validação cruzada (Figuras 6 e 7) para determinar o grau de erro entre as previsões e os valores reais. Nesse sentido, se o modelo do variograma refletiu adequadamente a estrutura espacial do conjunto de dados, os valores estimados devem estar próximos dos valores observados.

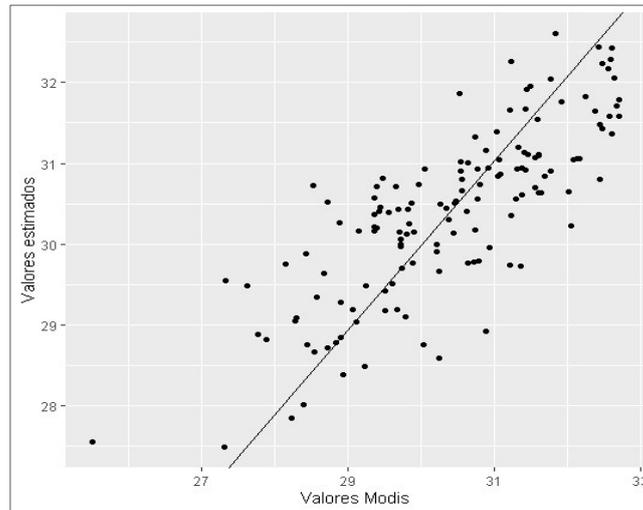
$$Y = \beta_0 + \beta_1 * X_1 + \dots + \epsilon \quad (3)$$

onde: Y = variável dependente de regressão linear  $\beta_0$  = intercepto em Y da equação de regressão linear quando X vale 0,  $\beta_1$  = inclinação da reta de regressão linear.  $\epsilon$  = erro da equação de regressão linear.

Portanto, para explicar a relação entre as duas variáveis neste estudo e analisar a dependência entre a LST observada e a LST preditora (independente), foi utilizada a intensidade dos coeficientes de correlação.

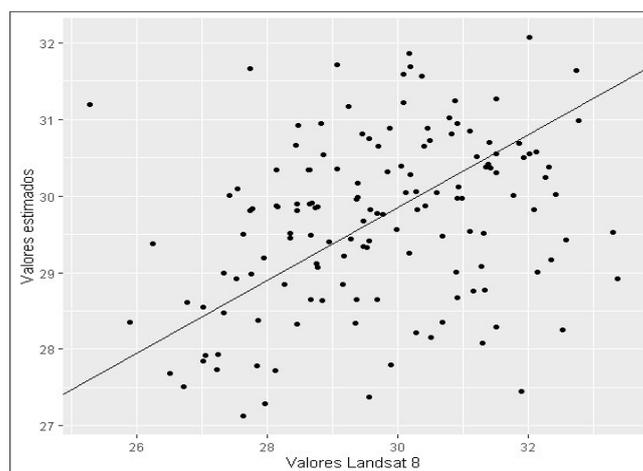
Na Figura 6 é possível verificar que a relação entre o valor observado do sensor MODIS e seu valor estimado ou variável preditora é mais forte, com um coeficiente  $r^2$  0,632, em comparação com o sensor Landsat (Figura 7), que apresentou um coeficiente mais fraco de  $r^2$  de 0,096. Ambos modelos mostraram uma relação direta, onde o aumento no valor de dependente está associado a um aumento na variável independente.

Figura 6: Correlação entre valores estimados (°C) e observados do Sensor Modis.



Fonte: Autoria própria (2023).

Figura 7: Correlação entre valores estimados (°C) e observados do Sensor Landsat 8.



Fonte: Autoria própria (2023).

## CONCLUSÃO

A modelagem realizada com os dados do MODIS demonstrou um ajuste superior no variograma, revelando uma maior estacionalidade tanto no variograma quanto na análise de regressão. Esse desempenho destacado pode ser atribuído à combinação da aleatoriedade da amostragem e à frequência dos dados. Com base nesses resultados, o MODIS se configura como um instrumento eficiente para análises de LST, oferecendo uma solução para a modelagem e avaliação das condições térmicas da superfície terrestre nesta pesquisa.

A diferença na modelagem pode ser atribuída à frequência temporal do sensor MODIS, que captura dados da emissividade da superfície terrestre a cada 3 dias. Essa alta frequência é benéfica, pois proporciona um ajuste mais preciso do modelo e valores que estão mais próximos da realidade. Em contraste, o sensor

Landsat 8 realiza medições a cada 20 dias ou mensalmente. Apesar de ter um tamanho de pixel de 100 m, a menor frequência de captura não permitiu a obtenção de um modelo de LST tão preciso quanto o do MODIS.

Os resultados dos dados do Landsat 8 mostram uma correlação espacial fraca, evidenciada pelos valores obtidos no variograma experimental, especialmente no variograma com direção de 10°. Embora se espere que os valores de  $\gamma(h)$  aumentem com o aumento da distância  $h$ , observam-se variações que não seguem esse padrão, indicando uma falta de correlação espacial. No variograma com direção de 80°, as amostras localizadas acima da linha de variância total do gráfico apresentam uma correlação reduzida, o que gera maiores incertezas na criação do modelo.

Para obter melhores resultados, recomenda-se aumentar a distribuição e o número de amostras, além de considerar uma menor distância crítica ( $d$ ) entre os pares no cálculo do variograma. Também é importante testar diferentes direções, seja omnidimensional ou bidirecional, para cada variável observada. Outro parâmetro a ser incluído é a tolerância angular, que dependerá da distribuição espacial dos dados e pode ser utilizada para gerar um melhor ajuste nos modelos de LST.

Esta metodologia pode auxiliar na geração de modelos de temperatura mais precisos e abrangentes e, em alguns casos, substituir os conjuntos de dados de áreas com baixa resolução espacial em termos de dados climáticos. Além disso, serve como suporte para análises de ondas de calor, que podem ter impacto significativo na morbidade da população em zonas locais.

# Modeling of land surface temperature using geostatistical techniques and experimental variogram: a case study in Acaraú-CE

## ABSTRACT

This article presents an adaptation of geostatistical techniques for generating Land Surface Temperature (LST) models based on the calculation of the experimental variogram, with the study area located in the central-northern region of the municipality of Acaraú - CE. The objective of this research is to find the model that best adapts to changes in direction and distances between samples in space. Algorithms were used to calculate Land Surface Temperature from MODIS and Landsat 8 sensors, employing the Google Earth Engine platform. A random sample of 144 points in the study area was generated to extrapolate or estimate temperature values, defining the total seasonality of the data through directions and distances between pairs (h) using the experimental variogram calculation. Subsequently, missing temperature values were calculated using the kriging interpolation method, based on observations made with the variogram. The relationship between observed and predictive values was analyzed through linear regression. As a result, the MODIS sensor showed greater accuracy, explaining 60% of the observed values, while the Landsat 8 model explained only 1.8%, showing lower performance among the models

**KEYWORDS:** Inferential Statistics. Geostatistical Modeling. Northeast of Brazil. Digital Image Processing. Remote Sensing

## REFERÊNCIAS

CHANDER, G.; ARKHAM, B. Revised Landsat-5 TM Radiometric Calibration Procedures and Postcalibration Dynamic Ranges. **IEEE Transactions on Geoscience and Remote Sensing**, v. 41 p4, 2003. [http:// 10.1109/818464](http://10.1109/818464).

CHEVAL, S.; DUMITRESCU, A.; & AMIHAESEI, V. A. Exploratory analysis of urban climate using a gap-filled landsat 8 land surface temperature data set. **Sensors**, v. 20, n. 18, p. 5336, 2020.

GOOGLE EARTH ENGINE. **Código Editor e instruções de uso**. Disponível em: <https://developers.google.com/earth-engine/guides/playground>.

GORELICK, Noel et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote sensing of Environment**, v. 202, p. 18-27, 2017.

IPECE. Perfil municipal. Acaraú. 2017. Disponível em: [https://www.ipece.ce.gov.br/wpcontent/uploads/sites/45/2018/09/Acarau\\_2017.pdf](https://www.ipece.ce.gov.br/wpcontent/uploads/sites/45/2018/09/Acarau_2017.pdf). Acesso em: 29 dez 2022.

HU, D.; GUO, F.; MENG, Q.; SCHLINK, U.; WANG, S.; HERTEL, D.; GAO, J. A novel dual-layer composite framework for downscaling urban land surface temperature coupled with spatial autocorrelation and spatial heterogeneity. **International Journal of Applied Earth Observation and Geoinformation**, v. 130, p. 103900, 2024.

ISAAKS, E. H.; SRIVASTAVA., M. **Applied Geostatistics**. New York : OXFORD UNIVERSITY PRESS. 1. ed., New York: Editora: OXFORD UNIVERSITY PRESS, 1989.

ISAAKS, E. H.; SRIVASTAVA., M. "**Uma Introdução à Geostatística Aplicada**". 1 ed. New York: Editora: Oxford Univ. Imprensa, 1989. p. 561.

LACIAK, M.; VÍZI, L.; KAČUR, J.; DURDÁN, M.; & FLEGNER, P. Application of geostatistical methods in spatio-temporal modelling of temperature changes of UCG experimental trial. **Measurement**, v. 171, p. 108826, 2021.

LANDSAT 8 ESUN (FOR ATMOSPHERIC CORRECTION). **Radiance, and TOA Reflectance**. Disponível em: < <https://www.gisagmaps.com/landsat-8-atco/>>. Acesso em 10 jul. 2023.

MORAES, M. V. Morfologia e sedimentologia da plataforma continental interna do município de Acaraú—Ceará—Brasil. **Revista de Geociências do Nordeste**, v. 1, n. 1, p. 01-21, abr. 2015. <https://repositorio.ufpe.br/handle/123456789/12135>

NASCIMENTO, F. R. **Degradação Ambiental e Desertificação no Nordeste Brasileiro: O contexto da Bacia do Rio Acaraú – Ceará.2006.** Tese (Doutorado em Geografia) – Setor de Ciências Humanas, Universidade Federal Fluminense, Rio de Janeiro, 2006. Disponível em: <https://shorturl.at/jCFP6> .Acesso em: 5 ago 2023.

OLIVER, M.A.; WEBSTER, R. Basic Steps in Geostatistics:The Variogram and Kriging. **Springer International Publishing AG Switzerland is part of Springer Science. New York**, p 1-106, 2015. [http:// 10.1007/978-3-319-15865](http://10.1007/978-3-319-15865).

RODRIGUES CORUJO, Sergio. **Detección de cambios en imágenes multibanda mediante reducción de su dimensionalidad.** 2020. Disponível em: <https://oa.upm.es/63373/>. Acesso em 10 jul. 2024

SHTILYANOVA, A.; BELLOCCHI, G.; BORRAS, D.; EZA, U.; MARTIN, R.; Carrère, P. Kriging-based approach to predict missing air temperature data. **Computers and Electronics in Agriculture**, v. 142, p. 440-449, 2017.

TOULLIER, T.; DUMOULIN, J.; & MEVEL, L. A. Kriging-based Interacting Particle Kalman Filter for the simultaneous estimation of temperature and emissivity in Infra-Red imaging. **IFAC-PapersOnLine**, v. 53, n. 2, p. 456-461, 2020.

UNITED STATES GEOLOGICAL SURVEY (USGS), 2021. **Landsat 8-9 Calibration and Validation (Cal/Val) Algorithm Description Document (ADD)**, South Dakota-United States of America. p, 819 U.S. Geological Survey, Imprensa.

VIERA, M, A.; GONZÁLEZ, R, C. **Geoestadística aplicada.** Instituto de Geofísica, UNAM-Instituto de Geofísica y Astronomía, CITMA. Cuba, 2002. Disponível em: [https://www.academia.edu/23486534/Geoestadistica Aplicada](https://www.academia.edu/23486534/Geoestadistica_Aplicada). Acesso em 25 jul. 2023

ZHANG, K.; OSWALD, E. M.; BROWN, D. G.; BRINES, S. J.; GRONLUND, C. J.; WHITE-NEWSOME, J. L.; O'NEILL, M. S. Geostatistical exploration of spatial variation of summertime temperatures in the Detroit metropolitan región. **Environmental research**, v. 111, n. 8, p. 1046-1053, 2011.

ZHAN, L. F.; WANG, Y.; SUN, H., ZHAI, J.; ZHAN, M. Study on the change characteristics of and population exposure to heatwave events on the North China Plain. **Advances in Meteorology**, v. 2019, n. 1, p. 7069195, 2019.

WAN, Z.; LIANG, Z. A physics based algorithm for retrieving land; surface emissivity and temperature from EOS/MODIS data. **EEE Transactions on Geoscience and Remote Sensing** .v 35 p 980-996. Jul. 1997. <http://10.1109/36.602541>

**Recebido:** 30 jan. 2024

**Aprovado:** 16 out. 2024

**DOI:** 10.3895/rbgeo.v12n2.18098

**Como citar:** MOJICA, J. E. P.; SANTOS, J. de O. Modelagem da temperatura da superfície terrestre com técnicas geoestatísticas e variograma experimental: estudo de caso em Acaraú-CE. **R. bras. Geom.**, Curitiba, v. 12, n. 2, p. 219-234, jul./dez. 2024. Disponível em: <<https://periodicos.utfpr.edu.br/rbgeo>>. Acesso em: XXX.

**Correspondência:**

Jack Endrick Pastrana Mojica

Rua São Manuel, 698, CEP 90610-261, Porto Alegre, Rio Grande do Sul, Brasil.

**Direito autoral:** Este artigo está licenciado sob os termos da Licença Creative Commons-Atribuição 4.0 Internacional.

