

ESTIMATIVA DA SAÚDE VEGETATIVA NO RIO GRANDE DO SUL

Bernardo Schettini

Universidade Federal do Rio Grande (FURG) – be.t.schettini@gmail.com
Universidade Federal do Rio Grande (FURG) – wlfcm@gmail.com

1. INTRODUÇÃO

A agricultura possui um papel importante para a economia Brasileira, tanto para o consumo interno quanto para o mercado no exterior (JANK; NASSAR; TACHINARDI, 2005), sendo a soja uma das principais *commodities* ao qual superou 159,1 bilhões de dólares em exportações.

Ciente de sua importância econômica, é indispensável compreender os principais fatores que podem afetar a produtividade agrícola, principalmente no Rio Grande do Sul (RS), fortemente suscetível por alterações ambientais e climáticos. Uma forma para avaliar o comportamento da cultura é a partir da *Vegetation Health Index (VHI)*

- (KOGAN, 2022). Neste trabalho, teve o objetivo de estimar o VHI ao longo do Rio Grande do Sul a partir da Regressão Geograficamente Ponderada.

2. METODOLOGIA

DADOS

Para avaliação da saúde vegetativa no Rio Grande do Sul baseado no *Vegetation Health Index (VHI)*, utilizou-se imagens do satélite GOES via sensor orbital *Advanced Very High Resolution Radiometer (AVHRR)* fornecidos pelo *National Environmental Satellite, Data, and Information Service do National Oceanic Atmospheric Administration (NOAA)* (KOGAN, 2022). O VHI (Eq. 1) é um produto resultante da composição de dois índices: *Vegetation Condition Index (VCI)*, baseado no *Normalized Difference Vegetation Index - NDVI* e o *Thermal Condition Index (TCI)*, obtido a partir do *Land Surface Temperature - LST* 2023improved.

$$VHI = a * VCI + (1 - a) * TCI \quad (1)$$

Onde $a=0.5$, VCI é o *Vegetation Condition Index* e TCI é o *Thermal Condition Index*.

Estes dados do VHI possuem resolução espacial de 4km x 4km e escala temporal do período de 1982 a 2022. A estimativa do VHI via modelo de Regressão Geograficamente Ponderada (RGP) foi realizada a partir da composição média anual do VHI deste período, a partir das variáveis independentes: evapotranspiração (ETP, mm), elevação (ELEV, m), precipitação (P, mm), temperatura (T, °C), e umidade do solo (US, em mm), correspondentes ao período de 1981-2010 oriundas do produto de reanálise *TerraClimate* (ABATZOGLOU et al., 2018).



REGRESSÃO GEOGRAFICAMENTE PONDERADA (RGP)

Após a organização e composição dos dados, criou-se a regressão linear múltipla (RLM) (Eq. 2) com a finalidade de selecionar as variáveis que constituirão o modelo RGP (CORRAR, 2007).

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_p x_p + \epsilon \quad (2)$$

Onde: β_0 é o intercepto, $\beta_1, \beta_2, \dots, \beta_p$ são os coeficientes, x_1, x_2, \dots, x_p são as variáveis independentes, e ϵ é a variável aleatória.

Em seguida a criação do RLM, aplicou-se o fator de inflação da variância (VIF) com a finalidade de detectar a presença de multicolinearidade das variáveis, neste caso, com valores inferiores a 10 (Eq. 3) - (CORRAR, 2007).

$$VIF_j = 1 / (1 - R_j) \quad (3)$$

Onde R^2 é o coeficiente de determinação, ao qual varia entre 0 e 1.

A partir da remoção das variáveis multicolineares via VIF, criou-se o modelo o RGP. Esta técnica de análise espacial utiliza variáveis não estacionárias com o objetivo de modelar a variável de interesse em função das variáveis independentes, incluindo em sua análise a influência local (ALVES; GALVANI, 2021).

$$y_i = \beta_0(u_i, v_i) + \sum \beta_k(u_i, v_i)x_{ik} + \epsilon_i \quad (4)$$

Onde u_i e v_i são coordenadas de longitude e latitude no i-ésimo ponto no espaço, $\beta_0(u_i, v_i)$ é o intercepto no i-ésimo ponto no ponto i, $\beta_k(u_i, v_i)$ é o coeficiente local no ponto i, e X_{ik} é o conjunto de variáveis independentes.

Para a manipulação das variáveis, aplicação dos testes estatísticos, e criação dos RLM e RGP utilizou-se o software RStudio versão 1.2.5033 (TEAM, 2019).

3. RESULTADOS E DISCUSSÃO

De acordo com o VIF 1, as variáveis não apresentam multicolinearidade ($US = 2,3$, $ETP = 3,1$, $ELEV = 8,7$, $P = 3,3$ e $T = 7,4$). Além disso, o resultado da RLM exibe significância estatística ($p < 0,05$), com exceção da precipitação ($p < 0,07$), com a capacidade preditiva (R^2) de 0,25.

No contexto da RGP, a avaliação dos coeficientes é realidade individualmente a cada ponto de grade por cada variável independente. Neste caso, a Figura 1 exibe o coeficiente e o Pseudo *T-Student* da variável Temperatura. A primeira (Figura 1, à Tabela 1: Coeficientes e testes

estatísticos dos modelos RLM e RGP. As letras **a**, **b** e **c** representam o p-valor com níveis de significância com valores de 0.1, 0.05 e 0.01, respectivamente, para cada uma das variáveis inseridas no modelo.

Variáveis	RLM	RGP	Testes	RLM	RGP
Intercepto	5,993c	-	R2	0,25	0,71
ELEV	0,011c	-	AIC	17.666,45	14.447,57
ETP	0,012c	-	AICc	17.666,48	14.815,86
P	-0,000a	-	BIC	14.173,07	13.066,91
T	1,488c	-	-	-	-
US	0,033c	-	-	-	-

esquerda) apresenta valores positivos nas regiões costeira e nordeste do RS, entre 10 e 80, enquanto que nas demais áreas exibem uma influência negativa, com valores - 20 e -50. Além disso, tais regiões apresentam significância estatística ($p < 0.05$, Figura 1, à direita).




Figura 1: Representação espacial da variável Temperatura referente ao coeficiente (à esquerda) e pseudo-T student e (à direita) para o modelo do RGP para estimação do VHI.

Em termos de capacidade preditiva (R^2 , Figura 2), verifica-se que há uma pequena diferença no valor entre o VHI observado (Figura 2, à direita) e o VHI estimado (Figura 2, ao centro) nas regiões costeira e nordeste do RS, com comportamento similar. Numa análise comparativa entre RGP e RLM, nota-se uma melhora significativa na predição (R^2) da estimativa do VHI (Figura 2), saltando de 0,25 (RLM) para 0,71 (RGP). Observa-se que as áreas que possuem a maior preditibilidade estão situadas na região costeira e nordeste do RS, com valores de R^2 superiores a 0,6 (Figura 2, à esquerda).




Figura 2: Análise comparativa entre o VHI observado (à esquerda) e estimado (centro), e análise preditiva (à direita, R^2 Local em %) do VHI anual referente a composição de 1982-2022.

4. CONCLUSÕES

O modelo RLM exibiu que todas as variáveis apresentaram significância estatística (p -valor < 0.05). Além disso, constatou-se um ganho expressivo da capacidade preditiva (R^2) do modelo RGP em relação ao RLM. O resultado RGP demonstrou que a temperatura exerceu a maior influência sobre a estimativa do VHI, com influência positiva sobre as regiões costeiras e noroeste do RS. Estas regiões mencionadas apresentaram significância estatística (p < 0.05) na Temperatura, exibiu a maior capacidade preditiva (R^2), com valores superiores a 0.6.

5. REFERÊNCIAS BIBLIOGRÁFICAS

- ABATZOGLOU, J. T. et al. Terraclimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. **Scientific data**, Nature Publishing Group, v. 5, n. 1, p. 1–12, 2018.
- ALVES, E. D. L.; GALVANI, E. Modelagem da ilha de calor urbana de superfície utilizando regressão geograficamente ponderada (gwr). **Revista Brasileira de Climatologia**, v. 28, p. 718–742, 2021.
- CORRAR, L. **Regressão linear múltipla. Análise multivariada para os cursos de administração, ciências contábeis e economia.** [S.I.]: São Paulo: Atlas, 2007.
- JANK, M. S.; NASSAR, A. M.; TACHINARDI, M. H. Agronegócio e comércio exterior brasileiro. **Revista USP**, n. 64, p. 14–27, 2005.
- KOGAN, F. Why this book? In: _____. **Remote Sensing Land Surface Changes : The 1981-2020 Intensive Global Warming**. Cham: Springer International Publishing, 2022. p. 1–19. ISBN 978-3-030-96810-6. Disponível em: <https://doi.org/10.1007/978-3-030-96810-6_1>.
- TEAM, R. Rstudio: Integrated development environment for r; v. 1.2. 5001. In: _____. [S.I.]: RStudio, Inc., 2019.