



Fonseca, A. C. N. da¹; Silva, E. G. F. A.¹, Bezerra, A. C.¹; Moura, G. B. A.¹, Anjos, J. F.¹, Figueiroa, E.²; Coelho, G. P. C.²; Andrade, J. P.²; Ferreira, E. V. L.³; Silva, J. R. I.¹

¹Universidade Federal Rural de Pernambuco, Brasil

²Scinet Institute, Brasil; ³Netcon Americas, Brasil

Nonlinear Modeling of Vegetation Response to Rainfall Variability in the Brazilian Semi-Arid Region Using Sentinel-2 and CHIRPS Data

17th International Conference on Precision Agriculture and 11th Brazilian Congress on Precision and Digital Agriculture

13-15 July 2026

Porto Alegre, Brazil

Abstract.

High climate variability in the Brazilian semi-arid region poses significant challenges to agriculture and the sustainable management of Caatinga ecosystems, requiring monitoring tools capable of anticipating vegetation responses to rainfall fluctuations. However, the spectral response of vegetation to precipitation does not always follow linear patterns and may reflect ecohydrological thresholds and water saturation effects. Sentinel-2 data were used to derive the Soil Adjusted Vegetation Index (SAVI), while precipitation estimates were obtained from the Climate Hazards Group InfraRed Precipitation with Station Data (CHIRPS) dataset. Both datasets were processed within the Google Earth Engine platform, covering the period from 2019 to 2025. Time series were stratified into dry and rainy seasons to evaluate potential structural differences in the climate–vegetation relationship under contrasting water availability regimes. Linear, quadratic, and cubic regression models were fitted to estimate SAVI as a function of precipitation. Model performance was compared using the coefficient of determination (R^2) and consistency across seasonal periods. The cubic model showed superior performance in both seasons, with greater explanatory capacity during the rainy season ($R^2 \approx 0.56$) compared to the dry period ($R^2 \approx 0.38$). The improved fit of the third-order model suggests that vegetation response to rainfall involves multiple phases, possibly associated with physiological activation, accelerated growth, and subsequent stabilization under water-limited conditions. Precipitation exerted stronger influence during the rainy season, whereas during the dry period additional factors, such as soil properties, accumulated water stress, and temperature, likely modulated the spectral response. Although precipitation explains a relevant portion of SAVI variability, results indicate that climate–vegetation dynamics in the Caatinga are intrinsically complex. These findings reinforce the need for polynomial approaches and future multivariate integrations to enhance predictive performance. The integration of high-resolution optical imagery, satellite-based climate estimates, and statistical modeling within a scalable cloud-computing platform demonstrates strong potential for the development of digital tools aimed at water-risk monitoring, detection of critical vegetative stress periods, and support for management planning in rainfed agricultural systems. This

approach aligns with precision agriculture principles and contributes to climate resilience monitoring strategies in environmentally vulnerable semi-arid regions.

Keywords.

Remote sensing; Ecohydrological dynamics; Climate resilience; Precision agriculture; Environmental monitoring; Digital agriculture systems

INTRODUÇÃO

A alta variabilidade climática exerce influência direta sobre os sistemas agrícolas e o bioma Caatinga no semiárido brasileiro. A recorrência de eventos de seca compromete significativamente a produção agrícola e a segurança alimentar (José et al., 2022), enquanto os agricultores se tornam mais suscetíveis aos impactos climáticos em função de limitações no manejo e de condições socioeconômicas desfavoráveis (Almeida et al., 2023). Paralelamente, no bioma Caatinga, o aumento das temperaturas associado à redução das precipitações têm contribuído para a perda de biodiversidade e alterações fisiológicas em espécies vegetais, incluindo sementes, além de intensificar processos de desertificação que reduzem a resiliência do ecossistema (OLIVEIRA et al., 2022).

Nesse contexto, a relação entre precipitação e dinâmica da vegetação em regiões semiáridas é caracterizada por forte não linearidade, resultante da interação entre processos ecológicos e hidrológicos. Índices espectrais derivados de sensoriamento remoto, como o Índice de Vegetação Ajustado ao Solo (SAVI), têm sido utilizados para representar essa dinâmica, embora reflitam de forma complexa as interações entre a vegetação e as variáveis climáticas. Parte dessa complexidade está associada à existência de limiares ecohidrológicos, nos quais pequenas variações na precipitação podem desencadear mudanças expressivas na cobertura vegetal. Na Caatinga, por exemplo, reduções de aproximadamente 15% na cobertura vegetal durante períodos secos indicam a presença de limites críticos de sustentação da vegetação (Silva et al., 2025).

A interpretação de índices espectrais pode ser limitada por efeitos de saturação, especialmente em condições de maior densidade de cobertura vegetal, o que dificulta a detecção de variações mais sutis. Nesses casos, a resposta espectral tende a perder sensibilidade, podendo mascarar padrões não lineares entre vegetação e precipitação, como observado em estudos em que o NDVI apresentou correlação significativa com a chuva apenas em períodos específicos (Silva et al., 2025). Soma-se a isso o fato de que a vegetação frequentemente apresenta respostas defasadas ou acumuladas em relação aos eventos de precipitação, com alterações em parâmetros como a profundidade óptica da vegetação (VOD) ocorrendo dias após os eventos de chuva (Gültekin, 2022) e podendo persistir por até dois meses, evidenciando a importância da dimensão temporal nesses estudos (Harris et al., 2022). Adicionalmente, embora a precipitação desempenhe papel central, outros fatores, como temperatura e propriedades do solo, também influenciam significativamente a dinâmica da vegetação, reforçando a necessidade de abordagens integradas para compreender essas relações em ambientes semiáridos (Almeida-Ñauñay et al., 2021).

Apesar dos avanços, a literatura aponta limitações importantes no uso de modelos lineares para descrever a relação entre precipitação e dinâmica da vegetação, sobretudo em ambientes com elevada variabilidade climática. Isso se deve ao fato de que as respostas ecológicas raramente seguem um comportamento linear, sendo influenciadas por múltiplos fatores e por variações sazonais ao longo do tempo. Em geral, esses modelos apresentam associações pouco robustas entre variáveis climáticas e a produtividade da vegetação, dificultando a interpretação dos processos ecológicos envolvidos (Sasaki et al., 2023). Além disso, ao assumirem relações estáticas no espaço, desconsideram variações locais na resposta da vegetação à precipitação (Mallick et al., 2021), bem como os efeitos da duração de anomalias

pluviométricas, que podem gerar respostas acumuladas e não lineares ao longo do tempo (Felton et al., 2021).

Nesse sentido, ainda são pouco exploradas abordagens capazes de representar melhor essa complexidade, como os modelos não lineares, a exemplo dos modelos aditivos generalizados (GAM), que permitem capturar variações mais realistas nas dimensões espacial e temporal (Li et al., 2024). Além disso, mesmo quando aplicados, esses modelos nem sempre incorporam de forma adequada a variabilidade sazonal, fator determinante na dinâmica da vegetação e em sua resposta à precipitação (Zhou et al., 2022). Dessa forma, observa-se uma lacuna na literatura quanto à aplicação integrada de modelos não lineares com abordagens que considerem explicitamente a sazonalidade, limitando uma compreensão mais aprofundada dessas relações em regiões semiáridas.

Diante desse cenário, a integração de dados de sensoriamento remoto e plataformas de processamento em nuvem tem se consolidado como uma alternativa eficiente para o monitoramento ambiental. O uso combinado de imagens do Sentinel-2, dados de precipitação do CHIRPS e a plataforma Google Earth Engine (GEE) possibilita análises em larga escala, com processamento automatizado e sem aumento significativo na demanda por recursos computacionais (Uyar, 2025; Fernandes et al., 2026; "Cálculo de erosão da bacia hidrográfica...", 2025). Além disso, o Sentinel-2 fornece imagens com alta resolução espacial e frequência temporal, permitindo o acompanhamento detalhado da dinâmica da vegetação, enquanto o CHIRPS disponibiliza séries históricas consistentes de precipitação, essenciais para a análise da variabilidade sazonal e interanual (Uyar, 2025; Santana et al., 2025; Gabriel, 2025; Fernandes et al., 2026). Outro aspecto relevante é o baixo custo operacional, uma vez que essas ferramentas são de acesso aberto e reduzem a necessidade de campanhas de campo extensivas (Uyar, 2025; "Cálculo de erosão da bacia hidrográfica...", 2025). Ainda assim, é fundamental considerar limitações associadas à qualidade dos dados e à necessidade de validação em campo, a fim de garantir a confiabilidade das análises.

Diante desse contexto, este estudo tem como objetivo avaliar a relação entre o índice de vegetação ajustado ao solo (SAVI) e a precipitação no semiárido brasileiro, a partir de dados do Sentinel-2 e do CHIRPS processados no Google Earth Engine. Para isso, busca-se comparar o desempenho de modelos de regressão linear, quadrático e cúbico na representação dessa relação, bem como analisar as diferenças entre os períodos seco e chuvoso, visando compreender como a variabilidade sazonal influencia a resposta da vegetação às condições hídricas.

MATERIAL E MÉTODOS

Área de Estudo

A pesquisa foi conduzida no município de Serra Talhada, inserido na Mesorregião do Sertão Pernambucano, Nordeste do Brasil, localizado a aproximadamente 413 km da capital estadual, Recife. O município encontra-se nas coordenadas geográficas 07°59'31" S e 38°17'54" W, com altitude média de 429 m em relação ao nível do mar (Figura 1), estando inserido na bacia hidrográfica do rio Pajeú (APAC, 2024). A área experimental foi estabelecida no distrito de Luanda, pertencente ao município de Serra Talhada, situado a cerca de 41 km da sede municipal.

Segundo a classificação climática de Köppen, o clima da região é do tipo BSh, caracterizado como semiárido quente de baixas latitudes e altitudes, apresentando precipitações concentradas no verão e estação seca durante o inverno (Alvares et al., 2013). De acordo com Silva et al. (2015), a temperatura média anual do ar é de aproximadamente 24,8 °C, enquanto a precipitação média anual corresponde a cerca de 641 mm, concentrando-se principalmente entre

os meses de janeiro e abril, evidenciando a irregularidade temporal das chuvas características do semiárido.




Fig. 1 Localização da área de estudo no distrito de Luanda, município de Serra Talhada, Pernambuco, Brasil, destacando a distribuição espacial dos pontos amostrais utilizados nas análises de precipitação e índice de vegetação.

A vegetação predominante no município é composta pela Caatinga hiperxerófila, bioma de elevada relevância ecológica para a manutenção da biodiversidade regional. O relevo caracteriza-se predominantemente como suave-ondulado, com ocorrência de áreas de Floresta Caducifólia (Carolino et al., 2023; Beltrão, 2005; IBGE, 2024). As principais atividades econômicas desenvolvidas no município incluem agricultura, pecuária, silvicultura, comércio e prestação de serviços (IBGE, 2024; Beltrão, 2005).

Dados utilizados

As análises foram realizadas no ambiente do Google Earth Engine (GEE), utilizando imagens orbitais do satélite Sentinel-2 e dados de precipitação do produto CHIRPS. A área experimental foi delimitada por meio de uma malha espacial contendo os pontos amostrais utilizados para extração das variáveis analisadas. Sentinel-2

Para avaliação da dinâmica da vegetação foi utilizada a coleção *COPERNICUS/S2_SR_HARMONIZED*, disponível no GEE, composta por imagens de reflectância de superfície do Sentinel-2. As imagens apresentam resolução espacial de 10 m nas bandas utilizadas e resolução temporal de aproximadamente 5 dias. Inicialmente, a coleção foi filtrada para a área de estudo e para imagens com percentual de cobertura de nuvens inferior ou igual a 40% ($CLOUDY_PIXEL_PERCENTAGE \leq 40$), visando reduzir interferências atmosféricas e melhorar a qualidade das análises temporais.

A partir das bandas do infravermelho próximo (B8) e vermelho (B4), foi calculado o índice SAVI (*Soil Adjusted Vegetation Index*) (Huete, 1988), utilizando fator de ajuste do solo igual a

0,5. O cálculo foi realizado conforme a equação:

$$SAVI = \frac{NIR - RED}{NIR + RED + L} \times (1 + L)$$

em que:

- *NIR* corresponde à reflectância da banda do infravermelho próximo;
- *Red* corresponde à reflectância da banda do vermelho;
- *L* representa o fator de correção do solo.

A utilização do SAVI foi escolhida por apresentar melhor desempenho em regiões semiáridas e áreas com maior influência de solo exposto, condição característica da área experimental. Diferentemente do NDVI, o SAVI minimiza os efeitos do brilho do solo sobre a resposta espectral da vegetação, permitindo uma representação mais adequada da cobertura vegetal em ambientes com baixa densidade vegetativa (Ahmad, 2012).

CHIRPS

Os dados de precipitação foram obtidos a partir do produto CHIRPS Daily (*Climate Hazards Group InfraRed Precipitation with Station data*), disponível no GEE. O conjunto possui resolução espacial aproximada de 0,05° (~5 km) e cobertura temporal diária.

O CHIRPS foi utilizado por apresentar boa consistência em estudos hidrológicos e climáticos, especialmente em regiões semiáridas e em áreas com baixa densidade de estações pluviométricas. Além disso, o produto integra dados de satélite, observações de superfície e informações derivadas de infravermelho, o que proporciona maior continuidade espacial e temporal das séries de precipitação. Esse conjunto de características permite que o CHIRPS represente de forma eficiente a variabilidade espacial da precipitação, evidenciando padrões e tendências relevantes em diferentes biomas do Brasil (Uliana et al., 2024).

Processamento no Google Earth Engine

O processamento das imagens e a extração das variáveis foram realizados integralmente no GEE. Após o cálculo do SAVI, foram geradas composições mensais por meio da média das imagens disponíveis em cada mês entre os anos de 2019 e 2025.

Para cada mês analisado, as imagens do Sentinel-2 foram filtradas temporalmente e submetidas ao cálculo do SAVI. Em seguida, foi aplicada a média dos pixels da coleção mensal, resultando em imagens representativas das condições médias de cada período.

Os valores de SAVI foram extraídos nos pontos pertencentes à malha experimental utilizando a função *sampleRegions*, com resolução espacial de 10 m. Para cada ponto amostral foram associados os atributos de ano, mês e período sazonal correspondente.

Posteriormente, os dados foram exportados em formato CSV para análises estatísticas e integração com as variáveis pluviométricas.

Para os dados de precipitação, foram selecionadas as imagens diárias do CHIRPS correspondentes às mesmas datas das imagens utilizadas no cálculo do SAVI, permitindo o alinhamento temporal entre as variáveis de vegetação e chuva. A precipitação média foi calculada para a área experimental por meio do redutor de média espacial (*Reducer.mean*).

Além disso, também foram geradas médias diárias de precipitação para os períodos seco e chuvoso entre 2019 e 2025, com extração dos valores nos pontos amostrais da malha experimental.

Estratificação sazonal

A estratificação sazonal foi realizada considerando o comportamento climático característico do semiárido pernambucano, especialmente para o município de Serra Talhada.

Foram definidos como:

- período chuvoso: meses de janeiro a abril;
- Período seco: meses de agosto a novembro.

A separação sazonal foi aplicada tanto para os dados de SAVI quanto para os dados de precipitação, permitindo avaliar as diferenças da resposta da vegetação sob distintas condições hídricas ao longo dos anos analisados.

Além das análises mensais, também foram geradas imagens médias representativas dos períodos seco e chuvoso entre 2019 e 2025, possibilitando a comparação espacial das condições médias de cobertura vegetal entre as estações.

O fluxograma (Figura 2) apresenta de forma resumida as etapas metodológicas adotadas no estudo, desde a aquisição dos dados orbitais e pluviométricos até a geração das séries temporais e produtos finais. Inicialmente, foram realizadas as etapas de filtragem e pré-processamento das imagens Sentinel-2, incluindo o cálculo do índice SAVI e a geração das composições mensais. Em seguida, os valores foram extraídos nos pontos pertencentes à malha experimental, permitindo a integração com os dados de precipitação do CHIRPS alinhados temporalmente às datas das imagens utilizadas. Posteriormente, os dados foram organizados conforme a sazonalidade regional, considerando os períodos seco e chuvoso característicos do semiárido pernambucano, possibilitando a comparação espacial e temporal das variáveis analisadas.

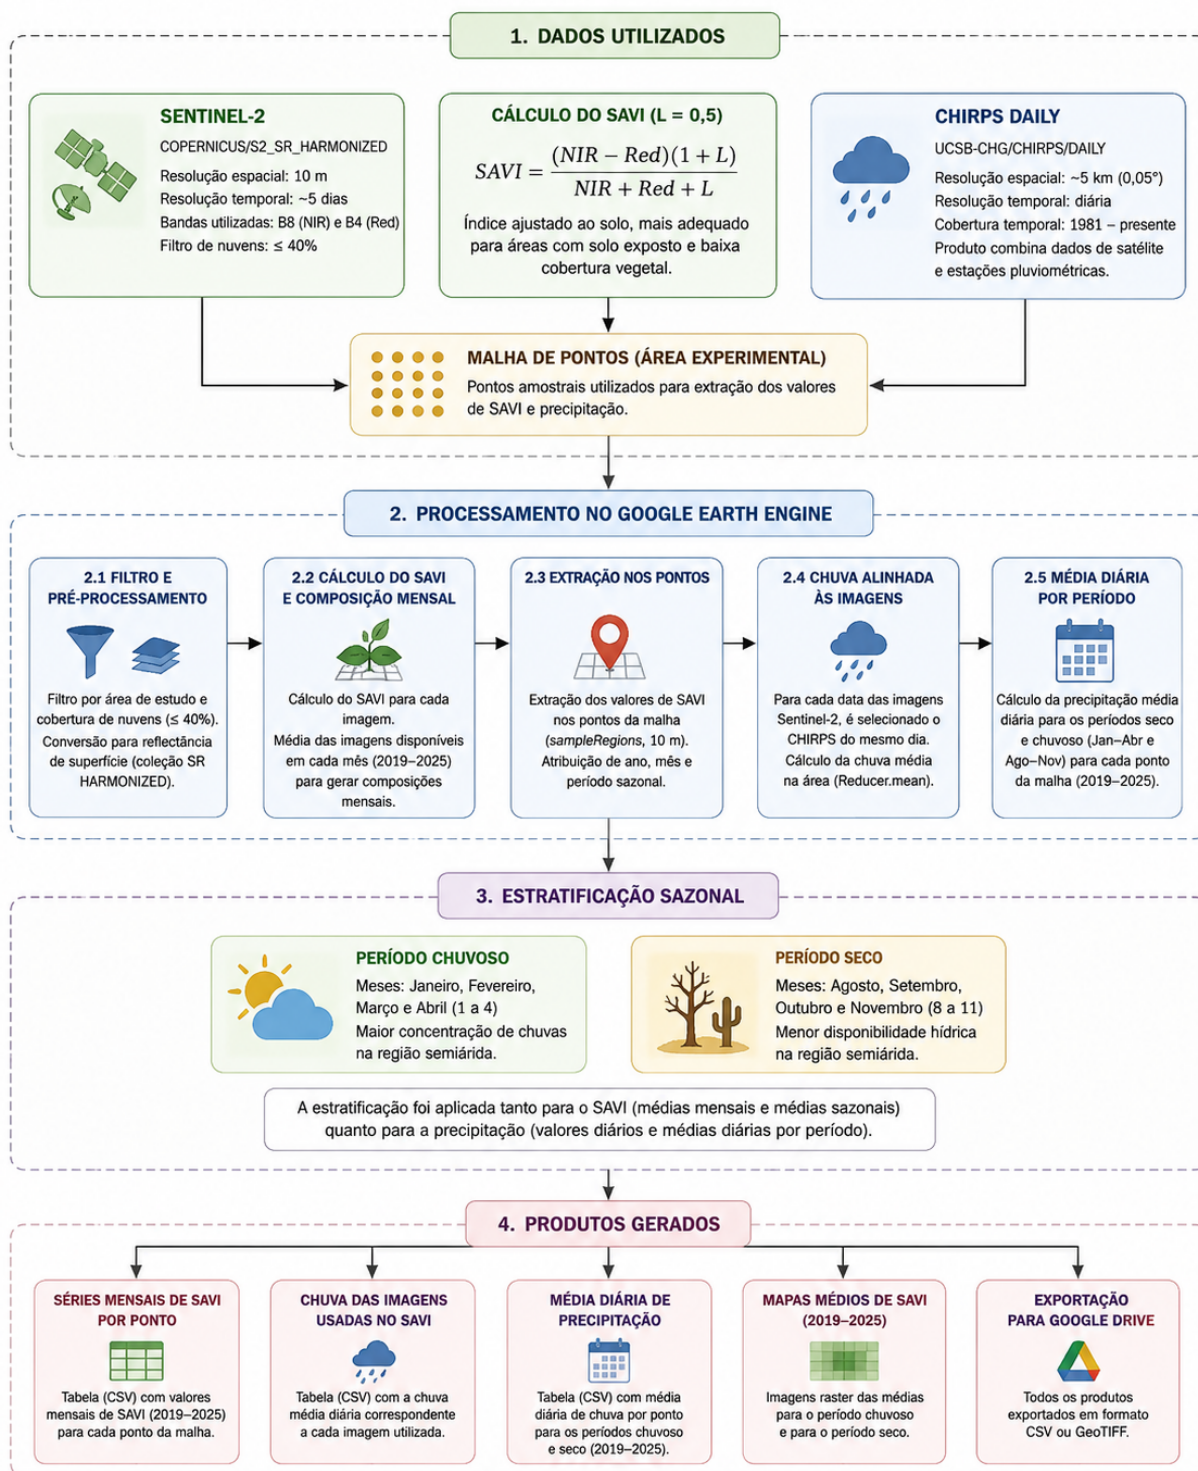


Fig 2 Fluxograma metodológico das etapas de aquisição, processamento e extração dos dados de SAVI e precipitação no ambiente do Google Earth Engine, utilizando imagens do Sentinel-2 e dados pluviométricos do CHIRPS para o período de 2019 a 2025.

Foram realizadas regressões linear, quadrática e cúbica para determinar a correlação existente entre o índice espectral (SAVI) e a lâmina precipitada. As regressões foram aplicadas de forma individualizada para cada ponto da área de estudo, mantendo-se a lâmina precipitada, uma vez que não houve variação espacial das chuvas.

Para a determinação das equações de regressão foi aplicado o método dos mínimos quadrados para minimização de erros residuais. Desta forma, aplicando-se a uma equação linear (eq.1) têm-se que:

$$e = y - a_0 - a_1 \cdot x \quad (\text{eq.1})$$

Em que e é o erro residual associado

Aplicando-se o método dos mínimos quadrados e observando-se a soma dos quadrados para determinação da soma dos resíduos (eq.2) é realizada a derivação em relação a cada coeficiente (eq.3).

$$Sr = \sum_{i=1}^n e_i^2 = \sum_{i=1}^n (y_{\text{estimado}} - y_{\text{observado}})^2 = \sum_{i=1}^n (y_i - a_0 - a_1 \cdot x)^2 \quad (\text{eq.2})$$

$$\frac{\partial Sr}{\partial a_0} \text{ e } \frac{\partial Sr}{\partial a_1} \quad (\text{eq.3})$$

Desta forma, obtém-se equações possíveis de serem transformadas em matrizes (eq.3). A partir da inversão da matriz A é possível determinar os coeficientes da equação (eq.4).

$$[A] \times [Z] = [B] \quad (\text{eq.4})$$

$$[Z] = [A]^{-1} \times [B] \quad (\text{eq.5})$$

Obtidos os coeficientes, é possível determinar os valores estimados da variável dependente aplicando-se novamente na equação original (eq.6) e determinar o coeficiente de determinação (eq.7) e coeficiente de determinação ajustado (eq.8) a partir da variabilidade explicada (eq.9) e variabilidade total (eq.10) dos dados.

$$\hat{y} = a_0 + a_1 \cdot x \quad (\text{eq.6})$$

$$R^2 = \frac{VE}{VT} \quad (\text{eq.7})$$

$$R^2_{\text{ajustado}} = 1 - \frac{(1 - R^2) * (n - 1)}{n - p - 1} \quad (\text{eq.8})$$

$$VE = \sum_{i=1}^n (\hat{y} - \bar{y})^2 \quad (\text{eq.9})$$

$$VT = \sum_{i=1}^n (y - \bar{y})^2 \quad (\text{eq.10})$$

em que: $\hat{y}$ = Valor estimado da variável dependente; $\bar{y}$ = Média da variável dependente; y = Valor observado da variável dependente; n = número de amostras; p = quantidade de variáveis independentes.

Dessa forma o mesmo procedimento metodológico foi aplicado para todas as regressões. O algoritmo foi escrito utilizando a linguagem de programação Python v.3.13.7 e a biblioteca Numpy v.2.4.2.

RESULTADOS E DISCUSSÃO

Conforme apresentado na Tabela 1, os modelos de regressão linear simples, quadrática e cúbica apresentaram desempenhos distintos na estimativa do SAVI a partir dos dados de precipitação obtidos pelo CHIRPS, considerando os 50 pontos amostrais analisados no período de 2019 a 2025.

Tabela 1 Métricas para os modelos de regressão

	Simples					Quadrático					Cúbico				
	R2	R2a	MAE	MSE	RMSE	R2	R2a	MAE	MSE	RMSE	R2	R2a	MAE	MSE	RMSE
Máximo	0.37	0.25	0.06	0.00	0.07	0.49	0.39	0.05	0.00	0.06	0.95	0.94	0.04	0.00	0.05
Média	0.091	-0.182	0.037	0.00	0.048	0.183	0.020	0.034	0.00	0.044	0.57	0.49	0.022	0.00	0.03
Mediana	0.065	-0.125	0.04	0.00	0.05	0.145	-0.025	0.04	0.00	0.045	0.58	0.49	0.02	0.00	0.03
Mínimo	0.00	-0.2	0.004	0.00	0.01	0.03	-0.16	0.01	0.00	0.01	0.07	-0.11	0.01	0.00	0.01

De forma geral, os resultados indicam que a relação entre precipitação e vigor vegetativo apresenta comportamento não linear, sendo mais bem representada por modelos polinomiais de terceira ordem. O modelo cúbico apresentou o melhor desempenho, com R^2 médio de 0,57, quando comparado aos modelos quadrático (0,183) e linear (0,091). Além disso, também apresentou os menores erros de predição, com MAE = 0,022 e RMSE = 0,030, indicando maior capacidade de representar a resposta da vegetação às variações de precipitação. Os valores de R^2 variaram entre 0,07 e 0,95, evidenciando elevada heterogeneidade espacial e temporal na relação entre precipitação e SAVI ao longo dos pontos e períodos analisados.

Essa superioridade dos modelos de ordem superior é demonstrada na literatura, que identifica os modelos polinomiais cúbicos como ferramentas de melhor desempenho para capturar relações entre índices de vegetação e parâmetros biofísicos. A baixa correlação linear apresentada para o SAVI também foi observada por Olmos-Trujillo et al (2020), que utilizaram Regressões lineares de mínimos quadrados ponderados baseadas em incerteza para correlacionar temperatura e precipitação com o SAVI e identificar diferentes superfícies de uso e ocupação do solo, alcançando regressões com coeficientes de determinação (R^2) na ordem de 0.013 a 0.193, sendo os maiores resultados com lag de um mês.

Observa-se ainda na Tabela 1 que os valores máximos de R^2 aumentaram progressivamente entre os modelos, passando de 0,37 na regressão linear, para 0,49 na regressão quadrática e atingindo 0,95 na regressão cúbica. Da mesma forma, os valores mínimos variaram entre 0,00 e 0,07, reforçando a forte variabilidade espacial e temporal na resposta do SAVI às condições pluviométricas. Essa variabilidade sugere que, além da precipitação, outros fatores ambientais, como a temperatura, também influenciam o comportamento do índice (Olmos-Trujillo et al., 2020), assim como características da cobertura vegetal, propriedades do solo, disponibilidade hídrica antecedente, condições climáticas locais e possíveis defasagens temporais entre a ocorrência da chuva e a resposta espectral da vegetação.

A Tabela 2 apresenta os melhores modelos ajustados para cada período sazonal. Para o período chuvoso, o modelo cúbico apresentou o melhor desempenho, descrito pela equação ajustada, alcançando $R^2 = 0,95$ e R^2 ajustado = 0,94, além dos menores erros de estimativa (MAE = 0,013; RMSE = 0,0154). Esse resultado indica que aproximadamente 95% da variabilidade do SAVI pode ser explicada pela precipitação durante a estação chuvosa, evidenciando a forte dependência da dinâmica da vegetação em relação à disponibilidade hídrica nesse período, quando a precipitação atua como um dos principais fatores condicionantes do vigor vegetativo. Silva Júnior et al. (2025) destacam que o vigor da vegetação da Caatinga está diretamente relacionado aos padrões de precipitação, com mudanças significativas entre as estações chuvosa e seca, destacando a sazonalidade e sensibilidade da vegetação da Caatinga.

Tabela 2 Melhores modelos de regressão para os períodos chuvoso e seco e métricas de avaliação

Período	Regressão	Modelo	R ²	R ² _A	MAE	MSE	RMSE
Chuvoso	Simple	$SAVI = -0.0134 \times P + 0.6295$	0.37	0.25	0.0181	0.0005	0.0231
	Quadrático	$SAVI = -0.0173 \times P^2 + 0.1868 \times P - 0.0366$	0.49	0.39	0.0339	0.0017	0.0415
	Cúbico	$SAVI = 0.0277 \times P^3 - 0.4304 \times P^2 + 2.1162 \times P - 2.7781$	0.95	0.94	0.013	0.0002	0.0154
Seco	Simple	$SAVI = 0.0922 \times P + 0.1456$	0.37	0.25	0.0171	0.00045	0.0212
	Quadrático	$SAVI = 0.3195 \times P^2 - 0.2432 \times P + 0.2199$	0.52	0.43	0.0137	0.00034	0.0185
	Cúbico	$SAVI = -2.611 \times P^3 + 4.1182 \times P^2 - 1.8723 \times P + 0.4291$	0.62	0.55	0.0126	0.00027	0.0164

Para o período seco, o modelo cúbico também apresentou o melhor ajuste, com R² = 0,62 e R² ajustado = 0,55, além de baixos erros (MAE = 0,0126; RMSE = 0,0164). Embora o desempenho seja inferior ao observado no período chuvoso, os resultados ainda indicam influência da precipitação sobre o SAVI. No entanto, a redução do poder explicativo sugere que outros fatores passam a exercer maior controle sobre a dinâmica da vegetação durante a estação seca, como a umidade residual do solo, a capacidade de armazenamento hídrico da cobertura vegetal e mecanismos fisiológicos de adaptação ao déficit hídrico.

Os resultados das regressões realizadas para os 50 pontos com pior ajuste evidenciam uma fraca relação entre precipitação e SAVI em ambos os períodos (Tabela 2). Os coeficientes de determinação variaram de 0,00 a 0,07 no período chuvoso e de 0,00 a 0,10 no período seco, indicando que a precipitação foi capaz de explicar, no máximo, cerca de 10% da variabilidade do índice nesses locais.

Tabela 3 Piores modelos de regressão para os períodos chuvoso e seco e métricas de avaliação

Período	Regressão	Modelo	R ²	R ² _A	MAE	MSE	RMSE
Chuvoso	Simple	$SAVI = -0.00037 \times P + 0.5284$	0	-0.2	0.043	0.0025	0.0496
	Quadrático	$SAVI = 0.0003 \times P^2 - 0.0063 \times P + 0.5379$	0.03	-0.16	0.0211	0.0007	0.027
	Cúbico	$SAVI = -0.0025 \times P^3 + 0.0391 \times P^2 - 0.1982 \times P + 0.8559$	0.07	-0.11	0.0204	0.0008	0.0288
Seco	Simple	$SAVI = 0.0106 \times P + 0.2676$	0	-0.2	0.0351	0.0018	0.0419
	Quadrático	$SAVI = 0.1548 \times P^2 - 0.1729 \times P + 0.2991$	0.03	-0.17	0.0209	0.001	0.0321
	Cúbico	$SAVI = -1.4039 \times P^3 + 2.1203 \times P^2 - 0.9662 \times P + 0.3063$	0.1	-0.08	0.0106	0.0003	0.016

No período chuvoso, o modelo linear apresentou desempenho praticamente nulo (R² = 0,00), com MAE de 0,043 e RMSE de 0,0496. A introdução de termos polinomiais resultou apenas em pequenas melhorias, elevando o R² para 0,03 no modelo quadrático e 0,07 no modelo cúbico. Apesar da redução dos erros (MAE = 0,0204 e RMSE = 0,0288 no modelo cúbico), os valores negativos de R² ajustado (entre -0,11 e -0,20) indicam baixa capacidade explicativa dos modelos.

No período seco, observou-se comportamento semelhante, com R² igual a 0,00 no modelo linear e valores de 0,03 e 0,10 nos modelos quadrático e cúbico, respectivamente. Embora o modelo cúbico tenha apresentado os menores erros entre os ajustes avaliados (MAE = 0,0106; MSE = 0,0003; RMSE = 0,016), o baixo R² e o R² ajustado ainda negativo (-0,08) reforçam que a precipitação isoladamente não é suficiente para explicar as variações do SAVI nesses pontos.

De modo geral, esses resultados indicam que as áreas com pior desempenho apresentam baixa sensibilidade da vegetação às variações da precipitação ou forte influência de

outros fatores ambientais não incorporados ao modelo, como características do solo, tipo de cobertura vegetal, uso e ocupação da terra, disponibilidade hídrica antecedente, profundidade radicular e possíveis defasagens temporais entre chuva e resposta espectral. Assim, a precipitação isolada se mostra insuficiente para modelar adequadamente a dinâmica do SAVI nesses locais, especialmente diante dos baixos coeficientes de determinação observados.

Contudo, estes efeitos de sazonalidade são citados na literatura, como demonstrado por Ji e Peters (2003), que, ao tentar correlacionar o NDVI com o índice de seca SPI, observaram os efeitos de sazonalidade nos resultados e que modelos de regressão simples forneceram estimativas fracas para a correlação do NDVI com o SPI. Os autores concluem que a sazonalidade relacionada a índices espectrais deve ser um fator importante para a tomada de decisão.




Fig. 4 Scatter plot 1:1 para os modelos lineares (a), quadráticos (b) e cúbicos (c) para o período chuvoso e para modelos lineares (d), quadráticos (e) e cúbicos (f) para o período seco

A análise dos gráficos de dispersão demonstra que os modelos lineares apresentaram maior dispersão dos pontos em relação à reta de referência (1:1), indicando menor precisão na estimativa do SAVI. Por outro lado, os modelos cúbicos demonstraram melhor ajuste, caracterizado pela menor dispersão dos dados e maior proximidade entre valores observados e estimados. Observou-se também que os modelos desenvolvidos para o período seco exibiram maior variabilidade quando comparados aos do período chuvoso, o que pode estar relacionado à maior heterogeneidade das condições da vegetação e à influência mais acentuada do solo sobre a resposta espectral nesse período. Em condições de seca, a exposição do solo torna-se um fator crítico que afeta a variabilidade dos índices espectrais (Rodrigues et al., 2020).

A correlação entre índices espectrais e precipitação é destacada por Safa et al. (2021) que observou a correlação direta entre a maioria dos índices espectrais com a precipitação, posto que com o aumento da precipitação, ocorre aumento do índice e vice-versa. Os autores observaram ainda o SAVI como índice com alta variabilidade, dentre os observados.

Limitações

Embora os resultados permitam analisar a dinâmica da cobertura vegetal por meio do SAVI e sua relação com a precipitação, algumas limitações metodológicas devem ser consideradas. A análise climática foi baseada exclusivamente na precipitação do produto CHIRPS, sem a inclusão de outras variáveis meteorológicas relevantes para os processos ecofisiológicos da vegetação, como temperatura do ar, radiação solar, umidade relativa, evapotranspiração e vento. Dessa forma, a utilização de uma única variável climática limita a representação da complexidade das interações entre clima e vegetação.

Outra limitação importante refere-se à ausência de variáveis edáficas, como textura,

profundidade do solo, matéria orgânica e capacidade de retenção de água, que influenciam diretamente a disponibilidade hídrica e a resposta da vegetação às chuvas, podendo gerar comportamentos distintos sob condições pluviométricas semelhantes.

Também há incertezas relacionadas à resolução espacial dos dados. As imagens Sentinel-2 (10 m) permitem bom detalhamento da cobertura vegetal, porém a área de estudo (~2 ha) ainda é representada por poucos pixels. Em contraste, o CHIRPS (~5 km) possui escala muito mais grosseira, sendo que um único pixel representa uma área muito maior que a área experimental, o que pode não captar a variabilidade local da precipitação, especialmente em eventos convectivos.

Além disso, ambos os produtos possuem incertezas inerentes aos seus processos de aquisição e processamento, como efeitos atmosféricos e presença de nuvens no Sentinel-2, e a natureza indireta da estimativa de precipitação no CHIRPS. A agregação temporal dos dados também pode suavizar eventos extremos de curta duração, relevantes para a dinâmica da vegetação em ambientes semiáridos.

Apesar dessas limitações, os resultados são relevantes por evidenciarem a relação entre precipitação e resposta espectral da vegetação em ambiente semiárido, além de mostrar a presença de comportamentos não lineares. O estudo reforça o potencial do sensoriamento remoto para o monitoramento da cobertura vegetal em regiões com restrição de dados, contribuindo para análises ecohidrológicas e servindo como base para estudos futuros com maior número de variáveis e melhor integração multiescalar.

Implicações na Agricultura

As implicações deste estudo para a agricultura em regiões semiáridas estão diretamente relacionadas ao entendimento da dinâmica entre precipitação e resposta espectral da vegetação, representada pelo SAVI. Os resultados indicam que a vegetação não responde de forma linear à variabilidade pluviométrica, o que reforça a necessidade de abordagens mais refinadas no monitoramento agrícola, especialmente em sistemas de produção dependentes de chuva.

O uso de sensoriamento remoto se mostra uma ferramenta estratégica para o acompanhamento da variabilidade espacial e temporal da vegetação, permitindo identificar áreas com maior ou menor resposta à precipitação. Essas informações podem subsidiar o manejo agrícola, auxiliando na definição de épocas de plantio, no monitoramento do estresse hídrico e na avaliação da eficiência do uso da água em sistemas produtivos.

Além disso, a heterogeneidade observada na relação entre precipitação e SAVI evidencia que fatores locais, como propriedades do solo e disponibilidade hídrica residual, exercem papel fundamental na produtividade agrícola. Assim, estratégias de manejo no semiárido devem considerar não apenas a precipitação, mas também as condições edáficas e a capacidade de retenção de água do solo, visando aumentar a resiliência dos sistemas agrícolas frente à variabilidade climática.

Dessa forma, os resultados reforçam a importância da integração entre dados climáticos, sensoriamento remoto e informações de solo como suporte à agricultura de precisão no semiárido, contribuindo para decisões mais eficientes e sustentáveis em um cenário de elevada incerteza climática.

CONCLUSÕES

As análises indicaram a existência de uma relação não linear entre a precipitação e o SAVI ao longo do período estudado, sendo o modelo cúbico o mais adequado para representar essa dinâmica, com melhor desempenho estatístico com base no R^2 ajustado.

Os resultados também evidenciaram que a influência da precipitação sobre a resposta da vegetação é mais expressiva durante a estação chuvosa, quando o índice SAVI apresenta maior dependência das variações pluviométricas, enquanto no período seco essa relação se torna mais limitada.

Além disso, a variabilidade observada entre os pontos amostrais reforça que a precipitação, isoladamente, não explica completamente a dinâmica da vegetação, indicando a necessidade de modelos multivariados que incorporem variáveis climáticas e edáficas para uma representação mais robusta dos processos ecohidrológicos no semiárido.

AGRADECIMENTOS

Os autores agradecem à Universidade Federal Rural de Pernambuco (UFRPE) pelo suporte institucional disponibilizado para o desenvolvimento desta pesquisa. Agradecem à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e à Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco (FACEPE) pelo apoio financeiro e pela concessão de bolsas que contribuíram para a realização deste trabalho. Os autores também agradecem à Netcon Americas e ao Scinet Institute pelo apoio.

REFERÊNCIAS

- Ahmad, F. (2012). Spectral vegetation indices performance evaluated for Cholistan Desert. *Journal of Geography and Regional Planning*, 5(6), 165–172. doi:10.5897/JGRP11.098
- Almeida, F. F. A. de, Sales Filho, R. L. M., Souza, W. M. de, & Galvêncio, J. D. (2023). Vulnerabilidade ambiental e socioeconômica aos eventos extremos de precipitação relacionados a seca no semiárido nordestino – Estudo de caso da Bacia Hidrográfica de Terra Nova – Pernambuco, Brasil. *Revista Brasileira de Geografia Física*, 16(3), 1490. doi:10.26848/rbgf.v16.3.p1490-1510
- Almeida-Ñauñay, A. F., Benito, R. M., Quemada, M., Losada, J. C., & Tarquis, A. M. (2021). The vegetation-climate system complexity through recurrence analysis. *Entropy*, 23(5), 559. doi:10.3390/E23050559
- Cálculo de erosão da bacia hidrográfica do curu, ceará usando google earth engine. (2025). *Zenodo Repository*. doi:10.5281/zenodo.15041454
- da Silva, U. J., da Costa, M. O., da Silva, J. A., Roberto, J., de Paiva, A. L. R., dos Santos, S. M., et al. (2025). Impact of precipitation fluctuations on vegetation dynamics: a spatiotemporal remote sensing analysis in pernambuco's semi-arid region, brazil. *Caminhos de Geografia*, 26(106), 88–109. doi:10.14393/rcg2610676114
- de São José, R. V., Coltri, P. P., Greco, R., de Souza, I. S., & de Souza, A. P. C. (2022). Hazard (seca) no semiárido da Bahia: Vulnerabilidades e Riscos climáticos. *Revista Brasileira de Geografia Física*, 15(4), 1978. doi:10.26848/rbgf.v15.4.p1978-1993
- Felton, A. J., Knapp, A. K., & Smith, M. D. (2021). Precipitation-productivity relationships and the duration of precipitation anomalies: An underappreciated dimension of climate change. *Global Change Biology*, 27(6), 1127–1140. doi:10.1111/GCB.15480
- Gültekin, A. (2022). Satellite-Observed Vegetation Responses to Intraseasonal Precipitation Variability. *Geophysical Research Letters*, 49(15). doi:10.1029/2022gl099635
- Harris, B. L., Taylor, C. M., Weedon, G. P., Talib, J., Dorigo, W., & van der Schalie, R. (2022). Satellite-Observed Vegetation Responses to Intraseasonal Precipitation Variability. *Geophysical Research Letters*, 49. doi:10.1029/2022GL099635

- Huete, A. R. (1988). A soil-adjusted vegetation index (SAVI). *Remote Sensing of Environment*, 25(3), 295–309.
- Ji, L., & Peters, A. J. (2003). Assessing vegetation response to drought in the northern Great Plains using vegetation and drought indices. *Remote Sensing of Environment*, 87(1), 85–98. doi:10.1016/S0034-4257(03)00174-3
- Li, Q., Yan, A., Chang, S., & Lo, K. (2024). Nonlinear time effects of vegetation response to climate change: Evidence from Qilian Mountain National Park in China. *Science of The Total Environment*. doi:10.1016/j.scitotenv.2024.173149
- Mallick, J., Almesfer, M. K., Singh, V. P., Falqi, I. I., Singh, C. K., Alsubih, M., et al. (2021). Evaluating the NDVI–Rainfall Relationship in Bisha Watershed, Saudi Arabia Using Non-Stationary Modeling Technique. *Atmosphere*, 12(5), 593. doi:10.3390/ATMOS12050593
- Oliveira, L. C., de Moura, J. A. G., Pereira, A. L., Neto, A. S., Pacheco, C. S. G. R., Neto, M., et al. (2023). *Mudanças climáticas e potenciais impactos negativos no bioma caatinga, semiárido brasileiro* (pp. 263–275). Editora Científica Digital. doi:10.37885/230613554
- Olmos-Trujillo, E., González-Trinidad, J., Júnez-Ferreira, H., Pacheco-Guerrero, A., Bautista-Capetillo, C., Avila-Sandoval, C., et al. (2020). Spatio-Temporal Response of Vegetation Indices to Rainfall and Temperature in A Semiarid Region. *Sustainability*, 12, 1939. doi:10.3390/su12051939
- Pereira, G. (2025). *Variabilidade climática e resposta da vegetação na bacia hidrográfica do rio são francisco (2000-2024) utilizando sensoriamento remoto*. doi:10.5281/zenodo.17230208
- Rodrigues, J. A. de M., Lopes, P. M. O., Silva, J. L. B. da, Araújo, H. L., Silva, M. V. da, Santos, A. dos, et al. (2020). Spatial-temporal dynamics of Caatinga vegetation cover by remote sensing in the Brazilian semiarid region. *Dyna*, 87(215), 109–117. doi:10.15446/DYNA.V87N215.87851
- Safa, M., Zarkesh, M. K., Ejlali, F., & Farsad, F. (2021). The spatial autocorrelation between precipitation and vegetation indices in the Bandar Abbas Basin. *International Journal of Scientific Research and Management*, 9(12). doi:10.18535/ijssrm/v9i12.fe1
- Santana, C. R. de, Guasselli, L. A., Cristiane, C., & Belloli, T. F. (2025). Seasonal and Hydroclimatic Dynamics in Wetlands Using Spectral Indices and Water Balance in Different Geomorphological Units. *Research Square Preprint*. doi:10.21203/rs.3.rs-6331096/v1
- Sasaki, T., Collins, S. L., Rudgers, J. A., Batdelger, G., Baasandai, E., & Kinugasa, T. (2023). Dryland sensitivity to climate change and variability using nonlinear dynamics. *Proceedings of the National Academy of Sciences of the United States of America*, 120. doi:10.1073/pnas.2305050120
- Uliana, E. M., Sousa, M. F. de, Araújo, J. de a., Aires, U. R. V., Silva, D. D. da, Zanuzo, M. R., et al. (2024). Validação e análise espaço-temporal de dados de precipitação obtidos por sensoriamento remoto CHIRPS para o estado de Mato Grosso, Brasil. *Revista Brasileira de Climatologia*, 35, 630–654. doi:10.55761/abclima.v35i20.18858
- Uyar, N. (2025). Prediction in Terrestrial and Aquatic Ecosystems Using Sentinel-2, Landsat 8, and MODIS Data: An Integrated Approach through Google Earth Engine. *International Journal of Environment and Geoinformatics*, 12(3), 251–262. doi:10.26650/ijgeo.1566123
- Zhou, Z. Y., Ding, Y., Fu, Q., Wang, C., Wang, Y., Cai, H., et al. (2022). Comprehensive evaluation of vegetation responses to meteorological drought from both linear and nonlinear perspectives. *Frontiers in Earth Science*, 10. doi:10.3389/feart.2022.953805