



**UNIVERSIDADE ESTADUAL DA PARAÍBA
CAMPUS V
CENTRO DE CIÊNCIAS BIOLÓGICAS E SOCIAIS APLICADA
DEPARTAMENTO DE CIÊNCIAS BIOLÓGICAS
CURSO DE BACHARELADO EM CIÊNCIAS BIOLÓGICAS**

DAYANA ALMEIDA DE SOUZA

**ESTIMANDO A PRODUTIVIDADE PRIMÁRIA BRUTA NO CARIRI PARAIBANO
ATRAVÉS DE SENSORIAMENTO REMOTO**

**JOÃO PESSOA
2024**

DAYANA ALMEIDA DE SOUZA

**ESTIMANDO A PRODUTIVIDADE PRIMÁRIA BRUTA NO CARIRI PARAIBANO
ATRAVÉS DE SENSORIAMENTO REMOTO**

Trabalho de Conclusão de Curso (Artigo) apresentado a Coordenação do Curso de Ciências Biológicas Bacharelado da Universidade Estadual da Paraíba, como requisito parcial à obtenção do título de Bacharel em Ciências Biológicas.

Área de concentração: Geociências

Orientador: Profa. Dra. Célia Cristina Clemente Machado.

JOÃO PESSOA

2024

É expressamente proibida a comercialização deste documento, tanto em versão impressa como eletrônica. Sua reprodução total ou parcial é permitida exclusivamente para fins acadêmicos e científicos, desde que, na reprodução, figure a identificação do autor, título, instituição e ano do trabalho.

S729e Souza, Dayana Almeida de.

Estimando a produtividade primária bruta no cariri paraibano através de sensoriamento remoto [manuscrito] / Dayana Almeida de Souza. - 2024.
30 f. : il. color.

Digitado.

Trabalho de Conclusão de Curso (Graduação em Ciências biológicas) - Universidade Estadual da Paraíba, Centro de Ciências Biológicas e Sociais Aplicadas, 2024.

"Orientação : Prof. Dra. Célia Cristina Clemente Machado, Coordenação do Curso de Ciências Biológicas - CCBSA".

1. Sensoriamento remoto. 2. Produtividade primária bruta.
3. Sentinel-2A. 4. Caatinga. 5. Cariri paraibano. I. Título

21. ed. CDD 551.1

DAYANA ALMEIDA DE SOUZA

ESTIMANDO A PRODUTIVIDADE PRIMÁRIA BRUTA NO CARIRI PARAIBANO
ATRAVÉS DE SENSORIAMENTO REMOTO

Trabalho de Conclusão de Curso
apresentado à Coordenação do Curso
de Ciências Biológicas da Universidade
Estadual da Paraíba, como requisito
parcial à obtenção do título de
Bacharela em Ciências Biológicas

Aprovada em: 21/11/2024.

Documento assinado eletronicamente por:

- **Cleber Ibraim Salimon** (***.493.788-**), em **05/12/2024 14:29:50** com chave **87e1659ab32e11ef8a042618257239a1**.
- **Nyedja Fialho Morais Barbosa** (***.062.864-**), em **05/12/2024 14:56:00** com chave **2ffc2cbcb33211efbb041a1c3150b54b**.
- **Célia Cristina Clemente Machado** (***.425.594-**), em **06/12/2024 07:38:05** com chave **2d469764b3be11efbaba1a7cc27eb1f9**.

Documento emitido pelo SUAP. Para comprovar sua autenticidade, faça a leitura do QrCode ao lado ou acesse https://suap.uepb.edu.br/comum/autenticar_documento/ e informe os dados a seguir.

Tipo de Documento: Termo de Aprovação de Projeto Final

Data da Emissão: 06/12/2024

Código de Autenticação: 09c8c4



A quem ainda continua aqui, DEDICO.

SUMÁRIO

1	INTRODUÇÃO	06
2	METODOLOGIA	10
2.1	Área de estudo	10
2.2	Obtenção dos dados e processamento da imagem segundo modelo LUE.....	11
2.3	Análises estatísticas: comparação do PPB-sentinel, índices de vegetação e reflectâncias simples com o produto PPB- MODIS.....	15
3	RESULTADOS E DISCUSSÃO	17
4	CONCLUSÃO	22
5	REFERÊNCIAS	23
	ANEXO	29

ESTIMANDO A PRODUTIVIDADE PRIMÁRIA BRUTA NO CARIRI PARAIBANO ATRAVÉS DE SENSORIAMENTO REMOTO

Dayana Almeida de Souza*

RESUMO

As crescentes preocupações com as consequências das mudanças climáticas, principalmente em regiões semiáridas, como a Caatinga, mais suscetíveis à desertificação e perda de biomassa verde, incentivam a medições mais detalhadas de variáveis biofísicas e bioquímicas da vegetação como a Produtividade Primária Bruta (PPB). PPB é um importante indicador da produtividade dos ecossistemas terrestres, representando o CO₂ absorvido pelas plantas para produção de matéria orgânica. Dessa forma, a medição da PPB torna-se um indicador-chave para monitorar a degradação do ecossistema Caatinga e o risco de desertificação. Assim, este trabalho teve o objetivo de testar a aplicabilidade do modelo da eficiência no uso da LUZ (LUE) para estimar a PPB no Cariri Paraibano, uma área de Caatinga, utilizando produtos do satélite Sentinel-2A com resolução de 10m, comparando com o produto obtido com o PPB do satélite MODIS. Com este também foi comparado alguns índices de vegetação, o índice de vegetação por diferença normalizada (NDVI), o índice de vegetação ajustado ao solo (SAVI) e o índice de vegetação melhorado (EVI) e as reflectâncias nas bandas do visível e infravermelho próximo, de forma a avaliar se as simples reflectâncias de ondas curtas ou suas associações através de índices se aproximariam dos valores de PPB. Os resultados do modelo de regressão aditiva (GAM) mostram que o PPB derivado do LUE, a partir da imagem do Sentinel-2A, explica 46% da variabilidade dos dados de PPB do MODIS, já o EVI explica 58%. O melhor desempenho do EVI pode estar ligado à sua maior capacidade de resposta em ambientes com alta variabilidade de vegetação e relevo, além de semelhanças nas correções atmosféricas aplicadas tanto no MODIS quanto no EVI. Portanto, os resultados indicam que é possível mapear o PPB na Caatinga de forma simples, objetiva e com uma boa aplicabilidade relacionada ao ambiente Caatinga.

Palavras-Chave: Sensoriamento remoto, produtividade primária bruta, Sentinel-2A, caatinga, cariri paraibano.

* Aluna do Curso de Ciências Biológicas - Bacharelado CCBSA/UEPB

ABSTRACT

Growing concerns about the consequences of climate change, especially in semiarid regions such as the Caatinga, which are more susceptible to desertification and loss of green biomass, encourage more detailed measurements of biophysical and biochemical variables of vegetation such as Gross Primary Productivity (GPP). GPP is an important indicator of the productivity of terrestrial ecosystems, representing the CO₂ absorbed by plants for the production of organic matter. Thus, the measurement of GPP becomes a key indicator for monitoring the degradation of the Caatinga ecosystem and the risk of desertification. Thus, this study aimed to test the applicability of the LIGHT USE EFF (LUE) model to estimate GPP in the Cariri Paraibano, an area of Caatinga, using products from the Sentinel-2A satellite with a resolution of 10m, comparing them with the product obtained with the GPP from the MODIS satellite. This study also compared several vegetation indices, the normalized difference vegetation index (NDVI), the soil adjusted vegetation index (SAVI) and the enhanced vegetation index (EVI), and the reflectances in the visible and near-infrared bands, in order to assess whether simple shortwave reflectances or their associations through indices would approximate the PPB values. The results of the additive regression model (GAM) show that the PPB derived from the LUE, from the Sentinel-2A image, explains 46% of the variability of the MODIS PPB data, while the EVI explains 58%. The better performance of the EVI may be linked to its greater response capacity in environments with high variability of vegetation and relief, in addition to similarities in the atmospheric corrections applied in both MODIS and EVI. Therefore, the results indicate that it is possible to map the PPB in the Caatinga in a simple, objective way and with good applicability related to the Caatinga environment.

Keywords: Remote sensing, gross primary productivity, Sentinel-2A, caatinga, cariri paraibano.

1 INTRODUÇÃO

As mudanças climáticas têm causado diversos transtornos em todo o mundo, devido ao aumento médio da temperatura global provocado, particularmente, pelos GEE (Gases de Efeito Estufa) que, nos últimos 250 anos, aumentou sua concentração de 290 para 379 ppm (partes por milhão), com previsão de chegar a 550 ppm em 2100, o dobro da concentração atmosférica antes da industrialização (Costa et al, 2015). O GEE que mais provoca preocupação na sua elevada concentração é o dióxido de carbono (CO₂), cuja origem provém, principalmente, da queima de combustíveis fósseis (Rocha, 2003). Esses acúmulos na concentração de CO₂ na atmosfera poderão desencadear um aumento de 1,5 °C entre 2021 e 2040 e, em um cenário mais extremo, a temperatura global poderia aumentar entre 3,3 °C e 5,7 °C até 2100 (IPCC, 2023).

Esse aquecimento é preocupante para a preservação de florestas naturais, principalmente em ambientes semiáridos, como na Caatinga, que devido à predisposição geológica, associado às mudanças climáticas e a seca naturais da região, pode se tornar ainda mais árido (Tavares et al. 2019). Os fenômenos que caracterizam a desertificação são a erosão dos solos devido ao processo laminar e/ou pelo ravinamento ligado ao desmatamento e ao déficit hídrico dos solos, a maior exposição à radiação solar e a ação dos ventos secos (Tavares et al, 2019). Porém, de acordo com Silva (1993), além desses fatores, a ação antrópica contribui consideravelmente para a desertificação. O total de área atingida pelo fenômeno alcança, aproximadamente, 600.000 km², chegando a ser cerca de 1/3 de todo o território nordestino. Ceará e Pernambuco são os Estados mais castigados, embora, proporcionalmente, a Paraíba apresente a maior extensão de área comprometida, com aproximadamente 71% de seu território já impactado pelos efeitos da desertificação. Um dos principais núcleos de desertificação na Paraíba está localizado na região dos Cariris Velhos (Perez-Marin,2012).

A desertificação está fortemente ligada à perda de biodiversidade, o que intensifica as mudanças climáticas. Isso ocorre porque a redução da vegetação diminui a capacidade das plantas de absorver carbono, prejudicando a produção primária que sustenta a cadeia alimentar e a produção de fibras, entre outros recursos. Além disso, as espécies vegetais desempenham um papel crucial na regulação do clima global por meio da evapotranspiração. (MA, 2005).

Apesar da assolação, a Caatinga é de grande importância na manutenção ecossistêmica da região, e sua preservação é fundamental para a manutenção de outros ecossistemas. O ecossistema Caatinga possui características únicas, com grande biodiversidade e elevada adaptação das plantas às características do semiárido (Silva, 2019). Essa vegetação é capaz de fixar uma quantidade significativa de carbono atmosférico, que pode ser mensurada por meio de indicadores de estoque de carbono, como a biomassa vegetal. Uma forma eficaz de avaliar a quantidade de carbono fixado pela vegetação é por meio da quantificação da Produtividade Primária Bruta (PPB).

De modo geral, a PPB representa o total de carbono retirado da atmosfera e convertido em carbono orgânico por meio da fotossíntese ao longo de um período específico. Ela quantifica o carbono fixado em matéria orgânica, refletindo a capacidade de um ecossistema em transformar CO₂ em biomassa. Possui um papel

fundamental no ciclo global do carbono pois é o maior estimulador das funções e equilíbrio dos ecossistemas terrestres (Zhang and Ye, 2022). A medição da PPB pode ser usada como um indicador-chave para monitorar a degradação do ecossistema da Caatinga e o risco de desertificação. O mapeamento sazonal da PPB pode fornecer dados tangíveis e mensuráveis sobre a importância da Caatinga e dos serviços ecossistêmicos que ela fornece. Essas informações podem ser usadas para conscientizar e engajar a comunidade local, os formuladores de políticas e os tomadores de decisão sobre a importância da conservação da Caatinga e da necessidade de medidas para combater a desertificação, através da implementação de práticas sustentáveis de gestão da terra, de um adequado planejamento regional e da adoção de políticas públicas apropriadas.

Medições de campo da PPB são laboriosas, morosas, frequentemente ineficientes e comumente executadas em pequenas regiões. O desenvolvimento de modelos para estimar a PPB utilizando sensoriamento remoto (SR) avançou significativamente nas últimas décadas. O sensoriamento remoto revolucionou a estimativa da PPB ao fornecer dados em larga escala, contínuos e consistentes, permitindo o monitoramento da PPB em escalas regionais e globais e em amplas séries temporais (Marandi et al, 2022).

Os primeiros modelos de PPB eram, em grande parte, empíricos e baseados em índices de vegetação derivados de sensores a bordo de satélites. Os índices de vegetação são algoritmos desenvolvidos para analisar essa cobertura vegetal através de imagens capturadas por sensores específicos calibrados em determinados intervalos de comprimentos de onda e, através de métodos particulares de interpretação, alguns desses índices são utilizados para capturar os processos fotoquímicos associados com a fotossíntese da planta, tal como o uso da eficiência da luz ou estimar o conteúdo de pigmentação da folha, por exemplo a clorofila, enquanto que outros foram projetados para obter o índice de área foliar (IAF). Os índices de vegetação se dividem basicamente em dois grupos: os índices de razão, baseados no contraste entre a resposta da vegetação na banda do vermelho e do infravermelho próximo, uma simples divisão entre bandas (Índice de vegetação da Simple Razão (SR), Índice de Vegetação Transformada (TVI), Índice de Relação da Vegetação (RVI) e Índice de Vegetação por Diferença Normalizada (NDVI)); e os índices ortogonais que fazem ajustes para minimizar influências de fatores externos, como do solo e do ar, nos valores de reflectância recebidos pelo sensor (Índice de

Vegetação Ajustado ao Solo (SAVI), Índice de Vegetação Perpendicular (PVI), Índice de Vegetação por Diferença Ponderada (WDVI) e Índice de Vegetação Melhorado (EVI)). Alguns dos índices mais utilizados são, por exemplo, o EVI, que foi desenvolvido para otimizar o sinal da vegetação, melhorando a sensibilidade de sua detecção em regiões com maiores densidades de biomassa, e para reduzir a influência do sinal do solo e da atmosfera sobre a resposta do dossel; o NDVI que visa eliminar diferenças sazonais do ângulo do Sol e minimiza os efeitos da atenuação atmosférica, observados para dados multitemporais e o SAVI que possui a propriedade de minimizar os efeitos do solo de fundo no sinal da vegetação ao incorporar uma constante de ajuste de solo, o fator L.

Os métodos de estimativa de PPB baseados em índices de vegetação são mais simples e amplamente aplicáveis, mas a literatura tende a classifica-los como menos precisos do que métodos mais avançados como: (1) o LUE, entre os mais amplamente utilizados, baseiam-se na função da radiação fotossinteticamente ativa absorvida (APAR) e na eficiência com que as plantas convertem a luz em biomassa; (2) o FLUXNET, uma rede global de torres de medição localizadas em diferentes regiões do mundo que mede os fluxos de CO₂; (3) o aprendizado de máquina (ML) que utiliza de algoritmos como por exemplo redes neurais artificiais, máquinas de vetores de suporte, regressão e árvores de modelo, onde os mesmos constroem modelos empíricos baseados nos padrões contidos nos dados com alta adaptabilidade; (4) o modelo de superfície terrestre baseado em processos (LSM) que é baseado nos fenômenos que ocorrem na biosfera, como por exemplo a fotossíntese, fenologia, condutância do dossel e respiração, onde o modelo descreve explicitamente os processos físicos da ciclagem de carbono, água e energia, levando em conta que a PPB é sensível às mudanças no fluxo de CO₂, também no clima e outros parâmetros; (5) o Projeto de Intercomparação de Modelos Acoplados (CMIP) que teve início em 1995 pelo Programa Mundial de Pesquisa Climática (WCRP), onde o PPB é simulado pelo modelo CNRM-CM6-1 e em que diferentes produtos estão sendo utilizados em vários estudos diferentes, incluindo os sobre as alterações climáticas globais, efeitos da seca na fotossíntese, características de crescimento da vegetação, sequestro de carbono da vegetação em ecossistemas e mudanças na fenologia da vegetação (Zahang and Ye, 2021).

De todos os métodos aqui apontados, o modelo LUE, originalmente descrito por Monteith (1972, 1977), possui uma fórmula simples e pode apresentar processos

ecológicos consistentes em vários tipos de vegetação (Wu et al., 2010), o que o torna um dos métodos mais promissor para abordar adequadamente as dinâmicas espaciais e temporais da PPB. Neste, a PPB do ecossistema é determinada pela radiação fotossinteticamente ativa absorvida (APAR) através do LUE, que pode ser reduzida pelas tensões ambientais que porventura possam prejudicar a condição ideal. O que liga o PPB terrestre e sensoriamento remoto no modelo baseado em LUE é a estimativa de APAR fracionário (fPAR) usando dados obtidos pelo sensoriamento remoto. Diversos modelos baseados na metodologia LUE foram desenvolvidos e são amplamente utilizados em diversas escalas para estimar e analisar quantitativamente o PPB de ecossistemas terrestres (Mâkelã et al; 2008; McCallum et al., 2013; Sun et al, 2019; Marandi et al, 2022).

Considerando a crescente necessidade de captação de carbono pelas florestas naturais, associado ao aumento nas consequências das mudanças climáticas, este trabalho tem o objetivo testar a aplicabilidade do modelo da eficiência no uso da luz (LUE) para estimar a PPB no Cariri Paraibano, uma área de Caatinga, utilizando produtos do satélite Sentinel-2A de boa resolução espacial (10m), comparando com o mesmo produto do satélite MODIS. Com este também serão comparados o NDVI e o EVI e as reflectâncias nas bandas do visível e infravermelho próximo, de forma a avaliar se as simples reflectâncias de ondas curtas ou suas associações através de índices se aproximariam dos valores de PPB obtidos pelo MODIS.

2 METODOLOGIA

2.1 Área de estudo

O Cariri Paraibano (Figura 1) está localizado na mesorregião do planalto da Borborema, possui clima BSh (B-Seco, S-Semi-árido, h-baixa latitude e altitude), precipitação média anual de 600 mm, temperatura média anual de 26°C e umidade relativa do ar entre 65 e 75%. A pluviosidade reduzida e o relevo serrano, dividido em duas unidades (terrenos dissecados e o nível da Borborema), condicionaram a diversidade e riqueza da vegetação na região (Alvares et al., 2013; Barbosa et al., 2007). A Caatinga é o ecossistema predominante da região. Com o uso e ocupação

histórica das terras do Cariri paraibano, as paisagens vegetais encontradas atualmente na região foram, ao longo do tempo, dando origem a áreas desertificadas, não só pela dinâmica natural, mas principalmente por intervenção antrópica (Souza e Souza, 2016).

Os principais fatores que contribuem para a aridez da região são: (1) o deslocamento no inverno das áreas de alta pressão que, sendo dispersora de vento, dificulta a chegada de umidade; (2) a geologia caracterizada pelo afloramento cristalino de rochas impermeáveis que não deixa a água se acumular para posterior fornecimento de umidade no sistema e (3) a disposição do relevo, mais especificamente, o planalto da Borborema, barrando os ventos úmidos vindos do oceano.

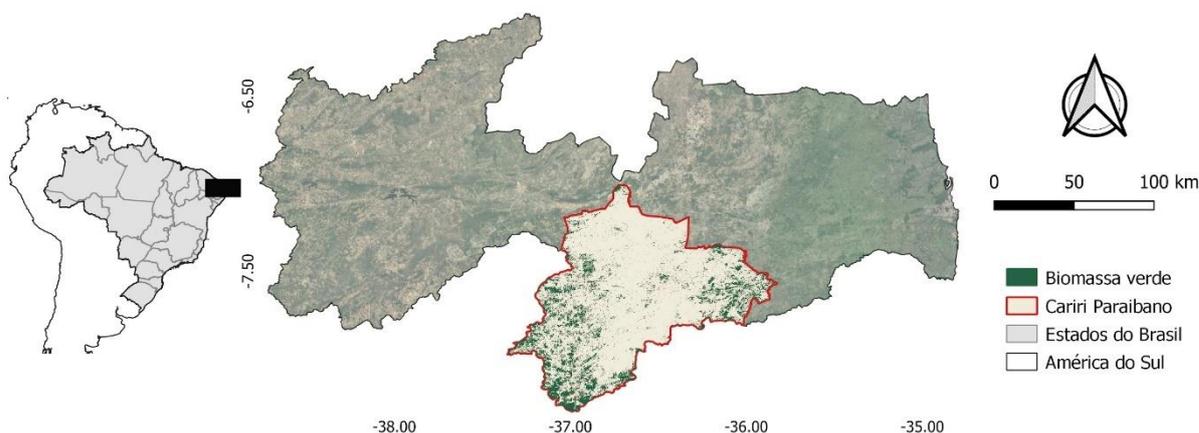


Figura 1. Localização do Cariri Paraibano e demonstração de suas áreas com maior concentração de biomassa vegetal de acordo com o produto *Above Ground Biomass* do *Global Forest Watch* (www.globalforestwatch.org). Limites geopolíticos (IBGE, 2022)

2.2 Obtenção dos dados e processamento da imagem segundo modelo LUE

A imagem da Missão Sentinel-2, plataforma S2A, produto tipo S2MSI1C (Tabela 1) foi obtida da USGS (United State Geological Survey) - Global Visualization Viewer (GloVis), de órbita e ponto 215/65, com data de passagem 27 de setembro de 2022, correspondente ao período seco, com menor cobertura de nuvens.

Utilizou-se o modelo LUE adaptado para imagens do Sentinel-2 de Marandi et al. (2022):

$$GPP = PAR \times fPAR \times \epsilon_{MAX} \times f \quad (1)$$

A radiação fotossinteticamente ativa (PAR) (0,4-0,7 μm) é parte da radiação solar de ondas curtas (0,3-3,0 μm) que é absorvida pela clorofila das plantas para a fotossíntese. Então, PAR é uma fração da radiação solar incidente. Os valores entre 45-50% são geralmente aceitos para representar as condições médias diárias (Moran et al, 1995):

$$\text{PAR} = 0,48 \text{ Rs}_{24\text{h}} \text{ (W m}^{-2}\text{)} \quad (2)$$

Onde $\text{Rs}_{24\text{h}}$ corresponde à radiação solar diária que aqui foi obtida das normais climatológicas disponibilizadas pelo WorldClim (Tabela 1), cujos *rasters* apresentam resolução de 30 arco-segundo ($\sim 1\text{km}$). Uma vez que a radiação solar não varia muito nem sazonal nem anualmente na área de estudo, opta-se por utilizar normais climatológicas com melhor resolução espacial gratuitamente disponível.

O valor de PAR descreve a quantidade total de radiação disponível para a fotossíntese se as folhas interceptarem toda a radiação. Esse valor é teórico porque as folhas também transmitem e refletem a radiação solar. Apenas uma fração de PAR será absorvida pela copa (fPAR) e usado para a assimilação de dióxido de carbono.

$$\text{fPAR} = \text{PAR} - \rho_{\text{PAR}}\text{PAR} - \text{PAR}_{\text{trans}} + \text{PAR}_{\text{soil}} \text{ (W m}^{-2}\text{)} \quad (3)$$

Onde ρ_{PAR} é a reflectância da copa, $\text{PAR}_{\text{trans}}$ é a quantidade total do PAR que é transmitida através da copa e direcionada para o solo e PAR_{soil} é a porção de $\text{PAR}_{\text{trans}}$ que é refletida pelo solo abaixo da copa e é recebida em direção à copa. Mas essa equação pode ser simplificada pela seguinte:

$$\text{fPAR} = f \times \text{PAR} \text{ (W m}^{-2}\text{)} \quad (4)$$

f muda de forma não-linear com o índice de área foliar (IAF) (Goudriaan, 1977). O IAF pode ser inferido matematicamente através de sensoriamento remoto a partir de medidas espectrais nos comprimentos de onda do vermelho e infravermelho próximo, levando a possibilidade de estimar fPAR através do NDVI. Autores, como Asrar et al. (1992) publicaram equações adequadas às suas áreas de estudo. Verificando a não compatibilidade com a nossa área de estudo, pois alguns valores retornavam negativos, demonstrando que a equação de Asrar et al. (1992) não estava calibrada para a Caatinga, resolvemos obter fPAR usando o NDVI calculado, uma

análise de regressão simples e o produto fPAR do MCD15A3H (Tabela 1) do MODIS, tendo obtido um R^2 de 0,62 e a seguinte equação:

$$fPAR = 0,12 + 1,316 \times NDVI \quad (5)$$

Onde o NDVI é o índice de vegetação por diferença (Rouse et al., 1973) normalizada calculado pela diferença entre as reflectância do infravermelho próximo e vermelho (bandas 8 e 4 do Sentinel-2A, respectivamente) a dividir pela soma dos dois. O NDVI é uma expressão da clorofila relacionada com a atividade fotossintética e expressa a biomassa verde. Uma vez que o NDVI pode ser calculado pela maioria dos sensores multiespectrais, existe possibilidade de gerar mapas de fPAR em escala regional, mesmo não tendo conhecimento sobre o uso da terra.

A eficiência do uso da luz ($\epsilon - MJ^{-1}$) deve ser corrigida de acordo com as condições ambientais, nomeadamente, as condições de umidade ($f Ws$) e de temperatura ($f Ts$) que impactam em ϵ . Field et al. (1995) desenvolveram um modelo global ecológico para a produção primária líquida e nele incorporaram a seguinte equação para ϵ :

$$\epsilon = \epsilon' f \quad (6)$$

$$f = f Ts f Ws \text{ (gMJ}^{-1}\text{)} \quad (7)$$

Onde ϵ' é a eficiência máxima do uso da luz. Gan et al. (2021) sugerem valores de $1,19 \pm 0,18$ para savana arbórea. Neste trabalho usaremos 1,3, um valor também utilizado por Machado (2015).

f é um valor adimensional que varia entre 0 e 1. $f Ts$ e $f Ws$ são restrições causadas pelas condições ambientais (temperatura e umidade, respectivamente). Esses parâmetros também são adimensionais que variam de 0 a 1, com valores baixos indicando impactos negativos mais fortes (Yuan et al., 2007). $f Ts$ e $f Ws$ representam as reduções diárias causadas pelas condições ambientais sobre o PPB. $f Ts$ foi estimado de acordo com (Raich, 1991):

$$f Ts = ((T - T_{min}) \times (T - T_{max})) / (((T - T_{min}) \times (T - T_{max})) - ((T - T_{opt})^2)) \quad (8)$$

Onde T_{\min} , T_{\max} e T_{opt} são os valores mínimos, máximos e ótimos da temperatura do ar ($^{\circ}\text{C}$), respectivamente, para o processo de fotossíntese. Os valores de temperatura do ar (T), assim como, T_{\min} e T_{\max} foram obtidos das normais climatológicas do WorldClim. De igual forma a radiação solar, as temperaturas não variam muito nem sazonal nem anualmente, por isso, opta-se por utilizar normais climatológicas com melhor resolução espacial gratuitamente disponível. O T_{opt} foi observado a partir das torres automáticas de Cabaceiras e Monteiro no mês de maior NDVI que corresponde aos meses de abril-maio (segundo a climatologia da região, Cabaceiras e Monteiro, março é o mês de maior precipitação, mas como a Caatinga demora cerca de 2 meses para responder, consideramos abril-maio com os de maior NDVI) e, portanto, a T_{opt} é de aproximadamente 23°C (Alvares et al., 2013).

$$fWs = (1+LSWI)/(1+LSWImax) \times PS \quad (9)$$

Ps representa a influência da idade da folha na fotossíntese a nível da copa, que depende da longevidade das folhas. Ps pode ser calculado da seguinte forma (Marandi et al., 2022):

$$Ps = (1+LSWI)/2 \quad (10)$$

Ps varia entre 0 e 1, sendo que 1 representa florestas perenes (Xiao et al., 2004). LSWI corresponde ao índice de água calculado a partir da seguinte equação:

$$LSWI = \frac{NIR-SWIR}{NIR+SWIR} \quad (11)$$

Sendo que NIR corresponde à reflectância na banda no infravermelho próximo, que no Sentinel-2A corresponde à banda 8 e SWIR corresponde à reflectância do infravermelho médio, banda 11 do mesmo satélite.

Tabela 1. Dados dos produtos utilizados para processamento da imagem e obtenção do PPB-Sentinel.

Dataset	Resoluções do Sensor	Data de Aquisição	Fonte
Sentinel-2A	Espacial: 10, 20, 60 m Temporal: 10 dias Espectral: 13 bandas	27 setembro, 2022	Copernicus
WorldClim: Global Climate Data • Temperatura média máxima e mínima do ar ($^{\circ}\text{C}$)	Espacial: $\sim 1 \text{ km}^2$ Normais climatológicas	1970-2000	WorldClim

- **Radiação Solar**
($\text{kJ m}^{-2} \text{day}^{-1}$)

MODIS LAI/Fpar (MCD15A3H)	Espacial: 500 m Temporal: 4 dias (Composição)	30 setembro, 2022	USGS
MODIS PPB (MOD17A2H V6)	Espacial: 500 m Temporal: 8 dias (composição)	30 setembro, 2022	USGS

2.3 Análises estatísticas: comparação do PPB-sentinel, índices de vegetação e reflectâncias simples com o produto PPB-MODIS.

O produto PPB-MODIS foi obtido do MOD17A2H V6 da plataforma da USGS, de resolução espacial 500 m (Tabela 1). Escolheu-se o PPB do dia 30-09-2022, da cena h14v09, pois esse dado corresponde ao acumulado de 8 dias ($\text{kgC}/8\text{d}$) (23-30 de setembro). Para efeitos de comparação com PPB-Sentinel, o *raster* PPB-MODIS foi dividido por 8 para obter o valor de 24h e depois dividido por 1000 para obter valores em $\text{gC}/24\text{h}$.

Além de comparar o produto PPB-MODIS com o PPB-sentinel obtido aqui, comparamos o PPB-MODIS com NDVI (acima explicado), SAVI (Huete, 1988), EVI (Jensen, 2011) e as reflectâncias das bandas do visível e do infravermelho próximo.

$$IVAS = \frac{(1+L)(\rho_{IV}-\rho_V)}{(\rho_{IV}+\rho_V)} \quad (12)$$

Onde L é o fator de ajuste para o solo (0,1 vegetação espaçada).

$$EVI = G \frac{(\rho_{IV}-\rho_V)}{(\rho_{IV}+C1\rho_V-C2\rho_B+L)} \quad (13)$$

Onde C1 e C2 são dois coeficientes para correção do espalhamento atmosférico por aerossóis, L o fator de ajuste para o solo e G o valor de ganho ajustado (L= 1; C1 = 6; C2= 7,5 e G = 2,5).

Os dados foram extraídos dos *raster* computados através da elaboração de uma grade cujas quadrículas coincidem com os pixels do PPB-MODIS, com cerca de 500 metros de resolução, totalizando 56.866 quadrículas numeradas (N total). A partir

dessa grade, a estatística zonal foi realizada de forma a obter a média dos pixels dentro de cada quadrícula.

Para medir a força e a direção da relação entre o produto PPB-MODIS e o PPB-Sentinel, os índices de vegetação e as reflectâncias das bandas individuais, averiguada a não normalidade dos dados pelo teste de Shapiro-Wilk, utilizou-se a correlação linear de Spearman (Tabela 2).

Os índices de vegetação e as reflectâncias das bandas individuais (variáveis preditoras) foram também comparados com o PPB-MODIS (variável resposta) através do modelo de regressão aditiva generalizada (GAM), de forma a modelar a relação entre a variável resposta com as variáveis preditoras, através do coeficiente de determinação e avaliar a proporção da variabilidade do PPB que pode ser explicada pelas variáveis preditoras (Tabela 2). O modelo GAM é flexível e pode modelar relações não lineares com funções suaves, independentemente da distribuição dos resíduos (Sothe, 2017).

Para o índice que obteve melhor correlação com o PPB-MODIS, ainda se testaram diversos modelos não-paramétricos do pacote "*NonlinearRegression*" do RStudio:

- 1: $y \sim a/(1+b*\exp(b-c*x))$ -> Exponencial1
- 2: $y \sim a*\exp(b*x)$ -> Exponencial2
- 3: $y \sim a-\exp(-b-c*x)$ -> Meloun II
- 4: $y \sim a*(1-b*\exp(-c*x))^3$ -> VonBertalanffy
- 5: $y \sim (a*x)/(x+b)$ -> Michaelis Menten
- 6: $y \sim a*\exp(-\exp(b-c*x))$ -> Gompertz

Tendo-se obtido melhor resultado (R^2 ajustado) com a Exponencial1: $y = a/(1+b*\exp(b-c*x))$ (Figura 4).

Os valores atípicos, outliers, foram removidos através da regra 1,5 x FIQ (FIQ = faixa interquartil), ou seja, os outliers foram identificados como os valores abaixo de 1º Quartil - 1,5. FIQ e acima de 3º Quartil + 1,5.FIQ (TUKEY, 1977). Este procedimento identificou os valores anormais, sendo que cerca de 1% das 56.866 quadrículas foram removidas com este método.

Todas as imagens foram processadas através do software QGIS, versão 3.28.1-Firenze. Os tratamentos estatísticos foram realizados pelo RStudio, versão 1.1.453.

3 RESULTADOS E DISCUSSÃO

A variação espacial da PPB sugere a presença de diferentes tipos de uso e cobertura da terra, incluindo variadas formas de vegetação e práticas de uso da terra (Figura 2). Essa diversidade nos tipos de vegetação e na cobertura do solo influencia a capacidade de fixação de carbono em cada área. Além disso, o EVI, também calculado a partir da imagem Sentinel (Figura 3), mostrou variações semelhantes, com valores mais altos na porção leste do Cariri, onde também foram encontrados os maiores valores de PPB. Essa área coincide com regiões de relevo mais acidentado, indicando que a topografia, ao lado das diferenças nos tipos de vegetação e uso do solo, pode estar contribuindo para a variabilidade na produtividade primária e na densidade de cobertura vegetal ao longo da região.

Essa análise destaca como fatores físicos e humanos, como relevo e práticas de uso da terra, moldam a produtividade e a dinâmica ecológica no Cariri Paraibano.

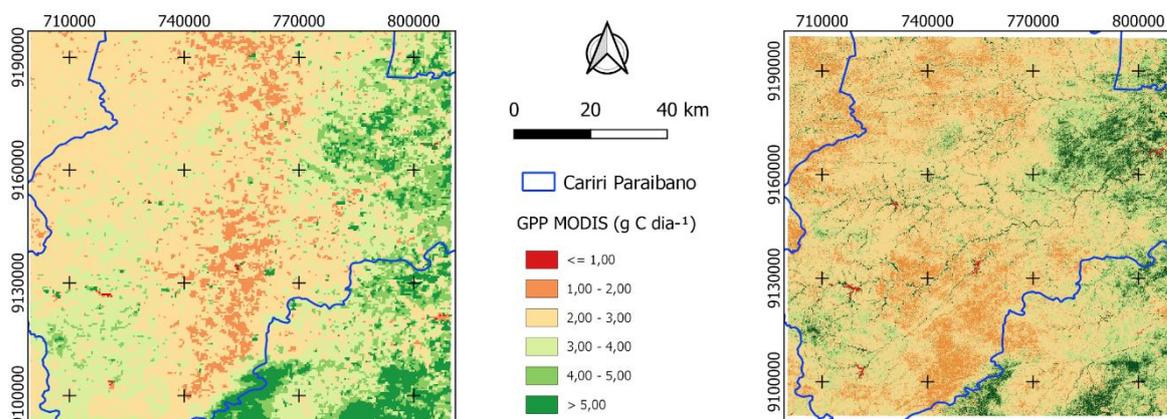


Figura 2. Comparação do PPB - MODIS (imagem à esquerda) em relação ao PPB - Sentinel (imagem à direita). Sistema Projetado de Coordenadas DATUM SIRGAS 2000, ZONA 24S.

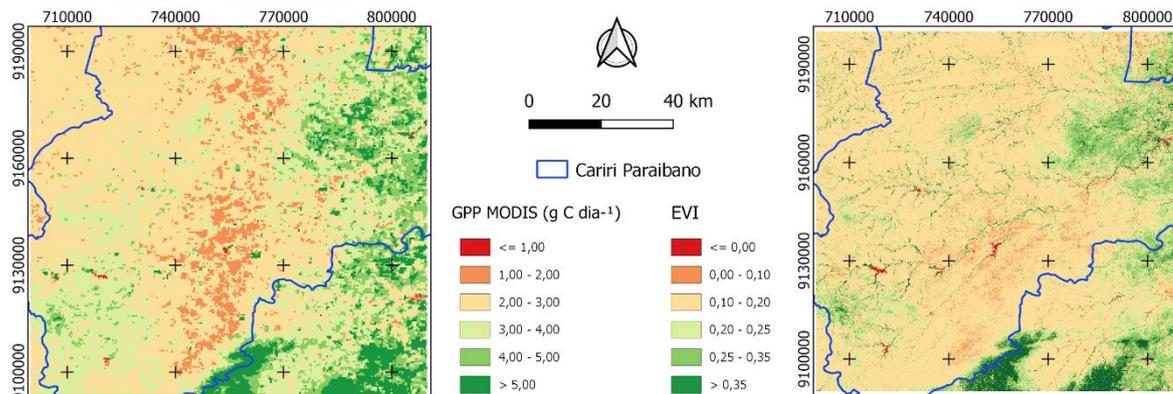


Figura 3. Comparação do PPB - MODIS (imagem à esquerda) em relação ao EVI - Sentinel (imagem à direita).

Os índices de vegetação, como EVI e NDVI, mostraram os melhores desempenhos em captar a produtividade da superfície, como mostra a Tabela 2. O EVI, em particular, foi projetado para maximizar a sensibilidade à vegetação e minimizar os efeitos de ruídos atmosféricos e de solo (Leivas, 2022). O EVI, que utiliza as bandas azul, vermelha e infravermelha próxima, é eficaz em áreas densamente vegetativas e sua correlação elevada com o PPB-MODIS sugere que este índice é altamente eficaz em captar as nuances da vegetação. Em contraste, o NDVI, embora menos complexo que o EVI, também se mostrou eficaz em medir a saúde da vegetação, mas pode ser menos sensível em áreas com vegetação densa devido a "saturação" em áreas altamente vegetativas. Ambos apresentaram melhores resultados que o PPB-Sentinel, indicando que possuem maior sensibilidade em prever a produtividade do ecossistema, pois diferenciam as estruturas dos tipos de vegetação, sendo mais precisos aos diferentes tipos florestais (Ginciene e Bitencourt, 2011).

A análise das correlações entre a produtividade da superfície, medida pelo índice PPB-MODIS, e as bandas espectrais do satélite revela compreensões importantes sobre a dinâmica da vegetação e o processo de fotossíntese. As correlações negativas observadas entre o PPB-MODIS e as bandas azul (450 – 495 nm), vermelho (620-750 nm) e verde (495-570 nm) são compreensíveis, uma vez que menores valores de reflectância indicam elevada absorção da radiação pelos

pigmentos fotossintéticos, ou seja, maior sequestro de carbono. A absorção da luz azul e vermelha é essencial para a fotossíntese, com a clorofila operando de forma mais eficaz nesses intervalos. Tanto os carotenóides quanto as xantofilas operam de forma eficaz na faixa do azul, absorvendo luz em comprimentos de onda que não são eficientemente capturados pela clorofila, como explica Ginciene e Bitencourt (2011).

A análise da correlação entre o PPB-MODIS e a reflectância no infravermelho próximo (IVP) revela um padrão esperado de baixa correlação. No IVP, que abrange comprimentos de onda de aproximadamente 750 a 2500 nm, a reflectância é predominantemente influenciada pela estrutura física e pela composição das folhas, em vez da atividade fotossintética. Embora o IVP seja útil para avaliar o estado hídrico e a saúde da vegetação, sua relação direta com a fotossíntese e, conseqüentemente, com o PPB, não é tão forte. Isso ocorre porque a reflectância no IVP não reflete diretamente a capacidade das plantas de realizar a fotossíntese, mas sim aspectos morfológicos e hídricos que não necessariamente se correlacionam com a produtividade. É importante também considerar o efeito das variações causadas pela caducifolia de algumas espécies dominantes, com isso, as características florísticas e fitossociológicas introduziram variações nos padrões de reflectância no IVP para as distintas parcelas na estratificação da vegetação (Gaida et al, 2016).

Tabela 2. Resultados da análise de correlação de Spearman (ρ) e valor de p (significância) e do modelo de regressão aditiva generalizada (R^2 Ajustado, desvio explicado e valor de p) para os pares de variáveis PPB do Modis (PPB-MODIS) e PPB do Sentinel (PPB-SENT), EVI, NDVI, SAVI, reflectâncias no vermelho, azul, verde e infravermelho próximo (IVP).

Variáveis	Análise de Correlação de Spearman		Modelo de Regressão Aditiva Generalizada	
	Rho	Valor p	R^2 Ajustado	Valor p
PPB-MODIS – PPB-SENT	0,679	P < 0,001	0,460	P < 0,001
PPB-MODIS – EVI	0,726	P < 0,001	0,575	P < 0,001
PPB-MODIS – NDVI	0,721	P < 0,001	0,573	P < 0,001
PPB-MODIS – SAVI	0,715	P < 0,001	0,565	P < 0,001
PPB-MODIS – VERMELHO	-0,475	P < 0,001	0,200	P < 0,001

PPB-MODIS – AZUL	-0,483	P < 0,001	0,069	P < 0,001
PPB-MODIS – VERDE	-0,400	P < 0,001	0,084	P < 0,001
PPB-MODIS – IVP	0,105	P < 0,001	0,060	P < 0,001

A Figura 4 mostra o gráfico do modelo exponencial entre o PPB Modis e o EVI Sentinel, índice que obteve a melhor resposta dentre os índices analisados em relação ao PPB-MODIS, com R² de 58% de correlação entre eles.

A correlação mais forte com o PPB calculado pelo MODIS e o EVI, quando comparado com outros índices de vegetação, como o NDVI e o SAVI, pode ser explicada pela construção técnica do EVI. Diferente do NDVI, que é mais sensível à saturação em áreas de alta densidade de biomassa, e do SAVI, que busca minimizar os efeitos do solo, o EVI foi especificamente desenvolvido para reduzir os efeitos da saturação e para ser menos influenciado por condições atmosféricas e de solo. Isso o torna particularmente eficaz em áreas heterogêneas e complexas, como o Cariri Paraibano, onde a vegetação e o relevo variam significativamente. Assim, o EVI pode capturar melhor as sutis diferenças de produtividade primária que ocorrem em áreas mais diversas, onde o NDVI não será tão sensível, e em regiões com maior influência do solo exposto, onde o SAVI pode perder precisão (Matsushita, 2007).

Além disso, o PPB do MODIS é calculado a partir de um modelo que leva em conta correções atmosféricas semelhantes às usadas no cálculo do EVI, o que provavelmente contribui para uma maior sinergia entre os dois. O modelo MODIS foi calibrado globalmente para otimizar sua sensibilidade em uma ampla variedade de ecossistemas, o que pode explicar a forte relação com o EVI, que reflete mudanças na densidade e vigor da vegetação de forma mais precisa nessas condições (Turner, 2006).

Por outro lado, o modelo LUE aplicado ao Sentinel pode ter tido menos precisão na estimativa do PPB localmente devido a possíveis limitações na calibração para as condições específicas do Cariri. O modelo LUE é robusto, mas pode ter uma sensibilidade menor a variáveis locais, como a variação no tipo de vegetação e nas condições atmosféricas, especialmente em uma região onde o relevo e os tipos de cobertura vegetal variam bastante (Cai, 2014). Dessa forma, o EVI, pela sua

construção e características, se mostrou mais adequado para refletir as variações do PPB conforme calculado pelo MODIS, que também foi projetado para se ajustar a uma ampla gama de condições ambientais.

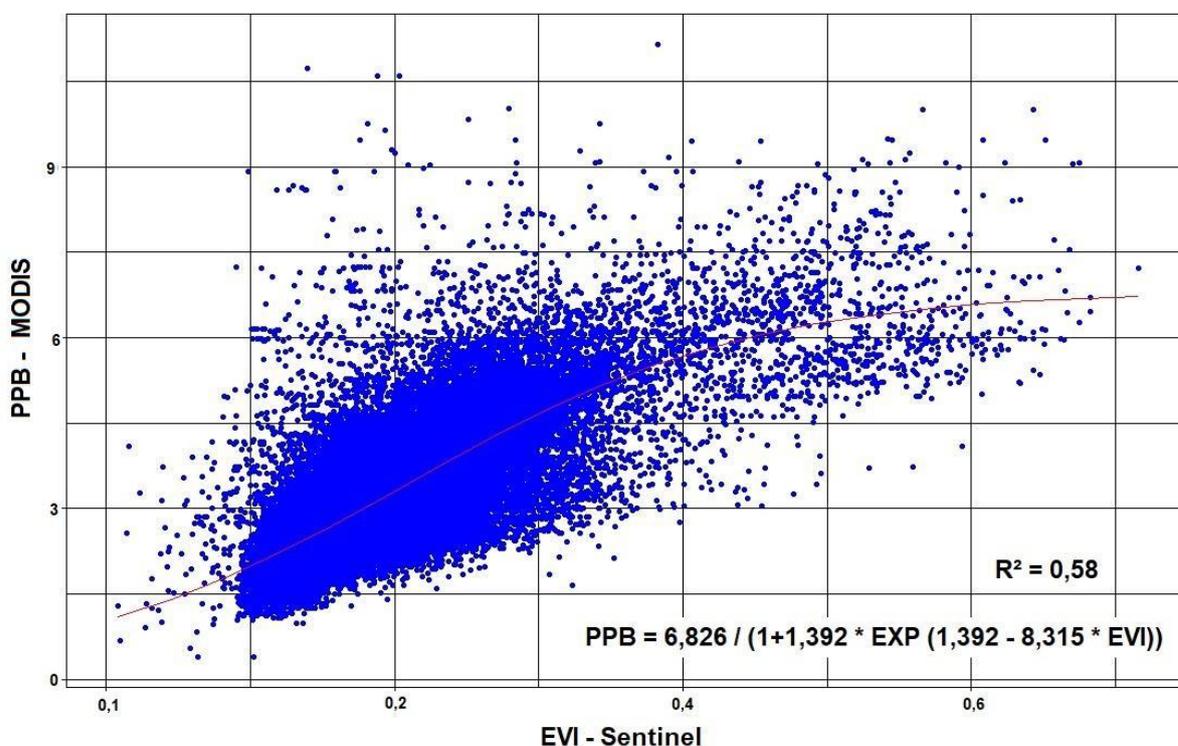


Figura 4. Modelo exponencial entre as variáveis do PPB - MODIS e do EVI – Sentinel.

Um estudo que verifica a potencialidade dos índices de vegetação NDVI e EVI sobre a separabilidade e a discriminação espectral de áreas de plantios de soja, utilizando imagens do MODIS, mostra resultados semelhantes em relação à superioridade do EVI em diferenciar tipos de vegetação. Neste estudo, para áreas de plantio de soja em relação a áreas de mata e de solo exposto, os resultados mostraram que o NDVI é mais eficiente durante o período de entressafra, mais especificamente durante a fase de pré-plantio, já que não se necessita de uma análise mais detalhada do tipo de vegetação. Já, durante o período de safra, a separabilidade entre os alvos, que nada mais é que a diferenciação dos tipos de vegetação, mostrou-se mais evidente para o EVI, particularmente no período de máximo desenvolvimento da soja (Risso et al, 2009). Ou seja, assim como demonstrado neste estudo, o EVI seria o mais indicado para ser utilizado em ambientes com alta variação de tipos vegetais.

Diante dos dados e em comparação com os índices de vegetação, a aplicabilidade do modelo LUE é incerta, pois os valores da LUE variam entre espécies de plantas. Muitos desses valores são conhecidos e estão disponíveis na literatura. Porém, quando o interesse é um ecossistema natural, constituído de uma comunidade de plantas, que por sua vez é composto por inúmeras espécies, o valor de LUE é cercado de muitas incertezas, pois deve representar efetivamente a eficiência média dessa comunidade ou um valor que seja representativo das espécies dominantes (Oliveira, 2022).

5 CONCLUSÃO

A proporção da variabilidade do PPB no Cariri Paraibano indica uma moderada correlação ao EVI, predizendo de uma forma significativa e relativamente satisfatória o PPB e indicando uma boa resolução espacial. Esses dados indicam que se consegue obter um bom produto calculando somente o EVI, e que o mesmo seria o suficiente para prever a variação do PPB da região, sem precisar recorrer a vários cálculos de diversas fontes de dados diferentes, que seria a metodologia complexa do modelo LUE, e só seria necessário a obtenção das reflectâncias do azul, vermelho e infravermelho próximo, presentes na grande maioria dos sensores multiespectrais. Com isso, a baixa aplicabilidade do modelo LUE para a região torna-se evidente devido às incertezas geradas pelas variações entre diferentes espécies de plantas que compõem o dossel, já que diferentes tipos de vegetação produzem biomassa de maneira distinta. Portanto, a partir dessas informações, é possível estimar o PPB na Caatinga através do EVI com uma melhor resolução espacial, aumentando a precisão do produto.

O EVI mostrou uma correlação mais forte com o PPB calculado pelo MODIS, comparado a outros índices como o NDVI e o SAVI, porque ele foi projetado para reduzir a saturação em áreas com alta biomassa e minimizar interferências atmosféricas e de solo. Essas características tornam o EVI especialmente eficaz em regiões complexas como o Cariri Paraibano, onde há grande variabilidade de vegetação e relevo. Além disso, o MODIS e o EVI aplicam cálculos de correções atmosféricas semelhantes, o que facilita uma correspondência mais robusta entre os

dois. Em contraste, outros índices e o modelo LUE do Sentinel podem ser menos ajustados às particularidades locais, resultando em correlações mais baixas.

Esses dados de produtividade primária bruta, obtidos por sensoriamento remoto, têm grande potencial para o monitoramento ambiental e a avaliação do sequestro de carbono ao longo do tempo. Além disso, eles fornecem informações valiosas para a conservação da Caatinga e para o combate à desertificação, permitindo identificar áreas críticas e acompanhar a degradação desse ecossistema único no planeta.

REFERÊNCIAS

ABEL, C.; HORION, S.; TAGESSON, T.; KEERSMAECKER, W. The human–environment nexus and vegetation–rainfall sensitivity in tropical drylands. **Nature Sustainability**, v. 4, p. 25-32, 2021.

ALVARES, C. A.; STAPE, J. L.; SENTELHAS, P. C. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, p. 711–728, 2013.

ASRAR, G.; MYNENI, R. B.; CHOUDHURY, B. J. Spatial heterogeneity in vegetation canopies and remote sensing of absorbed photosynthetically active radiation: a modelling study. **Remote Sensing of Environment**, v. 41, p. 85–103, 1992.

AUBRÉVILLE, André. **Climats, forêts et désertification de l’Afrique tropicale**. Paris: Société d’Éditions Géographiques Maritimes et Coloniales, 1949.

BARBOSA, M. R.; LIMA, I. B.; LIMA, J. R. Vegetação e flora no Cariri Paraibano. **Oecologia Brasil**, v. 11, p. 313–322, 2007.

BOLES, S. H.; XIAO, X.; LIU, J.; ZHANG, Q.; MUNKHTUYA, S.; CHEN, S.; OJIMA, D. Land cover characterization of temperate East Asia using multi-temporal VEGETATION sensor data. **Remote Sensing of Environment**, v. 90, p. 477–489, 2004.

CAETANO, R.; SILVA, T. B.; BENFICA, N. S.; CASTRO, D. R. Uso de índices espectrais na caracterização da cobertura vegetal em região de Caatinga do Semiárido Baiano. *Revista de Geociências do Nordeste*, v. 8, n. 2, 2022. Disponível em: <<https://doi.org/10.21680/2447-3359.2022v8n2ID26864>>.

CAI, W. et al. Large Differences in Terrestrial Vegetation Production Derived from Satellite-Based Light Use Efficiency Models. *Remote Sens.* 2014, 6, 8945-8965; doi:10.3390/rs6098945

COSTA, D. C. C. et al. Emergência e crescimento inicial de plântulas de cebola sob o aumento da temperatura e concentração de CO₂. *Revista Brasileira de Geografia Física, Recife*, v. 8, p. 471-483, 2015.

FIELD, C. B.; RANDERSON, J. T.; MALMSTROM, C. M. Global net primary production: combining ecology and remote sensing. *Remote Sensing of Environment*, v. 51, p. 74–88, 1995.

GAN, R. et al. Estimating ecosystem maximum light use efficiency based on the water use efficiency principle. *Environmental Research*, v. 16, p. 104032, 2021. Disponível em: <<https://doi.org/10.1088/1748-9326/ac263b>>. Acesso em: 20 set. 2023.

GOUDRIAAN, J. *Crop micrometeorology: a simulation study*. Wageningen: Centre for Agricultural Publishing and Documentation PUDOC, 1977. 249 p.

GINCIENE, B. R.; BITENCOURT, M. D. Utilização do EVI (Enhanced Vegetation Index) para maior sensibilidade na detecção de mudanças temporais em fragmentos de floresta estacional semidecidual. In: *Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 abr. a 5 mai. 2011*. INPE, p. 1620.

HUETE, A. R. et al. A comparison of vegetation indices over a global set of TM images for EOS-MODIS. *Remote Sensing of Environment*, n. 59, p. 440-451, 1997.

HUETE, A. R. et al. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**, n. 83, p. 195-213, 2002.

IBGE. Malha municipal. 2021. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html?=&t=downloads>>. Acesso em: 15 mai. 2023.

IPCC. **Climate change 2001** (3 vols). Cambridge: United Nations Intergovernmental Panel on Climate Change, Cambridge University Press, 2001.

LEIVAS, J. F. et al. Análise da dinâmica temporal de índices de vegetação NDVI, EVI, SAVI e IRECI através de imagens Sentinel-2a e MODIS. *Ciências agrárias: o avanço da ciência no Brasil*. São Paulo, SP: Editora Científica Digital, 2022.

MA. **Ecosystems and human well-being: desertification synthesis**. Washington, DC: World Resources Institute, 2005.

MACHADO, C. C. C. Alterações na superfície do Parque Nacional do Catimbau (PE-Brasil) – consolidação dos aspectos biofísicos na definição dos indicadores ambientais do bioma Caatinga. 2014. Tese (Doutorado) – Universidade Federal de Pernambuco, 2014.

MARANDI, M.; PARIDA, B. R.; GHOSH, S. Retrieving vegetation biophysical parameters and GPP using satellite-driven LUE model in a National Park. **Environmental Development and Sustainability**, v. 24, p. 9118–9138, 2022.

MATSUSHITA, B. et al. Sensibilidade do Índice de Vegetação Aprimorado (EVI) e do Índice de Vegetação de Diferença Normalizada (NDVI) aos Efeitos Topográficos: Um Estudo de Caso em Floresta de Ciprestes de Alta Densidade. *Sensors* 2007. <https://doi.org/10.3390/s7112636>

MORAN, M. S.; MAAS, S. J.; PINTER, P. J. Combining remote sensing and modeling for estimating surface evaporation and biomass production. **Remote Sensing Reviews**, v. 12, p. 335–353, 1995.

NAKAI, É. S. Quantificação da biomassa e estoque de carbono em diferentes coberturas vegetais por meio de sensoriamento remoto. 2016. Tese (Doutorado) – Universidade de São Paulo, Piracicaba, 2016.

OLIVEIRA, A. C. C. F. Eficiência de uso da luz do bioma Caatinga sob as condições climáticas do Seridó do Rio Grande do Norte. Natal: Universidade Federal do Rio Grande do Norte, Centro de Ciências Exatas e da Terra, Departamento de Ciências Atmosféricas e Climáticas, 2022.

PEREZ-MARIN, A. M. et al. Núcleos de desertificação no semiárido brasileiro: ocorrência natural ou antrópica. *Parcerias Estratégicas*, v. 17, n. 34, p. 87-106, 2012.

RAICH, J. W. et al. Potential net primary productivity in South America: application of a global model. **Ecological Applications**, v. 1, n. 4, p. 399-429, nov. 1991. doi: 10.2307/1941899.

ROCHA, M. T. Aquecimento global e o mercado de carbono: uma aplicação do modelo CERT. 2003. Tese (Doutorado em Economia Aplicada) – Escola Superior de Agricultura Luiz de Queiroz, Universidade de São Paulo, Piracicaba, 2003. doi: 10.11606/T.11.2003.tde-13052003-163913.

RISSO, J. et al. Potencialidade dos índices de vegetação EVI e NDVI dos produtos MODIS na separabilidade espectral de áreas de soja. In: *Anais XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, Brasil, 25-30 abr. 2009. INPE, p. 379-386.

ROUSE, J.W., HAAS; R.H., SCHELL, J.A.; DEERING, D.W. Monitoring vegetation systems in the Great Plains with ERTS, Third ERTS Symposium, NASA SP-351 I, 309-317, 1973.

SILVA, K. K. Avaliação da produtividade primária bruta da caatinga do semiárido paraibano. 2019. 64 f. Dissertação (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Paraíba, 2019.

SOTHE, C. et al. Uso de Modelo Aditivo Generalizado para Análise Espacial da Suscetibilidade a Movimentos de Massa. *Revista Do Departamento De Geografia*, 34, 68-81. 2017. <https://doi.org/10.11606/rdg.v34i0.132901>

SOUZA, B. I.; SOUZA, R. S. The occupation process of the Cariri Velhos – PB and the effects in the vegetal cover: contribution to the cultural biogeography of the semiárid. **Caderno de Geografia**, v. 26, n. Especial 2, p. 229–258, 2016.

SUN, Z. et al. Evaluating and comparing remote sensing terrestrial GPP models for their response to climate variability and CO₂ trends. **Science of the Total Environment**, v. 668, p. 696-713, 2019. doi: 10.1016/j.scitotenv.2019.03.025.

TAVARES, V. C.; ARRUDA, Í. R. P. de; SILVA, D. G. da. Desertificação, mudanças climáticas e secas no semiárido brasileiro: uma revisão bibliográfica. **Geosul**, v. 34, n. 70, p. 385-405, jan./abr. 2019. Disponível em: <<http://dx.doi.org/10.5007/2177-5230.2019v34n70p385>>. Acesso em: 23 mar. 2023.

TUKEY, J. W. **Exploratory data analysis**. Reading, Massachusetts: Addison-Wesley, 1977.

TURNER, D. P. Evaluation of MODIS NPP and GPP products across multiple biomes. *Remote Sensing of Environment* 102 (2006) 282–292

ZHANG, Y.; YE, A. Would the obtainable gross primary productivity (GPP) products stand up? A critical assessment of 45 global GPP products. **Science of the Total Environment**, v. 783, p. 146965, 2021. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2021.146965>>. Acesso em: 5 nov. 2023.

ZHANG, Y.; YE, A. Improving global gross primary productivity estimation by fusing multi-source data products. **Heliyon**, v. 8, n. 3, e09153, 2022. Disponível em: <<https://doi.org/10.1016/j.heliyon.2022.e09153>>. Acesso em: 9 mai. 2024.

YUAN, W.; LIU, S.; ZHOU, G. Deriving a light use efficiency model from eddy covariance flux data for predicting daily gross primary production across biomes. *Agricultural and Forest Meteorology**, v. 143, p. 189–207, 2007.

XIAO, X. et al. Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data. *Remote Sensing of Environment**, v. 91, n. 2, p. 256–270, 2004. Disponível em: <<https://doi.org/10.1016/j.rse.2004.03.010>>. Acesso em: 23 mar. 2023.

ZHONGYI, S. et al. Evaluating and comparing remote sensing terrestrial GPP models for their response to climate variability and CO₂ trends. *Science of the Total Environment**, v. 668, p. 696-713, 2019. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2019.03.025>>. Acesso em: 5 nov. 2023.

ANEXO

TESTE: 1: $y \sim a/(1+b*\exp(b-c*x)) \rightarrow$ Exponencial1

GL	SQ	QM	Fc	pValor	
Regressao	2	37811.07	18905.53272	44590.70389	0
Residuos	56021	23751.74	0.42398		
Total	56023	61562.81			

[1] "-----"

Formula: $y \sim a/(1 + b * \exp(b - c * x))$

Parameters:

	Estimate	Std. Error	t value	Pr(> t)
a	7.095921	0.041006	173.0	<2e-16 ***
b	1.503263	0.004173	360.2	<2e-16 ***
c	11.059440	0.089298	123.8	<2e-16 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 0.6511 on 56021 degrees of freedom

Number of iterations to convergence: 11

Achieved convergence tolerance: 8.413e-07

[1] "-----"

[1] "-----"

R2	R2ajust	AIC	BIC
0.6141892	0.6141685	1.109217e+05	1.109574e+05