



## Modelos da Produtividade Primária Bruta em área de floresta tropical em sazonalmente seca, usando dados reflectância da vegetação de caatinga

Joélia Natália Bezerra da Silva<sup>1</sup>, Josicléda Domiciano Galvêncio<sup>2</sup>, Rodrigo de Queiroga Miranda<sup>3</sup>, Magna Soelma Besera de Moura<sup>4</sup>

<sup>1</sup> Doutoranda em Desenvolvimento e Meio Ambiente da Universidade Federal de Pernambuco. E-mail: joelia.nataliageo@gmail.com / Bolsista Facepe. <sup>2</sup> Professora do Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente da Universidade Federal de Pernambuco, E-mail: [josicleda@gmail.com](mailto:josicleda@gmail.com) <sup>3</sup> Pesquisador PNP/FACEPE/CAPES do Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente da Universidade Federal de Pernambuco. E-mail: [rodrigo.qmiranda@gmail.com](mailto:rodrigo.qmiranda@gmail.com) <sup>4</sup> Professora do Programa de Pós-Graduação em Desenvolvimento e Meio Ambiente da Universidade Federal de Pernambuco, E-mail: magna\_upa@hotmail.com

Artigo recebido em 03/08/2021 e aceito em 12/12/2021

### RESUMO

Os estudos da troca de energia nos ecossistemas fornecem informações importantes para a compreensão da Produtividade nos ecossistemas. A vegetação é um dos principais elementos da biosfera terrestre sendo responsável pela avaliação e funcionamento da atividade fotossintética bem como para as trocas de carbono entre os ecossistemas e a atmosfera. Neste contexto, a Produção Primária Bruta-PPB é utilizada para avaliar, planejar e gerenciar os recursos ambientais frente as mudanças climáticas globais. Esse estudo tem por objetivo desenvolver modelo que estime PPB para o Bioma da Caatinga em Pernambuco, utilizando dados de reflectâncias. O estudo foi realizado na área de Floresta Tropical Sazonalmente Seca, a Caatinga no Estado de Pernambuco. Utilizou-se a reflectância da superfície do produto (MOD09) a partir do MODIS/TERRA satélite do sensor, a reflectância de superfície (SR) Landsat-8 e a reflectância a superfície em campo utilizando fieldspec. Foram adquiridas nove cenas para o produto (MOD09), seis cenas para a reflectância de superfície (SR) Landsat-8 e as mesmas datas das imagens foram utilizados os espectros de campo (fieldspec). Foi realizada a seleção de amostras espectrais na imagem (espectros de referência), considerando o ponto espectral do local de coleta. Os modelos foram construídos a partir das combinações das bandas ( $\rho_{350}, \rho_{351}, \rho_{352}, \dots, \rho_{2500}$ ) suas transformações ( $\rho, 1/\rho, \ln(\rho), \log_{10}(\rho), \sqrt{\rho}, \rho^2, e^{\rho}$ ). Os desempenhos dos modelos foram avaliados utilizando dois índices estatísticos, um de tendência (coeficiente de Pearson-r) e outro de desvio (Erro médio quadrático (RMSE - RMSE), e o PBIAS. Os resultados apontaram que os modelos calibrados demonstraram bom desempenho na estimativa da PPB com o uso das bandas do sensor OLI/Landsat 8 e do MODIS/Terra (MOD09GA).

Palavras-chave: Sensoriamento remoto, FieldSpec®3, Caatinga

## Models of Gross Primary Productivity in a seasonally dry tropical forest area using reflectance data from the Caatinga vegetation

### ABSTRACT

The studies of energy exchange in ecosystems provide important information for the understanding of Productivity in ecosystems. Vegetation is one of the main elements of the terrestrial biosphere and is responsible for the evaluation and functioning of photosynthetic activity as well as for carbon exchanges between ecosystems and the atmosphere. In this context, a PPB is used to assess, plan and manage environmental resources in the face of global climate change. This study aims to evaluate a Gross Primary Production in the Caatinga Biome in Pernambuco. The study was carried out in the Seasonally Dry Tropical Forest, a Caatinga in the State of Pernambuco. Use the product's surface reflectance (MOD09) from the sensor's MODIS / TERRA satellite and the Landsat-8 surface reflectance (SR), nine scenes for the product (MOD09), six scenes for surface reflectance (SR) Landsat-8 and similar data with fieldspec. A selection of spectral members in the image (reference spectra) was carried out, considering the spectral point of the collection site. The models were built from the combinations of the bands ( $\rho_{350}, \rho_{351}, \rho_{352}, \dots, \rho_{2500}$ ) their transformations ( $\rho, 1/\rho, \ln(\rho), \log_{10}(\rho), \sqrt{\rho}, \rho^2, e^{\rho}$ ). The performances of the models were taken using two statistical indices, one of trend (Pearson's coefficient - r) and another of deviation (Mean square error (RMSE - RMSE), and PBIAS. The results showed that the calibrated models showed good performance in prediction using the OLI / Landsat 8 and MODIS / Terra (MOD09GA) bands.

Keyword: Remote sensing, FieldSpec®3, Caatinga

## Introdução

O Produção Primária Bruta (PPB) é definido como a quantidade total de dióxido de carbono fixado pelas plantas durante a fotossíntese, que é o primeiro passo para o CO<sub>2</sub> atmosférico entrar nos ecossistemas terrestres, é um componente chave do ciclo biogeoquímico do carbono. Mendes et al. (2020) apontam que as projeções em ambientes semiáridos podem indicar aumento de 1° C na temperatura média do ar nas próximas décadas, podendo ter a redução de até 20% na quantidade de precipitação. Galvêncio e Luz (2021) aponta que até o ano de 2027 ocorrerá uma diminuição de 15% na precipitação média anual do semiárido de Pernambuco. Portanto, a quantificação precisa da PPB em uma escala regional e global pode melhorar nossa compreensão dos orçamentos de carbono e dos mecanismos globais de mudança climática (Liu, Wang, e Wang, 2014).

A maioria dos modelos para a estimativa dos fluxos de carbono são baseados na Eficiência de Uso de Radiação - RUE, esse conceito foi proposto por Monteith (1972), tornando-se a base para o desenvolvimento de vários modelos desenvolvidos com o uso do sensoriamento remoto na quantificação do PPB. Nesse sentido, as estimativas se fundamentam na relação entre a RUE, radiação fotossinteticamente ativa absorvida (APAR), fração da radiação fotossinteticamente ativa absorvida (fAPAR). Nesse contexto, sensores tem sido utilizado para desenvolver modelos (Jiang et al., 2013) para a obtenção dos componentes relacionados às trocas energéticas e de carbono entre a superfície e a atmosfera (Sun et al., 2019). O conceito de eficiência do uso de luz (LUE) proposto por Monteith (1972) e sua aplicação trouxe contribuições para os conceitos de processos de sumidouros de carbono pela vegetação representa a absorção da radiação ativa fotossintética (Ren et al. 2017), Modelo VPM modelo fotossíntese vegetação de (Xiao et al. 2004), entre outros.

Nas últimas décadas os modelos baseados em sensoriamento remoto têm sido amplamente utilizados (Zhang et al., 2014; Ren et al., 2017; He et al., 2018; Wang et al., 2018; Chen et al., 2019; Sun et al., 2019). Nota-se que houve uma melhoria nas propriedades técnicas dos sensores instalados em satélites orbitais, permitindo análises cada vez mais refinadas (Park, Im, and Kim 2019). Os produtos originados de satélite são úteis para identificar a dinâmica espaço-temporal em parâmetros biofísicos e geoquímicos (Sun et al., 2019; Park; Im; Kim, 2019). Vários pesquisadores têm

levantado estudos para estimar a distribuição dos fluxos de carbono em regiões secas do planeta (Gomes et al, 2019).

Na região semiárida brasileira, encontra-se a maior Floresta Tropical Sazonalmente Seca continua nas américas (Miranda et al. 2020). Constituído por um mosaico de espécies xerófila, com cactos suculentos, árvores são crassuláceas com estratos arbustivos adaptados a severas secas com formações vegetais secas, que compõem uma paisagem cálida e espinhosa, com estratos compostos por gramíneas, arbustos e árvores de porte baixo e médio (Sánchez et al. 2018). A vegetação da Caatinga apresenta dosséis semiabertos podendo atingir até 20 m de altura (Moura et al. 2017). A média do porte arbóreo fica em torno de 5 a 10 m, suas densidades variando entre 1000 a 3000 indivíduos com referência as plantas acima de 3 cm de diâmetro (Leal De Oliveira, Barbosa Santos, and Manzi 2005). Estudos apontam que a pouca quantidade de estudos realizados no Bioma Caatinga devido a complexidade e o alto custo das instalações de dados de EC, nesse contexto modelos ecológicos e ecossistêmico como métodos alternativos para simular às interações entre biosfera e atmosfera (Mendes et al. 2021; Oliveira et al. 2021).

Estudos realizados em ambientes secos na sua grande maioria avaliam a assimilação de energia e fluxos de CO<sub>2</sub> por meio do Surface Energy Balance Algorithms for Lnad-SEBAL ou o produto já pronto do MOD17A2, como pode ser visto no estudo de Ferreira et al. (2020) avaliaram a estimativa da PPB em um fragmento de Caatinga preservada, utilizaram a PPB derivada do produto MOD17A2 e dados EC instalado em área de Caatinga, a validação foi realizada comparações estatísticas por meio de dados micrometeorológicos medidos in situ, os resultados apontaram que, embora o produto MOD17A2 represente o comportamento da PPB, o algoritmo pode ser melhorado para oferecer dados mais semelhantes aos medidos na superfície. Morais et al. (2017) utilizaram imagens do produto MOD17A2 para estimar PPB e PPL em área de Caatinga, Brasil. Silva et al. (2013) determinaram a PPB no perímetro irrigado São Gonçalo -PB, localizado no Semiárido brasileiro, com imagens TM – Landsat 5 e dados complementares de superfície, os resultados obtidos foram comparados aos valores da PPB extraídos do produto MOD17A2. Lacerda (et al. 2020) utilizaram o produto MOD17A2 para avaliar a quantificação da PPB sob influência do relevo, da altitude, da precipitação e do solo na unidade de conservação Reserva de Vida Silvestre Tatu-Bola (REVIS) inserida no Bioma Caatinga. Maselli et al, (2017)

modelaram e analisaram a dinâmica da água e do carbono na Ilha Pianosa, no Mediterrâneo, foi utilizado dados de sensoriamento remoto (conjunto de dados LiDAR, imagens de satélites dos sensores Landsat OLI e MODIS) e dados de EC.

Assim, métodos que tentam medir a PPB em Floresta Tropical Sazonalmente Seca usando conjunto de dados de reflectância são muito escassos, porém podem apresentar bons resultados. Este estudo tem como objetivo desenvolver e avaliar modelos para estimativa Produção Primária Bruta no Bioma da Caatinga em Pernambuco, com base em reflectâncias obtidas no sensoriamento remoto.

### Material e métodos

A área de estudo compreende uma área de Floresta Tropical Sazonalmente Seca, a Caatinga no Estado de Pernambuco (Ponto vermelho na Figura 1). A EMBRAPA está localizada no

município de Petrolina, Pernambuco, Brasil (09S 03', W 40W 10', 380 m). A vegetação nesta área consiste em arbustos, árvores, plantas herbáceas e cactáceas. A altura média do dossel é de 4,5 m (Miranda et al. 2020). As espécies predominantes são *Poincianella microphylla* (Mart.), *Croton conduplicatus* Kunth, *Bauhinia cheilantha* (Bong.), *Manihot pseudoglaziovii* (Pax & Hoffman) e *Commiphora leptophloeos* (Mart.). (Souza et al. 2015). Predominam-se os solos com baixo desenvolvimento como os Neossolos, além dos Planossolos, e pequenas manchas de solos desenvolvidos como os Latossolos e Argissolos, entre outros.

O clima é semiárido (Alvares et al. 2013), com a estação chuvosa entre janeiro e abril e uma temperatura média anual de 26 ° C, a precipitação pluviométrica média anual é de 578 mm, evaporação anual de 2000 mm e umidade relativa média anual de 60% (Moura et al., 2007).

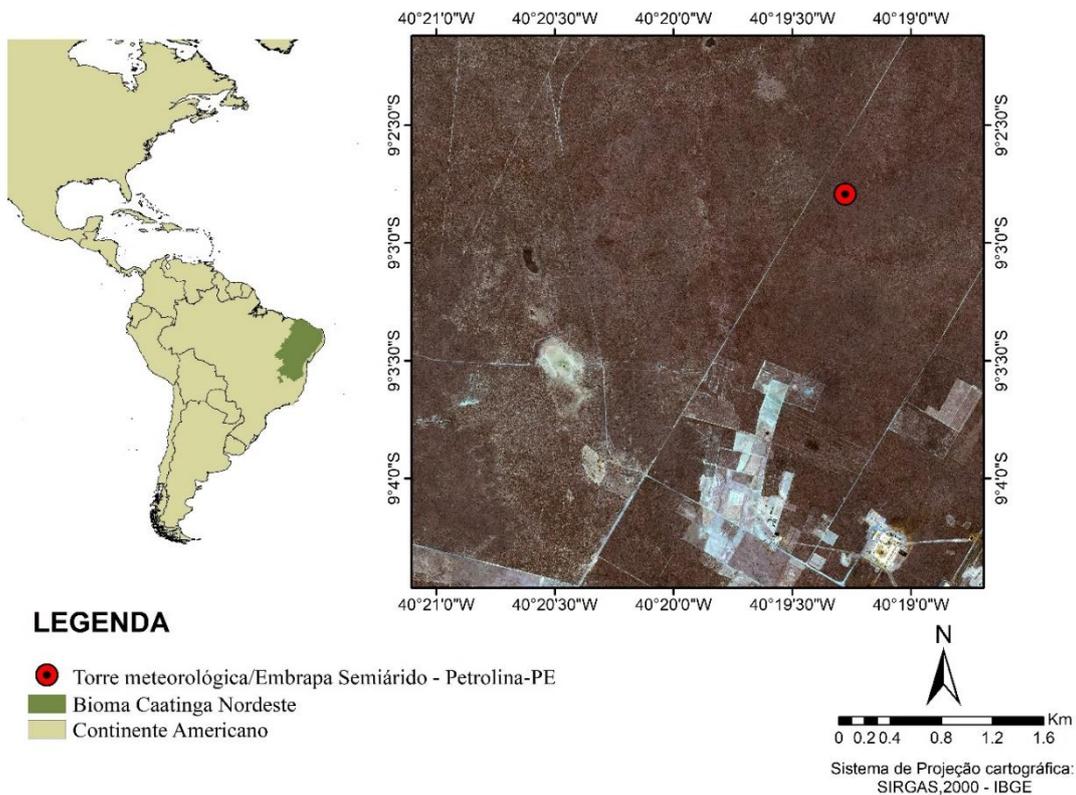


Figura 1. Embrapa Semiárido, oeste do Estado de Pernambuco, Petrolina – Brasil.

### Obtenção e processamento de imagens orbitais

Nesta etapa foram obtidas todas as imagens dos sensores MODIS (*Moderate Resolution Imaging Spectroradiometer*) e OLI/Landsat 8 obtido livremente pelo banco de dados <https://earthexplorer.usgs.gov/>. Obtivemos os dados de reflectância da superfície terrestre (MOD09A1) e o produto Level 2 de refletância da superfície, com base nas informações de latitude e longitude da torre de fluxo de covariância de vórtices na floresta de Caatinga de Janeiro de 2019

a março de 2019.

**MODIS.** Utilizou-se a refletância da superfície do produto (MOD09GA) a partir do MODIS/TERRA satélite do sensor, foram adquiridas nove cenas para a período de análise. Os valores de pixel de MOD09GA de oito dias representam os valores de refletância ideais para janelas de composição de oito dias, selecionando pixels com ângulos de visualização ideais e impactos mínimos de sombra na nuvem ou na nuvem. As séries temporais extraídas foram usadas

com garantia de Qualidade / Controle de Qualidade (QA / QC), assegurando a qualidade do produto MOD09GA. O MOD09GA é composto por sete bandas com resolução diária, que possuem valores de refletância da superfície com 500 m de resolução espacial no visível ( $\rho_1 = 620-670$  nm;  $\rho_3 = 459-479$  nm;  $\rho_{34} = 545-565$  nm), infravermelho próximo ( $\rho_2 = 841-876$  nm;  $\rho_5 = 1230-1250$  nm), e infravermelho médio ( $\rho_6 = 1628-1652$  nm;  $\rho_7 = 2105-2155$  nm). O produto MOD17 (Produção Primária Bruta – PPB e Líquida – PPL e Fotossíntese Líquida - PSN\_net), este produto possui três camadas: PPB, PPL, PSN\_net e qualidade do pixel. Estes dados são corrigidos para os efeitos atmosféricos, tais como gases atmosféricos e aerossóis.

**Landsat.** Utilizou-se a refletância de superfície (SR) Landsat-8 de 16 dias e os dados de Garantia de Qualidade (QA) associados da Arquitetura de Processamento Científico do Centro de Observação e Ciências da Terra do USGS: <https://espa.cr.usgs.gov/>. Do sensor OLI, foi utilizado o produto Level 2 de refletância da superfície com resolução temporal de 16 dias, e espacial de 30 m, foram adquiridas 6 cenas para o período de estudo. Este produto é composto por sete bandas espectrais distribuídas no espectro do visível ( $\rho_1 = 435-451$  nm;  $\rho_2 = 452-512$  nm;  $\rho_3 = 533-590$  nm;  $\rho_4 = 636-673$  nm), infravermelho próximo ( $\rho_5 = 851-879$  nm), e infravermelho médio ( $\rho_6 = 1566-1651$  nm;  $\rho_7 = 2107-2294$  nm).

Os valores de refletância da superfície da terra foram medidos valores médios para os pixels cobrindo parcialmente a torre de fluxo, apenas o pixel com as métricas de garantia de qualidade mais altas foi usado.

### Obtenção e pré-processamento de dados hiperspectrais

As medidas radiométricas do dossel vegetal plantas coletadas entre os meses de janeiro a março de 2019 em escala temporal de 8 em 8 dias. Foram medidas as posições dos dosséis em quatro direções (Norte, Sul, Leste e Oeste). A altura das medições do espectrorradiômetro foi de aproximadamente 10 metros do terreno, medido da torre de fluxo de covariância de vórtices na floresta de Caatinga.

Foi utilizado o espectrorradiômetro portátil *FieldSpec Spectroradiometer da Analytical Spectral Devices (ASD)*. *FieldSpec*®3, o qual adquire dados de refletância. A faixa espectral e o campo de visão do sensor foram de 350–2500 nm. Para cada data e cada área amostral foram obtidas quatro leituras, as quais foram convertidas em uma única leitura por meio de cálculo de média aritmética simples, para cada tratamento e coleta

realizada. Após a obtenção das curvas espectrais do sensor *FieldSpec*®3, primeiramente delimitou-se a região espectral em que a vegetação responde a atividade espectral (400-2500nm). Para verificar a aplicabilidade da localização e abrangência das bandas espectrais, foi feita uma simulação das respostas espectrais do sensor OLI, foi utilizado o produto Level 2 de refletância da superfície e MODIS produto MOD09GA. Com o objetivo de aplicar o classificador e analisar espectralmente as classes com base em dados físicos, os valores dos números digitais da imagem Landsat 8 sensor OLI, MODIS e do espectrorradiômetro foram serão convertidos para valores de refletância.

### Reamostragem espectral

Dada a diferença na resolução espectral entre as bandas das imagens OLI/Landsat8 e do MODIS, e visando o aproveitamento de ambos os conjuntos de bandas para a classificação, foi aplicado o método de reamostragem. Foi realizada a seleção de amostras espectrais na imagem (espectros de referência), considerando o ponto espectral do local de coleta. Foram reamostradas os comprimentos de ondas do ( $\rho_1 = 620-670$  nm;  $\rho_3 = 459-479$  nm;  $\rho_{34} = 545-565$  nm), infravermelho próximo ( $\rho_2 = 841-876$  nm;  $\rho_5 = 1230-1250$  nm), e infravermelho médio ( $\rho_6 = 1628-1652$  nm;  $\rho_7 = 2105-2155$  nm) e sensor OLI visível ( $\rho_1 = 435-451$  nm;  $\rho_2 = 452-512$  nm;  $\rho_3 = 533-590$  nm;  $\rho_4 = 636-673$  nm), infravermelho próximo ( $\rho_5 = 851-879$  nm), e infravermelho médio ( $\rho_6 = 1566-1651$  nm;  $\rho_7 = 2107-2294$  nm). Para verificar de forma quantitativa as semelhanças e diferenças entre as curvas espectrais foi realizada uma análise de correlação entre os valores de refletância correspondentes as medições espectrorradiométricas e as obtidas a partir das imagens, além de um teste de hipóteses com nível de significância  $\alpha = 0,05$  sobre os coeficientes de correlação  $\rho$ , para conhecer se associação ou correlação entre as variáveis eram significativas.

### Calibração dos modelos

Os modelos foram construídos a partir das combinações das bandas ( $\rho_{350}, \rho_{351}, \rho_{352}, \dots, \rho_{2500}$ ) suas transformações ( $\rho, 1/\rho, \ln(\rho), \log_{10}(\rho), \sqrt{\rho}, \rho^2, e^\rho$ ), e operações matemáticas (+, -, ×, ÷). O número de modelos avaliados pode ser calculado usando a seguinte função, onde  $\rho$  é a refletância e  $nc$  é o número de parâmetros inseridos no modelo (Eq. 1). Para tal, foi desenvolvido para este estudo um software de computador na linguagem de programação Python 2.7,

denominado “Correlator”.

$$f(nc) = C_{\begin{matrix} \rho_{350} & \rho_{351} & \rho_{352} \\ \rho_{353} & \rho_{354} & \rho_{355} \\ \rho_{356} & \dots & \rho_{2500} \end{matrix}}^{nc} + (nc-1) \times C_{\begin{matrix} \rho & 1/\rho & \ln(\rho) \\ \log_{10}(\rho) & \sqrt{\rho} & \rho^2 \\ e^\rho & & \end{matrix}}^{nc} + (nc-1) \tag{1}$$

$$\times \begin{cases} 1, & nc = 1 \\ C_{\begin{matrix} + & - \\ \times & \div \end{matrix}}^{(nc-1)} + (nc-2), & nc \geq 2 \end{cases}$$

**Validação dos modelos criados**

Os desempenhos dos modelos foram avaliados utilizando dois índices estatísticos, um de tendência (coeficiente de Pearson–r)

$$r = \frac{\text{cov}(x,y)}{\text{var}(x) \text{var}(y)} = \frac{\sum_{i=1}^n [(x_i\bar{x})(y_i\bar{y})]}{\sqrt{\sum_{i=1}^n (x_i\bar{x})^2} \sqrt{\sum_{i=1}^n (y_i\bar{y})^2}}, \tag{2}$$

onde:  $b = \frac{\text{cov}(x, y)}{\text{var}(x)},$  (2)

$a = \bar{y} - b\bar{x}$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}} \tag{3}$$

$PBIAS = 100 * [ \text{sum}( sim - obs ) / \text{sum}( obs ) ].$  (4)

e outro de desvio (Erro médio quadrático (RMSE–RMSE), e o PBIAS, utilizando as seguintes equações respectivamente:

## Resultados e discussão

Na Tabela 1 estão representados os valores de  $r^2$ , RMSE e o PBIAS associados com a PPB ( $g\ C\ m^{-2}\ d^{-1}$ ) obtidos com os sensores OLI/Landsat 8, e MODIS/Terra (MOD09GA).

Os modelos calibrados demonstraram bom desempenho na previsão com o uso das bandas do sensor OLI/Landsat 8 e do MODIS/Terra (MOD09GA). No conjunto de dados da calibração, os valores de coeficiente de determinação  $r^2$  do sensor MODIS/Terra (MOD09GA) obteve melhores resultados  $r^2 = 0,95$ , RMSE = 0,29 e o PBIAS=1,12% ( $g\ C\ m^{-2}\ d^{-1}$ ) como podemos observar na eq.6. Resultados similares pode ser visto no estudo de Run et al, 2017 os autores utilizaram diferentes fórmulas para calcular o PPB com os sensores MODIS/Terra (MOD09GA) e (MOD17A2), os resultados das métricas para calibração dos modelos aplicação diferentes sistemas ecológicos foi de  $r^2 = 0,97$  e RMSE = 1,61.

Os valores dos coeficientes de determinação demonstraram eficiência nos dois sensores utilizados, foram classificados como excelente segundo a escala de Hoffmann et al, (2015), seu maior valor foi na eq.6  $r^2 = 0,95$  e o menor nas eq.4 e eq.5 com os valores de  $r^2 = 0,81$ . A raiz quadrada do erro-médio (RMSE) variou entre satisfatório e bom, sendo que o sensor MODIS/Terra (MOD09GA) obteve resultado classificado como bom na eq.6.

Os resultados foram considerados aceitáveis quando avaliados pelos coeficientes PBIAS, visto que os valores estão dentro da faixa considerada excelente pelo PBIAS ficaram na faixa do <15%, foram os valores referidos ao sensor MODIS/Terra (MOD09GA) como podemos observar que na Tabela 3, os valores do PBIAS do sensor Landsat ficaram na faixa do valor considerado insatisfatório >70%. Observa-se que os modelos do sensor OLI/Landsat 8 na sua grande maioria superestimou, considerando que apenas a eq.1 subestimou. Para tanto, os valores do PBIAS do MODIS/Terra (MOD09GA) subestimou, podendo observar que apenas a eq.7 superestimou.

As bandas que demonstraram maior eficiência no sensor do OLI/Landsat 8 de uso foram infravermelho próximo ( $\rho_5 = 851-879\ nm$ ) onde obtém pouca absorção de radiação, a absorção de água geralmente é baixa e a reflectância tende a ser constante (Ponzoni e Shimabukuro, 2012). No estudo de Medeiros et al., (2019) os resultados indicam que existe uma correlação positiva entre a riqueza vegetal e a faixa espectral do infravermelho próximo (NIR) ( $r = 0,744$ ;  $p < 0,001$ ) na vegetação na região Semiárida. O alto potencial da banda espectral do infravermelho próximo acontece em razão da interação da radiação eletromagnética nessa faixa do espectro com as copas das plantas, sendo assim, quanto maior o número de camadas a nível de dossel, maior é o espalhamento múltiplo (Ponzoni e Shimabukuro, 2010; Medeiros et al, 2019). No sensor MODIS/Terra (MOD09GA) a banda mais utilizada foi a do visível ( $\rho_1 = 620-670\ nm$ ) essa região identifica os pigmentos existentes na vegetação (Ponzoni e Shimabukuro, 2012). Zhang et al (2014) utilizaram por meio de análises abrangentes, sobre a refletância espectral da copa, a luz visível para infravermelho próximo, para desenvolver os índices de vegetação. Vários autores têm utilizado em seus estudos novos modelos de índices de vegetação, e propuseram que as bandas espectrais do visível e do infravermelho próximo tem sido bem utilizada, já que tem melhorado a precisão da extração de informações da vegetação através do cálculo da banda em diferentes formas (Ihuoma; Madramootoo, 2019; Zhang, X. et al., 2019). Dai et al., (2018) empregaram essas mesmas métricas estatísticas ao avaliar modelos de GPP em manguezais nas áreas costeiras ao longo do Golfo do México e do Caribe mexicano com bom desempenho do modelo. O produto do PPB (MOD17A2) é bem utilizado como parâmetro em modelos de sensoriamento remoto, já que é útil para fazer estimativas utilizando os parâmetros estáticos na calibração e precisão dos modelos (RUN et al, 2017).

**Tabela 1.** Calibração de modelos de Produtividade Primária Bruta (PPB; g C m<sup>-2</sup> d<sup>-1</sup>), utilizando dados de espectrorradiômetro reamostrados para refletir as bandas dos sensores OLI/Landsat 8, e MODIS/Terra (MOD09GA).

Modelo		r <sup>2</sup> *	RMSE	PBIAS
Eq. 1	$y = \begin{cases} 23 + (\rho_4^2 - \log_{10}(\rho_5) \times \sqrt{\rho_5}) \times -56, & y > 1,81 \\ 0, & y \leq 1,81 \end{cases}$	0,83	0,55	4,31
Eq. 2	$y = \begin{cases} 5 + (\rho_5^2 - \rho_6 / \ln(\rho_6)) \times 22, & y > 1,67 \\ 0, & y \leq 1,67 \end{cases}$	0,83	0,56	-5,36
Eq. 3	$y = \begin{cases} 5 + (\rho_6^2 - \rho_5^2 \times \sqrt{\rho_7}) \times -70, & y > 1,53 \\ 0, & y \leq 1,53 \end{cases}$	0,82	0,57	-5,35
Eq. 4	$y = \begin{cases} 5 + (\rho_6^2 + \rho_5^2 / \ln(\rho_1)) \times -62, & y > 1,55 \\ 0, & y \leq 1,55 \end{cases}$	0,81	0,58	-4,60
Eq. 5	$y = \begin{cases} 4 + (\rho_5^2 + \rho_6^2 / \log_{10}(\rho_5)) \times 35, & y > 1,28 \\ 0, & y \leq 1,28 \end{cases}$	0,81	0,58	-4,48
Eq. 6	$y = \begin{cases} 269 + (e^{\rho_1} + \rho_7 / \ln(\rho_4)) \times -262, & y > 1,13 \\ 0, & y \leq 1,13 \end{cases}$	0,95	0,29	1,12
Eq. 7	$y = \begin{cases} 7 + (\rho_1 + \rho_7 / \ln(\rho_3)) \times -202, & y > 1 \\ 0, & y \leq 1 \end{cases}$	0,89	0,43	-2,24
Eq. 8	$y = \begin{cases} 14 + \left( \frac{\ln(\rho_7)}{\frac{\sqrt{\rho_6}}{1/\rho_1}} \right) \times 42, & y > 1,88 \\ 0, & y \leq 1,88 \end{cases}$	0,87	0,47	3,01
Eq. 9	$y = \begin{cases} 14 + \left( \frac{\log_{10}(\rho_7)}{\frac{\sqrt{\rho_6}}{1/\rho_1}} \right) \times 97, & y > 1,84 \\ 0, & y \leq 1,84 \end{cases}$	0,87	0,47	2,02
Eq. 10	$y = \begin{cases} 14 + \left( \frac{\rho_1}{\sqrt{\rho_6}} \times \ln(\rho_7) \right) \times 42, & y > 1,88 \\ 0, & y \leq 1,88 \end{cases}$	0,87	0,47	3,01

\*significante estatisticamente (α=0,05). Eqs. 1–5: OLI/L8; Eqs 6–10: MODIS/Terra (MOD09GA)

A Tabela 2 apresenta a validação dos modelos criados dos sensores OLI/Landsat 8, e MODIS/Terra (MOD09GA). As métricas não demonstraram estimativas confiáveis para o sensor OLI/Landsat 8, as equações dos modelos apresentaram o coeficiente de determinação com valores insatisfatório nas eq.1,2 e 4, nas eq. 2 e 6 os valores ficaram classificados como bom. O RMSE apresentou erros insatisfatório, como podemos observar na Eq.1 RMSE = 4,53. O PBIAS superestimou nas equações 1, 2 e 3, sendo que na

equação 3 foi avaliado como excelente.

Analizamos o desempenho das equações do sensor MODIS/Terra (MOD09GA). Os resultados do coeficiente de determinação no pixel da torre são apresentados na Tabela 2. As métricas foram validadas nas eq.6 e 7, os valores do r<sup>2</sup> foram considerados muito bom, os valores dos erros foram insatisfatórios, enquanto os valores do PBIAS subestimaram e foram considerados satisfatórios. As eq. 8, 9 e 10 não foram validadas.

**Tabela 2.** Validação dos modelos criados, utilizando dados dos sensores OLI/Landsat 8, e MODIS/Terra (MOD09GA).

Modelo	r <sup>2</sup> *	RMSE	PBIAS
Eq. 1	-0,18	4,53	49,50
Eq. 2	-0,47	2,04	49,44
Eq. 3	0,47	1,73	16,98
Eq. 4	-0,19	3,05	-28,49
Eq. 5	0,63	2,19	-42,78
Eq. 6	0,74	2,02	-53,75
Eq. 7	0,70	1,00	-19,55
Eq. 8	-	-	-
Eq. 9	-	-	-
Eq. 10	-	-	-

\*significante estatisticamente ( $\alpha=0,05$ )

Eqs. 1–5: OLI/L8; Eqs 6–10: MODIS/Terra (MOD09GA)

### Conclusões

Nosso estudo desenvolveu e avaliou dez modelos para a estimativa da Produção Primária Bruta para o ecossistema Caatinga. Sendo os melhores modelos quando utilizados para dados de refletâncias do sensor MODIS.

### Agradecimentos

Os autores agradecem à Fundação de Amparo à Ciência e Tecnologia do Estado de Pernambuco-FACEPE pelo auxílio financeiro junto ao Edital de número 27/2017, processo nº: IBPG-0030-9.25/18. À Embrapa Semiárido pela disponibilização dos dados de campo. Ao laboratório de sensoriamento remoto e geoprocessamento - SERGEO, e a Universidade Federal de Pernambuco - UFPE.

### Referências

- Alvares, Clayton Alcarde et al. 2013. “Köppen’s Climate Classification Map for Brazil.” *Meteorologische Zeitschrift*: 711–28.
- Bandim, C.G., Galvêncio, J. D. 2021. Mapeamento das áreas de armazenamento de água em depressão, usando dados Lidar: Estudo de caso avenida Caxangá. *Revista Brasileira de Geografia Física*, 14, 058-067. DOI: <https://doi.org/10.26848/rbgf.v14.1.p058-067>
- Brito Morais, Ygor Cristiano et al. 2017. “Análise Do Sequestro de Carbono Em Áreas de Caatinga Do Semiárido Pernambucano.” *Revista Brasileira de Meteorologia* 32(4): 585–99. [http://www.scielo.br/scielo.php?script=sci\\_arttext&pid=S0102-77862017000400585&tlng=pt](http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0102-77862017000400585&tlng=pt) (June 17, 2019).
- Chen, Shiliu, Yuefei Huang, Shuai Gao, and Guangqian Wang. 2019. “Impact of Physiological and Phenological Change on Carbon Uptake on

the Tibetan Plateau Revealed through GPP Estimation Based on Spaceborne Solar-Induced Fluorescence.” *Science of The Total Environment* 663: 45–59.

<https://www.sciencedirect.com/science/article/pii/S0048969719303031> (May 26, 2019).

Dai, Zhaohua, Carl C. Trettin, Steve Frohling, and Richard A. Birdsey. 2018. “Mangrove Carbon Assessment Tool: Model Validation and Assessment of Mangroves in Southern USA and Mexico.” *Estuarine, Coastal and Shelf Science* 208: 107–17.

<https://www.sciencedirect.com/science/article/pii/S0272771417304651> (August 2, 2019).

Ferreira, Rosaria R. et al. 2020. “An Assessment of the MOD17A2 Gross Primary Production Product in the Caatinga Biome, Brazil.” <https://doi.org/10.1080/01431161.2020.1826063> 42(4): 1275–91.

<https://www.tandfonline.com/doi/abs/10.1080/01431161.2020.1826063> (September 21, 2021).

França, L., Diaz, C., Reis, J., Costa, V., Galvêncio, J. 2019. Efeitos da precipitação na vazão da bacia hidrográfica do rio Pajeú-PE. *Revista Brasileira de Geografia Física*, 12(6), 2377-2391. doi:<https://doi.org/10.26848/rbgf.v12.6.p2377-2391>

Galvêncio, J. D. Luz, G. G. 2021. Desenvolvimento de Modelo que Estima o Impacto do CO<sub>2</sub> Atmosférico nas Precipitações do Estado de Pernambuco, utilizando ARIMA. *Revista Brasileira de Geografia Física*, 14, 1840-1851. Doi:<https://doi.org/10.26848/rbgf.v14.4.p1840-1851>

Galvêncio, J. 2020. Estimation of surface temperature with images obtained with drones. *Journal of*

- Hyperspectral Remote Sensing, 9(6), 397-406. doi:<https://doi.org/10.29150/jhrs.v9.6.p397-406>
- Galvêncio, J., & Naue, C. 2020. Estimation of NDVI with visible images (RGB) obtained with drones. *Journal of Hyperspectral Remote Sensing*, 9(6), 407-420. doi:<https://doi.org/10.29150/jhrs.v9.6.p407-420>
- He, Yue et al. 2018. "Global Patterns of Vegetation Carbon Use Efficiency and Their Climate Drivers Deduced from MODIS Satellite Data and Process-Based Models." *Agricultural and Forest Meteorology* 256-257: 150-58. <https://www.sciencedirect.com/science/article/pii/S0168192318300923> (May 26, 2019).
- Ihuoma, Samuel O., and Chandra A. Madramootoo. 2019. "Sensitivity of Spectral Vegetation Indices for Monitoring Water Stress in Tomato Plants." *Computers and Electronics in Agriculture* 163: 104860. <https://www.sciencedirect.com/science/article/pii/S0168169918313590> (August 13, 2019).
- Lacerda, Aldenice Correia et al. 2020. "Revista Brasileira de Geografia Física." 06: 3119-35.
- Leal De Oliveira, Maria Betânia, José Barbosa Santos, and Ocimar Manzi. 2005. Trocas De Energia E Fluxo De Carbono Entre A Vegetação De Caatinga E Atmosfera No Nordeste Brasileiro. <https://www.alice.cnptia.embrapa.br/bitstream/doc/159429/1/OPB1338.pdf> (June 17, 2019).
- Liu, Zhengjia, Lunche Wang, and Sisi Wang. 2014. "Comparison of Different GPP Models in China Using MODIS Image and ChinaFLUX Data." *Remote Sensing* 6(10): 10215-31. [www.mdpi.com/journal/remotesensingArticle](http://www.mdpi.com/journal/remotesensingArticle) (May 10, 2021).
- Lima, C. E. S., Costa, V. S. O., Galvêncio, J. D., Silva, R. M., Santos, C. A. G., 2021. Assessment of automated evapotranspiration estimates obtained using the GP-SEBAL algorithm for dry forest vegetation (Caatinga) and agricultural areas in the Brazilian semiarid region. *Agricultural Water Management*, 250, 106863.
- Mendes, Keila R. et al. 2020. "Seasonal Variation in Net Ecosystem CO<sub>2</sub> Exchange of a Brazilian Seasonally Dry Tropical Forest." *Scientific Reports* 2020 10:1 10(1): 1-16. <https://www.nature.com/articles/s41598-020-66415-w> (September 21, 2021).
- . 2021. "Assessment of SITE for CO<sub>2</sub> and Energy Fluxes Simulations in a Seasonally Dry Tropical Forest (Caatinga Ecosystem)." *Forests* 2021, Vol. 12, Page 86 12(1): 86. <https://www.mdpi.com/1999-4907/12/1/86/html> (September 21, 2021).
- Miranda, Rodrigo de Queiroga et al. 2020. "Realistic and Simplified Models of Plant and Leaf Area Indices for a Seasonally Dry Tropical Forest." *International Journal of Applied Earth Observation and Geoinformation* 85: 101992.
- Miranda, R. Q., Galvêncio, J. D., Morais, Y. C. B.; Moura, M. S. B.; Jones, C. A. ; Srinivasan, R. 2018. Dry forest deforestation dynamics in Brazil's Pontal basin. *Revista Caatinga*, 31, 385-395.
- Moura, Yhasmin Mendes et al. 2017. "Spectral Analysis of Amazon Canopy Phenology during the Dry Season Using a Tower Hyperspectral Camera and Modis Observations." *ISPRS Journal of Photogrammetry and Remote Sensing* 131: 52-64. <https://www.sciencedirect.com/science/article/pii/S0924271617302733> (June 17, 2019).
- Morais, Y. C. B., Araújo, M. S. B., Moura, M. S. B.; Galvêncio, J. D., Miranda, R. Q. 2017. Análise do Sequestro de Carbono em Áreas de Caatinga do Semiárido Pernambucano. *Revista Brasileira de Meteorologia*, v. 32, p. 585-599, <https://doi.org/10.1590/0102-7786324007>
- Park, Haemi, Jungho Im, and Miae Kim. 2019. "Improvement of Satellite-Based Estimation of Gross Primary Production through Optimization of Meteorological Parameters and High Resolution Land Cover Information at Regional Scale over East Asia." *Agricultural and Forest Meteorology* 271: 180-92. <https://www.sciencedirect.com/science/article/pii/S016819231930098X> (May 26, 2019).
- Ren, Yan et al. 2017. "Using the Vegetation-Solar Radiation (VSr) Model to Estimate the Short-Term Gross Primary Production (GPP) of Vegetation in Jinghe County, XinJiang, China." *Ecological Engineering* 107: 208-15. <https://www.sciencedirect.com/science/article/pii/S0925857417304457> (May 26, 2019).
- Sánchez, A.S. et al. 2018. "Alternative Biodiesel Feedstock Systems in the Semi-Arid Region of Brazil: Implications for Ecosystem Services." *Renewable and Sustainable Energy Reviews* 81: 2744-58. <https://www.sciencedirect.com/science/article/pii/S1364032117310274> (June 17, 2019).
- Silva, Bernardo Barbosa da et al. 2013. "Determinação Por Sensoriamento Remoto Da Produtividade Primária Bruta Do Perímetro Irrigado São Gonçalo - PB." *Revista Brasileira de Meteorologia* 28(1): 57-64. <http://www.scielo.br/j/rbmet/a/3VnCc9pT9rcmCYWXzxFYMzg/?lang=pt> (September 21, 2021).
- Soares, G., Galvêncio, J. 2020. Uso do Lidar para avaliar os padrões hídricos de bacias em áreas

- urbanas: Caracterização fisiográfica da bacia do Rio Beberibe, PE. *Revista Brasileira de Geografia Física*, 13, 3659-3674. Disponível: [doi.org/10.26848/rbgf.v13.07.p3659-3674](https://doi.org/10.26848/rbgf.v13.07.p3659-3674)
- Souza, Luciana et al. 2015. "Balanço de Radiação Em Ecossistema de Caatinga Preservada Durante Um Ano de Seca No Semiárido Pernambucano (Radiation Balance in Caatinga Ecosystem Preserved for a Year Drought in Semiarid Pernambucano)." *Revista Brasileira de Geografia Física* 8(1): 041–055. <https://periodicos.ufpe.br/revistas/rbgfe/article/view/233357> (June 17, 2019).
- Sun, Zhongyi et al. 2019. "Evaluating and Comparing Remote Sensing Terrestrial GPP Models for Their Response to Climate Variability and CO2 Trends." *Science of The Total Environment* 668: 696–713. <https://www.sciencedirect.com/science/article/pii/S004896971931006X> (May 26, 2019).
- Wang, Jian et al. 2018. "Improved Modeling of Gross Primary Productivity (GPP) by Better Representation of Plant Phenological Indicators from Remote Sensing Using a Process Model." *Ecological Indicators* 88: 332–40. <https://www.sciencedirect.com/science/article/pii/S1470160X18300426> (May 26, 2019).
- Xiao, Xiangming et al. 2004. "Satellite-Based Modeling of Gross Primary Production in an Evergreen Needleleaf Forest." *Remote Sensing of Environment* 89(4): 519–34. <https://www.sciencedirect.com/science/article/pii/S0034425703003456> (June 17, 2019).
- Zhang, Qingyuan et al. 2014. "Estimation of Crop Gross Primary Production (GPP): FAPARchl versus MOD15A2 FPAR." *Remote Sensing of Environment* 153: 1–6. <https://www.sciencedirect.com/science/article/pii/S0034425714002600> (May 26, 2019).