

ESTIMATIVAS DE PRODUTIVIDADE PRIMÁRIA BRUTA (GPP) UTILIZANDO IMAGENS LANDSAT E O MODELO GEESEBAL

Wilany Rodrigues Galvão Alves¹, Anderson Luis Ruhoff², Vanessa de Arruda Souza³, Débora Regina Roberti⁴

¹ Instituto de Pesquisas Hidráulicas – Universidade Federal do Rio Grande do Sul, wilanyg.alves@gmail.com; ² Instituto de Pesquisas Hidráulicas – Universidade Federal do Rio Grande do Sul, andersonruhoff@gmail.com; ³ Instituto de Pesquisas Hidráulicas – Universidade Federal do Rio Grande do Sul, v.arruda.s@gmail.com; ⁴ Departamento de Física – Universidade Federal de Santa Maria, debora@ufsm.br

RESUMO

A GPP corresponde ao carbono fixado pela vegetação. Com o objetivo de facilitar a compreensão e analisar a dinâmica dos fluxos de carbono, foi desenvolvido uma ferramenta para estimar a GPP para o Brasil usando imagens *Landsat*. Utilizamos o modelo *geeSEBAL* associado ao *CASA* no ambiente de programação da plataforma *Google Earth Engine*. O modelo foi aplicado em oito sítios experimentais, localizados nos biomas da Amazônia, Cerrado e Pampa. As estimativas de GPP diárias obtidas pelo modelo *geeSEBAL* foram comparadas aos dados observados em torres de fluxo e também com o produto *MOD17*. Com os resultados obtidos, verificamos que o *geeSEBAL* e o *MOD17* apresentaram RMSD médio de 3,35 e 3,54 $\text{gCm}^{-2}\text{dia}^{-1}$ em relação aos dados observados e os valores de *R2* foram maiores para a região sul do Brasil.

Palavras-chave — *GPP*, *geeSEBAL*, *CASA*, *LUE*, *landsat*.

ABSTRACT

GPP corresponds to carbon fixed by vegetation. In order to facilitate the understanding of the dynamics of carbon fluxes, a tool was developed to estimate the GPP for Brazil using *Landsat* images. We used the *geeSEBAL* model associated with *CASA*, programming in the *Google Earth Engine* platform. The model was applied in eight locations in the Amazon, Cerrado and Pampa biomes. The daily GPP estimates obtained by the *geeSEBAL* model were compared to data observed in flux towers and also compared with the *MOD17* product. With the results obtained, we verified that the *geeSEBAL* and *MOD17* presented a mean RMSD of 3.35 and 3.54 $\text{gCm}^{-2}\text{day}^{-1}$ in relation to the observed data and the *R2* values were higher for the southern region of Brazil.

Key words — *GPP*, *geeSEBAL*, *CASA*, *LUE*, *landsat*

1. INTRODUÇÃO

Entender e quantificar as interações que ocorrem entre a superfície e a atmosfera são de extrema importância frente ao cenário de mudanças climáticas. Na agricultura, é essencial compreender o impacto de diferentes práticas de manejo do solo analisando sua contribuição no ciclo do carbono. Entre os indicadores, a Produtividade Primária Bruta (GPP - *Gross Primary Production*) corresponde a quantidade de carbono presente na atmosfera que é fixado pela vegetação e convertido em matéria orgânica por meio de processos fotossintéticos.

Dentre os métodos utilizados para quantificar a GPP, destaca-se a técnica da covariância de vórtices turbulentos (EC – *Eddy Covariance*) [1] que possibilita a medição imediata de fluxos através de um sistema de sensores instalados em torres micro meteorológicas. Entretanto, sua aplicação demanda um alto investimento e as estimativas se restringem a área e ao período monitorado.

Técnicas de sensoriamento remoto [2,3,4,5] têm sido utilizadas como uma alternativa no monitoramento de áreas de interesse. Índices de vegetação obtidos por sensoriamento remoto, unidos a variáveis meteorológicas possibilitam monitorar processos naturais de evapotranspiração, além de ser possível acompanhar estágios fisiológicos da planta, sobre uma ampla cobertura espacial e aplicabilidade de baixo custo.

Este trabalho tem como principal objetivo apresentar os resultados obtidos ao aplicar uma ferramenta desenvolvida para estimar a GPP por sensoriamento remoto. Para isso serão utilizadas imagens *Landsat*, como informações de entrada no modelo *geeSEBAL* [6], no ambiente de programação da plataforma *Google Earth Engine* (GEE).

2. MATERIAL E MÉTODOS

2.1. Área de estudo

O modelo foi aplicado em 8 pontos (Figura 1), localizados na Amazônia, Cerrado e Pampa, onde também estão localizadas torres de fluxo para possibilitar a validação dos resultados.

Ao todo, foram processadas 359 imagens, para diferentes períodos, conforme detalhado na Tabela 1.

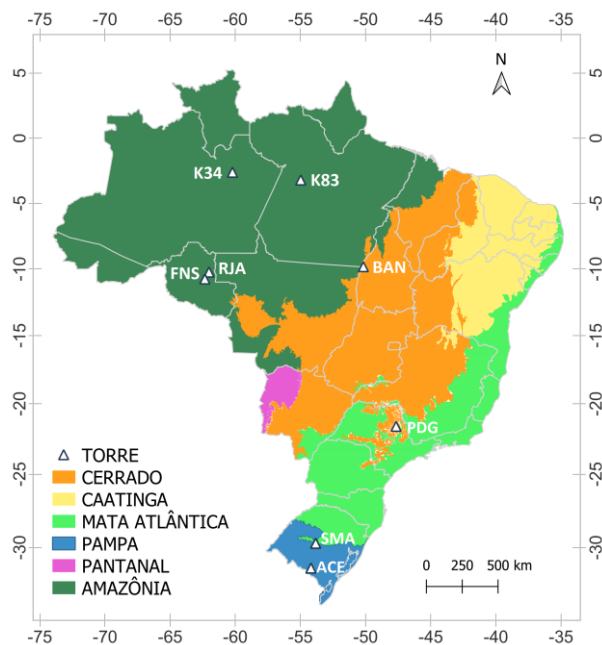


Figura 1. Sítios experimentais equipados com torres de fluxo

Local	Período	Nº de imagens	Cobertura
BAN	2003-2006	31	Formação florestal
PDG	2002-2003	08	Formação savânica
RJA	1999-2001	20	Formação florestal
FNS	2000-2001	23	Pastagem
K34	1999-2006	35	Formação florestal
K83	1999-2004	08	Formação florestal
SMA	2015-2021	173	Gramíneas
ACE	2018-2021	61	Gramíneas

Tabela 1. Detalhamento referente a cada local de estudo

2.2. Dados utilizados

Foram utilizadas imagens Landsat 5 com resolução espacial de 30 metros.

Os dados meteorológicos foram obtidos através do produto de reanálise ERA5 Land, que fornece informações horárias de variáveis de superfície [7].

Para determinar o uso e cobertura da terra foi utilizado o Projeto MapBiomos – Coleção 06 da Série Anual de Mapas de Uso e Cobertura da Terra do Brasil.

Para a validação foi utilizado séries temporais de dados diários do projeto LBA-ECO CD-32, versão 2 [8], com medições *in situ* de fluxos de carbono nos biomas Amazônia e Cerrado (sítios experimentais: BAN, PDG, RJA, FNS, K34 e K83). Para o bioma Pampa, foram utilizados dados do projeto SULFLUX (sítios experimentais: SMA e ACE).

O produto MOD17 [9] também foi utilizado com o intuito de avaliar o desempenho do modelo geeSEBAL em

relação a outro produto de sensoriamento remoto. O produto MOD17 disponibiliza estimativas acumuladas de GPP a cada 8 dias com uma resolução espacial de 500 metros.

Todos os dados foram processados na plataforma Google Earth Engine.

2.3. geeSEBAL

O SEBAL [10] é um modelo que permite estimar evapotranspiração através de imagens de satélite utilizando o balanço energético. Neste trabalho foi utilizada a ferramenta geeSEBAL [6] para obter a Fração Evaporativa (FE).

O modelo Carnegie Stanford Ames Approach (CASA) [11], possibilita calcular a GPP como resultado do produto da radiação fotossinteticamente ativa absorvida pela vegetação (APAR) e da eficiência do uso da luz (ϵ). Esse modelo foi adaptado [12] para adotar a fração evaporativa fornecida pelo SEBAL como elemento quantificador para o desenvolvimento dos cálculos de interesse, acoplando então o CASA ao SEBAL.

2.4. Fluxograma

A Figura 3 mostra o fluxograma que descreve os processos realizados para obter os resultados.

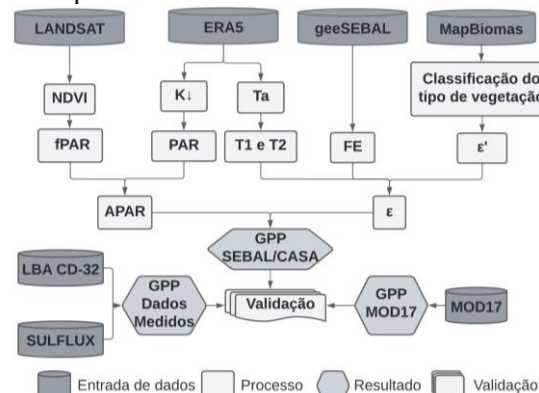


Figura 3. Fluxograma das etapas realizadas no trabalho

2.5. Modelo CASA para estimativa de GPP

A Radiação Fotossinteticamente Ativa (PAR), em $W \cdot m^{-2}$, é a parte da radiação solar de ondas curtas (0,3-3,0 m) que é absorvida pela clorofila durante o processo de fotossíntese [12]. Essa razão varia entre 45-50%. Neste estudo será adotado o valor de 48% da radiação solar global diária (K_{\downarrow}).

$$PAR = 0,48 \cdot K_{\downarrow} \quad (1)$$

Apenas uma fração (fPAR) da PAR é absorvida pela vegetação e pode ser calculada pela equação 02 a seguir:

$$fPAR = -0,161 + 1,257 \cdot NDVI \quad (2)$$

assim, a Radiação Fotossinteticamente Ativa Absorvida pela vegetação (APAR) é:

$$APAR = fPAR \cdot PAR \quad (Wm^{-2}) \quad (3)$$

O uso eficiente da luz pode ser quantificado como:

$$\varepsilon = \varepsilon' \cdot FE \cdot T_1 \cdot T_2 \quad (4)$$

Onde: ε' é a eficiência máxima de uso da luz pela vegetação sendo obtida através de adaptações de parâmetros para cada bioma e cobertura da terra; FE é a fração evaporativa obtida pelo geeSEBAL; e os fatores T_1 e T_2 indicam a influência da temperatura no uso eficiente da luz pelas plantas, sendo definidos pelas Equações 5 e 6, onde T_{opt} é a temperatura média do ar (°C) do mês de máximo NDVI e T_{day} é a temperatura média diária do ar (°C).

$$T_1 = 0,8 + 0,02T_{opt} - 0,0005T_{opt}^2 \quad (5)$$

$$T_2 = \frac{1}{1+exp(0,2T_{opt}-10-T_{day})} \cdot \frac{1}{1+exp[0,3(-T_{opt}-10+T_{day})]} \quad (6)$$

A partir dos parâmetros calculados anteriormente é possível estimar o valor da GPP em $g.C.m^{-2}.dia^{-1}$.

$$GPP = APAR \cdot \varepsilon \quad (7)$$

3. RESULTADOS

A Figura 4 mostra a variação sazonal de GPP ($gCm^{-2}dia^{-1}$) dos dados médios diários obtidos pelas torres de fluxos (EC), as estimativas diárias do modelo geeSEBAL e a média diária para o acumulado de 8 dias das estimativas do MOD17.

A Figura 5 mostra o comparativo das estimativas de GPP do modelo geeSEBAL com a observada no dia referente a cada imagem Landsat, e com a média diária do MOD17 para intervalo de 8 dias equivalente. A Tabela 2 mostra a análise do coeficiente R² e a raiz do desvio quadrático médio (RMSD) para o mesmo conjunto de dados.

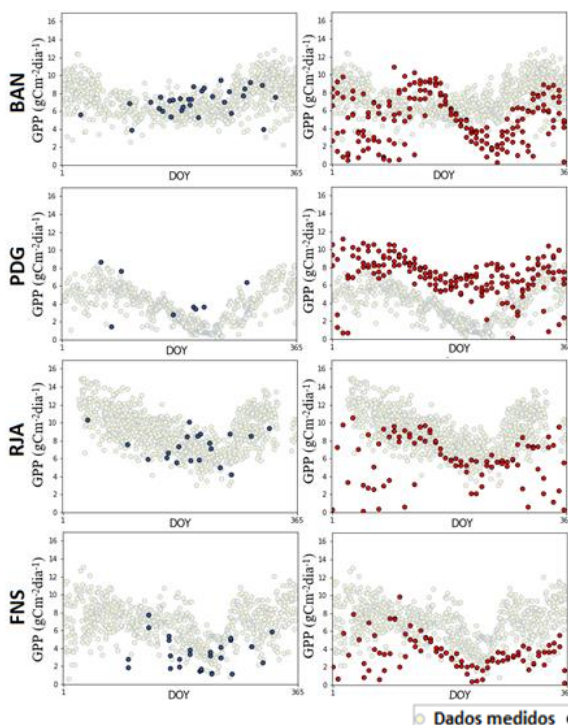


Figura 4. Variação sazonal dos dados medidos de torres de fluxo, e estimativas diárias dos modelos geeSEBAL e produto MOD17* (*média diária para acumulado de 8 dias).


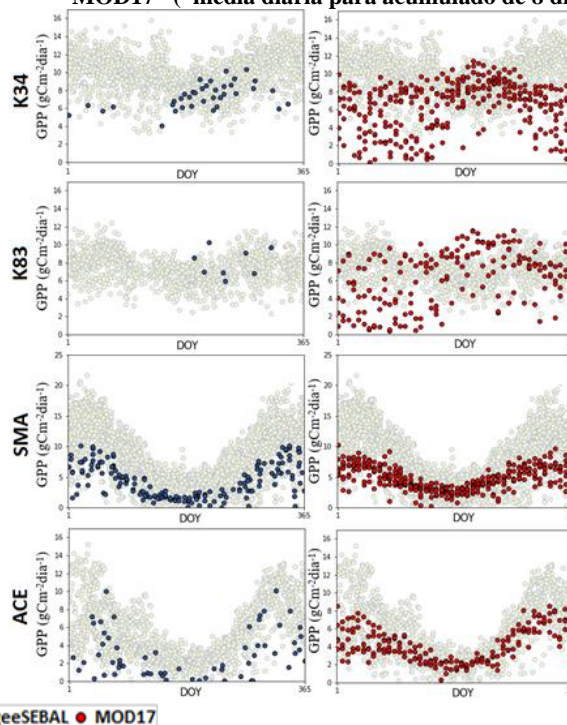


Figura 5. Comparação diária entre as medidas de torres de fluxo com as estimativas do modelo geeSEBAL e produto MOD17* (*média diária para acumulado de 8 dias).

Local	Nº de imagens	geeSEBAL-EC		MOD17-EC	
		RMSD	R ²	RMSD	R ²
BAN	21	2,06	0,00	3,82	0,04
PDG	08	2,52	0,32	3,63	0,77
RJA	11	2,83	0,12	2,72	0,52
FNS	22	3,52	0,30	3,20	0,35
K34	19	3,18	0,10	2,46	0,15
K83	03	2,96	0,23	4,55	0,79
SMA	168	6,08	0,44	5,31	0,62
ACE	61	3,67	0,55	2,61	0,58

Tabela 2. Métricas de comparação entre as medidas de torre de fluxos (EC) com a estimativa do modelo geeSEBAL e produto MOD17* (*média diária para acumulado de 8 dias).



4. DISCUSSÕES

Observamos baixos valores de R^2 em áreas tropicais úmidas (RJA, K34 e K83). Isso pode estar associado à pequena disponibilidade de imagens Landsat com baixa cobertura de nuvens. Os valores mais altos de R^2 foram obtidos para os sítios experimentais mais ao sul do Brasil, SMA e ACE. Estes sítios estão localizados em uma região de clima subtropical, apresentando uma sazonalidade bem definida. Além disso, há mais informações de dados, possibilitando um maior período analisado, e consequentemente mais imagens por sensoriamento remoto. O modelo geeSEBAL e o produto MOD17 apresentaram RMSD média de 3,35 e 3,54 $\text{gCm}^{-2}\text{dia}^{-1}$, respectivamente, em relação aos dados observados nas torres de fluxo. Para todos os sítios experimentais o produto MOD17 apresentou maiores valores de R^2 em relação ao modelo geeSEBAL.

5. CONCLUSÕES

De acordo com os resultados obtidos é possível concluir que o modelo geeSEBAL descreve uma boa sazonalidade para as estimativas de GPP em parte dos locais analisados. Os valores de RMSD indicam que o modelo geeSEBAL apresenta desempenho semelhante ao MOD17, porém os valores de R^2 foram inferiores, quando comparados ambas estimativas de GPP via sensoriamento remoto com os dados observados. É importante destacar a relevância de selecionar um número maior de imagens em trabalhos futuros para analisar melhor o desempenho das estimativas diárias de GPP e testar o modelo geeSEBAL para outros biomas.

6. REFERÊNCIAS

[1] Baldocchi, D.D. Assessing the Eddy Covariance Technique for Evaluating Carbon Dioxide Exchange Rates of Ecosystems: Past, Present and Future. *Global Change Biology*, 9, 479-492, **2003**. <https://doi.org/10.1046/j.1365-2486.2003.00629.x>

[2] Zhao, M. et al. Improvements of the MODIS terrestrial gross and net primary production global data set. – *Remote Sens. Environ.* 95: 164–176. **2005**

[3] Wu, C.Y.; Munger, J.W.; Niu, Z.; Kuang, D. Comparison of multiple models for estimating gross primary production using MODIS and eddy covariance data in Harvard Forest. *Remote Sens. Environ.* 114, 2925–2939. **2010**.

[4] Junttila, S.; Kelly, J.; Kljun, N.; Aurela, M.; Klemedtsson, L.; Lohila, A.; Nilsson, M.B.; Rinne, J.; Tuittila, E.-S.; Vestin, P.; Weslien, P.; Eklundh, L. Upscaling Northern Peatland CO₂ Fluxes Using Satellite Remote Sensing Data. *Remote Sens.* **2021**. <https://doi.org/10.3390/rs13040818>

[5] Lees, K.J., Quaife, T., Artz, R.R.E., Khomik, M., Clark, J.M. Potential for using remote sensing to estimate carbon fluxes across northern peatlands – A review, *Science of The Total Environment*, Volume 615, Pages 857-874, ISSN 0048-9697, **2018**. <https://doi.org/10.1016/j.scitotenv.2017.09.103>.

[6] Laipelt, L., Kayser, R.H. B., Kayser, Fleischmann A. S., Ruhoff A., Bastiaanssen W., Erickson T. A., Melton F., Long-term monitoring of evapotranspiration using the SEBAL algorithm and Google Earth Engine cloud computing, *ISPRS Journal of Photogrammetry and Remote Sensing*, Volume 178, Pages 81-96, ISSN 0924-2716, **2021**. <https://doi.org/10.1016/j.isprsjprs.2021.05.018>

[7] Muñoz Sabater, J. ERA5-Land hourly data from 1981 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS). **2019**.

[8] Saleska, S.R., H.R. da Rocha, A.R. Huete, A.D. Nobre, P.E. Artaxo, and Y.E. Shimabukuro. LBA-ECO CD-32 Flux Tower Network Data Compilation, Brazilian Amazon: 1999-2006. ORNL DAAC, Oak Ridge, Tennessee, USA. **2013**. <https://doi.org/10.3334/ORNLDAAC/1174>

[9] Running, S., Mu, Q., Zhao, M. MOD17 MODIS/Terra Gross Primary Productivity 8-Day L4 Global 500m SIN Grid V006 [Data set]. NASA EOSDIS Land Processes DAAC. **2015**. <https://doi.org/10.5067/MODIS/MOD17AH2.006>

[10] Bastiaanssen, W.G.M., Menenti, M., Feddes, R.A., Holtslag, A.A.M.. A remote sensing surface energy balance algorithm for land (SEBAL): 1. Formulation. *J. Hydrol.* 212–213, 198–212. **1998**. [https://doi.org/10.1016/S0022-1694\(98\)00253-4](https://doi.org/10.1016/S0022-1694(98)00253-4).

[11] Potter, C.S.; Randerson, J.T.; Field, C.B.; Matson, P.A.; Vitousek, P.M.; Mooney, H.A.; Klooster, S.A. Terrestrial ecosystem production: A process model based on global satellite and surface data. *Glob. Biogeochem. Cycle.* **1993**.

[12] BASTIAANSEN, W.G.M.; ALI, S. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. *Agriculture Ecosystems & Environment*, v.94, p.321-340, **2003**. [https://doi.org/10.1016/S0167-8809\(02\)00034-8](https://doi.org/10.1016/S0167-8809(02)00034-8)