

Inteligência Artificial Aplicada ao Aprimoramento de Parâmetros para o Monitoramento de Fluxo de Carbono por Satélite na Região Amazônica

Jean A. C. Dias¹, Leonardo de O. Tamasauskas¹, Pedro H. do V. Guimarães¹,
Alan B. S. Corrêa², João D. C. D. Neto¹, Albert E. C. dos Santos^{1,2},
Danilo Souza⁴, Ermínio R. Paixão^{1,2}, José G. dos S. Fernandes³,
Gabriel B. Costa³, Marcos C. da R. Seruffo^{1,2,3}

¹ Laboratório de Pesquisa Operacional (LPO)
Universidade Federal do Pará (UFPA), Belém-PA

² Programa de Pós Graduação em Engenharia Elétrica
Universidade Federal do Pará (UFPA), Belém-PA

³ Programa de Pós-Graduação em Estudos Antrópicos na Amazônia
Universidade Federal do Pará (UFPA), Castanhal-PA

⁴CARBONEXT
Belém-PA e São Paulo-SP

{jean.dias, alan.correa, albert.santos, erminio.paixao}@itec.ufpa.br,
{netodiasj1234, gabrielbritocosta, guilherme.profufpa}@gmail.com,
pedro.guimaraes@castanhal.ufpa.br, tamasauska@gmail.com,
erminio.paixao@itec.ufpa.br, seruffo@ufpa.br

Abstract. *The monitoring of atmospheric carbon flux has great importance in the comprehension of the ecosystems behaviors, being described in the measures of Gross Primary Production and Net Primary Production (GPP and NPP). Therefore, this article aims to apply the use of a machine learning algorithm to improve the parameters of the satellite product MOD17, in order to approximate their estimates of GPP and NPP in the Amazon to the Flux Towers' data at Santarém, in Brazil, and Iquitos, in Peru. Comparisons using the new obtained parameters demonstrated a reduction of the Root-Mean-Square Error (RMSE) in GPP of up to 9.72% and of the Mean Absolute Error (MAE) in NPP of up to 37.8%, indicating more precise and stable estimations.*

Resumo. *O monitoramento do fluxo de carbono na atmosfera tem grande importância na compreensão do comportamento dos ecossistemas, sendo descrito nas medições de Produção Primária Bruta (GPP) e Produção Primária Líquida (NPP). Por isso, este artigo busca aplicar inteligência artificial para melhorar os parâmetros do produto MOD17, a fim de aproximar as suas estimativas de GPP e NPP da Amazônia aos dados das Torres de Fluxo em Santarém, no Brasil, e Iquitos, no Peru. Comparações usando os novos parâmetros obtidos demonstraram uma redução na Raiz do Erro Quadrático Médio (RMSE) do GPP de até 9,72% e no Erro Médio Absoluto (MAE) para o NPP de até 37,8%, indicando estimativas mais estáveis e precisas.*

1. Introdução

A Amazônia desempenha um papel crucial no ciclo de carbono, atuando como a maior reserva por hectare de dióxido de carbono (CO_2) atmosférico do planeta, com sua proteção tendo papel crucial para combater o avanço das mudanças climáticas [Feitosa et al. 2023]. Nesse contexto, compreender melhor o fluxo de carbono na atmosfera da região se torna uma tarefa necessária para acompanhar as atividades realizadas na superfície que afetam a cobertura vegetal.

Para isso, é importante compreender as variáveis envolvidas nessa medição. Primeiramente, há a Produtividade Primária Bruta, ou GPP (do inglês, *Gross Primary Product*), que é a quantidade total de carbono que as plantas convertem em biomassa através da fotossíntese em um ecossistema, sendo então importante para compreender como a Floresta Amazônica influencia o clima global [Danelichen et al. 2015]. Ademais, há também a Produtividade Primária Líquida, ou NPP (do inglês, *Net Primary Product*), que representa todo o carbono utilizado pelo ecossistema, incluindo a manutenção e crescimento da vegetação [Anić et al. 2018].

Para obter tais medições, são necessárias fontes confiáveis e precisas para entender o comportamento dos dados, mas também de maior abrangência para poder mensurar o bioma inteiro. Para o fim de precisão, existe o AmeriFlux, que é uma rede de locais de estudos e pesquisadores que empregam a técnica de covariância de vórtices, ou EC (do inglês, *Eddy Covariance*), para quantificar os fluxos de carbono, água, energia e momento em diferentes ecossistemas das Américas utilizando as torres de fluxo.

No entanto, para regiões fora do alcance da torre, é preciso fazer estimativas com o auxílio de imagens de satélite, e para isso é utilizado o MOD17, um produto do sensor MODIS, transportado pelas coleções Terra e Aqua da NASA, que fornece estimativas globais de GPP¹ a cada 8 dias e de NPP² anualmente, sendo utilizado em estudos do ciclo de carbono terrestre, ajudando a entender a absorção de carbono pelas plantas.

Estudos anteriores buscaram melhorar a precisão das estimativas de GPP do produto MOD17 utilizando os dados *in situ*, usando a técnica bayesiana de fusão de dados do modelo [Wang et al. 2019, Endsley et al. 2023]. Nestas abordagens, por meio de algoritmos como a Cadeia de Markov de Monte Carlo se buscam novos valores dos parâmetros para o cálculo do GPP, dentro de limites estabelecidos previamente, a fim de aumentar a correlação com a torre de EC [Huang et al. 2021].

Visto que a abordagem citada foi capaz de melhorar as aproximações anteriores, foi considerado pertinente estudar outras heurísticas de busca capazes de obter bons resultados. Nesse sentido, o Algoritmo Genético (AG) têm se destacado como uma poderosa ferramenta de otimização, podendo ser aplicado para aprimorar parâmetros com o objetivo de minimizar o erro calculado e têm grande relevância no estado da arte no âmbito de monitoramento ambiental [Hong Tao and Lü 2019] e [Liu et al. 2023].

Portanto, no presente artigo foi utilizado AG para aprimorar os parâmetros do algoritmo MOD17 com base nos dados das torres de fluxo, com o objetivo de melhorar as estimativas de GPP, e em consequência, melhorar os resultados de NPP. A calibração desses algoritmos é fundamental para garantir a precisão em relação aos dados reais, especialmente em áreas não cobertas pelas torres e que dependem da coleta dos dados dos sensores MODIS.

Este artigo está dividido nas seguintes seções: Na segunda, se disserta sobre a metodologia, desde a obtenção dos dados até a técnica usada para melhoria dos parâmetros; na terceira, se apresentam os resultados obtidos, comparando a nova estimativa com a original; na quarta, se discorre sobre as conclusões alcançadas.

2. Metodologia

A metodologia de pesquisa foi realizada em cinco fases: na primeira fase, foi feita a seleção da área de estudo, conforme a disponibilidade de torres; na segunda, foi realizada a coleta e preparação dos dados, obtendo os valores de GPP e NPP nas torres a partir das fontes *in situ* e pelo algoritmo do satélite; na terceira, faz-se a análise comparativa e estatística das séries de dados em ambas as fontes; na quarta, ocorreu a aplicação do AG nos parâmetros usados no satélite para encontrar melhorias; na fase final, foram selecionados os melhores resultados e organizados para discussão.

2.1. Seleção da Área de Estudo

Para os fins deste estudo, buscou-se analisar pontos representativos da região amazônica. Nesse sentido, foi realizada uma pesquisa na base de dados da Ameriflux³, por torres dentro da licença aberta de uso, com no mínimo um ano de dados disponíveis, com a data mais recente possível da região, dentro da área do bioma amazônico. Nestes critérios, foram encontradas apenas duas torres, uma na área brasileira e outra na área peruana.

A torre em BR-Sa1 (54° 57' O, 2° 51' S) localiza-se em um amplo planalto, limitado pelo rio Tapajós a oeste, na Floresta Nacional Tapajós, na região de Santarém, no estado do Pará. A cobertura vegetal é classificada principalmente como primária, e o clima da região é caracterizado como monção tropical [Saleska 2019].

A torre em PE-QFR (3° 50' O, 73° 19' S) localiza-se na reserva florestal protegida de Quistococha, rodeada a leste pelo Rio Amazonas, e de norte a oeste pela cidade de Iquitos, no Peru. A cobertura vegetal da região é classificada como permanentemente úmida, e o clima é caracterizado como de floresta tropical [Roman et al. 2021].

2.2. Coleta e Preparação dos Dados

Os dados das torres de fluxo foram adquiridos através do site oficial da Ameriflux, onde as bases de dados são separadas em duas categorias de processamento, conforme descrito em [Chu et al. 2023]. O sítio PE-QFR disponibiliza a base de dados na categoria FluxNet, com informações sobre todas as variáveis de fluxo necessárias para a análise da dinâmica do carbono na região, enquanto o sítio BR-Sa1 disponibiliza apenas a categoria Base, não incluindo a variável de fluxo particionado GPP. Por causa disso, foi utilizada a ferramenta *Max Planck* nos dados desta torre de fluxo a fim de obter informações das variáveis referentes ao particionamento de fluxo do NEE, a troca líquida de carbono do ecossistema, seguindo a metodologia descrita em [Costa et al. 2022], em resolução temporal de 30 minutos.

2.2.1. Cálculo do Algoritmo MOD17 para GPP e NPP

O algoritmo MOD17 é focado na estimativa do GPP e NPP a partir de dados de sensoriamento remoto. O conceito do algoritmo é utilizar a eficiência de conversão de radiação

para prever a GPP diária (GPP_{MOD17}) utilizando estimativas de diversos campos meteorológicos. A partir dessas estimativas, é calculado o termo de respiração de manutenção que então é subtraído da GPP anual para obter a NPP anual (NPP_{MOD17}). O cálculo do algoritmo do satélite⁴ é focado nas estimativas de GPP e NPP para cada pixel de terra de 500m globalmente. O cálculo do GPP_{MOD17} é diário, enquanto a NPP_{MOD17} é anual.

São utilizados parâmetros específicos do bioma para o algoritmo, com base na classificação de vegetação do MOD12, são extraídos da BPLUT (em tradução livre, Tabela de Consulta de Propriedades de Bioma) cinco valores: eficiência máxima de uso da radiação (ϵ_{max}), além do máximo e mínimo dos escalares de temperatura mínima (TMIN) e de déficit de pressão de vapor (VPD). Os escalares TMIN ($TMIN_{SCALAR}$) e VPD (VPD_{SCALAR}), atenuam a ϵ_{max} para calcular o coeficiente de eficiência de uso de radiação (ϵ) seguindo a Equação 1. Os valores de TMIN e VPD são obtidos a partir do conjunto de dados GMAO/NASA, enquanto o valor de ϵ_{max} é obtido da BPLUT.

$$\epsilon = \epsilon_{max} \times TMIN_{SCALAR} \times VPD_{SCALAR} \quad (1)$$

Em seguida, o ϵ é combinado com a radiação fotossinteticamente ativa absorvida (APAR) para calcular a GPP, onde APAR é a multiplicação da PAR irradiada (IPAR) com a fração de PAR absorvida (FPAR). O IPAR é estimado a partir da radiação solar incidente (SWRad) como 45% da SWRad, e são utilizadas estimativas de FPAR providas do MOD15A2H. Por fim, a fórmula do GPP_{MOD17} segue a Equação 2. Assim, as somas de 8 dias de GPP_{MOD17} são criadas e disponibilizadas publicamente.

$$GPP_{MOD17} = \epsilon \times APAR \quad (2)$$

Já o cálculo da NPP_{MOD17} segue a Equação 3, em que é possível visualizar a relação entre essa variável, o GPP_{MOD17} e a respiração de manutenção (R_m), esta última que segue a Equação 4, na qual é calculada a partir da massa da folha ou raiz fina (m), a taxa de respiração de manutenção por unidade de carbono foliar (por dia, a 20 graus Celsius) (r_0), a soma anual da respiração de manutenção do fator Q10 (q) e a temperatura diária média (T) em graus celsius.

$$NPP_{MOD17} = 0.8 * (GPP_{MOD17} - R_m) \quad (3)$$

$$R_m = m \times r_0 \times q^{(T-10)/10} \quad (4)$$

Assim, com o propósito de utilizar a implementação do algoritmo do produto MOD17 para estimar as medidas do satélite de forma manual, no presente artigo foi empregado o uso do software e da BPLUT disponibilizados por [Endsley et al. 2023].

Nesse contexto, os valores de entrada das variáveis meteorológicas foram obtidos a partir do conjunto de dados de reanálise MERRA-2 [GMAO 2015], um dos produtos da coleção GMAO da NASA, que foram reprojitados para a projeção do MOD17, garantindo o mesmo sistema de coordenadas, e interpolados espacialmente através de um método de agregação por média para coincidir com a resolução do MOD17. Estes dados foram adquiridos através da ferramenta Google Earth Engine⁵.

Além disso, foram coletados dados do produto MOD15A2H⁶ como entrada para as variáveis referentes à FPAR e Índice de Área da Folha (LAI), as quais foram interpoladas para uma resolução diária para realizar os cálculos. Por fim, a partir de dados de classificação de cobertura terrestre obtidos pelo produto MCD12Q1⁷ no pixel das torres, ambos os sítios foram considerados como *Evergreen Broadleaf Forest* (EBF) na utilização da BPLUT. Nesse sentido, o GPP e NPP calculados pelo MERRA-2 serão denotados no presente artigo como $GPP_{MERRA-2}$ e $NPP_{MERRA-2}$.

2.2.2. Cálculo do NPP EC

Para calcular a NPP com os dados das torres de fluxo, referida no presente estudo como NPP_{EC} , foi utilizado o método de cálculo específico para EC, descrito com detalhes em [Aniç et al. 2018]. Este método consiste na soma inverso da Troca Líquida de CO₂ do Ecossistema, ou NEE (do inglês, *Net Ecosystem Exchange*), somado ao produto da Respiração do Ecossistema (R_{ECO}) pela constante 0,3919, como descrito na Equação 5:

$$NPP_{EC} = -NEE + 0.3919 \times R_{ECO} \quad (5)$$

A partir dos valores encontrados, a NPP_{EC} foi então comparada com a NPP_{MOD17} . Nesse sentido, sendo a estimativa do satélite de resolução anual, os dados das torres de fluxo de NPP_{EC} foram agregados para a mesma resolução através da soma e as unidades foram padronizadas para a mesma do MOD17.

2.3. Análise Comparativa e Estatística

Após a preparação dos dados, foi realizada a comparação dos valores de GPP entre as respectivas localidades. Nesse sentido, utilizaram-se métricas de avaliação das estimativas como o RMSE, e o Erro Absoluto Diário (EAD). Essas métricas são amplamente utilizadas para quantificar a discrepância entre os valores reais (GPP_{Torre}) e os valores preditos por algoritmos, como o MOD17, e possuem grande relevância para o monitoramento ambiental [Wang et al. 2019, Chen et al. 2023]. O RMSE atribui um peso maior a valores altos de erro, permitindo uma análise sensível do impacto dos valores de GPP dos algoritmos quando os mesmos são muito diferentes dos reais, enquanto o EAD permite a análise direta ao longo do tempo.




Figura 1. Série Temporal de Todas as Fontes.

A Figura 1 indica que a utilização dos parâmetros atuais do algoritmo em conjunto com dados do MERRA-2 e as estimativas do satélite MOD17 tendem a subestimar a quan-

tidade de GPP em comparação às medições das torres, apresentando constantemente valores substancialmente menores do que os medidos *in situ* em ambas as regiões durante os anos. Nesse sentido, há uma tendência do GPP de ambas as formas de medição por satélite não acompanhar o comportamento observado nas torres, desconsiderando períodos de altas estimativas durante o começo do ano, nos meses de janeiro a março, aproximando gradativamente durante a metade do ano (abril a agosto) e se distanciando no fim do ano (setembro a dezembro).

Ao avaliar as métricas de desempenho, no sítio BR-Sa1 foi observado um RMSE aproximado de 20,51 para as medições de $GPP_{MERRA-2}$ e 19,45 para o GPP_{MOD17} . Para PE-QFR, tais medições tiveram o RMSE resultante respectivamente de 23,10 e 21,08. Embora seja notável que em ambos os casos que o satélite MOD17 obteve estimativas de GPP ligeiramente melhores do que a do calculado pelo MERRA-2, essa diferença é pequena e pode ser influenciada por diversos fatores, como a incerteza dos dados de entrada e características específicas das regiões.

Sítio	Fonte	Média	Desvio Padrão	Mediana	Min	Max
BR-Sa1	$GPP_{MERRA-2}$	15,83	13,08	15,83	0,17	68,39
	GPP_{MOD17}	15,01	12,41	11,9	0,16	66,81
PE-QFR	$GPP_{MERRA-2}$	18,17	14,33	13,54	0,35	67,28
	GPP_{MOD17}	17,20	12,25	15,01	0,16	58,26

Tabela 1. Resultados do EAD

Como etapa seguinte, foi estimado o EAD a fim de avaliar o desempenho das estimativas ao longo do tempo. Com base na Tabela 1 nota-se que, em média, o EAD do $GPP_{MERRA-2}$ é consideravelmente maior que o GPP_{MOD17} em ambas as regiões. Além disso, o $GPP_{MERRA-2}$ apresenta os valores de desvio padrão, mediana e valores extremos maiores para BR-Sa1, e valores de desvio padrão e extremos maiores para PE-QFR, demonstrando uma maior instabilidade e incerteza na qualidade das estimativas em comparação com o GPP_{MOD17} .

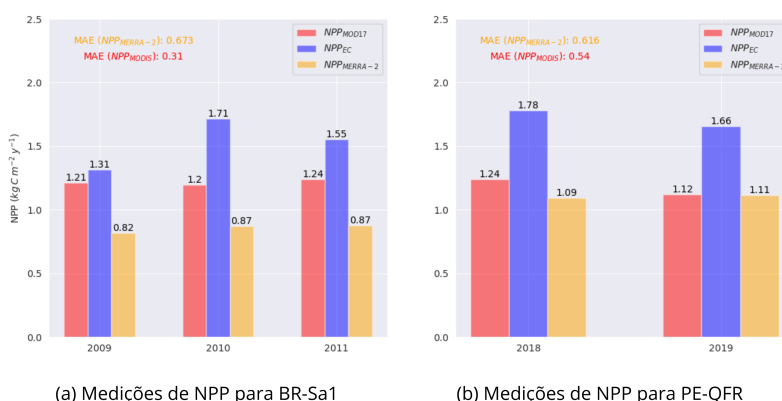


Figura 2. Comparativo da NPP Anual.

Considerando a relação da NPP e do GPP, é possível observar na Figura 2 que os valores de NPP são intensamente impactados pela falta de precisão nas medidas de GPP, resultando em estimativas muito abaixo das realizadas nas torres em ambas as regiões.

Essa discrepância é evidenciada pelo alto valor, considerando a escala das estimativas, do Erro Médio Absoluto (MAE), onde foi possível observar um MAE de 0,54 para o NPP_{MOD17} e 0,616 para o $NPP_{MERRA-2}$ para PE-QFR (Figura 2(b)), e 0,31 e 0,673 respectivamente em BR-Sa1 (Figura 2(a)), evidenciando o impacto das estimativas de GPP em relação ao NPP.

2.4. Utilização de Inteligência Artificial Para Melhoria dos Parâmetros da BPLUT

A BPLUT serve como base para a simulação do armazenamento de carbono. Nesse sentido, é importante destacar que os valores presentes na BPLUT permanecem estáticos para toda a série temporal calculada com base nela e diferentes formas de comportamento apresentados pelo mesmo bioma não são considerados. Devido a essa limitação, para obter estimativas de GPP e NPP mais próximas às das torres e assim, aprimorar a estratégia de monitoramento ambiental utilizando o MOD17, torna-se necessário considerar aplicações locais da BPLUT.

2.4.1. Algoritmo Genético

Foi utilizado o AG a partir da biblioteca Pymoo⁷, a fim de obter parâmetros da BPLUT que, quando utilizados no cálculo, resultem em estimativas de GPP mais próximas das medições das torres de fluxo. Para a implementação do algoritmo, utilizou-se o conjunto de parâmetros da BPLUT para biomas EBF, com população inicial de 1000 candidatas e limiares para a variação dos parâmetros de acordo com os especificados por [Wang et al. 2019]: ϵ_{max} ($gC/m^2/dia/MJ$), de 0,3 a 3,0; $Tmin_{min}$ ($^{\circ}C$), de -35 a -2; $Tmin_{max}$ ($^{\circ}C$), de 6 a 30; VPD_{min} (Pa), de 60 a 1000 ; e VPD_{max} (Pa), de 1500 a 6500.

Foram utilizadas a mutação polinomial e o crossover binário simulado (SBX, do inglês *Simulated Binary Crossover*) com o foco em obter variabilidade na geração dos parâmetros, ambos com 50% de probabilidade, um η (*eta*) com o valor de 20 e um total de 400 gerações. Como função objetivo para minimização, foi empregada a média aritmética do RMSE calculado em ambas as torres para encontrar parâmetros que atendam a ambas as regiões e definindo o problema como mono-objetivo. Vale salientar que, a escolha do algoritmo mono-objetivo se deve ao fato de que variações sazonais específicas de cada região poderiam não ser captadas com uma abordagem multi-objetivo.

Uma penalidade de 50 foi aplicada na função objetivo se os novos valores de RMSE gerados pelo algoritmo não fossem menores que os do MOD17. Por fim, tais parâmetros foram selecionados por meio de um processo iterativo visando ao melhor desempenho de RMSE em ambas as torres, e estão dispostos na Tabela 2.

	ϵ_{max}	$Tmin_{min}$ ($^{\circ}C$)	$Tmin_{max}$ ($^{\circ}C$)	VPD_{min} (Pa)	VPD_{max} (Pa)
Antes	0,001405	-8,0	9,09	1000	4000
Depois	0,001726	-2,0	23,99	176,79	6500

Tabela 2. Parâmetros encontrados

3. Resultados e Discussões

O gráfico de convergência e todos os detalhes da implementação e do código-fonte utilizados estão no repositório do artigo no GitHub, disponível aqui. Vale ressaltar que foram

necessárias aproximadamente cem gerações para o AG convergir para o ótimo global, permanecendo quase inalterável até o fim das quatrocentas gerações.

A partir dos novos parâmetros encontrados, o $GPP_{MERRA-2}$ e o $NPP_{MERRA-2}$ de ambas as regiões foi calculado novamente, resultando em novas estimativas que obtiveram melhores resultados e demonstram uma adaptação mais precisa dos parâmetros às características específicas das regiões das torres de fluxo.




Figura 3. Série Temporal do GPP Com os Parâmetros Melhorados.

Assim, na Figura 3 é possível visualizar a série temporal do GPP utilizando os novos parâmetros. Nesse contexto, é possível observar uma melhor aproximação dessas medianas em comparação com as medições do MOD17, demonstrando uma redução no viés das estimativas e melhor concordância com as medições das torres. Essa melhoria é evidenciada no começo do ano e fim de ano em ambas as regiões.

Para o sítio BR-Sa1 (Figura 3(a)), o RMSE com os novos parâmetros foi de 17,56, uma melhoria de 9,72% em comparação com o satélite. Já em PE-QFR (Figura 3(b)), o RMSE observado com os mesmos parâmetros foi de 20,02, uma melhoria de 5,03% em relação às medições do MOD17.

Sítio	Fonte	Média	Desvio Padrão	Mediana	Min	Max
BR-Sa1	GPP_{MERRA_2}	15,83	13,08	15,83	0,17	68,39
	GPP_{MERRA_2} (Novo)	13,01	11,83	9,75	0,07	66,79
	GPP_{MOD17}	15,01	12,41	11,9	0,16	66,81
PE-QFR	GPP_{MERRA_2}	18,17	14,33	13,54	0,35	67,28
	GPP_{MERRA_2} (Novo)	15,35	12,91	11,34	0,23	62,42
	GPP_{MOD17}	17,20	12,25	15,01	0,16	58,26

Tabela 3. Resultados do EAD Com os Novos Parâmetros.

Além disso, os resultados do EAD observados na Tabela 3, já utilizando os novos parâmetros encontrados, demonstraram valores médios consistentemente menores em ambas as regiões, um desvio padrão menor para BR-Sa1 e muito próximo para PE-QFR, demonstrando a melhoria na estabilidade dos resultados e da precisão das estimativas, bem como uma mediana menor, implicando um comportamento mais aproximado às medições das torres. Nos valores extremos, observou-se um desempenho favorável em BR-Sa1, porém inferior em PE-QFR, evidenciando a melhoria geral da qualidade das estimativas com os parâmetros encontrados.

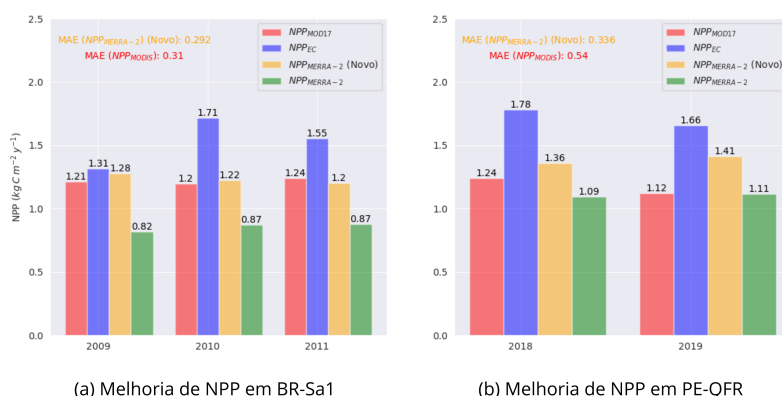


Figura 4. Comparativo do NPP Após a Melhoria no GPP.

Por fim, com a melhoria da precisão das novas estimativas de GPP, a partir da Figura 4 é possível observar uma melhoria nas estimativas da $NPP_{MERRA-2}$ após a melhoria dos parâmetros, que se aproximaram cada vez mais da NPP_{EC} . Em BR-Sa1 (Figura 4(a)), observou-se um MAE de 0,292, representando uma melhoria de aproximadamente 57,5% em relação às estimativas com os parâmetros anteriores e 5,81% em comparação a NPP_{MOD17} . Para PE-QFR (Figura 4(b)), o MAE resultante foi de 0,336, indicando uma melhoria de 45,4% em relação aos resultados anteriores e 37,8% em relação ao MOD17, refletindo a eficácia do AG no processo de melhoria dos parâmetros.

4. Conclusão

Este artigo apresentou os resultados da melhoria de parâmetros do algoritmo MOD17 para estimativas de GPP e NPP por satélite na Amazônia, nos sítios BR-Sa1, no Brasil, e PE-QRF, no Peru, utilizando dados das Torres de Fluxo nestes locais. Foi obtida uma melhoria nas estimativas em comparação a do satélite para BR-Sa1 e PE-QRF, com redução de respectivamente 9,72% e 5,03% do RMSE do GPP, e de respectivamente 57,5% e 37,8% no MAE do NPP. Essas melhorias demonstram a eficácia da técnica para a aproximação dos valores *in situ*, podendo ser aplicáveis para estudos em outras torres e biomas.

Para trabalhos futuros, afim de melhorar a qualidade das estimativas, planeja-se a aplicação de métodos de análise de série temporal, além de comparar o desempenho do algoritmo genético com testes próprios de outros métodos comuns na literatura, como a otimização bayesiana e o aprendizado por reforço. Para promover a replicação do estudo, o código usado nos experimentos está disponível em: JeanArthurCostaDias/Fine-Tuning-MOD17-BPLUT-with-Genetic-Algorithm.

Referências

- [Anić et al. 2018] Anić, M., Ostrogović Sever, M. Z., Alberti, G., Balenović, I., Paladinić, E., Peressotti, A., Tijan, G., Večenaj, Z., Vuletić, D., and Marjanović, H. (2018). Eddy covariance vs. biometric based estimates of net primary productivity of pedunculate oak (*quercus robur* L.) forest in croatia during ten years. *Forests*, 9(12).
- [Chen et al. 2023] Chen, X., Wei, D., and Wang, X. (2023). A modified sea ice area empirical prediction model based on multi-source satellite remote sensing data for liaodong bay of the bohai sea, china. In *Journal of Physics: Conference Series*, volume 2486, page 012020. IOP Publishing.

- [Chu et al. 2023] Chu, H., Christianson, D. S., Cheah, Y.-W., Pastorello, G., O'Brien, F., Geden, J., Ngo, S.-T., Hollowgrass, R., Leibowitz, K., Beekwilder, N. F., et al. (2023). Ameriflux base data pipeline to support network growth and data sharing. *Scientific Data*, 10(1):614.
- [Costa et al. 2022] Costa, G. B., Santos e Silva, C. M., Mendes, K. R., dos Santos, J. G., Neves, T. T., Silva, A. S., Rodrigues, T. R., Silva, J. B., Dalmagro, H. J., Mutti, P. R., et al. (2022). Wue and co2 estimations by eddy covariance and remote sensing in different tropical biomes. *Remote Sensing*, 14(14):3241.
- [Danelichen et al. 2015] Danelichen, V. H., Biudes, M. S., Velasque, M., Machado, N. G., Gomes, R. S., Vourlitis, G. L., and Nogueira, J. S. (2015). Estimating of gross primary production in an amazon-cerrado transitional forest using modis and landsat imagery. *Anais da Academia Brasileira de Ciências*, 87:1545–1564.
- [Endsley et al. 2023] Endsley, K. A., Zhao, M., Kimball, J. S., and Devadiga, S. (2023). Continuity of global modis terrestrial primary productivity estimates in the viirs era using model-data fusion. *Journal of Geophysical Research: Biogeosciences*, 128(9):e2023JG007457.
- [Feitosa et al. 2023] Feitosa, T. B., Fernandes, M. M., Santos, C. A. G., da Silva, R. M., Garcia, J. R., de Araujo Filho, R. N., de Moura Fernandes, M. R., and da Cunha, E. R. (2023). Assessing economic and ecological impacts of carbon stock and land use changes in brazil's amazon forest: A 2050 projection. *Sustainable Production and Consumption*, 41:64–74.
- [GMAO 2015] GMAO (2015). MERRA-2: 2d, 1-Hourly, Time-Averaged, Single-Level, Assimilation, Single-Level Diagnostics V5.12.4. Greenbelt, MD, USA, Goddard Earth Sciences Data and Information Services Center (GES DISC). Global Modeling and Assimilation Office (GMAO). DOI: 10.5067/VJAFPLI1CSIV.
- [Hong Tao and Lü 2019] Hong Tao, Manqi Li, M. W. and Lü, G. (2019). Genetic algorithm-based method for forest type classification using multi-temporal ndvi from landsat tm imagery. *Annals of GIS*, 25(1):33–43.
- [Huang et al. 2021] Huang, X., Xiao, J., Wang, X., and Ma, M. (2021). Improving the global modis gpp model by optimizing parameters with fluxnet data. *Agricultural and Forest Meteorology*, 300:108314.
- [Liu et al. 2023] Liu, C., Pan, G., Song, D., and Wei, H. (2023). Air quality index forecasting via genetic algorithm-based improved extreme learning machine. *IEEE Access*, 11:67086–67097.
- [Roman et al. 2021] Roman, T., Griffis, T., Kolka, R., Wayson, C., Lilleskov, E., del Castillo Torres, D., Malaverri, L. F., and Marin, J. E. R. (2021). Ameriflux fluxnet-1f pe-qfr quistococha forest reserve, ver. 3-5, ameriflux amp, (dataset). DOI: 10.17190/AMF/1832157.
- [Saleska 2019] Saleska, S. (2019). Ameriflux base br-sal santarem-km67-primary forest, ver. 5-5, ameriflux amp, (dataset). DOI: 10.17190/AMF/1245994.
- [Wang et al. 2019] Wang, H., Li, X., Ma, M., and Geng, L. (2019). Improving estimation of gross primary production in dryland ecosystems by a model-data fusion approach. *Remote Sensing*, 11(3).