


**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS**

PROGRAMA DE PÓS-GRADUAÇÃO EM

METEOROLOGIA



TESE DE DOUTORADO

Lady Layana Martins Custódio

**Estimativa da Produtividade Primária Bruta no
Nordeste do Brasil com produtos MODIS e
influência da base de dados meteorológicos**



UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE TECNOLOGIA E RECURSOS NATURAIS
UNIDADE ACADÊMICA DE CIÊNCIAS ATMOSFÉRICAS
COORDENAÇÃO DE PÓS-GRADUAÇÃO EM METEOROLOGIA



LADY LAYANA MARTINS CUSTÓDIO

**ESTIMATIVA DA PRODUTIVIDADE PRIMÁRIA BRUTA NO NORDESTE DO
BRASIL COM PRODUTOS MODIS E INFLUÊNCIA DA BASE DE DADOS
METEOROLÓGICOS**

Campina Grande - PB

Novembro - 2021

LADY LAYANA MARTINS CUSTÓDIO

Tese de Doutorado, apresentada ao Programa de Pós-Graduação em Meteorologia da Universidade Federal de Campina Grande - UFCG, em cumprimento às exigências para obtenção do grau de Doutora em Meteorologia.

Área de concentração: Meteorologia de Meso e Grande Escalas

Sub-área: Sensoriamento Remoto

Orientador: Prof. Dr. Bernardo Barbosa da Silva

Campina Grande - PB

Novembro – 2021

C987e

Custódio, Lady Layana Martins.

Estimativa da produtividade primária bruta no Nordeste do Brasil com produtos MODIS e influência da base de dados meteorológicos / Lady Layana Martins Custódio. – Campina Grande, 2022.

98 f. : il. color.

Tese (Doutorado em Meteorologia) – Universidade Federal de Campina Grande, Centro de Tecnologia e Recursos Naturais, 2021.

“Orientação: Prof. Dr. Bernardo Barbosa da Silva”.

Referências.

1. Ciclo do Carbono. 2. Nordeste Brasileiro. 3. MOD17A2H. I. Silva, Bernardo Barbosa da. II. Título.

CDU 551.5(812/813)(043)

LADY LAYANA MARTINS CUSTODIO

**ESTIMATIVA DA PRODUTIVIDADE PRIMÁRIA BRUTA NO NORDESTE DO
BRASIL COM PRODUTOS MODIS E INFLUÊNCIA DA BASE DE DADOS
METEOROLÓGICOS**

TESE APROVADA EM 07/12/2021

BANCA EXAMINADORA



Prof. Dr. BERNARDO BARBOSA DA SILVA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. ENILSON PALMEIRA CAVALCANTI
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Profa. Dra. CÉLIA CAMPOS BRAGA
Unidade Acadêmica de Ciências Atmosféricas
Universidade Federal de Campina Grande



Prof. Dr. GABRIEL ALVES VELOSO
Programa de Pós-Graduação em Geografia
Universidade Federal do Pará



Prof. Dr. KLEBER RENATO DA PAIXÃO ATAÍDE
Ministério da Agricultura, Pecuária e Abastecimento
Instituto Nacional de Meteorologia

AGRADECIMENTOS

Agradeço, primeiramente, a Deus pelas bênçãos. Aos meus pais e irmãos que entenderam minha ausência e que me apoiaram durante toda a trajetória do doutoramento.

Agradeço a Universidade Federal de Campina Grande – UFCG, a secretaria do Programada, por meio, da secretária Arilene Lucena, e aos professores do Programa de Pós-Graduação em Meteorologia – PPGMet/UACA por contribuir com a minha formação profissional e pela estrutura disponibilizada para o desenvolvimento da pesquisa, assim como, agradeço a Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – CAPES, pelo apoio financeiro para a realização do doutorado mediante a concessão de uma bolsa de pesquisa, recurso de possibilitou a minha dedicação a esta pesquisa.

Em especial, agradeço ao meu orientador, Prof. Dr. Bernardo Barbosa da Silva, pela confiança em meu trabalho, proposta de pesquisa e orientação, que foram e são de grande importância. Professor, lhe agradeço muito não só pela orientação, mas por sua grande disposição em conseguir uma bolsa de pesquisa para mim. Muito obrigada!

Agradeço aos meus colegas e amigos de mestrado e doutorado, em especial, Waléria Figueira, Dayse Moraes, Thays Oliveira, Nikolai Espinoza, Danielson Neves, Thomás Ferreira, Jéssica Rodrigues, Leide Priscila e a todos aqueles, que embora não citados nominalmente, contribuíram de alguma forma para a conclusão do doutorado, seja repassando conhecimento ou simplesmente em ouvir meus anseios da vida acadêmica.

Agradeço, também, a cidade de Campina Grande – PB, por me acolher e me mostrar a cultura nordestina, e as pessoas que conheci nesta cidade que irei levar no coração.

“A floresta não é simples consequência do clima, mas o atual equilíbrio do clima é modelado pela floresta. ”

(Dr. Enéas Salati, professor)

LISTA DE FIGURAS

Figura 1 - Esquema representativo do processo de fotossíntese e respiração	23
Figura 2 - Reflectância do tecido vegetal na região do visível. Fonte: Flickr.com	23
Figura 3 - Representação dos escalares fT_{min} e $fDPV$ atenuadores do $\epsilon_{m\acute{a}x}$ são em função de uma relação linear simples da Tar_{min} e DPV médio diários. Fonte: adaptado de Running e Zhao (2015)	28
Figura 4 - Localização das estações meteorológicas automáticas - EMAs do Instituto Nacional de Meteorologia - INMET (2019), estações radiométricas do Sistemas de Organização Nacional de Dados Ambientais - SONDA (2018), estação micrometeorológica do AMERIFLUX (AN TONINO, 2019) e os biomas do Nordeste Brasileiro - NEB do Instituto Brasileiro de Geografia e Estatística (IBGE, 2004).....	40
Figura 5 - Esquema resumido das etapas de preenchimento de falhas. Fonte: Reichstein et al. (2005) e Wutzler et al. (2018)	47
Figura 6 - Resumo das três metodologias de estimativas da produção primária bruta - GPP ($gC\ m^{-2}$). GPPmodis é um produto pronto do MOD17A2H, enquanto GPPmet e GPPevi são estimativas otimizadas	49
Figura 7 - Distribuição espacial e anual das chuvas (mm) no Nordeste Brasileiro para os anos de 2012 a 2018	53
Figura 8 - Distribuição espacial e anual da radiação global – Rg ($MJ\ m^{-2}$) no Nordeste Brasileiro para os anos de 2012 a 2018.....	54
Figura 9 - Distribuição espacial e anual da temperatura do ar média diária – Tar ($^{\circ}C$) no Nordeste Brasileiro para os anos de 2012 a 2018	55
Figura 10 - Distribuição espacial e anual da umidade relativa média diária – UR (%) no Nordeste Brasileiro para os anos de 2012 a 2018	56
Figura 11 - Distribuição espacial e anual do índice de vegetação melhorado – EVI09 no Nordeste Brasileiro para os anos de 2012 a 2018	57
Figura 12 - Distribuição espacial e anual da fração da radiação fotossinteticamente ativa – FPAR no Nordeste Brasileiro para os anos de 2012 a 2018	58
Figura 13 - Distribuição espacial e anual da produtividade primária bruta do produto MOD17A2H – GPPmodis ($gC\ m^{-2}$) para o Nordeste Brasileiro para os anos de 2012 a 2018	59

Figura 14 - Variabilidade anual da produtividade primária bruta do MOD17A2H – GPPmodis (gC m^{-2}), precipitação – Pr (mm), fração da radiação fotossinteticamente ativa – FPAR, índice de vegetação melhorado – EVI09 e os totais das áreas ocupada pela vegetação nativa e agropecuária em Mha para o período de 2012 a 2018.....	62
Figura 15 - Relação linear entre radiação fotossinteticamente ativa – PAR (MJ m^{-2}) diária e radiação global – Rg (MJ m^{-2}) diária para as cidades de São Luís (A), Natal (B), Palmas (C) e Petrolina (D).....	65
Figura 16 - Variabilidade mensal da produção primária bruta – GPP ($\text{gC m}^{-2} \text{d}^{-1}$) para os três modelos de GPP otimizados (GPPmet e GPPevi), uso eficiente da luz – LUE (gC MJ^{-1}), radiação global – Rg (MJ m^{-2}), radiação fotossinteticamente ativa – PAR (MJ m^{-2}), índice de vegetação melhorado – EVI09, fração da radiação fotossinteticamente ativa – FPAR, umidade relativa – UR (%), déficit de pressão de vapor – DPV (kPa), precipitação – Pr (mm), temperatura do ar – Tar ($^{\circ}\text{C}$) para os biomas Amazônia, Mata Atlântica, Cerrado e Caatinga para o período de 2012 a 2018.....	67
Figura 17 - Relação linear entre as médias diárias da produção primária bruta do MOD17A2H – GPPmodis ($\text{gC m}^{-2} \text{d}^{-1}$) com as duas GPPs otimizadas (GPPmet e GPPevi), além da relação com fração da radiação fotossinteticamente ativa – FPAR, índice de vegetação melhorado – EVI09, radiação fotossinteticamente ativa – PAR (MJ m^{-2}), uso eficiente da luz – LUE (gC MJ^{-1}), déficit de pressão de vapor – DPV (kPa), precipitação – Pr (mm) para os anos de 2012 a 2018 nos biomas Amazônia, Mata Atlântica, Cerrado e Caatinga.....	70
Figura 18 - Mapa de calor baseado na matriz de correlação entre os fatores ambientais, temperatura do ar – Tar ($^{\circ}\text{C}$), precipitação – Pr (mm), déficit de pressão de vapor – DPV (kPa), umidade relativa do ar – UR (%), radiação global – Rg (MJ m^{-2}), radiação fotossinteticamente ativa – PAR (MJ m^{-2}), uso eficiente da luz – LUE (gC MJ^{-1}) e produção primária bruta – GPP ($\text{gC m}^{-2} \text{d}^{-1}$) para os três modelos de GPP otimizados (GPPmodis, GPPmet e GPPevi), entre os anos de 2012 a 2018 para Amazônia (A), Mata Atlântica (B), Cerrado (C) e Caatinga (D). Cores em azul representam correlações negativas e cores em vermelho representam correlações positivas com o método de correlação de Pearson. Correlações com $p > 0,05$ são marcados com \times	72

- Figura 19 - Total médio mensal da produção primária bruta – GPP ($\text{gC m}^{-2} \text{mês}^{-1}$) para os três modelos de estimativa da GPP (GPPmodis, GPPmet e GPPevi) em espaço climático relacionados com temperatura do ar – Tar ($^{\circ}\text{C}$), precipitação – Pr (mm m^{-1}), e radiação solar – Rg (MJ m^{-2}) para os anos de 2012 a 2018 nos biomas Amazônia, Mata Atlântica, Cerrado e Caatinga..... 74
- Figura 20 - Variabilidade dos dados micrometeorológicas do sítio de Serra Talhada na Caatinga, em acumulado de 8 dias para a produção primária bruta – GPP (A) por CVT – GPPtorre e os modelos de estimativa de GPP (GPPmodis, GPPmet e GPPevi) todos em $\text{gC m}^{-2} 8\text{d}^{-1}$, precipitação – Pr ($\text{mm } 8\text{d}^{-1}$) (B), médias de 8 dias da radiação global – Rg (MJ m^{-2}) (B), radiação fotossinteticamente ativa – PAR (MJ m^{-2}) (B), déficit de pressão de vapor – DPV (kPa), temperatura do ar – Tar ($^{\circ}\text{C}$), fração da PAR – FPAR (D), índice de vegetação melhorado – EVI09 (D) e umidade relativa – UR (%) de junho de 2014 a julho de 2015. Sombra em cinza é referente a estação chuvosa..... 78
- Figura 21 – Relação entre produção primária bruta – GPP por CVT – GPPtorre diário, em $\text{gC m}^{-2} \text{d}^{-1}$ e acumulado de 8 dias, em $\text{gC m}^{-2} 8\text{d}^{-1}$, com GPP do produto MOD17A2H – GPPmodis (A, B), GPP com dados meteorológicos combinado a fração da radiação fotossinteticamente ativa – GPPmet (C, D) e GPP combinado ao índice de vegetação melhorado – GPPevi (E, F) para o sítio de Serra Talhada na Caatinga no período de junho de 2014 a julho de 2015, e para estação seca e chuvosa. * $p \leq 0,05$ 80
- Figura 22 - Estatística comparativa entre produção primária bruta – GPP por CVT – GPPtorre, GPP pelo MOD17A2H – GPPmodis (A, B), GPP com dados meteorológicos combinado a fração da radiação fotossinteticamente ativa – GPPmet (C, D) e GPP combinado ao índice de vegetação melhorado – GPPevi (E, F) em escalas diárias em $\text{gC m}^{-2} \text{d}^{-1}$, e acumulados de 8 dias em $\text{gC m}^{-2} 8\text{d}^{-1}$ para Serra Talhada – PB na Caatinga no período de junho/2014 a julho/2015, e para estação seca e chuvosa. EAM (erro relativo médio) e REQM (raiz do erro quadrático médio), na escala da variável, e ERM (erro relativo médio) em porcentagem do erro..... 82

LISTA DE TABELAS

Tabela 1 - Percentual aproximado de área ocupada pelos biomas nos estados do Nordeste Brasileiro - NEB. Fonte: IBGE/MMA (2004).....	41
Tabela 2 - Médias das áreas de cobertura vegetal e uso do solo por agropecuária e suas mudanças entre os anos 2012 e 2018 para os biomas do Nordeste Brasileiro. Fonte: MapBiomias (2019), coleção 5.0	45
Tabela 3 - Produtos do sensor MODIS com suas respectivas unidades e fatores de correção. Fonte: USGS (2020).....	46
Tabela 4 - Parâmetros dos Biomas de acordo com Running e Zhao (2015) utilizados na etapa de estimativa da produção primária bruta – GPP (gC m^{-2}). EBF = <i>Evergreen Broadleaf Forest</i> ; CShrub = <i>Closed Shrublands</i>	50
Tabela 5 - Coeficientes de determinação (R^2) em escala anual entre a produção primária bruta do MOD17A2H – GPPmodis (gC m^{-2}) e a precipitação – Pr (mm), radiação global – Rg (MJ m^{-2}), temperatura do ar – Tar ($^{\circ}\text{C}$), umidade relativa – UR (%), índice de vegetação melhorado – EVI09, fração da radiação fotossinteticamente ativa - FPAR e área total de cobertura vegetal e uso agropecuário em Mha para os biomas Amazônia, Mata Atlântica, Cerrado e Caatinga do Nordeste brasileiro no período de 2012 a 2018	64
Tabela 6 - Total das estimativas de produção primária bruta – GPP para os três modelos (GPPmodis, GPPmet e GPPevi) e GPP via CVT (GPPtorre) todos em gC m^{-2} por período para a localidade de Serra Talhada – PB no bioma Caatinga para o período de junho de 2014 a julho de 2015	75
Tabela 7 - Matriz de correlação de Pearson entre a produção primária bruta - GPP para os modelos: GPPmodis, GPPmet e GPPevi, e GPPtorre todos em gC m^{-2} , radiação fotossinteticamente ativa – PAR (MJ m^{-2}), fração da PAR – FPAR, índice de vegetação melhorado pelo MOD09 – EVI09, déficit de pressão de vapor – DPV (kPa), temperatura do ar – Tar ($^{\circ}\text{C}$), umidade relativa – UR (%), precipitação – Pr (mm).....	81

LISTA DE SIGLAS, ABREVIATURAS E SÍMBOLOS

AMERIFLUX	Rede de fluxo de CO ₂ , água e energia na América do Norte, Central e Sul
APAR	Radiação Fotossinteticamente Ativa Absorvida
BPLUT	<i>Biome Parameter Look-Up Table</i>
CO ₂	Dióxido de Carbono
CPC	<i>Climate prediction center</i>
CPTEC	Centro de Previsão de Tempo e Clima
CShrub	<i>Closed Shrublands</i>
CVT	Covariância de Vórtices Turbulentos
DOE	<i>Department of Energy</i>
DPV	Déficit de Pressão de Vapor
DPV _{máx}	Limiar de DPV máximo da tabela BPLUT
DPV _{mín}	Limiar de DPV mínimo da tabela BPLUT
ea	Pressão atual do vapor
EAM	Erro Absoluto Médio
EBF	<i>Evergreen Broadleaf Forest</i>
EC	Estação chuvosa
EMAs	Estações Meteorológicas Automáticas
ENOS	El Nino Oscilação Sul
ERM	Erro Relativo Médio
ES	Estação Seca
es	Pressão de saturação do vapor d'água atmosférico
EVI	Índice de Vegetação Melhorado
EVI09	Índice de Vegetação Melhorado pelo Produto MOD09A1
$\epsilon_{\text{máx}}$	Uso Eficiente da Luz Máximo
FAO	<i>Food and Agriculture Organization</i>
fDPV	Fator de ponderação do $\epsilon_{\text{máx}}$ a partir da DPV
FPAR	Fração da radiação fotossinteticamente ativa
fT _{min}	Fator de ponderação do $\epsilon_{\text{máx}}$ a partir da T _{min} _{mín}
GEE	Gases de Efeito Estufa
GMAO	<i>Global Modeling and Assimilation Office</i>
GPP	Produção Primária Bruta
GPPEvi	GPP estimado combinando dados meteorológicos e EVI09

GPPmet	GPP estimado por dados meteorológicos
GPPmodis	GPP estimado no produto MOD17A2H
GPPtorre	GPP estimado em torres micrometeorológicas
IAF	Índice de Área Foliar
IBGE	Instituto Brasileiro de Geografia e Estatística
IDW	Peso pelo Inverso da Distância
INMET	Instituto Nacional de Meteorologia
INPE	Instituto Nacional de Pesquisas Espaciais
IPCC	<i>Intergovernmental Panel on Climate Change</i>
LUE	<i>Light Use Efficiency</i>
MapBiomass	Mapeamento Anual da Cobertura e Uso do Solo no Brasil
Mha	Milhões de Hectares
MMA	Ministério do Meio Ambiente
MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
MSG	<i>Meteosat Second Generation</i>
NASA	<i>National Aeronautics and Space Administration</i>
NCEP	<i>National Centers for Environmental Prediction</i>
NDVI	<i>Normalized Difference Vegetation Index</i>
NEB	Nordeste Brasileiro
NEE	<i>Net Ecosystem CO₂ Exchange</i>
NIR	Infravermelho Próximo
NOAA	<i>National Oceanic and Atmospheric Administration</i>
O ₂	Oxigênio
ONDACBC	Observatório Nacional da Dinâmica da Água e CO ₂ no Bioma Caatinga
PAR	<i>Photosynthetically Active Radiation</i>
Pr	Precipitação
PSNnet	Fotossíntese Líquida
Ra	Respiração Autotrófica
Reco	Respiração do Ecossistema
RED	Vermelho
REQM	Raiz do Erro Quadrático Médio
Rg	Radiação Global
RM	Respiração de Manutenção

SEVIRI	<i>Spinning Enhanced Visible and Infrared Imager</i>
SONDA	Sistema Nacional de Organização de Dados Ambientais
Tar	Temperatura do Ar
Tar _{min}	Temperatura do ar Média Mínima do dia
TG	<i>Temperature and Greeness</i>
Tmin _{max}	Limiar de Tarmin máxima da tabela BPLUT
Tmin _{mín}	Limiar de Tarmin mínimo da tabela BPLUT
TSM	Temperatura da Superfície do Mar
Tsoil	Temperatura do Solo
UMD	Universidade de Maryland
UR	Umidade Relativa do Ar
USGS	Agência de Serviço Geológico dos Estados Unidos
WGS	<i>World Geodetic System</i>
λ	Comprimento de Onda

SUMÁRIO

1	INTRODUÇÃO.....	18
1.1	Hipótese.....	20
1.2	Objetivo Geral.....	21
1.3	Objetivos Específicos.....	21
2	FUNDAMENTAÇÃO TEÓRICA.....	22
2.1	Dinâmica do Carbono e Produção primária bruta (GPP).....	22
2.2	Sensoriamento Remoto, Uso Eficiente da Luz e a estimativa da GPP.....	24
3	REVISÃO DE LITERATURA.....	29
3.1	Aspectos Gerais da Produção Primária Bruta.....	29
3.2	Radiação fotossinteticamente ativa (PAR) e os impactos na GPP.....	30
3.3	Índices de Vegetação e a GPP.....	32
3.4	Estimativas de GPP pelo produto MOD17A2H.....	34
3.5	A Técnica de CVT (limitações e implicações no NEE).....	37
4	MATERIAL E MÉTODOS.....	40
4.1	Área de estudo.....	40
4.2	Dados.....	42
4.2.1	Dados Meteorológicos.....	42
4.2.2	Dados orbitais do MODIS.....	43
4.2.3	Dados de cobertura da terra (MapBiomas).....	44
4.3	Processamento de dados.....	45
4.3.1	Dados meteorológicos e dos produtos MODIS.....	45
4.3.2	Particionamento e preenchimento dos fluxos de carbono da estação micrometeorológica.....	46
4.4	Métodos.....	48
4.4.1	Métodos de estimativa da GPP.....	48
4.4.2	Validação dos métodos de estimativa de GPP e estatísticas.....	50
5	RESULTADOS E DISCUSSÃO.....	52
5.1	Característica bioclimáticas.....	52
5.2	Variabilidade interanual dos fatores bioclimáticos e uso e mudança da cobertura do solo e suas relações.....	60
5.3	Estimativas da GPP otimizado e sua relação com as variáveis de entrada.....	65
5.4	Validação das estimativas das GPPs.....	75
6	CONCLUSÕES.....	83
7	REFERÊNCIAS BIBLIOGRÁFICAS.....	84

RESUMO

A produção primária bruta (sigla em inglês – GPP) é um dos componentes fundamentais do ciclo de carbono global, por isto tem sido objeto de estudos por pesquisadores em todo o mundo, que se intensificaram com o advento das mudanças climáticas. Nesta pesquisa foram analisadas estimativas de GPP para os biomas nordestinos avaliando o produto MOD17A2H (GPPmodis), e mais dois modelos de determinação da GPP com base em dados meteorológicos do Instituto Nacional de Meteorologia (INMET), sendo 1: GPPmet combinando a fração da radiação fotossinteticamente ativa do produto MOD15A2H (sigla em inglês – FPAR); e 2: GPPevi combinando o índice de vegetação melhorado a partir do produto MOD09A1 (EVI09) para os anos de 2012 a 2018, contemplando os fenômenos oceânicos: El Niño, La Niña, gradiente positivo do Atlântico em 2012 e anos de condições neutras e suas relações com as variáveis ambientais e de uso e mudança do solo. As estimativas foram confrontadas com a GPP medida em uma torre micrometeorológica (GPPtorre) localizada no sítio de Serra Talhada, inserida no bioma Caatinga, compreendendo o período junho de 2014 a julho de 2015 do Ameriflux. Os resultados apontam que a variação interanual da GPPmodis foi ligeiramente influenciada pelo total anual da precipitação condicionados aos eventos climáticos, e não houve influências das mudanças de cobertura do solo. Todas as estimativas possuíram sazonalidades bem definidas, devido a isto, houve correlações entre si e com as variáveis ambientais. Em relação a comparação com GPPtorre, os maiores erros foram observados na GPPmodis e GPPevi, enquanto a GPPmet não se observou diferenças significativas ($p \leq 0,01$) que pode ter sido um reflexo da calibração local da radiação fotossinteticamente ativa (sigla em inglês – PAR). Portanto, a GPPmet demonstra ser o melhor modelo, desde que se ajuste a porcentagem da PAR pode ser aplicado para a Caatinga, principalmente devido a disponibilidade desses dados sem custos financeiros adicionais. Entretanto, a aplicabilidade para os outros biomas do Nordeste ainda precisa ser mais estudada. Com estes resultados, sugere-se o refinamento dos dados da PAR no MOD17A2H com porcentagens desta variável mais próximas da realidade dos biomas, principalmente, nos trópicos, mas na ausência de dados, a GPPmodis é a melhor alternativa para obtenção da GPP.

Palavras-chave: Ciclo do carbono; Nordeste brasileiro; MOD17A2H

ABSTRACT

Gross primary production (GPP) is one of the fundamental components of the global carbon cycle, in this sense it has been the object of studies around the world, which have intensified in the context of climate change. In this research, the GPP estimates were analyzed for the Northeastern of Brazil biomes, in order to evaluate the MOD17A2H product (GPPmodis), and two more models recalculated based on meteorological data from the Instituto Nacional de Meteorologia (INMET) being 1: GPPmet combined with the fraction of photosynthetically active radiation of the MOD15A2H product (FPAR); and 2: GPPevi combined with the enhanced vegetation index from the MOD09A1 product (EVI09), for the years 2012 to 2018, covering the oceanic phenomena: El Niño, La Niña, positive gradient of the Atlantic in 2012 and years of neutral conditions and their relationships with the environmental and land use and change variables. The estimates were compared with the GPP measured in a micrometeorological tower (GPPtorre) at the Serra Talhada site inserted in the Caatinga biome for June 2014 to July 2015 period, from Ameriflux database. The results show that the interannual variation of GPPmodis was slightly influenced by the total annual precipitation conditioned by climatic events, and there were no influences from changes in land cover. All estimates presented a well-defined seasonality, due to this, there were correlations between them and with the environmental variables. Regarding the comparison with GPPtorre, the biggest errors were observed in GPPmodis and GPPevi, while GPPmet did not show significant differences ($p\text{-value} \leq 0.01$) which may have been a reflection of the local calibration of photosynthetically active radiation (PAR). Therefore, GPPmet proves to be the best model, as long as the PAR percentage is adjusted, it can be applied to Caatinga biome, mainly due to the availability of these data without additional financial costs. However, the applicability to other biomes in the Northeast still needs to be further studied. With these results, it is suggested the refinement of the PAR data in MOD17A2H, including percentages closer to the reality of the biomes, mainly in the tropics, but in the absence of data, GPPmodis is the best alternative to obtain the GPP.

Keywords: carbon cycle; Brazilian Northeast; MOD17A2H

1 INTRODUÇÃO

O ciclo do carbono terrestre em debates sobre o aquecimento global, tem sido objeto de muitos estudos ao redor do mundo, que se intensificaram no contexto das tendências das mudanças climáticas. Nas últimas décadas, desde os primeiros relatórios do Painel Intergovernamental Sobre Mudanças Climáticas (sigla em inglês – IPCC), a comunidade científica tem direcionado estudos para compreender o real impacto do aumento das concentrações de gases de efeito estufa (GEE), em especial o dióxido de carbono (CO₂), nos diversos ecossistemas terrestres, que pode resultar no desequilíbrio climático a nível global.

Uma das principais fontes de emissão desses gases são atribuídas ao desmatamento, a agricultura e a outros usos do solo, que segundo o relatório especial do IPCC (2019) são responsáveis por cerca de 22% das emissões mundiais. E no relatório mais recente do órgão (IPCC, 2021) é alertado que em cenários de aumento das emissões de CO₂, a capacidade de assimilação dos ecossistemas, embora aumente, a eficácia diminui. Nesse contexto, os estudos dos efeitos da mudança de uso e ocupação do solo nas trocas de energia, água e carbono entre a superfície e a atmosfera são fundamentais para conhecer a dinâmica desses processos e a capacidade dos ecossistemas terrestres de absorver o CO₂ excedente (BROWN *et al.*, 2016; DELGADO *et al.*, 2018; CHAGAS *et al.*, 2019; DE SANTANA *et al.*, 2020).

Diante dessa problemática, algumas estratégias de mitigação, como políticas de conservação da vegetação nativa surgiram como alternativa devido ao papel fundamental das plantas em assimilar o CO₂ por meio do processo de fotossíntese (Produção primária bruta – sigla em inglês – GPP), e o armazenamento em sua biomassa. Dentre os ecossistemas que se destacam nos estudos sobre GPP são as regiões áridas e semiáridas, onde os efeitos das mudanças do uso e cobertura da terra nos ciclos do carbono são ainda mais importantes, pois essas regiões possuem grande vulnerabilidade, isso porque geralmente passam por frequentes anos de baixa precipitação (Pr) e longos períodos de secas.

Nesse aspecto, a região Nordeste do Brasil (NEB) que possui uma grande parte do seu território com irregularidades espaço-temporal da pluviosidade (ARAÚJO *et al.*, 2017), principalmente no setor semiárido, gera na comunidade científica e

governamental muitas preocupações, por se tratar de uma região bastante populosa (53.081.510 habitantes, segundo Instituto Brasileiro de Geografia e Estatística (IBGE) (Censo, 2010)). No território nordestino a pluviosidade pode variar de 2000 mm por ano, região litorânea, a 500 mm por ano, no interior, e essa distribuição das chuvas é o que determina a paisagem vegetal da região (BARBOSA *et al.*, 2019). O NEB engloba, de acordo com o IBGE (2004), quatro biomas, sendo: (1) a Caatinga que cobre 65% da região; (2) a Mata Atlântica, isolada na costa leste ocupando cerca de 16,9% do território nordestino; (3) o Cerrado, que tem características de savana, sendo um pouco menor que a Mata Atlântica; e (4) a Amazônia, com cerca de 3,7% do território do NEB, localizado no extremo noroeste da região.

Em função da importância desse tema, técnicas de estimativas da GPP têm sido usada com frequência por pesquisadores em todo mundo. Dentre elas destaca-se a de covariância de vórtices turbulentos (CVT) (CARRILLO-ROJAS *et al.*, 2019; CHAGAS *et al.*, 2019; WEGLE *et al.*, 2019). Entretanto, devido à baixa representatividade, alto custo e operacionalidade da técnica de CVT, muitos pesquisadores têm usado para estimar a GPP o sensoriamento remoto (SILVA *et al.*, 2013; ALMEIDA *et al.*, 2018; CHAGAS *et al.*, 2019; FERREIRA *et al.*, 2020). Por se tratar de uma técnica que possui muitas vantagens, é considerado o principal método para estimar adequadamente a dinâmica espaço-temporal da GPP, em razão da sólida base biofísica empregada (RUNNING *et al.*, 2004), baseada no conceito de Eficiência do Uso da Luz (sigla em inglês *Light Use Efficiency* – LUE) proposta por Monteith (1972), que quantifica a conversão de luz absorvida em carboidratos através da fotossíntese.

Uma das grandes vantagens da técnica de sensoriamento remoto é o monitoramento global da superfície para diversos tipos de vegetação, superando as deficiências de obtenção de dados em regiões de difícil acesso, permitindo estudos à nível regional e global. Além disso, os dados são contínuos, e disponibilizados imediatamente sem nenhum custo financeiro para os usuários do produto, fazendo com que tenha um ótimo custo benefício (ALMEIDA *et al.*, 2018; CHAGAS *et al.*, 2019).

Embora a GPP por sensoriamento remoto tenha grande credibilidade no meio científico, a técnica, assim como qualquer outra metodologia possui imprecisões. Os problemas relacionados às imprecisões do GPP por satélite são relatados em várias publicações (SILVA, *et al.*, 2013; YAN *et al.*, 2015; WANG *et al.*, 2017a; ALMEIDA

et al., 2018; CHAGAS *et al.*; 2019). Esses autores revelam que a GPP por satélite em comparação a técnica de CVT apresentou algumas limitações, tanto nas estimativas sazonais, como na magnitude e variações espaciais, superestimando a GPP em locais de baixa produtividade, e subestimando em locais de alta produtividade.

A GPP é uma variável altamente dependente do clima local (Temperatura do ar (Tar) e do solo (Tsoil), Precipitação (Pr), Umidade Relativa (UR), Déficit de Pressão de Vapor (DPV) e Radiação Fotossinteticamente Ativa (sigla em inglês – PAR)) que controlam diretamente o LUE. Os modelos que assumem o LUE, como o produto MOD17A2H do sensor *Moderate Resolution Imaging Spectroradiometer* (MODIS), em seu algoritmo têm o obstáculo de obter essa variável em extensas áreas, justamente devido à dependência dos fatores ambientais (CHAGAS *et al.*, 2019; JOINER e YOSHIDA, 2020).

Similarmente, a fração da PAR da Radiação Global (Rg) no MOD17A2H é constante (45%), e, portanto, extrapolada para todo o globo. É relatado em estudos que a PAR pode variar entre 44% a 69% (GALVANI, 2009). Por exemplo, em Brasília a PAR é em torno de 44% da Rg e em Petrolina em torno de 50% (CUSTÓDIO *et al.*, 2021). Esse tipo de incerteza pode levar a conclusões errôneas relacionadas a dinâmica do carbono, podendo desarticular decisões políticas, causando prejuízos ambientais e econômicos (WANG *et al.*, 2017a; ALMEIDA *et al.*, 2018).

Portanto, a precisão da estimativa da GPP em meio ao cenário das tendências de mudanças climáticas, e a mudança do uso da terra, torna esta variável imprescindível em estudos de previsão do aquecimento global (YAN *et al.*, 2015). Assim, pesquisas que destinam o aprimoramento da estimativa da GPP por sensoriamento remoto, servirão para melhor compreender a dinâmica do carbono, e assim, capacitar os modelos a respeito dos efeitos causados com o aumento de CO₂ sobre diversos ecossistemas.

1.1 Hipótese

Esta tese irá testar a hipótese de que estimativas da GPP otimizado com dados de estação meteorológica local possui melhor acurácia do que o produto de GPP do MOD17A2H.

1.2 Objetivo Geral

- Estimar a GPP em diferentes biomas da região Nordeste do Brasil, utilizando dados medidos em estações meteorológicas locais e observações por satélite, visando a performance e a qualidade das estimativas da GPP, contribuindo para a melhoria dos modelos climáticos e de ecossistemas.

1.3 Objetivos Específicos

Especificamente busca-se:

- Caracterização espacial e anual dos fatores bioclimáticos da região do Nordeste;
- Analisar a variabilidade interanual da GPP do MOD17A2H e fatores biofísicos com as áreas de vegetação nativa e de agropecuária para os biomas do Nordeste;
- Recalcular a GPP do algoritmo MOD17A2H substituindo dados de reanálise por dados meteorológicos locais combinando aos índices de vegetação (EVI e FPAR), e comparar as estimativas do produto MOD17A2H;
- Relacionar a variabilidade sazonal das variáveis climáticas envolvidas no cálculo da GPP com as estimativas de GPP otimizadas;
- Adotar a GPP medida em torres como referência e compará-las a GPP estimada pelo MOD17A2H e pelas GPP otimizadas.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Dinâmica do Carbono e Produção primária bruta (GPP)

A dinâmica do carbono nos ecossistemas consiste nas trocas desse elemento químico entre a atmosfera e o próprio ecossistema. A denominação dada ao termo correspondente ao transporte vertical entre o ecossistema e a atmosfera é conhecida como NEE (do inglês - *Net Ecosystem CO₂ Exchange*). A magnitude e sentido do fluxo vertical são conduzidos pela GPP e respiração do ecossistema (Reco) (Equação 1).

$$NEE = GPP - R_{eco} \quad (1)$$

A produção primária bruta (siga em inglês – GPP) é a taxa de carbono atmosférico fixado pela fotossíntese medido por unidade de massa por área e tempo (CHAPIN *et al.*, 2011). É durante o processo de fotossíntese que os seres fotossintetizantes produzem compostos orgânicos para serem utilizados no seu metabolismo celular, sendo a parte essencial que possibilita vida no planeta, por gerar alimento para os seres heterotróficos (MARENCO *et al.*, 2014). Esses seres fotossintetizantes captam a energia solar, por meio de um pigmento chamado de clorofila, que se encontram dentro da célula fotossintetizante, os cloroplastos. Portanto, a fotossíntese ocorre dentro dessas células, e estas estão presentes nas partes verdes da planta, ou seja, caules jovens e principalmente, folhas verdes (Figura 1).

Basicamente, embora seja um processo complexo, a fotossíntese remove o CO₂ atmosférico e liberam oxigênio (O₂). As raízes das plantas captam a água do solo, enquanto o CO₂ é obtido pelas minúsculas estruturas presentes nas folhas, chamadas de estômatos (Figura 1). Já a luz é absorvida pela clorofila. As moléculas de água são quebradas liberando o O₂ e o hidrogênio. Nesse processo, as plantas precisam de seis moléculas de CO₂ atmosféricos para produzir uma molécula de hidrato de carbono (MARENCO *et al.*, 2014).




Figura 1 - Esquema representativo do processo de fotossíntese e respiração

A chave para o processo da fotossíntese é a energia solar e o gás carbônico. Os comprimentos de onda (λ) entre 400 nm e 700 nm (luz visível ou PAR), é a faixa em que a clorofila absorve a luminosidade, principalmente, no violeta e vermelho, refletindo o verde (Figura 2). Nesse processo, a planta está interessada na quantidade de fótons que chegam à superfície da folha, pois se trata de um processo quântico. Como a luz vermelha produz mais fótons, logo é melhor para a produção de hidrocarbonetos, uma vez que, são necessários de 8 a 10 fótons para se ligarem a uma molécula de CO_2 na fotossíntese.




Figura 2 - Reflectância do tecido vegetal na região do visível. Fonte: Flickr.com

Todavia, não necessariamente a maior quantidade de densidade de fluxo de fótons fotossintéticos resultará em aumento da taxa de fotossíntese, pois a energia excedente é liberada pela respiração. É durante a respiração que as plantas, ou melhor, que os seres fotossintetizantes “soltam” o CO_2 e absorvem O_2 , sendo o processo inverso da fotossíntese. Neste processo, em virtude da eficiência da fotossíntese, a respiração é menor durante o dia e, maior durante a noite (MARENCO *et al.*, 2014). A resposta da fotossíntese vai depender de fatores externos e internos (MARENCO *et al.*, 2014). Os fatores externos são fatores ambientais, tais como, água, nutrientes, Temperatura, quantidade de CO_2 e irradiância. Por outro lado, os fatores internos estão associados aos próprios seres fotossintéticos, por exemplo, idade da planta, quantidade e espessura das folhas entre outros (CHAPIN *et al.*, 2011; MARENCO *et al.*, 2014).

2.2 Sensoriamento Remoto, Uso Eficiente da Luz e a estimativa da GPP

O sensoriamento remoto é a ciência de detectar e monitorar as características físicas sobre um objeto ou fenômeno, através de um dispositivo que não está em contato mecânico direto com o objeto ou área de investigação. Essa tecnologia inclui sensores aéreos a bordo de aviões e plataformas orbitais (satélites), incluindo também os radares, drones, balões meteorológicos e os sistemas de sonar nos navios. Dentre esses sensores, talvez o de maior destaque são os satélites artificiais, que ajudam os pesquisadores nas observações da superfície e da atmosfera da Terra (MAVI e TUPPER, 2004).

A fonte de energia por trás da ciência do sensoriamento remoto é a radiação eletromagnética. As informações sobre um objeto são possíveis, porque os sensores são capazes de registrar a interação da radiação eletromagnética com o alvo. A irradiância que chega ao sensor é convertida em sinais elétricos. Esses sinais, por sua vez, são transformados em números digitais associados aos pixels das imagens de satélites. Com isso, os valores podem ser transformados em radiância. O espectro eletromagnético é amplo, mas em sensoriamento remoto de observação da Terra, a porção do espectro comumente utilizado é a faixa da luz visível (entre 400 e 700 nm). Entretanto, outras porções do espectro também são utilizadas pelos sensores, que recebem energia na faixa do ultravioleta e infravermelho (MAVI E TUPPER, 2004).

Quando o foco são as interações da radiação eletromagnética com a superfície terrestre, os sensores medem a porção que é refletida e/ou emitida pelos objetos. Naturalmente, a composição química e estrutura física desse objeto ao interagir com a radiação solar vai apresentar características próprias de reflexão e emissão, que também vai depender do ângulo de incidência da luz sobre o objeto, a essa característica única do objeto chamamos de assinatura espectral. Nesse ponto, a vegetação é um exemplo dessa assinatura que é bem definida (Figura 2). Mesmo havendo algumas variações espectrais, a depender da própria vegetação e de fatores ambientais, em geral, a vegetação apresenta entre 400 nm e 500 nm e entre 600 nm e 700 nm alta absorção. Já entre 501 nm e 599 nm e acima dos 701 nm a refletância é predominante, pois nesse intervalo ocorre baixa absorção da radiação pela clorofila (Figura 2). Portanto, a faixa do infravermelho é mais bem detectada pelos sensores remotos devido à alta refletância da vegetação nesse intervalo. Sendo esta técnica amplamente aplicada em estudos do vigor da vegetação.

Por outro lado, no estágio de senescência, a vegetação apresenta características inversas de reflexão e absorção. Nesse período, a planta perde água e a pigmentação muda trazendo alterações nas propriedades de reflexão. Ou seja, com a diminuição do teor de água e clorofila a refletância na faixa acima de 700 nm (Infravermelho próximo – sigla em inglês – NIR) se torna baixa, enquanto o vermelho (sigla em inglês – RED) em torno de 630 nm aumenta. Com isso, é possível distinguir vegetações verdes e saudáveis de vegetações em estágio final de vida. Pressupõe-se que vegetações verdes e nutridas apresentam alta capacidade fotossintética, ou seja, alta GPP.

Em sensoriamento remoto, a GPP é uma estimativa oriunda da combinação das refletâncias das bandas do visível e NIR – que dão ideia do vigor da vegetação –, e dados de reanálise, utilizando a metodologia de LUE de Monteith (1972). A lógica de Monteith parte do princípio, que se uma vegetação estiver suprida de água e fertilizada a produtividade da vegetação será linearmente relacionada com a quantidade de PAR absorvida (APAR) pelo dossel. Entretanto, em condições reais, a produtividade da vegetação é afetada por fatores ambientais (XIAO *et al.*, 2019). Por tanto, a GPP via satélite, utilizando a método de Monteith, é em função da APAR e o LUE máximo ($\epsilon_{\text{máx}}$) limitado por DPV e Tar média mínimo do dia ($T_{\text{ar}_{\text{min}}}$) (RUNNING e ZHAO, 2015).

O conceito de Monteith é bastante sólido, porém o $\epsilon_{\text{máx}}$ é de difícil obtenção, pois o varia bastante de um tipo de vegetação para outro, além de variar sazonalmente e anualmente, e por fatores ambientais (ALMEIDA *et al.*, 2018; WAGLE *et al.*, 2019), incluindo o metabolismo da planta e estado fenológico (CHAPIN *et al.*, 2011). O $\epsilon_{\text{máx}}$ do algoritmo MOD17 é obtido por meio de valores tabelados e assume que o LUE é constante ocasionando um desempenho moderado em representar a sazonalidade da GPP. Cada pixel tem um valor relacionado ao tipo de cobertura da terra do MOD12Q1. A classificação da cobertura da terra é da Universidade de Maryland (UMD) disposto na tabela *Biome Parameter Look-Up Table* (BPLUT) no guia de usuário.

Essas simplificações do algoritmo, é relatado como um problema por provocar incertezas nas estimativas da GPP (SILVA *et al.*, 2013; MORAIS *et al.*, 2017). A inexatidão da estimativa da GPP está associada à fonte de dados do MOD17A2H. Embora o MOD17 contenha inconsistências, esse produto é amplamente utilizado e com o passar dos anos, a tecnologia proporcionou melhorias no produto. Entretanto, ainda é possível contribuir para o bom desempenho nas estimativas de GPP, focando principalmente nas variáveis de entrada do algoritmo, como a PAR, APAR e os fatores ponderadores que limitam o LUE.

O sensor do MOD17 está a bordo da plataforma do satélite Terra e Aqua lançados em 1999 e 2002 respectivamente. O produto MOD17A2H contém as informações de produtividade da vegetação para todo o globo terrestre. O mesmo dispõe imagens com resolução temporal de 8 dias e resolução espacial de 500 m. A projeção é senoidal e dividida em quadrantes de 1200 x 1200 Km. Este possui três camadas, quais sejam: a GPP (Kg C m^{-2}), fotossíntese líquida (PSNnet) resultante da diferença entre GPP e respiração de manutenção (RM), e por último, o controle de qualidade dos bits em relação a corrupção de dados em alguma fase do processamento.

Os dados do produto MOD17A2H é uma versão mais robusta do produto MOD17A2/A3. O principal ganho desse produto em relação ao anterior (MOD17A2) é a resolução espacial que antes era de 1 Km. Outras melhorias também significativas estão relacionadas à atualização dos dados de cobertura da terra (MOD12Q1), e uma versão atualizada dos dados meteorológicos do GMAO/NASA (*Global Modeling and Assimilation Office/National Aeronautics and Space Administration*).

O guia do usuário (RUNNING e ZHAO, 2015) descreve o algoritmo que faz a estimativa da GPP utilizando a Equação 2. A fração de 0,45 da Rg do algoritmo MOD17A2H se refere a PAR (Equação 3), sendo os valores da Rg obtidos por Reanálise do GMAO/NASA, enquanto o da fração da radiação fotossinteticamente ativa (FPAR) a partir do MOD15A2H da coleção 6.

$$GPP = \varepsilon_{m\acute{a}x} \times fT_{min} \times fDPV \times PAR \times FPAR \quad (2)$$

$$PAR = Rg \times 0,45 \quad (3)$$

No qual, $\varepsilon_{m\acute{a}x}$ é o máximo LUE em função do tipo de vegetação que vai determinar. Esta variável é retirada da tabela BPLUT que contém para cada classificação de vegetação (MOD12Q1) um valor de $\varepsilon_{m\acute{a}x}$. O procedimento é simples. O algoritmo detecta para cada pixel o tipo de vegetação, e a partir dessa vegetação o algoritmo consulta a tabela BPLUT e retira o valor de $\varepsilon_{m\acute{a}x}$ juntamente com os dados de ponderadores que limitam essa variável, e, por conseguinte, obtém-se o valor de LUE. Ressalta-se que, embora a classificação da vegetação traga erros, o mapa de vegetação do MOD12Q1 tem uma precisão de 65 a 80% (FRIEDL *et al.*, 2010). A descrição de cada bioma é encontrada na tabela BPLUT (RUNNING e ZHAO, 2015).

$$fT_{min} = \begin{cases} 0, & Tar_{min} < Tmin_{min} \\ \frac{(Tar_{min} - Tmin_{min})}{(Tmin_{max} - Tmin_{min})}, & Tmin_{min} < Tar_{min} < Tmin_{max} \\ 1, & Tar_{min} > Tmin_{max} \end{cases} \quad (4)$$

$$fDPV = \begin{cases} 0, & DPV > DPV_{max} \\ \frac{(DPV_{max} - DPV)}{(DPV_{max} - DPV_{min})}, & DPV_{min} < DPV < DPV_{max} \\ 1, & DPV < DPV_{min} \end{cases} \quad (5)$$

Os ponderadores climáticos do $\varepsilon_{m\acute{a}x}$ servem para atenuar o valor máximo de $\varepsilon_{m\acute{a}x}$ para condições desfavoráveis de baixa Tar e alto DPV. Assim, o LUE é igual ao $\varepsilon_{m\acute{a}x}$, quando a Tar_{min} para o dia na EMA for acima do limiar do parâmetro de Tar mínima máxima ($Tmin_{max}$) estabelecida para o bioma na tabela BPLUT. Já, o LUE é igual a zero, quando a Tar_{min} do dia na EMA for menor que o limiar do parâmetro de Tar mínima mínima ($Tmin_{min}$) tabelado para o bioma. Partindo do princípio que temperaturas baixas inibem o uso da PAR, o fator de ponderação de Tar_{min} (fT_{min}) assume valores de 0 a 1. O fator de ponderação do DPV ($fDPV$) segue a mesma analogia, mas é uma função linear inversamente proporcional ao DPV (Figura 3).




Figura 3 - Representação dos escalares fT_{min} e $fDPV$ atenuadores do $\epsilon_{m\acute{a}x}$ são em função de uma relação linear simples da $T_{ar_{min}}$ e DPV médio diários. Fonte: adaptado de Running e Zhao (2015)

Assim, para um DPV médio diária acima do limiar de DPV máximo do dia (DPV_{max}) para o bioma específico da tabela BPLUT, o LUE será zero, uma vez que, altos DPV inibem a fotossíntese, enquanto que para DPV médio diária for abaixo do DPV mínimo do dia (DPV_{min}) determinado para aquele bioma, o LUE será igual ao $\epsilon_{m\acute{a}x}$. Os parâmetros fT_{min} e $fDPV$ são parametrizados de acordo com as Equações 4 e 5, e os valores dos parâmetros de $T_{min_{min}}$ e $T_{min_{max}}$ estão dispostos na Tabela 4, na seção 4.4 desta pesquisa.

A variável FPAR na Equação 2 é obtida a partir do produto MOD15A2H composta pelo Índice de Área Foliar (IAF) e a FPAR, incluindo também mais 4 camadas sendo elas: Controle da qualidade IAF/FPAR, desvio-padrão da FPAR, desvio-padrão do IAF e uma banda extra de qualidade da FPAR. O MOD15A2H tem resolução espacial de 500 m e resolução temporal de 8 dias (GUIA DO USUÁRIO MOD15A2H, 2015). A FPAR é calculada utilizando a Lei de Beer, que é em função do IAF e do coeficiente de extinção de luz do dossel ($k = 0,5$) (Equação 6).

$$FPAR = 0,95 (1 - e^{-kIAF}) \quad (6)$$

A FPAR representa a porcentagem que as folhas verdes do dossel absorvem da PAR incidente, sendo a $FPAR \approx NDVI$ (do inglês – *Normalized Difference Vegetation Index*). O algoritmo é uma combinação dos dados de reflectância do MOD09GA do RED (648 nm) e NIR (858 nm).

3 REVISÃO DE LITERATURA

3.1 Aspectos Gerais da Produção Primária Bruta

Com as mudanças climáticas, resultantes do aumento das emissões de GEE antropogênicos, em especial CO₂ (IPCC, 2021), levantaram-se vários debates e questionamentos a respeito do impacto das mesmas na eficiência da vegetação em capturar o CO₂ atmosférico, que contrabalança as emissões do CO₂ antropogênico (ALMEIDA *et al.*, 2018). Como a GPP terrestre é a principal componente do ciclo de carbono global, a mesma indica a capacidade dos ecossistemas terrestres de absorver ou liberar CO₂ atmosférico (ANAV *et al.*, 2015); portanto, qualquer mudança na vegetação será percebida na GPP. Assim, analisar os padrões da GPP, é compreender o comportamento dos ecossistemas terrestres frente às mudanças do clima (ALMEIDA *et al.*, 2018).

Nesse sentido, Cunha *et al.* (2015) analisaram as respostas das variáveis ambientais da Caatinga às mudanças de uso e ocupação do solo dessa região. Verificaram que na mudança da vegetação nativa por vegetação degradada há uma diminuição da GPP de 68%, atribuído ao efeito da diminuição do índice de área foliar, atividade fotossintética e umidade, além da redução do saldo de radiação. Em outro estudo, Green *et al.* (2019) projetaram a umidade do solo em cenários futuros de aquecimento global e verificaram o impacto na produtividade do ecossistema terrestre. Foi observado pelos autores, que até o final do século a absorção de CO₂ poderia diminuir drasticamente, caso a tendência de diminuição de umidade do solo continuasse.

Atualmente, estima-se que os ecossistemas terrestres sejam capazes de absorver cerca de 25% do CO₂ atmosférico (MEDEIROS *et al.*, 2011). Desse total, as florestas tropicais e savanas são responsáveis por 34% e 26% da GPP terrestre, respectivamente (BEER *et al.*, 2010). Globalmente, Anav *et al.* (2015) mostraram que a GPP varia latitudinalmente, associado aos diferentes biomas, sendo maior em baixas latitudes, ou seja, em biomas quente e úmido e menor em altas latitudes, onde estão os biomas frios e secos. Apontaram, ainda, que a GPP é limitada pela disponibilidade de água, sendo este, o principal fator climático, e como fator secundário, a temperatura do ar. Para biomas áridos e semiáridos a produtividade é baixa devido à pouca existência de água e as

temperaturas acima de 30 °C, resultando em alta evaporação, o que retorna ao limitador água, como condicionador principal das trocas de carbono nessas regiões, corroborado também por Zscheischler *et al.* (2014). Em escala regional, Gilabert *et al.* (2015) revelaram que a GPP do MODIS depende bastante da FPAR. Mas, é relatado também que outras variáveis, como a PAR, Pr e DPV, que ajudam na redução do LUE, e a classificação do uso do solo, que determina o $\varepsilon_{\text{máx}}$, desempenham papel importante na caracterização do estresse térmico.

Em relação à variação espacial da GPP, Chen *et al.* (2019) relataram que a mesma é dirigida por fatores bióticos e abióticos, sendo associadas principalmente por variações de temperatura, precipitação, radiação e disponibilidade de água, além do IAF e tipos de folhas. As variações sazonais da GPP seguem relações similares, ou seja, varia com as condições climáticas de cada estação do ano, sendo geralmente maior na estação chuvosa (EC), ou em áreas irrigadas e menor na estação seca (ES) (MORAIS *et al.*, 2017).

Embora se conheça vários aspectos relacionados à GPP, a dinâmica e a incerteza na qualidade da estimativa continuam sistematicamente sendo estudadas com objetivo de estimar com precisão a produtividade de um ecossistema (FU *et al.*, 2014). Na tentativa de alcançar esse objetivo, diversos métodos têm sido avaliados e aprimorados ao longo do tempo. Nesse ponto, o produto MOD17A2H, que é amplamente utilizado, é constantemente avaliado por introduzir algumas incertezas devido aos dados de entrada. Por outro lado, este produto é considerado de confiança por ter a capacidade de detectar mudanças espaciais e temporais com moderada precisão (FU *et al.*, 2014).

3.2 Radiação fotossinteticamente ativa (PAR) e os impactos na GPP

A PAR é a faixa do espectro eletromagnético compreendida entre 400 a 700 nm, sendo esta, uma fração da radiação eletromagnética contida no espectro da Rg. A PAR é essencial nos processos biofuncionais, seja nos ecossistemas naturais ou agrícolas. Como a produção de biomassa está relacionada à PAR, é imprescindível que se saiba a magnitude da PAR dentro do espectro da Rg. A determinação da porção da PAR incidente, assim como a boa qualidade de dados de Rg constitui um importante

parâmetro para determinar a GPP (MERCADO *et al.*, 2009; CAI *et al.*, 2014; CUSTÓDIO *et al.*, 2021).

Nesse contexto, alguns trabalhos indicaram que a PAR exerce um papel importante que dirige a variabilidade diurna, sazonal e anual da GPP. Hashimoto *et al.* (2010) compararam vários conjuntos de dados de variáveis meteorológicas que são usadas como dados de entrada de modelos de atividade fotossintética. Os autores concluíram que a R_g , conseqüentemente a PAR, refletiu maior erro na estimativa de produção do ecossistema em relação a outros parâmetros meteorológicos. Revelaram também que dentre os dados de R_g utilizados, aqueles estimados a partir do NCEP apresentaram maiores erros.

Posteriormente, Cai *et al.* (2014), nessa mesma linha, analisaram seis modelos que estimam a PAR para avaliar os impactos na estimativa de GPP. Foi verificado que os dados de PAR do NCEP, por exemplo, utilizando o fator de proporção de 0,45, em geral, superestimou as observações de PAR em 37% a 92%, e exibiu o maior viés positivo, com um valor médio de $2,71 \text{ MJ m}^{-2} \text{ d}^{-1}$, sendo que em dias nublados os erros foram maiores que em dias de céu claro. Esses erros se propagaram na estimativa de GPP superestimando em 47% a 90% a GPP, em comparação com aquela obtida por CVT (GPP_{torre}). Dentre as diferentes estimativas de PAR analisadas pelos pesquisadores, as que promoveram maior erro na estimativa da GPP foram os dados derivados do NCEP.

No ano seguinte, Gilabert *et al.* (2015) evidenciaram em suas análises que a PAR estimada em 0,46 (IQBAL, 1983) da R_g , embora tenha apresentado bons resultados na estimativa de GPP quando comparados aos resultados de torres micrometeorológicas, a mesma apresentou erros em torno de 25% a 30% entre GPP com $\text{PAR} = 0,46R_g$ e GPP_{torre}. Ressalta-se que os dados de R_g adotados foram derivados de produtos de SEVIRI/MSG (*Spinning Enhanced Visible and Infrared Imager/ Meteosat Second Generation*) do METEOSAT para toda Espanha. Os autores também analisaram a contribuição da PAR e FPAR na GPP revelando que a PAR é a variável de maior influência, porém quando se trata de GPP com base no modelo de Monteith (1972) a FPAR tem maior relevância.

Em um trabalho simplificado, Rodrigues *et al.* (2018) analisaram o impacto do fator de proporção da PAR da Rg na magnitude da estimativa da GPP. O estudo foi dirigido para o município de Santa Rita do Passo Quatro, no estado de São Paulo. Os autores compararam as estimativas de GPP utilizando a proporção de 0,37 da Rg calculados para esta localidade, com a proporção de 0,48 sugeridos por Bastiaanssen e Ali (2003). Os resultados evidenciaram que a GPP estimada utilizando a $PAR = 0,37Rg$ se aproximou mais dos resultados de GPP torre enquanto a GPP estimada utilizando a proporção de 0,48 da Rg se apresentou superestimada em quase 20% em comparação aos dados de GPP de torre micrometeorológica. Já no produto de GPP do MOD17A2H (GPPmodis) a proporção de 45% é utilizada para estimar a PAR, e a partir dela, em combinação com outras, estima-se a GPP (RUNNING e ZHAO, 2015). O produto é gerado em nível global, e não varia com as condições de clima e tempo de uma dada região. Assim como, não é levado em consideração, a claridade ou nebulosidade do céu que variam em escalas diária e sazonal.

Recentemente, Hesong *et al.* (2020) exploraram o peso das variáveis preditoras dos modelos de LUE em área de pastagem semiárida no nordeste da China. Os autores constataram que a PAR seria a segunda variável de maior influência entre os dados de entrada dos modelos de LUE. Destacaram que a PAR para dias nublados e dias claros não estimaram na mesma magnitude a produtividade, pois a radiação difusa promove mais LUE, subestimando a GPP em condições de nebulosidade. Na literatura é possível encontrar proporções da PAR entre 35% a 69% da Rg (GALVANI, 2009) mostrando a grande variabilidade desse parâmetro. Portanto, é recomendado que a PAR seja calibrada para cada local (WANG *et al.*, 2014; CUSTÓDIO *et al.*, 2021).

3.3 Índices de Vegetação e a GPP

Em modelos de LUE que estimam a GPP é necessário incluir um parâmetro que afira a atividade fotossintética de um dossel. Em geral, os parâmetros responsáveis por esse processo são os índices de vegetação. No MOD17A2H, a FPAR é responsável por esse parâmetro, sendo equivalente ao NDVI. Entretanto, estudos têm relatado que a FPAR pode trazer incertezas significativas na estimativa da GPP (OGUTU e DASH, 2013; DONG *et al.*, 2015; ZHANG *et al.*, 2016; WANG *et al.*, 2017b). Segundo Ogutu

e Dash (2013), a grande razão das incertezas da FPAR em não estimar tão bem o GPP, é devido a forma com que a FPAR capta a absorção da PAR. A vegetação é composta por componentes que não fazem fotossíntese como, galhos e folhas mortas, contudo, a FPAR considera esses componentes, o que propaga uma superestimação da PAR absorvida, e conseqüentemente, há um aumento substancial da fotossíntese, influenciando diretamente a magnitude da produtividade. Diante dessas incertezas, muitos trabalhos avaliam os índices de vegetação visando encontrar aquele que melhor simula o processo de fotossíntese. Porém, é importante salientar que a vegetação é singular em cada região, e haverá, portanto, um índice específico que se adequa melhor a ela (NAKAI, 2016).

Em estudos sobre GPP, os principais índices utilizados como dado de entrada de modelos, são o NDVI e o índice de vegetação melhorado (sigla em inglês – EVI). Ma *et al.* (2013) destacaram a capacidade do EVI em estimar a GPP em savanas na Austrália. Em um outro trabalho, também de Ma *et al.* (2014), eles estenderam o seu estudo para vários tipos de savanas na Austrália. Os autores relacionaram o EVI e outros índices de vegetação com a GPP_{torre} e verificaram que o EVI explicou 66% da variação do GPP, confirmando o estudo anterior. Por outro lado, Dong *et al.* (2015) revelaram que o EVI não apresenta bom desempenho em anos de seca. Os resultados apresentados por esses autores, mostraram que a GPP foi superestimada em 20 a 61% em locais de sequeiros em anos de seca. Mas no geral, dentre os índices estudados, o EVI acompanhou bem as variações de GPP em anos secos e não secos.

Zheng *et al.* (2018) trabalharam com modelo de LUE de Monteith utilizando quatro tipos de FPAR e diferentes ponderadores que limitam o LUE. Os autores substituíram a FPAR pelos índices de vegetação, NDVI, EVI e FPAR do MOD15 e combinaram com distintos limiares do LUE. Concluíram que para todas as combinações, a FPAR por EVI otimizaram as estimativas de GPP para o norte da China.

Recentemente, Morais (2019) analisou o EVI e o NDVI para estimar a GPP na Caatinga. Comparando os dois índices, foi revelado que o EVI apresentou valores mais baixos que o NDVI. Sazonalmente, os dois índices seguiram o comportamento ao longo das estações do ano, mostrando-se condicionalmente relacionados com a Pr. Ao avaliar as contribuições dos índices de vegetação, relacionando-as com a GPP_{torre} e GPP_{modis}

foram encontrados valores de $R^2 = 0,55$ e $R^2 = 0,66$ para GPP de torres e para o MOD17A2H, respectivamente. Em geral, dentre os índices de vegetação utilizados, o EVI apresentou melhor desempenho em estimar a GPP, com valores muito bem relacionados com o GPPtorre ($R^2 = 0,83$).

Mais recentemente, Biudes *et al.* (2021) avaliaram as estimativas de GPP por diferentes modelos para o Cerrado brasileiro incluindo modelos com dados EVI, FPAR e NDVI. O NDVI e a FPAR tiveram boa correlação com a GPP de torres, enquanto o EVI apresentou fraca correlação. Os autores constataram que todos os modelos forneceram estimativas semelhantes. Entretanto, a versão do modelo usando NDVI apresentou melhor desempenho do que a versão EVI, isso porque o NDVI exibiu melhor dinâmica sazonal para esta região. Por outro lado, na publicação, é concluído que nenhum dos modelos realmente obteve uma performance superior a outro.

3.4 Estimativas de GPP pelo produto MOD17A2H

A avaliação e validação do produto MOD17A2H estão sempre sendo averiguadas devido às incertezas da qualidade das variáveis aplicadas no algoritmo. Para Paiva e Fernandes (2015), Morais *et al.* (2017) e Chiwara *et al.* (2018) as imprecisões da GPPmodis estão relacionadas aos dados de entrada como a Rg, Tar e DPV, por se tratar de dados de reanálise, além do LUE que não varia no tempo, e é constante para grandes biomas. Dessa forma, esse tópico vai apresentar as mais recentes pesquisas do Brasil e do mundo que buscaram avaliar o MOD17A2H em diferentes biomas.

Anav *et al.* (2015) analisaram os padrões espaciais e temporais de diferentes modelos de estimativa da GPP para todo o globo. Os autores comparam os modelos mostrando que dentre todos, a GPPmodis apresentou menores valores globais, sendo 66% menor que o modelo de maior estimativa. Isso já era esperado devido à baixa estimativa do GPPmodis para biomas de alta produtividade. Diante dessas imprecisões, Yan *et al.* (2015) propuseram um novo modelo e o comparou com produto MOD17A2H avaliando-os aos dados de CVT. As estimativas foram feitas para diferentes ecossistemas baseados em plantas C3 e C4. O novo modelo apresentou desempenho

melhor quando comparados com GPP por CVT. Foi observado também que o MOD17A2H subestimou as duas técnicas. Em parte, os modelos divergem devido a diferenças entre plantas C3 e C4 que possuem diferentes LUE, que não é bem modelado pelo algoritmo do produto MOD17A2H.

As estimativas imprecisas do GPPmodis também foram examinadas por Wang *et al.* (2017b). Nesse estudo os autores se propuseram a avaliar as melhorias do MOD17A2H, em relação à versão anterior, para vários biomas terrestres com dados de CVT. Os resultados mostraram que a GPPmodis subestimou os dados de CVT na maioria dos biomas. Seu desempenho foi ruim tanto para médias anuais quanto para estimativas de 8 dias. Para avaliar melhor as fontes de incertezas do algoritmo do MOD17A2H, os dados de reanálise foram substituídos por dados medidos em estações meteorológicas. De fato, houve uma pequena melhora, no entanto, a precisão foi maior quando utilizaram dados de FPAR. Também verificaram que o MOD17A2H sempre atribui valores de $\epsilon_{\text{máx}}$ pequenos, provavelmente em decorrência da má classificação da cobertura da terra do MOD12Q1. Assim, é sugerido que os dados de FPAR e de cobertura da terra sejam melhorados.

Nessa mesma linha, Chiwara *et al.* (2018) avaliaram o produto MOD17A2H e outro modelo, combinando dados de satélite e de torres micrometeorológicas. O estudo foi dirigido para ecossistemas africanos e comparado com a GPP de torres. Em geral, a GPPmodis conseguiu capturar o padrão espacial, porém novamente foi observado que a GPPmodis subestima regiões de floresta tropical, sendo visível principalmente na estação de crescimento. Por outro lado, em regiões de savana e savana arborizada, a GPP é superestimada, mas com forte correlação ($r > 0,76$) e significância estatística superior a 99,9%. Isto pode estar relacionada ao DPV que não consegue controlar a magnitude da GPP. As diferenças entre as duas estimativas (GPP modelado e do MOD17A2H) são principalmente, a entrada de dados e suas suposições para as relações.

As superestimativas do produto de GPPmodis também são verificadas em regiões de turfa, onde se encontram condições bastante úmidas do solo e vegetação hidrófita. Lees *et al.* (2019) analisaram dez anos de dados de GPP na Escócia e Irlanda. O objetivo principal do trabalho era avaliar o modelo *Temperature and Greenness* (TG) comparando com a GPPtorre e dados de GPPmodis. Os resultados comparativos entre GPPmodis e GPPtorre diferiram muito em sua magnitude, tendo a

GPPmodis superestimando a GPPtorre em mais da metade no total médio anual ($GPP_{torre} = 299 \text{ gC m}^{-2} \text{ ano}^{-1}$; $GPP_{modis} = 765 \text{ gC m}^{-2} \text{ ano}^{-1}$). Essa discrepância entre o GPPmodis e os dados de CVT pode estar relacionada a incorreta classificação do tipo de cobertura do solo pelo MOD12Q1, pois é a partir desse produto que é determinado o $\epsilon_{m\acute{a}x}$. Agregado a isto, os autores também comentam que em outros trabalhos em região de turfeiras o algoritmo do MOD17A2H subestimou outras medições, sugerindo que a disponibilidade de água não é bem modelada no algoritmo.

No Brasil, Silva *et al.* (2013) calcularam a GPP utilizando imagens Landsat para uma região irrigada na Paraíba. Os autores compararam os resultados do Landsat com a GPPmodis. Concluíram que as técnicas possuem poucas diferenças, não chegando a 12%. Além disso, também foi verificado que a região tem bom potencial de sequestro de carbono, embora presumam que esteja superestimada devido ao alto valor de $\epsilon_{m\acute{a}x}$ assumido na pesquisa. Posteriormente, em outra região do Brasil, Souza *et al.* (2014) avaliaram o potencial do produto MOD17A2H para uma área de transição Amazônia-Cerrado validando com dados de CVT. Constataram que os valores de GPPmodis foram maiores na EC e menores na ES. Segundo os resultados obtidos, os autores afirmam que os dados GPPmodis concordaram com os dados observados (GPP_{torre}) em magnitude e fase. Porém, no geral, a GPPmodis subestimou em 38% a média. Essa baixa capacidade do MOD17A2H em estimar a GPP se caracteriza devido à falta de adequação do LUE nessa região.

Outro estudo recente, dirigido para a Caatinga, foi realizado por Moraes (2019). Os resultados apresentados em seu trabalho mostraram mais uma vez a baixa capacidade da GPPmodis em modelar a magnitude dos valores de GPP_{torre} . No geral, a GPPmodis subestimou a GPP_{torre} durante a ES e superestimou na EC. A razão para isto, segundo o autor, é a incapacidade do algoritmo em limitar o LUE pelo DPV. Entretanto, o MOD17A2H conseguiu capturar as variações sazonais que inclusive é dos pontos fortes mencionados na literatura.

Similarmente, em outro ponto na Caatinga, Ferreira *et al.* (2020) avaliaram a GPPmodis. Foi concluído que, assim como outros estudos a GPPmodis descreve razoavelmente o comportamento anual da produção primária. Também foi observado superestimação na média anual, que é bastante evidente na EC, porém na ES a GPPmodis estava mais bem relacionado aos dados observados. Os autores creditaram

essas diferenças na baixa confiabilidade nos dados GMAO em regiões tropicais. Por fim, Biudes *et al.* (2021) verificaram que a GPPmodis superestimou em 81% a GPPtorre durante a estação chuvosa do Cerrado brasileiro.

3.5 A Técnica de CVT (limitações e implicações no NEE)

O método de CVT é a técnica mais utilizada para medição dos fluxos de energia e massa, isso porque os resultados obtidos se aproximam dos medidos por técnicas ecológicas (CURTIS *et al.*, 2002). O método foi proposto por Swinbank (1951) e só veio ganhar destaque com o avanço tecnológico da instrumentação a partir da década de 90. Tornou-se, então, uma ferramenta poderosa, promovendo um entendimento melhor dos processos dinâmicos dos fluxos de energia, água e CO₂. A CVT, como o nome já pressupõe, mede os vórtices que transportam propriedades da superfície à atmosfera, os quais são resultantes das variações de temperatura da superfície terrestre. Estas variações que ocorrem dentro da camada limite planetária são flutuações de curtíssimo tempo, sendo igual ou menores que uma hora (STULL, 1988). Para medir estas flutuações por CVT, a técnica se baseia na decomposição de Reynolds, relacionando a velocidade do vento vertical com um valor escalar, como a concentração de CO₂ e de água, ou temperatura, por exemplo, que é descrito como:

$$c = \bar{c} + c' \quad (7)$$

no qual, \bar{c} e c' são respectivamente, o valor médio e a parte flutuante dessa grandeza física ao longo de um dado período.

Os fluxos de um escalar, neste caso o carbono, é a média do produto entre a densidade do ar (ρ_{ar}), velocidade vertical do vento (w) e razão de mistura do carbono ($C = \rho_c/\rho_{ar}$), em que (ρ_c) é a densidade do carbono.

$$NEE = \overline{(\rho_{ar} + \rho'_{ar})(\bar{w} + w')(\bar{c} + c')} \quad (8)$$

Abrindo os termos da Equação 8, tem - se:

$$NEE = \overline{\rho_{ar}\bar{w}\bar{c} + \rho_{ar}\bar{w}c' + \rho_{ar}w'\bar{c} + \rho'_{ar}\bar{w}\bar{c} + \rho'_{ar}\bar{w}c' + \rho'_{ar}w'\bar{c} + \rho'_{ar}w'c' + \bar{\rho}_{ar}w'c'} \quad (9)$$

De acordo com as aproximações de Reynolds, a turbulência na camada limite planetária é bem definida, e, portanto, considera-se que os termos de flutuação média de um única variável é igual a zero ($c' = w' = p'_{ar} = 0$). Os termos de flutuações envolvendo a p_{ar} podem ser desprezadas, pois a densidade quase não varia na baixa atmosfera. Outra simplificação corresponde à velocidade média vertical do vento que é negligenciado, caso o local de observações seja plana e homogênea; assim, os termos que contenham \bar{w} são ignorados ($\bar{w} = 0$), simplificando a Equação 10 em um único termo.

$$NEE = \rho_{ar} \overline{w'c'} \quad (10)$$

O fluxo de CO₂, NEE é expresso em $\mu\text{mol m}^{-2} \text{s}^{-1}$, ρ_{ar} é em mol m^{-3} , w' é em s^{-1} e c' é a flutuação de concentração de CO₂ ($\mu\text{mol m}^{-2} \text{s}^{-1}$).

Portanto, o método de CVT, quando as condições necessárias são satisfeitas, apresenta-se um método muito vantajoso, pois as medidas são de baixo impacto ambiental, alta resolução temporal e boa área de abrangência, podendo chegar a vários quilômetros. Por outro lado, em terrenos não planos, condições não estacionárias e heterogeneidade da vegetação, a técnica pode não ser precisa, e assim sub ou superestimar as medidas (BALDOCCHI, 2003).

Um dos erros mais comuns de subestimação ou superestimação da medida de NEE ocorre em condições estáveis da atmosfera. É reconhecido que durante a noite, a Reco é subestimada, e logo ao amanhecer o NEE é superestimado. A razão para este fenômeno é devido à combinação de baixas temperaturas próximas à superfície e altas temperaturas nas camadas acima do dossel, resultando em fraca ou nenhuma turbulência. Com isso, o CO₂ acumulado próximo à superfície devido ao processo de Reco no período noturno, se movimenta nos primeiros momentos de convecção, e então o fluxo alcança a altura dos sensores, e finalmente é medido. De fato, médias para medidas de longo prazo podem balancear essas estimativas (BALDOCCHI, 2003).

Outro ponto importante a se ressaltar, é a advecção. Como foi mencionada anteriormente, a técnica assume que as medições *in situ*, ocorram em condições de terreno plano e vegetação homogênea, para que não ocorra advecção, ou seja, transporte de propriedade escalar pelo vento médio, onde esta é menos intensa. Este fenômeno,

embora ocorra a todo instante, tem sua maior importância à noite, e ocorre principalmente em regiões de transição de ecossistema. Dessa forma, Alves (2017) não recomenda a instalação de torres micrometeorológicas nessas localidades.

Por outro lado, na área de estudo, as condições mínimas de turbulência precisam ser atendidas (AUBINET *et al.*, 2000). Para essa exigência, analisa-se a velocidade de fricção (u^*) que é em função da vegetação, condições do terreno e condições meteorológicas da área de estudo. O limiar da velocidade de fricção será ainda mais importante durante a noite, pois é a partir desse critério que os fluxos noturnos são considerados válidos. Em geral, medidas de fluxos noturnos com $u^* > 0,15 \text{ m s}^{-1}$ contém menos erros (ZHANG *et al.*, 2016); entretanto, é sugerido também um intervalo entre 0,1 a $0,6 \text{ m s}^{-1}$ (BALDOCCHI, 2003). Com essas considerações, os valores de NEE noturnos abaixo de um limiar de u^* podem ser substituídos pela Reco (NEE = Reco).

4 MATERIAL E MÉTODOS

4.1 Área de estudo

Área de estudo compreende a região do NEB que engloba os estados do Maranhão, Piauí, Ceará, Rio Grande do Norte, Paraíba, Pernambuco, Alagoas, Sergipe e Bahia. A região possui quatro principais biomas, nomeadamente, Amazônia, Mata Atlântica, Cerrado e Caatinga (Figura 4), sendo composta por subdivisões e transições (ARAÚJO *et al.*, 2018). A vegetação do NEB é controlada por fatores climáticos e altamente dinâmicos. A Pr é a principal variável climática que afeta a distribuição e a estrutura da vegetação (ARAÚJO *et al.*, 2018).

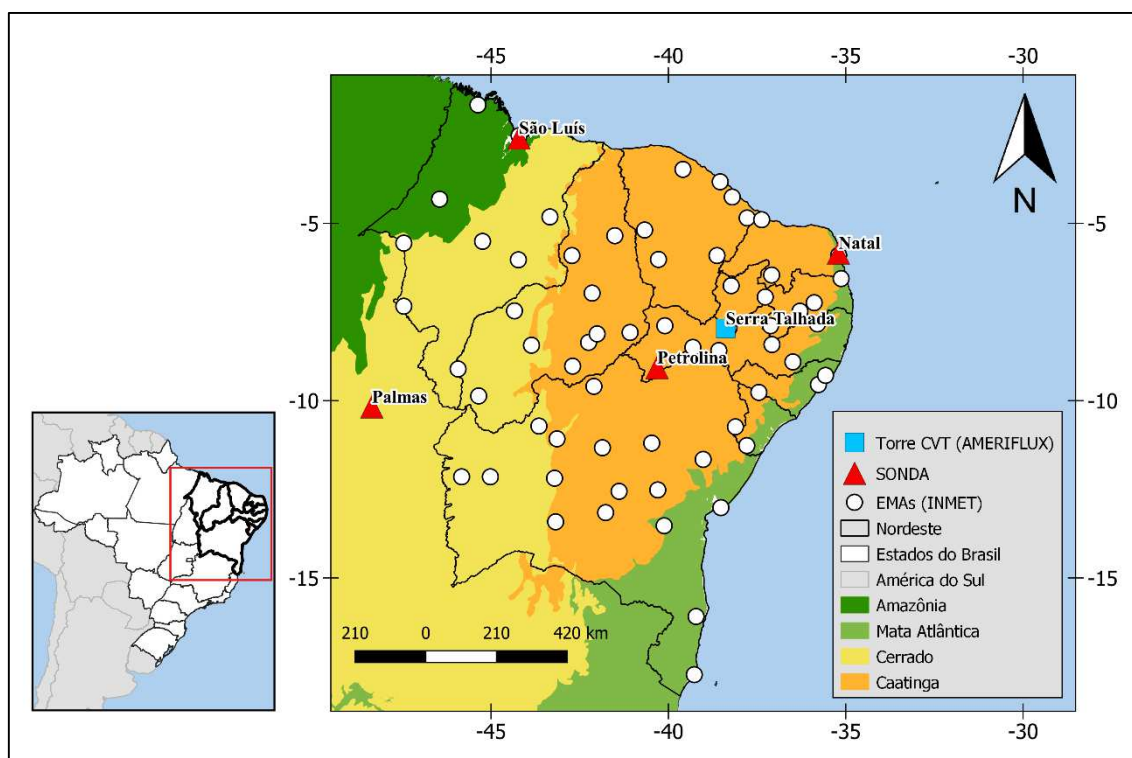


Figura 4 - Localização das estações meteorológicas automáticas - EMAs do Instituto Nacional de Meteorologia - INMET (2019), estações radiométricas do Sistema de Organização Nacional de Dados Ambientais - SONDA (2018), estação micrometeorológica do AMERIFLUX (ANTONINO, 2019) e os biomas do Nordeste Brasileiro - NEB do Instituto Brasileiro de Geografia e Estatística (IBGE, 2004)

O maior Bioma é a Caatinga, com 65%, seguida por Mata Atlântica e Cerrado com 16,9% e 14,3% respectivamente, e o menor deles é a Amazônia, com apenas 3,7%

do total do território nordestino, segundo o IBGE (2004) (Tabela 1). A Caatinga é um bioma exclusivo brasileiro, e embora tenha características de outros semiáridos quentes do mundo, a mesma possui um índice pluviométrico ligeiramente superior, porém com uma alta taxa de evapotranspiração (ARAÚJO *et al.*, 2017; SILVA JÚNIOR *et al.*, 2019; MARQUES *et al.*, 2020). As chuvas médias anuais variam entre 400 a 900 mm (ALVARES *et al.*, 2013) e Tar não variam muito ao longo do ano, com médias de 26,2 °C tendo uma estação chuvosa (EC) concentrada em aproximadamente seis meses ocorrendo, preferencialmente, de novembro a abril (SOUZA *et al.*, 2015). Devido a este padrão, a vegetação desenvolveu estratégias adaptativas, perdendo suas folhas durante o período seco para reduzir a perda de água por transpiração, e um sistema de raiz capaz de obter água do solo com pouca umidade (MARQUES *et al.*, 2020).

O segundo maior bioma nordestino é a Mata Atlântica, composta por vegetação alta, com Tar, em média não ultrapassando os 26 °C e as chuvas no total anual ficam entre 1300 a 2200 mm (ALVARES *et al.*, 2013). Este é um dos biomas mais ameaçados do Brasil, e dos que mais sofreu redução de sua área de floresta nativa nas décadas passadas (DELGADO *et al.*, 2018; SOUZA JÚNIOR. *et al.*, 2020; ROSA *et al.*, 2021).

Tabela 1 - Percentual aproximado de área ocupada pelos biomas nos estados do Nordeste Brasileiro - NEB. Fonte: IBGE/MMA (2004)

Estados	Caatinga	Mata Atlântica	Cerrado	Amazônia
Alagoas	48%	52%	-	-
Bahia	54%	19%	27%	-
Ceará	100%	-	-	-
Maranhão	1%	-	65%	34%
Paraíba	92%	8%	-	-
Pernambuco	83%	17%	-	-
Piauí	63%	-	37%	-
Rio Grande do Norte	95%	5%	-	-
Sergipe	49%	51%	-	-
NEB	65%	16,9	14,3%	3,7%

O Cerrado assemelha-se às savanas da África e da Austrália. A Paisagem vegetativa possui arbustos e gramíneas com troncos retorcidos, cascas espessas e folhas grossas com alguns tipos de vegetação adaptadas e de alguma forma, dependentes da ocorrência de incêndios (ARRUDA *et al.*, 2021). O índice pluviométrico varia entre 1000 a 1600 mm por ano, concentrando-se entre dezembro a fevereiro com 250 mm mês⁻¹. A Tar média pode variar espacialmente entre 20 °C a 26 °C (ALVARES *et al.*,

2013). Nesse Bioma, diferentemente da Caatinga, tem seus rios sempre cheios, embora em período de seca o volume diminua bastante.

Já a Amazônia é o menor de todos os biomas nordestinos, e é encontrado no extremo oeste do estado do Maranhão com 34% do seu território ocupada por este bioma. O total anual das chuvas varia entre 1300 mm em regiões de transição entre Cerrado e Amazônia, e de 2500 mm em regiões de fronteira com o estado do Pará, e região do litoral noroeste, e a Tar é em média 26 °C (ALVARES *et al.*, 2013).

4.2 Dados

4.2.1 Dados Meteorológicos

Foram utilizados dados das estações meteorológicas automáticas (EMAs) do Instituto Nacional de Meteorologia (INMET) instaladas por todo o NEB. Consiste em dados horários, sendo selecionadas as variáveis Rg (MJ m⁻²), UR (%), Pr (mm) e Tar (°C). Os dados meteorológicos foram adquiridos para os anos de 2012 a 2018, sendo este período selecionado devido a maior consistência dos dados. Além disso, esse período foi observado seca prolongada, iniciada em 2012 e finalizada em meados de 2016 (BARBOSA *et al.*, 2019), causando transtornos ao meio ambiente, ao agronegócio e as atividades humanas da região (BEZERRA DA SILVA *et al.*, 2020), e dois anos de La Niña (2017 e 2018) em que as chuvas foram favorecidas em praticamente todo o NEB (MARENGO *et al.*, 2016).

As informações quanto aos anos de El Niño e La Niña, assim como sua intensidade, foram obtidas do Instituto Nacional de Pesquisas Espaciais/Centro de Previsão de Tempo e Estudos Climáticos (INPE/CPTEC, 2020) disponível no link <http://enos.cptec.inpe.br/>. De acordo com INPE/CPTEC (2020), o período de 2012 a 2018 foram observados dois eventos de El Niño Oscilação Sul (ENOS). O período de 2015-2016 ocorreu o fenômeno de El Niño e 2017-2018 foi caracterizado o evento de La Niña, enquanto os anos de 2013-2014 foram anos de temperatura da superfície do mar (TSM) do Pacífico equatorial neutro. Já em 2012, houve a caracterização de gradiente positivo de anomalia de TSM do Atlântico Tropical, conforme dados de *Climate Prediction Center (CPC) da National Oceanic and Atmospheric Administration*

(NOAA) (CPC/NOAA, 2021) que foi o principal mecanismo oceano-atmosfera indutor da grande seca em 2012 no NEB, reportado nos estudos de Souza *et al.* (2015) e Marengo *et al.* (2016).

Complementarmente, dados das estações do Sistema de Organização Nacional de Dados Ambientais (SONDA) também foram adquiridos. O projeto SONDA disponibiliza dados de minuto a minuto e são obtidos gratuitamente (<http://sonda.ccst.inpe.br/infos/index.html>). Para a pesquisa os dados de Rg e PAR foram utilizados para modelar a PAR para cada bioma, sendo as estações de São Luís – MA, Palmas – TO, Petrolina – PE e Natal – RN consideradas representativas dos biomas Amazônico, Cerrado, Caatinga e Mata Atlântica, respectivamente (Figura 5). Embora Palmas não se situe na região NEB, esta foi a estação mais próxima e dentro do bioma Cerrado que continha medidas de PAR. Os dados também passaram por filtragens em busca de inconsistências ou falhas, sendo utilizados apenas os anos com menos de 25% de lacunas. Em virtude desta análise os anos com dados de boa qualidade foram 2013 (Palmas), 2014 (Petrolina), 2015 (Natal) e 2016 (São Luís).

Dados de torres micrometeorológicas foram utilizados para validação das estimativas de GPP pelo produto MOD17A2H e GPP melhoradas pela utilização de dados de estações meteorológicas. Os dados micrometeorológicos da estação de Serra Talhada - PE foram adquiridos juntos ao projeto AMERIFLUX (ANTONINO, 2019) cedidos pelo projeto Observatório Nacional da Dinâmica da Água e de Carbono no Bioma Caatinga (ONDACBC) do período de junho de 2014 a julho de 2015. As variáveis meteorológicas incluem medições automáticas de fluxo de CO₂ que possibilitou a avaliação da GPP que será estimada nesta pesquisa.

4.2.2 Dados orbitais do MODIS

Foram adquiridas as imagens MODIS do satélite TERRA referentes a três produtos, sendo eles: GPPmodis, MOD09A1 de reflectância da superfície para calcular o EVI conforme Equação 11 (LIU e HUETE, 1995), sendo a partir daqui denominado EVI09, e por último o produto MOD15A2H referente a FPAR. Os dados são da coleção

6.0, possuem resolução espacial de 500 m e resolução temporal de 8 dias. Para valores diários, cada pixel foi dividido por 8 e com isto as médias mensais foram obtidas.

$$EVI09 = 2,5 \frac{(NIR - RED)}{(NIR + 6xRED - 7,5xBLUE + 1)} \quad (11)$$

O período é de janeiro de 2012 a dezembro de 2018, sendo que os mosaicos selecionados compreendem todo o NEB, correspondendo aos *tiles* h13v9, h14v9, h13v10 e h14v10. As imagens são distribuídas gratuitamente pelo serviço geológico dos Estados Unidos sendo obtidas por meio da plataforma *Google Earth Engine*.

4.2.3 Dados de cobertura da terra (MapBiomas)

O Mapeamento anual da cobertura e uso do solo no Brasil (MAPBIOMAS) é um projeto que reúne especialistas em sensoriamento remoto, computação, biomas e ciências de dados para classificar o uso e cobertura do solo para todo Brasil (MAPBIOMAS, 2019). O Projeto iniciou em 2015, e desde então disponibiliza em sua plataforma (<https://mapbiomas.org/>) imagens do uso e cobertura da terra para todo o Brasil. A base de dados é anual, com resolução de 30 m, abrangendo uma série temporal de 1985 a 2019, acessadas e processadas pelo *Google Earth Engine*. A classificação feita pelo MapBiomas segue os esquemas de classes da *Food and Agriculture Organization* (FAO) e IBGE (SOUZA JÚNIOR *et al.*, 2020).

Para esta pesquisa foram selecionados os dados da coleção 5.0 correspondentes a todo o domínio do território do NEB. Os dados são de área total, obtidos diretamente no site do MapBiomas em formato de planilhas eletrônicas, compreendendo os anos de 2012 a 2018. A área total do uso e cobertura do solo e as mudanças para as classes Agropecuária e Vegetação Nativa estão sumarizadas na Tabela 2.

Tabela 2 - Médias das áreas de cobertura vegetal e uso do solo por agropecuária e suas mudanças entre os anos 2012 e 2018 para os biomas do Nordeste Brasileiro. Fonte: MapBiomas (2019), coleção 5.0

Bioma	Nível	2012	2018	Mudança de área (Mha)	Nível	2012	2018	Mudança de área (Mha)
		Vegetação Nativa (Mha)				Agropecuária (Mha)		
Caatinga	3 (Savana e Floresta)	49,6	49,7	0,14	Agropecuária	28,7	28,6	-0,12
Cerrado	Floresta)	32,7	31,1	-1,51		7,24	8,9	1,69
M. Atlântica	1 (Formação Florestal)	5,49	5,55	0,05		9,5	9,39	- 0,11
Amazônia	Florestal)	5,12	5,06	-0,06		5,35	5,43	0,08

Os dados das classes denominadas Agropecuária utilizadas nesta pesquisa, foram da categoria Agropecuária que consiste nas subcategorias de: Pastagem, Agricultura e Mosaicos de Agricultura e Pastagem. Enquanto os dados da Floresta (vegetação nativa) foram da categoria Vegetação Nativa que possui 2 níveis: o primeiro nível consiste em 3 subgrupos denominado Formação Florestal, Formação Savânica e Mangue; o segundo nível possui uma única categoria, sendo ela: Floresta Plantada.

4.3 Processamento de dados

4.3.1 Dados meteorológicos e dos produtos MODIS

Os dados meteorológicos passaram por uma análise prévia de consistência para identificação de dados errôneos e/ou horários sem registro de medidas das variáveis. Para este processo, planilhas virtuais do *software* Excel foram utilizadas, no quais os dados brutos foram submetidos a identificação e contagem de medidas inconsistentes com a utilização de funções lógicas em cada célula que permitiram conhecer a quantidade de células sem medidas e com valores fora das normais climatológicas daquela estação. Ao final desta etapa, as estações e os anos que continham 75% da série de dados horários sem falhas foram selecionadas, como sugerido por Almeida *et al.* (2018), ou seja, dados registrados válidos acima de 6570 para anos não-bissextos e 6588 para anos bissextos.

Assim, foram selecionadas 64 estações meteorológicas espacialmente distribuídas pelo NEB, sendo 3 para o bioma Amazônico, 11 para o Cerrado, 8 para a Mata Atlântica e 42 para a Caatinga (Figura 5). Posteriormente, com os dados horários foram obtidas as médias diárias, mensais e anuais. Com as médias anuais, foi feita a interpolação dos dados meteorológicos por meio do *software* QGIS versão 3.16.2 para análise espacial dos dados. A interpolação foi realizada utilizando o método: Peso pelo Inverso da Distância (sigla em inglês - IDW).

Já os processamentos iniciais das imagens orbitais dos produtos MODIS, a saber, GPP, FPAR e de reflectância (MOD09A1), foram realizadas junto a plataforma *Google Earth Engine*, no qual, as imagens foram mosaicadas, reprojetaadas para as coordenadas geográficas: latitude e longitude, e datum WGS1984, e também convertidas de número digital para valores biofísicos multiplicando os pixels pelo fator de correção (Tabela 3).

Tabela 3 - Produtos do sensor MODIS com suas respectivas unidades e fatores de correção. Fonte: USGS (2020)

Produto	Variável	Unidade	Fator de correção
MOD17A2H	GPP	gC m ⁻²	0,1
MOD15A2H	FPAR	%	0,01
MOD09A1	Reflectância da Superfície	Adimensional	0,0001

Com o *software* QGIS versão 3.16.2 foram obtidos os valores anuais das variáveis biofísicas, assim como a realização do acabamento final das figuras com recorte das imagens e escalas de cores. Para as médias mensais, foram extraídos de cada imagem os valores dos pixels correspondentes as estações meteorológicas, e transferidos para planilhas do Excel, no qual, foram obtidos os valores diários dividindo por 8.

4.3.2 Particionamento e preenchimento dos fluxos de carbono da estação micrometeorológica

A GPP de torres micrometeorológicas (GPP_{torre}) são obtidas pelo método de CVT que calcula os fluxos de carbono entre o ecossistema e a atmosfera (NEE), sendo

posteriormente particionado entre GPP e Reco conforme Equação 1. A obtenção da GPP vai depender dos valores de respiração do ecossistema (Reco) noturnos que são medidos diretamente via CVT, pois a noite a GPP é nula, uma vez que, não se realiza fotossíntese e, portanto, não há assimilação de CO₂ pela vegetação. Com os valores de Reco noturnos, há a extrapolação desses valores para o dia, e, por conseguinte, por meio da subtração do NEE se obtém a GPP ($GPP = Reco - NEE$). Os dados de Reco noturnos são usados para preenchimento de falhas dessa variável. Entretanto, só é possível obter valores válidos de a Reco a partir de um limiar de vento (u^*) que provoque turbulência.

Neste trabalho, foi usado a metodologia de Reichstein *et al.* (2005) para particionar NEE. Para tanto, antes é necessário o preenchimento de falhas (*gap-filling*) de NEE, e que também seguiu a proposta de Reichstein *et al.* (2005). O procedimento implica em separar os dados de NEE em três grupos, a depender dos dados das variáveis meteorológicas (Tar, DPV e Rg) disponíveis. O primeiro grupo de dados faltosos deve conter as três variáveis, e cada lacuna foi preenchida com a média dos valores de NEE de condições meteorológicas semelhantes. Para o segundo grupo, as falhas foram preenchidas apenas para condições de Rg aproximadas. O terceiro grupo é destinado para as lacunas que não possuem nenhuma variável meteorológica, nesse caso, os valores de NEE foram preenchidos pela média diária.

As informações faltosas dos grupos foram preenchidas com as médias do NEE de 7 dias, caso não encontre valores disponíveis, a janela é ampliada para 14 dias (Figura 5), esses critérios são partes da metodologia de Reichstein *et al.* (2005) e detalhado em Wutzler *et al.* (2018). Para os dois primeiros grupos, as condições meteorológicas semelhantes, de acordo com Aires (2007), são aquelas em que a Tar, Rg e DPV não diferem mais de 2,5 °C, 50 W m⁻² e 5 hPa, respectivamente.

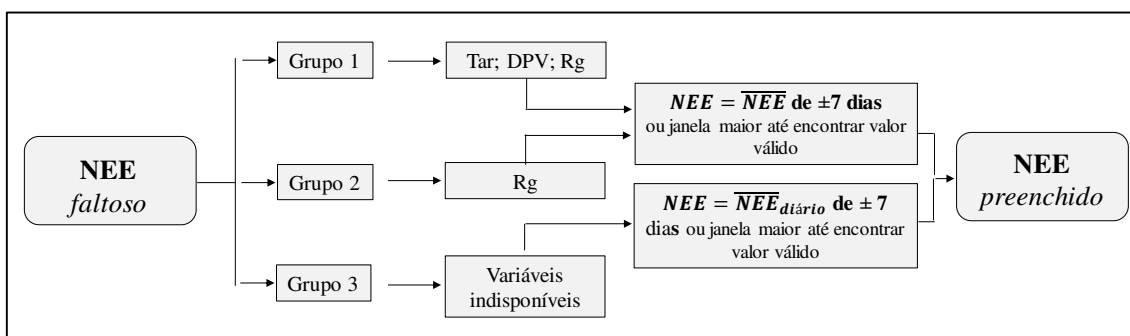


Figura 5 - Esquema resumido das etapas de preenchimento de falhas. Fonte: Reichstein *et al.* (2005) e Wutzler *et al.* (2018)

Com a etapa de *gap-filling* finalizada, o particionamento pode ser então realizado. Após separar os dados de NEE em diurnos e noturnos, os dados noturnos são considerados Reco. Posteriormente, em dias de baixa turbulência, a Reco diurna e noturna é estimada pela proposta de Lloyd e Taylor (1994) que ajusta os valores de Reco em função da Tar ou Tsoil, conforme Equação 12, no qual, T_{ref} é a temperatura de referência, T_0 é o parâmetro de regressão, é uma constante igual a $-46,02$ °C e E_0 é a energia de ativação dada uma Tar, ou seja, é o parâmetro de sensibilidade à Tar ou do Tsoil que faz com que a Reco seja ativada no modelo (Aires, 2007).

$$R_{eco} = R_{ref} e^{E_0 \left(\frac{1}{(T_{ref}-T_0)} - \frac{1}{(Tar-T_0)} \right)} \quad (12)$$

Os procedimentos metodológicos de preenchimento de falhas e particionamento de NEE foram executados utilizando a ferramenta online REddyProcWeb do Instituto Max Planck (Max Planck Institute for Biogeochemistry - Department Biogeochemical Integration | Services / REddyProcWeb (mpg.de)). Todas as informações das etapas do processamento do pacote *REddyProc* podem ser consultadas em Wutzler *et al.* (2018).

4.4 Métodos

4.4.1 Métodos de estimativa da GPP

A primeira estimativa da GPP para a análise é do próprio produto MOD17A2H (GPPmodis) obtida e processada conforme especificações citadas nos itens anteriores. Para a segunda estimativa da GPP (GPPmet) propõe-se recalculá-la esta variável, substituindo as variáveis Rg e DPV, oriundos de reanálise, pelos dados medidos pelas EMAs, substituindo também a proporção da PAR (MJ m⁻²) incidente (parametrizado a partir de 0,45 da Rg no algoritmo MOD17A2H) pela PAR modelada com dados do projeto SONDA. A terceira estimativa da GPP proposta aqui (GPPevi) foi substituir a variável FPAR (MOD15A2H) pela variável EVI09 calculada com os dados do MOD09A2, enquanto que os outros dados de entrada do algoritmo utilizados na segunda proposta (GPPmet) foram mantidos, variando apenas a FPAR. Um resumo esquemático de todas as metodologias de estimativas da GPP pode ser verificado na Figura 6.

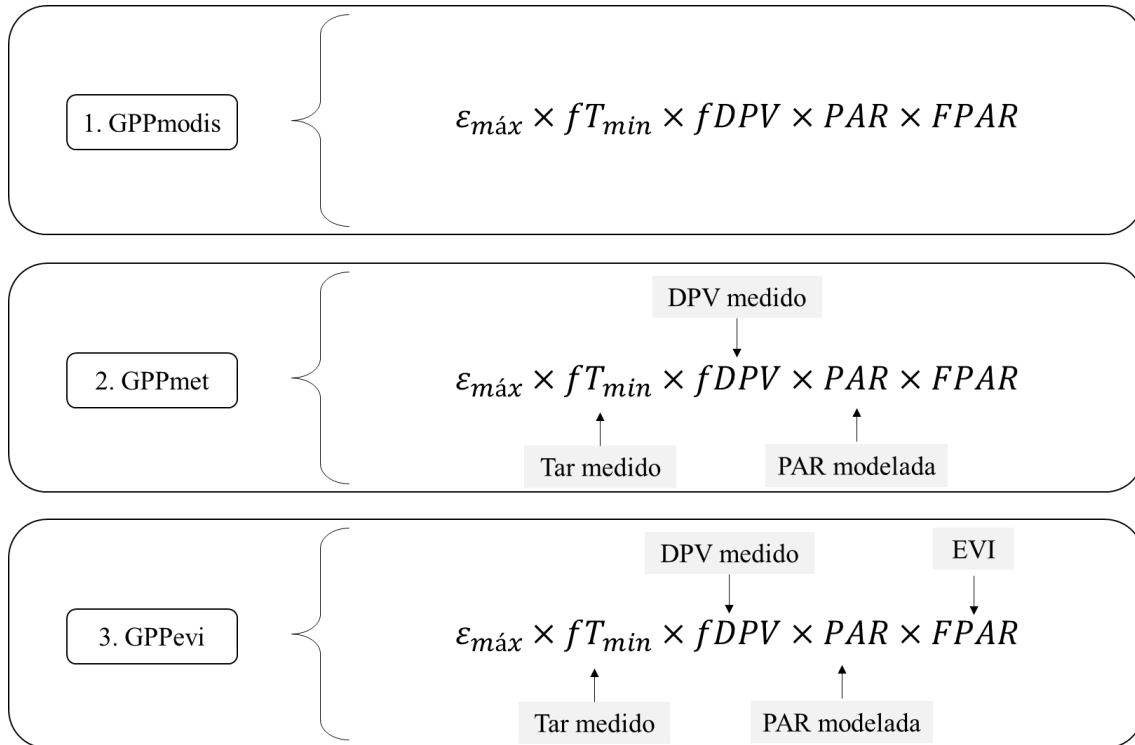


Figura 6 - Resumo das três metodologias de estimativas da produção primária bruta - GPP ($gC\ m^{-2}$). GPPmodis é um produto pronto do MOD17A2H, enquanto GPPmet e GPPevi são estimativas otimizadas

Para obtenção da variável PAR ($MJ\ m^{-2}$) uma análise de regressão linear com a Rg ($MJ\ m^{-2}$) foi aplicada, fornecendo as informações sobre a porcentagem da PAR incidente para a estação representativa de cada bioma, com esta informação, a proporção da PAR foi extrapolada para todas as EMAs do INMET, segundo sua localização no bioma, com intuito de calcular a PAR incidente. O DPV (kPa) diário foi adquirido partir das variáveis Tar ($^{\circ}C$) e UR (%) calculado pela diferença entre pressão de saturação do vapor d'água atmosférico diário (e_s , kPa) (TETENS, 1930), Equação 13, e a pressão atual do vapor diário (e_a , kPa), Equação 14.

$$e_s = 0,6108 \exp\left(\frac{7,5t}{237,3 + t}\right) \quad (13)$$

$$e_a = \frac{UR \times e_s}{100} \quad (14)$$

De posse desses dados, os parâmetros ponderadores, que limitam o LUE diário, foram obtidos conforme Equação 4 e Equação 5 para a fT_{min} e $fDPV$ respectivamente.

Os valores de ϵ_{\max} , $T_{\min_{\min}}$ e $T_{\min_{\max}}$ e DPV_{\max} e DPV_{\min} para cada bioma foram retirados da BPLUT (Tabela 4).

Tabela 4 - Parâmetros dos Biomas de acordo com Running e Zhao (2015) utilizados na etapa de estimativa da produção primária bruta – GPP (gC m^{-2}). EBF = *Evergreen Broadleaf Forest*; CShrub = *Closed Shrublands*

Bioma	BPLUT					
	Cobertura do Solo	ϵ_{\max} gC/MJ	$T_{\min_{\min}}$ °C	$T_{\min_{\max}}$ °C	DPV_{\min} kPa	DPV_{\max} kPa
Amazônico	EBF	1,27	-8,00	9,09	0,80	3,10
Mata Atlântica	EBF	1,27	-8,00	9,09	0,80	3,10
Cerrado	Savanna	1,21	-8,00	11,39	0,65	3,10
Caatinga	CShrub	1,28	-8,00	8,61	0,65	4,70

As escolhas dos parâmetros representativos dos biomas Amazônico (EBF) e Cerrado (*Savanna*), e Caatinga (CShrub) são recomendados por Almeida *et al.* (2018) e Mendes *et al.* (2020) respectivamente, por representar melhor as características climática e de cobertura vegetal. Com as estimativas de GPP para cada bioma foram então feitas as análises quantitativa e qualitativa dos modelos de produtividade da vegetação, e suas sensibilidades as mudanças dos fatores bioclimáticos e sobre o comportamento da GPP em anos de El Niño, La Niña de gradiente positivo de TSM do Atlântico.

4.4.2 Validação dos métodos de estimativa de GPP e estatísticas

Em uma primeira análise de sensibilidade do produto MOD17A2H (GPPmodis) em capturar possíveis efeitos das mudanças de uso e cobertura do solo, assim como mudanças dos fatores ambientais nos biomas nordestinos, foi empregado com o uso do método de regressão linear e se analisou o coeficiente de determinação (R^2) entre as variáveis. A análise entre as mudanças de uso e cobertura do solo e GPPmodis foram feitas com dados anuais da área total da agropecuária e da vegetação nativa em Mha ($M = 10^6$) do MapBiomas. Enquanto, a relação da variabilidade anual da GPPmodis e as contribuições dos fatores bioclimáticos foram realizadas com as médias anuais da Tar, UR, Rg, EVI09 e FPAR, e dos totais anuais da Pr para cada bioma.

Para examinar as relações em escala mensal entre as variáveis ambientais e biofísicas com as GPP estimadas, e as relações entre os modelos de GPP, foi usado o mapa de calor da matriz de correlação por meio do pacote *ggcorrplot* do *software* R 4.1.0 e o comando *p.mat* para exibir os coeficientes significativos. Além disso, R^2 foi empregado para complementar esta análise. Todos os coeficientes entre os modelos e as relações com as variáveis foram testados sob a hipótese nula em um nível de significância de 5%.

Para avaliar os métodos propostos de estimativa da GPP foram realizadas comparações dos resultados da GPP da estação micrometeorológica (GPPtorre) localizada em Serra Talhada – PE inserida no bioma Caatinga para o período de junho de 2014 a julho de 2015. Os dados meteorológicos (Tar, Rg e DPV) da estação micrometeorológica foram utilizados para recalculer a GPP para obtenção das estimativas de GPP pelos métodos propostos, a saber, GPPevi e GPPmet, enquanto a GPPmodis foi obtida diretamente pelo produto MOD17A2H.

Assim, análises estatísticas de desempenho das estimativas foram realizadas para quantificar a magnitude da diferença entre GPP estimado e GPP observado em escalas diárias, acumulado de 8 dias e mensais e sazonais. Também foram realizadas análises de correlação (r) para verificar o grau de relação entre GPP estimado e observado. Todos os coeficientes foram testados sob a hipótese nula em um nível de significância de 5%. As métricas estatísticas empregadas nesta pesquisa são: o Erro Absoluto Médio (EAM), Erro Relativo Médio (ERM) e Raiz do Erro Quadrático Médio (REQM) descritas nas Equações de 15 a 17.

$$EAM = \frac{1}{n} \sum_{i=1}^n |y_{mod} - y_{ec}| \quad (15)$$

$$ERM = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_{mod} - y_{ec}}{y_{ec}} \right| \quad (16)$$

$$REQM = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_{mod} - y_{ec})^2} \quad (17)$$

em que: y_{mod} e y_{ec} são os valores estimados e observados, respectivamente, e n é o número de pares da amostra. Tanto EAM e o REQM possuem a mesma unidade de cada variável investigada, enquanto o ERM exprime a porcentagem desse erro.

5 RESULTADOS E DISCUSSÃO

5.1 Característica bioclimáticas

Analisando o padrão espacial e anual da Pr (mm) na Figura 7 observa-se que os maiores valores são encontrados na região do extremo noroeste no estado do Maranhão e sudeste do litoral nordestino, nos anos de 2012, 2016 e 2018, mas em 2013, 2014 e 2017, observam-se maiores Pr, também por toda a extensão do leste do NEB. Os máximos variam entre 1750 mm a 2250 mm. Já os menores valores, inferiores a 1000 mm, são concentrados na região central, cobrindo a maior parte da região Nordeste. Portanto, caracterizando um padrão espacial bastante heterogêneo das chuvas na região (BARBOSA e KUMAR, 2016; ARAÚJO *et al.*, 2018).

Temporalmente, observa-se que no ano de 2012 as chuvas se apresentaram muito inferiores as dos outros anos. Por outro lado, no ano de 2018 os índices pluviométricos foram bem elevados. Os baixos índices da Pr em 2012, pode ter sido provocado pelo gradiente de TSM do Atlântico que neste ano foi positivo, impedindo o movimento da Zona de Convergência Intertropical para o Hemisfério Sul (SOUZA *et al.*, 2015) desfavorecendo as chuvas na região (ANDREOLI e KAYANO, 2007). Em contrapartida, no ano de 2018 houve a caracterização do fenômeno La Niña que favorece as chuvas tanto na intensidade quanto espacialmente (INPE/CPTEC).

As variáveis Rg diária (MJ m^{-2}) (Figura 8), Tar ($^{\circ}\text{C}$) (Figura 9) e UR (%) (Figura 10) também tiveram seus comportamentos moldados em decorrência dos fenômenos La Niña e gradiente positivo do Atlântico, como observado em Souza *et al.* (2015). Com a Rg mais alta durante o evento de gradiente positivo do Atlântico, ocorreu um aumento na Tar e diminuição da UR. Já durante o fenômeno La Niña ocorrido em 2018 a Rg reduziu seus valores em quase todo o NEB. A Tar, por consequência, também foi baixa, sendo predominantemente menor no sudeste da região de Mata Atlântica. A UR para este ano foi elevada, sendo menor na Caatinga maior na região de floresta Atlântica e Amazônica. No ano de 2014, em que as condições de TSM foram neutras, a Pr, Rg, Tar e UR comportaram-se de maneira climatológica. Em 2015, devido a ocorrência do El Niño, resultou em condições secas e quentes no NEB.

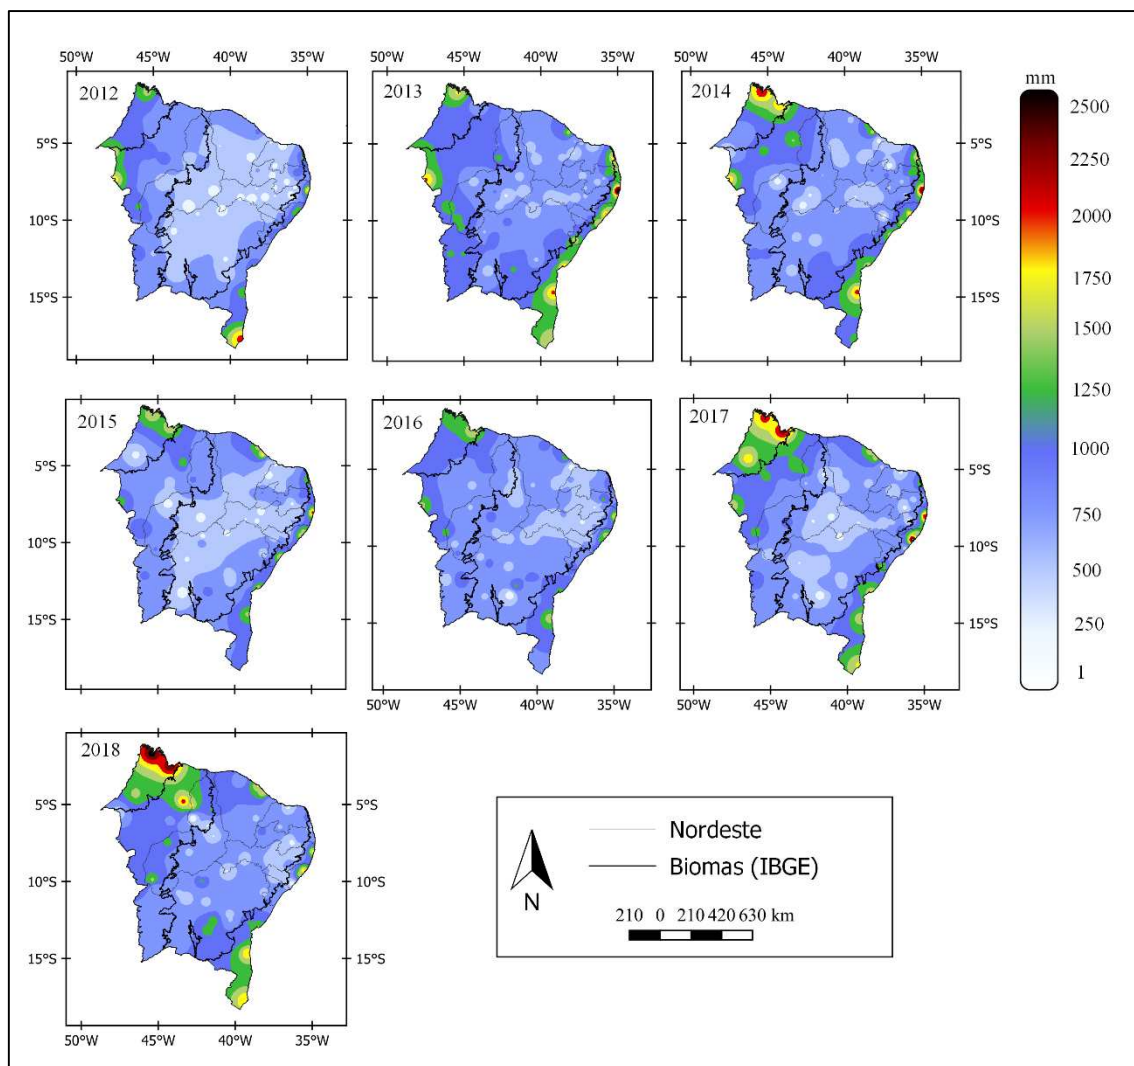


Figura 7 - Distribuição espacial e anual das chuvas (mm) no Nordeste Brasileiro para os anos de 2012 a 2018

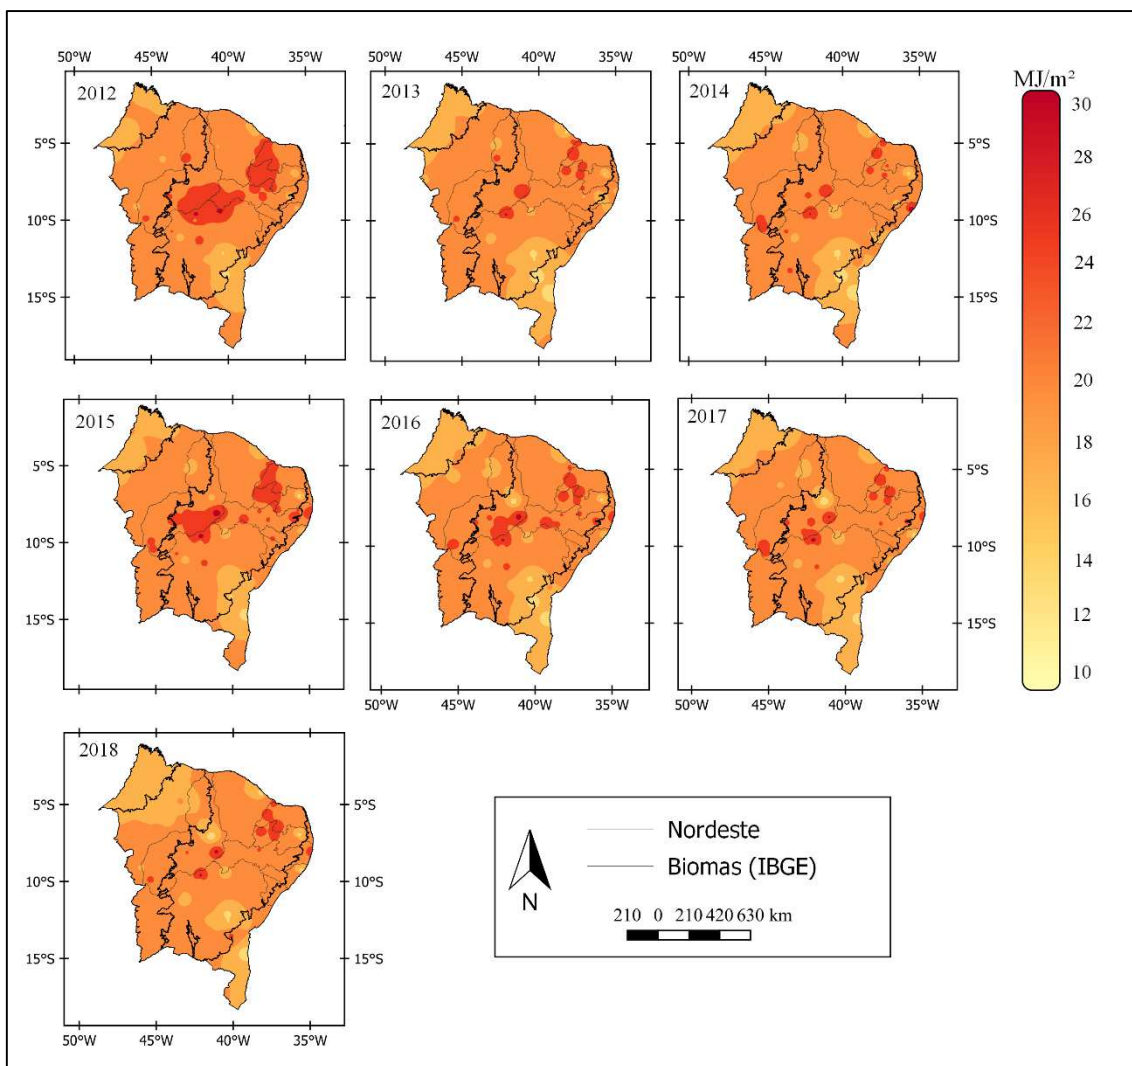


Figura 8 - Distribuição espacial e anual da radiação global – R_g (MJ m^{-2}) no Nordeste Brasileiro para os anos de 2012 a 2018

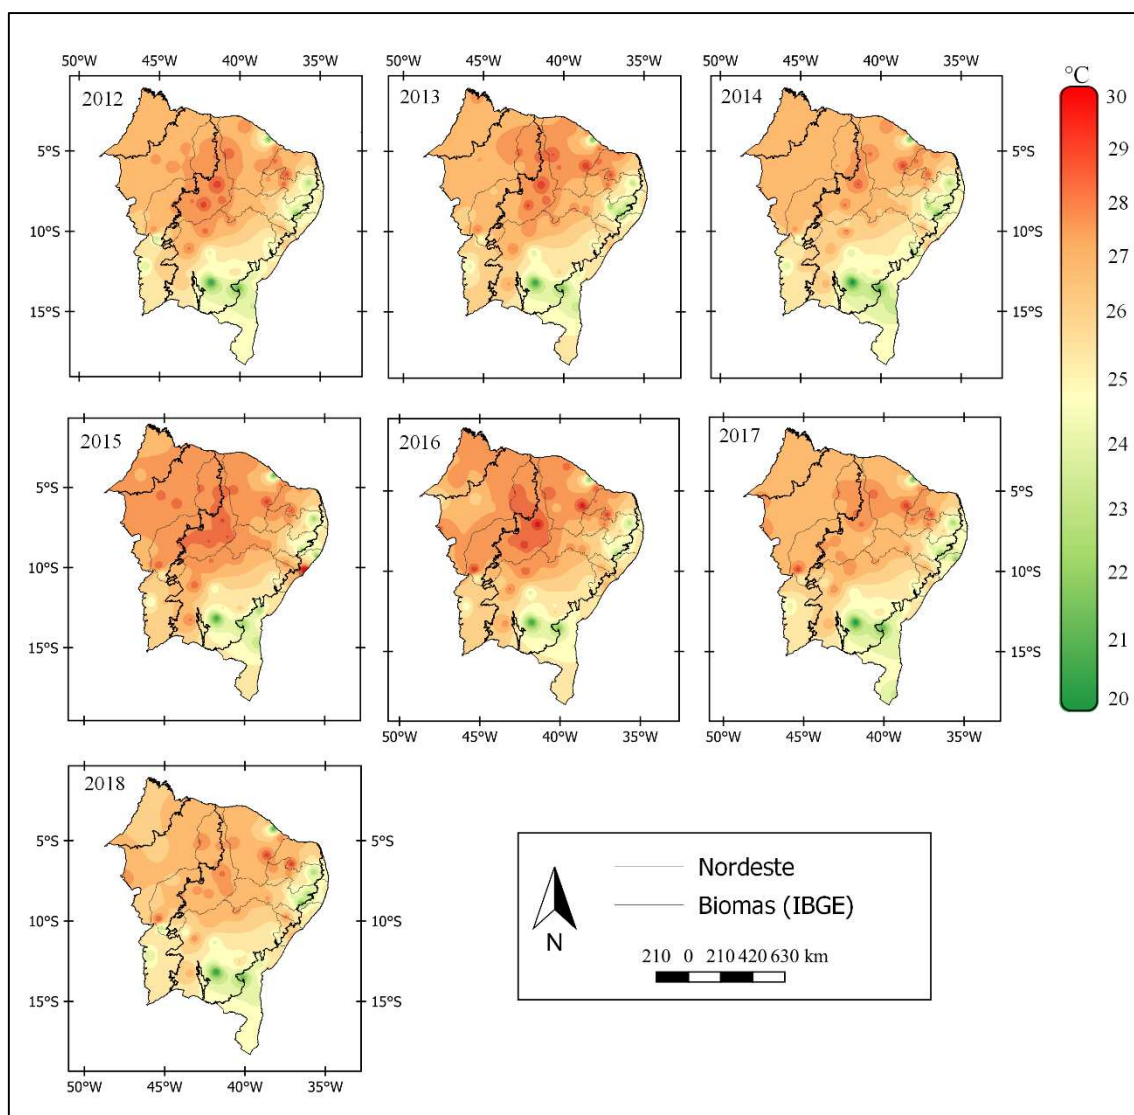


Figura 9 - Distribuição espacial e anual da temperatura do ar média diária – Tar (°C) no Nordeste Brasileiro para os anos de 2012 a 2018

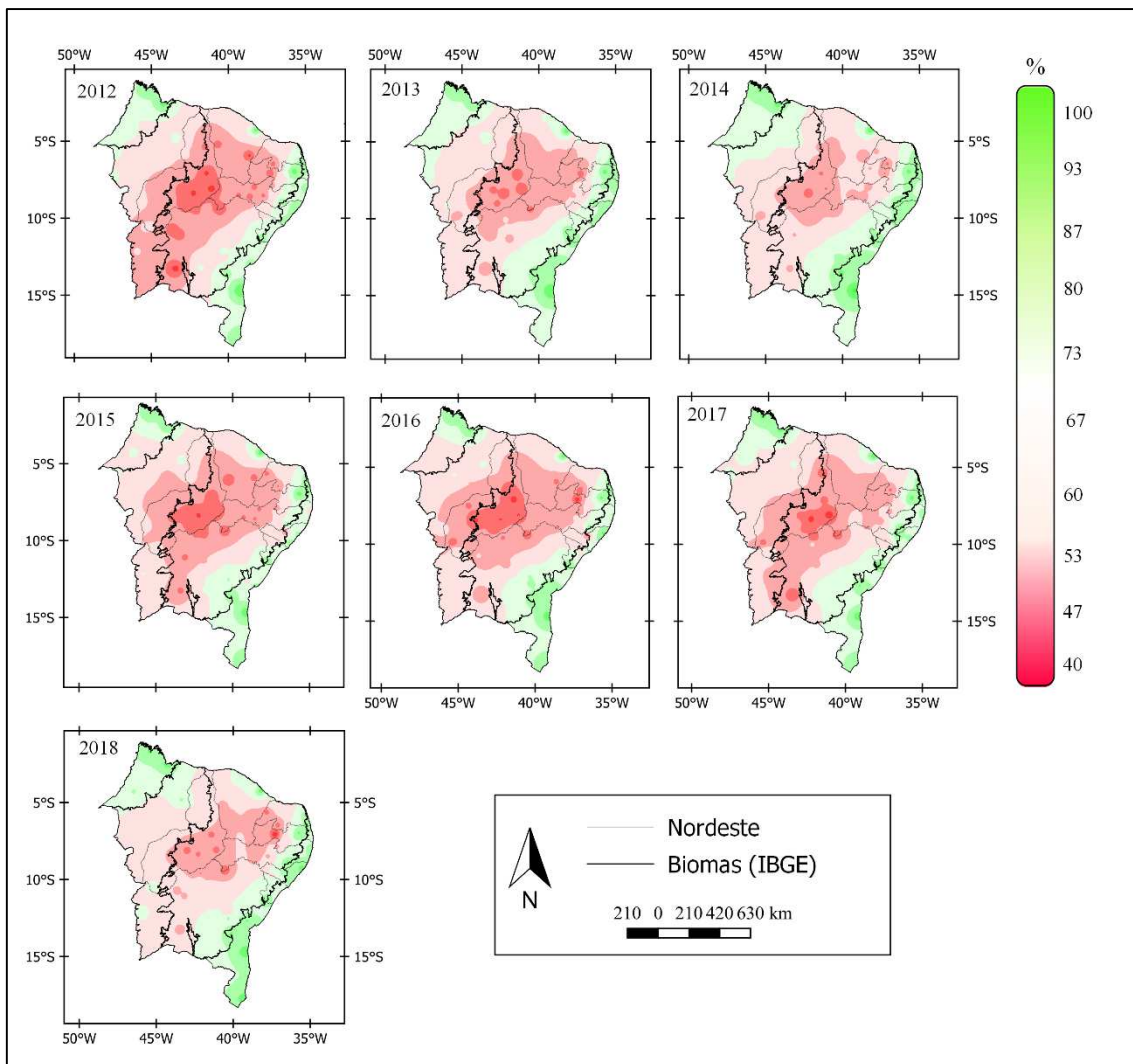


Figura 10 - Distribuição espacial e anual da umidade relativa média diária – UR (%) no Nordeste Brasileiro para os anos de 2012 a 2018

A Figura 11 mostra as variações do EVI09 para os anos de 2012 a 2018. Espacialmente, o EVI09 foi mais baixo no bioma Caatinga e sul do bioma Cerrado e os EVI09 mais elevados foram observados na parte norte e extremo noroeste do Cerrado e Amazônico, respectivamente, e na Mata Atlântica. Os valores mais altos de EVI09 foram entre 0,5 e 0,6 no noroeste e leste do Nordeste. Os menores valores foram inferiores 0,4 na Caatinga e sul do Cerrado. Mostrando que os padrões espaciais dessas variáveis são em função do tipo de vegetação que é condicionada ao padrão espacial das chuvas (MORAIS *et al.*, 2017).

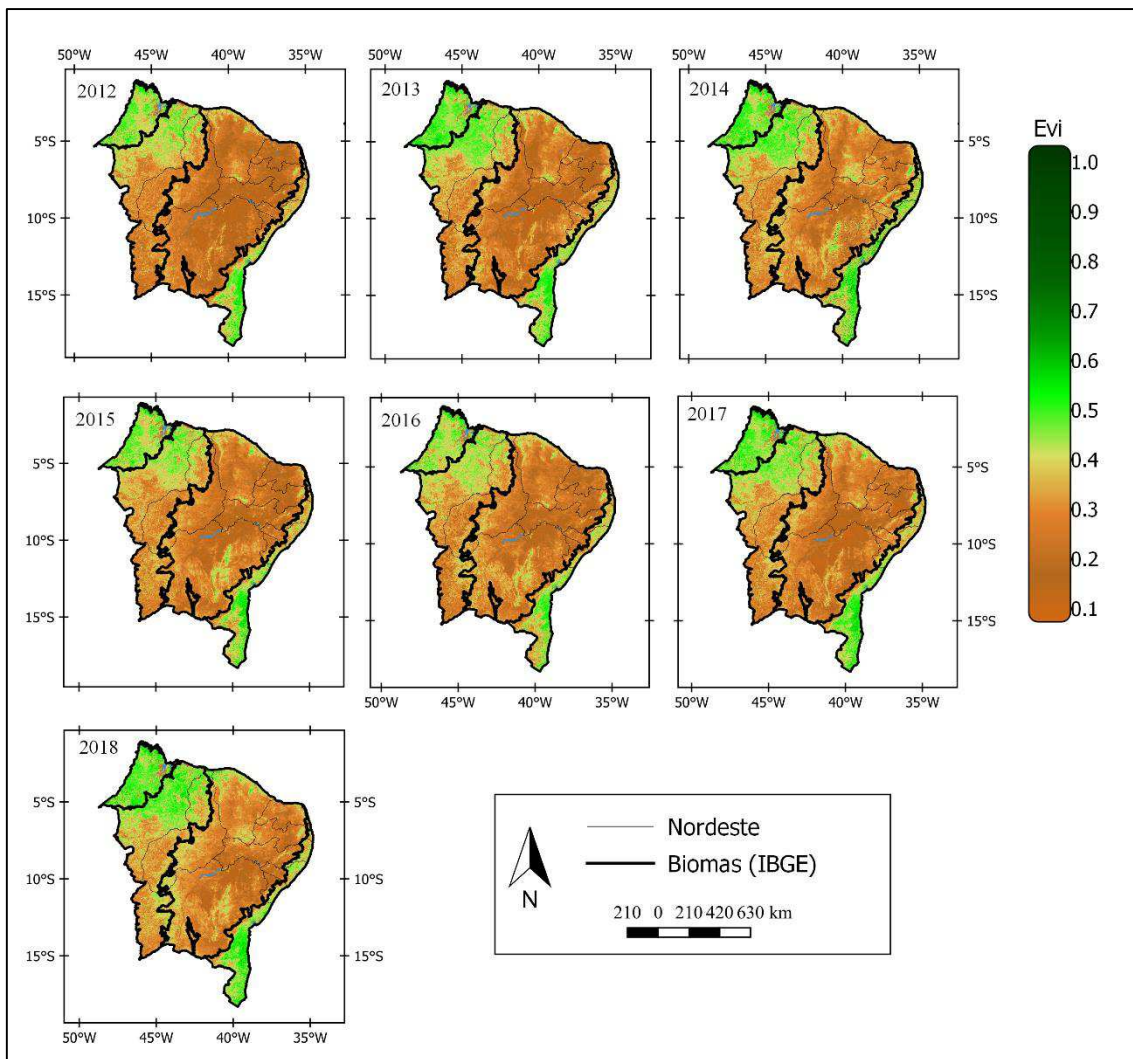


Figura 11 - Distribuição espacial e anual do índice de vegetação melhorado – EVI09 no Nordeste Brasileiro para os anos de 2012 a 2018

O comportamento anual e espacial da FPAR (Figura 12) é similar ao EVI09, mas a magnitude foi ligeiramente maior. Isto era esperado porque a FPAR computa todos os componentes da vegetação, inclusive as partes que não fazem fotossíntese, como galhos e folhas mortas (OGUTU e DASH, 2013). Em geral, os valores de FPAR variam de 0,1 a 0,8. Os maiores valores foram observados nas regiões Mata Atlântica e externo norte do Cerrado e Amazônia, e menores valores na parte central do Nordeste dentro dos biomas Caatinga e Cerrado. O ano de 2012 a FPAR, assim como para outras variáveis foi mais baixa, e em 2018 os valores foram maiores em todo o Nordeste, em concordância com a Pr elevada. As regiões de Mata Atlântica e Amazônia possuem valores mais altos dos índices de vegetação em virtude da densidade do dossel que é em função das chuvas (BRANDO *et al.*, 2010). Além disso, essas áreas não sofrem longos

períodos de déficit hídrico devido a convergência de umidade do oceano Atlântico (SANTOS *et al.*, 2020). Por outro lado, o bioma Caatinga e setor sul do Cerrado a vegetação é mais esparsa apresentando solo mais exposto, portanto, exibindo baixos índices de vegetação (BARBOSA *et al.*, 2019) em virtude do baixo IAF.

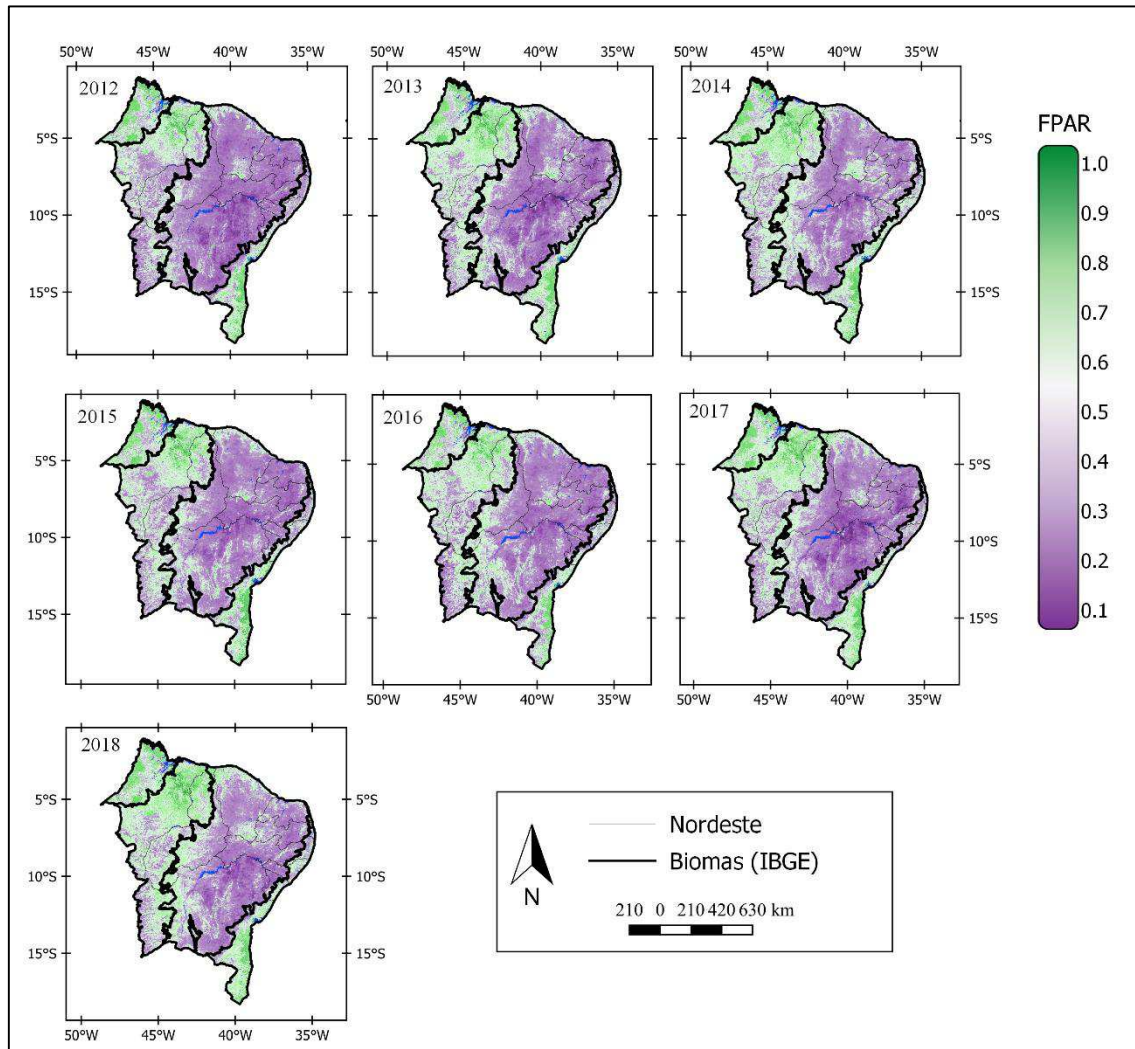


Figura 12 - Distribuição espacial e anual da fração da radiação fotossinteticamente ativa – FPAR no Nordeste Brasileiro para os anos de 2012 a 2018

A variação anual da GPPmodis (gC m^{-2}) entre os anos de 2012 a 2018 está apresentada na Figura 13. Os mais altos valores de GPPmodis foram observados nas regiões de alto índice de vegetação, Pr e baixa Tar. Ou seja, as regiões do sul da Mata Atlântica, extremo norte da Amazônia e Cerrado, onde são encontrados valores de GPPmodis acima de $2200 \text{ gC m}^{-2} \text{ ano}^{-1}$. Por outro lado, o GPPmodis abaixo de $1300 \text{ gC m}^{-2} \text{ ano}^{-1}$ chegando a valores menores que $500 \text{ gC m}^{-2} \text{ ano}^{-1}$ são observados na maior parte da região Nordeste, abrangendo a Caatinga, o sul do Cerrado, uma pequena parte

do centro da Amazônia e norte da Mata Atlântica. O ano de 2012 a GPPmodis foi predominantemente mais baixa em todo o NEB. Nos anos seguintes, 2013 e 2014, identificado como ano neutro, porém seco, e os anos de 2015 e 2016, anos de El Niño, mostraram padrão espacial semelhante a 2012, com GPP abaixo de 500 gC m^{-2} . Para os anos de 2017 e 2018 (La Niña) foram anos mais chuvosos e em virtude dos altos índices de Pr, a vegetação melhora os processos fotossintéticos. Assim a GPPmodis aumentou em toda área do Nordeste, mas ainda bem irregular, devido a dinâmica espacial das chuvas que condicionam o comportamento da fenologia da vegetação (MORAIS *et al.*, 2017).

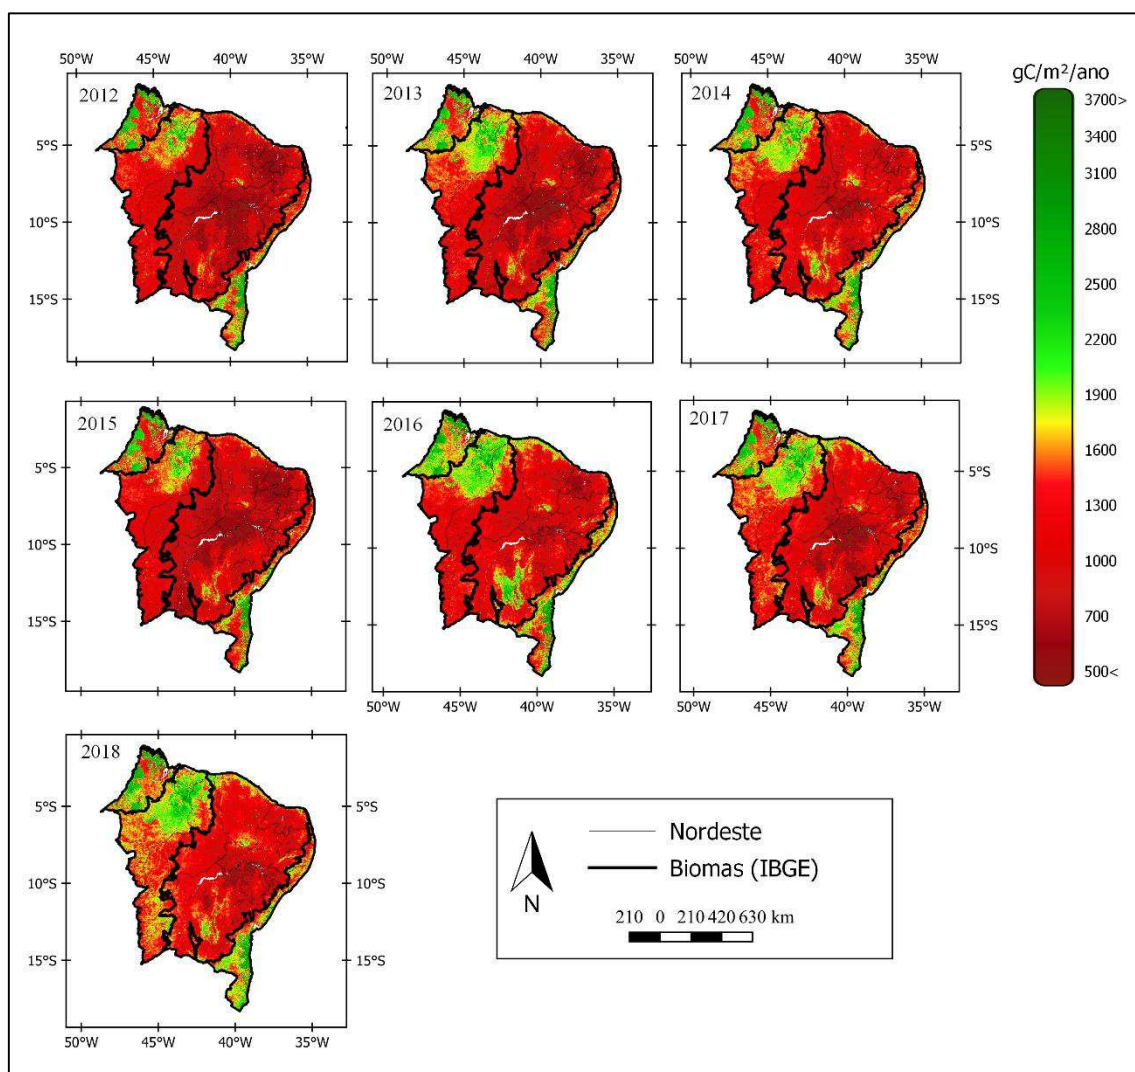


Figura 13 - Distribuição espacial e anual da produtividade primária bruta do produto MOD17A2H – GPPmodis (gC m^{-2}) para o Nordeste Brasileiro para os anos de 2012 a 2018

As variações espaciais da GPPmodis resultam na combinação da distribuição das chuvas e, em menor grau, atribuídas a outras variáveis ambientais (ANAV *et al.*, 2015). Os biomas Amazônico e Mata Atlântica possuem valores de GPPmodis maiores devido as características climáticas favoráveis, como Tar amena e alta Pr. Por outro lado, a Caatinga e Cerrado, apresentaram GPPmodis menor em reflexo da alta Tar e baixa Pr. Essas características espaciais da GPPmodis variando à medida que outros fatores mudam, isto mostra que o algoritmo do produto MOD17A2H consegue distinguir bem as condições climáticas favoráveis para alta produtividade.

5.2 Variabilidade interanual dos fatores bioclimáticos e uso e mudança da cobertura do solo e suas relações

A Figura 14 exibe a série anual da área ocupada pela vegetação nativa para cada bioma e a área total utilizada para agropecuária (MAPBIOMAS, 2019), e a série anual das variáveis Pr, EVI09, FPAR e GPPmodis de 2012 a 2018. A GPPmodis e os índices de vegetação na Amazônia nordestina (Figura 14 A) foram maiores em 2014, com 1554,5 gC m⁻² para a GPPmodis, 0,39 para EVI09 e 0,47 para FPAR com chuvas moderadas totalizando 1376,9 mm. Neste ano houve ligeira redução da vegetação florestal e um ganho da agropecuária. As características da superfície, associadas a um ano com chuvas na média forneceram boas condições para atingir altas GPP (FLACH *et al.*, 2020). Já o ano de menor GPPmodis foi em 2018, com total de 923,8 gC m⁻², e um dos menores EVI09 e FPAR, sendo de 0,37 e 0,42, respectivamente. Notavelmente, o ano de 2018 foi o mais chuvoso dentro do período estudado, e isto não refletiu maiores GPP. De Santana *et al.* (2020) também encontraram GPP mais baixo em ano de forte La Niña em área de floresta na Mata Atlântica. Possivelmente este efeito negativo na GPPmodis pode ser em virtude da redução abrupta da vegetação nativa refletida nos índices de vegetação.

A Mata Atlântica apresentou em 2016 o menor GPPmodis (1428,6 gC m⁻²), com índices de vegetação de 0,28 e 0,46 para EVI e FPAR, respectivamente (Figura 14 B). O maior GPPmodis ocorreu em 2014 com 1770,3 gC m⁻², também observado em De Santana *et al.* (2020), e EVI09 de 0,29 e FPAR de 0,49. Em 2016 a Pr foi o segundo ano menos chuvoso, com total de 1007,5 mm e isto impactou o desempenho da floresta

atlântica na produção de biomassa. Enquanto o ano de 2014 choveu 133,1 mm acima da média do período, o que favoreceu a abertura dos estômatos melhorando os processos fotossintéticos. Além disso, o ano anterior também foi chuvoso potencializando a produtividade do ano seguinte com o aumento da disponibilidade de água (DELGADO *et al.*, 2018; SILVA JÚNIOR *et al.*, 2019; DE SANTANA *et al.*, 2020). Destaca-se que durante o período estudado, o bioma apresentou um claro crescimento da vegetação nativa e uma concomitante redução da área ocupada pela agropecuária em virtude do processo de reflorestamento (ROSA *et al.*, 2021).

Notadamente, o Cerrado teve uma redução considerável da área vegetal, ao mesmo tempo que a agropecuária se expandiu (Figura 14 C). A dinâmica dessas trocas são reflexos da nova fronteira agrícola conhecida como MATOPIBA (Maranhão, Tocantins, Piauí e Bahia) (TRIGUEIRO *et al.*, 2020). O maior GPPmodis ocorreu em 2014 (1278,2 gC m⁻²), no qual, foi registrado um dos anos mais chuvosos da série, com 823,6 mm. Já o menor foi em 2016 com 978,7 gC m⁻² que registrou uma queda na Pr de 132,3 mm, em relação à média do período, e o ano de 2015 também foi bastante seco, com 719,6 mm, em virtude do forte El Niño, contribuindo para a baixa atividade fotossintética. Martinez *et al.* (2020) analisando a GPP em outras regiões de savanas corroboram com os resultados observados aqui. Os índices EVI09 e FPAR em 2014 foram igualmente elevados, sendo 0,25 e 0,43, respectivamente. Enquanto, em 2016 os índices foram os mais baixos, com EVI09 = 0,24 e FPAR = 0,40. Outros trabalhos, como os de Souza *et al.* (2014) e Silva Júnior *et al.* (2019) reportaram, para o Cerrado, característica semelhantes dos fatores ambientais discutidos aqui. É interessante notar que, o MOD17A2H consegue acompanhar os padrões anuais da Pr, que é moldada pela TSM do Pacífico e do Atlântico (PEREIRA *et al.*, 2018; BARBOSA *et al.*, 2019). Curiosamente, as variáveis bioclimáticas não seguem diretamente as perdas ou ganhos de vegetação nativa.

A Caatinga, assim como o Cerrado, é o bioma que mais sofreu desflorestamento e apresentou as maiores expansões agrícolas (SOUZA JÚNIOR *et al.*, 2020) (Figura 14 D). De 2012 a 2016 a vegetação nativa reduziu em 0,47 Mha, em virtude da seca prolongada (BARBOSA *et al.*, 2019) e ao crescimento da agropecuária que, mesmo com a seca se expandiu, impulsionadas pelas queimadas e desmatamento (BEZERRA DA SILVA *et al.*, 2020). Nos anos seguintes houve um ganho de 0,61 Mha da vegetação que está relacionada ao aumento das chuvas devido ao fenômeno La Niña

que rapidamente recuperou a vegetação da região (DA SILVA *et al.*, 2020). O maior GPPmodis do período foi de 1125,1 gC m⁻² em 2018, no qual foi registrado o maior volume de chuva com 622,4 mm, e um dos maiores EVI09 e FPAR com 0,26 e 0,36 respectivamente. Já o menor GPPmodis foi de 894,3 gC m⁻² em 2015, coincidindo com o segundo ano mais seco (Pr = 462,3 mm). Assim como para outras regiões, o comportamento interanual da GPPmodis foi condicionado as variações interanuais da Pr (PEREIRA *et al.*, 2018; BARBOSA *et al.*, 2019). Os efeitos positivos da superfície com os ganhos de vegetação nativa só puderam ser observados a partir de 2015, quando a vegetação nativa aumentou sua área e a GPPmodis também seguiu este comportamento. Enquanto anos anteriores, interessantemente, a área de vegetação reduziu, mas os efeitos na GPPmodis foram positivos, observando um aumento da GPPmodis que pode ser associado ao volume de chuva de 2013 e as chuvas dentro da média do período em 2014.

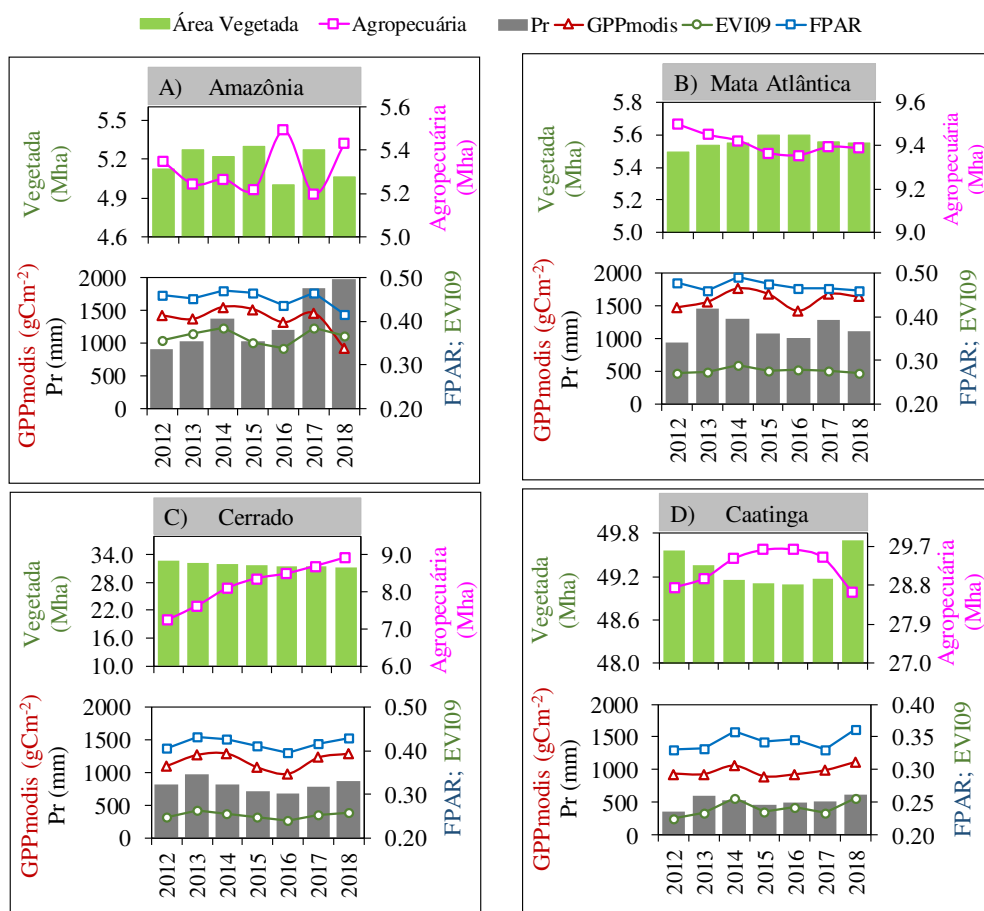


Figura 14 - Variabilidade anual da produtividade primária bruta do MOD17A2H – GPPmodis (gC m⁻²), precipitação – Pr (mm), fração da radiação fotossinteticamente ativa – FPAR, índice de vegetação melhorado – EVI09 e os totais das áreas ocupada pela vegetação nativa e agropecuária em Mha para o período de 2012 a 2018

No intuito de compreender melhor o comportamento da GPPmodis com as variáveis bioclimáticas e as mudanças no uso do solo, analisou-se a relação entre esses fatores em escala anual, por meio do coeficiente de determinação (R^2) apresentados na Tabela 5. Para o bioma Amazônico, todos apresentaram R^2 de fraco a moderado e apenas a FPAR foi significativo ($p \leq 0,01$). A ordem de contribuição foi: $FPAR > Rg > UR > Pr > Tar > EVI09$, notavelmente, a relação entre a variação em escala anual da GPPmodis com EVI09 não existiu. Avaliando as mudanças de cobertura do solo com a GPPmodis, verificou-se que, as duas categorias avaliadas tiveram uma certa contribuição para as variações de GPPmodis. Os fatores ambientais Pr, Tar e Rg têm uma relação de fraca a moderada devido a escala utilizada (anual), pois as contribuições destas variáveis para a promoção da produtividade são maiores em escalas diárias e mensais, reduzindo gradualmente nas escalas sazonais e anuais (HAN *et al.*, 2020).

A variância explicada (R^2) da variabilidade da GPPmodis para a Mata Atlântica teve maior proporção para Tar ($R^2 = 0,25$) e UR ($R^2 = 0,53$), e fraca ou nenhuma relação com as outras variáveis, sendo todas sem significância estatística. Paiva e Fernandes (2015) reportaram resultado semelhante, tendo a Tar e Pr como variáveis com baixo poder de explicação para a variabilidade da GPPmodis na Mata Atlântica. Os índices de vegetação quase não contribuíram para a variabilidade anual da GPPmodis, e isto não era esperado, dado que a GPPmodis tem a FPAR em seu algoritmo (RUNNING e ZHAO, 2015). A ordem de relação das variáveis foram: $UR > Tar = EVI09 > Pr > FPAR > Rg$.

Para o Cerrado nordestino, a GPPmodis anual teve contribuições de cinco fatores bioclimáticas que foram bastante significativos ($p \leq 0,05$), são eles, Pr, Tar, UR, FPAR e EVI09. Isto revela que a variabilidade anual neste bioma depende principalmente da interação desses cinco fatores. Do ponto de vista físico, estas variáveis possuem uma relação muito próximas, pois as chuvas, promovem aumento na umidade atmosférica e no conteúdo de água nas folhas, favorecendo o processo fotossintético, aumentando os índices de vegetação e captura do carbono da atmosfera (DONG *et al.*, 2015). Em contrapartida, não existiu relação da GPPmodis e mudança de cobertura solo. Resumidamente, as contribuições das variáveis foram: $FPAR > EVI09 > UR > Pr > Tar > Rg$.

Analisando os coeficientes para a Caatinga observou-se forte e significativa relação interanual da GPPmodis com o Tar ($R^2 = 0,82$, $p \leq 0,01$), e moderada com EVI09 ($R^2 = 0,66$, $p \leq 0,01$) e UR ($R^2 = 0,62$, $p \leq 0,05$). A Pr ($R^2 = 0,30$) mostrou relação fraca e não significativa, sendo controverso, pois a vegetação da Caatinga em especial, possui alta dependência das chuvas (FERREIRA *et al.*, 2020). Além disso, não houve relação entre GPPmodis e mudanças de cobertura do solo, também observado por Silva *et al.* (2017). As relações seguiram a seguinte sequência de importância: Tar > EVI09 > UR > FPAR > Rg > Pr (Tabela 5).

Tabela 5 - Coeficientes de determinação (R^2) em escala anual entre a produção primária bruta do MOD17A2H – GPPmodis (gC m^{-2}) e a precipitação – Pr (mm), radiação global – Rg (MJ m^{-2}), temperatura do ar – Tar ($^{\circ}\text{C}$), umidade relativa – UR (%), índice de vegetação melhorado – EVI09, fração da radiação fotossinteticamente ativa - FPAR e área total de cobertura vegetal e uso agropecuário em Mha para os biomas Amazônia, Mata Atlântica, Cerrado e Caatinga do Nordeste brasileiro no período de 2012 a 2018

Bioma	Vegetação	Agropecuária	Pr	Rg	Tar	UR	EVI09	FPAR
Amazônico	0,38	0,42	0,30	0,53	0,12	0,45	0,02	0,93**
M. Atlântica	0,01	0,03	0,24	0,06	0,25	0,53	0,25	0,20
Cerrado	0,00	0,00	0,62*	0,39	0,65*	0,82**	0,84**	0,88**
Caatinga	0,22	0,17	0,30	0,39	0,82**	0,62*	0,66**	0,54

** $p \leq 0,01$; * $p \leq 0,05$

Aparentemente, as variações interanuais de GPPmodis estão relacionadas com o volume das chuvas que influênciam no aumento da UR e diminuição da Tar resultando no aumento dos índices de vegetação. Mesmo havendo diminuição da Rg em períodos muito chuvosos, devido à alta nebulosidade, a fração da PAR incidente é maior (CUSTÓDIO *et al.*, 2021), e assim, a produtividade se beneficia. As mudanças de uso do solo, quando avaliadas em ganhos ou perdas de área não apresentaram influência na variação interanual da GPPmodis, conforme os baixos valores dos coeficientes. Esta relação é mais evidente no bioma Cerrado, em que, as variações de GPPmodis seguem o comportamento anual da Pr. Entretanto, é preciso investigar melhor, pois há evidências que a produtividade da vegetação à nível global reduza com a troca da vegetação nativa por agropecuária (MARTINEZ *et al.*, 2020; FLACH *et al.*, 2020).

5.3 Estimativas da GPP otimizado e sua relação com as variáveis de entrada

A produção de biomassa está relacionada a quantidade de PAR absorvida. Como a PAR é uma variável importante nos modelos de LUE, há necessidade de calibração local (WANG *et al.*, 2014; CUSTÓDIO *et al.*, 2021). Usualmente considera-se que a PAR é cerca de 50% da Rg. No MOD17A2H essa proporção é de 45% e não varia espacialmente. Portanto, é apresentado na Figura 15 a relação entre PAR e Rg para as localidades de São Luís – MA (Figura 15 A), Natal – RN (Figura 15 B), Palmas – TO (Figura 15 C) e Petrolina – PE (Figura 15 D), que representam os biomas Amazônico, Mata Atlântica, Cerrado e Caatinga, respectivamente. Os resultados mostraram que a razão PAR/Rg possuíram ótimos coeficientes ($R^2 > 0,97$), sendo todos significativos ($p \leq 0,0001$). Revelando que a Rg modela muito bem a PAR para essas localidades, sem necessidade de outra variável (AGUIAR *et al.*, 2012). As equações para estimar a PAR são: $PAR = 0,47Rg$ para a Amazônia, $PAR = 0,46Rg$ para a Mata Atlântica, $PAR = 0,50Rg$ para o Cerrado e $PAR = 0,54Rg$ para a Caatinga.




Figura 15 - Relação linear entre radiação fotossinteticamente ativa – PAR ($MJ m^{-2}$) diária e radiação global – Rg ($MJ m^{-2}$) diária para as cidades de São Luís (A), Natal (B), Palmas (C) e Petrolina (D)

A Figura 16 apresenta as estimativas da GPP mensais de 2012 a 2018 para os três métodos e as variáveis bioclimáticas para cada bioma. Analisando as curvas da GPP verificou-se que as estimativas seguiram uma dinâmica sazonal bem definida, sobretudo, para o bioma Cerrado. As maiores médias de GPP foram nos meses de maio a outubro, e de outubro a março, para a Amazônia e Mata Atlântica, respectivamente, enquanto para o Cerrado e Caatinga, os máximos se concentraram nos meses de janeiro a junho (EC). A GPPmodis foi predominantemente superior nos biomas Amazônico,

Mata Atlântica e Cerrado. Para a Caatinga, a GPPmet se apresentou maior. A GPPevi exibiu médias menores em todos os biomas, justificado pela menor magnitude do EVI09, enquanto que a GPPmodis e GPPmet possuem médias mais próximo por empregarem a FPAR na estimativa (RUNNING e ZHAO, 2015). O bioma Amazônico obteve a maior média diária com $3,05 \text{ gC m}^{-2} \text{ d}^{-1}$, $3,82 \text{ gC m}^{-2} \text{ d}^{-1}$ e $3,90 \text{ gC m}^{-2} \text{ d}^{-1}$ para GPPevi, GPPmet e GPPmodis, respectivamente. As menores produtividade foram observadas na Caatinga com $2,46 \text{ gC m}^{-2} \text{ d}^{-1}$ (GPPevi), $3,48 \text{ gC m}^{-2} \text{ d}^{-1}$ (GPPmet) e $2,72 \text{ gC m}^{-2} \text{ d}^{-1}$ (GPPmodis). Já a Mata Atlântica apresentou médias maiores que a Amazônia na GPPmet ($4,45 \text{ gC m}^{-2} \text{ d}^{-1}$) e GPPmodis ($4,49 \text{ gC m}^{-2} \text{ d}^{-1}$), e o Cerrado obteve o menor valor de produtividade com a GPPevi com a média de $1,89 \text{ gC m}^{-2} \text{ d}^{-1}$.

Na Amazônia e Mata Atlântica (Figura 16) a resposta da vegetação com o advento das chuvas só foi ocorrer na ES, concomitantemente com o aumento gradual da radiação PAR, e, EVI09 e FPAR, entretanto, não houve concordância sazonal entre as GPPs e os índices de vegetação para a Mata Atlântica. De acordo com Brando *et al.* (2010), Yang *et al.* (2018) e Vilanova *et al.* (2020), a atividade fotossintética tende a aumentar nas estações secas em florestas densas, dando indícios de que esta variável é mais relacionada a Rg e PAR, todavia, pode haver redução, caso a região passe por longo período de seca em virtude do decréscimo da umidade do solo. Chiwara *et al.* (2018) também verificaram altos valores de GPP em floresta tropicais na ES, e relacionaram este resultado à grande quantidade de luz disponível, em virtude da baixa nebulosidade, que consegue chegar nas camadas abaixo do dossel, aumentando a GPP total, o que não ocorre na EC, que em virtude do teor de clorofila e a baixa radiação decorrentes da frequência de nuvens, a radiação quase que completamente é interceptada pelo dossel, reduzindo a GPP total do ecossistema. Delgado *et al.* (2018) e De Santana *et al.* (2020) trabalhando com a floresta Atlântica também reportaram tendência de acréscimo da GPPmodis com a Rg. Por outro lado, Almeida *et al.* (2018) comparando estimativas de GPP para a Amazônia verificaram limitações da GPPmodis em capturar a sazonalidade, pois a GPP por fluxo de torre registrou maiores valores de GPP na EC, enquanto o MOD17A2H os maiores valores foram observados na ES.

Em relação ao Cerrado e a Caatinga, as GPPs estimadas pelos modelos capturaram bem a Pr, aumentando no início da EC e reduzindo no início da ES, acompanhando também os altos índices de vegetação. Assim como, reduz os valores da GPP no período de aumento do DPV, que restringe a condutância estomática e a

fotossíntese (FERREIRA *et al.*, 2020), e ao acréscimo da Rg que condiciona um aumento da Tar, contribuindo ainda mais para as baixas produtividades devido ao fechamento dos estômatos evitando perdas de água por transpiração. Estes resultados foram concernentes com os achados de Souza *et al.* (2014), no qual, a GPPmodis mostra valores mais altos na EC e mais baixos na ES, em reflexo das variações sazonais dos fatores meteorológicos e fenológicos. Corroborando com os resultados, Arantes *et al.* (2016) para Caatinga, encontraram os máximos de atividade da vegetação (EVI) no período de chuvas, indicando que nesse período a produtividade é maior. O mesmo foi observado em Alves *et al.* (2021), no qual, a GPP foi maior na EC do que na ES.




Figura 16 - Variabilidade mensal da produção primária bruta – GPP (gC m⁻² d⁻¹) para os três modelos de GPP otimizados (GPPmet e GPPevi), uso eficiente da luz – LUE (gC MJ⁻¹), radiação global – Rg (MJ m⁻²), radiação fotossinteticamente ativa – PAR (MJ m⁻²), índice de vegetação melhorado – EVI09, fração da radiação fotossinteticamente ativa – FPAR, umidade relativa – UR (%), déficit de pressão de vapor – DPV (kPa), precipitação – Pr (mm), temperatura do ar – Tar (°C) para os biomas Amazônia, Mata Atlântica, Cerrado e Caatinga para o período de 2012 a 2018

Os resultados comparativos entre GPP_{evi}, GPP_{met} com GPP_{modis} e as relações explicativas da sazonalidade com as variáveis ambientais foram analisados por meio do coeficiente de determinação (R^2) exposto na Figura 17. A GPP_{met} e GPP_{modis} possuíram forte relação, justificada com os altos R^2 superiores à 0,79 ($p \leq 0,01$) em todos os biomas. A forte relação entre essas variáveis pode ser dada a FPAR, que é comum nas duas estimativas. Entretanto, somente para o Cerrado e Caatinga, os coeficientes entre GPP_{modis} e o índice FPAR foram altos, sendo $R^2 = 0,82$ ($p \leq 0,01$), reportando, a Amazônia com coeficiente ligeiramente baixo ($R^2 = 0,54$, $p \leq 0,01$) e Mata Atlântica ($R^2 = 0,03$, $p > 0,05$) com nenhuma relação entre as variáveis. Mas deve ser destacado que estas relações podem ser influenciadas pelo tipo de cobertura vegetal que não é influenciado pela FPAR e demais variáveis. Notou-se também que, para estes dois últimos biomas (Amazônia e Mata Atlântica), as relações entre GPP_{modis} e os fatores ambientais (PAR, LUE e DPV) foram ainda mais baixas ou não existiram, porém, foram significativas ($p \leq 0,05$) revelando que os dados de reanálise não estão representando bem a sazonalidade e magnitude em regiões de alta produtividade.

Para os biomas Cerrado e Caatinga, as relações entre GPP_{modis} e as variáveis PAR, DPV e LUE, sobretudo o DPV, foram significativas e maiores do que para Amazônia e Mata Atlântica, mostrando que os dados de reanálise estão tendo moderada performance, sugerindo que as estimativas de GPP estariam mais próximos aos de fluxo de torre. A forte relação entre GPP_{modis} e DPV para biomas subúmidos e mais secos (semiáridos e savana) geralmente é alto, uma vez que, a Tar e PAR são constantemente altos, como discutido por Chiwara *et al.* (2018), por exemplo.

Devido a estes erros, Almeida *et al.* (2018) e Ferreira *et al.* (2020) confrontaram as variáveis meteorológicas medidas em torres micrometeorológicas e dados de reanálise, e observaram distintos erros. Os autores mostraram que, o DPV, e a PAR, na maioria dos sites apresentaram moderada correlação, mas erros na magnitude causando superestimação ou subestimação em algumas localidades. A Tar_{min} , embora tenha apresentada correlação baixa, não tem impacto na GPP estimada, uma vez que, a Tar_{min} não restringe o LUE em regiões tropicais. Assim, os autores concluem que, o DPV e PAR foram as variáveis que tiveram maior influência na estimativa da GPP.

Já para Wang *et al.* (2017b) a Tar, DPV teve alta correlação com dados de torre e pode ser usado para estimar a Tar, DPV de forma confiável para os biomas estudados

(florestas úmidas perenes, florestas mistas, florestas decíduas e pastagens) mas a PAR foi superestimada nos sítios. Entretanto, Biudes *et al.* (2021), estudando o Cerrado, as estimativas de GPP por sensoriamento e dados meteorológicos *in situ*, comparados as estimativas de torre, no geral, fornecem resultados semelhantes na média anual, observando dificuldades em modelar na ES do que na EC.

Relações não significativas entre GPPmodis e EVI09 foram observadas para Amazônia ($R^2 = 0,02$) e Mata Atlântica ($R^2 = 0,00$), e significativas para o Cerrado ($R^2 = 0,41$, $p \leq 0,01$) e Caatinga ($R^2 = 0,71$, $p \leq 0,01$). Isso ocorreu porque, no bioma Amazônia, as GPP estimadas aumentaram após as primeiras curvas crescentes do EVI09, entre a EC e ES, quando o solo apresentava bons níveis de umidade. Já para a Mata Atlântica não houve relação dada as curvas inversas entre as variáveis, pois os máximos de EVI09 aconteceram na EC enquanto a GPPmodis ocorreu na ES.

As boas relações entre essas variáveis (GPPmodis e EVI09) para Cerrado e Caatinga se justificam pela resposta mais rápida da vegetação as mudanças sazonais das variáveis ambientais (SOUZA *et al.*, 2014; MENDES *et al.*, 2020; ALVES *et al.*, 2021). Assim, houve reflexo na GPP_{evi}, que foi melhor relacionada com GPPmodis, no Cerrado ($R^2 = 0,54$, $p \leq 0,01$) e Caatinga ($R^2 = 0,50$, $p \leq 0,01$) do que na Amazônia ($R^2 = 0,43$, $p \leq 0,01$) e Mata Atlântica ($R^2 = 0,47$, $p \leq 0,01$). A Pr teve baixos coeficientes para todos os biomas, sendo não significativo para o Cerrado, retratando o fato de não haver concordância síncrona da dinâmica sazonal entre as GPPs e Pr.

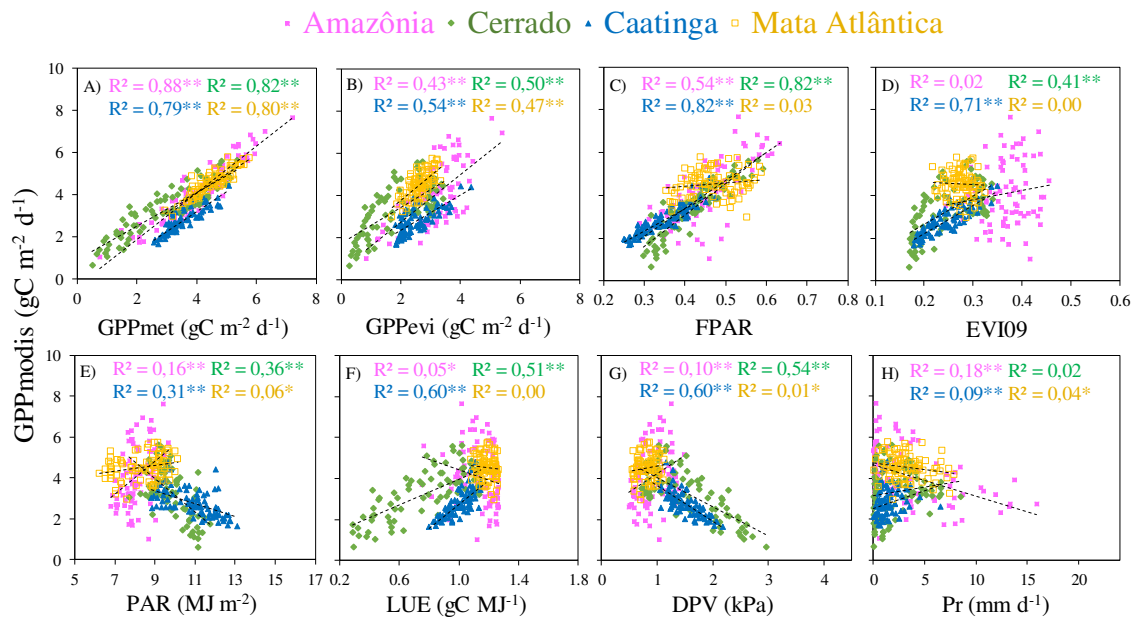


Figura 17 - Relação linear entre as médias diárias da produção primária bruta do MOD17A2H – GPPmodis ($\text{gC m}^{-2} \text{d}^{-1}$) com as duas GPPs otimizadas (GPPmet e GPPevi), além da relação com fração da radiação fotossinteticamente ativa – FPAR, índice de vegetação melhorado – EVI09, radiação fotossinteticamente ativa – PAR (MJ m^{-2}), uso eficiente da luz – LUE (gC MJ^{-1}), déficit de pressão de vapor – DPV (kPa), precipitação – Pr (mm) para os anos de 2012 a 2018 nos biomas Amazônia, Mata Atlântica, Cerrado e Caatinga

O mapa de calor baseado na matriz de correlação entre os fatores ambientais e GPP estimada para os biomas do NEB mostrou ótimas correlações para o Cerrado e Caatinga, mas fraca ou nenhuma correlação entre essas variáveis para Amazônia e Mata Atlântica (Figura 18). A FPAR, para o bioma Amazônia, foi positivamente correlacionada ($r > 0,69$, $p \leq 0,05$) com GPPmodis e GPPmet, tendo a GPPevi uma correlação menor ($r = 0,49$, $p \leq 0,05$), enquanto as outras variáveis não foram estatisticamente significativas no nível de 5% com as GPPs (Figura 18 A).

Para a Mata Atlântica, nenhuma variável ambiental apresentou correlações significativas com as GPPs, exceto GPPevi que foram correlações fracas (Figura 18 B). No Cerrado, as correlações entre as variáveis UR, LUE, e EVI09 e todas as GPPs estimadas foram positivas, e para DPV, Tar, FPAR, Rg, e PAR foram negativas, todas possuindo significância estatística ($p \leq 0,05$). Houve correlação positiva e significativa entre a UR, LUE, FPAR e EVI09 e as GPPs, e negativa para DPV na Caatinga.

Em outros modelos de estimativa de GPPs, Chiwara *et al.* (2018) verificaram que em ecossistemas subúmidos e semiáridos, as correlações negativas da Tar e PAR também foram observadas, pois caso estas variáveis ambientais sejam muito elevadas podem causar fotoinibição, principalmente, se houver baixa disponibilidade de água, dessa forma, a GPP reduzirá. A Pr foi significativamente correlacionada com a GPP_{evi} para a Mata Atlântica ($r = -0,20$), Cerrado ($r = 0,69$) e Caatinga ($r = 0,58$), e também com a GPP_{modis} com todos os biomas, exceto Mata Atlântica. Já com a GPP_{met}, a Pr foi significativa somente para Cerrado ($r = 0,42$) e Caatinga ($r = -0,30$).

No Cerrado e na Caatinga, a GPP é fortemente influenciada pelas condições atmosféricas (FERREIRA *et al.*, 2020; BIUDES *et al.*, 2021), notório tanto nos coeficientes de correlação, como nos coeficientes de determinação. As correlações negativas da radiação PAR e global e as variáveis DPV e Tar, indicam que a atividade fotossintética reduz em condições mais secas. Isto já era esperado, uma vez que, a GPP é restrita a disponibilidade de água em muitos biomas (ANAV *et al.*, 2015). A resposta negativa da PAR para a GPP é explicada pela fisiologia das plantas de regiões mais secas, que não é linear entre as variáveis (HESONG *et al.*, 2020).

Hesong *et al.* (2020) reporta que as folhas são propensas a saturação de luz direta causando redução ou até inversão da capacidade fotossintética. Em relação a Amazônia e Mata Atlântica, os resultados não significativos dos baixos valores dos coeficientes para todas as variáveis ambientais, exceto FPAR para a Amazônia, sugerem que as relações possuem um tempo de resposta mais longo. Como, os dois biomas são mais supridos de umidade no solo, a resposta da vegetação fica mais restrita a quantidade de PAR incidente (BRANDO *et al.*, 2010; YANG *et al.*, 2018; VILANOVA *et al.*, 2020). Han *et al.* (2020) mencionam que em florestas subtropicais a eficiência fotossintética é maior em condições de maior radiação difusa, e, portanto, geralmente a R_g é o fator mais forte que impulsiona a fotossíntese.

altas produtividade da vegetação. Os padrões espaciais da GPPmodis, GPPmet e GPPevi foram semelhantes, uma vez que os padrões sazonais das estimativas foram similares, divergindo apenas na magnitude. Analisando as figuras de espaço climático foi observado que a distribuição das GPPs em relação as variáveis ambientais foram mais concentradas, observando poucos valores atípicos. Um padrão de altos e baixos valores GPPs ligados a um determinado limiar de Tar, Pr e Rg não foram observados com clareza para Amazônia e Mata Atlântica. Por outro lado, os biomas Cerrado e Caatinga mostram uma relação mais bem definida entre as variáveis, com pontos de GPPs maiores e menores concentrados em determinados quadros do espaço.

As maiores GPPs para Amazônia e Mata Atlântica foram encontrados entre os limiares de Tar acima de 24,5 °C e abaixo de 27,5 °C, totais médios de Pr entre 50 mm a 100 mm, e Rg variando entre 16 MJ m⁻² a 20 MJ m⁻² para Amazônia e 18 MJ m⁻² a 22 MJ m⁻² para Mata Atlântica. Para os biomas mais secos, Cerrado e Caatinga, os maiores GPPmodis foram claramente identificados, sendo um intervalo maior de Tar e Rg para a Caatinga, e intervalo semelhante de Pr para ambos biomas. Condições ótimas de Tar foram entre 26 °C a 28 °C, e 24,5 °C a 27,5 °C para Cerrado e Caatinga respectivamente, e Rg entre 16 MJ m⁻² a 20 MJ m⁻² (Cerrado), e 17 MJ m⁻² a 21 MJ m⁻² (Caatinga), enquanto a Pr os pontos ficaram concentrados em 50 mm, com alguns pontos até 100 mm.

Estes resultados indicam a Pr de 50 mm mensais, já são suficientes para promover produtividade mais elevadas em todos os biomas (GPPmodis > 150 gC m⁻² mês⁻¹ para Amazônia e Mata Atlântica, e GPPmodis > 100 gC m⁻² mês⁻¹ para Cerrado e Caatinga, por exemplo). Enquanto valores de Tar e Rg mais baixos ou mais elevados podem limitar a eficiência da fotossíntese. Anav *et al.* (2015), discutindo esses limiares, identificaram que as altas produtividades são encontradas em regiões de alta Pr, com Tar entre 20 e 30, e moderada radiação.

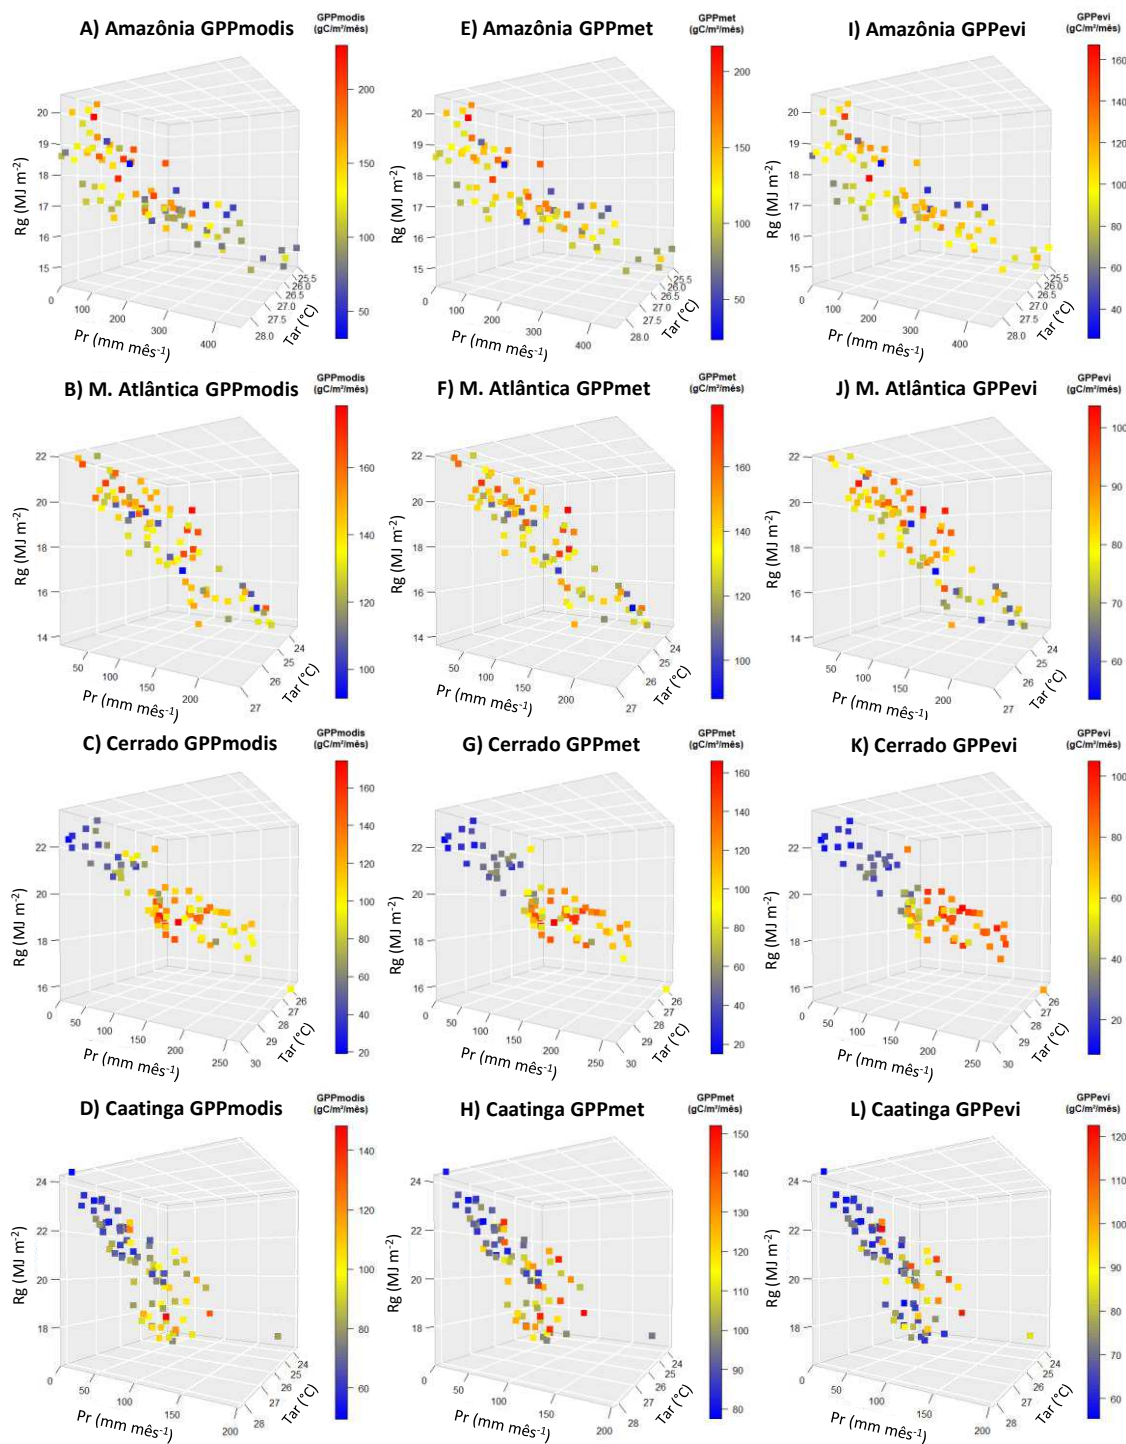


Figura 19 - Total médio mensal da produção primária bruta – GPP ($\text{gC m}^{-2} \text{mês}^{-1}$) para os três modelos de estimativa da GPP (GPPmodis, GPPmet e GPPevi) em espaço climático relacionados com temperatura do ar – Tar ($^{\circ}\text{C}$), precipitação – Pr (mm mês^{-1}), e radiação solar – Rg (MJ m^{-2}) para os anos de 2012 a 2018 nos biomas Amazônia, Mata Atlântica, Cerrado e Caatinga

5.4 Validação das estimativas das GPPs

A análise da acurácia das estimativas da GPPmodis, e as estimativas da GPP recalculadas com dados meteorológicos *in situ* foram avaliadas comparando-as com as estimativas de GPP via CVT (GPPtorre) para a localidade de Serra Talhada no estado de Pernambuco, inserido no bioma Caatinga. A Tabela 6 mostra os totais da produtividade da vegetação estimados pelos métodos para todo o período de estudo e também os totais para EC e ES, e entre os períodos de junho de 2014 a dezembro de 2014, e janeiro de 2015 a julho de 2015.

Os resultados mostram que os totais de GPP estimados para todo o período (jun/2014 a jul/2015) não ultrapassam 1466,5 gC m⁻² (GPPmet), apresentando o menor valor na ES de 403,1 gC m⁻² (GPPEvi) e o maior valor na EC de 942,7 gC m⁻² (GPPtorre). No geral, a GPPEvi e GPPmodis subestimam a GPPtorre tanto na EC e ES quanto em todo período. A GPPmet exibiu totais mais próximos da GPPtorre, apresentando em média uma diferença de 60,9 gC m⁻², sendo maior na ES (91,6 gC m⁻²) e menor período entre jun/2014 a dez/2014 (32,5 gC m⁻²). Entretanto, a menor e a maior diferença da GPPtorre, com outras estimativas, foi observada para a GPPmodis na ES com 3,4 gC m⁻², e para GPPEvi na EC com 383,1 gC m⁻², respectivamente. Enquanto, no total do período a menor diferença foi encontrada na GPPmet (40,1 gC m⁻²), e a maior na GPPEvi (472,0 gC m⁻²), seguida por GPPmodis (370,9 gC m⁻²).

Tabela 6 - Total das estimativas de produção primária bruta – GPP para os três modelos (GPPmodis, GPPmet e GPPEvi) e GPP via CVT (GPPtorre) todos em gC m⁻² por período para a localidade de Serra Talhada – PB no bioma Caatinga para o período de junho de 2014 a julho de 2015

Período	GPPtorre	GPPmet	GPPEvi	GPPmodis
	gC m ⁻²	gC m ⁻²	gC m ⁻²	gC m ⁻²
Jun-2014 a jul-2015	1426,4	1466,5	954,4	1055,5
Jun-2014 a dez-2014	631,7	599,2	389,7	426,6
Jan-2015 a jul-2015	794,8	867,3	564,7	629,0
Chuvoso	942,7	874,8	559,6	560,2
Seco	498,7	590,3	403,1	495,3

Avaliando os padrões sazonais das estimativas de GPP, a Figura 20, são apresentadas a variação sazonal acumulado de 8 dias da GPPtorre, GPPmodis, GPPEvi,

GPP_{met} e Pr, e os fatores ambientais em médias de 8 dias. A variação sazonal das estimativas de GPPs são bastante semelhantes, com a produtividade da vegetação medida por meio do fluxo de torre, apresentando – se maior na EC e menor na ES, sendo fortemente influenciada pelas chuvas, respeitando um tempo de resposta. Estes resultados são concernentes com achados de Ferreira *et al.* (2020) e Mendes *et al.* (2020) que encontraram padrão sazonal similar para este bioma. De acordo com estes autores, a dinâmica da fenologia da vegetação da Caatinga responde muito rápido, em relação a outros tipos de vegetação, a disponibilidade de umidade, e esta seria o fator preponderante na dinâmica da GPP.

Corroborando com estes resultados, foi observado também que os índices de vegetação, EVI09 e FPAR, cresceram consideravelmente na EC, em reflexo ao acréscimo da Pr, beneficiando o crescimento da área foliar, aumentando a absorção da luz e captação de carbono, e, portanto, favorecendo a produtividade primária (FERREIRA *et al.*, 2020; BIUDES *et al.*, 2021). Além disso, o DPV, Tar e radiação PAR e global reduziram ligeiramente durante esta estação, sendo similar aos resultados de Silva *et al.* (2017).

Como observado na Tabela 6, a Figura 20 A, revela diferenças na magnitude dos acumulados entre as estimativas de GPPs e GPP_{torre}. Estas diferenças são significativas para a GPP_{evi} e GPP_{modis} com GPP_{torre} no nível de significância de 1%, e são esteticamente ($p \leq 0,01$) iguais para a GPP_{met} com GPP_{torre}. As curvas de GPPs, mostraram claramente que a GPP_{met} apresentou estimativas mais próximos a GPP_{torre}, devido aos dados de entrada que foram diretamente medidos na torre, e ao uso da PAR modelada, que para este bioma, foi de 54% (Figura 15), em vez dos 45% do produto MOD17A2H. Com isso, os valores do GPP_{met} se elevam em relação as outras estimativas (GPP_{modis} e GPP_{evi}) por dispor de uma fração maior da PAR calculada no algoritmo.

Para as outras estimativas, a GPP_{evi} e GPP_{modis} subestimam a GPP_{torre}, sobretudo na EC. É interessante notar que, a GPP_{evi}, embora calculada com dados da torre e PAR modelado, se aproximou mais das estimativas da GPP_{modis} do que com GPP_{met}. Provavelmente, isso seja reflexo dos baixos valores do EVI09 em relação a FPAR, que influenciou diretamente o montante de PAR absorvida, reduzindo as estimativas (SOUZA *et al.*, 2014).

A GPPmodis, para o período de junho de 2014 a julho de 2015, apresentou, no geral, subestimativas, em relação a GPPtorre. Durante este período foi exibido superestimativas somente em um curtíssimo período da ES, enquanto em toda a EC e em uma pequena parte da ES os valores foram subestimados. Estes resultados diferem em parte com a literatura, que no geral, apontam a GPPmodis na Caatinga, predominantemente superestimada em praticamente todo o ano (MORAIS, 2019; FERREIRA *et al.*, 2020). Morais (2019) comparando as estimativas de GPPmodis com aqueles por CVT, verificou que a GPPmodis subestima os valores de GPPtorre em parte da EC e superestima na ES.

Entretanto, vale salientar que é reportado na literatura resultados bastante controversos da GPPmodis para biomas semelhantes, com estimativas superestimadas ou subestimadas, mostrando dificuldades da GPPmodis em capturar a magnitude da produtividade, mas de certa forma, a sazonalidade é bem modelada para a maioria dos ecossistemas (WANG *et al.*, 2017b; ALMEIDA *et al.*, 2018; CHIWARA *et al.*, 2018).

Para Sjöström *et al.* (2013), as subestimativas em regiões mais secas podem ocorrer devido as incertezas dos dados de entrada do algoritmo MOD17A2H, principalmente, na subestimação do LUE máximo. Wang *et al.* (2017b) recalculando o LUE máximo, observaram valores mais elevados do que aqueles usados no algoritmo do MOD17A2H para floresta densas e mistas. Em Almeida *et al.* (2018), LUE máximo também foi maior que os valores da BPLUT para a floresta densas, como a Amazônia, enquanto para savanas, como Cerrado, os valores foram menores, subestimando a GPPmodis em relação a GPP para este último bioma.

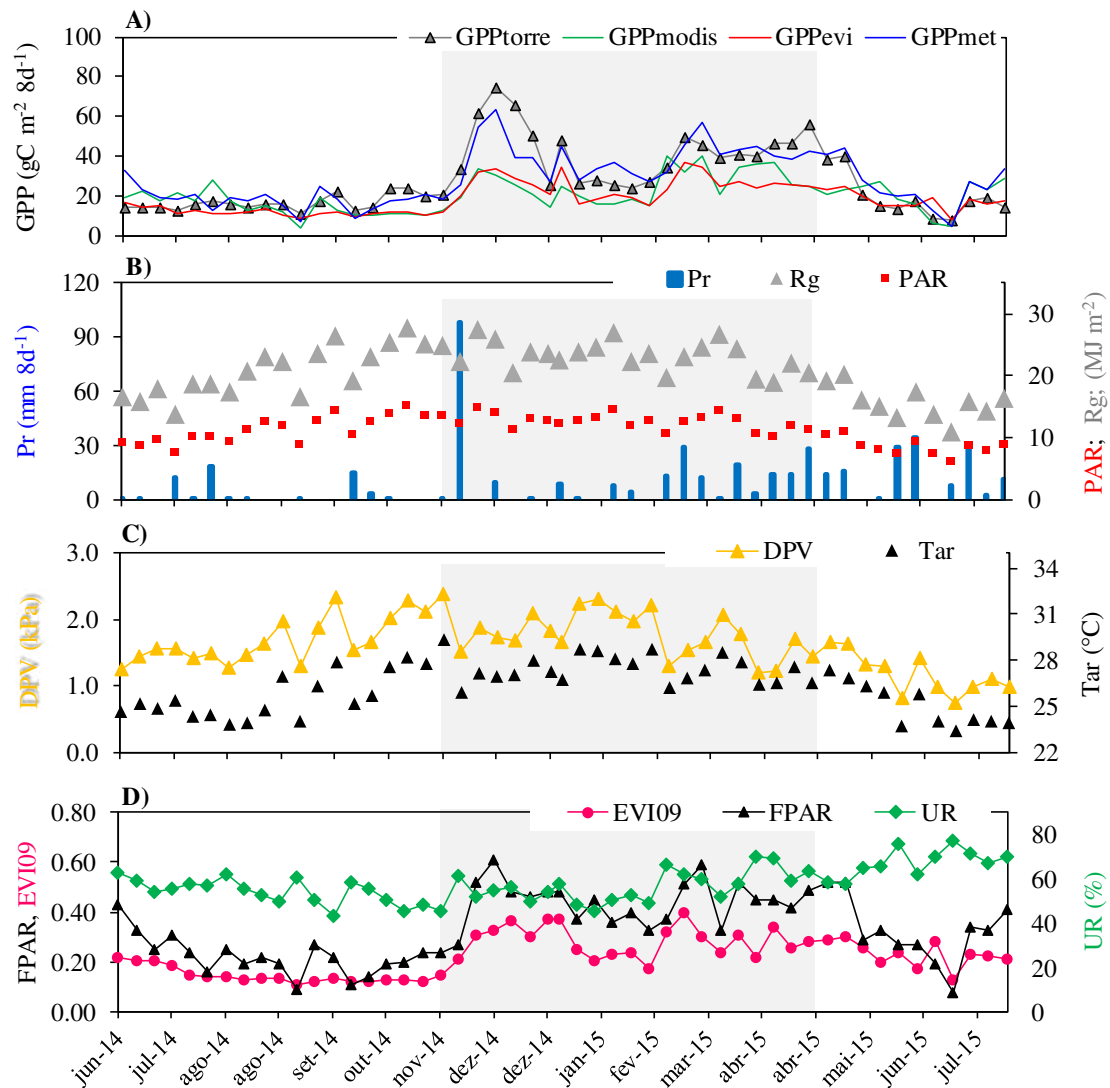


Figura 20 - Variabilidade dos dados micrometeorológicos do sítio de Serra Talhada na Caatinga, em acumulado de 8 dias para a produção primária bruta – GPP (A) por CVT – GPPtorre e os modelos de estimativa de GPP (GPPmodis, GPPmet e GPPpevi) todos em $\text{gC m}^{-2} \text{8d}^{-1}$, precipitação – Pr (mm 8d^{-1}) (B), médias de 8 dias da radiação global – Rg (MJ m^{-2}) (B), radiação fotossinteticamente ativa – PAR (MJ m^{-2}) (B), déficit de pressão de vapor – DPV (kPa), temperatura do ar – Tar ($^{\circ}\text{C}$), fração da PAR – FPAR (D), índice de vegetação melhorado – EVI09 (D) e umidade relativa – UR (%) de junho de 2014 a julho de 2015. Sombra em cinza é referente a estação chuvosa

Baseado no coeficiente de determinação (R^2), as GPP otimizadas para a localidade de Serra Talhada na Caatinga mostraram que as mesmas possuem boa concordância com a GPPtorre (Figura 21). Entretanto, a performance das GPPs foi melhor para a GPPmet em escala diária e acumulado de 8 dias, seguida por GPPpevi. As

relações foram todas significativas ($p \leq 0,05$) tanto para todo período de estudo, quanto para a EC e ES. Os coeficientes para GPP_{evi} e GPP_{met} foram iguais a 0,75, e de 0,40 para GPP_{modis} em escala de 8 dias, e $R^2 = 0,64$ e $0,66$ para GPP_{evi} e GPP_{met}, respectivamente, e para o GPP_{modis} o coeficiente foi de 0,30 para dados diários. No geral, as correlações são maiores na escala de 8 dias do que em escala diária, que pode ser resultado de compensação entre valores diários mais altos e mais baixos, como uma espécie de suavização (MORAIS, 2019). Os resultados dos coeficientes para GPP_{modis} foram semelhantes aos de Ferreira *et al.* (2020) que observaram $R^2 = 0,43$ na Caatinga.

Os coeficientes entre GPP_{modis} e GPP_{torre} separadas por período seco e chuvoso, foram maiores na EC ($R^2 = 0,27$, diário, e $R^2 = 0,43$, para 8 dias) do que na ES que praticamente não existiu ($R^2 = 0,05$, diário, e $R^2 = 0,07$, para 8 dias). Para as outras estimativas (GPP_{evi} e GPP_{met}) (Figura 21), os coeficientes também foram maiores na EC do que na ES para ambas escalas. Isto indica que todos os modelos seguiram bem as variações sazonais de Pr e atividades fotossintéticas da Caatinga. Em relação ao gráfico de regressão linear simples observou-se que a maioria dos dados se encontraram acima da linha 1:1 para GPP_{modis} e GPP_{evi} demonstrando subestimativa desses modelos, tendo uma contribuição maior da EC, que apresenta maior quantidade de pontos distantes da linha 1:1, enquanto na ES os pontos foram predominantemente mais próximos a linha principal (linha de 1:1). Por outro lado, a GPP_{met} obteve melhores resultados, subestimando ligeiramente a GPP_{torre} na EC e superestimando na ES, com alta correlação entre as duas medidas (Figura 21 E e F).

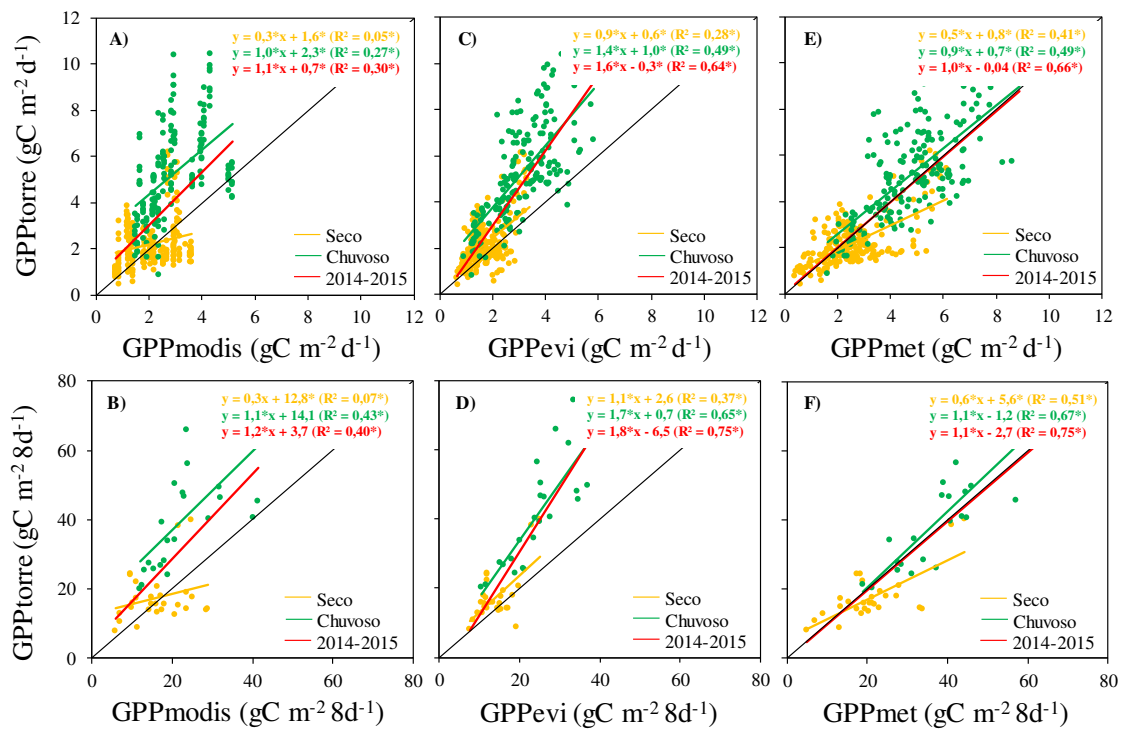


Figura 21 – Relação entre produção primária bruta – GPP por CVT – GPPtorre diário, em gC m⁻² d⁻¹ e acumulado de 8 dias, em gC m⁻² 8d⁻¹, com GPP do produto MOD17A2H – GPPmodis (A, B), GPP com dados meteorológicos combinado a fração da radiação fotossinteticamente ativa – GPPmet (C, D) e GPP combinado ao índice de vegetação melhorado – GPPevi (E, F) para o sítio de Serra Talhada na Caatinga no período de junho de 2014 a julho de 2015, e para estação seca e chuvosa. * p ≤ 0,05

A GPPtorre apresentou moderadas a fracas correlações positivas com DPV, PAR, Tar, e Pr, e negativas com UR (Tabela 7), nenhuma das correlações foram significativas ($p > 0,05$). Os índices de vegetação, FPAR e EVI apresentaram correlações positivas e significativas com a GPPtorre, sendo $r = 0,68$ ($p \leq 0,01$) e $r = 0,74$ ($p \leq 0,01$), respectivamente. Nos estudos de Biudes *et al.* (2021), foram encontradas correlações muito similares ao expostos aqui, relatando não ser uma surpresa encontrar similaridades dado ao fato da produtividade da vegetação ser muito dependente das condições dos fatores ambientais. Como foi observado na Figura 20, as variáveis bioclimáticas possuem uma variabilidade sazonal bem marcante, e as GPPs estimadas e por fluxo de torre, seguem um padrão semelhante, o que causou correlações entre elas. Por sua vez, também não foi observada correlação significativa entre a GPPmodis, GPPevi, e GPPmet com as variáveis ambientais registrado na torre.

Tabela 7 - Matriz de correlação de Pearson entre a produção primária bruta - GPP para os modelos: GPPmodis, GPPmet e GPPevi, e GPPtorre todos em gC m^{-2} , radiação fotossinteticamente ativa – PAR (MJ m^{-2}), fração da PAR – FPAR, índice de vegetação melhorado pelo MOD09 – EVI09, déficit de pressão de vapor – DPV (kPa), temperatura do ar – Tar ($^{\circ}\text{C}$), umidade relativa – UR (%), precipitação – Pr (mm)

	GPPtorre	GPPmodis	GPPevi	GPPmet	EVI09	FPAR	DPV	PAR	Tar	UR
GPPmodis	0.55**									
GPPevi	0.81**	0.63**								
GPPmet	0.81**	0.69**	0.90**							
EVI09	0.68**	0.56**	0.86**	0.73**						
FPAR	0.74**	0.73**	0.81**	0.91**	0.79**					
DPV	0.27	-0.12	0.07	0.15	-0.02	0.09				
PAR	0.48	0.05	0.39	0.45	0.07	0.22	0.80**			
Tar	0.50	0.13	0.32	0.39	0.27	0.36	0.86**	0.73**		
UR	-0.16	0.21	0.04	-0.04	0.13	0.01	-0.96**	-0.74**	-0.71**	
Pr	0.11	0.09	0.10	0.06	0.06	0.05	-0.06	0.02	-0.01	0.07

** $p \leq 0,01$

As métricas estatísticas foram utilizadas para contextualizar os resultados da validação entre a GPP dos modelos otimizados e a GPP de fluxo de torres (Figura 22). De acordo com os resultados a GPPmodis apresenta as piores métricas tanto para valores diários quanto para acumulados de 8 dias, entretanto os erros reduzem nessa última escala, certamente por ambas estarem na mesma escala. O ERM, REQM e EAM para dados diários foi em média 41,9%, 2,1 $\text{gC m}^{-2} \text{d}^{-1}$ e 1,55 $\text{gC m}^{-2} \text{d}^{-1}$, respectivamente (Figura 22 A). E para acumulados de 8 dias as médias foram de ERM = 38,8%, REQM = 15,2 $\text{gC m}^{-2} 8\text{d}^{-1}$ e EAM = 11,5 $\text{gC m}^{-2} 8\text{d}^{-1}$ (Figura 22 B), semelhante a reportados na literatura. Por outro lado, assim como já sugerido nos resultados anteriores, a GPPmet mostrou boas estatísticas de erros nas duas escalas, sendo ERM = 32,7%, REQM = 1,2 $\text{gC m}^{-2} \text{d}^{-1}$ e EAM = 0,70 $\text{gC m}^{-2} \text{d}^{-1}$ para médias diárias, e ERM = 27,9%, REQM = 7,9 $\text{gC m}^{-2} 8\text{d}^{-1}$ e EAM = 6,1 $\text{gC m}^{-2} 8\text{d}^{-1}$ para acumulados de 8 dias. Avaliando os erros estatísticos de cada estimativa separando os períodos sazonais apresentaram diferenças relativas para todos os modelos. Em médias diárias e totais de 8 dias, os períodos chuvosos, os erros foram maiores, enquanto na ES, os erros foram menores para as três estimativas. A exceção foi observada no ERM na ES para a GPPmet, que foi o único que se apresentou maior com 41,7% (diário) e 37,8% (8 dias).

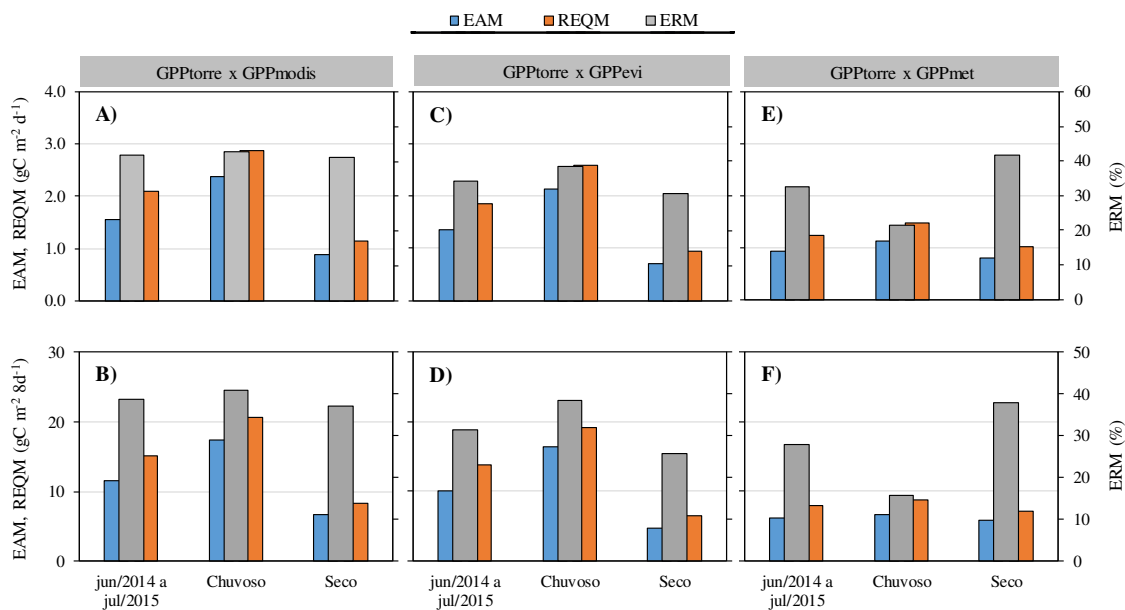


Figura 22 - Estatística comparativa entre produção primária bruta – GPP por CVT – GPPtorre, GPP pelo MOD17A2H – GPPmodis (A, B), GPP com dados meteorológicos combinado a fração da radiação fotossinteticamente ativa – GPPmet (C, D) e GPP combinado ao índice de vegetação melhorado – GPPevi (E, F) em escalas diárias em $\text{gC m}^{-2} \text{d}^{-1}$, e acumulados de 8 dias em $\text{gC m}^{-2} \text{8d}^{-1}$ para Serra Talhada – PB na Caatinga no período de junho/2014 a julho/2015, e para estação seca e chuvosa. EAM (erro relativo médio) e REQM (raiz do erro quadrático médio), na escala da variável, e ERM (erro relativo médio) em porcentagem do erro.

A interpretação destes resultados sugere que dados meteorológicos medidos *in situ* de fato melhoram a precisão das estimativas, como reportado em outras pesquisas (WANG *et al.*, 2017b; CHIWARA *et al.*, 2018; MORAIS, 2019). Mas a precisão aumenta ao modelar a PAR. Além disso, a FPAR parece representar melhor a fenologia da vegetação, tornando o modelo GPPmet potencialmente melhor para estimar a GPP na Caatinga. Já a GPPevi, embora tenha sido calculada com a mesma fonte de dados da GPPmet, pode-se atribuir os erros estatísticos ao EVI09 que teve menor magnitude, mesmo que esta tenha capturado bem a sazonalidade da vegetação, induzindo baixos valores de GPP que ficaram muito próximos aos da GPPmodis. Todos os modelos testados para o sítio de Serra Talhada, mostraram ERM semelhantes, pelo fato de todos partirem com dados de entrada semelhante, nomeadamente, LUE, UR, Tar, Rg e o EVI09 e a FPAR, que são bem correlacionados (BIUDES *et al.* 2021). Isto sugere que na ausência ou na dificuldade de algum dado, o produto MOD17A2H é uma alternativa razoável para estimar a GPP da região, principalmente na ES.

6 CONCLUSÕES

As variações da GPPmodis de 2012 a 2018, em geral, foram influenciadas pelas chuvas que amenizam as Tar e aumentam a disponibilidade de água no solo, indicando que o algoritmo do MOD17A2H consegue capturar razoavelmente bem as mudanças bioclimáticas da superfície. As mudanças de cobertura do solo, de um modo geral, não impactaram as variações anuais de GPPmodis. A GPPevi subestima a GPPmet e GPPmodis, na Amazônia, Mata Atlântica e Cerrado, e foi próxima a GPPmodis na Caatinga. As estimativas possuem dinâmicas sazonais bem definidas, principalmente, para o Cerrado. Nos biomas Amazônia e Mata Atlântica, as GPPs foram maiores na estação seca e no Cerrado e na Caatinga foram na estação chuvosa com maior influência das variáveis bioclimáticas nestes dois últimos biomas. As condições atmosféricas ideais para altas produtividades, estão dentro do intervalo de Tar entre 24 °C a 28 °C, Rg de 16 MJ m⁻² a 22 MJ m⁻² e Pr acima de 50 mm mensais em todos os biomas.

A GPPmodis e GPPevi confrontadas com a GPPtorre do sítio de Serra Talhada, na Caatinga, foram estatisticamente diferentes ($p \leq 0,01$) e as que apresentaram os maiores erros, enquanto que a GPPmet não registrou diferenças significativas ($p \leq 0,01$) e os erros foram menores, muito provavelmente aos dados de entrada, principalmente, a modelagem da PAR, que induziu a melhores estimativas. Entretanto devido os modelos capturarem bem a sazonalidade dessa região, as mesmas foram bem correlacionadas. Com isso, é possível deduzir que a GPPmet foi o melhor modelo para esta localidade. A GPPmodis para o NEB pode ser usada, mas com cautela, sobretudo, para Amazônia e Mata Atlântica que mostraram defasagem no ciclo sazonal da GPP em relação a Pr.

Os modelos otimizados, em geral, revelaram resultados satisfatórios para Serra Talhada em termos sazonais, sobretudo para a estação seca. Portanto, recalcular a GPP com dados meteorológicos, combinando a FPAR do MOD15A2H e ajustando a porcentagem da PAR para 54% da Rg, é recomendável para as áreas do bioma Caatinga, principalmente devido a disponibilidade desses dados nas EMAs e USGS sem custos financeiros adicionais, o que é uma grande vantagem. Com estes resultados, conclui-se que a principal melhoria sugerida para refinar o algoritmo MOD17A2H seja a inclusão na tabela BPLUT de um valor de porcentagem da PAR mais próximo da realidade para determinado bioma, com base em estudos que determinam esta variável pelo mundo, principalmente para os trópicos, onde são encontradas as maiores imprecisões.

7 REFERÊNCIAS BIBLIOGRÁFICAS

AGUIAR, L. J. G.; FISCHER, G. R.; LADLE, R. J.; MALHADO, A. C. M.; JUSTINO, F. B.; AGUIAR, R. G.; DA COSTA, J. M. N. Modeling the photosynthetically active radiation in south west Amazonia under all sky conditions. **Theoretical and Applied Climatology**, v.108, p.63-640, 2012.

AIRES, L. M. I. **Fluxo de CO₂, H₂O e energia numa pastagem mediterrânica C3/C4**. Universidade de Aveiro, Departamento de Ambiente e Ordenamento. Tese de Doutorado, Portugal. 2007.

ALMEIDA, C. T DE, DELGADO, R. C., GALVÃO, L. S., CRUZ, L. E. O, RAMOS, M. C. Improvements on the MODIS Gross Primary Productivity model based on a comprehensive uncertainty assessment over the Brazilian Amazonia. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 145, p. 268-283, 2018.

ALVARES, A. C., STAPE, J.L., SENTELHAS, P.C., MORAES, J.L. de, SPAROVEK, G. Köppen's climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22 (6), p. 711-728, 2013.

ALVES, J.D.N. **Partição do fluxo de CO₂ e eficiência do uso de água em pastagem natural**. Universidade Federal de Viçosa (UFV), Viçosa – Minas Gerais, Dissertação de Mestrado, p. 58, 2017.

ALVES, J. D. N., RIBEIRO, A., RODY, Y. P., LOOS, R. A., HALL, K., B. Carbon uptake and water vapor exchange in a pasture site in the Brazilian Cerrado. **Journal of Hydrology**, v. 594, 2021.

ANAV, A., FRIEDLINGSTEIN, P., BEER, C., CIAIS, P., HARPER, A., JONES, C., MURRAY-TORTAROLO, G., PAPALE, D., PARAZOO, N.C., PEYLIN, P., PIAO, S., SITCH, S., VIOVY, V., WILTSHIRE, A., ZHAO, M. Spatiotemporal patterns of terrestrial gross primary production: A review. **Reviews of Geophysics**, v. 53, p. 785-818, 2015.

ANDREOLI, R. V.; KAYANO, M. T. A importância relativa do Atlântico Tropical sul e Pacífico Leste na variabilidade de precipitação do Nordeste do Brasil. **Revista Brasileira de Meteorologia**, v. 22, n. 1, p. 63-74, 2007.

ANTONINO, A. **AmeriFlux BR-CST Caatinga Serra Talhada, Ver. 1-5, AmeriFlux AMP**, (Dataset). <https://doi.org/10.17190/AMF/1562386>, 2019.

ARANTES, A. E., FERREIRA, L. G., COE, M. T. The seasonal carbon and water balances of the Cerrado environment of Brazil: Past, present, and future influences of land cover and land use. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 117, p. 66–78, 2016.

ARAÚJO, A. L., SILVA, M. T., SILVA, B. B., SANTOS, C. A. C., AMORIM, M. R. B. Modelagem Simplificada para estimativa do balanço de energia à superfície em escala regional (R-SSEB). **Revista Brasileira de Meteorologia**, v. 32, p. 433-446. DOI: <http://dx.doi.org/10.1590/0102-77863230010>, 2017.

ARAÚJO, A. L.; SILVA, M. T.; SILVA, B.B.; SANTOS, C. A. C; DANTAS, M. P. Análise das mudanças de parâmetros biofísicos sobre o Nordeste Brasileiro de 2002 a 2011 com dados MODIS. **Revista Brasileira de Meteorologia**, v. 33, n. 4, p. 589-599. DOI: <http://dx.doi.org/10.1590/0102-7786334002>, 2018.

ARRUDA, V. L. S., PIONTEKOWSKI, V. J., LENCAR, A., PEREIRA, R. S., MATRICARDI, E. A. T. Na alternative approach for mapping burn scars using Landsat imagery, Google Earth Engine, and Deep Learning in the Brazilian Savanna. **Remote Sensing Applications: Society and Environment**, v. 22, pag. 100472. <https://doi.org/10.1016/j.rsase.2021.100472>, 2021.

AUBINET, M., GRELLE, A., IBROM, A., RANNIK, Ü., MONCRIEFF, J., FOKEN, T., KOWALSKI, A. S., MARTIN, P. H., BERBIGIER, P. BERNHOFER, Ch., CLEMENT, R., ELBERS, J., GRANIER, A., GRÜNWALD, T., MORGENSTERN, K., PILEGAARD, K., REBMANN, C., SNIJDERS, W., VALENTINI, R., VESALA, T. Estimates of the Annual Net Carbon and Water Exchange of Forests: The EUROFLUX Methodology. **Advances in Ecological Research**, v. 30, p. 113-175, 2000.

BALDOCCHI, D. D., Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: past, present and future. **Global Change Biology**, v. 9, p. 479-492, 2003.

BARBOSA, H. A., KUMAR, T. V. L. Influence of rainfall variability on the vegetation dynamics over Northeastern Brazil. **Journal of Arid Environments**, v. 124, p. 377-387. doi: <http://dx.doi.org/10.1016/j.jaridenv.2015.08.015>, 2016.

BARBOSA, H. A., KUMAR, L. T. V., PAREDES, F., ELLIOTT, S., AYUGA, J. G. Assessment of Caatinga response to drought using Meteosat-SEVIRI Normalized Difference Vegetation Index (2008–2016). **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 148, p. 235-252, 2019.

BASTIAANSEN, W. G. M.; ALI, S. A new crop yield forecasting model based on satellite measurements applied across the Indus Basin, Pakistan. **Agriculture, Ecosystems and Environment**, v. 94, p.321-340, 2003.

BEER, C., REICHSTEIN, M., TOMELLERI, E., VIAIS, P., JUNG, M., CARVALHAIS, N., RÖDENBECK, C., ARAIN, M. A., BALDOCCHI, D., BONAN, G. B., BONDEAU, A., CESCATTI, A., LASSLOP, G., LINDROTH, A., LOMAS, M., LUYSSAERT, S., MARGOLIS, H., OLESON, K. W., ROUPSARD, O., VEENENDAAL, S., VIOVY, N., WILLIAMS, C., WOODWARD, F. I., PAPALE, D. Terrestrial gross carbon dioxide Uptake: Global distribution and covariation with climate. **Science**, v. 329, p. 834-838, 2010.

BEZERRA DA SILVA, J. L., DE ALBUQUERQUE MOURA, G.B. DA SILVA, M. V., LOPES, M. O., GUEDES, R. V. DE S., FRANÇA E SILVA, E. F., ORTIZ, P. F. S., RODRIGUES, J. A. DE M. Changes in the water resources, soil use and spatial dynamics of Caatinga vegetation cover over semiarid region of the Brazilian Northeast. **Remote Sensing Applications: Society and Environment**, v. 20, 100372, p. 1-12. doi: <https://doi.org/10.1016/j.rsase.2020.100372>, 2020.

BIUDES, M. S., VOURLITIS, G. L., VELASQUE, M. C. S., MACHADO, N. G., DANELICHEN, V. H. DE M., PAVÃO, V. M., ARRUDA, P. H. Z., NOGUEIRA, J., DE S. Gross primary productivity of Brazilian Savanna (Cerrado) estimated by different remote sensing-based models. **Agricultural and Forest Meteorology**, v. 307, 2021.

BRANDO, P. M., GOETZ, S. J., BACCINI, A., NEPSTAD, D. C., BECK, P. S. A., CHRISTMAN, M. C., Seasonal and interannual variability of climate and vegetation indices across the Amazon. **PNAS**, v. 107, n. 33, p. 14685-14690. doi: www.pnas.org/cgi/doi/10.1073/pnas.0908741107, 2010.

BRONW, D. S., BRONW, J. C., BRONW, C. Land occupations and deforestation in the Brazilian Amazon. **Land Use Policy** 54, 331–338, 2016.

CAI, W., YUAN, W., LIANG, S., ZHANG, X., DONG, W., XIA, J., FU, Y., CHEN, Y., LIU, D., ZHANG, Q. improved estimations of gross primary production using satellite-derived photosynthetically active radiation. **Journal of Geophysical Research: Biogeosciences**, v. 119, p. 110-123, 2014.

CARRILLO-ROJAS, G., SILVA, B., ROLLENBECK, R., CÉLLERI, R., BENDIX, J. The breathing of the Andean highlands: Net ecosystem Exchange and evapotranspiration over the páramo of southern Ecuador. **Agricultural and Forest Meteorology**, v. 265, p. 30-78, 2019.

CHAGAS, M. C.; DELGADO, R. C; DE SOUZA, L. P.; DE CARVALHO, D. C.; PEREIRA, M. G.; TEODORO, P. E.; SILVA JUNIOR, C. A. Gross primary productivity in areas of different land cover in the western Brazilian Amazon. **Remote Sensing Applications: Society and Environment**, v. 16, 100259-100268, DOI: <https://doi.org/10.1016/j.rsase.2019.100259>, 2019.

CHAPIN, F. S., MATSON, P. A., MOONEY, H. A. **Principles of terrestrial ecosystem ecology**. 2ª Edição. Springer New York Dordrecht Heidelberg London, p. 546, 2011.

CHEN, Z., YOU, G., WANG, Q. Magnitude, pattern and controls of carbon flux and carbon use efficiency in China's typical forests. **Global and Planetary Change**, v. 172, p. 464-473, 2019.

CHIWARA, P., OGUTU, B. O., DASH, J., MILTON, E. J., ARDO, J., SAUNDERS, M., NICOLINI, G. Estimating terrestrial gross primary productivity in water limited ecosystems across Africa using the Southampton Carbon Flux (SCARF) model. **Science of the Total Environment**, v. 630, p. 1472-1483, 2018.

CPC/NOAA. **Monthly Atmospheric & Sea Surface Temperature Indices**. North Atlantic (5-20°North, 60-30°West), South Atlantic (0-20°South, 30°West-10°East), Global Tropics (10°South-10°North, 0-360). <https://www.cpc.ncep.noaa.gov/data/indices/sstoi.atl.indices>. Acesso em 19 de outubro de 2021.

CUNHA, A. P. M. A., ALVARÁ, R. C. S., KUBOTA, P., Y., VIEIRA, R. M. S. Impacts of land use and land cover changes on the climate over Northeast Brazil. **Atmospheric Science Letters**, v. 16, p. 219-227, 2015.

CURTIS, P. S., HANSON, P. J., BOLSTAD, P., BARFORD, C., RANDOLPH, J. C., SCHIMID, H. P. WILSON, K. B. Biometric and eddy-covariance based estimates of annual carbon storage in five eastern North American deciduous forests. **Agricultural and Forest Meteorology**, v. 113, p. 3-19, 2002.

CUSTÓDIO, L. L. M.; SILVA, B. B.; SANTOS, C. A. C. Relationship between photosynthetically active radiation and global radiation in Petrolina and Brasília, Brazil. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 25, n. 9, p. 612-619, 2021.

DA SILVA, M. V., PANDORFI, H., LOPES, P. M. O., DA SILVA, J. L. B., DE ALMEIDA, G. L. P., DE OLIVEIRA SILVA, D. A., SANTOS, A. DOS, RODRIGUES, J. A. DE M., BATISTA, P. H. D., DA ROSA FERRAZ JARDIM, A. M. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. **Remote Sensing Applications: Society and Environment**, V. 19, 100353, P. 1-9. doi:10.1016/j.rsase.2020.100353, 2020.

DE SANTANA, R; O.; DELGADO, R.C.; SCHIAVETTI, A. The past, present and future of vegetation in the Central Atlantic Forest Corridor, Brazil. **Remote Sensing Applications: Society and Environment**, v. 20, p. 100357-100371, 2020.

DELGADO, R. C., PEREIRA, M. G. TEODORO, P. E., DOS SANTOS, G. L., DE CARVALHO, D. C., MAGISTRALI, I. C., VILANOVA, R. S. **Seasonality of gross primary production in the Atlantic Forest of Brazil. Global Ecology and Conservation**, v. 14, e00392, p. 1-12. doi: <https://doi.org/10.1016/j.gecco.2018.e00392>, 2018.

DONG, J., XIAO, X., WAGLE, P., ZHANG, G., ZHOU, Y., JIN, C., TORN, M. S., MEYERS, T. P., SUYKER, A. E., WNAG, J., YAN, H. Comparison four EVI-based models for estimating gross primary production of maize and soybean croplands and tallgrass prairie under severe drought. **Remote Sensing of Environment**, v. 162, p. 154-168, 2015.

FERREIRA, R. R., MUTTI, P., MENDES, K. R., CAMPOS, S., MARQUES, T. V., OLIVEIRA, C. P., GONÇALVES, W., MOTA, J., DIFANTE, G., URBANO, S. A., FERNANDES, L., BEZERRA, B. G., E SILVA, C. M. S. An assessment of the MOD17A2 gross primary production product in the Caatinga biome, Brazil. **International Journal of Remote Sensing**. doi: <https://doi.org/10.1080/01431161.2020.1826063>, 2020.

FLACH, M., BRENNING, A., GANS, F., REICHSTEIN, M., SIPPEL, S., MAHECHA, M. D. Vegetation modulates the impact of climate extremes on gross primary production. **Biogeosciences**. doi: <https://doi.org/10.5194/bg-2020-80>, 2020.

FRIEDL, M. A., SULLA-MANASHE, D., TAN, B., SCHNEIDER, A., RAMANKUTTY, N., SIBLEY, A., HUANG, X. MODIS collection 5 global land cover: Algorithm refinements and characterization of new datasets. **Remote Sensing of Environment**, v. 114, p. 168-182, 2010.

FU, X., TANG, C., ZHANG, X., FU, J., JIANG, D. An improved indicator of simulated grassland production based on MODIS NDVI and GPP data: A case study in the Sichuan province, China. **Ecological Indicators**, v. 40, p. 102-108, 2014.

GALVANI, E. Avaliação da radiação solar fotossinteticamente ativa (PAR) em São Paulo, SP. **Espaço e Tempo, GEOUSP**, v. 25, p.155-164, 2009.

GILABERT, M. A., MORENO, A., MASELLI, F., MARTÍNEZ, B., CHIESI, M., SÁNCHEZ-RUIZ, S., GARCÍA-HARO, F. J., PÉREZ-HOYOS, A., CAMPOS-TABERNER, M., PÉREZ-PRIEGO, O., SERRANO-ORTIZ, P., CARRARA, A. Daily GPP estimates in Mediterranean ecosystems by combining remote sensing and meteorological data. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 102, p. 184-197, 2015.

GREEN, J. K., SENEVIRATNE, S. I., BERG, A. M., FINDELL, K. L., HAGEMANN, S., LAWRENCE, D., M., GENTINE, P. Large influence of soil moisture on long-term terrestrial carbon uptake. **Nature**, v. 565, p. 476-492, 2019.

GUIA DO USUÁRIO, MODIS collection 6 (C6) LAI/FPAR (MOD15A2H) product user's guide. **NASA Earth Observing System MODIS Land Algorithm**, p. 13, 2015.

HAN, J., GUO, C., YE, S., ZHANG, L., LI, S., WANG., YU, G. Effects of diffuse photosynthetically active radiation on gross primary productivity in a subtropical coniferous plantation vary in different timescales. **Ecological Indicator**, v. 115, 106403, p. 1-12. doi: <https://doi.org/10.1016/j.ecolind.2020.106403>, 2020.

HASHIMOTO, H., MELTON, F., ICHII, K., MILESI, C., WANG, W., NEMANI, R. R. Evaluating the impacts of climate and elevated carbon dioxide on tropical rainforests of the western Amazon basin using ecosystem models and satellite data. **Global Change Biology**, v. 16, p. 255-271, 2010.

HESONG, W., GENSUO, J., EPSTEIN, H. E., HUICHEN, Z., ANZHI, Z. Integrating a PhenoCam-derived vegetation index into a light use efficiency model to estimate daily gross primary production in a semi-arid grassland. **Agricultural and Forest Meteorology**, v. 288-289, p. 107983. <https://doi.org/10.1016/j.agrformet.2020.107983>, 2020.

IBGE/MMA, INSTITUTO BRASILEIRO DE GEOGRÁFIA E ESTATÍSTICA/MINISTÉRIO DO MEIO AMBIENTE. **Mapa de Biomas do Brasil - Primeira Aproximação.** Disponível em: <https://brasilemsintese.ibge.gov.br/territorio.html>, 2004

IBGE/MMA, INSTITUTO BRASILEIRO DE GEOGRÁFIA E ESTATÍSTICA/MINISTÉRIO DO MEIO AMBIENTE. **Geociências, biomas e download (Shapefile).** Disponível em: <https://brasilemsintese.ibge.gov.br/territorio.html>, 2004.

IBGE, INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Censo agropecuário - 2006: Brasil, Grandes Regiões e Unidades da Federação. Rio de Janeiro, 2006.** p. 775. Disponível em: <http://www.ibge.gov.br>.

IPCC, INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **An IPCC Special Report on Climate Change, Desertification, Land Degradation, Sustainable Land Management, Food Security, and Greenhouse Gas Fluxes in Terrestrial Ecosystems at Its 50th**. Geneva: Suíça, 2019.

IPCC, INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. **Summary for Policymakers. In: Climate Change 2021: The Physical Science Basis. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change.** In: https://www.ipcc.ch/report/ar6/wg1/downloads/report/IPCC_AR6_WGI_SPM_final.pdf, 2021.

INPE/CPTE, INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS/CENTRO DE PREVISÃO DE TEMPO E ESTUDOS CLIMÁTICOS. **Anos de El Niño e La Niña**. Disponível em: <http://enos.cptec.inpe.br/>. Acesso em: janeiro de 2020, 2020.

INMET, INSTITUTO NACIONAL DE METEOROLOGIA. **Dados históricos das estações meteorológicas automáticas**. Disponível em: <https://portal.inmet.gov.br/dadoshistoricos>. Acesso em: janeiro de 2019.

IQBAL, M. An introduction to solar radiation. **London, Academic Press**, p. 390, 1983.

JOINER, J., YOSHIDA, Y. Satellite-based reflectance capture large fraction of variability in global gross primary production (GPP) at weekly times scales. **Agricultural and Forest Meteorology**, v. 291, p. 108092. <https://doi.org/10.1016/j.agrformet.2020.108092>, 2020.

LEES, K. J., QUAIFFE, T., ARTS, R. R. R., KHOMIK, M., SOTTOCOMOLA, W., KIELY, G., HAMBLEY, G., HILL, T., SAUNDERS, M., COWIE, N. R., RITSON, J., CLARK, J. M. A model of gross primary productivity based on satellite data suggests formerly afforested peatlands undergoing restoration regain full photosynthesis capacity after five to ten years. **Journal of Environmental Management**, v. 246, p. 594-604, 2019.

LIU, H.Q., HUETE, A.R. A feedback based modification of the NDVI to minimize canopy background and atmospheric noise. **IEEE Transaction on Geoscience and Remote Sensing**, v. 33(2), p. 457-465, 1995.

LLOYD, J., TAYLOR, J. A. On the temperature dependence of soil respiration. **Functional Ecology**, v. 8, p. 315-323, 1994.

MA, X., HUETE, A., YU, Q., RESTREPO-COUBE, N., DAVIES, K., BROICH, M., RATANA, P., BERINGER, J., HUTLEY, L. B., CLEVERLY, J., BOULAIN, N., EAMUS, D. Spatial patterns and temporal dynamics in savana vegetation phenology across the North Australian Tropical Transect. **Remote Sensing of Environment**, v. 139, p. 97-115, 2013.

MA, X., HUETE, A., YU, Q., RETREPO-COUBE, N., BERINGER, J., HUTLEY, L. B., KANNIAH, K. D., CLEVERLY, J., EAMUS, D. Parameterization of na ecosystem light-use-efficiency model for predicting savana using MODIS EVI. **Remote Sensing of Environment**, v. 154, p. 253-271, 2014.

MAPBIOMAS, Coleção 5 da **Série Anual de Mapas de Cobertura e Uso de Solo do Brasil**. Acesso em fevereiro de 2019, 2019.

MARTINEZ, B., GILABERT, M. A., SANCHEZ-RUIZ, S., CAMPOS-TABERNER, M., GARCIA-HARO, F. J., BRUMMEN, C., CARRARA, A., FEIG, G., GRUWALD, T., MAMMARELLA, I., TAGESSON, T. Evaluation of the LSA-SAF gross primary production product derived from SEVIRI/MSG data (MGPP). **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 159, p. 220-238. doi: <https://doi.org/10.1016/j.isprsjprs.2019.11.010>, 2020.

MARENCO, R. A., ANTEZANA-VERA, S. A., GOUVÊA, P. R. dos S., CAMARGO, M. A. B., OLIVEIRA, M. F. DE, SANTOS, J. K. DA S. Fisiologia de espécies florestais da Amazônia, fotossíntese, respiração e relações hídricas. **Revista Ceres**, Suplemento, v. 61, p. 786-789, 2014.

MARENCO, J. A., TORRES, R. R., ALVES, L. M. Drought in Northeast Brazil – past, present, and future. **Theory Application Climatology**, v. 129, p. 1189-1200. doi:10.1007/s00704-016-1840-8, 2016.

MARQUES, T. V., MENDES, K., MUTTI, P., MEDEIROS, S., SILVA, L., PEREZ-MARIN, A. M., CAMPOS, S., LÚCIO, P. S., LIMA, K, DOS REIS, J., RAMOS, T. M., DA SILVA, D. F., OLIVEIRA, C. P., COSTA, G. B., ANTONINO, A. C. D., MENEZES, R. S. C., SANTOS E SILVA, C. M., BEZERRA, B. Environmental and biophysical controls of evapotranspiration from Seasonally Dry Tropical Forests (Caatinga) in the Brazilian Semiarid. **Agricultural and Forest Meteorology**, v 287, p. 107957, 2020.

MAVI, H. S., TUPPER, G. J. **Agrometeorology: Principles and applications of climate studies in agriculture**. Food Products Press, New York, 2004.

MEDEIROS, R.; YOUNG; C.E.F.; PAVESE, H. B., ARAÚJO, F. F. S. **Contribuição das unidades de conservação brasileiras para a economia nacional: Sumário Executivo**. Brasília: UNEP-WCMC, p. 44, 2011.

MENDES, K. R., S. CAMPOS, L. L. DA SILVA, P. R. MUTTI, R. R. FERREIRA, S. MEDEIROS, A. PEREZ-MARI, MARQUES, T. V., RAMOS, T. M., VIEIRA, M. M. DE L., OLIVEIRA, C. P., GONÇALVES, W. A., COSTA, G. B., ANTONINO, A. C. D., MENEZES, R. S. C., BEZERRA, B. G., SANTOS E SILVA, C. M. Seasonal Variation in Net Ecosystem CO₂ Exchange of a Brazilian Seasonally Dry Tropical Forest. **Scientific Reports** 10: 9454. doi:10.1038/s41598-020-66415-w, 2020.

MERCADO, L. M., BELLOUIN, N., SITCH, S., BOUCHER, O., HUNTINGFOR, C., WILD, M., COX, P. M. Impact of change in diffuse radiation on the global land carbon sink. **Nature**, v. 458, p. 1014-1018, 2009.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. **Journal Applied Ecology**, v. 19, p. 747-766, 1972.

MORAIS, Y. C. B., ARAÚJO, M. S. B., MOURA, M. S. B. DE, GALVÍNIO, J. D., MIRANDA, R. Q. Análise do sequestro de carbono em áreas de Caatinga do Semiárido Pernambucano. **Revista Brasileira de Meteorologia**, v. 32 (4), p. 585-599. DOI: <http://dx.doi.org/10.1590/0102-7786324007>, 2017.

MORAIS, Y. C. B. **Variação espacial e temporal do sequestro de carbono no Bioma Caatinga**. Tese de Doutorado, Universidade Federal de Pernambuco – UFPE, Recife-PE, p. 108, 2019.

NAKAI, E. S., **Quantificação da biomassa e estoque de carbono em diferentes coberturas vegetais por meio de sensoriamento remoto**. Universidade de São Paulo (USP), Escola Superior de Agricultura “Luiz de Queiroz”, Piracicaba – SP, Tese de Doutorado, 2016.

OGUTU, B., O., DASH, J. Na algorithm to derive the fraction of photosynthetically active radiation absorbed by photosynthetic elements of the canopy (FAPARps) from eddy covariance flux tower data. **New Phytologist**, v. 197, p. 511-523, 2013.

PAIVA, C. M., FERNANDES, F. R. Estudo da produtividade primária do bioma Mata Atlântica via sensoriamento remoto. **Anuário do Instituto de Geociências – UFRJ**, v. 38, n. 2, p. 05-14. doi: http://dx.doi.org/10.11137/2015_2_05_14, 2015.

PEREIRA, M. P. S.; MENDES, K. R.; JUSTINO, F.; COUTO, F.; DA SILVA, A. S.; DA SILVA, D. F.; MALHADO, A. C. M. The role of Pacific and Atlantic Ocean in multiple El Niño Southern Oscillation events impacting the Brazilian dry tropical forest (Caatinga). **Science of the Total Environment**, p.1-28. doi: <https://doi.org/10.1016/j.scitotenv.2019.135717>, 2018.

REICHSTEIN, M., FALGE, E., BALDOCCHIS, D., PAPALE, D., AUBINET, M., BERBIGIER, P., BERNHOFER, C., BUCHMANN, N., GILMANOV, T., GRNIER, A., GRUNWALD, T., HAVRÁNKOVÁ, K., ILVESNIEMI, H., JANOUS, D., KNOHL, A., LAURILA, T., LOHILA, A., LOUSTAU, D., MATTEUCCI, G., MEYERS, T., MIGLIETTA, F., OURCIVAL, J-M., PUMPANEN, J., RAMBAL, S., ROTENBERG, E., SANZ, M., TENHUNEN, J., SEUFERT, G., VACCARI, F., VESALA, T., YAKIR, D., VALENTINI, R. On the separation of net ecosystem Exchange into assimilation and ecosystem respiration: review and improved algorithm. **Global Change Biology**, v. 11, p. 1424-1439, 2005.

RODRIGUES, C. C. F. PATRIOTA, M. R. A.; SILVA, B. B.; OLIVEIRA, A. B. Influência entre relação de radiação fotossinteticamente ativa e radiação global na

produtividade primária bruta para Santa Rita do Passa Quatro – SP. **Revista Ciência e Natura**, v. 40, p. 52-56, edição especial, 2018.

ROSA, M. R., BRANCALION, P. H. S., CROUZEILLES, R., TAMBOSI, L. R., PIFFERS, R. P., LENTI, F. E. B., HIROTA, M., SANTIAMI, E., METZGER, J. P. Hidden destruction of older forests threatens Brazil's Atlantic Forest and challenges restoration programs. **Science Advances**, v. 7, p. 1-8. doi: 10.1126/sciadv.abc4547, 2021.

RUNNING, S. W., NEMANI, R. R., HEINSCH, F. A., ZHAO, M., REEVES, M. HASHIMOTO, H. A continuous satellite-derived measure of global terrestrial primary production. **Bioscience**, v. 54(6), p. 547-560, 2004.

RUNNING, S. W., ZHAO, M. User's Guide, Daily and annual NPP (MOD17A2/A3) products. **NASA Earth Observing System MODIS Land Algorithm**, versão 3, coleção 6, p. 28, 2015.

SANTOS, A. C. DOS, MARIANO, D. A., NASCIMENTO, F. DAS C. A. DO, DANTAS, F. R. DA C. D., OLIVEIRA, G. DE., SILVA, M. T., DA SILVA, L. L., SILVA, B. B. DA, BEZERRA, B. G., SAFA, B., MEDEIROS, S. DE S. NEALE, C. M. U. Spatio-temporal patterns of energy Exchange and evapotranspiration during na intense drought for drylands in Brazil. **Int. J. Appl. Earth Obs. Geoinformation**, v. 85, 101982. doi: <https://doi.org/10.1016/j.jag.2019.101982>, 2020.

SILVA, B. B. DA, GALVÍNCIO, J. D., MONTENEGRO, S. M. G. L., MACHADO, C. C. C., OLIVEIRA, L. M. M. de, MOURA, M. S. B. de. Determinação por sensoriamento remoto da produtividade primária bruta do perímetro irrigado São Gonçalo – PB. **Revista Brasileira de Meteorologia**, v. 28 (1), p. 57-64, 2013.

SILVA, P. F. DA., LIMA, J. R. DE S., ANTONINO, A. C. D., SOUZA, R., SOUZA, E. S. DE, SILVA, J. R. I., ALVES, E. M. Seasonal patterns of carbon dioxide, water and energy fluxes over the Caatinga and grassland in the semi-arid region of Brazil. **Journal of Arid Environments**, v. 147, p. 71-82. <http://dx.doi.org/10.1016/j.jaridenv.2017.09.003>, 2017.

SILVA JÚNIOR, C. A. DA., COSTA, G. DE M., ROSSI, F. S., VALE, J. C. E. DO., LIMA, R. B. DE., LIMA, M., OLIVEIRA-JÚNIOR, J. F. DE., TEODORO, P. E., SANTOS, R. C. Remote sensing for updating the boundaries between the Brazilian Cerrado-Amazonia biomes. **Environmental Science and Policy**, v. 101, p. 383-392. doi: <https://doi.org/10.1016/j.envsci.2019.04.006>, 2019.

SJÖSTRÖM, M., ZHAO, M., ARCHIBALD, S., ARNETH, A., CAPPELAERE, B., FALK, U., GRANDCOURT, A. DE, HANAN, N., KERGOAT, L., KUTSCH, W., MERBOLD, L., MOUGIN, E., NICKLESS, A., NOUVELLON, Y., SCHOLLES, R. J., VEENENDAAL, E. M., ARDÖ, J. Evaluation of MODIS gross primary productivity for Africa using eddy covariance data. **Remote Sensing of Environment**, 131, 275–286. doi:10.1016/j.rse.2012.12.023, 2013.

SONDA, SISTEMA DE ORGANIZAÇÃO DE DADOS AMBIENTAIS. **Rede de dados ambientais**. Disponível em: <http://sonda.ccst.inpe.br/infos/index.html>. Acesso em: 2018.

SOUZA, M. C., BIUDES, M. S., DANELICHEN, V. H. M., MUSIS, C. R. de VOURLITIS, G. L., NOGUEIRA, J. SOUZA. Estimation of gross primary production of the Amazon-Cerrado transitional forest by remote sensing techniques. **Revista Brasileira de Meteorologia**, v. 9(1), p. 1-12, 2014.

SOUZA, L. S. B. de, MOURA, M. B. DE, SEDIYAMA, G. C., SILVA, T. G. F. da. Balanço de energia e controle biofísico da evapotranspiração na Caatinga em condições de seca intensa. **Revista Pesquisa Agropecuária Brasileira**, v. 50 (8), p. 627-636, 2015.

SOUZA JÚNIOR, C. M.; SHIMBO, J. Z. ROSA, M. R.; PARENTE, L. L.; ALENCAR, A. A.; RUDOR, B. F.T.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L.G.; SOUZA-FILHO, P. W.M.; DE OLIVEIRA, S. W.; ROCHA, W. F.; FONSECA, A. V.; MARQUES, C. B.; DINIZ, C. G.; COSTA, D.; MONTEIRO, D.; ROSA, E. R.; VÉLEZ-MARTIN, E.; WEBER, L. J.; LENTI, F.E. B.; PATERNOST, F. F.; PAREYN, F. G.C.; SIQUEIRA, J. V. VIEIRA, J. L.; FERREIRA NETO, L. C.; SARAIVA, M. M.; SALES, M. H.; SALGADO, M.P.G.; VASCONCELOS, R.; GALANO, S.; MESQUITA, V. V.; AZEVEDO, T. Reconstruction three decades of land use and land

cover changes in Brazilian Biomes with Landsat archive and Earth Engine. **Remote Sensing**, v. 12, p. 2735 – 2762, 2020.

STULL, R. B. **An Introduction to Boundary Layer Meteorology**. Dordrecht, The Netherlands: Kluwer Academic Publishers, p. 666, 1988.

SWINBANK, W. C. The measurement of vertical transfer of heat and water vapor by eddies in the lower atmosphere. **Journal of the Atmospheric Sciences**, v.8, p. 135-145, 1951.

TRIGUEIRO, W. R., NABOUT, J. C., TESSAROLO, G. Uncovering the spatial variability of recent deforestation drives in the Brazilian Cerrado. **Journal of Environmental Management**, v. 275, p. 1-10. doi: <https://doi.org/10.1016/j.jenvman.2020.111243>, 2020.

TETENS, V. O. Uber einige meteorologische Begriffe. **Zeitschrift Geophysic**, v. 6, p.297-309, 1930.

USGS, U. S. GEOLOGICAL SURVEY. **Moderate Resolution Imaging Spectroradiometer (MODIS)**, version 6.0, 2018. https://lpdaac.usgs.gov/product_search. Acesso em: janeiro de 2020.

VILANOVA, R. S., DELGADO, R. C., DA SILVA ABEL, E. L., TEODORO, P. E., SILVA JUNIOR, C. A., WANDERLEY, H. S., CAPRISTO-SILVA, G. F., Past and future assessment of vegetation activity for the state of Amazonas-Brazil. **Remote Sensing Applications: Society and Environment**. doi: <https://doi.org/10.1016/j.rsase.2019.100278>, 2020.

XIAO, J., CHEVALLIER, F., GOMEZ, C., GUANTER, L., HICKE, J.A., HUETE, A.R., ICHII, K., NI, W., PANG, Y., RAHMAN, A.F., SUN, G., YUAN, W., ZHANG, L., ZHANG, X. Remote sensing of the terrestrial carbon cycle: A review of advances over 50 years. **Remote Sensing Environment**, v. 233, p. 1-37, 2019.

WAGLE, P., GOWDA, P. H. NORTHUP, B. K., Annual dynamics of carbon dioxide fluxes over a rainfed alfalfa field in the U.S. Southern Great Plains. **Agricultural and Forest Meteorology**, v. 265, p. 208-217, 2019.

WANG, L., GONG, W., MA, Y., HU, B., ZHANG, M. Photosynthetically active radiation and its relationship with global solar radiation in Central China. **International Journal Biometeorology**, v. 58, p. 1265-1277, 2014

WANG, J., DONG, J., YI, Y., LU, G., OYLER, J., SMITH, W. K., ZHAO, W., LIU, J., RUNNING, S. Decreasing net primary production due to drought and slight decreases in solar radiation in China from 2000 to 2012. **Journal of Geophysical Research: Biogeosciences**, v. 122, p. 261-278, 2017a.

WANG, L. ZHU, H., LIN, A., ZOU, L. QIN, W., DU, Q. Evaluation of the Latest MODIS GPP products across multiple biomes using global eddy covariance flux data. **Remote Sensing**, v. 9 n. 418, p. 1-20, 2017b.

WUTZLER, T., LUCAS-MOFFAT, A., MIGLIAVACCA, M., KNAUER, J., SICKEL, K., SIGUT, L., MENZER, O., REICHSTEIN, M. Basic and extensible post-processing of eddy covariance flux data with REdDyProc. **Biogeosciences**, v. 15, p. 5015-5030. <https://doi.org/10.5194/bg-15-5015-2018>, 2018.

YANG, J., TIAN, H., PAN, S., CHEN, G., ZHANG, B., DANGAL, S. Amazon droughts and forest responses: largely reduced forest photosynthesis but slightly increased canopy greenness during the extreme drought of 2015/2016. **Global Change Biology**, v. 24 (5), p.1919-1934. <https://doi.org/10.1111/gcb.14056>, 2018.

YAN, H., WANG, S-Q., BILLESBACH, D., OECHEL, W., BOHRER, G., MEYERS, T., MARTIN, T. A., MATAMALA, R., PHILLIPS, R. P., RAHMAN, F., YU, Q., SHUGART, H. H. Improved global simulations of gross primary product based on a new definition of water stress factor and a separate treatment of C3 and C4 plants. **Ecological Modelling**, v. 297, p. 42-59, 2015.

ZHANG, Y., SONG, C., SUN, G., BAND, L. E., MCNULTY, S., NOORMETS, A., ZHANG, Q., ZHANG, Z. Development of a coupled carbon and water model for estimating global gross primary productivity and evapotranspiration based on eddy flux and remote sensing data. **Agricultural and Forest Meteorology**, v. 223, p. 116-131, 2016.

ZHENG, Y., ZHANG, L., XIAO, J., YUAN, W., YAN, M., LI, T., ZHANG, Z. Sources uncertainty in gross primary productivity simulated by light use efficiency models: Model structure, parameters, input data, and spatial resolution. **Agricultural and Forest Meteorology**, v. 263, p. 242-257, 2018.

ZSCHEISCHLER, J., REICHSTEIN, M., HARMELING, S., RAMMING, A., TOMELLERI, E., MAHECHA, M.D. Extreme events in gross primary production: a characterization across continents. **Biogeosciences**, v. 11, p. 2909-2924, 2014.