

**UNIVERSIDADE FEDERAL DE UBERLÂNDIA
INSTITUTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA
ÁREA DE CONCENTRAÇÃO DINÂMICAS TERRITORIAIS E ESTUDOS
AMBIENTAIS**

**ESTIMATIVA DO FLUXO DE CO₂ NA CAMADA LIMITE DA ATMOSFERA
SOBRE A RDS UATUMÃ/AM-BRASIL POR MEIO DE IMAGENS ORBITAIS E
DADOS MICROMETEOROLÓGICOS**

EDUARDO AUGUSTO BRAGA Y GARCIA

Uberlândia/MG

2020

EDUARDO AUGUSTO BRAGA Y GARCIA

**ESTIMATIVA DO FLUXO DE CO₂ NA CAMADA LIMITE DA ATMOSFERA
SOBRE A RDS UATUMÃ/AM-BRASIL POR MEIO DE IMAGENS ORBITAIS E
DADOS MICROMETEOROLÓGICOS**

Dissertação apresentada ao Instituto de Geografia da Universidade Federal de Uberlândia como requisito parcial para a obtenção do título de Mestre em Geografia, na linha de pesquisa: Estudos Ambientais e Geotecnologias.

Área de Concentração: Dinâmicas Territoriais e Estudos Ambientais.

Orientador: Prof. Dr. Claudionor Ribeiro da Silva

**Uberlândia/MG
INSTITUTO DE GEOGRAFIA
2020**

Ficha Catalográfica Online do Sistema de Bibliotecas da UFU
com dados informados pelo(a) próprio(a) autor(a).

G216 2020	<p>Garcia, Eduardo Augusto Braga Y, 1987- Estimativa do fluxo de CO2 na camada limite da atmosfera sobre a RDS Uatumã - AM – Brasil por meio de imagens orbitais e de dados micrometeorológicos [recurso eletrônico] / Eduardo Augusto Braga Y Garcia. - 2020.</p> <p>Orientador: Claudionor Ribeiro da Silva. Dissertação (Mestrado) - Universidade Federal de Uberlândia, Pós-graduação em Geografia. Modo de acesso: Internet. Disponível em: http://doi.org/10.14393/ufu.di.2020.643 Inclui bibliografia. Inclui ilustrações.</p> <p>1. Geografia. I. Silva, Claudionor Ribeiro da, 1975- (Orient.). II. Universidade Federal de Uberlândia. Pós- graduação em Geografia. III. Título.</p> <p style="text-align: right;">CDU: 910.1</p>
--------------	---

Bibliotecários responsáveis pela estrutura de acordo com o AACR2:

Gizele Cristine Nunes do Couto - CRB6/2091



UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Coordenação do Programa de Pós-Graduação em Geografia
 Av. João Naves de Ávila, 2121, Bloco 1H, Sala 1H35 - Bairro Santa Monica, Uberlândia-MG, CEP 38400-902
 Telefone: (34) 3239-4381/3291-6304 - www.ppgeo.ig.ufu.br - posgeo@ufu.br



ATA DE DEFESA - PÓS-GRADUAÇÃO

Programa de Pós-Graduação em:	GEOGRAFIA				
Defesa de:	Mestrado Acadêmico, Número 502, PPGGEO				
Data:	16 de outubro de 2020	Hora de início:	14:00m	Hora de encerramento:	17h:50m
Matrícula do Discente:	11812GEO005				
Nome do Discente:	EDUARDO AUGUSTO BRAGA Y GARCIA				
Título do Trabalho:	ESTIMATIVA DO FLUXO DE CO2 NA CAMADA LIMITE DA ATMOSFERA SOBRE A RDS UATUMÃ - AM - BRASIL POR MEIO DE IMAGENS ORBITAIS E DE DADOS MICROMETEOROLÓGICOS				
Área de concentração:	GEOGRAFIA E GESTÃO DO TERRITÓRIO				
Linha de pesquisa:	ANÁLISE, PLANEJAMENTO E GESTÃO AMBIENTAL/GEOPROCESSAMENTO				
Projeto de Pesquisa de vinculação:					

Reuniu-se no Anfiteatro/Sala [Via Google Meet], Campus [Santa Mônica via Google Meet], da Universidade Federal de Uberlândia, a Banca Examinadora, designada pelo Colegiado do Programa de Pós-graduação em GEOGRAFIA, assim composta: Professores Doutores: [Paulo César Mendes - IG/UFU; Alessandro Carioca de Araújo - EMPRABA - AM; e Claudionor Ribeiro da Silva - IG/UFU; sendo o último, o orientador do candidato. Os membros da Banca participaram Via Google Meet.

Iniciando os trabalhos o(a) presidente da mesa, Prof. Dr. Claudionor Ribeiro da Silva - IG/UFU, apresentou a Comissão Examinadora e o candidato, agradeceu a presença do público, e concedeu ao Discente a palavra para a exposição do seu trabalho. A duração da apresentação do Discente e o tempo de arguição e resposta foram conforme as normas do Programa.

A seguir o senhor(a) presidente concedeu a palavra, pela ordem sucessivamente, aos(às) examinadores(as), que passaram a arguir o(a) candidato(a). Ultimada a arguição, que se desenvolveu dentro dos termos regimentais, a Banca, em sessão secreta, atribuiu o resultado final, considerando o(a) candidato(a):

Aprovado(a).

Esta defesa faz parte dos requisitos necessários à obtenção do título de Mestre.

O competente diploma será expedido após cumprimento dos demais requisitos, conforme as normas do Programa, a legislação pertinente e a regulamentação interna da UFU.

Nada mais havendo a tratar foram encerrados os trabalhos. Foi lavrada a presente ata que após lida e achada conforme foi assinada pela Banca Examinadora.

Documento assinado eletronicamente por **Claudionor Ribeiro da Silva, Professor(a) do Magistério Superior**, em 17/10/2020, às 13:08, conforme horário oficial de Brasília, com fundamento no art. 6º, §



1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Paulo Cezar Mendes, Professor(a) do Magistério Superior**, em 17/10/2020, às 21:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



Documento assinado eletronicamente por **Alessandro Carioca de Araújo, Usuário Externo**, em 03/11/2020, às 11:51, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site https://www.sei.ufu.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **2326383** e o código CRC **1F52D816**.

UNIVERSIDADE FEDERAL DE UBERLÂNDIA

Eduardo Augusto Braga y Garcia

**Estimativa do Fluxo de CO₂ na camada limite da atmosfera sobre a RDS Uatumã/AM-
Brasil: Análise de imagens orbitais e dados micrometeorológicos**

Prof. Dr. Claudionor Ribeiro da Silva (UFU - IG) (Orientador)

Dr. Alessandro Carioca de Araujo (EMBRAPA)

Prof. Dr. Paulo Cezar Mendes (UFU - IG)

Data: 16 / 10 de 2020

Resultado: APROVADO

Dedico este trabalho à minha família, meus amigos e aos mestres, pelo incentivo, aprendizado e fortaleza.

AGRADECIMENTOS

Essa dissertação não se trata apenas de uma pesquisa científica, trata-se de um agradecimento a todos que me ajudaram a construir os degraus nos quais eu subi e continuo subindo. Gostaria de agradecer a cada uma das inúmeras pessoas que me impulsionaram pra frente, pois sem vocês nada disso seria possível.

Primeiramente, gostaria de agradecer a minha mãe por sempre me incentivar a estudar e por me ensinar a indagar o mundo a minha volta, ao meu pai por me ensinar a ser sonhador e acreditar que os sonhos são possíveis. Gostaria de agradecer aos meus irmãos por sempre me desafiar e me motivarem a dar o meu melhor e à minha esposa por sempre me apoiar em todas as minhas empreitadas da vida e acreditar em mim, mesmo quando eu não acreditava. Gostaria de agradecer ao meu amigo Raví Nogueira, que me ajudou de boa vontade e prontidão a apresentar esses dados de maneira mais visual e por fim, mas não menos importante a minha esposa Maisa Barbosa, sem a força dela, o apoio, carinho, compreensão e incentivo, nada disso seria possível.

Como diz o ditado: “se consegui ver mais longe, foi porque subi em ombros de gigantes”. Tudo que almejei e logrei foi graças à confiança, o incentivo e a compaixão de todos os mestres que tive pela vida. Gostaria de agradecer ao Prof. Dr. David Francis por todas as longas horas de conversa, me convencendo que nunca é tarde demais para seguir nossos sonhos. Gostaria de agradecer ao Prof. Dr. Silvio Carlos, por sempre acreditar no meu potencial e me incentivar a dar o meu melhor desde a época de graduação. Gostaria de agradecer especialmente ao meu orientador Prof. Dr. Claudionor Ribeiro da Silva, pois sem sua paciência, bom humor, profissionalismo e compreensão, esse trabalho não seria possível.

Agradeço aos membros do Instituto Nacional de Pesquisas da Amazônia e do projeto ATTO, em especial ao Dr. Alessandro Carioca de Araújo e a Ma. Marta De Oliveira Sá, por disponibilizar todos os dados e por todo auxílio e presteza. Também ao Instituto de Geografia da Universidade Federal de Uberlândia, em especial a Prof. Dra. Marlene Teresinha de Muno Colesanti por toda compreensão e empatia e, finalmente, ao Sr. João Fernandes da Silva por seu profissionalismo e bom humor e pró atividade.

“A ciência não é só compatível com a espiritualidade; é uma profunda fonte de espiritualidade. Quando reconhecemos nosso lugar na imensidão de anos-luz e no transcorrer das eras, quando compreendemos a complexidade, a beleza e a sutileza da vida, então o sentimento sublime, misto de júbilo e humildade, é certamente espiritual.”

Carl Sagan – O Mundo Assombrado Pelos Demônios, 1995.b

RESUMO

No campo de estudo dos ecossistemas florestais, as florestas tropicais possuem uma constante dinâmica em relação à atmosfera e aos balanços de água e energia, concentrando em si uma vasta biodiversidade. Enquanto a principal faixa de floresta tropical do mundo, a Floresta Amazônica concentra cerca de um terço da área total de florestas tropicais úmidas no mundo, consistindo em uma importante regulador do clima e dos fluxos de armazenamento e dispersão de carbono. A Amazônia capta e libera grandes quantidades de CO₂ por meio da fotossíntese e da respiração das plantas e do solo, atuando fundamentalmente na formação do estoque de carbono no planeta. A troca líquida que ocorre nos fluxos de CO₂, bem como as políticas de uso do solo, afetam dinamicamente o clima do planeta, constituindo uma relação central para o estudo crítico na ciência ambiental. Neste sentido, há uma relação objetiva entre o aumento da concentração de dióxido de carbono (CO₂) no planeta e o crescimento das atividades antrópicas, como demonstram Wohlfahrt *et al.* (2010) e Ramankutty *et al.* (2007). Para melhor compreender tal relação e como esta influencia as mudanças climáticas, é essencial possuir meios confiáveis e acessíveis para estimar as variáveis responsáveis por tais mudanças. Neste contexto, essa pesquisa visa estimar o fluxo de carbono na área interna e no entorno da reserva RDS Uatumã (Amazonas/Brasil), a partir de imagens digitais do satélite CBERS-4 (sensor MUX) e dados micrometeorológicos provenientes da Torre Alta de Observação da Amazônia (ATTO). Para tanto, foi elaborado um modelo de fluxo de carbono para cada ano analisado (2017, 2018 e 2019), embasado nos dados micrometeorológicos e em imagens orbitais desta região. Para geração dos modelos com dados micrometeorológicos foi aplicada a regressão linear múltipla sobre os dados originais para cada ano ($R^2=0,271; 0,278; 0,316$) e sobre os dados alterados por Componentes Principais ($R^2 = 0,237; 0,246; 0,288$), finalmente transformados por polinômio ($R^2=0,334; 0,318; 0,339$). Em seguida, foram elaborados os índices espectrais para cada ano de NDVI ($R^2=0,2596; 0,0004; 0,1197$), PRI ($R^2=0,4749; 0,0549; 0,5218$) o método proposto por Rahman *et al.* (2000) ($R^2=0,2998; 0,0011; 0,158$) e pelo modelo proposto nessa pesquisa ($R^2 = 0,6251; 0,0083; 0,5896$). Os resultados desta pesquisa apontam que o índice espectral proposto neste estudo fornece um modo de estimativa indireta, para medir o fluxo de carbono na Amazônia, com um maior nível de confiança em relação aos demais modelos gerados a partir de dados micrometeorológicos e dos demais índices espectrais apresentados.

Palavras-chave: RDS Uatumã/AM, Fluxo de CO₂, Geotecnologias.

ABSTRACT

In the study field of forest ecosystems, tropical forests hold a constant dynamic in relation to the atmosphere and the balances of water and energy, possessing a vast biodiversity. As the main range of tropical rainforest in the world, the Amazon Rainforest concentrates about a third of the total area of tropical rainforests in the world, working as an important climate regulator, storing and dispersing carbon flows. The Amazon Forest captures and releases large amounts of CO₂ through photosynthesis and the respiration of plants and soil, acting fundamentally in the formation of carbon stocks on the planet. The net exchange embedded in the CO₂ flows, as well as the land policies, dynamically affect the planet's climate, representing a central relation for a critical approach in the field of environmental science. Therefore, there is an objective relation between the rise of carbon dioxide's (CO₂) concentration on the planet and the growth of human activities, as evidenced by Wohlfahrt *et al.* (2010) and Ramankutty *et al.* (2007). In order to widely understand this relation and how it influences the climate change, it is essential to hold on reliable and accessible data, as an effort to estimate the variables which affect the climate. In this context, the present research aims to estimate the carbon flux in the internal area and around the Uatumã RDS reserve (Amazonas / Brazil), using digital images from the CBERS-4 satellite (MUX sensor) and micro-meteorological data from the Amazon's High Observation Tower (ATTO). To achieve this, a carbon flow model was elaborated for each year (2017, 2018 and 2019), based on micro-meteorological data and orbital images from this region. In order to generate the models with micrometeorological data, multiple linear regression was applied on the original data for each year (2017, 2018 and 2019) ($R^2 = 0.271; 0.278; 0.316$) and on the data altered by Principal Components ($R^2 = 0.237; 0.246; 0.288$), finally transformed by polynomial ($R^2 = 0.334; 0.318; 0.339$). Then, the spectral indices for each year of NDVI ($R^2 = 0.2596; 0.0004; 0.1197$), PRI ($R^2 = 0.4749; 0.0549; 0.5218$) the proposed method by Rahman *et al.* (2000) ($R^2 = 0.2998; 0.0011; 0.158$) and the model proposed by this research ($R^2 = 0.6251; 0.0083; 0.5896$). The results of this research indicate that the spectral index proposed in this study provides an indirect estimation method, to measure the carbon flow in the Amazon, with a higher level of confidence in relation to the other models generated from micrometeorological data and the other spectral indexes presented.

Keywords: RDS Uatumã/AM, CO₂ Flux, Geotechnologies.

SUMÁRIO

1	INTRODUÇÃO.....	16
2	PROBLEMÁTICA.....	18
3	OBJETIVOS.....	20
3.1	Objetivos Específicos.....	20
4	REFERENCIAL TEÓRICO.....	20
4.1	Desmatamento da floresta amazônica.....	21
4.2	O ciclo e o fluxo de carbono em sistemas ambientais.....	23
4.3	Modelagem do fluxo de carbono usando imagens de satélite.....	31
4.4	Levantamento indireto por meio dos Índices de Vegetação.....	33
4.4.1	<i>O Índice de Vegetação da Diferença Normalizada (NDVI) e sua correlação com os fluxos de carbono.....</i>	<i>33</i>
4.4.1	<i>O Índice de Reflectância Fotoquímica (PRI) e sua correlação com os fluxos de carbono.....</i>	<i>34</i>
4.5	Modelagem utilizando regressão linear múltipla.....	36
5	MATERIAIS E MÉTODOS.....	38
5.1	Área de estudo.....	40
2.1.1	<i>Caracterização do meio físico da área de estudo.....</i>	<i>41</i>
5.2	Dados da Torre Alta de Observação da Amazônia (ATTO).....	48
5.2.1	<i>Descrição dos dados obtidos.....</i>	<i>49</i>
5.3	Imagens Orbitais CBERS-4 Sensor MUX.....	51
5.3.1	<i>Aquisição de imagens orbitais:.....</i>	<i>51</i>
5.3.2	<i>Descrição dos dados obtidos.....</i>	<i>52</i>
5.4	Softwares utilizados.....	54
5.4.1	<i>ArcGIS 10.5.....</i>	<i>54</i>
5.4.2	<i>QGIS 3.10 / SAGA GIS.....</i>	<i>54</i>
5.4.4	<i>Action Stat.....</i>	<i>55</i>
5.4.4	<i>Fluxograma metodológico da pesquisa.....</i>	<i>56</i>
5.4	Procedimentos para a modelagem dos dados de fluxo de carbono provenientes da ATTO57	
5.4.1	<i>Interpolação dos dados por Krigagem.....</i>	<i>57</i>
5.4.2	<i>Estatística descritiva.....</i>	<i>60</i>
5.4.3	<i>Matriz de Correlação.....</i>	<i>60</i>
5.4.4	<i>Modelagem por meio de Regressão Linear Múltipla.....</i>	<i>61</i>
5.4.5	<i>Modelagem com aplicação da Análise por Componentes Principais.....</i>	<i>62</i>
5.4.6	<i>Modelagem com aplicação de Polinômios.....</i>	<i>63</i>

5.4.7	<i>Cálculo de fluxo de carbono através do modelo e validação dos dados</i>	63
5.5	Procedimentos para cálculo de fluxo de carbono provenientes do CBERS-4/MUX.	64
5.5.1	<i>Processamento das imagens do CBERS</i>	64
5.5.2	<i>Cálculo do NDVI (Normalized Difference Vegetation Index)</i>	65
5.5.3	<i>Cálculo do índice de Reflectância Fotossintético (PRI)</i>	65
5.5.4	<i>Cálculo do Fluxo de CO2 Proposto por Rahman et al. (2000)</i>	66
5.5.5	<i>Cálculo do Fluxo de CO2 Proposto nesse Estudo</i>	66
5.6	Validação dos Resultados	67
6	RESULTADOS E DISCUSSÃO	68
6.1	Modelagem do fluxo de carbono por meio dos dados ATTO	68
6.1.1	<i>Interpolação dos dados por Krigagem</i>	68
6.1.2	<i>Estatística descritiva</i>	69
6.1.5	<i>Modelagem dos dados transformados por componentes principais</i>	88
6.1.6	<i>Modelagem dos dados transformados por polinômios</i>	93
6.2	Validação dos resultados dos modelos criados pelos dados da ATTO	99
6.2.1	<i>Modelo de fluxo de carbono gerado com os dados transformados por ACP</i>	100
6.2.3	<i>Modelo de fluxo de carbono gerado com os dados transformados por Polinômio</i>	101
6.3	Modelagem do fluxo de carbono dos dados provenientes do CBERS-04/MUX	102
6.3.1	<i>Definição dos pontos para coleta das amostras</i>	102
6.3.2	<i>Resultados dos valores de NDVI</i>	104
6.3.3	<i>Resultados dos valores de PRI e sPRI</i>	106
6.3.4	<i>Resultados dos valores de fluxo de carbono obtidos pelo método proposto por Rahman et. al. (2000)</i>	109
6.3.5	<i>Resultados dos valores de CFLUX obtidos pelo método proposto</i>	113
6.4	Validação dos resultados dos índices espectrais	113
6.4.1	<i>Comparação dos índices espectrais para o ano de 2017</i>	114
6.4.2	<i>Comparação dos índices espectrais para o ano de 2018</i>	116
6.4.3	<i>Comparação dos índices espectrais para o ano de 2019</i>	118
7	CONCLUSÕES	120
8	REFERÊNCIAS	124

LISTA DE FIGURAS

Figura 1. Esquemática dos reservatórios de carbono no planeta e suas relações.....	24
Figura 2. Fluxos naturais e antropogênicos de carbono no sistema climático. Tamanho das reservas em GtC, fluxos e taxas em GtC/ano.....	26
Figura 3. Exemplificação dos vórtices turbulentos.....	28
Figura 4. Localização das torres de fluxo de carbono registradas na FLUXNET.....	29
Figura 5. Gráfico dos Índices de Refletância do NDVI e PRI.....	34
Figura 6. Mapa de localização – RDS Uatumã e ATTO / AM - 2020.....	41
Figura 7. Mapa de caracterização geológica.....	44
Figura 8. Mapa de caracterização geomorfológica.....	45
Figura 9. Mapa de caracterização pedológica.....	46
Figura 10. Mapa de caracterização hidrográfica.....	47
Figura 11. Vista Parcial da Torre ATTO na RDS-Uatumã - 2015.....	48
Figura 12. Fluxograma metodológico da pesquisa proposta.....	57
Figura 13. Gráfico de dados levantados e de lacunas (2017, 2018 e 2019).....	59
Figura 14. Modelo de Fluxograma do Model Builder utilizado para a automação do processo.....	64
Figura 15. <i>P-valores</i> da matriz de dados segundo método Pearson (2017).....	73
Figura 16. <i>P-valores</i> da matriz de dados segundo método Pearson (2018).....	74
Figura 17. <i>P-valores</i> da matriz de dados segundo método Pearson (2019).....	75
Figura 18. Gráfico da relação Tau X Fluxo de Carbono (2017).....	82
Figura 19. Gráfico da relação Tau X Fluxo de Carbono (2018).....	82
Figura 20. Gráfico da relação Tau X Fluxo de Carbono (2019).....	83
Figura 21. Gráfico da relação U x Fluxo de carbono (2017).....	83
Figura 22. Gráfico da relação U x Fluxo de Carbono (2018).....	84
Figura 23. Gráfico da relação U x Fluxo de Carbono (2019).....	84
Figura 24. Gráfico da relação UV x Fluxo de Carbono (2017).....	85
Figura 25. Gráfico da relação UV x Fluxo de Carbono (2018).....	85
Figura 26. Gráfico da relação UV x Fluxo de Carbono (2019).....	86
Figura 27. Mapa de distância dos pontos amostrais em relação à área.....	103
Figura 28. Imagem com valores de NDVI referentes ao ano 2017.....	104
Figura 29. Imagem com valores de NDVI referentes ao ano 2018.....	104
Figura 30. Imagem com valores de NDVI referentes ao ano 2019.....	105
Figura 31. Imagem com valores de PRI referentes ao ano 2017.....	107
Figura 32. Imagem com valores de PRI referentes ao ano 2018.....	107
Figura 33. Imagem com valores de PRI referentes ao ano 2019.....	108
Figura 34. Imagem com valores de sPRI*NDVI referentes ao ano 2017.....	110
Figura 35. Imagem com valores de sPRI*NDVI referentes ao ano 2018.....	110
Figura 36. Imagem com valores de sPRI*NDVI referentes ao ano 2019.....	111

LISTA DE QUADROS

Quadro 1. Dados Micrometeorológicos provenientes da ATTO – RDS Uatumã	50
Quadro 2. Dados de fluxo de carbono provenientes da ATTO – RDS Uatumã.....	51
Quadro 3. Metadados do satélite CBERS-4.	52
Quadro 4. Cenas utilizadas para o cálculo dos índices de vegetação.....	52

LISTA DE TABELAS

Tabela 1. Estatística descritiva (2017)	70
Tabela 2. Estatística descritiva (2018)	71
Tabela 3. Estatística descritiva (2019)	72
Tabela 4. <i>p-valores</i> referentes da matriz de correlação nos anos 2017, 2018 e 2019.	76
Tabela 5. <i>p-valores</i> da tabela ANOVA	77
Tabela 6. Coeficientes de regressão	78
Tabela 7. Medida descritiva da qualidade do ajuste.....	86
Tabela 8. Valores máximos, mínimos e do RMSE	87
Tabela 9. Autovalores dos componentes principais dos anos 2017, 2018 e 2019.....	88
Tabela 10. <i>p-valores</i> da tabela ANOVA – ACP	89
Tabela 11. Coeficientes de regressão 2017, 2018 e 2019 – ACP.....	89
Tabela 12. Medida descritiva da qualidade do ajuste – ACP.....	92
Tabela 13. Valores de máximos, mínimos e RMSE – ACP.....	93
Tabela 14. <i>p-valores</i> da tabela ANOVA - Polinômios.....	94
Tabela 15. Coeficientes de regressão 2017, 2018 e 2019 – Polinômios	95
Tabela 16. Medida descritiva da qualidade do ajuste – Polinômios.....	98
Tabela 17: Valores máximos, mínimos e do RMSE - Polinômios.....	98
Tabela 18. Teste-t para todos os modelos propostos por Krigagem.....	99
Tabela 19. Teste-t para todos os modelos propostos por ACP.....	100
Tabela 20. Teste-t para todos os modelos propostos por Krigagem.....	101
Tabela 21. Média dos valores de NDVI extraídos	105
Tabela 22. Média dos valores de PRI extraídos	108
Tabela 23. Valores de sPRI calculados a partir dos valores de PRI.....	109
Tabela 24. Média dos valores de sPRI*NDVI	111
Tabela 25. Média dos valores de CO2Flux	112
Tabela 26. Média dos valores de CO2Flux pelo método proposto	113

LISTA DE GRÁFICOS

Gráfico 1: Linha de Regressão dos valores de NDVI (2017).....	116
Gráfico 2: Linha de Regressão dos valores de PRI (2017).....	116
Gráfico 3: Linha de Regressão dos valores de Cflux (2017).....	117
Gráfico 4: Linha de Regressão dos valores do modelo proposto(2017).....	117
Gráfico 5: Linha de Regressão dos valores de NDVI (2018).....	118
Gráfico 6: Linha de Regressão dos valores de PRI (2018).....	118
Gráfico 7: Linha de Regressão dos valores de NDVI (2018).....	119
Gráfico 8: Linha de Regressão dos valores de PRI (2018).....	119
Gráfico 9: Linha de Regressão dos valores de NDVI (2019).....	120
Gráfico 10: Linha de Regressão dos valores de PRI (2019).....	120
Gráfico 11: Linha de Regressão dos valores de Cflux (2019).....	121
Gráfico 12: Linha de Regressão dos valores (2019).....	121

1 INTRODUÇÃO

Ao longo da história, a concentração de dióxido de carbono (CO₂) na atmosfera tem aumentado, sendo que a principal causa desse aumento deve-se às atividades humanas, como queima de combustíveis fósseis e de biomassa, além das mudanças no uso e ocupação dos solos (IPCC, 2005). Devido a este aumento, a concentração atmosférica global de CO₂ ultrapassou 400 ppm recentemente (SHOWSTACK, 2013), afetando o balanço de radiação solar da atmosfera (FORSTER *et al.*, 2007). É importante acrescentar que o ciclo e as concentrações atmosféricas de CO₂ são naturalmente regulados por meio de processos como a respiração, a absorção por meio da fotossíntese e outros processos ativos e passivos da planta na captura de CO₂ atmosférico. Porém, essa alteração no ciclo de carbono causa um desequilíbrio nos ecossistemas e na dinâmica atmosférica, o que demanda um esforço global para mitigar os possíveis efeitos deste desequilíbrio, motivando pesquisas na comunidade científica para avaliar a quantidade de carbono terrestre, principalmente as relações de captura e de liberação de CO₂ da atmosfera (BACHELET *et al.*, 2001).

As florestas tropicais afetam a dinâmica da atmosfera e os balanços de energia e água, devido a fatores tais como a capacidade de absorção de radiação solar, a influência sobre o regime de chuvas, a produção de biomassa e também devido à biodiversidade extremamente alta (LOSOS e LEIGH, 2004; SAATCHI *et al.* 2011). No caso da floresta amazônica, esta capta e libera grandes quantidades de CO₂ através da fotossíntese e da respiração das plantas e do solo, desta forma, as florestas tropicais desempenham um papel importante no estoque de carbono no planeta (GRACE *et al.*, 1995; GASH *et al.*, 1996; SELLERS *et al.*, 1997). Ao longo dos anos, a floresta foi severamente impactada por mudanças no uso e cobertura da terra (NEPSTAD *et al.* 2008; DAVIDSON *et al.* 2012). Vale ressaltar que o Brasil possui a maior extensão de floresta tropical do mundo, sendo responsável por cerca de 20% do estoque mundial de armazenamento de carbono (BERNOUX *et al.* 2002).

Para compreender as consequências deste desequilíbrio, é necessário realizar medições e levantamentos de dados a longo prazo que forneçam o registro das condições climáticas e biogeoquímicas da atmosfera, a fim de conjecturar possíveis causas e consequências na dinâmica ambiental, permitindo a quantificação de padrões espaciais no saldo de CO₂. Com o aumento histórico da alteração no uso e ocupação do solo de ecossistemas naturais, estimar como essa troca afetará o clima e as políticas de uso da terra é, portanto, uma questão crítica na ciência ambiental (WOHLFAHRT *et al.*, 2010). Com isso, duas formas principais são

comumente utilizadas para se medir os fluxos de carbono em ecossistemas inteiros, uma forma indireta e outra forma direta (HOUGHTON *et al.*, 2012). Sobre as metodologias indiretas, as mais utilizadas são três: estatísticas nacionais agregadas de terras, dados de mudança de uso e ocupação do solo e dados de monitoramento de queimadas, ambos provenientes de imagens de satélite (HOUGHTON *et al.*, 2012).

Sobre as metodologias de análise direta, as abordagens mais usadas para estimar a densidade de carbono e a liberação ou absorção por meio da mudança no uso e ocupação do solo são: as estimativas baseadas em inventário florestal para contabilizar as alterações em reservatórios de carbono; as estimativas de densidade de carbono baseadas em imagens de satélite usado com uma variedade de modelos; processos de modelagem de vegetação que calculam internamente a densidade de biomassa (equações alométricas) (HOUGHTON *et al.*, 2012). Vale ressaltar que há também outras abordagens que utilizam modelos de orçamento de carbono, como demonstrado por Dai *et al.* (2014) e também por meio de dados de sensoriamento remoto, como demonstrado nas pesquisas de Fries *et al.* (2002) e Asner *et al.* (2010), ou até mesmo por uma combinação de ambos os métodos, com medições *in situ* e dados de imagens orbitais (MASEK E COLLATZ, 2006; ESPÍRITO-SANTO *et al.*, 2014).

A vantagem do sensoriamento remoto sobre as demais técnicas se deve ao fato das pesquisas minimizarem as perturbações físicas no ambiente, além de maximizar a utilidade dos recursos disponíveis (MALENOVSKY *et al.*, 2015). Todavia, ao se combinar a metodologia do sensoriamento remoto com a integração de dados diretos há uma redução considerável das incertezas além de uma maior agilidade nos processos de monitoramento com possibilidade de abranger escalas locais, regionais e globais e realizar todos esses procedimentos por meio de uma série histórica.

Vale enfatizar que o sensoriamento remoto possui algumas vantagens em relação aos métodos de levantamento tradicionais. Dentre as principais vantagens está o custo, a escala e a acessibilidade dos dados. Alguns estudos comprovam a eficácia no monitoramento de fluxos de carbono utilizando os satélites Terra, Aqua e da série LANDSAT em outros ecossistemas (WU, 2012; YUAN *et al.*, 2014; SIMS *et al.*, 2008; XIAO *et al.*, 2004 e PRINCE e GOWARD, 1995). A utilização do sensoriamento remoto é vantajosa devido a um grande número de dados de satélite disponibilizados gratuitamente, além da resolução temporal que permite acompanhar uma série histórica e da possibilidade de mapear grandes áreas (HARRIS *et al.*, 2005, CRICHTON *et al.*, 2014).

2 PROBLEMÁTICA

A Bacia Amazônica ocupa uma vasta extensão territorial, cerca de um terço do continente Sul americano e se estende por cerca de $6,9 \times 10^6$ km². Nesta extensão territorial, cerca de 80% é coberta por floresta tropical (GOULDING *et al.*, 2003). A região coberta pela floresta amazônica contém 90-120 Pg C em biomassa viva, equivalendo a 84% da biomassa acima do solo em toda a América Latina, equivalendo a 40% de todas as florestas tropicais do mundo (BACCINI *et al.*, 2012; GLOOR *et al.*, 2012). A bacia amazônica possui cerca de 160 Pg de carbono armazenados nos solos. Isso equivale a cerca da metade do carbono presente na atmosfera da Terra antes do período da revolução industrial (GLOOR *et al.*, 2012). Nesta vasta extensão florestal, o alto índice de biodiversidade e potencial de armazenamento de carbono atmosférico é constantemente afetado por atividades antrópicas e as consequências dessa alteração não são totalmente compreendidas, o que coloca a necessidade de mais pesquisas na área.

Desde a revolução industrial, o dióxido de carbono atmosférico (CO₂) é responsável por cerca de 60% do aquecimento global observado, principalmente devido ao aumento da queima de combustíveis fósseis (SOLOMON *et al.*, 2007). Dos 7 Pg de carbono liberados em média anualmente para a atmosfera, a biosfera terrestre absorve cerca de um terço desse valor (CANADELL *et al.*, 2000). Portanto, a floresta Amazônica desempenha um papel importante na regulação dos ciclos de carbono, da água, das mudanças climáticas, da química atmosférica e da biodiversidade. No entanto, apesar dessa região apresentar inúmeros estudos que estimam o ciclo de carbono, o autor Ramankutty *et al.*, (2007) demonstra em sua pesquisa que cerca de cinco estudos nessa região proporcionaram diferentes resultados que divergem entre si e, portanto, não podem ser comparáveis.

Apesar da existência de diversas técnicas, o método de avaliação do fluxo de carbono que utiliza a técnica de covariância dos vórtices turbulentos (*eddy covariance*), para estimar os fluxos de CO₂, H₂O e energia, fornecem maior confiabilidade nas estimativas (BALDOCCHI *et al.*, 2001). O método de covariância de vórtices turbulentos (MCVT) é uma técnica micrometeorológica que se baseia em fluxos de ar turbulentos para medir a troca líquida de ecossistemas (TLE) em uma grande área (> 1 km²), quantificando três fluxos turbulentos dimensionais em rápida sucessão (MASSMAN e LEE, 2002). Os dados desses fluxos são

coletados no topo de uma torre de observação meteorológica a uma altura a ser determinada pelo pesquisador, com medidas acima e abaixo do dossel, avaliando fluxos de energia em intervalos de 30 minutos. O MCVT ganhou popularidade nos últimos 20 anos devido à sua capacidade de medir o fluxo total dos ecossistemas de maneira contínua (GOULDEN, 1996-A; BALDOCCHI, 2003). Atualmente, existem mais de 500 torres de medição estabelecidas em todo o mundo, fornecendo informações de uma ampla variedade de ecossistemas.

Todavia, a instalação e manutenção dessas torres gera um alto custo financeiro e problemas logísticos que impossibilitam a implementação das mesmas em larga escala ao longo de todo o globo terrestre. Desta forma, a medição indireta por meio de imagens de satélite proporciona uma alternativa de baixo custo e de grande abrangência territorial para realizar as estimativas de fluxo de carbono. A disponibilidade gratuita das imagens de satélite do Programa CBERS (China-Brazil Earth Resources Satellite, Satélite Sino-Brasileiro de Recursos Terrestres) permite acessar através de tecnologia nacional e de baixo custo acessar imagens orbitais de todo território nacional. A existência desse programa espacial de parceria sino-brasileira, permite aos usuários acessarem um acervo robusto de imagens de satélite para realizar pesquisas voltada ao sensoriamento remoto. Para tanto, a utilização de imagens orbitais do CBERS-4 atende ao critério da facilidade de acesso, custo e disponibilidade de imagens na área de estudo, possibilitando a replicação deste método ou partes dele. A facilidade de acesso, custo reduzido, resolução espacial e temporal são questões cruciais para realizar estudos de sensoriamento remoto na bacia amazônica. Devido a fatores climatológicos e de dificuldade de acesso, o programa CBERS oferece a possibilidade de realizar estudos do campo do sensoriamento remoto nessa região.

Ao realizar uma análise completa das emissões de carbono, é necessário quantificar vários elementos, incluindo as taxas de mudanças e a dinâmica da cobertura do solo, o cálculo do estoque de carbono na vegetação e nos solos, a dinâmica de circulação do carbono liberado e armazenado, a resposta dos solos após sofrer mudanças em sua cobertura, a influência das mudanças históricas na cobertura do solo e, finalmente, a elaboração de modelos utilizados para integrar todos esses elementos descritos (RAMANKUTTY *et. al.*, 2007). Pois, caso sejam negligenciados esses fatores, uma simples comparação das estimativas demonstra que existe uma gama de incertezas em relação às emissões de carbono (RAMANKUTTY *et. al.*, 2007). Assim, compreender o ciclo e os fluxos do carbono na Terra, necessita de pesquisas que

demonstrem maior precisão, considerando a variabilidade biológica e ambiental da superfície terrestre, além da variabilidade de métodos e técnicas disponíveis.

3 OBJETIVOS

Este estudo objetivou desenvolver um modelo para estimar o fluxo de gás carbônico da Reserva de Desenvolvimento Sustentável Uatumã (RDS Uatumã), por meio da utilização de imagens de satélite e de dados micrometeorológicos.

3.1 Objetivos Específicos

Partindo da perspectiva de modelagem do fluxo de carbono, apontamos como objetivos específicos desta pesquisa:

- ◆ Estimar o fluxo de carbono sobre a RDS Uatumã usando séries históricas de dados micrometeorológicos provenientes da ATTO.
- ◆ Estimar o fluxo de carbono a partir de séries temporais com imagens digitais provenientes do CBERS-4, sensor MUX, tendo por base a metodologia proposta por Rahman et. al. (2000).
- ◆ Propor um método para estimativa do fluxo de carbono para a RDS Uatumã, a partir de imagens orbitais,
- ◆ Analisar os resultados obtidos pelos diferentes métodos.

4 REFERENCIAL TEÓRICO

A preocupação com o equilíbrio ambiental é crescente ao longo da história da humanidade. Pode-se citar como marco histórico a Comissão Mundial sobre Meio Ambiente e Desenvolvimento (1987), que visa promover práticas, políticas e pesquisas voltadas ao desenvolvimento sustentável, sendo definido como aquele que atende às necessidades do presente sem comprometer a capacidade das gerações futuras de atender suas próprias necessidades.

Com isso, o desenvolvimento sustentável se torna uma prerrogativa crítica para evitar um colapso na disponibilidade de recursos naturais. Assim, pesquisas voltadas para essa área do conhecimento são necessárias para evitar o esgotamento dos mesmos e atender ao conceito inicial de sustentabilidade, proposto nos objetivos de desenvolvimento do milênio (ODM) durante a Cúpula do Milênio das Nações Unidas em 2000. A necessidade de pesquisas referentes aos meios racionais na utilização desses recursos deve-se ao fato de que processo de degradação é difícil de ser revertido, uma vez que a recuperação da área degradada torna-se economicamente inviável. Desta forma, um diagnóstico que descreva a situação do objeto de estudo contribui para a tomada de decisão em assuntos ambientais. Como exemplo de tomada de decisão, temos a gestão dos recursos ambientais, essencial para atender as metas estabelecidas pela comunidade internacional (BRASIL, 1987).

4.1 Desmatamento da floresta amazônica

A Amazônia brasileira vem sofrendo um agressivo processo de mudança ambiental via desmatamento, poluição das áreas de mineração e inundações, que resultam de projetos mal elaborados na região. Soma-se a isso os casos de empreendimentos que são autorizados, sem estudos aprofundados, acarretando em danos ambientais e socioeconômicos incalculáveis, como ocorreu com a construção da barragem de Balbina, localizada no rio Uatumã (FEARNSIDE, 2015). O reservatório inundou uma área de aproximadamente 2.346 km², sendo que a maior parte desta compreendia uma floresta intocada desde 1970 (CUMMINGS, 1990: p.44). Além disso, cerca de 311 km² do território inundado estava dentro da reserva indígena dos Waimiri-Atroari. As inundações transformaram as cabeceiras do igarapé de Santo Antônio do Abonari, igarapé do Taquari e do rio Uatumã em áreas inabitáveis, emitindo toneladas de gases do efeito estufa para a atmosfera e culminando na submersão de extensas áreas de floresta, o que tornou a água imprópria para qualquer uso humano.

Tais perturbações no domínio morfoclimático da Amazônia causam alterações climáticas sensíveis nas mudanças do fluxo global de carbono terrestre e acarretam em alterações nos padrões climáticos locais, regionais e global, além da perda de biodiversidade (ARMENTERAS *et al.*, 2017; SHUKLA *et al.*, 1990). Particularmente, a floresta Amazônica possui destaque no cenário de mudanças climáticas devido à sua importância ecológica global e à ameaça de sua devastação por meio de ações humanas, como demonstrado nas pesquisas de

Escada e Alves (2001); Fearnside (2005); MMA (2011) e Higuchi *et al.* (2012). A Amazônia concentra cerca de um terço das florestas tropicais úmidas do mundo, além de regular o clima, realizar o sequestro de carbono e garantir a perpetuação de uma vasta biodiversidade (HANSEN *et al.*, 2008).

A Amazônia é vasta e abriga uma fração substancial das espécies animais e arbóreas do mundo, impactando positivamente na redução do carbono presente na atmosfera (MORI e PRANCE, 1987; MALHI *et al.*, 2008). Sua biomassa fornece um grande reservatório de carbono, que pode chegar de 0,4 a 0,6 $Pgano^{-1}$, representando cerca de 25% do carbono armazenado na biosfera terrestre (BONAN, 2008; MALHI *et al.*, 2008). Porém, devido as alterações climáticas, o desmatamento intenso e as intensas secas que afetam a Amazônia, a região se transforma de um sumidouro de carbono para uma fonte líquida de emissão de carbono (PHILLIPS *et al.*, 2009; LEWIS *et al.*, 2011; BAGLEY *et al.*, 2014).

Esta capacidade de estocagem de carbono da Amazônia, juntamente à sua extensão, gera um interesse fundamental no entendimento da sua dinâmica em relação aos processos de mudanças climáticas. De acordo com Ab'Saber (1977), esse domínio se estende do oceano Atlântico até a Cordilheira dos Andes e abrange nove países da América do Sul, sendo que cerca de 69% desta floresta se encontra em território brasileiro. A maior parte da floresta amazônica se encontra no território brasileiro, totalizando uma área em torno de 4.871.000 km² e uma população de aproximadamente vinte milhões de habitantes, sendo que 60% desta vive em áreas urbanas (INPE, 2004). Desta forma, utiliza-se o termo “Amazônia Legal” para se referir à floresta amazônica que está contida no Brasil, abrangendo os estados do Pará, Amazonas, Maranhão, Goiás, Mato Grosso, Acre, Amapá, Rondônia e Roraima. Considerada uma área de fronteira agrícola, em alguns destes estados há intensa atividade agropecuária, o que constitui a principal causa do desmatamento ilegal de áreas preservadas, o que está ligado ao aumento da taxa de mudança de cobertura do solo no mundo, em termos de perdas florestais (FAO, 2006).

A floresta amazônica, dentre as demais florestas tropicais, destaca-se pelo fato de agrupar aproximadamente 50% do carbono armazenado em todas as florestas tropicais do mundo (PAN *et al.*, 2011). Mesmo possuindo essa grande quantidade de carbono estocado na biosfera, é complexa a compreensão deste fluxo, devido ao alto grau de inconsistência no ciclo de carbono global (LE QUERÉ *et al.*, 2016). A Amazônia possui uma vasta extensão territorial, que abrange diversos ambientes geológicos, geomorfológicos e socioculturais. Todas as

variáveis descritas acima afetam as estimativas sobre os fluxos de carbono, como demonstrado nos estudos de Castanho *et al.* (2016) e Johnson *et al.* (2016). Ademais, variáveis biológicas afetam a normalização dos dados, uma vez que diferenças como as densidades médias da madeira, biodiversidade e os agentes modificadores da paisagem não são totalmente compreendidos, mesmo que hajam diversos estudos relacionados à liberação de carbono pelo desmatamento (MALHI *et al.*, 2006 e CHAVE *et al.*, 2006).

Com isso, a estimativa do estoque de carbono na floresta amazônica acumula incertezas que acarretam numa variação do cálculo global, que pode ser alterado a partir de fatores como o período sazonal, o deslocamento das massas de ar, entre outros aspectos, e que são usualmente negligenciados nos cálculos. Mesmo em medições diretas da produtividade líquida, através do cálculo da biomassa, desconsidera-se algumas variáveis que influenciam expressivamente na quantidade real de carbono que um sistema pode liberar ou absorver (HOUGHTON, 2005; PHILLIPS *et al.*, 2009; GATTI *et al.*, 2014; CHAMBERS *et al.*, 2013; FISHER *et al.*, 2008). Estudos realizados pelos autores Quesada *et al.* (2017) demonstraram que as propriedades do solo também influenciam na dinâmica de absorção do carbono. Vale ainda destacar os estudos dos autores Hofhansl *et al.* (2014) e Malhi *et al.* (2015), por demonstrarem que a sazonalidade também pode influenciar na produtividade primária líquida de carbono.

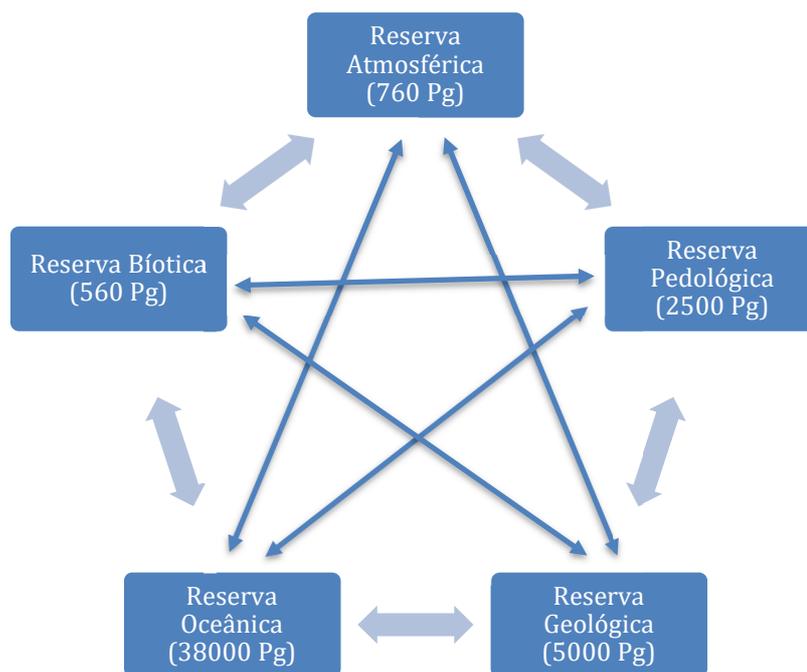
Todos estes fatores dificultam a estimativa apurada do fluxo de carbono na Amazônia. Por isso, um dos métodos desenvolvidos e consolidados na comunidade científica é a utilização de câmaras (Método dos Vórtices Turbulentos – MCVT) que analisam o fluxo de gás carbônico (LIANG *et al.* 2003). Além deste modelo, existe uma variedade de modelos projetados para medir tais fluxos, sendo que alguns deles são disponibilizados comercialmente.

4.2 O ciclo e o fluxo de carbono em sistemas ambientais

Dentre os problemas abordados, que se relacionam ao acúmulo dos GEE (Gases do Efeito Estufa), o processo de modificação do uso e cobertura da terra é o maior contribuinte para a emissão de CO₂ na atmosfera. Desde 1750, aproximadamente 35% das emissões antrópicas de CO₂ estão diretamente relacionadas às mudanças do uso da terra (FOLEY *et al.*, 2005). Como no caso da UHE Balbina, a área alagada de um reservatório é um grande modificador do uso e cobertura da terra, o que traz consequências indiretas para as áreas do entorno.

O armazenamento ou reserva de carbono no planeta terra é comumente dividido em cinco grandes compartimentos, que são: o oceânico, geológico, pedológico, biótico (biomassa vegetal e animal) e atmosférico (LAL, 2004). Estas reservas possuem um sistema de interação entre si, como demonstrado na Figura 1.

Figura 1. Esquemática dos reservatórios de carbono no planeta e suas relações



Fonte: LAL (2004). Elaboração, GARCIA, E. A. B. (2020)

Por se tratar de um sistema no qual há entrada e saída de energia e fluxos, todos estes compartimentos estão interconectados entre si, fazendo com que o carbono circule entre os mesmos (LAL, 2004). Já o reservatório pedológico contém cerca de 2.500 Pg de carbono, que estão divididos em 1.550 Pg na forma de carbono orgânico e 950 Pg de carbono inorgânico (LAL, 2006). Outro reservatório que merece destaque nesta pesquisa é proveniente do meio biótico, que apresenta cerca de 560 Pg de C (LAL, 2004).

De acordo com Eswaran *et al.* (1993), a quantidade de carbono estocado no solo, em até um metro de profundidade, está em torno de 1.576 Pg. Isso equivale a cerca de três vezes a quantidade de carbono no reservatório biótico e duas vezes do contido no reservatório atmosférico. Quando se consideram 30 centímetros da superfície de solo, nota-se que a

concentração de carbono chega a 800 Pg (CERRI *et al.*, 2006), que equivale à mesma quantidade no reservatório atmosférico. Estudos apontam que cerca de metade do carbono estocado no solo (787 Pg) é proveniente dos solos sob florestas e áreas preservadas (DIXON *et al.*, 1994). Um outro estudo aponta que áreas de pastagens contém em torno de 500 Pg e as áreas de cultivo agrícola possuem cerca de 170 Pg de C (SCHARPENSEEL, 1997; PAUSTIAN *et al.*, 2000). De acordo com Carvalho *et al.* (2010, p. 280):

Em regiões de clima tropical, as condições climáticas favorecem a decomposição da Matéria Orgânica do Solo (MOS), armazenando menos carbono em relação às regiões de clima temperado. (...) Apesar dessa maior taxa de decomposição de MOS (Matéria Orgânica do Solo), os solos em regiões de clima tropical estocam 32% do total de carbono orgânico contido nos solos do planeta (ESWARAN *et al.*, 1993 apud CARVALHO *et al.*, 2010, p.280).

Os mesmos autores constataram ainda que 78 Pg de carbono foram liberados para a atmosfera na forma de gás carbônico. Esse fato ocorreu devido à perda de MOS, oriunda das mudanças no uso da terra. Entretanto, outro estudo aponta que em um período de 25 a 50 anos de cultivo, cerca de 30 a 60 Pg de carbono podem ser recuperados no reservatório pedológico devido às práticas conservacionistas (LAL, 2004). Desta forma, coloca-se a possibilidade de recuperar todo o carbono perdido em curto período de tempo.

Para entender a necessidade de práticas que visam a conservação do solo, é necessário entender como o gás carbônico, armazenado no solo, é liberado para a atmosfera. Basicamente, “a emissão de CO₂ do solo para a atmosfera ocorre principalmente por dois processos biológicos: a decomposição de resíduos orgânicos e a respiração de organismos e sistema radicular das plantas” (ESWARAN *et al.*, 1993 apud CARVALHO *et al.*, 2010, p.280). Desta forma, o gás carbônico passa por um processo de difusão, no qual o gás concentrado se espalha pelo sistema, movendo-se junto com o ar ao qual está misturado (BALL e SMITH, 1991).

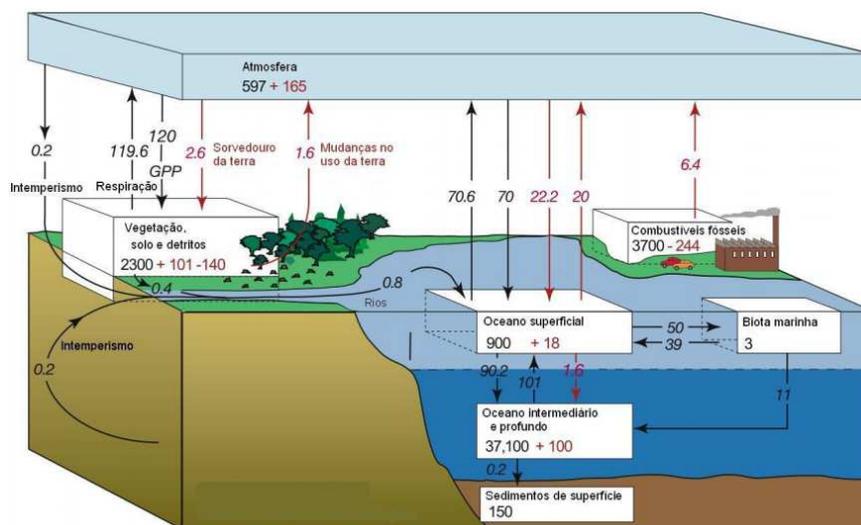
Em outro estudo realizado por Moreira e Siqueira (2006), foi apontado que nos poros do solo, a concentração de gás carbônico é maior do que na atmosfera, variando de 10 a 100 vezes a mais. Desse montante, cerca de 20% da concentração de CO₂ é oriunda de atividade respiratória biológica, e o restante é proveniente de atividades biológicas do solo (MELILLO *et al.*, 2002). Desta forma, devido a lei de difusão de sistemas, essa diferença de potencial entre o gás carbônico estocado no solo e o que está estocado na atmosfera, cria um fluxo ascendente de CO₂ para a atmosfera (BALL e SMITH, 1991).

Vale ressaltar que no desmatamento de áreas verdes, os impactos antropogênicos contribuem para as emissões dos GEE, ocasionando o declínio das precipitações nas áreas

desmatadas, uma vez que há uma forte relação de interdependência entre o clima e a vegetação (HOFFMANN e JACKSON, 2000). Neste sentido, Duiker e Lal (2000) apontam que as variáveis climáticas, como a temperatura, a umidade e outros fatores, influenciam diretamente no fluxo de CO₂ para a atmosfera. Também se constata que “a temperatura merece destaque especial no fluxo de CO₂, uma vez que acréscimos dessa variável podem elevar exponencialmente a taxa de respiração do solo” (FANG & MONCRIEFF, 2001, apud CARVALHO *et al*, 2010, p.280).

Ainda segundo Carvalho *et al* (2010), o gás carbônico, uma vez liberado para a atmosfera irá ser afetado pelas ações físicas e químicas da atmosfera tal como a influência dos ventos, da radiação solar, da temperatura, de reações químicas entre outras influências. Este desequilíbrio do sistema causa um processo de retroalimentação do aquecimento global, de acidificação dos oceanos e outras consequências que ainda não são inteiramente compreendidas. Ao se desmatar uma área nativa, altera-se o balanço de carbono armazenado no solo que, por consequência, é liberado para a atmosfera e, assim, surgem lugares onde são considerados sumidouros ou fonte de carbono. Esse desequilíbrio no sistema pode acelerar os processos de liberação do gás carbônico que está preso no solo ou em outros reservatórios de carbono, como demonstrado na Figura 2:

Figura 2. Fluxos naturais e antropogênicos de carbono no sistema climático. Tamanho das reservas em GtC, fluxos e taxas em GtC/ano



Fonte: (IPCC, 2007, p. 515).

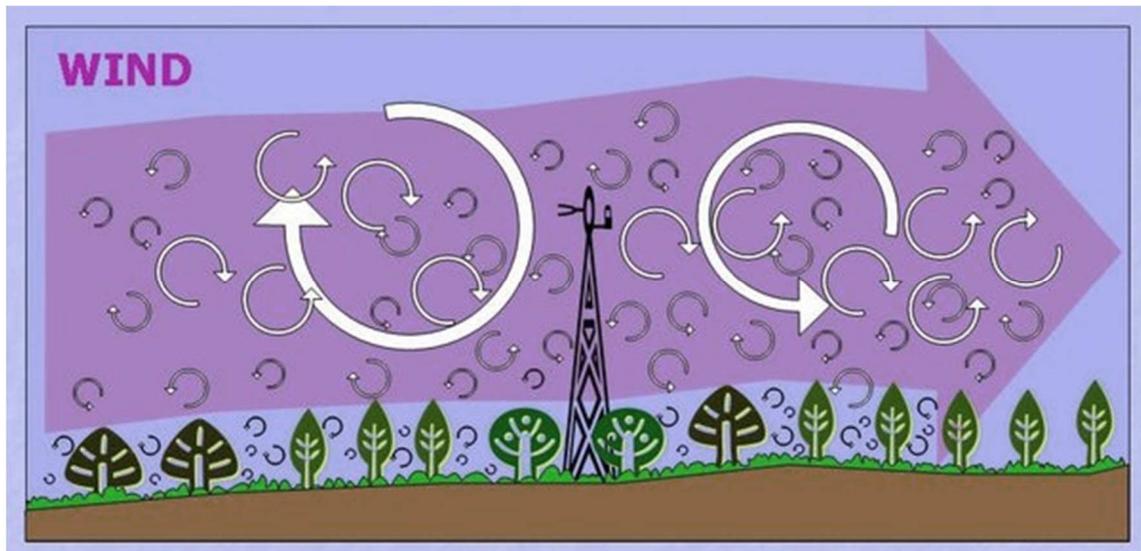
No bioma amazônico, a expansão agrícola tende a modificar o ciclo do carbono e afetar a sua capacidade de estocagem de CO₂. Neste sentido, compreender os fluxos desse gás e como identificá-los por meio de técnicas de sensoriamento remoto, permite que se elaborem dados confiáveis e rápidos para auxiliar no combate ao aquecimento global. Ao estimar a relação entre os fluxos de dióxido de carbono e o meio ambiente, por meio do uso de geotecnologias e do sensoriamento remoto, é possível realizar estimativas na mudança da cobertura vegetal em grandes áreas de forma mais rápida e barata além de calcular a contribuição dessa mudança do uso e ocupação do solo no aumento dos gases do efeito estufa, como demonstrado nos estudos de Kuntschik e Bittencourt (2003), Machado *et al.* (2004) e Pinheiro e Durigan (2009).

Mediante o exposto, entender o fluxo de carbono em florestas tropicais se torna imperativo, considerando o seu potencial de agravamento das mudanças climáticas. Acerca das técnicas de análise destes fluxos, as primeiras medições dos fluxos de CO₂ nos dosséis das plantas foram propostas por Thomas e Hill (1949), que usavam grandes caixas plásticas em campos de alfafa, beterraba, sacarina e trigo. Em seguida, na década de 1960, propôs-se a utilização de analisadores de gás infravermelho (MUSGRAVE e MOSS, 1961; ECKARDT, 1966). Posteriormente, foram propostos modelos micrometeorológicos, com a utilização de perfis verticais de concentração de CO₂ (RUMY *et al.* 1995). Os métodos de fluxos turbulentos, que operam por meio da instalação de torres de medição de dióxido de carbono, foram desenvolvidos pela primeira vez para medir os fluxos de calor e vapor de água, e posteriormente estendidos ao CO₂, devido à popularização de sensores mais baratos e confiáveis que começaram a ser produzidos na década de 1980 (RUMY *et al.*, 1995).

Assim, desde a década de 1980, várias torres de monitoramento de fluxo de carbono foram estabelecidas ao redor do mundo (BALDOCCHI *et al.*, 2001). Estas torres registram o fluxo de CO₂, de energia, além de medir o armazenamento e a variação de CO₂ na camada de ar acima do dossel, juntamente às variáveis meteorológicas, tal como a radiação global, a temperatura do solo e do ar, a umidade relativa, a precipitação, entre outros. Este método de medição de fluxos de covariância de vórtices turbulentos (também conhecido como *Eddy Covariance* em inglês) é a principal ferramenta de monitoramento para medir a troca de CO₂ de ecossistemas (TLE ou NEE em inglês). Este, por sua vez, é conhecido como o saldo do fluxo de CO₂, no qual verifica-se a respiração do ecossistema (liberação de CO₂) menos a fotossíntese (captção de CO₂ através da fotossíntese para a geração de biomassa).

No método de covariância de vórtices turbulentos, o fluxo de ar pode ser considerado como um fluxo horizontal que possui vários redemoinhos. Cada redemoinho de ar possui suas características de temperatura, umidade, concentração de CO₂ entre outras informações, incluindo o movimento vertical do ar, Figura 3. Os movimentos desses redemoinhos que sobem e descem, transportando os gases tal qual o CO₂, que é medido em vários setores da torre. Desta forma, é possível quantificar quantas moléculas de qualquer gás estão se movendo verticalmente na atmosfera ao longo do tempo, por meio da velocidade de ascensão ou descensão dessas moléculas.

Figura 3. Exemplificação dos vórtices turbulentos.

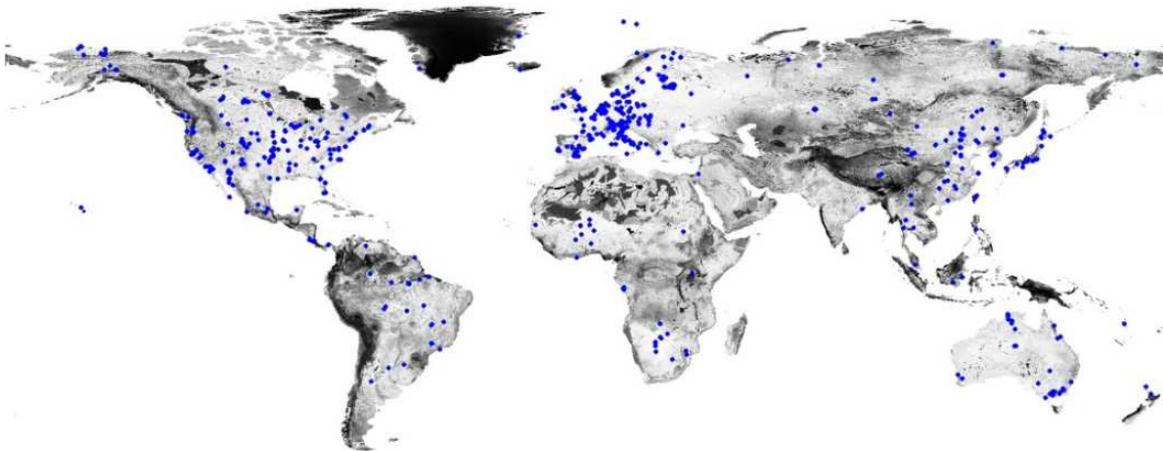


Fonte: (BURBA, 2013)

A metodologia da estimativa de CO₂, por meio da covariância de vórtices turbulentos, foi desenvolvida como um método alternativo para avaliar o saldo de ecossistemas de CO₂ (RAVINDRANATH e OSTWALD, 2007). Essa diferença, entre o dossel e a atmosfera, calcula a mudança de CO₂ entre a vegetação e a atmosfera por meio da medição da covariância entre as flutuações na velocidade vertical do vento e a razão na mistura de CO₂ (BALDOCCHI *et al.* 1988). Os fluxos medidos correspondem, então, a uma taxa média da troca de CO₂ da torre de fluxo. A área amostrada a partir deste método possui a denominação de “pegada de fluxo”, que pode ser de uma dimensão de metros a quilômetros, oferecendo informações sobre as trocas de CO₂ para um determinado ecossistema, em uma escala de tempo que pode variar de segundos a anos (SCHMID, 1994; WOFSY *et al.* 1993; BALDOCCHI *et al.* 2001).

Para fins de pesquisa, optou-se pelo método de fluxos turbulentos para realizar as medições de fluxo de gás CO₂, uma vez que este método mede diretamente o saldo do fluxo de dióxido de carbono de um ecossistema, além de ter sua eficácia comprovada enquanto método (WOFSY *et al.*, 1993; GRECO e BALDOCCHI, 1996; VALENTINI *et al.*, 1996). À medida que tal método se estabelece enquanto o mais confiável até o momento atual, criou-se uma rede chamada de EUROFLUX em 1996, no intuito de compreender a troca de CO₂ na região da Europa e, eventualmente, estabeleceram-se outros programas de monitoramento ao redor do mundo, inicialmente com a AmeriFlux em 1997 (VALENTINI *et al.*, 2000). Posteriormente, a NASA financiou um projeto para integrar todos os dados provenientes de torres de fluxo com a FLUXNET em 1998, buscando atender a demanda da comunidade científica para a centralização dos dados. Em 2002, o FLUXNET foi adicionado ao sistema de arquitetura de observação da NOAA (NOSA em inglês). Atualmente, a rede conta com a contribuição de mais de 500 torres de observação espalhadas pelo mundo, como mostra a Figura 4:

Figura 4. Localização das torres de fluxo de carbono registradas na FLUXNET



Fonte: (NASA. s.d.) <https://fluxnet.fluxdata.org/about/>

Este programa, a FLUXNET, permite que vários pesquisadores acessem a base de dados para compreender a magnitude, a localização, o tempo, o comportamento e as causas que originam as fontes e os sumidouros de carbono nos ecossistemas. Por meio de tal programa, as medições são realizadas a cada trinta minutos ou a cada hora. Entretanto, estes equipamentos estão sujeitos a diversas falhas no processo de coleta das informações, uma vez que a captação dos dados envolve inúmeras etapas que se interconectam. Os erros de captação mais comuns

são os de calibrações e as falhas técnicas dos equipamentos, resultando em lacunas de dados nas séries temporais.

Desta forma, para evitar a utilização de dados falhos ou inconsistentes, as verificações de qualidade dos mesmos se baseiam em testes estacionários com outros equipamentos e na detecção de picos ou baixas de dados que levam à rejeição destas medições, gerando lacunas adicionais no registro de dados. Desta maneira, somando-se as falhas de medição com os dados que não foram levantados devido a outros erros técnicos, tem-se expressivas lacunas de dados. Considerando este problema, inúmeras formas de preencher as lacunas de dados foram propostas ao longo dos anos.

Desde o trabalho pioneiro de Falge *et al.* (2001), várias técnicas surgiram, visando o preenchimento destas lacunas, não sendo possível encontrar na literatura uma técnica plenamente consolidada para realizar esse procedimento. Assim, uma gama de técnicas distintas pode ser encontrada no abrangente estudo comparativo realizado por Moffat *et al.* (2007), que relaciona técnicas para o preenchimento de lacunas de dados dos fluxos de carbono e de MCVT. Dentre as distintas metodologias apontadas nesse estudo, temos: as abordagens de interpolação; o preenchimento de lacunas por meio de técnicas probabilísticas; a utilização de tabelas de consulta; as técnicas de regressão não lineares; o preenchimento das lacunas por meio de redes neurais artificiais. O fato de não haver uma técnica plenamente consolidada, dificulta a realização da síntese dos resultados destes estudos, uma vez que as perspectivas e as inconsistências associadas a cada técnica ainda não são amplamente conhecidas (MORGENSTERN *et al.*, 2004).

Com isso, a instalação destas torres e a inserção dos dados no portal FLUXNET ainda tem sido módica, considerando-se a importância destes dados para em relação à urgência climática atual. Dentre as principais causas desta insuficiência, podemos citar os limites colocados ao financiamento de projetos, à capacitação de investigadores para analisar os dados e a falta de uma metodologia geoestatística padrão. Portanto, ainda não é possível medir os fluxos de CO₂ em todo o planeta por meio de uma metodologia única. Por outro lado, a rede de torres tem sido ativamente coordenada na comunidade científica e, mesmo com estas limitações, é possível deduzir certas informações sobre os padrões espaciais de fluxos de carbono nos locais de pesquisa em diferentes regiões e vegetações (RUNNING *et al.* 1999). Sendo assim, os fluxos de carbono e água só podem ser espacialmente integrados se combinadas

as medições das torres de vórtices turbulentos com modelos de ecossistemas e biofísicos, juntamente às medições por meio das imagens de satélite (RUNNING *et al.* 1999).

4.3 Modelagem do fluxo de carbono usando imagens de satélite

É provável que o fator-chave fundamental para a compreensão das mudanças climáticas e também o foco de maior interesse prático para a humanidade, compreende-se na mudança da produtividade biológica terrestre. Em outras palavras, a atividade biológica, assim como sua produção, é a fonte de todos os alimentos, fibras e combustíveis, atribuídos pelos seres humanos enquanto relações de interdependência, definindo de maneira fundamental a habitabilidade da Terra (RUNNING *et al.* 2000).

No entanto, o progresso na modelagem do ciclo de carbono mundial é difícil de ser mensurado, devido a fatores como a falta de dados observacionais adequados e de parametrização, bem como a falta de validação dos modelos propostos por meio de dados de campo (SCURLOCK *et al.* 1999). A base histórica da utilização das imagens de satélite para o cálculo de produção primária da vegetação é usualmente baseada em três inferências: a primeira é a noção de que a produção primária líquida está diretamente relacionada à energia solar absorvida; a segunda inferência é a correlação entre energia solar absorvida e a detecção por meio dos índices de vegetação; e a terceira inferência é a possibilidade de verificar as causas da variação na produção primária líquida (RUNNING *et al.* 2000).

Quanto às escalas espaciais maiores, nem a magnitude dos fluxos de carbono, tampouco a sua sensibilidade às variações biofísicas, são ainda adequadamente caracterizadas por sensoriamento remoto. Ainda assim, o sensor MODIS (popularmente utilizado para esse tipo de estudo) tem sido amplamente utilizado no cálculo da produção primária bruta e líquida (PPB / PPL) da vegetação global terrestre, com base apenas na eficiência do uso da luz. (FRIEDL *et al.*, 2010; RUNNING *et al.*, 2004; MONTEITH, 1962).

Neste contexto, tem crescido o interesse em usar dados dos fluxos de carbono com o intuito de validar e refinar os parâmetros usados em estimativas de produção primária, baseadas em imagens orbitais. Acredita-se que o maior desafio desta proposta está na incompatibilidade inerente das escalas espaciais e temporais das imagens de satélite em relação às medições realizadas em campo. Como apontam os autores Gockede *et al.* (2004) e Schmid (1994), os fluxos de carbono medidos em campo são amostrados em alta frequência temporal, enquanto a

escala espacial da amostragem de fluxos de carbono, pelo método de Vórtices Turbulentos (VT), varia de centenas de metros até a quilômetros quadrados, sofrendo variações devido a fatores como a estabilidade atmosférica e a velocidade do vento. Ainda assim, o uso das torres possui a vantagem de as medições serem menos afetadas pelas condições atmosféricas adversas e pela presença de nuvens, que impedem a observação por satélite ou aéreas em regiões de mata tropical (SANCHEZ-AZOFEIFA *et al.*, 2017).

Por outro lado, as medições baseadas em imagens de satélite possuem uma abrangência territorial mais extensa, mesmo que as imagens gratuitas possuam resolução espacial e temporal limitada, o que pode afetar a aplicação do método. Com isso, a maioria dos locais onde se encontram as torres de medição de fluxo de carbono, possuem dispositivos de amostragem óptica no nível do solo em diferentes alturas em relação ao dossel, de modo a reduzir a incompatibilidade entre os dados obtidos por satélite e pelas torres de fluxo (EKLUNDH *et al.*, 2011 e HUENNRICH *et al.*, 1999).

A unificação dos dois métodos de estimativa do fluxo de carbono se torna promissora, pois considera a utilização complementar destes dados para, posteriormente, realizar extrapolações para além da área de validação dos resultados. Especialmente na região amazônica, é possível notar a publicação de uma quantidade significativa de estudos utilizando técnicas de sensoriamento remoto para o cálculo do fluxo de carbono, como por exemplo, a obra de Wang *et al.* (2011), que utilizou dados do sensor MODIS juntamente aos dados micrometeorológicos, demonstrando o potencial da modelagem GLOPEM-CEVSA para quantificar os padrões espaciais e a dinâmica temporal das fontes e sumidouros de carbono dos ecossistemas terrestres, com alto grau de confiabilidade de valores observados com um intervalo r de 0,64 a 0,87.

Vale destacar também o estudo elaborado por Ferreira (2015), no qual parte do procedimento desta pesquisa se baseia para desenvolver uma metodologia de quantificação dos gases do efeito estufa (CO₂ e CH₄), por meio de índices de vegetação em relação ao reservatório da Serra do Facão, no estado de Goiás. A partir deste estudo, notou-se a necessidade da validação dos dados e de como estes índices se correlacionam aos dados micrometeorológicos. Ademais, observou-se que a temperatura combinada com uma alta produtividade primária líquida foram fatores importantes para estimar a emissão de metano nas áreas que estavam sendo alagadas (FERREIRA, 2015). Os resultados também mostram uma correlação com outras pesquisas realizadas anteriormente em reservatórios hidrelétricos,

demonstrando que há alta variabilidade espacial e temporal na emissão de metano e de outros gases do efeito estufa.

Outras pesquisas que relacionam dados de sensoriamento remoto com a validação de dados *in situ*, têm demonstrado grande potencial para desvendar as relações do fluxo de carbono com as áreas de preservação nos mais diversos ecossistemas. Neste caso, Dabrowska-Zielinska *et al.* (2016) demonstraram que a troca de CO₂ de ecossistemas pode ser avaliada por meio da utilização de dados combinados do Sentinel-1 VV e VH. Estes autores encontraram uma relação significativa entre o TLE e o coeficiente de retrodifusão (σ°), calculado a partir dos dados TSX ($R^2 = 0,53$), encontrando uma relação direta entre os valores de absorção de CO₂ e o aumento nos valores de NDVI e do coeficiente de retrodifusão.

Outros estudos promissores na modelagem do fluxo de carbono em regiões de floresta tropical também estão presentes na literatura científica. O estudo de Celes (2017) é um deles, que utiliza uma combinação de dados de sensoriamento remoto, aplicando uma modelagem matemática para quantificar o erro propagado, elaborando uma extrapolação para o carbono da floresta Ducke. Até o presente momento, nenhum estudo semelhante foi implementado para a reserva de Uatumã, a partir dos dados da Torre Alta da Amazônia.

4.4 Levantamento indireto por meio dos Índices de Vegetação

4.4.1 O Índice de Vegetação da Diferença Normalizada (NDVI) e sua correlação com os fluxos de carbono

Huemrich *et al.* (1999) demonstraram pela primeira vez o uso das propriedades de refletância acima do dossel de regiões boreais, por meio da radiação fotossinteticamente ativa (PAR) e do infravermelho próximo, para derivar um índice diário de vegetação de diferença normalizada (NDVI), com a finalidade de rastrear a fenologia das áreas de estudo. O índice foi elaborado por Tucker (1979) e varia entre os valores de -1 a +1. Os valores menores e próximos a zero representam uma diminuição ou ausência de cobertura vegetal, indicando feições como o solo exposto e corpos d'água. Valores próximos a 1 descrevem a cobertura vegetal disponível.

Desde então, o NDVI é um dos índices mais utilizados para monitorar a dinâmica da vegetação em escalas regional e global (VRIELING *et al.*, 2013). Este também é amplamente utilizado para monitorar as mudanças sazonais da vegetação em diversos ecossistemas, além de

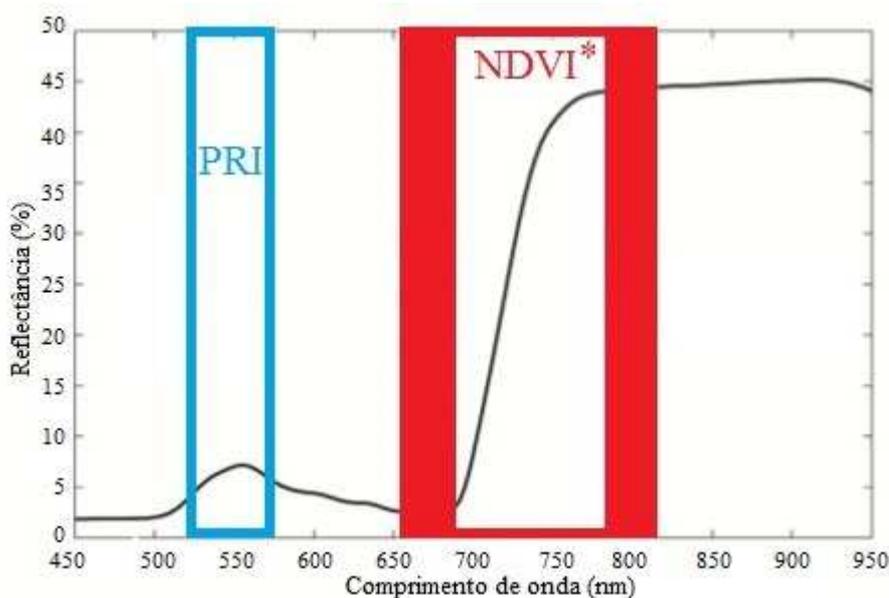
ser empregado em estimativas de produtividade de biomassa, como demonstrado nos estudos de Fensholt *et al.* (2004) e de Tittebrand *et al.* (2009). Tais índices também são usados como alternativa para preencher lacunas de registros de fluxos de carbono (SOUDANI *et al.*, 2012; NESTOLA *et al.* 2016).

O NDVI é calculado com base em duas faixas espectrais, que estão centralizadas nos comprimentos de ondas do vermelho e infravermelho, Figura 5. De acordo com Gamon *et al.* (1992), o valor de R é o fator de refletância do comprimento de onda da banda espectral utilizada. Esse método foi elaborado como uma forma de avaliar, a partir de dados de sensoriamento remoto, a eficiência fotossintética das folhas, por meio da refletância em bandas curtas (PEÑUELAS *et al.*, 1995).

4.4.1 O Índice de Refletância Fotoquímica (PRI) e sua correlação com os fluxos de carbono

O índice PRI já foi aplicado em processos fisiológicos medidos no nível foliar e, em escala maior, na análise do fluxo de ecossistemas inteiros, como demonstrado nos estudos de Peñuelas *et al.* (2011), de Drolet *et al.* (2011) e NICHOL *et al.* (2000).

Figura 5. Gráfico dos Índices de Refletância do NDVI e PRI



Elaboração, GARCIA, E. A. B., (2020).

Originalmente, o PRI havia sido utilizado para detectar a assinatura espectral de pigmentos do ciclo da xantofila, que é responsável pela dissipação não fotoquímica (NPQ), dispersando o excesso de luz em forma de calor (DEMMIG-ADAMS e ADAMS, 1996). Assim, quando ocorre uma queda na refletância no fator a 531 nm, há a depoxidação do ciclo de xantofila (GAMON *et al.*, 1990). Quando essa depoxidação ocorre, há um aumento na eficiência da fotossíntese, ampliando a captura de CO₂ na atmosfera para a produção de biomassa.

A utilização do índice PRI para a medição indireta de gases do efeito estufa (GEE) tem se demonstrado promissora. Principalmente pelo fato deste índice medir o isopreno espalhado pela atmosfera, o qual corresponde à maior fração dos compostos orgânicos voláteis biogênicos (COVBs). Este composto químico de carbono e hidrogênio é emitido pela vegetação, sendo utilizado em pesquisas relacionadas a química atmosférica e ao balanço de carbono. Assim, o isopreno desempenha um papel crucial na formação da poluição fotoquímica (*smog*), do ozônio, de alguns poluentes secundários – como nitratos de peroxiacila – e de aerossóis orgânicos secundários (CHAMEIDES *et al.*, 1988; FUENTES *et al.*, 2000; ANDREAE, 1997). Isto se deve ao fato de que emissões de isopreno influenciam substancialmente a química, a composição atmosférica e os processos do sistema climático da troposfera (PENUELAS E LLUSIA, 2003).

Um estudo conduzido por Filella *et al.* (2018), comparou séries temporais utilizando o índice PRI por meio do sensor MODIS com as emissões de isopreno medidas pelas torres de fluxo de carbono. Nesse estudo, o índice demonstrou forte correlação com as emissões de isopreno e também foi capaz de detectar o pico anual das emissões no período de seca. Ao fim, os autores constataram que o PRI é um índice promissor para estimar as emissões de isopreno quando complementado por informações em campo. Esta possibilidade de utilizar o levantamento indireto a partir do sensoriamento remoto, baseia-se na relação inversa entre a emissão de isoprenóides e a eficiência do uso da luz (LUE em inglês). Isto ocorre pelo fato do PRI ter sido amplamente testado para estimar o LUE desde o nível foliar até em ecossistemas inteiros, considerando diferentes escalas temporais (PENUELAS *et al.*, 2011; ZHANG *et al.*, 2016). O LUE fornece uma medida para quantificar o uso da luz incidente para a fotossíntese da planta. Assim, a eficiência no uso da luz está relacionada diretamente à capacidade de captação de carbono e às taxas de crescimento vegetativo e, de certa forma, à absorção

fracionada de radiação fotossinteticamente ativa (FAPAR). Portanto, esses índices ajudam a estimar a taxa de crescimento e a produção da vegetação.

4.5 Modelagem utilizando regressão linear múltipla

A estatística fornece uma variedade de ferramentas diferentes para inferir hipóteses de problemas relacionados à previsão. Suas aplicações nas ciências ambientais vão desde o gerenciamento de dados espaciais e riscos ambientais até a aplicações em estudos sobre fluxos de carbono e dados meteorológicos. Desta forma, a estatística aplicada aos estudos de fenômenos ambientais é comumente descrita como geoestatística, cuja origem etimológica designa o estudo estatístico dos fenômenos naturais. Neste caso, “geo” refere-se ao estudo da terra e dos fenômenos naturais, já “estatística”, ciência que estuda desde a coleta até a análise, refere-se à interpretação numérica dos dados que, para esta pesquisa, relacionam-se especificamente aos dados de modelagem dos fluxos de carbono.

Os primeiros relatos de estudos referentes a geoestatística provêm de 1950 e 1960 sendo que, de acordo com Krige (1951) e Journel e Huijbregts (1978) estes estudos visaram melhorar a avaliação de reservas em depósitos minerais. Tal campo de atuação abrange atualmente os campos da área de conhecimento descrita como geociência (tal como a geologia, geoquímica, hidrogeologia, pedologia, climatologia, hidrografia, oceanografia, sensoriamento remoto, agricultura entre outras mais). Desta forma, a geoestatística trata-se de um conjunto de disciplinas que lidam com a análise de dados numéricos e inferências estatísticas sobre o espaço-tempo, com a finalidade de extrair informações que permitam realizar correlações, inferências, previsões e visualizar padrões sobre o objeto de estudo.

A geoestatística se alinha à premissa de Tobler (1970, p.236), afirmando que “tudo está relacionado com o todo, mas as coisas próximas estão mais relacionadas do que as coisas distantes”. De fato, uma das principais características dos estudos geoestatísticos reside na distribuição estruturada dos dados no espaço e no tempo da área a ser pesquisada, podendo relacionar um ou mais fatores, como por exemplo, as variáveis pesquisadas neste estudo que são os dados meteorológicos, dados do domínio morfoclimático e dados de sensoriamento remoto, com diferentes unidades de medidas, escalas e variação temporal.

Modelos geoestatísticos espaço-temporais, tais como descritos por Kyriakidis e Journel, (1999), fornecem uma estrutura probabilística para análise de dados e predições que se

baseiam na dependência conjunta espacial e temporal das observações. Mediante o exposto, para a elaboração desta pesquisa utilizou-se diferentes métodos estatísticos para realizar o preenchimento de lacunas de dados da série temporal, procedendo no tratamento dos dados de modo a selecionar os dados mais contundentes com o proposto pela pesquisa e organizá-los estruturalmente para posteriormente verificar correlações.

O foco das análises de regressão é entender como o valor de uma ou mais variáveis dependentes, é alterado à medida que se altera uma ou mais variáveis independentes, enquanto outras variáveis se mantêm fixas. A variável dependente é normalmente representada por y , dentro de um conjunto de outras variáveis x , que são úteis para prever uma variável dependente (CHATTERJEE e SIMONOFF, 2013). Assim, para que o modelo de regressão linear seja válido, sua variável dependente deverá ser uma variável contínua, como em uma série temporal de dados (CAMERON, 2005). Uma série temporal é uma sequência cronológica ou orientada no tempo, referente a observações de uma variável de interesse. Sua análise compreende métodos para analisar dados de séries temporais para extrair informações de correlações significativas e outras características dos dados levantados.

Uma análise de regressão linear múltipla segue praticamente o mesmo critério de uma regressão linear, no entanto, é chamada linear devido a equação ser uma função linear da regressão de coeficientes desconhecidos. Uma regressão linear múltipla possui uma variável dependente e k variáveis independentes, como demonstrado na Equação 1 abaixo:

$$\hat{Y} = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p \quad (1)$$

\hat{Y} = A variável dependente ou regressando

X_i = A variável independente ou regressor

β_0 = o intercepto ou constante do modelo

β_i = o coeficiente angular do modelo

É importante destacar que a medição dos coeficientes de correlação não leva em conta possíveis influências entre as variáveis que sejam não x e Y . A utilização dessa metodologia estatística para a análise de séries históricas é bastante difundida nas pesquisas acadêmicas e para diversos usos em outras áreas da ciência. No âmbito das ciências climáticas e de

sensoriamento remoto, o uso dessa metodologia para validar dados e realizar previsões sobre eventos climáticos, fluxos de energia e fluxos de carbono tem sido amplamente difundido.

A utilização desse método para a validação, previsão e preenchimento de lacunas temporais mostra-se bastante confiável. Uma pesquisa realizada por Coutinho *et al.*, (2018), o qual estimou e preencheu falhas reais de dados meteorológicos pertencentes a quatro regiões do estado do Rio de Janeiro, utilizando Redes Neurais Artificiais (RNA) e Perceptrons de Múltiplas Camadas (MLP), comparando-as com os resultados obtidos por modelos de Regressão Linear Múltipla (RLM) e com a Média das Regiões (MD). A conclusão da pesquisa foi que os resultados alcançados pelo MLP se demonstraram convincentes, sendo superiores aos métodos de MD e MLR. No entanto, a pesquisa conclui que o MD e MLR apresentaram resultados satisfatórios com altos índices de correlação (r) e baixos erros médios (EMP) com os dados reais (COUTINHO *et al.*, 2018).

Por fim, um dos benefícios de utilizar os dados de fluxos de carbono e investigar a relação entre estes fluxos com fatores meteorológicos, tem sido a capacidade de demonstrar que, tanto a longo quanto a curto prazo, as tendências podem ser inferidas a partir dos dados gerados pela regressão linear múltipla (STOY *et al.*, 2009). Abordagens estatísticas para entender a relação entre essas variáveis (fluxo de carbono e dados meteorológicos) a partir de redes neurais como demonstrado por, Stoy *et al.*, (2009) e principalmente através de regressão linear (LAW *et al.*, 2002; HUI *et al.*, 2004) têm sido utilizados para entender as mudanças climáticas, criar modelos para compreender essas relações e prever possíveis cenários futuros.

5 MATERIAIS E MÉTODOS

A combinação de métodos diferentes nos quais se vinculam modelos processuais do ecossistema, concomitantemente às medições espaciais para se monitorar os fluxos de carbono em diferentes escalas, tornou-se uma abordagem confiável e com menor nível de incerteza. Os dados possuem uma vantagem tecnológica pelo fato de fornecer informações atualizadas com uma frequência de variáveis relacionadas a este tipo de monitoramento. Nesta estratégia, utilizamos os dados “de baixo para cima e de cima para baixo”, ou seja, dados observados no local próximo ao dossel e dados adquiridos por imagens de satélite, que podem ser ampliados espacialmente e temporalmente visando conclusões gerais e com baixo nível de incerteza.

Quando esses métodos são utilizados sinergicamente, as abordagens de cima para baixo e de baixo para cima aproveitam seus pontos fortes para compensar suas respectivas fraquezas, como demonstrado nos estudos de Cihlar, Denning e Gosz (2000). Na pesquisa de Ciais *et al.* (1995), utilizou-se várias fontes de dados para elaborar um modelo da biosfera que sejam consistentes com todas as observações de fluxos de carbono mundialmente. Na prática, esse modelo permitiu que se prevejam as variáveis observadas em locais onde as medições (baseadas em superfície ou satélite) estão disponíveis e, em seguida, foi possível encontrar valores dos parâmetros que minimizam a diferença geral com as medições. Ao combinar as técnicas “de baixo para cima e de cima para baixo”, é possível gerar uma distribuição espacial das fontes e dos sumidouros de carbono em diversas escalas, com altas resoluções espaciais e temporais de qualidade refinada, melhorando o entendimento do ciclo do carbono. Este tipo de abordagem permite a compatibilidade de escalas maiores, ou seja, para pequenas áreas.

Para a elaboração desta pesquisa utilizou-se o conceito de abordagem integrada para medições indiretas e diretas – dados de imagens orbitais e dados de medições diretas por meio de torres de observação – com o intuito de gerar modelos confiáveis de fluxo de carbono para a região amazônica. Isso foi realizado considerando que a absorção de CO₂ para a produção de biomassa está diretamente relacionada à radiação fotossinteticamente ativa absorvida (APAR) e à eficiência fotossintética desta unidade de radiação (PAR), que podem ser reduzidas em caso de estresses ambientais e hídricos, como baixas temperaturas (RUNNING *et al.*, 2004; YUAN *et al.*, 2014).

Devido à relação existente entre a fração de radiação fotossinteticamente ativa absorvida (APAR) e os índices de vegetação, estes índices são utilizados como um método indireto de medição de produção de biomassa (RUNNING *et al.*, 2004; YUAN *et al.*, 2014, ZHOU *et al.*, 2002). Os índices de vegetação mais utilizados para este fim na literatura científica são o Índice de Vegetação por Diferenças Normalizadas (NDVI) e o Índice de Vegetação Aprimorada (EVI), empiricamente conhecidos como boas métricas de biomassa verde (MYNENI *et al.*, 1994; NESTOLA *et al.* 2016; YAN *et al.* 2015; ZHOU *et al.*, 2014). Contudo, a validação desses modelos requer medidas de troca líquida de CO₂ de um ecossistema, provenientes de uma base de dados medidos na superfície (RUNNING *et al.*, 1999)

Para a validação destes dados, utilizou-se os dados do Observatório da Torre Alta da Amazônia (ATTO em inglês), por meio de levantamento direto dos fluxos de gás carbônico. A torre foi instalada em uma região preservada de floresta tropical e domínio morfoclimático da

Amazônia, localizando-se aproximadamente a 150 km a nordeste da cidade de Manaus, relativamente isolado de interferências antrópicas. A torre ATTO é uma torre de 325 metros de altura e além desta, há duas torres de 80 metros que estão em operação no local desde 2012. As torres realizam medições que incluem temperatura, dinâmica dos ventos, precipitação, fluxos de água e energia, componentes de turbulência, perfis de temperatura do solo e fluxos de calor do solo, fluxos de radiação e visibilidade. As medições de gases incluem monitoramento contínuo de dióxido de carbono, monóxido de carbono, metano e ozônio em cinco a oito alturas diferentes, complementadas por uma variedade de espécies adicionais, medidas durante campanhas intensivas (por exemplo, Reatividade de VOC, NO, NO₂ e OH). As medições ópticas, microfísicas e químicas do aerossol estão sendo feitas acima do dossel, bem como no espaço do mesmo.

Sendo assim, esta pesquisa avalia a aplicabilidade do método de levantamento indireto com a validação de dados observacionais diretos, para medir o fluxo de CO₂ sobre um dossel de floresta tropical na Reserva de Desenvolvimento Sustentável (RDS) do Uatumã no estado da Amazônia. O fluxo de CO₂ medido por meio do levantamento indireto foi comparado com o fluxo de CO₂, medido através da torre ATTO. A variabilidade anual dos fluxos de CO₂ também foi contabilizado para gerar os modelos de fluxo de dióxido de carbono para a reserva. Ademais, as alturas das medições da torre foram feitas a uma altura de 84 metros e o período de tempo do conjunto de dados variou de 2017 a 2019, utilizando-se principalmente os dados do período de seca.

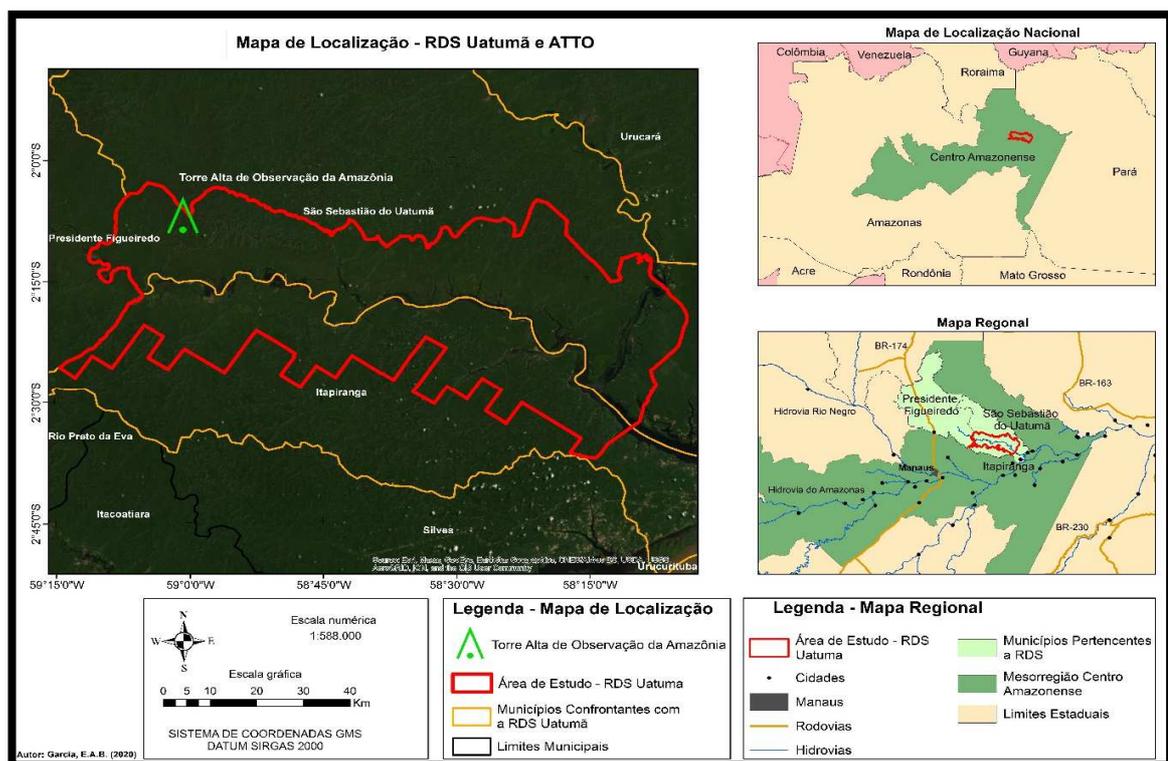
Os materiais e métodos utilizados nessa pesquisa estão divididos em subtítulos que serão apresentados primeiramente a partir a área de estudo e descrição do meio físico da RDS e, posteriormente, a partir da caracterização da ATTO e dos dados obtidos. Após essa breve explanação, será apresentado o fluxograma dos procedimentos metodológicos e o respectivo detalhamento dos procedimentos que serão apresentados nos capítulos e subcapítulos abaixo.

5.1 Área de estudo

Esta pesquisa foi realizada na Reserva de Desenvolvimento Sustentável de Uatumã (RDS – Uatumã). A reserva foi criada em junho de 2004, com uma área total de 424.430

hectares e localizada aproximadamente a 250 km a nordeste da cidade de Manaus, próximo aos municípios de Itapiranga e São Sebastião do Uatumã, nas coordenadas 2° 27' a 2° 4' S; 59° 10' a 58° 4' W). A reserva de Uatumã foi criada por meio do decreto nº 24.295 do Estado do Amazonas em 25 de julho de 2004, como parte de uma estratégia do governo do estado do Amazonas para conservar os ecossistemas florestais, além de garantir a subsistência de famílias ribeirinhas e tradicionais (AMAZONAS, SDS, 2009). O conjunto de dados diretos que foram utilizados nesta pesquisa foram cedidos pelo INPA – Instituto Nacional de Pesquisas na Amazônia provenientes das medições realizadas pelos equipamentos instalados na *Amazon Tall Tower Observatory* — ATTO, ou Observatório de Torre Alta da Amazônia, em Português, como mostra a Figura 6:

Figura 6. Mapa de localização – RDS Uatumã e ATTO / AM - 2020



Fonte: (<https://www.attoproject.org/pt/>), Elaboração, GARCIA, E. A. B., (2020).

2.1.1 Caracterização do meio físico da área de estudo

O clima da área de estudo é considerado como tropical com a sigla AmW da classificação Köppen, com temperaturas variando de 20 °C a 38 °C. Já a precipitação média anual é de 2.077 mm (AMAZONAS, SDS, 2009).

Geologicamente, Figura 7, a bacia de drenagem onde se encontra a RDS Uatumã é representada principalmente pelas unidades geológicas pré-cambrianas provenientes do Arqueano até o Proterozóico Superior (ELETRONORTE/IBAMA 1996). Apesar de ocorrerem na região, há uma incidência menor de sedimentos paleozóicos pertencentes à sinéclise do Amazonas, com a presença de coberturas lateríticas do terciário e de sedimentos aluviais do período recente que acarreta no preenchendo dos fundos dos vales dos rios e igarapés (ELETRONORTE/IBAMA 1996). Com base nos dados georreferenciados proveniente da CPRM (Companhia de Pesquisa de Recursos Minerais), a RDS possui a presença de Terraços Holocênicos (Sigla Q2t) na região onde se encontra o Rio Uatumã e a unidade geológica Alter do Chão (Sigla Kac) ao se afastar do rio. Também é possível notar falhas de rejeito direcional nos sentidos NE e SO e falhas de inversa/empurrão no sentido NO e SE por onde o rio segue o curso.

Geomorfologicamente, a RDS está situado em duas unidades principais: baixos platôs da Amazônia e a planície amazônica. De acordo com Muller e Carvalho (2005), a região onde se encontra a RDS possui características de Peneplano Rebaixado (Pr)- sendo uma região extremamente peneplanizada, de um relevo baixo, que se encontra entre o peneplano granítico/vulcânico e a planície aluvionar, possuindo rochas aflorantes Grupo Anauá e do Grupo Iricoumé, além de apresentar uma superfície peneplanizada, bastante uniforme com a presença de suaves colinas com cotas inferiores a 50 metros. Através dos dados georreferenciados provenientes do IBGE (Instituto Brasileiro de Geografia e Estatística), Figura 8, a região da RDS Uatumã possui dois tipos principais de características em nível macro: a geomorfológica, a depressão do médio baixo do rio Amazonas e as Planícies Fluviais e/ou Fluvialacustres, ambas com características deposicionais.

Os solos possuem características dos latossolos (em áreas mais altas), argissolos (nas encostas), espodossolos (em áreas com perfis arenosos) e neossolos e gleissolos nas planícies de inundação do rio Uatumã e seus afluentes (RADAM BRASIL, 1978), Figura 9. Na área onde se localiza a RDS Uatumã, através de dados georreferenciados da EMBRAPA, é possível notar a presença de dois tipos de solos característicos da região amazonense. O primeiro com a sigla LAd34 – (LAd34 – Latossolos Amarelos Distróficos + Neossolos Quartzarênicos Orticos +

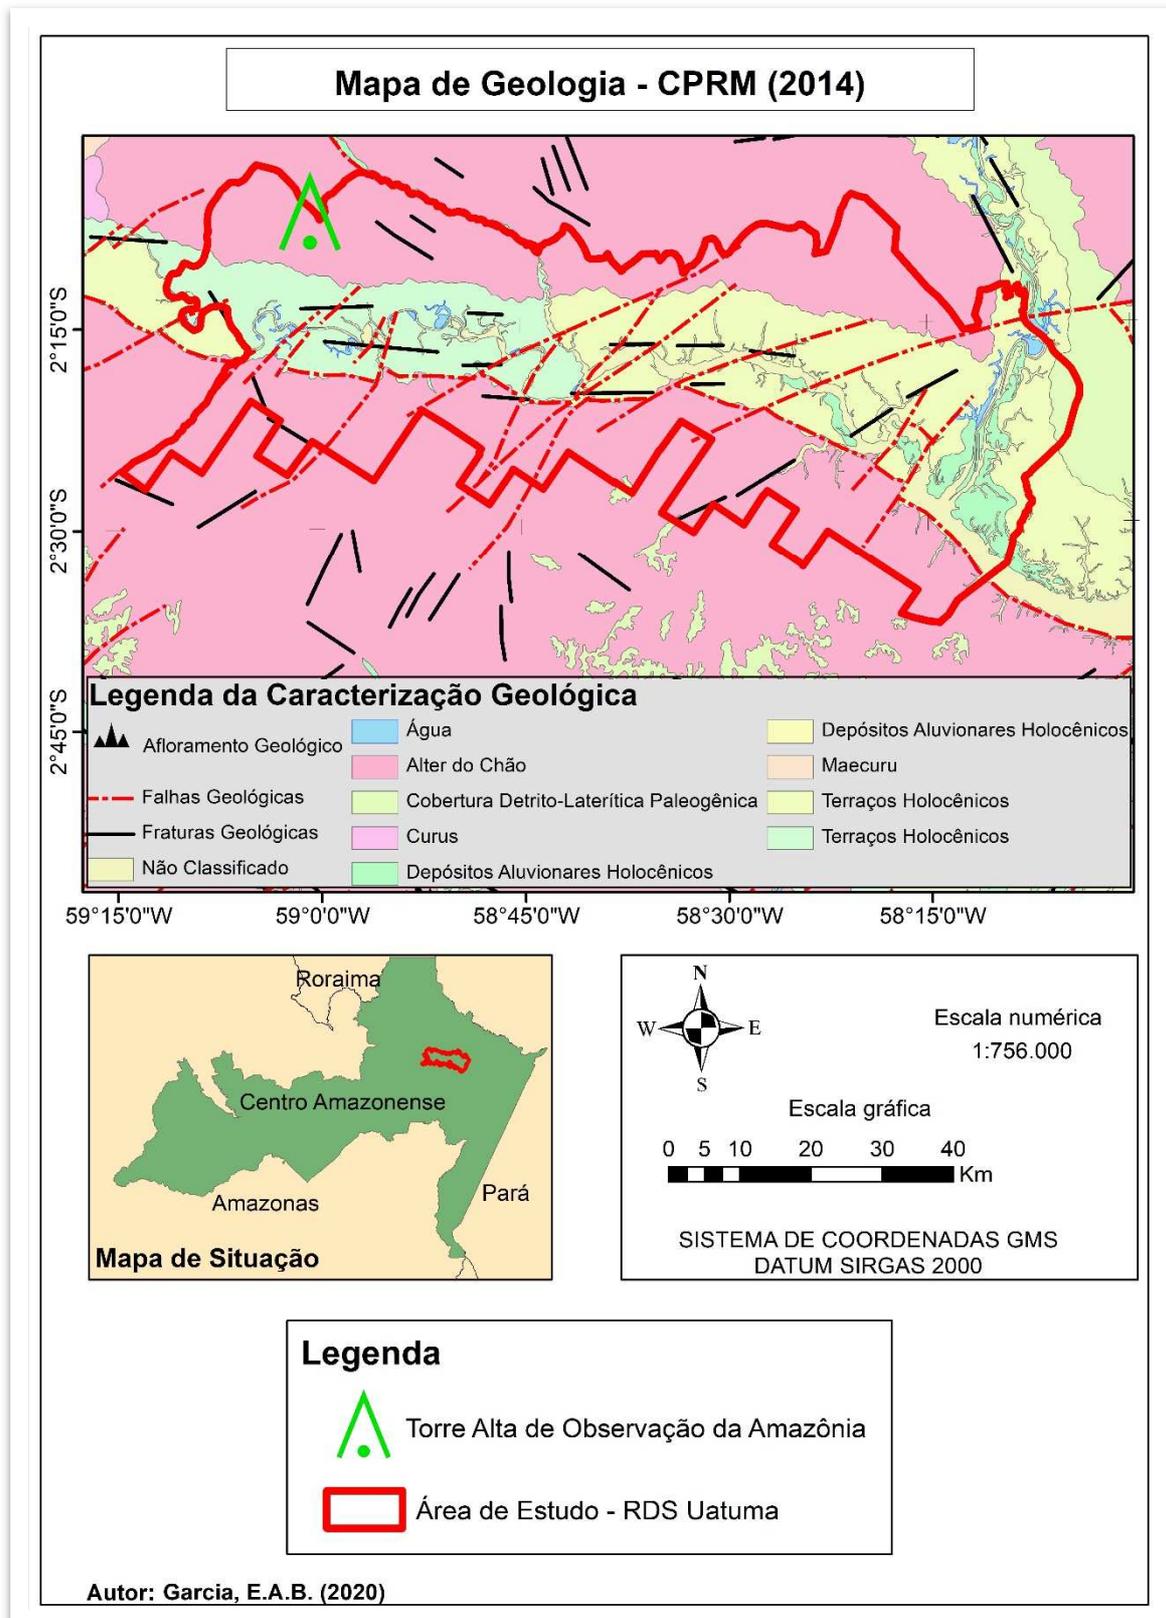
Plintossolos Háplicos Distróficos) e o segundo o LAd3 – (Latossolos Amarelos Distróficos + Argissolos Amarelos Distróficos). Ambos estão presentes nas proximidades do curso d'água principal, o rio Uatumã. Esse tipo de solo (Latossolos Amarelos Distróficos) estão bem distribuídos pelo do Brasil, porém, são nos platôs litorâneos e amazônicos onde se encontra mais ocorrência desse tipo pois, desenvolvem-se a partir de sedimentos do Grupo Barreiras (Plio-pleistoceno) e Formação Alter do Chão (Cretáceo) (KER, 1997).

Hidrograficamente, Figura 10, a bacia hidrográfica do rio Uatumã possui uma área de drenagem de aproximadamente 70.600 km² (ELETRONORTE/IBAMA 1996). Os principais cursos d'água que formam a bacia são os rios (também conhecidos como igarapés) Santo Antônio do Abonari, que possui uma área de drenagem de aproximadamente 1.626 km² e o igarapé Taquari que possui uma área de drenagem de aproximadamente 1.631 km² e possui como os afluentes principais os rios Pitinga e Jatapu (ELETRONORTE/IBAMA 1996). O rio Uatumã possui alta sinuosidade ao longo do seu curso além da bacia se encontrar coberta por florestas devido à presença da RDS. Apesar desta área ter baixa declividade, nota-se que nas proximidades da UHE Balbina e da Cachoeira Morena, é possível encontrar desníveis maiores existindo trechos favoráveis a quedas d'água (ELETRONORTE/IBAMA 1996). O Uatumã segue o sentido de norte-sul e posteriormente inflectindo para sudeste nas áreas onde ocorrem os maiores desníveis e declividades (ELETRONORTE/IBAMA 1996). O mesmo relatório do plano de manejo utilizado para a caracterização da RDS Uatumã destaca sobre a grande quantidade de cursos d'água na reserva:

A área da Reserva Biológica concentra elevado número de nascentes e de igarapés de pequeno porte, dentre os quais se podem citar: igarapés Esperança, Sumaúma, Tucumari e Jauari na parte leste e rios Pitinga e Pitinguinha ao norte (Figura 6). Os efeitos do remanso provocado pelo rio Amazonas sobre o Uatumã faz-se sentir até Cachoeira Morena (no auge da cheia), numa distância de 280 km desde sua foz. O regime hidrológico do rio Uatumã segue o mesmo padrão característico dos demais rios amazônicos, com um período de águas altas nos meses de abril a junho e outro, de águas baixas, nos meses de agosto a dezembro. (ELETRONORTE/IBAMA, 1996, p58).

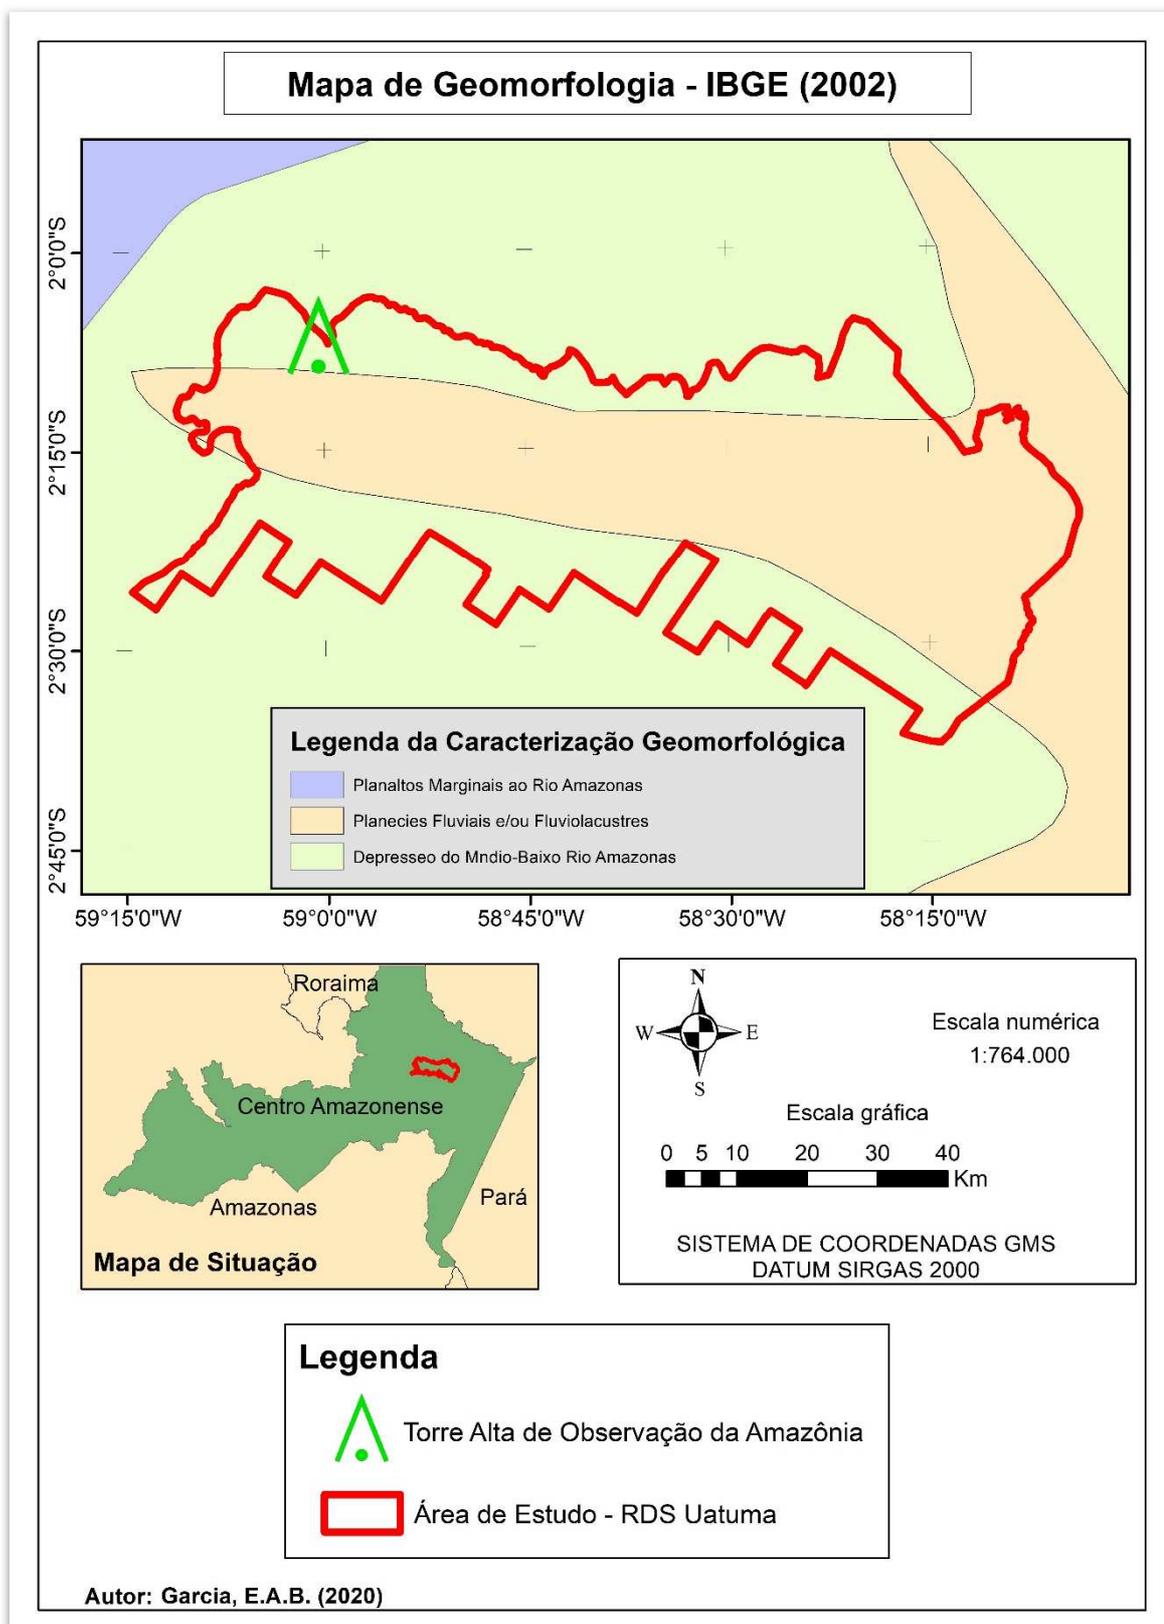
Vale ressaltar que a alta distribuição de drenagem com o alto índice pluviométrico dessa região permite que as florestas ombrófilas densas possuam áreas conhecidas como igapós, o igapós de pântanos de águas negras ou planície de inundações que possuem vegetação característica devido a regime fluvial (AMAZONAS, SDS, 2009; VELOSO *et al.*, 1991). A seguir, as figuras 7, 8, 9 e 10 mostram quatro principais aspectos que compõem a área da Reserva Biológica:

Figura 7. Mapa de caracterização geológica.



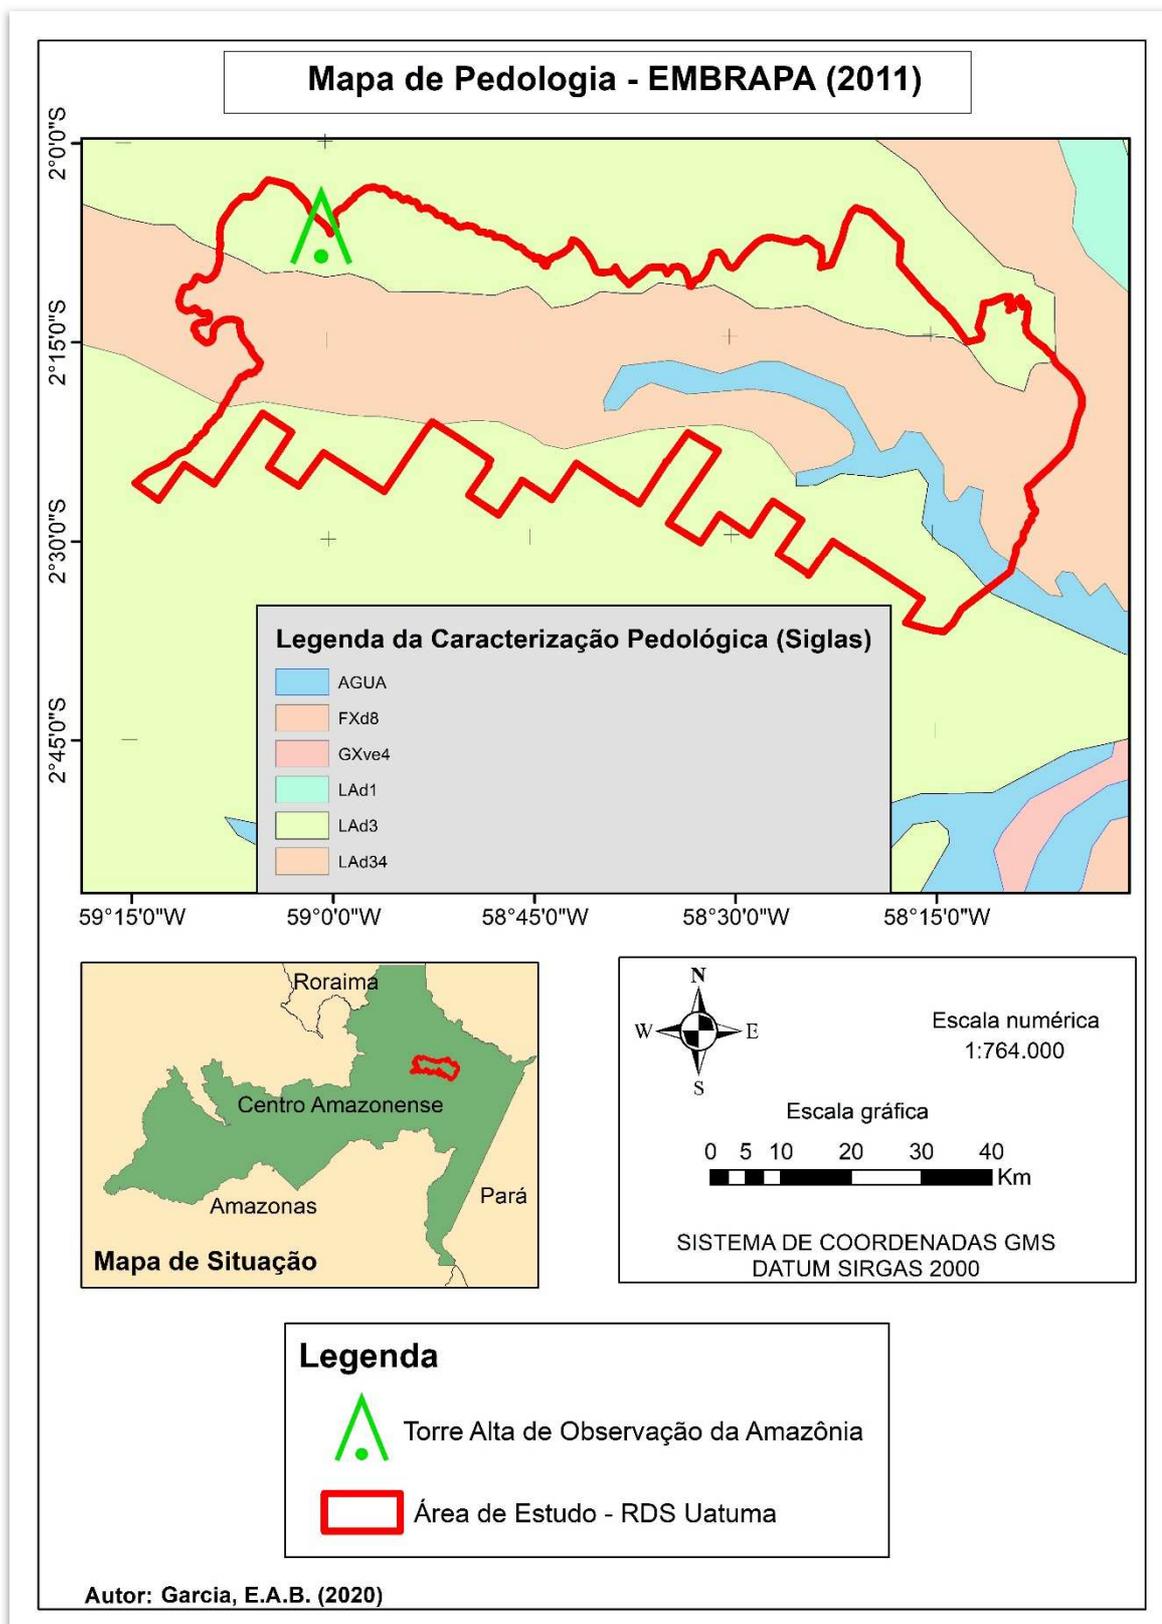
Elaboração: GARCIA, E. A. B. (2020).

Figura 8. Mapa de caracterização geomorfológica



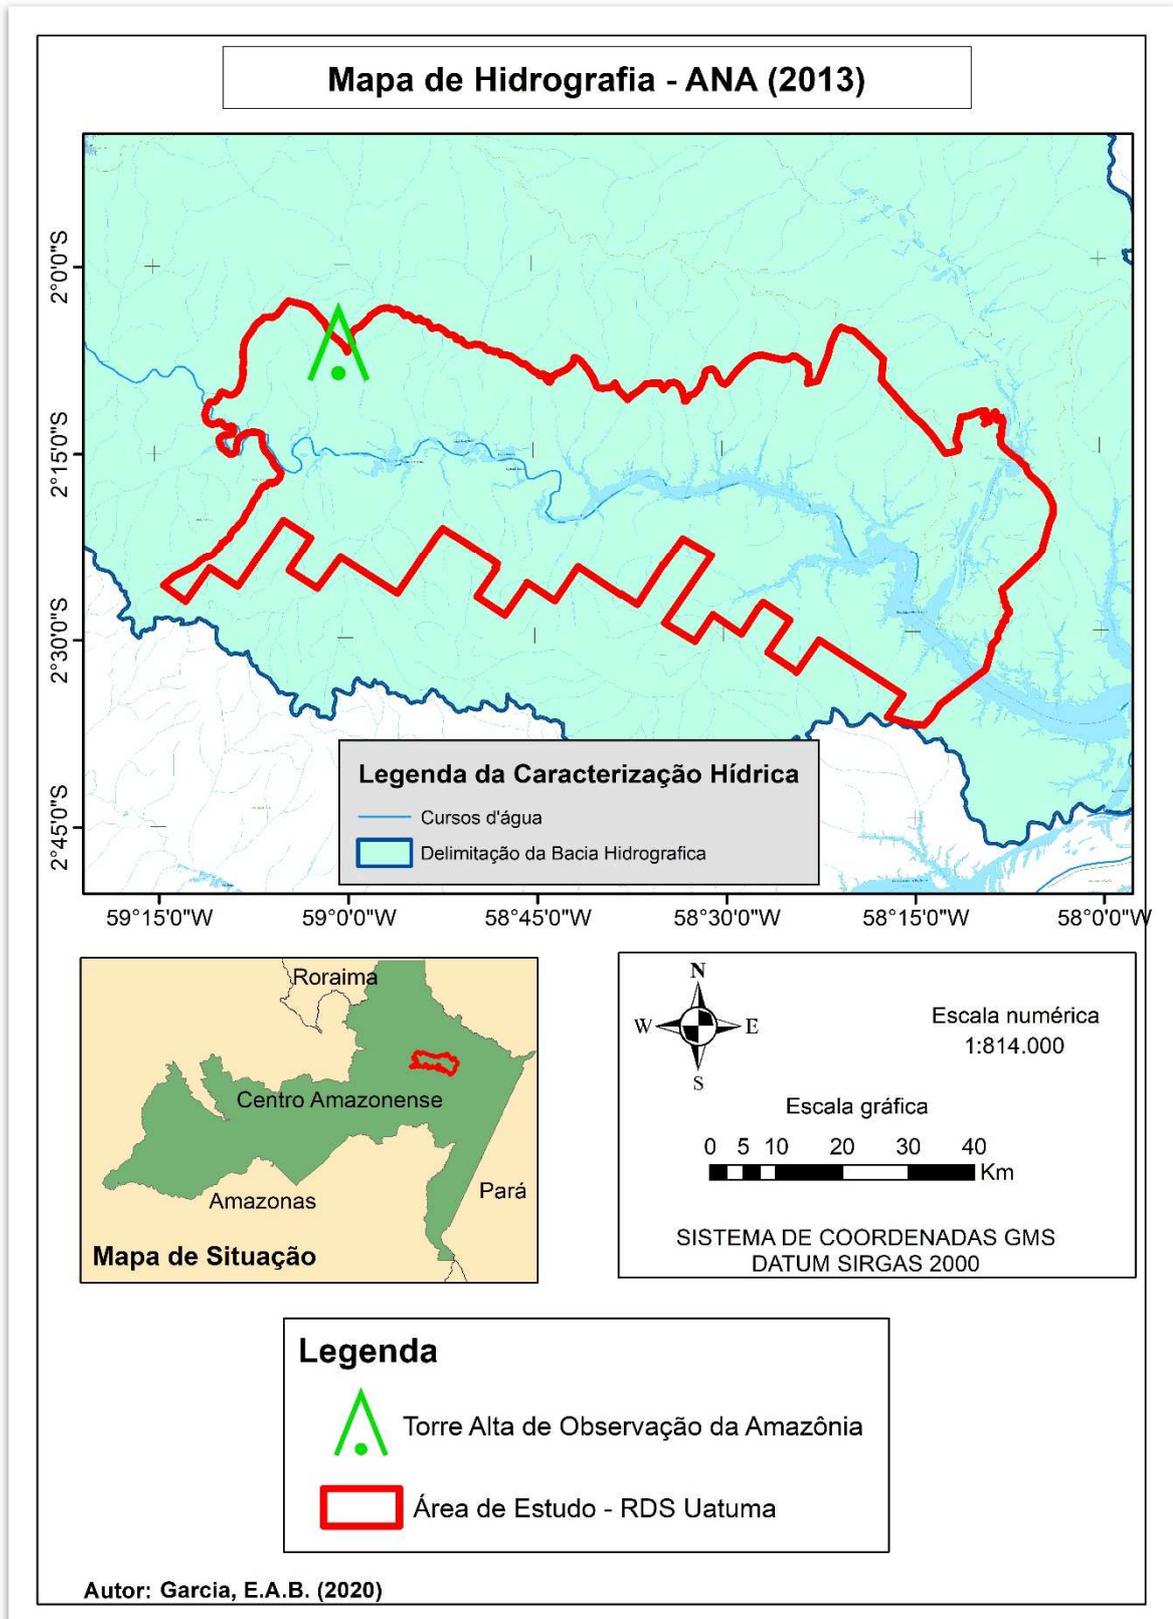
Elaboração: GARCIA, E. A. B. (2020).

Figura 9. Mapa de caracterização pedológica



Elaboração: GARCIA, E. A. B. (2020).

Figura 10. Mapa de caracterização hidrográfica



Elaboração: GARCIA, E. A. B. (2020).

5.2 Dados da Torre Alta de Observação da Amazônia (ATTO)

Os dados utilizados para a validação do método de levantamento indireto, utilizando índices de vegetação, são provenientes do INPA – Instituto Nacional de Pesquisas na Amazônia, através das medições realizadas pelo projeto *Amazon Tall Tower Observatory* — ATTO, ou Observatório de Torre Alta da Amazônia, em português, Figura 11. A torre possui uma altura de 325 metros e foi instalado em uma região da floresta tropical amazônica que está relativamente intocada. A torre está a aproximadamente 150 km a nordeste da cidade de Manaus entre os municípios de Presidente Figueiredo além de duas torres de 80 metros de altura que operadam no local desde 2012. As torres proporcionam as medições de variáveis químicas micrometeorológicas, fluxos de carbono e atmosféricas desde 2012.

Figura 11. Vista Parcial da Torre ATTO na RDS-Uatumã - 2015.



Fonte: ()

A torre é equipada para realizar medições micrometeorológicas que incluem perfis de temperatura e vento, precipitação, fluxos de água e energia, componentes de turbulência, medições de gases, fluxos de radiação entre outros. As medições de gases traços incluem monitoramento contínuo de dióxido e de monóxido carbono, metano e ozônio em alturas diferentes ao longo da torre, complementados pelas medições ópticas, microfísicas e químicas

do aerossol que são feitas acima do dossel, bem como abaixo do dossel. Os dados do projeto ATTO estão disponíveis na página oficial do projeto por meio de um cadastro no portal, é possível ter acesso aos dados levantados pelas torres.

Os dados estão disponíveis virtualmente no site após realizada a inscrição no mesmo, sendo possível baixar a série de dados correspondente aos anos que serão estudados. Para o desenvolvimento desta pesquisa, optou-se por utilizar os dados apresentados no Quadro 1 e 2. Estes dados correspondem a medições realizadas a uma altitude de 80 metros devido ao fato das árvores possuírem geralmente de 30 a 40 metros de altura (HOPKINS, 2005; SOTTA, 1998; NÖLSCHER *et al.*, 2016). Essa altitude permite que as medições sofram menos influência da camada superficial que é a camada imediatamente acima da superfície onde o fluxo de ar depende fortemente das características da superfície pois, essas as medições de fluxo dentro e perto do dossel, conhecida como subcamada de rugosidade, possui características próprias (BONAN, 2015).

Devido à presença de lacunas nos dados provenientes da torre, optou-se por utilizar a metodologia de interpolação de dados por krigagem. Este método é amplamente utilizado na literatura para o preenchimento de lacunas de dados espaciais, no entanto é possível verificar que já foi utilizado para dados temporais por meio do estudo de Shtiliyanova *et al.*, (2017) que apresentou boa acurácia ao utilizar esse método para preencher lacunas de dados de temperatura do ar. A metodologia consiste na espacialização desses dados temporais ao inseri-los em uma matriz espacial X e Y de coordenadas arbitrárias sendo a primeira observação localizado na coordenada (1,1) a segunda na coordenada (1,2) a terceira na coordenada (1,3) e assim por diante. O método geostatístico de *Kriging* pode prever valores ausentes utilizando informações de dados vizinhos, apoiadas na hipótese de que a previsão matemática é uma função da distância entre as observações.

5.2.1 Descrição dos dados obtidos

Uma vez cadastrado no portal a aquisição dos dados passa pela avaliação dos responsáveis pelo armazenamento dos dados micrometeorológicos e de fluxo de carbono. Os dados são enviados em formato de planilha eletrônica divididas em colunas e as variáveis separadas em intervalos de 30 minutos, iniciando a medida no primeiro dia do ano até a meia-noite do último dia desse mesmo ano. Os dados utilizados para esta pesquisa foram divididos

em dois quadros, o primeiro apresenta os dados micrometeorológicos (Quadro 1) e o segundo apresenta os dados relacionados aos fluxos de carbono (Quadro 2):

Quadro 1. Dados Micrometeorológicos provenientes da ATTO – RDS Uatumã

Nome Abreviado	Descrição	Unidade	Formato
Timestamps	Data e hora do final do período médio	Data e hora	ddmmyyyy hh:mm:ss
temperature	A temperatura do ar em graus celsius a 80,48 m	Graus Célcius	decimal
RH_81m	Úmidade relativa a 80,48 m	Porcentagem	decimal
SW_in	Radiação de ondas curtas recebida; a 75,55 m	Watt por metro quadrado	decimal
SW_out	Radiação de ondas curtas refletida a 75,55 m	Watt por metro quadrado	decimal
PAR_in	Radiação fotossinteticamente ativa recebida a 75,55 m; Unidade: $\mu\text{mol} + 1\text{s}^{-1}\text{m}^{-2}$	Micromol por área de tempo	decimal
PAR_out	Radiação fotossinteticamente ativa refletida a 75,55 m; Unidade: $\mu\text{mol} + 1\text{s}^{-1}\text{m}^{-2}$	Micromol por área de tempo	decimal
UV	Radiação ultravioleta a 75,55 m	Watt por metro quadrado	decimal
NetRad	Radiação líquida a 75,55 m	Watt por metro quadrado	decimal
airP	Pressão atmosférica a 81 m	Hectopascal	decimal
rain	Precipitação a 81,34 m; Unidade: L/m^2	Litro por metro quadrado	decimal
LW_atm	Radiação de ondas longas atmosférica a 75,55 m	Watt por metro quadrado	decimal
LW_terr	Radiação de ondas longas terrestre a 75,55 m	Watt por metro quadrado	decimal
Tau	Momentum do fluxo Corrigido; a 81 m; Unidade $\text{kg}/(\text{m}^*\text{s}^2)$	Quilograma por metro e segundo quadrado	decimal
ws	Velocidade do vento a 73.7 m	Metro por segundo	decimal
wDir	Direção do vento a 73.7 m; Unit: graus a partir do Norte	Graus	decimal

Fonte: (<https://www.attodata.org/>). Elaboração, GARCIA, E. A. B., (2020).

Quadro 2. Dados de fluxo de carbono provenientes da ATTO – RDS Uatumã

Nome Abreviado	Descrição	Unidade	Formato
Timestamps	Data e hora do final do período médio	Data e hora	ddmmyyyy hh:mm:ss
H	Fluxo de calor sensível a 81 m	watt por metro quadrado	decimal
FluxCO2	Fluxo de gás [CO ₂] a 81 m; Unidade: $\mu\text{mol} / (\text{s} * \text{m}^2)$	Micromol por área de tempo	decimal
airT	Temperatura média do ar ambiente, medida pelo anemômetro a 81 m	Graus célsius	decimal
co2f	Fração molar medida ou estimada de gás [CO ₂] a 81 m; Unidade: $\mu\text{mol} / \text{mol}$ (fração molar do ar)	Micromol por mol	decimal
wvd	Densidade de massa do vapor de água no ambiente a 81 m	Gramas por metro cúbico	decimal
airP	Pressão média do ar ambiente, calculada a partir de leituras de pressão atmosférica de alta frequência ou estimada com base na altitude do local (pressão barométrica a 81 m)	Pascal	decimal
U	Velocidade de Fricção; a 81 m	Metro por segundo	decimal

Fonte: (<https://www.attodata.org/>). Elaboração, GARCIA, E. A. B., (2020).

5.3 Imagens Orbitais CBERS-4 Sensor MUX

5.3.1 Aquisição de imagens orbitais:

Para a elaboração dessa pesquisa, optou-se por utilizar as cenas provenientes do satélite CBERS – 4, que é embarcado com o sensor multiespectral MUX, possuindo uma órbita/ponto de 165-124, com resoluções espaciais de 20 metros e uma resolução radiométrica de 8 bits, Quadro 3. O arquivo contém as bandas: 5 (0.45 a 0.52 μm), 6 (0.52 a 0.59 μm), 7 (0.63 a 0.69 μm) e 8 (0.77 a 0.89 μm). Todas na faixa espectral do visível ao infravermelho próximo, sendo obtidas no portal do Instituto Nacional de Pesquisas Espaciais (INPE). No quadro abaixo constam as cenas de imagens que serão utilizadas para calcular os índices de vegetação:

Quadro 3. Metadados do satélite CBERS-4.

Características do Satélite CBERS-4	Dados
Bandas Espectrais	B05 (Azul): 0,45 – 0,52 μm
	B06 (Verde): 0,52 – 0,59 μm
	B07 (Vermelho): 0,63 – 0,69 μm
	B08 (Infravermelho Próximo): 0,77 – 0,89 μm
Largura da Faixa Imageada	120 km
Resolução Espacial	20 m
Resolução Radiométrica	8 bits
Visada Lateral de Espelho	Não
Taxa Bruta de Dados	68 Mbit/s

Fonte (INPE). Elaboração, GARCIA, E. A. B., (2020).

5.3.2 Descrição dos dados obtidos

Para adquirir os dados do satélite CBERS sensor MUX, é necessário realizar um cadastro no site do INPE. A partir desse cadastro, é possível selecionar os períodos de imageamento, local da cena, percentual de cobertura de nuvens entre outros parâmetros. Para a realização dessa pesquisa, foram utilizadas as cenas descritas no quadro abaixo:

Quadro 4. Cenas utilizadas para o cálculo dos índices de vegetação.

Satélite	Sensor	Data	Horário**	Cena	Nível*
CBERS 4	MUX	10/12/2017	14:15:00	172_102	L2
CBERS 4	MUX	14/11/2017	14:15:30	172_102	L2
CBERS 4	MUX	19/10/2017	14:16:30	172_103	L4
CBERS 4	MUX	23/09/2017	14:17:00	172_103	L4
CBERS 4	MUX	28/08/2017	14:17:30	172_103	L4
CBERS 4	MUX	07/07/2017	14:19:00	172_103	L4
CBERS 4	MUX	11/06/2017	14:19:30	172_103	L4
CBERS 4	MUX	16/05/2017	14:19:49	172_103	L4
CBERS 4	MUX	20/04/2017	14:20:36	172_103	L4
CBERS 4	MUX	22/03/2017	14:24:43	173_102	L4
CBERS 4	MUX	27/02/2017	14:21:20	172_102	L2
CBERS 4	MUX	29/01/2017	14:25:43	173_103	L2
CBERS 4	MUX	09/12/2018	14:00:00	172_102	L2
CBERS 4	MUX	13/11/2018	14:01:30	172_102	L4
CBERS 4	MUX	18/10/2018	14:02:30	172_102	L2

CBERS 4	MUX	19/09/2018	14:07:30	173_102	L4
CBERS 4	MUX	01/08/2018	14:06:00	172_103	L4
CBERS 4	MUX	06/07/2018	14:07:00	172_103	L4
CBERS 4	MUX	10/06/2018	14:09:00	172_103	L4
CBERS 4	MUX	12/05/2018	14:13:00	173_102	L2
CBERS 4	MUX	19/04/2018	14:10:00	172_103	L2
CBERS 4	MUX	21/03/2018	14:15:30	173_102	L2
CBERS 4	MUX	26/02/2018	14:12:30	172_103	L4
CBERS 4	MUX	28/01/2018	14:17:30	173_102	L2
CBERS 4	MUX	11/12/2019	14:04:30	172_102	L2
CBERS 4	MUX	15/11/2019	14:03:30	172_103	L4
CBERS 4	MUX	20/10/2019	14:02:00	172_102	L4
CBERS 4	MUX	21/09/2019	14:05:00	173_102	L4
CBERS 4	MUX	03/08/2019	13:59:00	172_103	L4
CBERS 4	MUX	08/07/2019	13:58:00	172_102	L2
CBERS 4	MUX	09/06/2019	14:00:00	173_102	L4
CBERS 4	MUX	17/05/2019	13:55:30	172_103	L4
CBERS 4	MUX	21/04/2019	13:49:38	172_102	L2
CBERS 4	MUX	23/03/2019	13:54:30	172_102	L4
CBERS 4	MUX	25/02/2019	13:56:00	172_102	L2
CBERS 4	MUX	04/01/2019	13:59:00	172_103	L4

Fonte (INPE). Elaboração, GARCIA, E. A. B., (2020).

* Nível: L2 – Com correção radiométrica e geométrica do sistema.

* Nível:L4 – Com aplicação de Modelo Numérico de Elevação do Terreno

** O horário de obtenção da cena no portal do INPE não especifica se o horário é em relação a Brasília ou se é um fuso horário local

Ressalta-se que o levantamento das datas propostas se deve ao fato de ser o período com menor cobertura de nuvens na região. Tendo em vista que o domínio morfoclimático da Amazônia possui características biogeográficas que acarretam em um alto índice pluviométrico, e por consequência, um alto índice de cobertura de nuvens. Desta forma, a aquisição das cenas segue os critérios na seguinte ordem de importância descrita abaixo:

- 1- Cenas sem cobertura de nuvens sobre a localização da torre de observação.
- 2 - Cenas sem cobertura de nuvens sobre áreas próximas da torre de observação.
- 3 - Cenas sem cobertura de nuvens sobre a área da RDS Uatumã.
- 4 - Cenas sem cobertura de nuvens em áreas próximas a RDS Uatumã.

5.4 Softwares utilizados

Para a elaboração dos procedimentos metodológicos propostos nesta pesquisa, foram utilizados quatro softwares para o tratamento dos dados, para a análise estatística e para a validação desses dados. A utilização desses programas só foi possível com a contribuição do espaço e dos computadores devidamente licenciados do Laboratório de Cartografia e Sensoriamento Remoto do Instituto de Geografia da Universidade Federal de Uberlândia. A descrição de cada software e a sua utilização nas etapas de cada pesquisa será abordado nos subcapítulos a seguir.

5.4.1 ArcGIS 10.5

Para a elaboração dos cálculos das bandas espectrais provenientes do satélite CBERS-4 sensor MUX, optou-se por utilizar o software ArcGIS 10.5. Esse software pertence a empresa Environmental Systems Research Instituto (ESRI), na qual é considerada a maior organização do setor de GIS e oferece software, suporte, consultoria, treinamento e publicações acadêmicas (DONNELLY, 2010). O ArcGIS trabalha com uma infraestrutura de dados geográficos e permite realizar diversos tipos de cálculos matemáticos georreferenciados, administração de banco de dados geográficos e a utilização de uma interface de usuário orientada por comandos.

Devido à quantidade de cenas, bandas espectrais e operações de geoprocessamento, a ferramenta *Model Builder* que está inserida no programa ArcGIS foi utilizada. Esta ferramenta permite automatizar grandes quantidades operações cartográficas uma vez programado.

5.4.2 QGIS 3.10 / SAGA GIS

O QGIS (anteriormente conhecido como Quantum GIS) é um software de geoprocessamento gratuito e de código aberto para a aplicação de estudos em sistemas de informação geográfica (SIG). O QGIS é acessível em 42 dialetos e é composto por quatro componentes, QGIS Desktop, QGIS Browser / Mobile, Cliente da Web QGIS e servidor QGIS. O QGIS na versão Desktop é equiparado ao ArcGIS, pois fornece a mesma capacidade de

geoprocessamento para a criação, revisão, alteração e exame de informações geoespaciais. O QGIS foi formalmente inscrito como uma tarefa da Open Source Geospatial Foundation (OSGeo) em 2002, uma organização sem fins lucrativos com o intuito de permitir o avanço da utilização comunitária dos códigos geoespaciais para toda sociedade. O QGIS possui um design de módulo que permite incluir novos componentes que podem ser criados em Python ou C++ inserido na interface do próprio QGIS, ou através de comunidades independentes como na plataforma Github, um site para pesquisa de código e administração para tarefas de código aberto e privadas.

O Sistema para Análises Geocientíficas Automatizadas (SAGA) é um programa de informações geográficas de código aberto licenciado sob o GNU (General Public Licence). O programa foi lançado em 2004 e rapidamente se tornou uma ferramenta especializada para análise digital de espacial de forma abrangente e bem estabelecida globalmente na comunidade científica. Esse software é programado orientado a objeto em C++. Os recursos funcionais do software permitem o desenvolvimento e a implementação de novos métodos geocientíficos, possui uma interface gráfica de usuário amigável com muitas opções de visualização, possui também a possibilidade de utilizar linhas de comando e interfaces para linguagens em R e Python. A versão 2.1.4 oferece mais de 600 ferramentas, implementadas em bibliotecas carregáveis ou objetos compartilhados e representam a base para vários trabalhos geocientíficos

A realização da interpolação de dados do SAGA utiliza o formato *shapefile* que é dividido em formato de pontos, linhas e polígonos. Portanto, os dados de medição foram preparados como um arquivo de pontos contendo como atributos os dados da ATTO. Desta forma, o arquivo foi organizado em colunas com as coordenadas X e Y arbitrarias para realizar o processo de interpolação de krigagem para o preenchimento das lacunas dos dados.

5.4.4 Action Stat

O Action Stat é um sistema estatístico utilizando o poder computacional da linguagem R através de um sistema interoperativo ao Excel, que permite realizar levantamentos estatísticos de grandes dados. O desenvolvimento desse software foi realizado em 2005, a partir de uma equipe de doutores em computação e estatística, desenvolvido pela Estatcamp. Por meio deste sistema, é possível utilizar a linguagem R dentro da interface do Excel. Para fins de pesquisa, utilizou-se a ferramenta *Action Stat* para a realização de procedimentos da análise descritiva e inferência estatística. Utilizou-se a ferramenta de regressão linear múltipla (RLM), Análise de

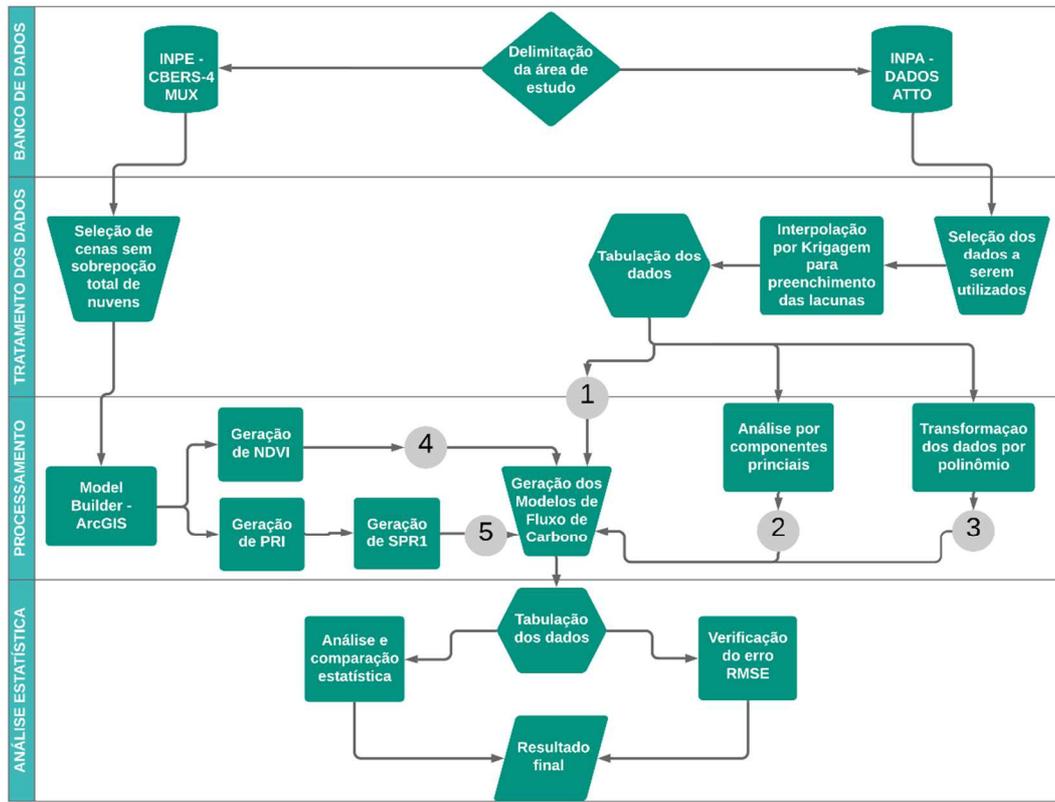
Componentes Principais, Matriz de Correlação, Testes-T para realizar as comparações entre os dados.

5.4.4 Fluxograma metodológico da pesquisa

A metodologia proposta para esta pesquisa está descrita no fluxograma, Figura 12, e brevemente explicado nesta introdução, será detalhado de maneira aprofundada nos subcapítulos a seguir. Primeiramente, utilizou-se os dados provenientes da ATTO, e fornecidas pelo INPA, para realizar a modelagem do fluxo de carbono com base nos dados micrometeorológicos e posteriormente realizar a validação do método através das medições diretas de fluxo de carbono. Foi efetivado a interpolação por krigagem das lacunas de dados, depois a regressão linear múltipla para gerar uma estimativa dos valores de fluxo de carbono. Então, esses modelos de fluxos de carbono provenientes dos dados levantados através do CBERS-4 e dos dados micrometeorológicos foram comparados com os dados de levantamento direto de fluxo de carbono da própria torre ATTO.

Posteriormente, foi realizado o levantamento dos dados provenientes das imagens orbitais, a realização dos cálculos de índices de vegetação e a extração dos valores do fluxo de carbono através de uma média de pixels de matriz 7×7 . Essa matriz serviu como base para calcular a média desses valores para verificar a aderência do método nesses dois processos metodológicos. Assim feito, foram tabulados os dados conjuntamente com os valores de fluxos de carbono da ATTO para cálculo das discrepâncias e do RMSE (Raiz do Erro Médio Quadrático), como mostra a Figura 12:

Figura 12. Fluxograma metodológico da pesquisa proposta.



Elaboração, GARCIA, E. A. B., (2020).

5.4 Procedimentos para a modelagem dos dados de fluxo de carbono provenientes da ATTO

A elaboração dos modelos de fluxo de carbono, por meio do método de regressão linear múltipla, da análise de componentes principais e de polinômios, foi realizada com o intuito de verificar se o ajustamento desse modelo foi satisfatório. A modelagem foi gerada para cada ano: 2017, 2018 e 2019, e analisadas separadamente.

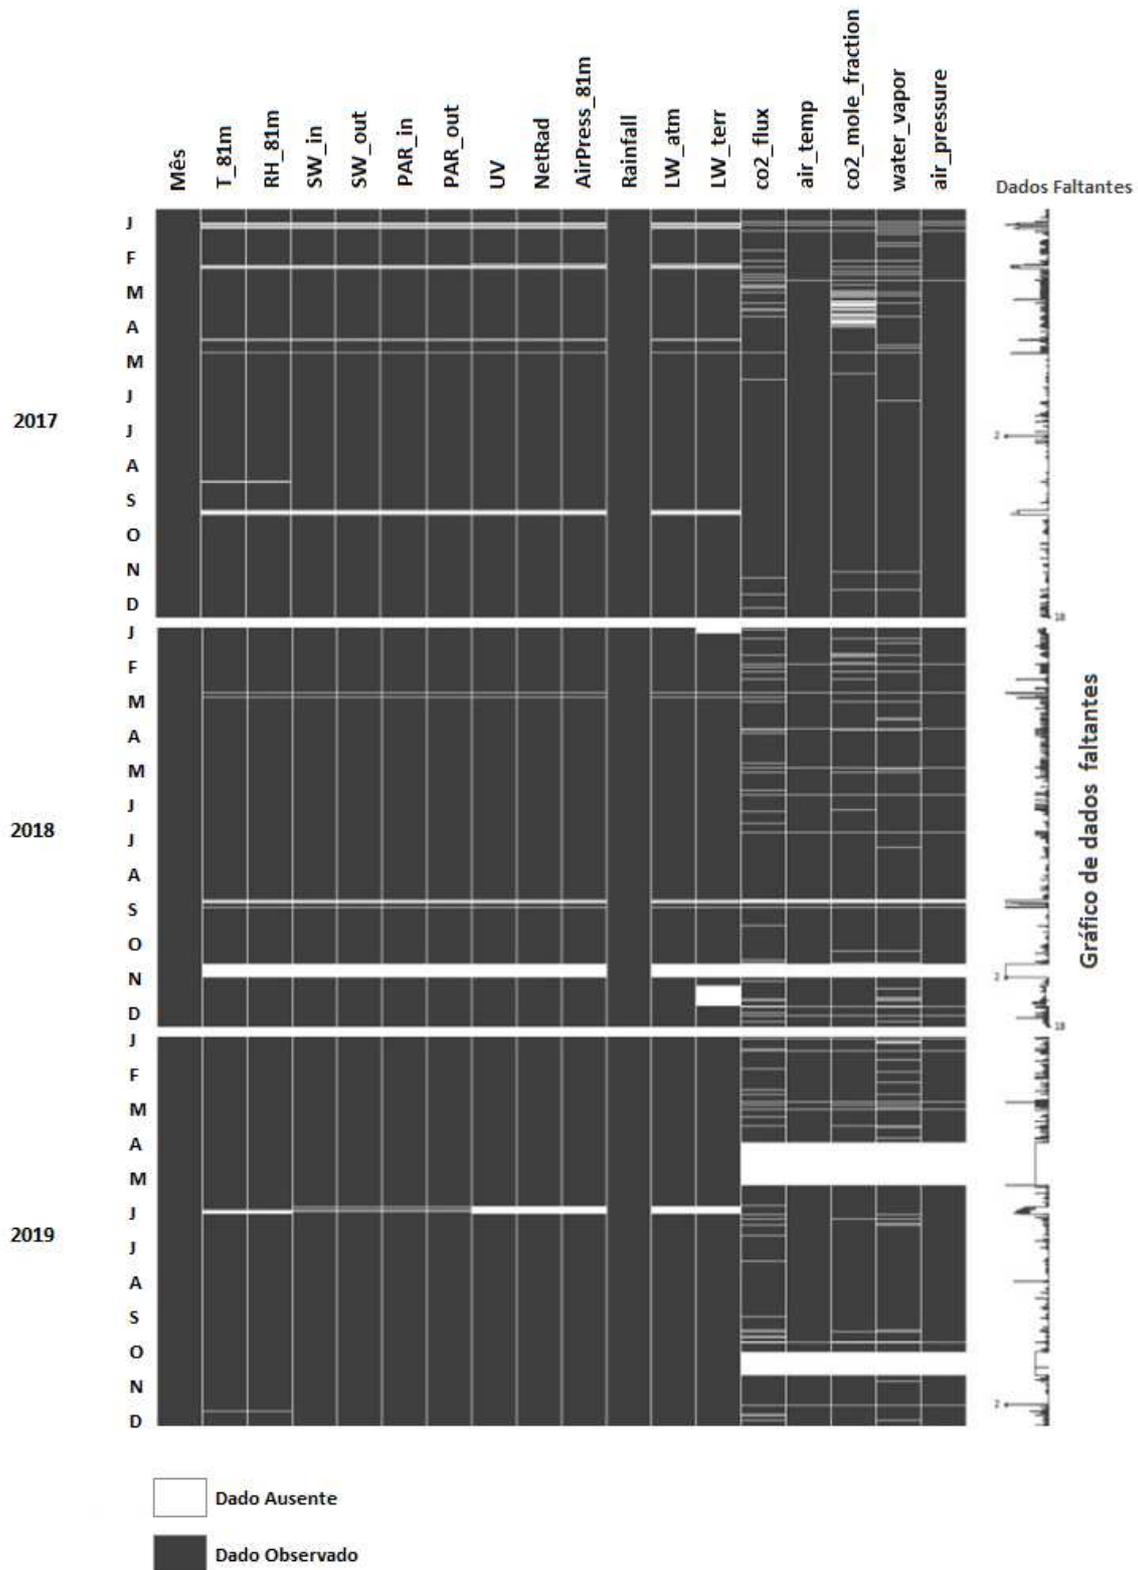
5.4.1 Interpolação dos dados por Krigagem

Os dados enviados pelo projeto da ATTO são tabulados em observações de 30 em 30 minutos, para cada parâmetro micrometeorológico. Assim, são disponibilizadas 17.520 medições anuais, de cada parâmetro micrometeorológico com as respectivas explicações sobre cada parâmetro nos Quadros 1 e 2 (H, LE, Tau, ws, airT, co2F, wvd, airP, u, wDir, RH_81m,

SW_in, SW_out, PAR_in, PAR_out, UV, NetRad, Rainfall, LW_atm, LW_terr, o que totaliza 1.103.760 medições anuais, se considerados os 21 parâmetros coletados ao longo dos anos: 2017, 2018 e 2019.

Naturalmente, ocorrem falhas nos dados devido problemas com os equipamentos relacionados, por exemplo, ao desgaste, mal funcionamento, erro de leitura e manutenção (Figura 13). Desta forma, para preenchimento dessas lacunas, foi realizada a interpolação dos dados usando o método de krigagem, implementado no software SAGA.

Figura 13. Gráfico de dados levantados e de lacunas (2017, 2018 e 2019)



Elaboração, GARCIA, E. A. B., (2020).

*No “Gráfico de dados faltantes”, as linhas horizontais representam a quantidade de informação faltante por coluna. Quanto maior e mais extensa a linha, maior a quantidade de colunas que faltam dados.

A ferramenta de geoprocessamento e de geoestatística SAGA, é capaz de realizar diversas operações em arquivos tanto no formato *shapefile* de dados vetoriais (pontos, linhas e polígonos) como no formato matricial. Dentre as operações existentes nesse software está a interpolação por krigagem, que é um método bastante utilizado pela comunidade científica, devido sua melhor estimativa linear imparcial (KIS, 2016) e sua eficiência em diversos tipos de dados espaciais, como, por exemplo, os micrometeorológicos.

Nesta pesquisa, para adaptação ao software SAGA, os dados micrometeorológicos, provenientes da torre ATTO foram organizados em tabelas, considerando o intervalo de 30 minutos. Assim, para cada variável, foi criada uma matriz referente ao ano em análise onde as linhas são as observações e as colunas são os meses. Portanto, cada matriz é composta de 1488 linhas por 12 colunas. Esses arquivos foram salvos no formato ASCII, conforme exigência para entrada no SAGA.

O procedimento de interpolação foi executado e as lacunas existentes foram preenchidas pelos valores interpolados por krigagem com base na espacialização desses dados. É sabido que esse método assume que a distância ou direção entre os pontos da amostra possui uma correlação espacial que pode ser usada para preencher tais lacunas. Nesse caso, assumiu-se a premissa que existe essa correlação por se tratar de um mesmo equipamento ao longo do tempo.

5.4.2 *Estatística descritiva*

Após o procedimento de interpolação de dados, foi realizado uma análise estatística realizando o cálculo da Média, Erro padrão, Mediana, Modo, Desvio padrão, Variância da amostra, Curtose, Assimetria, Intervalo, Mínimo, Máximo, Soma, Contagem e Análise do Nível de confiança (95,0%). Essas análises permitiram realizar inferências preliminares sobre o comportamento da amostra e sobre a possibilidade de correlações entre os diferentes dados dados.

5.4.3 *Matriz de Correlação*

Matriz de correlação é utilizada na estatística para encontrar a dependência entre muitas variáveis além de descrever a possibilidade de associação entre as variáveis do conjunto

de análise calculado. Assim, esta pesquisa utilizou a matriz de correlações para verificar padrões, como as variáveis se correlacionam e, por fim, para realizar uma regressão linear múltipla com o intuito de excluir valores ausentes em pares e dados discrepante. Neste estudo, a matriz de correlação de Pearson (Equação 2). Definiu-se que seriam eliminadas as variáveis que apresentaram *p-valores* diferentes de zero.

$$r = \frac{\Sigma(x+x^0)*(y+y^0)}{(n-1)*s_x*s_y} \quad (2)$$

Onde:

x^0 = média do conjunto de dados da primeira variável;

s_x = desvio padrão do conjunto de dados da primeira variável;

y^0 = média do conjunto de dados da segunda variável;

s_y = desvio padrão do conjunto de dados da segunda variável.

5.4.4 Modelagem por meio de Regressão Linear Múltipla

Neste estudo, foi proposto a geração de um modelo estatístico, por meio de Regressão Linear Múltipla (RLM), para verificar o ajuste do modelo aos dados reais. O mesmo procedimento estatístico foi realizado para todos os anos (2017, 2018 e 2019) em três momentos, primeiro após o cálculo da matriz de correlação e depois da análise dos componentes e posteriormente após a aplicação da equação de polinômio. Portanto, será apresentado aqui apenas o procedimento geral, demonstrado quais variáveis que foram utilizadas e posteriormente serão apresentados os resultados separadamente para cada ano. Para esta etapa utilizamos os dados micrometeorológicos e atmosféricos, obtidos na torre ATTO, como variáveis independentes (X_i), e os valores originais de fluxo de CO₂, também coletados por equipamentos acoplados na torre ATTO, como variável dependente (Y) na equação de regressão linear múltipla descrita abaixo na Equação 3:

$$\hat{Y} = \beta_0 + \beta_1 H_1 + \beta_2 LE_2 + \beta_3 Tau_3 + \beta_4 ws_4 + \beta_5 airT_5 + \beta_6 co2F_6 + \beta_7 wvd_7 + \beta_8 airP_8 + \beta_9 u_9 + \beta_{10} wDir_{10} + \beta_{11} RH_{81m_{11}} + \beta_{12} SW_{12} + \beta_{13} SW_{out_{13}} + \beta_{14} PAR_{14} + \beta_{15} PAR_{out_{15}} + \beta_{16} UV_{16} + \beta_{17} NetRad_{17} + \beta_{18} Rainfall_{18} + \beta_{19} LW_{atm_{19}} + \beta_{20} LW_{terr_{20}} + \varepsilon_i \quad (3)$$

\hat{Y} = fluxCO2

X_i = Variável independente ou regressor

β_0 = Intercepto ou constante do modelo

β_i = Coeficiente angular do modelo

ε_i = Erro Residual

Após a aplicação do RLM, o modelo gerado foi analisado por meio dos *p-valores*, do R^2 e R^2 ajustado e dos resíduos. Os *p-valores* foram calculados para verificar a condição de hipótese nula ou não, o r^2 foi calculado como 1 menos a razão da soma dos quadrados dos erros sobre a soma total dos quadrados e o R^2 ajustado foi calculado como 1 menos a razão entre o quadrado médio do erro em relação ao quadrado médio total. Segundo Charnet *et al.* (1999) o intervalo entre 0 e 1 representa o ajuste do modelo considerado, quanto mais próximo de 1 mais ajustado está o modelo.

5.4.5 Modelagem com aplicação da Análise por Componentes Principais

A Análise de Componentes Principais (ACP) é uma técnica utilizada com o intuito de reduzir a dimensionalidade dos conjuntos de dados utilizados nesse estudo. Essa ferramenta proporciona o aumento a interpretabilidade do modelo minimizando a perda de informações. Utiliza-se essa ferramenta com o intuito de reduzir a dimensão dos dados através de componentes que são combinações lineares das variáveis originais.

Com o objetivo de aprimorar o modelo de regressão, foram determinados os componentes principais do conjunto de todos dos dados micrometeorológicos e atmosféricos, gerando posteriormente um modelo de regressão dos componentes principais que mais contribuíram com os valores de fluxo de carbono. Isto é, foram analisados os pesos/autovetores gerados para a variável “co2Flux” e escolhidos aqueles componentes que apresentaram maiores pesos. Foi definido como limiar dos pesos o valor de 15%. A escolha desse valor se deu pela

diferença abrupta entre os valores superiores e inferiores a esse limiar, o que caracteriza muito bem o agrupamento em dois conjuntos.

Após escolha dos componentes principais mais apropriados para estimativa do fluxo de carbono, foi aplicada a RLM sobre esse grupo reduzido de componentes para geração do modelo. A análise da qualidade desse modelo seguiu o mesmo princípio aplicado no modelo de RLM apresentado na seção anterior.

5.4.6 Modelagem com aplicação de Polinômios

Com intuito de obter um modelo com melhor ajuste, os dados de fluxo de carbono originais (torre ATTO) foram transformados por meio de polinômios. A transformação por polinômios permite uma suavização dos dados de fluxo, reduzindo a variância com o reescalonamento dos dados sob a curva do polinômio apresentado na Equação 4.

$$y = x^{1/15} \quad (4)$$

Onde x são os valores de fluxo de carbono da torre ATTO e y são os valores de carbono transformados.

5.4.7 Cálculo de fluxo de carbono através do modelo e validação dos dados

Por fim, os valores/resultados obtidos pelo modelo gerado foram comparados com os valores reais obtidos na torre ATTO. Para essa análise, foram calculados os resíduos, apontando valores máximos, mínimos e médias, bem como a discrepância por meio da Raiz do Erro Médio Quadrático (Root Mean Square Error - RMSE), representado pela Equação 5:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \hat{X}_i)^2} \quad (5)$$

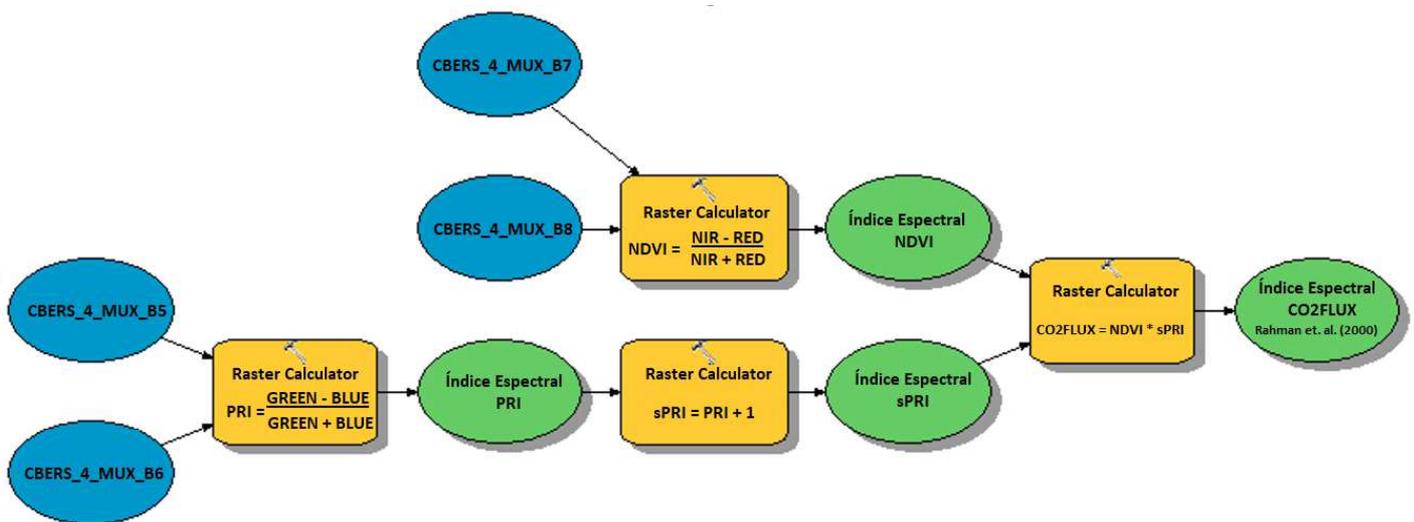
A qualidade da predição gerada pelo modelo proposto pode ser avaliada através da soma do resíduo médio, onde X_i é o valor observado e \hat{X}_i é o valor estimado a partir da regressão e n é a quantidade de dados da base. Adicionalmente, foram realizados os cálculos das estimativas de previsões dos valores de fluxo de carbono usando os modelos gerados. As

previsões foram geradas com base em grupos de valores das variáveis micrometeorológicas e atmosféricas obtidas nos mesmos anos daquele em que foi gerado o modelo. Isto é, o modelo gerado para o ano de 2017 foi usado para estimar valores de fluxos de carbono para o ano de 2017 e assim por diante. Os valores previstos foram comparados, pela Raiz do Erro Médio Quadrático (RMSE), com os valores reais de fluxos de carbono daquele ano em análise.

5.5 Procedimentos para cálculo de fluxo de carbono provenientes do CBERS-4/MUX

Devido à quantidade de cenas, bandas espectrais e operações de processamento digitais das imagens, para a elaboração desta pesquisa, utilizou-se a ferramenta *Model Builder* que está inserida no programa ArcGIS. Essa ferramenta permite automatizar grandes quantidades de operações cartográficas, uma vez programado como demonstrado na Figura 14 abaixo.

Figura 14. Modelo de Fluxograma do Model Builder utilizado para a automação do processo.



Elaboração, GARCIA, E. A. B., (2020).

5.5.1 Processamento das imagens do CBERS

Optou-se por não realizar as correções atmosféricas e geométricas devido ao fato de as imagens já serem fornecidas com as devidas correções após uma pesquisa de Martins et. al.

(2018) no qual providenciou um algoritmo nomeado CMPAC (*Coupled Moderate Products for Atmospheric Correction*) que foi aplicado as cenas do CBERS-4 do sensor MUX. Desta forma, não houve a necessidade de aplicar a metodologia de correção geométrica e atmosférica tradicionalmente utilizada na manipulação de imagens orbitais pelo fato desse procedimento já ter sido realizado automaticamente pelo INPE.

5.5.2 Cálculo do NDVI (*Normalized Difference Vegetation Index*):

O NDVI foi calculado com base na metodologia proposta por Ruse et al. (1973), conforme a Equação 1. Esse índice é utilizado como uma das variáveis úteis para estimar o sequestro de carbono pela vegetação no período fotossintético, Equação 6.

$$NDVI = \frac{\rho_{NIR} - \rho_{RED}}{\rho_{NIR} + \rho_{RED}} \quad (6)$$

Onde:

ρ_{NIR} é a reflectância correspondente à região espectral do infravermelho próximo;

ρ_{RED} é a reflectância correspondente à região espectral do vermelho.

5.5.3 Cálculo do índice de Reflectância Fotossintético (*PRI*):

O Índice de Reflectância Fotossintético (*PRI*) (Equação 2), proposto por Gamon et al. (1997), determina o ciclo da xantofila que ajusta a distribuição de energia nas reações fotossintéticas. Esse índice indica o uso eficiente da luz (*light-use efficiency* (*LUE*)) e *stress* hídrico da vegetação (GAMON et al., 1997), Equação 7

$$PRI = \frac{\rho_{GREEN} - \rho_{BLUE}}{\rho_{GREEN} + \rho_{BLUE}} \quad (7)$$

ρ_{GREEN} é a reflectância correspondente à região espectral do verde ;

ρ_{BLUE} é a reflectância correspondente à região espectral do azul.

5.5.4 Cálculo do Fluxo de CO₂ Proposto por Rahman *et al.* (2000)

Rahman *et al.* (2000) propuseram que a integração do índice PRI, que demonstra indiretamente a eficiência do uso da luz para o processo de fotossíntese, juntamente ao índice NDVI, seria possível medir a eficiência do processo de sequestro de carbono. Ferreira (2015) e Silva (2013) também utilizam essa fórmula para realizar o cálculo do fluxo de carbono através desses índices como descrito na, Equação 8.

$$Fluxo_{CO_2} = -5.6 * (NDVI * sPRI) - 0.69 \quad (8)$$

5.5.5 Cálculo do Fluxo de CO₂ Proposto nesse Estudo

O estudo de Rahman *et al.* (2000) foi realizado em vegetação de floresta boreal, que difere consideravelmente da floresta amazônica. Nesse sentido, com intuito de melhorar os resultados do modelo de Rahman *et al.* (2000), foi proposta a alteração da relação entre os índices PRI e NDVI. Com base em experimentos empíricos, foi demonstrado que a razão entre esses índices apresenta maior correlação com os valores de fluxos medidos na floresta amazônica, na torre ATTO, alterados pelo polinômio indicado na equação k. Assim, o modelo proposto assumiu a seguinte forma, Equação 9 e 10.

$$Fluxo_{CO_2\text{alterado}} = Fluxo_{CO_2}^{1/15} \quad (9)$$

e

$$Fluxo_{CO_2} = -0,7751 * (PRI/NDVI) - 1,3181 \quad (10)$$

Definidos os dois modelos, os valores mensais de fluxo de carbono foram calculados usando as imagens NDVI e PRI. Para análise estatística dos resultados, foram coletadas amostras de valores de fluxo, contidas em uma matriz de 7x7, nas proximidades da torre ATTO. As amostras foram coletadas nos resultados mensal, usando ambos modelos (Rahman *et al.* (2000) e proposto). O valor de fluxo, usado para cada mês, corresponde à média aritmética dos 49 valores contidos na referida matriz amostral. Após essa etapa, foram organizadas duas tabelas: uma com os valores médios mensais de previsão de fluxo do modelo de Rahman *et al.*.

(2000) para os anos de 2017, 2018 e 2019, e outra com os valores correspondente ao modelo proposto e ao mesmo intervalo de tempo.

Em seguida, foi organizada uma terceira tabela com os valores de fluxo de carbono medidos na torre ATTO, no mesmo período (2017, 2018 e 2019). Esses valores coletados correspondem às medidas realizadas nos mesmos dias e horários de passagem do satélite sobre a região onde está localizada a torre ATTO.

5.6 Validação dos Resultados

Os valores de fluxo resultantes da simulação pelos modelos de Regressão Linear Múltipla, Regressão Linear Múltipla com Análise por Componentes Principais, Regressão Linear Múltipla com Polinômios, Rahman *et al.* (2000) e modelo proposto, foram comparados com os valores reais obtidos na torre ATTO. Para essa análise, foram calculados os resíduos, apontando valores máximos, mínimos e médias, bem como a discrepância por meio da Raiz do Erro Médio Quadrático (Root Mean Square Error-RMSE), representado pela Equação 11:

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (X_i - \hat{X}_i)^2} \quad (11)$$

Os autores Willmott e Matsuura (2005), afirmaram que a raiz do erro quadrático médio (RMSE) é um método amplamente usado literatura climática e ambiental, além de ser confiável. O RMSE é frequentemente usado para representar a precisão e a acurácia das previsões do modelo, pois, ao elevar ao quadrado o termo da diferença, esse índice tende a dar maior peso às grandes discrepâncias entre os campos observados e previstos (WILKS, 2006).

A qualidade da predição gerada pelos modelos foi determinada pelo teste estatístico t, por meio de comparação de médias. As previsões foram geradas foi usado para estimar valores de fluxos de carbono para os anos de 2018 e 2019. Os valores previstos foram comparados, usando RMSE e teste t, com os valores reais de fluxos de carbono daquele ano em análise.

Por fim, as três tabelas geradas com os resultados (método Rahman *et al.* (2000), método proposto e dados reais da torre ATTO) foram analisadas estatisticamente, por meio de

regressões lineares, teste estatístico t, comparação de variâncias, e comparação de variâncias entre si.

6 RESULTADOS E DISCUSSÃO

Os resultados são apresentados na mesma ordem exibida nas etapas dos procedimentos metodológicos, Figura 12. Assim, inicialmente foi apresentada a estatística descritiva dos dados fornecidos pela torre ATTO já interpolados. Em seguida, foram apresentados os resultados da modelagem baseada na regressão linear múltipla. A primeira análise do fluxo de carbono, por regressão linear múltipla, envolveu os dados micrometeorológicos em formato original. A segunda análise compreendeu uma transformação dos dados micrometeorológicos por componentes principais e, posteriormente, foi aplicada a regressão linear múltipla sobre esses componentes. A terceira análise tratou-se da modelagem do fluxo de carbono por meio de um polinômio. Posteriormente, a comparação dos modelos de fluxo de carbono, gerados a partir dos dados micrometeorológicos e a validação individual dos modelos, através do teste estatístico *testes-t* e da Raiz do Erro Quadrático Médio (RMSE).

Em seguida, foram apresentados os resultados da modelagem obtida com o uso dos dados provenientes do Satélite CBERS-4, sensor MUX. Nessa etapa foram apresentados os resultados dos valores de NDVI, do PRI e do seu valor escalonado sPRI, do modelo de Fluxo de Carbono proposto nesta pesquisa, e do método proposto por Rahman *et al.* (2000) e finalmente é apresentado o modelo proposto de fluxo de carbono para o domínio morfoclimático da Amazônia proposto nesta pesquisa. Foram calculados a análise comparativa dos dois modelos (proposto nesta pesquisa e proposto por Rahman *et al.* 2000) por meio do teste estatístico *teste-t* e pelos índices R^2 e R^2 ajustado logo em seguida.

6.1 Modelagem do fluxo de carbono por meio dos dados ATTO

6.1.1 Interpolação dos dados por Krigagem

Os dados micrometeorológicos possuem grande variação de medições, devido as oscilações diárias de radiação solar entre outros, a interpolação apresentou um nível de confiança menor. Outra fragilidade no processo de interpolação foi observada em períodos com

ocorrência de falhas longas, como ocorrido com as variáveis H e LE nos meses de agosto a outubro de 2017, onde praticamente não apresentaram informação. Nesses casos, a interpolação tende a preencher os valores faltantes através de uma estimativa dos dados presentes.

O fato relacionado com a variabilidade dos dados pode ser observado nos valores da estatística descritiva, apresentada a seguir.

6.1.2 *Estatística descritiva*

Após a interpolação, todos os dados foram tabulados em uma única matriz, onde as linhas são as observações e as colunas são as variáveis analisadas. Feito isso, foram extraídos os resultados da estatística descritiva desse conjunto de variáveis, especialmente os valores de: média; erro padrão; mediana; desvio padrão; mínimo; máximo; e nível de confiança dos valores interpolados. Para todos os anos (Tabelas 1, 2 e 3), as variáveis LE, AirP, SW_in, PAR_in e NetRad foram as que apresentaram maiores erros padrão e de níveis de confiança. Isso é esperado devido a esses valores dependerem diretamente da incidência de radiação solar, ou seja, esses valores variam de acordo com o ciclo diário de luz do sol. O desvio padrão indicou que a medida de dispersão dos dados em torno de média amostral foi alta, isso indica que os dados estão afastados da média ou do valor esperado.

Tabela 1. Estatística descritiva (2017)

2017	Média	Desvio padrão	Mínimo	Máximo
fluxCO2	-1,63	10,43	-59,55	59,88
H	26,89	52,87	-88,96	299,88
LE	88,5	137,11	-250,01	699,69
Tau	0,15	0,16	-0,04	1,2
ws	2,9	1,14	0,09	12,71
airT	26,27	2,16	20,09	34,09
co2F	398,33	20,74	363,33	596,97
wwd	18,29	2,49	10	28,5
airP	98595,64	186,86	98001,58	99134,57
u	0,29	0,18	0	1,5
wDir	147,39	86,2	0,11	359,95
RH_81m	84,47	9,73	52,09	100
SW_in	197,41	228,27	-104,05	1108
SW_out	23,12	25,7	-9,71	125,31
PAR_in	405,19	467,61	-208,83	2316,94
PAR_out	12,35	13,56	-5,35	82,45
UV	9,93	11,41	-4,7	55,18
NetRad	128,4	189,32	-108,01	918,32
Rainfall	0,11	0,92	-1,6	32
LW_atm	417,41	12,16	381,14	458,64
LW_terr	452,26	13	420,21	494,51

Elaboração, GARCIA, E. A. B., (2020).

Tabela 2. Estatística descritiva (2018)

2018	Média	Desvio padrão	Mínimo	Máximo
fluxCO2	-1,77	11,35	-49,99	49,94
H	33,48	63,22	-49,93	299,76
LE	113,55	155,94	-79,69	698,55
Tau	0,14	0,21	-0,01	1,2
ws	2,79	1,31	0,02	14,84
airT	26,19	2,68	20,41	36,41
co2F	406,19	28,37	370,04	599,59
wwd	17,92	2,09	10,01	27,17
airP	98380,37	233,71	97682,1	99706,69
u	0,27	0,24	0	1,49
wDir	128,73	84,46	0	359,91
RH_81m	82,26	11,95	41,28	100
SW_in	198,32	282,98	-13,55	1156,7
SW_out	23,37	32,44	-0,85	130,6
PAR_in	409,12	582,96	-16,1	2411,5
PAR_out	12,4	16,85	-0,91	82,67
UV	10,11	14,16	-0,23	55,86
NetRad	126,07	231,38	-145,9	909,95
Rainfall	0,13	0,99	0	38,61
LW_atm	419,8	13,74	378,3	464,49
LW_terr	460,29	18,03	426,67	529,67

Elaboração, GARCIA, E. A. B., (2020).

Tabela 3. Estatística descritiva (2019)

2019	Média	Desvio padrão	Mínimo
Fluxco2	-1,97	10,93	-49,98
H	26,57	53,63	-49,98
Le	115,2	152,31	-79,88
Tau	0,19	0,66	-0,06
Ws	2,78	1,18	0,04
Airt	26,49	2,5	20,69
Co2f	410,98	25,32	348,35
Wwd	18,23	2	10,03
Airp	98312,98	202,44	97649,1
u	0,26	0,21	0,01
Wdir	128,35	77,14	0,08
Rh_81m	86,67	11,27	46,61
Sw_in	195,25	284,78	-3,1
Sw_out	22,53	31,85	-2,5
Par_in	400,59	584,91	0
Par_out	12,03	16,71	0
Uv	10,1	14,2	-2,75
Netrad	128,93	233,69	-113,6
Rainfall	0,13	1,01	0
Lw_atm	421,4	13,61	381,28
Lw_terr	453,55	16,02	424,54

Elaboração, GARCIA, E. A. B., (2020).

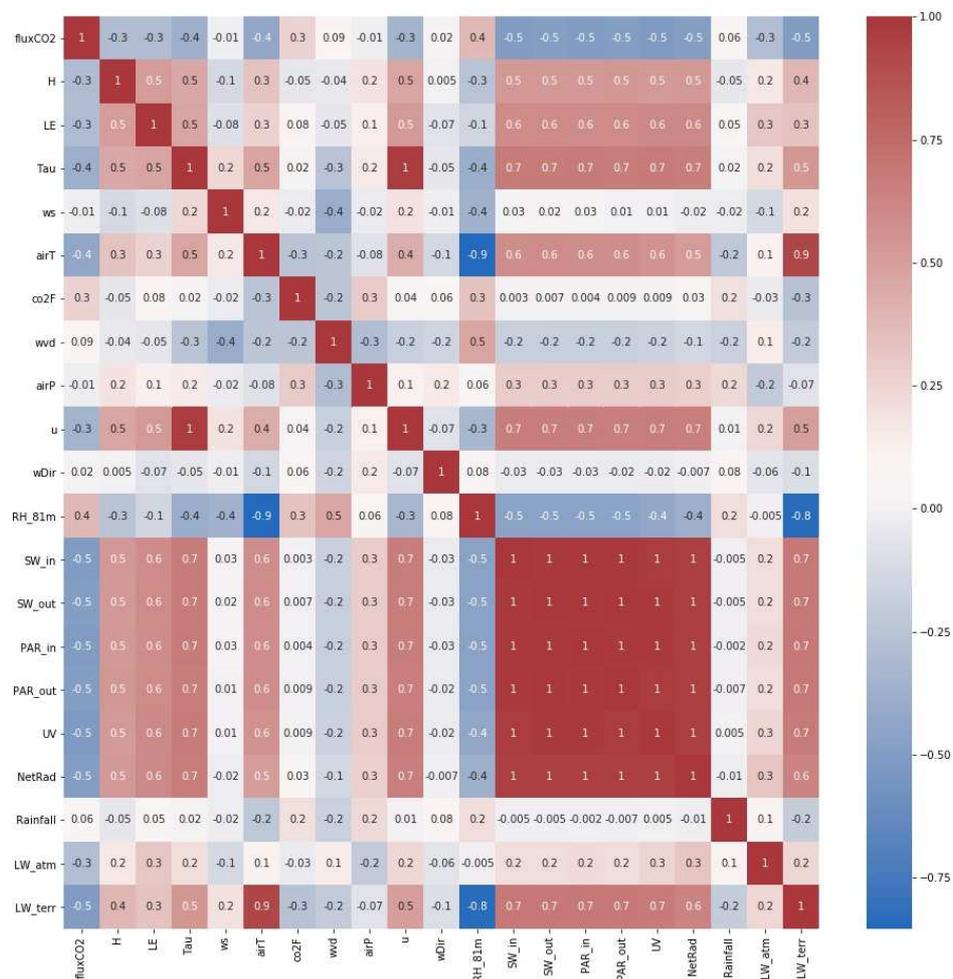
Por meio dos valores apresentados nas tabelas acima, constatou-se que as variáveis H, LE, airP, Wdir, SW_in, Par_in e NetRad apresentaram maiores valores de desvio padrão em relação a média. Infere-se que esse desvio padrão alto pode ser consequência da interpolação dos dados tendo em vista que houve muitas lacunas de dados para todos os anos. De modo geral, todos os anos mantiveram um padrão nos valores com poucas variações ao longo dos três anos. Vale ressaltar que o ano de 2018 apresentou significativas diferenças, propõe-se que o ano de 2018 possa ter sofrido erros de leituras mais frequentes que nos outros anos.

7.1.3 Matriz de Correlação

Nessa etapa, foi aplicada a matriz de correlação, pelo método de Pearson, sobre o conjunto/matriz de dados já interpolados. No resultado da correlação foi verificada,

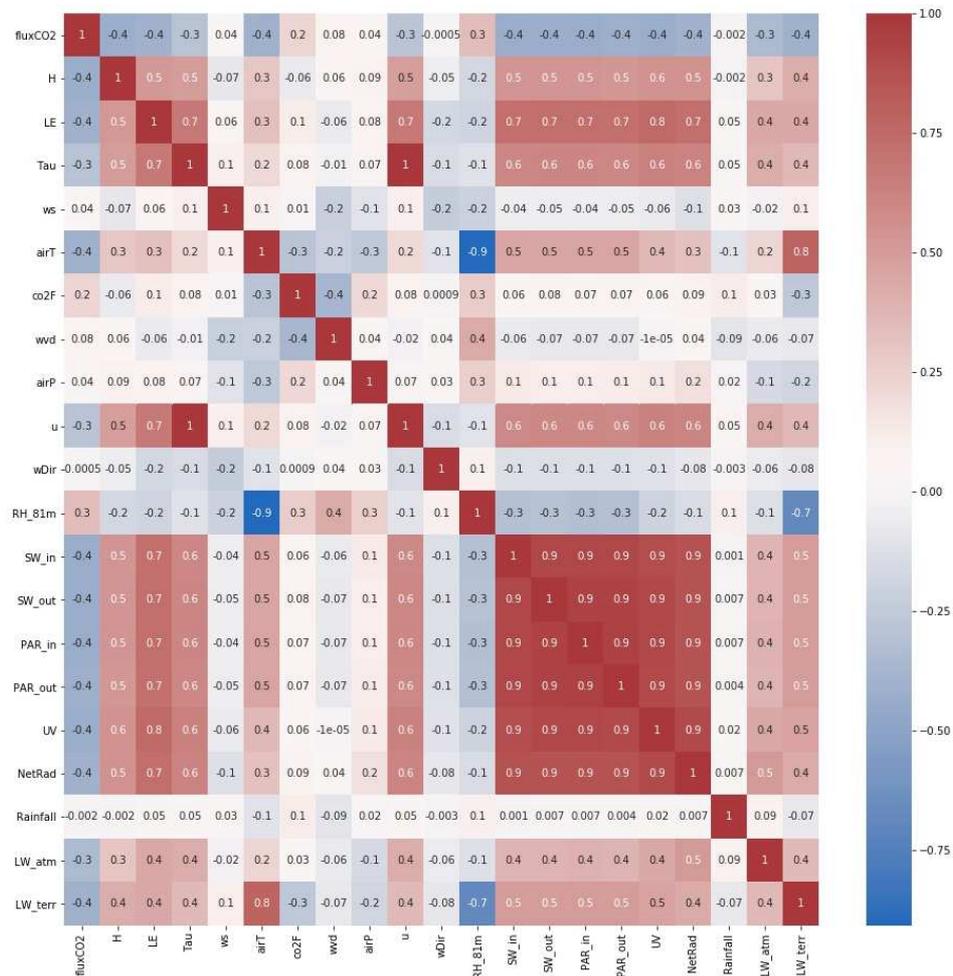
principalmente, a magnitude destes coeficientes em relação ao fluxo de carbono (Figura 15, 16 e 17). Sendo que os valores próximos de 1 indicam alta correlação e os valores próximos de zero indicam baixa correlação. As variáveis que possuíam alto *p*-valor e baixo índice de correlação com a variável de interesse foram ignoradas da análise. Ressalta-se que para a análise dos *p*-valores, utilizou-se a classificação de Cohen (1988), onde valores de *p* entre 0,10 e 0,29 foram considerados pequenos; valores entre 0,30 e 0,49 foram considerados como médios e valores entre 0,50 e 1,0 foram interpretados como grandes.

Figura 15. P-valores da matriz de dados segundo método Pearson (2017)



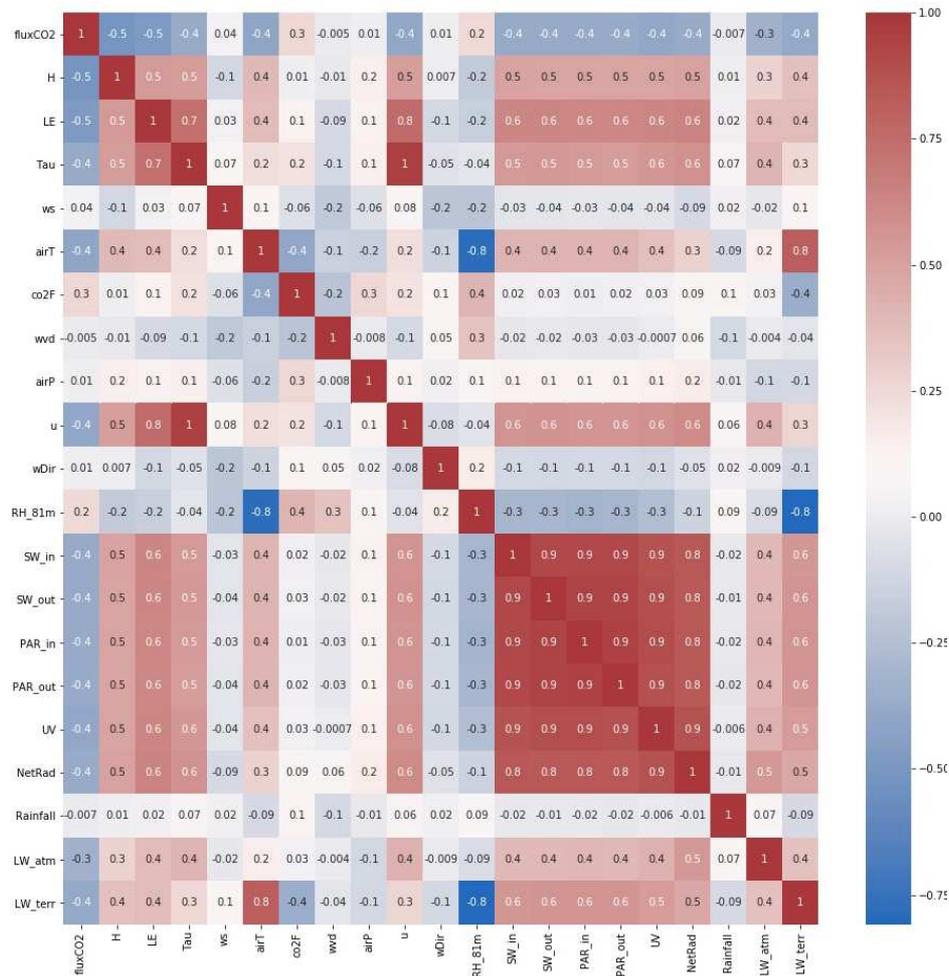
Elaboração, GARCIA, E. A. B., (2020).

Figura 16. *P*-valores da matriz de dados segundo método Pearson (2018)



Elaboração, GARCIA, E. A. B., (2020).

Figura 17. P-valores da matriz de dados segundo método Pearson (2019)



Elaboração, GARCIA, E. A. B., (2020).

Por meio dos *p-valores* mostrados na Tabela 4, as variáveis com valores acima de 5% (nível de significância) foram retiradas dos cálculos da regressão linear múltipla, para geração dos modelos de fluxo de carbono. Apesar da variável WS para o ano de 2017, e das variáveis wvd e airP, para o ano 2018, e WS e wvd para o ano de 2019 estarem abaixo do valor de 5%, suas observações foram removidas da regressão linear múltipla com o intuito de manter uma padronização dos dados para todos os três anos analisados. Assim, as variáveis WS, wvd, airP e Rainfall foram removidas das próximas etapas, referentes ao processo de modelagem do fluxo de carbono.

Tabela 4. *p*-valores referentes da matriz de correlação nos anos 2017, 2018 e 2019.

VARIÁVEIS	2017	2018	2019
fluxCO2	1	1	1
H	0,00%	0,00%	0,00%
LE	0,00%	0,00%	0,00%
Tau	0,00%	0,00%	0,00%
WS	4,49%	15,93%	3,10%
airT	0,00%	0,00%	0,00%
co2F	0,00%	0,00%	0,00%
wvd	42,08%	0,01%	0,18%
airP	67,64%	1,36%	22,14%
u	0,00%	0,00%	0,00%
wDir	0,00%	0,00%	0,00%
RH_81m	0,00%	0,00%	0,00%
SW_in	0,00%	0,00%	0,00%
SW_out	0,00%	0,00%	0,00%
PAR_in	0,00%	0,00%	0,00%
PAR_out	0,00%	0,00%	0,00%
UV	0,00%	0,00%	0,00%
NetRad	0,00%	0,00%	0,00%
Rainfall	30,25%	75,32%	25,15%
LW_atm	0,00%	0,00%	0,00%
LW_terr	0,00%	0,00%	0,00%

Elaboração, GARCIA, E. A. B., (2020).

7.1.4 Modelagem por meio de Regressão Linear Múltipla

Como descrito na metodologia, a Regressão Linear Múltipla (RLM) foi aplicada, primeiramente, sobre as variáveis microterológicas, selecionadas na etapa anterior, com base nos *p*-valores, em três momentos distintos nesta pesquisa. Neste subcapítulo e depois nos outros dois modelos propostos nos capítulos posteriores. A medida descritiva da qualidade do ajuste por meio do R^2 e do R^2 ajustado e o diagnóstico dos resíduos dos modelos 2017, 2018, e 2019, por meio dos valores máximo, mínimo e da Raiz do Erro Quadrático Médio (RMSE), foram calculados a fim de analisar o ajuste dos modelos gerados para o fluxo de carbono, com as variáveis independentes obtidas na torre ATTO. Após aplicação da RLM, usando o software *Action Stat*, foram gerados os resultados da análise de variância (ANOVA), com os respectivos *p*-valores, os resultados da análise exploratória dos resíduos, a estimativa dos coeficientes, com

seus respectivos *p-valores* e, por fim, o modelo de fluxo de carbono, propriamente dito. Os *p-valores* da tabela ANOVA, para cada modelo gerado, estão apresentados na Tabela 5:

Tabela 5. *p-valores* da tabela ANOVA

<i>Ano</i>	<i>2017</i>	<i>2018</i>	<i>2019</i>
<i>FATORES</i>	<i>P-valor</i>	<i>P-valor</i>	<i>P-valor</i>
H	0%	0%	0%
LE	0%	0%	0%
Tau	0%	0%	0%
airT	0%	0%	0%
co2F	0%	0%	0%
u	0%	26%	97%
wDir	0%	0%	0%
RH_81m	0%	0%	0%
SW_in	0%	0%	0%
SW_out	0%	0%	0%
PAR_in	0%	78%	3%
PAR_out	0%	59%	87%
UV	0%	0%	0%
NetRad	0%	0%	0%
LW_atm	0%	0%	0%
LW_terr	0%	0%	0%

Elaboração, GARCIA, E. A. B., (2020).

Analisando a tabela da ANOVA de cada modelo, observou-se que ocorreram 3 *p-valores* acima de 5% em 2018, e dois em 2019, mostrando que essas variáveis não são significativas para os respectivos modelos. Contudo, em 2017, todas as variáveis são significativas para o modelo referente a esse ano. A variável U foi a que apresentou pior *p-valor*, indicando apenas 3% de significância para o modelo de 2019. A segunda variável com valor alto foi a PAR_out com 13% de significância para o modelo do mesmo ano. Por outro lado, a PAR_in foi a pior para o ano de 2018, apontando 22% de significância para o modelo desse ano.

Os coeficientes de regressão, que indicam a relação negativa ou positiva da variável com o fluxo de carbono, foram estimados para geração dos modelos de cada ano: 2017, 2018 e 2019 (Tabela 6). Esses modelos foram utilizados para calcular a média de mudança das variáveis micrometeorológicas em relação a variável preditora, neste caso, o fluxo de carbono. Em adição, foram determinados os parâmetros estatísticos *p-valores* e a medida de dispersão

(desvio padrão), correspondentes a cada coeficiente, que permitiram analisar a importância de cada variável em um nível de significância de 5%.

Os coeficientes de regressão, o desvio padrão e os *p-valores* calculados para o modelo gerado a partir do conjunto de dados micrometeorológicos, referentes aos anos de 2017, 2018 e 2019, estão representados na Tabela 6:

Tabela 6. Coeficientes de regressão

Ano	2017		2018		2019	
	ESTIMATIVA	P-VALOR	ESTIMATIVA	P-VALOR	ESTIMATIVA	P-VALOR
Intercepto	-19,607	2%	-16,544	0%	-5,676	38%
H	0,005	1%	-0,021	0%	-0,052	0%
LE	-0,007	0%	-0,019	0%	-0,021	0%
Tau	-14,119	0%	4,669	0%	0,058	64%
airT	-0,297	0%	0,487	0%	-0,248	0%
co2F	0,092	0%	0,058	0%	0,073	0%
U	9,956	0%	0,742	35%	1,507	0%
wDir	-0,005	0%	-0,004	0%	-0,005	0%
Rh_81m	0,085	0%	0,176	0%	0,028	4%
SW_in	-0,017	2%	-0,006	33%	-0,038	0%
SW_out	0,269	0%	0,265	0%	0,308	0%
Par_in	-0,006	4%	0,003	9%	0,005	1%
Par_out	0,097	3%	-0,016	68%	0,023	47%
UV	-1	0%	-1,167	0%	-0,831	0%
NetRad	0,037	0%	0,027	0%	0,04	0%
LW_atm	-0,11	0%	-0,104	0%	-0,11	0%
LW_terr	0,071	0%	0,027	0%	0,065	0%

Elaboração, GARCIA, E. A. B., (2020).

As variáveis LE, Tau, airT, wDir, SW_in, PAR_in, UV e LW_atm, apresentaram coeficientes negativos, o que permite concluir que, no intervalo da análise, um aumento do valor dessas variáveis descritas, causará uma redução no valor do fluxo de carbono, isto é, há uma relação inversamente proporcional dessas variáveis com o fluxo de carbono. Em contrapartida, as variáveis co2F, UV, U, RH_81m, SW_out, PAR_out, NetRad e LW_terr apresentaram sinal positivo, indicando que, no intervalo da análise, um aumento do valor dessas variáveis atmosféricas provoca um aumento no fluxo de carbono.

As variáveis Tau (-14,119) e UV (-1,000) apresentaram maior correlação inversa com o fluxo de carbono, enquanto a variável U (9,956) domina a correlação direta com o referido

fluxo. Os demais valores apresentaram valores abaixo de 0,3 positivo ou negativo, o que indica uma correlação direta ou indireta, porém, de menor relevância para o fluxo de carbono.

Ainda na Tabela 6, pode-se ver que a maioria dos coeficientes demonstram *p-valores* abaixo de 5%. Nesse caso, a hipótese nula (H_0) é que o coeficiente é não significativo, demonstrando a rejeição da hipótese nula e aceitando a hipótese alternativa (H_1), dado que o nível de significância foi de 5%. Isso significa que o intercepto e as variáveis de entrada são todas importantes para o modelo. Desta forma o modelo inicial de fluxo de carbono para 2017 foi calculado com a seguinte expressão (Equação 12):

$$\begin{aligned} FluxoCO2reg2017 = & -19,60657804 + 0,004627142 * H + 0,006602615 * \\ & -14,11903308 * Tau - 0,296834643 * airT + 0,091647547 * co2F + 9,956458828 * \\ & u - 0,005395666 * wDir + 0,085039022 * RH_{81m} - 0,017169183 * SW_{in} + \\ & 0,268681989 * SW_{out} - 0,006162745 * PAR_{in} + 0,097319236 * PAR_{out} - \\ & 1,000218469 * UV + 0,036737435 * NetRad - 0,109887319 * LW_{atm} + 0,071075749 * \\ & LW_{terr} \end{aligned} \quad (12)$$

Para o ano de 2018, as variáveis que apresentaram coeficientes negativos foram: H, LE, wDir, SW_in, PAR_out, UV e LW_atm. Desta forma, conclui-se que, no intervalo da análise, um aumento dos valores dessas variáveis descritas, aumentará o valor do fluxo de carbono. Isto é, há uma relação inversamente proporcional entre esse conjunto de variáveis e o fluxo de carbono. Em outra mão, as variáveis que apresentaram coeficientes positivos (Tau, airT, co2F, u, RH_81m, SW_out, PAR_in, NetRad e LW_terr) indicam que, no intervalo da análise, um aumento no valor dessas variáveis atmosféricas provoca um aumento no fluxo de carbono, mantendo uma relação direta.

Os dados Tau (4,669), airT (0,487) e u (0,741) foram os dados que apresentaram maior correlação positiva com o fluxo de carbono. A variável UV (-1,166) é a que mais contribui inversamente com o fluxo de carbono. Os demais valores apresentaram valores abaixo de 0,3 positivo ou negativo, o que indica uma correlação direta ou indireta, porém, de menor intensidade em relação ao fluxo de carbono. É interessante observar que as variáveis Tau, U e UV são as mesmas que mais contribuíram no modelo do ano de 2017, ainda que com sinal invertido no caso da variável Tau.

Na Tabela 6 ainda pode ser visto que os coeficientes demonstraram *p-valores* abaixo de 5%, exceto as variáveis u (35%), SW_in (33%), PAR_in (9%) e PAR_out (68%). Nesse caso,

essas quatro variáveis não são significativas para o modelo, mas não devem ser retiradas porque são parte fixa do modelo proposto. Nessa análise, a hipótese nula (H_0) determina que essas variáveis são não significativas. As demais variáveis aceitam rejeição da hipótese nula, aceitando a hipótese alternativa (H_1), dado que o nível de significância foi de 5%. Isso significa que o intercepto e as variáveis de entrada são todas importantes para o modelo. Desta forma, o modelo inicial de fluxo de carbono para 2018 foi calculado com a seguinte expressão (Equação 13).

$$\begin{aligned} FluxoCO2reg2018 = & -16,54352643 - 0,020662219 * H - 0,019308326 * \\ & +4,669447669 * Tau + 0,487091587 * airT + 0,057507739 * co2F + 0,741894401 * \\ & u - 0,00356574 * wDir + 0,17609043 * RH81m - 0,005574481 * SWin + \\ & 0,264710957 * SWout + 0,003478092 * PARin - 0,015877102 * PARout - \\ & 1,166989753 * UV + 0,02703591 * NetRad - 0,104192589 * LWatm + 0,027174155 * \\ & LWterr \end{aligned} \quad (13)$$

Com base na Tabela 6 é possível observar que as variáveis H, LE, airT, wDir, SW_in, UV e LW_atm apresentaram coeficientes negativos. Igualmente aos dois anos anteriores, conclui-se que, no intervalo da análise, um aumento do valor dessas variáveis descritas, ocorrerá redução no valor do fluxo de carbono. Há, portanto, uma relação inversamente proporcional entre essas variáveis e o fluxo de carbono. Por outro lado, as variáveis que apresentaram coeficientes com sinal positivo (Tau, co2F, u, RH_81m, SW_out, PAR_in, PAR_out, NetRad e LW_terr) permitem inferir a ocorrência de uma relação direta entre essas variáveis atmosféricas e o fluxo de carbono.

Novamente, as variáveis u (1,507) e UV (-0,830) foram aquelas que apresentaram maior correlação com o fluxo de carbono. Curiosamente, a variável Tau (0,057) que se destacou nos modelos de 2017 e 2018, com maiores valores entre os coeficientes, apresentou valor insignificante no ano 2019. Os demais valores apresentaram valores abaixo de 0,3 positivo ou negativo, indicando menor contribuição em relação ao fluxo de carbono.

Nota-se que os coeficientes demonstraram os *p-valores* abaixo de 5%, exceto para as variáveis Tau (64%) e PAR_out (47%) e para o intercepto (38%). Isso implica na afirmação de que essas variáveis e intercepto são não significativos para o modelo. Contudo, esses parâmetros não devem ser retirados do modelo, porque são partes fixa do mesmo e suas

retiradas implicam em alteração do modelo tanto positivo quanto negativamente. Nessa análise, a hipótese nula (H_0) determina que estas variáveis não são significativas. As demais variáveis aceitam a rejeição da hipótese nula e aceite da hipótese alternativa (H_1), dado que o nível de significância foi de 5%. Isso significa que o intercepto e todas as variáveis de entrada são todas importantes para o modelo. Desta forma, o modelo inicial de fluxo de carbono para 2019 foi calculado com a seguinte expressão (Equação 14).

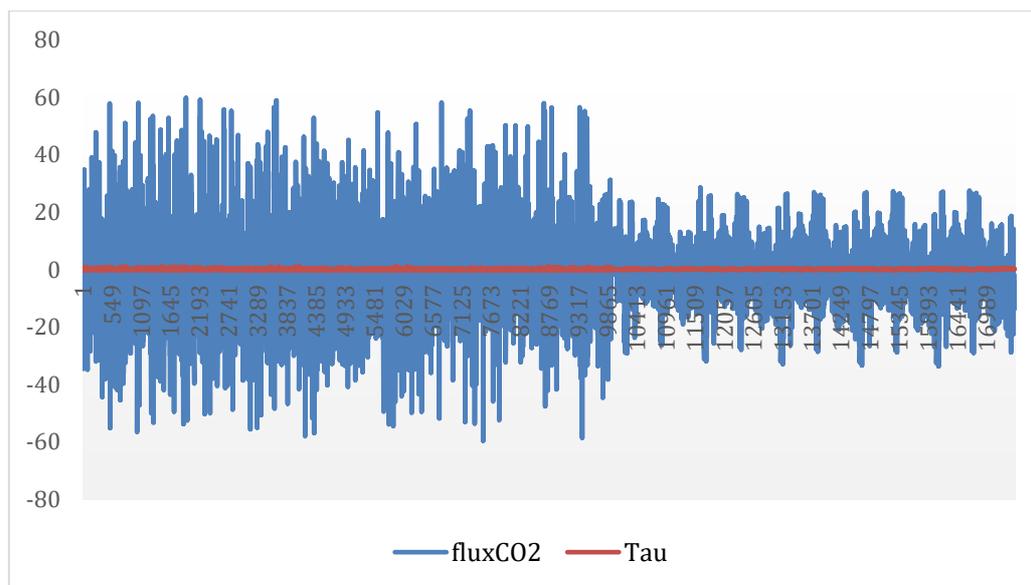
$$\begin{aligned} FluxoCO2reg2019 = & -5,676100057 - 0,052156131 * H - 0,020998345 * \\ & + 0,057878683 * Tau - 0,248251561 * airT + 0,072685179 * co2F + 1,507359599 * \\ & u - 0,004652838 * wDir + 0,027670038 * RH81m - 0,037628914 * SWin + \\ & 0,308468272 * SWout + 0,005406962 * PARin - 0,015877102 * PARout - \\ & 0,830986225 * UV + 0,040498713 * NetRad - 0,109938071 * LWatm + \\ & 0,064941985 * LWterr \end{aligned} \quad (14)$$

Ao verificar os três modelos, verificou-se que as variáveis Tau, U e UV tiveram alta correlação nos coeficientes, assim, como descrito nos Quadros 1 e 2, a variável Tau equivale ao fluxo do momento corrigido, pois a melhor forma de estimar esses fluxos é compensando os fluxos não corrigidos devido a perdas espectrais pelos equipamentos, portanto, toda correção nos fluxos de ar afetará diretamente as medições de gases realizadas pelo equipamento. A variável U corresponde a velocidade de fricção da massa de ar, ou seja, se trata da velocidade igual à raiz quadrada da tensão superficial dividida pela densidade do ar desta maneira é possível deduzir que quanto maior a fricção do fluxo de ar presente no equipamento, maior será a leitura dos fluxos de gases do equipamento e portanto, maior será o tempo de análise desse fluxo presente.

A variável UV corresponde à medição da radiação ultravioleta incidente a resposta dos instrumentos em medir o fluxo do analisador de gás infravermelho, ou seja, diferentes moléculas absorvem certos comprimentos de onda de luz. As moléculas de gás carbônico, ao serem iluminadas pode-se medir a quantidade de luz absorvida pelas moléculas em questão. Portanto cria-se uma proporção direta entre a quantidade de luz absorvida e a quantidade de molécula existente no fluxo de ar, assim o dióxido de carbono é analisado por meio da luz infravermelha. Devido ao fato desses gases serem analisados por meio de radiação eletromagnética (ondas espectrais da faixa do infravermelho) pode-se supor que o equipamento,

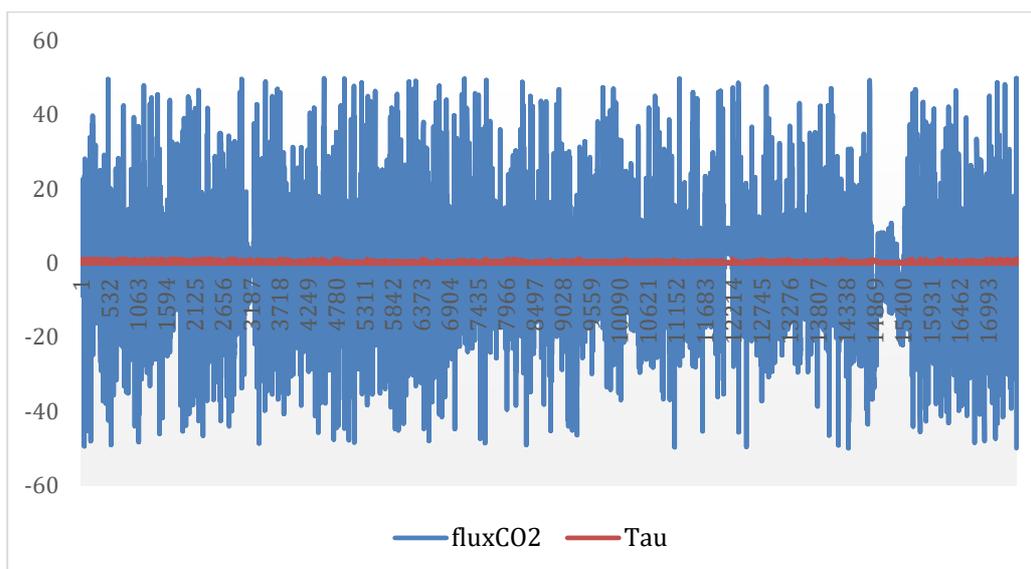
ou o fluxo de ar que contém o gás carbônico, sofre influências nas medições do fluxo de carbono que ainda não são bem compreendidas e que carecem de mais estudos. Uma análise mais precisa sobre a relação dessas variáveis em relação ao fluxo de carbono foi realizada por meio dos gráficos de dispersão abaixo:

Figura 18. Gráfico da relação Tau X Fluxo de Carbono (2017)



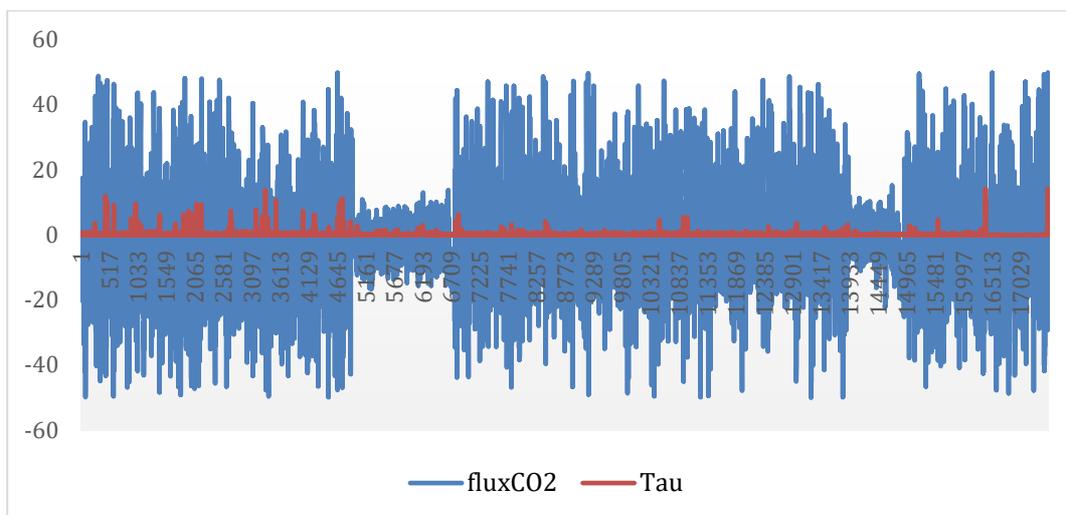
Elaboração, GARCIA, E. A. B., (2020).

Figura 19. Gráfico da relação Tau X Fluxo de Carbono (2018)



Elaboração, GARCIA, E. A. B., (2020).

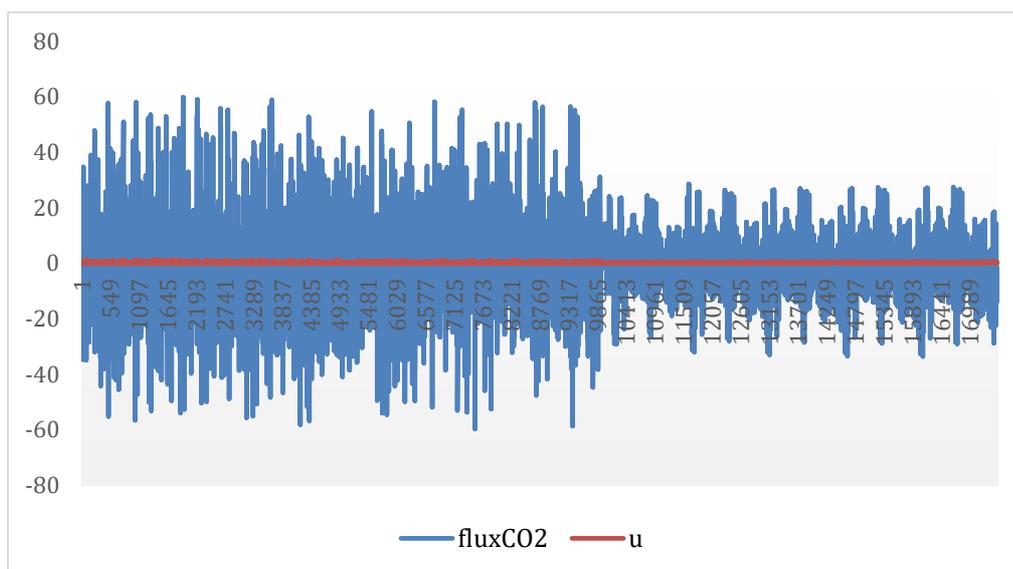
Figura 20. Gráfico da relação Tau X Fluxo de Carbono (2019)



Elaboração, GARCIA, E. A. B., (2020).

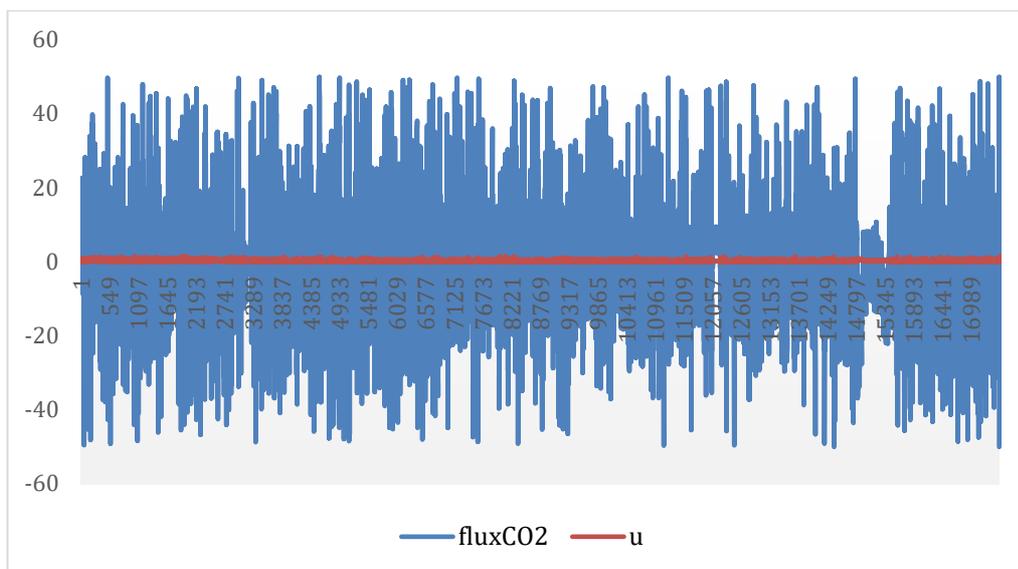
Nos gráficos apresentados, os valores de Tau nos anos de 2017 e 2018 não apresentaram variações significativas, que coincide com os coeficientes de correlações para esses mesmos anos. No entanto, para 2019, é possível que os picos de dados presentes ao longo das observações tenha interferido na contribuição dessa variável para o modelo de 2019. Prosseguindo, a variável U em relação ao fluxo de carbono está apresentado nos conjuntos de gráficos abaixo:

Figura 21. Gráfico da relação U x Fluxo de carbono (2017)



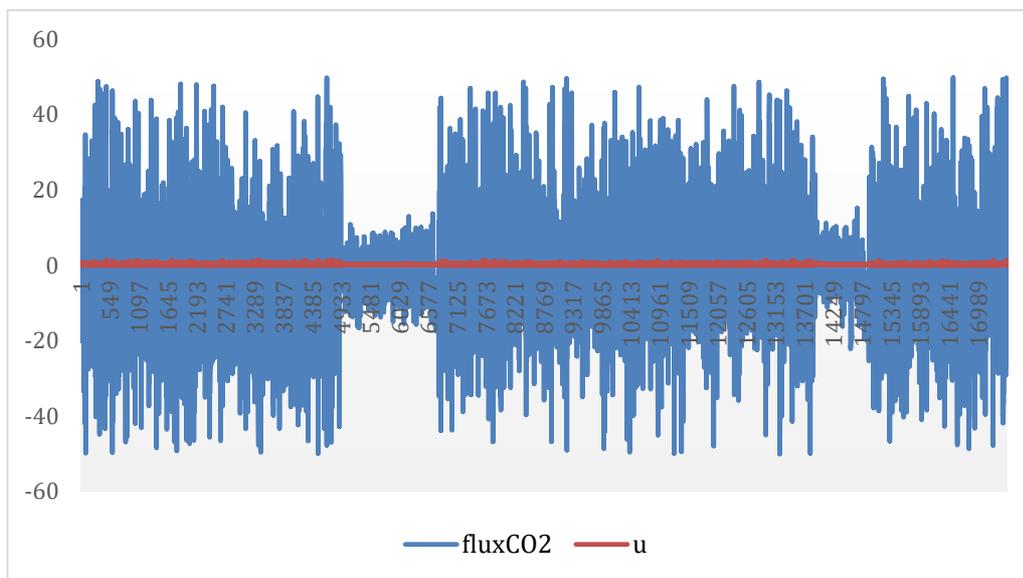
Elaboração, GARCIA, E. A. B., (2020).

Figura 22. Gráfico da relação U x Fluxo de Carbono (2018)



Elaboração, GARCIA, E. A. B., (2020).

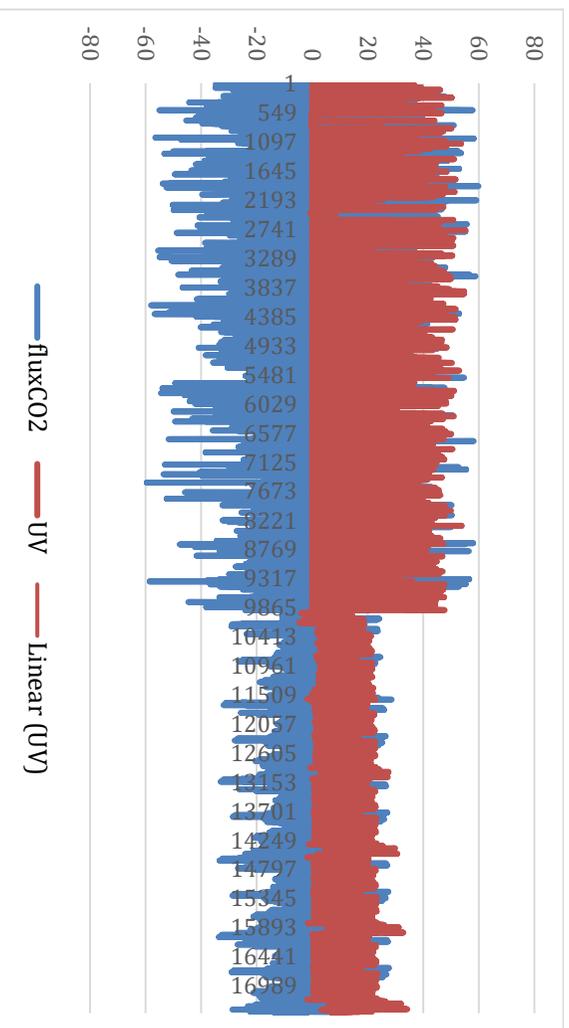
Figura 23. Gráfico da relação U x Fluxo de Carbono (2019)



Elaboração, GARCIA, E. A. B., (2020).

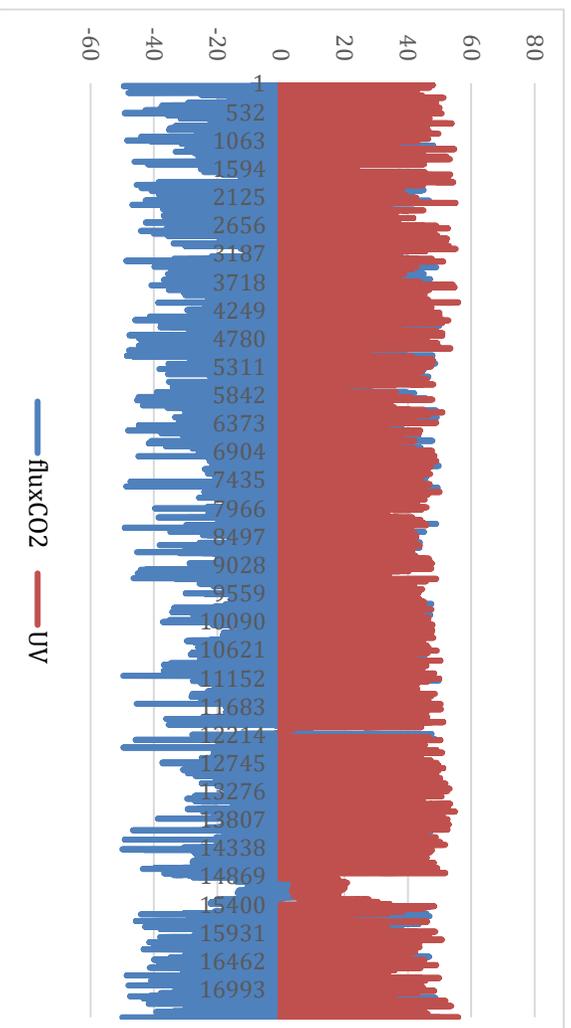
Por meio dos gráficos acima não foi possível constatar picos de variação dos dados ao longo dos anos com exceção de uma ligeira diminuição nas observações em torno do número 5539. Finalizando as análises das três variáveis para esses modelos, abaixo estão apresentados os gráficos de dispersão entre os valores da variável UV e do fluxo de carbono.

Figura 24. Gráfico da relação UV x Fluxo de Carbono (2017)



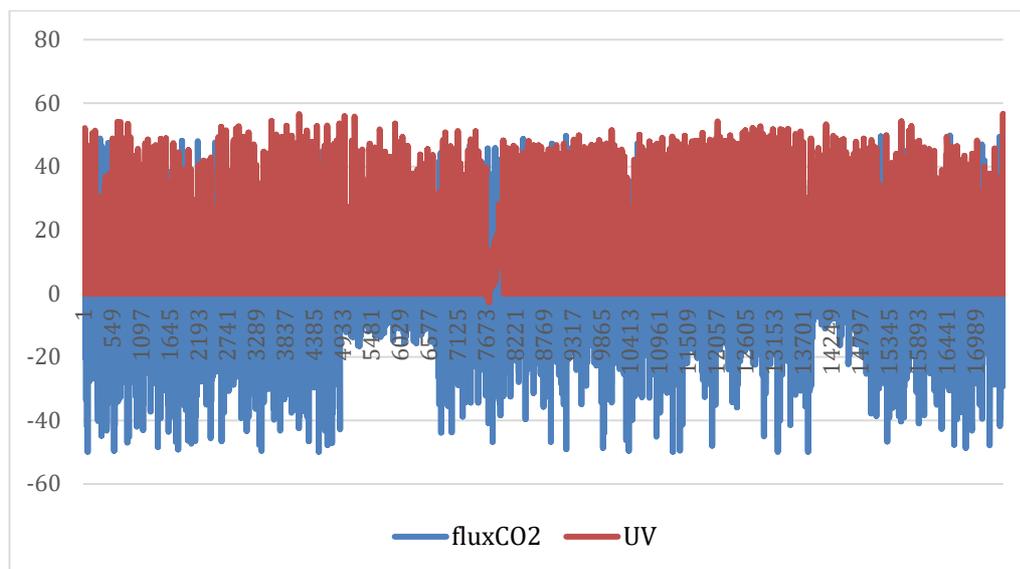
Elaboração, GARCIA, E. A. B., (2020).

Figura 25. Gráfico da relação UV x Fluxo de Carbono (2018)



Elaboração, GARCIA, E. A. B., (2020).

Figura 26. Gráfico da relação UV x Fluxo de Carbono (2019)



Elaboração, GARCIA, E. A. B., (2020).

As observações dos valores da variável UV coincidem com os valores de fluxo de carbono. Exceto para os valores negativos de fluxo de carbono pelo fato dos valores negativos estarem associados aos períodos com menor incidência, ou a ausência (período noturno), de radiação solar. É possível deduzir por meio dos dados que o fluxo de carbono possui uma correlação direta com os valores de fluxo de carbono, porém, essa correlação ainda não é bem compreendida e não foi possível encontrar na literatura científica estudos sobre correlações entre as medições de fluxo de carbono e de raios ultravioleta. Em seguida foram calculados os valores de R^2 , R^2 ajustado e o desvio padrão dos modelos na Tabela 7, abaixo:

Tabela 7. Medida descritiva da qualidade do ajuste

<i>Modelo</i>	<i>DESVIO PADRÃO DOS RESÍDUOS</i>	<i>GRAUS DE LIBERDADE</i>	<i>R²</i>	<i>R² AJUSTADO</i>
2017	8,914	17503	0,271	0,270
2018	9,652	17503	0,278	0,277
2019	9,045	17503	0,316	0,315

Elaboração, GARCIA, E. A. B., (2020).

Dados os valores de R^2 e R^2 ajustado (Tabela 7), tem-se que cerca de 28% (2017), 28% (2018) e 32% (2019) das variabilidades dos dados são explicadas pelos modelos de regressão ajustados. São valores relativamente baixo, levando a entender que os modelos não possuem poder estatístico para explicar o conjunto de dados reais, porém, devido à complexidade natural

de algumas das variáveis e a dimensão dos dados, que são medições realizadas em escala de 30 minutos, durante o ano inteiro, totalizando 17.520 observações anuais para cada variável, pode-se afirmar que esses percentuais são considerados um ajuste aceitável.

No entanto, a linha pode indicar um padrão ou estimar interpolações de dados até certo nível, isso permite que o modelo explique parcialmente a variância. Assim, pode haver outras características locais, geofísicas e/ou meteorológicas que teriam maior poder estatístico de explicação da variação dos dados observados. Os valores também apresentaram um desvio padrão alto indica que os dados estão mais distantes da média, isto já é esperado devido à variação dos valores de fluxo de carbono ao longo do dia. Mesmo assim, esta tendência fornece a previsão da variabilidade das observações de fluxo de carbono, embora os dados reais estejam mais distantes da linha de regressão. Portanto, infere-se que esses modelos não abordaram todos os preditores relevantes para explicar o fluxo de carbono real, contudo, mesmo com valores de R^2 e R^2 ajustados significativamente abaixo dos valores indicados por Cohen (1988), estes modelos indicam que a regressão aplicada tem poder estatístico significativo para explicar a variabilidade dos dados.

Ao verificar os valores de máximo, mínimo do do RMSE das observações (Tabela 8), fica evidente porque os modelos não se ajustaram bem suas linhas de regressão:

Tabela 8. Valores máximos, mínimos e do RMSE

MODELO	2017	2018	2019
MÁXIMO	25,470	49,941	49,857
MÍNIMO	-29,852	-49,989	-49,977
RMSE	8,909	9,648	9,040

Elaboração, GARCIA, E. A. B., (2020).

O RMSE determina a magnitude média dos erros e é sempre um valor positivo. Quanto mais próximo de zero, maior a precisão da modelagem. Embora os valores da raiz do erro médio quadrático obtidos nesse estudo sejam diferentes de zero, vale salientar que, a variabilidade dos dados, juntamente à diferença entre os tipos de variáveis analisadas, faz com que esse RMSE seja aceitável em estudos meteorológicos, que é o caso dessa pesquisa. Pode-se citar, como exemplo, altos valores de RMSE medidos em estudos como o de Werner *et al.* (2018), que gerou um modelo de previsão de umidade relativa do ar. No entanto, esses autores mostraram que o modelo é capaz de explicar satisfatoriamente a variabilidade dos referidos dados. A pesquisa de Ferrari e Ozaki (2014) também criaram modelos climatológicos para a previsão de

secas extremas e mediram elevado valor de RMSE, contudo concluíram que o modelo possui um ajuste significativo em relação aos dados reais.

6.1.5 Modelagem dos dados transformados por componentes principais

Ao concluir a elaboração dos primeiros modelos de fluxo de carbono, apresentados no subcapítulo anterior, utilizou-se a Análise por Componentes Principais (ACP) para tentar reduzir os erros encontrados, diminuindo, conseqüentemente, a dimensionalidade dos dados. Assim, buscou-se aumentar os valores de R^2 e R^2 ajustado e diminuir o valor do RMSE.

Como dito, o intuito é reduzir a quantidade de variáveis sem diminuir consideravelmente a quantidade de informação das variáveis. Adicionalmente, a ACP pode interferir nas discrepâncias das variáveis, que afetam a qualidade do ajuste do modelo. O conjunto de dados providenciados pela ATTO é extenso, portanto, é natural que se reduza o tamanho dos dados, minimizando perdas de informação para facilitar a compreensão/interpretação e aprimorar o processamento dos modelos. Assim, novos modelos de fluxo de carbono foram elaborados a partir da transformação das variáveis originais em componentes principais.

Desta forma, a técnica de ACP foi aplicada sobre as variáveis originais, gerando os novos componentes, para posterior aplicação da RLM e, finalmente, elaboração dos novos modelos de fluxo de carbono. Os resultados da ACP estão apresentados na Tabela 9 referentes aos anos 2017, 2018 e 2019, respectivamente.

Tabela 9. Autovalores dos componentes principais dos anos 2017, 2018 e 2019

	CP1	CP2	CP3	CP4	CP5	CP6	CP7	CP8	CP9	CP10	CP11	CP12	CP13	CP14	CP15	CP16
Autovalores 2017	57%	12%	7%	6%	6%	5%	4%	2%	1%	1%	0%	0%	0%	0%	0%	0%
Autovalores 2018	56%	13%	8%	6%	6%	4%	2%	2%	2%	1%	0%	0%	0%	0%	0%	0%
Autovalores 2019	54%	14%	7%	6%	5%	4%	3%	2%	2%	1%	0%	0%	0%	0%	0%	0%

Elaboração, GARCIA, E. A. B., (2020).

Os resultados da análise por componentes principais permitiram verificar que uma menor quantidade de variáveis explica bem as variáveis observadas nos três anos. Pode-se constatar que em nove componentes estão concentradas aproximadamente 99% de todas as informações contidas nas 16 variáveis originais.

Pelo fato dos 9 (nove) primeiros componentes principais explicarem cerca de 99% das informações originais, esses conjuntos de componentes foram selecionados nos três anos (2017, 2018 e 2019) para cálculo da regressão (RLM) e para a elaboração dos novos modelos. Inicialmente, foi gerada a tabela ANOVA, com os respectivos *p-valores*, como mostrado na Tabela 10:

Tabela 10. *p-valores* da tabela ANOVA – ACP

<i>Ano</i>	<i>2017</i>	<i>2018</i>	<i>2019</i>
<i>Fatores</i>	<i>P-valor</i>	<i>P-valor</i>	<i>P-valor</i>
CP1	0%	0%	0%
CP2	0%	0%	4%
CP3	5%	41%	0%
CP4	1%	0%	0%
CP5	0%	0%	0%
CP6	0%	0%	0%
CP7	0%	0%	0%
CP8	0%	0%	0%
CP9	0%	0%	0%

Elaboração, GARCIA, E. A. B., (2020).

Os valores apresentados na Tabela 10 indicam que houve uma melhora nos novos modelos em comparação com os modelos gerados sem a ACP. Isto é, apenas o *p-valor* referente ao componente 3, do ano de 2018, ficou acima de 5%. Os demais componentes demonstraram-se significativos para os modelos. Ressalta-se que mesmo com esse caso isolado em 2018, nenhum componente foi eliminado da geração dos modelos de fluxo de carbono, com o intuito de comparar os modelos entre si. As estimativas dos coeficientes do modelo, o desvio padrão e os *p-valores* referentes a cada componente, determinados para os anos de 2017, 2018 e 2019, estão relacionados na Tabela 11:

Tabela 11. Coeficientes de regressão 2017, 2018 e 2019 – ACP

<i>Ano</i>	<i>2017</i>		<i>2018</i>		<i>2019</i>	
	<i>ESTIMATIVA</i>	<i>P-VALOR</i>	<i>ESTIMATIVA</i>	<i>P-VALOR</i>	<i>ESTIMATIVA</i>	<i>P-VALOR</i>
INTERCEPTO	-1,633	0%	-1,766	0%	-1,967	0%
CP1	1,493	0%	1,645	0%	1,570	0%
CP2	0,525	0%	-0,317	0%	0,093	4%
CP3	-0,127	5%	0,056	41%	-0,662	0%
CP4	-0,183	1%	0,588	0%	-0,363	0%

CP5	1,463	0%	0,568	0%	-0,491	0%
CP6	-1,428	0%	2,099	0%	4,038	0%
CP7	0,958	0%	-1,317	0%	0,789	0%
CP8	1,097	0%	-2,336	0%	-1,123	0%
CP9	-1,816	0%	2,342	0%	2,081	0%

Elaboração, GARCIA, E. A. B., (2020).

No modelo de 2017, os coeficientes apresentaram os *p-valores* abaixo ou igual de 5%. Nesse caso, rejeita-se a hipótese nula (Ho) e aceita-se H1, mostrando que o intercepto e os 9 componentes são importantes para o modelo proposto. Como não houve variáveis com *p-valores* maiores que 5%, não foi retirado nenhum componente. Os coeficientes dos componentes CP3, CP4, CP6 e CP9 deram valores negativos, indicando que, no intervalo da análise, um aumento do valor desses componentes provoca uma redução no valor do fluxo de carbono. Por outro lado, os coeficientes dos componentes CP1, 2, 5, 7 e 8 possuem valores positivos, conclui-se que, no intervalo da análise, um aumento do valor desses componentes provoca um aumento no fluxo de carbono. Apenas os coeficientes 3 e 4 apresentaram uma menor correlação com o fluxo de carbono, os demais apresentaram uma alta correlação. Os CP1 e CP9 são os que mais contribuem com o modelo, de forma aumentando ou reduzindo, respectivamente.

Desta forma, o modelo inicial de fluxo de carbono de 2017 foi calculado com a seguinte expressão (Equação 15):

$$\begin{aligned}
 FluxCO2acp2017 = & -1,633287677 + 1,492709594 * CP1 + 0,524663356 * CP2 - \\
 & 0,126558359 * CP3 - 0,183147065 * CP4 + 1,463229589 * CP5 - 1,427792509 * \\
 & CP6 + 0,957901422 * CP7 + 1,096931637 * CP8 - 1,815563804 * CP9
 \end{aligned}
 \tag{15}$$

Para o modelo de 2018, quase todos os coeficientes apresentaram os *p-valores* abaixo de 5%, rejeitando-se a hipótese nula (Ho); no entanto, o componente 3 apresentou percentual de 41%, aceitando assim a hipótese nula (Ho). Mesmo assim, por motivos já explicados anteriormente, o componente 3 foi mantido no modelo. Os coeficientes dos componentes CP2, 7 e 8 apresentaram valores negativos, indicando-se que, no intervalo da análise, um aumento do valor desses componentes provoca uma redução no valor do fluxo de carbono. Por outro

lado, os coeficientes dos componentes 1, 3, 4, 5, 6 e 9 possuem valores positivos, concluindo-se que, no intervalo da análise, um aumento do valor desses componentes provoca um aumento no fluxo de carbono. Apenas o coeficiente do componente 3 apresentou baixa correlação, os demais coeficientes apresentaram alta correlação com o fluxo de carbono, com valores acima de 0,3. Destaca-se a maior contribuição dos componentes CP8 e CP9, de forma similar, mas com sinal contrário.

Desta forma, o modelo inicial de fluxo de carbono para 2018 foi calculado com a seguinte expressão (Equação 16).

$$\begin{aligned} FluxCO2acp2018 = & -1,766491804 + 1,645387439 * CP1 - 0,317082145 * CP2 + \\ & 0,055500725 * CP3 + 0,588293206 * CP4 + 0,568488024 * CP5 + 2,099318887 * \\ & CP6 - 1,317445673 * CP7 - 2,335576865 * CP8 + 2,341935003 * CP9 \end{aligned} \quad (16)$$

Para o modelo de 2019, todos os coeficientes apresentaram os *p-valores* abaixo de 5%, rejeitando-se a hipótese nula (H₀). Os coeficientes dos componentes 3, 4, 5 e 8 deram valores negativos, exprimindo-se que, no intervalo da análise, um aumento do valor desses componentes provoca uma redução no valor do fluxo de carbono. Por outro lado, os coeficientes dos componentes 1, 2, 6, 7 e 9 possuem valores positivos, assinalando-se que, no intervalo da análise, um aumento do valor dessa variável provoca um aumento no fluxo de carbono. Apenas o coeficiente do componente 2 apresentou baixa colaboração com o modelo desse ano. Os demais coeficientes apresentaram valores expressivos de contribuição com o modelo do fluxo de carbono, com valores acima de 0,3. Nesse modelo, os componentes CP6 (4,038) e CP9 (2,081) são os que mais contribuíram com o modelo. É interessante observar que nos três modelos apresentados, o componente CP9 está entre os que mais contribuíram.

O modelo inicial de fluxo de carbono para 2019 foi calculado com a seguinte expressão (Equação 17).

$$\begin{aligned} FluxCO2acp2019 = & -1,766491804 + 1,569735449 * CP1 + 0,092640176 * CP2 - \\ & 0,662451506 * CP3 - 0,362727885 * CP4 - 0,490726807 * CP5 + 4,038004449 * \\ & CP6 + 0,788819365 * CP7 - 1,122720555 * CP8 + 2,081007891 * CP9 \end{aligned} \quad (17)$$

Após gerar os modelos do fluxo de carbono, com base na ACP, verificou-se a qualidade do ajuste dos mesmos, por meio dos valores do R^2 e R^2 ajustado que resultaram em 24% para 2017, 25% para 2018 e de 29% para 2019. Nesse caso, os modelos não expressam a variabilidade dos dados pelo modelo linear de modo satisfatório, porém com certo nível de ajuste. Essa tendência fornece a previsão da variabilidade das observações para esses percentuais, embora os dados reais estejam mais distantes da linha de regressão. A análise destes modelos se torna semelhante aos modelos anteriores, por não incluir todos os preditores relevantes para explicar a variabilidade dos dados. Mesmo com os valores de R^2 e R^2 ajustados menores com ACP, eles são significativamente diferentes de 0%, indicando que a regressão aplicada tem o poder estatístico significativo.

Tabela 12. Medida descritiva da qualidade do ajuste – ACP

MODELO	<i>DESVIO PADRÃO DOS RESÍDUOS</i>	<i>GRAUS DE LIBERDADE</i>	R^2	R^2 <i>AJUSTADO</i>
2017	9,114	17510	0,237	0,236
2018	9,861	17510	0,246	0,245
2019	9,221	17510	0,288	0,288

Elaboração, GARCIA, E. A. B., (2020).

Dado o valor de 0,237 para 2017, do valor de 0,246 para 2018 e o valor de 0,288 para 2019, a variabilidade dos dados é explicada parcialmente pelos modelos de regressão ajustado, os modelos se ajustaram bem ao conjunto de dados de maneira significativamente melhor que os modelos do subcapítulo anterior (7.1.4) com a metade dos dados utilizados. É possível induzir que a perda de informações por meio da ACP, por menor que seja, interferiu no ajuste do modelo na linha de regressão e na qualidade do ajuste dos dados reais. Contudo, embora com os valores desses índices sejam ligeiramente menores nos modelos com ACP, tem-se o benefício de obter uma explicação estatística semelhante ao capítulo anterior com apenas 9 componentes em substituição às 16 variáveis originais.

Os resultados dos RMSE, de máximo e mínimo dos componentes estão apresentados na Tabela 13, abaixo:

Tabela 13. Valores de máximos, mínimos e RMSE – ACP

MODELO	2017	2018	2019
MÁXIMO	20,040	15,724	18,730
MÍNIMO	-21,956	-21,898	-27,241
RMSE	9,112	9,858	9,219

Elaboração, GARCIA, E. A. B., (2020).

Apesar dos valores de RMSE e de R^2 e R^2 ajustados não possuírem uma precisão elevada, a ACP possibilitou verificar quais variáveis possuem maior correlação com o fluxo de carbono observado. Essa afirmativa corrobora com a pesquisa desenvolvida por Andrade, Silveira e Azevedo (2003) no qual concluíram que apenas dois componentes principais conseguiam explicar a variação de evapotranspiração em três estações meteorológicas com valores de 70% a 80% de precisão. A modelagem permitiu verificar as variáveis com maior correlação com o fluxo de carbono que condiz com outros estudos micrometeorológicos parecidos tal qual a pesquisa elaborada por Souza *et al.* (2017) em Campo Grande no estado de Mato Grosso do Sul (MS) a ACP conseguiu explicar em 38% ($R^2 = 0.38$) a relação entre temperatura do ar, velocidade do vento e radiação solar com a concentração de ozônio na atmosfera.

Mesmo com poder de explicação estatístico reduzido, com a utilização de apenas 9 componentes, os valores de RMSE para cada modelo ficaram ligeiramente elevados em comparação com os modelos anteriores. Os valores extremos do mínimo e máximo reduziram em magnitude, suavizando os dados nos 3 modelos propostos. No entanto, a contribuição da metodologia aplicada permite verificar quais variáveis possuem maior correlação direta com o fluxo de carbono além de demonstrar que o fluxo desse gás possui uma lógica complexa que é afetado diretamente (e indiretamente) por pelo menos 9 variáveis micrometeorológicas.

6.1.6 Modelagem dos dados transformados por polinômios

Os últimos modelos gerados, com base nos dados micrometeorológicos, fizeram uso da transformação dos dados originais por polinômios. Assim, foi aplicado a equação polinomial (Equação 4) para gerar novos modelos para cada ano pesquisado. A utilização de polinômios com o intuito de explicar uma variável independente ou até mesmo realizar previsões são

amplamente utilizadas em estudos agronômicos como o de Barbieri e Tuon (1992) que utilizaram uma equação polinomial para estimar o volume de produção de algumas culturas.

Essa transformação dos dados possibilita, entre outras coisas, um reescalonamento dos dados micrometeorológicos em relação aos dados de fluxo de carbono. Após a transformação por polinômios, foram elaborados os modelos, por meio da RLM, referentes aos anos de 2017, 2018 e 2019. Os respectivos *p*-valores dos três modelos, calculados na estatística ANOVA, estão apresentados na Tabela 14:

Tabela 14. *p*-valores da tabela ANOVA - Polinômios

<i>ANO</i>	<i>2017</i>	<i>2018</i>	<i>2019</i>
<i>FATORES</i>	<i>P-valor</i>	<i>P-valor</i>	<i>P-valor</i>
H	0%	0%	0%
LE	0%	0%	0%
Tau	0%	0%	0%
AIRT	0%	0%	0%
CO2F	0%	0%	0%
U	0%	85%	0%
WDIR	0%	0%	0%
RH_81M	37%	4%	0%
SW_IN	0%	0%	5%
SW_OUT	2%	54%	7%
PAR_IN	0%	0%	1%
PAR_OUT	0%	0%	0%
UV	0%	0%	0%
NETRAD	0%	53%	0%
LW_ATM	0%	0%	0%
LW_TERR	0%	0%	0%

Elaboração, GARCIA, E. A. B., (2020).

Os *p*-valores referentes à estatística ANOVA, para os modelos 2017, 2018 e 2019, indicaram que, em comparação aos outros métodos, essa abordagem se comportou de forma bem distinta, isto é, com exceção da variável U, todas as demais que tiveram *p*-valor acima de 5% são diferentes daquelas dos outros experimentos (com dados reais/originais). Os *p*-valores indicam que as variáveis RH_81m para 2017, u, SW_out e NetRad para o ano de 2018 e SW_out 2019 proporcionaram valores acima de 5%, demonstrando que essas variáveis não são significativas para o modelo. Porém, essas variáveis não foram eliminadas dos modelos, como feito anteriormente. Esse fato permite a homogeneização entre os modelos, tornando possível a

comparação entre eles. Outro fator importante se deu pelos *p-valores* apresentados na tabela anterior no qual demonstra que ao menos uma variável em 2017, três variáveis em 2018 e duas variáveis em 2019 poderiam ser eliminadas do processo para alcançar melhores resultados.

Posteriormente, após a transformação por polinômio, foi aplicada a RLM para geração dos modelos para cada ano. Os coeficientes obtidos da RLM para o ano 2017, 2018 e 2019 estão demonstrado na Tabela 15.

Tabela 15. Coeficientes de regressão 2017, 2018 e 2019 – Polinômios

<i>Ano</i>	<i>2017</i>		<i>2018</i>		<i>2019</i>	
	<i>ESTIMATIVA</i>	<i>P-VALOR</i>	<i>ESTIMATIVA</i>	<i>P-VALOR</i>	<i>ESTIMATIVA</i>	<i>P-VALOR</i>
INTERCEPTO	63,741	0%	21,873	0%	29,498	0%
H	-0,038	0%	-0,168	0%	-0,223	0%
LE	0,038	0%	0,041	0%	-0,029	0%
TAU	-2,711	0%	0,721	0%	-0,125	24%
AIRT	1,066	17%	-3,755	0%	-9,761	0%
CO2F	5,647	0%	2,714	0%	5,577	0%
U	4,151	0%	-0,481	4%	-0,946	0%
WDIR	-0,093	0%	-0,180	0%	-0,176	0%
RH_81M	0,553	6%	2,526	0%	-1,014	0%
SW_IN	-0,056	15%	-0,102	0%	0,006	86%
SW_OUT	0,086	28%	0,063	28%	-0,080	17%
PAR_IN	-0,246	0%	-0,188	1%	-0,249	0%
PAR_OUT	1,390	0%	1,413	0%	0,708	0%
UV	-1,205	0%	-1,471	0%	-0,408	0%
NETRAD	-0,098	0%	0,022	7%	0,090	0%
LW_ATM	-9,640	0%	-10,353	0%	-11,008	0%
LW_TERR	-16,073	0%	1,664	0%	3,370	0%

Elaboração, GARCIA, E. A. B., (2020).

No modelo de 2017, quase todos os coeficientes apresentaram os *p-valores* abaixo de 5%, rejeitando-se a hipótese nula (H_0), no entanto, três variáveis apresentaram percentual elevado: airT com 17%, SW_in com 15% e SW_out com 28%. Os coeficientes dos das variáveis H, Tau, wDir, SW_in, PAR_in, UV, NetRad, LW_atm e LW_terr apresentaram sinais negativos, indicando-se que, no intervalo da análise, um aumento do valor dessa variável provoca uma redução no valor do fluxo de carbono. Os coeficientes dos componentes LE, airT, co2F, u, RH_81m, SW_out e PAR_out apresentaram valores positivos, apontando-se que, no

intervalo da análise, um aumento do valor dessa variável provoca um aumento no fluxo de carbono.

Os coeficientes Tau, airT, co2F, u, RH_81m, PAR_out, UV, LW_atm e LW_terr apresentaram valores acima de 0,3, o que representa uma forte relação com o fluxo de carbono, com destaque para as variáveis Tau, co2F, u, LW_atm e LW_terr, que apresentaram valores superiores a 2, positivo ou negativo, indicando uma relação ainda mais forte com o fluxo. Desta forma o modelo inicial de fluxo de carbono para 2017 foi calculado com a seguinte expressão (Equação 18):

$$\begin{aligned}
 FluxoCO2pol2017 = & 63,74113912 - 0,038204968 * H + 0,037803868 * -2,710663123 * \\
 & Tau + 1,066111656 * airT + 5,647312124 * co2F + 4,150720286 * u - 0,092804004 * \\
 & wDir + 0,553435825 * RH_{81m} - 0,055809932 * SW_{in} + 0,086177128 * SW_{out} - \\
 & 0,245884352 * PAR_{in} + 1,389856348 * PAR_{out} - 1,205477522 * UV - 0,097674342 * \\
 & NetRad - 9,640144521 * LW_{atm} - 16,0734235 * LW_{terr}
 \end{aligned}
 \tag{18}$$

No modelo de 2018, as variáveis que possuem os coeficientes negativos, são correspondentes às variáveis H, airT, u, wDir, SW_in, PAR_in, UV e LW_atm. Nesse caso, essas variáveis possuem relação inversamente proporcional ao fluxo de carbono. Em contrapartida, as variáveis LE, Tau, co2F, RH_81m, SW_out, PAR_out, NetRad e LW_terr apresentaram valores positivos, apontando relação direta com fluxo de carbono.

As variáveis Tau, airT, co2F, u, RH_81m, PAR_out, UV, LW_atm e LW_terr apresentaram maior correlação com o fluxo de carbono, com valores acima de 0,3, positivo ou negativo, o que indica uma relação direta ou indiretamente alta com o fluxo de carbono.

Na Tabela 15, os coeficientes demonstraram os *p-valores* abaixo de 5%, exceto para as variáveis SW_out (28%) e NetRad (7%). Essas duas variáveis são não significativas para o modelo, mas não devem ser retiradas porque são parte fixa desse modelo. Nesse caso, a hipótese nula (H_0) determina que essas variáveis são não significativas. As demais variáveis aceitam a rejeição da hipótese nula, aceitando a hipótese alternativa (H_1), dado que o nível de significância foi de 5%. Isso significa que o intercepto e as variáveis de entrada são todas importantes para o modelo. Desta forma, o modelo inicial de fluxo de carbono para 2018 foi calculado com a seguinte expressão (Equação 19).

$$\begin{aligned}
 FluxoCO2pol2018 = & 21,8727436 - 0,168418279 * H + 0,040938876 * \\
 & +0,721385012 * Tau - 3,755451563 * airT + 2,714176228 * co2F - 0,480652689 * \\
 & u - 0,179685079 * wDir + 2,525760018 * RH81m - 0,102210097 * SWin + \\
 & 0,062683884 * SWout - 0,188271458 * PARin + 1,412940028 * PARout - \\
 & 1,470937163 * UV + 0,021695725 * NetRad - 10,35260507 * LWatm + \\
 & 1,664206894 * LWterr
 \end{aligned}
 \tag{19}$$

No modelo de 2019, as variáveis que possuem os coeficientes negativos, são as variáveis H, LE, Tau, airT, u, wDir, RH_81m, SW_out, PAR_in, UV e LW_atm, mostrando uma relação inversamente proporcional com o fluxo de carbono. As variáveis que apresentaram valor positivo são: co2F, SW_in, PAR_out, NetRad e LW_terr, indicando uma relação direta com fluxo de carbono.

As variáveis airT, co2F, RH_81m, PAR_out, UV, LW_atm e LW_terr, apresentaram maiores valores de coeficientes, mostrando uma forte relação (direta ou indireta) com o fluxo de carbono, com valores acima de 0,3, positivo ou negativo. Na Tabela 15, os coeficientes demonstraram os *p-valores* abaixo de 5% exceto para as variáveis Tau (24%), SW_in (84%) e SW_out (17%). Essas três variáveis são classificadas como não significativas para o modelo, mas serão mantidas no modelo. As demais variáveis permitem a rejeição da hipótese nula, aceitando a hipótese alternativa (H_1), dado que o nível de significância foi de 5%. Nesse caso, o intercepto e as variáveis de entrada são todas importantes para o modelo.

Desta forma, o modelo inicial de fluxo de carbono para 2019 foi calculado com a seguinte expressão (Equação 20):

$$\begin{aligned}
 FluxoCO2pol2019 = & 29,4982 - 0,2232 * H - 0,0292 * -0,1245 * Tau - 9,7611 * airT + \\
 & 5,5770 * co2F - 0,9455 * u - 0,1755 * wDir - 1,0138 * RH81m + 0,0055 * SWin - \\
 & 0,0795 * SWout - 0,2487 * PARin + 0,7077 * PARout - 0,4083 * UV + 0,0900 * \\
 & NetRad - 11,0083 * LWatm + 3,3695 * LWterr
 \end{aligned}
 \tag{20}$$

Após a elaboração dos modelos, foram calculados os valores dos índices R^2 e R^2 ajustado (Tabela 16) para descreverem a qualidade do ajuste dos modelos.

Tabela 16. Medida descritiva da qualidade do ajuste – Polinômios

MODELO	DESVIO PADRÃO DOS RESÍDUOS	GRAUS DE LIBERDADE	R ²	R ² AJUSTADO
2017	1,080	17503	0,334	0,334
2018	1,077	17503	0,318	0,3182
2019	1,073	17503	0,339	0,339

Elaboração, GARCIA, E. A. B., (2020).

Os valores dos desvios padrões de 2017 e de 2018 são menores que dos demais modelos dos subcapítulos anteriores. Observa-se que com a aplicação da transformação por polinômios, os três modelos gerados por regressão (RLM) se ajustaram de maneira significativamente (com R² e R² ajustado entre 31 e 34%) melhor que os demais modelos apresentados anteriormente. Isto é, os percentuais de R² e R² ajustado são valores superiores aos modelos anteriores, demonstrando que esses modelos possuem poder estatístico para explicar as variáveis melhor que os modelos gerados pelas outras abordagens.

Os valores dos RMSE, de máximo e mínimo das observações (Tabela 17) também apresentaram valores melhores que os casos anteriores demonstrando que a metodologia aplicada para a elaboração dos modelos de fluxo de carbono por meio de variáveis micrometeorológicas conseguiu a melhor explicação da variação dos dados observados. Contudo, proporcionalmente, os valores de RMSE são muito melhores ao analisar o intervalo de dispersão das variáveis.

Tabela 17: Valores máximos, mínimos e do RMSE - Polinômios

MODELO	2017	2018	2019
MÁXIMO	4,182	3,981	2,185
MÍNIMO	-2,529	-2,984	-2,187
RMSE	1,080	1,077	1,073

Elaboração, GARCIA, E. A. B., (2020).

Os valores da discrepância da raiz do erro médio quadrático foram melhores que os demais modelos, reduzindo os valores máximo e mínimo obtidos. O método de modelagem polinomial para a previsão do fluxo de carbono apresentou o melhor resultado de todos os modelos apresentados até então. A regressão polinomial fornece uma maneira eficaz de descrever a relação complexa entre os dados. A literatura científica ainda é escassa, porém é possível notar o potencial desse tipo de metodologia para a modelagem de processos

meteorológicos. Em um estudo similar, Krupa *et al.* (2003) gerou um modelo estatístico não linear multivariado por meio de modelagem polinomial com o intuito de simular medições do gás ozônio para prever as distribuições desse gás de hora em hora e conseguiu chegar a valores de R^2 e R^2 ajustado de 62.5% e 67.5%.

A pesquisa recente de Nicolás *et al.* (2020) gerou modelos globais para estimar o ângulo de inclinação anual ideal por meio de variáveis locais (latitude, fração difusa e albedo) com base nos dados de irradiância de 14.468 sites espalhados por todo o mundo e conseguiu valores de RMSE de 2% e de 0,7% respectivamente. Fan *et al.* (2018) também apresentou melhores estimativas de temperatura e radiação solar por meio do uso da modelagem de polinômios dos demais modelos propostos, obtendo valores de $R^2=0.741$ e de $RMSE = 3.814$.

6.2 Validação dos resultados dos modelos criados pelos dados da ATTO

Este capítulo apresentará os resultados e as análises estatísticas dos três modelos propostos (RLM-original, RLM-ACP e RLM-Polinômios) para cada ano. Para tanto, utilizou-se o teste-t de student pareado para informar o quão significativas são as diferenças entre os 3 modelos propostos. Em outras palavras, os testes-t foram utilizados para verificar se as variâncias dos resíduos dos diferentes métodos são iguais entre si, estatisticamente.

7.2.1 Modelo de fluxo de carbono gerado por RLM sobre os dados originais

Foi aplicado o teste-t em cada par de amostras de fluxo de carbono, sendo uma gerada pelo modelo e outra registrada na ATTO. Nesse teste, presumiu-se que as variâncias são equivalentes nos três casos: 2017, 2018 e 2019. Os resultados estão demonstrados na Tabela 18.

Tabela 18. Teste-t para todos os modelos propostos por Krigagem

<i>Modelo</i>	<i>fluxCO2 - 2017</i>	<i>fluxCO2reg2017</i>	<i>fluxCO2 - 2018</i>	<i>fluxCO2reg2018</i>	<i>fluxCO2 - 2019</i>	<i>fluxCO2reg2019</i>
Média	-1,633	-1,633	-1,766	-1,766	-1,967	-1,967
Variância	108,838	29,459	128,917	35,837	119,455	37,725
Observações	17520	17520	17520	17520	17520	17520
Variância agrupada	69,148		82,377		78,590	
Hipótese da diferença de média	0		0		0	

GI	35038	35038	35038
Stat t	0,0000009	-0,0000038	-0,0000013
P(t<=t) unicaudal	0,500	0,500	0,500
T crítico unicaudal	1,645	1,645	1,645
P(t<=t) bicaudal	1	1	1
T crítico bicaudal	1,960	1,960	1,960

Elaboração, GARCIA, E. A. B., (2020).

A hipótese nula (H_0) analisada, nesse caso, é de que as variâncias das duas amostras são iguais. Portanto, a hipótese alternativa (H_1) é de as duas variâncias são diferentes. Nesse sentido, o objetivo é que a hipótese nula seja aceita, mostrando que os resultados dos diferentes modelos em relação aos dados reais/observados apresentaram variabilidade estatisticamente iguais.

Avaliando o caso unicaudal, observa-se que os *p-valores* (0,500), referentes à estatística t, nos três modelos (2017, 2018 e 2019), são maiores que 0,05 (nível de confiança de 95%), portanto, aceita a hipótese nula (H_0). Adicionalmente, observa-se que os valores da estatística t são aproximadamente zero (000009, -0,0000038 e -0,0000013), portanto são menores que o limite t crítico (1,645), o que demonstra que deve-se aceitar H_0 . Deste modo, não há diferença estatística entre as variâncias dos resultados dos modelos e os dados reais, mostrando a qualidade dos modelos em atender a variabilidade dos dados.

Analisando o caso bicaudal percebe-se que a hipótese nula também é aceita, pois os *p-valores* referentes à estatística t, todas iguais a 1,00, estão dentro do intervalo dos t-críticos (de -1,96 a +1,96).

6.2.1 Modelo de fluxo de carbono gerado com os dados transformados por ACP

Tabela 19. Teste-t para todos os modelos propostos por ACP

	<i>fluxCO2 - 2017</i>	<i>fluxCO2_{acp}2017</i>	<i>fluxCO2 - 2018</i>	<i>fluxCO2_{acp}2018</i>	<i>fluxCO2 - 2019</i>	<i>fluxCO2_{acp}2019</i>
Média	-1,633	-1,633	-1,766	-1,766	-1,967	-1,967
Variância	108,837	25,800	128,917	31,726	119,454	34,454
Observações	17520	17520	17520	17520	17520	17520
Variância agrupada	67,319		80,321		76,954	
Hipótese da diferença de média	0		0		0	

Gl	35038	35038	35038
Stat t	0,000	0,000	0,000
P(t<=t) uni-caudal	0,500	0,500	0,500
T crítico uni-caudal	1,644	1,644	1,644
P(t<=t) bi-caudal	1,000	1,000	1,000
T crítico bi-caudal	1,960	1,960	1,960

Elaboração, GARCIA, E. A. B., (2020).

Os modelos gerados pela ACP, para os anos 2017, 2018 e 2019, demonstraram, também, que a hipótese nula é aceita, indicando que as variâncias dos respectivos pares de amostras são iguais estatisticamente. Isto é, os *p-valores* são maiores que 0,05 (nível de confiança de 95%) e os valores da estatística t (nulos) são menores que os limites dos t-críticos (1,64).

6.2.3 Modelo de fluxo de carbono gerado com os dados transformados por Polinômio

A transformação dos dados por polinômio apresentou resultados significativamente melhores, como demonstrado na Tabela 20.

Tabela 20. Teste-t para todos os modelos propostos por Krigagem

	<i>Fluxco22017</i>	<i>Fluxco2pol 2017</i>	<i>Fluxco2 2018</i>	<i>Fluxco2pol 2018</i>	<i>Fluxco22019</i>	<i>Fluxco2pol 2019</i>
Média	-0,194	-0,194	-0,178	-0,178	-0,218	-0,219
Variância	1,752	0,587	1,704	0,543	1,742	0,592
Observações	17520	17520	17520,0000	17520	17520	17520
Variância agrupada	1,169		1,124		1,167	
Hipótese da diferença de média	0,0000		0,0000		0,0000	
Gl	35038		35038		35038	
Stat t	0,000		0,000		0,042	
P(t<=t) uni-caudal	0,500		0,500		0,483	
T crítico uni-caudal	1,644		1,644		1,644	
P(t<=t) bi-caudal	1,000		1,000		0,966	
T crítico bi-caudal	1,960		1,960		1,960	

Elaboração, GARCIA, E. A. B., (2020).

Igualmente aos casos anteriores, os modelos gerados com a transformação dos dados por polinômio, referentes aos anos de 2017, 2018 e 2019, apresentaram *p-valores* maiores que 0,05 (nível de confiança de 95%) e os valores da estatística *t* ($>0,042$) menores que os limites *t*-críticos (1,644), portanto aceita-se a hipótese nula (H_0), inferindo, assim, que não há diferença estatística de variâncias entre as duas amostras (modelos x dados reais).

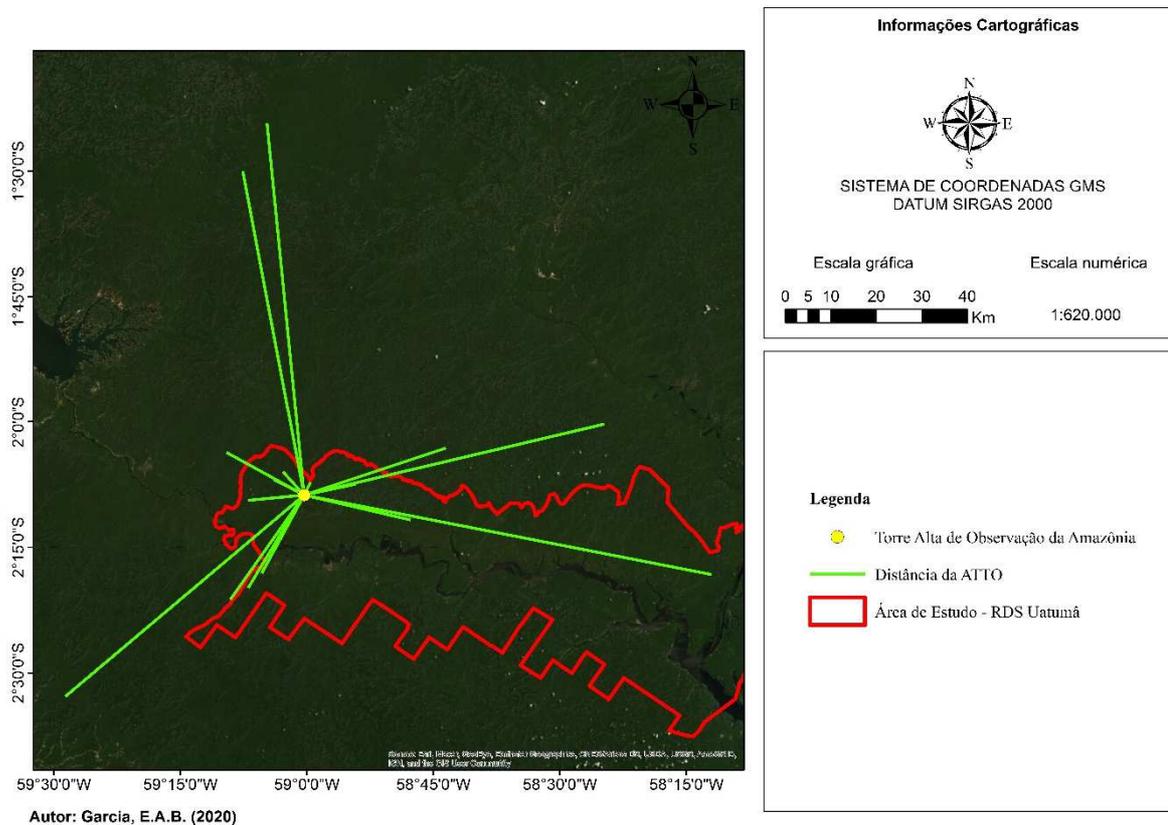
6.3 Modelagem do fluxo de carbono dos dados provenientes do CBERS-04/MUX

6.3.1 Definição dos pontos para coleta das amostras

O procedimento de estimativa do fluxo de carbono, usando imagens digitais está apresentado nesse subcapítulo. As imagens usadas são provenientes do sensor MUX do satélite CBERS-4, com resolução temporal de 26 dias. Desta maneira, foi realizada uma seleção das cenas mensais que apresentaram o menor percentual de cobertura de nuvens e que cobriam a região. Por se tratar de uma região de floresta tropical, com elevado índice de precipitação ao longo do ano, encontrar imagens de satélite, que abrange todo o período do ano, com baixa cobertura de nuvens se torna uma tarefa complexa.

Assim, em algumas cenas, devido à presença de nuvens, os pontos para coleta foram selecionados fora da coordenada onde se encontra a ATTO (local onde foram realizadas as medições de fluxo de carbono). Contudo, foi mantido o cuidado de coletar os pontos em locais onde a cobertura do solo era similar a área próxima à torre ATTO. Isto é, foram escolhidas áreas totalmente cobertura por vegetação, mesmo que a localização dos pontos se distanciasse da referida torre. Na imagem abaixo, as linhas verdes representam todas as distâncias dos pixels amostrais em relação a torre para todos os anos, obviamente quando as imagens de satélite não possuíam cobertura de nuvens sobre a coordenada da torre, os pixels amostrais foram coletados sobre a torre e no entorno da mesma.

Figura 27. Mapa de distância dos pontos amostrais em relação à área



Elaboração, GARCIA, E. A. B., (2020).

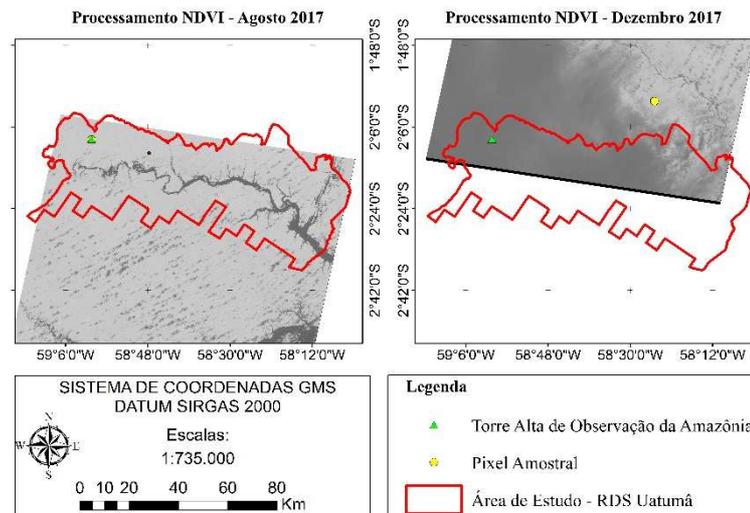
Após selecionadas as imagens com menor cobertura de nuvens, definidos os pontos de interesse e realizados todos os processamentos necessários, as amostras foram coletadas por meio de uma matriz de 7×7 pixels, em cada imagem, de cada mês, dos três anos analisados. Nesse caso, foram coletados 49 valores em cada amostra e a média aritmética desse conjunto foi utilizada como valor final de fluxo de carbono, estimado pelo método proposto, para posterior comparação com os dados medidos na torre.

Na etapa de processamento foram calculados os valores de PRI, SPRI, NDVI e CFLUX. Considerando a quantidade de cenas e a quantidade de dados coletados, optou-se por apresentar nesta pesquisa um exemplo de cena do período de seca (agosto) e outra cena do período chuvoso (dezembro). O restante dos valores é apresentado em tabelas.

6.3.2 Resultados dos valores de NDVI

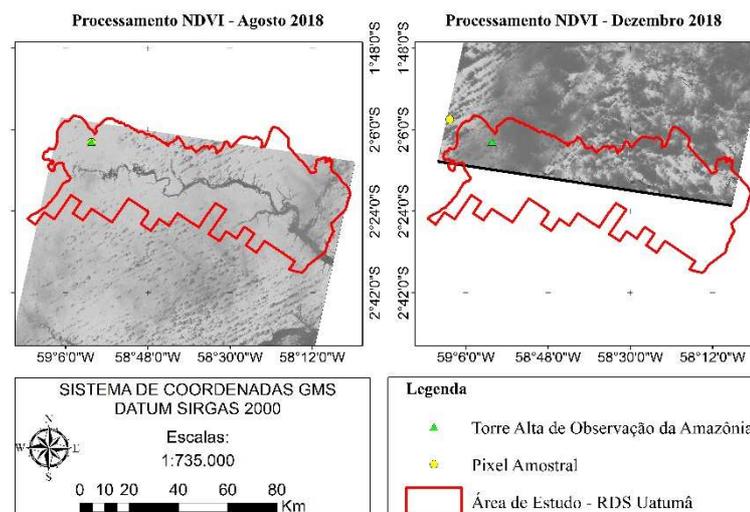
As imagens para exemplificar os resultados de NDVI, gerados por meio da metodologia proposta por Tucker (1979), estão apresentadas nas Figuras 28, 29 e 30 abaixo.

Figura 28. Imagem com valores de NDVI referentes ao ano 2017



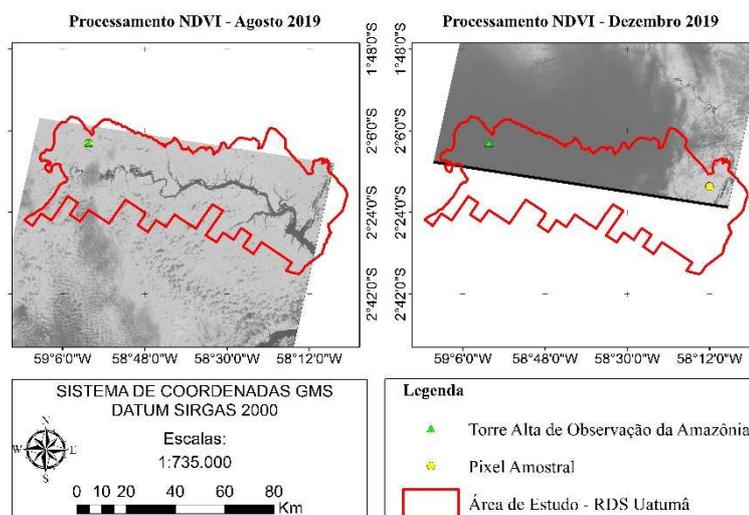
Elaboração, GARCIA, E. A. B., (2020).

Figura 29. Imagem com valores de NDVI referentes ao ano 2018



Elaboração, GARCIA, E. A. B., (2020).

Figura 30. Imagem com valores de NDVI referentes ao ano 2019



Elaboração, GARCIA, E. A. B., (2020).

Por meio dos *pixels* que foram inseridos em regiões da imagem para cada ano, foi possível extrair os valores das médias da matriz de 7x7, correspondentes ao raster, como demonstrado na Tabela 21.

Tabela 21. Média dos valores de NDVI extraídos

AN O	NDVI											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	0,48 2	0,53 1	0,63 6	0,61 6	0,38 5	0,60 6	0,62 7	0,57 7	0,58 1	0,55 1	0,42 9	0,53 8
2018	0,54 5	0,65 2	0,57 0	0,45 3	0,39 1	0,61 9	0,59 7	0,57 4	0,61 8	0,60 5	0,47 8	0,64 3
2019	0,65 0	0,32 4	0,61 3	0,46 0	0,59 9	0,57 2	0,52 9	0,47 2	0,65 2	0,33 2	0,62 0	0,62 6

Elaboração, GARCIA, E. A. B., (2020).

É sabido que o NDVI possui uma relação não-linear com o índice de área foliar, biomassa verde e de clorofila em floresta temperada (GAMON *et al.*, 1995). Devido à diferença entre o bioma amazônico e o de floresta temperada, no entanto, o NDVI pode ser utilizado como indicador da estrutura do dossel até certo limite de densidade foliar da vegetação, pois os autores Gamon *et al.* (1995) constataram que até uma determinada densidade é possível notar diferenças de valores de NDVI, porém, após esse ponto de densidade, não é possível notar diferenças significativas no NDVI.

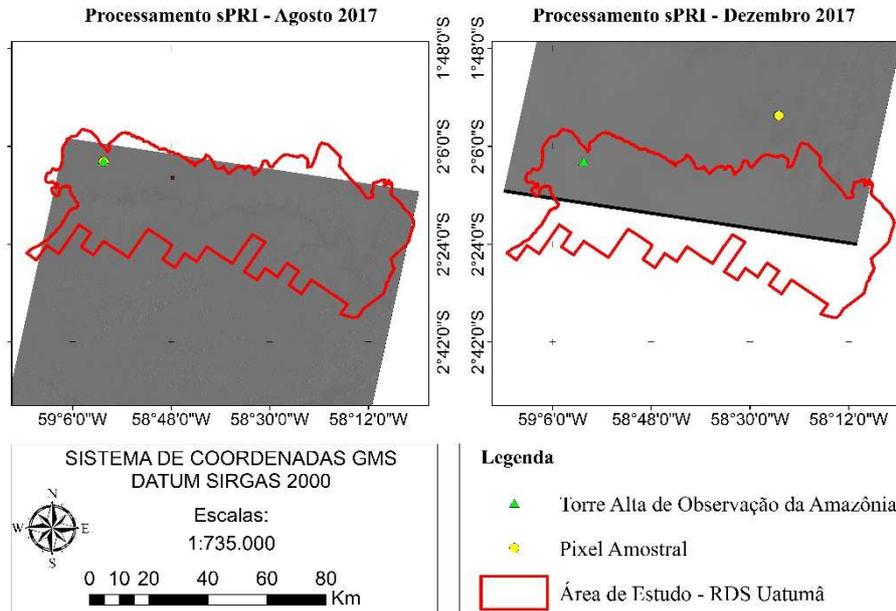
Entretanto, a utilização desse índice demonstrou resultados significativos na vegetação que se encontra em estágios iniciais de sucessão na Floresta Amazônica (AMARAL *et al.*, 1997). O mesmo resultado foi obtido nos estudos que não encontraram problemas de saturação no NDVI na floresta tropical decídua da Índia (BAWA *et al.*, 2002) e na floresta tropical seca da Costa Rica (ARROYO-MORA *et al.*, 2003).

Por conseguinte, a análise dos dados de NDVI proporcionaram pouca variação dos valores ao longo dos meses de cada ano. Todas as regiões selecionadas possuíam características similares de cobertura de uso e cobertura do solo e distanciamento de áreas antropizadas, demonstrando que há uma certa homogeneidade dos valores de NDVI ao longo de grandes trechos de floresta amazônica preservada. Vale destacar o mês de maio, para os anos de 2017 e 2018, e o mês de outubro, para o ano de 2019, apresentaram valores abaixo de 0,4. Tais valores podem ter sofrido influência da reflectância absorvida ou variações micrometeorológicas da região onde foram coletados. Isso não é bom para a análise proposta, mas infelizmente isso poderia ocorrer mesmo em pontos mais próximos. Como não existiam outras cenas, não foi possível descartar tais valores.

6.3.3 *Resultados dos valores de PRI e sPRI*

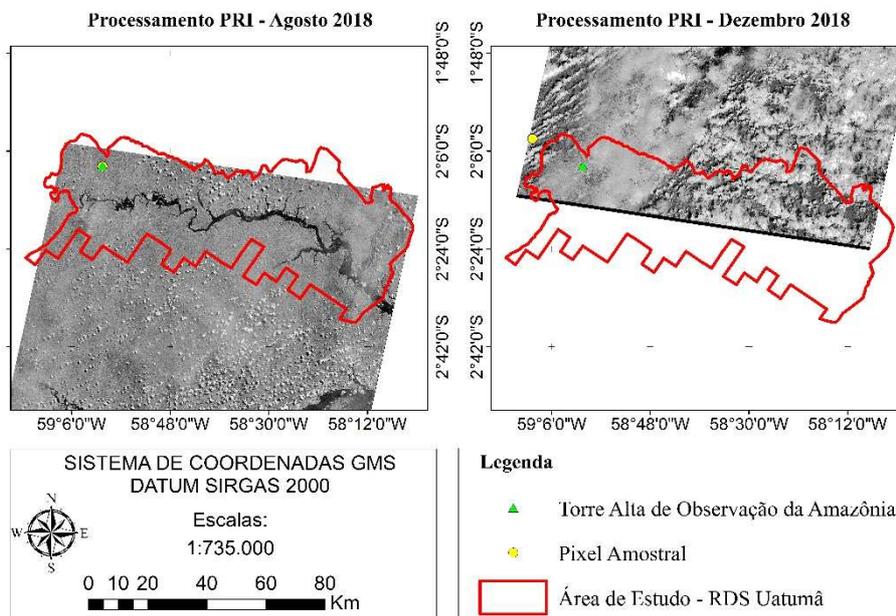
As cenas do Índice de Reflexão Fotoquímico (PRI) que foram geradas a partir das imagens do CBERS-4, do sensor MUX, mostraram os seguintes resultados (Figura 31, 32 e 33).

Figura 31. Imagem com valores de sPRI referentes ao ano 2017



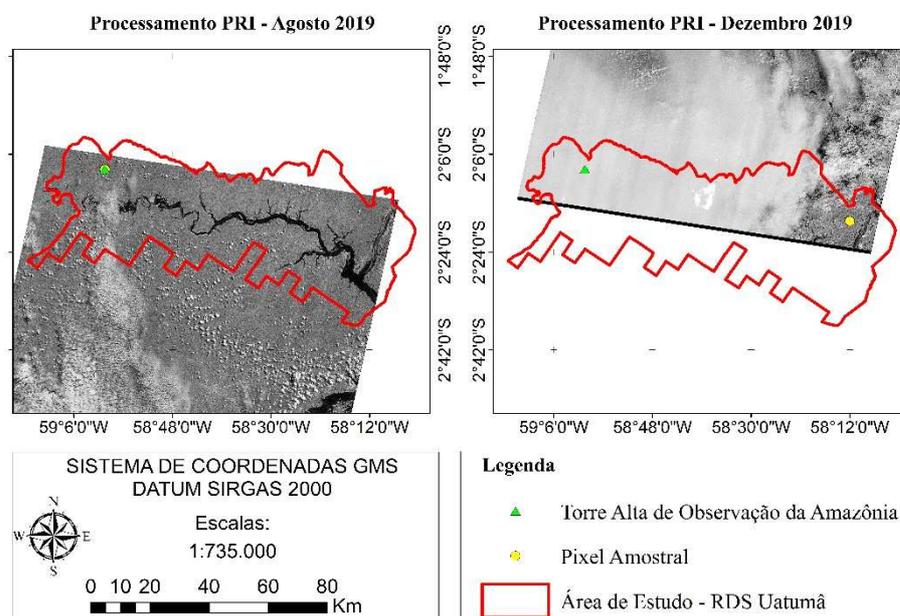
Elaboração, GARCIA, E. A. B., (2020).

Figura 32. Imagem com valores de PRI referentes ao ano 2018



Elaboração, GARCIA, E. A. B., (2020).

Figura 33. Imagem com valores de PRI referentes ao ano 2019



Elaboração, GARCIA, E. A. B., (2020).

Nos mesmos *pixels* (matriz 7x7) usados na amostragem de NDVI foram coletados os valores de PRI, em cada imagem mensal, em cada ano. Os valores das médias extraídos das imagens PRI estão demonstrados na Tabela 22.

Tabela 22. Média dos valores de PRI extraídos

	PRI											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	-	-	-	-	-	-	-	-	-	-	-	-
	0,091	0,081	0,093	0,080	0,077	0,086	0,071	0,076	0,072	0,062	0,103	0,076
2018	-	-	-	-	-	-	-	-	-	-	-	-
	0,072	0,070	0,087	0,074	0,087	0,079	0,079	0,068	0,072	0,064	0,066	0,082
2019	-	-	-	-	-	-	-	-	-	-	-	-
	0,081	0,065	0,072	0,066	0,096	0,091	0,087	0,111	0,060	0,065	0,077	0,072

Elaboração, GARCIA, E. A. B., (2020).

É sabido também que o PRI determina a capacidade de utilização da luz pela fotossíntese, portanto, os valores próximos de zero indicam maior eficiência da planta em realizar a fotossíntese (GAMON *et al.*, 1997). Deste modo, o índice demonstra de maneira indireta a capacidade de produção de biomassa e de sequestro de carbono por meio da eficiência da fotossíntese. Os valores de PRI deram negativos em todos os meses levantados, variando

entre -0,111 e -0,060. Isso significa que as regiões estudadas estavam, no momento da passagem do satélite, realizando fotossíntese de maneira eficiente e aproveitando a radiação ativa de maneira homogênea. Assim, os valores apresentados na Tabela 22 indicam que as áreas selecionadas estavam utilizando o carbono atmosférico com eficiência alta.

De acordo com os estudos de Peñuelas *et al.* (2013), sobre a utilização do PRI, foi demonstrada uma relação exponencial com o Uso Eficiente da Luz (LUE) em diferentes biomas e escalas, sugerindo que há uma relação das emissões de isoprenóides com o PRI, podendo então ser utilizadas para extrapolar para ecossistemas inteiros.

Os valores do sPRI são uma forma escalonada de representar o PRI, como exposto por Rahman *et al.* (2000). Esses autores usaram o sPRI para homogeneizar a equação em valores de -1 a +1, portanto, os valores de PRI (próximos de zero) indicam uma eficiência do uso da luz fotossintética baixa, e os valores de sPRI elevados (próximos a 1) indicam o oposto (Rahman *et al.*, 2000). Dessa forma, os valores de sPRI medidos nas imagens PRI foram os seguintes:

Tabela 23. Valores de sPRI calculados a partir dos valores de PRI

	SPRI											
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	0,454	0,459	0,453	0,460	0,461	0,457	0,464	0,462	0,464	0,469	0,448	0,462
2018	0,464	0,465	0,460	0,463	0,457	0,461	0,460	0,466	0,464	0,468	0,467	0,459
2019	0,459	0,467	0,464	0,467	0,452	0,455	0,457	0,444	0,470	0,467	0,462	0,464

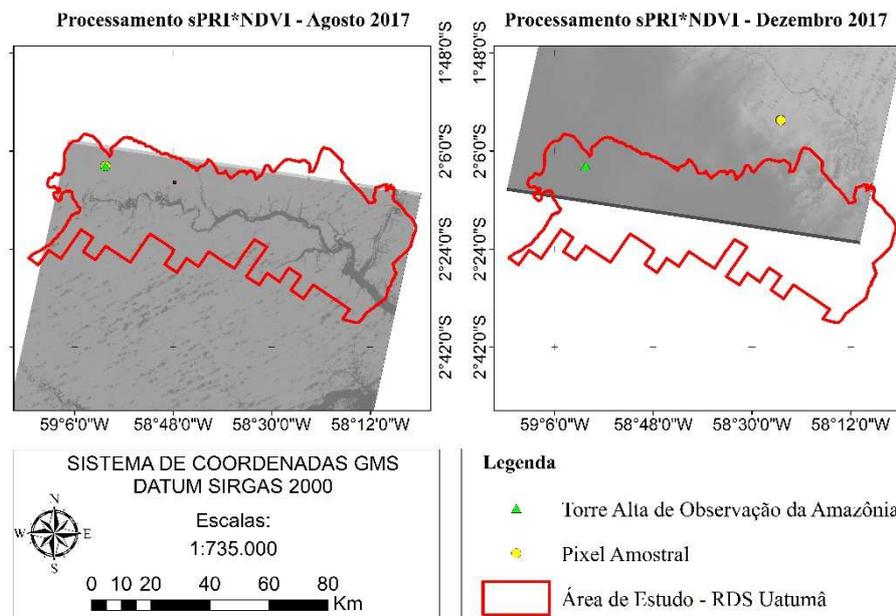
Elaboração, GARCIA, E. A. B., (2020).

6.3.4 Resultados dos valores de fluxo de carbono obtidos pelo método proposto por Rahman *et. al.* (2000)

Os procedimentos para descritos pelo método de Rahman *et al.*, (2000) inicialmente se baseia na Equação 8. No entanto, ao longo da literatura nota-se que algumas pesquisas utilizam esses índices apenas multiplicando diretamente esses valores NDVI vezes o sPRI (BAPTISTA, 2003; CERQUEIRA e ROCHA, 2007; JUNGES *et al.*, 2007, COLTRI *et al.*, 2009, SILVA, 2014). Todavia, a equação de Rahman *et al.* (2000) foi elaborada para o bioma de floresta boreal com a presença de constantes numéricas na equação que permitem realizar as medições de fluxo de carbono para aquele determinado tipo de sistema. Neste subcapítulo será apresentado a fórmula de Rahman *et al.* (2000) com as constantes numéricas determinadas para

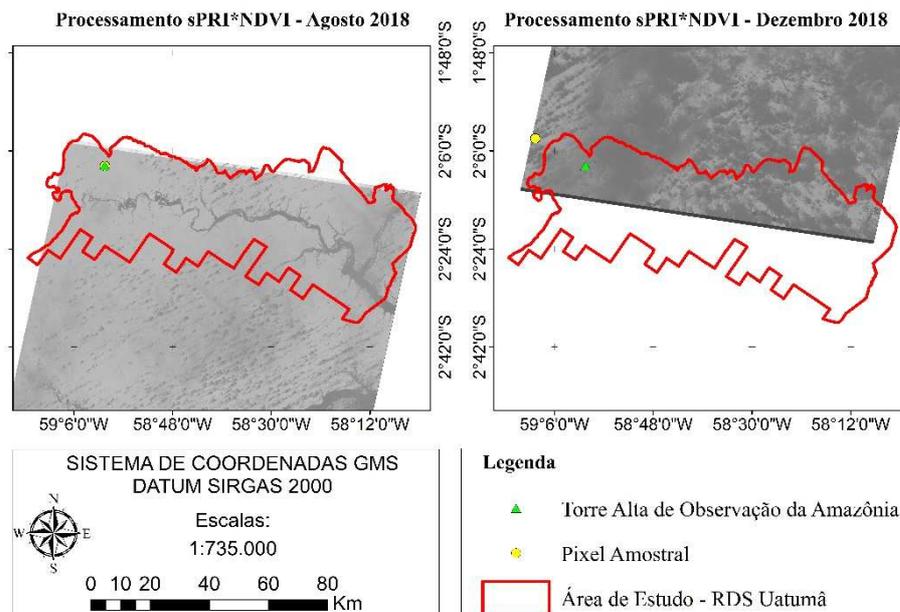
o bioma amazônico não antropizado. Nas Figuras 34, 35 e 36 abaixo estão apresentados o resultado da multiplicação direta do sPRI e do NDVI sem as constantes numéricas, mais adiante os valores serão apresentados em formato de tabela com a multiplicação dessas constantes.

Figura 34. Imagem com valores de sPRI*NDVI referentes ao ano 2017



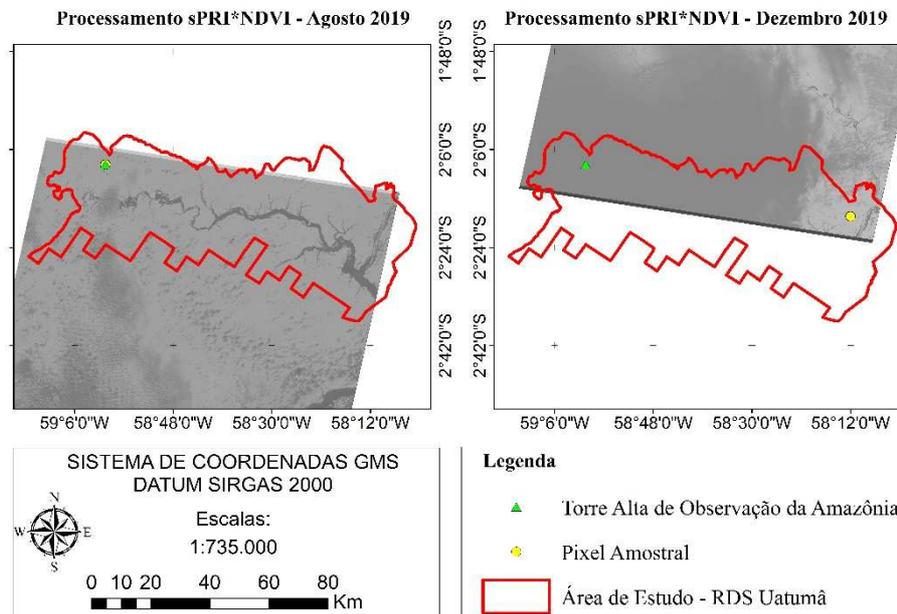
Elaboração, GARCIA, E. A. B., (2020).

Figura 35. Imagem com valores de sPRI*NDVI referentes ao ano 2018



Elaboração, GARCIA, E. A. B., (2020).

Figura 36. Imagem com valores de sPRI*NDVI referentes ao ano 2019



Elaboração, GARCIA, E. A. B., (2020).

Os valores médios dos 49 *pixels* amostrais, correspondentes aos valores de sPRI*NDVI obtidos pela metodologia de Rahman *et al.* (2000), estão demonstrados na Tabela 24.

Tabela 24. Média dos valores de sPRI*NDVI

SPRI*NDVI - MÉDIA												
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	0,21	0,23	0,28	0,27	0,16	0,27	0,29	0,26	0,27	0,23	0,20	0,23
	9	7	1	4	6	4	2	5	2	9	5	3
2018	0,25	0,30	0,26	0,21	0,17	0,28	0,27	0,26	0,29	0,28	0,22	0,29
	3	3	2	0	9	5	5	7	0	3	3	5
2019	0,29	0,15	0,28	0,21	0,27	0,26	0,24	0,21	0,30	0,15	0,28	0,29
	9	2	4	5	1	0	2	0	6	5	6	1

Elaboração, GARCIA, E. A. B., (2020).

Aplicando-se as constantes determinadas pela Equação 8 completa na metodologia, obteve-se os seguintes resultados:

Tabela 25. Média dos valores de CO2Flux

CO2FLUX												
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	-	-	-	-	-	-	-	-	-	-	-	-
	1,91	2,05	2,30	2,27	1,68	2,24	2,32	2,18	2,20	2,13	1,76	2,08
	7	5	5	9	4	1	1	4	1	7	6	4
2018	-	-	-	-	-	-	-	-	-	-	-	-
	2,36	1,53	2,28	1,89	2,20	2,14	2,04	1,86	2,40	1,55	2,29	2,31
	1	9	2	4	7	5	3	4	5	9	2	7
2019	-	-	-	-	-	-	-	-	-	-	-	-
	2,10	2,38	2,15	1,86	1,69	2,28	2,22	2,18	2,29	2,27	1,94	2,34
	5	7	9	6	1	6	8	9	5	6	0	1

Fonte:(Rahman *et al.*, 2000). Elaboração, GARCIA, E. A. B., (2020).

Os valores de fluxo de carbono gerados pela metodologia de Rahman *et al.* (2000) demonstraram uma variação de -2,405 e de -1,539 na eficiência do sequestro de carbono. Os valores apresentados demonstram que as áreas não antropizadas mantiveram ou melhoraram a eficiência da captura do fluxo de carbono ao longo dos anos. O ano de 2019 foi o que possuiu melhores valores ao longo dos anos, com menos variação, alcançando uma média de -2,147 para o ano todo, em seguida o ano de 2017 apresenta uma média de -2,098 e por fim, 2018 apresenta a menor média com o valor de -2,076. O ano de 2018 foi o que apresentou valores discrepantes dos demais anos. Supõe-se que a discrepância desses valores se deve a distância da coleta dos valores dos pixels assim como a variabilidade do clima para o ano de 2018.

Os índices de fluxo de carbono, provenientes de imagens orbitais, demonstraram ao longo de alguns estudos que há uma relação direta com a capacidade de absorção do fluxo de carbono presente na atmosfera. De acordo com Belloli (2019), a utilização do sPRI, provenientes das bandas verde e azul de sensores de satélites multiespectrais possuem maior correlação com conteúdo de carbono orgânico para áreas úmidas. Esse tipo de correlação também foi encontrado em outros estudos para diferentes biomas, como no próprio estudo de Rahman *et al.* (2000), obtendo valores de $R^2=0,78$. A pesquisa de Leite e Baptista (2015) também corrobora com esses resultados, pois mostraram relação dos valores desse índice com a capacidade de sequestro de carbono de ambientes de *wetland* do afluente Riacho Fundo. Por fim, Ferreira (2015) encontrou resultados similares, com elevados índices de CO2flux, no entorno do reservatório da UHE da Serra do Facão, na divisa dos Estados de Minas Gerais e Goiás, por meio de imagens do LANDSAT 8, do sensor OLI.

6.3.5 Resultados dos valores de CFLUX obtidos pelo método proposto

Após o cálculo dos valores por meio da equação completa de Rahman *et al.* (2000), foi realizado o cálculo dos valores de sPRI e NDVI com as constantes calculadas para o domínio morfoclimático amazônico não antropizado como demonstrado na Equação 10, presente na metodologia deste estudo. Os resultados estão apresentados na Tabela 26, abaixo:

Tabela 26. Média dos valores de CO2Flux pelo método proposto

CFLUX – MÉTODO PROPOSTO												
	Jan	Fev	Mar	Abr	Mai	Jun	Jul	Ago	Set	Out	Nov	Dez
2017	-1,171	-1,199	-1,204	-1,218	-1,162	-1,208	-1,230	-1,216	-1,223	-1,231	-1,132	-1,209
2018	-1,215	-1,235	-1,209	-1,192	-1,147	-1,220	-1,215	-1,227	-1,228	-1,236	-1,211	-1,219
2019	-1,220	-1,162	-1,227	-1,207	-1,194	-1,195	-1,191	-1,135	-1,246	-1,166	-1,222	-1,229

Elaboração, GARCIA, E. A. B., (2020).

Os valores de fluxo de carbono gerados pela metodologia de proposta demonstraram uma variação de -1,132 até -1,236 na eficiência do sequestro de carbono. Os coeficientes propostos nesta pesquisa apresentaram valores menos discrepantes que os da Tabela 25. O ano de 2019 apresentou maior discrepância dos valores comparados com os demais anos apesar de apresentar a mesma média que o ano de 2017 (-1,200) e o ano de 2018 apresentou a menor média com o valor de -1,213. De modo geral, os valores de mínimos de máximos tiveram valores aproximados de um ano para o outro havendo pouca variação.

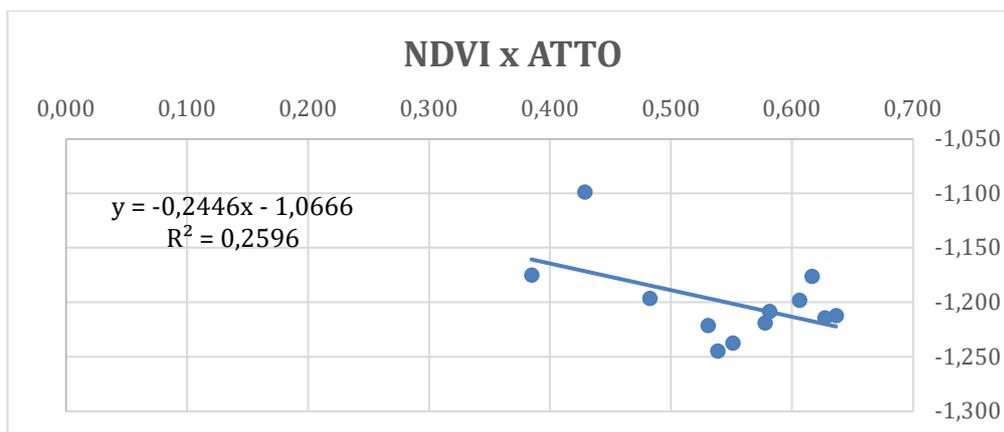
6.4 Validação dos resultados dos índices espectrais

Com base nos resultados gerados pela álgebra de cenas do CBERS-4, sensor MUX, foi aplicado a Equação 8, proposta pelos autores Rahman *et al.* (2000) para gerar o modelo de regressão e comparar os resultados com os dados observados pela ATTO. Foram comparados os índices PRI, NDVI, CO2flux (RAHMAN *et al.*, 2000) e a metodologia nova proposta nesta pesquisa (Equação 10) com os dados de fluxo de carbono levantados pela ATTO para cada ano respectivo. Assim esse capítulo apresentara os resultados dos índices para cada ano em sequência, iniciando com os resultados de 2017, depois de 2018 e por fim 2019.

6.4.1 Comparação dos índices espectrais para o ano de 2017.

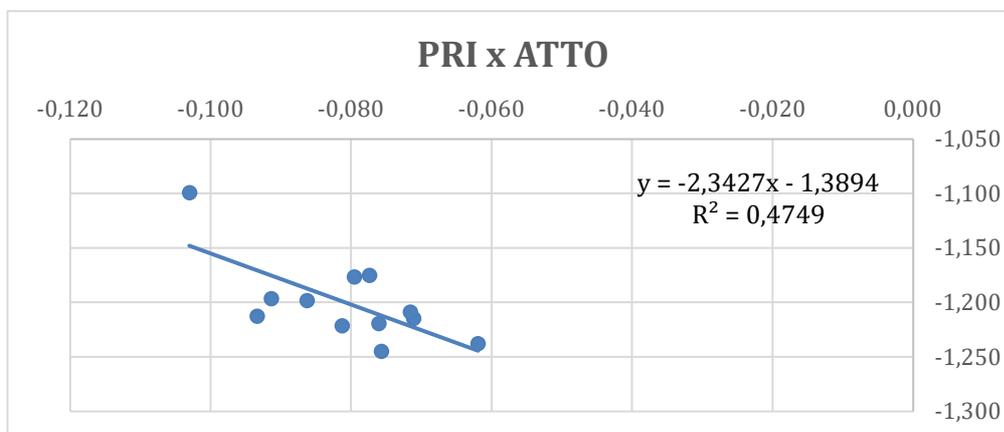
Mediante o exposto, a resposta dos índices espectrais para o ano de 2017 apresentaram os seguintes demonstrados nos Gráficos 1, 2, 3 e 4 abaixo:

Gráfico 1: Linha de Regressão dos valores de NDVI (2017)



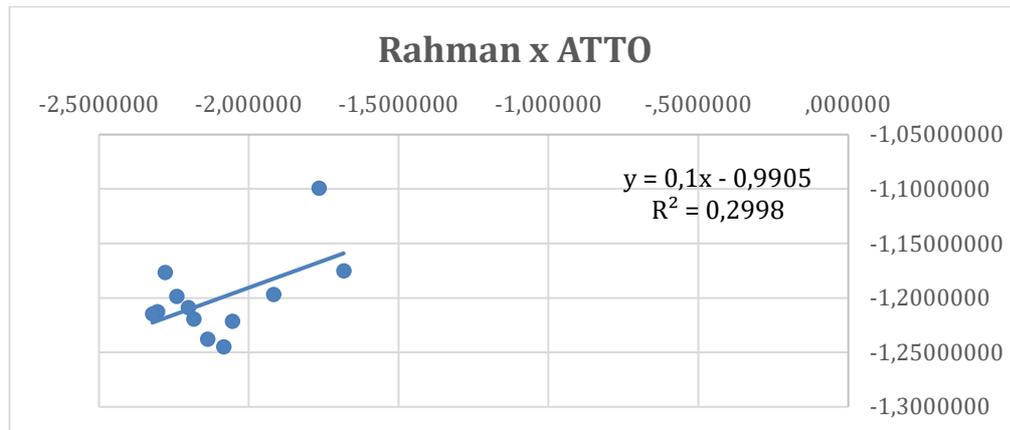
Fonte: (ATTO, 2017). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 2: Linha de Regressão dos valores de PRI (2017)



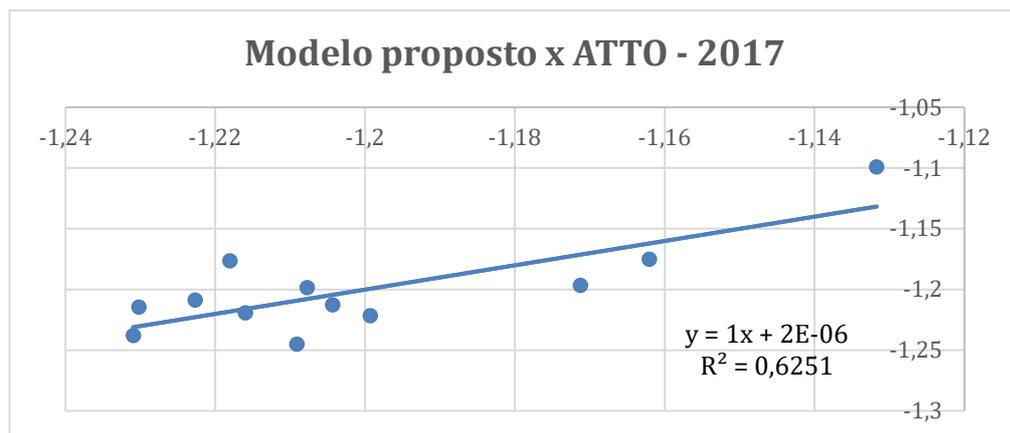
Fonte: (ATTO, 2017). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 3: Linha de Regressão dos valores de Cflux (2017)



Fonte: (ATTO, 2017). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 4: Linha de Regressão dos valores do modelo proposto (2017)

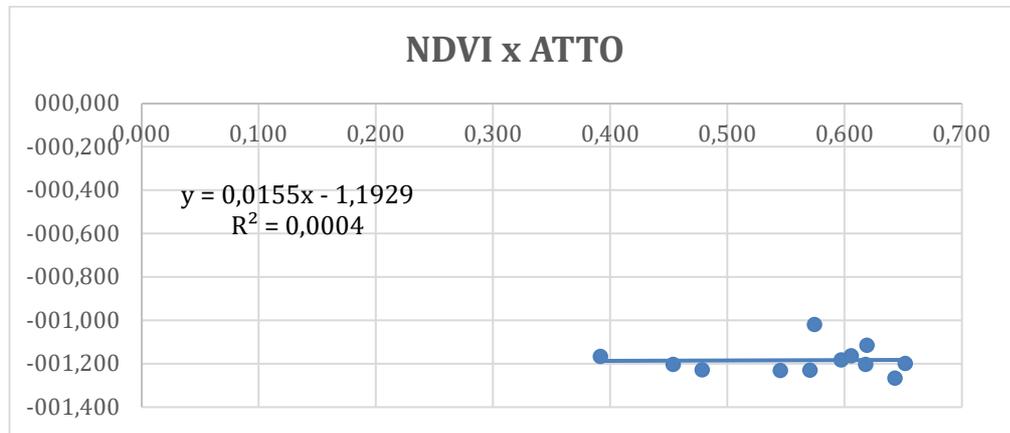


Fonte: (ATTO, 2017). Elaboração, GARCIA, E. A. B., (2020).

Todos os modelos analisados proporcionaram valores estatísticos significantes, porém o método proposto nesta pesquisa demonstrou maior correlação. Em outras palavras, R^2 demonstra que de todos os modelos apresentados neste estudo, o que possui maior ajuste, foi o modelo proposto nesta pesquisa com $R^2 = 0,6251$ com o valor do RMSE de 0,022. Já o modelo de regressão proposto por Rahman *et al.* (2000) apresentou um RMSE de 0,916 e $R^2=0,2998$. Os valores dos índices de PRI também demonstraram um ajuste superior a metodologia proposta por Rahman *et al.*, com $R^2= 0,4749$ e o NDVI teve o pior resultado com $R^2= 0,2596$. Seguindo a sequência, no ano de 2018, a resposta dos índices espectrais proporcionou os Gráficos 5, 6, 7 e 8, expostos na próxima subseção.

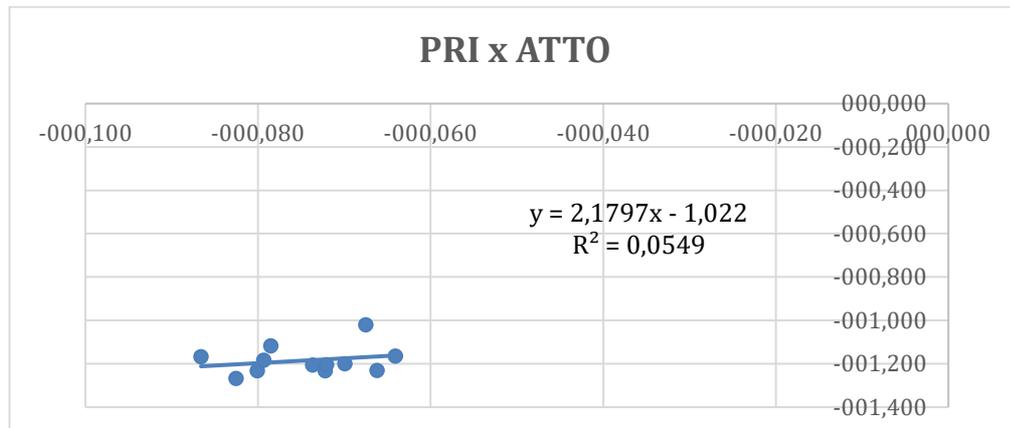
6.4.2 Comparação dos índices espectrais para o ano de 2018.

Gráfico 5: Linha de Regressão dos valores de NDVI (2018)



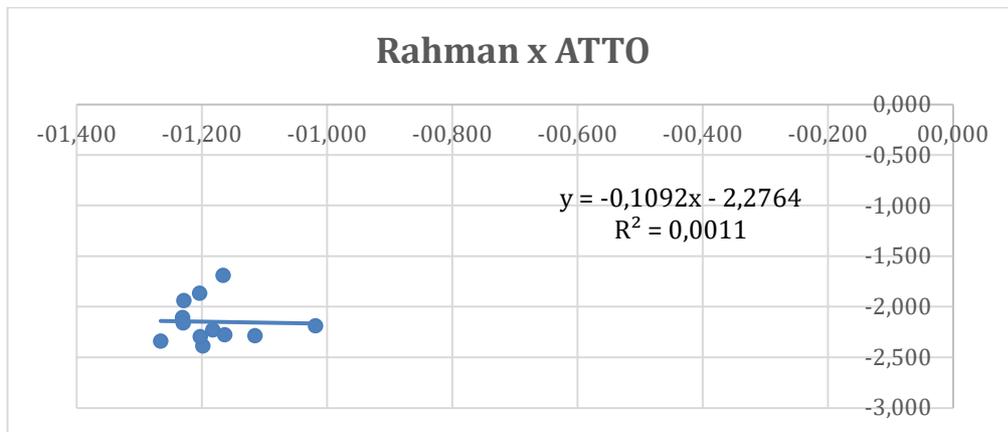
Fonte: (ATTO, 2018). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 6: Linha de Regressão dos valores de PRI (2018)



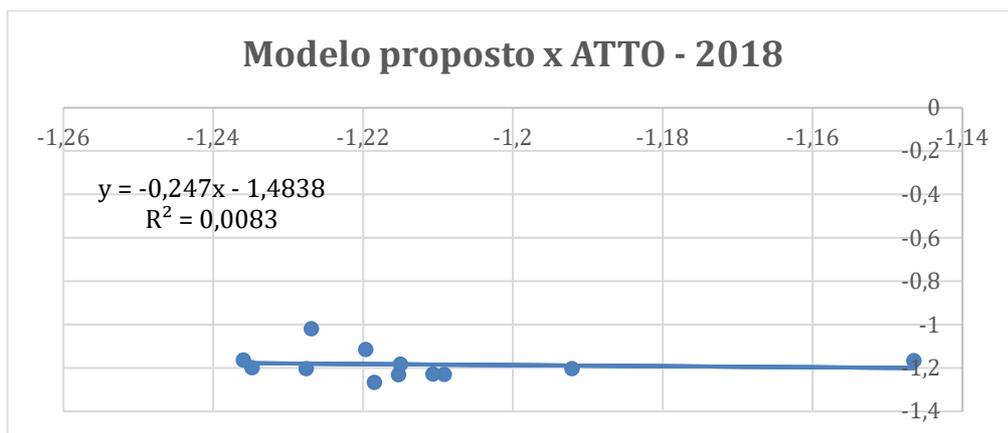
Fonte: (ATTO, 2018). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 7: Linha de Regressão dos valores de NDVI (2018)



Fonte: (ATTO, 2018). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 8: Linha de Regressão dos valores de PRI (2018)

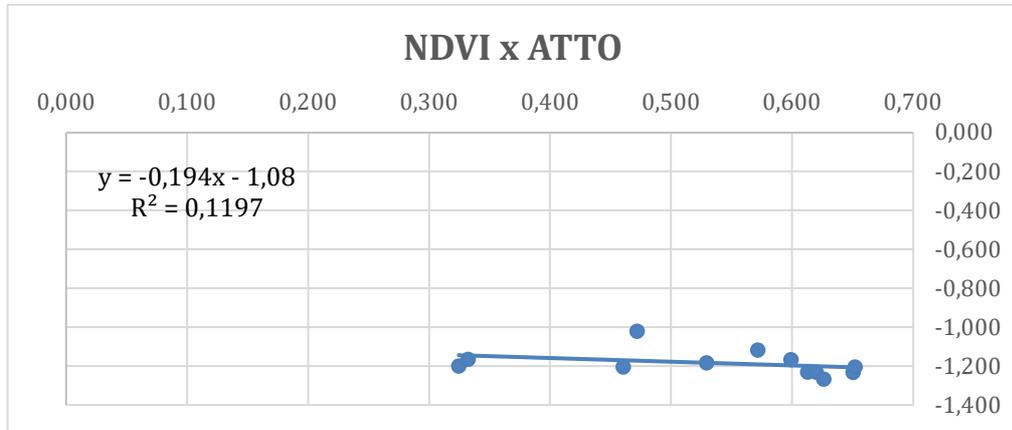


Fonte: (ATTO, 2018). Elaboração, GARCIA, E. A. B., (2020).

No ano de 2018, os valores de R^2 demonstraram que o modelo proposto nesta pesquisa não conseguiu explicar a variabilidade de dados da ATTO. O melhor ajuste, $R^2 = 0,0549$ foi obtido através do índice PRI, seguido do índice proposto nesta pesquisa com R^2 de 0,0083, o método de proposto por Rahman *et al.* (2000) com $R^2=0,0011$ e por fim o índice de NDVI com $R^2=0,0004$. No entanto, ao se comparar os RMSE do índice proposto por Rahman *et al.* (2000), $RMSE= 0,986$, e desta pesquisa, $RMSE= 0,074$, nota-se que o modelo proposto possui um ajuste significativamente superior. Finalizando a série temporal, no ano de 2019, a resposta dos índices espectrais proporcionou os Gráficos 9, 10, 11 e 12, abaixo:

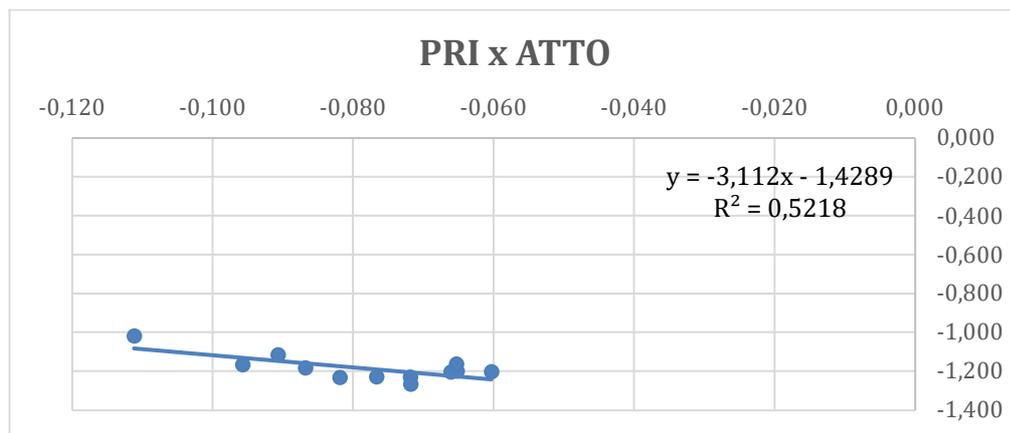
6.4.3 Comparação dos índices espectrais para o ano de 2019.

Gráfico 9: Linha de Regressão dos valores de NDVI (2019)



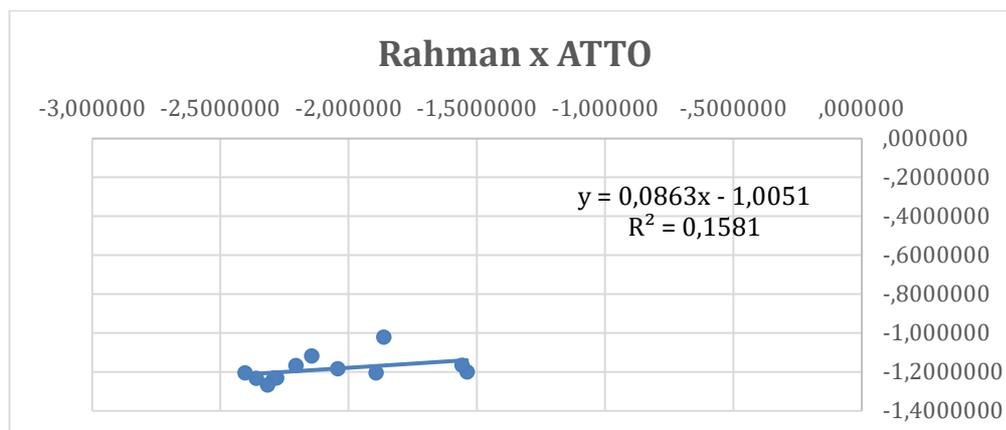
Fonte: (ATTO, 2019). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 10: Linha de Regressão dos valores de PRI (2019)



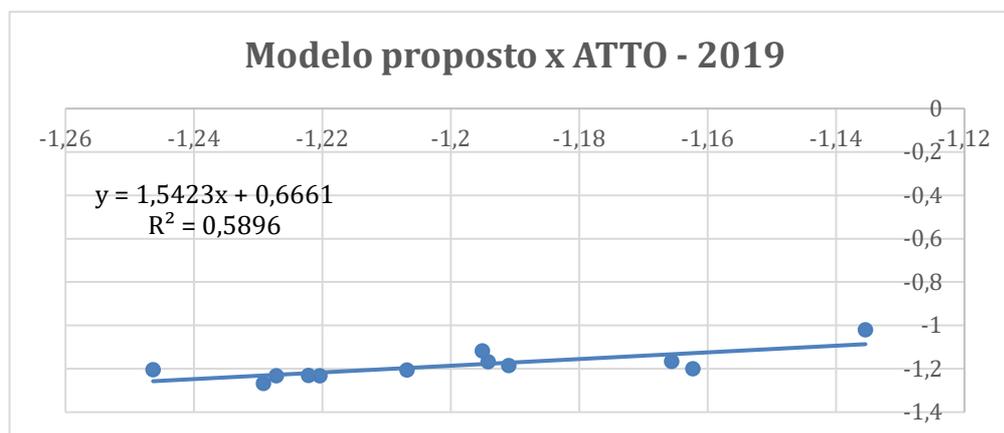
Fonte: (ATTO, 2019). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 11: Linha de Regressão dos valores de Cflux (2019)



Fonte: (ATTO, 2019). Elaboração, GARCIA, E. A. B., (2020).

Gráfico 12: Linha de Regressão dos valores (2019)



Fonte: (ATTO, 2019). Elaboração, GARCIA, E. A. B., (2020).

Em 2019, os valores de R^2 voltaram a ter grandezas superior ao de 2018, porém ligeiramente inferiores em relação ao ano de 2017. O modelo proposto nesta pesquisa conseguiu explicar a variabilidade de dados da ATTO com o ajuste, $R^2 = 0,5896$, seguido do índice PRI, com $R^2 = 0,5218$, depois pelo método proposto por Rahman *et al.* (2000) com $R^2=0,1581$ e por fim o índice de NDVI com $R^2=0,1197$. Os valores do RMSE do índice proposto por Rahman *et al.* (2000), foram de $RMSE= 0,931$, e desta pesquisa, $RMSE= 0,046$, demonstrando que o índice proposto nesta pesquisa possui um ajuste significativamente superior tanto pelo R^2 , como pelo RMSE.

7 CONCLUSÕES

Ao analisar os métodos propostos nesta pesquisa, interpolação por krigagem, ACP e interpolação por polinômios, foi possível constatar sobre a eficácia de cada um dos modelos propostos. Primeiramente ao analisar a interpolação pelo método de krigagem, é possível notar que os RMSE desses modelos deram demasiadamente altos (8,909; 9,648; 9,040) apesar desses valores altos, o modelo conseguiu explicar uma variabilidade dos dados pelo R^2 (0,270; 0,277; 0,315).

O modelo proposto pela Análise de Componentes Principais (ACP) no qual reduz a quantidade de informação para os componentes, demonstrou também valores de RMSE altos, (9,112; 9,858; 9,219) e valores de R^2 (0,237; 0,246; 0,288) apresentando um resultado ligeiramente inferior ao método proposto por krigagem. Tal redução de precisão e ajuste do modelo, poderia ser esperada uma vez que no modelo de ACP reduz a quantidade de variáveis que possa explicar a variável dependente (fluxo de carbono).

O último modelo por polinômios, apresenta uma melhora significativa em relação as demais metodologias. Os valores de RMSE foram significativamente melhores que os demais modelos (1,080; 1,077; 1,073) e os valores de R^2 (0,334; 0,318; 0,339). Supõe-se que esses valores possam ser explicados devido a forma como a equação polinomial permitiu ajustar a linha de regressão aproximando considerando as lacunas e a amplitude dos valores de cada variável, a literatura científica ainda é escassa para explicar porque a modelagem por meio de polinômios possui uma resposta melhor de ajuste da linha de regressão. Como citado anteriormente, sabe-se que em outros tipos de pesquisas utilizando dados meteorológicos, essa metodologia também apresentou bons resultados na previsão das variáveis independentes.

Vale ressaltar que as duas medidas (R^2 e RMSE) têm significado e uso diferentes. O R^2 conseguiu explicar o comportamento (ou a variância) do fluxo em uma que varia de aproximadamente 24% a aproximadamente 34% ao longo de todas as metodologias propostas nesta pesquisa. Portanto, esse modelo consegue explicar esse mesmo percentual do comportamento do fluxo de carbono ao longo dos anos, o que indica que o fluxo de carbono possui algumas correlações com as variáveis micrometeorológicas e que esses fluxos são influenciados por essas variáveis ou possui uma correlação até certo grau. O RMSE permitiu criar intervalos de confiança em torno da estimativa de regressão ao longo das metodologias propostas para um nível de confiança de 95%.

Os dados corroboram em parte a pesquisa elaborado por Tramontana *et al.* (2016) que conseguiu por meio de Aprendizado de Máquina (ML) prever os fluxos de carbono para os dias observados com 70% de aproveitamento. Portanto, sugere-se que em trabalhos verifique a eficácia do ML para a interpolação de dados e a geração de modelos de fluxo de carbono com base em dados micrometeorológicos.

Sabe-se que vários fatores climáticos, influenciam a variabilidade dos dados registrados nos fluxos de carbono (GRIFFIS *et al.*, 2000), porém ainda não possível compreender os seus efeitos individuais de maneira precisa (HUI *et al.*, 2003). No entanto, é possível inferir que a absorção de carbono para a geração de biomassa é afetado pelas taxas de precipitação, (FERLAN *et al.*, 2011) no entanto a composição do solo também afeta profundamente a capacidade de crescimento da vegetação, que afeta a absorção de carbono da atmosfera, e é uma variável que não foi analisada nesta pesquisa.

Fortes correlações diretas foram observadas entre fluxos e índices de vegetação da mesma maneira que a pesquisa de Rossini *et al.* (2012). O índice espectral PRI apresentou bom desempenho para estimar indiretamente os valores de fluxo de carbono no momento da aquisição das imagens orbitais. A utilização do PRI como parâmetro de comparação com os dados diretos também proporcionou valores altos no R^2 de 0,474; 0,008; e 0,521. O ano de 2018 foi o que apresentou maior RMSE e menor valor de R^2 . Infere-se que esses resultados abaixo do esperado se devem a erro de leitura dos equipamentos ou pelas lacunas de dados que foram interpolados já que em todas as modelagens propostas nesta pesquisa, o ano de 2018 apresentou pior desempenho no ajuste das linhas de regressão. Apesar do ano de 2018 apresentar valores de R^2 inferiores aos demais anos, esse índice ainda apresentou maior correlação que os demais índices para o mesmo ano.

Desta forma, a utilização desse índice tem demonstrando uma boa correlação com os índices de fluxo de carbono reais devido ao fato que do PRI calcular indiretamente a absorção do fluxo de carbono pelo aproveitamento da fotossíntese. Em uma revisão da literatura, Garbulsky *et al.* (2011) descobriram que o PRI possui grande correlação a com a Eficiência no Uso da Radiação (RUE) e outras variáveis ecofisiológicas relevantes em escalas espaço-temporais diferentes em outros tipos de biomas. PRI serve como parâmetro indireto de medição dos processos ecofisiológicos com base na eficiência da radiação solar, portanto fornece um meio rápido, simples, não destrutivo e de baixo custo amostragem para estimar as interações

dos fluxos de carbono de diversos ecossistemas (PEÑUELAS *et al.*, 2011; GARBULSKY *et al.*, 2011; DROLET *et al.*, 2008; PEÑUELAS *et al.*, 2015; SONG *et al.*, 2013)

Os valores de NDVI não conseguiram explicar os dados observados pela ATTO, isso provavelmente se deve ao fato desse índice medir a atividade vegetativa. Em outras palavras, o índice permite diferenciar a vegetação de outros tipos de cobertura da terra e determinar seu estado geral e não fotossíntese em si. Em uma revisão de 13 estudos publicados entre os anos de 1977 e 1985 pelo autor Cannell *et al.* (1987), apontou que de 0,8 a 2,1 g de biomassa foi utilizado a unidade de megajoule de radiação solar absorvida. Portanto, as folhas verdes sofrem estresse em poucas horas e cessam a atividade fotossintética, mesmo apresentando altos índices de NDVI. Em outros estudos (GAMON *et al.*, 1995; MYNENI *et al.*, 1995; NESTOLA *et al.*, 2016) que indicaram que o índice de NDVI é eficaz para medir a atividade fotossintética e, portanto, a absorção de fluxo de carbono. No entanto, esta pesquisa demonstrou que esse índice não seria o melhor para estimar essa absorção.

O novo índice proposto nesta pesquisa apresentou os melhores resultados de todos com valores de R^2 de 0,625; 0,054; e de 0,589 para os anos de 2017, 2018 e 2019. Com a exceção do ano de 2018, o modelo proposto nesta pesquisa demonstrou melhor aproveitamento estatístico que os demais índices e modelos. Desta forma, esse índice demonstrou ser confiável para estimar o fluxo de carbono no domínio morfoclimático amazônico de maneira indireta e com baixo custo.

O uso dos modelos de regressão através dos índices espectrais com validação de dados micrometeorológicos para mapear o fluxo de carbono demonstrou promissor devido a eficácia desses modelos. Esse tipo de validação cruzada permite realizar a distribuição espacial dos fluxos de carbono em torno de áreas homogêneas. Deve-se atentar ao fato da escala temporal dos dados, assim como a resolução espacial das imagens orbitais influenciam nos valores dos *pixels*, e que possivelmente, imagens com maior resolução espacial provavelmente estimarão valores mais precisos de fluxo de carbono.

Sugere-se, para pesquisas futuras, que sejam realizados os mesmos procedimentos com o índice proposto nesta pesquisa e realizar uma interpolação dos valores dos *pixels* para toda a região da Amazônia com validação das torres presentes nesse domínio morfoclimático. Também se sugere para pesquisas futuras que sejam utilizados métodos de interpolação por meio de redes neurais ou de aprendizado de máquinas para verificar se há aumento ou

diminuição dos valores de R^2 e do RMSE ao aplicar esses mesmos índices apresentados nesta pesquisa.

8 REFERÊNCIAS

- AB'SABER, A. N. Os domínios morfoclimáticos da América do Sul. Primeira aproximação. **Geomorfologia**, 53: 1–23, 1977.
- AMARAL, S.; SOARES, J. V.; ALVES, D. S.; MELLO, E. M. K.; ALMEIDA, S. A. S.; SILVA, O. F.; SILVEIRA, A. M. Relações entre índice de área foliar (LAI), área basal e índice de vegetação (NDVI) em relação a diferentes estágios de crescimento secundário na Floresta Amazônica em Rondônia. **Revista Selper**, v. 13, p. 35-39, 1997.
- AMAZONAS, Secretaria de Estado do Meio Ambiente e Desenvolvimento Sustentável (SDS). **Série técnica planos de gestão: Reserva de Desenvolvimento Sustentável do Uatumã** (v. 1 e 2). Manaus, Amazonas, Brazil: Governo do Estado do Amazonas, Itapiranga e São Sebastião do Uatumã, 2009.
- ANDRADE, E. M.; SILVEIRA, S. S.; AZEVEDO, B. M. Investigação da Estrutura Multivariada da Evapotranspiração na Região Centro Sul do Ceará pela Análise de Componentes Principais. **Revista Brasileira de Recursos Hídricos**, v. 8, n. 1, p. 39-44, 2003. <https://doi.org/10.21168/rbrh.v8n1.p39-44>
- ANDREAE, M.O. Atmospheric Aerosols: Biogeochemical Sources and Role in Atmospheric Chemistry. **Science**, 276, 1052–1058, 1997. <https://doi.org/10.1126/science.276.5315.1052>
- ARMENTERAS, D.; ESPELTA, J. M.; RODRÍGUEZ, N.; RETANA, J. Deforestation dynamics and drivers in different forest types in Latin America: Three decades of studies (1980–2010). **Global Environmental Change**, 46, 139–147, 2017. <https://doi.org/10.1016/j.gloenvcha.2017.09.002>
- ARROYO-MORA, P.; SANCHEZ-AZOFEIFA, A.; RIVARD, B.; CALVO, J. C. Integrating very high and high resolution imagery for detecting secondary growth in a neotropical dry forest ecosystem: a vegetation indices approach. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 11. 2003, Belo Horizonte. Anais. São José dos Campos: INPE, p. 2655-2662, 2003.

- ASNER G. P. et al. High-resolution forest carbon stocks and emissions in the Amazon. **Proc Natl Acad Sci USA**. 107:16738–16742, 2010. <https://doi.org/10.1073/pnas.1004875107>
- BACCINI, A.; GOETZ, S. J.; WALKER, W. S.; LAPORTE, N. T.; SUN, M.; SULLAMENASHE, D.; HACKLER, J.; BECK, P. S. A.; DUBAYAH, R.; FRIEDL, M. A.; SAMANTA, S.; HOUGHTON, R. A. Estimated carbon dioxide emissions from tropical deforestation improved by carbon-density maps, **Nature Climate Change**, 2, 182–185, 2012. <https://doi.org/10.1038/nclimate1354>
- BACHELET, D.; NEILSON, R. P.; LENIHAN, J. M.; DRAPEK, R. J. Climate Change Effects on Vegetation Distribution and Carbon Budget in the United States. **Ecosystems**, 4, 164– 185, 2001. <https://doi.org/10.1007/s10021-001-0002-7>
- BAGLEY, J. E., A. R. DESAI, K. J. HARDING, P. K. SNYDER, AND J. A. FOLEY. Drought and deforestation: Has land cover change influenced recent precipitation extremes in the Amazon? **Journal of Climate**, 27, 345–361, 2014. <https://doi.org/10.1175/JCLI-D-12-00369.1>
- BALDOCCHI, D. D. et al. FLUXNET: A New Tool to Study the Temporal and Spatial Variability of Ecosystem–Scale Carbon Dioxide Water Vapor and Energy Flux Densities. **Bulletin Am Meteorol Soc**, 82:2415–2434, 2001. [https://doi.org/10.1175/1520-0477\(2001\)082<2415:FANTTS>2.3.CO;2](https://doi.org/10.1175/1520-0477(2001)082<2415:FANTTS>2.3.CO;2)
- BALDOCCHI D.D.; HICKS, B.B.; MEYERS T. P. Measuring biosphere-atmosphere exchanges of biologically related gases with micrometeorological methods. **Ecology**, 69:1331–340, 1988. <https://doi.org/10.1046/j.1365-2486.2003.00629.x>
- BALDOCCHI, D. D. Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: past, present and future. **Global Change Biology**, 9.4, 479-92, 2003. <https://doi.org/10.1111/j.1365-2486.1996.tb00069.x>
- BALDOCCHI, D.; VALENTINI, R.; RUNNING, S.; OECHEL, W.; DAHLMAN, R. Strategies for measuring and carbon dioxide and water vapor fluxes over terrestrial ecosystems. **Glob. Change Biol.** 2, 159–168, 1996.
- BALL, B.C.; SMITH, K.A. Gas movement. In: SMITH, K.A. & MULLINS, C.E. (orgs.). **Soil analysis: Physical methods**. New York, Marcel Dekker. p.511-549, 1991.

- BAPTISTA, G. M. M. Validação da Modelagem de seqüestro de carbono para ambientes tropicais de cerrado, por meio de dados AVIRIS HYPERION. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 11 (SBSR), 2003, Belo Horizonte. Anais. São José dos Campos: INPE, 2003. p. 1037-1044. Disponível em: http://marte.dpi.inpe.br/col/ltid.inpe.br/sbsr/2002/09.07.21.45/doc/10_002.pdf. Acesso em 17 de setembro de 2019.
- BARBIERI, V.; TUON, R. L. Metodologia para estimativa da produção potencial de algumas culturas. **Piracicaba: ESALQ/Departamento de Física e Meteorologia**, 1992.
- BAWA, K. et al. Assessing biodiversity from space: an example from the Western Ghats, India. **Conservation Ecology**, v. 6, n. 2, 2002. <https://doi.org/10.5751/ES-00434-060207>
- BELLOLI, T. F. **Estimativa de biomassa e estoque de carbono de vegetação macrofítica a partir de dados espectrais e de campo em Banhado Grande, RS**. 2019. 127 f. Dissertação (Mestrado em Geografia) - Curso de Geografia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2019. Disponível em: <https://www.lume.ufrgs.br/bitstream/handle/10183/202034/001106858.pdf?sequence=1>. Acesso em: 14 ago. 2020.
- BONAN, G. B. Forests and Climate Change: forcings, feedbacks, and the climate benefits of forests. American Association for the Advancement of Science (AAAS). **Science**, [s.l.], v. 320, n. 5882, p. 1444-1449, 13 jun. 2008. <https://doi.org/10.1126/science.1155121>
- BONAN, G. Soil Moisture and the Atmospheric Boundary Layer. In **Ecological Climatology: Concepts and Applications** (pp. 218-230), 2015. Cambridge: **Cambridge University Press**. <https://doi.org/10.1017/CBO9781107339200.015>
- BRASIL, Ministério da Agricultura. **Programa Nacional de Microbacias Hidrográficas: manual operativo**. Brasília, 1987. Disponível em <http://www.embrapa.br> acesso em: 26 de novembro de 2018.
- _____. Projeto Radam Brasil. Ministério das Minas e Energia, Departamento Nacional da Produção Mineral, Folha SA-20 Manaus. **Levantamento dos recursos naturais**, Rio de Janeiro, 1978.

BURBA, G. Eddy Covariance Method for Scientific, Industrial, Agricultural and Regulatory Applications: a Field Book on Measuring Ecosystem Gas Exchange and Areal Emission Rates. **LI-COR Biosciences**, Lincoln, USA, 331 pp, 2013.

CAMERON, S., **Econometrics**. United Kingdom: McGraw-Hill Education, 2005.

CANADELL, J. G. *et al.*. Carbon metabolism of the terrestrial biosphere: a multi-technique approach for improved understanding. *Ecosystems* 3:115–130, 2000. <https://doi.org/10.1007/s100210000014>

_____. Saturation of the terrestrial carbon sink. In: CANADELL, J.G.; PATAKI, D.E.; PITELKA, L.F. (orgs.) **Terrestrial Ecosystems in a Changing World**. Springer; Germany: pp. 59–78, 2007. https://doi.org/10.1007/978-3-540-32730-1_6

CANNELL M. G. R. *et al.* Radiation interception and productivity of Willow. **Journal of Applied Ecology**, 24, 261–278, 1987. <https://doi.org/10.2307/2403803>

CARVALHO, J. L. N. *et al.* Potencial de sequestro de carbono em diferentes biomas do Brasil. **Revista Brasileira de Ciência do Solo**, v. 34, n. 2, p. 277–290, abr. 2010. Disponível em: <http://www.scielo.br/scielo.php?script=sci_arttext&pid=S0100-06832010000200001&lng=pt&tlng=pt>. Acesso em 17 de outubro de 2019. <https://doi.org/10.1590/S0100-06832010000200001>

CELES, C H S. **Estoque de carbono e quantificação da incerteza propagada combinando inventário florestal e sensoriamento remoto**. 2017. 121 f. Tese(Doutorado em Ciências de Florestas Tropicais - CFT) - Instituto Nacional de Pesquisas da Amazônia, Manaus, 2017.

CERQUEIRA, D.B.; ROCHA, W.F. Relação entre tipos de vegetação e fluxo de CO₂ no Bioma Caatinga: Estudo de caso em Rio das Contas-BA. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 13. (SBSR), 2007, Florianópolis. Anais. São José dos Campos: INPE, 2007. p. 2413-2419. Disponível em: <<http://marte.dpi.inpe.br/col/dpi.inpe.br/sbsr@80/2006/11.16.00.29/doc/2413-2419.pdf>>. Acesso em: 01 nov. 2019.

CERRI, C. C.; BERNOUX, M; CERRI, C. E. P.; LAL, R. Chapter 2 - Challenges and opportunities of soil carbon sequestration in Latin America. In: **Carbon sequestration in soils of Latin America** [S.l: s.n.], 2006.

- CHAMBERS, L. E. *et al.* Phenomenological Changes in the Southern Hemisphere. **Plos One**, 8(10): e75514, 2013. <https://doi.org/10.1371/journal.pone.0075514>
- CHAMEIDES, W.L.; LINDSAY, R.W.; RICHARDSON, J.; KIANG, C.S. The Role of Biogenic Hydrocarbons in Urban Photochemical Smog — Atlanta as a Case-Study. **Science**, v. 241, 1473–1475, 1988. <https://doi.org/10.1126/science.3420404>
- CHARNET, R.; BONVINO, H; FREIRE C. A. L; CHARNET, E. M. R. **Análise de modelos de regressão linear com aplicações**. Campinas, SP: Unicamp, 1999.
- CHATTERJEE, S. E SIMONOFF, J. S. **Handbook of Regression Analysis**. John Wiley & Sons, 2013. <https://doi.org/10.1002/9781118532843>
- CIAIS, P. *et al.* Partitioning of ocean and land uptake of CO₂ as inferred by $\delta^{13}\text{C}$ measurements from the NOAA Climate Monitoring and Diagnostics Laboratory Global Air Sampling Network. **Journal of Geophys. Res.**, 100, 5051–5070, 1995. <https://doi.org/10.1029/94JD02847>
- CIHLAR, J.; DENNING, A.S.; GOSZ, J. **Global terrestrial Carbon Observation Requirements, Present Status, and Next Steps**. CCRS, Ottawa, Canada satellite carbon flux, 2000. <https://doi.org/10.4095/219687>
- COHEN, J. **Statistical power analysis for the behavioral sciences**. Hillsdale, NJ, Erlbaum, 1998..
- COLTRI, P. P. *et al.* Utilização de índices de vegetação para estimativas não-destrutivas da biomassa, estoque e sequestro de carbono do Cafeeiro Arábica. In: **XIV Simpósio Brasileiro de Sensoriamento Remoto**. Natal, p. 121-128, 2009.
- COUTINHO, E .R. *et al.*. Application of Artificial Neural Networks (ANNs) in the Gap Filling of Meteorological Time Series. **Revista Brasileira de Meteorologia**, [S.L.], v. 33, n. 2, p. 317-328, jun. 2018. <https://doi.org/10.1590/0102-7786332013>
- CUMMINGS, B. **Dam the Rivers, Damn the People**. Earthscan Publications. London, 1990.
- ARMENTERAS, D.; BARRETO, J. S.; TABOR, K.; MOLOWNY, R.; RETANA, J. Changing patterns of fire occurrence in proximity to forest edges, roads and rivers between NW Amazonian countries. **Biogeosci Discuss**, pp. 1-29, 2017. <https://doi.org/10.5194/bg-2016-532-supplement>

- DABROWSKA-ZIELINSKA, K. *et al.* **Remote Sensing**, [s.l.], v. 8, n. 9, p. 756, 15 set. 2016. <https://doi.org/10.3390/rs8090756>
- DAI, Z. *et al.* Modeling carbon stocks in a secondary tropical dry forest in the Yucatan Peninsula, Mexico. **Water Air Soil Pollut.** 1925;2014:225, 2014. <https://doi.org/10.1007/s11270-014-1925-x>
- FRIES, R.S. de; HOUGHTON, R. A.; HANSEN, M. C.; FIELD, C. B.; SKOLE, D.; TOWNSHEND, J. **Carbon emissions from tropical deforestation and regrowth based on satellite observations for the 1980s and 1990s.** Proc Natl Acad Sci USA, 2002.
- DEMMIG-ADAMS, B.; ADAMS, W. The role of xanthophyll cycle carotenoids in the protection of photosynthesis. **Trends Plant Sci**, 1, 21–26, 1996. [https://doi.org/10.1016/S1360-1385\(96\)80019-7](https://doi.org/10.1016/S1360-1385(96)80019-7)
- DIXON, R.K.; BROWN, S.; HOUGHTON, R.A.; SOLOMON, A.M.; TREXLER, M.C. & WISNIEWSKI, J. Carbon pools and flux of global forest ecosystems. **Science**, 263:185-190, 1994. <https://doi.org/10.1126/science.263.5144.185>
- DONNELLY, F. P. Evaluating open source GIS for libraries. Emerald Group Publishing, **Library Hi Tech**, v. 28 No. 1, pp. 131-151, 2010. <https://doi.org/10.1108/07378831011026742>
- DROLET, G.G.; HUENNRICH, K.F.; HALL, F.G.; MIDDLETON, E.M.; BLACK, T.A.; BARR, A.G.; MARGOLIS, H.A. A MODIS derived photochemical reflectance index to detect inter-annual variations in the photosynthetic light-use efficiency of a boreal deciduous forest. **Remote Sens. Environ.**, 98, 212–224, 2005. <https://doi.org/10.1016/j.rse.2005.07.006>
- DROLET, G.G.; MIDDLETON, E.M.; HUENNRICH, K.F.; HALL, F.G.; AMIRO, B.D.; BARR, A.G.; BLACK, T.A.; MCCAUGHEY, J.H.; MARGOLIS, H.A. Regional mapping of gross light-use efficiency using MODIS spectral indexes. **Remote Sens. Environ.**, 112, 3064– 3078, 2008. <https://doi.org/10.1016/j.rse.2008.03.002>
- DUIKER, S.W. & LAL, R. Carbon budget study using CO₂ flux measurements from a no till system in central Ohio. **Soil Tillage Res.**, 54:21-30, 2000. [https://doi.org/10.1016/S0167-1987\(99\)00101-4](https://doi.org/10.1016/S0167-1987(99)00101-4)

- ECKARDT, F.E. Le principe de la soufflerie climatisee, applique a l'etude des echanges gazeux de la couverture vCgCtale. **Oecologia Plantarum**, 1,369-400, 1966.
- EKLUNDH, L.; HONGXIAO, J.; SCHUBERT, P.; GUZINSKI, R.; HELIASZ, M. An optical sensor network for vegetation phenomenology monitoring and satellite data calibration. **Sensors**, 11 7678–709, 2011. <https://doi.org/10.3390/s110807678>
- ELETRONORTE/IBAMA. Reserva Biológica do Uatumã – **Plano de Manejo – Fase 1**. Manaus: 173p., 1996.
- ESCADA, M. I. S.; ALVES, D. S. **Mudanças de uso e cobertura do solo na Amazônia: Impactos socioambientais na ocupação de regiões de fronteira agrícola (Relatório técnico)**. Programa de Ciência e Tecnologia para Gestão de Ecossistemas, Instituto Nacional de Pesquisas Espaciais, Ministério da Ciência e Tecnologia. São Paulo, Brasil, 2001.
- ESPÍRITO-SANTO, F. D. B. *et al.* Size and frequency of natural forest disturbances and the Amazon forest carbon balance. **Nat Commun**. v. 5:3434, 2014. <https://doi.org/10.1038/ncomms4434>
- ESWARAN, H. *et al.* Gap filling strategies for defensible annual sums of net ecosystem exchange. **J. Agric. For. Meteorol**. 107, 43–69, 2001.
- FAN, J., CHEN, B., WU, L., ZHANG, F., LU, X., & XIANG, Y. Evaluation and development of temperature-based empirical models for estimating daily global solar radiation in humid regions. **Energy**, v. 144, 903–914, 2018. <https://doi.org/10.1016/j.energy.2017.12.091>
- FAO. **Global forest resources assessment 2005: Progress towards sustainable forest management**. Rome, Food and Agriculture Organization of the United Nations, 2006.
- FEARNSIDE, P. M. Desmatamento na Amazônia brasileira: História, índices e consequências. **Mega Diversidades**. 1, 113–123, 2005.
- FEARNSIDE, P. M. A Hidrelétrica de Balbina: O faraonismo irreversível versus o meio ambiente na Amazônia. pp. 97-125. In: COHN; HAFT (orgs.). **Hidrelétricas na Amazônia: Impactos Ambientais e Sociais na Tomada de Decisões sobre Grandes Obras**. v. 1. Editora do Instituto Nacional de Pesquisas da Amazônia (INPA), 2015.

FENSHOLT, R.; SANDHOLT, I.; RASMUSSEN, M. Evaluation of MODIS LAI, FAPAR and the relation between FAPAR and NDVI in a semi-arid environment using in situ measurements **Remote Sens. Environ.** 91 490–507, 2004. <https://doi.org/10.1016/j.rse.2004.04.009>

FERLAN, M.; ALBERTI, G.; ELER, K.; BATIČ, F.; MIGLIETTA, F.; ZALDEI, A.; SIMONČIČ, P. Comparing carbon fluxes between different stages of secondary succession of a karst grassland. **Agriculture, Ecosystems and Environment**, v. 140, 199–207, 2011. <https://doi.org/10.1016/j.agee.2010.12.003>

FERRARI, G. T.; OZAKI, V. Missing data imputation of climate datasets: implications to modeling extreme drought events. **Revista Brasileira de Meteorologia**, 29(1), 21–28, 2014. <https://doi.org/10.1590/S0102-77862014000100003>

FERREIRA, S. **Estimativa de emissões de gases de efeito estufa em reservatórios de hidrelétricas utilizando técnicas de sensoriamento remoto**. 2017. 102 f. Tese (Doutorado em Sensoriamento Remoto) – Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre 2017.

FILELLA, I. *et al.* A MODIS Photochemical Reflectance Index (PRI) as an Estimator of Isoprene Emissions in a Temperate Deciduous Forest. **Remote Sens**, v. 10, 557, 2018. <https://doi.org/10.3390/rs10040557>

FOLEY, J.A. *et al.* Global consequences of land use. **Science**, v. 309:570-574, 2005. <https://doi.org/10.1126/science.1111772>

FORSTER, P., V. RAMASWAMY, P. ARTAXO, T. BERNTSEN, R. BETTS, D.W. FAHEY, J. HAYWOOD, J. LEAN, D.C. LOWE, G. MYHRE, J. NGANGA, R. PRINN, G. RAGA, M. SCHULZ AND R. VAN DORLAND, 2007: Changes in Atmospheric Constituents and in Radiative Forcing. In: *Climate Change 2007: The Physical Science Basis. Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change*. **Cambridge University Press**, Cambridge, United Kingdom and New York, NY, USA.

FRIEDL, M. A.; SULLA-MENASHE, 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 Sens. Environ.** 114 168–82, 2010. <https://doi.org/10.1016/j.rse.2009.08.016>
- FUENTES, J.D. *et al.* Biogenic Hydrocarbons in the Atmospheric Boundary Layer: A Review. *Bull. Am. Meteorol. Soc.*, v. 81, 1537–1575, 2000. [https://doi.org/10.1175/1520-0477\(2000\)081<1537:BHITAB>2.3.CO;2](https://doi.org/10.1175/1520-0477(2000)081<1537:BHITAB>2.3.CO;2)
- GAMON, J. A. *et al.* Remote sensing of the xanthophyll cycle and chlorophyll fluorescence in sunflower leaves and canopies. **Oecologia**, v.85, 1–7, 1990 <https://doi.org/10.1007/BF00317336>
- _____. A narrow-waveband spectral index that tracks diurnal changes in photosynthetic efficiency. **Remote Sensing of Environment**, v. 41, 35-44, 1992. [https://doi.org/10.1016/0034-4257\(92\)90059-S](https://doi.org/10.1016/0034-4257(92)90059-S)
- _____. Relationships Between NDVI, Canopy Structure, and Photosynthesis in Three Californian Vegetation Types. **Ecological Applications**, v.5(1), 28–41, 1995. <https://doi.org/10.2307/1942049>
- _____. The photochemical reflectance index: an optical indicator of photosynthetic radiation use efficiency across species, functional types, and nutrient levels. **Oecologia**, v. 112, n.4, p. 492-501, 1997. <https://doi.org/10.1007/s004420050337>
- GARBULSKY, M.F.; PEÑUELAS, J.; GAMON, J. A.; INOUE, Y.; FILELLA, I. The photochemical reflectance index (PRI) and the remote sensing of leaf, canopy and ecosystem radiation use efficiencies: A review and meta-analysis. **Remote Sens. Environ**, 115, 281–297, 2011. <https://doi.org/10.1016/j.rse.2010.08.023>
- GASH, J. H. C., NOBRE, C. A., Roberts, J., and Victoria, R. L. (orgs.). **Amazonian Deforestation and Climate**. John Wiley, Chichester, 611 pp., 1996.
- GATTI, L. V. J. *et al.* Drought sensitivity of Amazonian carbon balance revealed by atmospheric measurements. **Nature**, 506(7486), 76–80, 2014. <https://doi.org/10.1038/nature12957>
- GLOOR, M. *et al.* The carbon balance of South America: a review of the status, decadal trends and main determinants, **Biogeosciences**, n. 9, 5407–5430, 2012. <https://doi.org/10.5194/bg-9-5407-2012>

- GOCKEDE, M.; REBMANN, C.; FOKEN, T. A combination of quality assessment tools for eddy covariance measurements with footprint modelling for the characterization of complex sites. **Agric. Forest Meteorol.** 127 175–88, 2004. <https://doi.org/10.1016/j.agrformet.2004.07.012>
- GOULDEN, M. L. *et al.* Measurements of carbon sequestration by long-term eddy covariance: Methods and a critical evaluation of accuracy. **Global Change Biology**, 2.3: 169- 82, 1996. <https://doi.org/10.1111/j.1365-2486.1996.tb00070.x>
- GOULDING, M.; BARTHEM, R. B.; DUENAS, R. **The Smithsonian Atlas of the Amazon.** Washington, D.C., Smithsonian Books, 253 pp., 2003.
- GRACE, J. *et al.* Carbon Dioxide Uptake by an Undisturbed Tropical Rain Forest in South-West Amazonia 1992–1993. **Science**, n. 270, 778–780, 1995. <https://doi.org/10.1126/science.270.5237.778>
- GRECO, S. AND BALDOCCHI, D. Seasonal variations of CO₂ and water vapour exchange rates over a temperate deciduous forest. **Global Change Biol.** 2,183-1 97, 1996. <https://doi.org/10.1111/j.1365-2486.1996.tb00071.x>
- GRIFFIS, T. J., ROUSE, W. R., AND WADDINGTON, J. M. Interannual variability of net ecosystem CO₂ exchange at a subarctic fen. **Global Biogeochemical Cycles**, 14(4), 1109–1121, 2000. <https://doi.org/10.1029/1999GB001243>
- HANSEN M. C. *et al.* Humid tropical forest clearing from 2000 to 2005 quantified by using multitemporal and multiresolution remotely sensed data. **Proceedings of the National Academy of Sciences**, 105(27), 9439-9444, 2008. <https://doi.org/10.1073/pnas.0804042105>
- HIGUCHI, F., CARNEIRO FILHO, A., SILVA, R. P., LIMA, A. J. N., SANTOS, J., & HIGUCHI, N. A floresta e as mudanças climáticas. In: HIGUCHI, M.; HIGUCHI, N. (orgs.). **A floresta amazônica e suas múltiplas dimensões: Uma proposta de educação ambiental** (2nd rev. ed.). Manaus, Brazil: INPA, 2012. <https://doi.org/10.5380/rf.v41i3.24060>
- HOFFMANN, W. A.; JACKSON, R. B. Vegetation-Climate feedbacks in the conservation of tropical savanna to grassland. **Journal of Climate**, Boston, v. 13, p. 1593-1602, 2000. [https://doi.org/10.1175/1520-0442\(2000\)013<1593:VCFITC>2.0.CO;2](https://doi.org/10.1175/1520-0442(2000)013<1593:VCFITC>2.0.CO;2)

HOFHANSL F., SCHNECKER J., SINGER, G.; WANEK W. New insights into mechanisms driving carbon allocation in tropical forests. **New Phytol.** p.137–46, 2014. <https://doi.org/10.1111/nph.13007>

HOPKINS M. J. G. **Flora Da Reserva Ducke.** Amazonas, Brasil. *Rodriguésia* 86: 9– 25, 2005. <https://doi.org/10.1590/2175-78602005568602>

HOUGHTON, R. A. *et al.* Carbon emissions from land use and land-cover change. **Biogeosciences**, v. 9, n. 12, p. 5125–5142, 2012. Disponível em: <<http://www.biogeosciences.net/9/5125/2012/>>. Acesso em 22 de janeiro de 2020. <https://doi.org/10.5194/bg-9-5125-2012>

HUEMMRICH KF, Black TA, Jarvis PG, McCaughey JH, Hall FG. High temporal resolution NDVI phenology from micrometeorological radiation sensors. **J. Geophys. Res.**104(D22):27935–27944, 1999. <https://doi.org/10.1029/1999JD900164>

HUI, D., LUO, Y.; KATUL, G. Partition interannual variability in net ecosystem exchange between climatic variability and functional change. **Tree Physiology**, 23, 433–442, 2003. <https://doi.org/10.1093/treephys/23.7.433>

HUI, D., WAN, S., SU, B., KATUL, G., MONSON, R., LUO, Y. Gapfilling missing data in eddy covariance measurements using multiple imputation (MI) for annual estimations. **Agric. For. Meteorol.** 121, 93–111, 2004. [https://doi.org/10.1016/S0168-1923\(03\)00158-8](https://doi.org/10.1016/S0168-1923(03)00158-8)

HUI, D., LUO, Y.; KATUL, G. Partitioning interannual variability in net ecosystem exchange between climatic variability and functional change, **Tree Physiol.**, 23(7), 433–442, 2003. <https://doi.org/10.1093/treephys/23.7.433>

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). **Monitoramento da Floresta**, São José dos Campos 2004.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE – IPCC. Special report on carbon dioxide capture and storage. In: METZ B, et al.(orgs).**Prepared by Working Group III of the Intergovernmental Panel on Climate Change.** Cambridge University Press, Cambridge, United Kingdom/New York, NY, USA, p 442, 2005.

INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE - IPCC. Climate change 2007. **Fourth Assessment Report on climate change impacts, adaptation and**

vulnerability of the Intergovernmental Panel on Climate Change. Cambridge, Cambridge University, 939p., 2007. <https://doi.org/10.1017/CBO9780511546013>

JOHNSON, M. O. et al. Variation in stem mortality rates determines patterns of above-ground biomass in Amazonian forests: implications for dynamic global vegetation models. **Global change biology**, v. 22, n. 12, p. 3996-4013, 2016.

JUNBANG W. *et al.* Modelling carbon fluxes of different forests by coupling a remotesensing model with an ecosystem process model, **International Journal of Remote Sensing**, 32:21, 6539-6567, 2011. <https://doi.org/10.1080/01431161.2010.512933>

JUNGES, A.H.; ALVES, G.; FONTANA, D.C. Estudo indicativo do comportamento do NDVI e EVI em lavouras de cereais de inverno da região norte do Estado do Rio Grande do Sul, através de imagens MODIS. In: Simpósio Brasileiro de Sensoriamento Remoto, 13. (SBSR), Florianópolis. **Anais São José dos Campos: INPE**, p. 2413-2419, 2007.

KER, J. C. **Latosolos do Brasil: uma revisão.** Geonomos, 5:17-40, 1997. <https://doi.org/10.18285/geonomos.v5i1.187>

KIS, I M. Comparison of Ordinary and Universal Kriging interpolation techniques on a depth variable (a case of linear spatial trend), case study of the Šandrovac Field. **Rudarsko-Geološko-Naftni Zbornik**, Zagreb, v. 31, n. 2, p. 41-58, 12 abr. 2016. Disponível em: <https://core.ac.uk/download/pdf/91950915.pdf>. Acesso em: 06 de agosto de 2020.

KRUPA, S., NOSAL, M., FERDINAND, J. A., STEVENSON, R. E., & SKELLY, J. M. A multi-variate statistical model integrating passive sampler and meteorology data to predict the frequency distributions of hourly ambient ozone (O₃) concentrations. **Environmental Pollution**, 124(1), 173–178, 2003. [https://doi.org/10.1016/S0269-7491\(02\)00407-4](https://doi.org/10.1016/S0269-7491(02)00407-4)

KUNTSCHIK, G.; BITENCOURT, M. D.. Quantificação de fitomassa florestal aérea de cerrado e cerradão através de imagens orbitais SAR. **XI Simpósio Brasileiro de Sensoriamento Remoto**, v. 5, p. 2201-2208, 2003.

LAL, R. Soil carbon sequestration impacts on global climate change and food security. **Science**, 304:1623-1627, 2004. <https://doi.org/10.1126/science.1097396>

- LAL, R. Soil carbon sequestration in Latin America. In: LAL, R.; CERRI, C.C.; BERNOUX, M.; ETCHEVERS, J. & CERRI, C.E.P. **Carbon sequestration in soils of Latin America**. New York, Haworth Press, p.49-64, 2006. <https://doi.org/10.1201/9781482298031>
- LAW, B. E., *et al.*. Environmental controls over carbon dioxide and water vapor exchange of terrestrial vegetation, **Agric. For. Meteorol.**, 113(1-4), 97-120, 2002. [https://doi.org/10.1016/S0168-1923\(02\)00104-1](https://doi.org/10.1016/S0168-1923(02)00104-1)
- LEITE, B. R. A.; BAPTISTA, G.M.M. Avaliação da importância ambiental da wetland do Riacho Fundo para o Lago Paranoá e comunidades vizinhas. **Revista Brasileira de Geografia Física**, v. 08 n. 05, 1524-1540, 2015. <https://doi.org/10.5935/1984-2295.20150085>
- LEWIS, S. L. *et al.*. The 2010 Amazon Drought. **Science**, n. 331 (6017), 554-554, 2011. <https://doi.org/10.1126/science.1200807>
- MACHADO, R. B. *et al.*. **Estimativas de perda da área do Cerrado brasileiro**. Relatório técnico não publicado. Conservação Internacional, Brasília, DF, 2004.
- MALHI, Y. *et al.* The linkages between photosynthesis, productivity, growth and biomass in lowland Amazonian forests, **Global Change Biol.**, 21, 2283-2295, 2015. <https://doi.org/10.1111/gcb.12859>
- MALHI, Y., J. T. ROBERTS, R. A. BETTS, T. J. KILLEEN, W. LI, AND C. A. NOBRE. Climate Change, Deforestation, and the Fate of the Amazon. **Science**, n.319 (5860), 169-172, 2008. <https://doi.org/10.1126/science.1146961>
- MALHI, Y. *et al.* The regional variation of above ground live biomass in old-growth Amazonian forests. **Global Change Biology**, [s.l.], v. 12, n. 7, p. 1107-1138, jul. 2006. <https://doi.org/10.1111/j.1365-2486.2006.01120.x>
- MARTINS, V. S.; SOARES, J. V.; NOVO, E. M. L. M.; BARBOSA, C. C. F.; PINTO, C. T.; ARCANJO, J. S.; KALEITA, A. Continental-scale surface reflectance product from CBERS-4 MUX data: assessment of atmospheric correction method using coincident landsat observations. **Remote Sensing of Environment**, [S.L.], v. 218, p. 55-68, dez. 2018. <https://doi.org/10.1016/j.rse.2018.09.017>

- MASEK JG, COLLATZ GJ. **Estimating forest carbon fluxes in a disturbed southeastern landscape:** Integration of remote sensing, forest inventory, and biogeochemical modeling. *J Geophys Res*, 2006. <https://doi.org/10.1029/2005JG000062>
- MASSMAN, W., LEE, X. Eddy covariance flux corrections and uncertainties in long-term studies of carbon and energy exchanges. **Agricultural and Forest Meteorology** 113, 121-144, 2002. [https://doi.org/10.1016/S0168-1923\(02\)00105-3](https://doi.org/10.1016/S0168-1923(02)00105-3)
- MELILLO, J.M. *et al.*. Soil warming and carbon-cycle feedbacks to the climate system. **Science**, 298:2173-2176, 2002. [https://doi.org/10.1016/S0168-1923\(02\)00105-3](https://doi.org/10.1016/S0168-1923(02)00105-3)
- MINISTÉRIO DO MEIO AMBIENTE. **SNUC—Sistema nacional de unidades de conservação da natureza.** Lei n 9.985, de 18 de julho de 2000; Decreto n 4.340, de 22 de agosto de 2002; Decreto n 5.746, de 5 de abril de 2006. Plano estratégico nacional de áreas protegidas: decreto n 5.758, de 13 de abril de 2006. Brasília, Brazil, 2011.
- MOFFAT, A. M. *et al.* Comprehensive comparison of gap-filling techniques for eddy covariance net carbon fluxes. **Agricultural And Forest Meteorology**, [s.l.], v. 147, n. 3-4, p. 209-232, dez. 2007. <https://doi.org/10.1016/j.agrformet.2007.08.011>
- MONCRIEFF JB, MAHLI, Y, LEUNING R. The propagation of errors in long term measurements of land atmosphere fluxes of carbon and water. **Global Change Biology**, 2, 231-240, 1996. <https://doi.org/10.1111/j.1365-2486.1996.tb00075.x>
- MONTEITH, J.L. (1962). Measurement and interpretation of carbon dioxide fluxes in the field. *Neth. J. Agr. Sci.* 10, 334-346. <https://doi.org/10.18174/njas.v10i5.17575>
- MOREIRA, F. M. S.; SIQUEIRA, J. O. **Microbiologia e bioquímica do solo.** Lavras: UFLA, 2006.
- OCIO, J. A.; BROOKES, P. C. An evaluation of methods for measuring the microbial biomass in soils following recent additions of wheat straw and characterization of the biomass that develops. **Soil Biology and Biochemistry**, v. 22, n. 5, p. 685-694, 1990. [https://doi.org/10.1016/0038-0717\(90\)90016-S](https://doi.org/10.1016/0038-0717(90)90016-S)
- MORGENSTERN, K. *et al.* Sensitivity and uncertainty of the carbon balance of a Pacific Northwest Douglas-fir forest during an El Nino-La Nina cycle. **Agric. For. Meteorol.** 123, 201–219, 2004. <https://doi.org/10.1016/j.agrformet.2003.12.003>

- MORI, S. A.; G. T. PRANCE. **The Geophysiology of Amazonia:** Chapter Species Diversity, Phenology, Plant-Animal Interactions, and Their Correlation with Climate, as Illustrated by the Brazil Nut Family (Lecythidaceae). pp. 69–90. New York: Wiley, 1987.
- MUSGRAVE, R.B. AND MOSS, D.N. Photosynthesis under field conditions. I. A portable, closed system for determining net assimilation and respiration of corn. **Crop Sci.** 1,37-41, 1961. <https://doi.org/10.2135/cropsci1961.0011183X000100010012x>
- MYNENI, R. B., HALL, F. G., SELLERS, P. J., and MARSHAK, A. L. The interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**, 33(2), 481– 486, 1995. <https://doi.org/10.1109/36.377948>
- MYNENI, R.B.; WILLIAMS, D.L. On the relationship between FAPAR and NDVI. **Remote Sensing Environ.** 49, 200–211, 1994. [https://doi.org/10.1016/0034-4257\(94\)90016-7](https://doi.org/10.1016/0034-4257(94)90016-7)
- NESTOLA, E., *et al.* Monitoring grassland seasonal carbon dynamics, by integrating MODIS NDVI, proximal optical sampling, and eddy covariance measurements. **Remote Sensing**, 8(3), 25, 2016. <https://doi.org/10.3390/rs8030260>
- NICHOL, C.J.; RASCHER, U.; MATSUBARA, S.; OSMOND, B. Assessing photosynthetic efficiency in an experimental mangrove canopy using remote sensing and chlorophyll fluorescence. **Trees**, 20, 9–15, 2006. <https://doi.org/10.3390/rs8030260>
- NICOLÁS-MARTÍN, C. *et al.* A global annual optimum tilt angle model for photovoltaic generation to use in the absence of local meteorological data. **Renewable Energy**, v. 161, p. 722-735, 2020. <https://doi.org/10.1016/j.renene.2020.07.098>
- NÖLSCHER, A., YAÑEZ-SERRANO, A., WOLFF, S. ET AL. Unexpected seasonality in quantity and composition of Amazon rainforest air reactivity. **Nat Commun**, v. 7, 10383, 2016. <https://doi.org/10.1038/ncomms10383>
- PAN, Y. *et al.* A Large and Persistent Carbon Sink in the World's Forests. **American Association for the Advancement of Science (AAAS)**. [s.l.], v. 333, n. 6045, p. 988-993, 14 jul. 2011.
- PAUSTIAN, K.; SIX, J.; ELLIOTT, E.T. & HUNT, H.W. Management options for reducing CO₂ emissions from agricultural soils. **Biogeochemistry**, 48:147-163, 2000. <https://doi.org/10.1023/A:1006271331703>

- PEÑUELAS, J., FILELLA, I., & GAMON, J. A. Assessment of photosynthetic radiation use efficiency with spectral reflectance. **The New Phytologist**, 131, 291-296, 1995. <https://doi.org/10.1111/j.1469-8137.1995.tb03064.x>
- PEÑUELAS, J. *et al.* Photochemical reflectance index as an indirect estimator of foliar isoprenoid emissions at the ecosystem level. **Nat Commun.** 4, 2604, 2013. <https://doi.org/10.1038/ncomms3604>
- PEÑUELAS, J.; BARTRONS, M.; LLUSIA, J.; FILELLA, I. Sensing the energetic status of plants and ecosystems. **Trends Plant Sci.** n. 20, 528–530, 2015. <https://doi.org/10.1016/j.tplants.2015.07.002>
- PEÑUELAS, J.; GARBULSKY, M.F.; FILELLA, I. Photochemical reflectance index (PRI) and remote sensing of plant CO₂ uptake. *New Phytol.* n. 191, 596–599, 2011. <https://doi.org/10.1111/j.1469-8137.2011.03791.x>
- PEÑUELAS, J.; LLUSIA, J. BVOCs: Plant defense against climate warming? **Trends Plant Sci.** v. 8, 105–109, 2003. [https://doi.org/10.1016/S1360-1385\(03\)00008-6](https://doi.org/10.1016/S1360-1385(03)00008-6)
- PHILLIPS, O. L. *et al.* Drought Sensitivity of the Amazon Rainforest. **Science**, 323 (5919), 1344–1347, 2009.
- PINHEIRO, E. S.; DURIGAN, G. Dinâmica espaço-temporal (1962-2006) das fitofisionomias em unidade de conservação do Cerrado no sudeste do Brasil. **Revista Brasileira de Botânica**, São Paulo, v. 32, n. 3, p. 441-454, 2009. <https://doi.org/10.1590/S0100-84042009000300005>
- QUÉRÉ, C. L. *et al.* Global Carbon Budget 2016. **Earth System Science Data**, [s.l.], v. 8, n. 2, p. 605-649, 2016.
- RAHMAN, A.F.; GAMON, J.A.; FUENTES, D.A.; ROBERTS, D.; PRENTISS, D.; QIU, H. Modeling CO₂ flux of boreal forests using narrow-band indices from AVIRIS imagery. **AVIRIS Workshop**, JPL/NASA, Pasadena, Califórnia, 2000.
- RAMANKUTTY, N., GIBBS, H. K., ACHARD, F., DEFRIES, R., FOLEY, J. A., & HOUGHTON, R. A. Challenges to estimating carbon emissions from tropical deforestation. **Global Change Biology**, 13(1), 51–66, 2007. <https://doi.org/10.1111/j.1365-2486.2006.01272.x>

RAVINDRANATH, N.H.; M. OSTWALD. **Carbon Inventory Methods**: Handbook for Greenhouse Gas Inventory, Carbon Mitigation and Roundwood Production Projects. 29. ed. Springer Science & Business Media, 306 p., 2007. <https://doi.org/10.1007/978-1-4020-6547-7>

RDS Uatumã. Reserva de Desenvolvimento Sustentável Uatumã – Plano de Manejo. Serie Técnica Planos de Gestão. **Secretaria de Estado do Meio Ambiente e Desenvolvimento Sustentável – SDS/CEUC**, Manaus, Amazonas. Vol. 1 e 2, 394pp, 2009. Disponível em: https://www.icmbio.gov.br/portal/images/stories/docs-planos-de-manejo/rebio_uatuma_pm.pdf. Acesso em 13 de julho de 2020.

RUIMY, A., JARVIS, P. G., BALDOCCHI, D. D., e SAUGIER, B. CO₂ fluxes over plant canopies and solar radiation: a review. **FAO**: N. p., 1995. Web. doi:10.1016/S0065-2504(08)60063-X. [https://doi.org/10.1016/S0065-2504\(08\)60063-X](https://doi.org/10.1016/S0065-2504(08)60063-X)

RUNNING S. W. *et al.* A global terrestrial monitoring network integrating tower fluxes, flask sampling, ecosystem modeling and EOS satellite data. **Remote Sen Environ**, 70:108–127, 1999. [https://doi.org/10.1016/S0034-4257\(99\)00061-9](https://doi.org/10.1016/S0034-4257(99)00061-9)

RUNNING, S W.; THORNTON, P E.; NEMANI, R; GLASSY, J M.. Global Terrestrial Gross and Net Primary Productivity from the Earth Observing System. **Methods In Ecosystem Science**, p. 44-57, 2000. https://doi.org/10.1007/978-1-4612-1224-9_4

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**, 54, 547, 2004. [https://doi.org/10.1641/0006-3568\(2004\)054\[0547:ACSMOG\]2.0.CO;2](https://doi.org/10.1641/0006-3568(2004)054[0547:ACSMOG]2.0.CO;2)

SANCHEZ-AZOFEIFA A. *et al.* Twenty-first century remote sensing technologies are revolutionizing the study of tropical forests. **Biotropica**, 49 604–19, 2017. <https://doi.org/10.1111/btp.12454>

SCHARPENSEEL, H.W. Preface to workshop 'Management of carbon in tropical soils under global change: Science, practice and policy'. **Geoderma**, 79:1-8, 1997. [https://doi.org/10.1016/S0016-7061\(97\)00035-9](https://doi.org/10.1016/S0016-7061(97)00035-9)

SCHMID, H.P. Source areas for scalars and scalar flux. **Bound-Layer Meteor.** 67:293–318, 1994. <https://doi.org/10.1007/BF00713146>

- SCURLOCK, J.M.O.; CRAMER, W.; OLSON, R.J.; PARTON, W.I.; PRINCE, S.D. Terrestrial NPP: Towards a consistent data set for global model evaluation. **Ecol. Applic.** 9(3):913—919; 1999. [https://doi.org/10.1890/1051-0761\(1999\)009\[0913:TNTACD\]2.0.CO;2](https://doi.org/10.1890/1051-0761(1999)009[0913:TNTACD]2.0.CO;2)
- SELLERS, P. J. *et al.* A. Modeling the Exchanges of Energy, Water and Carbon between Continents and the Atmosphere. **Science**, n. 275, 502–509, 1997. <https://doi.org/10.1126/science.275.5299.502>
- SHOWSTACK, R. Carbon dioxide tops 400 ppm at Mauna Loa, Hawaii. **Eos, Transactions American Geophysical Union**, n. 94 (21): 192-192, 2013. <https://doi.org/10.1002/2013EO210004>
- SHTILYANOVA, A; BELLOCCHI,; BORRAS, D; EZA, U; MARTIN, R; CARRÈRE, P. Kriging-based approach to predict missing air temperature data. **Computers And Electronics In Agriculture. Elsevier BV**. v. 142, p. 440-449, nov. 2017. <https://doi.org/10.1016/j.compag.2017.09.033>
- SHUKLA, J., NOBRE, C., SELLERS, P. Amazon deforestation and climate change. **Science**, n. 247 1322–1325, 1990. <https://doi.org/10.1126/science.247.4948.1322>
- SOLOMON, S. *et al.* **Contribution of Working Group I to the Fourth Assessment Report of the Intergovernmental Panel on Climate Change**. Cambridge University Press, Cambridge, United Kingdom and New York, 996 pp, 2007.
- SONG, C.; DANNENBERG, M.P.; HWANG, T. Optical remote sensing of terrestrial ecosystem primary productivity. **Prog. Phys. Geogr.** n. 37, 834–854, 2013. <https://doi.org/10.1177/0309133313507944>
- SOTTA, E.D. **Fluxo de CO₂ entre Solo e Atmosfera em Floresta Tropical Úmida da Amazônia Central**. 1998. 87 p. Dissertação (Mestrado em Ciências Biológicas) - Instituto Nacional de Pesquisas da Amazônia – INPA, Manaus, 1998. Disponível em: <https://ainfo.cnptia.embrapa.br/digital/bitstream/item/28955/1/Sotta-1998-DissMestrado.pdf>. Acesso em: 13 jul. 2020.
- SOUDANI, K. *et al.* Ground-based Network of NDVI measurements for tracking temporal dynamics of canopy structure and vegetation phenology in different

- biomes. **Remote sensing of environment**, v. 123, p. 234-245, 2012. <https://doi.org/10.1016/j.rse.2012.03.012>
- SOUZA, A., SANTOS, D. A. S., ARISTONE, F., KOVAC-ANDRIC, E., MATASOVIC, B., PIRES, J. C., IKEFUTI, P. V. Impacto de fatores meteorológicos sobre as concentrações de ozônio modelados por análise de séries temporais e métodos estatísticos multivariados. **Holos**, v. 5, n. 33, 2017. <https://doi.org/10.15628/holos.2017.5033>
- STOY, P. C. *et al.* (2009), Biosphere-atmosphere exchange of CO₂ in relation to climate: A cross-biome analysis across multiple time scales, **Biogeosciences**, 6(10), 2297–2312, 2009. <https://doi.org/10.5194/bg-6-2297-2009>
- THOMAS, M. D.; HILL, G. R. Photosynthesis under field conditions. In: FRANCK, J.; LOOMIS, W. E.(orgs.) **Photosynthesis in Plants: a monograph of the American Society of Plant Physiologists**. The Iowa State College Press, Ames, Iowa, 1949.
- TITTEBRAND, A.; SPANK, U.; BERNHOFER, C. H. Comparison of satellite and ground-based NDVI above different land-use types. **Theor. Appl. Climatol.** n. 98, p.171–86, 2009. <https://doi.org/10.1007/s00704-009-0103-3>
- TRAMONTANA, G. *et al.* Predicting carbon dioxide and energy fluxes across global FLUXNET sites with regression algorithms. **Biogeosciences**, [S.L.], v. 13, n. 14, p. 4291-4313, 29 jul. 2016.
- TUCKER, C.J. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sens. Environ.** 8 (2), 127–150, 1979. [https://doi.org/10.1016/0034-4257\(79\)90013-0](https://doi.org/10.1016/0034-4257(79)90013-0)
- VELOSO, H. P., RANGEL, A. L. R., LIMA, J. C. A. **Classificação da vegetação brasileira adaptada a um sistema universal**. Rio de Janeiro: IBGE, 1991.
- VRIELING, A.; LEEUW, J.; SAID, M.Y. Length of growing period over Africa: variability and trends from 30 years of NDVI time series. **Remote Sens.** 5 (2), 982–1000, 2013. <https://doi.org/10.3390/rs5020982>
- WERNER, L.; BISOGNIN, C.; MENEGOTTO, L. Previsão da umidade relativa do ar diária de Porto Alegre. **Cadernos Do IME – Série Estatística**, 39, 2018. Disponível em: <https://doi.org/10.12957/cadest.2017.31211>. Acesso em 03 de abril de 2020.

WILKS, D. S., 2006. **Statistical methods in the atmospheric sciences**. Academic press, 2011.

WILLMOTT, C. J.; MATSUURA, K. Advantages of the mean absolute error (MAE) over the root mean square error (RMSE) in assessing average model performance. **Climate research**, v. 30, p. 79-82, 2005. <https://doi.org/10.3354/cr030079>

WOFSY, S.C.; GOULDEN, M.L.; MUNGER, J.W.; FAN, S-M.; BAKWIN, P.S.; DAUBE, B.C.; BASSOW, S.L.; BAZZAZ, F.A.; Net exchange of CO₂ in a mid-latitude forest. **Science** **260**, p.1314–1317, 1993. <https://doi.org/10.1126/science.260.5112.1314>

WOHLFAHRT G.; PILLONI S.; HÖRTNAGL L.; HAMMERLE A. Estimating carbon dioxide fluxes from temperate mountain grasslands using broad-band vegetation indices. **Biogeosciences**. 2010;7(2):683-694. doi:10.5194/bg-7-683-2010. <https://doi.org/10.5194/bg-7-683-2010>

YAN W, HU Z, ZHAO Y, ZHANG X, FAN Y, SHI P, et al. (2015) Modeling Net Ecosystem Carbon Exchange of Alpine Grasslands with a Satellite-Driven Model. **PLoS ONE** 10(4): e0122486. <https://doi.org/10.1371/journal.pone.0122486>

YUAN, W.; CAI, W.; XIA, J.; CHEN, J.; LIU, S.; DONG, W.; MERBOLD, L.; LAW, B.; ARAIN, A.; BERINGER, J.; ET AL. Global comparison of light use efficiency models for simulating terrestrial vegetation gross primary production based on the LaThuile database. **Agriculture For Meteorology**. 2014, 192–193, 108–120. <https://doi.org/10.1016/j.agrformet.2014.03.007>

ZHANG, C.; FILELLA, I.; GARBULSKY, M.F.; PEÑUELAS, J. Affecting Factors and Recent Improvements of the Photochemical Reflectance Index (PRI) for Remotely Sensing Foliar, Canopy and Ecosystemic Radiation-Use Efficiencies. **Remote Sens**. 2016, 8, 677. <https://doi.org/10.3390/rs8090677>

ZHOU, X.; ZHU, Q.; TANG, S.; CHEN, X.; WU, M. Interception of PAR and relationship between FPAR and LAI in summer maize canopy. In: **Proceedings of the IEEE International Geoscience and Remote Sensing Symposium**. Toronto, ON, Canada, 24–28 June 2002; Volume 6, pp. 3252–3254.

ZHOU, Y.; ZHANG, L.; XIAO, J.; CHEN, S.; KATO, T.; ZHOU, G. A comparison of satellite-derived vegetation indexes for approximating gross primary productivity of

grasslands. Rangel. **Ecologic Management.** 2014, 67, 9–18.
<https://doi.org/10.2111/REM-D-13-00059.1>