

**UNIVERSIDADE ESTADUAL DO OESTE DO PARANÁ – CAMPUS DE CASCAVEL
CENTRO DE CIÊNCIAS EXATAS E TECNOLÓGICAS – CCET**

PÓS-GRADUAÇÃO EM ENGENHARIA AGRÍCOLA

**ESTIMATIVA DA PRODUÇÃO PRIMÁRIA BRUTA EM ÁREAS COM DIFERENTES TIPOS
DE COBERTURA DA TERRA**

CARLOS EDUARDO VIZZOTTO CATTANI

CASCAVEL – PARANÁ – BRASIL

SETEMBRO – 2022

CARLOS EDUARDO VIZZOTTO CATTANI

**ESTIMATIVA DA PRODUÇÃO PRIMÁRIA BRUTA EM ÁREAS COM DIFERENTES TIPOS
DE COBERTURA DA TERRA**

Tese apresentada ao programa de Pós-Graduação em Engenharia Agrícola, em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração em Sistemas Biológicos e Agroindustriais.

Orientador: Prof. Dr. Erivelto Mercante.

CASCADEL – PARANÁ – BRASIL

SETEMBRO – 2022

Ficha de identificação da obra elaborada através do Formulário de Geração Automática do Sistema de Bibliotecas da Unioeste.

Vizzotto Cattani, Carlos Eduardo
ESTIMATIVA DA PRODUÇÃO PRIMÁRIA BRUTA EM ÁREAS COM
DIFERENTES TIPOS DE COBERTURA DA TERRA / Carlos Eduardo
Vizzotto Cattani; orientador Erivelto Mercante. --
Cascavel, 2022.
84 p.

Tese (Doutorado Campus de Cascavel) -- Universidade
Estadual do Oeste do Paraná, Centro de Ciências Exatas e
Tecnológicas, Programa de Pós-Graduação em Engenharia Agrícola,
2022.

1. Dióxido de carbono. 2. Sensoriamento remoto. 3. SEBAL.
4. GEE. I. Mercante, Erivelto , orient. II. Título.

CARLOS EDUARDO VIZZOTTO CATTANI

PRODUTIVIDADE PRIMÁRIA BRUTA EM ÁREAS COM DIFERENTES TIPO S DE USO E COBERTURA DA TERRA

Tese apresentada ao Programa de Pós-Graduação em Engenharia Agrícola em cumprimento parcial aos requisitos para obtenção do título de Doutor em Engenharia Agrícola, área de concentração Sistemas Biológicos e Agroindustriais, linha de pesquisa Geoprocessamento, Estatística Espacial e Agricultura de Precisão, APROVADO(A) pela seguinte banca examinadora:



Orientador(a) - Erivelto Mercante

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)



Victor Hugo Rohden Prudente

Newe Seguros S. A.



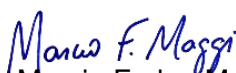
Marcus Metri Correa

Universidade Federal Rural de Pernambuco (UFRPE)



Maritane Prior

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)



Marcio Furlan Maggi

Universidade Estadual do Oeste do Paraná - Campus de Cascavel (UNIOESTE)

Cascavel, 14 de setembro de 2022.

BIOGRAFIA RESUMIDA

Carlos Eduardo Vizzotto Cattani, nascido em 17/11/1990, natural da cidade Cascavel, Paraná, concluiu o curso de graduação em Engenharia Agrícola, pela Universidade Estadual do Oeste do Paraná – UNIOESTE, no ano de 2015. No ano de 2016, ingressou no Programa de Pós-Graduação em Engenharia Agrícola – Sistemas Biológicos e Agroindustriais, sob orientação do Prof. Dr. Erivelto Mercante, para cursar mestrado na área de agricultura e geoprocessamento. Em 2018, ingressou no doutorado sob mesma orientação. Atualmente, é pesquisador associado na empresa Corteva Agriscience.

“ Nada como um dia após o outro dia”

Racionais MC's

Dedico a todas as pessoas que de alguma maneira contribuíram para a conclusão desse trabalho.

A minha família, que sempre me apoiou e acreditou e incentivou ao estudo.

Ao meu falecido avô e meu falecido pai, que mesmo não estando presentes nessa conquista deram força e sentido em minha caminhada.

Ao meu orientador e amigo Erivelto Mercante, pois além de um profissional extraordinário é um amigo que levarei para vida toda.

Ao colegas de laboratório que além da amizade para a vida sempre contribuíram para desenvolvimento da pesquisa.

AGRADECIMENTOS

Ao meu orientador Erivelto Mercante, À Universidade Estadual do Oeste do Paraná e a todos professores que fizeram parte da minha formação;

Ao Programa de Pós-Graduação em Engenharia Agrícola – PGEAGRI, aos seus docentes, pelos conhecimentos e ensinamentos compartilhados;

Ao Parque Tecnológico de Itaipu – PTI e ao CAPES - Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, pelo apoio e pela concessão da bolsa de estudos;

Ao Laboratório de geoprocessamento – GEOLAB, pelos momentos de aprendizado e de humor, vividos a cada dia, vai deixar saudades.

A todos os meus amigos e colegas, em especial o pessoal do GEOLAB, que me ajudaram nesta etapa e me acompanharam a campo e em laboratório.

RESUMO

Cattani, Carlos Eduardo Vizzotto, **Estimativa da produção primária bruta em áreas com diferentes tipos de cobertura da terra**. Orientador: Erivelto Mercante, 2022. 84 F. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2022.

O sequestro de carbono por biomas terrestres desempenha um papel significativo no ciclo global do carbono para mitigar o aumento de CO₂ atmosférico e as consequências por ele causadas nas mudanças climáticas. A Produção Primária Bruta (PPB) é um parâmetro biofísico de qualquer ecossistema e pode auxiliar no entendimento da dinâmica espacial e temporal dos fluxos de carbono. O uso de técnicas de sensoriamento remoto orbital tem se mostrado uma ferramenta valiosa, pois possibilita uma visão panorâmica, em diferentes escalas, com elevada precisão e menor custo operacional em relação às técnicas tradicionais de monitoramento do uso e cobertura da terra e ciclo do carbono. Embora pesquisas tenham obtido relativo êxito na utilização de sensores remotos orbitais para o monitoramento do uso e cobertura da terra e quantificação da PPB, o principal desafio está em desenvolver uma metodologia sistemática, ágil que facilite a identificação do uso e cobertura do solo e obtenção de valores de PPB. Uma alternativa para contornar e solucionar estas demandas é a plataforma *Google Earth Engine* (GEE), repositório de dados geográficos em nuvem que possibilita a análise de dados ambientais em grande escala e com recursos computacionais amplos, pois utiliza os servidores Google para processamento e armazenamento. Portanto, o objetivo do artigo 1 foi desenvolver uma metodologia sistematizada para classificação de diferentes tipos de uso e cobertura da terra, com imagens de Landsat 8 na plataforma GEE, e o objetivo do artigo 2 foi avaliar a metodologia para estimar a PPB por técnicas de sensoriamento remoto, a partir de imagens do sensor Landsat 8 para diferentes tipos de uso e cobertura da terra. A metodologia de obtenção baseia-se no modelo de estimativa da radiação fotossinteticamente ativa absorvida – RFFA pela vegetação, combinado ao modelo de eficiência do uso da luz e foi implementada na plataforma GEE.

Palavras-chave: Dióxido de carbono, Sensoriamento remoto, SEBAL, GEE

ABSTRACT

Cattani, Carlos Eduardo Vizzotto, **Estimation of gross primary production in lands with different cover crops areas**. Orientador: Erivelto Mercante, 2022. 84 F. Tese (Doutorado em Engenharia Agrícola) - Universidade Estadual do Oeste do Paraná, Cascavel – Paraná, 2022.

Carbon sequestration by terrestrial biomes plays a significant role on the global carbon cycle to mitigate the atmospheric CO₂ increase and its consequences on climate changing. Gross Primary Production (GPP) is a biophysical parameter of any ecosystem and can assist understanding the spatial and temporal dynamics of carbon flows. The use of orbital remote sensing techniques has been a valuable tool because it allows a panoramic view, at different scales, with high precision and lower operating cost when compared to the traditional techniques of monitoring land use and carbon cycle cover. Although several researches have been successful in using remote orbital sensors to monitor land use and land cover and quantify GPP, the main challenge is developing a systematic and able methodology that makes it easy to identify land use, land cover and to obtain GPP values. An alternative to solve these demands is the Google Earth Engine (GEE) platform, a geographic spatial data repository that enables large-scale environmental data analysis with broad computational capabilities as it uses Google servers for processing and storage. Thus, paper 1 aims at developing a systematic methodology to classify different kinds of land use and land cover with Landsat 8 images on GEE platform, while paper 2 aims at evaluating the methodology to estimate GPP by remote sensing techniques, based on Landsat 8 sensor images for different kinds of land use and land cover. This methodology is based on the Estimating Absorbed Photosynthetically Active Radiation model - A PAR - by vegetation, associated with the light use efficiency model and was implemented on GEE platform.

Keywords: Carbon dioxide, Remote Sensing, SEBAL, GEE

SUMÁRIO

1	INTRODUÇÃO	14
2	OBJETIVOS	16
2.1	Objetivo geral	16
2.2	Objetivos específicos	16
3	REVISÃO BIBLIOGRÁFICA	17
3.1	Visão geral do ciclo do carbono e técnicas de estimativa de fluxos de carbono por meio sensoriamento remoto	17
3.1.1	Produção primária bruta (PPB)	18
3.2	Sensoriamento Remoto	19
3.2.1	Sensores OLI/TIRS e Sensor MODIS	21
3.3	Estimativa de PPB MODIS	22
3.4	Estimativa de PPB OLI/TIRS	23
3.4.1	Variáveis derivadas do modelo SEBAL	24
3.5	Google Earth Engine (GEE)	29
4	REFERÊNCIAS	31
5	METODOLOGIA GERAL	36
6	ARTIGOS	37
6.1	Mapeamento do uso e cobertura da terra utilizando métricas espectro-temporais no Google Earth Engine	37
6.1.1	INTRODUÇÃO	38
6.1.2	MATERIAL E MÉTODOS	40
6.1.3	RESULTADOS E DISCUSSÃO	46
6.1.4	CONCLUSÃO	52
6.1.5	REFERÊNCIAS	53
6.2	Artigo 2: Dinâmica temporal da Produção Primaria Bruta para município de Cascavel-PR utilizando GEE	56
6.2.1	INTRODUÇÃO	57
6.2.2	MATERIAL E MÉTODOS	58
6.2.3	RESULTADOS E DISCUSSÃO	65
6.2.4	CONCLUSÃO	73
6.2.5	REFERÊNCIAS	74
7	ANEXO I	77
7.1	Cálculos para obtenção do saldo de radiação (Rn)	77
7.1.1	Calibração radiometria	77

7.1.2	Refletância em função do ângulo solar	77
7.1.3	Albedo no topo da atmosfera e na superfície.....	77
7.1.4	Índices de vegetação	78
7.1.5	Emissividade	79
7.1.6	Temperatura na superfície	79
7.1.7	Radiação de onda longa emitida pela superfície	79
7.1.8	Radiação de onda curta incidente.....	80
7.1.9	Radiação de onda longa incidente	80
7.2	Cálculos para obtenção do Fluxo de calor sensível (H)	80
7.2.1	Resistência aerodinâmica	80
7.2.2	Diferença de temperatura.....	82
7.2.3	Comprimento de Monin-Obukhov	83
7.3	Rotinas GEE	86
7.3.1	Classificação artigo 1	86
7.3.2	GPP MODIS.....	86
7.3.3	GPP LANDSAT 8	86

LISTA DE TABELAS

Tabela 1. Especificações e uso potencial das bandas Landsat OLI/TIRS.....	22
Tabela 2. Matriz de erro e acurácias de produtor e usuário para o Caso 1.....	48
Tabela 3. Matriz de erro e acurácias de produtor e usuário para o Caso 2.....	48
Tabela 4. Matriz de erro e acurácias de produtor e usuário para o Caso 3.....	49
Tabela 5. Matriz de erro e acurácias de produtor e usuário para o Caso 4.....	50
Tabela 6. Matriz de erro e acurácias de produtor e usuário para o Caso 5.....	51
Tabela 7. Matriz de erro e acurácias de produtor e usuário para o Caso 6.....	51
Tabela 8. Índices de acurácias gerados para os seis casos abordados.....	51
Tabela 9. Teste Z para comparação entre os seis casos de classificação.....	52
Tabela 10. Calendário agrícola do Paraná para Soja, Milho 1 ^a e 2 ^a safras e culturas de inverno	60
Tabela 11. Datas das imagens OLI/TIRS, valores de temperatura média (T_{med}), temperatura média no mês de maior NDVI (T_{opt}) e radiação solar global	62
Tabela 12. Resumo estatístico da <i>Performance</i> dos modelos PPB_{L8} vs PPB_{MOD} , para cada data observada	72

LISTA DE FIGURAS

Figura 1. Fluxo e estoques de carbono quantificados usando sensoriamento remoto, os fluxos de C estimados por sensoriamento remoto incluem produção primária bruta (PPB), respiração do ecossistema (R), produção primária líquida (PPL).	17
Figura 2. Curvas espectrais de diferentes alvos.	20
Figura 3. Fluxograma das etapas computacionais para obtenção de R_s , G, H, LE e FE.	25
Figura 4. Fluxograma da metodologia de cálculo do saldo de radiação.	26
Figura 5. Fluxograma da metodologia de cálculo do fluxo de calor sensível (H).	29
Figura 6. Ambiente de desenvolvimento do Google Earth Engine.	30
Figura 7. Fluxograma das etapas de desenvolvimento da tese.	36
Figura 8. Localização da área de estudo – Oeste do paraná.	40
Figura 9. Amostras coletadas na área de estudo.	42
Figura 10. Mapa de uso e cobertura do solo da AMOP, (1) Mapa de cobertura para o caso 1, (2) Mapa de cobertura para o caso 2, (3) Mapa de cobertura para o caso 3, (4) Mapa de cobertura para o caso 4, (5) Mapa de cobertura para o caso 5 e (6) Mapa de cobertura para o caso 6.	46
Figura 11. Espacialização de uso e cobertura do solo. A – Área de pastagens 1. B – Áreas de pastagem 2, C – Áreas de pastagem 3	47
Figura 12. Estação meteorológica da área de estudo	59
Figura 13. Pontos amostrais de classes. A – Imagens do google Earth com exemplos de amostragem; B – Imagem com pixels puros para PPB_{L8} ; C Imagem com pixels puros para PPB_{MOD}	64
Figura 14. Gráfico de precipitação e temperatura para as safras 2019/2020 e 2020/2021.	65
Figura 15. Valores médios de PPB_{L8} e PPB_{mod} para diferentes datas de observação.	66
Figura 16. Produção primária bruta Landsat 8 (PPB_{L8}) para o município de Cascavel-PR, para os dias (1) 30/09/19, (2) 20/01/2020, (3) 24/03/2020, (4) 09/04/2020, (5) 25/04/2020, (6) 27/05/2020, (7) 12/06/2020, (8) 31/08/2020, (9) 02/10/2020, (10) 07/02/2021, (11) 11/03/2021, (12) 28/04/2021, (13) 01/07/2021, (14) 08/02/2021, (15) 18/08/2021.	68

Figura 17. Produção primária bruta MODIS (PPB_{MOD}), para os dias (1) 30/09/19, (2) 01/01/2020, (3) 21/03/2020, (4) 06/04/2020, (5) 22/04/2020, (6) 24/05/2020, (7) 09/06/2020, (8) 28/08/2020, (9) 29/09/2020, (10) 10/02/2021, (11) 14/03/2021, (12) 01/05/2021, (13) 04/07/2021, (14) 08/05/2021, (15) 21/08/2021. 69

Figura 18. Dispersão de PPB_{L8} e PPB_{MOD} . (A) Todos os pontos e classes coletados nas 15 imagens observadas, (B) todos os pontos da classe “Agricultura” coletados nas 15 imagens observadas, (C) todos os pontos da classe “Mata” coletados nas 15 imagens observadas, (D) todos os pontos da classe “Pastagem” coletados nas 15 imagens observadas..... 70

Figura 19. Pontos amostrados em diferentes tipos de alvos. A – (1 - amostras de pastagem imagens alta resolução, 2 – amostras pastagem imagens PPB_{MOD} , 3 – amostras pastagem imagens PPB_{L8}), B – (1 - amostras de agricultura imagens alta resolução, 2 – amostras agricultura imagens PPB_{MOD} , 3 – amostras agricultura imagens PPB_{L8}), C – (1 - amostras de mata imagens alta resolução, 2 – amostras mata imagens PPB_{MOD} , 3 – amostras mata imagens PPB_{L8}). 71

1 INTRODUÇÃO

Alterações das condições climáticas globais vêm causando mudanças nos regimes de precipitação, na temperatura do ar e na concentração de gás carbônico em diversas regiões do Planeta. Dados temporais mais concisos relatam que, no período dos anos de 1880 a 2012, ocorreu um acréscimo de 0,85 °C na temperatura, atribuído principalmente ao aumento da emissão antrópica de gás carbônico (CO₂) e outros Gases de Efeito Estufa.

O aumento da concentração de gases na atmosfera e o aumento da temperatura da superfície terrestre resultante podem causar respostas adversas em ecossistemas, portanto, existe um interesse global na fixação de dióxido de carbono como medida para conter as alterações climáticas em nível regional e global.

A taxa total em que produtores de um ecossistema transformam a energia luminosa em energia química, na forma de biomassa através da fotossíntese, é denominada Produção Primária Bruta (PPB). O conhecimento desta taxa é essencial no contexto das mudanças climáticas, tendo em vista que a PPB está diretamente relacionada ao carbono efetivamente extraído da atmosfera pelos diferentes ecossistemas terrestres.

Existem estudos de caso realizados que buscam compreender a dinâmica da PPB em diferentes ecossistemas e sua atuação no balanço global de carbono. São utilizados vários métodos para a estimativa do fluxo de carbono. O método de covariância turbulenta é uma técnica muito empregada que utiliza torres meteorológicas de fluxo. Esta técnica analisa os fluxos de carbono e possibilita o entendimento dos fatores atmosféricos e climáticos que regulam a PPB. No entanto, em alguns casos, esta técnica pode ser impraticável por seus elevados custos operacionais e pouca representatividade para locais heterogêneos.

Neste sentido, o sensoriamento remoto, vinculado a dados de campo, é uma ferramenta viável para a obtenção de informações que permitem estudos sobre a troca de carbono no ecossistema. Alguns sensores orbitais podem ser utilizados para a determinação da PPB, dentre eles o sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) que possui o produto MOD17A2 que estima a PPB de 8 em 8 dias com resolução espacial de 1Km e 500m. Outra possibilidade são os sensores da série de satélites Landsat (*Land Remote Sensing Satellite*), que podem estimar a PPB através do desenvolvimento de modelos, e algoritmos associados a técnicas de geoprocessamento e sensoriamento remoto, com ampla cobertura espacial e continuidade no tempo. Tais sensores destacam-se por detectarem variações espaço-temporais de longo prazo da cobertura da terra, graças à sua grande disponibilidade de dados, cobertura global e continuidade ao longo de 40 anos.

Assim, vale ressaltar que existem poucos estudos que avaliam a eficácia do sensor Landsat 8 para estimar PPB para distintos uso e cobertura da terra. Desta maneira, ressalta-se a importância de propor um algoritmo para estimativa da Produção Primária Bruta a partir de imagens Landsat 8 OLI/TIRS e analisar os padrões espaço-temporais em diferentes tipos de vegetação.

2 OBJETIVOS

2.1 Objetivo geral

Quantificar e comparar, a partir de técnicas de sensoriamento remoto, a Produção Primária Bruta (PPB) para diferentes usos e cobertura da terra em quatro safras agrícolas no município de Cascavel-PR.

2.2 Objetivos específicos

- Gerar um modelo associado a técnicas de sensoriamento remoto para estimar a PPB, aplicadas aos sensores OLI e TIRS (PPB_{L8}).
- Utilizar a plataforma do GEE juntamente com técnicas de mineração de dados *e-machine learning* para mapear o uso e cobertura da terra em quatro safras agrícolas no Oeste do Paraná.
- Verificar a acurácia do modelo PPB_{L8} comparando com o modelo de PPB oriundo dos dados do produto MOD17A2.
- Analisar e gerar mapas atualizados e PPB para a região de estudo, e observar a dinâmica de PPB da vegetação em dois anos de safra.

3 REVISÃO BIBLIOGRÁFICA

3.1 Visão geral do ciclo do carbono e técnicas de estimativa de fluxos de carbono por meio sensoriamento remoto

Os ecossistemas terrestres “inspiram” o dióxido de carbono (CO_2) por fotossíntese e liberam carbono (C) na atmosfera através da respiração, portanto, desempenham um papel importante no ciclo C global e no clima da Terra (SCHIMMEL et al., 1995).

A Produção Primária Bruta (PPB) juntamente com a respiração (R) são os principais processos que controlam as trocas de CO_2 entre os ecossistemas terrestres e a atmosfera, e proporcionam a capacidade parcial de compensação das emissões de CO_2 . A PPB é definida como a quantidade de carbono fixada pelos ecossistemas terrestres por fotossíntese. E é considerada a base para produção de vegetal, portanto, tem importante papel em relação às questões econômicas e sociais. Uma fração substancial do carbono fixado pela PPB é perdida pela respiração do ecossistema (R), o que inclui a respiração de organismos autotróficos e heterotróficos. O restante da PPB é destinado à produção primária líquida (PPL) da biomassa estrutural dos caules, folhas e frutas (XIAO et al., 2019).




Figura 1. Fluxos de C estimados incluem produção primária bruta (PPB), respiração do ecossistema (R), produção primária líquida (PPL).

Fonte: AUTOR

A dinâmica do fluxo de C entre os biomas terrestres vem recebendo atenção especial da comunidade acadêmica durante as últimas décadas, pois a transferência de carbono dos reservatórios terrestres para a atmosfera, a partir de atividades

antropogênicas, tais como a geração de energia advinda de combustíveis fósseis e do desmatamento, vem provocando aumento nos níveis de gases de efeito estufa (GEE) na atmosfera (IPCC, 2014). A elevação nos níveis de GEE podem causar mudanças climáticas globais, principalmente no aumento gradual da temperatura do ar, tendo em vista que, apesar do depósito de C atmosférico ser pequeno em relação aos demais, ele é muito ativo e vulnerável à perturbação antrópica.

Neste sentido, o sensoriamento remoto tem sido amplamente utilizado para estudar o ciclo C terrestre, pois quantifica os fluxos e os estoques do ecossistema C (RUNNING et al., 2004; SAATCHI et al., 2011; XIAO et al., 2014) e examina os impactos das mudanças globais na dinâmica C (NEMANI et al., 2003; SMITH et al., 2016; LI et al., 2018). Isto ocorreu pela disponibilidade de satélites para observação da superfície terrestre desde a década de 1970, particularmente, desde o início da década de 1980. E possibilitou avaliar a magnitude, os padrões espaciais, a variabilidade e as tendências da dinâmica do carbono no ecossistema. Métodos de estimativa de fluxo de C que empregam o SR têm a vantagem de fornecer estimativas de PPB para macro escalas, onde os métodos no nível do terreno não são viáveis a um baixo custo e com maior operacionalidade (GOUGH, 2012).

3.1.1 Produção primária bruta (PPB)

Existem diversos métodos destinados à quantificação de fluxos de carbono ou carbono estocado na vegetação (XIAO et al., 2019), dentre os quais destaca-se a técnica da covariância de vórtices turbulentos, muito empregada para quantificar o fluxo de CO₂ em diversos ecossistemas florestais (BEER et al., 2010; CABRAL et al., 2011).

Esta técnica é bem aceita pela comunidade científica, porém, seu custo e operacionalidade muitas vezes apresentam-se onerosos aos pesquisadores. Outra questão que restringe o uso de tal técnica é a sua representatividade, pois cobre apenas alguns quilômetros quadrados, salvo nos casos de áreas extensas e homogêneas. Em contrapartida, os métodos que empregam o sensoriamento remoto apresentam-se como grande vantagem à ampla cobertura espacial, a um baixo custo e maior operacionalidade. Muitas dessas técnicas se fundamentam no conceito de eficiência de uso da luz – LUE (do inglês *Light Use Efficiency*) proposto por Monteith (1972). A sua aplicação prática resultou da contribuição dada por Field et al. (1995) e, mais recentemente, Bastiaanssen e Ali (2003) empregaram o conceito de fração evaporativa com o objetivo de contabilizar o fator água no processo de fixação do carbono por parte da vegetação.

Muitos dos modelos de PPB baseados em sensoriamento remoto se fundamentam na relação entre a eficiência de uso da luz - ϵ , a radiação fotossinteticamente ativa absorvida (RFAA) (Equação (1)).

$$PPB = RFAA * \epsilon \quad (1)$$

Um dos maiores desafios no uso de tais modelos consiste na obtenção dos valores de " ϵ " em áreas extensas, em virtude de sua dependência em relação aos fatores ambientais e da própria vegetação. Uma das soluções consiste em relacionar " ϵ " em função do seu valor máximo - ϵ_{\max} (FIELD et al., 1995; BASTIAANSEN e ALI, 2003).

A estimativa da RFAA é utilizada para determinar a eficiência do uso da radiação pelas plantas e a modelagem deste parâmetro informa o crescimento da vegetação. A RFAA pode ser estimada como o produto entre a RFA (Radiação fotossinteticamente ativa), pela Fração da Radiação Fotossinteticamente Ativa (FRFA). Sendo, $RFAA = RFA \times FRFA$. A FRFA depende de parâmetros variáveis como estrutura do dossel, índice de área foliar (IAF), quantidade de folhagem, ângulo zenital solar, proporção de radiação difusa e reflectância do solo.

Os sensores orbitais mais utilizados, empregados na determinação da PPB a partir do modelo LUE são o *Moderate Resolution Imaging Spectroradiometer* – MODIS (ALMEIDA, 2016), o *Advanced Very High Resolution Radiometer* – AVHRR (KITAMOTO et al., 2007) e o TM/ETM+ da série Landsat (GITELSON et al., 2008). Porém, o lançamento do sensor *Operational Terra Imager* (OLI/TIRS) do satélite Landsat 8 em 2013, surge como uma nova opção para o cômputo da PPB para monitoramento e observações futuras (AHONGSHANGBAM et al., 2016) e sua resolução espacial pode fornecer informações mais detalhadas e significativas das relações do fluxo de PPB e alterações no uso da terra.

3.2 Sensoriamento Remoto

Jensen (2009) define a técnica de SR como a medição ou aquisição de informações de alguma propriedade de um objeto ou fenômeno, por um dispositivo de registro que não esteja em contato físico com o objeto ou fenômeno em estudo.

Os autores Ponzoni, Simabukuro e Kuplich (2012) destacam que, assim como os conceitos de distância, informação e contato físico são importantes, existem outros conceitos que permitem ao usuário uma melhor compreensão da técnica. Dentre

esses conceitos destacam-se aqueles intrínsecos ao processo de interação entre a radiação eletromagnética (REM) e os alvos dos quais pretende-se extrair informação.

Diferentes propriedades bio-físico-químicas dos alvos da superfície terrestre (solo, vegetação, corpos d'água e outros) fazem com que porções específicas do espectro eletromagnético sejam absorvidas ou refletidas, em diferentes intensidades. Assim, é permitido identificar um padrão de reflectância característico da REM em diferentes comprimentos de ondas. Ao se conhecer qual comprimento de onda é absorvido por um alvo e a intensidade de sua respectiva reflectância, torna-se possível analisar uma imagem de sensoriamento remoto bem como obter interpretações quanto ao tipo de alvo observado (JENSEN, 2009).

Este comportamento espectral dos alvos é comumente denominado “espectro de reflectância característico”. Ele é composto por um conjunto de valores específicos de reflectância dentro do espectro eletromagnético (Figura 2), fatores que permitem ao sensoriamento remoto distinguir diversos tipos de alvos observados.




Figura 2. Curvas espectrais de diferentes alvos.
Fonte: FLORENZANO (2002).

Em relação ao SR orbital, a REM provinda do sol é a energia geralmente utilizada ao se estudar a superfície terrestre (ABREU; COUTINHO, 2014). Após ser emitida pela fonte de energia, ela passa por uma série de processos, propaga-se pela atmosfera, interage com os alvos na superfície terrestre, é refletida através da atmosfera, captada e registrada pelos equipamentos denominados de sensores orbitais (LILLESAND; KIEFER; CHIPMAN, 2015).

No SR, os sensores orbitais são embarcados em plataformas chamadas de satélites e os dados são registrados em imagens (LILLESAND; KIEFER; CHIPMAN, 2015). As características dos sensores orbitais dependem de quatro resoluções: (a) resolução espacial, que se refere ao tamanho do pixel da imagem gerada; (b) resolução radiométrica, que se refere à intensidade de radiância de cada pixel que o

sensor é capaz de mensurar, representado por valores numéricos ou nível de cinza; (c) resolução espectral, que se refere ao número de faixas espectrais do sensor; e (d) a resolução temporal, que corresponde ao tempo de revisita do satélite na mesma área (MENESES et al., 2012).

O uso e a cobertura da terra estão entre as plataformas com amplo histórico de utilização para monitoramento nas séries históricas dos satélites Landsat, com mais de 40 anos de imageamento da superfície terrestre. Os principais satélites da série Landsat utilizados em pesquisas são o Landsat 5, o Landsat 7, e recentemente o Landsat 8. Atualmente, o Landsat 8 disponibiliza imagens dos Sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*), em órbita desde 2013 (USGS, 2019).

Outro importante sensor orbital de monitoramento terrestre é o MODIS (*Moderate Resolution Imaging Spectroradiometer*), a bordo satélites Terra e Aqua, lançados pela NASA (*National Aeronautics and Space Administration*) em 18 de dezembro de 1999 e 4 de maio de 2002, respectivamente. Existem diversos produtos derivados deste sensor, dentre eles refletância da superfície, temperatura e emissividade da superfície, cobertura de nuvem, Albedo, IVs (índices de vegetação), IAF (índices de área foliar), entre outros (JUSTICE et al., 2002), características que o tornam amplamente utilizado para observação e detecção de mudanças na superfície terrestre.

3.2.1 Sensores OLI/TIRS e Sensor MODIS

O satélite Landsat 8, lançado em 11 de fevereiro de 2013, é resultado de uma parceria entre a *National Aeronautics and Space Administration* (NASA) e o *Department of the interior U.S. Geological Survey* (USGS). Este satélite possui dois sensores: o sensor *Operacional Terra Imager* (OLI), 9 bandas espectrais de ondas curtas, com resolução espacial de 30 metros, com exceção da banda pancromática de 15 metros, e o *Thermal Infrared Sensor* (TIRS) capta dados para duas bandas térmicas, com resolução espacial de 100 metros, ambos os sensores possuem resolução radiométrica de 16 bits e tempo de revisita de 16 dias, (Tabela 1). Cada cena cobre aproximadamente 190 km ao Norte-Sul e 180 km Leste-Oeste (USGS, 2019).

Tabela 1. Especificações e uso potencial das bandas Landsat OLI/TIRS

Banda	Comprimento de onda (μm)	Resolução (m)
Banda 1 – Aerossol/Costeiro	0,43 – 0,45	30
Banda 2 - Azul	0,45 – 0,51	30
Banda 3 – Verde	0,53 – 0,59	30
Banda 4 – Vermelho	0,63 – 0,67	30
Banda 5 – Infravermelho Próximo (NIR)	0,85 – 0,87	30
Banda 6 – Infravermelho de ondas Curtas (SWIR) 1	1,56 – 1,65	30
Banda 7 - Infravermelho de ondas Curtas (SWIR) 2	2,10 – 2,29	30
Banda 8 - Pancromática	0,50 – 0,67	15
Banda 9 – Cirrus	1,36 – 1,38	30
Banda 10 – Sensor Infravermelho Termal -TIRS 1	10,60 – 11,19	100
Banda11 –Sensor Infravermelho Termal -TIRS 2	11,50 – 12,51	100

Fonte: USGS (2019).

O sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) está a bordo dos satélites Terra e Aqua, lançados pela NASA (*National Aeronautics and Space Administration*) em 18 de dezembro de 1999 e 4 de maio de 2002, respectivamente. O satélite Terra possui órbita em torno da Terra com direção de Norte a Sul, passando sobre a linha do Equador na parte da manhã. Já o satélite Aqua passa na direção de Norte a Sul, passando sobre a linha do Equador na parte da tarde (JUSTICE et al., 2002).

Esses satélites fazem parte do projeto EOS (*Earth Observing System*), formado por diversos países para o estudo dos processos de mudança globais. A resolução temporal dos satélites Terra e Aqua permite que dentro de um a dois dias seja feita a cobertura de toda a superfície da terra, registrando dados espectrais em 36 intervalos de comprimentos de ondas. Destas bandas, duas possuem resolução espacial de 250 m, outras cinco possuem resolução de 500 metros e as demais possuem resolução de 1000 metros. A resolução radiométrica é de 12 bits e cobre o intervalo do espectro eletromagnético de 0,4 a 14,4 μm (JUSTICE et al., 2002).

3.3 Estimativa de PPB MODIS

Dentre os diversos produtos produzidos pelo MODIS, a NASA fornece o produto MOD17A2 que estima a PPB. Tem como base o conceito de eficiência do uso da luz que pode ser utilizado em modelos para calcular o saldo de energia terrestre, carbono e biogeoquímica da vegetação (RUNNING, 2015).

O algoritmo para o cálculo da PPB a partir desse produto é baseado na pesquisa de Monteith (1972) que sugere que a produtividade da vegetação está

linearmente relacionada à quantidade de radiação solar absorvida pela vegetação, ou seja, dados de RFAA do sensor MODIS.

A interpretação da RFAA para uma estimativa de produtividade real é realizada pelo fator de conversão da eficiência do uso da luz (ϵ), que é um parâmetro tabelado que varia com os diferentes tipos de vegetação, e dados meteorológicos de superfície (RFA, déficit de pressão de vapor, temperatura).

3.4 Estimativa de PPB OLI/TIRS

De acordo com a metodologia proposta por Silva et al. (2013), a determinação de PPB determinação por sensoriamento remoto pode ser realizada combinando o modelo de estimativa da Radiação Fotossinteticamente Ativa Absorvida - RFAA pela vegetação, proposto por Monteith (1972), com o modelo de eficiência de uso da luz na fotossíntese de Field et al. (1995), adaptado por Bastiaanssen e Ali (2003). Ambos os modelos sugerem a aplicação da fração evaporativa (FE), definida pela razão entre o fluxo de calor latente e o saldo de radiação para determinar as necessidades hídricas e a evapotranspiração.

A FE pode ser obtida através do cálculo do Balanço de Energia calculado através do SEBAL (*Surface Energy Balance Algorithms for Land*). A radiação fotossinteticamente ativa – RFA, corresponde à fração da radiação solar, situada entre 400 nm e 700 nm, e na ausência de medições da mesma, pode-se estimá-la em função da radiação solar global diária – R_{s24h} , fornecida pela estação meteorológica (SILVA et al., 2012).

Abaixo segue a sequência de equações a serem empregadas para a determinação da PPB, baseada no modelo proposto por Monteith (1972):

$$PPB = RFAA * \epsilon$$

2)

Onde, RFAA é a radiação fotossinteticamente ativa absorvida – RFAA ($W m^{-2}$) pela vegetação, e “ ϵ ” ($Kg C MJ^{-1}$) é a eficiência do uso de luz da vegetação. Os elementos dessa equação serão explicados separadamente nas subseções seguintes.

O cálculo da radiação fotossinteticamente ativa absorvida – RFAA pode ser desenvolvido em função do Índice de Vegetação da Diferença Normalizada - NDVI:

$$\text{RFAA} = \text{RFA} * (-0,161 + 1,257 \text{ NDVI}) \quad 3)$$

A radiação fotosinteticamente ativa - RFA pode ser estimada em função da radiação solar global diária, de acordo com Bastiaanssen e Ali (2003), através da equação:

$$\text{RFA} = 0,48 * R_{s24h} \quad 4)$$

R_{s24h} é a radiação solar global diária (W m^{-2}) e deve ser obtida a partir de estações meteorológicas.

A eficiência do uso de luz (ϵ) (g C), embora dependa de elementos da comunidade vegetal, foi quantificada pelo modelo de Field et al., (1995), modificado por Bastiaanssen e Ali (2003):

$$\epsilon = \epsilon' * T_1 * T_2 * \text{FE} \quad 5)$$

em que, ϵ' representa a eficiência máxima de uso da luz pela vegetação (considerada na pesquisa igual a $2,15 \text{ Kg C MJ}^{-1}$); FE é a fração evaporativa e T_1 e T_2 referem-se à contribuição da temperatura na eficiência de uso da luz pelas plantas, e podem ser calculadas por:

$$T1 = 0,8 + 0,02 - 0,0005 T_{opt}^2 \quad 6)$$

$$T2 = \frac{1}{1 + \exp(0,2T_{opt} - 1 - T_{dia})} * \frac{1}{1 + \exp(0,3(-T_{opt} - 10 - T_{dia}))} \quad 7)$$

Em que, T_{opt} é a temperatura média do ar no mês de maior NDVI ($^{\circ}\text{C}$) e T_{dia} é a temperatura média diária do ar ($^{\circ}\text{C}$).

3.4.1 Variáveis derivadas do modelo SEBAL

As variáveis saldo de radiação (Rs), fluxo de calor no solo (G), fluxo de calor sensível (H), fluxo de calor latente (LE) e fração evaporativa (FE) podem ser obtidas

por algoritmo SEBAL (*Surface Energy Balance Algorithm for Land*) proposto por Bastiaanssen et al. (1998), sintetizadas no fluxograma da Figura 3.

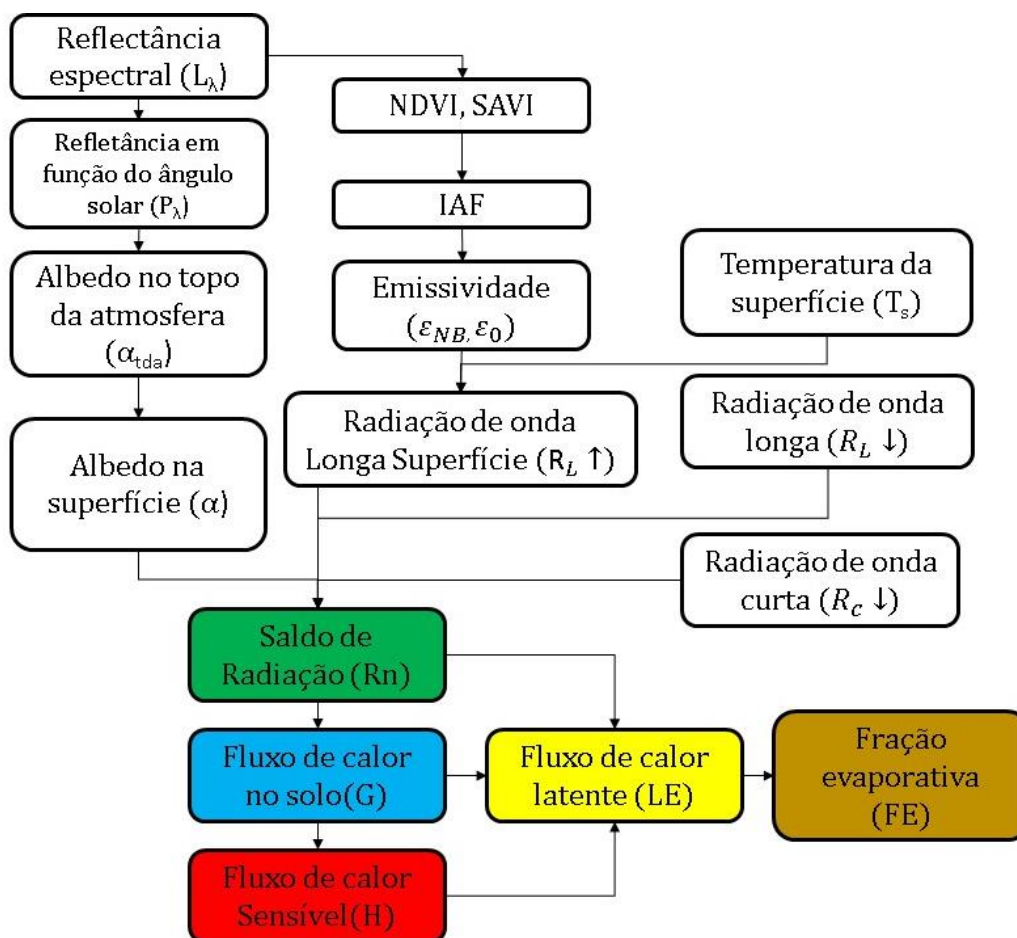


Figura 3. Fluxograma das etapas computacionais para obtenção de R_n , G , H , LE e FE .
Fonte: Autor.

A Fração evaporativa - FE representa a contribuição do elemento água na fotossíntese e pode ser determinada com base no balanço de energia através do SEBAL (ALLEN et al., 2002), de acordo com a equação:

$$FE = \frac{LE}{(R_n - G)} \quad 8)$$

Em que R_n é saldo de radiação ($W m^{-2}$), G é a densidade do fluxo de calor no solo ($W m^{-2}$), H é a densidade do fluxo de calor sensível ($W m^{-2}$) e LE é o fluxo de calor latente ($W m^{-2}$). O fluxo de calor latente – LE , calculado como resíduo do balanço de energia à superfície, segundo a expressão:

$$LE = R_n - G - H$$

9)

Saldo de radiação (R_n)

O saldo de radiação (R_n), variável envolvida no cálculo do fluxo de calor latente (LE), é a primeira componente necessária para obtenção das demais variáveis envolvidas no modelo de PPB_{LB}. O R_n representa a radiação disponível à superfície, onde são consideradas tanto a radiação de onda longa quanto a radiação de onda curta.

O método para obtenção desta variável, a partir de dados de sensoriamento remoto, envolve uma série de etapas (Figura 4), dentre elas estão calibração de radiometria, cálculo de refletância das bandas, cálculo de albedo no topo da atmosfera e superfície, cálculo de índices de vegetação, emissividade, temperatura da superfície, fluxo de radiação de ondas curtas incidentes, fluxo de radiação de ondas longas incidentes e radiação de onda longa emitida. Os cálculos para obtenção das variáveis envolvidas no balanço de radiação estão descritos de forma mais detalhada no Anexo I, tópico 9.1.

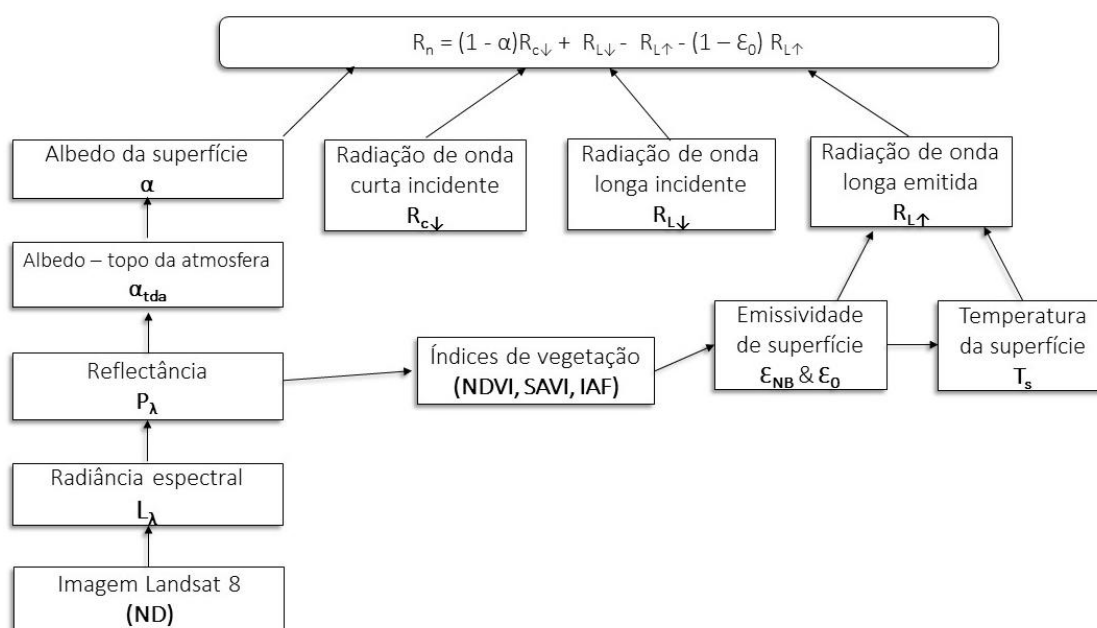


Figura 4. Fluxograma da metodologia de cálculo do saldo de radiação.
Fonte: CATTANI et al., (2017).

Após a determinação de cada um de seus componentes, o saldo de radiação é calculado utilizando-se equação:

$$R_n = (1 - \alpha)R_c \downarrow + R_L \downarrow - R_L \uparrow - (1 - \epsilon_0)R_L \downarrow \quad (10)$$

em que: R_n é o saldo de radiação ($W m^{-2}$), α é albedo da superfície (adimensional), $R_c \downarrow$ é a radiação de onda curta incidente ($W m^{-2}$); $R_L \uparrow$ representa a radiação de onda longa incidente ($W m^{-2}$), $R_L \downarrow$ é a radiação de onda longa emitida pela superfície ($W m^{-2}$), e ϵ_0 é a emissividade da superfície (adimensional).

Fluxo de radiação no solo (G)

Em posse do valor de saldo de radiação (R_n), é possível calcular a segunda variável envolvida no cálculo de LE, o fluxo de calor no solo (G), o qual representa a quantidade de energia utilizada para aquecimento do solo. O fluxo de calor no solo é função da condutividade térmica no solo e gradiente vertical da temperatura. São requeridas informações detalhadas sobre as propriedades dos solos para sua determinação. Com isso, as medidas convencionais desse fluxo de energia requerem conhecimento do gradiente de temperatura entre dois níveis do solo, informação passível de ser obtida com auxílio de instrumentos adequados.

Entretanto, de acordo com Bezerra (2013), para as estimativas que utilizam o sensoriamento remoto, não é possível a determinação deste gradiente. Portanto, a abordagem mais comumente empregada para estimar o fluxo de calor no solo utilizando imagens de satélite é a construção de uma relação empírica, a partir do saldo de radiação. Isto ocorre a partir da equação empírica apresentada por Bastiaanssen (2000), e o fluxo de calor no solo ($W m^{-2}$) pode ser obtido, representando valores próximos ao meio-dia:

$$G = \left[\frac{T_s}{\alpha} (0,0038\alpha + 0,0074\alpha^2) * (1 - 0,98NDVI^4) \right] R_n \quad (11)$$

em que: T_s é a temperatura de superfície ($^{\circ}C$), α é o albedo da superfície (adimensional), NDVI representa o índice de vegetação por diferença normalizada (adimensional) e R_n é o saldo de radiação ($W m^{-2}$).

Fluxo de calor sensível (H)

A última variável para obtenção da fração evaporativa é o fluxo de calor sensível, que consiste na taxa de calor perdido para o ar por convecção e condução, devido a um gradiente de temperatura. A determinação do fluxo de calor sensível (H) consiste na etapa de maior complexidade e importância do algoritmo SEBAL.

A estimativa deste fluxo é baseada na velocidade do vento, rugosidade e temperatura da superfície usando uma calibração interna da diferença da temperatura entre dois níveis próximos à superfície (Equação **Erro! Fonte de referência não encontrada.**).

$$H = \rho C_p \frac{(a + b * T_s)}{r_{ah}} \quad (12)$$

em que: H é o fluxo de calor sensível, ρ é a densidade do ar úmido (kg m^{-3}), C_p é o calor específico do ar à pressão constante ($1004 \text{ J Kg}^{-1} \text{ K}^{-1}$); a e b são as constantes de calibração da diferença de temperatura; T_s é a temperatura da superfície (K) e r_{ah} é a resistência aerodinâmica ao transporte de calor (s m^{-2}).

O fluxo de calor sensível é obtido através de um processo iterativo (Figura 5), que envolve a resistência aerodinâmica da superfície e a temperatura da superfície de pontos chamados de pixels-âncora (pixel frio e pixel quente). São pontos localizados na imagem que representam duas condições de fluxo de calor. O pixel frio representa uma área úmida (Área de floresta com valores altos de NDVI e IAF) onde se assume que o fluxo de calor sensível é igual a zero, e o de calor latente é máximo.

Outro ponto é o pixel quente, o qual deve ser selecionado em uma área de solo exposto, onde não há umidade suficiente para ocorrer a evapotranspiração. Neste caso, o fluxo de calor sensível é máximo e o fluxo e o calor latente é nulo. As etapas para obtenção dos coeficientes envolvidos no cálculo do calor sensível (H) (Resistencia aerodinâmica, diferença de temperatura próxima à superfície, correção pela teoria do comprimento de Monin-Obukhov) estão descritos de maneira mais detalhada no Anexo I, Tópico 9.2.

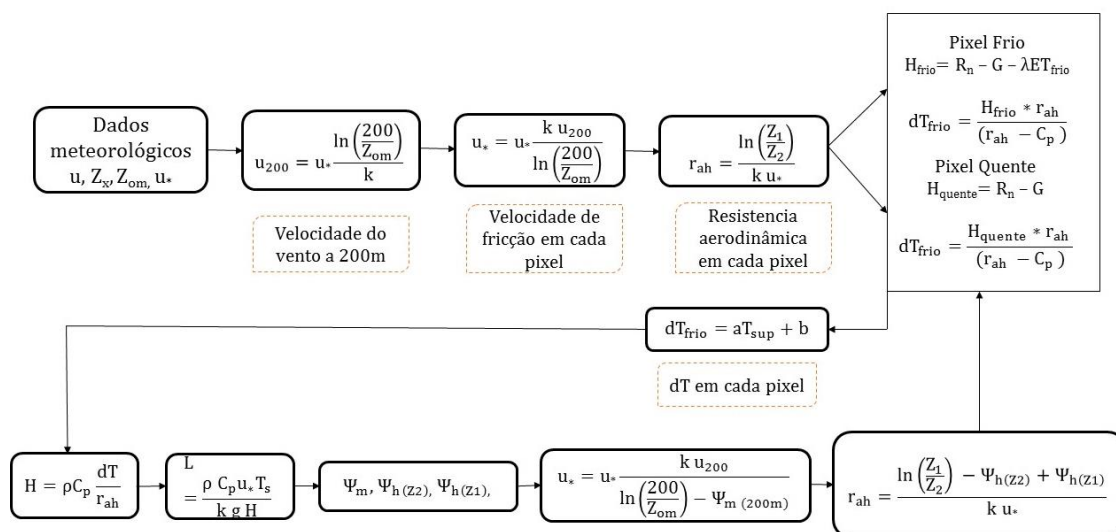


Figura 5. Fluxograma da metodologia de cálculo do fluxo de calor sensível (H).
Fonte: CATTANI et al., (2017).

Fluxo de calor Latente (LE) e Fração evaporativa (FE)

De posse dos valores das variáveis Saldo de radiação, Fluxo de calor no solo e Fluxo de calor sensível, é possível calcular o fluxo de calor latente e a fração evaporativa, como descritos nas Equações (8) e (9), e assim dar seguimento para obtenção do PPB_{L8} .

3.5 Google Earth Engine (GEE)

Os repositórios de dados disponibilizados por fornecedores comerciais e organizações públicas, como a *Google Earth* e *Global Land Cover Facility*, diversificaram as oportunidades para fazer observações baseadas em sensoriamento remoto em várias escalas espaciais e temporais globalmente (TURNER et al., 2015, KLEIN et al., 2017). Combinadas com recursos de computação baseados em nuvem, essas soluções aumentaram substancialmente as possibilidades de monitoramento do desenvolvimento de recursos ambientais e terrestres.

A ferramenta *Google Earth Engine* (GEE) é uma plataforma para análise científica e visualização de conjunto de dados para usuários acadêmicos, empresariais ou governamentais. Esta plataforma de processamento de dados geoespaciais baseados em nuvem tem capacidade de gerir análises de dados em grandes escalas, assim como um enorme potencial para processamentos computacionais, pois utiliza servidores da *Google* para armazenar e processar os dados (GOOGLE, LLC 2019).

A plataforma GEE hospeda imagens de satélite e as armazena em um arquivo de dados públicos que inclui séries históricas de imagens globais com mais de 40 anos, e fornece uma API (interface de programação de aplicativos) para JavaScript e Python (hospedado no GitHub) para gerir e analisar grandes conjuntos de dados de forma gratuita (GOOGLE LLC, 2019).

Segundo Gorelick et al. (2017), a API do GEE tem mais de 800 tipos diferentes de funções, dentre elas análises geoespaciais complexas, incluindo sobreposição, álgebra de mapas, operações de matriz, processamento de imagem, classificação, detecção de alterações, análise de séries temporais entre outros.

Em relação aos dados disponíveis para utilização estão as imagens dos satélites Landsat, Sentinel, Terra, Aqua, entre outros. Com relação às séries históricas dos satélites Landsat, a plataforma contém dados desde o satélite Landsat-1, de 1972

ao atual Landsat-8, assim como os dados do sensor MODIS, presente nos satélites Terra e Aqua, com dados desde 1999 e 2002 (GOOGLE LLC, 2018).

A plataforma GEE é composta pelo editor de códigos pelo compositor de mapas (Figura 6). No editor de códigos estão disponíveis as abas do gerenciador de scripts, documentação de scripts, gerenciador de arquivos, botões para executar e salvar scripts, barra para pesquisa das séries de dados disponíveis no GEE, abas de inspeção de pixel, painel de saída, gerenciador de tarefas, gerenciador de camadas e compositor de mapas.

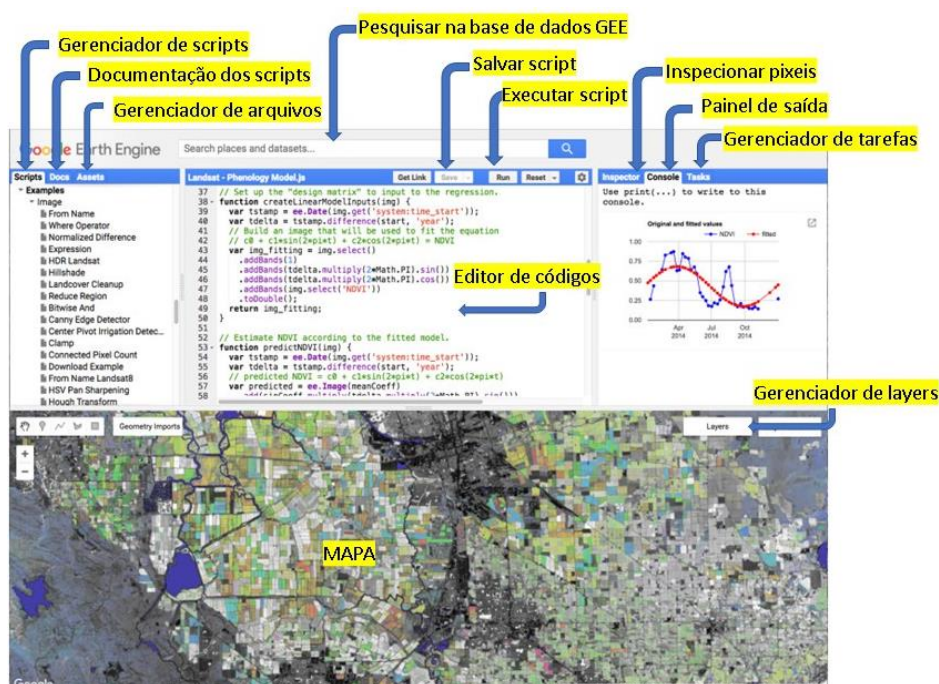


Figura 6. Ambiente de desenvolvimento do Google Earth Engine.
Fonte: Adaptado de Gorelick et al. (2017).

Alguns trabalhos têm destacado o GEE como excelente alternativa para o mapeamento do uso e cobertura da terra (LOBELL et al., 2015; XIONG et al., 2017), pelo fato da diminuição das fases anteriormente trabalhosas como download e pré-processamento de dados de satélite, acesso geral e habilitação de usos combinados de várias fontes de dados simultaneamente e processamento rápido e menos oneroso computacionalmente, ambos em um ambiente baseado em nuvem.

4 REFERÊNCIAS

ABREU, K. M. P. de; COUTINHO, L. M. Remote sensing applied to the study of vegetation with emphasis on index of vegetation and landscapes metrics. **Revista Vértices**, v. 16, n. 1, p. 173-198, 2014.

AHONGSHANGBAM, J.; PATEL, NR; KUSHWAHA, SPS; DADHWAL, V. K. J. **Indian Soc. Remote Sens.** v. 44, n. 6, p. 895-904, 2016.

ALLEN, R.; BASTIAANSEN, W.; WATERS, R.; TASUMI, M.; TREZZA, R. **Surface energy balance algorithms for land (SEBAL), Idaho implementation – Advanced training and user’s manual.** Idaho, 2002. 97p.

ALLEN, R.; BASTIAANSEN, W.; WATERS, R.; TASUMI, M.; TREZZA, R. Surface energy balance algorithms for land (SEBAL), **Idaho implementation – Advanced training and user’s manual.** Idaho, 2002. 97p.

ALMEIDA, C. T. **Produtividade Primária Bruta na Amazônia Legal: relação com variáveis meteorológicas e validação do produto MOD17A2.** 77f. Dissertação (Mestrado em ciências Ambientais e Florestais) – Universidade Federal Rural do Rio de Janeiro, Seropédica, 2016.

APARECIDO, L. E. de O.; ROLIM, G. D. S.; RICHETTI, J.; SOUZA, P. S. de; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405-417, 2016.

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

BASTIAANSEN, W. G. M. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**, v. 229, p. 87-100, 2000.

BASTIAANSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLTSLAG, A. A. M. The surface energy balance algorithm for land (SEBAL): Part 1 formulation, **Journal of Hydrology**. v. 212-213, p.198-212, 1998.

BASTIANI, F. de; URIBE-OPAZO, M. A.; DALPOSSO, G. H. Comparison of maps of spatial variability of soil resistance to penetration constructed with and without covariables using a spatial linear model. **Engenharia Agrícola**, v. 32, n. 2, p. 393-404, 2012.

BEER, C.; REICHSTEIN, M.; TOMELLERI, E.; CIAIS, P.; JUNG, M.; CARVALHAIS, N.; RÖDENBECK, C.; ARAIN, M. A.; BALDOCCHI, D.; BONAN, G. B.; BONDEAU, A.; CESCATTI, A.; LASSLOP, G.; LINDROTH, A.; LOMAS, M.; LUYSSAERT, S.; MARGOLIS, H.; OLESON, K. W.; ROUPSARD, O.; VEENENDAAL, E.; VIOVY, N.; WILLIAMS, C.; WOODWARD, F. I.; PAPALE, D. Terrestrial Gross Carbon Dioxide Uptake: Global Distribution and Covariation with Climate. **Science**, v. 329, n. 5993, p.834-838, 2010.

BEZERRA, J. M. 2013. 61f. Dissertação (Mestrado em Engenharia de água e solo) - Universidade **Estimativa da evapotranspiração real para área de caatinga utilizando Sebal.** Universidade Federal Rural de Pernambuco, Recife, 2013.

CABRAL, O. M. R.; GASH, J. H.C.; ROCHA, HUMBERTO R.; MARSDEN, C.; LIGO, M. A.V.; FREITAS, H. C.; TATSCH, J. D.; GOMES, E. Fluxes of CO₂ above a plantation of Eucalyptus in southeast Brazil. **Agricultural and Forest Meteorology**. v. 151, n. 1, p. 49-59, 2011.

CATTANI, C.E.V.; SILVA, B. B.; OLDONI, L. V.; MERCANTE, E.; ANTUNES, J. F. G.; ESQUERDO, J. C. D. M. Estimativa da evapotranspiração real diária para o município de São Gabriel do Oeste-MS utilizando imagens orbitais. **Acata Iguazu**. v. 6, n. 2, p. 13-24, 2017.

FAGAN, M.E.; DEFRIES, R.S.; SESNIE, S.E.; ARROYO-MORA, J.P.; SOTO, C.; SINGH, A.; TOWNSEND, P.A.; CHAZDON, R.L. Mapping species composition of forests and tree plantations in Northeastern Costa Rica with an integration of hyperspectral and multitemporal landsat imagery. **Remote Sens**. v. 7, p. 5660-5696, 2015.

FIELD, C. B.; RANDERSON, J.T.; MALMSTROM, C. M. Global net primary production: Combining ecology and remote sensing. **Remote Sensing of the Environment**. v. 281, n. 1, p. 237-240, 1995.

FLORENZANO, TERESA GALLOTTI. **Imagem de satélite para estudos ambientais**. Ed. São Paulo: Oficina de Textos, 2002.

FRANÇA JÚNIOR, P.; VILLA, M. E. C. D.; VILLA, J. F. D. Características Geomorfológicas e a Produção de Culturas Temporárias no estado do Paraná-Brasil. **Revista Formação**, v. 1, n. 22, p. 71-86, 2015.

GITELSON, A. A.; VIÑA, A.; MASEK, J. G.; VERMA, S. B.; SUYKER, A.E. Synoptic Monitoring of Gross Primary Productivity of Maize Using Landsat Data. **IEEE Geosciences and Remote Sensing Letters**. v. 5, n. 2, p. 133-137, 2008.

GOOGLE LLC. Datasets – Google Earth Engine. Disponível em: <<https://earthengine.google.com/datasets/>>. Acesso em: 22 set. 2018.

GOOGLE LLC. Google Earth Engine. Disponível em: <<https://earthengine.google.com/>>. Acesso em: 15 mar. 2019.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

GOUGH, C. M. Terrestrial Primary Production: Fuel for Life. **Nature Education Knowledge**. v. 3, n. 10, p. 28, 2012.

HEINSCH, F. A.; REEVES, M.; VOTAVA, P.; KANG, S. Y.; MILESI, C.; ZHAO, M. S.; et al. **User's Guide, GPP and NPP (MOD17A2/A3) Products, NASA MODIS land algorithm**. Disponível em <<http://www.ntsg.umt.edu/modis/MOD17UsersGuide.pdf>> acessado: 27 de setembro 2019.

HUETE, A. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**. v. 25, n. 3, p. 295-309, 1988.

IPCC - **Intergovernmental Panel on Climate Change**. Climate Change 2014: Synthesis Report. Contribution of Working Groups I, II and III to the Fifth Assessment

Report of the Intergovernmental Panel on Climate Change [Core Writing Team, R.K. Pachauri and L.A. Meyer (eds.)]. IPCC, Geneva, Switzerland, 2014. 151 p.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: uma perspectiva em recursos terrestres. 2ª ed. São José dos Campos: Parêntese, 2009.

JOHANN, J. A.; BECKER, W. R.; URIBE-OPAZO, M. A.; MERCANTE, E. Uso de imagens do sensor orbital MODIS na estimação de datas do ciclo de desenvolvimento da cultura da soja para o estado do Paraná. **Engenharia Agrícola**, v. 36, n. 1, p. 126-142, 2016.

JOHANN, J. A.; ROCHA, J. V.; GARBELLINI, D.; AUGUSTO, R.; LAMPARELLI, C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI / Modis. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

JUNIOR, C. C.; JOHANN, J. A.; ANTUNES, J. F. G. Mapping of sugarcane crop area in the Paraná State using Landsat / TM / OLI and IRS / LISS-3 images. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 21, n. 6, p. 427-432, 2017.

JUSTICE, C. O.; TOWNSHEND, J. R. G.; VERMOTE, E. F.; MASUOKA, E.; WOLFE, R. E.; SALEOUS, N.; ROY, D. P.; MORISETTE, J. T. An overview of MODIS Land data processing and product status. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 315, 2002.

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S. V. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: general guidelines for practitioners and future research. **Remote Sens. Environ.** v. 177, p. 89-100, 2016.

KITAMOTO, T.; UEYAMA, M.; HARAZONO, Y.; IWATA, T.; YAMAMOTO, S. Applications of NOAA/AVHRR and observed fluxes to estimate 3 regional carbon fluxes over black spruce forests in Alaska. **Journal of Agricultural Meteorology**. v. 63, p. 171-183, 2007.

KLEIN, T.; NILSSON, M.; PERSSON, A.; HAKANSSON, B. From open data to open analysis - new opportunities for environmental applications. **Environments**, v. 4, p. 32, 2017.

LENZ, A. M.; ROSA, H. A.; MERCANTE, E.; MAGGI, M. F.; MENDES, I. S.; CATTANI, C. E. V.; JOHANN, J. A.; FERRUZZI, Y.; GURGACZ, F. Expansion of eucalyptus energy plantations under a Livestock-Forestry Integration scenario for agroindustries in Western Paraná, Brazil. **Ecological Indicators**. v. 98, p. 39-48, 2019.

LI, X.; XIAO, J.F.; HE, B. B. Higher absorbed solar radiation partly offset the negative effects of water stress on the photosynthesis of Amazon forests during the 2015 drought. **Environ. Res. Lett.** v. 13, p. 1-12, 2018.

LILLESAND, T. M.; KIEFER, R. W.; CHIPMAN, J. W. Remote sensing and image interpretation. [s.l.], **Wiley journal**, 2015.

LUIZ, A. J. B.; OLIVEIRA, J. C.; EPIPHANIO, J. C. N.; FORMAGGIO, A. R. Auxílio das imagens de satélite aos levantamentos por amostragem em agricultura. **Agricultura em São Paulo**, v. 49, n. 1, p. 41-54, 2002.

LOBELL, D. B.; THAU, D.; SEIFERT, C.; ENGLE, E.; LITTLE, B. A scalable satellite-based crop yield mapper. **Remote Sensing of Environment**, v. 164, p. 324-333, jul., 2015.

MENESES, P. R.; ALMEIDA, T. de; SANTA ROSA, A. N. de C.; SANO, E. E.; SOUZA, E. B. de; BAPTISTA, G. m de M.; BRITES, R. S. **Introdução ao processamento de imagens de sensoriamento remoto**. 1. Ed. 2012.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. **Journal of Applied Ecology**. v. 9, n. 3, p. 747-766, 1972.

NEMANI, R. R.; KEELING, C. D.; HASHIMOTO, H.; JOLLY, W. M.; PIPER, S. C.; TUCKER, C. J.; MYNENI, R. B.; RUNNING, S. W. Climate-driven increases in global terrestrial net primary production from 1982 to 1999. **Science**. v. 300, p. 1560-1563, 2003.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2ª ed. São Paulo: Oficina de Textos, 2012.

PRUDENTE, V. H.; MERCANTE, E.; JOHANN, J. A.; SOUZA, C. H. W.; CATTANI, C. E. V.; MENDES, I. S.; CAON, I. L. Use of terrestrial remote sensing to estimate soybeans and beans biophysical parameters. **Geocarto international**. p. 1-19, 2019. <<https://doi.org/10.1080/10106049.2019.1624982>>.

ROUSE, J. W.; HASS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. Earth Resources Technology Satellite-1 Symposium. **Anais...** Washington, USA: NASA. Goddard Space Flight Center, 1973.

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

SAATCHI, S.S.; HARRIS, N.L.; BROWN, S.; LEFSKY M.; MITCHARD, E.T.A.; SALAS, W.; ZUTTA, B.R.; BUERMANN, W.; LEWIS, S.L.; HAGEN S.; PETROVA, S.; WHITE, L.; SILMAN, M.; MOREL, A. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proc. Natl. Acad. Sci. U. S. A.**, V. 108, p. 9899-9904, 2011.

SANTOS, R.N.; MERCANTE, E.; JOHANN, J. A.; SOUZA, C. H. W.; CATTANI, C. E. V.; PALUDO, A. Mapping of Winter Crops and Second-Crop Corn in the Paraná State-Brazil, Using Multitemporal Images From MODIS Sensor. **Journal of Agricultural Science**. v. 11, n. 2, p. 477-487, 2019.

SCHIMEL, D; PAVLICK, R.; FISHER, J. B.; ASNER, G. P.; SAATCHI, S.; TOWNSEND, P.; MILLER, C.; FRANKENBERG, C.; HIBBARD, K.; COX, P. Observing terrestrial ecosystem sand the carbon cycle from space. **Glob. Chang. Biol**. v. 21, p. 1762–1776, 2015.

SEAB; DERAL. **Previsão e Estimativa de Safras, 2018**. Disponível em: <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=75>. Acesso em: 15 dez. 2018.

SILVA, B. B. et al. Determinação Por Sensoriamento Remoto Da Produtividade Primária Bruta Do Perímetro Irrigado São Gonçalo – PB. **Revista Brasileira de Meteorologia**, v. 28, n. 1, p. 57-64, 2013.

SMITH, W. K.; REED, S. C.; CLEVELAND, C. C.; BALLANTYNE, A. P.; ANDEREGG, W. R. L.; WIEDER, W. R.; LIU, Y. Y.; RUNNING, S. W. Large divergence of satellite and Earth system model estimates of global terrestrial CO₂ fertilization. **Nat. Clim. Chang.**, v. 6, p. 306-310, 2016.

TORBICK, N.; LEDOUX, L.; SALAS, W.; ZHAO, M. Regional mapping of plantation extent using multisensor imagery. **Remote Sens.**, v. 8, p. 1-21, 2016.

TURNER, W.; RONDININI, C.; PETTORELLI, N.; MORA, B.; LEIDNER, A.K.; SZANTOI, Z.; BUCHANAN, G.; DECH, S.; DWYER, J.; HEROLD, M.; KOH, L.P.; LEIMGRUBER, P.; TAUBENBOECK, H.; WEGMANN, M.; WIKELSKI, M.; WOODCOCK, C. Free and open-access satellite data are key to biodiversity conservation. **Biol. Conserv.**, v. 182, p. 173-176, 2015.

USGS - Science for a Changing World. **Landsat 8 | Landsat Missions**. Disponível em: <https://landsat.usgs.gov/landsat-8>. Acesso em: 26 maio 2019.

VERMOTE, E.; JUSTICE, C.; CLAVERIE, M.; FRANCH, B. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. **Remote Sensing of Environment**, v. 185, p. 46-56, 2016.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088-2094, 2012.

WONS, I. **Geografia do Paraná**. Curitiba: Ensino Renovado, p. 5, 1982.

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

XIAO, J. F.; OLLINGER, S. V.; FROLKING, S.; HURTT, G. C.; HOLLINGER, D. Y.; DAVIS, K. J.; PAN, Y. D. ZHANG, X. Y.; DENG, F.; CHEN, J. Q.; BALDOCCHI, D. D.; LAW B. E.; ARAIN, M. A.; DESAI, A. R.; RICHARDSON, A. D.; SUN, G.; AMIRO, B.; MARGOLIS, H.; GU, L. H.; SCOTT, R. L.; BLANKEN, P. D.; SUYKER, A. E. Data-driven diagnostics of terrestrial carbon dynamics over North America. **Agric. For. Meteorol.** v. 197, p. 142-157, 2014.

XIONG, J.; THENKABAIL, P.; TILTON, J.; GUMMA, M.; TELUGUNTLA, P.; OLIPHANT, A.; CONGALTON, R.; YADAV, K.; GORELICK, N. Nominal 30-m Cropland Extent Map of Continental Africa by Integrating Pixel-Based and Object-Based Algorithms Using Sentinel-2 and Landsat-8 Data on Google Earth Engine. **Remote Sensing**, v. 9, n. 10, p. 1065, 19 out. 2017.

ZHAO, Y.; FENG, D.; YU, L.; WANG, X.; CHEN, Y.; BAI, Y.; JAIME HERNANDEZ, H.; GALLEGUILLOS, M.; ESTADES, C.; BIGING, G. S.; RADKE, J. D.; GONG, P. Detailed dynamic land cover mapping of Chile: Accuracy improvement by integrating multi-temporal data. **Remote Sens. Environ.** v. 183, p. 170-185, 2016.

5 METODOLOGIA GERAL

Os resultados estão separados em duas partes referentes aos artigos desenvolvidos para esta tese. O fluxograma abaixo se refere ao modo como foram divididos os artigos desenvolvidos na tese. A (Figura 7-A) apresenta o fluxo de trabalho realizado para o Artigo 1, o qual objetiva utilizar uma plataforma de dados em nuvem (GEE) para caracterizar o uso e cobertura da terra para região da Oeste do Paraná, para um período de quatro safras agrícolas (verão e inverno 2019/2020 e verão e inverno 2020/2021), e a Figura 7-B refere-se ao Artigo 2, cujos objetivos são quantificar e comparar, a partir de técnicas de sensoriamento remoto, a Produção Primária Bruta (PPB) para diferentes usos e cobertura da terra no município de Cascavel-PR.

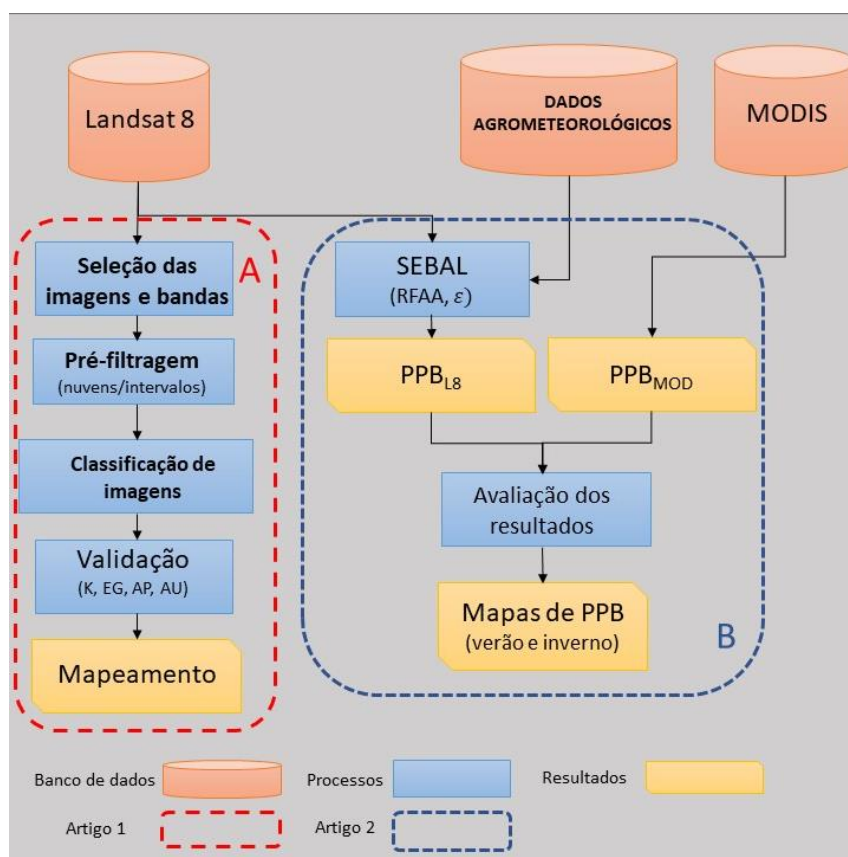


Figura 7. Fluxograma das etapas de desenvolvimento da tese.

6 ARTIGOS

6.1 Mapeamento do uso e cobertura da terra utilizando métricas espectro-temporais no Google Earth Engine

RESUMO: O *Google Earth Engine* (GEE) é uma plataforma em Nuvem muito versátil em diversas abordagens do sensoriamento remoto, dentre estas abordagens está a classificação de uso e cobertura da terra. O GEE disponibiliza muitas funções para tratamento e mineração de grandes volumes de dados e vários algoritmos de *Machine Learning* (ML) para classificação de imagens. Tudo ocorre em ambiente de nuvem a fim de diminuir o custo computacional do usuário. Neste contexto, o presente trabalho fez uso da plataforma do GEE para realizar classificações do uso e cobertura da terra para o Oeste do estado do Paraná, utilizando métricas espectrais temporais (Mediana, Média e Desvio-Padrão) assim como índices de vegetação (NDVI, EVI, SAVI e SRI) por meio dos algoritmos *Random Forest* (RF) e *Support Vector machine* (SVM) em comparação com as classificações comumente utilizadas. Os resultados apontaram que, para o período abordado, os classificadores que utilizaram apenas a métrica estatística mediana das bandas B2 a B7 como dados de entrada apresentaram os maiores valores de acurácia kappa e exatidão global.

PALAVRAS-CHAVE: Classificadores, *Random Forest*, *Support Vector Machine*, Índices de vegetação, Séries temporais.

6.1.1 INTRODUÇÃO

Uso do solo e cobertura do solo (LULC) são conceitos clássicos e informações cruciais para entender a relação entre os seres humanos e o meio ambiente (GÓMES et al., 2016). Informações detalhadas LULC em escalas global e regional são essenciais em muitas aplicações, como proteção de recursos naturais, desenvolvimento sustentável e mudanças climáticas (RAIBONGSHI et al., 2018).

O sensoriamento remoto por satélite em combinação com sistemas de informação geográfica (GIS) fornece informações espaço-temporais convenientes, baratas e contínuas do LULC's e detecta mudanças na superfície da Terra de escalas regionais a globais (KONG et al., 2016) graças à sua característica sinóptica, repetibilidade e capacidade de atingir áreas amplas ou inacessíveis, bem como pode obter dados de alta resolução espacial e temporal (PATEL et al., 2019).

O sensoriamento remoto por satélites (SR) fornece dados essenciais que auxiliam no mapeamento, estudo e interpretação da dinâmica da superfície terrestre, e graças à crescente disponibilidade de novos satélites e ao aumento das resoluções de imagem (radiométrica, espectral, espacial e temporal) vem permitindo que os usuários acessem e analisem uma gama de conjuntos e dados de séries temporais muito grandes, o que demanda tempo crescente e elevados custos computacionais.

O processamento de dados SR vem sofrendo modificações em suas estações de trabalho tradicionais equipadas com hardwares para processamento de imagens (muitas vezes de elevado custo para aquisição e manutenção) e software SR, para plataformas baseadas em nuvem que permitem aos usuários acessar e analisar grandes conjuntos dados geoespaciais processados por interfaces web e linguagens de programação eficazes (GORELICK et al., 2017).

Plataformas de computação em nuvem, abordagens baseadas em séries temporais e inteligência artificial (KWAN et al., 2020, GUO et al., 2022, KEMPENEERS et al., 2022, XU et al., 2022) forneceram novas perspectivas no campo do mapeamento LULC em larga escala. Plataformas de computação em nuvem como o *Google Earth Engine* (GEE) oferecem alto poder computacional e acessibilidade a séries temporais densas (TASSI & VIZZARI, 2020).

A análise de séries temporais de imagens de satélite permite a integração de um conjunto diversificado de características e métricas espectrais-temporais para capturar características sazonais e fenológicas de várias classes de LULC (HTITIOU et al., 2021, LIANG et al., 2022). Alguns dos métodos usados para extrair características sazonais de séries temporais em LULC são métricas espectrais-

temporais (PFLUGMACHER et al., 2019). As métricas espectrais-temporais produzem informações espectrais estatísticas de todos os *pixels* ao longo de uma escala de tempo. Essas métricas podem ser produzidas com base na média, mediana, desvio padrão, máximo, mínimo ou percentis de informações espectrais durante o período definido (WHITE et al., 2022).

Outro recurso muito utilizado em análises espectro-temporais para LULC é a utilização de índices de vegetação (IV's) (CHENLI LIU et al., 2020), pois estes IV's possuem a finalidade de ressaltar a resposta espectral da vegetação em relação à resposta espectral de outros alvos como o solo (JACKSON, 1983), este fator pode auxiliar os algoritmos de classificação na distinção de alvos e melhoria de acurácia.

Neste sentido, pode-se ressaltar a importância de plataformas de computação em nuvem, pois os métodos de extração de características de séries temporais tornam-se onerosos em termos computacionais, pois exigem a necessidade de processar grandes quantidades de dados para mapeamento LULC preciso e em larga escala (STROMANN et al., 2019).

Embora diversas pesquisas tenham obtido êxito na utilização do SR para monitoramento do LULC por meio de métricas espectrais-temporais, ainda existem lacunas quanto à agilidade no processo de aquisição de informações de LULC e à acurácia destas métricas para fins de mapeamento. Neste sentido, o *Google Earth Engine* (GEE) apresenta-se como ferramenta eficiente para experimentação e análise de dados orbitais, pois é uma plataforma que fornece diversas fontes de dados de orbitais e produtos derivados de satélite por meio de seu catálogo de dados. Os usuários que utilizam a plataforma podem evitar armazenar imagens localmente e acessar maior poder computacional para analisar e processar imagens (CARRASCO et al., 2019), além de algoritmos robustos para classificação de imagens baseados em ML (*Machine Learning*).

Neste contexto, este trabalho visou testar e desenvolver a implementação de um código GEE, gratuitamente disponível. É útil para realizar o LULC e ajustar parâmetros de entrada (por exemplo, ao escolher os parâmetros de entrada como métricas espectro-temporais ou índices de vegetação e também selecionar o algoritmo de classificação a ser utilizado). Assim como é útil para avaliar a acurácia de classificações utilizando métricas espectrais-temporais (mediana, média e desvio padrão) e índices de vegetação (NDVI, EVI, SAVI e SRI) para identificar o uso e cobertura da terra para região Oeste do Paraná.

6.1.2 MATERIAL E MÉTODOS

6.1.2.1 Área de estudo

A região em estudo é o Oeste do Paraná, que apresenta área de cerca de 22.851,003 km², com um total de 52 municípios dentro das coordenadas latitudinais de 24° 00' S a 25° 70' S e coordenadas longitudinais de 52° 59' W a 54° 60' W. O clima da região é classificado como úmido subtropical, sem estação seca, verões quentes e invernos relativamente frios e secos, com geadas ocasionais. A precipitação tende a se concentrar durante o verão, e a pluviosidade média anual é de 1850 mm por ano. Durante os meses mais quentes, a temperatura média é superior a 22 °C e, nos meses frios, é de aproximadamente 18 °C (WONS, 1982; APARECIDO et al., 2016). A altitude do terreno varia de 88,45 metros no Vale do Rio Paraná a 998,63 metros acima do nível do mar no lado Leste da região (Figura 8).

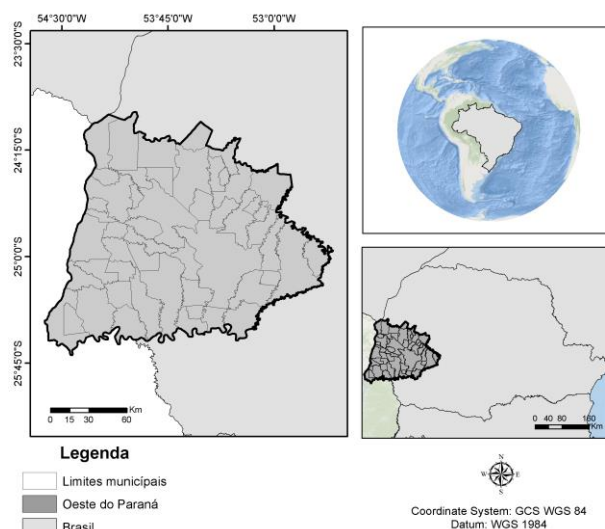


Figura 8. Localização da área de estudo – Oeste do Paraná.

A região abordada é de grande interesse comercial e econômico, pois destaca-se pela grande produção agrícola, principalmente culturas como soja, milho e trigo (JOHANN et al., 2012; FRANÇA JUNIOR et al., 2015; SANTOS et al., 2019; PRUDENTE et al., 2019), produção de cana-de-açúcar (ADAMI et al., 2012; JUNIOR et al., 2017), produção de suínos, aves e pecuária, alguns impulsionantes da forte agroindústria instalada na região (LENZ et al., 2019).

6.1.2.2 Seleção de dados e pré-processamento

A etapa de pré-processamento e seleção de dados foi desenvolvida na plataforma GEE, pelo fato de oferecer uma gama de dados aliados à alta capacidade computação em nuvem. As imagens utilizadas para pesquisa foram provenientes do sensor *Operational Land Imager* (OLI) a bordo do satélite Landsat 8. Quatro *tiles* Landsat 8 (223/77, 223/78, 224/77 e 224/78) foram utilizados para que as imagens cobrissem todo o perímetro que delimita a área de estudo.

A primeira pré-filtragem teve como intuito selecionar as imagens que estavam entre os intervalos de semeadura e colheita das safras 2019/2020 e 2020/2021, portanto, foi selecionado um período entre 01/09/2019 e 01/09/2021. A segunda pré-filtragem teve como objetivo identificar as imagens com menores porcentagens possíveis de nuvens (entre 0 e 20%). Ambas as filtrações tiveram a função de maximizar o potencial dos classificadores para distinção dos alvos. Com base nos critérios de filtragem, setenta e duas imagens foram encontradas, sendo vinte e uma delas para o *tile* 227/077, dezenove para o *tile* 227/078, dezessete para o *tile* 224/077 e quinze para o *tile* 224/078.

6.1.2.3 Amostragem, dados de treinamento e classificadores

A seleção dos dados de treinamento (Pixels Puros) foi realizada mediante a composição RGB- 432 (cor verdadeira) e RGB-564 (falsa cor) do sensor OLI. Foram também definidas quatro classes de Cobertura do Solo, Agricultura, Pastagem, Floresta e Água (Figura 9). Foram selecionadas ao todo 1.000 amostras: 250 amostras para cada classe de Cobertura, as quais foram divididas em dois grupos, com 70% para treinamento dos algoritmos classificadores, e 30%, para testes de acurácia.

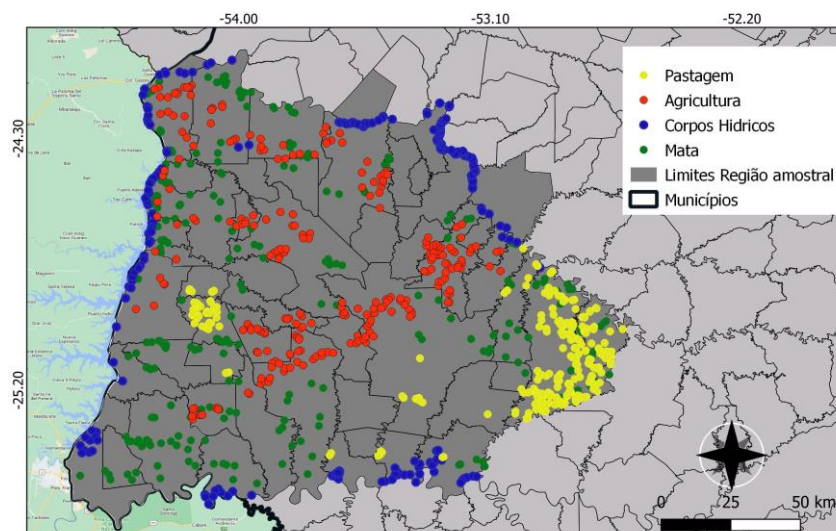


Figura 9. Amostras coletadas na área de estudo.

O mapeamento foi realizado na plataforma *online Google Earth Engine (GEE)*, onde foram utilizados dois classificadores diferentes: o *Support Vector Machine (SVM)* e o algoritmo *Random Forest (RF)*. Esses classificadores têm uma base metodológica bem estabelecida e são amplamente utilizados em aplicações de mapeamento de cobertura da terra (FAGAN et al., 2015, KHATAMI et al., 2016, TORBICK et al., 2016, ZHAO et al., 2016).

Testes foram realizados considerando entre 50 e 500 árvores de decisão, para definição dos parâmetros classificadores do algoritmo RF, que iniciou com 50 árvores de decisão e, a cada teste, o número de árvores foi aumentando progressivamente em 50 árvores por teste até total de 500 árvores de decisão. Ao realizar os testes, notou-se que não existiu ganho de acurácia e os resultados apresentaram-se similares ao elevar o número de árvores acima de 300 árvores. Levando em consideração o tempo de processamento, portanto, optou-se por utilizar o RF com 300 árvores de decisão.

O algoritmo SVM mapeia os dados para um hiperplano, onde decisões são feitas de forma linear para garantir alta generalização da máquina de aprendizagem (CORTES e VAPNIK, 1995). Para este algoritmo, foram realizados testes com os demais parâmetros existentes no GEE. No entanto, por apresentarem tempo de computação excedido neste estudo, o algoritmo SVM foi configurado para o modo padrão do sistema GEE.

6.1.2.4 Classificação

O estudo foi dividido em seis diferentes casos. Cada caso com seus respectivos dados de entrada e algoritmo de classificação. Os algoritmos utilizados foram SMV e o algoritmo RF, e os diferentes processos serão detalhados a seguir.

Caso 1: Este caso simulou uma classificação usual, ou seja, utiliza o algoritmo RF para classificar uma única imagem durante o período de estudo. Portanto, como dados de entrada, recebem apenas três bandas para classificação da imagem (B6, B5, B4) provenientes das imagens que correspondem aos dias 17/11/2019 (*tile* 223/077 e 223/078) e 23/10/2019 (*tile* 224/077 e 224/078). A data utilizada é referente a um período agrícola em que é possível realizar a melhor distinção das classes estudadas, fator que auxilia a classificação dos alvos presentes nas cenas. Tendo em vista que a área em estudo abrangeu quatro *tiles* Landsat-8, foi necessário realizar um mosaico entre as imagens, utilizando a média dos valores das imagens nas áreas coincidentes.

Caso 2: Este caso é similar ao caso anteriormente descrito, entretanto, foi utilizado o algoritmo SVM para classificar uma única imagem durante o período de estudo. Ele recebeu três bandas para classificação (B6, B5, B4) e as datas de aquisição das imagens correspondem aos dias 17/11/2019 (*tile* 223/077 e 223/078) e 23/10/2019 (*tile* 224/077 e 224/078). Pelo fato de a área em estudo abranger quatro *tiles* Landsat-8, foi necessário realizar um mosaico entre as imagens e utilizar a média dos valores pixel nas áreas onde havia sobreposição.

Ambos os casos simulam classificações mais comumente utilizadas em estudos de uso e cobertura do solo, pois, ao utilizar apenas uma única imagem, o processo de classificação torna-se menos oneroso, assim como o processo de aquisição das imagens, além de reduzir o custo computacional no processamento das imagens.

Caso 3: Este caso utiliza o algoritmo RF para classificar a mediana da série temporal das bandas B2 a B7, totalizando sete camadas de entrada para classificação.

Caso 4: O quarto caso utiliza o algoritmo SVM para classificar a mediana da série temporal das bandas B2 a B7 totalizando sete bandas de entrada.

O pré-processamento utilizado em ambos os casos tem como função diminuir ruídos presentes na série temporal, tais como a presença de nuvens e sombras e sintetizar a informação espectro temporal presente na série para apenas sete camadas de entrada. Estes fatores têm como objetivo diminuir a demanda computacional.

Caso 5: O quinto caso utiliza o algoritmo RF para classificar métricas estatísticas e índices de vegetação para classificação. Como dados de entrada para o algoritmo, foram utilizados a mediana, média, o desvio padrão das bandas B2 a B7 das séries temporais e os índices de vegetação NDVI, EVI, SAVI e SRI calculados a partir da mediana da série temporal, totalizando 22 camadas de entrada.

Caso 6: Semelhante ao caso anteriormente descrito, este caso utiliza o algoritmo SVM para classificar métricas estatísticas e índices de vegetação para classificação. Como dados de entrada para o algoritmo, foram utilizados a mediana, média, o desvio padrão das bandas B2 a B7 das séries temporais e os índices de vegetação NDVI, EVI, SAVI e SRI, calculados a partir da mediana da série temporal, totalizando vinte e duas (22) camadas de entrada. A utilização de índices de vegetação utiliza razões matemáticas entre bandas do infravermelho próximo e o vermelho apresenta vantagens que contribuem para a distinção da vegetação em relação aos demais alvos presentes na imagem, o que auxilia tanto na distinção como na diminuição de erros de classificação por meio de algoritmos.

O uso de métricas estatísticas nas classificações tem como objetivo avaliar a variabilidade dos valores de *pixels* ao longo dos ciclos anuais e auxiliar os classificadores na distinção de alvos, de acordo com sua variabilidade ao longo tempo. A utilização de métricas estatísticas assim como os índices de vegetação são úteis e contribuem para destacar a vegetação em relação a outros alvos. Os casos V e VI também têm o intuito de avaliar se existe um aumento de qualidade no uso de uma maior quantidade de informação espectro temporal.

6.1.2.5 Avaliação dos resultados

A avaliação da acurácia espacial dos mapeamentos foi realizada por meio das matrizes de erros usando o conjunto de dados de teste 30% de amostras, bem como a plataforma GEE. A partir da matriz de erros, foram calculados a Exatidão Global (13) e o Índice Kappa (14) para avaliar as acurácias do mapeamento.

A exatidão global (EG) foi utilizada para mensurar a similaridade entre o mapa de referência e a classificação.

$$EG = \frac{\sum_{i=1}^q x_{ij}}{n} \times 100 \quad (13)$$

em que: x_{ij} =observação na linha i e coluna j ; n é o número total de *pixels* considerados, e q é o número de classes.

O índice Kappa (K) tem a função de mensurar a exatidão das classificações temáticas. É recomendado como uma medida apropriada da exatidão por utilizar todos os elementos da matriz de erros. Fornece uma medida de concordância entre as classes do mapa referência e as classes da classificação.

$$K = \frac{[n * \sum_{i=1}^r x_{ij} - \sum_{i=1}^r (x_i * x_j)]}{[n^2 - \sum_{i=1}^r (x_i * x_j)]} \quad (14)$$

em que: x_{ij} é a observação na linha i e na coluna j ; x_i é o total marginal da linha i ; x_j é o total marginal da coluna j ; n é o número total de pixel considerados; i é a classe considerada e r é o numero de linhas da matriz de erros.

Os valores da acurácia de produtor (AP) (15) também foram utilizados como forma de avaliação das classificações, os quais referem-se à probabilidade de um *pixel* de referência ter sido corretamente classificado e à acurácia de usuário (AU) (16), que indica a probabilidade que um *pixel* classificado na imagem de fato representa aquela categoria no campo.

$$AP_i = \frac{x_{ij}}{x_i} \times 100 \quad (15)$$

$$AU_i = \frac{x_{ij}}{x_j} \times 100 \quad (16)$$

P

em que: x_{ij} é a observação na linha i e coluna j ; x_i é o total marginal da linha i ; x_j é o total marginal da coluna j ; i é a classe considerada. O teste Z (Equação 17) foi utilizado para avaliar se existem diferenças significativas das medidas de precisão entre diferentes resultados de classificação (FOODY, 2009). Para este teste, assume-se que se o valor de $|Z| > 1,96$ indicará que as duas classificações comparadas são significativamente diferentes no nível de significância de 5% (FOODY, 2009).

$$Z = \frac{P_1 - P_2}{\sqrt{\bar{p}(1 - \bar{p}) \left(\frac{1}{n_1} + \frac{1}{n_2} \right)}} \quad (17)$$

em que $\bar{p} = (x_1 + x_2)/(x_1 - x_2)$, P_1 e P_2 correspondem aos Índices Kappa de cada método comparado; x_1 é o número de casos alocados corretamente em classificações de dados com tamanho n_1 e x_2 é o número de casos alocados corretamente em classificações de dados com tamanho n_2 .

6.1.3 RESULTADOS E DISCUSSÃO

A partir do mapa de uso e cobertura do solo, das classes Agricultura, Pastagem, Mata e Água, é possível destacar alguns padrões de espacialização dos alvos observados.

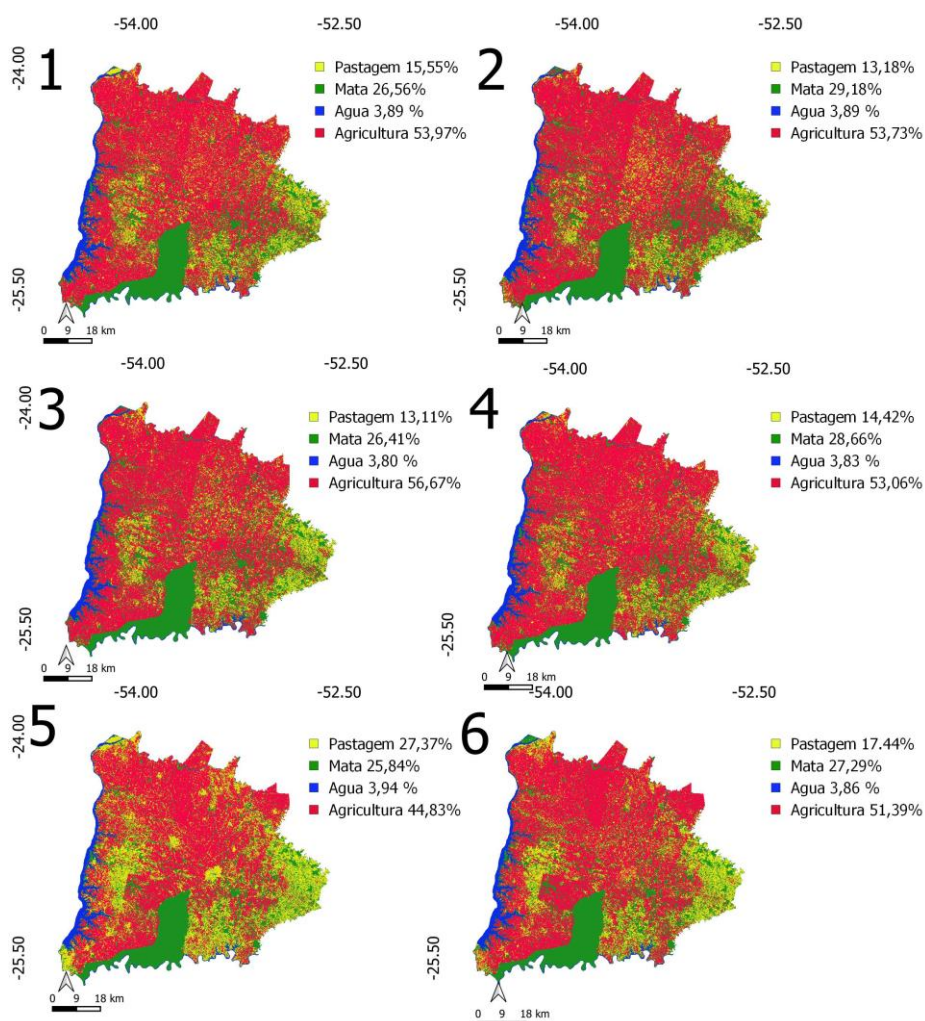


Figura 10. Mapa de uso e cobertura do solo da AMOP, (1) Mapa de cobertura para o caso 1, (2) Mapa de cobertura para o caso 2, (3) Mapa de cobertura para o caso 3, (4) Mapa de cobertura para o caso 4, (5) Mapa de cobertura para o caso 5 e (6) Mapa de cobertura para o caso 6.

A partir da (Figura 10), é possível observar que os classificadores identificaram maior incidência e predominância da classe pastagem em algumas regiões da área de pesquisa. A região 1 (Figura 11 - A) região Leste da área de pesquisa, nos municípios

de Guaraniaçu, Diamante do Sul e Catanduvas. Também é possível observar a alta incidência da classe Pastagem na região 2 (Figura 11 - B) que abrangem os municípios próximos à área preservação do parque nacional do Iguaçu, nos municípios de Cascavel, Lindoeste, Boa Vista da Aparecida e Santa Lúcia e também na região 3 (Figura 11 - C) nos municípios de Santa Helena, Vera Cruz, Ramilândia e Ouro Verde.

A maior concentração de área florestal está presente no parque nacional do Iguaçu, entretanto, existem diversos fragmentos menores da classe Mapa, dispersos nos municípios da área de pesquisa. A maior parte da classe Água encontra-se ao Oeste da área de pesquisa, no reservatório da usina hidrelétrica do Itaipu. Entretanto, podemos ressaltar que existem outros grandes cursos d'água presentes na imagem, tais como o Rio Piquiri, ao norte da área de pesquisa, e o Rio Iguaçu, ao sul da área de pesquisa.

A classe Agricultura esteve distribuída por toda a extensão da área de pesquisa. Em todos os casos foi possível observar que esta classe ocupou mais de 50% da área total observada.

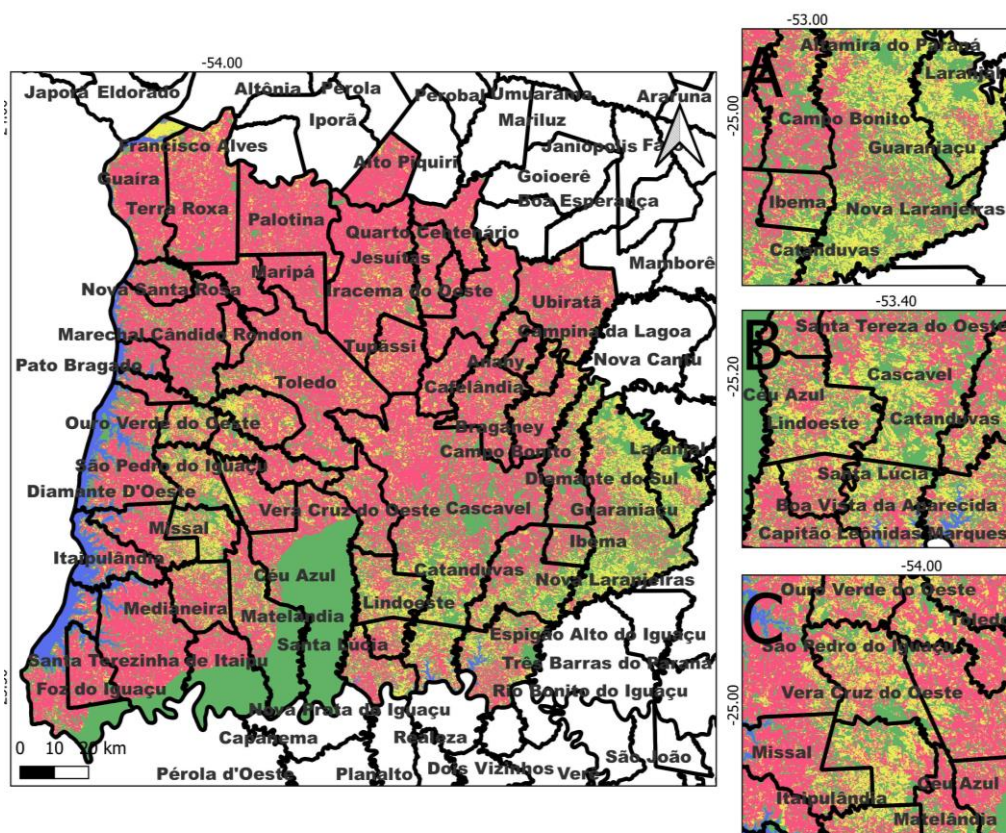


Figura 11. Espacialização de uso e cobertura do solo. A – Área de pastagens 1. B – Áreas de pastagem 2, C – Áreas de pastagem 3

Os resultados obtidos para o Caso 1 apontam a classe Agricultura como a classe de Cobertura de predominância com 53,9% de ocupação da área total, seguida pelas classes Mata (26.72%), Pastagem (15.55%) e Água (3.89%). Neste caso, a classe Pastagem apresentou o maior erro quando classificada (AU = 78.66%), confundindo-se principalmente com a classe Agricultura (Tabela 2). Observa-se que a classe Agricultura também apresentou uma AU de 80.0%, inferior aos demais alvos, confundindo a classe Agricultura com a classe Pastagem.

Tabela 2. Matriz de erro e acurácias de produtor e usuário para o Caso 1.

Caso 1	Mata	Água	Agricultura	Pastagem	AU (%)
Mata	72	0	3	0	96
Água	0	75	0	0	100
Agricultura	0	0	60	15	80
Pastagem	0	0	16	59	78.66
AP (%)	100	100	75.94	79.72	

Os resultados obtidos para o Caso 2 também indicam que a classe de Cobertura de predominância na área de pesquisa é a classe Agricultura com 53.7% da área total, seguida pelas classes Mata (29.18%), Pastagem (13.18%) e Água (3.89%). Assim como no caso anterior, neste caso, a classe Pastagem foi a maior fonte de erro (Tabela 3) com AU de 73.33%, seguida da classe Agricultura com AU = 80.0%. A partir da matriz de erros, é possível observar que a classe Pastagem apontou que 25% das amostras de avaliação foram classificadas como agricultura, assim como para a classe Agricultura, 20.0% dos erros atribuídos obtidos pelo classificador confundiram esta classe com Pastagem.

Tabela 3. Matriz de erro e acurácias de produtor e usuário para o Caso 2.

Caso 2	Mata	Água	Agricultura	Pastagem	AU (%)
Mata	70	0	4	1	93.33
Água	0	75	0	0	100
Agricultura	0	0	60	15	80
Pastagem	0	0	20	55	73.33
AP (%)	100	100	71.42	77.46	

Os resultados obtidos para o Caso 2 também indicam que a classe de Cobertura de predominância na área de pesquisa é a classe Agricultura com 53.7% da área total, seguida pelas classes Mata (29.18%), Pastagem (13.18%) e Água (3.89%). Assim como no caso anterior, neste caso, a classe pastagem foi a maior fonte de erro (Tabela 3) com AU de 73.33%, seguido da classe Agricultura com AU = 80.0%. A

partir da matriz de erros, é possível observar que a classe Pastagem apontou que 25% das amostras de avaliação, foram classificadas como agricultura, assim como para a classe Agricultura, 20.0% dos erros atribuídos obtidos pelo classificador confundiram esta classe com Pastagem.

Oldoni et al. (2019), ao utilizarem imagens Landsat 8 e o classificador RF para classificação de imagens na região Oeste do Paraná, identificaram certa confusão entre a classe Pastagem e os outros tipos de alvos agrícolas, assim como Garofalo et al. (2015) que, ao utilizarem o classificador SVM em imagens Landsat 8 na Bacia do Rio Piracicaba -Jaguari - MG, também destacaram confusão entre a classe de Pastagem e os outros tipos de cultivos agrícolas. Ponzoni et al. (2012) sugerem que esta confusão entre estes tipos de alvos esteja atrelada à semelhança espectral entre as duas classes observadas. Tal fato pode ter sido atenuado, pois a utilização do RGB em uma única data que não expressa as diferenças espectro-temporais entre a agricultura e a pastagem.

As classificações que utilizam a métrica estatística mediana das bandas B2 a B7 para ambos os classificadores (RF e SVM) foram realizadas nos casos 3 e 4. No caso 3, podemos observar que o classificador RF identificou a classe Agricultura como classe predominante, cobrindo em torno de 56,67% da área em estudo. Este foi o classificador que obteve maior valor de área para esta classe. Em contrapartida, foram obtidos os menores valores para a classe Pastagem - 13.11%. A classe Mata obteve cobertura de 26,41%, e a classe Água obteve 3.80%. As classes Agricultura e Pastagem apresentaram AU de 86.66% e 88.0%, valores superiores aos encontrados nos casos 1 e 2, o que demonstra melhor acurácia por parte do classificador. Porém, é possível observar que as maiores fontes de erros encontradas nesta classificação são oriundas da confusão entre as classes Pastagem e Agricultura (Tabela 4).

Tabela 4. Matriz de erro e acurácias de produtor e usuário para o Caso 3.

Caso 3	Mata	Água	Agricultura	Pastagem	AU (%)
Mata	74	0	0	1	98.66
Água	0	75	0	0	100
Agricultura	0	0	66	9	88
Pastagem	0	0	10	65	86.66
AP (%)	100	100	86.84	86.66	

O caso 4 é classificado com 53.06% da área como agricultura, 14,42% da área como pastagem, 28.66% da área como mata e 3.82% como água. Este classificador apontou os maiores valores de AU dentre os métodos utilizados, com 100% para mata e água e 88,6% e 92.42% para as classes Agricultura e Pastagem, respectivamente (

Tabela 5).

Tabela 5. Matriz de erro e acurácias de produtor e usuário para o Caso 4.

Caso 4	Mata	Água	Agricultura	Pastagem	AU (%)
Mata	75	0	0	0	100
Água	0	75	0	0	100
Agricultura	4	0	70	5	88.60
Pastagem	1	0	4	61	92.42
AP (%)	93.75	100	94.56	92.42	

Tassi et al. (2021) destacam que o GEE é uma excelente ferramenta para o processamento e as análises de sensoriamento remoto, pois maximizam de forma muito eficaz o processamento de imagens e condensam informações de séries temporais, eliminação de nuvens e sombras. Gorelick et al. (2017) afirmam que as ferramentas disponíveis no GEE permitem que cada *pixel* efetivo da imagem seja utilizado o máximo possível em pesquisa.

A ferramenta filtro de mediana utilizada nos casos 3 e 4, pelo fato de utilizar informação espectro-temporal das imagens, diminui a interferência de alvos como nuvem e sombras. Assim, é possível que ocorra influência positiva em áreas com alta incidência de nuvens. Estes fatores podem ter colaborado para melhor acurácia obtida por ambos os classificadores. Porém, é válido ressaltar que existem algumas restrições quanto a este filtro. Segundo Oliveira et al. (2019), ao realizarem o mapeamento em Moçambique por meio dos sensores Landsat8 e Sentinel-2, os autores encontraram a forte presença de nuvens durante as estações chuvosas. Eles apontaram que a utilização do filtro de média para composição de mosaicos afetou negativamente, pois ao serem substituídos *pixels* contaminados por nuvens, gerou-se também uma mistura da resposta espectral e conseqüentemente a divergência entre as áreas classificadas, em especial, em áreas de vegetação com características espectrais semelhantes.

Nos casos 5 e 6, foram realizadas classificações utilizando-se métricas estatísticas (média, mediana e desvio padrão) juntamente com índices de vegetação calculados a partir da mediana da série temporal (NDVI, EVI, SAVI e SRI). O caso 5 também apontou a predominância da classe Agricultura com 44,83% da área total da área em estudo, 27,3% do total da cobertura como a classe Pastagem, 25,84% como Mata e 3,94 como Água. Este caso apontou a menor porcentagem de área de agricultura e apresentou o maior percentual para a classe Pastagem dentre as seis hipóteses abordadas. Assim como nos casos anteriores, os maiores erros são possíveis de se observar na matriz de erros (Tabela 6), erros de omissão para a classe Agricultura (AP = 73.75) assim como erros de inclusão para a classe Pastagem

(AU = 76.0), apontados que a classe Agricultura foi classificada erroneamente na classe Pastagem.

Tabela 6. Matriz de erro e acurácias de produtor e usuário para o Caso 5.

Caso 5	Mata	Água	Agricultura	Pastagem	AU (%)
Mata	70	0	3	2	93.33
Água	0	75	0	0	100
Agricultura	0	0	59	16	78.66
Pastagem	0	0	18	57	76.0
AP (%)	100	100	73.75	76.0	

O caso 6 obteve predominância da classe Agricultura com 51.39% da área total, seguido pelas classes Mata (27.29%), Pastagem 17.44% e Água 3.86%. Esta hipótese 6 assim como os demais classificadores também apresentaram confusão na classificação entre as classes Agricultura e Pastagem (Tabela 7). Entretanto, apresentaram erros menores em relação ao caso 5, que utiliza métricas similares para classificação de imagens.

Tabela 7. Matriz de erro e acurácias de produtor e usuário para o Caso 6.

Caso 6	Mata	Água	Agricultura	Pastagem	AU(%)
Mata	70	0	4	1	92.10
Água	0	75	0	1	97.33
Agricultura	3	0	60	14	80.00
Pastagem	3	0	10	62	82.66
AP (%)	93.33	100	81.08	79.48	

Os resultados de acurácia para cada mapeamento são apresentados na Tabela 8 e mostram valores muito próximos entre os classificadores avaliados. É possível destacar que os maiores valores de acurácia foram obtidos para os casos 4 (K = 0.93, EG = 95.25%) e 3 (K = 0.91, EG = 93.33%). Observa-se também que o caso 5 obteve o menor valor de acurácia dentre os classificadores (K = 0.82, EG = 87.66%).

Tabela 8. Índices de acurácias gerados para os seis casos abordados.

Casos	EG (%)	K
Caso 1	88.66	0.84
Caso 2	86.66	0.82
Caso 3	93.33	0.91
Caso 4	95.25	0.93
Caso 5	87.66	0.82
Caso 6	88.33	0.84

Apesar da similaridade entre os valores de acurácia encontrados, pelo Teste Z ($|Z| < 1,96$) (Tabela 9), encontraram-se diferenças significativas entre os casos avaliados. Os casos 1 e 2, que utilizaram RF e SVM para classificação em uma imagem RGB falsa, não diferiram entre si e apresentaram diferenças significativas apenas em relação aos casos 3 e 4. Casos que utilizaram RF e SVM para a classificação da mediana da série temporal. Os casos 3 e 4 não apresentaram diferenças significativas entre si, entretanto, apresentaram diferença significativa quando comparados aos demais casos observados. Os casos 4 e 5 não apresentaram diferença significativa entre si e entre os casos 1 e caso 2, porém, apresentaram diferenças entre os casos 3 e 4.

Tabela 9. Teste Z para comparação entre os seis casos de classificação.

Casos	1	2	3	4	5	6
1						
2	1.2 ^{ns}					
3	2.15*	2.12*				
4	2.65*	2.16*	0.14 ^{ns}			
5	0.42 ^{ns}	0.88 ^{ns}	2.01*	3.14*		
6	0.85 ^{ns}	0.21 ^{ns}	3.15*	2.82*	1.81 ^{ns}	

Nota: * significativo a 5% de probabilidade; ns - não significativo.

6.1.4 CONCLUSÃO

Os resultados sugeriram que apesar de condensar informações em apenas seis variáveis de entrada, os casos 3 e 4 obtiveram os melhores resultados com os maiores valores de acurácia e não diferiram entre si, pelo Teste Z. Mesmo com o incremento de variáveis e mais dados de entrada, os casos 5 e 6 não diferiram estatisticamente dos casos 1 e 2, e obtiveram resultados de acurácia inferiores aos casos 3 e 4. Todos os classificadores apresentaram erros de comissão e omissão entre as classes Agricultura e Pastagem.

O GEE, pelas características de disponibilidade de big-datas e de processamento em nuvem, destacou-se como uma ferramenta eficaz para tratamento, pré-processamento e classificação de imagens Landsat 8.

6.1.5 REFERÊNCIAS

ADAMI, M.; MELLO, M. P.; AGUIAR, D. A.; RUDORFF, B. F. T.; SOUZA, A. F. de. A web platform development to perform thematic accuracy assessment of sugarcane mapping in South-Central Brazil. **Remote Sensing**, v. 4, n. 10, p. 3201-3214, 2012.

APARECIDO, L. E. de O.; ROLIM, G. D. S.; RICHETTI, J.; SOUZA, P. S. de; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405-417, 2016.

CARRASCO, L.; O'NEIL, A. W.; MORTON, R. D.; ROWLAND, C. S. Evaluating Combinations of Temporally Aggregated Sentinel-1, Sentinel-2 and Landsat 8 for Land Cover Mapping with Google Earth Engine. **Remote Sensing**, v. 11, p. 1-21, 2019.

CHENLI, L.; WENLONG, L.; GAOFENG, Z.; HEPIAO, Y; PENGFEI, X. Land Use/Land Cover Changes and Their Driving Factors in the Northeastern Tibetan Plateau Based on Geographical Detectors and Google Earth Engine: A Case Study in Gannan Prefecture. **Remote Sensing**, v. 12, p. 1-18, 2020.

CORTES, C.; VAPNIK, V. Support-vector networks, **machine Learning**, v. 20, p. 273-297, 1995.

FAGAN, M. E.; DEFRIES, R. S.; SESNIE, S. E.; ARROYO-MORA, J. P.; SOTO, C.; SINGH, A.; TOWNSEND, P. A.; CHAZDON, R. L. Mapping species composition of forests and tree plantations in Northeastern Costa Rica with an integration of hyperspectral and multitemporal landsat imagery. **Remote Sensing**, v. 7, p. 5660-5696, 2015.

FOODY, G. M. Classification accuracy comparison: Hypothesis tests and the use of confidence intervals in evaluations of difference, equivalence and non-inferiority. **Remote Sensing of Environment**, v. 113, n. 8, p. 1658-1663, 2009.

FRANÇA JUNIOR, P.; VILLA, M. E. C. D.; VILLA, J. F. D. Características Geomorfológicas e a Produção de Culturas Temporárias no estado do Paraná-Brasil. **Revista Formação**, v. 1, n. 22, p. 71-86, 2015.

GAROFALO, D. F.; MESSIAS, C. G.; LIESENBERG, V.; BOLFE, E. L.; FERREIRA, M. C. Comparative analysis of digital classifiers of Landsat-8 images for thematic mapping. **Pesq. Agropec. Bras.**, v. 50, n. 7, p. 593-604, 2015.

GÓMEZ, C.; BRANCO, J. C; WULDER, M. A. Optical Remotely Sensed Time Séries Data for Land Cover Classification: A Review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 116, p. 55-72, 2016.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

GUO, J.; HUANG, C.; HOU, J. A Scalable Computing Resources System for Remote Sensing Big Data Processing Using GeoPySpark Based on Spark on K8s. **Remote Sensing**, v. 14, p. 521. 2022.

HTITIOU, A.; BOUDHAR, A.; CHEHBOUNI, A.; BENABDELOUAHAB, T. National-Scale Cropland Mapping Based on Phenological Metrics, Environmental Covariates,

and Machine Learning on Google Earth Engine. **Remote Sensing**, v. 13, p. 1-26, 2021.

JACKSON, R. D. Spectral indices in n-Space. **Remote Sensing of Environment**, v. 13, p. 409-421, 1983.

JOHANN, J. A.; ROCHA, J. V.; GARBELLINI, D.; AUGUSTO, R.; LAMPARELLI, C. Estimativa de áreas com culturas de verão no Paraná, por meio de imagens multitemporais EVI / Modis. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

KEMPENEERS, P.; KLIMENT, T.; MARLETTA, L.; SOILLE, P. Parallel Processing Strategies for Geospatial Data in a Cloud Computing Infrastructure. **Remote Sensing**, v. 14, n. 398, p. 1-14, 2022.

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S.V. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: general guidelines for practitioners and future research. **Remote Sens. Environ.** v. 177, p. 89-100, 2016.

KONG, F., LI, X., WANG, H., XIE, D., LI, X. E BAI, Y. Land Cover Classification Based on Fused Data from GF-1 and MODIS NDVI Time Séries , **Remote Sensing**, v.8, p. 1-20, 2016.

KWAN, C.; AYHAN, B.; BUDAVARI, B.; LU, Y.; PÉREZ, D.; LI, J.; BERNABÉ, S.; PLAZA, A. Deep Learning para Classificação da Cobertura do Solo Usando Apenas Algumas Bandas. **Remote Sensing**. v. 12, p. 1-17, 2020.

LENZ, A. M.; ROSA, H. A.; MERCANTE, E.; MAGGI, M. F.; MENDES, I. S.; CATTANI, C. E. V.; JOHANN, J. A.; FERRUZZI, Y.; GURGACZ, F. Expansion of eucalyptus energy plantations under a Livestock-Forestry Integration scenario for agroindustries in Western Paraná, Brazil. **Ecological Indicators**. v. 98, p. 39-48, 2019.

LIANG, S.; GONG, Z.; WANG, Y.; ZHAO, J.; ZHAO, W. Accurate monitoring of submerged aquatic vegetation in a macrophytic lake using time-séries sentinel-2 images. **Remote sensing**, v. 14, p. 1-16, 2022.

OLDONI, L. V.; CATTANI, C. E. V.; MERCANTE, E.; JOHANN, J. A.; ANTUNES, E. J. G.; ALMEIDA, L. Annual cropland mapping using data mining and OLI Landsat-8. **Agriambi**. v. 23, n. 12, p. 952-958, 2019.

OLIVEIRA, W. N.; MIZIARA, F.; FERREIRA, N. C. Mapping Land Use and Land Cover of Mozambique Using Google Earth Engine Platform. **Anuário do Instituto de Geociências – UFRJ**. v. 42, p. 336-345, 2019.

PATEL, S. K., VERMA, P., AND SINGH, G. S. Agricultural growth and land use land cover change in peri-urban India, **Environmental Monitoring and Assessment**, v. 191, p. 1-17, 2019.

PFLUGMACHER, D.; RABE, A.; PETERS, M.; HOSTERT, P. Mapping pan-European land cover using Landsat spectral-temporal metrics and the European LUCAS survey. **Remote sensing of Environment**. v. 221, p. 583-595, 2019.

PONZONI, F. J.; SHIMABUKURO, Y. E.; KUPLICH, T. M. **Sensoriamento remoto da vegetação**. 2ª ed. São Paulo: Oficina de Textos, 2012.

PRUDENTE, V. H.; MERCANTE, E.; JOHANN, J. A.; SOUZA, C. H. W.; CATTANI, C. E. V.; MENDES, I. S.; CAON, I. L. Use of terrestrial remote sensing to estimate soybeans and beans biophysical parameters. **Geocarto international**. p. 1-19, 2019.

RAJBONGSHI, P.; DAS, T.; ADHIKARI, D. Micro environmental heterogeneity caused by anthropogenic LULC foster lower plant assemblages in the riparian habitats of lentic systems in tropical floodplains. **Science of the Total Environment**, v. 639, p.1254-1260, 2018.

SANTOS, R. N.; MERCANTE, E.; JOHANN, J. A.; SOUZA, C. H. W.; CATTANI, C. E. V.; PALUDO, A. Mapping of Winter Crops and Second-Crop Corn in the Paraná State-Brazil, Using Multitemporal Images From MODIS Sensor. **Journal of Agricultural Science**. v. 11, n. 2, p. 477-487, 2019.

STROMANN, O.; NASCETTI, A.; YOUSIF, O.; BAN, Y. Dimensionality reduction and feature selection for object-based land cover classification based on Sentinel-1 and Sentinel-2 time series using Google Earth Engine. **Remote Sensing**. v. 12, p. 1-24, 2019.

TASSI, A.; GIGANTE, D.; MODICA, G.; DI MARTINO, L.; VIZZARI, M. Pixel- vs. Object-Based Landsat 8 Data Classification in Google Earth Engine Using Random Forest: The Case Study of Maiella National Park. **Remote Sensing**. v. 13, n. 12, p. 1-20, 2021.

TASSI, A.; VIZZARI, M. Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms. **Remote Sensing**. v. 12, p. 1-17, 2020.

TORBICK, N.; LEDOUX, L.; SALAS, W.; ZHAO, M. Regional mapping of plantation extent using multisensor imagery. **Remote Sens**. V. 8, p. 1-21, 2016

WHITE, J. C.; HERMOSILLA, T.; WULDER, M. A.; Coops, N. C. Mapping, validating, and interpreting spatio-temporal trends in post-disturbance forest recovery. **Remote sensing of Environment**. v. 271, 11- 29, 2022.

XU, L.; HEROLD, M.; TSENDBAZAR, N. E.; MASILIŪNAS, D.; LI, L.; LESIV, M.; FRITZ, S.; VERBESSELT, J. Time séries analysis for global land cover change monitoring: A comparison across sensors. **Remote Sensing of Environment**, v. 271, 11-20, 2022.

ZHAO, Y.; FENG, D.; YU, L.; WANG, X.; CHEN, Y.; BAI, Y.; JAIME HERNANDEZ, H.; GALLEGUILLOS, M.; ESTADES, C.; BIGING, G. S.; RADKE, J. D.; GONG, P. Detailed dynamic land cover mapping of Chile: Accuracy improvement by integrating multi-temporal data. **Remote Sensing of Environment**. v. 183, p. 170-185, 2016.

6.2 Artigo 2: Dinâmica temporal da Produção Primária Bruta para município de Cascavel-PR utilizando GEE

RESUMO: A Produção Primária Bruta (PPB) é um parâmetro biofísico de qualquer ecossistema e pode auxiliar no entendimento da dinâmica espacial e temporal dos fluxos de carbono. O uso de técnicas de sensoriamento remoto orbital tem se mostrado uma ferramenta valiosa, pois possibilita uma visão panorâmica, em diferentes escalas, com elevada precisão e menor custo operacional em relação às técnicas tradicionais de monitoramento de uso e cobertura da terra e ciclo do carbono. Neste sentido, o presente trabalho teve como objetivo desenvolver um algoritmo para cálculo de Produção Primária Bruta (PPB) em dados do satélite Landsat OLI/TIRS (PPB_{L8}) em uma plataforma em nuvem (*Google Earth Engine* – GEE) e avaliar o potencial dos satélites Landsat 8 em estimar o PPB e avaliar a dinâmica da PPB para diferentes tipos de cobertura vegetal no período de dois anos-safra (2019/2020 e 2020/2021) no município de Cascavel-PR. Também foi avaliada a acurácia do modelo PPB_{L8} em relação aos dados de PPB produto MOD17A2 (PPB_{MOD}). Os valores de PPB_{L8} demonstraram excelente potencial ao observar distinções nos tipos de alvos na região em estudo, tal como identificar padrões sazonais de PPB em diferentes tipos de cobertura. No modelo PPB_{L8}, a classe Mata apresentou os melhores valores de acurácia dentre as classes avaliadas, com r , d_r e RMSE de 0.78, 0.74 e 1.41 g.C.m⁻².dia⁻¹, respectivamente. A diferença de resolução espacial entre as imagens pode diminuir a acurácia entre os modelos de PPB. O algoritmo proposto, devido à sua aplicabilidade ao satélite Landsat 8 OLI/TIRS, pode ser útil para análises mais precisas de PPB para áreas de estudo locais bem como bacias hidrográficas ou áreas florestais.

PALAVRAS-CHAVE: Carbono, Agricultura, Produção Primária Bruta, Processamento em Nuvem, Sequestro de Carbono.

6.2.1 INTRODUÇÃO

A produção primária bruta (PPB) é um importante parâmetro para a pesquisa do ciclo do carbono e do clima tendo em vista que é utilizada para quantificar a quantidade total de energia ou biomassa produzida pela vegetação através da fotossíntese em uma unidade de tempo (PINGINTHA et al., 2010, VASHUM e JAYAKUMAR, 2012, ANAV et al., 2015).

Os ecossistemas florestais e agropecuários são considerados como um dos principais contribuintes no sequestro de carbono e na mitigação dos efeitos das mudanças climáticas globais. Assim, as estimativas quantitativas da distribuição espacial e temporal do PPB de áreas vegetadas são fatores importantes no monitoramento das trocas de carbono em uma região (GITELSON et al., 2008). Existem diversos métodos destinados à quantificação do carbono estocado na vegetação, dentre os quais destaca-se o método da covariância de vórtices turbulentos (LI et al., 2007, SHIM et al., 2014). Apesar de sua elevada acurácia na quantificação do CO₂ fixado pelas plantas, seu custo de aquisição e operacional torna seu uso restrito para alguns pesquisadores. Outro fator que torna o método limitado é sua representatividade, pois sua área de abrangência cobre apenas alguns quilômetros quadrados próximos aos equipamentos de coleta de dados (SILVA et al., 2013).

Uma alternativa para contornar estas limitações é a aplicação do sensoriamento remoto utilizando imagens de satélite, com ampla cobertura espacial, baixo custo e maior operacionalidade. As estimativas de sensoriamento remoto da produção primária terrestre evoluíram significativamente nas últimas décadas, e os conjuntos de dados resultantes fornecem as informações necessárias sobre a emissão de CO₂ na atmosfera (PAN et al., 2014). Devido à alta variabilidade de tipos de alvos, bem como suas características espectro-temporais, a medição de CO₂ é muito desafiadora em grandes áreas. Entretanto, produtos derivados do sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*), tais como o produto MOD17A2, vêm fornecendo estimativas consistentes no processo de monitoramento do PPB em grandes escalas (ZHAO e RUNNING, 2010). Porém, sua baixa resolução espacial pode ser um fator limitante em locais com características mais heterogêneas, como talhões agrícolas, pastagens ou fragmentos de mata, onde existe a presença de áreas menores ou próximas à área de um *pixel* do MODIS (2.5 ha). Uma alternativa para contornar estas limitações é a utilização de séries temporais do satélite Landsat 8 para o cálculo de PPB.

Uma abordagem utilizada para o cálculo de PPB em dados Landsat 8 é a metodologia proposta por Silva et al. (2013). Ela aponta que sua determinação por sensoriamento remoto pode ser realizada pela combinação entre o modelo de estimativa da Radiação Fotossinteticamente Ativa Absorvida - RFAA pela vegetação, proposto por Monteith (1972), e o modelo de eficiência de uso da luz na fotossíntese de Field et al. (1995), adaptado por Bastiaanssen e Ali (2003). Ambos os modelos sugerem a aplicação da fração evaporativa (FE) que é definida pela razão entre o fluxo de calor latente e o saldo de radiação para determinar as necessidades hídricas e evapotranspiração.

O algoritmo *Surface Energy Balance Algorithm for Land* (SEBAL), proposto por Bastiaanssen (1998), tem se mostrado muito eficiente em estimar parâmetros ligados ao cálculo da PPB em escalas regional e global (BASHIR et al., 2008). Porém, o processamento dos dados de sensoriamento remoto para grandes áreas em longos intervalos de tempo demanda elevada capacidade de armazenamento e processamento, os quais impactam diretamente na aplicação de modelos como o SEBAL. Nesse sentido, a plataforma *Google Earth Engine* (GEE) possibilita o processamento de informações geoespaciais em larga escala, a partir da computação de alto desempenho em nuvem e do acesso a um vasto acervo de dados orbitais (GORELICK et al., 2017).

Vale ressaltar que existem poucos trabalhos que fazem a utilização de processamento em nuvem para cálculo de PPB em escalas mais finas como as do satélite Landsat 8. Neste contexto, este trabalho visou implementar na plataforma GEE um algoritmo para calcular e mapear a PPB para o Landsat 8 OLI/TIRS (PPB_{L8}) e avaliar a dinâmica da PPB para diferentes tipos de cobertura do solo no período de dois anos-safra (2019/2020 e 2020/2021) no município de Cascavel-PR. Também foi avaliada a acurácia do modelo PPB_{L8} em relação aos dados de PPB do Sensor MODIS produto MOD17A2 (PPB_{MOD}).

6.2.2 MATERIAL E MÉTODOS

6.2.2.1 Área de estudo

O município de Cascavel-PR, utilizado como objeto neste estudo, possui uma área de 2091 km² localizada na região Oeste do estado. É uma região de grande produção agrícola Paranaense, principalmente em soja e milho (JOHANN et al., 2012; FRANÇA JÚNIOR et al., 2015). O solo da região é classificado como Latossolo Vermelho Distroférico (EMBRAPA, 2013). O clima da região é classificado subtropical

mesotérmico (Cfa) segundo a classificação de Köppen, com temperatura anual média de 18,5 a 22,9 °C e precipitação anual de 1200 a 1800 mm (APARECIDO et al., 2016).

6.2.2.2 Seleção de dados da estação meteorológica

Para o cálculo de PPB_{L8} , por meio do modelo SEBAL, foi necessária a aquisição de alguns dados das variáveis, tais como temperatura média do ar (T_{med} em °C), temperatura média do ar do mês de maior NDVI no ano (T_{mod} em °C), velocidade do vento (em m/s) e radiação solar global ($W m^{-2}$). Estes dados assim como os valores de precipitação foram obtidos em uma estação meteorológica do SIMEPAR, localizada na área rural do município de Cascavel-PR (Figura 12, coordenada -24,88 e -53,55).

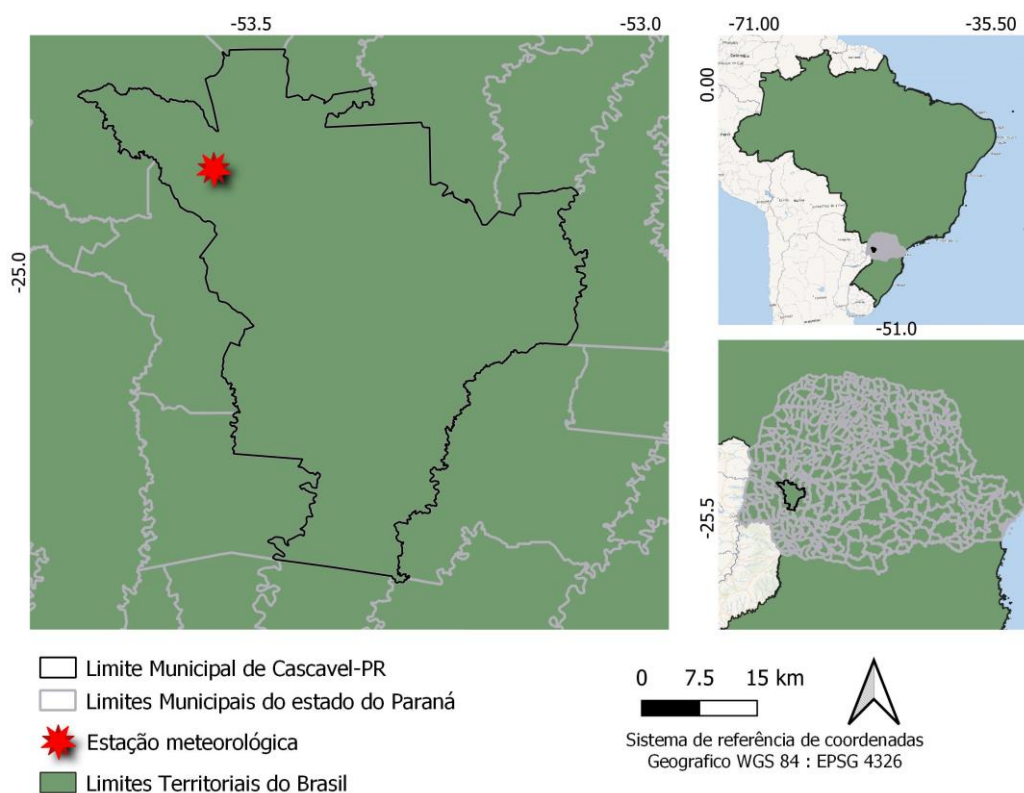


Figura 12. Estação meteorológica da área de estudo

Tendo em vista que a região de estudo apresenta grande variabilidade em relação às datas de semeadura e colheita tanto para as culturas de verão como para as de inverno (Tabela 10), devido à presença de variações de clima, solo ou variáveis agrometeorologias como precipitação e temperatura, foram coletados dados que abrangessem a safra de verão (soja e milho 1ª safra) e inverno (milho 2ª safra e cultivos de inverno – trigo, aveia, cevada e sorgo), para os anos-safra de set-2019/set-2020 e set-2020/set-2021.

Tabela 10. Calendário agrícola do Paraná para Soja, Milho 1^a e 2^a safras e culturas de inverno

Culturas		set	out	nov	dez	jan	fev	mar	abr	mai	jun	jul	ago
Soja	Semeadura	x	x										
	Colheita					x	x	x					
Milho 1 ^a	Semeadura	x	x	x									
	Colheita						x	x	x	x			
Milho 2 ^a	Semeadura					x	x	x					
	Colheita									x	x	x	
Culturas de inverno	Semeadura								x	x	x	x	x
	Colheita	x	x	x									x

Fonte: Adaptado de SEAB; DERAL, (2019).

6.2.2.3 Seleção e processamento de dados orbitais

Foram utilizadas imagens provenientes de dois satélites, um deles o Landsat 8, sensores OLI (*Operational Land Imager*) e TIRS (*Thermal Infrared Sensor*) e satélite TERRA, sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*).

As imagens Landsat 8 foram adquiridas a partir da Plataforma GEE, utilizando a coleção de imagens nível 1 que apresentam os dados em valores de radiância. As bandas do sensor OLI, bandas multiespectrais com resolução espacial de 30 metros (banda 2 a 7) e a termal com resolução espacial de 100 m (banda 10) foram utilizadas para o cálculo das métricas de PPB_{L8}, IV's e os demais parâmetros do SEBAL. Para este estudo, a cena Landsat 8 foi selecionada, que corresponde à órbita/ponto 223/077, onde está contido o município de Cascavel.

As cenas que abrangeram o intervalo de dois anos-safra (01/09/2019 a 01/09/2021) foram selecionadas a partir do banco de dados. As imagens correspondentes a este período foram filtradas utilizando os parâmetros da banda de qualidade (ZHU; WOODCOCK, 2012; ZHU; WANG; WOODCOCK, 2015), distribuída juntamente com as imagens de refletância da superfície. E, apenas imagens que apresentavam menos de 20% de cobertura de nuvens foram selecionadas. Posteriormente, as imagens filtradas foram analisadas tanto individual como visualmente para eliminar as cenas que continham nuvens no local de estudo.

Após o pré-processamento, foram obtidas quinze imagens para o período de estudo, da seguinte maneira: uma imagem para o ano de 2019 (30/09/2019), oito imagens para o ano de 2020 (20/01/2020, 24/03/2020, 09/04/2020, 25/04/2020,

27/05/2020, 12/06/2020, 31/08/2020, 02/10/2020) e seis imagens para o ano de 2021 (07/02/2021, 11/03/2021, 28/04/2021, 01/07/2021, 08/02/2021, 18/08/2021).

Para o cálculo de PPB_{mod} , foi utilizado um dos produtos do satélite TERRA sensor MODIS (MOD17A2H). Este produto é composto por uma banda com o cumulativo de PPB de oito dias em uma resolução de 500 metros e expresso em Kg de carbono por metro quadrado ($Kg.C.m^{-2}$). As imagens foram obtidas pela plataforma GEE e selecionadas no intervalo de dois anos-safra (01/09/2019 a 01/09/2021) em datas próximas às obtidas para as imagens do satélite Landsat 8.

Em vista disso, foram obtidas uma imagem para o ano de 2019 (30/09/2010), oito imagens para o ano de 2020 (01/01/2020, 21/03/2020, 06/04/2020, 22/04/2020, 24/05/2020, 06/09/2020, 28/08/2020 e 29/09/2020) e cinco imagens para o ano de 2021 (10/02/2021, 14/03/2021, 01/05/2021, 04/07/2021, 08/05/2021 e 21/08/2021). O cálculo da PPB_{L8} (Equação (18)) baseia-se no método proposto por Silva et al. (2013), no qual os autores sugerem que a obtenção de PPB por sensoriamento remoto pode ser obtida pela combinação entre o modelo de estimativa da radiação fotossinteticamente ativa absorvida pela vegetação (RFAA), proposto por Monteith (1972), e o modelo de eficiência no uso da luz proposto por Field et al. (1995) adaptado por Bastiaanssen e Ali (2003). Os autores sugerem o emprego da fração evaporativa (FE) como elemento quantificador do status da água pela vegetação. A obtenção da fração evaporativa decorre da aplicação sequencial em imagens de satélites do algoritmo SEBAL.

$$PPB_{OLI/TIRS} = RFAA \times \varepsilon = RFA \times FPAR \times \varepsilon \quad (18)$$

Em que PPB_{L8} é a Produção Primária Bruta dos sensores OLI/TIRS, RFAA é a radiação fotossinteticamente ativa absorvida pela vegetação ($W m^{-2}$) e ε é a eficiência do uso da luz da vegetação ($g C w^{-1}$). A RFA é a radiação fotossinteticamente ativa (Wm^{-2}) e FPAR é a fração da radiação RFA que é absorvida pela vegetação ($W m^{-2}$). A radiação fotossinteticamente ativa ($W m^{-2}$) compreende a região espectral de 400 a 700 nm e pode ser estimada como uma fração da radiação solar global diária. Na ausência de medições *in loco* da RFA, pode-se estimá-la em função da radiação solar global, ou seja, $RFA = 0,48 \times R_{S_{24h}}$ (BASTIAANSEN e ALI, 2003), em que $R_{S_{24h}}$ é a radiação solar global diária ($W m^{-2}$). Já a radiação fotossinteticamente ativa absorvida ($W m^{-2}$), segundo Bastiaanssen e Ali (2003) e Silva et al. (2012), pode ser expressa em função do Índice de Vegetação da Diferença Normalizada (NDVI):

$$RFFA = RFA \times (-0.161 \times 1.25 \times NDVI) \quad (19)$$

A eficiência do uso de luz - ε ($g \cdot C \cdot w^{-1}$), embora dependa de outros elementos da comunidade vegetal, pode ser quantificada pelo modelo de Field et al. (1995), modificado por Bastiaanssen e Ali (2003):

$$\varepsilon = \varepsilon' \times T1 \times T2 \times FE \quad (20)$$

Em que ε' é a eficiência máxima de uso da luz pela vegetação, 2,5 ($g \cdot w^{-1}$), indicado por Bastiaanssen e Ali (2003), para a maioria das plantas (C3 e C4); FE é a fração evaporativa; T1 e T2 refletem a contribuição da temperatura na eficiência de uso da luz pelas plantas. Assim, a partir dos dados obtidos por meio de estações meteorológicas, temperatura média diária (T_{med}), temperatura média no mês de maior NDVI (T_{opt}) e radiação solar global diária (RS_{24h}) (Tabela 11), foram calculados os valores de T1 e T2 e os valores de RFA.

Tabela 11. Datas das imagens OLI/TIRS, valores de temperatura média (T_{med}), temperatura média no mês de maior NDVI (T_{opt}) e radiação solar global

Data	RS_{24h} ($W \cdot m^{-2}$)	T_{opt} ($^{\circ}C$)	T_{med} ($^{\circ}C$)	T1	T2
30/09/2019	315.10	28.5	26.3	0.96	0.93
20/01/2020	350.12	27.1	26.2	0.97	0.92
24/03/2020	335.10	27.1	23.7	0.97	0.91
09/04/2020	320.15	27.1	18.8	0.97	0.93
25/04/2020	280.15	27.1	20.5	0.97	0.92
27/05/2020	233.10	27.1	14.3	0.97	0.92
12/06/2020	212.25	27.1	23.1	0.97	0.91
31/08/2020	360.86	27.1	24.8	0.97	0.94
02/10/2020	363.24	27.1	27.5	0.97	0.91
07/02/2021	403.12	26.5	21.4	0.97	0.92
11/03/2021	362.10	26.5	24.5	0.97	0.92
28/04/2021	263.45	26.5	17.1	0.97	0.93
01/07/2021	224.10	26.5	10.0	0.97	0.91
02/08/2021	328.16	26.5	15.7	0.97	0.91
18/08/2021	395.16	26.5	26.5	0.97	0.92

A variável Fração evaporativa (FE) representa a contribuição do elemento água na fotossíntese e foi determinada com base no balanço de energia através do modelo SEBAL (ALLEN et al., 2002), de acordo com a equação:

$$FE = \frac{LE}{(Rn - G)} \quad (21)$$

Em que R_n é o saldo de radiação e é obtido em $W m^{-2}$, G é a densidade do fluxo de calor no solo obtido em $W m^{-2}$ e LE é a densidade do fluxo de calor latente obtido em $W m^{-2}$. O fluxo de calor latente (LE) foi calculado como resíduo do balanço de energia à superfície, segundo a expressão:

$$LE = R_n - G - H \quad (22)$$

As variáveis saldo de radiação (R_n), fluxo de calor no solo (G), fluxo de calor sensível (H), fluxo de calor latente (LE) e fração evaporativa (FE) foram obtidas por meio do algoritmo SEBAL, proposto por Bastiaanssen et al. (1998). Todos os cálculos que envolvem estas etapas (R_n , G , H , LE e FE) foram desenvolvidos na plataforma GEE devido às vantagens que esta plataforma apresenta. São exemplos de vantagens: disponibilidade dos bancos de dados de imagens Landsat 8 em diferentes níveis de aquisição, menor demanda computacional nas etapas de pré-processamento e tratamento de imagens e menor demanda computacional para o cálculo das variáveis do modelo SEBAL, pois utiliza o processamento em nuvem.

Os dados das imagens MOD17A2H foram utilizados para comparação com a $PPB_{OLI/TIRS}$. Conforme sugerem Heinsch et al. (2003), os números digitais da imagem MODIS devem ser convertidos para valores biofísicos ($kg C m^{-2} dia^{-1}$), pela multiplicação pelo fator de escala (0,0001). Os valores de PPB_{MODIS} também devem ser transformados para valores de PPB diários, pois as imagens PPB_{MODIS} são um acumulado do período de oito dias. Para isto, deve-se dividir o valor de PPB_{MODIS} por oito (8) e posteriormente multiplicado por 1000 para que se obtenha o valor biofísico em $g C.m^{-2}.dia^{-1}$.

$$PPB_{MODIS} = \text{Fator de escala} \times \text{valor digital} \quad (23)$$

Em que o fator de escala = 0,0001 ($kg C m^{-2}$) e valor digital é o valor numérico de um *pixel* de arquivo.

6.2.2.4 Avaliação dos resultados

Um vetor contendo 300 pontos foi criado para avaliar os resultados, em que foram identificadas 100 feições para classe Mata, 100 feições para classe Pastagem e 100 feições para classe Agricultura. Na identificação e distinção dos alvos, foram utilizadas imagens composição RGB-564 (falsa cor) do sensor OLI, imagens de NDVI e imagens do *Google Earth*. Para a coleta destas amostras, foram selecionadas áreas que apresentassem *pixels* puros em ambas as resoluções de 30 metros para PPB_{L8} e 500 metros para PPB_{MOD} (Figura 13).

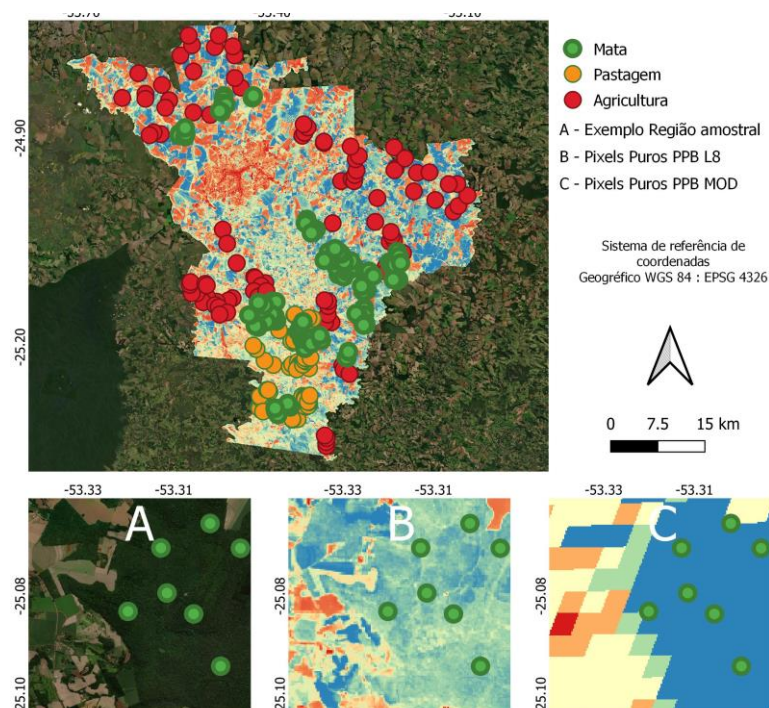


Figura 13. Pontos amostrais de classes. A – Imagens do *Google Earth* com exemplos de amostragem; B – Imagem com *pixels* puros para PPB_{L8}; C Imagem com *pixels* puros para PPB_{MOD}.

Para a comparação entre o modelo de PPB_{OLI/TIRS} e os valores derivados do produto PPB_{MODIS}, métricas estáticas foram utilizadas, tais como teste de correlação de Spearman (r_s), raiz quadrada do erro médio (RMSE) (24) e o índice refinado de Wilmott (d_r) (Equação (25)) (WILLMOTT; ROBESON; MATSUURA, 2012). O RMSE tem o objetivo de medir a dimensão dos erros entre os valores estimados de PPB_{L8} e os valores observados de PPB_{MOD}, e o d_r indica o grau de afastamento dos valores estimados em relação aos observados. O índice d_r é variável de -1 a 1. Valores próximos a um (1) indicam uma boa concordância entre valores observados e preditos; d_r próximo ou menor que zero (0) representam discordância entre os valores (WILLMOTT; ROBESON; MATSUURA, 2012).

$$\text{RMSE} = \sqrt{\frac{1}{n} * \sum_{i=1}^n (O - E)^2} \quad (24)$$

$$d_r = 1 - \frac{\sum_{i=1}^n |O - E|^2}{\sum_{i=1}^n (|E - \bar{O}| + |O - \bar{O}|)^2} \quad (25)$$

em que, n é o número de *pixels*; O são os valores de $\text{PPB}_{\text{MODIS}}$ da imagem MOD17A2H; E são os valores de $\text{PPB}_{\text{OLI/TIRS}}$ da imagem Landsat 8 e \bar{O} são os valores médios PPB_{mod} da imagem MOD17A2H.

6.2.3 RESULTADOS E DISCUSSÃO

Intervalos foram definidos de acordo com as seguintes safras: safras de verão (Soja e Milho 1ª safra) e safras de inverno (Milho 2ª safra, trigo e Sorgo) para quantificar os volumes de precipitação. O valor acumulado de precipitação para as safras de verão do primeiro ano agrícola avaliado (2019/2020) foi de 665,2 mm, intervalo de 01/09/2019 a 15/02/2020 e de 529,2 mm para a segunda safra e culturas de inverno (15/01/2020 a 01/09/2020). Para o segundo ano agrícola avaliado (2020/2021), os valores de precipitação acumulados são de 409,1mm para primeira safra de verão (01/09/2020 a 15/02/2021) e 704,4mm para a segunda safra e culturas de inverno (15/01/2021 a 01/09/2021).

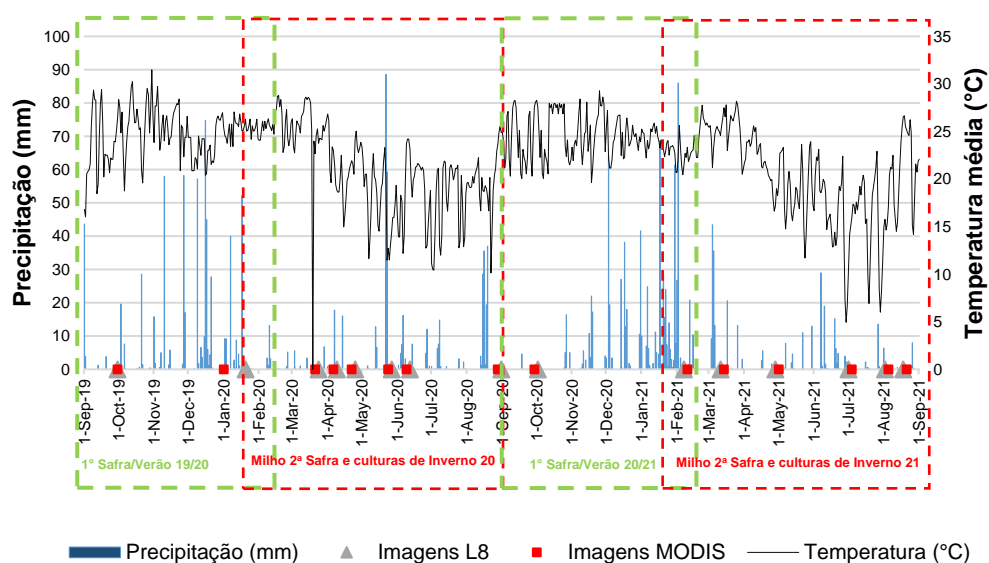


Figura 14. Gráfico de precipitação e de temperatura para as safras 2019/2020 e 2020/2021.

Os valores de média de PPB_{L8} e PPB_{MOD} para diferentes tipos de alvos (Figura 15) apontam similaridades quanto à amplitude de valores ao longo da série temporal, para as três classes de vegetação observadas (Mata, Pastagem e Agricultura), com valores de máximos e mínimos em datas coincidentes para os dois modelos observados.

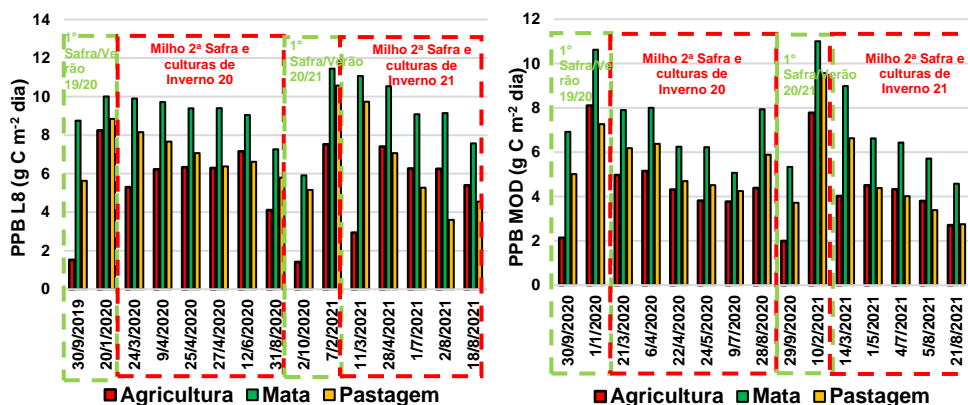


Figura 15. Valores médios de PPB_{L8} e PPB_{MOD} para diferentes datas de observação.

Para a classe Agricultura, é possível observar alta dispersão entre os valores de média de PPB_{L8} e PPB_{MOD} , com coeficientes de variação (CV) 63,51% e 43,20%, respectivamente, para os valores médios coletados ao longo das quatro safras.

A elevada variação de valores de PPB para alvos agrícolas está atrelada aos ciclos das culturas temporárias implantadas na região (Tabela 10), que apresentam baixos valores de PPB ao início de ciclo. E, à medida que a cultura anual se estabelece nos campos, são apresentados maiores valores de PPB, e retornam a patamares mais baixos de PPB quando os cultivos entram em estágios de senescência.

Os valores mínimos de médias de PPB para a classe Agricultura foram registrados no início das safras, com médias mínimas variando em torno de 1,93 g.C.m⁻².dia (30/09/19 e 02/10/20) para PPB_{L8} e 2,01 Kg.C.m⁻².dia (30/09/19 e 29/09/20), para PPB_{MOD} . Segundo o ZARC (Zoneamento agrícola de risco climático) publicado pelo governo federal (MAPA, 2022), o município de Cascavel encontra-se na zona edafoclimática 201 da Macroregião 2. Aqui é indicada a semeadura de soja e milho na primeira safra, no primeiro e segundo decêndios de setembro, visando à diminuição de riscos atrelados a diversos fatores agroclimáticos. Neste sentido, é possível atrelar os baixos valores de PBB aos períodos de entressafra (meses de agosto e setembro dos anos de 2019, 2020 e 2021), quando há predominância de áreas de solo exposto ou culturas de inverno como aveia, trigo, sorgo ou outras gramíneas de inverno estão em fase de senescência.

Os valores máximos de PPB_{L8} para a classe Agricultura foram de 8.05 $\text{Kg.C.m}^{-2}.\text{dia}$ em 20/01/20 e 7.82 $\text{Kg.C.m}^{-2}.\text{dia}$ em 07/02/21. Assim como os valores máximos de PPB_{MOD} para a classe Agricultura foram encontrados em datas próximas (01/01/20 e 10/02/21), com valores na faixa de 8.04 e 7.49 $\text{Kg.C.m}^{-2}.\text{dia}$, respectivamente. A classe Mata apresentou as maiores amplitudes de valores de PPB em ambos modelos de observação em relação às classes de vegetação observadas, com amplitudes de médias que variaram entre 5.48 $\text{Kg.C.m}^{-2}.\text{dia}$ (02/10/20) e 11.66 $\text{Kg.C.m}^{-2}.\text{dia}$ (07/02/21) para PPB_{L8} e 5.43 $\text{Kg.C.m}^{-2}.\text{dia}$ (29/09/20) e 11.32 $\text{Kg.C.m}^{-2}.\text{dia}$ (10/02/21) para PPB_{MOD} . A classe Mata apresentou os menores coeficientes de variação ao longo do período de pesquisa, com CV's de 16.35% para PPB_{L8} e 32,54% para PPB_{MOD} . É possível observar que os menores valores de PPB para a classe Mata, em ambos os modelos, são obtidos em períodos quando há um baixo volume acumulado de precipitação e os valores máximos de PPB ocorrem em períodos de maior disponibilidade hídrica.

A classe Pastagem em relação às médias, durante o período observado, obteve CV's de 31,93% e 37,10% para PPB_{L8} e para PPB_{MOD} , respectivamente. Sua distribuição temporal de valores de PPB foi muito semelhante em ambos os modelos, com amplitudes de média de PPB que variaram entre 3.81 $\text{Kg.C.m}^{-2}.\text{dia}$ (02/08/20) e 9.85 $\text{Kg.C.m}^{-2}.\text{dia}$ (07/02/21) para PPB_{L8} , e 2,91 $\text{Kg.C.m}^{-2}.\text{dia}$ (21/08/21) a 9.42 $\text{Kg.C.m}^{-2}.\text{dia}$ (10/02/21) para PPB_{MOD} . Destaca-se que o comportamento encontrado neste estudo é semelhante ao encontrado por outros trabalhos em diferentes regiões do Brasil, com maiores valores de carbono fixado pelas pastagens em estação úmida e menores na estação seca (SANTOS e FERREIRA, 2017; VELOSO et al., 2020).

Observa-se a importância da manutenção da qualidade das pastagens, principalmente porque elas cobrem cerca de 164 milhões de hectares no território (rígido) brasileiro, ou seja, representam 3/4 das áreas agrícolas que funcionam como eficientes estoques de carbono (ROSA et al., 2014). Em estudos da variabilidade temporal de NDVI e PPB em turfeiras (Alvos perenes), McPartland et al. (2018) identificaram redução geral de NDVI e PPB em locais de estiagem, e valores maiores de NDVI e PPB em locais onde havia maior disponibilidade de água. Logo, é possível destacar que os alvos perenes identificados na área em estudo (Pastagem e Mata) apresentaram maiores valores de PPB em períodos de maior valor acumulado de precipitação para ambos os modelos observados. Ribeiro et al. (2018), ao avaliarem a evapotranspiração e os fluxos de carbono em feijão de sequeiro, sugerem que a intensa troca de água com a atmosfera é fator crucial para a absorção de carbono,

pois possuem comportamentos proporcionais. Ou seja, quanto maior a taxa de perda de água, maior o sequestro de carbono atmosférico.

A partir da espacialização de PPB_{L8} e PPB_{MOD} (Figura 16 e Figura 17), podem-se observar as mudanças espacial e temporal das variáveis em estudo. Visualmente, as imagens que apresentaram maiores valores de PPB (Figura 16 – 2, Figura 16 – 10, Figura 17 -2 e Figura 17 - 10), períodos em que a predominância de valores de PPB foram superiores a 6,40 Kg.C.m⁻².dia para mais de 60% da área total municipal, para as quatro imagens observadas. Nas imagens que apresentam as menores médias gerais de PPB (Figura 16 – 1, Figura 16 – 9, Figura 17 -1 e Figura 17 – 9), observam-se valores inferiores a 3.20 Kg.C.m⁻².dia para mais de 43,3% da área total municipal em todos os casos.

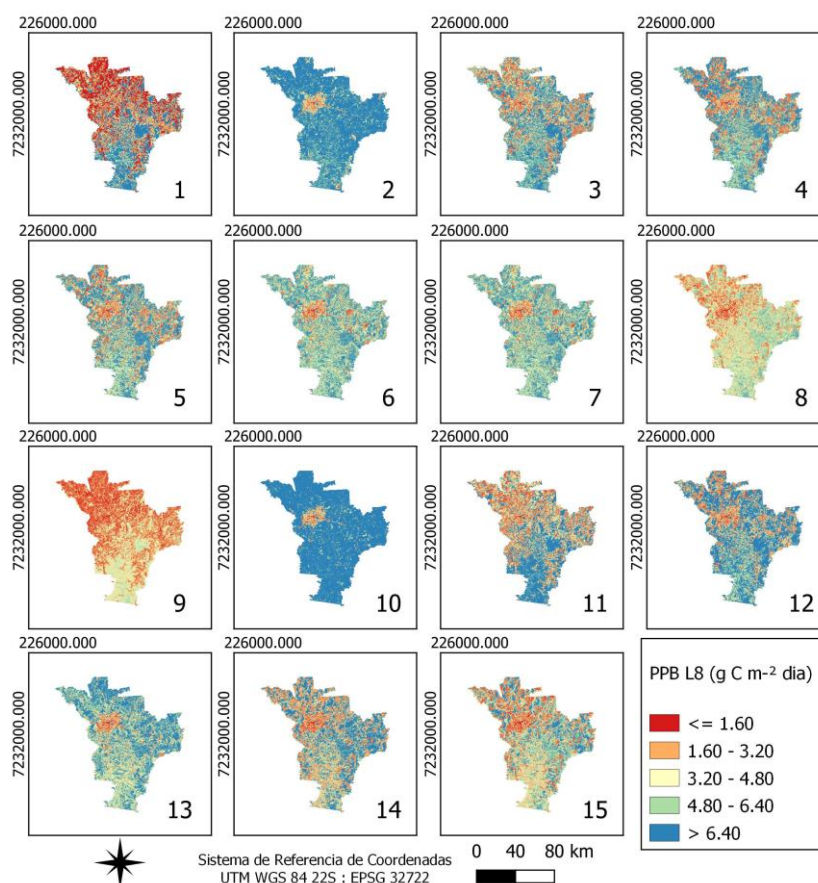


Figura 16. Produção primária bruta Landsat 8 (PPB_{L8}) para o município de Cascavel-PR, para os dias (1) 30/09/19, (2) 20/01/2020, (3) 24/03/2020, (4) 09/04/2020, (5) 25/04/2020, (6) 27/05/2020, (7) 12/06/2020, (8) 31/08/2020, (9) 02/10/2020, (10) 07/02/2021, (11) 11/03/2021, (12) 28/04/2021, (13) 01/07/2021, (14) 08/02/2021, (15) 18/08/2021.

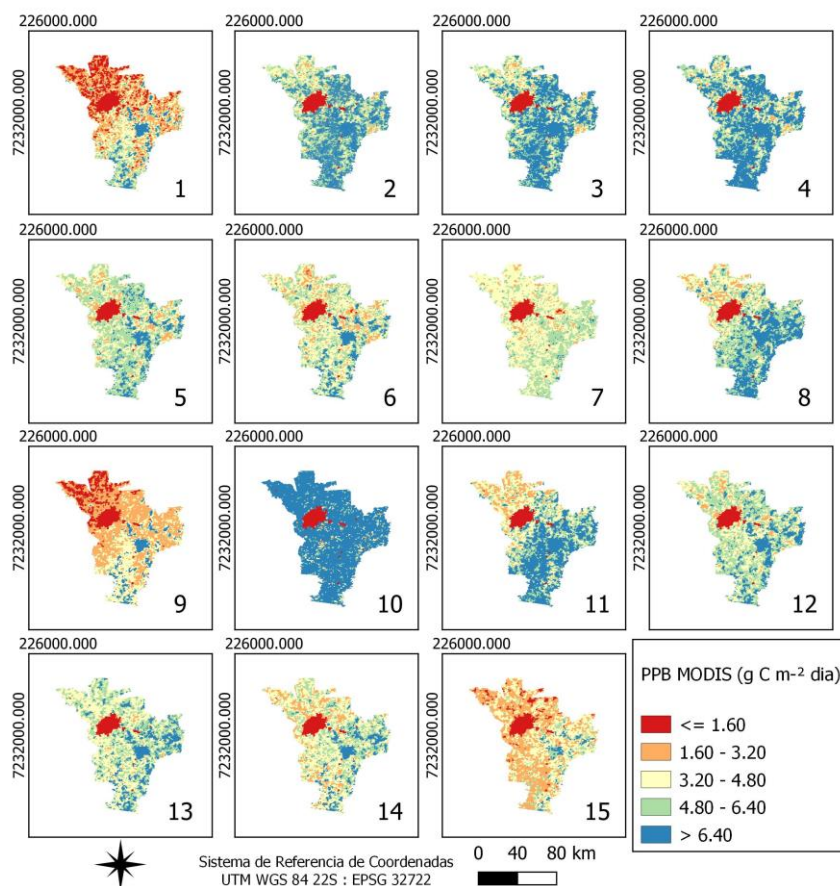


Figura 17. Produção primária bruta MODIS (PPB_{MOD}), para os dias (1) 30/09/19, (2) 01/01/2020, (3) 21/03/2020, (4) 06/04/2020, (5) 22/04/2020, (6) 24/05/2020, (7) 09/06/2020, (8) 28/08/2020, (9) 29/09/2020, (10) 10/02/2021, (11) 14/03/2021, (12) 01/05/2021, (13) 04/07/2021, (14) 08/05/2021, (15) 21/08/2021.

A análise de regressão e correlação dos dados PPB_{L8} em comparação aos dados do produto PPB_{MOD} , considerando todos os valores amostrados durante o período de estudo, (Figura 18 Figura 1 - A), apresentou valor de $r = 0.63$, valores superiores aos encontrados por Chagas et al. (2019). Esses autores avaliaram o desempenho de modelos de estimativa de PPB em dados dos sensores OLI/TIRS em comparação aos produtos do sensor MODIS, para diferentes tipos de uso e cobertura do solo na região amazônica, e obtiveram valores de coeficientes de correlação $R^2 = 0.28$ e $r = 0.53$ e $R^2 = 0.11$ e $r = 0.33$ para estações chuvosas e secas, respectivamente.

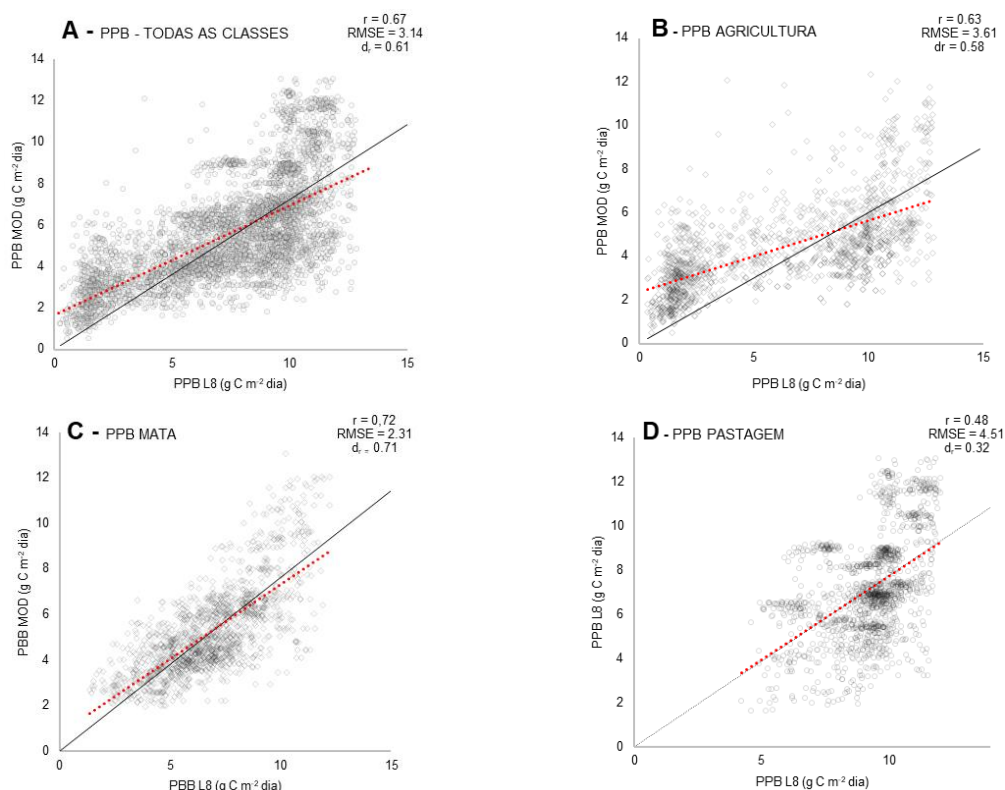


Figura 18. Dispersão de PPB_{L8} e PPB_{MOD} . (A) Todos os pontos e classes coletados nas 15 imagens observadas, (B) todos os pontos da classe “Agricultura” coletados nas 15 imagens observadas, (C) todos os pontos da classe “Mata” coletados nas 15 imagens observadas, (D) todos os pontos da classe “Pastagem” coletados nas 15 imagens observadas.

A partir da análise qualitativa do modelo, obteve-se a correlação dos modelos para cada tipo de alvo, considerando todas as observações no período de dois anos safra. Dentre os alvos observados, a classe Mata obteve os maiores valores de coeficiente de correlação $r = 0.72$, seguidos das classes Agricultura com $r = 0.63$ e Pastagem com $r = 0.48$. Portanto, é válido destacar que na região em estudo, as áreas amostradas como Mata e Agricultura apresentam características mais homogêneas quanto aos tipos de elementos presentes dentro de uma área amostrada. Em contrapartida, comumente, as regiões utilizadas como pastagem encontram-se em terrenos mais irregulares ou declivosos, com solos de baixa fertilidade ou impróprios para agricultura. Estes fatores levam à presença de áreas com formatos mais irregulares, proximidade com áreas de mata e corpos hídricos. Sendo assim, as áreas amostradas como a classe Pastagem, em alguns casos, apresentam alvos com características heterogêneas, tais como pequenos corpos hídricos como lagos e açudes, árvores, solo exposto ou construções rurais (Figura 19).

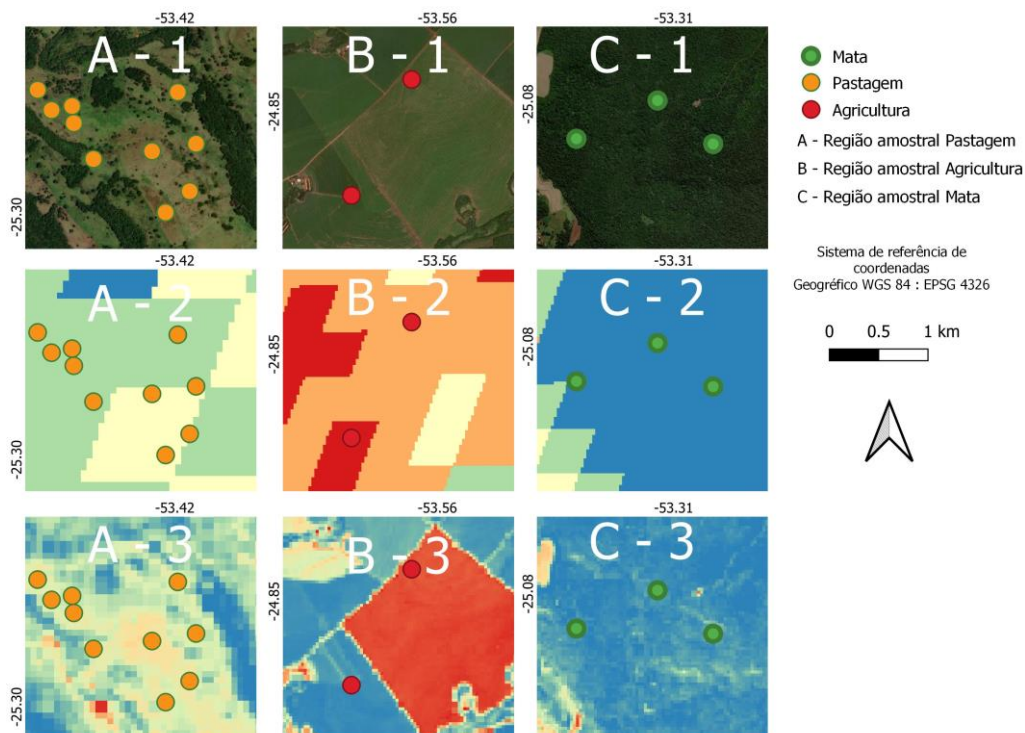


Figura 19. Pontos amostrados em diferentes tipos de alvos. A – (1 - amostras de pastagem imagens alta resolução, 2 – amostras pastagem imagens PPB_{MOD} , 3 – amostras pastagem imagens PPB_{L8}), B – (1 - amostras de agricultura imagens alta resolução, 2 – amostras agricultura imagens PPB_{MOD} , 3 – amostras agricultura imagens PPB_{L8}), C – (1 - amostras de mata imagens alta resolução, 2 – amostras mata imagens PPB_{MOD} , 3 – amostras mata imagens PPB_{L8}).

Estes elementos podem influenciar os valores de PPB em ambos os modelos, tanto para PPB_{MOD} com resolução espacial mais grosseira, quanto para PPB_{L8} com uma resolução espacial mais fina. Isso pode ser um dos fatores que levaram ao modelo a obter os menores valores de coeficientes de correlação dentre os alvos analisados, assim como o maior valor de raiz quadrada do erro médio (RMSE) igual a 4.51 e menor valor de coeficiente de Willmott (d_r) igual a 0.32.

O alvo agricultura, considerando todos os dados coletados durante o período amostrado, apresentou valor de correlação de $r = 0.63$, $RMSE = 3.61$ e $d_r = 0.68$. Este alvo apresentou alta variabilidade de valores ao longo dos dois anos-safra. Contudo, apresentou maior valor de correlação e de d_r e menores erros médios, quando comparado à classe Pastagem. Este fato pode ser atribuído às áreas amostradas como agricultura apresentarem maior homogeneidade.

Chagas et al. (2019) encontraram maior variabilidade nos resultados de PPB em áreas de uso extrativista e com ações antrópicas (extração de madeira, cultivos de castanha e extração de seringueiras) porque, nestes locais, foram encontrados padrões de fragmentação de remanescentes florestais, em que a Produção Primária

Bruta teve os valores alterados significativamente em relação a outros alvos semelhantes com características homogêneas.

A classe Mata obteve o maior valor de correlação $r = 0.72$, o menor valor de $RMSE = 2.31$ e o maior valor de $d_r = 0.71$, entre os alvos estudados. As áreas de mata amostradas apresentaram maiores valores de acurácia devido a alguns fatores característicos à classe, dentre eles a homogeneidade dos *pixels* nas áreas amostradas. Devido ao fato de ser uma cultura perene e apresentar menor variabilidade na amplitude de valores de PPB, baixa variabilidade de mudança de uso e cobertura para estes tipos de alvo. A Tabela 12 apresenta o resumo estatístico qualitativo entre os modelos PPB_{L8} e PPB_{MOD} e a avaliação dos modelos individualmente para cada data.

Tabela 12. Resumo estatístico da *Performance* dos modelos PPB_{L8} vs PPB_{MOD} , para cada data observada.

Data	r_s				RMSE				d_r			
	G	A	M	P	G	A	M	P	G	A	M	P
30/09/2019 PPB_{L8}	0.64	0.61	0.73	0.68	4.61	3.71	2.41	3.15	0.48	0.68	0.70	0.55
30/09/2019 PPB_{MOD}												
01/01/2020 PPB_{MOD}	0.55	0.58	0.62	0.43	4.18	5.71	3.15	4.22	0.48	0.65	0.71	0.53
20/01/2020 PPB_{L8}												
21/03/2020 PPB_{MOD}	0.60	0.58	0.61	0.55	3.12	2.14	2.55	4.01	0.68	0.65	0.60	0.61
24/03/2020 PPB_{L8}												
06/04/2020 PPB_{MOD}	0.62	0.48	0.63	0.43	4.31	3.9	2.42	3.22	0.67	0.52	0.71	0.48
09/04/2020 PPB_{L8}												
22/04/2020 PPB_{MOD}	0.65	0.58	0.64	0.50	4.81	4.12	3.05	4.18	0.62	0.6	0.6	0.58
25/04/2020 PPB_{L8}												
24/05/2020 PPB_{MOD}	0.67	0.61	0.68	0.55	3.24	3.01	3.21	4.12	0.63	0.65	0.71	0.52
27/05/2020 PPB_{L8}												
09/06/2020 PPB_{MOD}	0.75	0.69	0.78	0.68	2.15	3.01	1.41	4.01	0.72	0.68	0.83	0.65
12/06/2020 PPB_{L8}												
28/08/2020 PPB_{MOD}	0.51	0.61	0.63	0.54	4.61	3.02	3.24	4.12	0.52	0.58	0.61	0.53
31/08/2020 PPB_{L8}												
29/09/2020 PPB_{MOD}	0.53	0.48	0.61	0.44	4.12	2.28	3.12	4.22	0.61	0.52	0.71	0.49
02/10/2020 PPB_{L8}												
10/02/2021 PPB_{MOD}	0.70	0.72	0.75	0.68	2.31	2.16	2.01	3.01	0.71	0.65	0.75	0.73
07/02/2021 PPB_{L8}												
14/03/2021 PPB_{MOD}	0.62	0.65	0.68	0.61	4.71	2.27	2.11	3.12	0.61	0.69	0.76	0.63
11/03/2021 PPB_{L8}												
01/05/2021 PPB_{MOD}	0.5	0.48	0.49	0.48	4.18	3.19	3.01	4.52	0.51	0.53	0.54	0.45
28/04/2021 PPB_{L8}												
04/07/2021 PPB_{MOD}	0.43	0.47	0.50	0.41	3.55	4.12	3.18	4.31	0.51	0.55	0.61	0.43
01/07/2021 PPB_{L8}												
05/08/2021 PPB_{MOD}	0.55	0.53	0.56	0.51	3.78	3.12	2.51	3.29	0.61	0.68	0.7	0.58
02/08/2021 PPB_{L8}												
21/08/2021 PPB_{MOD}	0.49	0.53	0.63	0.46	4.01	3.15	2.82	3.89	0.61	0.68	0.71	0.58
18/08/2021 PPB_{L8}												

Nota: G = Considerando todas as classes observadas; A = agricultura; M = Mata; P = Pastagem. (r) – Coeficiente de correlação de Spearman, (RMSE) - raiz quadrada do erro médio, (dr) - coeficiente de Willmott,

Os modelos apresentaram coeficientes de correlação que variaram entre 0.43 e 0.75 ao serem observadas todas as classes simultaneamente, quando o valor máximo foi encontrado entre os modelos nos dias 09/06/2020 (PPB_{MOD}) e 12/06/2020 (PPB_{L8}). Nesta data, o RMSE apontou valores de erro na ordem de 2.15 g.C.m⁻².dia⁻¹, menor

erro relativo observado durante o período avaliado, assim como o maior valor de coeficiente de Willmott ($d_r = 0.72$).

A classe Mata apresentou os maiores valores de r e d_r para todas as datas avaliadas e apresentou, em grande parte das datas, os menores valores de RMSE. Os maiores valores de r , d_r e menor valor de RMSE foram obtidos para classe Mata para os dias 09/06/2020 (PPB_{MOD}) e 12/06/2020 (PPB_{L8}). São eles: 0.78, 0.74 e 1.41 g.C.m⁻².dia⁻¹. A classe Pastagem apresentou os menores valores de r e d_r e os maiores valores de RMSE dentre os alvos observados para todas as datas, com coeficientes de correlação que variaram entre 0.41 e 0.69. Assim, a partir da análise de cada imagem, observa-se que as classes de cobertura têm valores estatísticos qualitativos que corroboram com os encontrados ao se analisar a série histórica simultaneamente, quando se encontram os maiores valores de acurácia para classe Mata, e os menores valores de acurácia para classe Pastagem.

As maiores variabilidades de PPB encontradas em ambos os modelos podem ocorrer devido à baixa resolução do produto MOD17A2H (PPB_{mod}), que impede uma detecção precisa dos alvos na imagem em comparação às imagens dos sensores OLI/TIRS. Apesar das limitações do sensor MODIS, a utilização do produto MOD17A2H ainda se faz muito importante para observação de fluxos de carbono em uma escala global, pois fornece informações em uma escala de tempo relativamente curta (8 dias) e com boa confiabilidade nos valores de PPB.

Tendo em vista que outros modelos podem ter seus valores de entrada comprometidos, pois, apesar da dinâmica do carbono terrestre ser bem conhecida, ainda há uma grande incerteza de dados como fonte primária para os modelos que estimam a PPB em nível global ou regional (TRAMONTANA et al., 2015). A observação e os testes em microescalas podem auxiliar no entendimento da dinâmica e melhoria da acurácia dos modelos derivados dos sensores OLI/TIRS para estimativa de PPB. Posto que o monitoramento de valores referentes à pluviosidade, temperatura, radiação solar incidente e aos estádios fenológicos dos alvos pode auxiliar no ajuste dos modelos. Silva et al. (2013), ao avaliarem a PPB a partir de dados Landsat TM em áreas irrigadas e vegetação nativa, sugerem que os valores de PPB são superestimados ou subestimados devido aos valores de eficiência máxima do uso da luz.

6.2.4 CONCLUSÃO

Os valores de PPB_{L8} possibilitaram observar distinções nos tipos de cobertura da região, bem como identificar padrões sazonais de PPB_{L8} para área em estudo.

A classe Mata apresentou os maiores valores de acurácia dentre os tipos de cobertura a partir da avaliação dos conjuntos de dados, assim como ao serem analisados os modelos individualmente por data, além de ter apresentado os melhores resultados.

A diferença de resolução espacial entre as imagens pode diminuir a acurácia entre os modelos de PPB. Por fim, o algoritmo proposto, devido à sua aplicabilidade ao satélite Landsat 8 OLI/TIRS, pode ser útil para análises mais precisas de GPP para áreas locais em estudo, como bacias hidrográficas ou áreas florestais.

6.2.5 REFERÊNCIAS

ANAV, A.; FRIEDLINGSTEIN, P.; CERVEJA, C.; CIAIS, P.; HARPER, A.; JONES, C.; MURRAY-TORTAROLO, G.; PAPALE, D.; PARAZOO, N. C.; PEYLIN, P.; PIAO, S.; SITCH, S.; VIOVY, N.; WILTSHIRE, A.; ZHAO, M. Spatiotemporal patterns of terrestrial gross primary production: A review. **Rev. Geophys.** v. 3, p. 785-818, 2015.

APARECIDO, L. E. de O.; ROLIM, G. D. S.; RICHETTI, J.; SOUZA, P. S. de; JOHANN, J. A. Köppen, Thornthwaite and Camargo climate classifications for climatic zoning in the State of Paraná, Brazil. **Ciência e Agrotecnologia**, v. 40, n. 4, p. 405-417, 2016.

BASHIR, M. A.; HATA, T.; TANAKAMARU, H.; ABDELHAD, A. W.; TADA, A. Satellite-based energy balance model to estimate seasonal evapotranspiration for irrigated sorghum: a case study from the Gezira scheme, Sudan. **Hydrol. Earth Syst. Sci.** v. 12, p. 1129-1139, 2008.

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

BASTIAANSSEN, W. G. M. SEBAL-based sensible and latent heat fluxes in the irrigated Gediz Basin, Turkey. **Journal of Hydrology**, v. 229, p. 87-100, 2000.

BASTIAANSSEN, W. G. M.; MENENTI, M.; FEDDES, R. A.; HOLTSLAG, A. A. M. The surface energy balance algorithm for land (SEBAL): Part 1 formulation. **Journal of Hydrology**, v. 212-213, p. 198-212, 1998.

CHAGAS, M. C.; DELGADO, R. C.; SOUZA, L. P.; CARVALHO, D. C.; PEREIRA, M.G.; TEODORO, P.E.; SILVA JUNIOR, C. A. Gross primary productivity in areas of different land cover in the Western Brazilian Amazon. **Remote Sensing Applications: Society and Environment**. v. 16, p. 1-9, 2019.

EMBRAPA SOJA. **Tecnologia de produção de soja** - região central do Brasil – 2014. Londrina, PR, Brasil. Embrapa Soja, 2013.

FRANÇA JUNIOR, P.; VILLA, M. E. C. D.; VILLA, J. F. D. Características Geomorfológicas e a Produção De Culturas Temporárias No Estado Do Paraná-Brasil. **Revista Formação**, v. 1, n. 22, p. 71-86, 2015.

GITELSON, A.A.; VINA, A.; MASEK, J.G.; VERMA, S.B.; SUYKER, A.E. Synoptic monitoring of gross primary productivity of maize using Landsat data. **IEEE Geosci. Remote Sen. Lett.**, v.5, n. 2, p. 133-137, 2008.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017.

JOHANN, J. A.; ROCHA, J. V.; DUFT, D. G.; LAMPARELLI, R. A. C. Estimativa de áreas 51 com culturas de verão no Paraná, por meio de imagens multitemporais EVI/Modis. **Pesquisa Agropecuária Brasileira**, v. 47, n. 9, p. 1295-1306, 2012.

LI, Z. Q.; YU, G. R.; XIAO, X. M.; LI, Y. N.; ZHAO, X. Q.; REN, C. Y.; ZHANG, L. M.; FU, Y. L. Modeling gross primary production of alpine ecosystems in the Tibetan Plateau using MODIS images and climate data. **Remote Sens. Environ.** v. 107, n. 3, p. 510-519, 2007.

MAPA. **Zoneamento de risco Agrícola**, Disponível em:<<https://indicadores.agricultura.gov.br/zarc/index.htm>>, cessado: 27 de setembro 2019.

MCPARTLAND, M. Y.; KANE, E. S.; FALKOWSKI, R. K.; TURESTSKY, M. R.; PALIK, B.; MONTGOMERY, R. A. The response of boreal peatland community composition and NDVI to hydrologic change, warming, and elevated carbon dioxide. **Global Change Biology**. v. 25, n. 1, p. 93-107, 2018.

MONTEITH, J. L. Solar radiation and productivity in tropical ecosystems. **Journal of Applied Ecology**. v. 9, n. 3, p. 747-766, 1972.

PAN, S.; TIAN, H.; DANGAL, S. R. S.; OUYANG, Z.; TAO, B.; REN, W.; LU, C.; RUNNING, S. Modeling and monitoring terrestrial primary production in a changing global environment: toward a multiscale synthesis of observation and simulation. **Adv. Meteorol.** v. 2014, p. 1-17, 2014.

PINGINTHA, N.; LECLERC, M. Y.; BEASLEY JR, J. P.; DURDEN, D.; ZHANG, G.; SENTHONG, C.; ROWLAND, D. Hysteresis response of daytime net ecosystem exchange during drought. **Biogeosciences**, v. 7, n. 3, p. 1159-1170, 2010.

RIBEIRO, A. A.; LIMA, J. R. S.; SOUZA, R. M. S.; ANTONINO, A. C. D.; SOUZA, E. S. Fluxos de carbono e evapotranspiração de feijão comum sob condições de sequeiro. **Revista Engenharia na Agricultura**. v. 26, n. 03, p. 229-239, 2018.

ROSA, R.; SANO, E. E.; ROSENDO, J. dos S. Estoque de carbono em solos sob pastagens cultivadas na bacia hidrográfica do Rio Paranaíba. **Sociedade & Natureza**, v. 26, n. 2, p. 333-351, 2014.

SANTOS, P. S.; FERREIRA, L. G. Análise descritiva dos aspectos biofísicos associados aos padrões de cobertura e uso da terra na bacia hidrográfica do Rio Vermelho, bioma cerrado. **Geofocus: Revista Internacional de Ciencia y Tecnología de la Información Geográfica**, n. 20, p. 3-28, 2017.

SEAB; DERAL. **Previsão e Estimativa de Safras, 2018**. Disponível em: <http://www.agricultura.pr.gov.br/modules/conteudo/conteudo.php?conteudo=75>. Acesso em: 15 dez. 2019.

SILVA, B. B. et al. Determinação por sensoriamento remoto da produtividade primária bruta do perímetro irrigado São Gonçalo – PB. **Revista Brasileira de Meteorologia**, v. 28, n. 1, p. 57-64, 2013.

TRAMONTANA, G.; ICHII, K.; CAMPS-VALLS, G.; TOMELLERI, E.; PAPALE, D. Uncertainty analysis of gross primary production up-scaling using Random Forests, remote sensing and eddy covariance data. **Remot. Sensing of Environment**. v. 168, p. 360-373, 2015.

VASHUM, K. T.; JAYAKUMAR, S. Methods to Estimate Above-Ground Biomass and Carbon Stock in Natural Forests - A Review. **Journal of Ecosystem & Ecography**. v. 2, n. 4, p. 1-7, 2012.

VELOSO, G. A.; FERREIRA, M. E.; FERREIRA JÚNIOR, L. G.; SILVA, B. B. Modelling gross primary productivity in tropical savanna pasturelands for livestock intensification in Brazil. **Remote Sensing Applications: Society and Environment**, v. 17, p. 1-8, 2020.

WILLMOTT, C. J.; ROBESON, S. M.; MATSUURA, K. A refined index of model performance. **International Journal of Climatology**, v. 32, n. 13, p. 2088-2094, 2012.

ZHAO, M. AND RUNNING, S.W. Drought-induced reduction in global terrestrial net primary production from 2000 through 2009. **Science**, v. 329, p. 940-943, 2010.

ZHU, Z.; WANG, S.; WOODCOCK, C. E. Improvement and expansion of the F-mask algorithm: cloud, cloud shadow, and snow detection for Landsats 4–7, 8, and Sentinel 2 images. **Remot. Sensing of Environm.** v. 159, n. 15, p. 269-277, 2015.

ZHUE, Z.; WOODCOCK, C.E. Object-based cloud and cloud shadow detection in Landsat imagery. **Remot. Sensing of Environm.** v. 118, n. 15, p. 83-94, 2012.

7 Anexo I

7.1 Cálculos para obtenção do saldo de radiação (Rn)

7.1.1 Calibração radiometria

O primeiro passo do processo é composto pela Calibração radiometria.

$$L_{\lambda} = M_L + Q_{cal} + A_L \quad (26)$$

Em que M_L e A_L são fatores de redimensionamento multiplicativo e aditivo, respectivamente, para cada banda específica (ambos os fatores são fornecidos no arquivo metadados e são adimensionais); Q_{cal} são os valores de *pixel* calibrados padronizados ou números digitais (ND). As unidades de radiância espectral (L_{λ}) são dados em $W/m^2/sr/\mu m$.

7.1.2 Refletância em função do ângulo solar

Próxima etapa consiste no cálculo da refletância em função do ângulo solar para cada banda, para isto, é necessário primeiramente calcular a refletância planetária no topo da atmosfera ($\rho_{\lambda i}'$).

$$\rho_{\lambda i}' = M_p Q_{cal} + A_p \quad (27)$$

Em que M_p e A_p são fatores de redimensionamento multiplicativo e aditivo, respectivamente, para cada banda específica (ambos os fatores são fornecidos no arquivo metadados e são adimensionais); Q_{cal} são os valores de *pixel* calibrados padronizados ou números digitais (ND).

Posteriormente, calcula-se a refletância em função do ângulo solar (ρ_{λ}).

$$\rho_{\lambda} = \frac{\rho_{\lambda i}'}{\text{sen}(\theta_{ES})} \quad (28)$$

Em que $\rho_{\lambda i}'$ é a reflectância sem correção do ângulo solar; θ_{ES} é o ângulo local de elevação do sol.

7.1.3 Albedo no topo da atmosfera e na superfície

A próxima etapa consiste no cálculo do albedo no topo da atmosfera (α_{tda}) e o albedo da superfície (α).

$$\alpha_{tda} = \sum (\omega_{\lambda} x \rho_{\lambda}) \quad (29)$$

Em que ω_{λ} é o coeficiente de ponderação para cada banda, $\omega_{\lambda} = \frac{ESOL_{\lambda}}{\sum ESOL_{\lambda}}$, em que ESOL são as irradiâncias espectrais exoatmosféricas solares; ρ_{λ} são reflectâncias para cada banda.

$$\alpha = \frac{\alpha_{tda} - \alpha_{atm}}{\tau_{SW}^2} \quad (30)$$

α_{tda} é a parcela média de radiação solar incidente a qual é espalhada de volta para o satélite antes que a mesma alcance a superfície (0,03); τ_{SW}^2 é a transmissividade atmosférica, $\tau_{SW}^2 = 0,75 + 2 \times 10^{-5} z$; em que z é a altitude de cada pixel em metros (m), em que será utilizada imagem do SRTM e α_{tda} é o albedo do topo da atmosfera.

7.1.4 Índices de vegetação

Outra etapa para o cálculo de R_n é a obtenção dos índices de vegetação NDVI, SAVI, e do índice de área foliar (IAF). O NDVI (*Normalized Difference Vegetation Index*) é um indicador sensível da quantidade e condição da vegetação, cujos valores variam no intervalo de -1 a 1 (ROUSE 1974).

O Índice de Vegetação Ajustado para os efeitos do Solo (*Soil Adjusted Vegetation Index – SAVI*) é um índice muito similar ao NDVI, entretanto, leva em consideração efeitos do solo exposto e, por sua vez, ameniza os efeitos de reflectância do solo. Isto se ocorre a partir da inclusão de um fator de ajuste (L) que é variável com o grau de fechamento do dossel, e permite melhoria na interpretação das variáveis da vegetação (HUETE, 1988).

O Índice de Área Foliar (IAF) é definido pela razão entre a área foliar de toda a vegetação por unidade de área total da vegetação, e indica a biomassa de cada *pixel* da imagem (ALLEN et al., 2002).

$$NDVI = \frac{\rho_V - \rho_{IV}}{\rho_V + \rho_{IV}} \quad (31)$$

$$SAVI = \frac{(1 + L)(\rho_V - \rho_{IV})}{(L + \rho_V + \rho_{IV})} \quad (32)$$

$$IAF = -\frac{\left(\ln\left(\frac{0,69 - SAVI}{0,59}\right)\right)}{0,91} \quad (33)$$

7.1.5 Emissividade

Em posse dos valores de IAF, calculam-se as emissividades (ϵ), que foram obtidas através das seguintes equações (ALLEN et al., 2002).

$$\epsilon_{NB} = 0,97 + 0,0033.IAF \quad (34)$$

$$\epsilon_0 = 0,95 + 0,01.IAF \quad (35)$$

Em que *pixels* com NDVI e para corpos de água (NDVI<0) ϵ_{NB} e ϵ_0 assumem valores de 0,99 e 0,985, respectivamente, conforme recomendado por Allen, Tasumi e Trezza (2002).

7.1.6 Temperatura na superfície

Como parte da obtenção de R_n , deve-se calcular a Temperatura na superfície (T_s), em graus Kelvin (K), obtida em função da radiância espectral da banda 10 ($L_{\lambda t}$), a partir das seguintes equações disponibilizadas pelos Serviço Geológico Americano (USGS, 2015):

$$T_s = - \frac{T_b}{1 + \left(\frac{\lambda * T_b}{\rho}\right) \ln_2} \quad (36)$$

$\rho = \frac{h * c}{\sigma}$ em que, h e σ são constantes de Planck e Boltzmann, respectivamente com valores de $16,626 \times 10^{-34}$ e $1,38 \times 10^{-23} \text{ J.K}^{-1}$ e c é valor da velocidade da luz, $2,998 \times 10^8 \text{ m.s}^{-1}$. T_b é temperatura de brilho; λ é comprimento de onda da radiação emitida, $10,8 \mu\text{m}$ para banda 10 do Landsat 8. ϵ é a emissividade da superfície.

7.1.7 Radiação de onda longa emitida pela superfície

Em posse do valor de T_s , calculam-se os valores de radiação de onda longa emitida pela superfície ($R_{L\uparrow}$)

$$R_{L\uparrow} = \epsilon_0 \cdot \sigma \cdot T_s^4 \quad (37)$$

ϵ_0 é a emissividade de cada *pixel*, σ é a constante de Boltzman e T_s é temperatura de superfície.

$$R_{c\downarrow} = S \cdot \cos Z \cdot d_r \cdot \tau_{sw} \quad (38)$$

7.1.8 Radiação de onda curta incidente

S é a constante solar (1367 W m^{-2}), Z é o ângulo zenital solar, d_r é o inverso do quadrado da distância relativa Terra-Sol $d_r = 1 + 0,033 \cos\left(\frac{D_{SA} \cdot 2\pi}{365}\right)$ em que D_{SA} é o Dia Sequencial do ano.

$$R_{L\downarrow} = \epsilon_a \cdot \sigma \cdot T_a^4 \quad (39)$$

7.1.9 Radiação de onda longa incidente

ϵ_a é a emissividade atmosférica obtida por $\epsilon_a = 0,85 \cdot (-\ln \tau_{sw})^{0,09}$ (ALLEN; TASUMI; TREZZA, 2002), σ é a constante de Stefan-Boltzmann e T_a é a temperatura do ar (K).

Após a determinação de cada um de seus componentes, o saldo de radiação é calculado utilizando-se a equação:

$$R_n = (1 - \alpha)R_{c\downarrow} + R_{L\downarrow} - R_{L\uparrow} - (1 - \epsilon_0)R_{L\downarrow} \quad (40)$$

em que: R_n é o saldo de radiação (W m^{-2}), α é albedo da superfície (adimensional), $R_{c\downarrow}$ é a radiação de onda curta incidente (W m^{-2}), $R_{L\uparrow}$ representa a radiação de onda longa incidente (W m^{-2}), $R_{L\downarrow}$ é a radiação de onda longa emitida pela superfície (W m^{-2}), e ϵ_0 é a emissividade da superfície (adimensional).

7.2 Cálculos para obtenção do Fluxo de calor sensível (H)

7.2.1 Resistência aerodinâmica

Para início do cálculo do fluxo de calor sensível, são obtidas informações da estação meteorológica próxima à área estudada: velocidade do vento (u) (m s^{-1}) e altura média da vegetação (h)(m).

Dentre as variáveis para o cálculo de H está a resistência aerodinâmica ao transporte de calor r_{ah} ($s\ m^{-2}$). E, para obter-se o valor desta variável, deve-se efetuar o cálculo do valor de velocidade de fricção do vento (u^*), em que é necessária pelo menos uma leitura de velocidade do vento (u) da estação meteorológica da área de estudo, preferencialmente durante o intervalo de tempo coincidente com o horário da passagem do satélite.

Assim, a partir do conhecimento do parâmetro u na altura de sua medição, é possível a estimativa deste em outros níveis acima da superfície do solo. No SEBAL, o parâmetro u^* é computado usando o perfil do logaritmo do vento para a condição de estabilidade neutra:

$$u_* = \frac{k * u_x}{\ln\left(\frac{Z_x}{Z_{0m}}\right)} \quad (41)$$

$$Z_{0m} = 0,123 * h \quad (42)$$

em que: k é a constante de Von Karman (0,41), u_x é a velocidade do vento ($m\ s^{-1}$) na altura Z_x (Elevação local da estação meteorológica em m), Z_{0m} representa a rugosidade da superfície, a qual é dependente da altura da vegetação (h) que é expressa metros.

A partir do valor da velocidade de fricção do vento próximo à estação, calcula-se a velocidade do vento a 200 m de altitude (ALLEN, TASUMI e TREZZA, 2002). Nesta altitude, assume-se que os efeitos da rugosidade da superfície são desprezíveis, a chamada *blending height*.

$$u_{200} = u_* \frac{\ln\left(\frac{200}{Z_{0m}}\right)}{k} \quad (43)$$

em que: Z_{0m} é o coeficiente de rugosidade da superfície e pode ser obtido em função do índice de vegetação ajustado ao solo, segundo a equação desenvolvida por Bastiaanssen (2000).

$$Z_{0m} = \exp(5,809 + 5,62SAVI) \quad (44)$$

A partir dos valores de u^* calculados para cada *pixel*, estima-se a resistência aerodinâmica (r_{ah}) (em $s\ m^{-1}$).

$$r_{ah} = \frac{\ln\left(\frac{Z_1}{Z_2}\right)}{k * u_*} \quad (45)$$

7.2.2 Diferença de temperatura

O último passo consiste no cálculo de diferença de temperatura próxima à superfície dT (°C) para cada *pixel* dado pelo SEBAL através da relação linear entre dT e a temperatura da superfície (T_s) dos *pixels* “quente e frio”.

$$dT = a + b * T_s \quad (46)$$

em que: a e b são os coeficientes que precisam ser determinados a partir dos *pixels* quente e frio

O procedimento na escolha dos *pixels* âncora deve ser criterioso, a fim de se garantir que as condições extremas de fluxos de calor sejam bem representadas. O *pixel* frio deve ser escolhido em uma área de vegetação densa (preferencialmente área irrigada), com NDVI maior ou igual a 0,5 e IAF maior ou igual a seis, em que se assume que o fluxo de calor sensível (H) é nulo e o fluxo de calor latente (LE) é máximo, dado pela diferença entre R_n e G .

$$LE_{frio} = R_{n_{frio}} - G_{frio} \quad (47)$$

Desta forma, a diferença de temperatura do *pixel* frio é nula, devido à $H=0$, conforme mostrado na equação abaixo:

$$dT_{frio} = \frac{H_{rah}}{\rho C_p} = 0 \quad (48)$$

Por sua vez, o *pixel* quente é escolhido em uma área de solo exposto, preferencialmente com intensa atividade da ação antrópica, em que se assume fluxo de calor latente nulo (LE) e fluxo de calor sensível (H) máximo:

$$H_{quente} = R_{n_{quente}} - G_{quente} \quad (49)$$

A diferença de temperatura no *pixel* quente foi dada por:

$$dT_{\text{quente}} = \frac{(R_n - G)r_{ah}}{\rho C_p} \quad (50)$$

Com a obtenção das diferenças de temperatura nos *pixels* quente e frio, é possível a determinação dos coeficientes *a* e *b*, montando-se um sistema simples com duas equações e duas incógnitas:

$$dT_{\text{quente}} = b + aT_{s(\text{quente})} \quad dT_{\text{frio}} = b + aT_{s(\text{frio})} \quad (51)$$

A partir dos valores de diferença de temperatura e resistência aerodinâmica, os valores iniciais de calor sensível para cada *pixel* são determinados.

7.2.3 Comprimento de Monin-Obukhov

Os valores iniciais obtidos de *H* em cada *pixel* não são adequados e têm utilidade apenas como valor inicial do processo iterativo o qual, a cada iteração, tem por objetivo refinar o valor considerando efetivamente, resultando na condição de/ considerado efetivamente. O resultado é a condição de estabilidade atmosférica de cada *pixel*. Com isso, a identificação da estabilidade da atmosfera é realizada a partir da estimativa do comprimento de Monin-Obukhov (*L*):

$$L = \frac{\rho C_p u_* T_s}{kgH} \quad (52)$$

em que: C_p é o calor específico do ar (1004 J kg^{-1}), u_* é a velocidade fricção (m s^{-1}) em cada *pixel*, T_s é a temperatura da superfície (K) de cada *pixel*, k é a constante de Von Karman (0,41), g é a aceleração da gravidade ($9,81 \text{ m s}^{-2}$), H é o fluxo de calor sensível (W m^{-2}) obtido inicialmente em cada *pixel* e ρ é a densidade do ar, dada pela expressão:

$$L = 3,486 \frac{P}{T \left(1 - 0,378 * \frac{e_a}{P}\right)^{-1}} \quad (53)$$

em que: P é a pressão atmosférica na elevação z (kPa), T é a temperatura absoluta (K) e e_a é a pressão real de vapor (kPa), conforme descrito em Allen et al. (1998).

O comprimento de Monin-Obukhov está relacionado ao fluxo de calor sensível, pois assume valores negativos ($L < 0$) em condições instáveis (fluxo de calor sensível positivo) e valores positivos ($L > 0$) em condições estáveis (fluxo de calor sensível negativo), se $L = 0$ a atmosfera é considerada neutra.

Dependendo das condições atmosféricas, os valores de correção de estabilidade para o transporte de momentum (ψ_m) e de calor (ψ_h) deverão ser considerados. Para isto, são utilizadas as formulações abaixo (ALLEN; TASUMI; TREZZA, 2002):

- quando $L < 0$ (condição de instabilidade), tem-se que:

$$\Psi_{h(200m)} = 2 \ln\left(\frac{1 + x_{(200)}}{2}\right) + \ln\left(\frac{1 + x_{(200)}^2}{2}\right) - 2 \arctg(x_{(200)}) + 0,5 \pi \quad (54)$$

$$\Psi_{h(2m)} = 2 \ln\left(\frac{1 + x_{(2m)}^2}{2}\right) \quad (55)$$

$$\Psi_{h(0,1m)} = 2 \ln\left(\frac{1 + x_{(0,1m)}^2}{2}\right) \quad (56)$$

em que:

$$x_{(200m)} = \left(1 - 16 \frac{200}{L}\right)^{0,25} \quad (57)$$

$$x_{(2m)} = \left(1 - 16 \frac{2}{L}\right)^{0,25} \quad (58)$$

$$x_{(0,1m)} = \left(1 - 16 \frac{0,1}{L}\right)^{0,25} \quad (59)$$

quando $L > 0$ (condição de estabilidade):

$$\Psi_{h(200m)} = -5 \left(\frac{200}{L}\right) \quad (60)$$

$$\Psi_{h(2m)} = -5 \left(\frac{2}{L}\right) \quad (61)$$

$$\Psi_{h(0,1m)} = -5 \left(\frac{0,1}{L}\right) \quad (62)$$

Para quando a situação for $L = 0$, em condições neutras: ψ_m e $\psi_h = 0$.

O valor corrigido da velocidade de fricção u_* (m s^{-1}) é dado por:

$$u_* = \frac{u_{200}k}{\ln\left(\frac{200}{Z_{0m}}\right) - \Psi_{h(200m)}} \quad (63)$$

em que: u_{200} é a velocidade do vento a 200 m (m s^{-1}), k é a constante de von Karman (0,41), Z_{0m} é o coeficiente de rugosidade de cada *pixel* (m) e $\Psi_{m(200m)}$ é a correção da estabilidade para o transporte de momentum a 200 m. Com a obtenção de u_* corrigido, obtém-se o valor corrigido para a resistência aerodinâmica ao transporte de calor r_{ah} (s m^{-1}):

$$r_{ah} = \frac{\ln\left(\frac{Z_2}{Z_1}\right) - \Psi_{h(z_2)} - \Psi_{h(z_1)}}{u_*k} \quad (64)$$

em que: $Z_2 = 2,0$ m, $Z_1 = 0,1$ m, e $\Psi_{h(z_2)}$ e $\Psi_{h(z_1)}$ são as correções de estabilidade para o transporte de calor a 2,0 m e 1,0 m, respectivamente.

Uma vez corrigidos u e r_{ah} , volta-se ao cálculo da função da diferença de temperatura e são repetidos os cálculos mencionados anteriormente até a obtenção da estabilidade nos valores sucessivos da diferença de temperatura (dT) e da resistência aerodinâmica (r_{ah}). Em geral, são necessários de 5 a 10 iterações, até que os valores se estabilizem (ALLEN; TASUMI; TREZZA, 2002).

7.3 Rotinas GEE

7.3.1 Classificação artigo 1

Script Disponível no link a Seguir <
https://drive.google.com/drive/folders/159N7q4m1_3_sJvN_25fbNyRaJbFk6ZFX?usp=sharing>.

7.3.2 GPP MODIS

Script Disponível no link a Seguir <
https://drive.google.com/drive/folders/159N7q4m1_3_sJvN_25fbNyRaJbFk6ZFX?usp=sharing>.

7.3.3 GPP LANDSAT 8

Script Disponível no link a Seguir <
https://drive.google.com/drive/folders/159N7q4m1_3_sJvN_25fbNyRaJbFk6ZFX?usp=sharing>.