

UFRRJ
INSTITUTO DE FLORESTAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS
AMBIENTAIS E FLORESTAIS

DISSERTAÇÃO

Comparação da Produtividade Primária Bruta entre os
Sensores OLI/TIRS e MODIS

Mariana Campista Chagas

2018



UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS E FLORESTAIS

**COMPARAÇÃO DA PRODUTIVIDADE PRIMÁRIA BRUTA ENTRE OS
SENSORES OLI/TIRS E MODIS**

MARIANA CAMPISTA CHAGAS

Sob a Orientação do Professor

Rafael Coll Delgado

Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**, no Curso de Pós-Graduação em Ciências Ambientais e Florestais, Área de Concentração em Conservação da Natureza

Seropédica, RJ

Março de 2018

Universidade Federal Rural do Rio de Janeiro
Biblioteca Central / Seção de Processamento Técnico

Ficha catalográfica elaborada
com os dados fornecidos pelo(a) autor(a)

C426c Chagas, Mariana Campista, 1988-
Comparação da Produtividade Primária Bruta entre os
Sensores OLI/TIRS e MODIS / Mariana Campista Chagas.
2018.
43 f.

Orientador: Rafael Coll Delgado.
Dissertação(Mestrado). -- Universidade Federal Rural
do Rio de Janeiro, Pós Graduação em Ciências Ambientais
e Florestais, 2018.

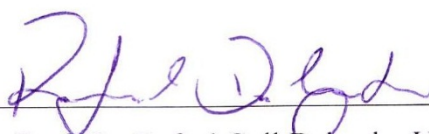
1. Produtividade Primária Bruta. 2. Sensoriamento
Remoto. 3. Landsat 8 OLI/TIRS. I. Delgado, Rafael
Coll, 1978-, orient. II Universidade Federal Rural do
Rio de Janeiro. Pós Graduação em Ciências Ambientais e
Florestais III. Título.

UNIVERSIDADE FEDERAL RURAL DO RIO DE JANEIRO
INSTITUTO DE FLORESTAS
PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS E FLORESTAIS

MARIANA CAMPISTA CHAGAS

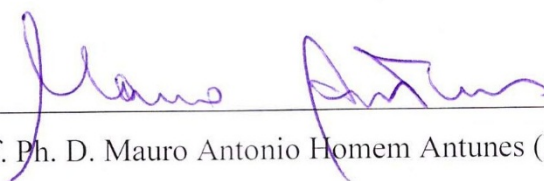
Dissertação submetida como requisito parcial para obtenção do grau de **Mestre em Ciências**,
no Curso de Pós-Graduação em Ciências Ambientais e Florestais, Área de Concentração em
Conservação da Natureza

DISSERTAÇÃO APROVADA EM 21/03/2018

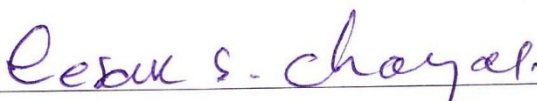


Prof. Dr. Rafael Coll Delgado. UFRRJ

(Orientador)



Prof. Ph. D. Mauro Antonio Homem Antunes (UFRRJ)



Dr. Cesar da Silva Chagas (Embrapa Solos)

A minhas avós Odiva Bezerra e Maria da Silva
Aos meus pais, Rita de Cássia Campista, Celio Chagas e irmão Lucas Chagas
Dedico

AGRADECIMENTOS

Agradeço primeiramente a minha grande família com todo apoio dado desde a graduação, os incentivos e conselhos desde sempre. Gratidão pela base necessária à minha evolução.

Aos amigos também pelo apoio, os momentos divertidos, leves e os ouvidos disponíveis para os desabafos.

Ao meu companheiro Fabiano Fernandes Lage, por estar sempre presente nos dias bons e ruins, pelo carinho e suporte como meu melhor incentivador.

Aos colegas do PPGCAF e amigos do LSRACA pelas trocas de conhecimento, experiências e as gentilezas de sempre.

Ao professor orientador Rafael Coll Delgado por me aceitar sempre como orientada desde a graduação, pela paciência, sugestões, esclarecimentos e apoio.

Aos professores do PPGCAF, pela minha formação acadêmica e contribuição educacional, e principalmente pelo exemplo como profissionais da ciência e educação, tão prejudicadas pelo governo.

A banca examinadora, por aceitar participar e dividir informações valiosas para a melhoria desta pesquisa.

A Universidade Federal Rural do Rio de Janeiro por sempre ser meu segundo lar.

À Capes, pela concessão da bolsa de estudos.

Ao CNPq, pelo financiamento do projeto relacionado a este estudo.

RESUMO

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 das mudanças climáticas. A Produção Primária Bruta (PPB) é um importante parâmetro biofísico de qualquer ecossistema e desempenha um papel fundamental na dinâmica espaço-temporal de CO₂. A incerteza na captação bruta de carbono e seu entendimento em escalas locais, regionais e globais podem ser superados através do monitoramento dos processos de superfície da terra em altas resoluções espaciais e temporais. As metodologias de superfície para o cálculo da PPB fornecem estimativas precisas, porém seu custo de implantação e operacionalidade é alto, e sua representatividade limitada, salvo em áreas extensas e homogêneas. Neste sentido, métodos que empregam o sensoriamento remoto se apresentam como vantagem para expandir a cobertura espacial da estimativa da PPB, fornecer observações sintéticas e consistentes da vegetação em áreas heterogêneas e com baixo custo. Diversos sensores orbitais têm sido empregados na determinação da PPB e para extrapolar as medições locais. Destacam-se os sensores dos satélites Landsat que fornecem registros temporais mais longos de observação da superfície da terra e o lançamento do satélite Landsat 8 OLI/TIRS em 2013 continua esse legado. O objetivo deste estudo é apresentar um algoritmo para estimar a PPB por técnicas de sensoriamento remoto, a partir de imagens do sensor, em diferentes usos do solo. A metodologia baseia-se no modelo de estimativa da radiação fotossinteticamente ativa absorvida – RFFA pela vegetação, combinado ao modelo de eficiência do uso da luz. Para isso, foram realizadas as correções atmosféricas e radiométricas das imagens previamente e como entrada básica para o modelo, foi calculado o saldo de radiação e demais componentes do balanço de energia através do algoritmo SEBAL (Surface Energy Balance Algorithm for Land). Posteriormente, foram comparadas a estimativa da PPB através do sensor OLI/TIRS, com o produto MOD17A2. A comparação foi baseada no Erro Médio (EM), Raiz do Erro Médio Quadrático (REMQ). As análises estatísticas foram realizadas no software R, versão 3.4.2. A PPB estimada pelo sensor possibilitou analisar as distinções espaciais entre os usos do solo na região. A imagem representativa da estação seca, apresentou os maiores valores de PPB indicando que o algoritmo extrapola a PPB quando oferta de radiação, valores de NDVI e umidade da superfície são altos. Porém a imagem representativa do período chuvoso, apresentou maior correlação Spearman com o produto MOD17A2, ainda com subestimativa para todos os usos do solo. As diferenças entre a resolução temporal e espacial de cada sensor também influenciam na comparação, pois apresentam dados de superfície específicos da data de imageamento. O algoritmo proposto, devido a sua aplicabilidade ao sensor OLI/TIRS, pode ser útil para a análise mais precisa da PPB em áreas de estudo locais. No entanto, é necessário averiguar melhor as estimativas temporais para os sensores OLI/TIRS com dados de superfície, que integrados poderão determinar valores mais precisos de PPB, principalmente nas áreas mais remotas.

Palavras-chave: Produtividade Primária Bruta, Sensoriamento Remoto, Landsat 8.

GENERAL ABSTRACT

Carbon sequestration by terrestrial biomes plays a significant role in the global carbon cycle to mitigate the increase in atmospheric CO₂ and the consequences of climate change. Gross Primary Production (PPP) is an important biophysical parameter of any ecosystem and plays a key role in the spatio-temporal dynamics of CO₂. Uncertainty in gross carbon sequestration and its understanding at local, regional and global scales can be overcome by monitoring the surface processes of the earth at high spatial and temporal resolutions. Surface methodologies for PPB calculation provide accurate estimates, but their implementation and operational costs are high and their representativeness limited, except in large and homogeneous areas. In this sense, methods that use remote sensing are presented as an advantage to expand spatial coverage of PPB estimation, provide synthetic and consistent observations of vegetation in heterogeneous and low cost areas. Several orbital sensors have been used to determine PPB and to extrapolate local measurements. Of particular note are the Landsat satellite sensors that provide longer time records of earth surface observations and the launch of the Landsat 8 OLI / TIRS satellite in 2013 continues this legacy. The objective of this study is to present an algorithm to estimate PPB by remote sensing techniques, from sensor images, in different soil uses. The methodology is based on the estimative model of the absorbed photosynthetically active radiation - RFFA by the vegetation, combined with the light efficiency model. For this, the atmospheric and radiometric corrections of the images were performed previously and as basic input for the model, the balance of radiation and other components of the energy balance were calculated through the SEBAL (Surface Energy Balance Algorithm for Land) algorithm. Subsequently, the estimation of PPB was compared through the OLI / TIRS sensor, with the product MOD17A2. The comparison was based on the Mean Error (EM), Root Mean Square Error (REMQ). Statistical analyzes were performed in software R, version 3.4.2. The PPB estimated by the sensor made it possible to analyze the spatial distinctions between the land uses in the region. The representative image of the dry season presented the highest values of PPB indicating that the algorithm extrapolates to PPB when radiation supply, NDVI values and surface humidity are high. However, the representative image of the rainy season presented a higher Spearman correlation with the product MOD17A2, still underestimating for all soil uses. The differences between the temporal and spatial resolution of each sensor also influence the comparison, since they present specific surface data of the imaging date. The proposed algorithm, due to its applicability to the OLI / TIRS sensor, can be useful for the more accurate analysis of PPB in local study areas. However, it is necessary to better investigate temporal estimates for OLI / TIRS sensors with surface data, which integrated can determine more accurate values of PPB, especially in the more remote areas.

Keywords: Gross Primary Productivity, Remote Sensing, Landsat 8.

LISTA DE FIGURAS

Figura 1: Evolução da Produtividade Primária Bruta (PPB), Líquida (PPL), biomassa (B) e respiração (R) no processo de sucessão florestal. Fonte: ARAGÃO (2004), adaptado de ODUM (1983)	4
Figura 2: Área de estudo e localização da imagem Landsat 8. Bandas 6, 5 e 4 de 04/08/2013.	11
Figura 3: Mapa de uso da terra da área de estudo, adaptado de IBGE 2013.....	12
Figura 4: Fluxograma das etapas computacionais do processamento do balanço de radiação, fluxos de calor no solo e sensível pelo método do SEBAL.....	14
Figura 5: Variabilidade espacial da Produtividade Primária Bruta ($\text{g C m}^{-2} \text{ dia}^{-1}$) estimada a partir do sensor OLI/TIRS para o dia 04/08/2013.....	27
Figura 6: Variabilidade espacial da Produtividade Primária Bruta ($\text{g C m}^{-2} \text{ dia}^{-1}$) estimada a partir do sensor OLI/TIRS para o dia 10/10/2014.....	27
Figura 7: Histograma dos pixels dos fluxos de calor sensível (H) e calor latente (LE) das áreas antropizadas (Agropecuária e Cidades) 04/08/2013 (A) e 10/10/2014 (B).....	29
Figura 8: Variabilidade da média diária da precipitação para o mês de agosto de 2013 (A) e para o mês de outubro de 2014 (B) para área de estudo. Dados TRMM, produto 3B43.	29
Figura 9: Variabilidade espacial da Fração Evaporativa - FE (W m^{-2}) estimada a partir do sensor OLI/TIRS para o dia 04/08/2013.....	30
Figura 10: Variabilidade espacial da Fração Evaporativa - FE (W m^{-2}) estimada a partir do sensor OLI/TIRS para o dia 10/10/2014.	31
Figura 11: Histogramas dos pixels de NDVI, Albedo da superfície e temperatura da superfície de cada uso para a estação seca (04/08/2013).	32
Figura 12: Histogramas dos pixels de NDVI, Albedo da superfície e temperatura da superfície de cada uso. Período seco (2014).	33
Figura 13: Erro médio da PPB para estação seca e chuvosa para os usos do solo avaliados...35	

LISTA DE QUADROS E TABELAS

Quadro 1: Especificações de cada banda do sensor OLI/TIRS.	9
Tabela 1: Data, sensor, hora da passagem em GMT (Greenwich Mean Time) e órbita/ponto e do satélite OLI/TIRS - Landsat 8 na para a área de estudo – RO.....	12
Tabela 2: Dados de superfície necessários ao cômputo. Data referente as imagens OLI/TIRS; Altitude da estação meteorológica; Temperatura média do dia das imagens em Kelvin e graus Celsius; Radiação solar global diária média em Watt m ⁻²	13
Tabela 3: Parâmetros utilizados nas equações para calcular o saldo de radiação.	19
Tabela 4: Estatística descritiva da PPB OLI/TIRS em cada uso do solo na estação seca.	27
Tabela 5: Estatística descritiva da PPB OLI/TIRS em cada uso do solo na estação chuvosa. .	27
Tabela 6: Data das imagens, Radiação Solar Global diária, para o momento de passagem do satélite, e estimativa da Radiação Fotossinteticamente Ativa.	28
Tabela 7: Médias da Fração Evaporativa para cada uso do solo das imagens estudadas.....	30
Tabela 8: PPB segundo o produto MOD17 - PPB _{MOD} de 05/08/2013 e PPB estimada pelos sensores OLI/TIRS – PPB _{OLI/TIRS} de 04/08/2013, estação seca.	34
Tabela 9: PPB segundo o produto MOD17 - PPB _{MOD} de 08/10/2014 e PPB estimada pelos sensores OLI/TIRS – PPB _{OLI/TIRS} de 10/10/2014, estação chuvosa.	34
Tabela 10: Erro médio da PPB (gCm ⁻² dia ⁻¹), REMQ (gCm ⁻² dia ⁻¹) dos usos do solo para as duas estações.....	35
Tabela 11: Erro médio da PPB (gCm ⁻² dia ⁻¹), REMQ (gCm ⁻² dia ⁻¹) e coeficiente de correlação de Spearman entre o total da PPB _{OLI/TIRS} e PPB _{MOD} da área de estudo.....	36

LISTA DE SIGLAS E ABREVIATURAS

AVHRR - *Advanced Very High Resolution Radiometer*
BDMEP - Banco de Dados Meteorológicos para Ensino e Pesquisa
BE - Balanço de Energia
CO₂ - Dióxido de carbono
EM - Erro médio
EMC - Estação Meteorológica Convencional
ETM+ - *Enhanced Thematic Mapper Plus*
FE - Fração Evaporativa
FRFA - Fração da radiação fotossinteticamente ativa
GEE - Gases de Efeito Estufa
GMT - *Greenwich Mean Time*
GPP - *Gross Primary Productivity*
IAF - Índice de área foliar
IBGE - Instituto Brasileiro de Geografia e Estatística
INMET - Instituto Nacional de Meteorologia
INPA - Instituto Nacional de Pesquisas da Amazônia
Landsat - *Land Remote Sensing Satellite*
LBA - Projeto Grande Escala Biosfera-Atmosfera na Amazônia
LUE - *Light Use Efficiency*
MODIS - *Moderate Resolution Imaging Spectroradiometer*
MRT - *Modis Reprojection Tools*
NASA - *National Aeronautics and Space Administration*
NDVI - *Normalized Difference Vegetation Index*
OLI - *Operational Land Imager*
PPB - Produtividade Primária Bruta
PPB_{MOD} - Produtividade Primária Bruta estimada pelo sensor MODIS
PPB_{OLI/TIRS} - Produtividade primária bruta estimada pelos sensores OLI/TIRS
PPL - Produção Primária Líquida
Ra - Respiração autotrófica
Re - Respiração do ecossistema
REMQ - Raiz do erro médio quadrático
RFA - Radiação Fotossinteticamente Ativa
RFAA - Radiação Fotossinteticamente Ativa Absorvida
Rh - Respiração heterotróficas
Rs,24h - Radiação Solar Global diária
SAVI - *Soil Adjusted Vegetation Index*
SEBAL - *Surface Energy Balance Algorithm for Land*
TIRS - *Thermal Infrared Sensor*
TM - *Thematic Mapper*

SUMÁRIO

1	INTRODUÇÃO	1
2	OBJETIVOS.....	3
2.1	Objetivo Geral.....	3
2.2	Objetivos Específicos	3
3	REVISÃO DE LITERATURA	4
3.1	A Produtividade Primária Bruta no Ecossistema Amazônico	4
3.2	Sensoriamento Remoto e Modelagem da PPB	5
3.3	Sensores OLI/TIRS da Plataforma Landsat 8.....	7
3.3.1	Sensor Operacional Land Imager (OLI).....	8
3.3.2	Sensor infravermelho térmico (TIRS).....	8
3.4	Sensor MODIS e Produto MOD17A2.....	9
4	MATERIAL E MÉTODOS	10
4.1	Caracterização da Área de Estudo	10
4.2	Dados de Superfície e de Satélite	12
4.3	Algoritmo SEBAL Aplicado aos Sensores OLI e TIRS.....	13
4.3.1	Reflectância aparente (ρ_i)	14
4.3.2	União da Reflectância.....	15
4.3.3	Índice de Vegetação da Diferença Normalizada (NDVI).....	15
4.3.4	Índice de vegetação Ajustado aos Efeitos do Solo (SAVI).....	15
4.3.5	Índice de Área Foliar (IAF).....	16
4.3.6	Emissividade (ε)	16
4.3.7	Albedo Planetário ou Albedo do Topo da Atmosfera (α_{toa})	16
4.3.8	Albedo da Superfície (α).....	17
4.3.9	Temperatura da Superfície (T_s).....	17
4.3.10	Radiação de Onda Longa Emitida pela Superfície ($R_{L\uparrow}$).....	18
4.3.11	Radiação de Onda Longa Emitida pela Atmosfera ($R_{L\downarrow}$)	18
4.3.12	Radiação de Ondas Curtas espalhadas pela Atmosfera ($R_s\downarrow$)	18
4.3.13	Saldo de Radiação (R_n)	19
4.3.14	Fluxo de Calor no Solo (G)	19
4.3.15	Fluxo de Calor Sensível (H)	20
4.4	Processo de estimativa da Produtividade Primária Bruta	23
4.5	Comparação dos algoritmos	24
5	RESULTADOS E DISCUSSÃO	26

5.1	Análise da PPB OLI/TIRS	26
5.2	Análise dos parâmetros da PPB OLI/TIRS.....	28
5.3	Comparação da PPB _{OLI/TIRS} com a PPB _{MOD}	33
6	CONCLUSÃO	36
	REFERENCIAS BIBLIOGRÁFICAS	37

1 INTRODUÇÃO

Alterações das condições climáticas globais vêm causando anomalias de precipitação, temperatura do ar e na concentração de gás carbônico em diversas regiões do planeta. Segundo dados recentes do Instituto Goddard Estudos Espaciais da *National Aeronautics and Space Administration* - NASA, a temperatura média global calculada para o mês de março de 2016 foi 1,22°C mais alta que a média de março de 1951-1980, que é o período utilizado como dado base (SILBERG, 2016). Dados temporais mais concisos relatam que no período dos anos de 1880 a 2012, houve um incremento de 0,85 °C na temperatura, atribuída principalmente ao aumento da emissão antrópica de gás carbônico (CO₂) e outros Gases de Efeito Estufa (GEE). (ALMEIDA et al., 2016).

O aumento da concentração de CO₂ na atmosfera e o aumento da temperatura da superfície terrestre resultante, causam respostas diferentes nos processos biogeoquímicos do sistema solo-planta-atmosfera. Portanto, há um interesse global na fixação de CO₂, estimulado por um renovado esforço para limitar as taxas de emissões, como medida mitigadora das alterações climáticas em nível regional e global (GUSTAVSSON et al., 2014). Nos ecossistemas terrestres as plantas utilizam o CO₂ como fonte para os processos fotossintéticos, com a função parcial de estocagem do carbono atmosférico. A taxa total em que produtores de um ecossistema transformam a energia solar em energia química, na forma de biomassa através da fotossíntese, é chamada Produtividade Primária Bruta (PPB) - GPP (do inglês *Gross Primary Productivity*) (ZHANG et al., 2016). O conhecimento da PPB é essencial no contexto das mudanças climáticas, já que a PPB está diretamente relacionada ao carbono efetivamente extraído da atmosfera pelos diferentes ecossistemas terrestres (ALMEIDA, 2016).

Neste sentido, estudos têm sido realizados na tentativa de compreender a dinâmica da produtividade em diversos ecossistemas e sua atuação no balanço global de carbono (PULLENS et al., 2015). Nas florestas tropicais, como a floresta Amazônica, estudos indicam que estas contribuem significativamente no quadro global de assimilação da PPB, e são regiões estratégicas para projetos de compensação de carbono e recomposição florestal (BEER et al., 2010; RESTREPO-COUBE et al., 2013). Entretanto, a expansão da agricultura e pastagem vem elevando as taxas de desmatamento ao longo das últimas décadas, e também modificando significativamente a dinâmica dos fluxos de energia e água na superfície da terra, portanto possui potencial de atuar como fonte de CO₂ para a atmosfera (BROWN et al., 2016).

São utilizados vários métodos para a estimativa do fluxo de carbono em áreas florestadas. O método de covariância turbulenta é uma técnica muito empregada que utiliza torres micrometeorológicas de fluxo. Esta técnica analisa os fluxos de carbono e possibilita o entendimento dos fatores atmosféricos e climáticos que regulam a PPB (SALESKA et al., 2009). No entanto, em alguns casos, esta técnica pode ser impraticável por seus altos custos operacionais e sua pouca representatividade para locais heterogêneos. O uso de dados de campo integrado com dados de satélite, são uma ferramenta viável para a obtenção de informações que permitem estudos sobre a troca de carbono no ecossistema.

Diversos sensores orbitais são aplicados na determinação da PPB. O sensor MODIS (*Moderate Resolution Imaging Spectroradiometer*) possui diversos produtos dentre eles o MOD17A2 que estima a PPB de 8 em 8 dias com resolução espacial de 1Km, 500m (SAKAMOTO et al., 2011). Os sensores da série de satélites Landsat (*Land Remote Sensing Satellite*) podem estimar a PPB através do desenvolvimento de modelos, e algoritmos associados a técnicas de geoprocessamento e sensoriamento remoto, com uma ampla cobertura espacial e continuidade no tempo (SIMS et al., 2008; WU et al., 2009,). Se destacam por detectar 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 (GITELSON et al., 2008; SILVA et al., 2013).

As imagens multiespectrais recentemente disponíveis dos sensores *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS), do satélite Landsat 8 lançado em 2013, surgem como uma promessa futura em estudos ambientais. Sua importância é significativa para estender a missão de monitoramento de florestas pela série Landsat, dadas as suas melhorias no que diz respeito à relação sinal-ruído, resolução radiométrica e resolução espacial (IRONS et al., 2012; ROY et al., 2014).

A região amazônica com sua grande extensão e diversidade biológica apresenta diversos padrões PPB. E o balanço de carbono responde de diferentes formas para cada sítio, a partir de características específicas da superfície. Mudanças no uso da terra em biomas amazônicos são uns dos impactos mais evidentes de perda de produtividade da vegetação. Portanto, a criação de modelos a partir de técnicas de sensoriamento remoto é necessária para acurácia no monitoramento da mudança da superfície e suas consequências climáticas, além de garantir a continuidade das observações futuras e complementares aos estudos relativos à PPB nos ecossistemas florestais. (SALESKA et al., 2009).

Neste sentido, o presente trabalho tem como objetivo propor um algoritmo para estimativa da Produtividade Primária Bruta a partir de imagens Landsat 8 OLI/TIRS e analisar os padrões espaço-temporais em diferentes usos do solo. Em adição, comparar o algoritmo proposto, com a PPB estimada pelo produto MOD17A2.

2 OBJETIVOS

2.1 Objetivo Geral

Quantificar e comparar, a partir de técnicas de sensoriamento remoto, a Produtividade Primária Bruta (PPB) para diferentes usos e cobertura do solo no estado de Rondônia.

2.2 Objetivos Específicos

- Gerar um modelo associado à técnica de sensoriamento remoto para estimar a PPB aplicado para os sensores OLI e TIRS;
- Verificar e comparar a PPB do modelo proposto com dados do produto MOD17A2;
- Compreender os padrões da PPB na escala espaço-temporal e em média resolução, relacionando com uso e cobertura do solo a partir de dados orbitais;
- Analisar e gerar mapas atualizados e em média resolução da dinâmica da PPB para a região de estudo;

3 REVISÃO DE LITERATURA

3.1 A Produtividade Primária Bruta no Ecossistema Amazônico

O carbono participa da composição química de todos os componentes orgânicos atualmente conhecidos e, portanto, é essencial para a existência da vida (RAMPELOTTO, 2012). A captação do carbono atmosférico nos ecossistemas terrestres ocorre através do processo fotossintético que, a partir do carbono inorgânico, produz compostos orgânicos. Parte do carbono inorgânico absorvido pelas plantas, algas e micro-organismos dos oceanos é utilizado para a construção da biomassa e permanece de forma estável nas plantas, solo ou sedimentos profundos dos oceanos. A outra parte é consumida pelos produtores (respiração autotrófica) ou microrganismos decompositores (respiração heterotrófica), no que resulta em liberação de CO₂ para a atmosfera (MOREIRA, 2013).

A taxa de CO₂ inorgânico presente na atmosfera que é convertida pela fotossíntese em substâncias orgânicas, é chamado de Produtividade Primária Bruta - PPB (BEER et al., 2010). A PPB é considerada a quantidade total de dióxido de carbono fixado pelo ecossistema, medida em unidades de massa de carbono por área por tempo (ex. g C m⁻² ano⁻¹) (CHAPIN III et al., 2011). Uma parte da PPB é referente à Produção Primária Líquida (PPL), que é a fração de carbono efetivamente absorvido pelas plantas para compor a estrutura dos caules, folhas, frutos e carboidratos instáveis como açúcares e amido. A outra parte é perdida por meio da respiração do ecossistema (Re), que é composta pela respiração dos organismos autotróficos (Ra) e heterotróficos (Rh) (GOUGH, 2012). A PPB terrestre, portanto, refere-se a PPL na seguinte equação:

$$PPB = PPL + Re \quad (1)$$

O comportamento da produtividade do sistema ao longo do processo de sucessão florestal em um ecossistema florestal sem perturbação é caracterizado pela figura 1 a seguir:

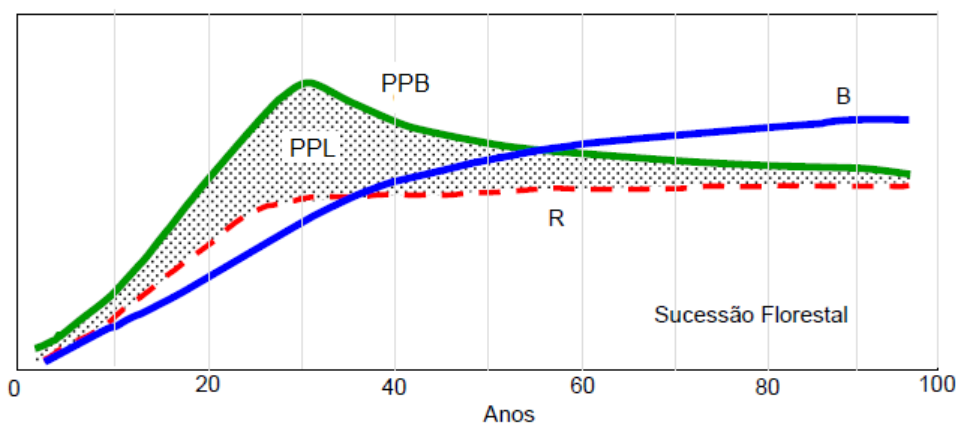


Figura 1: Evolução da Produtividade Primária Bruta (PPB), Líquida (PPL), biomassa (B) e respiração (R) no processo de sucessão florestal. Fonte: ARAGÃO (2004), adaptado de ODUM (1983)

O crescimento da comunidade vegetal depende de que a taxa de armazenamento de matéria orgânica exceda as perdas de CO₂ pelo processo de respiração autotrófica (R_a) (MALHI et al., 2009). Já no contexto geral do ecossistema, quando temos que a PPB é maior que respiração do ecossistema (Re), a PPL é positiva. Ou seja, o ecossistema é um sumidouro de carbono, consumindo mais carbono do que liberando. Quando Re é maior que o PPB, temos

que este ecossistema é uma fonte de carbono (CHAPIN III et al., 2011). A produtividade primária da fitomassa e conseqüentemente a assimilação do carbono atmosférico, depende de fatores químicos, biológicos e físicos (concentração do nitrogênio foliar, área foliar, resistência estomática, água do solo, concentração de CO₂ atmosférico, temperatura do ar, radiação solar, etc.). Portanto, os efeitos da modificação antrópica como, desmatamentos e conversão de florestas em pastagens e agricultura no ecossistema, podem ser avaliados a partir do conhecimento da sua produtividade.

Dado o seu papel central no orçamento global de carbono e a necessidade de compreender o status do ciclo de carbono na biosfera terrestre, é fundamental desenvolver uma compreensão e monitoramento concisos dos padrões espaço-temporais da PPB, principalmente para o desenvolvimento de medidas mitigadoras dos efeitos das alterações climáticas (PROPASTIN et al., 2012). Dentro deste contexto, há um enfoque voltado principalmente para o estudo da PPB nas florestas tropicais, com destaque a amazônica, pois estas assimilam até 34% da PPB terrestre global e possuem a maior PPB por unidade de área (HOUGHTON et al., 2001; BEER et al., 2010).

Segundo Anav et al. (2015) em geral, tanto a fotossíntese da folha e a PPB variam diariamente e sazonalmente em resposta a mudanças no clima (luz, precipitação, temperatura e umidade) e disponibilidade de nutrientes, enquanto que a distribuição espacial é determinada principalmente pelas condições climáticas. Especificamente nas florestas tropicais úmidas da bacia amazônica, segundo Restrepo-Coupe et al. (2013) e Almeida (2015), são encontrados três padrões distintos na sazonalidade da PPB em áreas pontuais da Amazônia Legal. O primeiro padrão é definido pela manutenção ou aumento da PPB em área florestada durante o período seco na região equatorial. O decréscimo das chuvas e aumento radiação incidente funciona como principal característica no acréscimo de PPB na região. O segundo padrão caracteriza-se por uma pequena diminuição da PPB no período seco em área florestada na região do estado de Rondônia, indicando stress hídrico. O terceiro padrão é associado a mudanças no uso do solo, com redução da PPB no período seco em áreas de pastagem, com padrão distinto do observado em áreas de floresta próximas. Esses resultados apontam para uma variação dos mecanismos de controle da PPB em escala de dossel em diferentes condições ambientais.

Porém apesar do avanço nos estudos relacionados a variabilidade e dinâmica da PPB na Amazônia, alguns fatores ainda são pouco compreendidos principalmente a longo prazo (FRIEDLINGSTEIN et al., 2006). Isso ocorre em particular pela alta complexidade fenológica, diversidade de espécies arbóreas e área continental da floresta Amazônica, o que resulta em diferentes respostas aos fatores ambientais (REICH et al., 2004).

Em adição, induzidos pela mudança climática e do uso da terra, podem vir a ocorrer variações significativas a nível mundial nos padrões de PPB (MONTEITH, 1965; CORLETT, 2016). O aumento da emissão antrópica de gás carbônico e outros gases do efeito estufa (GEE) (IPCC, 2014), além da expansão da agricultura e pastagem que vem elevando as taxas de desmatamento ao longo das últimas décadas, modificam significativamente os fluxos de energia, água e dinâmica entre a superfície da terra e da atmosfera na região (SWANN et al., 2015; BROWN et al., 2016). Assim, a compreensão da variação espacial do metabolismo floresta é uma base importante para a encontrar as respostas ecológicas ao clima em geral.

3.2 Sensoriamento Remoto e Modelagem da PPB

O sensoriamento remoto auxilia no estudo de parâmetros ambientais em áreas de grandes extensões onde a mensuração em campo é tecnicamente e economicamente inviável. A produtividade primária bruta como uma variável biofísica, é dependente de variáveis espaciais e temporais da vegetação e radiação incidente na superfície que podem ser

mensuradas através da combinação de algoritmos e bandas das imagens orbitais.

Existem diversos métodos com o objetivo de quantificar a PPB na vegetação. Os mais comumente empregados, são aqueles que utilizam dados de torres micrometeorológicas de fluxo ou técnicas de modelagem através do sensoriamento remoto (VERMA et al., 2015; AHONGSHANGBAM, 2016). Dentre os métodos baseados em estimativas de torres de fluxo, a técnica de covariância de vórtices turbulentos facilita um estudo mais detalhado e preciso sobre o ciclo de carbono em ecossistemas (FALGE et al., 2002; RESTREPO-COUPÉ et al., 2013). Em termos de escala espacial, o método de covariância turbulenta pode fornecer medições de PPB sobre áreas que vão desde alguns milhares de metros quadrados a vários hectares, dependendo altura da torre, características físicas do dossel, e a velocidade do vento (LIU et al., 2015).

No Brasil, a rede de torres de fluxo do Projeto Grande Escala Biosfera-Atmosfera na Amazônia (Projeto LBA), coordenado pelo Instituto Nacional de Pesquisas da Amazônia (INPA) vem cumprindo esse papel em diversos biomas na região amazônica. Porém, apresenta restrições no caso de áreas extensas, pois fornece apenas dados pontuais de PPB, cobrindo apenas alguns quilômetros, além do alto custo de implantação e manutenção (SILVA et al., 2013).

Portanto, vem sendo desenvolvidas muitas abordagens para extrapolar as medições locais de fluxo de carbono através do sensoriamento remoto. O uso de algoritmos aplicados a imagens de satélite, fornece observações mais concisas e detalhadas ajudando na caracterização da estrutura da vegetação, com baixo custo e aplicabilidade em áreas de difícil acesso (XIAL et al., 2004a, b, 2005; VERMA et al., 2015).

A modelagem da PPB depende de propriedades físicas, químicas e biológicas que regulam a fotossíntese. O acúmulo de biomassa está relacionado principalmente à absorção de radiação eletromagnética pelas plantas da faixa espectral da região do visível (0,4 a 0,7 μm). Esta faixa é também conhecida como Radiação Fotossinteticamente Ativa (RFA), pois parte de desta radiação incidente sobre a vegetação, é absorvida pelos pigmentos fotossintetizantes das folhas, compostos pelas clorofilas, carotenoides, xantofilas e antocianinas (MOREIRA, 2012). Porém apenas parte da RFA é aproveitada no processo fotossintético, a chamada Radiação Fotossinteticamente Ativa Absorvida (RFAA), que compreende o balanço entre a radiação recebida, subtraindo as frações de radiação transmitidas e refletidas para o meio.

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, pela fração da radiação fotossinteticamente ativa (FRFA). Sendo, $RFAA = RFA \times FRFA$. A FRFA depende de parâmetros variáveis como a estrutura do dossel, índice de área foliar (IAF), quantidade de folhagem, ângulo zenital solar, proporção de radiação difusa e reflectância do solo. Portanto relaciona-se com a eficiência com que a planta absorve RFA sobre o dossel (KUMAR e MONTEITH, 1981).

Dentre as técnicas de sensoriamento remoto mais utilizadas e com maior potencial para a estimativa adequada da PPB, o modelo baseado no conceito de eficiência do uso da luz - LUE (do inglês *Light Use Efficiency*) é comumente utilizado (WU, 2010; YUAN et al., 2014). Esta técnica é uma combinação do modelo de Monteith (1972), utilizado na determinação da radiação fotossinteticamente ativa absorvida – RFAA, com o modelo de Field et al. (1995), utilizado na determinação da eficiência do uso de luz (ϵ) (Equação 2). Segundo Monteith, (1972) o ϵ pode ser entendido como a quantidade líquida de energia solar armazenada pela fotossíntese, dividida pela constante solar integrada no mesmo período de tempo.

Embora a RFAA seja facilmente estimada em função da radiação solar global, o fator (ϵ) pode ser difícil de ser estimado para grandes áreas, sendo disponível apenas para um conjunto específico de biomas, pois depende de fatores da própria vegetação (MONTEITH, 1972).

$$PPB = RFAA \times \varepsilon \quad (2)$$

Porém, Bastiaanssen e Ali (2003), aperfeiçoaram a equação adicionando conceitos de temperatura do ar e Fração Evaporativa (FE), relacionando o (ε) em função do seu valor máximo.

A FE é obtida por meio do algoritmo SEBAL (Surface Energy Balance Algorithm for Land) proposto por Bastiaanssen et al. (1998) que surge como mais uma contribuição no computo da PPB. O SEBAL é um método de processamento de imagens de satélite que estima os componentes do Balanço de Energia – BE da superfície, baseado em combinações de relações empíricas e parametrizações físicas (BASTIAANSSEN et al., 1998). Os resultados das etapas do cálculo do SEBAL, contribuem como base para os dados de entrada para os cálculos da PPB, de acordo com a metodologia proposta por Silva et al. (2013). O SEBAL tem sido utilizado para estimar, de forma simples e eficaz, o albedo, a temperatura da superfície e saldo de radiação com imagens Landsat 5 e 7 (SILVA et al., 2004, GITELSON et al., 2008). No entanto, a teoria é independente do tipo de satélite e pode ser aplicado a outras imagens se usado com coeficientes apropriados (ALLEN et al., 2002).

Os sensores orbitais mais utilizados, empregados na determinação da PPB através do modelo LUE são o Moderate Resolution Imaging Spectroradiometer – MODIS (SAKAMOTO et al., 2011; ALMEIDA, 2015), o *Advanced Very High Resolution Radiometer* – AVHRR (KITAMOTO et al., 2007) e o TM/ETM+ da série Landsat (GITELSON et al., 2008, 2012). Mais recentemente, o lançamento do sensor Operational Terra Imager (OLI/TIRS) do satélite Landsat 8 em 2013, vem surgindo como uma nova opção para o computo da PPB para o monitoramento e observações futuras (AHONGSHANGBAM et al., 2016). Sua alta resolução espacial pode fornecer informações mais detalhadas e significativas das relações do fluxo de PPB e alterações no uso do solo.

3.3 Sensores OLI/TIRS da Plataforma Landsat 8

Os sensores *Operational Land Imager* (OLI) e o *Thermal Infrared Sensor* (TIRS) do satélite Landsat 8 são os mais recentes sensores lançados do programa Landsat (*Land Remote Sensing Satellite*), que fornece registros contínuos e multiespectrais de média resolução de toda superfície terrestre desde 1972, e com dados livremente disponíveis para o público (IRONS et al., 2012; ROY et al., 2014; USGS, 2016). O programa Landsat aborda uma série de prioridades de pesquisa de longo prazo, tais como monitoramento dos distúrbios e mudanças no uso e cobertura do solo, além de estudos sobre a cobertura vegetal, a utilização dinâmica na qualidade e quantidade da água, a biodiversidade, o desenvolvimento de energia, alterações climáticas e muitos outros temas ambientais (SLEETER et al., 2012). O Landsat 8 é parte integrante do programa de pesquisa global da *National Aeronautics and Space Administration* (NASA) *Landsat Data Continuity Mission* (LDCM) (USGS, 2016). O principal objetivo da missão Landsat 8, é estender o registro de imagens Landsat para o futuro, e manter a continuidade das observações com dados tão consistentes e comparáveis com os dos sistemas Landsat anteriores (ROY et al., 2014)

O lançamento bem-sucedido do Landsat 8 OLI/TIRS em maio de 2013 na Base da Força Aérea de Vandenburg, Califórnia - USA, forneceu à comunidade científica uma série de modificações e melhorias no satélite, sensores, transmissão, recepção, processamento de dados e armazenamento das imagens (VERMOTE et al., 2016; MISHRA et al., 2016). As principais diferenças em relação aos sistemas Landsat anteriores (Landsat 1, 2, 3, 4, 5 e 7) são bandas espectrais mais estreitas, melhorias na calibração radiométrica, geometria mais precisa, desempenho radiométrico de 12 bits, possibilitando uma maior caracterização de alvos da

imagem além de contribuir bastante para a diminuição do efeito de sombras, além de sistema de previsão de cobertura de nuvens para excluir imagens menos úteis (ROY et al., 2014; ESTOQUE e MURAYAMA; 2015). Possui um período de revisita a cada 16 dias, com órbita circular, quase polar (Heliosíncrone), descendente, com 98,2° de Inclinação, e altitude de 705 Km. Seu horário de mapeamento é às 10 h 00 min AM e ultrapassa uma coleção média de 650 cenas fotografadas por dia de imageamento.

Transporta dois sensores: o Operacional Land Imager (OLI) e o sensor infravermelho térmico (TIRS). Ambos coletam dados em conjunto porém de forma independente, fornecendo imagens coincidentes com área de 170 km ao norte-sul por 183 km a leste-oeste da superfície da terra (USGS, 2016).

3.3.1 Sensor Operacional Land Imager (OLI)

O sensor OLI recolhe dados de imagem por nove bandas espectrais de ondas curtas com resolução espacial de 30 m para todas as bandas com exceção da banda pancromática de 15 m. Possui maior resolução radiométrica de 12 bits, e geometria mais precisa, em comparação com o Landsat-7 ETM + (IRONS et al., 2012), além de melhorias na acurácia da calibração radiométrica (MARKHAM et al., 2014). As bandas permanecem globalmente comparáveis ao Landsat 7 *Thematic Mapper* (ETM +) porém OLI possui duas novas bandas adicionais além das bandas encontradas nos sensores dos satélites Landsat anteriores (1-5, 7, e pancromática): A banda Costeira / Aerossol (Banda 1; 0,435 - 0,451 μm), destina-se a melhorar a sensibilidade a clorofila e outros materiais em suspensão nas águas costeiras, e para recuperar propriedades de aerossóis atmosféricos. E a nova banda “Cirrus” (Banda 9; 1,36 – 1,38 μm) que auxilia na detecção de nuvens finas compostas de cristais de gelo (USGS, 2016). As bandas também são espectralmente mais estreitas e abrangem diferentes faixas espectrais em comparação com ETM+ (ROY et al., 2014).

3.3.2 Sensor infravermelho térmico (TIRS)

Imagens térmicas de satélite são cruciais para estimar umidade do solo e evapotranspiração (HOLZMAN et al., 2014).

O sensor infravermelho térmico TIRS, recolhe dados de imagem para duas bandas térmicas com uma resolução espacial de 100 m. As duas bandas espectrais compreendem o comprimento de onda antes coberto por uma única banda nos sensores TM e ETM (USGS, 2013). Em comparação com o sensor ETM + que possui uma resolução espacial de 60 m em uma única banda do infravermelho termal, a reduzida resolução espacial do TIRS não é o ideal, mas foi necessária em virtude de restrições de custo de engenharia (ROY et al., 2014).

Embora as tecnologias e metodologias utilizadas no sensor TIRS sejam muito diferentes daquelas usadas em missões Landsat anteriores, TIRS ainda dá continuidade aos dados térmicos e fornece informações da temperatura de superfície e emissividade ainda mais precisas (FU e WENG, 2016). Os seus dois canais com sensibilidade muito elevada fornecem uma nova análise de imagem em comparação com os geradores de imagens de canal único anteriores, tal como a capacidade de fazer correção atmosférica (REUTER et al., 2015).

Quadro 1: Especificações de cada banda do sensor OLI/TIRS.

Landsat 8 bandas OLI /TIRS			
Banda	Largura de banda (µm)	Resolução espacial (m)	Utilidade para mapeamento
1 – Aerossol Costeira (CA)	0,43 – 0,45	30	Estudos de regiões costeiras e aerossóis
2 - Azul	0,45 – 0,51	30	Mapeamento batimétrico, distingue solo de vegetação e vegetação decídua de vegetação de coníferas
3 - Verde	0,53 – 0,59	30	Enfatiza o topo da vegetação, o que é útil para avaliar o vigor da planta
4 - Vermelho	0,63 – 0,67	30	Discrimina encostas de vegetação
5 – Infravermelho Próximo (NIR)	0,85 – 0,87	30	Enfatiza teor de biomassa e linhas costeiras
6 – Infravermelho de ondas curtas IR-1 (SWIR 1)	1,56 – 1,65	30	Discrimina conteúdo de umidade do solo e da vegetação; penetra nuvens finas
7 - Infravermelho de ondas curtas SWIR 2	2,10 – 2,29	30	Aperfeiçoa o conteúdo de umidade do solo e da vegetação; penetra nuvens finas
8 - Pancromática (Pan)	0,50 – 0,67	15	Proporciona uma definição de imagem mais nítida
9 – Cirrus (Nuvem)	1,36 – 1,38	30	Melhor detecção de contaminação nuvem cirrus
10 – Infravermelho Termal TIR 1	10,60 -11,19	100	Mapeamento térmico e estimativa da umidade do solo
11 - Infravermelho Termal TIR 2	11,50 – 12,51	100	Mapeamento térmico melhorado e estimativa da umidade do solo

Adaptado de USGS, 2016.

3.4 Sensor MODIS e Produto MOD17A2

O sensor MODIS fornece dados de alta qualidade para o monitoramento da vegetação terrestre, devido a sua maior resolução espectral em relação a outros sensores (36 bandas espectrais) (JUSTICE et al., 2002), sua alta resolução temporal (1-2 dias), sua calibração a bordo que garante a consistência da série temporal de reflectância (GUENTHER et al., 2002) e às manobras de órbita e altitude do satélite que fornecem precisão na geolocalização (WOLFE et al., 2002).

Lançado a bordo da plataforma Terra em 19 de dezembro de 1999, com uma varredura de 2.330 km, o sensor MODIS iniciou operacionalmente o fornecimento de produtos de produção primária (nomeados de MOD17) em 24 de fevereiro de 2000, em um intervalo de 8 dias, com uma resolução espacial de 500 metros (ZHAO et al., 2005). Pela primeira vez na história, foi possível obter o status de crescimento da vegetação mundial, incluindo a produção

primária, em tempo quase real (JUSTICE et al, 2002).

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 através do fator de conversão da eficiência do uso da luz (ϵ), que se trata de um parâmetro tabelado que varia com os diferentes tipos de vegetação, e dados meteorológicos de superfície (RFA, déficit de pressão de vapor, temperatura).

Alguns estudos recentes avaliaram desempenho do produto MOD17A2 em florestas tropicais em comparação com dados de torres micrometeorológicas. Com enfoques em padrões sazonais da PPB em diversos pontos na Amazônia, as pesquisas analisam em função de variáveis como padrões fenológicos do dossel, usos do solo, disponibilidade de água e influência da radiação, e outras variáveis meteorológicas. Como resultado, evidenciam uma grande variabilidade espacial e sazonal na região (RESTREPO-COUBE et al., 2013; ALMEIDA, 2016), o que leva à necessidade de maiores estudos relacionados a análise deste produto e as especificidades da PPB na Amazônia e em florestas tropicais.

4 MATERIAL E MÉTODOS

4.1 Caracterização da Área de Estudo

A área de estudo localiza-se ao sudoeste da Amazônia Legal no estado de Rondônia entre latitude 8° e 15°S, e longitude 60° e 65°W. Compreende a uma área de aproximadamente 24.847 Km² abrangendo parte de 13 municípios: Cujubim, Rio Crespo, Machadinho D'oeste, Ariquemes, Vale do Anari, Ji-Paraná, Ouro Preto do Oeste, Theobroma, Jarú, Nova União, Governador Jorge Teixeira e Cacaulândia (Figura 2).

Segundo a classificação climática de Köppen o estado enquadra-se no tipo Am, tropical de monção (ALVARES et al., 2013), com temperatura média anual de 26°C e precipitação pluviométrica média anual de 2.300 mm. A chuva mostra grande sazonalidade, com uma estação chuvosa entre novembro e março, e a estação seca entre maio e setembro. Os meses de abril e outubro são meses de transição entre um regime e outro. A umidade relativa do ar varia entre 80 e 90% de novembro a maio e em julho e agosto permanece em torno de 75% (BRASIL, 2007).

A declividade varia de solos planos à terreno ondulado e elevação entre 80 e 140 m acima do nível do mar. A vegetação dominante é de floresta tropical úmida, com presença de palmeiras e lianas (DNPM, 1978). As principais formações vegetais incluem: Floresta Estacional Semidecidual, Floresta Ombrófila Aberta, Floresta Ombrófila Densa, Savana e as Formações Pioneiras de Influência Fluvial (BRASIL, 1978).

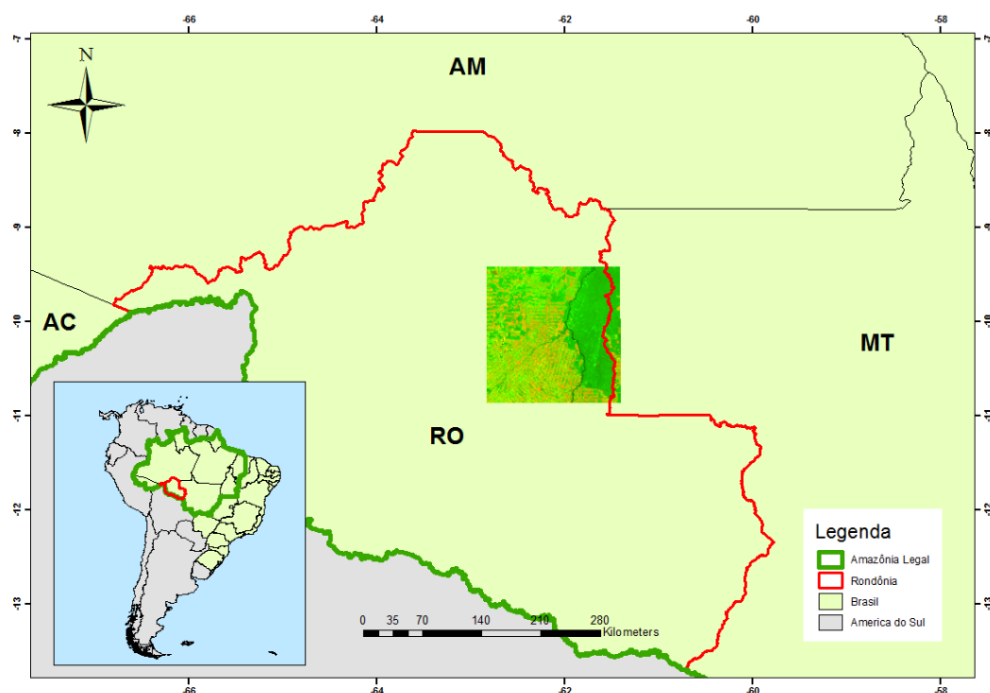


Figura 2: Área de estudo e localização da imagem Landsat 8. Bandas 6, 5 e 4 de 04/08/3013.

As principais classes de cobertura e uso da terra na área de estudo são, segundo o IBGE (2013), extrativismo vegetal em área florestal, unidades de conservação de proteção integral e de uso sustentável, pecuária de animais de grande porte, cultivos agrícolas, terras indígenas e cidades. Na figura 3 as classes de cultivos agrícolas e pecuária foram condensados em uma única classe (Agropecuária), assim como os dois tipos de unidades de conservação e terras indígenas (Unidades de conservação).

O estado de Rondônia é caracterizado por ter um histórico de altas taxas de desmatamento (INPE, 2003). Entre os anos de 2003 a 2005 houve um pico nas taxas de desmatamento em torno de 300.000 hectares/ano. Nos anos seguintes houve redução das taxas a até 80 hectares/ano em 2011, (PIONTEKOWSKI et al., 2014) o que faz do estado, mesmo com a redução, um dos principais emissores de carbono devido as áreas desmatadas.

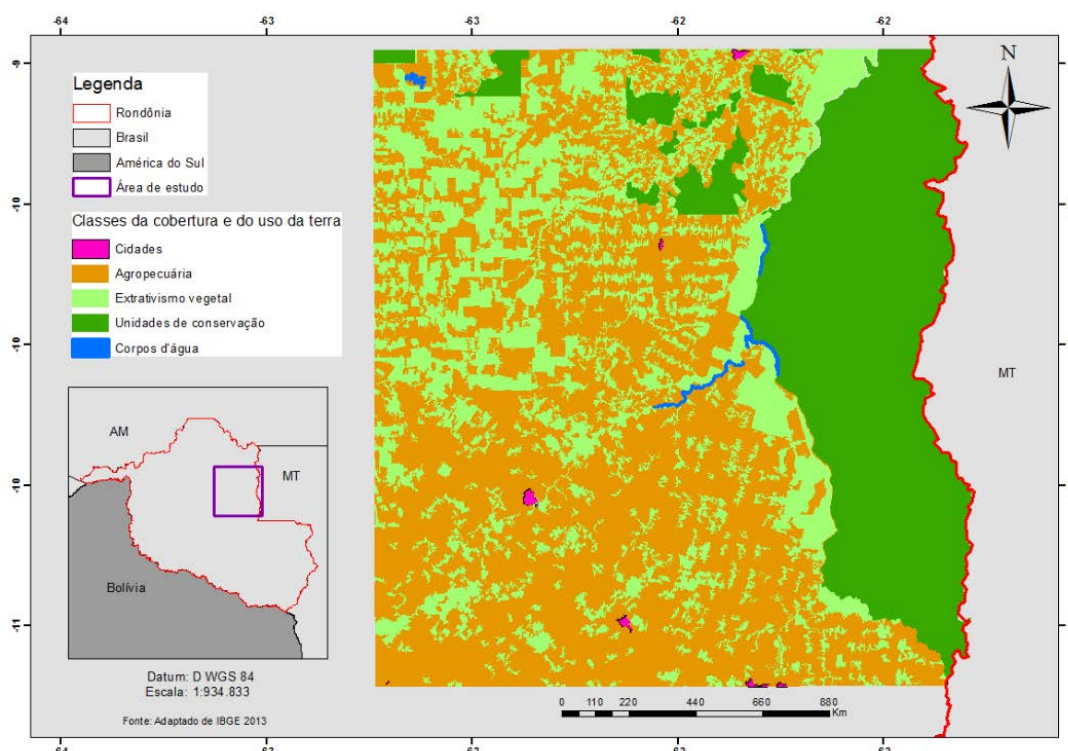


Figura 3: Mapa de uso da terra da área de estudo, adaptado de IBGE 2013.

4.2 Dados de Superfície e de Satélite

Para análise da variabilidade da PPB OLI/TIRS, foi utilizado o shapefile de cobertura e uso da terra, disponibilizado no site do IBGE http://downloads.ibge.gov.br/downloads_geociencias.htm do estado de Rondônia, recortado para a área de estudo (Figura 3).

As imagens utilizadas são provenientes do satélite Landsat 8, obtidas pelos sensores OLI e TIRS, por meio do site <http://glovis.usgs.gov/> (USGS, 2016). As imagens obtidas por estes sensores consistem de nove bandas multiespectrais com resolução espacial de 30 metros (bandas de 1 a 7 e 9), uma banda pancromática com resolução espacial de 15 m (banda 8) e duas bandas termais com resolução espacial de 100 m (banda 10 e 11). O tamanho aproximado da cena é de 170 km ao norte-sul por 183 km a leste-oeste, sendo selecionadas as cenas de 04 agosto de 2013, representando a estação seca, e 10 de outubro de 2014, representando a estação chuvosa, ambas sem a presença de nebulosidade.

Tabela 1: Data, sensor, hora da passagem em GMT (Greenwich Mean Time) e órbita/ponto e do satélite OLI/TIRS - Landsat 8 para a área de estudo – RO.

Ano	Satélite	Sensores	Data	Hora da passagem GMT	Órbita/Ponto
2013	Landsat 8	OLI e TIRS	04/08	14:16:56	231/67
2014	Landsat 8	OLI e TIRS	10/10	14:16:22	231/67

Para o cálculo da PPB também foram necessárias as variáveis de temperatura média do ar (T_{ar} em $^{\circ}C$) e radiação solar global ($KJ\ m^{-2}$) para as mesmas datas das imagens OLI/TIRS no momento da passagem do satélite. Esses dados foram adquiridos no Banco de Dados

Meteorológicos para Ensino e Pesquisa (BDMEP) do INMET (Instituto Nacional de Meteorologia), referente à Estação Meteorológica Convencional (EMC) de Ariquemes-RO. Para facilitar o computo, a T_{ar} foi transformada de C° para Kelvin e a radiação solar global de $KJ\ m^{-2}$ para $Watt\ m^{-2}$.

Tabela 2: Dados de superfície necessários ao cômputo. Data referente as imagens OLI/TIRS; Altitude da estação meteorológica; Temperatura média do dia das imagens em Kelvin e graus Celsius; Radiação solar global diária média em $Watt\ m^{-2}$.

Parâmetros	Data	
	04/08/2013	10/10/2014
Altitude estação meteorológica (m)	140	140
Temperatura média do ar (C°)	21	28,5
Temperatura média do ar (K)	294,15	301,65
Radiação solar global (W/m^2)	476,436	413

Os dados de precipitação pluvial foram obtidos a partir do satélite TRMM produto 3B43 no formato NetCDF (TRMM,2014), para os meses de agosto de 2013 e outubro de 2014 da região de estudo. Esse produto fornece dados com resolução espacial de aproximadamente 30 km e resolução temporal mensal. Utilizou-se o programa ArcGIS versão 10.2 para a conversão dos dados, originalmente em $mm.h^{-1}$ para $mm.dia^{-1}$.

4.3 Algoritmo SEBAL Aplicado aos Sensores OLI e TIRS

Componentes do Balanço de Radiação da superfície são necessários como dados de entrada para o cálculo da PPB. Para sua determinação, foi utilizado como padrão a sequência de procedimentos do algoritmo SEBAL (*Surface Energy Balance Algorithm for Land*) proposto por Bastiaanssen et al. (1998), sintetizada no fluxograma da Figura 4. Para algumas etapas do processo, realizou-se a adaptação dos coeficientes e parâmetros específicos do satélite Landsat 8. A temperatura da superfície foi calculada a partir das equações indicadas no site do Serviço Geológico Americano, USGS (2015). No software ERDAS IMAGINE 2015 foram calculadas:

- Reflectância de cada banda específica para os coeficientes radiométricos do satélite Landsat 8,
- União da reflectância,
- Índices de vegetação,
- Índice de área foliar,
- Emissividade de cada pixel no domínio espectral da banda termal,
- Emissividade da banda larga,
- Albedo no topo da atmosfera com equação ajustada as bandas do satélite,
- Albedo da superfície,
- Temperatura da superfície,
- Radiação de onda longa emitida pela atmosfera e superfície,
- Radiação de onda curta descendente emitida pela atmosfera,
- Saldo de radiação,
- Fluxo de calor do solo,
- Fluxo de calor sensível.

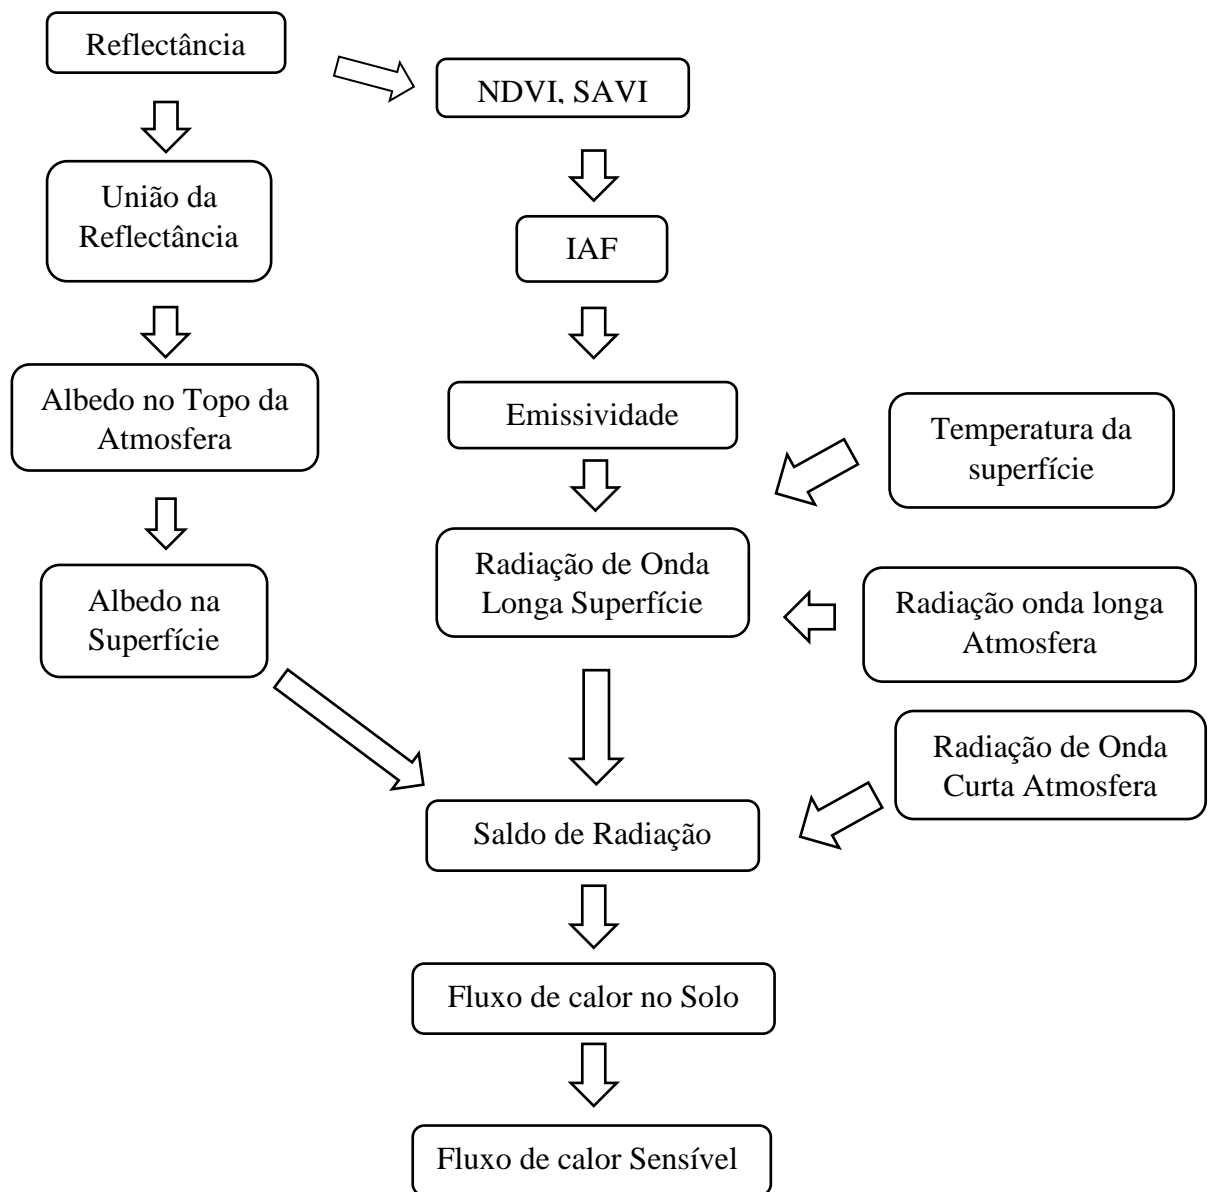


Figura 4: Fluxograma das etapas computacionais do processamento do balanço de radiação, fluxos de calor no solo e sensível pelo método do SEBAL.

4.3.1 Reflectância aparente (ρ_i)

A Reflectância aparente de cada banda (ρ_i), é definida como a razão entre o fluxo de radiação solar refletido pela superfície e o fluxo de radiação solar incidente. Para converter os valores (Q_{cal}) das imagens do sistema sensor Landsat 8 OLI para reflectância espectral, utilizou-se coeficientes radiométricos disponibilizados no arquivo de metadados das imagens. Os procedimentos foram obtidos no acervo online da USGS, através do site <https://landsat.usgs.gov/using-usgs-landsat-8-product>. A reflectância planetária no topo da atmosfera ($\rho\lambda'_i$) é calculada a partir da Equação 3:

$$\rho\lambda'_i = M_\rho \cdot Q_{cal} + A_\rho \quad (3)$$

Em que:

$\rho\lambda'_i$ = Reflectância planetária sem correção para o ângulo solar;
 M_ρ = Fator multiplicativo de reescalonamento para cada banda (disponível nos metadados da imagem);
 A_ρ = Fator aditivo de reescalonamento para cada banda (disponível nos metadados da imagem);
 Q_{cal} = Número digital para cada pixel;
 i = São as bandas (1,2,3,4,5,6,7) do satélite Landsat 8 OLI.

Para corrigir a reflectância em função do ângulo solar, usou-se a Equação 4:

$$\rho\lambda_i = \frac{\rho\lambda'_i}{\text{sen}(\theta_{SE})} \quad (4)$$

Em que:

$\rho\lambda_i$ = Reflectância planetária no topo da atmosfera corrigida;
 $\rho\lambda'_i$ = Reflectância planetária sem correção para o ângulo solar;
 θ_{SE} = Ângulo de elevação solar (disponível nos metadados da imagem);
 i = São as bandas (1,2,3,4,5,6,7) do satélite Landsat 8 OLI.

4.3.2 União da Reflectância

Para cada imagem foi realizado a união da refletividade, com a ferramenta *Layer Stack* do software ERDAS IMAGINE 2015, com exceção das bandas 10 e 11, por serem bandas termais não refletivas.

4.3.3 Índice de Vegetação da Diferença Normalizada (NDVI)

É a razão entre a diferença das refletividades das bandas no infravermelho próximo e no vermelho, pela soma dessas mesmas refletividades (ROUSE et al., 1973). 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. Nas superfícies que contêm água ou nuvens, esta variação é sempre menor do que 0. Será calculado pela seguinte equação:

$$NDVI = \frac{(\rho_V - \rho_{IV})}{(\rho_V + \rho_{IV})} \quad (5)$$

Em que: ρ_V e ρ_{IV} são os valores da refletância das bandas 4 e 5 do Landsat 8 OLI respectivamente.

4.3.4 Índice de vegetação Ajustado aos Efeitos do Solo (SAVI)

O cálculo do Índice de Vegetação Ajustado para os efeitos do Solo (*Soil Adjusted Vegetation Index* – SAVI), que leva em consideração efeitos do solo exposto nas imagens analisadas amenizando os efeitos de reflectância do solo. Através da inclusão de um fator de ajuste (L) que é variável com o grau de fechamento do dossel, permite uma melhoria na interpretação das variáveis da vegetação. Foi calculado através da equação de Huete (1988):

$$SAVI = \frac{(1+L) \times (\rho_{IV} - \rho_V)}{(L + \rho_{IV} + \rho_V)} \quad (6)$$

Em que:

SAVI = Índice de Vegetação Ajustado para os efeitos do Solo;

L = Constante, cujo valor usado foi 0,5 (BOEGH et al., 2002; SILVA et al., 2005);

ρ_{IV} = Refletividade do infravermelho próximo, correspondente a banda 5 do Landsat 8 OLI;

ρ_V = Refletividade do vermelho, correspondente a banda 4 do Landsat 8 OLI.

4.3.5 Índice de Área Foliar (IAF)

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, indicando a biomassa de cada pixel da imagem. Foi obtido pela seguinte equação empírica (ALLEN et al., 2002):

$$IAF = - \frac{\ln\left(\frac{0,69 - SAVI}{0,59}\right)}{(0,91)} \quad (7)$$

4.3.6 Emissividade (ϵ)

Como cada pixel não constitui um corpo negro, há necessidade de se estabelecer a emissividade de cada pixel das bandas termais (ϵ_{NB}) do espectro eletromagnético do Landsat 8 (banda 10 e 11). Para fins do cômputo da radiação de onda longa emitida pela superfície, que nesse caso é considerada a emissividade da banda larga (ϵ_0) (4 – 100 μm).

As emissividades foram obtidas através das seguintes equações (ALLEN et al., 2002):

$$\epsilon_{NB} = 0,97 + 0,00331IAF \quad (8)$$

$$\epsilon_0 = 0,95 + 0,011IAF \quad (9)$$

A equação (8) e (9) são validas para pixels com $IAF < 3$. Para valores de $IAF \geq 3$, considera-se, ϵ_{NB} e $\epsilon_0 = 0,98$ e para corpos de água ($NDVI < 0$), $\epsilon_{NB} = 0,99$ e $\epsilon_0 = 0,985$ segundo Allen et al. (2002).

4.3.7 Albedo Planetário ou Albedo do Topo da Atmosfera (α_{toa})

O cálculo do Albedo Planetário (α_{toa}), isto é, o albedo não ajustado, foi obtido pela combinação linear das refletâncias monocromáticas de cada banda reflectiva do Landsat 8 de acordo com adaptações nas equações de Ruhoff et al. (2015):

$$\alpha_{toa} = 0,300 \cdot \rho_1 + 0,277 \cdot \rho_2 + 0,233 \cdot \rho_3 + 0,143 \rho_4 + 0,036 \rho_5 + 0,012 \rho_7 \quad (10)$$

Em que:

α_{toa} = Albedo planetário;

$\rho_1, \rho_2, \rho_3, \rho_4, \rho_5$ e ρ_7 = reflectância planetária no topo da atmosfera das bandas 1, 2, 3, 4, 5 e 7.

4.3.8 Albedo da Superfície (α)

O cálculo do albedo da superfície para os efeitos atmosféricos (α) é obtido mediante correção atmosférica que considera a transmitância e a reflectância atmosférica em todo o domínio da radiação de onda curta, sendo determinado por meio da equação (BASTIAANSEN, 1995; BASTIAANSEN et al., 1998; ALLEN et al., 2002; SILVA et al., 2005):

$$\alpha = -\frac{\alpha_{toa} - \alpha_p}{\tau_{sw}^2} \quad (11)$$

Em que:

α = Albedo da Superfície;

α_{toa} = Albedo planetário;

α_p = Radiação solar refletida pela atmosfera que varia entre 0,025 e 0,04, foi utilizado o valor de 0,03 (é o mais comumente utilizado, considerado como valor médio);

τ_{sw} = Transmissividade atmosférica.

A transmissividade atmosférica foi calculada por meio da seguinte equação (ALLEN et al., 2002), para as condições de céu claro:

$$\tau_{sw} = 0,75 + 2 \times 10^{-5} z \quad (12)$$

Em que:

z = Altitude (m) da estação meteorológica da área estudada (Tabela 2)

4.3.9 Temperatura da Superfície (T_s)

O cálculo da temperatura da superfície (T_s), em graus Kelvin (K), foi obtido em função da radiância espectral da banda 10 ($L_{\lambda t}$), através das seguintes equações disponibilizadas pelos Serviço Geológico Americano (USGS, 2015):

$$L_{\lambda} = ML \cdot Q_{cal} \cdot AL \quad (13)$$

$$T_s = \frac{K_2}{\ln\left(\frac{K_1}{L_{\lambda t}} + 1\right)} \quad (14)$$

Em que:

$L_{\lambda t}$ = Radiância espectral da banda termal ($W/m^2 \cdot sr \cdot \mu m$);

ML = Fator multiplicativo de redimensionamento de banda 10 3,3420E-04 (No metadados);

Q_{cal} = Valor quantizado calibrado pelo pixel em DN = a própria imagem;

AL = Fator multiplicativo de redimensionamento aditivo da banda 10 = 0,10000 (No metadados);

T_s = Temperatura da superfície (K);

K_1 e K_2 = São constantes de calibração da banda termal do sensor TIRS do Landsat 8. 774,89 (K) e 1321,08 (K), respectivamente (No metadados da imagem);

4.3.10 Radiação de Onda Longa Emitida pela Superfície ($R_{L\uparrow}$)

Nesta etapa de cálculo a radiação de onda longa emitida pela superfície ($R_{L\uparrow}$) (Wm^{-2}), foi determinada pela equação de Stefan-Boltzmann, em função da temperatura da superfície (K) e da emissividade da superfície (ϵ_0):

$$R_{L\uparrow} = \epsilon_0 \cdot \sigma \cdot T_s \quad (15)$$

Em que:

$R_{L\uparrow}$ = Radiação de onda longa emitida pela superfície (Wm^{-2});

ϵ_0 = Emissividade de cada pixel (Equação 7);

σ = Constante de Stefan-Boltzman ($\sigma=5,67 \cdot 10^{-8} Wm^{-2}K^{-4}$);

T_s = Temperatura do ar (K) (Tabela 2).

4.3.11 Radiação de Onda Longa Emitida pela Atmosfera ($R_{L\downarrow}$)

A radiação de onda longa emitida pela atmosfera na direção da superfície ($R_{L\downarrow}$) ($W m^{-2}$) também foi calculada pela equação de Stefan-Boltzman (σ), em função da emissividade do ar (ϵ_a) e da temperatura do ar (T_a), obtida em estação meteorológica na área de estudo:

$$R_{L\downarrow} = \epsilon_a \cdot \sigma \cdot T_a^4 \quad (16)$$

Em que:

$R_{L\downarrow}$ = radiação de onda longa emitida pela atmosfera na direção da superfície ($W m^{-2}$);

ϵ_a = Emissividade do ar;

T_a = Temperatura do ar (K).

A emissividade do ar foi obtida segundo modelo proposto por Bastiaanssen (1995) e calibrado por Allen et al. (2002a):

$$\epsilon_a = 0,85(-\ln \cdot \tau_{sw}) \quad (17)$$

Em que:

τ_{sw} = Transmissividade atmosférica (Equação 12).

4.3.12 Radiação de Ondas Curtas espalhadas pela Atmosfera ($R_{s\downarrow}$)

A radiação de ondas curtas incidentes ($R_{s\downarrow}$) corresponde ao fluxo de radiação solar (direta e difusa) que atinge a superfície terrestre e que, para condição de céu claro, foi obtida pela equação (BASTIAANSSEN, 1995; SILVA et al, 2011):

$$R_{s\downarrow} = S \cdot \cos Z \cdot d_r \cdot \tau_{sw} \quad (18)$$

Em que:

$R_{s\downarrow}$ = Radiação de ondas curtas incidentes;

S = Constante solar (1367 Wm^{-2});

Z = Ângulo zenital solar (obtido no cabeçalho das imagens adquiridas, e depende da órbita, ponto e época do ano) (Tabela 3);

d_r = Inverso do quadrado da distância relativa Terra-Sol, dada por (ALLEN et al., 2007);

τ_{sw} = Transmissividade atmosférica (Equação 12).

4.3.13 Saldo de Radiação (R_n)

Por fim, o saldo de radiação à superfície (R_n) (Wm^{-2}), será calculado através da seguinte equação do balanço de radiação à superfície (SILVA,2011):

$$R_n = R_{S\downarrow} - \alpha R_{S\downarrow} + R_{L\downarrow} - R_{L\uparrow} (1 - \varepsilon_0) R_{L\downarrow} \quad (19)$$

Em que:

R_n = Saldo de Radiação (Wm^{-2});

$R_{S\downarrow}$ = Radiação de ondas curtas emitidas pela atmosfera (incidente) (Wm^{-2});

α = Albedo da superfície (unidade);

$R_{L\downarrow}$ = Radiação de onda longa emitida pela atmosfera na direção de cada pixel (Wm^{-2});

$R_{L\uparrow}$ = Radiação de onda longa emitida pela superfície (cada pixel) (Wm^{-2});

ε_0 = Emissividade de cada pixel.

Tabela 3: Parâmetros utilizados nas equações para calcular o saldo de radiação.

Parâmetros	Data	
	04/08/2013	10/10/2014
Dia do ano	216	283
Latitude (°)	-10,76	-10,76
Elevação do sol (°)	50,2404	64,9826
Ângulo Zenital solar (Z°)	39,7596	25,0174
Dia astronômico do ano (U.A)	0,9723	1,0052
Temperatura do ar (K)	274,1223	274,1552

4.3.14 Fluxo de Calor no Solo (G)

O fluxo de calor no solo (G) é a quantidade de energia necessária para aquecer o solo. Diversos fatores exercem influência neste parâmetro que possui grande variedade espacial e temporal. O aquecimento superficial do solo é condicionado pela quantidade de radiação solar absorvida, ou seja, depende da radiação solar, propriedades do solo, como a condutividade térmica, e tipo de cobertura vegetal. Portanto, a abordagem mais usualmente empregada para estimar G através de imagens de satélite é uma relação empírica a partir do saldo de radiação. O SEBAL computa a razão entre o fluxo de calor no solo e o saldo de radiação, representando valores próximos ao meio-dia, a partir da equação desenvolvida por Bastiaanssen (2000):

$$G = \left[\frac{T_s}{\alpha} (0,0038\alpha + 0,0074\alpha^2)(1 - 0,98NDVI^4) \right] R_n \quad (20)$$

Em que:

T_s = Temperatura da superfície (°C);

α = albedo da superfície;

NDVI = Índice de Vegetação da Diferença Normalizada;

R_n = Saldo de Radiação.

4.3.15 Fluxo de Calor Sensível (H)

A determinação do fluxo de calor sensível (H) é a etapa mais complexa do modelo SEBAL. Sua estimativa requer uma série de processos iterativos para ser corretamente computada.

O H foi calculado por:

$$H = \rho C_p \frac{(a+b T_s)}{r_{ah}} \quad (21)$$

Em que:

H = fluxo de calor sensível;

ρ = densidade do ar (1,15 K g m⁻³);

C_p = calor específico do ar à pressão constante de (1,004 J K g⁻¹ K⁻¹);

a e b = constantes de calibração da diferença de temperatura;

T_s = temperatura da superfície (K);

r_{ah} = resistência aerodinâmica ao transporte de calor (s m⁻²).

O fluxo de calor sensível é obtido através de um processo iterativo que compreende a resistência aerodinâmica da superfície e a temperatura da superfície de pontos chamados de pixels-âncora. Os pixels-âncora são pontos localizados na imagem que representam duas condições de fluxo de calor: o pixel frio, que representa uma área úmida onde se assume que o fluxo de calor sensível é nulo, e o de calor latente é máximo. E o pixel quente, no qual deve ser selecionado numa área de solo exposto, onde não há umidade suficiente para ocorrer a evapotranspiração. Neste caso o fluxo de calor sensível é mínimo e o fluxo e calor latente é máximo.

Neste estudo, os pixels frio e quente foram escolhidos, respectivamente, sobre uma porção da imagem com floresta ombrófila densa e sobre uma região de solo exposto. Também foram necessários dados da estação meteorológica mais representativa da área de estudo. Seguem abaixo as equações necessárias ao processo iterativo:

Velocidade de fricção do vento u_* (ms⁻¹) utilizando seu perfil logarítmico considerando neutralidade da atmosfera é calculado por:

$$u_* = \frac{k u_x}{\ln\left(\frac{100}{z_{om}}\right)} \quad (22)$$

Em que:

u^* = Velocidade de fricção do vento (ms^{-1});
 u_x = é a velocidade do vento (m s^{-1}) na altura Z_x (elevação local em m);
 k = constante de von Karman = 0,41 (Silva Filho et al., 1992);
 Z_{0m} = é o parâmetro de rugosidade estimado pelo valor da altura média da vegetação existente no entorno da área da estação meteorológica. É calculado pela equação apresentada por Brutsaert (1982):

$$Z_{0m} = 0,123 \times h \quad (23)$$

Em que:

Z_{0m} = Coeficiente de rugosidade local;

h = Altura média da vegetação (m) no entorno da área da estação meteorológica (Neste estudo considerou-se a altura de 0,08).

Considerando-se ainda a atmosfera em equilíbrio neutro, foi estimada a velocidade de fricção do vento a 100 m, onde se assume que os efeitos da rugosidade da superfície são desprezíveis, a chamada *blending height*, dada pela equação:

$$u_{100} = u_* \frac{\ln\left(\frac{100}{Z_{0m}}\right)}{k} \quad (24)$$

Com o pressuposto que u_{100} é constante em toda a área de estudo, pode-se obter a velocidade de fricção u_* (ms^{-1}) para cada pixel da imagem, pela equação:

$$u_* = \frac{u_{100} k}{\ln\left(\frac{100}{Z_{0m}}\right)} \quad (25)$$

Em que neste caso, Z_{0m} em cada pixel foi obtido em função do SAVI calculado anteriormente no saldo de radiação. Para isso foi utilizada a proposta de Bastiaanssen (1995), qual seja:

$$Z_{0m} = \exp(-5,809 + 5,62 \text{ SAVI}) \quad (26)$$

A partir dos valores de u_* calculados para cada pixel, foi estimada a resistência aerodinâmica (r_{ah}) (em s m^{-1}). Neste caso também se aceita a atmosfera em condições de estabilidade neutra, segundo a equação:

$$r_{ah} = \frac{\ln\left(\frac{Z_2}{Z_1}\right)}{k u_*} \quad (27)$$

Em que:

r_{ah} = resistência aerodinâmica no transporte ao calor (s m^{-1})

Z_1 e Z_2 = alturas em metros acima da superfície (Neste estudo considerou-se 0,1 e 2 respectivamente).

O cálculo da diferença de temperatura próxima à superfície dT ($^{\circ}\text{C}$) para cada pixel é dado pelo SEBAL através da relação linear entre dT e a temperatura da superfície (T_s) dos pixels “quente e frio”:

$$dT = a + bT_s \quad (28)$$

Em que:

a e b = são coeficientes empíricos, que dependem dos pixels âncoras selecionados (pixels “quente” e “frio”).

Segundo Bastiaansen (2002), assume-se que o fluxo de calor sensível é nulo para o pixel “frio”, ou seja, $H = 0$ e o fluxo do calor latente é obtido por:

$$\lambda E T_{\text{Pixel frio}} = R_n - G \quad (29)$$

Para o pixel “quente” é determinado que o fluxo de calor latente é nulo, ou seja, $\lambda E = 0$, e o fluxo de calor sensível (H) é dado por:

$$H_{\text{pixel quente}} = R_n - G = \frac{\rho c_p (a+bT_s)}{r_{ah}} \quad (30)$$

Onde, R_n , G , T_s e r_{ah} são os valores encontrados para o pixel “quente” escolhido.

Com base nas equações acima e nos valores de dT determinados para os pixels quente e frio, é estabelecido uma relação linear através da resolução do sistema de equações, sendo:

$$a + b dT = r_{ah} \frac{(R_n - G)}{\rho c_p} \quad (\text{Pixel quente}) \quad (31)$$

$$a + b T_s = 0 \quad (\text{Pixel frio}) \quad (32)$$

Assim, pode-se determinar os valores de a e b iniciais.

Os valores de H estimados a partir dos pixels âncora são somente o início do processo iterativo. Eles não representam o fluxo de calor sensível de cada pixel de forma apropriada. Para isso, é aplicada a teoria de Monin-Obukhov que considera os efeitos da rugosidade e da estabilidade atmosférica, e pode estimar os valores corrigidos de r_{ah} para as iterações seguintes (Brutsaert, 1982). A estimativa do comprimento de Monin-Obukhov (m) se dá por:

$$L = - \frac{\rho c_p u_*^3 T_s}{kgH} \quad (33)$$

Em que: todos os elementos foram apresentados nas equações acima exceto $g(m s^{-2})$ = módulo de aceleração da gravidade.

Foram utilizadas as formulas de Paulson (1970) e Webb (1970) para corrigir o perfil de vento de acordo com as condições atmosféricas instável, estável e neutra. Estimou-se os valores da correção transporte de *momentum* (Ψ_m) e do transporte de calor (Ψ_h). A partir destes cálculos, pode-se corrigir o valor de u_* para os pixels das imagens. Segue equações abaixo:

$$u_* = \frac{u_{100} k}{\ln\left(\frac{100}{z_{0m}}\right) - \Psi_{m(100)}} \quad (34)$$

Em que: Ψ_m (100m) é o fator de correção para o transporte de momentum obtido em todos os pixels da imagem.

Desta maneira com os valores de u_* corrigidos para cada pixel, os valores da resistência aerodinâmica ao transporte de calor sensível corrigido (r_{ah}) e dado por:

$$r_{ah} = \frac{\ln\left(\frac{z_2}{z_1}\right) - \Psi_h(z_2) + \Psi_h(z_1)}{k u_*} \quad (35)$$

Em que: $\Psi_h(z_2)$ e $\Psi_h(z_1)$ são as correções de estabilidade para o transporte de calor a 2,0 m e 0,1 m, respectivamente.

Com os novos valores de r_{ah} , retornou-se ao cálculo de dT e posteriormente de H . O processo foi repetido várias vezes até a estabilização dos valores de dT , r_{ah} , e as constantes de calibração da diferença de temperatura (a e b). Foram necessárias 8 repetições do processo iterativo para a imagem representando o período seco e 11 iterações para a imagem representando o período chuvoso.

4.4 Processo de estimativa da Produtividade Primária Bruta

A taxa de CO_2 presente na atmosfera que é convertido pela fotossíntese em substâncias orgânicas é chamado de Produtividade Primária Bruta - PPB (BEER et al., 2010). A PPB é considerada a quantidade total de dióxido de carbono fixado pelo ecossistema, medida em unidades de massa de carbono por área por tempo (ex. $g C m^{-2} ano^{-1}$) (CHAPIN III et al., 2002).

De acordo com a metodologia proposta por Silva et al. (2012), sua 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) que é definida pela razão entre o fluxo de calor latente e o saldo de radiação para determinar as necessidades hídricas e evapotranspiração. A FE é obtida através do cálculo do Balanço de Energia calculado através do SEBAL. 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 – $R_{s,24h}$ 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):

$$PPB = RFAA \times \varepsilon \quad (36)$$

Onde, RFAA é a radiação fotossinteticamente ativa absorvida – RFAA ($W m^{-2}$) pela vegetação, e “ ε ” ($g C MJ^{-1}$) é a eficiência do uso de luz da vegetação. O cálculo da radiação fotossinteticamente ativa absorvida – RFAA pode ser desenvolvido em função do Índice de Vegetação da Diferença Normalizada - NDVI, proposta por Daughtry et al. (1995) como na equação abaixo:

$$RFAA = RFA \times (-0,161 + 1,257 NDVI) \quad (37)$$

A radiação RFA, que é absorvida pela vegetação, pode ser estimada em função da radiação solar global diária, de acordo com Bastiaanssen e Ali (2003), através da equação:

$$RFA = 0,48 \times R_{s,24h} (W m^{-2}) \quad (38)$$

Com base nos dados diários da radiação solar global diária ($W m^{-2}$), que foi obtido na estação meteorológica automática do INMET (Tabela 2), foi calculada a Radiação Fotossinteticamente Ativa ($W m^{-2}$) para todos os dias selecionados para a pesquisa (Tabela 3).

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):

$$\varepsilon = \varepsilon' \times T_1 \times T_2 \times FE \quad (39)$$

Em que, ε' representa a eficiência máxima de uso da luz pela vegetação (considerada na pesquisa igual a $2,15 g C MJ^{-1}$, FE é a fração evaporativa, e T_1 e T_2 referem-se a contribuição da temperatura na eficiência de uso da luz pelas plantas, podendo ser calculados por:

$$T_1 = 0,8 + 0,02 T_{opt} - 0,0005 T_{opt}^2 \quad (40)$$

$$T_2 = \frac{1}{1 + \exp(0,2 T_{opt} - 10 - T_{dia})} \times \frac{1}{1 + \exp [0,3(- T_{opt} - 10 - T_{dia})]} \quad (41)$$

Em que, T_{opt} é a temperatura média do ar ($^{\circ}C$) do mês de máximo NDVI e T_{dia} é a temperatura média diária do ar ($^{\circ}C$).

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 (BASTIAANSSEN et al., 1998; SILVA e BEZERRA, 2006; ALLEN et al., 2007) de acordo com a equação:

$$FE = \frac{LE}{(Rn - G)} \quad (42)$$

Em que, Rn ($W m^{-2}$) o saldo de radiação, G ($W m^{-2}$) é a densidade do fluxo de calor no solo e LE ($W m^{-2}$) a densidade do fluxo de calor latente.

Através do SEBAL se obtêm a densidade do fluxo de calor latente - LE calculado como resíduo do balanço de energia à superfície, segundo a expressão:

$$LE = Rn - G - H \quad (43)$$

Em que, H ($W m^{-2}$) é a densidade do fluxo de calor sensível, calculado anteriormente.

4.5 Comparação dos algoritmos

Para comparação da estimativa da PPB referente às imagens do Landsat 8, foram utilizados dados do sensor MODIS, produto MOD17A2. O produto foi obtido no site https://lpdaac.usgs.gov/data_access/data_pool para o estado de Rondônia para os anos de 2013 e 2014. As imagens MODIS são de datas próximas as datas das imagens OLI/TIRS. Na escolha das imagens de cada sensor, critérios como temperatura do ar e pluviosidade similares também foram considerados. Não foi possível comparar as imagens com a mesma data, devido ao período de disponibilidade das imagens do sensor MODIS (a cada 8 dias), e a dificuldade de encontrar uma imagem OLI/TIRS, sem nebulosidade, com data correspondente.

As imagens foram pré-processadas no software MRT (*Modis Reprojection Tools*) do formato HDF para GEOTIFF, e da projeção Sinusoidal para o sistema geográfico de coordenadas em *datum* WGS 84. Os números digitais das imagens MODIS foram convertidos em valores biofísicos (Kg C m^{-2}) através da multiplicação pelo fator de escala (0,0001) segundo Heinsch et al. (2003). Os valores de PPB também foram transformados do valor acumulado a cada 8 dias para média de PPB a cada 8 dias e convertidos de $\text{Kg C m}^{-2} \text{ dia}^{-1}$ para $\text{g C m}^{-2} \text{ dia}^{-1}$.

Os dados de PPB do produto MOD17A2 utilizados para a comparação foram os referentes à média dos pixels da mesma área delimitada para as imagens OLI/TIRS. Somente foram utilizados os pixels com boa qualidade, obtida pelo “MODIS Quality Control” (QC). Nesse caso, um pixel foi apenas considerado quando o QC atendia as seguintes exigências:

- categoria “CLOUDSTATE” é igual a 0 (nuvens significativas não presentes) ou 3 (estado de cobertura de nuvens não definido, assume-se estado de céu claro);
- categoria “SCF_QC” igual a 0 (método utilizado com melhores resultados possíveis) ou 1 (método usado com saturação).

Inicialmente seriam utilizados para comparação, os dados de PPB de duas torres micrometeorológicas de fluxo, localizadas em área de pastagem e floresta do projeto LBA, próximas a área de estudo. Porém, devido a manutenção das torres os dados só foram divulgados até 2006, inviabilizando a comparação com imagens Landsat 8, disponíveis a partir de 2013.

Primeiramente os pixels de 30 m de resolução do satélite Landsat 8 foram reamostrados para 500 m, de acordo com a resolução MODIS. Para a comparação dos dados calculados a partir dos sensores OLI/TIRS com os valores derivados do produto MOD17A2, foram selecionados 500 pixels de cada uso do solo. Os parâmetros estatísticos aplicados foram: Erro Médio (EM) e Raiz do Erro Médio Quadrático (REMQ) e coeficiente de correlação de Spearman (ρ). A significância do ρ foi avaliada pelo teste t de Student, com α de 0,05. Todas as análises foram realizadas no software R, versão 3.4.2.

$$EM = \frac{\sum_{i=1}^N (E_i - O_i)}{N} \quad (44)$$

$$REMQ = \sqrt{\frac{1}{N} \sum_{i=1}^N (E_i - O_i)^2} \quad (45)$$

Em que N é o número de observações, E_i a PPB estimada (mensurada pelo modelo), O_i a PPB observada (mensurada através de dados MOD17A2), \bar{E} e \bar{O} são as médias dos valores de E_i e O_i .

5 RESULTADOS E DISCUSSÃO

5.1 Análise da PPB OLI/TIRS

Nas Figuras 11 e 12 são apresentados os mapas temáticos da PPB estimada a partir do algoritmo aplicado aos sensores OLI/TIRS para a área de estudo.

Observa-se que não há diferença perceptível dos padrões espaciais em cada data, onde o valor de PPB é substancialmente superior para as áreas que compreendem a cobertura florestal (Figuras 11 e 12).

Os usos Floresta e Extrativismo apresentaram os maiores valores médios de PPB no período seco, com $13,83 \text{ gCm}^{-2}\text{dia}^{-1}$, e $13,94 \text{ gCm}^{-2}\text{dia}^{-1}$, respectivamente. Obteve-se valores próximos de PPB para os dois usos pois se tratam de áreas com cobertura florestal (Tabela 4).

O mesmo padrão foi observado para o período úmido (Tabela 5). As médias obtidas para Floresta e Extrativismo foram de $7,35 \text{ gCm}^{-2}\text{dia}^{-1}$ e $6,99 \text{ gCm}^{-2}\text{dia}^{-1}$, respectivamente, com maior variação para Extrativismo, com desvio padrão de $0,31 \text{ g C m}^{-2} \text{ dia}^{-1}$. A maior variabilidade de valores para o uso Extrativismo provavelmente se dá devido a intervenção antrópica neste uso e características fenológicas da vegetação. Segundo o IBGE (2013) as principais atividades são a extração de madeira, o cultivo da castanha e extração da seringa. Além disso, são caracterizados como remanescentes florestais no formato de fragmentos onde a produtividade é reduzida também pelo efeito de borda, em comparação com áreas com vegetação homogênea, destacando a presença de pixels com baixa produtividade.

Os usos Agropecuária e Cidades apresentaram os menores valores de PPB em comparação com os outros usos, em cada período. Em 2013 (estação seca) obteve-se $6,34$ e $1,53 \text{ gCm}^{-2}\text{dia}^{-1}$ respectivamente e 2014 (estação chuvosa) $1,71$ e $0,27 \text{ gCm}^{-2}\text{dia}^{-1}$, respectivamente.




Figura 5: Variabilidade espacial da Produtividade Primária Bruta ($\text{g C m}^{-2} \text{ dia}^{-1}$) estimada a partir do sensor OLI/TIRS para o dia 04/08/2013.

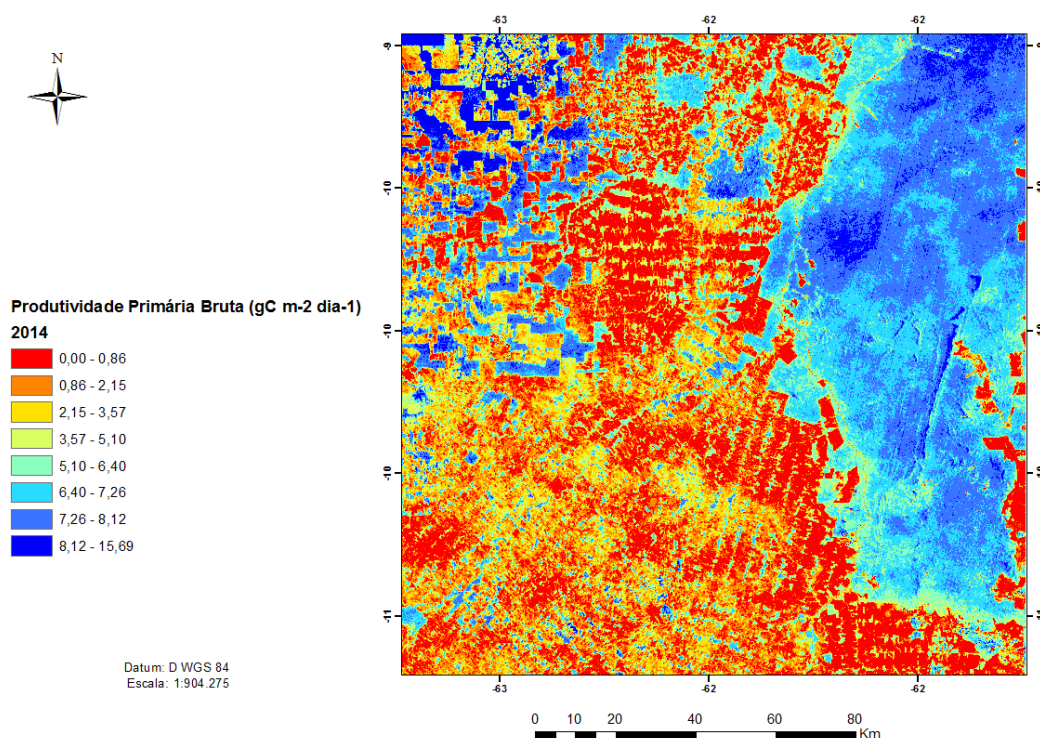


Figura 6: Variabilidade espacial da Produtividade Primária Bruta ($\text{g C m}^{-2} \text{ dia}^{-1}$) estimada a partir do sensor OLI/TIRS para o dia 10/10/2014.

Tabela 4: Estatística descritiva da PPB OLI/TIRS em cada uso do solo na estação seca.

Ano	n	Uso do solo	PPB ($\text{gC m}^{-2} \text{ dia}^{-1}$)				
			média	sd	min	max	erro padrão
2013	500	Floresta	13,83	0,06	0,22	15,74	0,00
2013	500	Extrativismo	13,94	0,06	0,14	15,82	0,00
2013	500	Agropecuária	6,34	0,19	0,04	15,86	0,01
2013	500	Cidade	1,53	0,07	0,00	15,68	0,00

Tabela 5: Estatística descritiva da PPB OLI/TIRS em cada uso do solo na estação chuvosa.

Ano	n	Uso do solo	PPB ($\text{gC m}^{-2} \text{ dia}^{-1}$)				
			média	sd	min	max	erro padrão
2014	500	Floresta	7,35	0,08	0,06	11,03	0,00
2014	500	Extrativismo	6,99	0,31	0,13	9,69	0,01
2014	500	Agropecuária	1,71	0,06	0,03	7,34	0,00
2014	500	Cidade	0,27	0,01	0,00	4,84	0,00

Comparando a PPB encontrada entre os dois períodos estudados, os valores encontrados para cada uso da terra na estação seca (2013) foram em média maiores que da estação chuvosa

(2014) (Tabelas 4 e 5), provavelmente resultado da maior oferta da Radiação Fotossinteticamente Ativa para a data da imagem de 2013. A Radiação Solar Global diária ($R_{s,24h}$) obtida na Estação Convencional, para o momento da passagem do satélite de cada imagem, foi de 476 Wm^{-2} para a estação seca e 413 Wm^{-2} para a estação chuvosa.

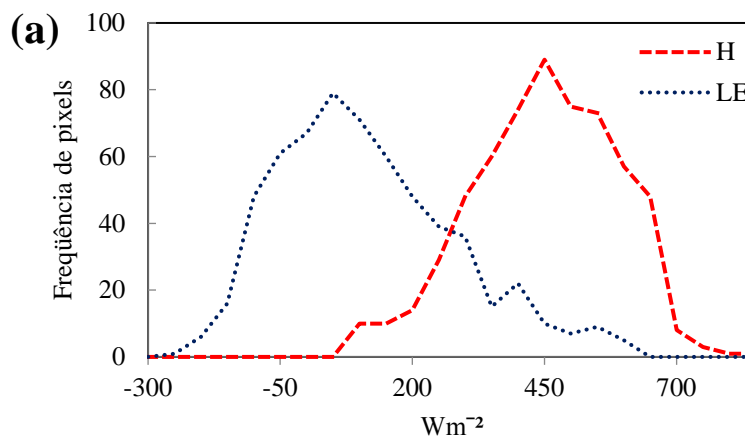
A estimativa da Radiação Fotossinteticamente Ativa (RFA) que depende da $R_{s,24h}$, resultou em $228,69 \text{ Wm}^{-2}$ para a estação seca, e $198,24 \text{ Wm}^{-2}$ para a estação chuvosa (Tabela 6). A sazonalidade da RFA também está relacionada á cobertura de nuvens. No período seco a nebulosidade é menor, o que aumenta a transmitância atmosférica, elevando os valores de RFA.

Tabela 6: Data das imagens, Radiação Solar Global diária, para o momento de passagem do satélite, e estimativa da Radiação Fotossinteticamente Ativa.

Data	$R_{s,24h}$ (Wm^{-2})	RFA
04/08/2013	476	228,48
10/10/2014	413	198,24

5.2 Análise dos parâmetros da PPB OLI/TIRS

Na Figura 5 podemos observar o histograma de valores de H e LE das áreas antropizadas. Estas áreas possuem padrões onde a maior parcela da energia radiante é convertida em fluxo de calor sensível, aquecendo a superfície, enquanto o fluxo de calor latente é menor, o que diminui a umidade do ar. Analisando as diferenças entre os dois períodos, os padrões de H e LE encontrados ratificam os maiores valores de PPB para o período seco, pois as diferenças entre H e LE são menores que no período úmido. Maiores diferenças entre H e LE, sugerem baixa umidade no solo, portanto a produtividade fotossintética fica reduzida.



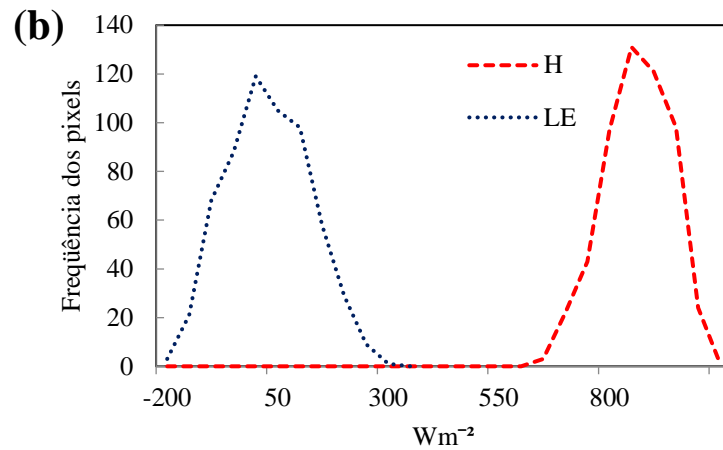


Figura 7: Histograma dos pixels dos fluxos de calor sensível (H) e calor latente (LE) das áreas antropizadas (Agropecuária e Cidades) 04/08/2013 (A) e 10/10/2014 (B).

Na figura 6 apresentam-se os valores e a espacialização da precipitação diária da região, provenientes do TRMM, para as mesmas datas das imagens Landsat utilizadas no estudo.

A a variabilidade da precipitação média diária, para região de estudo no total foi de 0,27 mm para agosto de 2013, e de 7,04 mm para outubro de 2014. Apesar dos maiores índices de pluviosidade na estação chuvosa, uma maior cobertura de nuvens limita a incidência de radiação na superfície, o que conseqüentemente induz a redução dos valores da PPB.

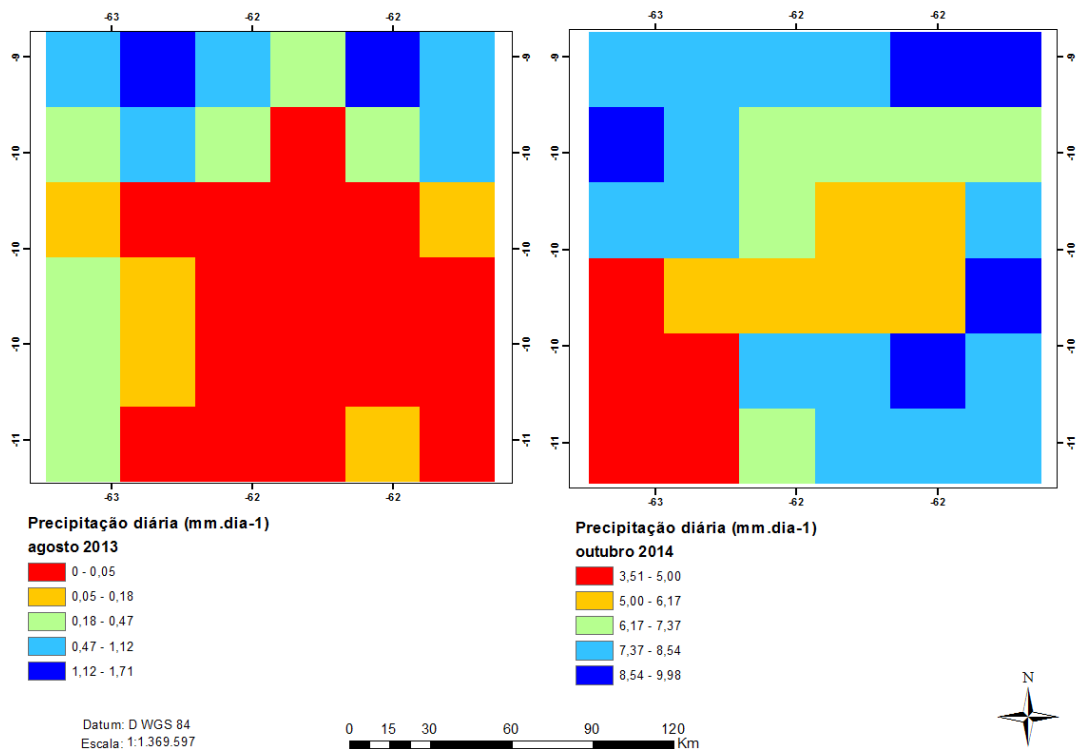


Figura 8: Variabilidade da média diária da precipitação para o mês de agosto de 2013 (A) e para o mês de outubro de 2014 (B) para área de estudo. Dados TRMM, produto 3B43.

Resultados semelhantes foram encontrados por Saleska (2009). Este estudo da análise da PPB a partir de dados de fluxos turbulentos em campo e por sensoriamento remoto, validadas pelo Sensor MODIS, concluíram que as florestas tropicais amazônicas não possuem uma limitação pela água em escala sazonal e os fluxos fotossintéticos respondem mais a combinação da energia solar disponível e as características fenológicas da vegetação.

Outro dado que pode explicar os maiores valores de PPB para o período seco são os valores médios encontrados para a Fração Evaporativa – FE (Tabela 7). Segundo o SEBAL (BASTIAANSEN et al., 1998) a partir dos valores de FE pode-se calcular a evapotranspiração diária. A FE representa a influência da umidade para a realização da fotossíntese, relacionando os fluxos de calor latente, fluxo de calor no solo e saldo de radiação.

Tabela 7: Médias da Fração Evaporativa para cada uso do solo das imagens estudadas.

Ano	FE (Wm^{-2})			
	Floresta	Extrativismo	Agropecuária	Cidades
2013	0,90	0,93	0,34	-0,02
2014	0,29	0,27	0,08	-0,05

Os maiores valores de FE foram encontrados para a imagem de 2013 que também apresentou os maiores valores de PPB em geral para toda área de estudo (Figuras 7 e 8). Da Rocha et al (2009) em estudos sobre fluxo de água e radiação líquida disponível, concluíram que em todos os sítios estudados na estação seca, a ausência de nebulosidade aumenta a energia disponível, implicando em evapotranspiração mais alta.

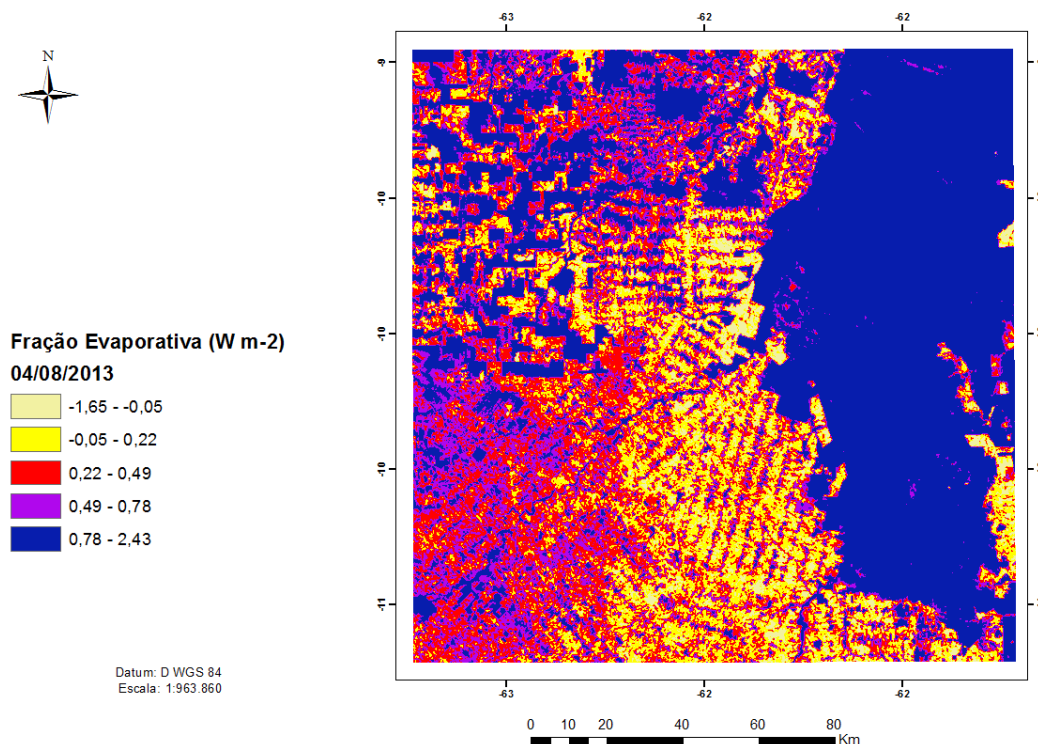


Figura 9: Variabilidade espacial da Fração Evaporativa - FE ($W m^{-2}$) estimada a partir do sensor OLI/TIRS para o dia 04/08/2013.

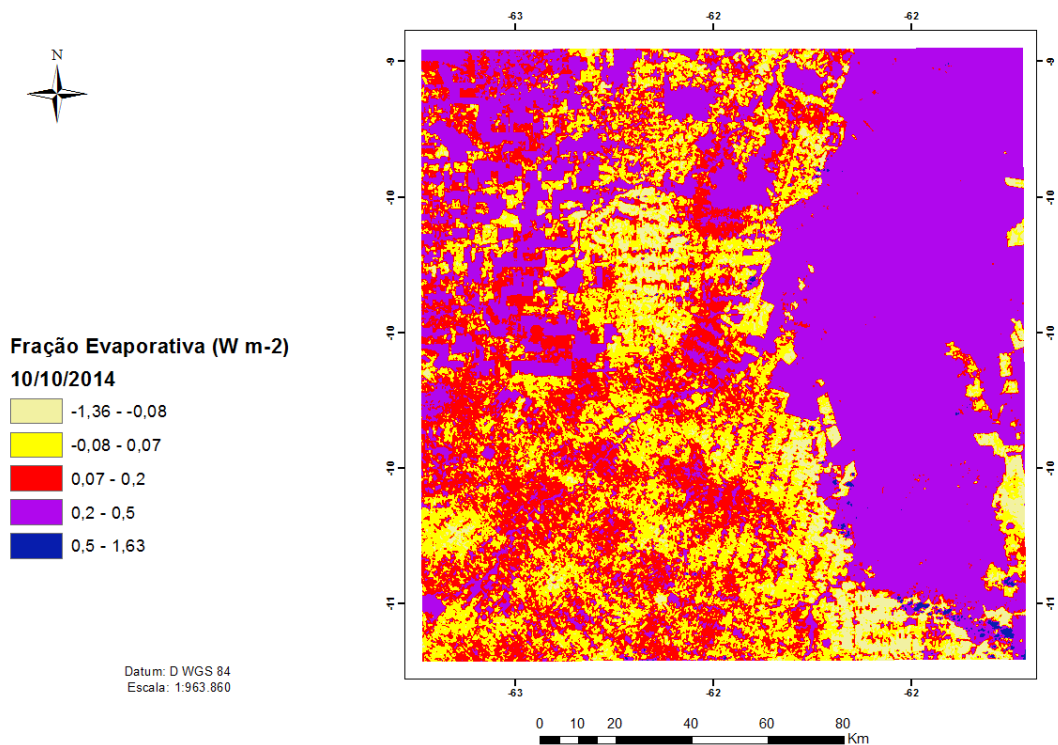


Figura 10: Variabilidade espacial da Fração Evaporativa - FE ($W m^{-2}$) estimada a partir do sensor OLI/TIRS para o dia 10/10/2014.

Para a estação seca, o NDVI apresentou 0,76 e 0,74 para os usos de Floresta e Extrativismo, respectivamente e 0,54 e 0,32 para os usos Agropecuária e Cidades (Figura 9).

Para a estação chuvosa o NDVI apresentou valores de 0,70 e 0,71 para os usos de Floresta e Extrativismo e 0,56 e 0,36 para os usos Agropecuária e Cidades (Figura 10).

A saturação do NDVI na estação seca se deu à medida que o dossel aproximou seu estágio de crescimento vegetativo máximo. O NDVI chega à sua saturação com altos valores do Índice de Área Foliar (IAF). Isto ocorre pela influência da radiação na trajetória atmosférica, ampliando o brilho e efeito espectral do solo, o que interfere na avaliação da vegetação (JANSEN, 2009), o que pode explicar a alta produtividade encontrada para a imagem representativa da estação seca.

Com comportamento inverso ao NDVI, os valores de albedo da superfície e temperatura da superfície encontrados, evidenciam as diferenças na cobertura da região, apresentando os maiores valores para Agropecuária e Cidades e os menores para Floresta e Extrativismo para as duas estações (Figuras 11 e 12).

Alves et al, (2017) calculando o balanço de radiação a partir de imagens Landsat 8, na Bacia do Rio Pajeú na divisa entre os estados do Ceará e Paraíba, observaram que valores de albedo aumentam juntamente a temperatura da superfície em diferentes usos. Os valores de albedo encontrados para as estações seca e chuvosa variaram de 0,12 a 0,14 para áreas vegetadas, e de 0,17 a 0,21 para as áreas com intervenção antrópica. Ruhoff et al (2015) também com imagens Landsat 8, numa microbacia no Parque Estadual da Serra do Mar, no estado de São Paulo, encontrou valores de albedo para áreas de floresta ombrófila densa entre 0,11 e 0,12 e para áreas urbanas, de campos e pastagens encontraram valores de albedo acima de 0,14 corroborando com os valores encontrados nesta pesquisa.

Os valores de albedo correspondem ao tipo de cobertura da superfície onde parte da energia incidente é absorvida e parte é refletida. Áreas sem cobertura vegetal apresentam alta

refletividade difusa e baixa absorção de energia, aumentando o albedo e consequentemente a temperatura da superfície

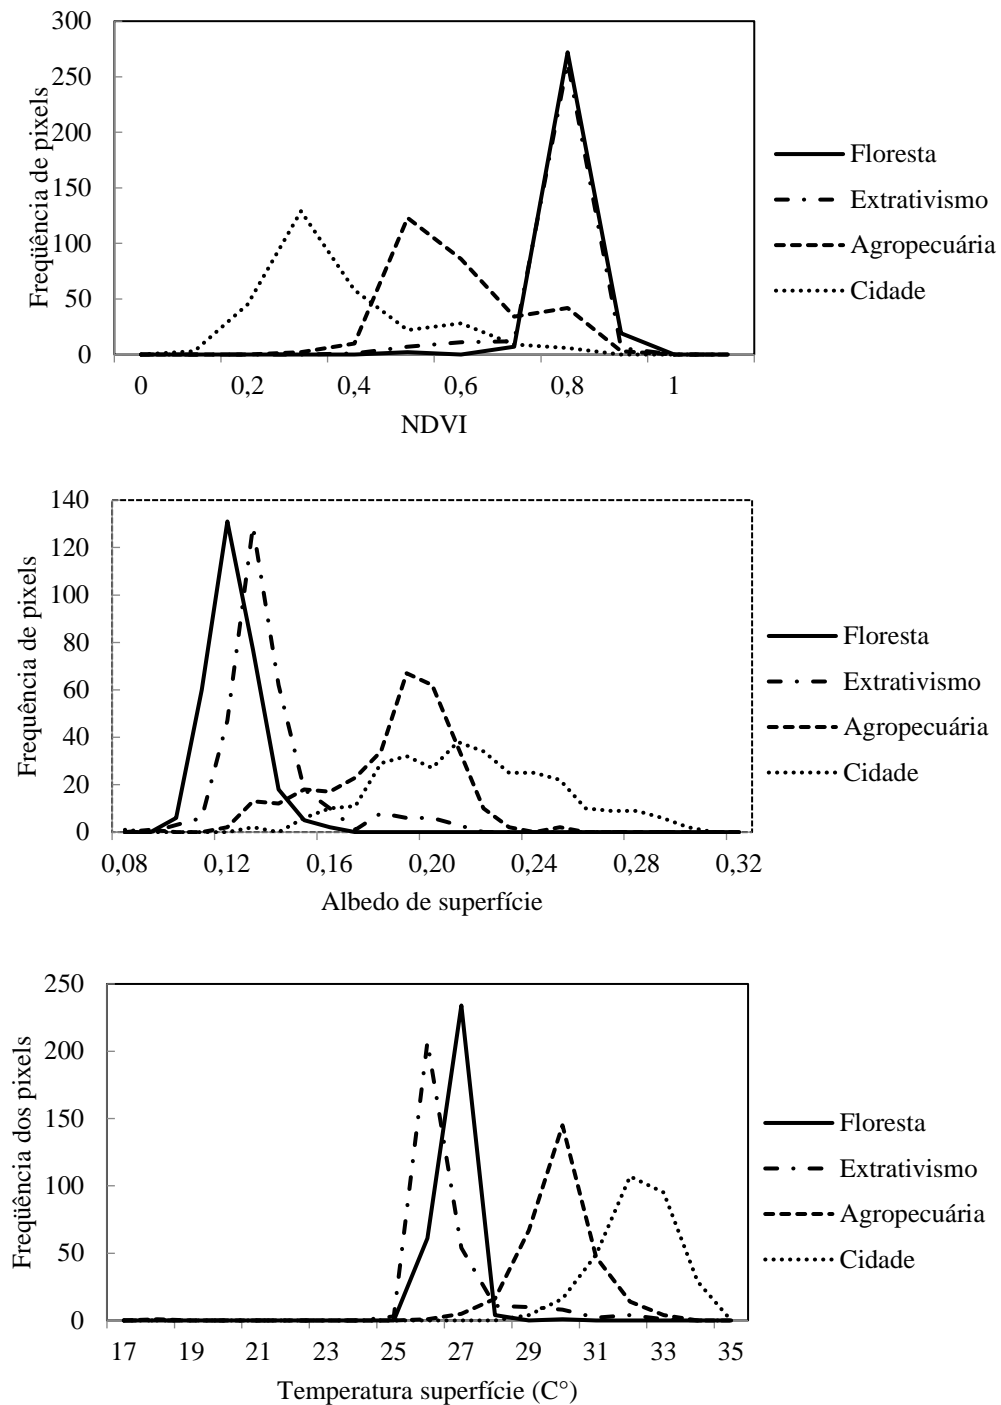


Figura 11: Histogramas dos pixels de NDVI, Albedo da superfície e temperatura da superfície de cada uso para a estação seca (04/08/2013).

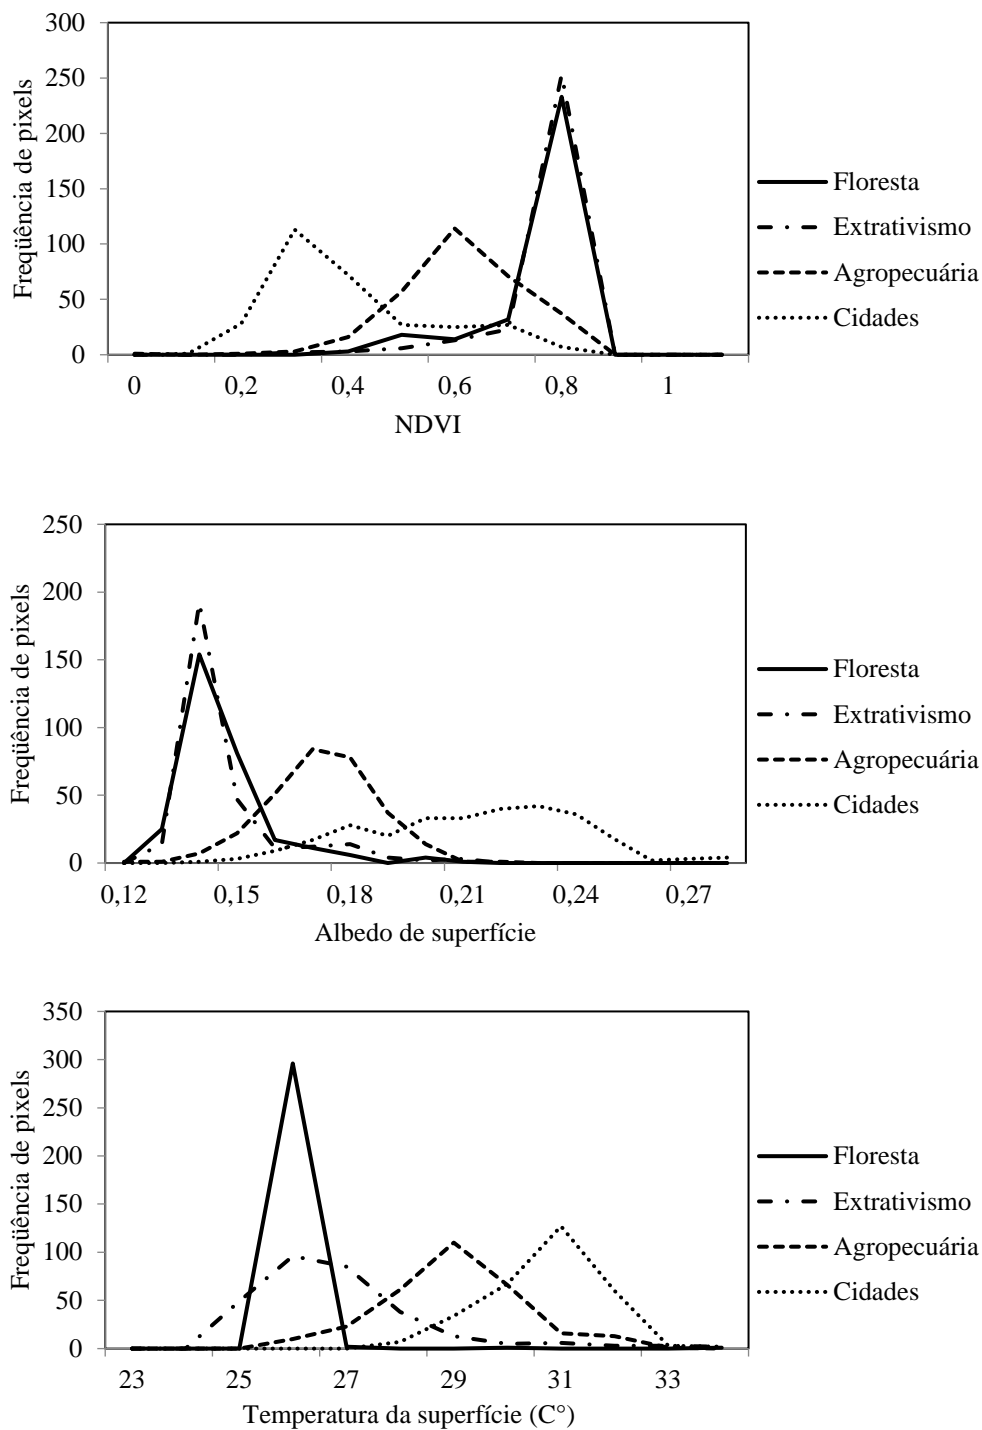


Figura 12: Histogramas dos pixels de NDVI, Albedo da superfície e temperatura da superfície de cada uso. Período seco (2014).

5.3 Comparação da PPB_{OLI/TIRS} com a PPB_{MOD}

As tabelas 8 e 9 apresentam as estatísticas descritivas da PPB estimada pelo sensor MODIS através do algoritmo MOD17A2 (PPB_{MOD}) e a PPB estimada pelo algoritmo aplicado

aos sensores OLI/TIRS ($PPB_{OLI/TIRS}$) em cada uso do solo. Para comparação, a resolução da $PPB_{OLI/TIRS}$ (30 m) foi redimensionada para a mesma resolução das imagens MODIS de 500 m.

Tabela 8: PPB segundo o produto MOD17 - PPB_{MOD} de 05/08/2013 e PPB estimada pelos sensores OLI/TIRS – $PPB_{OLI/TIRS}$ de 04/08/2013, estação seca.

Ano	n	Uso do solo	PPB_{MOD} (g C m ⁻² dia ⁻¹)					
			média	sd	min	max	Variância	CV
2013	88	Floresta	10,24	0,37	8,85	10,61	0,13	3,57
2013	115	Extratativismo	9,39	0,74	6,91	10,35	0,55	7,89
2013	40	Agropecuária	6,71	0,56	5,17	8,37	0,31	8,30
2013	7	Cidade	6,01	0,80	4,65	6,89	0,64	13,31
			$PPB_{OLI/TIRS}$ (g C m ⁻² dia ⁻¹)					
2013	88	Floresta	9,12	4,37	0,40	15,74	19,06	47,85
2013	115	Extratativismo	9,87	4,10	1,16	15,99	16,81	41,55
2013	40	Agropecuária	6,41	4,20	0,14	15,95	17,61	65,45
2013	7	Cidade	3,04	2,50	0,07	5,81	6,27	82,32

Tabela 9: PPB segundo o produto MOD17 - PPB_{MOD} de 08/10/2014 e PPB estimada pelos sensores OLI/TIRS – $PPB_{OLI/TIRS}$ de 10/10/2014, estação chuvosa.

Ano	n	Uso do solo	PPB_{MOD} (g C m ⁻² dia ⁻¹)					
			média	sd	min	max	Variância	CV
2014	66	Floresta	8,21	0,53	6,78	8,86	0,28	6,47
2014	118	Extratativismo	8,24	0,91	4,91	9,02	0,83	11,06
2014	89	Agropecuária	5,06	0,64	3,24	6,31	0,41	12,59
2014	8	Cidade	4,08	0,33	3,62	4,57	0,11	8,04
			$PPB_{OLI/TIRS}$ (g C m ⁻² dia ⁻¹)					
2014	66	Floresta	7,47	2,60	0,15	11,19	6,75	34,79
2014	118	Extratativismo	6,54	2,12	0,39	10,71	4,50	32,43
2014	89	Agropecuária	3,00	2,14	0,02	9,31	4,59	71,55
2014	8	Cidade	0,46	0,37	0,04	1,14	0,13	80,06

n - tamanho da amostra de dados em cada uso do solo. sd – desvio-padrão. máx – valor máximo. mín – valor mínimo. CV – Coeficiente de variação.

Na Tabela 8, observa-se que no período seco (ano de 2013) a PPB média estimada pelo sensor OLI/TIRS foram próximas a PPB do sensor MODIS para todos os usos do solo, exceto para Cidades. A PPB obtida pelo produto MOD17A2, apresentou desvio padrão de 0,37 a 0,80 gCm⁻² dia⁻¹ variando muito pouco em comparação com a $PPB_{OLI/TIRS}$ com desvio padrão de 2,50 a 4,37 gCm⁻² dia⁻¹. A estação chuvosa apresenta o mesmo padrão. Com desvio padrão da PPB_{MOD} variando de 0,33 a 0,91 gCm⁻² dia⁻¹ e a $PPB_{OLI/TIRS}$ de 0,37 a 2,60. A maior variabilidade da PPB encontrada para a $PPB_{OLI/TIRS}$ pode ocorrer devido à alta resolução do sensor OLI/TIRS mesmo após a reamostragem. Em comparação ao produto MOD17A2 de 500 m, a baixa resolução impede a detecção mais precisa dos alvos na imagem. A resolução de 30m $PPB_{OLI/TIRS}$ pode captar mais nitidamente os extremos de máximo e mínimo, que são suavizados

pela resolução mais grosseira do MODIS. Além disso o produto MOD17A2 se trata de um produto global e apresenta dados de reanálise em pontos de grade, o que limita a especificidade das características locais (SILVA et al., 2013).

Na Figura 11 e Tabela 10 também se observa a partir dos valores de erro médio a tendência a subestimativa da $PPB_{OLI/TIRS}$ em relação a PPB_{MOD} na estação chuvosa e na estação seca exceto no uso Extrativismo. Os menores erros da PPB entre os sensores foram observados no período seco. Neste período as médias encontradas para os dois satélites são semelhantes (Tabela 8) além da subestimativa ser menor (Figura 13). Já a estação chuvosa apresentou maiores diferenças entre os satélites para cada uso. A maior subestimativa para a estação chuvosa pode estar relacionada a nebulosidade neste período.

Os dados Landsat OLI/TIRS foram obtidos em um dia com alta transmitância atmosférica, ou seja, com ausência de nuvens e para o momento da passagem do satélite sobre a área de estudo. Já o produto MOD17A2 é resultado da média da PPB acumulada de 8 dias consecutivos, ou seja, possui uma composição mais heterogênea da cobertura de nuvens. A conversão deste produto para um dado diário, reduz sua precisão. Braga (2013) encontrou padrão semelhante analisando a PPB calculada a partir do Landsat TM. No estudo, comparado ao produto MOD17A2, no mês de setembro, início da estação chuvosa, as mesmas características citadas acima amplificam as discrepâncias entre os dois sensores.

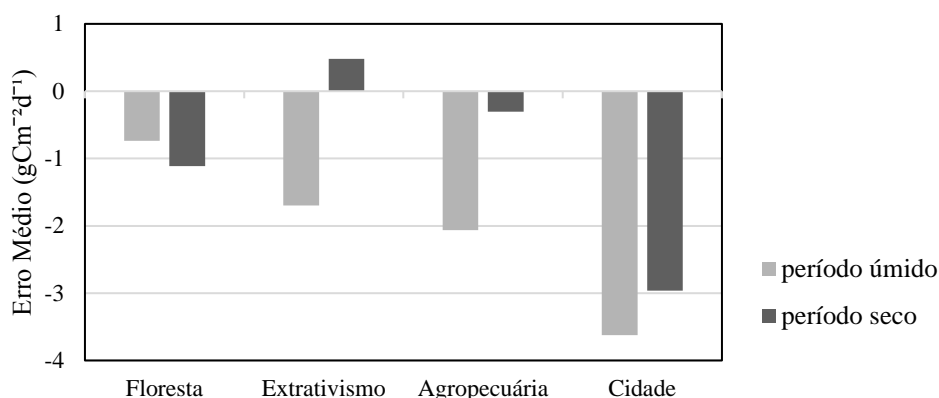


Figura 13: Erro médio da PPB para estação seca e chuvosa para os usos do solo avaliados.

Tabela 10: Erro médio da PPB ($gCm^{-2} dia^{-1}$), REMQ ($gCm^{-2} dia^{-1}$) dos usos do solo para as duas estações.

Estação	Uso do solo	EM	REMQ
Seca	Floresta	-1,11	4,46
Seca	Extrativismo	0,48	4,18
Seca	Agropecuária	-0,3	4,29
Seca	Cidade	-2,96	4,06
Chuvosa	Floresta	-0,74	3,01
Chuvosa	Extrativismo	-1,7	2,97
Chuvosa	Agropecuária	-2,06	3,03
Chuvosa	Cidade	-3,62	3,67

Analisando a PPB total na área de estudo, ambas as imagens apresentaram correlação de Spearman significativa moderada entre a $PPB_{OLI/TIRS}$ e a PPB_{MOD} (tabela 11). Almeida (2016), encontrou correlação positiva de 0,46 e 0,44 do produto MOD17A2 com dados de campo de duas torres micrometeorológicas localizadas em Rondônia: uma na Rebio Jarú, e outra numa área de pastagem, inseridas na área deste estudo.

Tabela 11: Erro médio da PPB ($gCm^{-2} dia^{-1}$), REMQ ($gCm^{-2} dia^{-1}$) e coeficiente de correlação de Spearman entre o total da $PPB_{OLI/TIRS}$ e PPB_{MOD} da área de estudo.

Estação	EM	REMQ	rho
Seca	-0,15	4,26	0,32*
Chuvosa	-1,64	3,02	0,46*

*p-valor < 0,05

Porem em virtude da quantidade de imagens utilizadas neste estudo, e em função do número expressivo de nebulosidade na região Amazônica, nesta pesquisa não se pôde determinar as características sazonais com clareza, pois as imagens são referentes a apenas um dia representativo de cada estação, levando em consideração o momento da passagem do satélite.

6 CONCLUSÃO

A PPB estimada pelo sensor OLI/TIRS possibilitou analisar as distinções espaciais entre os usos do solo na região. A imagem representativa da estação seca apresentou as maiores médias de PPB, o que sugere que o algoritmo é influenciado principalmente pela combinação da alta oferta de radiação, umidade e índice de vegetação para região, aumentando as disparidades entre os usos e cobertura do solo.

A alta resolução espacial do satélite Landsat 8 OLI/TIRS aumenta as diferenças dos máximos e mínimos calculados, apresentando uma maior variabilidade de alvos da superfície em comparação com o produto MOD17A2. Porém as duas imagens apresentaram subestimativa com o produto MOD17A2, na maioria dos usos.

As diferenças entre a resolução temporal de cada sensor também influenciam na comparação, pois apresentam dados de superfície específicos da data de imageamento. O algoritmo proposto, devido a sua aplicabilidade ao sensor OLI/TIRS, pode ser útil para a análise mais precisa da PPB em áreas de estudo locais, como microbacias e fragmentos florestais. No entanto, apesar de apresentarem coeficiente de correlação de Spearman positivo significativo com o produto MOD17A2, é necessário averiguar melhor as estimativas temporais para os sensores OLI/TIRS com dados de superfície, que integrados poderão determinar valores mais precisos de PPB, principalmente nas áreas mais remotas.

REFERENCIAS BIBLIOGRÁFICAS

AHONGSHANGBAM, J. et al. Estimating Gross Primary Production of a Forest Plantation Area Using Eddy Covariance Data and Satellite Imagery. **J Indian Soc Remote Sens.** 2016.

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.

ALMEIDA, C. T. et al. Spatiotemporal rainfall and temperature trends throughout the Brazilian Legal Amazon, 1973–2013. **INTERNATIONAL JOURNAL OF CLIMATOLOGY**, v. 37, p. 2013-2026, 2016. Disponível em: <<http://onlinelibrary.wiley.com/doi/10.1002/joc.4831/abstract>>. Acesso em: 11 dez. 2017.

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.

ALVARES, C. A. et al. Köppen’s climate classification map for Brazil. **Meteorologische Zeitschrift**, v. 22, n. 6, p. 711-728, 2013. DOI: 10.1127/0941-2948/2013/0507.

BRASIL. Ministério do Desenvolvimento Agrário. Plano territorial de desenvolvimento rural sustentado. Rio Branco: PESACRE, 2007. 135 p.

ALVES, L. E. R. et al. Balanço de Radiação Através do Satélite Landsat-8 na Bacia do Rio Pajeú. **Revista do Departamento de Geografia da USP**, São Paulo, v. 33, p. 117-127, 2017.

ANAV, A., et al. Spatiotemporal patterns of terrestrial gross primary production: A review. **Rev. Geophys.** v. 53, 785–818. 2015.

AUBINET, M. et al. Estimates of the annual net carbon and water exchange of forests: Euroflux methodology. **Advances in Ecological Research.** v. 30, p. 113-175, 2000.

ANDREAE M. O. et al. Biogeochemical cycling of carbon, water, energy, trace gases, and aerosols in Amazonia: The LBA-EUSTACH experiments. **J Geophys Res.** v. 107, 2002. doi: 10.1029=2001JD000524

AVISSAR, R. e NOBRE, C.A. Preface to special issue on the Large-Scale Biosphere-Atmosphere experiment in Amazonia (LBA). **J. Geophys. Res.** v.107, 2002
<http://dx.doi.org/10.1029/2002JD002507>

BRAGA, A. P. **Estimativa da Produtividade Primária Bruta em Áreas Agrícolas e de Vegetação Primária no Cerrado por Sensoriamento Remoto.** 66f. Dissertação. (Mestrado em Meteorologia) – Universidade Federal de Campina Grande, Campina Grande, 2013.

BASTIAANSEN, W.G.M. **Regionalization of surface flux densities and moisture indicators in composite terrain.** 1995. 288 f. Thesis (Ph.D) - Agricultural University, Wageningen, The Netherlands.

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.

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

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

BEER, C. et al. Terrestrial Gross Carbon Dioxide Uptake: Global Distribution and Covariation with Climate. **Science**. v.329, n.5993, p.834-838, 2010.

BEGON, M et al. **Ecologia: de individuos a ecossistemas**. 4 ed.[S.L.]: **Artmed**, 2007.

BOEGH, E.; SOEGAARD, H.; THOMSEN, A. Evaluating evapotranspiration rates and surface conditions using Landsat TM to estimate atmospheric resistance and surface resistance. **Remote Sensing of Environment**, v.79, n.1, p.329-343, 2002.

BROWN, D. S. et al. Land occupations and deforestation in the Brazilian Amazon. **Land Use Policy**. v. 54, p. 331-338, 2016.

CANADELL, J. G., et al. Carbon metabolism of the terrestrial biosphere: A multitechnique approach for improved understanding. **Ecosystems**. v. 3, p.115–130, 2000.

CARNEIRO FILHO, A. **Atlas de pressões e ameaças às terras indígenas na Amazônia brasileira**. São Paulo : Instituto Socioambiental, 2009. 48p.

CHANDER, G.; MARKHAM, B.; HELDER, D. “Summary of current radiometric calibration coefficients for Landsat MSS, TM, ETM+ and EO-1 ALI sensors”, **Remote Sensing of Environment** v.113 p. 893-903, 2009.

CHAPIN III, F. S.; MATSON, P. A.; MOONEY, H. A. Principles of Terrestrial Ecosystem Ecology. Germany: **Springer-Verlag**, p. 436 . 2002.

CHAPIN, F. S. et al. **Principles of terrestrialecosystem ecology**. 2 Edição. **Springer New York Dordrecht Heidelberg London**. 2011. 546 p.

CORLETT, R. T. The Impacts of Droughts in Tropical Forests Review Article .**Trends in Plant Science**. v. 21, n. 7, p. 584-593. 2016.

ESTOQUE, R. C. e MURAYAMA, Y. Classification and change detection of built-up lands from Landsat-7 ETM+ and Landsat-8 OLI/TIRS imageries: A comparative assessment of various spectral índices. **Ecological Indicators**. v. 56, p. 205–217. 2015

FALGE, E. et al. Seasonality of ecosystem respiration and gross primary production as derived from FLUXNET measurements. **Agricultural and Forest Meteorology**, v.113, n.1–4, p.53-74. 2002.

FIGUEROA, S. N.; NOBRE, C. A. Precipitations distribution over Central and Western Tropical South America. **Climanálise** - Boletim de Monitoramento e Análise Climática, v.5, n.6, p. 36 - 45, 1990.

FIELD, C. B.; RANDERSON, J. T.; MALMSTROM, C. M. Global net primary production: combining ecology and remote sensing. **Remote Sensing of Environment**, v.51, p.74-88, 1995.

FRIEDLINGSTEIN, P. et al. Climate-carbon cycle feedback analysis: results from the C4MIP model intercomparison. **J. Climate**. v.19, p.3337-3353. 2006.

FU, P. e WENG, O. Consistent land surface temperature data generation from irregularly spaced Landsat imagery. **Remote Sensing of Environment**. v. 184, p. 175-187. 2016

GIONGO, P. R. et al. Albedo à superfície a partir de imagens Landsat 5 em áreas de cana-de-açúcar e cerrado. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v.14, p.279-287, 2010.

GITELSON, A. A. et al. 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.

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

GUSTAVSSON, L. et al. Climate effects of bioenergy from forest residues in comparison to fossil energy. **Applied Energy**, v. 138, p. 36-50, out 2017. Disponível em: <<http://dx.doi.org/10.1016/j.apenergy.2014.10.013>>. Acesso em: 12 set. 2017.

HUETE, A. R. Adjusting vegetation indices for soil influences. **International Agrophysics**, v.4, n.4, p.367-376, 1988.

HOLZMAN, M.E, et al. Estimating soil moisture and the relationship with crop yield using surface temperature and vegetation index. **International Journal of Applied Earth Observation and Geoinformation**, v. 28, p. 181-192. 2014.

HOMMA, A. K. O. Expansão agropecuária e desmatamento na Amazônia: Quais os caminhos. In: COELHO, A. B., TEIXEIRA, E. C. e BRAGA, M. J. (Eds.). *Recursos Naturais e Crescimento Econômico*. 1. ed. Viçosa, MG: [s.n.]. p. 125-176.

IQBAL, M. **An Introduction to Solar Radiation**. New York: Academic Press. 1983. 212p.

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.

IRONS, J. R. et al. The next Landsat satellite: The Landsat Data Continuity Mission. **Remote Sensing of Environment**. v. 122, p.11-21. 2012.

IRONS, J.R. e MASEK, J.G. Requirements for a Landsat data continuity mission. **Photogrammetric Engineering and Remote Sensing**, v.72, p. 1102–1108. 2006.

LIU M. et al. Evolution and variation of atmospheric carbon dioxide concentration over terrestrial ecosystems as derived from eddy covariance measurements. **Atmospheric Environment**, v.114, p. 75–82. 2015.

MALHI, Y. et al. Comprehensive assessment of carbon productivity, allocation and storage in three Amazonian forests. **Global Change Biology**, v.15, n.5, p.1255-1274, 2009.

MALLICK, K. et al. A surface temperature initiated closure (STIC) for surface energy balance fluxes. **Remote Sensing of Environment**, v. 141. p.243–261. 2014

MARKHAM, B. L. et al. Landsat-8 Operational Land Imager radiometric calibration and stability. **Remote Sensing**, N. 6 p. 12275–12308. 2014.

MARKHAM, B.L.; BAKER, J.L. “Landsat MSS and TM Post-Calibration Dynamix Ranges, Exoatmospheric Reflectances and At-Satellite Temperatures”. **Landsat Technical Notes**, n. 1, p. 3-5, 1987.

MARKHAM, B. L. & BARKER, J. L. Thematic mapper band pass solar exoatmospherical irradiances. **International Journal of Remote Sensing**, v. 8, n. 3, p. 517-523, 1987.

MISHRA, N. et al. Continuous calibration improvement in solar reflective bands: Landsat 5 through Landsat 8. **Remote Sensing of Environment** Available online. 2016. <http://dx.doi.org/10.1016/j.rse.2016.07.032>

MOREIRA, Maurício Alves. **Fundamentos do sensoriamento remoto e metodologias de aplicação**. 4 ed. Viçosa, MG: Editora UFV, 2011. 422 p.

MOREIRA, D. S. Simulação numérica do ciclo do carbono na Amazônia. 2013. 209f. Tese (Doutorado em Meteorologia) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2013.

MONTEITH, J.L. Evaporation and environment. In: *The State and Movement of Water in Living Organisms*. Cambridge University Press, Swansea/Cambridge, UK, pp. 205–234. 1965

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

PROPASTIN, P. et al. Effects of canopy photosynthesis saturation on the estimation of gross primary productivity from MODIS data in a tropical forest. **Remote Sensing of Environment**. v. 121, p. 252–260. 2012.

PULLENS, J. W. M. et al. Carbon fluxes of an alpine peatland in Northern Italy. **Agricultural and Forest Meteorology**, v.220, p.69-82. 2015

RAMPELOTTO, H. P. A química da vida como nós não conhecemos. **Quim. Nova**, v.35, n. 8, p.1619-1627, 2012.

- REICH, P. B. et al. Leaf demography and phenology in Amazonian rain forest: A census of 40,000 leaves of 23 tree species. **Ecological Monographs**, v.74, n.1, p.3-23, 2004.
- REUTER, D. C. et al, 2015. The Thermal Infrared Sensor (TIRS) on Landsat 8: Design Overview and Pre-Launch Characterization. **Remote Sens**, n. 7, p. 1135-1153. 2015.
- RESTREPO-COUBE, N. et al. What drives the seasonality of photosynthesis across the Amazon basin? A cross-site analysis of eddy flux tower measurements from the Brasil flux network. **Agricultural and Forest Meteorology**. p. 128– 144. 2013
- ROSCOE, R. Rediscutindo o papel dos ecossistemas terrestres no seqüestro de carbono. **Cadernos de Ciência & Tecnologia**, v. 20, n. 2, p. 209-223. 2003.
- ROUSE, J.W. et al. Monitoring vegetation systems in the great plains with ERTS. In: Third ERTS Symposium, Proceedings, NASA SP-351, NASA, Washignton, DC, v. 1, p. 309-317, 1973.
- ROY , D.P.et al. Landsat-8: Science and product vision for terrestrial global change research. **Remote Sensing of Environment**. v.145, p. 154–172. 2014.
- ROY, D. P. et al. Characterization of Landsat-7 to Landsat-8 reflective wavelength and normalized difference vegetation index continuity. **Remote Sensing of Environment**, 2015.
- RUHOFF, A. et al. Determinação da irradiância solar no topo da atmosfera para cálculo do albedo e balanço de energia a partir de imagens Landsat 8 OLI. Anais XVII Simpósio Brasileiro de Sensoriamento Remoto – SBSR. INPE, 2015.
- RUNNING, S.W. et al. A continuous satellite-derived measure of global terrestrial primary production. **BioScience**. v. 54, p. 547–560, 2004.
- RUNNING, Q. M. MOD17A2H MODIS/Terra Gross Primary Productivity 8-Day L4 Global 500m SIN Grid V006. NASA EOSDIS Land Processes DAAC.
- SALESKA, S. et al. Fluxos de Carbono do Ecossistema e Metabolismo da Floresta Amazônica. **Amazonia and Global Change**. American Geophysical Union. Geophysical Monograph Series 186, 2009.
- SIMS, D. A. et al. A new model of gross primary productivity for North American ecosystems based solely on the enhanced vegetation index and land surface temperature from MODIS. **Remote Sensing of Environment**, v.112, n.4, p.1633-1646, 2008.
- SILBERG, B. 2016 had hottest March on Record. **NASA's Jet Propulsion Laboratory**, EUA, 20 abr. 2016. Disponível em: <<http://climate.nasa.gov/news/2432/2016-had-hottest-march-on-record/>>. Acesso em: 22 mai. 2016.
- SILVA, B. B. et al. Balanço de radiação no perímetro irrigado São Gonçalo - PB mediante imagens orbitais. **Revista Caatinga**, v.24, n.3, p.145 -152. 2011.

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.

SLEETER, B.M. et al. Scenarios of land use and land cover change in the conterminous United States: Utilizing the special report on emission scenarios at ecoregional scales. **Global Environmental Change**. v. 22. p. 896–914. 2012.

SUDAM – SUPERINTENDÊNCIA DO DESENVOLVIMENTO DA AMAZÔNIA. *Legislação sobre a criação da Amazônia Legal*. Disponível em: <http://www.e.gov.br/defaultCab._____asp?idservinfo=35616&url=http://www.ada.gov.br/index.php?option=com_content&task=category§i_onid=9&id=54&Itemid=51>. Acesso em: 07 jul. 2016.

SWANN, A. L. S. et al. Future deforestation in the Amazon and consequences for South American climate. **Agricultural and Forest Meteorology**. v. 214–215, p. 12-24. 2015.

TASUMI, M.; ALLEN, R.G.; TREZZA, R. Estimation of at surface reflectance and albedo from satellite for routine, operational calculation of land surface energy balance. **Journal of Hydrology**, v. 13, n. 2, p. 51-63, 2008.

USGS. Landsat 8 (L8) Data Users Handbook, 2015, LSDS-1574, version 2.0. Sioux Falls, USA: USGS EROS. Disponível em: <https://landsat.usgs.gov/documents/Landsat8DataUsersHandbook.pdf>). Acesso em 23 jun 2016

VERMA, M. et al. Improving the performance of remote sensing models for capturing intra- and inter-annual variations in daily GPP: An analysis using global FLUXNET tower data. **Agricultural and Forest Meteorology**. v. 214-215. p. 416–429. 2015.

VERMOTE, E. Preliminary analysis of the performance of the Landsat 8/OLI land surface reflectance product. Available online .2016. <http://dx.doi.org/10.1016/j.rse.2016.04.008>

VON RANDOW, C. et al. Comparative measurements and seasonal variations in energy and carbon exchange over forest and pasture in South West Amazonia. **Theor. Appl. Climatol.** v.78, n.1, p.5-26, 2004.

WRIGHT, S. J. e SCHAIK, C. P. Light and the phenology of tropical trees. **American Naturalist**, v.143, n.1, p.192-199, 1994.

WU, C. et al. Remote estimation of gross primary production in wheat using chlorophyll-related vegetation indices. **Agricultural and Forest Meteorology**, v.149, p.1015–1021, 2009.

XIAO, X. M. et al. Modeling gross primary production of temperate deciduous broadleaf forest using satellite images and climate data. **Remote Sensing of Environment**, v.91, n.2, p.256-270. 2004.

YUAN, W. et al. Global estimates of evapotranspiration and gross primary production based on MODIS and global meteorology data. **Remote Sensing of Environment**. v. 114, p. 1416–1431. 2010.

YUAN, W. et al. Global comparison of light use efficiency models for simulating terrestrial vegetation gross primary production based on the LaThuile database. **Agric. For. Meteorol.** 192–193, 108–120. 2014. doi.org/10.1016/j.agrformet.2014.03.007

ZHANG, Y. et al. Development of a coupled carbon and water model for estimating global gross primary productivity and evapotranspiration based on eddy flux and remote sensing data. **Agricultural and Forest Meteorology**, v. 223, p. 36-50, 2016. Disponível em: <<https://doi.org/10.1016/j.agrformet.2016.04.003>>. Acesso em: 15 set. 2017.