

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

HENRIQUE LUIS GODINHO CASSOL

**ESTIMATIVA DE BIOMASSA E ESTOQUE
DE CARBONO EM UM FRAGMENTO DE
FLORESTA OMBRÓFILA MISTA COM
USO DE DADOS ÓPTICOS DE
SENSORES REMOTOS**

Porto Alegre

2013

HENRIQUE LUIS GODINHO CASSOL

**ESTIMATIVA DE BIOMASSA E ESTOQUE DE CARBONO EM UM
FRAGMENTO DE FLORESTA OMBRÓFILA MISTA COM USO DE
DADOS ÓPTICOS DE SENSORES REMOTOS**

Dissertação de Mestrado apresentada
como requisito parcial para obtenção do
título de Mestre em Sensoriamento Remoto
pelo Programa de Pós Graduação em
Sensoriamento Remoto da Universidade
Federal do Rio Grande do Sul.

Orientadora: Dejanira Luderitz Saldanha

Co-Orientadora: Tatiana Mora Kuplich

Porto Alegre

2013

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Carlos Alexandre Netto

Vice-Reitor: Rui Vicente Oppermann

INSTITUTO DE GEOCIÊNCIAS

Diretor: André Sampaio Mexias

Vice-Diretor: Nelson Luiz Sambaqui Gruber

Cassol, Henrique Luis

Estimativa de biomassa e estoque de carbono em um fragmento de floresta ombrófila mista com uso de dados ópticos de sensores remotos. / Henrique Luis Cassol. - Porto Alegre: IGEO/UFRGS, 2013. [143 f.] il.

Dissertação de Mestrado - Universidade Federal do Rio Grande do Sul. Programa de Pós-graduação em Sensoriamento Remoto. Instituto de Geociências. Porto Alegre, RS - BR, 2013
Orientador: Dejanira Luderitz Saldanha
Coorientador: Tatiana Mora Kuplich

1. Variáveis biofísicas. 2. Carbono orgânico. 3. Sensoriamento remoto. 4. Equações alométricas. I. Título.

Catálogo na Publicação
Biblioteca Instituto de Geociências - UFRGS
Alexandre Ribas Semeler CRB: 10/1900

HENRIQUE LUIS GODINHO CASSOL

**ESTIMATIVA DE BIOMASSA E ESTOQUE DE CARBONO EM UM FRAGMENTO
DE FLORESTA OMBRÓFILA MISTA COM USO DE DADOS ÓPTICOS DE
SENSORES REMOTOS**

Dissertação de Mestrado apresentada como requisito parcial para obtenção do título de Mestre em Sensoriamento Remoto pelo Programa de Pós Graduação em Sensoriamento Remoto da Universidade Federal do Rio Grande do Sul.

Banca Examinadora:

.....
Prof. Dr. Carlos Roberto Sanquetta (PPGEF/UFPR)

.....
Prof. Dr. Rudiney Soares Pereira (PPGEF/UFSM)

.....
Prof. Dra. Denise Cybis Fontana (PPGSR/UFRGS)

Porto Alegre,dede

DEDICATÓRIA

Aos meus avós Alda P. Godinho e Fiorentino Cassol que infelizmente nos deixaram ano passado, dedico.

AGRADECIMENTOS

Aos meus pais, pelo apoio afetivo e pela perseverança incondicional que sempre dedicaram a mim;

À minha namorada Julia, que me apoiou nos momentos mais difíceis e esteve comigo nos mais alegres;

Às minhas orientadoras Prof. Dr^a. Dejanira Luderitz Saldanha e Dr^a. Tatiana Mora Kuplich, pelos esmerados e prestimosos conselhos;

Ao Prof Dr. Carlos Roberto Sanquetta e Prof. Dr^a Ana Paula Dalla Corte pelo apoio institucional e científico na realização da etapa de campo;

Ao do Programa de Pesquisas Ecológicas de Longa Duração (PELD) Sítio 9 – Floresta com Araucária e suas transições e seus colaboradores, pelo fornecimento dos dados de inventário, sem os quais não seria possível a realização deste trabalho;

Ao Jonas Bianchi, Lucas Oliveira, Tomaz Longhi e demais amigos da UFPR, pelo apoio na tarefa de campo;

Ao Centro Estadual de Pesquisa em Sensoriamento Remoto e Meteorologia e seus colaboradores e funcionários;

À Universidade Federal do Rio Grande do Sul pela estrutura fornecida e oportunidade de desenvolver a pesquisa;

À CAPES, pelo apoio financeiro-institucional concedido;

Aos colegas do PPGSR;

*“Mestre não é quem sempre ensina,
mas quem de repente aprende”.*

João Guimarães Rosa (1908 – 1967).

RESUMO

A imprecisão das estimativas de carbono estocado em florestas naturais no ciclo global de carbono vem criando uma demanda de desenvolvimento e padronização de métodos indiretos para modelagem deste ciclo e de emissões de CO₂ provenientes de mudanças de uso da terra e florestas. O trabalho teve como objetivo estabelecer as relações empíricas existentes entre a biomassa e o estoque de carbono de uma Floresta Ombrófila Mista (FOM) e os dados ópticos provenientes de sensores remotos de média resolução espacial (ASTER, LiSSIII e TM) por meio de análise de regressão. Além disso, criou-se um cenário hipotético de Redução de Emissões por Desmatamento, Degradação Florestal e Aumento de Estoque de Carbono (REDD⁺). O estudo foi desenvolvido na Estação Experimental de São João do Triunfo, no estado do Paraná. As equações de regressão envolveram como variáveis dependentes (y): a biomassa e o carbono florestal, obtidos indiretamente do inventário florestal contínuo do Programa de Pesquisas Ecológicas de Longa Duração (PELD), e como variáveis independentes (x) as bandas espectrais e os índices de vegetação (IV). O tratamento estatístico envolveu a análise da matriz de correlação (*r*) entre as variáveis x e y; a análise de regressão linear simples, não linear e múltipla, com as seguintes estatísticas: R^2 , R^2_{aj} , Syx , $Syx\%$ e dispersão dos resíduos. Por fim, elaboraram-se mapas temáticos para estas variáveis biofísicas. Como as correlações (*r*) entre as variáveis biofísicas e espectrais do sensor ASTER (15m) foram baixas, a imagem foi degradada para 30m e 45m. Na resolução de 30m, o uso dos dados ASTER foi superior ao seu uso na resolução original. Não houve diferenças significativas nos valores de *r* entre o uso das bandas ou dos IVs para prever as variáveis biofísicas. Regressões lineares simples se mostraram mais adequadas do que as regressões não lineares (exponenciais e logarítmicas) e múltiplas para estimar as variáveis biofísicas, apresentando erros inferiores aos estabelecidos nas campanhas de inventários tradicionais ($\alpha < 5\%$). Os mapas gerados a partir do sensor ASTER 30m foram mais fidedignos ao retratar a distribuição espacial destas variáveis na área de estudo devido à alta correspondência destes com os valores observados no inventário (PELD). Assim, a equação de regressão de carbono florestal a partir do ASTER foi usada na criação do projeto REDD⁺. A estimativa de biomassa e de carbono florestal da FOM mediante uso de dados de sensores ópticos foi adequada, com possibilidades de ser expandida para extensas áreas. A metodologia, portanto, se mostrou apropriada para ao monitoramento, relatório e verificação de estoques de carbono em florestas.

Palavras-chave: variáveis biofísicas, carbono orgânico, sensoriamento remoto, equações alométricas, REDD⁺.

ABSTRACT

The imprecision of the estimates of carbon stock in natural forests in the global carbon cycle has created a demand for development and standardization of indirect methods for modeling this cycle and CO₂ emissions from land use change and forestry. The work had as objective to establish empirical relationships between biomass and carbon stock of an Araucaria Forest (FOM) and medium spatial resolution remote sensing data (ASTER, and LiSSIII TM) through regression analysis. In addition, we created a hypothetical scenario of Reducing Emissions from Deforestation and Forest Degradation and Enhanced Carbon Stocks (REDD⁺). The study was developed at the Experimental Station of São João do Triunfo, state of Paraná. The regression analysis involved the forest biomass and forest carbon obtained from continuous forest inventory of the Long Term Ecological Research Program (LTER) as dependent variables (y) and spectral bands and vegetation indices (VIs) as independent variables (x). The statistical analysis comprised correlation analysis (*r*) between the variables x and y; regression analysis from linear, nonlinear and multiple regressions with the following statistics: *R*², *R*²_{adj}, *S*_{yx}, *S*_{yx}% and residual dispersion. Furthermore thematic maps were made. Correlations between the biophysical variables and the spectral ASTER data were weak therefore ASTER was scaling up to 30m and 45m. The resolution of 30m, using ASTER data was higher than its use in the original resolution. There were not significant differences in *r* values between use of bands or VIs to predict the biophysical variables. Linear regressions were more suitable than nonlinear regressions (exponential and logarithmic) and multiple to estimate the biophysical variables, with errors lower than established in traditional inventories campaigns ($\alpha < 5\%$). Maps generated from ASTER 30m were more reliable in portraying the spatial distribution of these variables in the study area due to the high correlation of these with the values observed in the inventory (LTER). Thus, the forest carbon equation from ASTER data was used in the creation of REDD⁺. The estimated biomass and forest carbon by using optical sensors data was adequate, with possibilities to be expanded to large areas. The methodology thus proved suitable for the monitoring, reporting and verification of carbon stocks in forests.

Keywords: biophysical variables, organic carbon, optical remote sensing, allometric equations, REDD⁺.

LISTA DE FIGURAS

Figura 1	Padrão típico de absorção, reflexão e transmissão da REM em uma folha verde sadia. Fonte: Adaptado de Jones e Vaughan, (2010).26
Figura 2	Representação da interação da REM com um dossel vegetal, mostrando os múltiplos eventos de espalhamento (a); Representação esquemática do dossel vegetal tratado como um conjunto de finas camadas (folhas), onde a radiação transmitida é atenuada pela absorção e transmissão das múltiplas camadas e o fluxo de radiação que volta à atmosfera é a soma da radiação espalhada pelas múltiplas camadas (b) (JONES e VAUGHAN, 2010).28
Figura 3	Efeito do aumento de camada de folhas na transmissão (τ), absorção (α) e reflexão (ρ) da REM pelas folhas. Modificado de Jacquemoud e Baret, (1990).29
Figura 4	Exemplo do estoque de carbono (caixas) e o fluxo de materiais e de CO ₂ (flechas) em um ecossistema florestal. Modificado de Muukkonen, (2006).....39
Figura 5	Localização geográfica da Estação Experimental de São João do Triunfo. No detalhe, uma composição colorida natural da estação experimental.....50
Figura 6	Divisão Fitogeográfica do estado do Paraná.....52
Figura 7	Estrutura vertical da Floresta Ombrófila Mista da Estação Experimental de São João do Triunfo vista de cima da torre micrometeorológica. Observa-se no primeiro plano a copa umbeliforme de uma <i>Araucária angustifolia</i> dominando o estrato superior da floresta. Fonte: Autor. ...53
Figura 8	Mapa da localização das parcelas permanentes em função dos diferentes dosséis florestais predominantes.54
Figura 9	Fluxograma do processamento digital das imagens ASTER, TM e LiSS III.61
Figura 10	Croqui metodológico do co-registro. À direita, os pontos representam as árvores contidas na UA e os círculos a projeção das copas.66
Figura 11	Representação esquemática do aumento de escala (<i>up-scaling</i>), em que a resolução espacial original de 15m do sensor ASTER foi degradada para duas resoluções espaciais menores, 30m e 45m. Os pontos na imagem representam as árvores contidas dentro de um pixel de resolução, usados para formar as UA.69
Figura 12	Fluxograma da metodologia empregada.....70

Figura 13	Comportamento dos coeficientes de variação em função da degradação espacial.	84
Figura 14	Correlograma entre as variáveis biomassa e carbono florestal e as variáveis espectrais, em função da ampliação da escala de observação.	87
Figura 15	Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor ASTER <i>versus</i> os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a dois foram destacadas. As unidades amostrais com resíduos superiores a 2σ estão destacadas.	104
Figura 16	Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor LiSS III <i>versus</i> os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a 2σ estão destacadas.	105
Figura 17	Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor TM <i>versus</i> os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a 2σ estão destacadas.	107
Figura 18	Gráfico de dispersão dos resíduos padronizados gerados pelas regressões não lineares dos índices e bandas espectrais, a partir dos dados espectrais do sensor LiSS III, <i>versus</i> os valores estimados padronizados de biomassa florestal (acima) e <i>versus</i> os valores estimados padronizados de carbono florestal (abaixo). As unidades amostrais com resíduos superiores a 2σ estão destacadas.	111
Figura 19	Gráfico de dispersão dos resíduos padronizados gerados pelas regressões não lineares dos índices e bandas espectrais, a partir dos dados espectrais do sensor TM, <i>versus</i> os valores estimados padronizados de biomassa florestal (esquerda) e <i>versus</i> os valores estimados de carbono florestal (direita). As unidades amostrais com resíduos superiores a 2σ estão destacadas.	112
Figura 20	Mapa de Biomassa Florestal na área da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor ASTER.	114
Figura 21	Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear do índice TVI do sensor ASTER.	115
Figura 22	Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor ASTER.	116

Figura 23	Mapa de Biomassa Florestal da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor LiSS III.....	117
Figura 24	Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor LiSS III.....	118
Figura 25	Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor LiSS III.....	119
Figura 26	Mapa de Biomassa Florestal da ESSJT, gerado a partir da regressão linear do índice NDVI do sensor TM.....	120
Figura 27	Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear do índice NDVI do sensor TM.....	121
Figura 28	Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor TM.	122
Figura 29	Princípio da adicionalidade. A linha base (pontilhada) representa a quantidade de CO ₂ e. existente na área anterior à criação do projeto de REDD ⁺	124

LISTA DE TABELAS

Tabela 1	Comparação de diferentes métodos usados em estimativas de biomassa para a medição de estoques de carbono florestais.....	36
Tabela 2	Características do Sensor ASTER, TM e LiSS III.	60
Tabela 3	Parâmetros de transformação radiométrica do sensor TM.	63
Tabela 4	Parâmetros de transformação de transformação do sensor LiSS III....	63
Tabela 5	Índices de Vegetação utilizados no estudo, ρ_{Red} , ρ_{Green} , ρ_{Blue} e ρ_{NIR} são as reflectâncias na região do vermelho, verde, azul e infravermelho próximo do espectro EM, respectivamente.....	65
Tabela 6	Estatísticas dos valores de biomassa florestal estimados para os anos de 2010 e 2011.	78
Tabela 7	Estatísticas dos valores de carbono florestal para os anos de 2010 e 2011.	80
Tabela 8	Estatísticas das unidades amostrais em nível de pixel de resolução 15m do sensor ASTER.....	81
Tabela 9	Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais. Em negrito, as mais altas correlações.	82
Tabela 10	Estatísticas descritivas das UA para as diferentes resoluções espaciais utilizadas (15m, 30m e 45m).	84
Tabela 11	Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais, com o pixel de dimensão de 30x30m. Em negrito, os maiores coeficientes.....	86
Tabela 12	Matriz de correlação entre os dados biofísicos e os dados espectrais do sensor ASTER com resolução espacial de 45 metros. Em negrito, as mais altas correlações.....	87
Tabela 13	Resultados das regressões lineares entre a biomassa florestal e as bandas e IV, nas diferentes resoluções espaciais do sensor ASTER..	88
Tabela 14	Resultados das regressões lineares entre o carbono florestal e as bandas e IV, nas diferentes resoluções espaciais do sensor ASTER..	90
Tabela 15	Estimativas de biomassa florestal por hectare, em $t.ha^{-1}$, geradas a partir das regressões lineares simples. Em negrito, destacam-se as menores variações.....	91

Tabela 16	Estimativas de carbono florestal por hectare, em t.ha ⁻¹ , geradas a partir das regressões lineares simples. Em negrito, as menores variações. .91
Tabela 17	Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais transformadas, em cada uma das escalas propostas.92
Tabela 18	Equações de regressão gerados a partir das variáveis espectrais selecionadas pelo método <i>Stepwise</i> , para a variável dependente Y = biomassa florestal.94
Tabela 19	Equações de regressão gerados a partir das variáveis espectrais selecionadas pelo método <i>Stepwise</i> , para a variável dependente Y = carbono florestal.94
Tabela 20	Estatísticas das variáveis biofísicas em kg/m ² e das variáveis espectrais nas unidades amostrais em cada um dos sensores avaliados.96
Tabela 21	Matriz de correlação entre as variáveis espectrais e biofísicas - transformadas ou não - em cada um dos sensores. Em negrito os coeficientes de correlação significativos ao nível $\alpha = 0,01$98
Tabela 22	Resultado da análise de regressão linear entre a biomassa florestal e as variáveis espectrais obtidas nos três sensores avaliados. Em negrito os mais altos coeficientes. 101
Tabela 23	Resultado da análise de regressão linear entre o carbono florestal e as variáveis espectrais obtidas nos três sensores avaliados. Em negrito os mais altos coeficientes. 103
Tabela 24	Estimativas de biomassa florestal por hectare, em t.ha ⁻¹ , geradas a partir das regressões lineares simples. 109
Tabela 25	Estimativas de carbono florestal por hectare, em t.ha ⁻¹ , geradas a partir das regressões lineares simples. 109
Tabela 26	Equações de regressão lineares múltiplos significativos para as variáveis espectrais provenientes do sensor LiSSIII. 110
Tabela 27	Equações de regressão lineares múltiplos significativos para as variáveis espectrais provenientes do sensor TM. 112
Tabela 28	Cenário de REDD ⁺ para a área de estudo. 123

LISTA DE EQUAÇÕES

Equação 1	Equação geral do balanço de energia da radiação eletromagnética incidente.....	25
Equação 2	Índice de Vegetação Razão Simples.....	30
Equação 3	Índice de Vegetação por Diferença Normalizada	30
Equação 4	Equação hipsométrica ajustada para a <i>Araucaria angustifolia</i>	55
Equação 5	Equação hipsométrica ajustada para as folhosas.	55
Equação 6	Equação alométrica ajustada para a Floresta Ombrófila Mista.	56
Equação 7	Equação para transformação de ND para radiância no topo da atmosfera dos dados ASTER.....	62
Equação 8	Equação para transformação de ND para radiância no topo da atmosfera dos dados TM.....	62
Equação 9	Cálculo para a conversão de radiância para FRB.	64
Equação 10	Cálculo do coeficiente de correlação de Pearson.	71
Equação 11	Linearização da equação logarítmica e exponencial, respectivamente.	72
Equação 12	Cálculo do coeficiente de determinação e coeficiente de determinação ajustado, respectivamente.	73
Equação 13	Erro padrão da estimativa e erro padrão relativo, respectivamente.	73
Equação 14	Cálculo dos resíduos padronizados.	74
Equação 15	Equação de regressão utilizada para estimar a biomassa florestal estabelecida com base nos valores de reflectância do infravermelho próximo do sensor ASTER.....	113
Equação 16	Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base no índice TVI do sensor ASTER.....	115
Equação 17	Equação de regressão utilizada para estimar a biomassa florestal mediante a banda do IVP do sensor LiSSIII como preditora.....	116
Equação 18	Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base na banda IVP do sensor LiSS III.....	117

Equação 19	Equação de regressão utilizada para estimar a biomassa florestal, estabelecida com base no índice NDVI do sensor TM.....	119
Equação 20	Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base no índice NDVI do sensor TM.....	120
Equação 21	Montante de carbono florestal, a partir da lei dos juros compostos. ..	122

LISTA DE ABREVIÇÕES

ASTER	<i>Advanced Spaceborne Thermal Emission and Reflection Radiometer</i>	IVC	Índice de Valor de Cobertura
ATP	Adenosina Trifosfato	IVP	Infravermelho Próximo
ARVI	<i>Atmospherically Resistant Vegetation Index</i>	i.e.	Isto é
APP	Área de Preservação Permanente	kg	Quilogramas
BEF	<i>Biomass Expansion Factor</i>	LDCM	<i>Landsat Data Continuity Mission</i>
BRDF	<i>Bidirectional Reflectance Distribution Function</i>	LiDAR	<i>Light Detecting and Range</i>
C	Carbono Orgânico	LiSSIII	<i>Linear Imaging Self-Scanner</i> (Geração III)
CAP	Circunferência à Altura do Peito	LULUCF	<i>Land Use, Land-Use Change and Forestry</i>
CCD	<i>Charge-Coupled Device</i>	MAUP	<i>Modifiable Areal Unit Problem</i>
COP	<i>Conference of the Parties</i>	MCT	Ministério da Ciência e Tecnologia
CO ₂	Dióxido de Carbono (Gás Carbônico)	MDL	Mecanismo de Desenvolvimento Limpo
CO _{2eq.}	Dióxido de Carbono Equivalente	MLS	<i>Middle Latitude in the Summer</i> (Meia Latitude no Verão)
CRE	Certificados de Redução de Emissões	MODIS	<i>Moderate Resolution Imaging Spectroradiometer</i>
CV	Coeficiente de Variação	MODTRAN	<i>Moderate Spectral Resolution Atmospheric Transmittance Algorithm</i>
DAP	Diâmetro à Altura do Peito	NADP ⁺	Nicotinamida Adenina Dinucleótido Fosfato (forma catiônica)
DP	Desvio Padrão	NADPH	Nicotinamida Adenina Dinucleótido Fosfato (forma reduzida)
EESJT	Estação Experimental de São João do Triunfo	NASA	<i>National Aeronautics and Space Administration</i>
EM	Eletromagnético	ND	Número Digital
EVI	<i>Enhanced Vegetation Index</i>	NDVI	<i>Normalized Difference Vegetation Index</i>
FLAASH	<i>Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes</i>	NFI	<i>National Forest Inventory</i>
FOM	Floresta Ombrófila Mista	NPP	<i>Net Primary Productivity</i>
FRB	Fator de Reflectância Bidirecional Aparente	ONU	Organizações das Nações Unidas
GEE	Gases de Efeito Estufa	PAR	<i>Photosynthetically Active Radiation</i>
IAF	Índice de Área Foliar	PELD	Programa de Pesquisas Ecológicas de Longa Duração
IBGE	Instituto Brasileiro de Geografia e Estatística	PK	Protocolo de Kyoto
IPA	Incremento Periódico Anual	p.ex.	Por Exemplo
IPCC	<i>Intergovernmental Panel on Climate Change</i>		
IRS	<i>Indian Remote Sensing Satellite</i>		
IV	Índice de Vegetação		

r	Coeficiente de correlação de Perason
R^2	Coeficiente de Determinação
R^2_{aj} .	Coeficiente de Determinação Ajustado
REDD	<i>Reducing Emissions from Deforestation and Degradation</i>
REDD ⁺	<i>Reduced Emissions from Deforestation and Degradation and Enhancement of Carbon Stocks</i>
REM	Radiação Eletromagnética
RL	Reserva Legal
RMSE	<i>Root Mean Square Error</i>
SAD-69	<i>South American Datum - 1969</i>
SAVI	<i>Soil-Adjusted Vegetation Index</i>
SIG	Sistema de Informações Geográficas
SR	<i>Simple Ratio</i>
t.ha ⁻¹	Tonelada por hectare
t.(ha.ano) ⁻¹	Tonelada por hectare e ano.
t. CO2e.	Tonelada de Dióxido de Carbono Equivalente
TC	Teor de Carbono
TD	Taxa de Desmatamento
TM	<i>Thematic Mapper</i>
TVI	<i>Triangular Vegetation Index</i>
TIR	<i>Thermal Infrared</i>
SWIR	<i>Short-Wave Infrared</i>
Syx	Erro Padrão da Estimativa
Syx%	Erro Padrão da Estimativa Relativo
UA	Unidade Amostral
UNFCC	<i>C United Nations Framework Convention on Climate Change</i>
UFPR	Universidade Federal do Paraná
UTM	Universal Transversa de Mercator
v.a.	Variáveis Aleatórias
VIS	Visível

SUMÁRIO

INTRODUÇÃO.....	21
OBJETIVOS.....	24
1.1 INTERAÇÃO DA RADIAÇÃO ELETROMAGNÉTICA (REM) COM AS FOLHAS	25
1.2 INTERAÇÃO DA REM COM OS DOSSÉIS VEGETAIS.....	27
1.3 ÍNDICES DE VEGETAÇÃO (IV)	30
1.4 FLORESTA OMBRÓFILA MISTA.....	32
1.5 BIOMASSA FLORESTAL	33
1.6 ESTIMATIVA DE CARBONO FLORESTAL.....	36
1.7 EQUAÇÕES ALOMÉTRICAS	41
1.8 GEOESTATÍSTICA APLICADA AO SENSORIAMENTO REMOTO	43
1.9 ESTADO DA ARTE: ESTIMATIVAS DE BIOMASSA E ESTOQUE DE CARBONO FLORESTAL versus SENSORIAMENTO REMOTO.....	45
1.10 INVENTÁRIO DE CO ₂ EM FLORESTAS.....	47
2 MATERIAIS E MÉTODOS.....	50
2.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO	50
2.1.1 Clima	51
2.1.2 Solos	51
2.1.3 Vegetação	51
2.2 DADOS DE CAMPO	53
2.2.1 Inventário Florestal	55
2.2.2 Estimação das Alturas	55
2.2.3 Estimativa de Biomassa Florestal	56
2.2.4 Estimativa de Carbono Florestal	56
2.3 DADOS ÓPTICOS DE SENSORIAMENTO REMOTO	57
2.3.1 Sensor ASTER	57
2.3.2 Sensor LiSS III	58
2.3.3 Sensor TM	59
2.3.4 Transformação Radiométrica dos dados	61
2.3.5 Correção atmosférica	64
2.3.6 Índices de vegetação	65

2.3.7	Georreferenciamento das imagens	66
2.3.8	Ampliação da Escala (<i>Up-scaling</i>)	67
2.4	TRATAMENTO ESTATÍSTICO E ANÁLISE DE REGRESSÃO	70
2.4.1	Análise de correlação	70
2.4.2	Análise de regressão	71
2.4.3	Validação das estimativas de biomassa e estoque de carbono	74
2.5	MAPAS TEMÁTICOS DE BIOMASSA E CARBONO FLORESTAL.....	75
2.6	PROJETO REDD ⁺	75
3	RESULTADOS E DISCUSSÕES.....	78
3.1	INVENTÁRIO DE BIOMASSA E ESTOQUE DE CARBONO FLORESTAL.....	78
3.2	ANÁLISE DE CORRELAÇÃO DO SENSOR ASTER	80
3.2.1	Variabilidade espacial de biomassa e carbono florestal com a mudança de escala de observação	83
3.2.2	Análise de regressão.....	88
3.2.3	Validação das regressões.....	90
3.2.4	Transformação das variáveis	92
3.2.5	Equações de regressão lineares múltiplas	93
3.3	COMPARAÇÃO DOS SENSORES ASTER, TM E LiSS III	95
3.3.1	Correlações entre variáveis analisadas sob os diferentes sensores.....	98
3.3.2	Análise de regressão.....	100
3.3.3	Análise dos resíduos da regressão.....	103
3.3.4	Validação das regressões.....	108
3.3.5	Equações de regressão lineares múltiplas	110
3.4	MAPAS DE BIOMASSA E CARBONO FLORESTAL	113
3.4.1	Sensor ASTER	113
3.4.2	Sensor LiSS III.....	116
3.4.3	Sensor TM	119
3.5	MERCADO DE CARBONO: CONTEXTO DO REDD ⁺	122
	CONCLUSÕES.....	127
	RECOMENDAÇÕES FINAIS.....	129
	REFERÊNCIAS BIBLIOGRÁFICAS.....	130

INTRODUÇÃO

A preocupação ambiental com que a sociedade tem-se defrontado com relação à manutenção de emissões de gases de efeito estufa na atmosfera é relativamente recente. Até meados do século passado era impossível imaginar que as ações realizadas pelos homens pudessem causar algum impacto significativo no clima ou na sobrevivência do sistema terrestre. No entanto, a história tem provado o contrário, especialmente, com relação ao aumento da quantidade CO₂ na atmosfera (GORE, 1993; IPCC, 2003).

Segundo Lovelock (2009), ironicamente, foi justamente quando Neil Armstrong deu “um pequeno passo para um homem e um grande salto para a humanidade” que os seres humanos se deram conta da suscetibilidade deste pequeno Planeta “Azul”, imerso na escuridão do espaço. Foi esta visão de mundo que levou James Lovelock a considerar nosso planeta Terra como um organismo vivo, o qual passou a chamar de Gaia (LOVELOCK, 1979). Esta imagem da Terra, vista da Lua, começou a ser incorporada na maioria das campanhas ambientais e em defesa do meio ambiente.

O impacto deixado nos astronautas, a bordo da missão Apollo, e nos seres humanos que aqui vivem, devido a esta visão da Terra, foi expressivo para a mudança de percepção de como se tem levado a vida no planeta e da utilização desenfreada dos recursos naturais, até então tidos como inesgotáveis.

Assim como Arquimedes teve que transcender sua percepção, que tinha sobre o mundo, ao imaginar o planeta Terra como sendo redondo, o homem necessitou sair de seu mundo para perceber que os recursos e o ambiente no qual vive são finitos, conforme disse Ralph Waldo Emerson apud Gore (1993): “as árvores não permitem uma visão da floresta”.

A partir desta nova perspectiva, em que a Terra passou a ser vista não mais do plano da superfície, mas a partir do espaço, que o Sensoriamento Remoto (SR) orbital passou a ser explorado com afinco pelos pesquisadores. A era espacial contribuiu para a consolidação do uso de sensores remotos para o estudo do meio ambiente em nível global.

Esta análise holística¹ do planeta desencadeou mudanças na forma de monitorar as ações do homem no meio ambiente. A Eco-92, realizada no Rio de Janeiro, foi o reflexo desta mudança de percepção, perante a sociedade, de que o uso indiscriminado dos recursos naturais em um país afetaria os demais; e que seriam necessárias ações conjuntas para que os objetivos de redução das taxas de emissão de gases de efeito estufa fossem alcançados pelos países-membros.

Assim, a criação do Protocolo de Kyoto (PK) foi uma tentativa de criar mecanismos de redução de gases de efeito estufa (GEE) na atmosfera aos maiores emissores. De acordo com o tratado, os países em desenvolvimento (como Brasil, Argentina e Índia) não receberam metas de redução, pelo menos por enquanto e, por isso, têm recebido o papel de sequestradores de carbono ou compensadores da poluição gerada pelos países-membros que ratificaram o acordo (YU, 2002).

Sabe-se, entretanto, que os objetivos de redução não vêm sendo alcançados e que políticas e instrumentos têm sido criados com esta finalidade, a exemplo do Mecanismo de Desenvolvimento Limpo (MDL), da Redução de Emissões por Desmatamento e Degradação (REDD) e mais recentemente do REDD⁺. Dentre estes mecanismos propostos, apenas o MDL está inserido nos tratados do PK como cláusula de redução de emissões e possui negociações reguladas pelo mercado internacional, enquanto o REDD e REDD⁺ não são requeridos por regulações internacionais, como o PK, mas sim negociados via mercado de carbono voluntário (CORTE et al. 2012).

No MDL, apenas as áreas de florestamento e reflorestamento são passíveis de compensações financeiras de reduções de emissões, o que impossibilita sua extensão para as áreas de florestas nativas, ao passo que o REDD e especialmente o REDD⁺ envolvem a compensação financeira referente à quantidade de CO₂ não liberada na atmosfera decorrente de mudanças no uso da terra em florestas e estoque de carbono em florestas naturais, além da possibilidade de manejo florestal (PARKER, 2008).

¹ Conceito filosófico que prega a compreensão integral do fenômeno, em que o todo é maior que a simples soma de suas partes.

Os métodos convencionais para estimar o estoque de carbono em florestas como o método destrutivo e o método de conversão de volume de madeira em carbono são muito onerosos e demanda esforço muito grande para sua realização, especialmente, em nível regional ou nacional, o que tem levantado o interesse em realizar as estimativas por meio do uso de dados de sensoriamento remoto (QURESHI et al. 2012).

Neste sentido, a aplicação de dados provenientes de sensores remotos orbitais para as estimativas de biomassa e estoque de carbono é uma solução promissora em termos de: reduzir o tempo e o custo se comparadas às grandes campanhas de inventários florestais necessárias; avaliar com rapidez os impactos de alta magnitude como desflorestamento e florestamento; integrar a variabilidade espacial da floresta em uma escala regional de estoque e fluxo de carbono; e quantificar com precisão aceitável o carbono estocado para ser negociável em acordos internacionais (LE MAIRE et al. 2011).

Esta metodologia possibilita que se alie técnica e economicamente a questão ambiental de redução dos GEE com o aumento de precisão das estimativas de estoque de carbono florestal em extensas áreas e em áreas pouco estudadas, como é o caso da Floresta Ombrófila Mista.

A Floresta Ombrófila Mista possui relevante interesse comercial e se encontra atualmente bastante fragmentada. Esta é uma das formações florestais com uma das maiores quantidades de biomassa florestal e de estoque de carbono dentre as formações florestais brasileiras, atrás apenas da Floresta Ombrófila Densa - Floresta Amazônica (LAMPRECHT, 1990).

Estimativas de biomassa acima do solo e estoques de carbono na Floresta Ombrófila Mista por métodos não destrutivos baseados em sensoriamento remoto são escassos, podendo-se citar como único o trabalho de Watzlawick et al. (2009), com dados do IKONOS II. A utilização de dados provenientes de sensores com média resolução espacial para esta finalidade em áreas de Floresta Ombrófila Densa é abundante, porém, inexistentes na literatura em áreas de Floresta Ombrófila Mista.

OBJETIVOS

Objetivo Geral

Estimar a biomassa e o carbono estocado a partir de dados oriundos de imagens ópticas de sensoriamento remoto e dados de campo, em fragmento de Floresta Ombrófila Mista, no Paraná.

Objetivos Específicos

Os objetivos específicos são descritos a seguir:

- a) Avaliar as relações entre os dados espectrais (bandas e índices de vegetação) gerados pelos sensores ASTER, LISSIII e TM e os valores de biomassa e carbono florestal obtidos no campo;
- b) Analisar, dentre os sensores estudados, qual o mais adequado para descrever as variações locais de biomassa e carbono florestal;
- c) Gerar mapas da distribuição espacial da biomassa e carbono florestal;
- d) Estimar a biomassa e o carbono estocado na área de estudo;
- e) Criar um cenário hipotético de REDD⁺ para a área de estudo, com relação à compensação financeira do estoque e redução de emissão de CO₂;

1.1 INTERAÇÃO DA RADIAÇÃO ELETROMAGNÉTICA (REM) COM AS FOLHAS

A radiação eletromagnética ao incidir sobre uma superfície vegetal apresenta três fenômenos físicos básicos que descrevem os processos desta interação, são eles: reflexão, transmissão e absorção (Equação 1). Segundo Jones e Vaughan (2010), a magnitude destes fenômenos depende não somente do comprimento de onda, mas também da estrutura e das características químicas do vegetal como a composição, a idade, a espessura, o conteúdo hídrico, entre outros.

$$1 = \rho + \tau + \alpha \quad (1)$$

Equação 1 - Equação geral do balanço de energia da radiação eletromagnética incidente.

Onde os três termos gregos definem a fração de reflectância (ρ), de transmitância (τ) e de absortância (α) do material em função da energia total incidente, representada pelo número inteiro 1, adimensional. Dentre estes fenômenos, o da reflexão é o de mais fácil registro pelos sensores remotos e, frequentemente, aquele mais estudado pelos pesquisadores da área de sensoriamento remoto. A magnitude da reflexão ao longo dos diferentes comprimentos de onda é o que se define como “comportamento espectral” de um objeto-alvo.

Sendo assim, a vegetação possui comportamento espectral bastante distinto, quando for analisada a reflexão da radiação eletromagnética nas diferentes regiões ópticas do espectro eletromagnético (Figura 1). No entanto, pela Figura 1, nota-se que este comportamento possui uma similaridade muito peculiar em todas as plantas saudáveis (BOWKER et al. 1985; PONZONI e SHIMABUKURO, 2009).

A radiação eletromagnética incidente, correspondente à região visível do espectro EM (0,40 – 0,72 μm), interage especialmente, com os pigmentos presentes nos cloroplastos, como xantofilas (29%), carotenoides (6%) e clorofila (65%) (GATES et al. 1965). Por ser a porção da REM vital para as plantas – participa ativamente no processo de fotossíntese, esta região do espectro possui baixa reflectância e transmitância espectral, todavia apresenta alta absortância (a vegetação absorve com maior intensidade os comprimentos de onda do azul e do

vermelho e com menor intensidade o comprimento de onda do verde e, por isso, enxerga-se a vegetação sadia na cor verde).

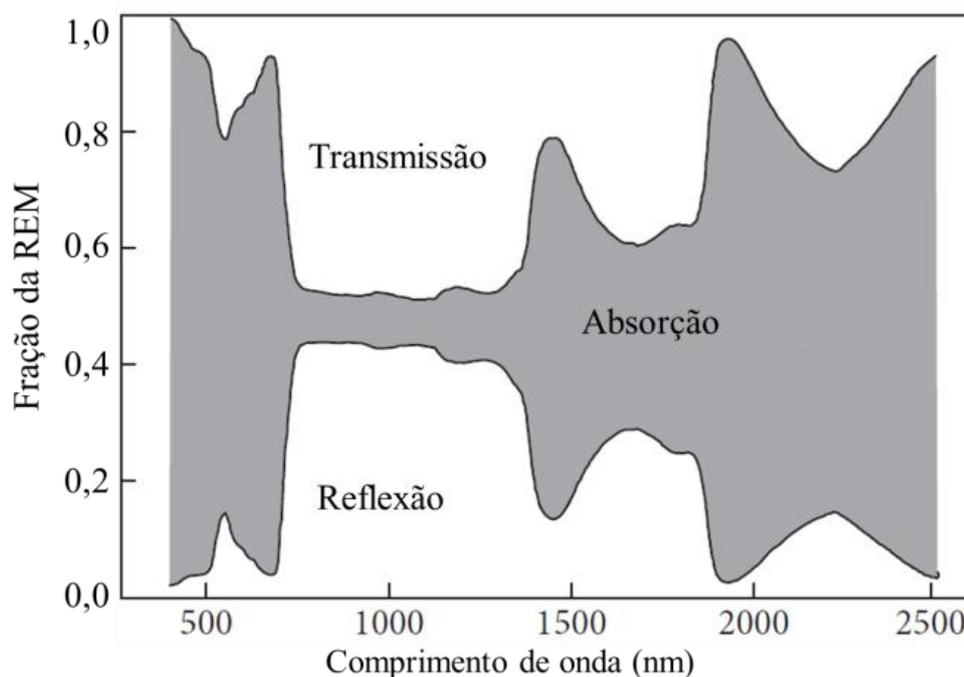


Figura 1 – Padrão típico de absorção, reflexão e transmissão da REM em uma folha verde sadia. Fonte: Adaptado de Jones e Vaughan, (2010).

Na região do infravermelho próximo (0,73 – 1,10 μm) predomina a reflexão e a transmissão na proporção do total da REM incidente, devido especialmente aos componentes estruturais das folhas: mesófilo paliçádico e esponjoso (JENSEN, 2009). Segundo Ponzoni e Shimabukuro (2009), a forma e a densidade destes componentes estruturais é que define a intensidade de transmissão e de reflexão da REM.

Para Gates et al. (1965), se as plantas absorvessem REM nesta faixa do espectro eletromagnético com a mesma eficiência que absorvem a radiação visível, a folha tornar-se-ia muito quente e as proteínas entrariam em um processo de desnaturação².

Em comprimentos de onda maiores que 1,10 μm até 2,5 μm a absorção da REM aumenta acentuadamente, enquanto decaem a reflexão e a transmissão espectral, causada pelo conteúdo hídrico presente na estrutura foliar (BOWKER et

² Desnaturação é um processo irreversível que ocorre em moléculas orgânicas, principalmente proteínas, quando estas são expostas a condições ambientais diferentes das que foram criadas, como excesso de calor, perdendo, então, sua estrutura e propriedades.

al. 1985). Proteínas, celulose e lignina também contribuem na absorção da radiação neste intervalo espectral (JACQUEMOUD et al. 1996).

Segundo Gates e Benedict (1963) do total da energia absorvida pelas plantas, aproximadamente 75 % é irradiada de volta para a atmosfera e 25% é dissipada por convecção e transpiração. Uma vez que as plantas absorvem eficientemente a radiação de que necessitam para o seu desenvolvimento, quase não absorvem a REM do infravermelho próximo para evitar o superaquecimento; voltam a absorver o infravermelho distante, a fim de serem radiadores eficientes. Sendo assim, toda a faixa do espectro eletromagnético é usada, sincronicamente, com a finalidade de manter os sinais vitais da planta de forma muito eficiente (GATES et al. 1965).

1.2 INTERAÇÃO DA REM COM OS DOSSÉIS VEGETAIS

Ao se ampliar a escala de observação, da superfície foliar para os dosséis vegetais³, a complexidade da interação da REM com a vegetação aumenta significativamente (PONZONI e SHIMABUKURO, 2009). A reflexão da radiação eletromagnética de dosséis depende das propriedades radiativas dos componentes individuais da vegetação (folhas, galhos, tronco, água, sombra) e da arquitetura da copa (JONES e VAUGHAN, 2010).

Além disso, conforme Norman, Welles e Walter (1985) a geometria de aquisição dos dados em dosséis vegetais é diferente da geometria obtida em folhas singulares, a qual passa a ter papel muito importante nos valores de radiância registrados pelos sistemas sensores.

Na geometria de aquisição de dados espectrais de folhas singulares, as folhas são vistas em uma só direção, mediante o uso de esferas integradoras⁴, onde se obtém o Fator de Reflectância Direcional Hemisférica; em dosséis vegetais, existem duas geometrias bem definidas, uma de iluminação (fonte) e outra de visada

³ Dossel vegetal é o estrato superior de uma superfície vegetada. Este termo é muito empregado em sensoriamento remoto por ser o alvo primeiro a interagir com a REM.

⁴ Como o nome já diz, esferas integradoras são esferas que integram a luz com a finalidade de eliminar a anisotropia da reflexão e detectar as propriedades espectrais de alvos. São comumente utilizadas em estudos de espectrorradiometria e comportamento espectral de alvos.

(sensor), reconhecidas como Fator de Reflectância Bidirecional – BRDF (*Bidirectional Reflectance Distribution Function*) (KIMES, 1984; PONZONI et al. 2002).

A luz solar ao incidir sobre um dossel vegetal pode ser esquematicamente representada pela Figura 2. A irradiação solar pode ser diretamente refletida de volta para a atmosfera pela superfície da folha (A). Uma pequena fração da radiação incidente pode ser transmitida através da folha ou também ser refletida novamente para a atmosfera em uma segunda camada de folhas (B) e, eventualmente, terceira camada de folhas (C). Similarmente, parte da contribuição da radiação refletida pode envolver o solo (D).

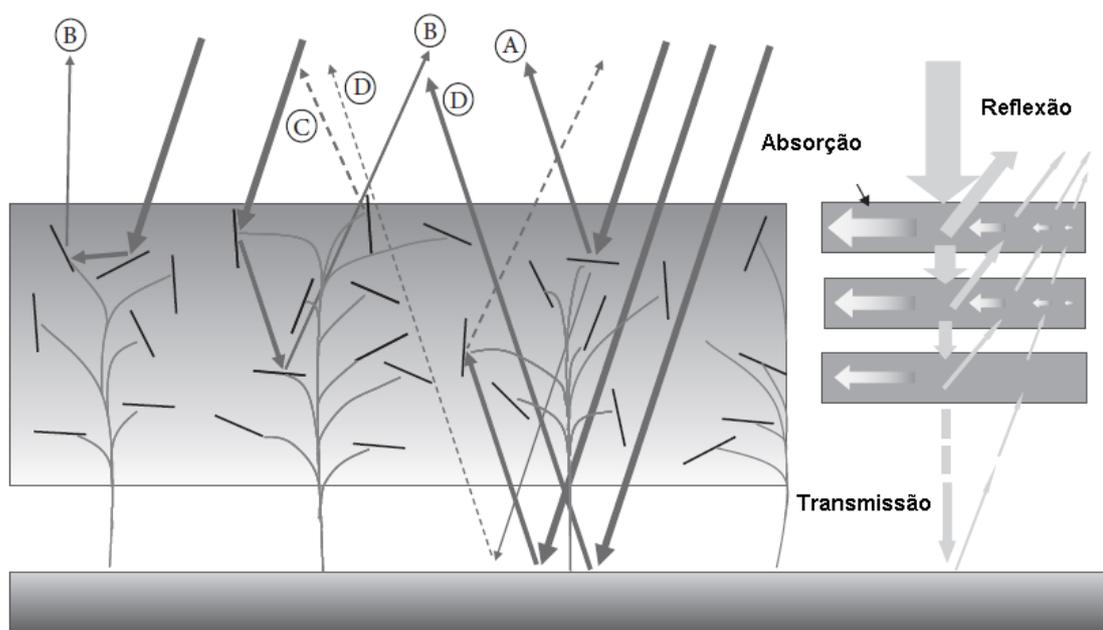


Figura 2 - Representação da interação da REM com um dossel vegetal, mostrando os múltiplos eventos de espalhamento (a); Representação esquemática do dossel vegetal tratado como um conjunto de finas camadas (folhas), onde a radiação transmitida é atenuada pela absorção e transmissão das múltiplas camadas e o fluxo de radiação que volta à atmosfera é a soma da radiação espalhada pelas múltiplas camadas (b) (JONES e VAUGHAN, 2010).

Nota-se que a característica dominante na reflexão e na transmissão da radiação pelos dosséis florestais é o número de camadas de folhas, denominado Índice de Área Foliar (IAF). Este é definido como a área foliar por unidade de área superficial (JORDAN, 1969). A influência do número de camadas de folhas, ou IAF, nos fenômenos de transmissão, absorção e reflexão da REM em um dossel vegetal pode ser analisada pela Figura 3.

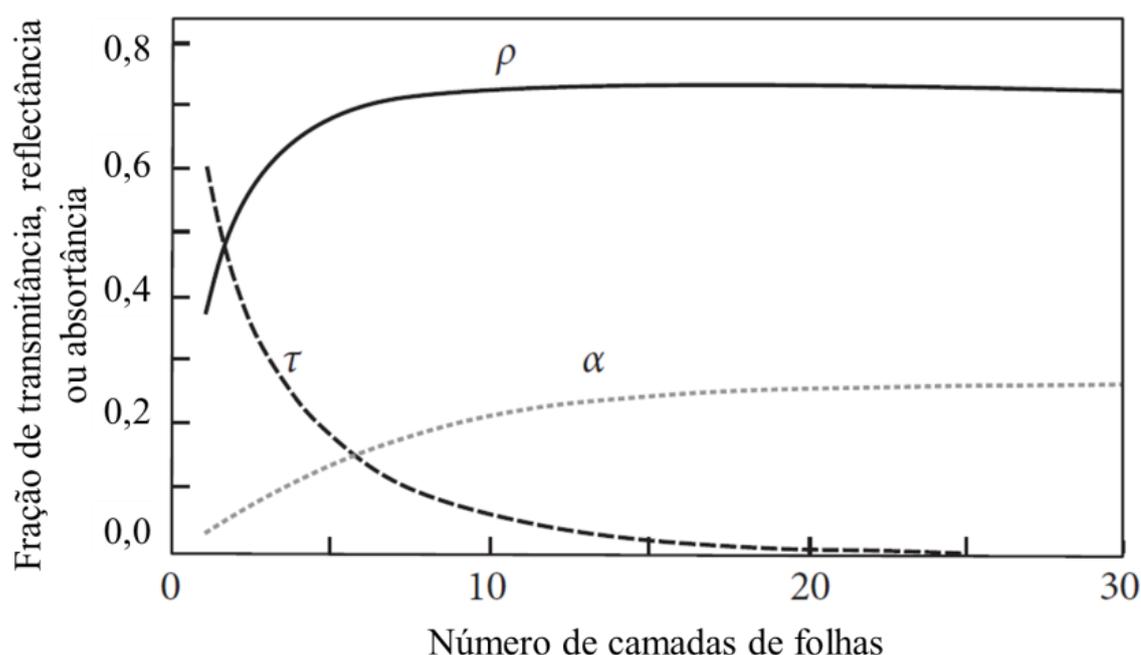


Figura 3 - Efeito do aumento de camada de folhas na transmissão (τ), absorção (α) e reflexão (ρ) da REM pelas folhas. Modificado de Jacquemoud e Baret, (1990).

Pela Figura 3, verifica-se que a reflectância aumenta assintoticamente com o aumento do número de camadas de folhas do dossel até atingir um valor de saturação de IAF, em torno de 8. A transmitância e a absorptância são saturadas mais lentamente (JONES e VAUGHAN, 2010).

De forma simplificada, as múltiplas camadas de folhas do dossel irão absorver uma maior quantidade de radiação na região do visível, devido a maior oferta de pigmentos fotossintetizantes, se comparadas às folhas isoladas e; a reflexão será maior na região do infravermelho próximo por conta do espalhamento múltiplo⁵ causado pela sobreposição foliar (PONZONI e SUIMABUKURO, 2009).

Sendo assim, a maior parte dos Índices de vegetação (IVs) é baseada nessa premissa básica de que a diferença ou a razão entre esses intervalos de comprimento de onda espectrais - visível e infravermelho próximo – está diretamente relacionada com a densidade vegetal presente (ROUSE et al. 1973).

⁵ Espalhamento múltiplo é o fenômeno de transmissão + reflexão da REM ocasionada pela sobreposição de múltiplas camadas de folhas em um dossel vegetal.

1.3 ÍNDICES DE VEGETAÇÃO (IVs)

Segundo Glenn et al. (2008), os IVs são uma das mais antigas ferramentas criadas em SR aplicado para estudos da vegetação. Os primeiros índices desenvolvidos datam do início da década de 1970 e têm sido empregados com sucesso para avaliar as diferentes condições vegetais, tais como cobertura, fenologia e produtividade primária.

O mais simples deles é conhecido como razão simples, SR - *Simple Ratio*, (JORDAN, 1969) mas fornece informações importantes sobre a biomassa florestal ou sobre o IAF, sobretudo em florestas com elevada concentração de biomassa (SCHLERF, ATZBERGER e HILL, 2005), Equação 2:

$$SR = \rho_{NIR}/\rho_{Red} \quad (2)$$

Equação 2 - Índice de Vegetação Razão Simples

Entretanto, o mais citado na literatura continua sendo o índice de vegetação por diferença normalizada, NDVI - *Normalized Difference Vegetation Index*, (ROUSE et al. 1973), Equação 3:

$$NDVI = (\rho_{NIR} - \rho_{Red})/(\rho_{NIR} + \rho_{Red}) \quad (3)$$

Equação 3 - Índice de Vegetação por Diferença Normalizada

Onde ρ_{NIR} e ρ_{Red} representam a reflectância das regiões do infravermelho próximo e do vermelho do espectro eletromagnético, respectivamente.

O NDVI é equivalente ao SR, porém, com intervalos de ocorrência definidos [-1,1], isto é, normalizados (JENSEN, 2009). O SR e o NDVI são altamente correlacionados com o IAF, só que ambos saturam com elevados valores de IAF (ver seção 1.2). Jensen, (2009) destaca ainda que o intervalo dinâmico do NDVI [-1,1] é ampliado a favor de baixas condições de biomassa e comprimido nos locais com alta biomassa, ou seja, é menos sensível às variações nos altos valores de biomassa; oposto do que ocorre com o SR.

Posteriormente foram formulados outros IVs mais elaborados, que levam em conta a atenuação dos solos na resposta espectral, como o *Soil-Adjusted Vegetation*

Index – SAVI (HUETE, 1988), a atenuação da atmosfera *Atmospherically Resistant Vegetation Index* – ARVI (KAUFMAN e TANRÉ, 1992) e recentemente a redução de ambos os fatores *Enhanced Vegetation Index* – EVI (HUETE et al. 2002). Além destes têm-se os índices ditos geométricos como o *Triangular Vegetation Index* – TVI e o *Perpendicular Vegetation Index* – PVI.

O SAVI foi formulado por Huete, (1988) com a finalidade de amenizar o efeito do solo sobre os valores gerados pelo NDVI, quando este é “visível” ao sensor. Dessa forma, Huete (1988) propôs a incorporação de um fator de ajuste para o substrato sob o dossel, que chamou de L, que leva em conta a extinção diferencial da REM através do dossel. Assim, para o autor, o valor de L igual a 0,5 minimiza satisfatoriamente as variações de brilho dos solos, independente do tipo de substrato e da porcentagem de cobertura das copas.

O EVI foi desenvolvido para ser usado nos dados do sensor *Moderate Resolution Imaging Spectroradiometer* - MODIS (JENSEN, 2009). Este índice foi formulado para ser um índice mais completo, contendo um fator de ajuste para o solo (L) e dois coeficientes (C1 e C2), que descrevem o uso da banda azul para a correção da banda vermelha quanto ao espalhamento atmosférico. G é o fator de ganho ajustado em 2,5. Assim, o EVI, além de ser sensível às variações de biomassa florestal, tem permitido um melhor desempenho no monitoramento da vegetação, através da redução dos efeitos do solo e da influência atmosférica sobre o sinal de retorno (GLENN et al. 2008).

Broge e Leblanc, (2000) desenvolveram o Índice Triangular (TVI), que descreve a REM absorvida pelos pigmentos presentes na folha como uma função da diferença relativa entre as reflectâncias no vermelho e infravermelho próximo, juntamente com a magnitude de reflectância no verde.

O TVI é definido como a área do triângulo formado pelos vértices dos picos de absorção do verde e vermelho e pelo pico de reflexão do infravermelho próximo. Assim, quanto maior a área do triângulo, maior será o valor do IV e o da biomassa presente (JENSEN, 2009).

Segundo Myneni et al. (1995), a construção de índices, baseados na razão entre bandas espectrais, tem a finalidade de diminuir a influência da geometria na

aquisição dos dados (efeito de sombreamento, topografia, retroespalhamento), enquanto a reflectância suaviza as discrepâncias entre as grandezas da irradiância da fonte (sol) e dos valores máximos e mínimos de radiância detectada pelo sensor, para os diferentes intervalos de comprimento de onda (PONZONI e SHIMABUKURO, 2009).

O contraste entre essas duas faixas espectrais (vermelho e infravermelho próximo) é o que define, em suma, a densidade de vegetação na superfície observada (McCOY, 2006). Analogamente, maiores valores de IVs e, conseqüentemente, de densidades vegetais encontradas caracterizariam maiores valores de biomassa. Contudo, esta relação empírica⁶ nem sempre é válida e em alguns casos não é linear (FRANK e KARN, 2003; MYNENI et al. 1995). Além disso, há o efeito da saturação do índice de área foliar, discutido anteriormente (JONES e VAUGHAN, 2010; PONZONI e SHIMABUKURO, 2009).

Apesar destas incoerências, diversos autores têm relatado a plausível e empírica correlação entre os índices de vegetação e as variáveis descritivas da vegetação, tais como o IAF, a biomassa e os parâmetros fisiológicos (LE MAIRE et al. 2011; MYNENI et al. 1995; ROY e RAVAN, 1996; STEININGER, 2000).

1.4 FLORESTA OMBRÓFILA MISTA

A Floresta Ombrófila Mista (FOM) possui esta denominação por ser uma floresta úmida, com chuvas uniformemente distribuídas ao longo do ano, do grego, *ombros*, chuva (LEITE e KLEIN, 1990) e de caráter misto, pois alude à coexistência de coníferas (*Araucaria angustifolia* (Bert.) O. Kuntz) e de folhosas, angiospermas dicotiledôneas, na estrutura da vegetação (MARCHIORI, 2006).

A Floresta Ombrófila Mista é uma das sete fitofisionomias pertencentes ao Bioma Mata Atlântica (ProBIO, 2007). Segundo o levantamento do ProBIO para o ano base de 2002, esta tipologia florestal cobre 20.000 km² do estado do Paraná;

⁶ A correlação entre os índices de vegetação e os parâmetros biofísicos é dita empírica, pois é formulada sem levar em conta todos os fenômenos físicos envolvidos na interação da REM com as plantas.

cerca de 10% do Estado. Contudo, a FOM sofreu intenso desmatamento e consequente perda de informação genética, por conter extensas áreas de Pinheiro Brasileiro (*Araucaria angustifolia*), espécie de alto valor comercial (MATTOS, 2011).

Com a construção da ambiciosa ferrovia da empresa *Brazil Railway Company*, em meados do século XX, ligando o rio Paraná ao porto de Paranaguá (MATTOS, 2011) o processo de colonização se acentuou com a conversão da floresta em terras agriculturáveis no sentido Leste-Oeste (HUECK, 1972). Atualmente, encontra-se reduzida a fragmentos relictuais⁷ (ProBIO, 2007).

Lamprecht (1990) descreve a FOM como a segunda maior floresta produtora de matéria viva – atrás apenas da Floresta Amazônica –, em toneladas de biomassa florestal por hectare, atingindo valores superiores a 300 t.ha⁻¹. Watzlawick et al. (2002) reportaram que a quantidade de biomassa florestal presente na FOM depende do estágio de desenvolvimento em que esta se encontra, podendo variar de 69,37 t.ha⁻¹ em estágio de regeneração inicial a 397,79 t.ha⁻¹ em estágio avançado de desenvolvimento.

1.5 BIOMASSA FLORESTAL

A Biomassa é a quantidade, em massa, de material de origem biológica, viva ou morta, animal ou vegetal (SANQUETTA e BALBINOT, 2004) e está relacionada à produtividade primária líquida que um ecossistema tem a capacidade de produzir (ZHAO e RUNNING, 2010). Sua medição é um instrumento útil na avaliação de um ecossistema, tendo em vista sua aplicação na análise da produtividade, conversão de energia, ciclagem de nutrientes, absorção e armazenagem de energia solar (SOARES; NETO; SOUZA, 2006).

Sanquetta (2002) a descreve como sendo fitomassa, pois a maioria dos trabalhos envolve apenas a massa de origem vegetal. A biomassa florestal, por outro lado, significa toda a biomassa existente na floresta ou apenas na sua fração

⁷ O termo relictual, do inglês *relict*, diz respeito à espécie ou habitat encontrado isoladamente, remanescente de flora ou fauna que outrora foi amplamente distribuído e agora encontra-se descaracterizado.

arbórea (SILVEIRA et al. 2008). Na literatura, a biomassa florestal é frequentemente subdividida em biomassa acima do solo e em biomassa abaixo do solo, por conta dos distintos processos metodológicos usados nas suas estimativas (do inglês *Above-Ground Biomass* – AGB e *Below-Ground Biomass* – BGB, respectivamente). Neste trabalho será empregada somente a biomassa florestal acima do solo (AGB), descrita apenas como biomassa florestal.

Basicamente, existem dois métodos para se estimar a biomassa de uma tipologia florestal: a) os obtidos pelo método direto (destrutivo), quando seus componentes vegetais são separados e pesados e; b) os obtidos pelos métodos indiretos, mediante uso equações alométricas estabelecidas com base nos métodos diretos e em variáveis dendrométricas (CHAVE et al. 2005; VIEIRA et al. 2008) ou em variáveis oriundas de dados de sensoriamento remoto (QURESHI et al. 2012; SILVEIRA et al. 2008). Também pode ser estimada por meio de fatores de expansão do volume de madeira em biomassa, método conhecido como *Biomass Expansion Factor* (BEF). Sanquetta e Balbinot (2004) citam que métodos diretos implicam determinações, ao passo que métodos indiretos geram estimativas. Outros métodos são conhecidos e serão analisados na próxima seção.

No método destrutivo, os componentes da biomassa são pesados em campo, obtendo-se a biomassa verde; em laboratório, amostras de cada um destes componentes são secas em estufa, obtendo-se o teor de umidade; a biomassa seca é calculada subtraindo-se o teor de umidade da biomassa verde (WATZLAWICK, 2003). A biomassa florestal total é então calculada somando-se todos os componentes arbóreos secos, tais como os galhos, as folhas, os troncos e as raízes, ou simplesmente a biomassa acima e abaixo do solo (FRANKLIN, 2001). Assim, as equações alométricas de biomassa florestal podem envolver a biomassa verde ou a biomassa seca nas suas estimativas. A biomassa seca é frequentemente utilizada por ser facilmente convertida para carbono orgânico florestal e foi empregada neste estudo.

A metodologia de mensuração da biomassa florestal pode abarcar apenas as árvores-amostra ou os tipos de sítios (parcelas). No primeiro método, utilizam-se as árvores médias, se realizado em povoamentos homogêneos, ou as árvores de centro de classe diamétrica para povoamentos heterogêneos nas pesagens das

amostras de biomassa. No segundo método, a amostra representa toda a biomassa presente no sítio ou parcela, realizando-se para isso o corte e pesagem de toda a matéria vegetal (SANQUETTA, 2002). O primeiro método tem a vantagem de ser mais prático, porém este é menos preciso que o segundo, visto que exclui a biomassa presente no sub-bosque e na regeneração natural em sua metodologia. Assim, a metodologia adequada deve contemplar todos os compartimentos e componentes do ecossistema florestal. A escolha do melhor método, no entanto, dá-se em função do objetivo proposto e do custo operacional e financeiro.

Os métodos diretos são onerosos e tediosos e, por isso, são aplicáveis apenas em pequena escala. Estes são utilizados para calibrar as equações alométricas obtidas pelos métodos indiretos (QURESHI et al. 2012; SALATI, 1994; SANQUETTA, 2002). As equações alométricas de biomassa florestal envolvem a seleção de variáveis independentes nos modelos, como diâmetro, altura e densidade, podendo ser usadas separadas ou em conjunto (CHAVE et al. 2005). Os mesmos autores descrevem que o uso das três variáveis conjuntamente apresentam os melhores resultados, mas devido à altura e, principalmente, à densidade ser de difícil medição em campo, o uso apenas da variável diâmetro como preditora torna-se mais prático e usual.

As equações alométricas de biomassa florestal podem ser lineares ou não lineares. O uso de modelos não lineares é justificado pelo comportamento não linear da maioria das variáveis naturais (SANTOS, 1996). Contudo, tem a desvantagem, por se tratar de um processo iterativo de seleção de variáveis, de ser mais complexa a estimação de seus parâmetros e o cômputo dos erros provenientes das estimativas (SILVEIRA et al. 2008). Os modelos lineares são simples e os erros são facilmente minimizados pelo método dos mínimos quadrados, por exemplo. Porém, são apenas confiáveis dentro do intervalo de dados para os quais foram criados (SILVEIRA et al. 2008). A escolha do melhor modelo, no entanto, envolve a experiência do analista, o comportamento das variáveis e as recomendações da literatura.

1.6 ESTIMATIVA DE CARBONO FLORESTAL

Para se gerar uma boa estimativa do carbono florestal, uma acurada estimativa da biomassa é um pré-requisito (SILVEIRA et al. 2008). Qureshi et al. (2012) compararam cinco diferentes métodos para a estimativa de biomassa florestal a serem usados na conversão para carbono florestal. Os métodos avaliados foram: a) Baseados em modelagem de processos fisiológicos das plantas; b) Modelos desenvolvidos por técnicas de sensoriamento remoto; c) Medidas de fluxo de carbono pela técnica de *Eddy Covariance*; d) Método destrutivo e; e) Método BEF. A avaliação desenvolvida pelos autores encontra-se na Tabela 1.

Tabela 1 - Comparação de diferentes métodos usados em estimativas de biomassa para a medição de estoques de carbono florestais.

Método	Operacional	Custo	Precisão	Escala Espacial	Eficiência (tempo)	Cobertura sub-bosque
Fisiológico	Complexo	Alto	Baixa	Limitada	Dispendioso ²	Inclui
Sensores Remotos	Simple	Alto	Baixa	Ampla	Eficiente	Exclui
<i>Eddy Covariance</i>	Complexo	Alto	Baixa	Variável ¹	Eficiente	Inclui
Destrutivo	Simple	Baixo	Alta	Variável ¹	Dispendioso	Inclui
Fator de Expansão	Simple	Baixo	Baixa	Ampla	Eficiente	Exclui

Fonte: Adaptado de Qureshi et al. (2012).

Nota: Algumas características foram modificadas pelo autor, por serem julgadas mais coerentes segundo consultas à literatura.

Os dados originais foram:

(1) Ampla;

(2) Eficiente.

Qureshi et al. (2012) destacam ainda que cada um dos métodos possuem vantagens e desvantagens e que estas são dependentes dos objetivos propostos. Por exemplo, os métodos baseados em processos fisiológicos fundamentam-se na simplificação dos processos de balanço de carbono nas diferentes partes das plantas, mas por envolver uma grande quantidade de variáveis nos modelos (como área foliar, eficiência respiratória, entre outras variáveis fisiológicas) são operacionalmente complexos e limitados a pequenas áreas. Estes métodos são dependentes da produtividade local e da maturidade da planta (MONSERUD et al. 2003).

Os métodos que se utilizam de técnicas de sensoriamento remoto são eficientes, operacionalmente simples, possuem ampla cobertura espacial, mas a sua limitação reside no fato de serem dependentes de fontes de dados confiáveis sobre a biomassa florestal, obtidos por outros métodos diretos (DONG et al. 2003). Além disso, possuem alto custo, devido não somente ao custo de aquisição dos próprios dados espaciais, como ao custo de calibração em campo destas relações empíricas. Estes métodos serão mais bem descritos e discutidos nas seções 1.7 e 1.9.

No método de mensuração de CO₂ conhecido por *Eddy Covariance*, o fluxo de CO₂ entre a atmosfera e a superfície das plantas é medido pela covariância entre a flutuação da velocidade do vento e a proporção de CO₂ (QURESHI et al. 2012). A velocidade de flutuação do vento, bem como, a concentração de CO₂ são medidas por meio de sensores posicionados em diferentes estratos da floresta⁸. Estes sensores possuem alto custo e necessitam de estruturas complementares, tais como torres micrometeorológicas, para alçá-los nas distintas alturas. Além disso, limitam-se pelo fato de serem aplicáveis somente em condições ambientais estáveis, devido à sensibilidade dos sensores às variações ambientais (BALDOCCHI, 2003). Entretanto, as observações são feitas em tempo real e continuamente (alta resolução temporal), o que lhe confere a vantagem de ser o único método que tem a capacidade de registrar as variações dinâmicas nos fluxos de CO₂ no interior da floresta, conquanto todos os outros métodos sejam estáticos.

O método destrutivo é aquele que alcança a maior acurácia dentre os métodos avaliados (QURESHI et al. 2012). É simples, com baixo custo e, frequentemente, é utilizado como fonte de dados para a estimativa de biomassa e carbono florestal por meio de outros métodos, como os métodos que se utilizam de fatores de expansão, de equações alométricas ou de dados oriundos de sensores remotos. Mas são dispendiosos em termos de tempo de operação e limitados à escala de trabalho (SILVEIRA et al. 2008).

O método de estimativa de biomassa e carbono florestal por meio de fatores de expansão de volume de madeira é o mais simples dos métodos possíveis, é

⁸ Estratos florestais são definidos como a organização vertical da floresta, em que as árvores de cada um dos estratos atingem alturas máximas conhecidas. Por exemplo, a FOM em estágio avançado de desenvolvimento possui três estratos arbóreos bem definidos, com alturas de até 7m, de 7-15m e superiores a 15m, para os estratos inferior, médio e superior, respectivamente (SANQUETTA, CORTE e KOVALEK, 2011).

eficiente e com baixo custo, visto que muitos países realizam inventários florestais nacionais de forma contínua (NFI – *National Forest Inventory*). Porém, este possui baixa precisão, por que o uso do volume comercial de madeira não retrata de forma fidedigna toda a gama de variações de biomassa dentro de seus componentes arbóreos (fuste, casca, folhas, galhos e raízes). Além disso, não inclui a biomassa e o carbono florestal do sub-bosque nas suas estimativas, já que são obtidos por inventários comerciais, cujos indivíduos arbóreos com pequenos diâmetros frequentemente não são medidos.

O carbono estocado por um ecossistema florestal está compartimentado em (MUKKONEN, 2006; QURESHI et al. 2012): 45-55% na biomassa acima do solo (fuste, casca, galhos e folhas); 20-26% na biomassa abaixo do solo (raízes); 20% no próprio solo (respiração das raízes e respiração heterotrófica dos micro-organismos edáficos) e 6-8% na serapilheira (material inerte). Estes valores, no entanto, variam conforme o estágio de desenvolvimento da floresta. Watzlawick et al. (2002) observaram valores de quase 50% de contribuição da fração arbórea (acima e abaixo do solo) no carbono orgânico total do ecossistema florestal quando a FOM encontrava-se em estágio inicial de desenvolvimento para quase 90%, em estágio avançado de desenvolvimento.

Da fração de biomassa florestal acima do solo, a madeira apresenta a maior proporção em quantidade de carbono (SANQUETTA e BALBINOT, 2004). Em geral, a madeira é constituída de 50% de carbono, 43% de oxigênio, 6% de hidrogênio e 1% de nitrogênio e uma fração de outros elementos minerais (KLOCK et al. 2005). Conforme Andrae (1978) o maior porcentual de C concentra-se no tronco e aumenta à medida que este envelhece. Por isso, mensurações tomadas a partir do diâmetro à altura do peito (DAP) providenciam boas estimativas de biomassa e de carbono florestal (Gifford, 2000a; 2000b apud Köhl et al. 2006).

Na Figura 4, tem-se a complexa rede de fluxo de gases e fixação de carbono florestal (C), demonstrando as múltiplas interações com o ecossistema florestal (MUKKONEN, 2006). Segundo Ciais, Peylin e Bousquet (2000) as estimativas de estoque e fixação de carbono pelas florestas são complexas por que a paisagem e a biomassa florestal são amplamente variáveis em escalas espaciais e temporais.

Além disso, distúrbios naturais e ações antrópicas também podem ocorrer na floresta.

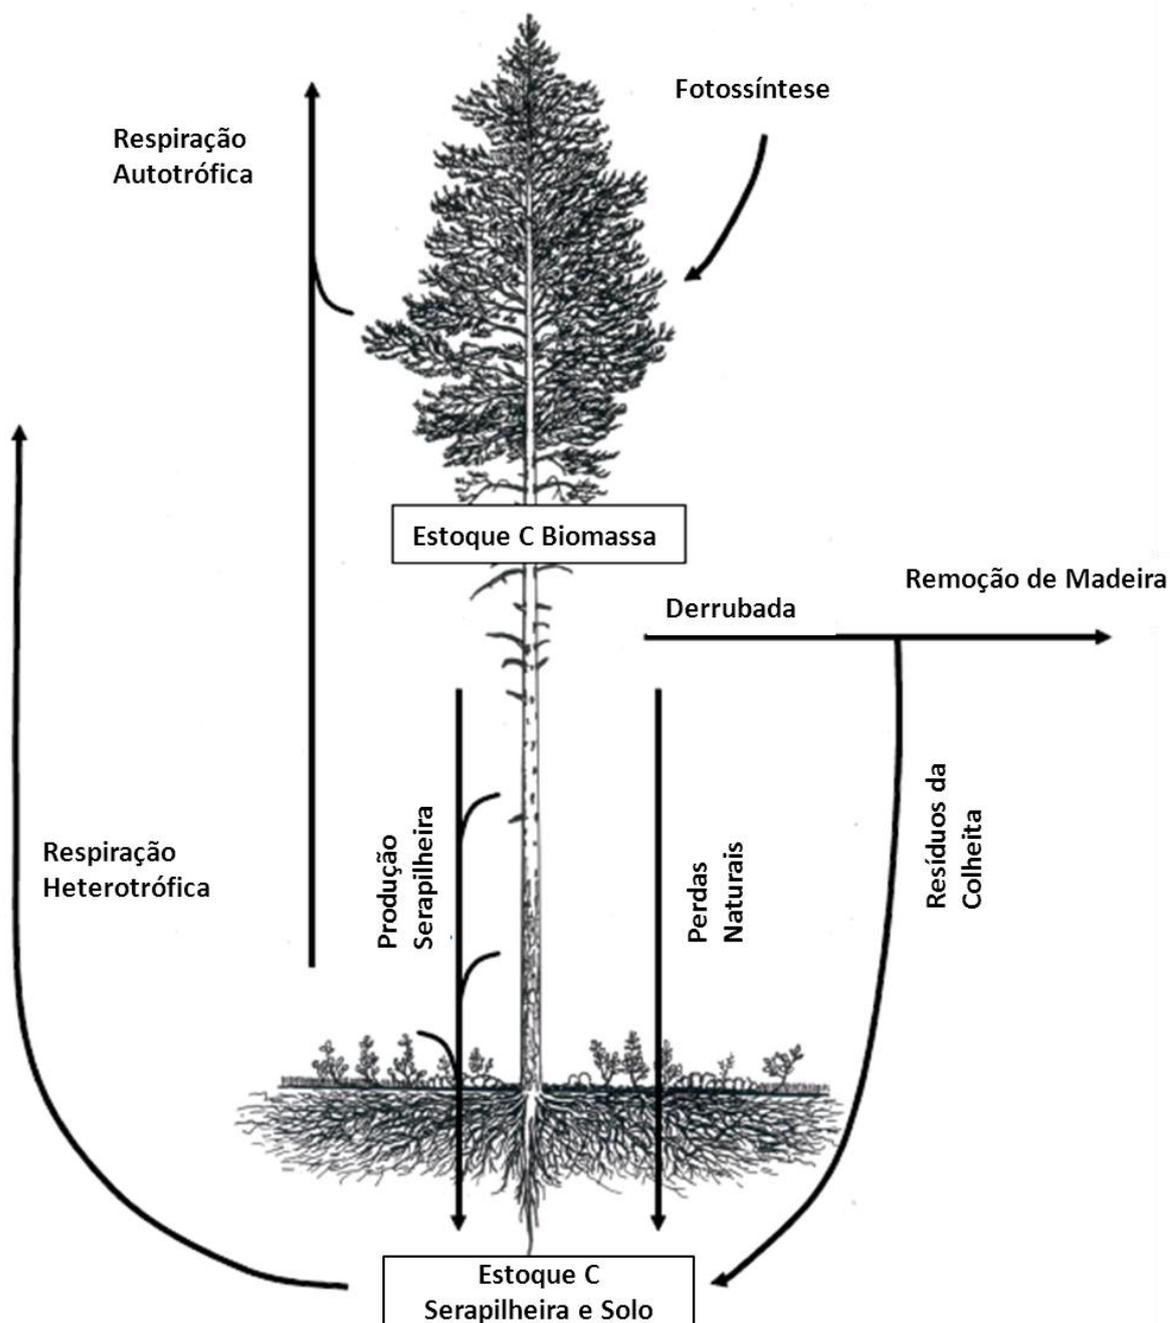


Figura 4 - Exemplo do estoque de carbono (caixas) e o fluxo de materiais e de CO₂ (flechas) em um ecossistema florestal. Modificado de Muukkonen, (2006).

Entretanto, os teores de carbono (TC) variam conforme a espécie, fase de desenvolvimento, estado nutricional, condições edafoclimáticas e a parte do vegetal a ser considerada. O TC florestal é determinado pela análise química de carbono orgânico nos tecidos vegetais de acordo com metodologia de Walkley-Black,

descrita por Tedesco et al. (1995). Watzlawick et al. (2004) encontraram TC, em espécies florestais de uma FOM, variando de 30,01% a 51,42%, dependendo da espécie e do componente considerado (fuste, casca, galhos, folhas ou raízes). Sendo assim, para Kohler et al. (2002) e Sanquetta e Balbinot (2004), o uso de fatores genéricos de conversão de biomassa para carbono, tal como 0,5 preconizado pelo *Intergovernmental Panel on Climate Change* (IPCC, 2003) pode levar a sub ou superestimativas do verdadeiro estoque de carbono.

Watzlawick (2003) observou a seguinte distribuição porcentual de acúmulo de carbono orgânico entre os componentes de uma Floresta Ombrófila Mista: galhos vivos > madeira do fuste > casca do fuste > folhas > galhos mortos > miscelânea⁹. Porém, o autor comenta que o fato da concentração de C nos galhos vivos ser superior à da madeira se deve à metodologia empregada, que considerou os galhos vivos a porção a partir do ponto de inversão morfológica (inserção do primeiro galho vivo).

Para Neeff et al. (2005) a determinação das quantidades de carbono fixadas em extensas áreas, por meio do método destrutivo, torna-se onerosa e pouco eficiente. Isto tem levado os pesquisadores a estimar a biomassa e carbono florestal com o uso de dados de sensores remotos, correlacionando-os com as equações alométricas *in situ* (BROWN, 2002).

Lu (2006) descreve que devido à dificuldade de mensurar a biomassa abaixo do solo, as pesquisas recentes com o uso de sensoriamento remoto para estimativa de biomassa viva têm focado apenas na biomassa acima do solo. Ainda, os métodos destrutivos são a fonte mais confiável para se determinar o carbono florestal a nível local e as equações alométricas estabelecidas com base nestes dados e em dados de sensoriamento remoto continuam sendo os métodos mais promissores para a geração de modelos de fluxo globais de carbono florestais (ROSENQVIST et al. 2003; MUUKKONEN e HEISKANEN, 2007).

⁹ Miscelânea se refere às partes vegetais não incluídas nas demais classes.

1.7 EQUAÇÕES ALOMÉTRICAS

Segundo Atazadeh (2011), alometria (do grego *allos*, “outros” e *metron*, “medida”) é a correlação entre o tamanho ou o número de organismos e seus componentes. Sendo assim, as equações alométricas são criadas para se estimar variáveis de difícil mensuração (como a biomassa e o carbono florestal) com base no uso de outras variáveis de mais fácil obtenção (tal como o DAP ou dados de satélite). É lógico pensar que isto implica em erros e que estes são dependentes da metodologia empregada e do nível de precisão estabelecido.

Dong et al. (2003) citam que a biomassa florestal não pode ser calculada diretamente do espaço, mas a reflectância pode ser relacionada com a quantidade de biomassa florestal presente, por meio de equações alométricas que descrevam esta relação.

Para Labrecque et al. (2006) os métodos para mapeamento de biomassa florestal, associados ao uso de dados obtidos por sensores remotos, têm duas principais abordagens: (i) os que envolvem modelagem radiométrica (físicos); (ii) aqueles que se utilizam de tabelas de conversões para uma classificação temática na imagem. Existem outros modelos como aqueles baseados em modelagem por transferência radiativa da REM nos componentes vegetais. Porém, estes fogem do escopo do trabalho e não foram retratados.

Os métodos radiométricos são comumente utilizados e implicam análises de regressão, de forma a correlacionar dados espectrais (físicos) com medidas ou estimativas de biomassa e carbono para os locais correspondentes (FOODY et al. 2003). Estes dados espectrais podem ser o fator de reflectância de superfície, índices de vegetação, razão de bandas, um único canal da imagem (STEININGER, 2000; WATZLAWICK, KIRCHNER e SANQUETTA, 2009) ou até mesmo o resultado das transformações espectrais, tais como dados de textura (BARBIER et al. 2010; SARKER e NICHOL, 2011), componentes principais (MATOS e KIRCHNER, 2008) ou modelos lineares de mistura espectral (MACIEL, 2002; MATOS e KIRCHNER, 2008).

Na segunda abordagem, as imagens são classificadas e conforme as densidades de vegetação em cada uma das classes, os fatores de expansão para a biomassa florestal são aplicados. Tem duas abordagens principais: os que envolvem só a classificação temática da floresta – método conhecido como *Land Cover Classification* (LCC) ou aqueles que envolvem a inserção de outros parâmetros da floresta – método conhecido como *Biomass from Cluster Labeling Using Structure and Type* (BioCLUST). Somente o método radiométrico foi usado no trabalho e, por isso, deu-se maior atenção. Para saber mais sobre os métodos de conversão ver Labrecque et al. (2006).

Nos métodos radiométricos, os dados biofísicos são tratados como variáveis dependentes (y) e os dados espectrais como variáveis independentes (x) pelas equações de regressões. As equações de regressão são avaliadas por testes estatísticos e análises de regressão, como o coeficiente de determinação (R^2) para regressões lineares simples ou ajustado ($R^2_{aj.}$) para regressões múltiplas.

Em geral, a avaliação das estimativas de biomassa florestal mediante uso de informações espectrais engloba três tipos de aplicações, que são elas: em nível de pixel, em nível de talhão ou parcela ou em nível de área total (LU, 2006). Devido ao erro de co-registro de informações entre os pixels e a área correspondente no campo é preferível se tomar a quantidade de biomassa total a ser estimada para compará-la com a observada por outra fonte de dados, como provenientes de inventários nacionais. Além disso, os dados de sensoriamento de um único pixel consistem de uma mistura de informações contidas na área relativa à dimensão do pixel, que pode ser de até 900 m², no caso do sensor TM.

Em nível de área total, surgem dois outros problemas decorrentes do aumento da área de campo. O primeiro é de ordem operacional, pois há uma dificuldade de coletar informações sobre a biomassa florestal em campo sobre extensas áreas. O segundo é de ordem estatística, visto que serão utilizadas menos unidades de amostra para validar os modelos. O modelo usado neste trabalho apesar de ter sido formulado em nível de pixel, utiliza-se de uma área maior de referência, equivalente a um hectare da parcela permanente, reduzindo o erro de co-registro e contornando o problema da insuficiência amostral.

Estudando a FOM com o uso de dados de SR Watzlawick, Kirchner e Sanquetta, (2009) encontraram alta correlação negativa entre biomassa (-0,8) e carbono (-0,79) e a banda MS-4 do sensor IKONOS-II. No mesmo sentido, foram encontradas correlações negativas entre a Banda MS-4 e o NDVI com a biomassa florestal em uma Floresta de Terra Firme na Amazônia (MATOS, 2006). Contudo, com baixos coeficientes de correlação entre estas variáveis (-0.061 e -0.07, respectivamente).

Já Bernardes (1998) encontrou $r = -0.82$ entre o índice SAVI, gerado a partir do sensor TM e a biomassa de uma Floresta Ombrófila Densa, enquanto Maciel (2002) encontrou $r = -0.83$ entre o SAVI e a biomassa, na mesma floresta, utilizando-se do mesmo sensor.

Contudo, Dong et al. (2003) descrevem que a precisão das estimativas de biomassa tem papel fundamental no resultado de estudos que envolvam estas relações empíricas. Os inventários florestais, conciliados com as informações provenientes de sensoriamento remoto são os dois principais recursos para se estimar a biomassa florestal, assim como, os estoques e fluxos de carbono em larga escala (KRANKINA et al. 2004; MUUKKONEN e HEISKANEN, 2007).

1.8 GEOESTATÍSTICA APLICADA AO SENSORIAMENTO REMOTO

A maioria das variáveis aleatórias (v.a.) ambientais ou naturais, como a biomassa florestal e os valores de reflectância, é tratada pela estatística clássica como variáveis independentes, i.e., possuem a mesma probabilidade de ocorrência em certo evento aleatório independente da posição em que estas se encontram no espaço. Este pressuposto, quando aplicado às v.a. naturais é importante, pois exclui o efeito bias ou erro sistemático.

Sabe-se, porém, que além da independência do fenômeno, há uma forte correlação entre as amostras adjacentes. Isto levou Matheron, em 1970, a definir o que chamou de teoria das variáveis regionalizadas. Pela teoria, espera-se que próxima às amostras que apresentem altos valores de biomassa florestal ou de

reflectância obtenham-se também amostras com valores elevados, que será tanto mais influente quanto maior for a sua continuidade espacial.

Nas imagens provenientes de sensores remotos, os valores dos números digitais representados pelos pixels $Z(x)$ podem ser considerados como idealizações das variáveis regionalizadas propostas por Matheron (1970), onde a distância entre as amostras ($lag = h$) é a própria dimensão do pixel $Z(x+h)$, $x = 1, 2, \dots, n$ (CURRAN e ATKINSON 1998).

A função que reflete a estrutura dos dados das variáveis regionalizadas é o variograma. Segundo Soares (2000) e Andriotti (2003), o variograma é por definição a variância dos desvios ($Z(x) - Z(x+h)$) quando ambos os pontos x e $x+h$ pertencem a uma mesma área. Por convenção matemática, o semivariograma representa a metade do variograma e é mais comumente utilizado pelos geoestatísticos.

O semivariograma mede as relações estatísticas, pelas covariâncias, que existem entre as amostras espaçadas de sucessivos valores de h (CAMARGO, 2011) e proporciona uma concisa e não enviesada descrição da escala e padrão da variabilidade espacial (CURRAN, 1988).

Alguns autores utilizaram-se do semivariograma com o intuito de encontrar a escala de observação apropriada para classificar imagens digitais (WOODCOCK e STRAHLER, 1987) ou para correlacionar os valores de NDVI com as variáveis biofísicas (CURRAN, 1988; GOODIN e HENEERY, 2002). Todavia, o uso do semivariograma neste caso tem dois problemas fundamentais: o primeiro é que este é dependente da escala da variável e, por isso, não pode ser utilizado para compará-lo com o semivariograma gerado por outra variável ou por mesma variável proveniente de outro sensor; o segundo é que o semivariograma se baseia em apenas uma variável regionalizada, impossibilitando a verificação da continuidade espacial da biomassa florestal em virtude dos IVs, por exemplo.

Portanto, o correlograma $[\rho(h)]$ passa a ser mais apropriado para comparar diferentes variáveis regionalizadas, já que é função do próprio semivariograma $[\gamma(h)]$ e da covariância $[C(h)]$ entre os pares de pixels (ISAAKS e SRIVASTAVA, 1989). O correlograma é um gráfico de dispersão entre os coeficientes de correlação obtidos

em $Z(x)$ versus os coeficientes de correlação separados a uma distância $Z(x+h)$ (ISAAKS e SRIVASTAVA, 1989).

A teoria geoestatística foi utilizada para fundamentar a escolha acerca da escala de observação apropriada para correlacionar os dados biofísicos com os dados espectrais do sensor ASTER, não sendo feitas quaisquer estimativas com base em Krigagem ou mesmo sobre a escolha de modelos matemáticos de variogramas e graus de anisotropia. Para saber mais, importante discussão e revisão sobre a aplicação da geoestatística nos dados oriundos de sensoriamento remoto foi dada por Curran e Atkinson (1998).

1.9 ESTADO DA ARTE: ESTIMATIVAS DE BIOMASSA E ESTOQUE DE CARBONO FLORESTAL versus SENSORIAMENTO REMOTO

Segundo Rosenqvist et al. (2003) o sensoriamento remoto, em comum acordo com o IPCC é um caminho em aberto para se estimar o estoque de carbono e monitorar o fluxo de CO_2 decorrentes de mudanças no uso da terra e florestas sob o ponto de vista de larga escala (BACCINI et al. 2004; BROWN, 2002; MUUKKONEN e HEISKANEN, 2007).

Na literatura, diferentes tipos de imagens têm sido usados para estimar a biomassa e carbono florestal por meio de dados de sensores remotos (KOCH, 2010). Radar interferométrico e LiDAR (*Light Detecting and Range*) são as mais promissoras técnicas para estimativas de biomassa florestal (HYPPA et al. 2000; FREITAS e SHIMABUKURO, 2007) e é sabido que dados ópticos não alcançam o mesmo nível de acurácia (PATENAUDE et al. 2005). Entretanto, estimativas de biomassa ao longo do tempo e em grandes áreas não podem ser satisfeitas por técnicas de sensoriamento remoto ativos, devido ao alto custo envolvido, significando que a solução por imagens ópticas são ainda essenciais (FRANKLIN, 2001; POWELL et al. 2010).

Em virtude de algumas limitações da correlação direta entre índices de vegetação e a biomassa florestal com dados ópticos (LABRECQUE et al., 2006; LU, 2006), estes têm-se demonstrado interessantes quando combinados com outros

dados, como por exemplo, dados climáticos (BACCINI et al. 2004; MAIN-KNORN et al. 2011), biofísicos (BROWN, 2002; WULDER et al. 2008), de textura (PROISY; COUTERON; FROMARD, 2007; SARKER e NICHOL, 2011) e multitemporais (LE MAIRE et al. 2011).

Mesmo assim, alguns autores têm demonstrado, ainda, que o uso de dados ópticos de sensoriamento remoto, associados a confiáveis pesquisas de campo, proporcionam aceitáveis estimativas de biomassa e estoque de carbono florestal (BAKER et al. 2010; BROWN et al. 2010; EVA et al. 2009; GOETZ et al. 2010; LE MAIRE et al. 2011).

Recentemente, outros autores tem verificado um aumento na precisão das estimativas de biomassa florestal com o uso de dados provenientes de multisensores, conciliando dados ópticos de alta resolução espacial com dados de radar (HÄME et al. 2010; HOU; XU; TOKOLA, 2011; TOKOLA e HOU, 2012), com dados de laser aerotransportado (ASNER, 2009; SWATANTRAN, 2011) ou com dados hiperespectrais (CLARK et al. 2011; KOCH, 2010; XIAOPING et al. 2011).

Entretanto, imagens de alta resolução espacial (<10m), como o QuickBird e o IKONOS, para estimativa de biomassa florestal são limitadas a pequenas áreas, pois têm a desvantagem de necessitar de um grande volume de dados, exigindo laborioso tempo no processamento digital destas imagens. Por último, e não menos importante, as imagens de alta resolução espacial ainda possuem alto custo de aquisição. Justificando-se o porquê do uso intensivo de imagens de média resolução espacial (10 – 100m) para esta finalidade (LU, 2006).

De modo análogo, o uso de imagens provenientes do sensor TM, por exemplo, para estimativas de biomassa e fluxo de carbono em nível nacional ou global, torna-se inviável. Sensores de baixa resolução espacial (p.ex. MODIS) podem realizar esta ponte para áreas que sejam bastante homogêneas (MUUKKONEN e HEISKENEN, 2007), mas não em áreas muito fragmentadas por consequência da mistura espectral e da baixa acurácia destas estimativas. Assim, a análise em multiescala combinando dados de alta, média e baixa resolução espacial com dados de campo poderia aumentar a precisão das estimativas de biomassa e carbono florestal em nível nacional ou global (LU, 2006). Há que se ter um equilíbrio entre o nível de precisão e os custos em trabalhos desta natureza.

1.10 INVENTÁRIO DE CO₂ EM FLORESTAS

A primeira iniciativa envolvendo projetos de sequestro florestal de carbono remonta ao início dos anos 90, lançada na convenção do clima das Organizações das Nações Unidas (ONU) como instrumento de compromisso de redução de emissões de GEE, por parte dos países pertencentes ao Anexo I¹⁰ (CHANG, 2004). Trata-se de uma das modalidades do MDL legalizada pelo Protocolo de Kyoto (PK)¹¹ durante a terceira Conferência das Partes (COP-3).

O PK estabelece que os países industrializados devam reduzir suas emissões de GEE em 5,2% abaixo dos níveis observados em 1990 até o ano de 2012 (primeiro período do compromisso). Contudo, apenas 35 Partes (países) ratificaram o Protocolo, não alcançando, portanto, os 55 países necessários ou 55% de representatividade das emissões de GEE no mundo, devido, especialmente, à relutância dos Estados Unidos da América em assinar o Tratado.

O estabelecimento do PK, por outro lado, permitiu que o mercado pudesse auxiliar no processo de redução das emissões, através da criação de Certificados de Redução de Emissões (CRE) e da referência de equivalente de Carbono CO₂e (ROCHA, 2002). Assim, o MDL foi criado para que as Partes incluídas no Anexo I pudessem cumprir com suas obrigações de reduções de emissões, ao passo que os países não incluídos no Anexo I, a exemplo do Brasil, beneficiar-se-iam de projetos que resultem em CRE.

Dentre as modalidades do MDL para reduções de emissões, apenas o reflorestamento e florestamento¹² se enquadram como sequestradores de carbono (*carbon sink*). Porém, para que um projeto possa validar os créditos de carbono, este deve apresentar o princípio de adicionalidade. Tal princípio é definido como sendo a soma de carbono sequestrado superior à linha de base, que por sua vez representa a quantidade de carbono estocado antes da implementação do projeto

¹⁰ Basicamente representados pelos países industrializados e maiores emissores de GEE.

¹¹ Uma cópia do protocolo pode ser acessada no site: <http://mudancasclimaticas.cptec.inpe.br/~rmclima/pdfs/Protocolo_Quito.pdf>.

¹² Florestamento (*afforestation*) é o plantio de árvores em terras não florestadas por um período mínimo de 50 anos e reflorestamento (*reforestation*) é o plantio em terras não florestadas até 31 de Dezembro de 1989, segundo o MDL.

(YU, 2002). Estes procedimentos supracitados inviabilizariam quaisquer projetos aplicados às florestas naturais, perante esta modalidade do MDL.

Sendo assim, foi discutida pelas partes integrantes do UNFCCC a necessidade de valorar a “floresta em pé”, já que esta estaria deixando de liberar CO₂ para atmosfera, decorrente do desmatamento ou mudanças de uso da terra com a finalidade de serem alcançadas as metas de reduções de emissões pós PK por parte dos países pertencentes ao Anexo 1 (UNFCCC, 2008).

Segundo o relatório do Ministério da Ciência e Tecnologia (MCT), 75% das emissões de GEE no Brasil são provenientes de mudanças no uso da terra; destas, 90% correspondentes à conversão de florestas naturais em outros usos (MCT, 2004). Conforme o IPCC estima-se que cerca de 20 % das emissões globais de carbono são oriundas de desflorestamentos nos trópicos (PARKER et al. 2008). Destacando-se a importância das emissões de CO₂ oriundas de desflorestamentos no Brasil.

Assim, conforme Corte et al. (2012), na 11^a Conferência das Partes o termo REDD foi cunhado. Este se refere exclusivamente à Redução de Desmatamentos e Degradação Florestal, podendo ser alcançado mediante projetos, contratos e acordos através de um mercado voluntário bilateral entre países, comunidades ou indivíduos com o intuito de reduzir as emissões provenientes de desmatamento e degradação provenientes de florestas.

Diferentemente do MDL onde as negociações são realizadas no mercado aberto na bolsa de valores, no REDD e no REDD⁺ as negociações são realizadas mediante acordos bilaterais entre as partes interessadas (*stakeholders*) através do mercado de carbono voluntário (*voluntary carbono market*), caracterizados por doações, mercados informais e fundos de proteção ao meio ambiente (CORTE et al. 2012), onde destaca-se o indicador genérico OTC (*over the counter*) ou negociações livres de carbono, em tradução livre.

Porém, segundo Hett et al. (2011), até o presente momento reduções de emissões para mudanças no uso da terra e florestas não estão ainda bem determinadas como uma categoria perante o UNFCCC e o PK. Mas foram, contudo, formalmente incluídos no regime climático internacional pós 2012, através do

mecanismo proposto REDD⁺, que inclui o manejo sustentável da floresta e o estoque de carbono existente (COP16, 2010).

O fato de ainda estar em discussão a validade de projetos de “desmatamento evitado” é citado por Gibbs et al. (2007) por causa das preocupações sobre a diluição de responsabilidades sobre as reduções de combustíveis fósseis, soberania nacional e as metodologias de medição destas reduções. Conforme Cenamo et al. (2010) o grande desafio é harmonizar diferentes situações de desmatamento e conservação florestal, sem que isso gere incentivos perversos, ou seja, beneficiem locais com maiores taxas de desmatamento e não recompensem, por outro lado, locais que empreenderam esforços para conservar suas florestas.

Apesar das incertezas envolvidas ao REDD⁺, este se mostra como uma das iniciativas transnacionais mais promissoras em termos do controle de desmatamento e conservação da biodiversidade nos ecossistemas florestais, além de evitar a emissão de CO₂ para a atmosfera.

2 MATERIAIS E MÉTODOS

2.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de estudo compreende um fragmento de FOM, objeto do Programa de Pesquisas Ecológicas de Longa Duração (PELD) Sítio 9 – Floresta com Araucária e suas transições, localizado em São João do Triunfo, região centro-sul do estado do Paraná, a 125 km de Curitiba, com as coordenadas centrais 25°41'20''S e 50°09'45''W (Figura 5).

A área está inserida na Estação Experimental de São João do Triunfo (EESJT), de propriedade da Universidade Federal do Paraná (UFPR). O local tem cerca de 30 hectares de área de floresta natural e altitude média de 780 metros acima do nível médio do mar (DURIGAN, 1999).

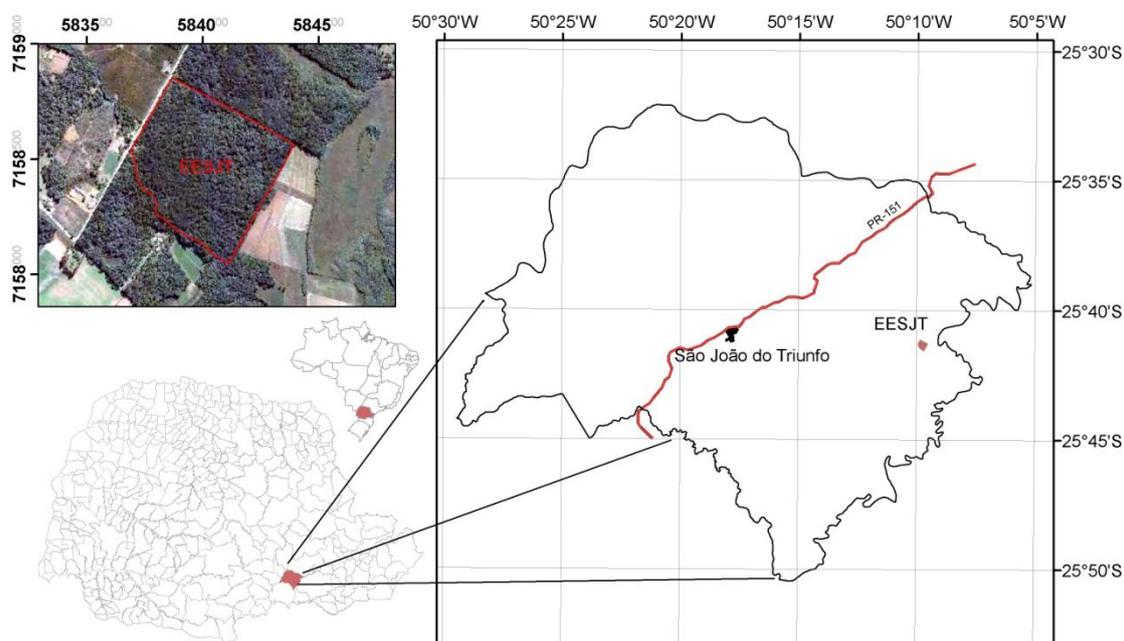


Figura 5 - Localização geográfica da Estação Experimental de São João do Triunfo. No detalhe, uma composição colorida natural da estação experimental.

2.1.1 Clima

Segundo a classificação climática de Köppen o clima é Cfb - clima temperado propriamente dito; temperatura média no mês mais frio abaixo de 18°C (mesotérmico), com verões frescos, temperatura média no mês mais quente abaixo de 22°C e sem estação seca definida (IAPAR, 2000).

2.1.2 Solos

O solo local foi classificado como tipo podzólico vermelho-amarelo distrófico, com uma pequena porção de solo do tipo cambissolo distrófico álico. Ambos possuem baixa saturação de bases (distróficos) e alta concentração de alumínio (álico), sendo, portanto, considerados solos com elevada acidez (LONGHI, 1980).

2.1.3 Vegetação

A vegetação é caracterizada como um fragmento de Floresta Ombrófila Mista Montana, em altitudes médias de 400 m até mais ou menos 1000 metros, segundo as adaptações de Velloso et al. (1991) para a classificação da vegetação brasileira (IBGE, 1992). Na Figura 6 se observa a inserção do município de São João do Triunfo nas diferentes regiões fitogeográficas do Estado do Paraná.

A composição florística deste tipo de formação vegetal tem como espécies predominantes o pinheiro-do-paraná (*Araucaria angustifolia* (Bert.) O. Ktze) e diversas espécies folhosas, como a imbuia (*Ocotea porosa* (Mez.) L. Barroso), a erva mate (*Ilex paraguariensis* St. Hil), o cedro (*Cedrela fissilis*), as canelas da família Lauraceae (*Nectandra* spp., *Ocotea* spp.), e membros da família Myrtaceae, entre outras (HUECK, 1972; ProBIO, 2007);

O pinheiro-do-paraná é a espécie dominante do estrato superior, podendo atingir 35 metros de altura e diâmetros superiores a um metro, cujos indivíduos são

facilmente distinguidos dos demais, quando adultos, por apresentarem copas umbeliformes¹³ e troncos retilíneos, livres de ramificações até uma altura correspondente a 2/3 do total (LAMPRECHT, 1990).

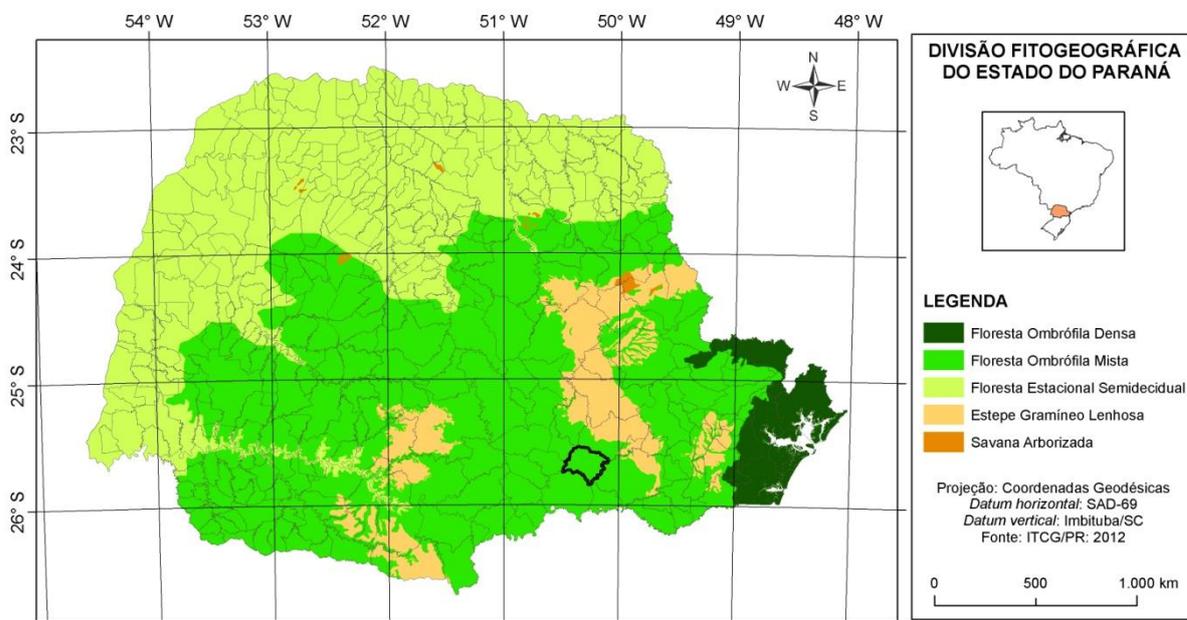


Figura 6 - Divisão Fitogeográfica do estado do Paraná.

Na FOM da área de estudo, Longhi (1980) havia encontrado 51 espécies, pertencentes a 36 gêneros e 26 famílias botânicas. Pizzato (1999), em 1995, observou 66 espécies, divididas em 47 gêneros e 30 famílias, enquanto Durigan (1999) encontrou, dois anos mais tarde, 69 espécies, divididas em 44 gêneros e 29 famílias. Neste trabalho foram observadas 83 espécies, pertencentes a 52 gêneros e 31 famílias botânicas. Nota-se claramente o aumento da diversidade florística ao longo de quase 35 anos de estudo no local.

Apesar de ter sofrido intervenções antrópicas no passado - a área sofreu exploração seletiva de Araucária e exploração de erva-mate até 1972, além de tratamentos silviculturais em alguns talhões e do registro de incêndio em 1982, nos talhões localizados próximos à estrada (SCHAAF, 2001) - a floresta ainda mantém a estrutura e composição florística típicas de florestas pouco alteradas (CÔRTE et al. 2007); a associação da araucária com a imbuia se constitui no estágio sucessional mais avançado de desenvolvimento da FOM (KLEIN, 1960; WEBER et al. 2005).

¹³ Umbeliforme é um tipo de copa com o formato de umbela (guarda-chuva). As araucárias apresentam copa com formato de guarda-chuva invertido quando adultas, facilitando a sua identificação.

Em todos os estudos na EESJT, a *Araucaria angustifolia* foi a espécie mais abundante e a que apresentou o maior índice de valor de cobertura (IVC) (LONGHI, 1980; PIZATTO, 1999; DURIGAN, 1999). Na Figura 7 observa-se a estrutura vertical típica da FOM com a predominância da *Araucaria angustifolia* no estrato superior.



Figura 7 - Estrutura vertical da Floresta Ombrófila Mista da Estação Experimental de São João do Triunfo vista de cima da torre micrometeorológica. Observa-se no primeiro plano a copa umbeliforme de uma *Araucaria angustifolia* dominando o estrato superior da floresta. Fonte: Autor.

2.2 DADOS DE CAMPO

Os dados de campo são provenientes de parcelas permanentes PELD *Site 9: Araucária*, localizadas na EESJT. Este programa está vinculado ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq) e tem como objetivo a realização de pesquisas que visem à conservação e ao monitoramento dos principais ecossistemas brasileiros.

O PELD do sítio Araucária foi iniciado em 1999 (MOGNON, 2011), embora as parcelas permanentes tenham sido implementadas em São João do Triunfo um

pouco antes, em 1995, a título de um projeto de longo prazo coordenado pelo Prof. Dr. Carlos Roberto Sanquetta (PIZATTO, 1999).

As parcelas permanentes, quadráticas, de um hectare de área, estão distribuídas em quatro lugares distintos da estação experimental, englobando diferentes sítios ambientais e são comumente conhecidas como: parcela Imbuia, parcela Araucária, parcela Fogo e parcela Rio. Apenas a parcela Rio possui 0,5 hectares, pois é cortada pelo Rio do Bromado (Figura 8).

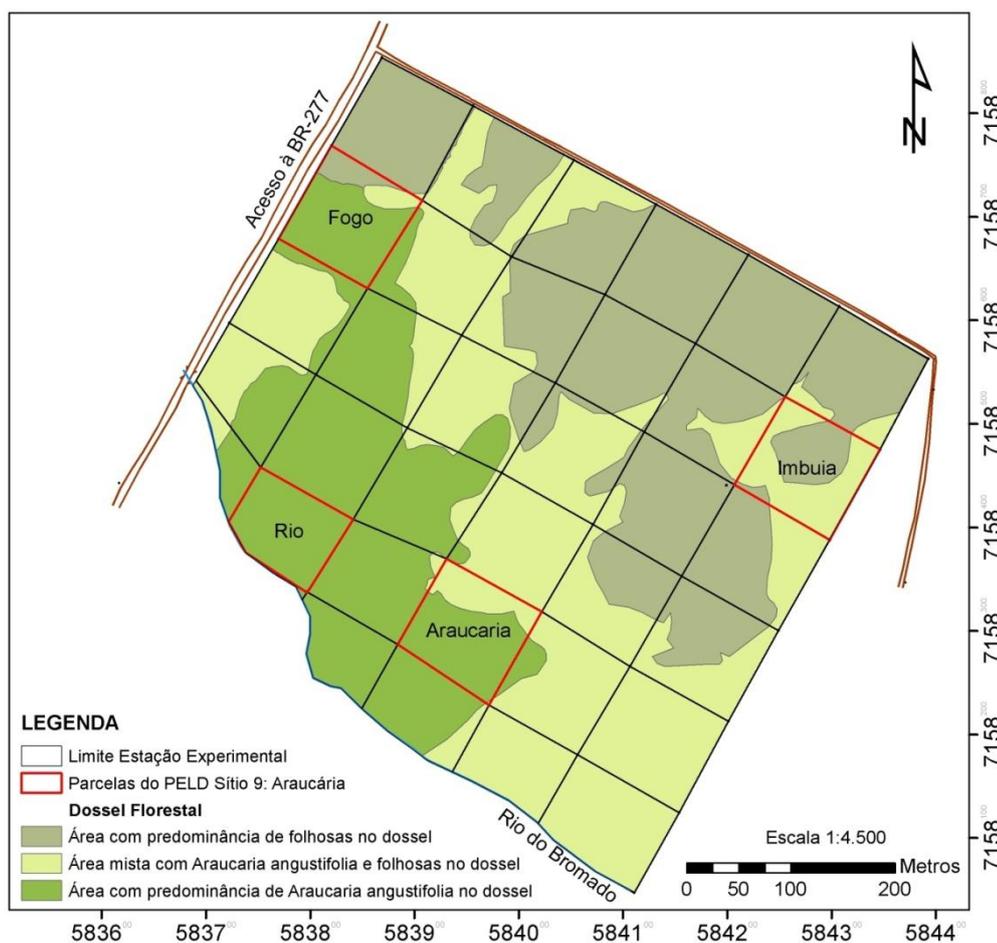


Figura 8 - Mapa da localização das parcelas permanentes em função dos diferentes dosséis florestais predominantes.

As parcelas Imbuia e Araucária possuem esta denominação por conterem na sua composição florística a predominância das espécies *Ocotea porosa* e *Araucaria angustifolia*, respectivamente, no dossel florestal. A parcela Fogo está localizada em uma área com registro de incêndio em 1982, enquanto a parcela Rio está localizada próxima ao Rio do Bromado, limite da EESJT. Estas características influenciam na composição e diversidade das espécies, assim como, nos valores de biomassa e

carbono florestal observados em cada parcela. As parcelas permanentes do PELD estão georreferenciadas e numeradas conforme a Figura 8 abaixo, em formato *shapefile*.

2.2.1 Inventário Florestal

O inventário florestal contínuo é realizado, durante o período de julho a agosto, a título do PELD, em todas as árvores cujas circunferências à altura do peito (CAP) sejam superiores a 30 cm. Todas as árvores são mapeadas e identificadas por seu respectivo número de placa, além de catalogadas por espécie e família botânica. Os pontos das árvores são salvos em formato *shapefile* e as informações contidas nos pontos, como nome e espécie, número de placa e DAP são registradas na tabela de atributos do respectivo *shapefile*.

2.2.2 Estimação das Alturas

As alturas das árvores foram estimadas com base nas equações hipsométricas ajustadas por Pizatto, (1999) para a área de estudo, a partir das CAPs obtidas em campo, o qual separou as espécies folhosas das araucárias em duas equações logarítmicas distintas, denominadas (Equação 4 e Equação 5):

$$h = -2,231 + 4,75 * \ln \text{DAP}; \quad R^2_{aj.} = 0,7 \quad (4)$$

Equação 4 - Equação hipsométrica ajustada para a *Araucaria angustifolia*.

$$h = -21,284 + 10,951 * \ln \text{DAP}; \quad R^2_{aj.} = 0,64 \quad (5)$$

Equação 5 - Equação hipsométrica ajustada para as folhosas.

Onde h é a altura, em metros, e DAP, o diâmetro à altura do peito a 1,3 m, em centímetros, em que $\text{DAP} = \text{CAP}/\pi$.

Estas equações hipsométricas foram utilizadas para se estimar as alturas de todas as árvores pertencentes às parcelas permanentes.

2.2.3 Estimativa de Biomassa Florestal

A Biomassa Florestal foi estimada por meio da equação ajustada por Ratuchne (2010), a partir da base de dados do trabalho desenvolvido por Luciano Farinha Watzlawick, em 2003. Watzlawick (2003), em seu trabalho, determinou a biomassa florestal de uma Floresta Ombrófila Mista Montana selecionando 20 Unidades de Amostra e pesando os diferentes componentes do ecossistema florestal. Assim, separou-os em biomassa arbórea (fuste, casca e galhos), biomassa arbustiva (sub-bosque), biomassa morta (serapilheira) e biomassa subterrânea (raízes). Além disso, as medidas dendrométricas como a altura total, altura do ponto de inversão morfológica e CAP foram feitas nos 156 indivíduos catalogados.

Com base no banco de dados desenvolvido por Watzlawick (2003), Ratuchne (2010) testou uma série de equações alométricas para estimativa de biomassa florestal acima do solo. Mognon (2011), por sua vez, aplicou estas equações alométricas testadas por Ratuchne (2010) em Parcelas Permanentes do PELD da Floresta Ombrófila Mista Montana. Assim, a equação encontrada por Mognon (2011), que melhor se ajustou aos dados, apresentando alto coeficiente de determinação ($R^2_{aj} = 0,995$) e aceitável erro-padrão relativo ($Sy_x = 47,24\%$) foi a seguinte equação alométrica (Equação 6):

$$P = -3,025 \times DAP + 0,425 \times DAP^2 + 0,006 \times (DAP^2 \times h) \quad (6)$$

Equação 6 - Equação alométrica ajustada para a Floresta Ombrófila Mista.

Onde P é a biomassa florestal seca acima do solo, em kg; DAP o diâmetro a 1,3 m, em centímetros e h a altura, em metros. A equação alométrica descrita foi usada para se estimar a biomassa florestal acima do solo de cada uma das árvores, a partir dos diâmetros medidos e das alturas estimadas.

2.2.4 Estimativa de Carbono Florestal

Os teores de carbono (TC) foram definidos por espécie e grupos de espécies, estabelecidos com base nos dados observados por Watzlawick et al. (2004). Neste

trabalho citado foram determinados os percentuais dos TC de 91 indivíduos, pertencentes a 39 espécies arbóreas e 21 famílias botânicas, de uma Floresta Ombrófila Mista Montana, localizada em General Carneiro, estado do Paraná.

Das 39 espécies catalogadas para se estimar os teores de carbono da FOM Montana, 35 espécies são pertencentes à FOM do presente estudo. Estes teores de carbono, por espécie, foram utilizados para se estimar a quantidade de C presente na porção arbórea da floresta. O TC médio de $408,33 \text{ g.kg}^{-1}$ foi utilizado para se estimar o C das espécies pertencentes à EESJT, que não foram contempladas no trabalho de Watzlawick et al. (2004).

Os dados estimados de biomassa e carbono florestal foram inseridos na tabela de atributos do arquivo *shapefile* contendo as árvores das parcelas permanentes. Estes dados serviram como referência de campo sobre a biomassa e o carbono florestal, usados como variáveis dependentes na geração de equações de regressão, conforme será explicado a seguir.

2.3 DADOS ÓPTICOS DE SENSORIAMENTO REMOTO

Três sistemas sensores que operam na faixa do espectro EM do visível e infravermelho próximo foram utilizados no processamento dos dados. Estes sistemas sensores são o ASTER, o TM e o LiSS III, os quais serão brevemente descritos.

2.3.1 Sensor ASTER

O sensor *Advanced Spaceborne Thermal Emission and Reflection Radiometer* (ASTER) a bordo do satélite *Terra* (EOS AM-1), é um instrumento de pesquisa de cooperação entre a *National Aeronautics and Space Administration* (NASA) e o Ministério de Comércio Internacional e Indústria do Japão (ASTER, 2012).

O ASTER é um sensor multiespectral de alta resolução espacial com três subsistemas operando em diferentes regiões espectrais denominadas: visível (VIS), infravermelho próximo (IVP), infravermelho de ondas curtas (SWIR) e infravermelho termal (TIR) (YAMAGUCHI et al. 1998). Com estes equipamentos, o ASTER obtém informações detalhadas sobre a temperatura de superfície, emissividade, reflectância e elevação (JENSEN, 2009).

Apesar de o sensor ASTER ser semelhante ao do sensor TM em suas características, este foi concebido para fornecer uma melhor resolução espectral na região do SWIR em comparação àquele, fazendo com que esta região domine a maior parte de suas aplicações. Aplicações do sensor ASTER em áreas florestais são escassas na literatura, justificando-se o uso deste sensor para esta finalidade (MUUKKONEN e HEISKANEN, 2005). Uma cena ASTER VIS-IVP cobre uma superfície de 60 x 60 km de área e tem 15 metros de resolução espacial na região do visível e infravermelho próximo.

Segundo Fujisada (1998), o instrumento ASTER tem dois níveis de dados, o nível 1A e o nível 1B. Os dados do nível 1A são formalmente definidos como reconstruídos, instrumento de dados não processados na resolução máxima. De acordo com esta definição, o dado ASTER 1A consiste de uma imagem sem aplicação de coeficientes radiométricos, geométricos e outros dados auxiliares, mantendo assim seus valores originais. Os dados de nível 1B são gerados pela aplicação dos coeficientes radiométricos e geométricos.

2.3.2 Sensor LiSS III

O sensor *Linear Imaging Self-scanning Sensor*, terceira versão (LiSS III), é um instrumento do tipo *Charge Couple Device* (CCD), que usa tecnologia de arranjo linear para o registro das imagens.

O sensor LiSS III foi desenvolvido em duas versões: a primeira a bordo dos satélites *Indian Remote Sensing Satellite* IRS-1C e IRS-1D, operando em quatro bandas espectrais e oferecendo resoluções espaciais diferenciadas, variando de 23,5 a 180 metros; a segunda versão do LiSS III foi lançada a bordo do satélite IRS-

P6, em que as principais mudanças foram na resolução espacial, que passou a ser de 23,5 metros em todas as bandas espectrais.

A faixa de imageamento do LiSS III é de 141 km para as bandas 2, 3 e 4 e de 148 km para a banda do SWIR. As bandas do sensor LiSS III são praticamente idênticas às do TM, a bordo do Landsat 5 (JENSEN, 2009). Imagens deste sensor têm sido utilizadas para substituir as imagens do sensor TM no Projeto de Monitoramento do Desflorestamento na Amazônia Legal (PRODES) do Instituto Nacional de Pesquisas Espaciais (INPE) e estão sendo disponibilizadas gratuitamente pelo INPE desde setembro de 2009.

2.3.3 Sensor TM

O Sensor *Thematic Mapper* (TM) é um instrumento óptico mecânico do tipo “whiskbroom”, a bordo dos satélites Landsat 4 e 5, que registra a energia eletromagnética refletida da região do visível, infravermelho próximo e médio do espectro EM, além da região emitida do termal (JENSEN, 2009). Uma cena do sensor TM cobre uma superfície de 185 x 170 km de área.

As bandas do sensor Landsat - originalmente designado como satélite para o estudo dos usos da Terra - foram desenvolvidas para maximizar o uso dos fatores que controlam a reflectância da vegetação, assim como os fatores dominantes na identificação de alteração hidrotermal de certos tipos de rochas e na discriminação de alvos da superfície terrestre (JENSEN, 2009).

A série Landsat foi o programa espacial com a mais longa duração dentre os programas espaciais desenvolvidos com a finalidade de monitorar os usos e mudanças de uso da terra continuamente, a partir de imagens de satélite. Em novembro de 2011, o Instituto de Pesquisa Geológica dos EUA (USGS) parou de adquirir imagens TM do satélite Landsat 5, após 27 anos de observação da Terra, devido a uma rápida degradação de um componente eletrônico, conforme comunicado pela NASA, (2013). A nova série Landsat passará a se chamar de *Landsat Data Continuity Mission* (LDCM) e tem o objetivo de dar continuidade ao programa de longa data desempenhado pelas séries antecedentes (NASA, 2013).

Conforme a própria Agência, o LDCM foi lançado com sucesso em 11 de fevereiro de 2013 e se encontra em órbita terrestre – até o momento da finalização desta dissertação não se teve notícia acerca do registro das primeiras imagens pelo sensor.

A comparação entre sensores e índices de vegetação só foi possível devido à semelhança entre as bandas dos sensores (Tabela 2). Todavia, a resolução espacial é diferente nos três sensores (15m – ASTER; 30m – TM; 23,5m – LiSS III), assim como, a resolução radiométrica (8 bits – ASTER e TM e 7 bits – LiSS III).

Tabela 2 - Características do Sensor ASTER, LiSS III e TM.

Sensor	Banda	Resolução			Temporal	Data de Aquisição
		Espectral (μm)	Espacial (m)	Radiométrica		
ASTER	1	0,52 - 0,60	15	8 bits	16 dias	02/11/2010
	2	0,63 - 0,69				
	3N	0,78 - 0,86				
	3B	0,78 - 0,86				
LiSS III	2	0,52 – 0,59	23,5	7 bits	24 dias	02/09/2010
	3	0,62 – 0,68				
	4	0,77 – 0,86				
TM	1	0,45 - 0,52	30	8 bits	16 dias	28/10/2011
	2	0,52 - 0,60				
	3	0,63 - 0,69				
	4	0,76 - 0,90				

Fonte: ASTER (YAMAGUCHI et al. 1998), LiSS III (JENSEN, 2009) e TM (JENSEN, 2009).

Uma cena de cada sensor foi adquirida e os critérios de seleção das cenas foram a baixa incidência de nuvens e a coincidência de datas entre a data de aquisição das imagens e a data de realização do inventário florestal. Dessa forma, as cenas ASTER e LiSS III foram adquiridas em novembro e setembro de 2010, respectivamente, enquanto a cena TM, em outubro de 2011.

Devido à alta incidência de nuvens no ano de 2010, durante os meses próximos à realização do inventário, só foi possível usar uma cena do sensor TM no ano de 2011. Logo, os dados utilizados de biomassa e carbono florestal foram correspondentes ao ano de aquisição das imagens, ano de 2010 para o ASTER e LiSS III e 2011 para o TM. Nas três cenas adquiridas, foram realizados os seguintes processamentos digitais: transformação radiométrica dos dados, correção atmosférica, geração de índices de vegetação e georreferenciamento. Estas etapas metodológicas se encontram no fluxograma da Figura 9.

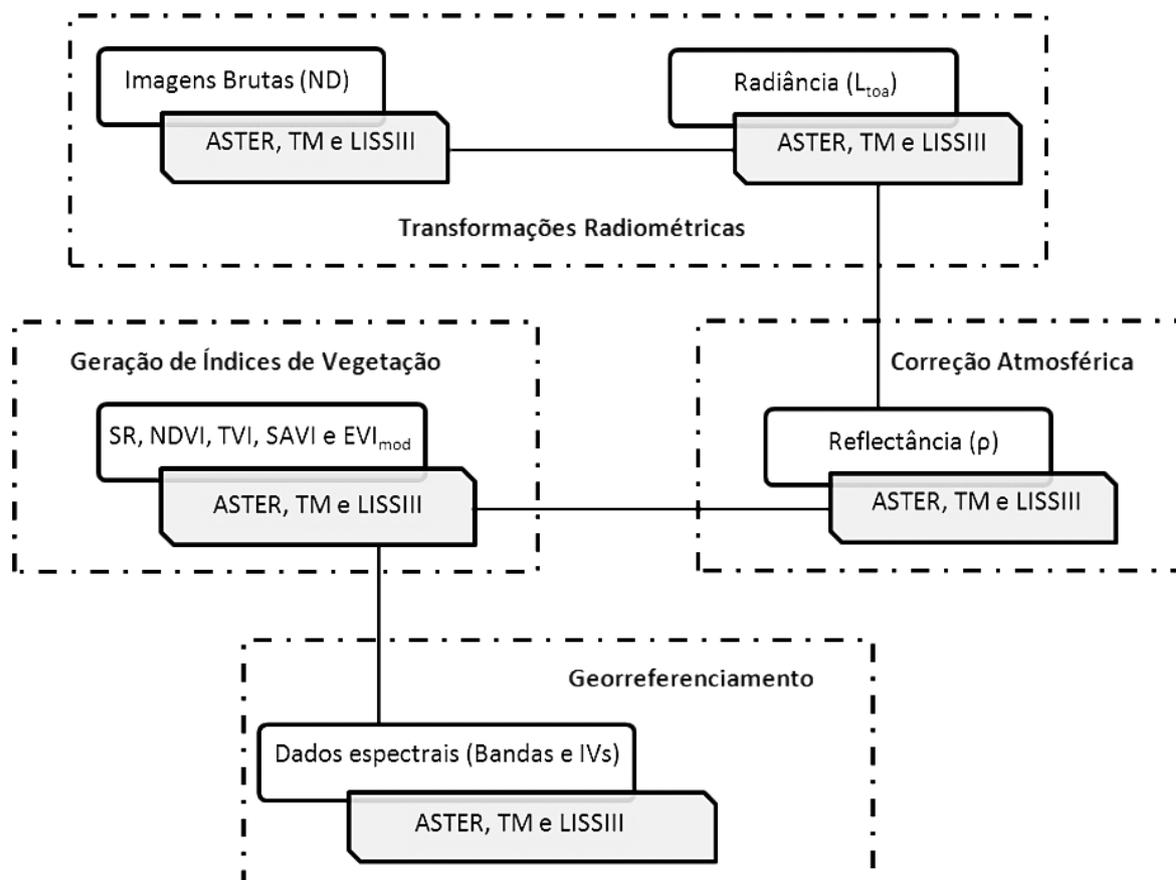


Figura 9 - Fluxograma do processamento digital das imagens ASTER, TM e LISS III.

2.3.4 Transformação Radiométrica dos dados

O sensor a bordo do satélite registra a intensidade de REM (radiância) propagada da Terra até o sensor e forma uma imagem da superfície sob este aspecto físico (SLATER, 1980). Cada detector integra este fluxo de energia que deixa a superfície (irradiância) para formar a medida de cada pixel.

Schowengerdt (2007) destaca que a irradiância integrada em cada pixel é convertida em um sinal elétrico e quantizada com um valor inteiro, o número digital (ND) e estes são, então, codificados em um alcance de um número finito de bits, que é dependente da resolução radiométrica do sensor.

Porém, Ponzoni e Shimabukuro (2009) destacam que esta conversão não é igual para cada uma das bandas do sensor, mas é função dos valores máximo e mínimo de radiância de cada um destes detectores (calibração pré-lançamento),

específicos em cada um dos comprimentos de onda ou bandas (CHANDER et al. 2009).

Assim, quando a finalidade é se trabalhar com informações quantitativas oriundas de dados de sensoriamento remoto, torna-se necessária a transformação radiométrica, que consiste na conversão dos ND em radiância aparente ou radiância no topo da atmosfera (MARKHAM e BARKER, 1986).

2.3.4.1 Transformação Radiométrica dos dados ASTER

Os dados dos ND, nível 1A, não processados, foram convertidos para Radiância no Topo da Atmosfera (L_{toa}) pela Equação 7 (ABRAMS, HOOK e RAMACHANDRAN, *guia do usuário*, s.d.)¹⁴:

$$L_{toa} \frac{W}{m^2} \cdot sr \cdot \mu m = (ND - 1) \times \text{Coeficiente de Conversão} \quad (7)$$

Equação 7 - Equação para transformação de ND para radiância no topo da atmosfera dos dados ASTER.

Onde ND é o número digital e o coeficiente de conversão é o ganho de Radiância para cada uma das bandas. Estes coeficientes são encontrados nos metadados da imagem e foram de 0,676; 0,708 e 0,862 W/m².sr.μm, para as bandas ASTER 1, 2 e 3N, respectivamente.

2.3.4.2 Transformação Radiométrica dos dados TM

Os dados dos ND da imagem TM foram transformados para Radiância no Topo da Atmosfera com base na Equação 8 (PONZONI e SHIMABUKURO, 2009):

$$L_{toa} \frac{W}{m^2} \cdot sr \cdot \mu m = L_{min} \lambda + \frac{L_{max} \lambda - L_{min} \lambda}{2^n} \times ND (\lambda) \quad (8)$$

Equação 8 - Equação para transformação de ND para radiância no topo da atmosfera dos dados TM.

Onde ND é o número digital da respectiva banda, n é o número de bits (resolução radiométrica) e L_{min} e L_{max} são os valores de calibração de radiância mínimo e máximo, respectivamente, em cada uma das bandas. Os parâmetros L_{min} e

¹⁴ ABRAMS, M.; HOOK, S.; RAMACHANDRAN B. ASTER User Handbook. 2 ed. 135f. Disponível em: http://asterweb.jpl.nasa.gov/content/03_data/04_Documents/aster_user_guide_v2.pdf. Acesso em: 05/07/2011.

L_{max} de para a transformação radiométrica dos dados TM estão descritos na Tabela 3:

Tabela 3 - Parâmetros de transformação radiométrica do sensor TM.

Banda	Intervalo espectral (μm)	Comprimento de onda central (μm)	Largura da banda (μm)	$L_{min\lambda}$ ($\text{W}/\text{m}^2\text{sr } \mu\text{m}$)	$L_{max\lambda}$ ($\text{W}/\text{m}^2\text{sr } \mu\text{m}$)
1	0,45 - 0,52	0,485	0,066	-1,52	193,00
2	0,52 - 0,60	0,569	0,082	-2,84	365,00
3	0,63 - 0,69	0,659	0,067	-1,17	204,30
4	0,76 - 0,90	0,841	0,123	-1,51	206,20
5	1,55 - 1,75	1,676	0,217	-0,37	27,19
7	2,08 - 2,35	2,222	0,252	-0,15	14,38

Fonte: Chander et al. (2009).

2.3.4.3 Transformação Radiométrica dos dados LiSS III

Os dados dos ND do sensor LISSIII foram convertidos para Radiância no topo da atmosfera conforme a Equação 8 da seção anterior. Os parâmetros de calibração do sensor LISSIII, usados no cálculo de conversão, estão listados na Tabela 4.

Tabela 4 – Parâmetros de transformação de transformação do sensor LiSS III.

Banda	Intervalo espectral (μm)	Comprimento de onda central (μm)	Largura da banda (μm)	$L_{min\lambda}$ ($\text{W}/\text{m}^2\text{sr } \mu\text{m}$)	$L_{max\lambda}$ ($\text{W}/\text{m}^2\text{sr } \mu\text{m}$)
2	0,52 - 0,59	0,56114	0,07186	0	120,64
3	0,62 - 0,68	0,65477	0,06574	0	151,31
4	0,77 - 0,86	0,81702	0,09030	0	157,57
5	1,55 - 1,70	1,62908	0,13762	0	69,03

Fonte: Chander et al. (2008) e Pandya et al. (2007).

Apesar de a radiância ser um fenômeno físico explicado pela intensidade da reflexão da REM dos distintos alvos na superfície, esta não é a variável física apropriada para a caracterização espectral dos alvos na superfície terrestre, porque é dependente da intensidade de irradiância da fonte (Sol), em determinado comprimento de onda, e da geometria de aquisição da imagem (sensor), que envolve o ângulo solar zenital e a distância do Sol-Terra – ambos os fatores são influenciados pela época do ano de aquisição dos dados (PONZONI e SHIMABUKURO, 2009).

Em virtude disto, os valores de radiância no topo da atmosfera devem ser transformados para fator de reflectância bidirecional aparente (FRB) em cada uma das bandas e para os três sistemas sensores segundo a Equação 9:

$$\rho_a = \frac{\pi \cdot L_{toa} \lambda \cdot d^2}{E_{sun} \lambda \cdot \cos\theta} \quad (9)$$

Equação 9 - Cálculo para a conversão de radiância para FRB.

Onde ρ_a é o FRB aparente, $L_{toa} \lambda$ é a radiância no topo da atmosfera, em $\text{mW cm}^{-2} \times \text{sr}^{-1}$, calculadas anteriormente, em cada comprimento de onda, d é a distância Sol-Terra em unidades astronômicas, $E_{sun} \lambda$ é a irradiância solar média no topo da atmosfera, em determinado comprimento de onda, e θ é o ângulo solar zenital.

Após a transformação radiométrica das cenas para FRB é possível realizar operações aritméticas, utilizando-se de dados de diferentes bandas espectrais de um mesmo sensor ou entre sensores diferentes, haja vista que os ND foram convertidos em um parâmetro físico apresentado em uma mesma escala (PONZONI e SHIMABUKURO, 2009).

Entretanto, intrínsecos ao valor da FRB aparente há o efeito da atmosfera sobre os valores registrados pelos sensores, que é distinto para cada data de aquisição, sendo necessário corrigir o efeito atmosférico sobre os valores da FRB aparente (SONG et al. 2001).

2.3.5 Correção atmosférica

A correção atmosférica consiste na minimização da contribuição do espalhamento e absorção da REM sobre os valores do FRB registrados pelo sensor. Quando os efeitos atmosféricos são corrigidos da imagem, têm-se o FRB de superfície (BRDF) ou simplesmente reflectância (σ), termo este usado aqui para facilitar a compreensão.

As imagens foram então convertidas para valores de reflectância em cada uma das bandas e sensores, a partir do modelo de redução atmosférica por transferência radiativa *Moderate spectral resolution atmospheric transmittance algorithm* (MODTRAN4) (Adler-Goldman et al. 1999) implementado na rotina *Fast Line-of-sight Atmospheric Analysis of Spectral Hypercubes* (FLAASH) do software ENVI 4.5®.

Este modelo de redução do efeito atmosférico possibilita que se insiram diferentes dados de entrada, relacionados à caracterização da atmosfera na época de aquisição dos dados, tais como as concentrações de vapor d'água, profundidade óptica, modelos atmosféricos (p. ex. média latitude, tropical subártico), modelos de aerossol (p. ex. rural, urbano, marítimo), assim como, aqueles referentes ao sensor (resolução espacial) e ao satélite (altura da órbita, data de aquisição da cena, altitude do terreno e localização geográfica da cena) no modelo.

Todos estes dados de entrada alimentam o modelo de redução atmosférica do tipo *blackbox* (caixa-preta) implementado no software ENVI, em que os valores de reflectância são gerados a partir da imagem radiância aparente (FRB aparente), segundo a Equação 9, descrita na seção anterior. Como todas as cenas foram geradas livres de nuvens, os dados de entrada para os parâmetros atmosféricos foram os mesmos: visibilidade de 40 km (céu limpo), tipo de aerossol rural e modelo atmosférico de Meia Latitude no Verão (MLS); mudando apenas os dados de entrada referentes ao sensor e ao satélite, segundo as características de cada um deles.

2.3.6 Índices de vegetação

Os índices de vegetação foram estabelecidos com base nas imagens de reflectância de cada uma das bandas e sensores. Os IVs utilizados estão listados na Tabela 5.

Tabela 5 - Índices de Vegetação utilizados no estudo, $\rho_{\text{Verm.}}$, ρ_{Verde} , ρ_{Azul} e ρ_{IVP} são as reflectâncias na região do vermelho, verde, azul e infravermelho próximo do espectro EM, respectivamente.

Índice Vegetação	Fórmula	Referência
SR - Razão Simples	$\rho_{\text{IVP}} / \rho_{\text{Verm.}}$	Birth e McVey (1968)
NDVI – Diferença Normalizada	$(\rho_{\text{IVP}} - \rho_{\text{Verm.}}) / (\rho_{\text{IVP}} + \rho_{\text{Verm.}})$	Rouse et al. (1974)
TVI - Triangular	$(0,5 (120(\rho_{\text{IVP}} - \rho_{\text{Verde}}))) - 200(\rho_{\text{Verm.}} - \rho_{\text{Verde}})$	Broge e Leblanc (2000)
SAVI - Ajustado ao Solo	$((1+L)(\rho_{\text{IVP}} - \sigma_{\text{Verm.}})) / (\rho_{\text{IVP}} + \rho_{\text{Verm.}} + L)$, onde $L = 0,5$	Huete (1998)
EVI - Realçado modificado	$G((\rho_{\text{IVP}} - \rho_{\text{Verm.}}) / (\rho_{\text{IVP}} + C1 \rho_{\text{Verm.}} + \rho_{\text{Azul}} C2 + L))(1+L)$, onde G, C1, C2 e L têm valores empíricos de 2,5; 6; 7,5 e 1, respectivamente.	Huete et al. (2002)

Nota: A banda de reflectância referente ao comprimento de onda do azul do espectro EM foi substituída pela banda do verde, nos três sensores.

2.3.7 Georreferenciamento das imagens

As imagens “reflectância” foram exportadas para o ArcGIS 9.2, onde foram georreferenciadas no mesmo sistema de referência SAD-69 e projeção Universal Transversa de Mercator (UTM), fuso 22s, dos arquivos *shapefile*, contendo os pontos das árvores e os polígonos das parcelas permanentes do PELD.

Esta etapa metodológica é de suma importância, porque os dados de campo devem se ajustar o mais perfeitamente possível aos dados registrados pelos sensores, sendo fundamental um georreferenciamento preciso dos dados (CASSOL, SALDANHA e KUPILICH, 2012).

McCoy (2006) cita esse “ajustamento” nos dados, provenientes de fontes de dados diferentes, como um co-registro de informações, pois, uma base de dados (imagens reflectância) é registrada a outra base de dados pré-existent (shapefile do polígono da EESJT). O croqui da etapa de co-registro de informações pode ser visualizado na Figura 10, em que a dimensão do pixel da cena representa uma Unidade Amostral (UA).

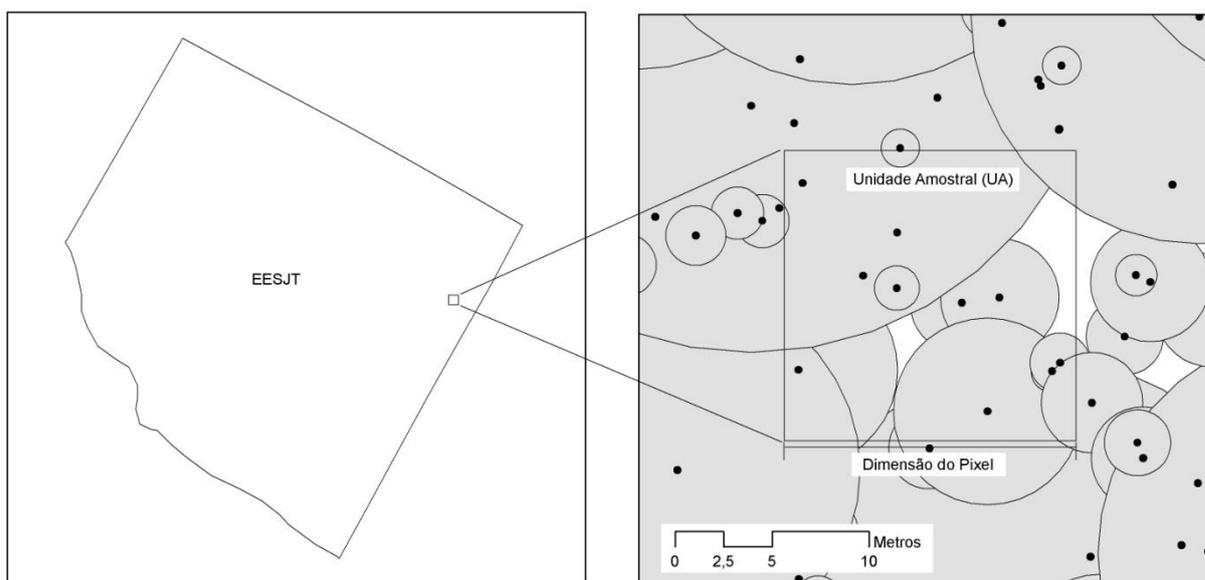


Figura 10 - Croqui metodológico do co-registro. À direita, os pontos representam as árvores contidas na UA e os círculos a projeção das copas.

Embora a precisão no georreferenciamento tenha sido aumentada nos últimos anos, ainda é difícil de certificar-se se a localização das parcelas de campo está

precisamente amarrada à coordenada de um pixel particular na imagem (MCCOY, 2006), especialmente se o pixel possui baixa resolução espacial. Aqui, têm-se os erros de posicionamento das árvores (não controlados) e os erros inerentes do georreferenciamento das cenas atuando no resultado da análise.

Apesar disso, o resultado do co-registro foi considerado satisfatório para as três imagens, com valores de Raiz do Erro Médio Quadrático (RMSE) oscilando em torno de um pixel. O método de reamostragem foi o do vizinho mais próximo, aplicado às variáveis discretas.

2.3.8 Ampliação da Escala (*Up-scaling*)

A baixa correlação entre as variáveis biofísicas e espectrais pode estar associada à escala de observação e não somente a inexistência de covariância entre as variáveis, uma vez que a variabilidade dos dados observada em uma escala não é a mesma da observada em outra escala (CURRAN e ATKINSON, 1999). A ideia por trás disso é que com o aumento da escala (*up-scaling*¹⁵) ou agregação de dados espaciais, a variância dos valores de biomassa e carbono tende a diminuir, aproximando-se da variância dos dados espectrais (CASSOL, SALDANHA e KUPLICH, 2012).

Bian e Butler (1999) citam que imagens com alta resolução espacial precisam ser agregadas para que a representação das características espaciais (padrão, correlação, etc.) seja correspondente à escala de observação¹⁶ da variável estudada. Porém, a escala de observação adequada nem sempre é intuitiva, mas sim função do comportamento espacial da variável, i.e., da continuidade espacial do fenômeno (COLLINS e WOODCOCK, 1999). Na literatura, este problema é conhecido como *Modifiable Areal Unit Problem* – MAUP (CURRAN e ATKINSON, 1999) ou problema da unidade de área modificável.

¹⁵ *Up-scaling* ou *aggregation* é o processo de combinar dados de alta resolução dentro de alguns pixels. Este processo pode envolver a redução da resolução espacial ou temporal. Também chamado de degradação espacial (JONES e VAUGHAN, 2010).

¹⁶ A definição de escala de observação é análoga à da resolução espacial (WOODCOK e STRAHLER, 1987).

Segundo Curran e Williamson (1986), o uso de unidades amostrais com pequenas dimensões para caracterizar a complexidade espacial de um sítio florestal é a principal fonte de erro em investigações por meio do uso de dados de sensoriamento remoto e comumente um equívoco primordial por parte dos pesquisadores da área.

Yule (1950) citado por Curran e Atkinson (1999) deu uma importante contribuição em relação a isto ao estudar o grau de relação entre a escala de observação e o coeficiente de correlação observado entre campos de trigo e batata, em 48 municípios agrícolas da Inglaterra. O coeficiente de correlação entre os campos de 0,22 passou para 0,55 e, então, para 0,99 quando os municípios foram agregados em 12 e depois 3 unidades semelhantes (efeito da escala). Assim, constatou-se que o MAUP das ciências agrárias se assemelha com o efeito da dimensão do pixel sobre as correlações entre os dados de sensoriamento remoto e os dados de campo (CURRAN e ATKINSON, 1999).

Além de diminuir a variância dos dados, a degradação da resolução espacial consiste em diminuir a contribuição do erro de registro da imagem e da alocação das parcelas (HEISKANEN, 2006), bem como, em diminuir a influência do efeito de heterogeneidade espacial local, ou seja, a variabilidade não explicada pelo fenômeno físico (CASSOL, SALDANHA e KUPLICH, 2012). Esta pressuposição tem semelhança ao efeito pepita, empregado pela ciência geoestatística, que mede o tanto de variação que não é espacial (GOODIN e HENEERY, 2002).

Dessa forma, a dimensão do pixel da imagem ASTER de 15m foi degradada para duas resoluções espaciais menores, 30m e 45m, agregando 2x2 e 3x3 pixels, respectivamente (Figura 11). O processamento foi efetuado no software ENVI 4.5[®], por meio da ferramenta *Resize data >> Set output Dims by Pixel Size*, “setando” as diferentes resoluções espaciais supracitadas, como saídas. O método de reamostragem foi o bilinear, pois este se utiliza da média dos quatro pixels vizinhos mais próximos para formar o valor do pixel de saída (SCHOWENGARDT, 2007) ou simplesmente tomando-se o valor médio dos pixels (BIAN e BUTLER 1999). Estas novas dimensões ou resoluções espaciais foram usadas para avaliar as correlações entre as variáveis biofísicas e espectrais nas diferentes escalas de observação.

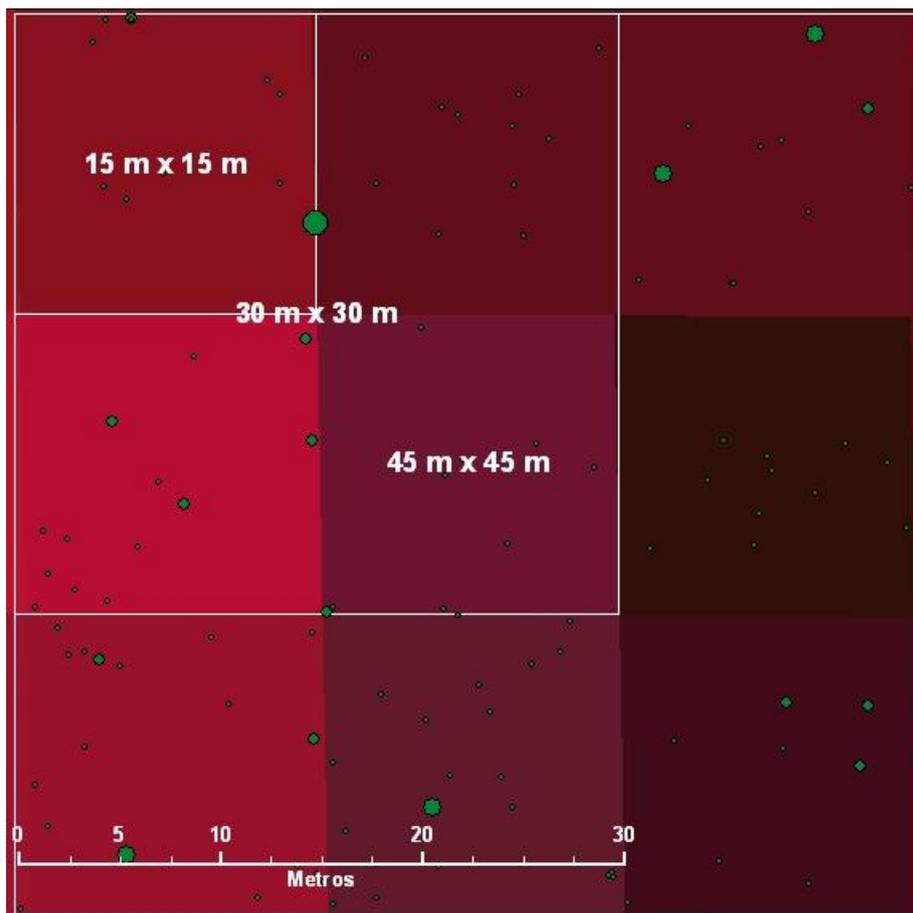


Figura 11 - Representação esquemática do aumento de escala (*up-scaling*), em que a resolução espacial original de 15m do sensor ASTER foi degradada para duas resoluções espaciais menores, 30m e 45m. Os pontos na imagem representam as árvores contidas dentro de um pixel de resolução, usados para formar as UA.

A biomassa e o carbono florestal contidos na área correspondente à dimensão do pixel foram somados e exportados para a planilha eletrônica do Excel[®] e para o software estatístico SPSS 13.0[®], onde se efetuaram os tratamentos estatísticos e as análises de regressões.

A metodologia do trabalho está resumida no fluxograma da Figura 12, cujas etapas foram divididas em três fases metodológicas distintas e complementares, que foram: as correlações entre as variáveis biofísicas e espectrais, a validação dos modelos de regressão e o resultado das estimativas.

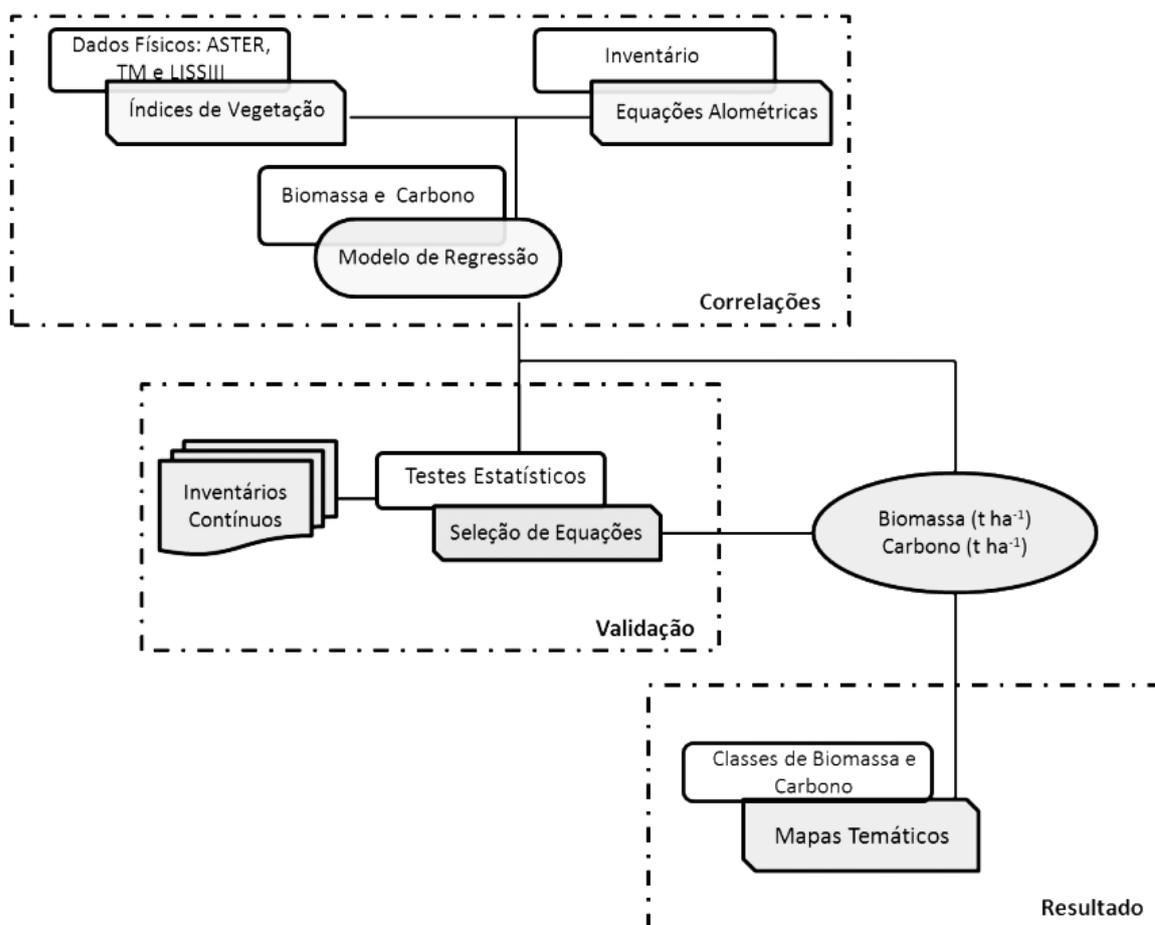


Figura 12 – Fluxograma da metodologia empregada.

2.4 TRATAMENTO ESTATÍSTICO E ANÁLISE DE REGRESSÃO

2.4.1 Análise de correlação

O tratamento estatístico inicial foi o desenvolvimento da análise de correlação entre os dados biofísicos e os dados espectrais. O grau de dependência entre variáveis pode ser facilmente visualizado pelo diagrama de dispersão entre os pontos coletados nas UA; alta dependência entre variáveis significa que o aumento nos valores de uma variável está associado ao aumento proporcional nos valores da outra variável. Esta se constitui na primeira etapa da análise de correlação (HO, 2006).

A análise de correlação tem a finalidade de quantificar o grau de associação linear entre as variáveis e a estatística que descreve a intensidade desta associação é o coeficiente de correlação (WATZLAWICK et al. 2004). O coeficiente de correlação varia de -1 a 1, sendo que os extremos representam perfeita correlação entre variáveis e 0, a ausência. O coeficiente de correlação de Pearson (r) é dado pela Equação 10 (DRAPER e SMITH, 1998):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \cdot \sum_{i=1}^n (y_i - \bar{y})^2}} = \frac{\text{cov}(X,Y)}{\sqrt{\text{var} X \cdot \text{var}(Y)}} \quad (10)$$

Equação 10 - Cálculo do coeficiente de correlação de Pearson.

Onde r é o coeficiente de correlação de Pearson; $\sum_{i=1}^n (x_i - \bar{x}) \cdot (y_i - \bar{y})$ é a covariância entre as variáveis X e Y, $\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2}$ é o desvio padrão de X e $\sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}$ o desvio padrão de Y.

2.4.2 Análise de regressão

A análise de regressão envolveu as relações empíricas existentes entre os dados espectrais em cada sensor, tratados como variáveis independentes e os valores de biomassa e carbono florestal, correspondentes ao pixel da imagem, como variáveis dependentes.

No SPSS foram testadas, inicialmente, as relações lineares entre os dados espectrais e os valores de biomassa e carbono florestal, $y = \alpha x + \beta$, bem como o uso de outras regressões lineares múltiplas, p. ex., $y = \beta_0 + \beta_1 \cdot x_1 + \beta_2 \cdot x_2$, com múltiplos índices e bandas espectrais como variáveis de entrada.

O método de seleção de variáveis foi o *stepwise*, que seleciona apenas as variáveis com contribuição significativa para o modelo de regressão, de acordo com um nível de significância F de *Fischer* pré-estabelecido (WATZLAWICK, KIRCHNER e SANQUETTA, 2009). O valor de significância utilizado foi de 5% para incluir variáveis no modelo e de 10% para removê-las.

A primeira etapa do método inicia com a escolha da variável regressora que contém o maior coeficiente de correlação com a variável resposta e segue com a inserção da segunda variável; após o acréscimo de uma nova variável, esta é verificada se deve ser descartada, de acordo com a significância do teste e segue com a verificação das demais variáveis, passo-a-passo. O método termina quando não há mais variável significativa para ser inserida ou descartada no modelo.

As variáveis espectrais foram transformadas para logaritmo natural com o objetivo de testar se as relações existentes entre os dados espectrais transformados e as variáveis biofísicas seriam mais bem explicadas por funções não lineares.

Heiskanen (2006) cita que a logaritmização das variáveis espectrais melhora o poder da regressão na estimativa de dados biofísicos. Myneni et al. (1995) reportou a relação não linear entre as variáveis florestais e os dados de reflectância. Assim, as equações logarítmicas ($y = \alpha x^\beta$) e exponenciais ($y = \alpha e^{\beta x}$) também foram avaliadas. Ambas as equações podem ser facilmente linearizadas Equação 11 (CALBO, SILVA e TORRES, 1989):

$$\ln(y) = \ln(\alpha) + \beta \ln(x); \ln y = \ln(\alpha) + \beta(x) \quad (11)$$

Equação 11 - Linearização da equação logarítmica e exponencial, respectivamente.

A validação das regressões foi efetuada pelas seguintes estatísticas:

- i) Coeficientes de determinação (R^2) e de determinação ajustado (R^2_{aj}):

O coeficiente de determinação (R^2) mede o quanto da relação entre as variáveis dependentes (biomassa e carbono) e as variáveis independentes (valores de reflectâncias e IVs) é explicado pela regressão linear. Os valores de R^2 variam de -1 a 1 e quanto mais próximos de 1 e -1 melhor será o ajuste (DRAPER e SMITH, 1998).

O coeficiente de determinação ajustado (R^2_{aj}) funciona de forma semelhante ao R^2 , porém este é utilizado quando são comparadas equações com diferentes números de coeficientes de entrada para alimentar as regressões múltiplas. O cálculo dos R^2 e R^2_{aj} estão descritos na Equação 12:

$$R^2 = \frac{SQ_{regressão}}{SQ_{total}} \text{ e } R_{aj.}^2 = 1 - \frac{1 - R^2}{\frac{n-1}{n-p-1}} \quad (12)$$

Equação 12 - Cálculo do coeficiente de determinação e coeficiente de determinação ajustado, respectivamente.

Onde R^2 e $R_{aj.}^2$ são os coeficientes de determinação, $SQ_{regressão}$ é a diferença entre a soma dos quadrados totais e a soma dos quadrados dos resíduos, em que $SQ_{total} = \sum (Y_i - \bar{Y})^2$ e $SQ_{resíduos} = \sum (Y_i - \hat{Y}_i)^2$; Y_i são os valores reais observados; \bar{Y} é a média dos valores reais observados; \hat{Y}_i são os valores estimados pela equação; n é o número de observações e p o número de coeficientes da equação.

ii) Erro Padrão da estimativa (S_{yx}) e Erro Padrão Relativo ($S_{yx} \%$)

O erro padrão da estimativa (S_{yx}) é o erro cometido ao ajustar os resíduos aos valores reais observados. Quanto menor o S_{yx} melhor o ajuste da equação, i.e., a soma dos resíduos das estimativas é baixa. O S_{yx} é, por vezes, denominado de raiz do erro médio quadrático (RMSE). O erro padrão relativo ($S_{yx} \%$) é o erro padrão expresso em percentagem, sendo mais apropriado quando se deseja comparar os erros oriundos de fontes de dados diferentes, pois independe da escala das unidades das variáveis. O S_{yx} e $S_{yx} \%$ são calculados conforme a Equação 13:

$$S_{yx} = \sqrt{\frac{SQ_{resíduos}}{n-p}} \text{ e } S_{yx} \% = \frac{S_{yx}}{\bar{Y}} \times 100 \quad (13)$$

Equação 13 - Erro padrão da estimativa e erro padrão relativo, respectivamente.

Onde S_{yx} e $S_{yx} \%$ é o erro padrão e erro padrão relativo da estimativa, respectivamente.

iii) Análise gráfica dos resíduos padronizados

A análise dos resíduos foi realizada mediante a construção de gráficos de dispersão, contendo os resíduos padronizados gerados pelas estimativas. A análise gráfica dos resíduos serve para verificar a tendenciosidade das estimativas e analisar onde os valores estimados pela regressão apresentam sub ou superestimativas.

O gráfico dos resíduos é construído plotando-se os valores estimados padronizados (eixo x) *versus* resíduos padronizados (eixo y). Uma boa dispersão

gráfica dos resíduos ocorre quando os valores estimados flutuam uniformemente em torno do resíduo nulo, com pelo menos 95% dos valores dos resíduos dentro do intervalo [-2,2] (MOGNON, 2011). O cálculo do resíduo padronizado da regressão em cada unidade amostral é dado pela Equação 14:

$$d_i = \frac{Y_i - \hat{Y}_i}{QM_{resíduos}} \quad (14)$$

Equação 14 - Cálculo dos resíduos padronizados.

Onde d_i é o resíduo padronizado, $QM_{resíduos} = \frac{SQ_{resíduos}}{n-1}$ e $Y_i - \hat{Y}_i$ é o resíduo não padronizado.

As equações que obtiveram os melhores ajustes foram utilizadas para avaliar a precisão destas em estimar a biomassa e o carbono florestal contido em toda a EESJT.

2.4.3 Validação das estimativas de biomassa e estoque de carbono

A precisão das estimativas de biomassa e estoque de carbono para a estação experimental foi testada comparando-se os valores estimados pelo inventário do PELD, em toneladas por hectare, com os valores de carbono estimados pelas diferentes equações ajustadas nos diferentes sensores.

Os valores de biomassa e estoque de carbono estimados pelo inventário do PELD são o resultado da soma de todos os valores individuais de biomassa e carbono das árvores contidas nas parcelas permanentes. A média foi calculada dividindo-se o total pelas quatro parcelas. Esta média de biomassa e carbono florestal foi utilizada para validar as estatísticas e os resultados dos modelos de regressão, gerados conforme metodologia descrita por Muukkonen e Heiskanen, (2005), que utilizaram os valores de biomassa florestal observado pelo inventário florestal nacional (NFI) para validar o resultado das estimativas.

A variação absoluta é dada pela diferença entre o valor estimado no inventário e o estimado de biomassa florestal, em $t \cdot ha^{-1}$, e a variação relativa é dada

pela porcentagem de variação entre o valor de biomassa florestal observado e o estimado pela equação de regressão (MUUKKONEN e HEISKANEN, 2007).

As equações de regressão que apresentaram os melhores ajustes assim como, uma boa estimativa de biomassa e carbono florestal, em $t.ha^{-1}$, foram empregadas para confeccionar os mapas de distribuição espacial destas variáveis biofísicas.

2.5 MAPAS TEMÁTICOS DE BIOMASSA E CARBONO FLORESTAL

A última etapa metodológica consistiu na elaboração de mapas temáticos, contendo a distribuição espacial das quantidades de biomassa e carbono florestal. Os mapas foram gerados a partir dos modelos inversos de regressão, cujos valores de biomassa e carbono florestal foram estimados em nível de pixel pelas equações que contiveram o melhor ajuste, em cada um dos sensores.

Os modelos inversos de regressão foram inseridos na matemática de bandas do *software* ENVI 4.5[®] para a confecção dos mapas estimados de biomassa e carbono florestal; após classificou-se os pixels segundo intervalos iguais de biomassa e carbono florestal em um ambiente de Sistema de Informações Geográficas (SIG).

2.6 PROJETO REDD⁺

Utilizando-se do modelo que obteve o melhor resultado nas estimativas de carbono florestal para toda a área da EESJT, por meio dos dados espectrais, criou-se um cenário hipotético de REDD⁺ com o intuito de avaliar a compensação financeira pelo montante de CO₂ fixado e estocado pela FOM.

Um projeto de REDD⁺ para ser fiável precisa de um período mínimo de duração como garantia de que a floresta não será explorada com corte raso ou de

que ao menos a sua taxa histórica de desmatamento anual seja descontada no cômputo do total de reduções de emissões (CORTE et al. 2012). Neste sentido, estabeleceu-se um período de 40 anos e uma taxa zero de desmatamento, já que a floresta é pertencente a uma instituição pública e protegida por Lei¹⁷.

A criação do cenário do projeto foi estabelecida com base no Projeto Antonina (CENAMO et al. 2010), exclusivamente por estar no mesmo Bioma Mata Atlântica em que a FOM está inserida, mesmo que este seja considerado um projeto de REDD e não REDD⁺. O período de duração, portanto, foi o mesmo do referido projeto e a taxa nula de desmatamento, que fora justificada anteriormente, também é semelhante à taxa de desmatamento daquele (TD = 0,09%). Ressalva-se que esta TD é apenas um exemplo hipotético, pois áreas privadas devem ser exploradas de alguma forma para se mantiverem viáveis economicamente.

Em um projeto de REDD⁺ a compensação pelo serviço ambiental prestado é negociada nos tratados internacionais em toneladas de dióxido de carbono equivalente (t.CO₂e.) e, por isso, o carbono orgânico florestal deve ser convertido para t. CO₂e. O fator de conversão é dado por: Massa do Carbono: 12 u.m.a; Massa de Oxigênio: 16 u.m.a; Massa de CO₂: 12 + (16 x 2) = 44 u.m.a; Logo, o fator de conversão de C para CO₂ é de 44/12 = 3,6667. Isto é, cada tonelada de C queimada é convertida em 3,6667 de CO₂e.

O valor fixado de CO₂e. foi obtido da média dos negócios de mercado voluntário *Over the Counter* – OCT de REDD⁺ para o ano de 2011. A tonelada de CO₂ foi firmada em \$ 6,2 segundo o relatório anual das transações de mercado voluntário de carbono¹⁸. A taxa de conversão de um Euro para Real utilizada foi a de 1,99, na data de 07/02/2013, segundo o Banco Central do Brasil. Assim, o montante de C nos 32,48 hectares da EESJT foi convertido para CO₂e e computados os valores financeiros desta transação.

¹⁷ Lei n. 11.428 de 22 de dezembro de 2006. Dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica, e dá outras providências. Brasília, 2013. Disponível em: <http://www.planalto.gov.br/ccivil_03/_ato2004-2006/2006/lei/l11428.htm>. Acesso em: 02/02/2013.

¹⁸ PETERS-STANLAY, M.; HAMILTON, K. Developing Dimension: State of the voluntary carbon markets 2012. Ecosystem Marketplace & Bloomberg New Energy Finance, 2012. 110p.

A intenção deste trabalho não é servir de base à criação de projetos REDD⁺, mas sim demonstrar uma das muitas aplicações de se inventariar o estoque de carbono em florestas naturais com relação ao ciclo de carbono.

3 RESULTADOS E DISCUSSÕES

3.1 INVENTÁRIO DE BIOMASSA E ESTOQUE DE CARBONO FLORESTAL

Os valores de biomassa florestal estimados no inventário do PELD, para os anos de 2010 e 2011, estão descritas na Tabela 6.

Tabela 6 - Estatísticas dos valores de biomassa florestal estimados para os anos de 2010 e 2011.

Biomassa	2010				
	Imbuia	Fogo	Araucária	Rio*	x
Nº de árvores	802	927	934	1178	960
Mínimo (kg)	13,74	10,78	4,83	8,94	4,83
Máximo (kg)	16.157,01	2.802,88	3.430,94	2.764,99	16.157,01
Soma (t/ha)	282,91	164,98	213,39	209,74	217,75
Média (kg)	352,75	177,97	228,47	178,05	234,31
DP (kg)	1.136,22	318,09	429,64	362,13	561,52
Biomassa	2011				
	Imbuia	Fogo	Araucária	Rio*	x
Nº de árvores	802	927	934	1178	960
Mínimo (kg)	11,74	11,74	4,83	8,94	4,83
Máximo (kg)	16.772,48	2.866,61	3.459,10	2.790,22	16.772,48
Soma (t/ha)	280,20	169,06	217,57	211,21	219,51
Média (kg)	349,38	182,37	232,95	179,30	236,00
DP (kg)	1.157,43	325,28	440,14	365,27	572,03

Nota: Em decorrência de a parcela Rio conter 0,5 hectares, os valores referentes à soma e ao número de árvores foi multiplicado por 2.

Sinais convencionais utilizados:

Mínimo - valor individual mínimo de biomassa estimado, em quilogramas;

Máximo - valor individual máximo de biomassa estimado, em quilogramas;

Soma - somatório dos valores individuais de biomassa florestal acima do solo em toneladas por hectare;

Média - valor individual médio, em quilogramas;

x - valores médios nas parcelas;

DP - desvio padrão.

No ano de 2010 o valor médio de biomassa florestal foi calculado em 217,76 t.ha⁻¹, com uma média individual de 234,31 kg de biomassa, ao passo que no ano de 2011, o valor médio de biomassa florestal foi de 219,51 t.ha⁻¹ e média individual de 236 kg. Isto representa um incremento anual de 1,76 t.ha⁻¹.ano⁻¹ de biomassa florestal ou 0,8% de incremento periódico anual relativo (IPA).

Segundo Watzlawick et al. (2002), esses valores de biomassa florestal encontrados de 217,76 t.ha⁻¹ e 219,51 t.ha⁻¹ enquadram-se a vegetação como estágio intermediário de regeneração (168,84 t.ha⁻¹) para estágio avançado de regeneração (397,79 t.ha⁻¹) de uma FOM. Em outro trabalho, Watzlawick (2003) observou 250,90 t.ha⁻¹ e Mognon (2011) 186 t.ha⁻¹, sendo que ambos os trabalhos foram realizados em uma FOM localizada em General Carneiro/PR.

As parcelas Fogo e Rio possuem médias individuais de biomassa florestal inferiores aos valores das parcelas Imbuia e Araucária devido a estas conterem alguns indivíduos com altos valores de biomassa, p. ex., a parcela Imbuia registra um único exemplar com mais de 16 t de biomassa e àquelas contemplarem muitos indivíduos com valores baixos de biomassa.

O histórico de exploração local condicionou certos valores de biomassa florestal observados nas parcelas, p ex., a Imbuia não foi uma espécie explorada comercialmente nos registros históricos (SCHAAF, 2001) e, por isso, a parcela Imbuia apresenta indivíduos com grandes dimensões. O Pinheiro-do-Paraná, por outro lado, tiveram seus espécimes de maior dimensão retirados, fato comprovado pela parcela Araucária ter como máximo 3430,94 kg de biomassa florestal individual. No mesmo sentido, a parcela Fogo – em decorrência de um incêndio em 1982 – apresentou baixo valor de biomassa florestal individual (média de 177,97 kg) e a menor quantidade de biomassa florestal em uma parcela (164,98 t.ha⁻¹). Esta parcela seria classificada como uma transição do estágio inicial para o estágio intermediário de regeneração segundo a classificação de Watzlawick et al. (2002).

Na Tabela 7, têm-se as estatísticas encontradas para os valores de carbono florestal, observados nos anos 2010 e 2011, nas quatro parcelas do PELD. No ano de 2010, o valor médio de carbono florestal observado foi de 90,19 t.ha⁻¹ e o valor médio individual de 97 kg; já no ano de 2011, de 90,93 t.ha⁻¹ e 97,71 kg, respectivamente. Incremento anual de 0,74 t.ha⁻¹ano⁻¹ de carbono ou IPA = 0,82%. Este valor representa mais do que o dobro do IPA observado por Mognon (2011) em uma FOM de General Carneiro. Weber, Sanquetta e Eisfeld (2005), observaram 104,31 t.ha⁻¹ de carbono imobilizado na biomassa arbórea, em 2004, estudando apenas os dados referentes à parcela Imbuia. Atualmente, o valor observado de carbono nesta parcela foi calculado em 116,56 t.ha⁻¹, correspondente a um

incremento bruto de 12,25 t.ha⁻¹ em seis anos, ou pouco mais de 2 t.ha⁻¹.ano⁻¹. No trabalho de Weber, Sanquetta e Einfeld (2005), o incremento médio anual, na parcela Imbuia, foi de cerca de 1,5 t.ha⁻¹.ano⁻¹ de carbono florestal, durante o período analisado 1995-2004.

Tabela 7 - Estatísticas dos valores de carbono florestal para os anos de 2010 e 2011.

Carbono	2010				
	Imbuia	Fogo	Araucária	Rio*	x
Nº de árvores	802	927	934	1178	960
Mínimo (kg)	5,61	4,40	1,93	3,83	1,93
Máximo (kg)	6829,08	1167,85	1429,54	1152,06	6829,08
Soma (t/ha)	116,56	68,42	88,50	87,27	90,19
Média (kg)	145,33	73,80	94,76	74,08	96,99
DP (kg)	473,22	132,48	178,82	151,03	233,89
Carbono	2011				
	Imbuia	Fogo	Araucária	Rio*	x
Nº de árvores	802	927	934	1178	960
Mínimo (kg)	4,79	4,79	1,93	3,83	1,93
Máximo (kg)	7089,22	1194,40	1441,27	1162,57	7089,22
Soma (t/ha)	115,48	70,11	90,24	87,89	90,93
Média (kg)	143,99	75,63	96,61	74,61	97,71
DP (kg)	482,32	135,50	183,20	152,32	238,33

Nota: Em decorrência de a parcela Rio conter 0,5 hectares, os valores referentes à soma e ao número de árvores foram multiplicados por 2.

Sinais convencionais utilizados:

Mínimo - valor individual mínimo de carbono estimado, em quilogramas;

Máximo - valor individual máximo de carbono estimado, em quilogramas;

Soma - somatório dos valores individuais de carbono florestal em toneladas por hectare;

Média - valor individual médio, em quilogramas;

x - valores médios nas parcelas;

DP - desvio padrão.

3.2 ANÁLISE DE CORRELAÇÃO DO SENSOR ASTER

As estatísticas básicas das 48 unidades amostrais estão descritas na Tabela 8. Estas foram usadas no desenvolvimento da análise de correlação entre as variáveis biofísicas e as variáveis espectrais do sensor ASTER contendo a mesma dimensão do pixel da imagem ASTER (15x15 m). Nota-se na Tabela 8 a heterogeneidade dos valores de biomassa e carbono florestal observados nas UA, sobretudo pelos altos valores dos coeficientes de variação (CV) de biomassa e de carbono florestal 46,91% e 46,53 %, respectivamente. O CV mede a dispersão

porcentual dos dados em torno da média dos valores observados; é dado pela razão porcentual entre o desvio padrão (DP) e a média.

As variações nos valores dos índices e bandas espectrais observadas nas UA foram inferiores às variações observadas nas variáveis biofísicas, notadamente pelos baixos CVs dos índices NDVI, SAVI e EVI_{mod} (1,05%, 7,68% e 7,81%, respectivamente). Isto terá reflexo nos valores dos coeficientes de correlação e afetará sobremaneira o grau de associação linear entre as variáveis biofísicas e as variáveis espectrais, devido à presença de heterocedasticidade¹⁹ nos dados.

Tabela 8 – Estatísticas das unidades amostrais em nível de pixel de resolução 15m do sensor ASTER.

	N	Mín.	Máx.	Máx. - Mín.	Média	Desvio Padrão	CV (%)
Biomassa (kg/m ²)	48	5,28	37,74	32,46	17,33	8,13	46,91
Carbono (kg/m ²)	48	2,16	15,89	13,73	7,27	3,38	46,53
ρ Verde	48	0,00 ¹	0,02	0,01	0,01	0,00 ¹	36,36
ρ Vermelho	48	0,00 ¹	0,01	0,01	0,01	0,00 ¹	20,00
ρ IVP	48	0,19	0,31	0,12	0,22	0,03	11,77
SR	48	22,61	47,19	24,58	32,29	5,50	17,02
NDVI	48	0,92	0,96	0,04	0,94	0,01	1,05
TVI	48	10,69	18,94	8,25	12,85	1,74	13,54
SAVI	48	0,40	0,55	0,15	0,44	0,03	7,68
EVI _{mod}	48	0,72	1,01	0,29	0,80	0,06	7,81

Nota: (1) Valores inferiores a duas casas decimais.

- Biomassa (kg/m²)** - biomassa florestal acima do solo em quilogramas por metro quadrado;
- Carbono (kg/m²)** - carbono florestal em quilogramas por metro quadrado;
- ρ Verde** - banda correspondente ao verde do espectro EM;
- ρ Vermelho** - banda correspondente ao vermelho do espectro EM;
- ρ IVP** - banda correspondente ao infravermelho próximo do espectro EM;
- SR** - índice de vegetação razão simples;
- NDVI** - índice de vegetação por diferença normalizada;
- TVI** - índice de vegetação triangular;
- SAVI** - índice de vegetação ajustado ao solo;
- EVI_{mod}** - índice de vegetação melhorado modificado

Existem alguns métodos possíveis de se contornar este problema. Dentre os quais, a transformação logarítmica de variáveis e a agregação de informações espaciais são os mais utilizados e serão empregados neste trabalho (DRAPER e SMITH, 1998). Detalhes destes métodos serão vistos a seguir.

¹⁹ Heterocedasticidade é um fenômeno estatístico que ocorre quando o modelo de regressão apresenta variâncias para as variáveis X (x_1, x_2, \dots, x_n) e Y não iguais para todas as observações. Isto é, quando os dados não se encontram homoganeamente dispersos em torno da reta de um modelo de regressão linear (HO, 2006).

Na Tabela 9 estão listadas as correlações de Pearson (r) geradas a partir da associação entre duas variáveis pareadas. Conforme verificado na análise da matriz de correlação (Tabela 9), as variáveis biofísicas apresentaram fracas correlações negativas com as variáveis espectrais. O EVI modificado foi o índice que apresentou a maior correlação com a biomassa e o carbono florestal ($r = -0,24$ e $r = -0,27$, respectivamente), embora esta correlação seja considerada baixa. Entre as bandas espectrais, a banda correspondente à faixa do infravermelho próximo foi a que apresentou o maior valor de r para a biomassa e carbono florestal, $-0,20$ e $-0,23$, respectivamente.

Tabela 9 - Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais. Em negrito, as mais altas correlações.

	Biomassa	Carbono	ρ Verde	ρ Vermelho	ρ IVP	SR	NDVI	TVI	SAVI
ρ Verde	-0,01	-0,05							
ρ Vermelho	-0,10	-0,14	0,60						
ρ IVP	-0,20	-0,23	0,83	0,57					
SR	-0,03	-0,01	-0,15	-0,80	0,01				
NDVI	0,02	0,04	-0,15	-0,83	-0,02	0,98			
TVI	-0,16	-0,19	0,87	0,48	0,99	0,11	0,08		
SAVI	-0,21	-0,25	0,82	0,50	1,00	0,10	0,06	0,99	
EVI mod	-0,24	-0,27	0,73	0,42	0,98	0,18	0,14	0,97	0,99
ρ Verde		-	banda correspondente ao verde do espectro EM;						
ρ Vermelho		-	banda correspondente ao vermelho do espectro EM;						
ρ IVP		-	banda correspondente ao infravermelho próximo do espectro EM;						
SR		-	índice de vegetação razão simples;						
NDVI		-	índice de vegetação por diferença normalizada;						
TVI		-	índice de vegetação triangular;						
SAVI		-	índice de vegetação ajustado ao solo;						
EVI mod		-	índice de vegetação melhorado modificado						

Por outro lado, Heiskanen (2006) encontrou fortes correlações negativas entre as bandas do verde e do vermelho do sensor ASTER ($r = -0,698$ e $r = -0,831$, respectivamente) e a biomassa florestal de uma floresta classificada como Floresta Montanhosa Subalpina de Bétulas. Porém, a alta correlação encontrada por Heiskanen (2006) pode ser explicada pelo fato de a floresta subalpina conter valores de no máximo $33,26 \text{ t.ha}^{-1}$ de biomassa florestal, enquanto a FOM estudada apresentou até $282,91 \text{ t.ha}^{-1}$. A baixa correlação entre as variáveis neste estudo pode ser resultado da saturação dos dados espectrais com os altos valores de biomassa. Esta é discutida na literatura em decorrência da saturação dos índices de

vegetação para altos valores de biomassa (JONES e VAUGHAN, 2010; LU, 2006; PATENAUDE et al. 2005).

Já Muukkonen e Heiskanen (2005) encontraram valores de $r = -0,69$, $r = -0,60$ e $r = -0,62$, para as bandas 1, 2 e 3N (ASTER), respectivamente, e a biomassa florestal de um Floresta Boreal²⁰ na Finlândia, com valores de biomassa variando de 1 - 388 t.ha⁻¹ e média de 105 t.ha⁻¹. Valores de r inferiores ao de Heiskanen (2006), mas ainda superiores aos encontrados no presente estudo. Estes valores superiores de r observados por Muukkonen e Heiskanen (2005) podem ser atribuídos à alta intensidade amostral, pois utilizaram 1.331 UA, perfazendo uma gama maior de fitofisiologias e variabilidade de biomassa florestal, enquanto neste trabalho foram utilizadas apenas 48 UA.

A correlação negativa entre as variáveis biofísicas e espectrais é típica de coníferas (MUUKKONEN e HEISKANEN, 2005), pois como reportaram alguns autores, as múltiplas camadas de copas e as pequenas superfícies formadas pelas acículas diminuem a reflectância, à proporção que se aumenta estrutura vertical da floresta e o efeito de sombreamento (ÄRDO, 1992; HÄME et al. 1997). Lillesand, Kiefer e Chipman (2007) comentam que as espécies folhosas têm normalmente maiores valores de reflectância tanto na região do infravermelho próximo quanto na região do vermelho, pois apresentam maior variabilidade de pigmentos e estruturas celulares. A dificuldade de avaliar a resposta espectral da FOM encontra-se no fato de ser característica desta tipologia florestal a coexistência de coníferas e folhosas e a resposta espectral ser uma mistura de ambas, portanto.

3.2.1 Variabilidade espacial de biomassa e carbono florestal com a mudança de escala de observação

Na Tabela 10 têm-se as estatísticas descritivas das UA em cada uma das resoluções espaciais degradadas. À medida que há uma agregação espacial nos dados, a média dos valores observados se mantém inalterada ao passo que a

²⁰ A Floresta Boreal, também conhecida por floresta de coníferas, ou ainda Taiga, é um bioma comumente encontrado no norte do Alasca, Canadá, sul da Groelândia, parte da Noruega, Suécia, Finlândia, Sibéria e Japão. Sua formação vegetal é pouco diversificada, tipicamente pinheiros, abetos e lárices.

variância decresce monotonicamente²¹ (DECOLA, 1994). O CV da maioria das variáveis diminuiu em decorrência da agregação nos dados espaciais, quando então as variáveis biofísicas que continham altos CVs, aproximaram-se dos CVs das demais variáveis espectrais (homocedasticidade) (Figura 13). Em alguns índices este fenômeno não se confirmou, a exemplo do TVI, SAVI e EVI_{mod}, e das Bandas verde e infravermelho próximo, logo, pode-se considerar que essas áreas já eram suficientemente homogêneas para tais variáveis espectrais.

Tabela 10 - Estatísticas descritivas das UA para as diferentes resoluções espaciais utilizadas (15m, 30m e 45m).

	ASTER 15m				ASTER 30m				ASTER 45m			
	Nº	Média	DP.	CV%	Nº	Média	DP.	CV%	Nº	Média	DP.	CV%
Biomassa (kg/m ²)	48	17,33	8,13	46,91	21	19,58	4,75	24,24	12	18,30	2,50	13,64
Carbono (kg/m ²)	48	7,27	3,38	46,53	21	8,10	1,96	24,17	12	7,58	1,02	13,52
ρ Verde	48	0,01	0,00	36,36	21	0,01	0,00 ¹	27,28	12	0,01	0,00 ¹	29,57
ρ Vermelho	48	0,01	0,00	20,00	21	0,01	0,00 ¹	14,67	12	0,01	0,00 ¹	13,04
ρ IVP	48	0,22	0,03	11,77	21	0,22	0,02	9,31	12	0,22	0,03	11,52
SR	48	32,29	5,50	17,02	21	32,03	3,68	11,49	12	31,18	2,98	9,54
NDVI	48	0,94	0,01	1,05	21	0,94	0,01	0,74	12	0,94	0,01	0,64
TVI	48	12,85	1,74	13,54	21	13,01	1,37	10,56	12	13,10	1,74	13,31
SAVI	48	0,44	0,03	7,68	21	0,44	0,03	6,18	12	0,44	0,03	7,64
EVI _{mod}	48	0,80	0,06	7,81	21	0,81	0,05	6,38	12	0,81	0,06	7,74

Nota: (1) Valores inferiores a duas casas decimais.

- Biomassa (kg/m²) - biomassa florestal acima do solo em quilogramas por metro quadrado;
- Carbono (kg/m²) - carbono florestal em quilogramas por metro quadrado;
- ρ Verde - banda correspondente ao verde do espectro EM;
- ρ Vermelho - banda correspondente ao vermelho do espectro EM;
- ρ IVP - banda correspondente ao infravermelho próximo do espectro EM;
- SR - índice de vegetação razão simples;
- NDVI - índice de vegetação por diferença normalizada;
- TVI - índice de vegetação triangular;
- SAVI - índice de vegetação ajustado ao solo;
- EVI_{mod} - índice de vegetação melhorado modificado

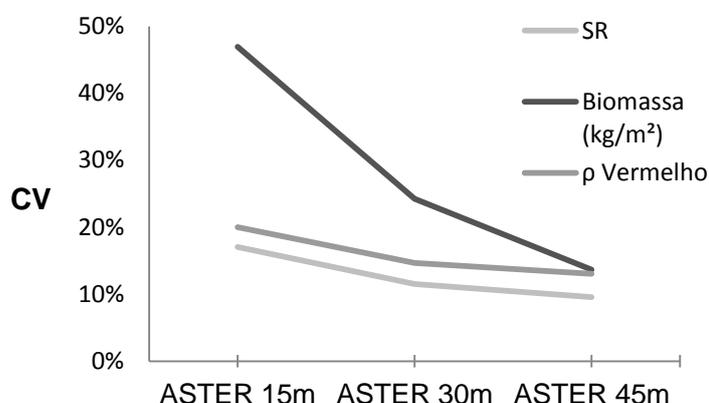


Figura 13 - Comportamento dos coeficientes de variação em função da degradação espacial.

²¹ Monotonicamente diz-se de um comportamento quase linear dos dados; em um só tom.

O efeito da mudança da escala de observação nos dados provenientes de sensoriamento remoto com o objetivo de encontrar a escala apropriada para avaliar determinado fenômeno natural tem sido reportado por diversos autores (BIAN e BUTLER 1999; CASSOL, SALDANHA e KUPLICH, 2012; COLLINS e WOODCOCK, 1999; CURRAN e ATKINSON, 1999; GOODIN e HENEGBRY, 2002; WOODCOK e STRAHLER, 1987).

Bian e Butler (1999) testaram o efeito de três métodos de reamostragem para agregar pixels, mudando a escala de observação local para regional. Os três métodos foram: pixel médio, mediana e o pixel central. Ambos os métodos mediana e pixel médio produziram resultados semelhantes, sendo que, estatisticamente, a atribuição do pixel médio foi superior. O pixel central produziu erros grosseiros, com altos desvios e tendências em algumas situações, como em transições abruptas nos valores dos NDs entre pixels adjacentes.

Goodin e Henebry (2002) avaliaram o efeito de degradar a resolução do pixel, contendo valores de NDVI, em uma área de pradaria nos Estados Unidos. O NDVI foi gerado por imagens de um sensor aerotransportado, operando nas bandas do vermelho e infravermelho próximo do espectro EM. As imagens foram coletadas em quatro altitudes de voo, produzindo resoluções espaciais que variaram de 0,625m a 3,125m.

Os autores verificaram que o aumento da escala de observação modificou a estrutura espacial da variável estudada, pois o comportamento do NDVI foi afetado pela diminuição de sua variância. No entanto, pelo variograma do NDVI, constataram que esta se estabiliza a uma distância fixa (alcance), independentemente do aumento da escala, fixada em 40 metros. Os autores ressaltam, porém, que este efeito foi verificado no local estudado e que em outras áreas o resultado poderia ser diferente. Isto refere-se à escolha da escala de observação apropriada para a variável ambiental estudada, quando analisada através de informações oriundas de sensores remotos (WOODCOCK e STRAHLER, 1987).

De fato, o aumento na escala de observação do fenômeno resultou em um incremento na correlação entre os dados biofísicos e os dados espectrais. Na Tabela 11 nota-se o substancial aumento de r obtidos a partir dos dados do sensor

ASTER degradados para a resolução espacial de 30m. Aqui a banda ρ Verde e o índice TVI apresentaram significativa correlação positiva com as variáveis biofísicas. Usando a mesma banda deste sensor para correlacioná-la com a biomassa da Floresta Boreal Heiskanen (2006) observou $r = -0,698$ e Muukkonen e Heiskanen (2005), $r = -0,69$.

Tabela 11 - Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais, com o pixel de dimensão de 30x30m. Em negrito, os maiores coeficientes.

	Biomassa	Carbono	ρ Verde	ρ Vermelho	ρ IVP	SR	NDVI	TVI	SAVI
ρ Verde	0,55¹	0,56¹							
ρ Vermelho	0,16	0,18	0,76						
ρ IVP	0,52 ²	0,52 ²	0,83	0,60					
SR	0,20	0,18	-0,28	-0,76	0,06				
NDVI	0,22	0,20	-0,28	-0,77	0,05	0,99			
TVI	0,57¹	0,57¹	0,85	0,56	0,99	0,10	0,10		
SAVI	0,52 ²	0,52 ²	0,79	0,53	1,00	0,14	0,13	0,99	
EVI _{mod}	0,49 ²	0,49 ²	0,70	0,43	0,98	0,24	0,23	0,97	0,99

Nota: (1) Significativo ao nível $\alpha = 0,01$;
(2) Significativo ao nível $\alpha = 0,05$;

Verifica-se que houve uma inversão no sentido do grau de correlação das variáveis espectrais, haja vista que antes negativamente correlacionadas na resolução espacial de 15 m estas passaram a ser positivamente correlacionadas com as variáveis biofísicas. Pressupõe-se que com a agregação espacial dos dados a reflectância das folhosas pode ter sobrepujado a reflectância das coníferas, além disso, a homogeneização da resposta espectral amenizou a influência de fatores externos, como o sombreamento, outrora aparentes.

No entanto, ao contrário do que poderia se supor, o aumento dos valores de r , em virtude da contínua agregação espacial dos dados, não ocorre linearmente, mas decresce à medida que informações espaciais fisicamente distintas são agregadas dentro de um único pixel (WOODCOCK e STRAHLER, 1987).

Na matriz de correlação entre as variáveis biofísicas e os dados espectrais, construídos a partir da degradação do pixel ASTER de 15m de resolução espacial para 45m (Tabela 12) não houve valores de r significativos.

Tabela 12 - Matriz de correlação entre os dados biofísicos e os dados espectrais do sensor ASTER com resolução espacial de 45 metros. Em negrito, as mais altas correlações.

	Biomassa	Carbono	ρ Verde	ρ Vermelho	ρ IVP	SR	NDVI	TVI	SAVI
ρ Verde	0,42	0,43							
ρ Vermelho	0,16	0,17	0,81						
ρ IVP	0,50	0,50	0,97	0,68					
SR	0,33	0,31	0,03	-0,55	0,24				
NDVI	0,35	0,33	0,05	-0,54	0,25	0,99			
TVI	0,50	0,51	0,97	0,65	1,00	0,27	0,29		
SAVI	0,50	0,50	0,95	0,63	1,00	0,30	0,31	1,00	
EVI _{mod}	0,52	0,52	0,93	0,58	0,99	0,36	0,37	0,99	1,00

No correlograma da Figura 14 estão plotados os valores de r encontrados para as bandas e IVs *versus* as resoluções espaciais degradadas do sensor ASTER (15m, 30m e 45m) em função das variáveis biofísicas. Verifica-se o aumento não linear dos coeficientes de correlação de Pearson com a degradação da resolução espacial (*up-scaling*), excetuando-se os valores de r referentes aos índices NDVI e SR que apresentaram tendência linear.

No correlograma, o valor de r cresce até que atinja o patamar ($C_0 = r_{\text{máx}}$) e alcance máximos (*range* (a)), quando então o aumento na distância entre amostras ($h = 15$ metros) não é acompanhado pelo aumento da correlação entre pares de amostras (SOARES, 2000).

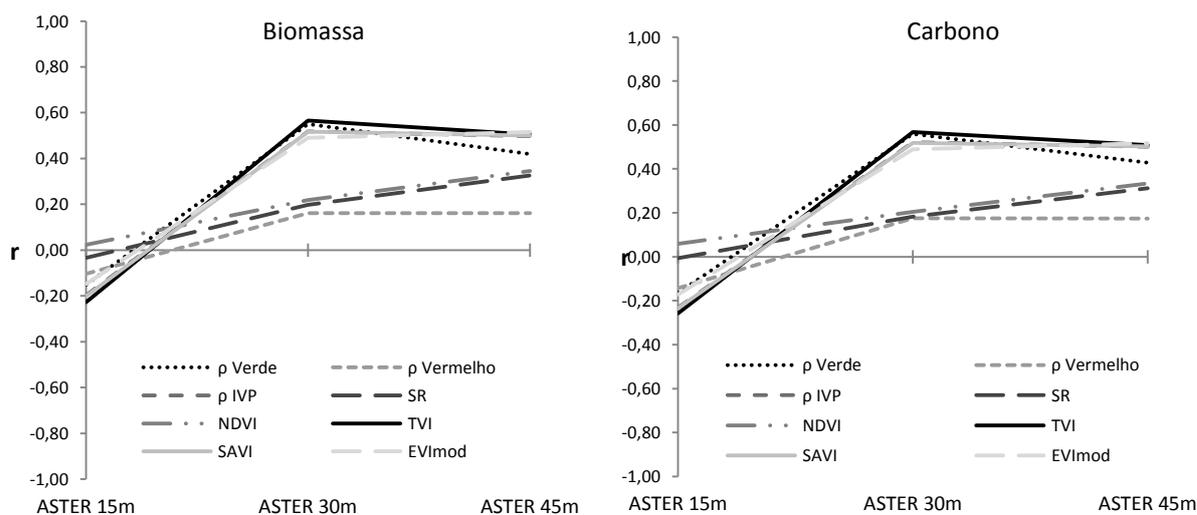


Figura 14 - Correlograma entre as variáveis biomassa e carbono florestal e as variáveis espectrais, em função da ampliação da escala de observação.

À medida que se aumentam os valores de h a correlação espacial entre as amostras diminui. Isto representa o valor do correlograma correspondente ao seu alcance, onde se considera que não há mais dependência espacial com o aumento da distância entre pares de amostras ($Var [Z(x) - Z(x+h)] = 0$). Para a maioria das variáveis espectrais a ausência de dependência espacial ocorreu na resolução espacial de 30 metros, a exceção dos índices SR e NDVI que demonstram um claro aumento linear da correlação com a diminuição da resolução espacial dos dados ASTER.

Watzlawick, Kirchner e Sanquetta (2009) estudando a biomassa e o carbono florestal de uma FOM em General Carneiro, a partir de dados espectrais do sensor IKONOS II de 4 metros de resolução espacial encontraram valores de r de até -0,80 entre o MS4 (banda do IVP) e a biomassa florestal na resolução espacial degradada para 12 metros. Difere-se da baixa correlação constatada por esta mesma banda para o sensor ASTER 15m e a biomassa florestal ($r = -0,20$), embora ambos contivessem correlações negativas.

3.2.2 Análise de regressão

Os coeficientes de determinação lineares, bem como, os erros padrões totais e erros padrões relativos observados pelas regressões lineares entre a biomassa e o carbono florestal e as variáveis espectrais do sensor ASTER nas diferentes resoluções espaciais estão descritos nas Tabela 13 e Tabela 14.

Tabela 13 – Resultados das regressões lineares entre a biomassa florestal e as bandas e IV, nas diferentes resoluções espaciais do sensor ASTER.

	ASTER 15m			ASTER 30m			ASTER 45m		
	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)
ρ Verde	0,00	1828,48	46,90	0,30	3664,47	21,84	0,18	4588,30	12,38
ρ Vermelho	0,01	1818,94	46,66	0,03	4217,08	23,93	0,03	4989,37	13,47
ρ IVP	0,04	1792,92	45,99	0,27	3652,43	20,73	0,25	4386,35	11,84
SR	0,00	1827,61	46,88	0,04	4187,50	23,76	0,11	4780,51	12,90
NDVI	0,00	1828,38	46,90	0,05	4168,41	23,66	0,12	4744,30	12,80
TVI	0,03	1804,83	46,30	0,32	3523,47	20,00	0,25	4366,17	11,78
SAVI	0,05	1786,38	45,83	0,27	3655,97	20,75	0,25	4377,20	11,81
EVlmod	0,06	1773,65	45,50	0,24	3723,71	21,13	0,27	4331,99	11,69

À semelhança do que ocorreram com os valores de r , os valores de R^2 foram significativamente melhorados com a agregação espacial dos pixels – o coeficiente de determinação linear pode ser calculado pelo quadrado do coeficiente de correlação. O índice TVI/ASTER 30m apresentou o maior coeficiente de determinação ($R^2 = 0,32$) e o menor erro padrão ($S_{yx} = 3523,47$ Kg) na equação de regressão linear simples (Tabela 13). Os valores de R^2 observados neste estudo foram bem inferiores aos valores mínimos e máximos de R^2 encontrados por Heiskanen (2006) que variaram de 0,66 a 0,81, para a banda do vermelho e o SR, respectivamente, nos modelos de regressões lineares de estimativas de biomassa florestal, a partir de dados espectrais do sensor ASTER.

Muukkonen e Heiskanen (2005) encontraram R^2_{aj} de 0,56 para as bandas do sensor ASTER e a biomassa florestal, utilizando-se da seguinte equação não linear: $y = \exp(a) \times (1 - B2)^a \times (B3N)^c \times \exp(d \times B2) \times \exp(e \times B3N) + \varepsilon$, onde y é a biomassa florestal, a - e são os coeficientes da regressão e ε o erro. O erro da estimativa foi de $S_{yx} = 42,3\%$ observado pelos autores. Bajracharya (2008), por sua vez, encontrou $R^2 = 0,028$ para a equação de regressão linear entre a biomassa florestal no Nepal e o índice NDVI do sensor ASTER. Estando próximo ao valor de R^2 observado neste índice na resolução de 30m ($R^2 = 0,05$).

Os erros relativos foram menores na resolução espacial do ASTER degradada para 45m, inferiores a 15% em todas as bandas e índices (Tabela 13). Porém, estes valores se devem à diminuição na variância dos valores de biomassa florestal observados, não necessariamente à melhora no estimador (CASSOL, SALDANHA e KUPLICH, 2012; REESE et al. 2002).

O resultado da análise de regressão linear simples para a variável dependente, carbono florestal, foi semelhante ao resultado encontrado para a variável biomassa florestal discutida anteriormente (Tabela 14). Pela Tabela 14 observa-se que o maior R^2 foi obtido a partir da regressão linear simples, usando como variável independente o TVI na resolução espacial ASTER degradada para 30m ($R^2 = 0,32$). Corroborando o uso da resolução espacial de 30 metros para esta finalidade, neste trabalho.

Tabela 14 - Resultados das regressões lineares entre o carbono florestal e as bandas e IV, nas diferentes resoluções espaciais do sensor ASTER.

	ASTER 15m			ASTER 30m			ASTER 45m		
	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)
ρ Verde	0,00	760,49	46,47	0,31	1456,00	19,97	0,18	1873,35	12,21
ρ Vermelho	0,02	753,64	46,05	0,03	1735,68	23,80	0,03	2042,64	13,31
ρ IVP	0,05	740,77	45,27	0,27	1504,15	20,63	0,25	1795,22	11,70
SR	0,00	761,42	46,53	0,03	1732,40	23,76	0,10	1970,28	12,84
NDVI	0,00	760,67	46,48	0,04	1724,84	23,65	0,11	1955,39	12,74
TVI	0,04	747,04	45,65	0,32	1451,05	19,90	0,26	1786,78	11,64
SAVI	0,06	737,84	45,09	0,27	1507,61	20,67	0,25	1793,35	11,69
EVImod	0,07	732,42	44,75	0,24	1537,53	21,08	0,27	1776,46	11,58

Aplicando-se as equações lineares de cada um dos índices e bandas espectrais a cada uma das resoluções espaciais nos pixels contidos dentro dos limites da EESJT, foi possível estimar a biomassa e o carbono florestal total da área de estudo; desta calculou-se a média, em $t.ha^{-1}$, dividindo-se o total pela área em hectares.

3.2.3 Validação das regressões

O resultado das variações das estimativas de biomassa florestal se encontra na Tabela 15. Ressalta-se o alto desempenho das equações de regressões lineares simples em estimar a biomassa florestal por hectare na resolução espacial de 30 metros, notadamente, as construídas com os índices TVI, SAVI e EVImod e a banda do infravermelho próximo como variáveis independentes (Tabela 15). As variações para estes índices e banda espectral foram inferiores a 5% do valor observado, as quais estão dentro do intervalo de confiança da maioria dos trabalhos de inventário florestal utilizados com os métodos clássicos (IC = 95%). Além disso, os índices TVI, SAVI e a banda do infravermelho próximo estariam dentro do intervalo de confiança de 99%. Sendo, portanto, um resultado bastante significativo, apesar dos baixos valores de R^2 .

Tabela 15 - Estimativas de biomassa florestal por hectare, em t.ha⁻¹, geradas a partir das regressões lineares simples. Em negrito, destacam-se as menores variações.

	ASTER 15m			ASTER 30m			ASTER 45m		
	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)
Observada	217,75			217,75			217,75		
ρ Verde	173,08	-44,68	20,52	206,14	-11,62	5,33	189,77	-27,99	12,85
ρ Vermelho	168,61	-49,14	22,57	202,83	-14,93	6,85	186,63	-31,13	14,29
ρ IVP	161,14	-56,62	26,00	217,47	-0,28	0,13	191,29	-26,47	12,15
SR	174,16	-43,60	20,02	193,84	-23,92	10,98	181,62	-36,14	16,60
NDVI	173,29	-44,46	20,42	191,36	-26,39	12,12	178,81	-38,95	17,89
TVI	164,16	-53,59	24,61	218,29	0,53	-0,25	190,77	-26,98	12,39
SAVI	160,55	-57,20	26,27	215,87	-1,88	0,86	190,96	-26,79	12,30
EVI _{mod}	159,07	-58,68	26,95	213,66	-4,10	1,88	190,96	-26,79	12,30

Observada	-	biomassa florestal acima do solo observada pela média nas quatro parcelas, em tonelada por hectare;
ρ Verde	-	banda correspondente ao verde do espectro EM;
ρ Vermelho	-	banda correspondente ao vermelho do espectro EM;
ρ IVP	-	banda correspondente ao infravermelho próximo do espectro EM;
SR	-	índice de vegetação razão simples;
NDVI	-	índice de vegetação por diferença normalizada;
TVI	-	índice de vegetação triangular;
SAVI	-	índice de vegetação ajustado ao solo;
EVI_{mod}	-	índice de vegetação melhorado modificado

Na Tabela 16 têm-se as variações nos valores de carbono estimados, a partir das equações de regressão lineares simples estabelecidas com base nos índices e bandas espectrais do sensor ASTER. Novamente, os resultados são próximos aos encontrados para biomassa florestal, devido ao alto grau de correlação entre estas variáveis biofísicas. Aqui na Tabela 16, a ρ Verde (correspondente ao verde) foi a melhor a preditora do carbono florestal, com apenas 0,04% de variação relativa.

Tabela 16 - Estimativas de carbono florestal por hectare, em t.ha⁻¹, geradas a partir das regressões lineares simples. Em negrito, as menores variações.

	ASTER 15m			ASTER 30m			ASTER 45m		
	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)
Observada	90,19			90,19			90,19		
ρ Verde	71,91	-18,28	20,26	90,15	-0,04	0,04	78,63	-11,56	12,82
ρ Vermelho	69,97	-20,21	22,41	84,16	-6,03	6,68	77,39	-12,80	14,19
ρ IVP	66,76	-23,42	25,97	90,01	-0,17	0,19	79,21	-10,98	12,17
SR	72,97	-17,22	19,09	80,30	-9,89	10,97	75,24	-14,95	16,57
NDVI	72,44	-17,75	19,68	79,34	-10,85	12,03	74,12	-16,06	17,81
TVI	68,14	-22,05	24,44	90,34	0,16	-0,17	79,00	-11,19	12,41
SAVI	66,59	-23,59	26,16	89,33	-0,86	0,96	79,07	-11,12	12,33
EVI _{mod}	66,08	-24,11	26,73	88,38	-1,81	2,01	79,06	-11,13	12,34

Observada - **carbono florestal médio nas quatro parcelas, em tonelada por hectare;**

Além desta a banda ρ IVP, o TVI, o SAVI e o EVI_{mod} obtiveram resultados satisfatórios, sendo que os três primeiros obtiveram variações inferiores a 1% e o EVI_{mod}, inferior a 5%.

3.2.4 Transformação das variáveis

Na Tabela 17, tem-se a matriz de correlação entre as variáveis biofísicas e as variáveis espectrais transformadas para logaritmo natural em cada uma das escalas de observação propostas. Nota-se pela Tabela 17 que a transformação das variáveis espectrais não trouxe incremento substancial na correlação linear entre estes conjuntos de dados. O aumento mais relevante de r , devido à transformação das variáveis, ocorreu nos dados originais ASTER com resolução espacial de 15m, sobretudo nos índices LnTVI, LnSAVI e especialmente LnEVI_{mod}, que foram significativos ao nível $\alpha = 0,05$. Na resolução de 30m, a transformação das variáveis espectrais foi significativa apenas em nível $\alpha = 0,05$. Com a resolução ASTER de 45m não houve coeficientes de correlação significativos.

Tabela 17 - Matriz de correlação entre as variáveis biofísicas e as variáveis espectrais transformadas, em cada uma das escalas propostas.

	ASTER 15m				ASTER 30m				ASTER 45m			
	Bio	Carb	LnBio	LnCarb	Bio	Carb	LnBio	LnCarb	Bio	Carb	LnBio	LnCarb
ρ Verde	-0,01	-0,05	-0,06	-0,10	0,55 ¹	0,56 ¹	0,47 ²	0,47 ²	0,42	0,43	0,39	0,40
ρ Verm.	-0,10	-0,14	-0,06	-0,10	0,16	0,18	0,07	0,08	0,16	0,17	0,14	0,15
ρ IVP	-0,20	-0,23	-0,21	-0,24	0,52 ²	0,52 ²	0,44 ²	0,44 ²	0,50	0,50	0,48	0,48
SR	-0,03	-0,01	-0,09	-0,06	0,20	0,18	0,24	0,23	0,33	0,31	0,33	0,32
NDVI	0,02	0,04	-0,03	-0,01	0,22	0,20	0,27	0,26	0,35	0,33	0,35	0,34
TVI	-0,16	-0,19	-0,19	-0,22	0,57 ¹	0,57 ¹	0,49 ²	0,49 ²	0,50	0,51	0,48	0,49
SAVI	-0,21	-0,25	-0,23	-0,27	0,52 ²	0,52 ²	0,45 ²	0,45 ²	0,50	0,50	0,48	0,48
EVI _{mod}	-0,24	-0,27	-0,26	-0,29 ²	0,49 ²	0,49 ²	0,43	0,43	0,52	0,52	0,50	0,50
Ln ρ Verde	-0,08	-0,12	-0,12	-0,17	0,45 ²	0,46 ²	0,38	0,38	0,37	0,38	0,35	0,36
Ln ρ Verm.	-0,11	-0,16	-0,08	-0,12	0,14	0,15	0,05	0,06	0,15	0,16	0,13	0,14
Ln ρ IVP	-0,22	-0,26	-0,23	-0,27	0,50 ²	0,50 ²	0,42	0,42	0,48	0,48	0,46	0,47
LnSR	-0,01	0,02	-0,06	-0,03	0,21	0,19	0,26	0,24	0,34	0,32	0,34	0,33
LnNDVI	0,02	0,05	-0,03	0,00	0,22	0,21	0,27	0,26	0,35	0,33	0,35	0,34
LnTVI	-0,18	-0,22	-0,21	-0,25	0,54 ²	0,54 ²	0,47 ²	0,47 ²	0,49	0,49	0,47	0,47
LnSAVI	-0,23	-0,26	-0,25	-0,28	0,50 ²	0,50 ²	0,43 ²	0,43 ²	0,49	0,49	0,47	0,47
LnEVI _{mod}	-0,26	-0,29 ²	-0,27	-0,30 ²	0,48 ²	0,48 ²	0,42	0,41	0,50	0,50	0,49	0,49

Nota: (1) Significativo ao nível $\alpha = 0,01$;
(2) Significativo ao nível $\alpha = 0,05$;

Pelo resultado apresentado na matriz de correlação dos dados espectrais transformados da Tabela 17 pode-se inferir que as equações não lineares serão menos apropriados do que as equações lineares para se estimar as variáveis biofísicas, devido à menor significância com o uso destas variáveis.

3.2.5 Equações de regressão lineares múltiplas

Devido à tendência de linearidade exposta anteriormente entre os dados biofísicos e os dados espectrais, o passo seguinte foi testar equações de regressão lineares múltiplas, com múltiplas variáveis de entrada, através do método *stepwise*. Na resolução espacial original do sensor ASTER de 15 metros, assim como, na resolução espacial degradada para 45 metros, não foram gerados quaisquer equações de regressão lineares múltiplas significativas, considerando os valores de significâncias de *F* de *Fischer* de 5% para incluir variáveis no modelo e de 10% para removê-las.

Na resolução espacial de 30 metros, três equações de regressão lineares múltiplas foram geradas para estimar a biomassa florestal a partir das variáveis espectrais (Tabela 18). Em todos eles, o índice TVI e a banda do infravermelho próximo – transformada ou não – foram as variáveis que mais contribuíram como preditoras para as equações múltiplas. Nota-se que o R^2_{aj} foi superior ao R^2 das mesmas variáveis espectrais, obtidos pelas regressões lineares simples (ver Tabela 14). Gebreslasie, Ahmed e van Aardt (2010) obtiveram valores de R^2_{aj} de 0,51 utilizando as variáveis MSAVI e a banda p IVP como preditoras do volume de um plantio de Eucalipto na África do Sul por meio de regressão linear múltipla. Semelhante ao observado na equação N° 2 do presente estudo, trocando-se, porém, o MSAVI pelo TVI.

A equação 2 foi aquela que obteve o maior R^2_{aj} (0,53), mas foi a N° 1 que alcançou a maior acurácia em estimar a biomassa florestal por hectare, variação de 7,86%. Nota-se também que todas as equações superestimaram os valores de biomassa florestal por hectare e que esta variação foi superior à variação observada pelas regressões lineares simples. Muukkonen e Heikanen (2005) também relataram

superestimativas nos dados de biomassa florestal utilizando-se de regressões não lineares das bandas do sensor ASTER na ordem de 10%.

Tabela 18 - Equações de regressão gerados a partir das variáveis espectrais selecionadas pelo método Stepwise, para a variável dependente Y = biomassa florestal.

N	Equações de regressão	$R^2_{aj.}$	Syx (kg)	Syx (%)	Biomassa (t.ha ¹)	Variação (%)
1	$Y = 14981,1 + 12819,6.TVI - 739236,7.B3N$	0,42	3177,42	18,02	234,87	-7,86
2	$Y = -455736,7 + 13978,6.TVI - 193214,9.LnB3N$	0,53	2852,73	16,18	242,26	-11,25
3	$Y = e^{-15,8 + 0,746.TVI - 10,52.LnB3N}$	0,46	2818,54	16,17	246,63	-13,26

As equações de regressão lineares múltiplas geradas para se estimar o carbono florestal estão demonstradas na Tabela 19. A melhor equação observada foi a segunda, pois tem maior $R^2_{aj.}$ e baixo Syx. Além disso, a variação de carbono florestal por hectare foi pequena (-11,24%). Semelhante ao efeito ocorrido nas equações obtidas para a biomassa florestal, todas apresentaram tendência a superestimar o carbono observado na área (Tabela 19).

Watzlawick et al. (2009) obtiveram o melhor ajuste pelo método *stepwise* com as seguintes variáveis espectrais selecionadas: MS-4, SAVI e NDVI do sensor IKONOS II para descrever as variações de carbono orgânico florestal da FOM. As estatísticas observadas foram: $R^2_{aj.} = 0,75$ e $Syx = 22,13\%$. Estes autores observaram variações de biomassa e carbono florestal de 2,81% e 3,91%, respectivamente, tendo, portanto, variações inferiores às variações geradas pelos modelos de regressão lineares múltiplos, mas superiores às variações observadas pelas equações lineares simples deste trabalho (Tabela 15 e Tabela 16).

Tabela 19 - Equações de regressão gerados a partir das variáveis espectrais selecionadas pelo método Stepwise, para a variável dependente Y = carbono florestal.

N	Equações de regressão	$R^2_{aj.}$	Syx (kg)	Syx (%)	Carbono (t.ha ¹)	Variação (%)
1	$Y = 88285,9 + 12909,8.TVI - 544445,2.SAVI - 1088511,9.B1$	0,54	1169,81	16,00	102,89	-14,09
2	$Y = -189842,7 + 5818,8.TVI - 80490,5.LnB3N$	0,54	1166,65	15,99	100,32	-11,24
3	$Y = e^{-16,7 + 0,7464.TVI - 10,52.LnB3N}$	0,47	1146,83	15,90	102,02	-13,12

Tendo em vista que a resolução espacial do sensor ASTER degradada para 30m foi a resolução que se mostrou mais apropriada para se estimar as variáveis biofísicas, uma segunda abordagem foi realizada. Nesta segunda abordagem foi avaliada a aplicabilidade dos sensores LiSS III e TM, que têm resolução espacial na

mesma ordem de grandeza do sensor ASTER 30m para a estimativa de biomassa e estoque de carbono florestal.

O sensor TM tem sido bastante utilizado para estimar a biomassa florestal nas mais diversas composições florísticas e localizações geográficas, por uma gama de métodos (FOODY et al. 2003; KRANKINA et al. 2004; ROY e RAVAN, 1996; SANTOS, 1998). O sensor ASTER também foi aplicado com certa intensidade, especialmente, em Florestas Boreais (MUUKKONEN, 2006, MUUKKONEN e KEISKANEN, 2005; MUUKKONEN e KEISKANEN, 2007). Entretanto, as aplicações do sensor LiSS III para esta finalidade são escassas. Os trabalhos de Madugundu, Nizalapur e Jha, (2008) e de Kumar et al. (2012), ambos na Índia, foram os únicos encontrados. Aplicações de quaisquer uns destes sensores para estimativas de biomassa e estoque de carbono na FOM não foram encontradas na literatura.

3.3 COMPARAÇÃO DOS SENSORES ASTER, TM E LiSS III

Na Tabela 20 têm-se as estatísticas encontradas nas UA utilizadas para descrever as variações das variáveis biofísicas a partir das variáveis espectrais, em cada um dos sensores. Nota-se que as médias nos valores de biomassa e carbono foram semelhantes entre os sensores avaliados. As variáveis espectrais, em contrapartida, apresentaram comportamento bastante distinto, pois os valores médios observados nos índices e bandas de um sensor não foram os mesmos dos demais. O índice EVI_{mod}, p.ex., tem valor médio de 0,81 no sensor ASTER, 0,40 no sensor LiSS III e 0,66 no sensor TM. Em outro exemplo, o índice de razão simples que tem CV de 17,02% no sensor ASTER, apenas 7,63% no sensor LISSIII e até 51,52% no sensor TM.

Se por um lado os erros inerentes aos dados biofísicos são os mesmos (parcelas do PELD), por outro, os erros provenientes dos dados espectrais são diferentes em cada um dos sensores. O esperado seria que os seus valores fossem muito próximos uns dos outros, já que os números digitais estão em um mesmo parâmetro físico estão minimizados os efeitos geométricos e atmosféricos nas cenas e a área coberta é a mesma.

Tabela 20 – Estatísticas das variáveis biofísicas em kg/m² e das variáveis espectrais nas unidades amostrais em cada um dos sensores avaliados.

		N	Máx. - Mín.	Média	Desvio Padrão	CV %
ASTER	Biomassa (kg/m ²)	21	19,94	19,58	4,75	24,24
	Carbono (kg/m ²)	21	8,33	8,10	1,96	24,17
	ρ Verde	21	0,01	0,01	0,00 ¹	27,28
	ρ Vermelho	21	0,00 ¹	0,01	0,00 ¹	14,67
	ρ IVP	21	0,09	0,22	0,02	9,31
	SR	21	13,93	32,03	3,68	11,49
	NDVI	21	0,03	0,94	0,01	0,74
	TVI	21	6,04	13,01	1,37	10,56
	SAVI	21	0,11	0,44	0,03	6,18
	EVI _{mod}	21	0,19	0,81	0,05	6,38
		N	Máx. - Mín.	Média	Desvio Padrão	CV %
LISSIII	Biomassa (kg/m ²)	26	23,18	19,77	6,08	30,74
	Carbono (kg/m ²)	26	9,44	8,18	2,49	30,48
	ρ Verde	26	0,00 ¹	0,03	0,00 ¹	4,19
	ρ Vermelho	26	0,01	0,03	0,00 ¹	8,28
	ρ IVP	26	0,05	0,15	0,01	6,50
	SR	26	1,40	5,55	0,42	7,63
	NDVI	26	0,07	0,69	0,02	2,83
	TVI	26	2,10	7,99	0,57	7,11
	SAVI	26	0,06	0,27	0,02	5,62
	EVI _{mod}	26	0,10	0,40	0,03	6,27
		N	Máx. - Mín.	Média	Desvio Padrão	CV %
TM	Biomassa (kg/m ²)	21	22,52	19,17	5,12	26,69
	Carbono (kg/m ²)	21	9,47	7,94	2,14	26,90
	ρ Verde	21	0,01	0,02	0,00 ¹	16,61
	ρ Vermelho	21	0,01	0,00 ¹	0,00 ¹	24,26
	ρ IVP	21	0,09	0,18	0,03	15,18
	SR	21	105,18	49,88	25,69	51,52
	NDVI	21	0,05	0,96	0,01	1,26
	TVI	21	6,12	12,18	1,85	15,16
	SAVI	21	0,15	0,38	0,04	11,35
	EVI _{mod}	21	0,31	0,66	0,08	12,85

Nota: (1) Valores inferiores a duas casas decimais;
N – Número de unidades amostrais;
CV % - coeficiente de variação, em porcentagem.

Os baixos CVs encontrados nos dados espectrais observados no sensor LiSS III podem estar associados à menor resolução radiométrica deste²². Verifica-se também a consistente baixa variação nos valores de NDVI, com CVs variando de 1,06% no ASTER até o máximo de 2,83% no LiSS III, o que demonstra este índice não ser muito sensível às altas variações de biomassa (JENSEN, 2009). Huete et al. (1997) demonstraram que valores de NDVI acima de 0,75 começam a saturar em superfícies densamente vegetadas e que o *Soil and Atmospherically Resistant Vegetation Index* (SARVI2) só tende a saturar com valores a partir de 0,9. O SARVI2 tem concepção análoga ao EVI, já que ambos têm propriedades de atenuar os efeitos do solo e os efeitos atmosféricos na resposta espectral. Enquanto o valor médio de NDVI foi de 0,95 no sensor TM, com alcance de apenas 0,05 entre os valores máximos e mínimos, o EVI teve valor médio de 0,65 e alcance de 0,31 mostrando-se ser, de fato, mais sensível às variações de biomassa florestal.

Estas disparidades observadas nos valores de reflectância das bandas espectrais dos diferentes sensores podem ter duas causas principais: aquelas inerentes às características do sensor e os efeitos ambientais durante a aquisição das cenas, que, neste caso, não podem ser controlados. Curran e Hay (1986) descrevem sete as fontes de erros nos dados obtidos de SR ópticos, que são elas: variações na irradiância espectral (E), erros de calibração do sensor, resolução radiométrica do sensor, erro de deriva (calibração/tempo), erro na discretização do sinal, atenuação atmosférica e irradiância atmosférica. Dentre estes erros, as variações na irradiância espectral têm a maior contribuição, podendo chegar a mais ou menos 15% de erro absoluto no valor de radiância registrado pelo sensor TM (CURRAN e HAY, 1986).

A maioria destes erros é removida ou atenuada pela transformação radiométrica das cenas, pela correção atmosférica e eventualmente pela razão de bandas. Infelizmente, o erro referente à discretização do sinal permanece, porque é dependente do comprimento de onda, mas este tem pequena ordem de grandeza – mais ou menos 0,3% ou em torno de 1ND para o sensor TM (CURRAN e HAY,

²² O sensor LiSS III tem um bit a menos de resolução radiométrica que o ASTER e TM. Pode parecer pouco, mas os 8 bits ($2^8 = 256$) de resolução radiométrica do sensor TM e ASTER representam NDs que variam de 0 – 255, ao passo que os 7 bits ($2^7 = 128$) de resolução radiométrica do sensor LiSS III representam NDs que variam de 0 – 127. Isto corresponde à metade do intervalo ou *range*, no jargão de sensoriamento remoto, possível dos valores de radiância a serem discretizados dentro de um único pixel.

1986) e inferior a 0,5% para o sensor ASTER (FUJISADA, 1994). Por isso, diferentes sensores possuem diferentes magnitudes de erros e estas influenciam na resposta espectral da FOM registrada pelos sensores.

3.3.1 Correlações entre variáveis analisadas sob os diferentes sensores

A matriz de correlação da Tabela 21 mostra o grau de associação entre as variáveis biofísicas e as variáveis espectrais, transformadas ou não, nos três sensores avaliados. No sensor ASTER 30m, como discutido anteriormente, a banda do verde e índice TVI foram as variáveis significativas.

Os sensores LiSS III e TM apresentaram coeficientes de correlação superiores daqueles encontrados no sensor ASTER para estimar as variáveis biofísicas da FOM (Tabela 21).

Tabela 21 - Matriz de correlação entre as variáveis espectrais e biofísicas - transformadas ou não - em cada um dos sensores. Em negrito, os coeficientes de correlação significativos ao nível $\alpha = 0,01$.

	ASTER 30m				LiSSIII				TM			
	Bio	Carb	LnBio	LnCarb	Bio	Carb	LnBio	LnCarb	Bio	Carb	LnBio	LnCarb
ρ Verde	0,55¹	0,56¹	0,47 ²	0,47 ²	0,05	0,05	0,00	0,00	0,10	0,10	0,13	0,13
ρ Verm.	0,16	0,18	0,07	0,08	0,24	0,24	0,21	0,21	-0,57¹	-0,57¹	-0,51 ²	-0,52 ²
ρ IVP	0,52 ²	0,52 ²	0,44 ²	0,44 ²	0,71¹	0,72¹	0,65¹	0,65¹	0,52 ²	0,51 ²	0,48 ²	0,48 ²
SR	0,20	0,18	0,24	0,23	0,36	0,36	0,34	0,34	0,77¹	0,78¹	0,70¹	0,70¹
NDVI	0,22	0,20	0,27	0,26	0,35	0,35	0,33	0,33	0,67¹	0,67¹	0,62¹	0,62¹
TVI	0,57¹	0,57¹	0,49 ²	0,49 ²	0,57	0,57	0,51	0,51	0,53 ²	0,53 ²	0,50 ²	0,50 ²
SAVI	0,52 ²	0,52 ²	0,45 ²	0,45 ²	0,72¹	0,72¹	0,66¹	0,66¹	0,53 ²	0,52 ²	0,50 ²	0,49 ²
EVI _{mod}	0,49 ²	0,49 ²	0,43 ²	0,43 ²	0,71¹	0,71¹	0,66¹	0,66¹	0,56¹	0,55¹	0,52 ²	0,51 ²
Ln ρ Verde	0,45 ²	0,46 ²	0,38	0,38	0,05	0,05	0,01	0,00	0,11	0,10	0,13	0,13
Ln ρ Verm.	0,14	0,15	0,05	0,06	0,22	0,22	0,19	0,19	-0,61¹	-0,61¹	-0,55¹	-0,56¹
Ln ρ IVP	0,50 ²	0,50 ²	0,42	0,42	0,72¹	0,72¹	0,66¹	0,66¹	0,48 ²	0,48 ²	0,46 ²	0,45 ²
LnSR	0,21	0,19	0,26	0,24	0,35	0,35	0,33	0,33	0,74¹	0,74¹	0,68¹	0,68¹
LnNDVI	0,22	0,21	0,27	0,26	0,34	0,34	0,33	0,33	0,66¹	0,66¹	0,62¹	0,62¹
LnTVI	0,54 ²	0,54 ²	0,47 ²	0,47 ²	0,56¹	0,56¹	0,50¹	0,50¹	0,51 ²	0,50 ²	0,48 ²	0,48 ²
LnSAVI	0,50 ²	0,50 ²	0,43 ²	0,43 ²	0,71¹	0,71¹	0,65¹	0,65¹	0,51 ²	0,50 ²	0,48 ²	0,47 ²
LnEVI _{mod}	0,48 ²	0,48 ²	0,42	0,41	0,70¹	0,71¹	0,65¹	0,65¹	0,53 ²	0,52 ²	0,50 ²	0,49 ²

Nota: (1) Significativo ao nível $\alpha = 0,01$;
(2) Significativo ao nível $\alpha = 0,05$;

No sensor LiSS III, foram significativas ao nível $\alpha = 0,01$ as variáveis pIVP, SAVI e EVI_{mod}. Por outro lado, a banda referente ao vermelho do espectro EM foi fracamente correlacionada com a biomassa e o carbono florestal, 0,24 e 0,24, respectivamente, e a correlação da banda do verde com as variáveis biofísicas foi inexpressiva $r = 0,05$. Barati et al. (2011) observaram coeficientes de correlação semelhantes, na ordem de $r = 0,72$ para os seguintes IVs: SAVI, NDVI, SR e MSAVI, gerados pelo sensor LiSS III e as classes de vegetação do Irã central. O maior valor de r encontrado ficou por conta do *Difference Vegetation Index* (DVI), $r = 0,82$.

No sensor TM, o índice espectral SR foi o índice com o maior r encontrado para a biomassa e carbono florestal (0,77 e 0,78, respectivamente), embora não seja significativamente diferente da banda do vermelho, do índice NDVI e do EVI_{mod} ao nível $\alpha = 0,01$. Nota-se que as respostas entre as variáveis espectrais e as variáveis biofísicas, avaliadas em cada sensor, foram muito díspares, pois as bandas ou índices que melhor descreveram as variações das variáveis biofísicas em um sensor não foram as mesmas daquelas observadas pelos outros sensores (Tabela 21).

A contribuição do solo e o efeito da atmosfera na resposta espectral dos índices foi mais sentida no sensor LiSS III do que nos sensores ASTER e TM, por conta do resultado da alta correlação obtida com o índice SAVI e EVI_{mod} (Tabela 21). Este resultado pode ser atribuído à maior resolução espacial e à menor resolução radiométrica deste sensor. Apesar de se tratar de uma floresta fechada existem trilhas entre as parcelas do PELD que podem ter contribuído no efeito aditivo do solo na resposta espectral registrada pelo sensor e este efeito foi mais sentido no sensor com a maior resolução espacial (SAVI/LiSS III). Analogamente, o efeito atmosférico foi mais atenuado no sensor com a menor resolução radiométrica, uma vez que uma pequena contribuição atmosférica no sinal representará um efeito maior no valor convertido de radiância registrado pelo sensor (EVI/LiSSIII).

A baixa correlação em algumas bandas decorre de que mudanças nos valores de biomassa não refletem diretamente mudanças nos valores de reflectância (LU, 2006). Os sensores ópticos atingem apenas o dossel da floresta e este nem sempre está relacionado com a biomassa presente, porque depende de uma série de fatores, tais como estrutura da vegetação, espécies dominantes, composição e estrutura foliar. Este, portanto, é um dos motivos pelos quais se tem utilizado dados

de outras fontes, como de sistemas radares, por exemplo. Os dados de radares “penetram” mais profundamente na vegetação do que os dados ópticos, interagindo com o tronco, os galhos e as copas das árvores, dependendo do comprimento de onda utilizado, aumentando a correlação com a biomassa consequentemente (JENSEN, 2009). Além disso, são insensíveis à presença de nuvens – problema recorrente em florestas tropicais (KOCH, 2010) e neste trabalho com as imagens TM.

Lu (2006) e Steninger (2000) citam que a saturação típica nos IVs com o aumento de biomassa ocorre com valores em torno de 15 kg.m^{-2} , observados na Floresta Ombrófila Densa. Neste trabalho, onde a média de 19 kg.m^{-2} (Tabela 20) não foi observado nítida saturação dos IVs, explicada, em parte, pelas regressões lineares serem mais adequadas que as exponenciais ou logarítmicas para descrever as variações biofísicas, o oposto do esperado.

Nos sensores LiSS e TM, as variáveis transformadas para a base de logaritmo natural foram estatisticamente semelhantes às das variáveis não transformadas. Santos (1988) correlacionando a biomassa foliar do Cerrado (*stricto sensu*) com dados do sensor TM também demonstrou não haver diferenças significativas entre os modelos lineares e exponenciais quanto ao ajuste. Além disso, os resultados encontrados pelo autor evidenciaram que dentre as bandas espectrais, a banda três do TM (pVerm) foi a que obteve maior correlação com a biomassa foliar. Este resultado foi bastante consistente com os dados aqui apresentados.

3.3.2 Análise de regressão

Os diferentes índices e bandas espectrais, em cada um dos sensores avaliados, foram testados para estimar a biomassa florestal mediante análise de regressão linear simples. Os valores de R^2 , S_{yx} e $S_{yx}\%$ desta análise estão descritos na Tabela 22.

Os sensores LiSS III e TM obtiveram maiores valores de R^2 se comparados aos valores de R^2 encontrados no sensor ASTER 30m.

Tabela 22 - Resultado da análise de regressão linear entre a biomassa florestal e as variáveis espectrais obtidas nos três sensores avaliados. Em negrito os mais altos coeficientes.

	ASTER			LiSSIII			TM		
	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)
ρ Verde	0,30	3664,47	21,84	0,00	3497,20	30,71	0,01	4582,26	26,56
ρ Verm.	0,03	4217,08	23,93	0,06	3399,80	29,85	0,32	3986,75	24,80
ρ IVP	0,27	3652,43	20,73	0,51	2456,23	21,57	0,27	3946,28	22,87
SR	0,04	4187,50	23,76	0,13	3269,35	28,71	0,60	2920,16	16,92
NDVI	0,05	4168,41	23,66	0,12	3283,63	28,83	0,45	3425,44	19,85
TVI	0,32	3523,47	20,00	0,32	2887,40	25,35	0,28	3895,00	22,57
SAVI	0,27	3655,97	20,75	0,51	2447,88	21,49	0,28	3906,22	22,64
EVI _{mod}	0,24	3723,71	21,13	0,50	2464,82	21,64	0,31	3816,04	22,12

Nota-se na Tabela 22 que os índices SAVI e EVI_{mod} gerados a partir do sensor LiSS III e a banda espectral referente ao infravermelho próximo obtiveram resultados semelhantes com valores de R^2 variando de 0,51 para o ρ IVP e SAVI e 0,50 para EVI_{mod}. O índice TVI/LiSS obteve mesmo resultado de R^2 do TVI/ASTER, ainda que este tenha tido menor Syx do que aquele (Syx = 20,00% contra Syx = 25,35%).

Madugundu, Nizalapur e Jha (2008) observaram $R^2 = 0,63$ entre o NDVI/LiSS e a biomassa acima do solo em área florestal no sudoeste da Índia, com valores de biomassa variando de 145 - 350 t.ha⁻¹. Em outro estudo na Índia, Kumar et al. (2012) encontraram $R^2 = 0,53$ quando utilizada a banda do vermelho como preditora da biomassa florestal de uma reserva, com valores de biomassa entre 42 - 431 t.ha⁻¹. Porém, o melhor resultado foi com a regressão linear obtida a partir do NDVI/LiSS III, com $R^2 = 0,7$. Os resultados observados por Kumar et al. (2012) foram bastante distintos dos encontrados no presente estudo.

Verifica-se pela Tabela 22 que o índice de razão simples, gerado a partir do sensor TM, foi o índice que apresentou o maior coeficiente de determinação linear ($R^2 = 0,60$) e menor erro padrão relativo da estimativa (Syx % = 16,92). O índice NDVI, gerado a partir das bandas do sensor TM, também apresentou razoável desempenho para estimativa de biomassa florestal, com R^2 de 0,45 e Syx% de 19,85. Contudo, a aplicação destes índices pode apresentar o problema de saturação com altos valores de biomassa. Huete et al. (1997; 2002) demonstraram que os índices mais elaborados como o SARVI2 e o EVI contornam este problema e

ainda apresentam boa correlação com uma gama de valores biomassa, presentes em distintas fisionomias florestais.

Roy e Ravan (1996) encontraram $R^2 = 0,22 - 0,46$ para estimar a biomassa florestal presente em um Parque Nacional na Índia a partir do NDVI/TM. As diferenças observadas pelos autores são referentes à inclusão ou não de parcelas com predominância de arbustos e pastagens na análise. O maior valor observado pelos autores foi obtido quando todas as parcelas foram utilizadas.

Reese et al. (2002) observaram Syx variando de 58 – 80% utilizando-se do algoritmo de k vizinho mais próximo (k -NN) para estimar o volume da Floresta Boreal da Suécia a partir das bandas do sensor TM, em nível de pixel. No entanto, a acurácia da estimativa foi significativamente melhorada em nível de parcela do NFI ($Syx = 17 - 38\%$) e máxima quando agregada em uma área de 100 ha ($Syx = 10\%$). Semelhante observação também havia sido feita por Trotter, Dymond e Goulding (1997) em uma área de floresta plantada da Nova Zelândia. Tratam-se, portanto, de duas regiões com florestas bastante homogêneas e, por isso, a agregação de informações espaciais melhorou as estimativas. Esta situação foi discutida na primeira abordagem do trabalho com relação às estimativas através dos dados ASTER.

Na Tabela 23 estão descritas as estatísticas das análises das regressões lineares para o carbono florestal a partir as variáveis espectrais geradas pelos três sensores. As estatísticas demonstram resultados semelhantes aos encontrados para a biomassa florestal (Tabela 22).

Apesar dos R^2 terem sido inferiores aos encontrados por Watzlawick (2003), os valores de $Syx\%$ foram inferiores aos observados pelo referido autor, que foram de $Syx = 33,90\%$ para o NDVI até $Syx = 46,12\%$ para a banda do vermelho (MS-3) do sensor IKONOS II.

Tabela 23 - Resultado da análise de regressão linear entre o carbono florestal e as variáveis espectrais obtidas nos três sensores avaliados. Em negrito, os mais altos coeficientes.

	ASTER			LiSSIII			TM		
	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)	R^2	Syx (kg)	Syx(%)
ρ Verde	0,31	1456,00	19,97	0,00	1433,92	30,44	0,01	1912,37	26,77
ρ Verm.	0,03	1735,68	23,80	0,06	1392,58	29,56	0,33	1679,76	21,81
ρ IVP	0,27	1504,15	20,63	0,51	1003,67	21,30	0,26	1654,76	23,16
SR	0,03	1732,40	23,76	0,13	1341,86	28,48	0,61	1207,46	16,90
NDVI	0,04	1724,84	23,65	0,12	1347,54	28,60	0,45	1429,30	20,01
TVI	0,32	1451,05	19,90	0,32	1184,40	25,14	0,28	1632,49	22,85
SAVI	0,27	1507,61	20,67	0,51	1002,27	21,28	0,27	1638,20	22,93
EVImod	0,24	1537,53	21,08	0,51	1009,80	21,43	0,31	1601,08	22,41

3.3.3 Análise dos resíduos da regressão

Apesar das estatísticas acima proverem bons resultados sobre a precisão das equações de regressões, pouco se sabe sobre o enviesamento das estimativas e sobre a dispersão destes erros. O gráfico de dispersão dos resíduos, cruzando-se os resíduos padronizados da regressão *versus* as estimativas padronizadas é um bom indicador da qualidade da regressão gerada.

Frisa-se que uma boa distribuição dos resíduos ocorre quando estes se encontram centrados em zero nos dois eixos ortogonais e que 95% destes resíduos estejam situados no intervalo [-2,2]. Sendo assim, nos sensores ASTER e TM, com $N = 21$ UA e no sensor LiSS III, com $N = 26$ UA, o ideal seria que apenas uma UA apresentasse resíduo superior a dois desvios padrões (σ). As UA com desvios superiores a dois desvios foram destacadas. Apenas os resíduos oriundos das regressões lineares da variável biomassa florestal foram gerados, pois os resíduos gerados da variável carbono foram semelhantes, evitando-se assim, a redundância de informações.

A dispersão dos resíduos padronizados provenientes das regressões lineares, estabelecidas com base nos índices e bandas espectrais do sensor ASTER, com resolução espacial de 30 metros, encontra-se na Figura 15.

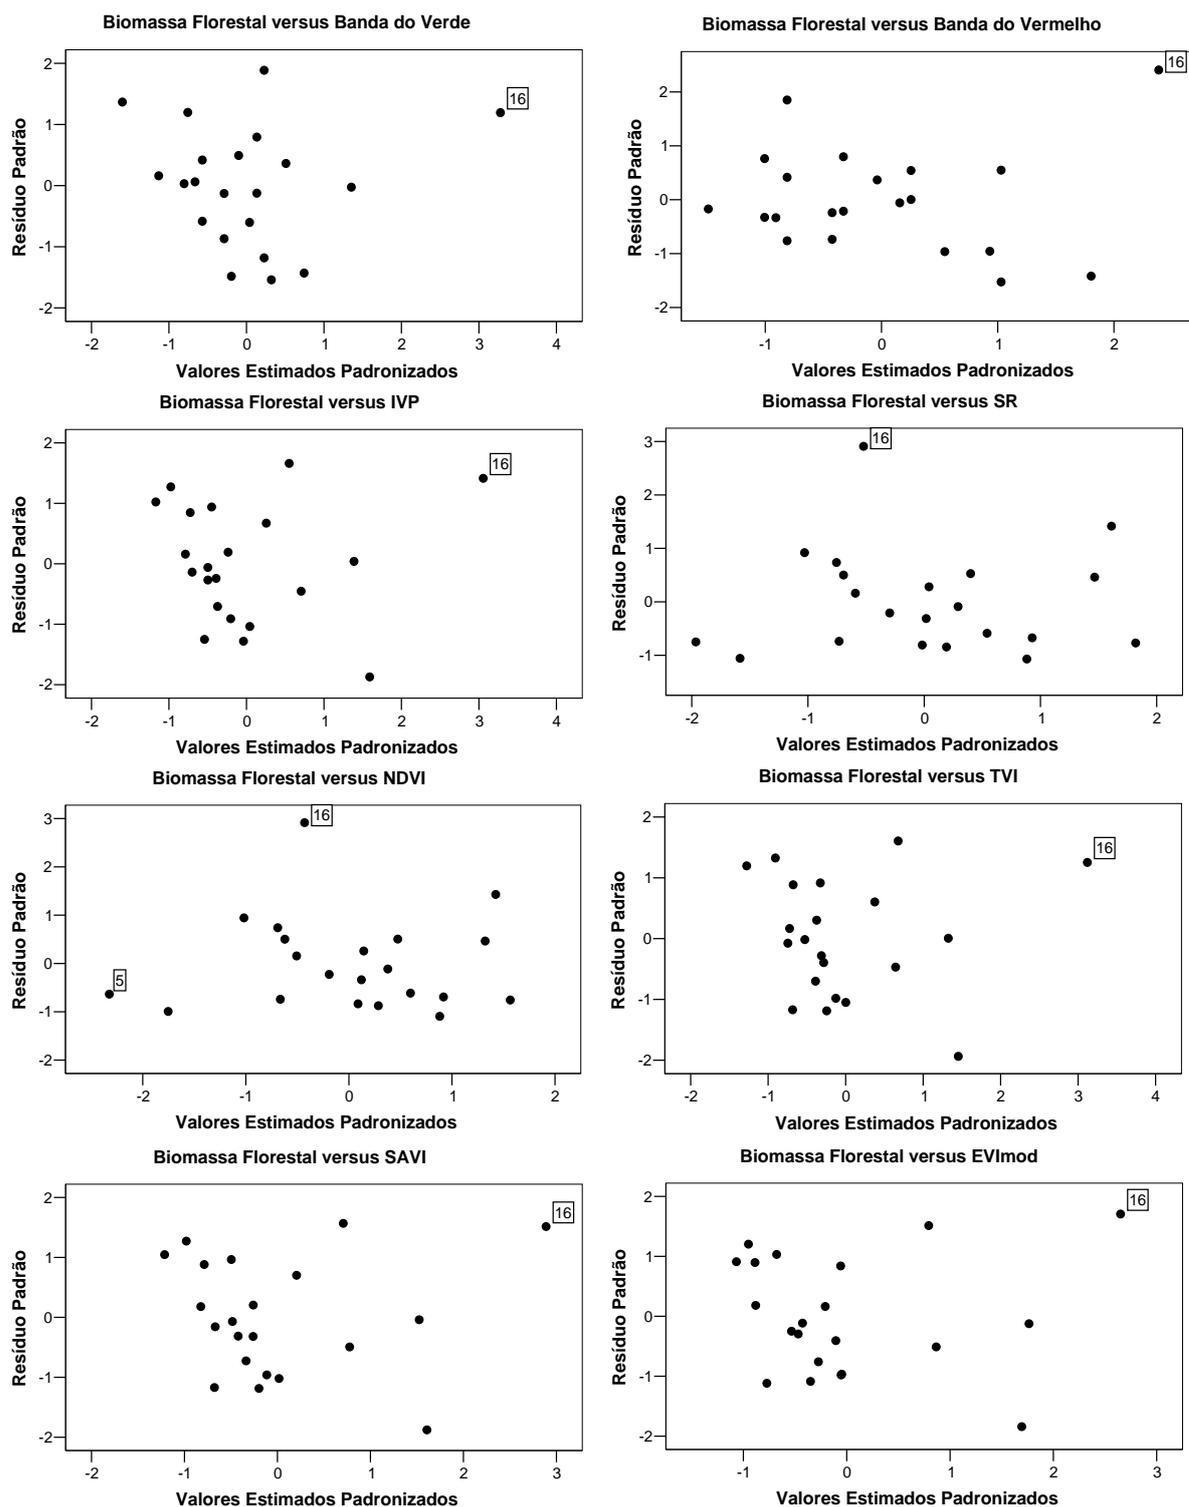


Figura 15 - Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor ASTER versus os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a 2σ estão destacadas.

A dispersão dos resíduos foi consistente com o resultado das estatísticas oriundas da análise de regressão, haja vista que a melhor distribuição dos resíduos ocorreu nas bandas do verde e do IVP/ASTER 30m. De mesmo modo, os baixos

valores de R^2 encontrados para a banda do vermelho e para os índices SR e NDVI como predictoras da biomassa florestal (ver Tabela 22) resultaram em uma dispersão irregular dos resíduos (Figura 15).

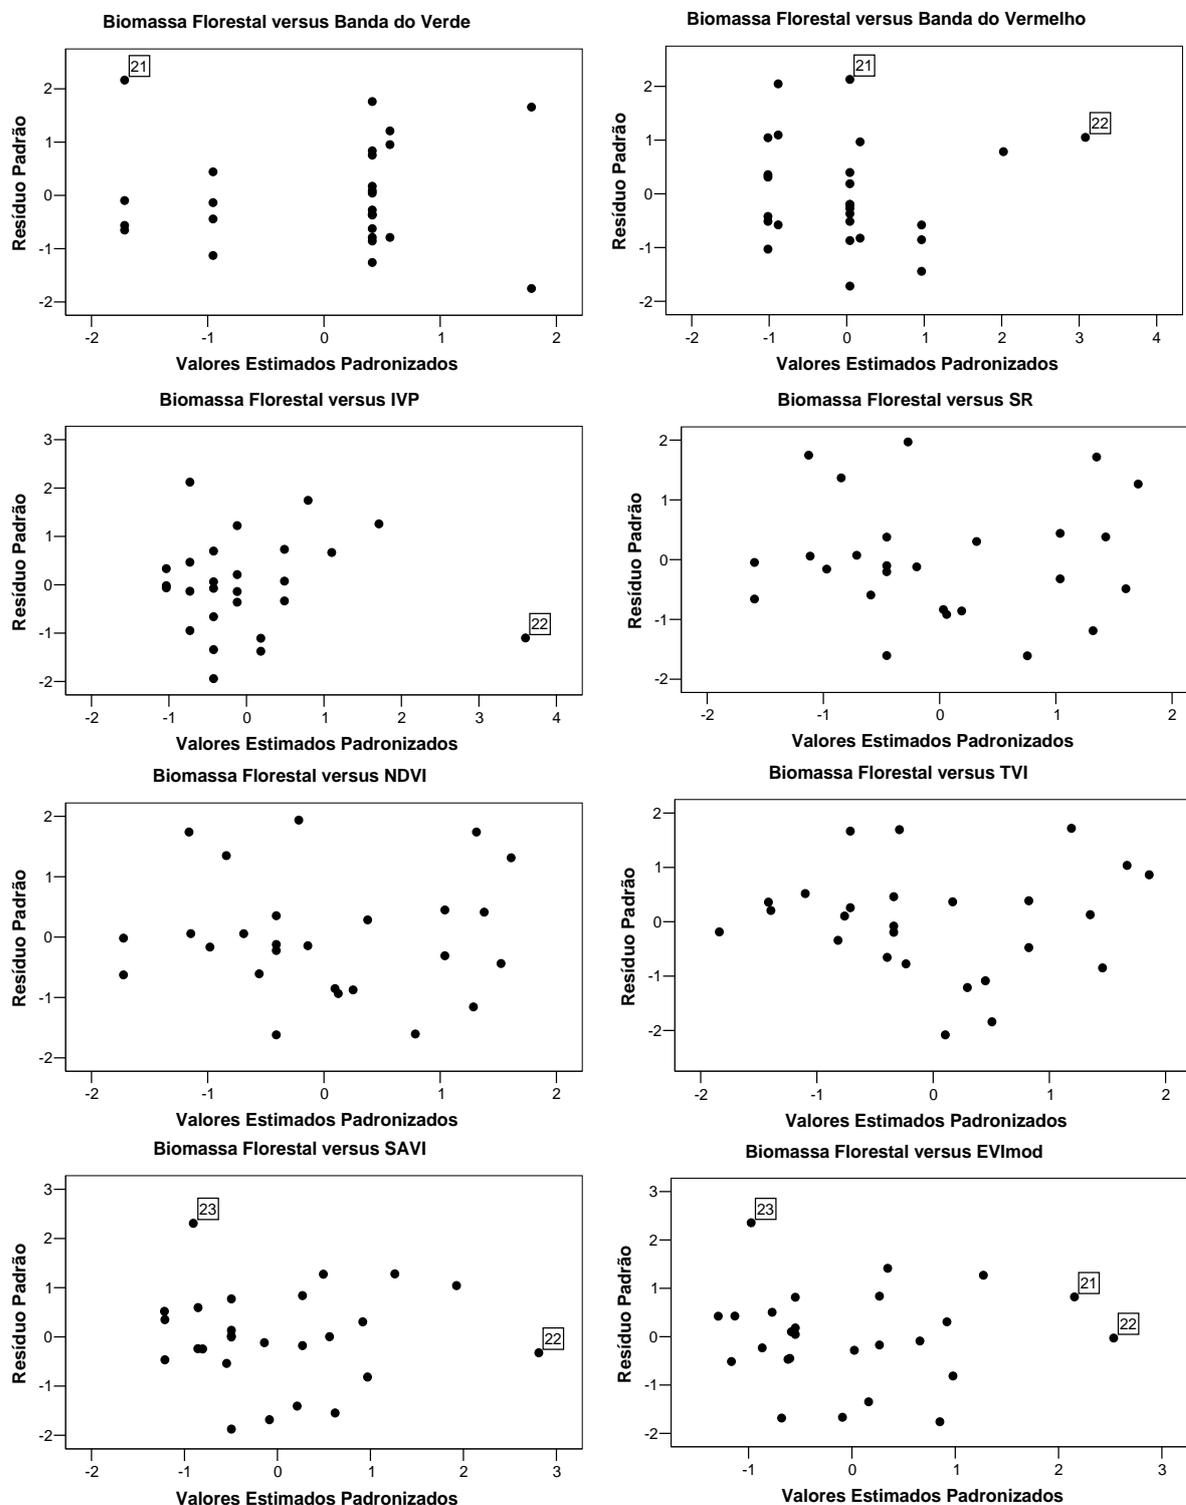


Figura 16 - Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor LiSS III versus os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a 2σ estão destacadas.

Na Figura 16 tem-se a dispersão dos resíduos padronizados das regressões lineares geradas a partir dos dados espectrais do sensor LiSS III, com relação aos valores de biomassa florestal estimados padronizados. As bandas do verde e do vermelho tiveram seus resíduos agrupados em torno de poucos valores, destacando-se uma clara tendência nos valores de biomassa caso fossem estimados a partir destas variáveis espectrais (Figura 16). Embora os coeficientes de determinação das regressões lineares obtidas a partir dos índices SAVI, EVI_{mod} e da banda do IVP estejam em uma mesma ordem de grandeza ($R^2 \approx 0,50$, Tabela 22), esta última apresentou a melhor distribuição dos resíduos padronizados. Além disso, a banda do IVP teve apenas uma UA com desvio superior a dois, enquanto o SAVI apresentou duas e o EVI_{mod}, três.

Na Figura 17 observa-se a dispersão dos resíduos padronizados provenientes das regressões lineares, estabelecidas com base nos índices e bandas espectrais do sensor TM. Semelhante ao observado nos resíduos padronizados provenientes da banda do verde e do vermelho do sensor LiSS III como preditoras da biomassa florestal, estas duas bandas do sensor TM também apresentaram tendência, pois seus resíduos estão agrupados em poucos valores estimados de biomassa florestal. A banda do IVP, porém, teve boa dispersão dos seus resíduos padronizados com apenas uma UA acima de dois desvios padrões.

Dentre os IVs, os índices TVI, SAVI e EVI_{mod} obtiveram dispersão semelhante dos resíduos, não obstante haja uma leve tendência a superestimar os valores de biomassa abaixo da média e de subestimar a biomassa florestal acima da média dos valores estimados nestes três índices (Figura 17). Os índices SR e NDVI, que obtiveram os maiores valores de R^2 (Tabela 22), apresentaram distribuições bastante distintas de seus resíduos, pois apesar de ambos os índices terem UA com resíduos superiores 2σ , o SR teve seus resíduos concentrados à esquerda do gráfico (Figura 17). Em contrapartida, o NDVI que teve menor R^2 calculado se comparado ao SR ($R^2 = 0,45$ contra $R^2 = 0,60$, respectivamente) tem seus resíduos padronizados mais bem distribuídos, com a maioria dos pontos no intervalo $[-1,1]$. O índice SR do sensor TM, portanto, não deve ser um bom preditor da biomassa florestal, pois há um claro viés nos valores estimados (casos 20 e 21 destacados na Figura 17). Estes dois casos foram justamente os que fizeram com que houvesse alto coeficiente de determinação para a regressão deste índice.

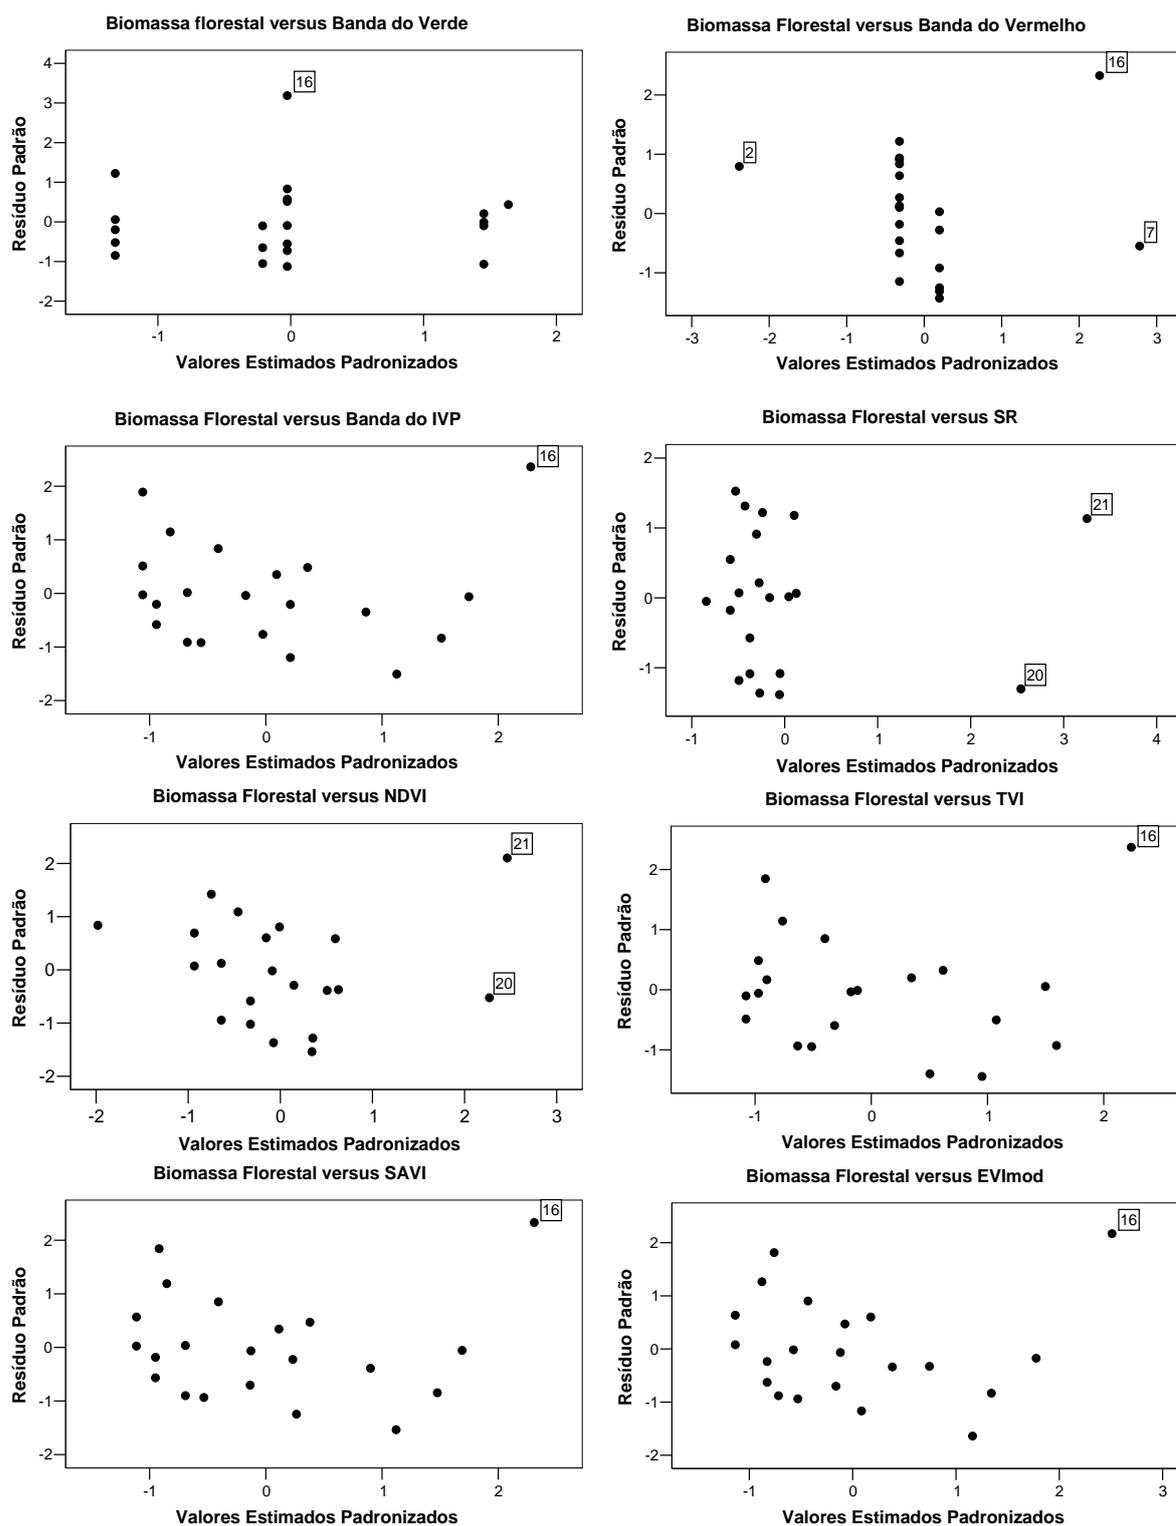


Figura 17 - Gráfico de dispersão dos resíduos padronizados das regressões lineares dos índices e bandas espectrais, gerados a partir dos dados do sensor TM versus os valores estimados padronizados de biomassa florestal. As unidades amostrais com resíduos superiores a 2σ estão destacadas.

3.3.4 Validação das regressões

Os resultados das estimativas de biomassa florestal, por hectare, gerados pelas regressões lineares simples, em cada um dos sensores, com as variáveis espectrais como predictoras estão listados na Tabela 24.

Conforme discutido na seção 3.2.3, as variáveis espectrais do sensor ASTER 30m que alcançaram a maior acurácia em estimar a biomassa florestal foram a banda do IVP e os índices TVI, SAVI e EVI_{mod}, com variações absolutas de -0,28; 0,53; -1,88; -4,10 t.ha⁻¹, respectivamente. Sendo que os dois primeiros foram superiores aos demais, por possuírem maior valor de R^2 e melhor dispersão dos resíduos.

No sensor LiSS III, a banda do infravermelho próximo foi a variável espectral que obteve a menor variação de biomassa florestal, com variação absoluta de apenas 0,60 t.ha⁻¹; também a que teve a melhor distribuição de seus resíduos (Figura 16), ainda que as regressões lineares dos índices SAVI e EVI_{mod} não tenham sido estatisticamente diferentes (ver Tabela 22).

Para o sensor TM, as variáveis espectrais que alcançaram a maior acurácia como predictoras da biomassa florestal foram o NDVI e o EVI_{mod}, com variação relativa de 2,33% e -2,78%, respectivamente. Estatisticamente, o índice SR foi a variável com o maior R^2 e menor $Sy_x\%$ (Tabela 22), mas foi a que teve uma das piores distribuições dos resíduos padronizados (Figura 17) e uma das maiores variações de biomassa florestal, subestimativa de 27,23 t.ha⁻¹ ou relativa de 12,40% (Tabela 24).

Este resultado vem de encontro à máxima de que o melhor desempenho estatístico da análise de regressão confere ao analista o melhor modelo regressor. Foody et al. (2001) observaram resultado semelhante ao avaliar a biomassa da Floresta Tropical do Bornéu, por que embora os valores de r tivessem sido menores que 0,30 nos índices e bandas propostos, a relação entre a biomassa estimada e a observada obteve boa correspondência, com $R^2 = 0,64$.

Tabela 24 - Estimativas de biomassa florestal por hectare, em t.ha⁻¹, geradas a partir das regressões lineares simples.

	ASTER			LISS III			TM		
	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Biomassa (t.ha ¹)	Varição (t.ha ¹)	Varição (%)
Observada	217,75			217,75			219,51		
ρVerde	206,14	-11,62	5,33	202,16	-15,60	7,16	199,50	-20,01	9,12
ρVerm.	202,83	-14,93	6,85	212,46	-5,30	2,43	183,96	-35,55	16,20
ρIVP	217,47	-0,28	0,13	218,36	0,60	-0,28	228,26	8,75	-3,99
SR	193,84	-23,92	10,98	184,67	-33,09	15,19	192,28	-27,23	12,40
NDVI	191,36	-26,39	12,12	182,51	-35,25	16,19	214,40	-5,11	2,33
TVI	218,29	0,53	-0,25	197,98	-19,78	9,08	233,48	13,97	-6,36
SAVI	215,87	-1,88	0,86	203,19	-14,57	6,69	226,38	6,87	-3,13
EVImod	213,66	-4,10	1,88	195,90	-21,85	10,04	225,60	6,09	-2,78

Observada	- biomassa florestal acima do solo observada pela média das quatro parcelas do PELD;
ρ Verde	- banda correspondente ao verde do espectro EM;
ρ Vermelho	- banda correspondente ao vermelho do espectro EM;
ρ IVP	- banda correspondente ao infravermelho próximo do espectro EM;
SR	- índice de vegetação razão simples;
NDVI	- índice de vegetação por diferença normalizada;
TVI	- índice de vegetação triangular;
SAVI	- índice de vegetação ajustado ao solo;
EVImod	- índice de vegetação melhorado modificado

Na Tabela 25 têm-se os resultados das estimativas de carbono florestal, obtidos por meio das regressões lineares e tomando-se as variáveis espectrais (bandas e IVs) como predictoras. Como esperado, os resultados foram coincidentes com os resultados observados para a biomassa florestal. No entanto, as variações entre o carbono florestal observado e o estimado foram ainda menores do que as observadas para a biomassa.

Tabela 25 - Estimativas de carbono florestal por hectare, em t.ha⁻¹, geradas a partir das regressões lineares simples.

	ASTER			LISS III			TM		
	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)	Carbono (t.ha ¹)	Varição (t.ha ¹)	Varição (%)
Observada	90,19			90,19			90,93		
ρVerde	90,15	-0,04	0,04	83,65	-6,53	7,24	82,56	-8,37	9,21
ρVerm.	84,16	-6,03	6,68	87,94	-2,25	2,50	87,51	-3,42	3,77
ρIVP	90,01	-0,17	0,19	90,28	0,09	-0,10	94,41	3,48	-3,83
SR	80,30	-9,89	10,97	76,48	-13,71	15,20	79,61	-11,32	12,45
NDVI	79,34	-10,85	12,03	75,59	-14,60	16,19	88,83	-2,10	2,31
TVI	90,34	0,16	-0,17	81,90	-8,28	9,19	96,60	5,67	-6,24
SAVI	89,33	-0,86	0,96	84,03	-6,16	6,83	93,64	2,71	-2,98
EVImod	88,38	-1,81	2,01	81,05	-9,13	10,13	93,34	2,41	-2,65

3.3.5 Equações de regressão lineares múltiplas

As equações de regressão lineares múltiplas foram testados nos dados espectrais dos sensores LiSS III e TM (regressões múltiplas das variáveis do sensor ASTER já foram testadas, ver seção 3.2.5), mediante o método *stepwise* de seleção de variáveis. As variáveis espectrais utilizadas para alimentar os modelos foram as bandas espectrais e os IVs dos respectivos sensores, transformadas ou não para logaritmo natural.

Na Tabela 26 se observam as equações de regressão obtidas pelos critérios de significância de inclusão e remoção de variáveis, 5% e 10%, respectivamente para o sensor LiSS III. Nota-se que a equação N° 1 forneceu um razoável R^2 aj. e pequena variação relativa de biomassa e de carbono florestal, utilizando-se a banda do IVP transformada para logaritmo natural como variável preditora.

Embora o coeficiente de determinação ajustado para a primeira equação tenha sido superior ao R^2 da regressão linear simples com a mesma variável IVP não transformada, esta foi superior em estimar a biomassa florestal, pois teve menor variação em comparação àquele (ver Tabela 22). Mesma inferência pode ser feita para o carbono florestal.

Tabela 26 - Equações de regressão lineares múltiplos significativos para as variáveis espectrais provenientes do sensor LiSSIII.

Biomassa						
N	Equações de regressão	R^2 aj.	Syx (kg)	Syx (%)	Biomassa (t.ha ¹)	Varição (%)
1	$Y = 88628,76 + 40870,34.LnpIVP$	0,52	2436,23	21,39	219,27	-0,70
2	$Y = e^{5,71 + 13,11.SAVI}$	0,43	2443,11	21,97	198,87	8,67
Carbono						
N	Equações de regressão	R^2 aj.	Syx (kg)	Syx (%)	Carbono (t.ha ¹)	Varição (%)
1	$Y = 36478,80 + 16809,38.LnpIVP$	0,52	995,75	21,14	90,66	-0,52
2	$Y = e^{4,84 + 13,04.SAVI}$	0,43	999,96	21,73	82,28	8,77

Pelo gráfico de dispersão dos resíduos padronizados das equações não lineares para a biomassa e carbono florestal, geradas a partir dos dados espectrais do sensor LiSS III (Figura 18), verifica-se que a equação N° 1 não teve boa distribuição dos resíduos, além de possuir duas UA com valores de resíduos

superiores a dois desvios padrões. A dispersão dos resíduos da equação N° 2 foi um pouco superior, mas teve três UA com resíduos padronizados superiores a 2σ . O modelo linear está em um mesmo grau de acurácia do modelo não linear, mas foi selecionado pela facilidade de manuseio e geração dos mapas contendo as estimativas.

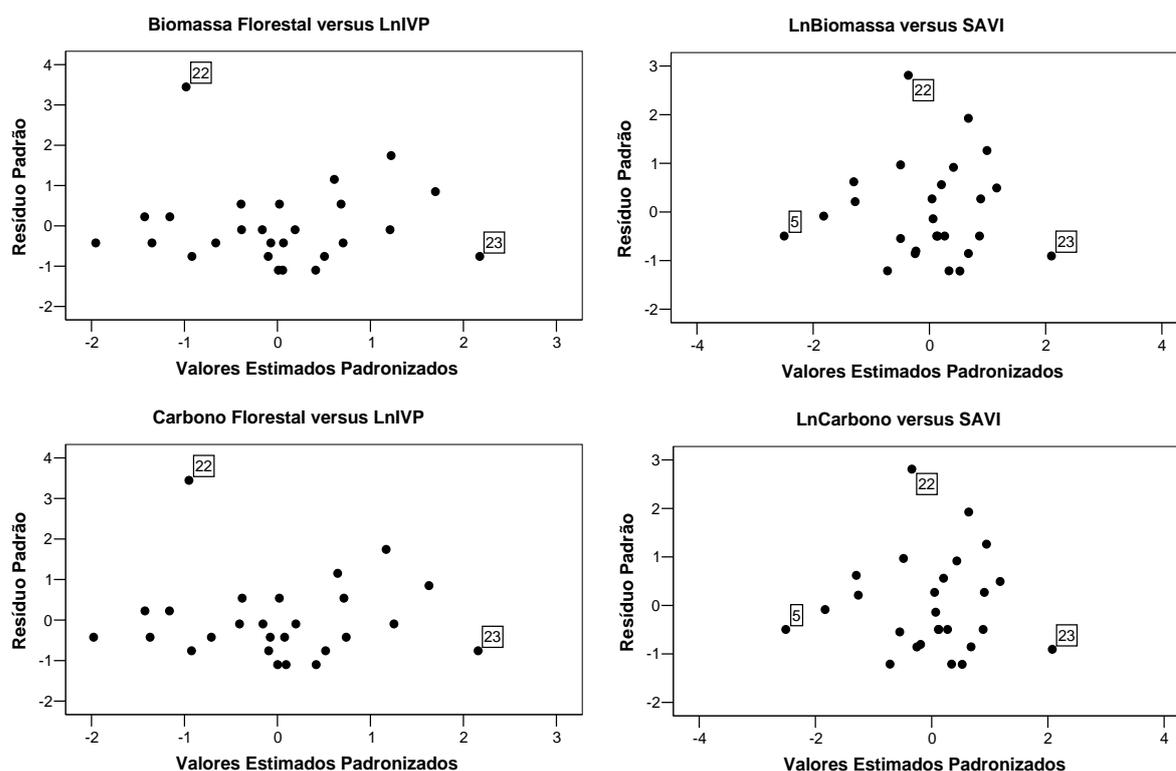


Figura 18 - Gráfico de dispersão dos resíduos padronizados gerados pelas regressões não lineares dos índices e bandas espectrais, a partir dos dados espectrais do sensor LiSS III, versus os valores estimados padronizados de biomassa florestal (acima) e versus os valores estimados padronizados de carbono florestal (abaixo). As unidades amostrais com resíduos superiores a 2σ estão destacadas.

Na Tabela 27 têm-se as equações de regressões significativas para estimar a biomassa e o carbono florestal da EESJT utilizando-se as variáveis espectrais do sensor TM, transformadas ou não, como preditoras. A equação N° 1, gerada para estimar a biomassa florestal a partir do índice SR e da banda do vermelho transformada para logaritmo natural, apresentou alto R^2_{aj} (0,64) e baixo $Sy\%$ (15,54%). Entretanto, sua utilização na estimativa da área da EESJT não foi possível, devido a presença de alguns pixels com valores de ρ negativos na banda do vermelho. Estes valores negativos constituem-se em erros que abrangem apenas algumas áreas limítrofes da estação. A origem destes erros não pôde ser detectada,

mas a causa pode ser a repentina degradação radiométrica do sensor, já que a imagem foi adquirida no último mês de recepção de vida do sensor em órbita (NASA, 2013), conforme descrito na seção 2.3.3.

A equação exponencial N° 2 obteve um resultado satisfatório, pois gerou baixo erro padrão da estimativa, razoável R^2_{aj} e, principalmente, uma baixa variação de biomassa florestal por hectare. No entanto, a equação de regressão linear simples, gerado a partir do NDVI deste mesmo sensor foi superior a estas não lineares, pois teve variação inferior de biomassa florestal por hectare e, notadamente, por apresentar melhor distribuição dos resíduos padronizados (Figura 19). Roy e Raven, (1997) utilizando-se do método *stepwise* observaram R^2_{aj} de 0,64 quando os índices *Greeness* e *Wetness* da transformação *Tassled Cap* do sensor TM foram usados como preditores da biomassa.

Tabela 27 - Equações de regressão lineares múltiplos significativos para as variáveis espectrais provenientes do sensor TM.

Biomassa						
N	Equações de regressão	R^2_{aj}	Syx (kg)	Syx (%)	Biomassa (t.ha ¹)	Varição (%)
1	$Y = 62051,91 + 260,99.SR + 10389,5.LnpVerm.$	0,64	2681,87	15,54	**	**
2	$Y = e^{9,4 + 0,0065.SR}$	0,49	2879,38	16,92	213,25	2,85
Carbono						
N	Equações de regressão	R^2_{aj}	Syx (kg)	Syx (%)	Carbono (t.ha ¹)	Varição (%)
1	$Y = e^{8,52+0,0066.SR}$	0,50	1188,15	16,86	88,43	2,74

** Não foi possível utilizar tal equação tendo em vista que havia valores de ρ negativos na área da EESJT.

Os resíduos padronizados gerados pelas regressões não lineares foram menos bem distribuídos que aqueles gerados pelas regressões lineares simples deste mesmo sensor, especialmente, utilizando-se o NDVI como preditor destas variáveis biofísicas (Figura 19).

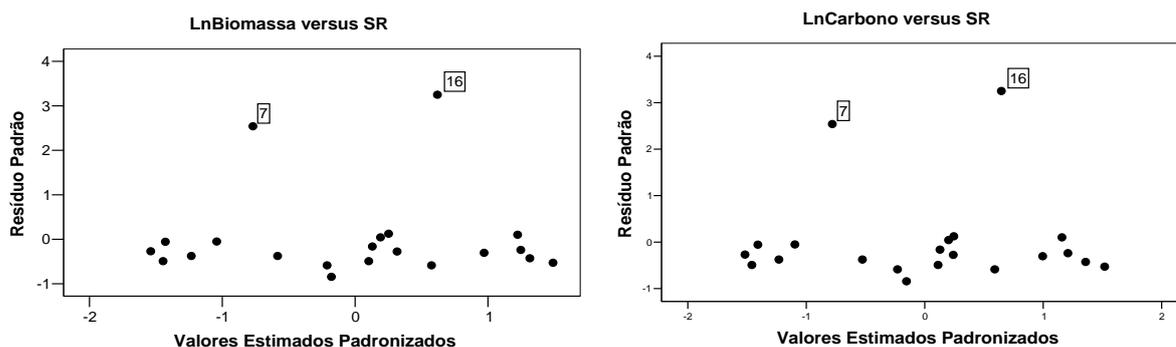


Figura 19 - Gráfico de dispersão dos resíduos padronizados gerados pelas regressões não lineares dos índices e bandas espectrais, a partir dos dados espectrais do sensor TM.

3.4 MAPAS DE BIOMASSA E CARBONO FLORESTAL

Os mapas contendo as distribuições de biomassa e de carbono florestal foram confeccionados mediante as equações de regressões que obtiveram os melhores resultados, ou seja, aquelas que foram superiores estatisticamente, que contiveram seus resíduos mais bem distribuídos e, especialmente, que obtiveram a menor variação de biomassa e estoque de carbono na área de estudo.

Dessa forma, uma equação para cada sensor foi selecionada e os mapas temáticos foram gerados, em que cada pixel passou a representar os valores biomassa e de carbono florestais estimados. Posteriormente, a distribuição espacial destas variáveis biofísicas foi analisada e comparada. Para facilitar esta análise, a biomassa florestal foi separada em classes de 2,5 t e o carbono em classes de 1,5 t.

3.4.1 Sensor ASTER

A regressão utilizada para confeccionar o mapa temático de biomassa florestal a partir dos dados espectrais do sensor ASTER 30m foi a seguinte Equação 15:

$$y = 1071111 x IVP - 6167 \quad (15)$$

Equação 15 - Equação de regressão utilizada para estimar a biomassa florestal estabelecida com base nos valores de reflectância do infravermelho próximo do sensor ASTER.

Onde o IVP representa os valores de reflectância do sensor ASTER 30m, banda 3N e y o valor de biomassa florestal, em quilogramas.

Na Figura 20 observa-se o mapa temático de biomassa florestal, gerado a partir da equação supracitada. Nota-se que há uma boa correspondência dos valores de biomassa florestal com as parcelas permanentes do PELD, visto que as parcelas que contêm os maiores valores de biomassa florestal se encontram à direita da EESJT, como, por exemplo, a Parcela Imbuia (localizada no canto superior direito da área de estudo, ver Figura 8 e Tabela 6).

É interessante notar que há uma similaridade entre o mapa de biomassa gerado a partir dos dados do sensor ASTER e o mapa de distribuição dos dosséis florestais da área de estudo (Figura 8), pois os locais com valores mais baixos de biomassa florestal, em quilogramas por pixel, coincidem com os locais de predominância da Araucária no dossel, assim como, as áreas com os maiores valores de biomassa florestal coincidem com a predominância de folhosas no dossel. Bajracharya (2008) observou índice Kappa de 0,77 na classificação de florestas manejadas e não manejadas no Nepal com o uso do sensor ASTER, apesar das baixas correlações encontradas pelos autores entre a biomassa e os índices espectrais, mostrando ser um sensor adequado para caracterizar as diferentes estruturas da floresta.

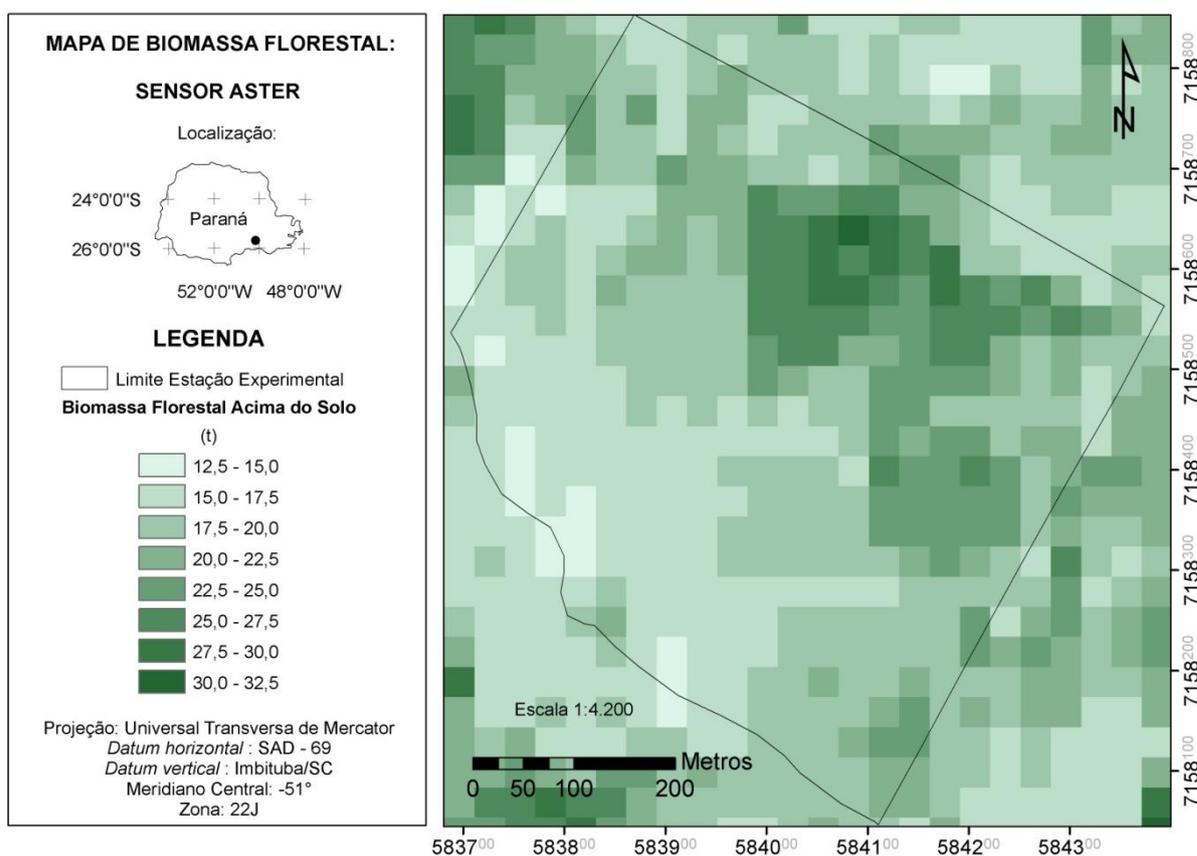


Figura 20 - Mapa de Biomassa Florestal na área da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor ASTER.

A Equação 16, abaixo, foi utilizada para se estimar o carbono florestal a partir do índice *Triangular Vegetation Index* do sensor ASTER 30m, sendo a variável espectral deste sensor com a melhor correlação com o carbono florestal.

$$y = 727,77 x TVI - 2178,2 \quad (16)$$

Equação 16- Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base no índice TVI do sensor ASTER.

Onde o TVI é índice triangular calculado a partir das bandas espectrais do ASTER 30m e y o carbono florestal em quilogramas por pixel.

O mapa temático de estoque de carbono, elaborado a partir da variável TVI como preditora, encontra-se na Figura 21. Verifica-se que há uma alta correspondência do mapa de carbono florestal com o mapa de biomassa florestal obtido com os dados do mesmo sensor, devido à alta relação entre estas variáveis biofísicas.

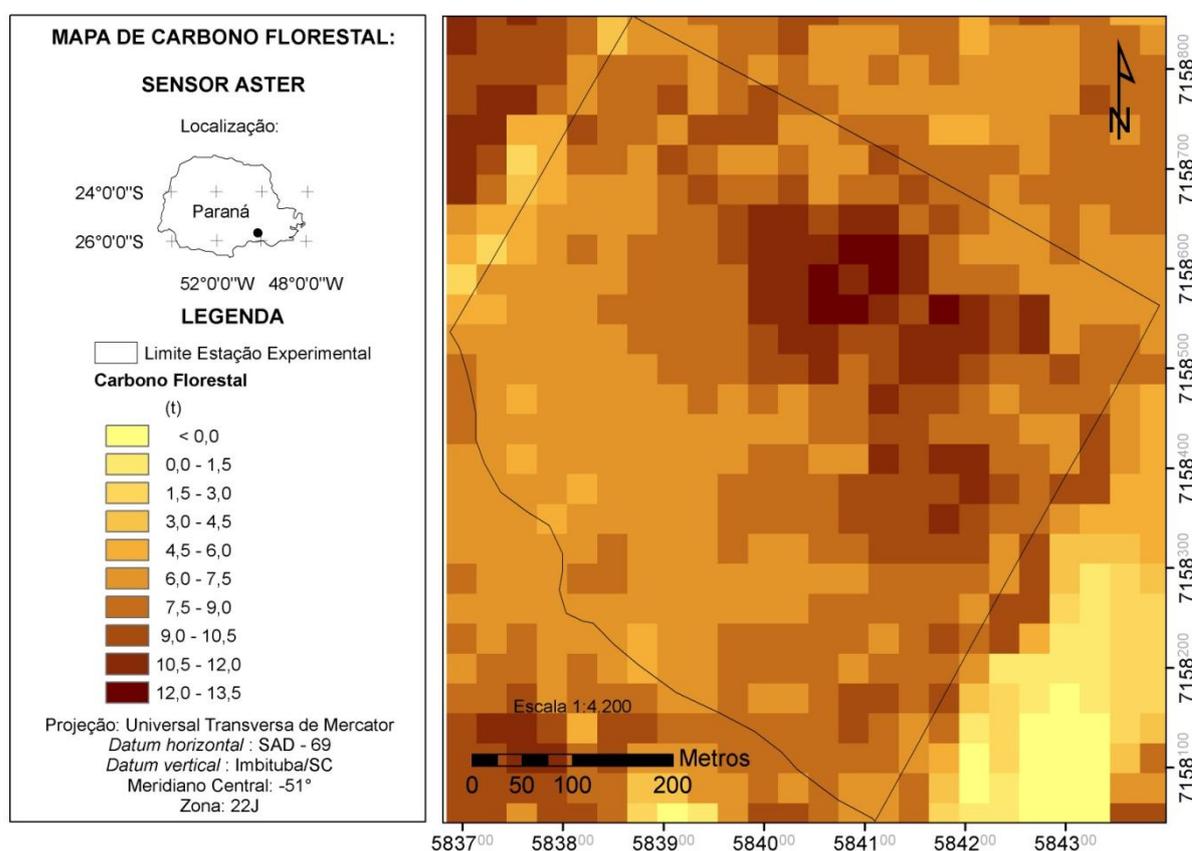


Figura 21 - Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear do índice TVI do sensor ASTER.

A área da EESJT com seus 32,48 ha abrange 361 pixels do sensor ASTER com resolução espacial de 30 metros (900 m²). A frequência dos valores de carbono florestal, em toneladas por pixel, encontrados na área estão na Figura 22, bem como as estatísticas básicas desta distribuição.

A distribuição das frequências de carbono florestal segue a distribuição quase normal, com maior quantidade de carbono entre 7 – 8 t (900 m²). O valor médio observado foi de 8,62 toneladas por pixel e soma de 2927,13 t.C. O valor médio de 90,12 t.ha⁻¹ difere-se dos 90,01 t.ha⁻¹ estimados pela mesma regressão linear (Tabela 23), devido aos erros inerentes de georreferenciamento entre os softwares.

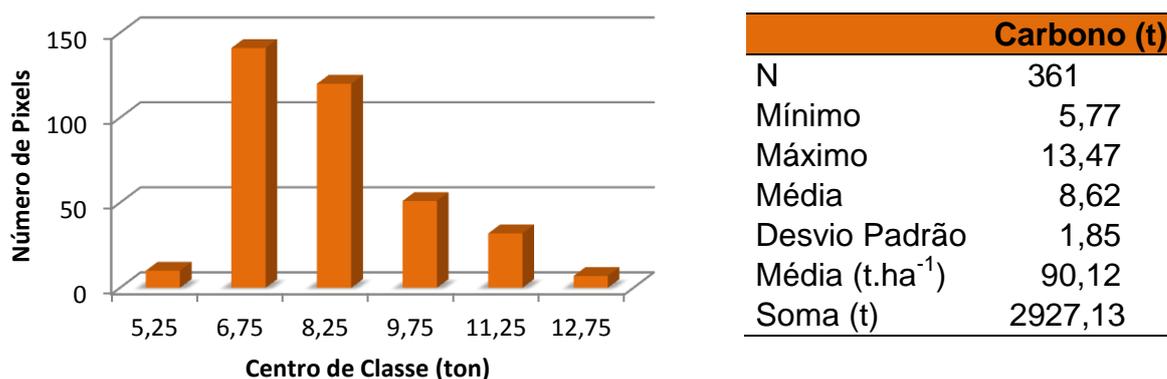


Figura 22 - Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor ASTER.

3.4.2 Sensor LiSS III

A equação que melhor descreveu as variações de biomassa florestal na área de estudo, obtida pelo sensor LiSS III foi a seguinte Equação 17:

$$y = 253677 x \text{ IVP} - 27012 \quad (17)$$

Equação 17 - Equação de regressão utilizada para estimar a biomassa florestal mediante a banda do IVP do sensor LiSSIII como preditora.

Onde o IVP refere-se aos valores de reflectância correspondentes à banda três do sensor LiSS III e y ao valor de biomassa florestal em quilogramas por pixel.

Na Figura 23 tem o resultado do mapa temático com os valores de biomassa florestal, gerados através da Equação 17 e separados em classes de 2,5 t. Devido a maior resolução espacial do sensor LiSS III, o mapa tem menor variabilidade espacial - aspecto suavizado - se comparado ao mapa gerado pelo ASTER. Contudo, possui bastante semelhança com o mapa de biomassa florestal confeccionado a partir da banda do IVP do sensor ASTER.

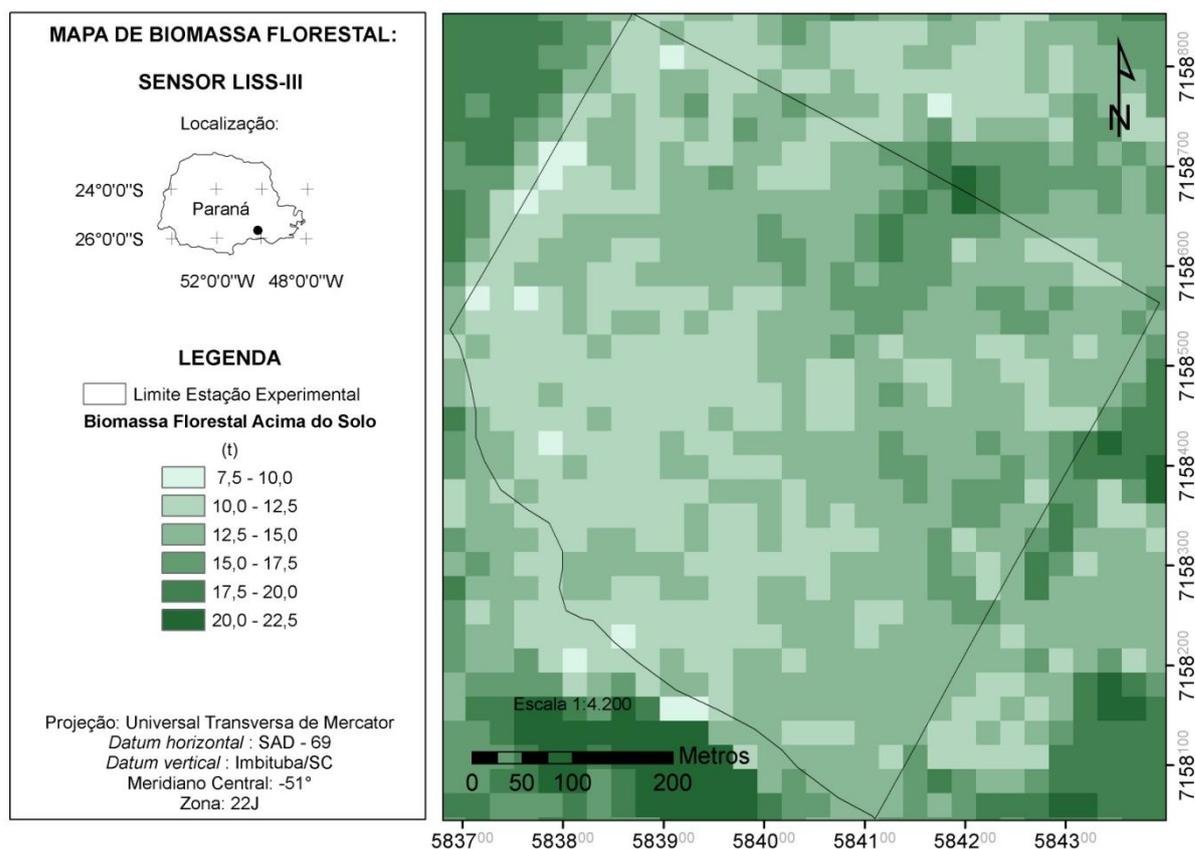


Figura 23 - Mapa de Biomassa Florestal da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor LiSS III.

O sensor LiSS III apresentou índice Kappa de 0,81 na classificação das distintas tipologias florestais em um estudo sobre uma reserva florestal na Índia com biomassa florestal variando de 42 - 431 t.ha⁻¹ (KUMAR et al. 2012). Mostrando-se também ser bastante adequado para a classificação temática de uma ampla variedade de valores de biomassa florestal.

A Equação 18, abaixo, foi utilizada para a estimativa de carbono florestal mediante uso da banda do infravermelho próximo do sensor LiSS III.

$$y = 104369 x \text{ IVP} - 11088 \quad (18)$$

Equação 18 - Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base na banda IVP do sensor LiSS III.

Onde IVP a banda do infravermelho próximo e y o carbono florestal, em quilogramas por pixel. O mapa temático com a distribuição de carbono florestal a cada 1,5 t pode ser visualizado na Figura 24.

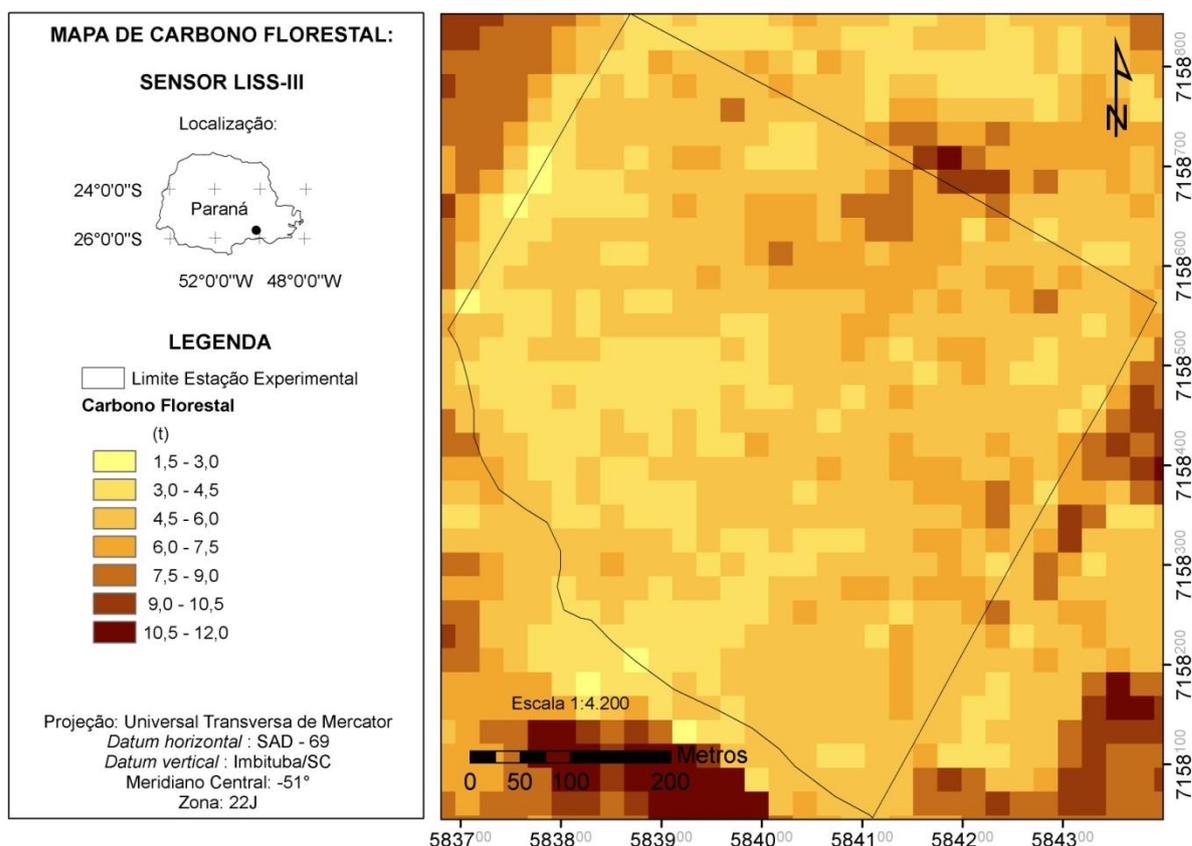
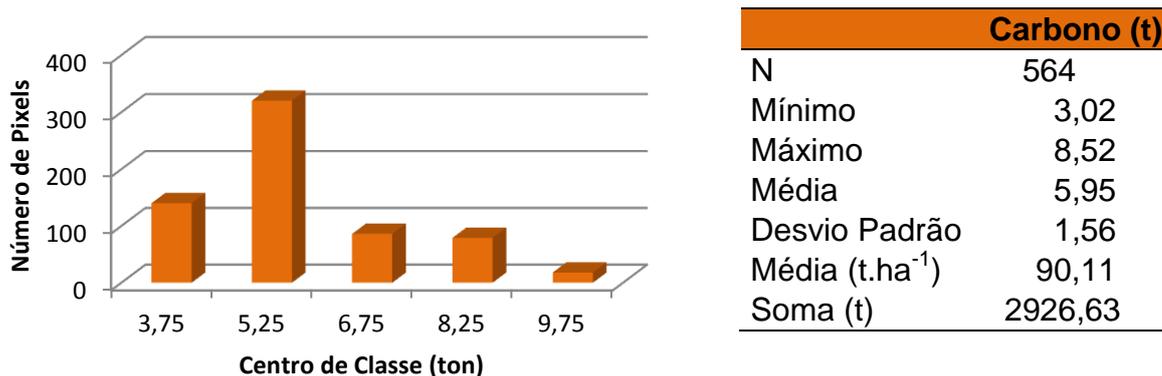


Figura 24 - Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear da banda do IVP do sensor LiSS III.

Como o sensor LiSS III tem 24 m de resolução espacial (576 m²) são necessários 564 pixels para perfazer a totalidade da área de estudo. Assim, os valores de carbono florestal em toneladas por pixel diminuem e explicam a menor média e amplitude de carbono observadas na Figura 25. Interessante seria diminuir os intervalos de classe para este sensor para realçar as diferenças, contudo preferiu-se deixar como estão por permitir uma melhor comparação entre os três sensores.

Pela distribuição das frequências, na mesma figura, verifica-se que as variações de carbono seguem uma distribuição próxima a normal, com média em 5,95 toneladas por pixel e soma de 2926,63 toneladas de C. Nota-se que há uma razoável semelhança na forma de distribuição dos valores de carbono do sensor LiSS III com as do sensor ASTER.



Carbono (t)	
N	564
Mínimo	3,02
Máximo	8,52
Média	5,95
Desvio Padrão	1,56
Média (t.ha ⁻¹)	90,11
Soma (t)	2926,63

Figura 25 - Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor LiSS III.

3.4.3 Sensor TM

No sensor TM, a variável espectral que obteve o melhor resultado para prever a biomassa florestal foi o NDVI, com a seguinte Equação 19:

$$y = 255258 x NDVI - 226622 \quad (19)$$

Equação 19 - Equação de regressão utilizada para estimar a biomassa florestal, estabelecida com base no índice NDVI do sensor TM.

Onde NDVI é o índice de vegetação por diferença normalizada calculado a partir das bandas espectrais do sensor TM e y é o valor de biomassa florestal, em quilogramas por pixel.

Observa-se que o resultado do mapa foi bastante confuso, com a presença de valores extremos (pixels verde-escuros e verdes claros) deslocados das áreas onde se sabe que contém altos valores de biomassa (Figura 26). O sensor TM apresentou resultados pouco confiáveis, porque o mapa gerado pelo modelo inverso do NDVI com as distribuições de carbono florestal na EESJT apresentou alguns ruídos, representados por pixels com valores inconsistentes com a realidade, como valores negativos de biomassa; Estes ruídos podem ser decorrentes da rápida degradação radiométrica do sensor, que levou a sua inativação logo em seguida (NASA, 2013) e não da inadequabilidade deste sensor em estimar as variáveis biofísicas, portanto;

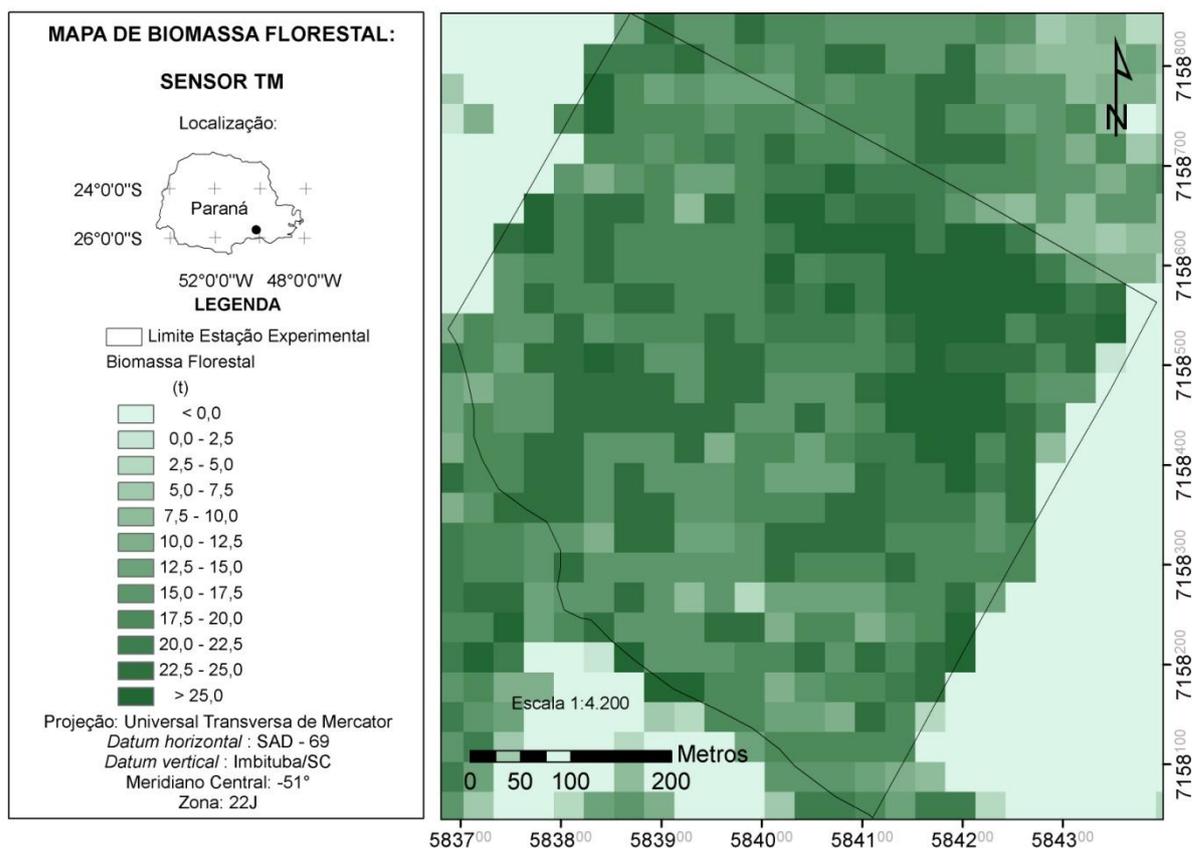


Figura 26 - Mapa de Biomassa Florestal da ESSJT, gerado a partir da regressão linear do índice NDVI do sensor TM.

O carbono florestal da EESJT foi estimado pelo mesmo índice NDVI do sensor TM, com a seguinte Equação 20:

$$y = 106510 \times NDVI - 94618 \quad (20)$$

Equação 20 - Equação de regressão utilizada para estimar o carbono florestal, estabelecida com base no índice NDVI do sensor TM.

Onde NDVI é o índice de vegetação por diferença normalizada calculado a partir das bandas espectrais do sensor TM e y é o valor de biomassa florestal, em quilogramas por pixel.

O mapa com as distribuições espaciais de carbono florestal, separados em intervalos de 1,5 t, estimados mediante a regressão linear supracitada, encontra-se na Figura 27. O resultado do mapa temático demonstra uma clara correspondência com o mapa de biomassa florestal gerado pelo mesmo sensor.

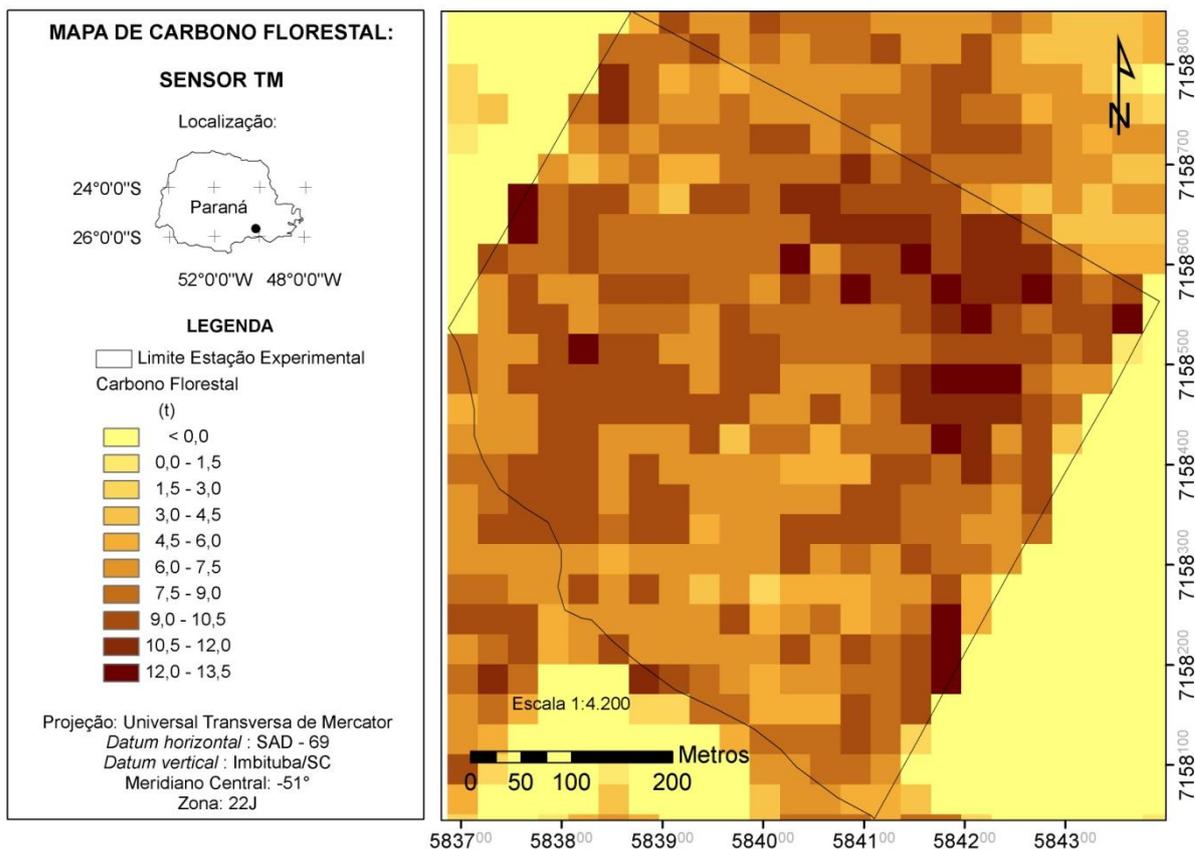


Figura 27 - Mapa de Carbono Florestal da ESSJT, gerado a partir da regressão linear do índice NDVI do sensor TM.

Na Figura 28 estão distribuídos os valores de carbono florestal, gerados a partir dos dados de NDVI do sensor TM, separados em classes de três toneladas por pixel ou três toneladas a cada 900 m². Nota-se que, além do possível ruído superestimando a biomassa e o carbono comentado anteriormente, gerou-se, na área, valores negativos de carbono florestal, o que seria impossível fisicamente. O que ocorreu é que os valores de NDVI que estimaram os pixels negativos de carbono florestal encontravam-se fora da amplitude dos valores de NDVI utilizados para gerar a equação de regressão. Quando realizado o procedimento inverso, estes valores baixos de NDVI geraram valores negativos de carbono florestal.

Estes ruídos estão provavelmente associados à degradação do componente eletrônico deste sensor e que determinou o fim da missão do Landsat 5, conforme notificado pela Agência Norte-Americana.

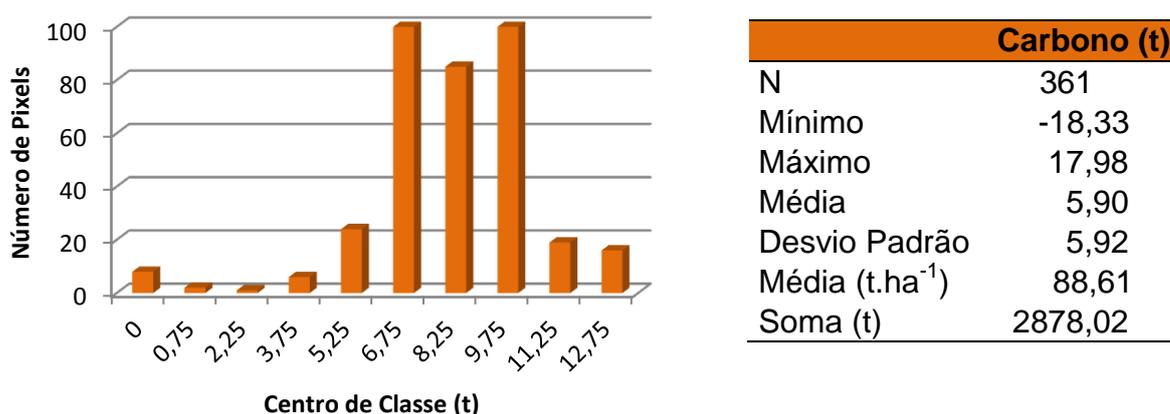


Figura 28 - Distribuição das frequências de carbono florestal, em toneladas por pixel (esquerda); Estatísticas básicas da estimativa (direita) geradas a partir do sensor TM.

3.5 MERCADO DE CARBONO: CONTEXTO DO REED⁺

O cenário de REDD⁺ foi criado tomando-se o montante de carbono florestal estimado na área da EESJT pelo sensor ASTER com relação ao serviço ambiental prestado pela floresta. Para isso, foi criado um cenário atual e futuro de fixação de CO₂e atinentes a um projeto REDD⁺.

O cenário atual representa o atual valor estimado de CO₂e estocado, calculado mediante a regressão linear da banda IVP/ASTER 30 m. O cenário de final de projeto refere-se ao montante de CO₂e obtido pela projeção de carbono florestal acumulado no decorrer dos 40 anos do projeto, por meio do cálculo de incremento de carbono florestal, supondo-se que a variável CO₂e se comportasse segundo a lei dos juros compostos (Equação 21):

$$M = P \times (1 + IPA)^n \quad (21)$$

Equação 21 - Montante de carbono florestal, a partir da lei dos juros compostos.

Onde M é o montante de CO₂e, em toneladas, no final do período de realização do projeto; P é o valor atual de CO₂e (linha base), em toneladas, IPA é o Incremento Periódico Anual e n o período de duração do projeto.

Por fim, a adicionalidade diz respeito à redução de emissão de CO₂e propriamente dita, proveniente da não utilização dos recursos naturais diretos da floresta. Refere-se exclusivamente ao incremento total, em toneladas de carbono,

observada pela diferença entre o início do projeto (linha base) e o seu final, sendo um dos pré-requisitos de criação do referido projeto. A compensação financeira dos cenários criados pode ser visualizada na Tabela 28.

Tabela 28 - Cenário de REDD⁺ para a área de estudo.

Cenário	ASTER	
Características do Projeto	Taxa de Desmatamento	0,00%
	Período	40 anos
	Incremento Periódico Anual	0,82%
	Área (ha)	32,48
Atual	C (t.ha ⁻¹)	90,12
	C total (t)	2927,13
	CO ₂ e (t.ha ⁻¹)	330,44
	CO ₂ e total (t)	10732,82
	R\$.ha ⁻¹	4093,36
	R\$ total	132953,88
Final de Projeto	CO ₂ e (t.ha ⁻¹)	458,11
	CO ₂ e total (t)	14879,27
	R\$.ha ⁻¹	5674,88
	R\$ total	184318,44
	R\$.ha ⁻¹ .ano ⁻¹	141,87
Adicionalidade	Redução de CO ₂ e (t)	4146,45
	CO ₂ e t.ha ⁻¹ .ano ⁻¹	3,19
	R\$.ha ⁻¹ .ano ⁻¹	39,53

No cenário atual, a EESJT retém 10,7 Mt de CO₂e em sua biomassa, podendo chegar a 14,9 Mt CO₂e ao final do projeto. Incremento de 4,1 Mt CO₂e ou 3,19 t.ha⁻¹.ano⁻¹. O valor de 330,44 t.ha⁻¹ CO₂e estimado no cenário atual é superior às 284,27 t.ha⁻¹ CO₂e estimadas na FOM de General Carneiro por Mognon (2011).

Levando-se em conta apenas a redução de emissões de CO₂e (adicionalidade), a partir da linha base 2010, 4146,45 t.CO₂e seria evitada de ser liberada na atmosfera, compensando um valor de R\$ 39,53 ha.ano⁻¹, superior aos R\$ 25,93 ha.ano⁻¹ calculados por Mognon (2011). É claro que este é um cenário otimista, porque foi considerado um IPA constante e desconsideradas as perdas de CO₂ decorrentes de distúrbios naturais (p.ex. incêndios, queda de árvores, etc.).

De outro modo, a biomassa presente no sub-bosque e a biomassa abaixo do solo não foram contabilizadas no cálculo total, o que indubitavelmente aumentaria o tanto o valor de carbono fixado pela floresta quanto o valor monetário da floresta no

contexto do REDD⁺. Segundo Watzlawick et al. (2002) na fase inicial de desenvolvimento da FOM os valores de biomassa presentes no sub-bosque e na biomassa abaixo do solo representar 20% e 30% da biomassa florestal total, respectivamente.

Segundo Mognon (2011), a modalidade REDD (sem mais) paga aos proprietários apenas os valores referentes ao desmatamento evitado (princípio da adicionalidade) e não ao carbono previamente estocado (linha base), anterior ao início do projeto. A representação do princípio de adicionalidade durante o período do projeto está esquematizada na Figura 29, obtida a partir dos dados de carbono florestal estimados pelo sensor ASTER 30m.

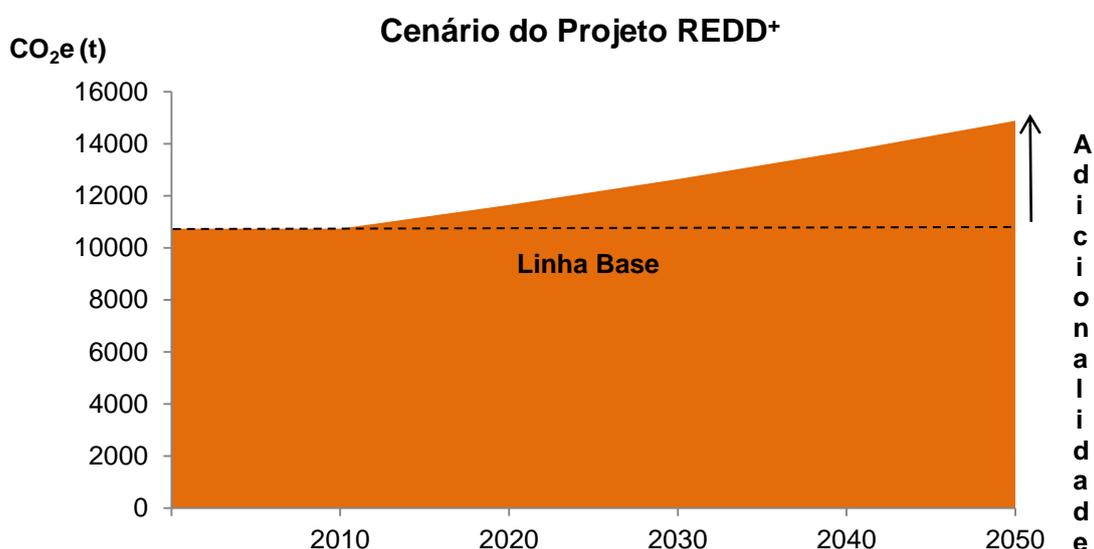


Figura 29 - Princípio da adicionalidade. A linha base (pontilhada) representa a quantidade de CO₂e existente na área anterior à criação do projeto de REDD⁺.

Na nova modalidade de REDD⁺, incluem-se no cálculo compensatório os valores de carbono florestal estocado, tornando-a mais atrativa economicamente que a sua predecessora. Dessa forma, o projeto REDD⁺ compensaria um montante de R\$ 184.318,44 ou R\$ 141,87 ha.ano⁻¹. Embora este valor não seja expressivo, se comparado à exploração seletiva de madeira, representa um retorno financeiro adicional ao agente que utiliza a floresta para fins menos nobres, como ecoturísticos, por exemplo. Outro exemplo seria a sua implementação em áreas proibitivas ou com

restrição para exploração instituída pela Lei 12.651/12²³, como as Áreas de Preservação Permanente (APP) e de Reserva Legal (RL). A averbação da APP e RL inclusive isenta a cobrança do imposto territorial rural (ITR) referente à área calculada²⁴, tratando-se, portanto, de um incentivo à legalização da propriedade e, nesse caso, de um retorno financeiro adicional ao proprietário.

Apesar de promissores, os projetos de REDD⁺ são escassos e ainda são motivos de muita discórdia entre os reguladores (UNFCCC) e os agenciadores (Instituições, Empresas, Países). Segundo Corte et al. (2012) persistem problemas de ordem metodológica, por que muitas vezes inexitem informações confiáveis sobre a linha base dos projetos, bem como, sobre as taxas de incremento anuais de CO₂e. Harris et al. (2012) descrevem que as variações metodológicas de medição dos estoques de carbono na vegetação e solos florestais causam erros expressivos nas estimativas de CO₂ em extensas áreas, na ordem de 25% a até 50%. Estes autores reportam ainda que, enquanto a contribuição das emissões de GEE decorrentes da queima de combustíveis é medida com aceitável precisão, as mensurações de emissões de GEE (CO₂) provenientes de mudanças de uso da terra e florestas (LULUCF – *Land Use, Land-Use Change and Forestry*) no ciclo global do carbono são pouco confiáveis.

Por estes motivos, o órgão subsidiário de assessoramento científico e assessoria técnica (SBSTA – *Subsidiary Body for Scientific and Technical Advice*) da UNFCCC está concentrado na uniformização metodológica que incluem os níveis de referências de emissões por desmatamentos e degradações e as taxas de desmatamento dos projetos REDD⁺ (QURESHI et al. 2012). Os níveis de referência (*benchmarks*) serão a linha base para que as reduções de emissões futuras sejam medidas e potencialmente recompensadas (HARRIS et al. 2012; SAATCHI et al. 2011). A padronização metodológica, portanto, irá resultar na eficácia das medições de reduções de emissões no contexto de um projeto de REDD⁺, na eficiência por

²³ Lei n. 12.651/12 (Novo Código Florestal). Disponível em: http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2012/Lei/L12651.htm#art83. Acesso em: 16/02/2012.

²⁴ Lei n. 9.393/96, artigo 10, § 1º, II, alínea “a”, e o § 7º. Dispõe sobre o Imposto sobre a Propriedade Territorial Rural - ITR, sobre pagamento da dívida representada por Títulos da Dívida Agrária e dá outras providências. Disponível em: http://www.planalto.gov.br/ccivil_03/leis/L9393.htm. Acesso em: 15/02/2013.

dólar gasto e na equidade da distribuição das receitas, por permitir alcançar um nível regional ou nacional de um projeto REDD⁺ (BUSCH et al. 2009).

Enquanto o nível de referência tem sido recentemente aprimorado por diversos autores (HARRIS et al. 2012; SAATCHI et al. 2011), pouco se tem estudado para verificar o vazamento (*leakage*). O termo vazamento refere-se à mudança no local de desmatamento e degradação sofrida pela pressão antropogênica em decorrência da implementação de um projeto de REDD⁺ (BAKER et al. 2010; BUSCH et al. 2009). Este tem sido o maior imbróglio das discussões concernentes ao tema, pois não há meios de se certificar se o vazamento foi decorrente da implementação do projeto ou se este ocorreu sob condições normais, em sua ausência.

Além disso, há certo desconforto na comunidade científica (e ambiental) com relação à queda gradual dos preços da tonelada de CO₂e, por que isto diminuiria o interesse intergovernamental para projetos de redução de desmatamento e degradação de florestas (PETERS-STANLEY et al. 2012). Como consequência a evolução tecnológica e o aprimoramento das técnicas de mensuração de CO₂ serão diretamente prejudicados.

Nota-se, portanto, que este é um tema bastante controverso, pois se desenrola há pelo menos duas décadas (desde a criação do MDL pelo PK) e que há muito a avançar para que seja amplamente aceito. Não obstante, deve continuar na pauta do alto quórum da conferência das partes da UNFCCC para que os objetivos de redução de emissões por GEE sejam alcançados em tempo hábil, antes que o aquecimento global traga consequências mais agravantes para a vida do planeta (BAKER et al. 2010).

A fixação de carbono e a diminuição do desmatamento e degradação em florestas são as ações menos custosas em curto prazo com a finalidade de reduzir o aumento de CO₂ na atmosfera, se comparada ao custo de se cambiar para tecnologias mais limpas alternativas aos combustíveis fósseis; as técnicas de SR vêm ao encontro deste objetivo, portanto.

CONCLUSÕES

Com base nos resultados e nos objetivos propostos chegou-se às seguintes conclusões:

- I. O sensor com a mais alta resolução espacial não necessariamente providenciará o melhor resultado estatístico, pois este é dependente da escala de observação do fenômeno analisado; a resolução espacial de 30m, degradada da original 15m do sensor ASTER, neste trabalho, foi mais apropriada para estimar as variáveis biofísicas do que a sua original;
- II. As regressões lineares foram mais adequadas para descrever as variações de biomassa e carbono da Floresta Ombrófila Mista do que as não lineares e/ou múltiplas, contrariando, neste caso, o postulado de que os índices NDVI e SR saturam com elevados valores de biomassa florestal;
- III. Avaliar apenas o resultado estatístico das regressões pode resultar em um equívoco; a regressão linear da ρ IVP/ASTER 30m alcançou a maior precisão na estimativa de biomassa florestal por hectare com variação de apenas 0,13% do valor estimado pelo PELD, apesar das baixas estatísticas observadas ($R^2 = 0,27$ e $Syx = 20,73$).
- IV. Ao contrário do esperado, não houve diferenças significativas entre o uso de índices de vegetação e o uso das bandas espectrais isoladas para estimar a biomassa e o carbono florestal; Nos sensores ASTER e LiSS III as variáveis biofísicas foram mais bem descritas por regressões lineares construídas com base nos valores de reflectância do canal do infravermelho próximo; no sensor TM, pelo NDVI;
- V. O mapa temático de carbono obtido pelo sensor ASTER na resolução degradada para 30 m foi aquele que alcançou a maior correspondência com os locais onde houve maior valor de carbono na EEJST; também teve alta correspondência com o mapa que descreve os sítios da estação em função dos dosséis predominantes, em que os locais onde as folhosas predominam

têm-se os maiores valores de carbono e os locais onde as coníferas predominam os menores;

- VI. O mapa de carbono florestal e os resultados das estimativas obtidas através dos dados do sensor LiSS III foram praticamente idênticos aos do sensor ASTER 30m. Além disso, ambos os sensores se mostraram adequados para serem usados como alternativos do sensor TM em programas e/ou projetos que utilizem os dados deste último.

- VII. Além de proverem estimativas atuais de estoque de carbono (nível de referência) com relativa confiabilidade, o uso de dados ópticos é especialmente útil para o monitoramento, relatório e verificação dos estoques de carbono, uma das etapas necessárias de um projeto de REDD⁺ (BAKER et al. 2010).

RECOMENDAÇÕES FINAIS

De acordo com as conclusões e discussões apresentadas neste trabalho recomendam-se as seguintes iniciativas:

- I. O trabalho exposto foi realizado em um fragmento da FOM, que não contempla toda a variabilidade espacial nem dinâmica desta tipologia florestal; recomenda-se a aplicação metodológica em outras áreas da FOM, que apresentem maior variabilidade de biomassa por hectare, sobretudo as que se encontram em diferentes estágios sucessionais de desenvolvimento, de forma a inserir a metodologia em um nível regional ou nacional no ciclo do carbono;
- II. Em se tratando de nível regional ou nacional, seria necessário testar a metodologia englobando outros tipos de sensores, que tenham como característica a menor resolução espacial, tal qual o MODIS, para alcançar áreas mais extensas de floresta, trabalhando-se, assim, as variações espectrais e biofísicas em multiescala, i.e., com sensores atuando em diferentes resoluções espaciais concomitantemente.
- III. O interesse em avaliar o estoque de carbono em nível regional ou nacional, além do contexto de fluxo global de carbono resultaria em um aporte financeiro maior de um projeto REDD⁺ ao mesmo tempo que diluiria os seus custos com a aquisição de imagens e com os métodos de validação em campo;
- IV. Outras técnicas poderiam ser buscadas para alcançar maior acurácia local, utilizando-se de dados de sistemas radares ou de sensores com alta resolução espacial, por exemplo, com o intuito de explorar outros níveis de inter-relação entre as variáveis provenientes de SR e as variáveis biofísicas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ADLER-GOLDEN, S.M.; MATTHEW, M.W.; BERNSTEIN, L.S.; LEVINE, R.Y.; BERK, A.; RICHTSMEIER, S.C.; ACHARYA, P.K; ANDERSON, G.P.; FELDE, G.; GARDNER, J.; HOKE, M.; JEONG, L.S.; PUKALL, B.; MELLO, J.; RATKOWISKI, A.; BURKE, H.H. Atmospheric Correction for Short-wave Spectral Imagery Based on MODTRAN4. **SPIE Proceedings on Imaging Spectrometry**, v. 3753, p. 61-69, 1999.
- ANDRAE, F. **Ecologia florestal**. Santa Maria: UFSM – DCFL, 1978. 278p.
- ANDRIOTTI, J. L. S. **Fundamentos de Estatística e Geoestatística**. Editora Unisinos, São Leopoldo, 2003. 165p.
- ÄRDO, J. Volume quantification of coniferous forest compartments using spectral radiance recorded by Landsat Thematic Mapper. **International Journal of Remote Sensing**. v. 13. p. 1779– 1786. 1992.
- ASNER, G. P. Tropical forest carbon assessment: integration satellite and airborne mapping approaches. **Environmental Research Letters**. v.4. n. 3. p. 1-11. 2011.
- ASTER - Advanced Spaceborne Thermal and Reflection Radiometer. Disponível em: <http://asterweb.jpl.nasa.gov/mission.asp>. Acesso em: 08/10/2012.
- ATAZADEH, I. **Biomass and remote sensing of biomass**. Intech: Rijeka, Croatia. 2011. 272p.
- BACCINI, A.; FRIEDL, M. A.; WOODCOCK, C. E.; WARBINGTON, R. Forest biomass estimation over regional scales using multisource data. **Geophysical Research Letters**. v. 31. p. 1–4. 2004.
- BALDOCCHI, D.D. Assessing the eddy covariance technique for evaluating carbon dioxide exchange rates of ecosystems: past, present and future. **Global Change Biology**. v. 9. p. 479–492. 2003.
- BAKER, D. J.; RICHARDS, G.; GRAINGER, A.; GONZALEZ, P.; BROWN, S.; DEFRIES, R.; HELD, A.; KELLNDORFER, J.; NDUNDA, P.; OJIMA, D.; SKROVSETH, P. E.; SOUZA, C. JR.; STOLLE, F. Achieving forest carbon information with higher certainty: A five-part plan. **Environmental Science and Policy**, v.13, p. 249–260. 2010.
- BAJRACHARYA, S. **Community carbon forestry: remote sensing of forest carbon and forest degradation in Nepal**. 2008. 92p. Master of Science (M.Sc. of Geo-Information Science and Earth Observation for Environmental Modelling and Management) - International Institute for Geo-Information Science and Earth Observation Enschede, The Netherlands. 2008.
- BARATI, S.; RAYEGANI, B.; SAAATI, M.; SHARIFI, A.; NASRI, M. Comparison the accuracies of different spectral indices for estimation of vegetation cover fraction in sparse vegetated areas. **The Egyptian Journal of Remote Sensing and Space Sciences**. v. 14. p. 49-56. 2011.

BARBIER, N.; PROISY, C.; VÉGA, C.; SABATIER, D.; COUTERON, P. Bidirectional texture function of high resolution optical images of tropical forest: An approach using LiDAR hillshade simulations. **Remote Sensing of Environment**. v. 115. p. 968-977. 2011.

BERNARDES, S. **Índices de vegetação e valores de proporção na caracterização de floresta tropical primária e estádios sucessionais na área de influência da Floresta Nacional de Tapajós – Estado do Pará**. 1998. 86 p. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional e Pesquisas Espaciais, São José dos Campos.

BIAN, L.; BUTLER, R. Comparing effects of aggregation methods on statistical and spatial properties of simulated spatial data. **Photogrammetric Engineering & Remote Sensing**. v. 65 n. 1. p. 73-84. 1999.

BIRTH, G.S.; MCVEY, G. Measuring the color of growing turf with a reflectance spectrophotometer. **Agronomy Journal**. v. 60. p. 640-643. 1968.

BOWKER, D. E.; DAVIS, R.; MYRICK, D. L.; STACY, K.; JONES, W. T. Spectral reflectances of natural targets for use in remote sensing studies. **NASA Reference Publication**. n. 1139. 1985. 184p.

BROWN, S. Measuring, monitoring, and verification of carbon benefits for forest-based projects. **Philosophical Transactions of the Royal Society**, v. 360. p. 1669-1683. 2002.

BUSCH, J.; STRASSBURG, B.; CATTANEO, A.; LUBOWSKI, R.; BRUNER, A.; RICE, R.; CREED, A.; ASHTON, R.; BOLTZ, F. Comparing climate and cost impacts of reference levels of reducing emissions from deforestation. **Environmental Research Letters**. v. 4. n. 4. p. 1-11. 2009.

CALBO, A.G.; SILVA, W.L.C.; TORRES, A.C. Ajuste de funções não lineares de crescimento. **Revista Brasileira de Fisiologia Vegetal**, v. 1. n.1. p. 9-18. 1989.

CAMARGO, E. C. G. **Geoprocessamento para projetos ambientais**. Instituto Nacional de Pesquisas Espaciais – INPE. Capítulo 5 – Geoestatística: Fundamentos e Aplicações. 2ª Edição revisada e ampliada. São José dos Campos, 1998. Disponível em: http://www.dpi.inpe.br/gilberto/tutoriais/gis_ambiente/5geoest.pdf. Acesso em 06 de Janeiro de 2013.

CARVALHO, P. E. R. **Espécies florestais brasileiras: recomendações silviculturais, potencialidades e uso da madeira**. Brasília: EMBRAPA-CNPQ; EMBRAPA-SPI, 1994. 640p.

CASSOL, H. L. G.; SALDANHA, D. L.; KUPLICH, T. M. Estimando biomassa florestal com dados ASTER: A questão da escala. In: X Seminário de Atualização em Sensoriamento Remoto e Sistema de Informações Geográficas aplicados à Engenharia Florestal, Curitiba, 2012. **Anais...** Curitiba: SENGEF. p. 642-650. 2012.

CENAMO, M.; PAVAN, M. N.; CAMPOS, M. T.; BARROS, A. C.; CARVALHO, F. **Guia sobre Projetos de REDD+ na América Latina**. 2Ed. Manaus, 2010. 96p.

CHANDER, G.; MARKHAM, B. L.; HELDER, D. L. 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.

CHANG, M. Y. Sequestro florestal de carbono no Brasil – Dimensões políticas socioeconômicas e ecológicas. In: SANQUETTA, C. R.; BALBINOT, R.; ZILLOTTO, M. A. B. **Fixação de carbono: atualidades, projetos e pesquisas**. Curitiba: AM Impressos, p. 15-37, 2004.

CHAVE, J.; ANDALO, S.; BROWN, S.; CAIRS, M.A.; CHAMBERS, J.Q.; EAMUS, D.; FÖLSTER, H.; FROMARD, F.; HIGUCHI, N.; KIRA, T.; LESCURE, J.P.; NELSON, B.W.; OGAWA, H.; PUIG, H.; RIERA, B.; YAMAKURA, Y. Tree allometry and improved estimation of carbon stocks and balance in tropical forests. **Oecologia**. V. 145. n. 1. p. 87-99, 2005.

CIAIS, P.; PEYLIN, P.; BOUSQUET, P. Regional biospheric carbon fluxes as inferred from atmospheric CO₂ measurements. **Ecological Applications**. v. 10. n. 6. p. 1574–1589. 2000.

CLARK, D. A.; S, B.; KICKLIGHTER, D. W.; CHAMBERS, J. Q.; THOMLINSON, J. R.; NI, J. Measuring net primary production in forest: concepts and field methods. **Ecological Applications**. v. 11. n. 2. p. 356-370. 2001.

CLARK, M. L.; ROBERTS, D. A.; EWEL, J. J.; CLARK, D. B. Estimation of tropical rain forest aboveground biomass with small-footprint LIDAR and hyperspectral sensors. **Remote Sensing of Environment**. v.115. p. 2931–2942. 2011.

COLLINS, J.B.; WOODCOCK, C.E. Geostatistical estimation of resolution-dependent variance in remotely sensed images. **Photogrammetric Engineering & Remote Sensing**. v. 65 n. 1. p. 41-50. 1999.

COP3 – Conference of Parties. Decision 3/CP.3. Kyoto, 1997. Review of the implementation of the convention financial mechanism. Disponível em: <http://unfccc.int/cop4/resource/docs/cop3/03.pdf>. Acesso em: 07/10/2011.

COP16 – Conference of Parties. Decision 1/CP.16 The Cancun Agreements: Outcome of the work of the Ad Hoc working group on long-term cooperative action under the convention Disponível em: http://unfccc.int/files/meetings/cop_16/application/pdf/cop16_lca.pdf. Acesso em: 15/10/2011.

CORTE, A. P. D.; SANQUETTA, C. R.; KIRCHNER, F. F.; ROSOT, N. C. Os projetos de redução de emissões do desmatamento e da degradação florestal (REDD). **Floresta**. v. 44. n. 1. p. 177-188. 2012.

CURRAN, P.J.; WILLIAMSON, H.D. Sample size for ground and remotely sensed data. **Remote Sensing of Environment**. v.20. p. 31-41. 1986.

CURRAN, P.J; HAY, A.M. The importance of measurement error for certain procedures in remote sensing at optical wavelengths. **Photogrammetric Engineering and Remote Sensing**, v. 52. n. 2. p. 229-241. 1986.

CURRAN, P.J. The semi-variogram in remote sensing: an introduction. **Remote Sensing of Environment**. v. 24. p. 493-507. 1988.

CURRAN, P.J.; ATKINSON, P.M. Geostatistics and remote sensing. **Progress in Physical Geography**. v. 22. n.1. p. 61-78. 1998.

CURRAN, P.J.; ATKINSON, P.M. Issues of scale and optimal pixel size. In: STEIN, A.; MEER, F.; GORTE, B. **Spatial Statistics for Remote Sensing**. Dordrecht: Kluwer Academic Publishers. Chapter 7. P. 115-133. 1999. 325p.

DALLA CORTE, A. P.; SANQUETTA, C. R. Quantificação do estoque de carbono fixado em reflorestamentos de Pinus na área de domínio da Floresta Ombrófila Mista no Paraná. **Cerne**. v.13, n.1, p. 32-39, 2007.

DECOLA, L. Simulating and mapping spatial complexity using multiscale techniques. **International Journal of Geographic Information System**. v. 8. p. 411-421. 1994.

DEERING, D.W.; ROUSE J.W.; HAAS, R.H.; SCHELL, J.A. Measuring “forage production” of grazing units from Landsat MSS data. In: Tenth International Symposium of Remote Sensing of the Environment, ERIM, Ann Arbor, Michigan. **Proceedings...** 1975. p. 1169–1198. 1975.

DONG, J.; KAUFMANN, R. K.; MYNENI, R. B.; TUCKER, C. J.; KAUPPI, P. E.; LISKI, J.; BUERMANN, W.; ALEXEYEV, V.; HUGHES, M. K. Remote sensing estimates of boreal and temperate forest woody biomass: Carbon pools, sources, and sinks. **Remote Sensing of Environment**. v.84. p. 393–410. 2003.

DRAPER, N. R.; SMITH, H. **Applied regression analysis**. John Wiley & Sons, Inc: Canadá. 3ªed. 1998. 704p.

DURIGAN, M. E. **Florística, dinâmica e análise proteica de uma Floresta Ombrófila Mista em São João do Triunfo**. 138p. Dissertação (Mestrado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 1999.

EVA, H.; CARBONI, S.; ACHARD, F.; STACH, N.; DURIEUX, L.; FAURE, J. F.; MOLLICONE, D. Monitoring forest areas from continental to territorial levels using a sample of medium spatial resolution satellite imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65 p. 191-197. 2010.

FOODY, G.M.; CUTLER, M.E.; MCMORROW, J.; PELZ, D.; TANGKI, H.; BOYD, D.S.; DOUGLAS, I. Blackwell Science, Ltd Mapping the biomass of Bornean tropical rain forest from remotely sensed data. **Global Ecology & Biogeography**. v. 10. p. 379–387. 2001.

FOODY, G.M.; BOYD, D.S.; CUTLER, M.J. Predictive relations of tropical forest biomass from Landsat TM data and their transferability between regions. **Remote Sensing of Environment**. v. 85. p. 463–474. 2003.

FRANKLIN, S. E. **Remote Sensing for Sustainable Forest Management**. Lewis Publishers: Florida, USA. 2001. 393p.

FREITAS, S. R.; SHIMABUKURO, Y. E. Diagnosticando florestas tropicais através do sensoriamento remoto. In: XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, 2007. **Anais...**São José dos Campos: INPE, 2007. p. 1671-1678.

- FUJISADA, H. Overview of ASTER instrument on EOS-AM1 platform. **SPIE Proceedings on Imaging Spectrometry**, v. 2268, p. 14-36, 1994.
- FUJISADA, H. ASTER Level-1 Data Processing Algorithm. **IEEE Transactions on Geoscience and Remote Sensing**, v. 36, n. 4, p. 1101-1112, 1998.
- GATES, D. M e BENEDICT, C. M. Convection phenomena from plants in still air. **American Journal of Botany**. v. 50. n. 6. p. 563-573. 1965.
- GATES, D. M.; KEEGAN, H. J.; SCHLETER, J. C.; WEIDNER, V. R. Spectral properties of plants. **Applied Optics**. v. 4. no.1. p. 11-20. 1965.
- GEBRESLASIE, M.T.; AHMED, F.B.; van AARDT, J.A.N. Predicting forest structural attributes using ancillary data and ASTER satellite data. **International Journal of Applied Earth Observation and Geoinformation**. v. 12. Supplement 1. p. s23-s26. 2010.
- GIFFORD, R. **Carbon Content of Woody Roots: Revised Analysis and a Comparison with Woody Shoot Components** (Revision 1). NCAS Technical Report No. 7. 10p. Australian Greenhouse Office, Canberra. 2000a.
- GIFFORD, R. **Carbon Content of Above-ground Tissues of Forest and Woodland Trees**. NCAS Technical Report n. 22. 28p. Australian Greenhouse Office, Canberra. 2000b.
- GLENN, E. P.; HUETE, A. R.; NAGLER, P. L.; NELSON, S. G. Relationship between remotely-sensed vegetation indices, canopy attributes and plant physiological processes: what vegetation indices can and cannot tell us about the landscape. **Sensors**. v. 8. p. 2136-2160. 2008.
- GOODIN, D.G.; HENEYRY, G.M. The effect of rescaling on fine spatial resolution NDVI data: a test using multi-resolution aircraft sensor data. **International Journal of Remote Sensing**. v. 23. n. 18. p. 3865-3871. 2002.
- GOETZ, S.; BACCINI, A.; LAPORTE, N.; JOHNS, T.; WALKER, W.; KELLNDORFER, J.; HOUGHTON, R.; SUN, M. Mapping and monitoring carbon stocks with satellite observations: A comparison of methods. **Carbon Balance and Management**.. v. 4. n. 2. p. 1-7. 2009.
- GORE, A. **A Terra em Balanço. Ecologia e Espírito Humano**. Augustus: São Paulo, São Paulo. 1993. 447p.
- HÄME, T.; SALLI, A.; ANDERSSON, K.; LOHI, A. A new methodology for estimation of biomass of conifer-dominated boreal forest using NOAA AVHRR data. **International Journal of Remote Sensing**. v. 18. p. 3211– 3243. 1997.
- HÄME,T.; KILPI, J.; AHOLA, H.; RAUSTE, Y.; SIRRO, L.; BOUNPONE, S. Monitoring of tropical forest cover and biomass by combining VHR image sample and wall to wall optical and SAR data. In: ESA Living Planet Syposium. Bergen, Norway. 2010. **Proceedings...** Noordwijk, The Neederlands, 2010.
- HARRIS, N.; BROWN, S.; HAGEN, S.C.; SAATCHI, S.S.; PETROVA, S.; SALAS, W.; HANSEN, M.C.; PETAPOV, P.V.; LOTSCH, A. Baseline map of carbon emissions from deforestation in tropical regions. **Science**. v. 336 p. 1573-1575. 2012.

HEISKANEN, J. Estimating aboveground tree biomass and leaf area index in a mountain birch forest using ASTER satellite data. **International Journal of Remote Sensing**. v. 27. n. 6. p. 1135-1138. 2006.

HETT, C.; CASTELLA, J. C.; HEINIMANN, A.; MESSERLI, P.; PFUND, J. L. A landscape mosaics approach for characterizing Sweden systems from a REDD+ perspective. **Applied Geography**. v. 32. p. 608-618. 2011.

HO, R. **Handbook of univariate and multivariate data analysis and interpretation with SPSS**. New York: Taylor & Francis Group. 2006. 393p.

HOU, Z.; XU, Q.; TOKOLA, T. Use of ALS, Airborne CIR and ALOS AVNIR-2 data for estimating tropical forest attributes in Lao PDR. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 66. n.6. p. 776-786. 2011.

HUECK, K. **As florestas da América do Sul: ecologia, composição e importância econômica**. São Paulo: Editora Polígono S/A. 1972. 466p. cap 21 e 22.

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

HUETE, A. R.; LIU, H.Q.; BATCHILY, K.; van LEEUWEN, W. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. **Remote Sensing of Environment**, v. 59, p. 440–451. 1997.

HUETE, A.R.; DIDAN, K.; MIURA, T.; RODRIGUEZ, E.P.; GAO, X.; FERREIRA, L.G. Overview of the radiometric and biophysical performance of the MODIS vegetation indices. **Remote Sensing of Environment**. v. 83. p. 195–213. 2002.

HYYPPÄ, J; HYYPPÄ, H; INKINEN, M; ENGDAHL, M; LINKO, S; ZHU, Y. Accuracy comparison of various remote sensing data sources in the retrieval of forest stand attributes. **Forest Ecology and Management**. v. 128. p. 109-120. 2000.

IAPAR - Instituto Agrônomo do Paraná. CAVIGLIONE, J. H.; KIIHL, L. R. B.; CARAMORI, P. H.; OLIVEIRA, D. Cartas climáticas do Paraná. Londrina : IAPAR, 2000. CD Londrina, PR. Cartas Climáticas. Disponível em: <http://www.iapar.br/modules/conteudo/conteudo.php?conteudo=677>. Acesso em: 03/04/2013.

IBGE - Instituto Brasileiro de Geografia e Estatística (IBGE). **Manual técnico da vegetação brasileira**. Rio de Janeiro, 1992. 92p. (Manuais Técnicos em Geociências, 1).

IPCC – International Panel on Climate Change. **Good practice guidance for land use, land-use change and forestry**. Hayama, Japan: IPCC National Greenhouse Gas Inventories Programme 295 pp. 2003.

ISAAKS, E. H.; SRIVASTAVA R. M. **An Introduction to Applied Geostatistics**. New York, Oxford University Press, 1989. 560p.

JACQUEMOND, S.; BARET, V. PROSPECT: A model of leaf optical properties spectra. **Remote sensing of environment**. v. 34. p. 75- 91. 1990.

JACQUEMOUD, S.; USTIN, S. L.; VERDEBOUT, J.; SCHMUCK, G.; ANDREOLI, G.; HOSGOOD, B. Estimation leaf biochemistry using the PROSPECT leaf optical properties model. **Remote Sensing of Environment**. v. 56. p. 194-202. 1996.

JENSEN, J. R. **Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres**. Tradução da 2 ed. por (pesquisadores do INPE): José Carlos N. Epiphânio (coordenador); Antonio R. Formaggio; Athos R. Santos; Bernardo F. T. Rudorff; Cláudia M. Almeida; Lênio S. Galvão. São José dos Campos: Parêntese. 2009. 672 p.

JONES, H. G.; VAUGHAN, R. A. **Remote Sensing of Vegetation: Principles, Techniques and Applications**. Oxford: Oxford University Press. 2010. 353p.

JORDAN, C. F. Derivation of leaf-area index from quality of light on the forest floor. **Ecology**. v. 50. n. 4. p. 663-666. 1969.

KAUFMAN, Y. J. e TANRÉ, D. Atmospherically resistant vegetation index (ARVI) for EOS-MODIS. **IEEE Transaction on Geosciences and Remote Sensing**. v. 30. p. 261-270. 1992.

KIMES, D. S. Modeling the directional reflectance from complete homogeneous vegetation canopies with various leaf-orientation distributions. **Journal of the Optical Society of America**. v. 1. n. 7. p. 725-737. 1984.

KLEIN, R.M. O aspecto dinâmico do pinheiro-brasileiro. **Sellowia**. v.12. n.12, p.17-44, 1960.

KLOCK, U.; MUÑIZ, G.I.B.; HERNANDEZ, J.A.; ANDRADE, A. S. Química da Madeira. 3ed. Curitiba, 2005. 86p.

KOCH, B. Status and future of laser scanning, synthetic aperture radar and hyperspectral remote sensing data for forest biomass assessment. **ISPRS Journal of Photogrammetry and Remote Sensing**. v. 65. n. 6. p. 581-590. 2010.

KOEHLER, H. S.; WATZLAWICK, L. F.; KIRCHNER, F. F. Fontes de erros nas estimativas do potencial de fixação de carbono. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILIOOTTO, M. A. B; GOMES, F. S. **As florestas e o carbono**. Curitiba, p. 251 – 264. 2002.

KÖHL, M.; MAGNUSSEN, S.S.; MARCHETTI, M. **Sampling Methods, Remote Sensing and GIS Multisource Forest Inventory**. Springer. 2006. 367p.

KRANKINA, O. N.; HARMON, M. E; COHEN, W. B.; OETTER, D. R.; ZYRINA, O.; DUANE, M V. Carbon stores, sinks, and sources in forest northwest Russia: can we reconcile forest inventories with remote sensing results? **Climatic Change**. v. 67. p. 257-272. 2004.

KUMAR, P.; SHARMA, L.K.; PANDEY, P.C.; SINHA,S.; NATHAWAT, M.S. Geospatial strategy for tropical forest-wildlife reserve biomass estimation. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**. v. PP. p. 1-7. 2012.

LAMPRECHT, H. **Silvicultura nos trópicos: ecossistemas florestais e respectivas espécies arbóreas – possibilidades e métodos de aproveitamento**

sustentado. Eschborn: Deutsche Gesellschaft für technische Zusammenarbeit (GTZ) GmbH, 1990. 343p.

LABRECQUE, S.; FOURNIER, R. A.; LUTHER, J. E.; PIERCEY, D. A comparison of four methods to map biomass from Landsat-TM and inventory data in western Newfoundland. **Forest Ecology and Management.** v. 226. p. 129–144. 2006.

LE MAIRE, G.; MARSDEN, C.; NOUVELLON, Y.; GRINAND, C.; HAKAMADA, R.; STAPE, J.L.; LACLAU, J. P. MODIS NDVI time-series allow the monitoring of Eucalyptus plantation biomass **Remote Sensing of Environment.** v.115 n.10. p. 2613-2625. 2011.

LEITE, P. F.; KLEIN, R. M. Vegetação. In: FUNDAÇÃO INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Geografia do Brasil.** v. 2. Região Sul. Rio de Janeiro: IBGE, p. 113-150, 1990.

LILLESAND, T.M.; KIEFER, R.W.; CHIPMAN, J. **Remote sensing and interpretation.** 6 ed. New York, John Wiley, 1994. 804p.

LONGHI, S. J. **A estrutura de uma floresta natural de *Araucaria angustifolia* (Bert.) O. Kuntze, no sul do Brasil.** 198p. Dissertação (Mestrado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 1980.

LOVELOCK, E. J. **Gaia: Um Novo Olhar Sobre a Vida na Terra.** Universo da Ciência: Rio de Janeiro – RJ. Ed 70. 1979. 169p.

LOVELOCK, E. J. **Gaia: Alerta Final.** Intrínseca: Rio de Janeiro – RJ. 2009. 264p.

LU, D. The potential and challenge of remote sensing-based biomass estimation. **International Journal of Remote Sensing,** v. 27. p. 1297–1328. 2006.

MACIEL, M. N. M. **Estimativa de parâmetros estruturais de uma floresta primária na Amazônia Oriental através de dados orbitais.** 2002. 144p. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba. 2002.

MADUGUNDU, R.; NIZALAPUR, V.; JHA, C.S. Estimation of LAI and above-ground biomass in deciduous forests: Western Ghats of Karnataka, India. **International Journal of Applied Earth Observation and Geoinformation.** v. 10. p. 211-219. 2008.

MAIN-KNORN, M.; GRETCHEN, G. M.; SEAN P. H.; WILLIAM S. K.; ELIZABETH A. F.; PATRICK HOSTERT. Evaluating the Remote Sensing and Inventory-Based Estimation of Biomass in the Western Carpathians. **Remote Sensing of Environment.** v. 3. p. 1427-1446. 2011.

MARCHIORI, J. N. C. **Fitogeografia do Rio Grande do Sul.** Embasamento Florístico. EST Edições: Porto Alegre. 2006. 39p.

MARKHAM, B.L.; BARKER, J.L. Landsat MSS and TM post-calibration dynamic ranges, exoatmospheric reflectances and at-satellite temperature. **EOSAT Landsat Technical Notes.** n.1. 8p. 1986.

MATHERON, G. **La Theorie des Variables Regionalisées et ses Applications**. Les Cahiers du Centre de Morphologie Mathématique de Fontainebleau. Fascicule 5. Thome 1. École Supérieure des Mines de Paris. 1970.

MATOS, F. D. A. **Estimativa de biomassa e carbono em Floresta Ombrófila Densa de Terra Firme na Amazônia Central, Manaus – AM, Brasil, por meio de dados de satélites de média e alta resolução espacial**. 2006. 146p. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba.

MATOS, F. D. A.; KIRCHNER, F. F. Estimativa de biomassa da floresta ombrófila densa de terra firme na amazônia central com o satélite Ikonos II. **Floresta**. v. 38. n. 1. p. 157-171. 2008.

MATTOS, J. R. **O pinheiro brasileiro**. Editora UFSC: Florianópolis, 2011. 698p.

MCCOY, R. M. **Fields Methods in Remote Sensing**. The Guilford Press: New York, 2005. 177p.

MINISTÉRIO DE CIÊNCIA E TECNOLOGIA MCT - Primeiro Inventário Brasileiro de Emissões Antrópicas de Gases de Efeito Estufa. Brasília. 2004. 86 p.

MOGNON, F. **Dinâmica do estoque de carbono como serviço ambiental prestado por um fragmento de floresta Ombrófila Mista Montana localizada no sul do estado do Paraná**. 2011. 104p. Dissertação. (Mestrado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba. 2011.

MONSERUD, R.A. Evaluating forest models in a sustainable forest management context. **Forest Biometry, Modeling and Information Science**. v. 1. p. 35–47. 2003.

MUUKKONEN, P.; HEISKANEN, J. Estimating biomass for boreal forests using ASTER satellite data combined with standwise forest inventory data. **Remote sensing of Environment**. v. 99. p. 434-447. 2005.

MUUKKONEN, P.; HEISKANEN, J. Biomass estimation over a large area based on standwise forest inventory data and ASTER and MODIS satellite data: A possibility to verify carbon inventories. **Remote sensing of Environment**. v.107. p. 617-624. 2007.

MUUKKONEN, P. **Forest inventory-based large-scale forest biomass and carbon budget assessment: new enhanced methods and use of remote sensing for verification**. 2006. 49p. Dissertation. (Forestry Master's) – University of Helsinki, Helsinki. Finland. 2006.

MYNENI, R.; HALL, F., SELLER, P.; MARSHAK, A. The interpretation of spectral vegetation indexes. **IEEE Transactions on Geoscience and Remote Sensing**. v. 33. n. 2. p. 481-486. 1995.

NASA - National Aeronautics and Space Administration. Image Gallery. Disponível em: <<http://www.nasa.gov/multimedia/imagegallery/index.html>>. Acesso em: 23 Setembro de 2012.

NASA - National Aeronautics and Space Administration. The Landsat Program. Disponível em: <http://landsat.gsfc.nasa.gov/about/index.html>. Acesso em: 05 Janeiro de 2013.

NEEFF, T.; GRAÇA, P. M. A.; DUTRA, L. V.; FREITAS, C, C. Carbon budget estimation in Central Amazônia: Sucessional Forest modeling from remote sensing data. **Remote Sensing of Environment**. v. 94. p. 508-522. 2005.

NORMAN, J. M.; WELLES, J. M.; WALTER, E. A. Contrasts among bidirectional reflectance of leaves, canopies, and soils. **IEEE Transactions On Geoscience And Remote Sensing**. v. GE-23. no. 5. p. 659-667. 1985.

PARKER, C.; MITCHELL, A.; TRIVEDI, M.; MARDAS, N. The Little REDD Book. Global Canopy Foundation. Oxford. 2008. 112 p.

PATENAUDE, G.; MILNE, R.; DAWSON, T. P. Synthesis of remote sensing approaches for forest carbon estimation: Reporting to the Kyoto Protocol. **Environmental Science and Policy**. v.8. p. 161–178. 2005.

PIZATTO, W. **Avaliação biométrica da estrutura e da dinâmica de uma Floresta Ombrófila Mista em São João do Triunfo – PR: 1995 a 1998**. Curitiba, 1999. 172p. Dissertação (Mestrado) – Universidade Federal do Paraná. 1999.

PROBIO – Projeto de Conservação e Utilização Sustentável Da Diversidade Biológica Brasileira. **Levantamento da Cobertura Vegetal Nativa do Bioma Mata Atlântica**. Relatório Final. 84 p. IESB – IGEO/UFRJ: 2007.

PROISY, C.; COUTERON, P.; FROMARD, F. Predicting and mapping mangrove biomass from canopy grain analysis using Fourier-based textural ordination of IKONOS images. **Remote Sensing of Environment**. v.109, p. 379–392. 2007.

PONZONI, F. J.; SHIMABUKURO, Y. E. **Sensoriamento remoto aplicado ao estudo da vegetação**. São José Dos Campos: Parêntese, 2010. 135 p.

POWELL, S. L.; COHEN, W. B.; HEALEY, S. P.; KENNEDY, R. E.; MOISEN, G. G.; PIERCE, K. B.; OHMANN, J. L. Quantification of live aboveground forest biomass dynamics with Landsat time-series and field inventory data: A comparison of empirical modeling approaches. **Remote Sensing of Environment**. v.114, p. 1053–1068. 2010.

QURESHI, A.; PARIVA.; BADOLA, R.; HUSSAIN, S.A. A review of protocols used for assessment of carbon stock in forested landscapes. **Environmental Science & Police**. v. 16. p. 81-89. 2012.

RATUCHNE, L. C. **Ajuste e Seleção de Equações Alométricas para a Estimativa de Biomassa, Carbono e Nutrientes em uma Floresta Ombrófila Mista**. 102p. Dissertação (Mestrado em Agronomia) – Setor de Ciências Agrárias, UNICENTRO/PR, Guarapuava, 2010.

REESE, H.; NILSSON, M.; SANDSTROM, P.; OLSSON, H. Applications using estimates of forest parameters derived from satellite and forest inventory data. **Computers and Electronics in Agriculture**. v. 37. p. 37-55. 2002.

REZENDE, D.; MERLIN, S.; SANTOS, M. T. **Sequestro de Carbono: uma experiência concreta**. Ed. Gráfica Terra. Palmas: Instituto Ecológica, 2001. 2ª Edição. 178p.

ROCHA, M. T. O aquecimento global e os instrumentos de mercado para a solução do problema. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILIOOTTO, M. A. B.; GOMES, F. S. **As florestas e o carbono**. Curitiba. p. 1-34. 2002.

ROSENQVIST, Å.; MILNE, A.; LUCAS, R.; IMHOFF, M.; DOBSON, C. A review of remote sensing technology in support of the Kyoto protocol. **Environmental Science and Policy**, v.6, p. 441–455. 2003.

ROUSE, J.; HASS, R.; SCHELL, J.; DEERING, D. Monitoring vegetation systems in the great plains with ERTS. Third ERTS Symposium 1973, NASA, SP-351 I, 309-317. 1973.

ROY, P.S.; RAVAN, S.A. Biomass estimation using satellite remote sensing data - An investigation on possible approaches for natural forest. **Journal of Biosciences**. v. 21. n. 4. p. 535-561. 1996.

SAATCHI, S.S.; HARRIS, N.L.; BROWN, S.; LEFSKY, M.; MITCHARD, E.T.A.; SALAS, W.; ZUTTA, B.; BUERMANN, W.; LEWIS, S.L.; HAGEN, S.; PETROVA, S.; WHITE, L.; SILMAN, M.; MOREL, A. Benchmark map of forest carbon stocks in tropical regions across three continents. **Proceedings of the National Academy of Sciences of the United States of America**. v. 108. p. 9899-9904. 2011.

SALATI, E. Emissão X sequestro de CO₂ – uma nova oportunidade de negócios para o Brasil. In: EMISSÃO X SEQUESTRO DE CO₂ – UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL, 1994. Rio de Janeiro. **Anais...** Rio de Janeiro, 1994 p.13–37.

SANQUETTA, C. R. Métodos de determinação de biomassa florestal. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILIOOTTO, M. A. B.; GOMES, F. S. **As florestas e o carbono**. Curitiba. p. 119-140. 2002.

SANQUETTA, C. R.; BALBINOT, R. Metodologias para a determinação de biomassa florestal. In: SANQUETTA, C. R.; BALBINOT, R.; ZILIOOTTO, M. A. B. **Fixação de carbono: atualidades, projetos e pesquisas**. Curitiba. p. 77-93. 2004.

SANQUETTA, C.R.; CORTE, A.P.D.; KOVALEK, N. Estrutura e composição de copas e clareiras em um fragmento de Floresta Ombrófila Mista no centro-sul do Estado Paraná. **Revista de estudos ambientais** (Online) v.13, n. 2, p. 68-77. 2011.

SARKER, L. R e NICHOL, J. E. Improved forest biomass estimates using ALOS AVNIR-2 texture indices. **Remote Sensing of Environment**. v.115. p. 968–977. 2011.

SANTOS, J.R. **Biomassa aérea da vegetação de cerrado: estimativa e correlação com dados do sensor “Thematic Mapper” do satélite LANDSAT**. Curitiba, 1988. 156p. Tese (Doutorado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná.

SANTOS, J.R. **Análise de modelos de regressão para estimar a fitomassa da floresta tropical úmida de terra-firme da Amazônia brasileira**. 121 p. Tese (Doutorado) - Universidade Federal de Viçosa, Viçosa, MG, 1996.

SCHAAF, L.B. **Florística, estrutura e dinâmica, no período 1979-2000, de uma Floresta Ombrófila Mista, localizada no sul do Paraná**. 131p. Dissertação (Mestrado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2001.

SCHLERF, M.; ATZBERGER, C.; HILL, J. Remote sensing of forest biophysical variables using HyMap imaging spectrometer data. **Remote Sensing of Environment**. v. 95. p. 177–194. 2005.

SCHOWENGERDT, R. A. **Remote Sensing: Models and Methods for Image Processing**. 3. Ed. Tucson, Arizona: Academic Press. 2007. 509p.

SILVEIRA, P.; KOEHLER, H. S; SANQUETTA, C. R.; ARCE, J. E. O estado da arte na estimativa de biomassa e carbono em formações florestais. **Floresta**. v.38. n.1. p. 185-206. 2008.

SLATER, P. N. **Remote Sensing: The Image Chain Approach**. New York, NY: Oxford University Press, 1980. 394p.

SOARES, A. **Geoestatística para ciências da terra e do ambiente**. Lisboa: IST Press. 2000. 206p.

SOARES, C. P. B.; NETO, F. P.; SOUZA, A. L. **Dendrometria e Inventário Florestal**. Editora UFV: Viçosa, MG. 2006. 276p.

SONG, C.; WOODCOCK, C. E.; SETO, K. C.; PAX-LENNEY.; M. e MACOMBER, S. A. Classification and change detection using Landsat TM data: when and how to correct atmospheric effects? **Remote sensing of environment**, v.75, p.230-244, 2001.

STEININGER, M. K. Satellite estimation of tropical secondary forest above-ground biomass: data from Brazil and Bolivia. **International Journal of Remote Sensing**. v. 21. No. 6 e 7. p. 1139-1157. 2000.

SWATANTRAN, A.; DUBAYAH, R.; ROBERTS, D.; HOFTON, M.; BLAIR, J. B. Mapping biomass and stress in the Sierra Nevada using LIDAR and hyperspectral data fusion. **Remote Sensing of Environment**. v. 115. p. 2917–2930. 2011.

TEDESCO, M.J.; GIANELLO, C.; BIASSANI, C. A.; BOHNEN, H.; VOLKWEISS, S. J. **Análise de solos, plantas e outros materiais**. Porto Alegre: UFRGS, Departamento de Solos/Faculdade de Agronomia, 1995. 174p. (Boletim Técnico; 5).

TOKOLA, T.; HOU, Z. Alternative remote sensing materials and inventory strategies in tropical forest inventory – Case Lao PDR. **Ambiência**. Ed. Especial. v. 8. p. 483-500. 2012.

TROTTER, C.M.; DYMOND, J.R.; GOULDING, C.J. Estimation timber in a coniferous plantation forest using Landsat TM. **International Journal of Remote Sensing**. v. 18. n.10. p. 2209-2223. 1997.

TUCKER, C. Red and photographic infrared linear combinations for monitoring vegetation. **Remote Sensing of Environment**. v.8. p. 127-150. 1979.

UNFCCC - United Nations Framework Convention on Climate Change. Reducing emissions from deforestation in developing countries: Approaches to stimulate action.FCCC/SBSTA/2008/L.12. UNFCCC Secretariat, Bonn, Germany. Acesso em: 20/10/2012. Disponível em: <http://unfccc.int/resource/docs/2008/sbsta/eng/l12.pdf>.

VELOSO, R. B.; RANGEL FILHO, A. L. R.; LIMA, J. C. A. **Classificação da vegetação brasileira, adaptada a um sistema universal**. IBGE, Departamento de Recursos Naturais e Estudos Ambientais. Rio de Janeiro. 1991. 124p.

VIEIRA, S.A.; ALVES, L.F.; AIDAR, M.P.M.; ARAÚJO, L.S.; BAKER, T.; BATISTA, J.L.F.; CAMPOS, M.C.R.; CAMARGO, P.B.; CHAVE, J.; DELITTI, W.B.; HIGUCHI, N.; HONÓRIO, E.; JOLY, C.A.; KELLER, M.; MARTINELLI, L.A.; DE MATTOS, E.A.; METZKER, T.; PHILLIPS, O.; SANTOS, F.A.M.; SHIMABUKURO, M.T.; SILVEIRA, M.; TRUMBORE, S. E. Estimation of biomass and carbon stocks: the case of the Atlantic Forest. **Biota Neotropica**. v.8. n.2. p. 21-29. 2008.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R.; SCHUMACHER, M. V. Fixação de Carbono em Floresta Ombrófila Mista em diferentes estágios de regeneração. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILLOTTO, M. A. B; GOMES, F. S. **As florestas e o carbono**. Curitiba, p. 153 – 174. 2002.

WATZLAWICK, L. F. **Estimativa de biomassa e carbono em Floresta Ombrófila Mista e plantações florestais a partir de dados de imagens de satélite IKONOS II**. 120p. Tese (Doutorado em Ciências Florestais) – Setor de Ciências Agrárias, Universidade Federal do Paraná. Curitiba, 2003.

WATZLAWICK, L. F.; BALBINOT, R.; SANQUETTA, C. R.; CALDEIRA, M. V. W. Teores de carbono em espécies da Floresta Ombrófila Mista. In: SANQUETTA, C. R.; BALBINOT, R.; ZILLOTTO, M. A. B. **Fixação de carbono: atualidades, projetos e pesquisas**. Curitiba: AM Impressos, p. 95-109, 2004.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANQUETTA, C. R. Estimativa de biomassa e carbono em floresta com araucária utilizando Imagens do satélite Ikonos II. **Ciência Florestal**. v. 19. n. 2. p. 169-181. 2009.

WEBER, K. S.; SANQUETTA, C. R.; EISFELD, R. L. Variação volumétrica e distribuição espacial do estoque de carbono em Floresta Ombrófila Mista. **Revista Acadêmica Ciências Agrárias e Ambientais**. Curitiba, v.3. n.2. p. 77-85. 2005.

WEZYK, P. The integration of the terrestrial and airborne laser scanning technologies in the semi-automated process of retrieving selected trees and forest stand parameters. **Ambiência**. Ed Especial. v. 8. p. 533-548. 2012.

WOODCOCK, C.E.; STRAHLER, A.H. The factor of scale in Remote Sensing. **Remote Sensing of the Environment**. v. 21. p. 311-332. 1987.

WULDER, M; WHITE, J; FOURNIER, R; LUTHER, J; MAGNUSSEN, S. Spatially explicit large area biomass estimation: Three approaches using forest inventory and remotely sensed imagery in a GIS. **Sensors**, v. 8. p. 529–560. 2008.

YAMAGUCHI, Y.; KAHLE, A.B.; TSU, H.; KAWAKAMI, T.; PNIEL, M. Overview of Advanced Spaceborne Thermal Emission and Reflection Radiometer (ASTER). **IEEE Transactions On Geoscience and Remote Sensing**. v.36, no. 4. p. 1062-1071. 1998.

YU, C. M. Caracterização e tipologia dos projetos de sequestro de carbono no Brasil. In: SANQUETTA, C. R.; WATZLAWICK, L. F.; BALBINOT, R.; ZILIOOTTO, M. A. B; GOMES, F. S. **As florestas e o carbono**. Curitiba. p. 59-87. 2002.

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