

ANTONIO SANTANA FERRAZ

**ESTIMAÇÃO DOS ESTOQUES DE BIOMASSA E CARBONO NA PARTE  
AÉREA DE UM FRAGMENTO DE FLORESTA ESTACIONAL  
SEMIDECIDUAL POR MEIO DE IMAGENS DE SATÉLITE IKONOS II**

Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

VIÇOSA  
MINAS GERAIS – BRASIL  
2012

**Ficha catalográfica preparada pela Seção de Catalogação e  
Classificação da Biblioteca Central da UFV**

T

F381e  
2012

Ferraz, Antonio Santana, 1954-

Estimação dos estoques de biomassa e carbono na parte  
aérea de um fragmento de floresta estacional semidecidual por  
meio de imagens de satélite IKONOS II / Antonio Santana

Ferraz. – Viçosa, MG, 2012.

xiii, 88f. : il. (algumas col.) ; 29cm.

Orientador: Vicente Paulo Soares.

Tese (doutorado) - Universidade Federal de Viçosa.

Referências bibliográficas: f. 79-88

1. Biomassa florestal. 2. Florestas. 3. Vegetação -  
Classificação. 4. Carbono. 5. Redes neurais (Computação).  
6. Imagens de satélite. I. Universidade Federal de Viçosa.  
II. Título.

CDO adapt. CDD 634.989

ANTONIO SANTANA FERRAZ

**ESTIMAÇÃO DOS ESTOQUES DE BIOMASSA E CARBONO NA PARTE  
AÉREA DE UM FRAGMENTO DE FLORESTA ESTACIONAL  
SEMIDECIDUAL POR MEIO DE IMAGENS DE SATÉLITE IKONOS II**

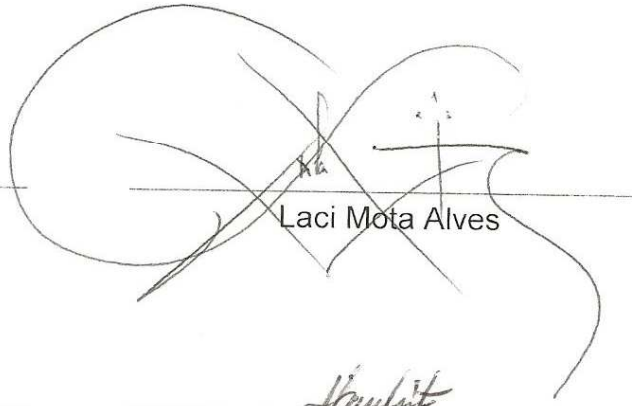
Tese apresentada à Universidade Federal de Viçosa, como parte das exigências do programa de Pós-Graduação em Ciência Florestal, para obtenção do título de *Doctor Scientiae*.

APROVADA: 28 de junho de 2012.



---

Joel Grippo Junior



---

Laci Mota Alves



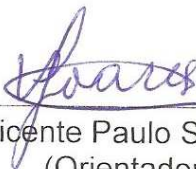
---

Carlos Pedro Boechat Soares  
(Coorientador)



---

Hélio Garcia Leite  
(Coorientador)



---

Vicente Paulo Soares  
(Orientador)

## AGRADECIMENTOS

À Universidade Federal de Viçosa, por ter me proporcionado a oportunidade, com a liberação de minhas atividades acadêmicas, para o desenvolvimento do meu treinamento.

Ao Departamento de Engenharia Florestal da UFV (DEF-UFV), pela oportunidade concedida para a realização do meu treinamento.

Aos companheiros do Departamento de Engenharia Civil da UFV (DEC-UFV), pelas constantes manifestações de apoio e pelo estímulo manifestados antes e durante o treinamento.

Ao meu orientador, professor Vicente Paulo Soares, pela amizade, pelo incentivo, pelas sugestões e pelo apoio permanente durante todas as etapas da execução dos trabalhos.

Ao professor Hélio Garcia Leite e ao engenheiro florestal Daniel Binoti, que foram fundamentais no auxílio nos trabalhos de análise estatística dos resultados e das configurações das redes neurais artificiais.

Ao professor Carlos Pedro Boechat Soares, pelo apoio, pelo incentivo, pelas sugestões e pela valiosa contribuição na interpretação dos resultados.

Aos professores Agostinho Lopes de Souza, José Marinaldo Gleriani e Carlos Antônio Álvares Soares Ribeiro, pelas inúmeras sugestões e pela pronta disposição em discutir e sanar as muitas dúvidas que ocorreram no desenvolvimento do trabalho.

Ao professor Joel Gripp Júnior do (DEC-UFV), pela amizade e consideração. Sempre solícito em colaborar, dirimir as dúvidas e apresentar sugestões, principalmente nos trabalhos referentes ao procedimento de ortorretificação da imagem utilizada.

Ao professor Marco Antônio Amaro, da Universidade Federal do Acre, tanto na presteza em nos auxiliar na identificação da localização das parcelas experimentais na área de estudo quanto em disponibilizar os dados do inventário florestal.

Ao professor Rafael Kopschitz Xavier Bastos (DEC-UFV), pela disponibilização das imagens IKONOS II, utilizadas na pesquisa, adquiridas inicialmente para o projeto “Plano de Segurança da Água”.

Ao Patrick Bromatti, Bruno Rocha, Thiago Soares e Luiz Henrique Falchetto, pelo valioso auxílio nos trabalhos de levantamento topográfico conduzidos na área de estudo, com vistas à obtenção das coordenadas dos limites das parcelas.

À Dra. Cláudia Saltarelli Saraiva, do Instituto de Geociências Aplicadas do Estado de Minas Gerais (IGA-MG), pelo apoio necessário à permissão do uso do *software* PCI Geomatics.

Ao Geraldo Cândido Faria, auxiliar do Laboratório de Engenharia de Agrimensura, tanto pela preocupação com as condições dos equipamentos utilizados nos trabalhos de campo quanto pela disponibilidade em colaborar nos trabalhos durante toda a fase de desenvolvimento da pesquisa.

A meu pai, hoje não mais entre nós, e à minha mãe, que não mediram esforços para ver os seus filhos formados.

À minha esposa, Silvana, meu porto seguro; e aos meus filhos, Gabriel e Erich, que, com o permanente apoio, incentivo, carinho e compreensão, me proporcionaram segurança e tranquilidade na condução dos trabalhos em todas as etapas do treinamento.

# SUMÁRIO

	Página
RESUMO .....	x
ABSTRACT .....	xii
1 INTRODUÇÃO .....	1
2 OBJETIVOS .....	5
2.1 Objetivo geral .....	5
2.2 Objetivo específico .....	5
3 REVISÃO DE LITERATURA .....	6
3.1 Números digitais, radiância e reflectância .....	6
3.2 Correção geométrica .....	10
3.3 Correção atmosférica .....	12
3.4 Conversão de números digitais em radiância espectral .....	14
3.5 Conversão da radiância espectral em reflectância aparente .....	15
3.6 Índices de vegetação .....	16
3.7 Redes Neurais Artificiais (NRA) .....	28
3.8 Estimativas de biomassa e carbono com o uso de imagens de satélites .....	30
4 MATERIAL E MÉTODOS .....	37
4.1 Caracterização da área de estudo .....	37
4.2 Materiais, equipamentos e <i>softwares</i> .....	37
4.3 Imagens IKONOS II utilizadas na pesquisa .....	39
4.4 Modelo Digital de Elevação (MDE) .....	39
4.5 Ortorectificação .....	39
4.6 Inventário de biomassa e carbono .....	45
4.7 Limites das parcelas amostrais na imagem .....	46
4.8 Conversão dos números digitais em reflectância planetária .....	49
4.9 Estimativa da biomassa e do carbono aéreo a partir das imagens IKONOS II .....	52
4.9.1 Estimativas por de análise de regressão linear .....	52
4.9.2 Redes Neurais Artificiais (RNA) .....	56
5 RESULTADOS E DISCUSSÃO .....	57
5.1 Estimação da biomassa e do carbono por meio de análise de regressão .....	57
5.2 Estimação da biomassa e do carbono por meio de RNA .....	66

	<b>Página</b>
5.3 Comparação dos estoques de biomassa e carbono estimados pela análise de regressão e redes neurais.....	73
6 CONCLUSÕES.....	78
7 REFERÊNCIAS BIBLIOGRÁFICAS.....	79

## LISTA DE TABELAS

	<b>Página</b>
1 Parâmetros das bandas sensor IKONOS II – Imagens de 11 bits ...	14
2 Coeficientes <i>Tasseled Cap</i> para o sensor IKONOS II.....	27
3 Imagens brutas do satélite IKONOS II adquiridas pelo PSA.....	39
4 Estoque total médio de biomassa (t/ha) nas parcelas.....	47
5 Estoque total médio de carbono (t/ ha) nas parcelas .....	47
6 Metadados das imagens utilizadas na pesquisa .....	50
7 Elementos astronômicos do Sol (0 <sup>h</sup> tempo Terrestre, out./2007).....	51
8 Variáveis dependentes.....	53
9 Variáveis independentes.....	53
10 Estimativas de biomassa e carbono do inventário florestal (t ha <sup>-1</sup> ) ..	54
11 Valores médios da reflectância nas parcelas experimentais.....	55
12 Valores médios dos índices de vegetação nas parcelas experi- mentais.....	55
13 Matriz de correlação entre as variáveis dependentes e indepen- dentes .....	57
14 Equações para estimar a biomassa total .....	61
15 Equações para estimar o estoque de carbono.....	62
16 Estimativas de biomassa total: inventário e modelos de regressão.	63
17 Estimativas de carbono total: inventário e modelos de regressão ...	64
18 Configurações das redes neurais artificiais testadas .....	67
19 Estimativas de biomassa: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada .....	67
20 Estimativas de carbono: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada .....	68



	<b>Página</b>
21 Estimativas de biomassa: inventário e estimado por RNA com os índices de vegetação como variáveis de entrada .....	69
22 Estimativas de carbono: inventário e estimado e por RNA com os índices de vegetação como variáveis de entrada .....	70
23 Estimativas de biomassa: inventário e estimado por RNA com as bandas espectrais e índices de vegetação como variáveis de entrada .....	71
24 Estimativas de carbono: inventário e estimado por RNA com as bandas espectrais e índices de vegetação como variáveis de entrada .....	72
25 Resíduos das estimativas da biomassa total por RNA.....	74
26 Resíduos das estimativas de carbono por RNA.....	74

## LISTA DE FIGURAS

	<b>Página</b>
1 Resposta espectral de uma folha verde sadia .....	8
2 Geometria das distorções na imagem causadas pelo relevo .....	12
3 Linha de solo .....	19
4 Estrutura de uma RNA .....	28
5 Localização da área de estudo .....	38
6 Distribuição dos pontos de controle na imagem bruta .....	41
7 Distribuição dos pontos de checagem na imagem bruta.....	42
8 Ponto de controle – Rastreo no campo e sua posição imagem .....	43
9 Ponto de checagem – Rastreo no campo e sua posição imagem...	43
10 Avaliação das deformações em um ponto de controle.....	44
11 Indivíduos e fustes das famílias mais encontradas nas unidades amostrais.....	45
12 Localização e distribuição das parcelas no fragmento estudado .....	48
13 Modelo para geração da imagem com os valores de radiância .....	49
14 Imagens de radiância da área de estudo .....	50
15 Modelo para geração das imagens com os valores de reflectância	51
16 Imagens de reflectância da área de estudo .....	52
17 Representação das correlações entre biomassa e carbono com os índices de vegetação calculados.....	59
18 Representação das correlações entre biomassa e carbono com as bandas 1, 2, 3 e 4.....	60
19 Estoque de biomassa do inventário e modelos de regressão .....	63
20 Estoque de carbono do inventário e modelos de regressão .....	64
21 Análises de resíduos das estimativas de biomassa total, obtidas a partir das variáveis Banda4 e TCap1 .....	65

	<b>Página</b>
22 Análises de resíduos das estimativas de carbono total, obtidas a partir das variáveis Banda4 e TCap1 .....	65
23 Representação gráfica do estoque de biomassa: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada .....	67
24 Representação gráfica do estoque de carbono: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada).....	68
25 Representação gráfica do estoque de biomassa: inventário e observado e estimado por RNA com os índices de vegetação como variáveis de entrada	69
26 Representação gráfica do estoque de carbono: inventário e estimado por RNA com os índices de vegetação como variáveis de entrada .....	70
27 Representação gráfica do estoque de biomassa: inventário e estimado por RNA com todas as variáveis de entrada consideradas no estudo .....	71
28 Representação gráfica do estoque de carbono: inventário e estimado por RNA com todas variáveis de entrada consideradas no estudo) .....	72
29 Biomassa total observada e biomassa total estimada por regressão e por redes neurais artificiais.....	75
30 Resíduos percentuais das estimativas da biomassa total obtidos por meio de regressão .....	75
31 Resíduos percentuais das estimativas de biomassa total obtidos por meio de RNA.....	76

## RESUMO

FERRAZ, Antonio Santana, D.Sc., Universidade Federal de Viçosa, junho de 2012. **Estimação dos estoques de biomassa e carbono na parte aérea de um fragmento de floresta estacional semidecidual por meio de imagens de satélite IKONOS II.** Orientador: Vicente Paulo Soares. Coorientadores: Carlos Pedro Boechat Soares e Carlos Antônio Soares Álvares Ribeiro.

Estimativas de massa e carbono em povoamentos florestais podem ser obtidas empregando-se equações alométricas. Imagens de alta resolução, provenientes de sensores remotos, também têm sido amplamente utilizadas para estimar massa e carbono de árvores, com base em variáveis digitais (valores de radiância/reflectância e índices de vegetação) extraídas das imagens. No caso de florestas naturais, normalmente heterogêneas, com grande diversidade florística, fisionômica e fenológica, a utilização desta técnica reveste-se de maior complexidade, uma vez que há pouca disponibilidade de dados quantitativos de biomassa coletados em nível de campo, havendo, assim, carência de pesquisas que integrem dados de diferentes fontes, como inventários florestais e imagens de satélites, na obtenção daquelas estimativas. Nesta pesquisa, imagens do satélite IKONOS II foram utilizadas para obtenção das estimativas de biomassa aérea e do estoque de carbono de um fragmento de Floresta Estacional Semidecidual, situada no município de Viçosa, MG, em uma área denominada “Mata da Silvicultura”, pertencente à Universidade Federal de Viçosa. Com base em dados de inventário florestal, conduzido em 15 parcelas de 1.000 m<sup>2</sup> (20 m x 50 m), foram obtidas as estimativas dos estoques de biomassa e carbono acima do terreno, a partir de equações alométricas. Estas estimativas foram relacionadas com variáveis digitais (reflectância nas quatro bandas multiespectrais e nos 12 índices de vegetação), extraídas das imagens do satélite IKONOS II, empregando-se análise de regressão e redes neurais artificiais (RNA). Na análise de regressão, as maiores correlações (significativas) com biomassa e carbono foram observadas para as variáveis independentes Banda2 e Banda4 e os índices de vegetação GEMI, SAVI, TCap1, TCap2 e TCap3. Porém, apenas as variáveis Banda4 e TCap1 foram suficientes para estimar tanto a biomassa total quanto o estoque de carbono. No caso

das estimativas da biomassa, foram obtidos o coeficiente  $r^2 = 0,394$  para a variável Banda4 e  $r^2 = 0,496$  para a variável TCap1. Já para o caso das estimativas do estoque de carbono, foi obtido o coeficiente Banda4  $r^2 = 0,400$  para a variável Banda4 e  $r^2 = 0,504$  para a variável TCap1. Por meio do treinamento de redes neurais verificou-se que a utilização das quatro bandas espectrais do satélite IKONOS II, como variáveis de entrada, mostraram-se suficientes para estimar os estoques de biomassa e carbono, para o caso da área de estudo. Os resíduos obtidos com o emprego da análise de regressão ultrapassaram 60%, enquanto resíduos na faixa de  $\pm 1,5\%$  foram obtidos a partir das redes neurais.

## ABSTRACT

FERRAZ, Antonio Santana, D.Sc., Universidade Federal de Viçosa, June, 2012. **Aboveground biomass and carbon stock estimations in a semi-deciduous forest using IKONOS II images.** Adviser: Vicente Paulo Soares. Co-advisers: Carlos Pedro Boechat Soares and Carlos Antônio Soares Álvares Ribeiro.

Estimates of carbon and biomass in forested areas can be obtained using allometric equations. High resolution remote sensing imagery has also been widely used to estimate tree carbon biomass, based on digital variables (radiance/reflectance values and vegetation indices) extracted from images. In natural forests, that are typically heterogeneous and present high floristic, physiognomical and phenological diversity, the use of this technique is more complex since there is little quantitative biomass data collected in the field and a lack of research that integrates data from different sources such as forest inventories and satellite images to obtain estimates. In this study a set of IKONOS II satellite images was used to estimate aerial biomass and carbon stock in a semideciduous seasonal forest fragment located in Viçosa, MG, in an area known as “Mata da Silvicultura”, belonging to the Universidade Federal de Viçosa. Estimates of above ground biomass and carbon stocks were obtained with allometric equations based on forest inventory data conducted in fifteen 1,000 m<sup>2</sup> (20 m × 50 m) parcels. These estimates were related to digital variables (reflectance of four spectral bands and 12 vegetation indices) extracted from IKONOS II satellite images using regression analysis and an artificial neural network. In regression analysis the highest (significant) correlations to carbon stock and biomass were found for the spectral bands 2 and 4 and the GEMI, SAVI, TCap1, TCap2 and TCap3 vegetation indices. However, only variables Band4 and TCap1 were necessary for estimating both total biomass and carbon stock. For biomass estimates, correlation coefficients of  $r^2 = 0.394$  for Band4, and  $r^2 = 0.496$  for TCap1 were observed. For carbon stock estimates, correlations of  $r^2 = 0.400$  with Band4 and  $r^2 = 0.504$  for TCap1 were found. Through neural network training it was found that use of the four IKONOS II satellite spectral bands as input variables were sufficient to estimate biomass and carbon stocks for the area studied. Residuals obtained using

regression analysis exceeded 60% while residuals in the range of  $\pm 1.5\%$  were obtained using neural networks.

## 1 INTRODUÇÃO

O aumento da concentração de gases de efeito estufa na atmosfera terrestre, notadamente do dióxido de carbono ( $\text{CO}_2$ ), do metano ( $\text{CH}_4$ ) e do óxido nitroso ( $\text{N}_2\text{O}$ ), é uma das questões de ampla discussão em nível mundial. Com este aumento ocorre uma maior retenção da radiação solar incidente sobre a Terra, que seria refletida para o espaço em condições normais, conduzindo ao chamado aquecimento global, com diversas alterações relacionadas ao clima, como, por exemplo, o aumento da temperatura média da Terra, a alteração no regime de chuvas e o derretimento das calotas polares.

Em virtude da quantidade com que é emitido, o  $\text{CO}_2$  é o gás que mais contribui para o aquecimento global. Suas emissões representam, aproximadamente, 55% do total das emissões mundiais de gases do efeito estufa (GEE). O tempo de sua permanência na atmosfera é, no mínimo, de 100 anos. Isto significa que as emissões de hoje têm efeitos de longa duração, podendo resultar em impactos no regime climático ao longo dos séculos (PÉLLICO NETTO, 2008).

No Brasil, o Inventário de Emissões e Remoções Antrópicas de Gases de Efeito Estufa, não controlados pelo Protocolo de Montreal, mostra que, no ano de 1994, 75,4% das emissões de dióxido de carbono ( $\text{CO}_2$ ) foram provenientes das mudanças no uso da terra e das florestas; e 23% do setor de energia, valores similares aos obtidos para o ano de 2005. Estes valores evidenciam que, diferentemente dos países industrializados, aqui a maior parcela das emissões líquidas de  $\text{CO}_2$  é proveniente da mudança do uso da



terra, em particular da conversão de florestas para uso agropecuário (MCT, 2004; MCT, 2009).

Por meio da fotossíntese as plantas absorvem a energia solar e o CO<sub>2</sub> da atmosfera, produzindo oxigênio e compostos de carbono, que servem de base para a formação da estrutura vegetal. Desta forma, além de oferecer uma variedade de serviços ambientais, como a proteção e a recarga das bacias hidrográficas, a regulação do clima, a proteção do solo e a conservação da biodiversidade, dentre outros, as florestas têm ainda um importante papel no ciclo global do carbono (MARTINELLI; CAMARGO, 1996).

A redução de emissões de gases de efeito estufa, por meio de cooperação entre países desenvolvidos, foi estabelecida no artigo 12, do Protocolo de Quioto, pelo chamado Mecanismo de Desenvolvimento Limpo (MDL), que objetiva auxiliar os países desenvolvidos a financiar projetos em países em desenvolvimento, como forma de cumprir suas metas de redução de emissões no âmbito do referido Protocolo e, ao mesmo tempo, contribuir para o desenvolvimento sustentável dos países anfitriões (UNFCCC, 1998).

O florestamento e o reflorestamento estão entre as modalidades contempladas para a compensação de emissões de CO<sub>2</sub> como um MDL. As definições e as modalidades para a inclusão destas atividades no MDL foram estabelecidas na 9ª Conferência das Partes, realizada em Kyoto, Japão, em dezembro de 2003, possibilitando, assim, a captação de recursos financeiros pela geração de reduções certificadas de emissão, ou “créditos de carbono” (ROCHA, 2004).

Projetos que visam à preservação de áreas ameaçadas, bem como as atividades que impeçam o desmatamento, ainda são inelegíveis no MDL. Entretanto, outros mecanismos envolvendo ações voltadas à redução de emissões de gases de efeito estufa, com base na redução do desmatamento, da degradação, da conservação florestal e do manejo sustentável, têm sido propostos, como é o caso do REDD (*Reducing Emissions from Deforestation and Forest Degradation*), que necessitarão do conhecimento dos estoques de carbono (CENAMO; CARRERO, 2012).

Por outro lado, além de ser um elemento básico para estudos de sequestro de carbono, o conhecimento da biomassa florestal é também importante em outras áreas, como, por exemplo, na avaliação da regeneração natural de matas ciliares; subsídios aos estudos relacionados à conservação de

recursos naturais; estudos relacionados à quantificação da ciclagem de nutrientes; e planejamento energético em regiões onde a biomassa florestal é utilizada como combustível primário para geração de energia (WATZLAWICK, 2003; ALMEIDA *et al.* 2006; SILVEIRA, 2010).

Os estudos de quantificação de biomassa em campo são trabalhosos, demorados e muito onerosos, podendo ser realizados por meio de métodos diretos e indiretos. Pelo método direto, todas as árvores são cortadas e seus componentes separados e pesados. Estas porções são pesadas no campo (componentes maiores) ou no laboratório (componentes menores), sendo que as análises do teor de carbono são efetuadas por diferentes metodologias propostas para o caso (HIGUCHI; CARVALHO JR., 1994; WATZLAWICK, 2003).

Segundo Smogyi *et al.* (2006), as estimativas de biomassa para grandes áreas florestais têm sido obtidas de forma indireta, com base em informações originárias de inventário florestal. Equações de biomassa são utilizadas para transformar dados de altura, diâmetro e volume em estimativas de biomassa.

Nos últimos anos, com a disponibilidade de imagens de alta resolução, provenientes de sensores remotos e os avanços nas técnicas de processamento digital destas imagens, o sensoriamento remoto tem sido utilizado para estudos relacionados à estimativa de biomassa florestal e ao sequestro de carbono, com base na associação do conteúdo de biomassa e carbono aos valores de radiância/reflectância, obtidos com a utilização de imagens de satélite (WATZLAWICK *et al.*, 2009)

Normalmente, estas estimativas são efetuadas com a utilização dos chamados índices de vegetação (IVs) e outras variáveis extraídas de imagens de sensoriamento remoto, apresentando a grande vantagem de proporcionar a acessibilidade de informações em locais remotos de difícil acesso, além de menos onerosos, em termos de trabalhos de campo, quando comparados aos métodos tradicionais.

Técnicas de sensoriamento remoto têm sido amplamente empregadas na área florestal. A análise comparativa entre os resultados relacionados à quantificação da biomassa, obtidos por meio de técnicas de sensoriamento remoto, como aqueles oriundos das técnicas tradicionais, é facilitada quando envolve o caso de florestas plantadas, por de serem normalmente constituídas de apenas um gênero e periodicamente inventariadas (SILVEIRA *et al.*, 2008).

Entretanto, no caso de florestas naturais, normalmente heterogêneas, com grande diversidade florística, fisionômica e fenológica, a utilização desta técnica reveste-se de maior complexidade, uma vez que há pouca disponibilidade de dados quantitativos de biomassa coletados em nível de campo (SOUZA; PONZONI, 1998). Desta forma, há carência de pesquisas que integrem dados de diferentes escalas e fontes, como inventários florestais e imagens de satélites, para a obtenção de mapas de distribuição de dados biofísicos para florestas naturais (SCHOENINGER, 2008b).

Segundo Lu (2006), a técnica de sensoriamento remoto vem sendo aplicada com maior frequência para estimar biomassa aérea das árvores. Porém, é um procedimento complexo, que envolve muitos fatores, como condições atmosféricas, dados insuficientes nas amostras, mistura de pixels, saturação de dados, complexidades dos ambientes biofísicos, etc., que podem afetar a exatidão das estimativas.

## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Estimar a massa seca do fuste e a correspondente massa de carbono em um povoamento inequiâneo utilizando dados de sensoriamento remoto.

### **2.2 Objetivo específico**

Verificar, por meio de análises estatísticas e utilização das redes neurais artificiais, a potencialidade da utilização dos valores digitais das bandas espectrais e dos índices de vegetação nas estimativas de massa e carbono em povoamento inequiâneo.

### 3 REVISÃO DE LITERATURA

#### 3.1 Números digitais, radiância e reflectância

As imagens digitais, produzidas pelos sensores remotos, são normalmente armazenadas como uma matriz de números, gerados após a interação da radiação eletromagnética com o alvo. Cada pixel na linha (i) e na coluna (j) da matriz tem um valor de brilho ou valor de intensidade a ele associado, denominado de número digital (ND). Quanto maior a variação possível dos valores de brilho, mais precisas serão as medidas de quantidade de radiação detectada pelo sensor (JENSEN, 2009).

A radiação solar, refletida por um elemento qualquer situado na superfície da Terra, é convertida em valores digitais, que são atribuídos a cada pixel que compõe a imagem original da cena, representando a radiação média refletida ou emitida pelos elementos existentes na área definida pelo pixel. Estes números, conhecidos como números digitais (NDs), são dependentes de um conjunto de fatores, como a data da aquisição da imagem, das condições atmosféricas no instante da aquisição, do relevo da área imageada, da banda espectral, da posição do sensor, bem como das características biofísicas do elemento considerado. Entretanto, os valores originais dos números digitais não têm significado físico algum, ou seja, não representam quantitativamente uma grandeza física, como, por exemplo, radiância, reflectância ou temperatura, não servindo, assim, para a caracterização espectral de objetos (CHEN; HERZ, 1996; CROSTA, 1999; PONZONI, 2007).


Conhecendo-se algumas características do sensor, pelo qual a imagem foi gerada, bem como as condições ambientais no momento da sua aquisição, é possível efetuar a conversão dos números digitais para valores físicos. Mesmo considerando-se imagens de um mesmo sensor tomadas em diferentes épocas, esta conversão é necessária e possibilita uma comparação mais efetiva destes valores físicos, uma vez que os parâmetros de calibração são modificados ao longo da vida do sensor. Obviamente, o mesmo raciocínio deve ser aplicado aos elementos extraídos de imagens em bandas espectrais similares, porém, de diferentes sensores, uma vez que estes apresentam diferentes sensibilidades à radiação. Também, com os números digitais convertidos em reflectância aparente, é possível realizar operações aritméticas utilizando imagens de diferentes bandas espectrais de um mesmo sensor ou mesmo de sensores distintos, uma vez que novos valores digitais passam a representar um parâmetro físico apresentado em uma mesma escala (PONZONI; SHIMABUKURO, 2007; CHUVIECO; HUETE, 2010).

A radiância ( $L$ ) é a grandeza radiométrica fundamental em sensoriamento remoto, uma vez que descreve exatamente a medida efetuada pelo sensor. Representa a intensidade radiante por unidade de área-fonte projetada em uma direção específica. Normalmente, o sensoriamento remoto é medido em  $W/m^2/Sr$ , ou seja, Watts por unidade de área da fonte emissora ( $m^2$ ), por unidade de ângulo sólido (esterradiano). Quando a radiância é relacionada a um determinado comprimento de onda é chamada de radiância espectral ( $L_\lambda$ ), medida agora em  $W/m^2/Sr/\mu m$ , ou seja, Watts por unidade de área da fonte emissora ( $m^2$ ), por unidade de ângulo sólido (esterradiano) e por unidade de comprimento de onda ( $\mu m$ ) (SCHOWENGERDT, 2007; JENSEN, 2009; CHUVIECO; HUETE, 2010).

A reflectância, grandeza adimensional que representa a razão entre a energia radiante refletida e a energia radiante incidente em um determinado alvo, variável com o comprimento de onda e com as características do alvo, é calculada em função da radiância.

Quando se buscam elementos diversos sobre a vegetação, com base em dados do sensoriamento remoto, é fundamental conhecer a interação da radiação solar com a vegetação.

O comportamento da radiação solar, após sua interação com uma folha verde e sadia, está representado na Figura 1.



Fonte: adaptada de Hoffer (1978) e Mather (2009).

Figura 1 – Resposta espectral de uma folha verde sadia.

De acordo com Chuvieco e Huete (2010), na região do espectro visível (0,40 a 0,70 μm), a pigmentação das folhas é o fator fundamental pela baixa reflectância, onde a maior parte da energia incidente é absorvida pelos pigmentos predominantes na folha (clorofila, em maior quantidade, carotenóides, xantofilas e antocianinas), utilizados no processo de fotossíntese. Todos estes pigmentos absorvem na região do azul (0,4 a 0,5 μm), enquanto a clorofila absorve também na região do vermelho (0,6 a 0,7 μm). Entre o azul e o vermelho há uma região com menos intensidade de absorção (pico de reflectância verde -0,5 a 0,6 μm), que é responsável pela aparência verde das folhas. Os termos fAPAR (fração da radiação fotossinteticamente absorvida) ou IPAR (*incident photosynthetically active radiation*) são frequentemente utilizados para descrever a radiação nesta faixa do espectro eletromagnético.

Na região do IV próximo (0,70 a 1,2 μm) ocorre um aumento da reflectância, que está relacionada com as alterações das propriedades óticas das folhas relacionadas com as estruturas celulares internas. Há muito pouca

absorção e um considerável espalhamento interno da radiação incidente, formando-se um platô de reflectância.

Já a região do IV médio (de 1,2 – 2,5  $\mu\text{m}$ ) é caracterizada pela forte absorção da radiação pela água existente nas células das folhas. Quanto maior a quantidade de água líquida presente na folha maior será a absorção e, conseqüentemente, menor a reflectância. Os comprimentos de onda de 1,45 e 1,95  $\mu\text{m}$  não são utilizados no sensoriamento remoto da Terra, uma vez que a absorção é tão forte que grande parte da radiação solar não atinge o solo.

Em algumas regiões do espectro eletromagnético, conhecidas como janelas atmosféricas, ocorre baixa absorção da radiação solar, acarretando em alta transmitância, ou seja, a atmosfera é parcialmente transparente à radiação solar. Segundo Chuvieco e Huete (2010), as principais janelas atmosféricas estão localizadas entre 0,3 e 1,35  $\mu\text{m}$  (espectro visível e infravermelho próximo), diversas faixas no infravermelho médio (1,5 a 1,8  $\mu\text{m}$ , 2,0 a 2,4  $\mu\text{m}$ , 2,9 a 4,2  $\mu\text{m}$  e 4,5 a 5,5  $\mu\text{m}$ ), entre 8 e 14  $\mu\text{m}$  no infravermelho termal e, acima de 20  $\mu\text{m}$ , onde a atmosfera é praticamente transparente.

Estas peculiaridades são utilizadas na concepção dos sensores de satélites, com o objetivo de se evitar ao máximo os efeitos das atenuações atmosféricas na radiação solar.

A reflectância de um dossel se assemelha à reflectância de uma folha, ocorrendo, entretanto, variações ocasionadas por fatores morfológicos (índice de área foliar, densidade de plantio, ângulo de inserção foliar, altura do dossel, tamanho das folhas e da copa, densidade e distribuição de galhos e folhas) e fisiológicos (idade da planta, déficit hídrico, nutrientes, etc.), que influenciam a interceptação, a absorção e a reflexão da luz solar (KNIPLING, 1970; MYNENI *et al.*, 1995a; MOREIRA, 2007).

Por outro lado, outros elementos relacionados ao instante da aquisição da imagem, como, por exemplo, o ângulo de elevação e o azimute do Sol, ângulo de visada do sensor e a distância Terra-Sol, podem proporcionar variações na radiância da superfície e, conseqüentemente, na sua reflectância.

Na presente pesquisa interessa os valores de reflectância ( $\rho$ ), uma vez que se irá trabalhar com índices de vegetação (IVs), que são amplamente utilizados como indicadores da existência e das condições da vegetação e,



consequentemente, em estimativas de biomassa. Como os índices mais utilizados são originados por razões de reflectância, torna-se, então, necessária a obtenção dos valores de reflectância ( $\rho$ ), em função dos números digitais (ND).

### 3.2 Correção geométrica

Segundo Crosta (1999), imagens de sensoriamento remoto, sejam fotografias aéreas ou imagens de satélite, estão sujeitas a uma série de distorções espaciais e não possuem precisão cartográfica em relação ao posicionamento de objetos, à superfície ou aos fenômenos representados nas mesmas, não podendo, assim, serem consideradas como mapas.

Entretanto, frequentemente, informações presentes em fotografias aéreas e em imagens oriundas de sensores orbitais são extraídas para integrar bases de dados em sistemas de informações espaciais, sem que sejam consideradas as distorções espaciais que, no caso de sensores orbitais, são influenciadas principalmente pelas variações de altitude, posição e velocidade da plataforma, pelo movimento do espelho de imageamento, pela curvatura da superfície terrestre e pelo movimento de rotação da Terra.

Desta forma, para que uma imagem de sensoriamento remoto assuma as propriedades de escala e de projeção de um mapa torna-se necessário proceder à sua correção geométrica, que tem a função de reorganizar os pixels da imagem em relação a um determinado sistema de projeção cartográfica.

Kardoulas *et al.* (1996) destacam que a correção geométrica em imagens provenientes de sensoriamento remoto é requerida em diversas situações, como:

- aplicar um sistema de projeção cartográfico em uma imagem;
- localizar pontos de interesse tanto no mapa quanto na imagem;
- coincidir imagens adjacentes em um registro;
- efetuar análise de imagens de uma mesma área, obtidas em diferentes datas ou mesmo de diferentes sensores; e
- sobrepor uma imagem em um mapa ou integrá-la em um banco de dados de sistemas de informação geográfica (SIGs).

Entre os vários termos utilizados para descrever correção geométrica de imagens, Schowengerdt (2007) apresenta as seguintes definições:

**Registro:** alinhamento de uma imagem para outra imagem de mesma área. Quaisquer dois pixels de mesma localização em ambas as imagens estão registrados, representando duas amostras do mesmo ponto na superfície terrestre.

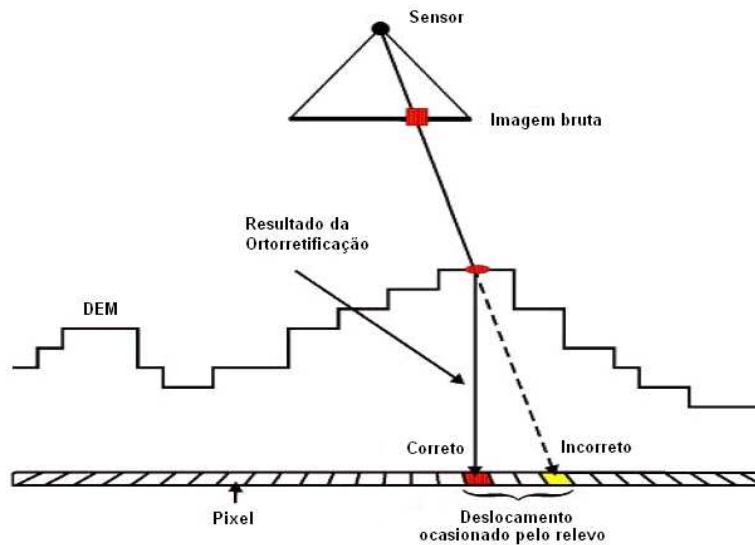
**Retificação:** alinhamento da imagem conforme as coordenadas planimétricas de um mapa. Este processo também é conhecido como *georreferenciamento*, e faz com que a imagem assuma as propriedades cartográficas de sistema de projeção presentes em um mapa.

**Geocodificação:** caso especial de retificação que inclui escala para uniformizar e padronizar os pixels da imagem, permitindo combinar imagens de diferentes sensores e mapas em um sistema de informação geográfica (SIG).

**Ortorretificação:** correção de uma imagem, pixel a pixel, considerando a distorção topográfica gerada pela variação do relevo. Cada pixel passa a representar a imagem do ponto como tomada na vertical, ou seja, a imagem obtida será uma projeção ortográfica da área coberta pela imagem.

Desta forma, quando o trabalho envolve a utilização de imagens representativas de regiões com relevo acidentado (grandes variações de altitude com inclinações acentuadas), o que acarretará distorções nas posições dos pixels nas imagens brutas (Figura 2), a ortorretificação é um processo fundamental na correção destas imagens.

Para a reordenação dos pixels da imagem em relação a um sistema de projeção cartográfica é necessário o conhecimento dos parâmetros de transformação, que servirão para relacionar as coordenadas da imagem com as coordenadas do terreno. Estes parâmetros podem ser determinados pelos pontos criteriosamente escolhidos, conhecidos como pontos de controle. Neste caso, de acordo com Crosta (1999), estes pontos devem ser feições bem definidas, geralmente de grande contraste espectral, em relação aos seus arredores na imagem e facilmente reconhecíveis tanto na imagem quanto no campo, como, por exemplo, interseções de estradas, limites de feições agrícolas, pistas de aeroportos, dentre outros.



Fonte: adaptada de PCI Geomatics (2007).

Figura 2 – Geometria das distorções na imagem causadas pelo relevo.

É importante ressaltar que a qualidade da imagem ortorretificada está diretamente relacionada à qualidade do modelo digital de elevação (MDE) e do modelo matemático utilizado no procedimento da ortorretificação. Um modelo matemático de baixa qualidade e um MDE impreciso ou incorretamente georreferenciado causará erros na imagem ortorretificada (PCI GEOMATICS, 2007).

### 3.3 Correção atmosférica

Além das perturbações próprias do sensor e do relevo terrestre, a relação entre os valores digitais das imagens e a reflectância ou a radiância das superfícies observadas é afetada por interferências atmosféricas (absorção, espalhamento, emissão e reflexão), que ocorrem na trajetória da radiação refletida pelo alvo até sua captura pelo sensor (ZULLO JÚNIOR, 1994; LIU, 2007).

Desta forma, os valores digitais originais, registrados pelo sensor, não representam o fluxo radiante proveniente da superfície, ou seja, representam uma combinação do brilho da superfície com o brilho da própria atmosfera, sendo que as interferências atmosféricas afetam de maneira diferente cada uma das bandas espectrais do sensor, ou seja, a contribuição do brilho da atmosfera depende do comprimento de onda da banda.

De acordo com Hadjimitsis *et al.* (2010), a remoção dos efeitos da atmosfera tem o objetivo de recuperar a reflectância que caracteriza as propriedades da superfície imageada, sendo, sem dúvida, a parte mais importante do pré-processamento de dados de sensoriamento remoto por satélite, principalmente no caso de estudos que envolvem análise de imagens obtidas em diferentes épocas.

De acordo com Mather (2009) e Oliveira *et al.* (2009), existem duas abordagens principais para o procedimento da correção atmosférica. A primeira delas consiste na técnica conhecida como DOS (*Dark Object Subtraction*), que utiliza dados obtidos na própria imagem, envolvendo a subtração de um valor constante para todos os pixels em uma determinada banda espectral da imagem. Na sua aplicação assume-se que alguns pixels na imagem (áreas cobertas com materiais que apresentam alta absorção da radiação solar, como sombras e corpos límpidos de água) deveriam ter uma reflectância próxima de zero. Se o valor digital registrado na imagem para estes pixels forem maiores que zero a causa seria os efeitos do espalhamento atmosférico.

Segundo Antunes *et al.* (2003), a correção atmosférica pelo método da subtração do pixel mais escuro é realizada sem embasamento físico, o que não possibilita sua aplicação em condições variadas tanto de superfície como de atmosfera.

A outra metodologia delas é baseada em modelos de transferência radiativa (MTRs), que exigem informações sobre parâmetros meteorológicos da atmosfera no instante da aquisição da imagem (temperatura, concentração de vapor d'água, aerossóis, CO<sub>2</sub>, etc.), que nem sempre estão disponíveis. Dentro desta metodologia estão os modelos denominados 5S (*Simulation of the Sensor Signal in the Solar Spectrum*) e 6S (*Second Simulation of the Sensor Signal in the Solar Spectrum*). A eficiência do processo de correção atmosférica das imagens vai depender da qualidade dos dados disponíveis para alimentação dos algoritmos dos modelos.

Segundo Oliveira *et al.* (2009), a caracterização atmosférica tem sido realizada por meio de medidas obtidas com fotômetros solares ou por balões meteorológicos e, recentemente, por meio de dados produzidos por alguns sensores orbitais, como os fornecidos pelo sensor MODIS

### 3.4 Conversão de números digitais em radiância espectral

De acordo com Fleming (2003) e Thenkabail *et al.* (2004), a equação utilizada para o cálculo da radiância em imagens com resolução de 11 bits, para uma determinada banda espectral do sensor IKONOS II contida no Space Imaging Document Number SE-REF-016, é a seguinte:

$$L_{\lambda} = \frac{ND_{\lambda}}{CalCoef_{\lambda}} \quad (1)$$

em que

$L_{\lambda}$  = radiância para a banda espectral  $\lambda$  na abertura do sensor  
(m W cm<sup>-2</sup>-sr<sup>-1</sup>);

$ND_{\lambda}$  = número digital do pixel na imagem IKONOS na banda  $\lambda$ ; e

$CalCoef_{\lambda}$  = coeficiente de calibração radiométrica do sensor  
(ND\*[mW/cm<sup>2</sup>-sr]<sup>-1</sup>) (Tabela 1).

Ao utilizar os coeficientes de calibração (CalCoef) apresentados na Tabela 1, deve-se atentar para a data da aquisição da imagem, uma vez que eles são diferentes para imagens produzidas em datas antes e depois de fevereiro de 2001. Os coeficientes de calibração originais para as quatro bandas, constantes da mesma tabela, não são mais utilizados (FLEMING, 2003).

Tabela 1 – Parâmetros das bandas sensor IKONOS II – Imagens de 11 bits

Bandas	CalCoef $\lambda$	CalCoef $\lambda$	CalCoef $\lambda$	Bandwidth $\lambda$	ESun $\lambda$
	(Original)	(Pré 22/02/01)	(Pós 22/02/01)		
Unidades	ND*[mW/cm <sup>2</sup> -sr] <sup>-1</sup>	ND*[mW/cm <sup>2</sup> -sr] <sup>-1</sup>	ND*[mW/cm <sup>2</sup> -sr] <sup>-1</sup>	nm	W/m <sup>2</sup> /μm
Azul	637	633	728	71,3	1.930,9
Verde	573	649	727	88,6	1.854,8
Vermelho	663	840	949	65,8	1.556,5
IV Próximo	503	746	843	95,4	1.156,9

Fonte: adaptada de Fleming (2003) e Taylor (2009).

Ainda, segundo Fleming (2009), o valor da radiância para cada banda do sensor a ser utilizado em fórmulas de conversão deverão estar em unidades de W/m<sup>2</sup>/sr/μm e pode ser obtido dividindo-se a radiância espectral pela amplitude da banda (*Bandwidth*) em questão, ou seja:

$$L_{\lambda}(W / m^2 / sr / \mu m) = \frac{ND}{(CalCoef / 10) * Bandwidth (\mu m)} \quad (2)$$

Note-se que, para aplicação da equação 2, os valores dos coeficientes de calibração (CalCoef), apresentados na Tabela 1, devem ser divididos por 10 e a amplitude da banda deverá ser em micrômetros ( $\mu m$ ) e não em nanômetros (nm), como apresentados na mesma tabela.

Taylor (2009) apresenta outra equação para obtenção do valor da radiância espectral, também em unidades de  $W/m^2/sr/\mu m$ , com a seguinte formulação:

$$L_{\lambda} = \frac{10^4 ND_{\lambda}}{CalCoef_{\lambda} * Bandwidth} \quad (3)$$

em que

$L_{\lambda}$  = radiância para a banda espectral  $\lambda$  na abertura do sensor  
(em  $W/m^2/sr/\mu m$ );

$ND_{\lambda}$  = número digital do pixel na imagem IKONOS na banda  $\lambda$ ;

$CalCoef_{\lambda}$  = coeficiente de calibração radiométrica do sensor  
(em  $ND * [mW/cm^2-sr]^{-1}$ ; e

$Bandwidth_{\lambda}$  = amplitude da banda espectral  $\lambda$  (nm).

Note-se que a equação 3 utiliza as mesmas unidades dos parâmetros das bandas como normalmente são apresentados na literatura (Tabela 1). O valor da radiância (em  $W/m^2/sr/\mu m$ ), calculado pela equação 3, é igual ao obtido com a utilização da equação 2.

### 3.5 Conversão da radiância espectral em reflectância aparente

A reflectância planetária ( $\rho_p$ ) é utilizada em análise de imagens de sensoriamento remoto, com o objetivo de reduzir os efeitos ocasionados pela diferença de iluminação. Segundo Taylor (2009), é definida pela equação:

$$\rho_p = \frac{\pi \cdot L_{\lambda} \cdot d^2}{ESUN_{\lambda} \cdot \cos \theta_s} \quad (4)$$

em que

$\rho_p$  = reflectância planetária (adimensional);

$L_\lambda$  = radiância para a banda espectral  $\lambda$  na abertura do sensor

(em  $W/m^2/\mu m/Sr$ );

$d$  = distância Terra-Sol em unidades astronômicas (anuário astronômico ou calcular);

$\theta_s$  = ângulo solar zenital (obtido no arquivo de dados da imagem); e

$ESUN_\lambda$  = irradiância exoatmosférica média do Sol em  $W/m^2/\mu m$  (Tabela 1).

### 3.6 Índices de vegetação

De acordo com Chuvieco e Huete (2010), os índices de vegetação (IVs) são utilizados para extrair informações relacionadas à vegetação, com base nos pixels de uma imagem digital. Estes índices envolvem transformações espectrais entre duas ou mais bandas do espectro eletromagnético, sendo uma delas a região do vermelho (0,6 a 0,7  $\mu m$ ), onde a vegetação verde e sadia apresenta alta absorção (baixa reflectância) da radiação solar pela clorofila, e outra na região do infravermelho próximo (0,7 a 1,1  $\mu m$ ), onde ocorre muito pouca absorção (alta reflectância). A combinação destas duas bandas tem o objetivo de enfatizar o sinal da vegetação e, ao mesmo tempo, minimizar as influências da ausência de vegetação.

Segundo Ponzoni e Shimabukuro (2007), a utilização da faixa espectral do vermelho, em detrimento das outras faixas do espectro visível (verde e azul), se deve ao fato da relativa menor influência dos efeitos da atmosfera e da maior absorção da radiação eletromagnética, pela ação da clorofila verificada nesta faixa espectral, uma vez que quanto menor o comprimento de onda maior será a interferência da atmosfera.

Vários índices de vegetação têm sido desenvolvidos com o objetivo de entender as variáveis da vegetação. Diversos estudos têm mostrado que estes índices estão correlacionados às várias propriedades da vegetação, como o índice de área foliar, a biomassa, o conteúdo de água, a fenologia e o vigor da vegetação. Com isto, eles têm sido considerados uma técnica robusta no sensoriamento remoto, produzindo consistentes comparações espaciais e temporais da vegetação verde, tanto em escala local quando global (MYNENI *et al.*, 1995b; CHUVIECO; HUETE, 2010; AHAMED *et al.*, 2011)

Liu (2007) destaca que um índice de vegetação ideal deve ser sensível à vegetação, insensível aos efeitos de fundo do solo e isento de interferências atmosféricas e que, em princípio, a sua utilização tem o objetivo de condensar informações espectrais e discriminar o que é vegetação e não vegetação, além de possibilitar a avaliação das condições de crescimento das culturas e a ocorrência de fatores que as afetam, como pragas, doenças, secas, etc.

Vários trabalhos de pesquisa mostram que os IVs estão relacionados aos diversos parâmetros da vegetação. Dentre estes, destacam-se os seguintes:

- realce de feições de vegetação, minimização dos efeitos do solo, angulares e atmosféricos (EIPHANIO *et al.*, 1996);
- estimativas de variáveis da vegetação, como porcentagem de cobertura vegetal, índice de área foliar (IAF), radiação absorvida pelos tecidos fotossintéticos (APAR – *Absorbed Photosynthetically Active Radiation*), utilizada para analisar processos vegetativos, como produção primária líquida (NPP – *Net Primary Production* e evapotranspiração (ELVIDGE; CHEN, 1995);
- outras aplicações, como a descrição dos principais tipos de vegetação, classificação de imagens, produtividade de sistemas agrícolas, estimativa de biomassa e monitoramento de desmatamento florestal (LEPRIEUR *et al.*, 1994 *apud* ARAGÃO; SHIMABUKURO, 2004).

Os índices de vegetação são afetados por diversos fatores, como, por exemplo, a arquitetura do dossel, o ângulo zenital solar, o ângulo de visada do sensor e os efeitos atmosféricos e do solo. Como o espalhamento atmosférico altera a resposta espectral da vegetação nas bandas do vermelho e infravermelho próximo, valores diferentes destes índices são obtidos antes e após a correção atmosférica (JACKSON; HUETE, 1991; PONZONI; SHIMABUKURO, 2007).

Os números digitais (NDs) não estão em uma mesma escala radiométrica nas diferentes bandas espectrais, ou seja, um mesmo valor de ND em uma banda de uma imagem digital, de uma determinada cena, não representa a mesma intensidade da radiação medida em outra banda para a mesma cena.



Desta forma, não é recomendável proceder ao cálculo de índices de vegetação sem converter os valores digitais da imagem em valores físicos, como a radiância ou a reflectância de superfície (PONZONI; SHIMABUKURO, 2007).

Em geral, os índices de vegetação são obtidos pela razão de bandas ou pela combinação linear de bandas. As reflectâncias obtidas nas regiões do infravermelho próximo (NIR) e do vermelho (R) são as mais comuns na formulação destes índices. Entretanto, reflectância em outras bandas, como a das regiões do azul (B), do verde (G) e do infravermelho de ondas curtas (SWIR) também são utilizadas.

Uma concepção amplamente utilizada em pesquisas envolvendo a interpretação de dados de sensoriamento remoto é a chamada “linha de solo”. Segundo Baret *et al.* (1993), esta linha é definida como a relação linear entre a reflectância do solo exposta, observada em duas diferentes faixas do espectro eletromagnético.

A linha de solo pode ser obtida pela representação dos valores das reflectâncias dos pixels de uma imagem espectral, nas bandas do vermelho (eixo X) e do infravermelho próximo – NIR (eixo Y). Com estes valores são geradas isolinhas, como as representadas na Figura 3. Os pixels situados no limite inferior do gráfico são relativos ao solo exposto, ou seja, sem cobertura vegetal (índice de área foliar IAF = 0) e a isolinha gerada para estes pontos é chamada de linha de solo.

Observa-se ainda na Figura 3 que, com o aumento do índice de área foliar, as linhas que representam este aumento apresentam valores maiores tanto do coeficiente de inclinação (a) quanto do intercepto (b).

Segundo Yoshioka *et al.* (2009), a relação entre o vermelho e o infravermelho próximo para um tipo específico de solo específico é usualmente caracterizada pela equação:

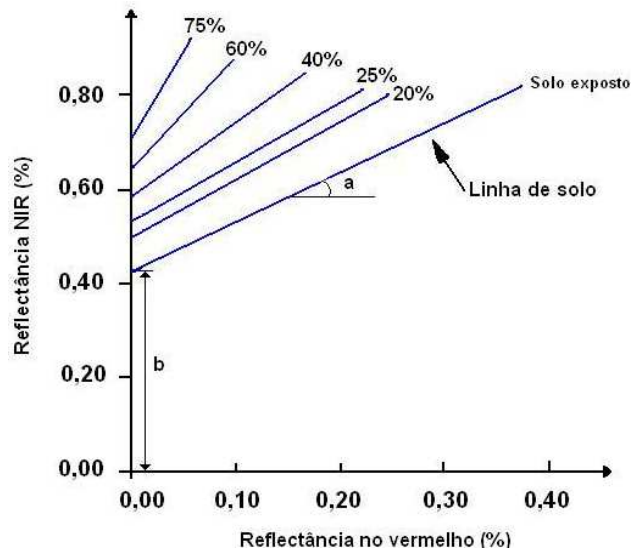
$$R_{sNIR} = a.R_{sRED} + b \quad (5)$$

em que

$R_{sNIR}$  = reflectância do solo na banda do infravermelho próximo;

$R_{sRED}$  = reflectância do solo na banda do vermelho; e

a e b = parâmetros da linha de solo.



Fonte: adaptada de Qi *et al.* (1994).

Figura 3 – Linha de solo.

Segundo Epiphanyo *et al.* (1996), a maioria dos índices de vegetação propostos supõe a existência de uma única linha de solos, onde as reflectâncias do vermelho e infravermelho próximo estão diretamente relacionadas, o que, na maioria dos casos, pode ser considerado como verdadeiro. Entretanto, Baret *et al.* (1993) e Yoshioka *et al.* (2009) afirmam que as propriedades óticas de um determinado solo são mais bem descritas, com linhas de solo específicas, uma vez que os parâmetros  $a$  e  $b$  dependem de alguns fatores relacionados ao solo, como os teores de umidade e a matéria orgânica, química e conteúdo mineral, que são únicos para um determinado tipo de solo.

Dezenas de IVs foram propostos e outros estão sendo desenvolvidos por diversos pesquisadores. Os mais encontrados na literatura são apresentados a seguir.

### - Índice de Vegetação da Razão (RVI)

Segundo Jackson e Huete (1991), o RVI (*Ratio Vegetation Index*) foi, provavelmente, o primeiro índice de vegetação a ser definido, sendo representado pela seguinte equação:

$$RVI = \frac{NIR}{R} \quad (6)$$

em que

NIR = reflectância na região do infravermelho próximo (adimensional); e

R = reflectância na região do vermelho (adimensional).

Atribuído a Jordan (1969), este índice se baseia no princípio de que as folhas verdes e saudáveis absorvem relativamente mais a luz vermelha do que a luz infravermelha. Desta forma, em áreas com grande densidade de vegetação, a reflectância na faixa do vermelho é muito baixa e quanto maior a densidade de folhas na copa maior será o contraste espectral.

Analisando a equação 6, verifica-se que quanto mais alto o valor do RVI maior é a presença de vegetação verde, uma vez que a reflectância da vegetação na faixa do vermelho está inversamente relacionada com a densidade da vegetação verde. Quanto mais intensa a presença da clorofila, maior será a absorção e menor a reflectância na faixa do vermelho.

Entretanto, um menor contraste espectral pode indicar tanto uma menor quantidade de vegetação verde e saudável, ou com base em conhecimentos adicionais relativos à área imageada, uma maior quantidade de vegetação em condições de estresse ou em estado de senescência.

Segundo Liu (2007), o RVI pode ser um bom indicador do crescimento da vegetação e da estimativa de biomassa; entretanto, interferências na radiação durante a passagem pela atmosfera (principalmente, a reflectância diferenciada entre a radiação visível e o infravermelho próximo no topo das nuvens) afetam o valor absoluto deste índice, podendo, assim, comprometer a interpretação dos resultados.

### **- Índice de Vegetação da Diferença Normalizada (NDVI)**

Este índice foi proposto por Rouse *et al.* (1973a) para separar a vegetação verde de solo exposto, utilizando imagens do Landsat MSS. A base deste índice é o contraste entre a máxima absorção na região do vermelho, em virtude dos pigmentos da clorofila e na máxima reflexão no infravermelho próximo, ocasionada pela estrutura celular das folhas. Segundo Häme *et al.* (1997) e Haboudane *et al.* (2004), é o índice mais conhecido e amplamente utilizado em pesquisas relacionadas com o monitoramento e mapeamento da cobertura vegetal.

O NDVI (*Normalized Difference Vegetation Index*) é calculado pela diferença de reflectância entre a faixa do infravermelho próximo e a do vermelho. Esta diferença é normalizada pela soma das reflectâncias nestas mesmas faixas, conforme a equação seguinte:

$$NDVI = \frac{NIR - R}{NIR + R} \quad (7)$$

Simulações conduzidas por Holben (1986) mostraram que o NDVI encobre parcialmente os efeitos causados pelos constituintes atmosféricos, pelas perturbações radiométricas e geométricas, além de minimizar o grau de influência das nuvens, o vapor d'água e o ângulo solar.

Teoricamente, os valores de NDVI variam de -1 a +1, sendo que valores próximos de zero representam solo sem vegetação; valores maiores que zero indicam presença de vegetação; e valores negativos indicam a presença de água e nuvens (LIU, 2007).

De acordo com Huete *et al.* (2002), uma vantagem deste índice é a redução de muitas formas de ruídos, presentes em várias bandas, como diferenças de iluminação, sombras de nuvens, atenuação atmosférica e alguns efeitos topográficos.

Entretanto, de acordo com Carvalho *et al.* (2008), apesar de sua utilidade na estimativa de parâmetros biofísicos da vegetação, o NDVI apresenta problemas de saturação em áreas com vegetação densa. Ocorre também não linearidade com o índice de área foliar (IAF) e com a fração de radiação fotosinteticamente absorvida (fAPAR).

### **- Índice de Vegetação Transformado (TVI)**

Em virtude de algumas limitações do NDVI, como a saturação em áreas com alta densidade de biomassa e sua sensibilidade a várias fontes de perturbação, como efeitos do solo, nuvens, efeitos atmosféricos, dentre outros, encontram-se na literatura índices derivados do NDVI, desenvolvidos com o objetivo de minimizar estas limitações, como é o caso do TVI (*Transformed Vegetation Index*), proposto por Rouse *et al.* (1973b), obtido pela seguinte expressão:

$$TVI = \sqrt{NDVI + 0,5} \quad (8)$$

A adição da constante 0,5 ao valor do NDVI foi introduzida para evitar operações com valores negativos, e a raiz quadrada do resultado da adição foi a transformação utilizada na esperança de estabilização da variância.

Observando a expressão (10) observa-se que o índice TVI requer que o valor mínimo de entrada do NDVI seja menor que -0,5.

Na literatura este índice é também apresentado com o nome TNDVI (*Transformed Normalized Difference Vegetation Index*), com a mesma formulação da equação 10 (WEBER; DUNNO, 2001; SEBEM, 2005; YANG *et al.*, 2008).

### **- Índice Perpendicular de Vegetação (PVI)**

Segundo Liu (2007), o NDVI não infere bem na quantidade de vegetação quando o solo está parcialmente coberto por vegetação, em virtude do efeito da reflectância do solo abaixo da copa da vegetação. Para eliminar esta interferência, Richardson e Wiegand (1977) desenvolveram o PVI (*Perpendicular Vegetation Index*).

O PVI calcula a distância ortogonal de um pixel e a linha de solo, segundo a equação (CHUVIECO; HUETE, 2010):

$$PVI = (NIR - a * R - b) / (1 + a^2)^{1/2} \quad (9)$$

em que **a** e **b** representam, respectivamente, a inclinação e o intercepto da linha de solo.

### **- Índice de Vegetação da Diferença Ponderada (WDVI)**

O WDVI (*Weighted Difference Vegetation Index*) atribuído a Clevers (1988) foi desenvolvido para estimativas de área foliar (IAF), sendo obtido pela diferença ponderada entre a reflectância nas faixas do infravermelho próximo e do vermelho, assumindo uma proporcionalidade constante entre as reflectâncias nestas duas faixas (linha de solo). O WDVI é obtido pela seguinte expressão (CLEVERS, 1997):

$$WDVI = NIR - a * R \quad (10)$$

em que

NIR = reflectância na faixa do infravermelho próximo;

R = reflectância na faixa do vermelho; e

a = inclinação da linha de solo.

### ***Índice de Vegetação Ajustado para o Solo (SAVI)***

Visando minimizar os efeitos do solo sobre diferentes densidades de cobertura vegetal, Huete (1988) propôs uma variação no NDVI criando o Índice SAVI (*Soil Adjusted Vegetation Index*), com a adição de um fator de ajuste do solo (L), que varia de acordo com a densidade de vegetação. Este índice é obtido pela seguinte equação:

$$SAVI = \frac{(NIR - R)}{(NIR + R + L)}(1 + L) \quad (11)$$

Os melhores valores deste fator de ajuste encontrados pelo autor em estudos experimentais foram:

L = 1,0 (densidade de vegetação muito baixa);

L = 0,5 (densidade de vegetação intermediária); e

L = 0,25 (densidade de vegetação elevada).

Ainda, de acordo com Huete (1988), o valor de 0,5 para o fator de ajuste do solo reduz consideravelmente a interferência do solo em áreas com ampla variedade de densidades de vegetação.

Pela análise da equação 11, se L = 0, o índice SAVI é equivalente ao NDVI.

### ***- Índice de Vegetação Ajustado para a Interferência do Solo (MSAVI)***

Qi *et al.* (1994) introduziram uma modificação no cálculo do índice SAVI, apresentando o MSAVI (*Modified Soil Adjusted Vegetation Index*). Utilizando o NDVI e o WDVI (*Weighted Difference Vegetation Index*) para determinação do coeficiente L, por meio de processos iterativos, os autores chegaram à seguinte expressão:

$$MSAVI = \frac{2NIR + 1 - \sqrt{(2NIR + 1)^2 - 8(NIR - R)}}{2} \quad (12)$$

### **- Índice de Vegetação Melhorado (EVI)**

O EVI (*Enhanced Vegetation Index*) foi concebido para melhorar o sinal da vegetação pela diminuição das influências do sinal do solo e da atmosfera, proporcionando uma melhor sensibilidade em áreas com maiores densidades de biomassa. Enquanto o NDVI é sensível à clorofila, o EVI é mais sensível às variações estruturais do dossel, incluindo o índice de área foliar, o tipo e a arquitetura da copa e a fisionomia vegetal (HUETE *et al.*, 2002; CHUVIECO; HUETE, 2010).

O EVI, também conhecido na literatura como índice de realce de vegetação, é obtido pela seguinte equação:

$$EVI = G \frac{NIR - R}{NIR + C_1R - C_2B + L} \quad (13)$$

em que

NIR, R e B = reflectâncias nas bandas do infravermelho próximo, vermelho e azul, respectivamente;

L = fator de correção para as interferências do solo; e

C<sub>1</sub> = fator de correção dos efeitos atmosféricos para a banda do vermelho; C<sub>2</sub> para a banda do azul; e G o fator de ganho.

Os coeficientes adotados no algoritmo MODIS EVI são: L = 1, C<sub>1</sub> = 6, C<sub>2</sub> = 7,5 e G (fator de ganho) = 2,5 (HUETE *et al.*, 2002). Estes mesmos valores foram utilizados por Colombo *et al.* (2003), Chen *et al.* (2004) e Soudani *et al.* (2006), em pesquisas envolvendo índices de vegetação obtidos a partir de imagens do sensor IKONOS.

### **- Índice de Vegetação com Resistência Atmosférica (ARVI)**

O ARVI (*Atmospherically Resistant Vegetation Index*) foi desenvolvido e proposto por Kaufman e Tanré (1992) para utilização no sensoriamento da

vegetação, utilizando dados do sensor orbital MODIS (*Moderate Resolution Imaging Spectroradiometer*) do sistema EOS (*Earth Observing System*).

Este índice foi desenvolvido para remover a influência dos aerossóis na banda vermelha, através do uso da banda azul (mais sensível aos efeitos atmosféricos). A diferença de radiância entre estas duas bandas gera uma nova banda (vermelho e azul), sendo que esta combinação minimiza os efeitos do espalhamento atmosférico causados pelos aerossóis na banda vermelha. A partir de simulações com várias condições atmosférica, Kaufman e Tainré (1992) mostraram que o ARVI tem a mesma variação dinâmica do NDVI, porém com efeitos atmosféricos quatro vezes menores (LIU, 2007).

As equações para o cálculo do ARVI, apresentadas por Kaufman e Tainré (1992), são as seguintes:

$$ARVI = \frac{\rho_{NIR}^* - \rho_{rb}^*}{\rho_{NIR}^* + \rho_{rb}^*} \quad (14)$$

em que

$\rho_{NIR}^*$  = reflectância aparente na banda do infravermelho próximo; e

$\rho_{RA}^*$  = fator que considera a diferença de reflectância entre a banda azul e a banda vermelha. Este fator é obtido por:

$$\rho_{rb}^* = \rho_r - \gamma(\rho_b^* - \rho_r^*) \quad (15)$$

Nas equações 14 e 15,  $\rho_{NIR}^*, \rho_r^*, \rho_{br}^*$  são as reflectâncias aparentes, contaminadas apenas pelos efeitos da atmosfera, nas bandas do infravermelho próximo, vermelho e azul.

O fator  $\gamma$  é um parâmetro de calibração que depende do tipo de aerossóis presente na atmosfera. Vários cálculos do ARVI considerando  $\gamma = 1$  mostraram ser este o valor ideal para aplicações em sensoriamento remoto (KAUFMAN; TAINRÉ, 1992; CHUVIECO; HUETE, 2010; PONZONI; SHIMABUKURO, 2007).

Analisando as expressões 14 e 15, verifica-se que se  $\gamma = 0$ , o ARVI se iguala ao NDVI. Por outro lado, se nas mesmas expressões fazendo  $\gamma = 1$ , o ARVI pode ser calculado pela expressão 16, também apresentada por Kaufman e Tainré (1996):



$$ARVI = \frac{\rho_{NIR}^* - (2 \cdot \rho_R^* - \rho_{BLU}^*)}{\rho_{NIR}^* + (2 \cdot \rho_R^* - \rho_{BLU}^*)} \quad (16)$$

### - Índice Global de Monitoramento Ambiental (GEMI)

Pinty e Verstraete (1992), considerando que a correção dos efeitos atmosféricos em dados obtidos pelos satélites é possível, requerendo, porém, um grande conjunto de informações sobre a composição da atmosfera, propuseram o índice de vegetação GEMI (*Global Environment Monitoring Index*), utilizando uma combinação não linear dos dados AVHRR (*Advanced Very High Resolution Radiometer*) do satélite NOAA (*National Oceanic Atmospheric Administration*). O objetivo deste índice é manter as informações sobre a cobertura vegetal e, ao mesmo tempo, reduzir os efeitos relativos às perturbações indesejáveis da atmosfera. Este índice é calculado pelas expressões:

$$GEMI = \eta(1 - 0,25\eta) - \frac{(R - 0,125)}{(1 - R)} \quad (17)$$

$$\eta = \frac{[2(NIR^2 - R^2) + 1,5NIR + 0,5R]}{NIR + R + 0,5} \quad (18)$$

### - Transformações Tasseled Cap (TCap)

Estas transformações se incluem dentro das várias maneiras de se modelar os pixels presentes em uma imagem multiespectral para estimativas de variáveis da vegetação, incorporando outras bandas espectrais, além das bandas do infravermelho próximo e do vermelho e, segundo Jensen (1996), é um dos mais importantes índices de vegetação, rigorosamente testado e usado extensivamente em pesquisas na agricultura. Este índice foi desenvolvido por Kauth e Thomas (1976), utilizando as quatro bandas do sensor Landsat MSS, buscando melhorar o conteúdo de informação espectral dos dados das imagens deste satélite e, segundo Horne (2003), são transformações lineares que são úteis tanto na distinção de diferentes tipos de vegetação (árvores, arbustos, grama, etc.) quanto na distinção de vegetação com outros elementos introduzidos pelo homem na paisagem (estradas, edifícios, etc.).

Por meio de equações lineares são atribuídos pesos às diferentes bandas espectrais da imagem gerando novas imagens, que são utilizadas para distinguir as superfícies presentes na imagem.

Segundo Gleriani *et al.* (2003), o nome deriva do desenho resultante da trajetória espectro-temporal dos pixels de uma cena agrícola que se assemelha a um capuz.

Horne (2003) desenvolveu os coeficientes da transformação *Tasseled Cap* para as quatro bandas multiespectrais do sensor IKONOS II, derivados da análise de cerca de 200 imagens, cobrindo diferentes partes da Terra. Os resultados obtidos são mostrados na Tabela 2.

Tabela 2 – Coeficientes *Tasseled Cap* para o sensor IKONOS II

<b>Bandas</b>	<b>TCap1</b>	<b>TCap2</b>	<b>TCap3</b>	<b>TCap4</b>
Azul	0,326	-0,311	-0,612	-0,650
Verde	0,509	-0,356	-0,312	0,719
Vermelho	0,560	-0,325	0,722	-0,243
IV Próximo	0,567	0,819	-0,081	-0,031

Fonte: Horne (2003).

De acordo com Horne (2003) e El-Mezouar *et al.* (2010), as equações para o cálculo destes índices, a partir de imagens do sensor IKONOS II, apresentadas por Horne (2003), são:

$$TCap1 = 0,326 \times azul + 0,509 \times verde + 0,560 \times vermelho + 0,567 \times IVPróximo \quad (19)$$

$$TCap2 = -0,311 \times azul - 0,356 \times verde - 0,325 \times vermelho + 0,819 \times IVPróximo \quad (20)$$

$$TCap3 = -0,612 \times azul - 0,312 \times verde + 0,722 \times vermelho - 0,081 \times IVPróximo \quad (21)$$

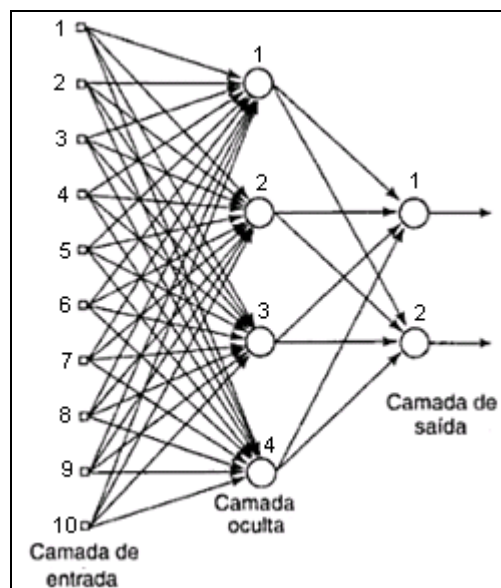
$$TCap4 = -0,650 \times azul + 0,719 \times verde - 0,243 \times vermelho - 0,031 \times IVPróximo \quad (22)$$

Segundo Matos e Kirchner (2008), estudos relativos à determinação destes coeficientes para o Brasil ainda não foram realizados.

### 3.7 Redes Neurais Artificiais (NRA)

As redes neurais artificiais (NRA) são modelos computacionais concebidos de forma a simular a funcionalidade dos neurônios biológicos (MORAIS, 2010). São organizadas em camadas conectadas, consistindo, basicamente, em uma camada de entrada, uma ou mais camadas ocultas (onde são processados os dados apresentados na camada de entrada) e uma camada de saída (que apresenta o resultado do processamento). A camada de entrada comunica-se com uma ou mais camadas ocultas, por meio de um sistema de conexões ponderadas. A adição de uma ou mais camadas ocultas melhora o desempenho da rede, característica importante quando o tamanho da camada de entrada é grande (JENSEN *et al.*, 1999; HAYKIN, 2001; BOTELHO; 2004).

Um esquema básico de uma rede neural artificial é apresentado na Figura 4.



Fonte: adaptada de Haykin (2001).

Figura 4 – Estrutura de uma RNA.

A RNA apresentada na Figura 4 possui uma camada de entrada (com dez neurônios de entrada), uma camada oculta (com quatro neurônios) e uma camada de saída (com dois neurônios). Uma rede com esta topologia é normalmente referida na literatura com uma rede 10-4-2.

Uma importante característica das redes neurais é a capacidade de aprendizagem, com o objetivo de melhorar o seu desempenho, ou seja, a rede pode ser treinada a partir do fornecimento de informações (dados de treinamento) na camada de entrada para se chegar a uma resposta desejada na camada de saída.

No treinamento ou aprendizado de uma rede, os pesos são ajustados de forma que o resultado apresentado na saída coincida com um valor desejado, podendo ser efetuado de forma supervisionada ou não supervisionada, sendo que a principal diferença entre estas formas é a existência de um agente externo que controla o processo de aprendizagem (RIBEIRO; CENTENO, 2002 *apud* BOTELHO, 2004).

No treinamento *supervisionado* a solução desejada é conhecida. Assim, a diferença (erro) entre a resposta desejada e a resposta da rede é utilizada para ajustar os pesos entre os neurônios da rede, por uma quantidade proporcional ao erro, com o objetivo de minimizar o erro global, na busca pela melhor solução. Este processo é repetido, passo a passo, iterativamente, até que se atinja a solução desejada, definida por um limiar definido pelo usuário. Uma vez treinada, a rede armazena o conhecimento adquirido e pode executar a predição desejada, com base em novos dados de entrada (JENSEN *et al.*, 1999; HAYKIN, 2001).

Os exemplos mais conhecidos de algoritmos utilizados no treinamento supervisionado são a regra *delta* e a sua generalização *backpropagation* para redes de múltiplas camadas. As redes neurais artificiais, conhecidas como *Perceptron Multicamadas (MultiLayer Perceptron – MLP)*, treinadas com este algoritmo, é um dos principais modelos utilizados (SCHLUNZEN *et al.*, 1993; BOTELHO, 2004; MORAIS, 2010).

No treinamento *não supervisionado* não há exemplos rotulados da função a ser aprendida pela rede, ou seja, não há informações que indicam que uma saída gerada em função dos padrões de entrada é ou não correta. Neste caso, o treinamento é inteiramente feito com base nos dados de entrada e, a partir da análise destes dados, a tarefa da rede é organizar os dados de entrada em grupos ou categorias com base em semelhanças ou correlações. Para o treinamento são utilizados vários algoritmos não supervisionados como, por exemplo, os Mapas Auto-Organizados (*SOM – Self Organizing Map*) e

Análise de Componentes Principais (CHAKRABORTY; CHAKRABORTY, 2000).

Várias pesquisas foram desenvolvidas utilizando a técnica de redes neurais artificiais em temas envolvendo recursos naturais. Segundo Klobucar *et al.* (2008), experimentos iniciais relacionados à aplicação de RNA em florestas começou nos Estados Unidos e no Canadá no final de 1980. Blackard e Dean (1999) utilizaram a tecnologia RNA para predição de cobertura florestal a partir de variáveis cartográficas (elevação, inclinação, orientação, etc.) em florestas no Colorado (USA); Schoeninger (2006) utilizou a técnica para mapeamento de biomassa e carbono de uma floresta ombrófila densa no estado do Paraná; e Klobucar *et al.* (2008) utilizaram RNA para avaliar cinco parâmetros florestais (número de árvores/ha, estoque, área basal/ha, volume/ha e idade) na Croácia, a partir de dados de textura extraídos de uma imagem do sensor IKONOS (PAN 1x1m).

### **3.8 Estimativas de biomassa e carbono com o uso de imagens de satélites**

Roy e Ravan (1996) utilizaram as técnicas de sensoriamento remoto para o cálculo de biomassa acima do solo no Madhav National Park (Índia), utilizando imagens Landsat 5 e desenvolveram modelos empíricos para relacionar a resposta espectral da vegetação com o conteúdo de biomassa.

Os autores observaram que os parâmetros de brilho (*brightness*) e umidade (*wetness*) apresentaram uma forte relação com os valores de biomassa. Análises de regressão múltipla utilizando-se destes dois parâmetros foram empregadas para a estimativa da biomassa, tendo o modelo utilizado apresentado um coeficiente de correlação de 0,77, indicando, assim, a potencialidade da utilização de imagens espectrais na estimativa de biomassa.

Foody *et al.* (2001) estimaram a biomassa de florestas tropicais no nordeste de Bornéu utilizando imagens do Landsat TM. No trabalho, as abordagens convencionais, utilizadas na estimativa de biomassa florestal, a partir de dados de sensoriamento remoto, foram avaliadas com a aplicação da metodologia das redes neurais artificiais, técnica que mostrou ser adequada para a estimativa de biomassa, uma vez que as estimativas obtidas apresentaram fortemente correlacionadas com os dados de inventário florestal correlação

( $r = 0,80$ ). Além disso, as estimativas encontradas foram mais fortemente correlacionadas com a biomassa do que aquelas obtidas com o uso de índices de vegetação, incluindo o NDVI, que é amplamente utilizado em pesquisas relacionadas com o mapeamento da cobertura vegetal.

Watzlawick (2003) desenvolveu uma metodologia para realizar estimativas de biomassa e carbono orgânico em plantações florestais de *Pinus taeda* e *Araucaria angustifolia* e na Floresta Ombrófila Mista Montana, utilizando imagens do satélite IKONOS II, localizadas no município de General Carneiro (PR).

Inicialmente, utilizando-se do método destrutivo em unidades amostrais na área estudada, foi quantificada a biomassa da vegetação arbórea, arbustiva (sub-bosque), serapilheira, subterrânea (raízes) e a miscelânea (material vegetal não enquadrado nas categorias citadas). Posteriormente, utilizando uma imagem geometricamente corrigida do satélite IKONOS II, foram calculados os índices de vegetação R (Razão Simples), NVDI (Índice de Vegetação por Diferença Normalizada) e SAVI (Índice de Vegetação Ajustado ao Solo), a partir dos valores médios de reflectância nas unidades amostrais para as bandas MS-1 (azul), MS-2 (Verde), MS-3 (vermelho) e MS-4 (infravermelho próximo).

Foi efetuada uma análise de correlação entre as variáveis biométricas (biomassa arbórea e carbono orgânico) e as variáveis digitais (valores provenientes da imagem). Diferentes modelos de regressão para estimativas da biomassa arbórea e do carbono arbóreo foram testados. Segundo o autor, as estimativas das variáveis estudadas, mostraram que os valores obtidos permitiram realizar a quantificação tanto da biomassa quanto do carbono aéreo com o uso desta tecnologia. A banda 4 (MS-4) e os índices de vegetação RVI, NDVI e SAVI apresentaram melhores correlações com a biomassa e o carbono.

Zheng *et al.* (2004) estudaram a aplicação das técnicas de sensoria-mento remoto na gestão de florestas no estado de Wisconsin (USA). Com uso de imagens Landsat 7 ETM+ produziram mapas de idade da vegetação e de biomassa acima do solo. Foi encontrada alta correlação ( $r^2 = 0,86$ ) entre o índice de vegetação NDVI e a biomassa acima do solo para florestas de pinheiro.

Lu *et al.* (2005) investigaram as relações entre a biomassa acima do solo e assinaturas espectrais do sensor Landsat TM em florestas primárias e

sucessionais na região amazônica brasileira. No estudo, a análise de mistura espectral foi utilizada para converter imagens do Landsat TM em imagens fração de vegetação verde, sombra e solo e modelos foram desenvolvidos para estimativas de biomassa em florestas sucessionais e primárias na região amazônica (Rondônia). Os resultados obtidos indicaram que os modelos com a utilização das imagens fração apresentaram melhor desempenho para as estimativas da biomassa em florestas sucessionais do que os modelos desenvolvidos com as assinaturas espectrais do satélite Landsat TM. No caso de florestas primárias, os dois modelos apresentaram baixo desempenho.

Padrón e Navarro-Cerrilo (2007) utilizaram imagens do satélite Landsat 7 para efetuar estimativas de biomassa em uma área de bosque tropical seco no Peru. Com os valores do diâmetro da base (considerados apenas aqueles com valores iguais ou superiores a 10 cm) e da altura da vegetação, obtidos por meio de um inventário florestal, conduzido em parcelas de 1 hectare, foi obtida a estimativa de biomassa acima do solo a partir de equações alométricas específicas para espécies individuais ou grupo de espécies. Os resultados obtidos foram relacionados com os dados de reflectância das imagens do satélite com o uso dos índices de vegetação NDVI, SAVI, MSAVI, EVI (adotando os coeficientes do algoritmo MODIS), além dos índices N37I (razão normalizada das bandas 3 e 7 do Landsat TM) e o NDMI (Normalized Difference Moisture Index) calculado com a razão normalizada das bandas 5 e 4 do Landsat TM.

Equações de regressão foram desenvolvidas para buscar a correlação entre os resultados de biomassa obtidos a partir do inventário florestal com aqueles obtidos através das imagens, obtendo-se correlações variando de 0,52 a 0,72, considerados pelos autores como razoáveis para o tipo de ecossistema estudado. Os índices EVI e NDVI foram aqueles que melhor estimaram a biomassa, sendo que o EVI apresentou os melhores coeficientes de correlação ( $R = 0,85$  para a biomassa total e  $R = 0,72$  para a biomassa das árvores).

Matos (2006) conduziu seus estudos em uma área dominada por floresta ombrófila densa de terra firme localizada na Estação Experimental de Silvicultura Tropical (EEST) do Instituto Nacional de Pesquisa da Amazônia (INPA), localizada a aproximadamente 90 km ao norte do município de Manaus, AM.

A quantificação de biomassa foi efetuada inicialmente pelo método indireto, a partir de inventário florestal, com base na variável dap (diâmetro à altura do peito), constante de um banco de dados de 315 árvores com  $dap \geq 5$  cm, presentes em cinco parcelas de 400 m<sup>2</sup>. O conteúdo de carbono foi calculado mediante porcentuais descritos na literatura.

Os resultados foram correlacionados com os dados de reflectância das bandas e da transformação de bandas. A integração das informações de campo com os dados das imagens dos satélites Landsat e IKONOS II foi realizada por procedimentos de regressão linear múltipla com variáveis selecionadas pelo método *stepwise*.

Para as imagens do satélite Landsat os resultados da modelagem mostraram que as variáveis independentes que tiveram melhores correlações com as variáveis biométricas, biomassa e carbono, foram B2 (banda 2), B3 (banda 3), ARVI, ND<sub>54</sub> (razão normalizada entre as bandas 5 e 4 do satélite Landsat), MM<sub>VEG</sub> (imagem fração vegetação do MLME), MM<sub>sombra</sub> (imagem fração sombra do MLME) e MSAVI.

Já para as imagens do satélite IKONOS II, as maiores correlações foram obtidas com as variáveis R43 (índice de vegetação da razão entre as bandas 4 e 3), NDVI, e as imagens de transformação TCap3 e TCap4.

Schoeninger (2006) desenvolveu um trabalho com o objetivo de elaborar mapas temáticos para estimativas de biomassa e carbono orgânico armazenado no componente arbóreo de uma Floresta Ombrófila Densa, localizada nos municípios de Apiúna e Presidente Nereu, no Estado de Santa Catarina. Na pesquisa foi verificado o desempenho de redes neurais artificiais (RNA) e equações de regressão linear na predição das variáveis biomassa arbórea e carbono arbóreo.

Inicialmente, a biomassa lenhosa acima do solo foi quantificada utilizando-se do método destrutivo, sendo que as árvores abatidas foram cubadas para a obtenção do volume e das variáveis dendrométricas necessárias ao ajuste das equações alométricas.

Por meio da análise de regressão as variáveis dependentes, biomassa arbórea e conteúdo de carbono foram correlacionados com as variáveis independentes, representadas pelas bandas MS-1 (azul) MS-2 (verde), MS-3 (vermelho) e MS-4 (infravermelho próximo) do satélite IKONOS II. As variáveis



MS-1, MS-2 e MS4 apresentaram as maiores correlações negativas com as variáveis dendrométricas biomassa e carbono, enquanto a variável MS-3 apresentou um grau de correlação médio para as mesmas variáveis dendrométricas.

Também foram efetuadas estimativas de biomassa arbórea e carbono com a utilização da metodologia de redes neurais artificiais (RNA) e os resultados foram superiores àqueles obtidas com as técnicas de regressão linear. Os melhores resultados com o emprego de RNA apresentaram um erro percentual médio, em relação às amostras de verificação, de 3,73% para a biomassa e de 3,59% para o carbono, enquanto a melhor equação de regressão linear apresentou erros padrão da estimativa da ordem de 29,8%.

Maciel *et al.* (2007) efetuaram a estimativa de parâmetros estruturais de uma floresta primária no município de Paragominas (PA), utilizando as bandas 3, 4 e 5 de imagens georreferenciadas do satélite Landsat-7.

Pela sobreposição das unidades amostrais de campo (dimensões 50 x 50 m) nas imagens orbitais foram extraídos os números digitais (DN) correspondentes às unidades amostrais, que foram convertidos em valores de refletância para utilização na obtenção do índice de vegetação NDVI utilizado no trabalho.

Foram desenvolvidos modelos de regressão onde as variáveis densidade, biomassa, volume, área basal e diversidade foram consideradas dependentes e os valores digitais como variáveis independentes.

Por meio de regressão linear foram encontradas altas correlações negativas (inferiores a 0,7) entre o índice de vegetação NDVI e as variáveis biométricas (área basal, biomassa e volume), concluindo os autores que o NDVI mostrou-se como um bom discriminador na caracterização da heterogeneidade da floresta primária, em termos de biomassa, volume e área basal.

De Paula e Pereira Filho (2009) conduziram estudos em um fragmento de floresta madura na Mata Atlântica nordestina, localizada no município de Ibatequara (AL), com o objetivo de testar a hipótese da existência de correlação entre índices de vegetação e o carbono acima do solo, utilizando o cruzamento de dados coletados no campo com dados espectrais.

Para o cálculo da biomassa os autores utilizaram parte de um inventário florestal realizado no fragmento estudado, composto de 30 parcelas de

10 x 100 m de floresta madura. Nestas parcelas, todas as árvores com dap > 10 cm foram identificadas e medidas (altura e dap). A biomassa das parcelas foi calculada usando a média de quatro equações alométricas, utilizando as variáveis dap, altura e a densidade das espécies coletadas.

As reflectâncias nas bandas azul, vermelho e infravermelho próximas das imagens do satélite SPOT-4 (*Satellite Pour l'Observation de la Terre*) e do Landsat-5, foram utilizadas para o cálculo dos índices espectrais NDVI, SAVI e EVI (com os coeficientes do algoritmo MODIS), adotados como medidores da produtividade primária líquida acima do solo – ANPP (*Aboveground Net Primary Productivity*).

As análises das regressões lineares do carbono total em relação aos índices de vegetação como medidores da ANPP foram significativas, mas os  $r^2$  da regressão foram muito baixos (0,14 NDVI – SPOT); 0,24 (NDVI – LANDSAT); 0,20 (SAVI – Landsat) e 0,28 (EVI – Landsat). Concluíram os autores que a variável ANPP não seria adequada para explicar, isoladamente, o carbono total de uma área e que, provavelmente, esta variável participaria de um modelo multivariado e se associada a outros fatores, como topografia, solo e umidade, possibilitaria o desenvolvimento de um modelo mais preciso.

Pinheiro *et al.* (2009) conduziram um estudo na Estação Ecológica de Assis (EEcA), localizada no sudoeste do estado de São Paulo, com o objetivo de avaliar a confiabilidade das estimativas de biomassa aérea em uma área de cerrado, a partir de imagens dos satélites Quickbird e Landsat-5.

Foram estudadas as relações da variável de interesse (biomassa arbórea), utilizando dez índices espectrais de vegetação. A variável de interesse também foi relacionada com os componente principais (CP1, CP2, CP3 e CP4) das imagens, bem como com as imagens-fração do solo (IfS1), da vegetação (IfV) e sombra (IfSo), derivadas do Modelo Linear de Mistura Espectral (MLME).

A biomassa foi inicialmente quantificada pelo método indireto por meio de amostragem da vegetação dos indivíduos arbóreos com dap  $\geq$  5 cm, em 40 parcelas de 20 x 40 m, sendo 20 cobertas por cerrado e 20 cobertas por cerrado. Com os valores de dap e altura total das árvores estimou-se a biomassa por meio de equações alométricas desenvolvidas para diferentes fisionomias do cerrado na área estudada.

Análises de regressão linear foram efetuadas, tendo como variável dependente a biomassa aérea (ou sua transformação logarítmica) e, como variáveis independentes, as bandas espectrais e suas transformações.

A reflectância nas bandas espectrais dos sensores avaliados (Landsat-5 e Quickbird) apresentou correlação variando de fracas a moderadas com a biomassa aérea do bioma estudado. Segundo os autores, estes resultados estão possivelmente associados à grande diversidade florística, porcentagem de cobertura do solo, iluminação, sombreamento e à arquitetura complexa do cerrado na área estudada.

Para os dois sensores, os índices de vegetação apresentaram correlações melhores para a biomassa do bioma estudado, quando comparados com as bandas espectrais individuais, mesmo, assim, com correlações baixas.

Nichol e Sarker (2011) investigaram os parâmetros de textura dos satélites de alta resolução, AVNIR-2 (*Advanced Visible and Near Infrared Radiometer type 2*) e SPOT-5 (*Satellite Pour l'Observation de la Terre*), em diferentes combinações de processamento com o objetivo visando à estimativa de biomassa em floresta situada na costa no sudeste da China.

Foram desenvolvidos modelos de regressão linear múltipla entre os parâmetros extraídos das imagens e a biomassa estimada em campo com a utilização de modelos alométricos. Os resultados demonstraram uma melhoria na estimativa da biomassa com o uso de parâmetros de textura ( $r^2 = 0,854$ ), quando comparados aos resultados obtidos a partir da refletância simples ( $r^2 = 0,494$ ) e razões simples de bandas espectrais ( $r^2 = 0,590$ ).

## 4 MATERIAL E MÉTODOS

### 4.1 Caracterização da área de estudo

O trabalho foi realizado em um fragmento florestal de mata nativa, classificada como Floresta Estacional Semidecidual Montana, localizado no município de Viçosa, MG, no *campus* da Universidade Federal de Viçosa (UFV) (Figura 5). Este fragmento está inserido em uma área denominada de “Mata da Silvicultura”, com cerca de 17 hectares, adquirida pela UFV em 1936 e, desde então, é protegida contra cortes e extração de madeira (FLORES, 1993).

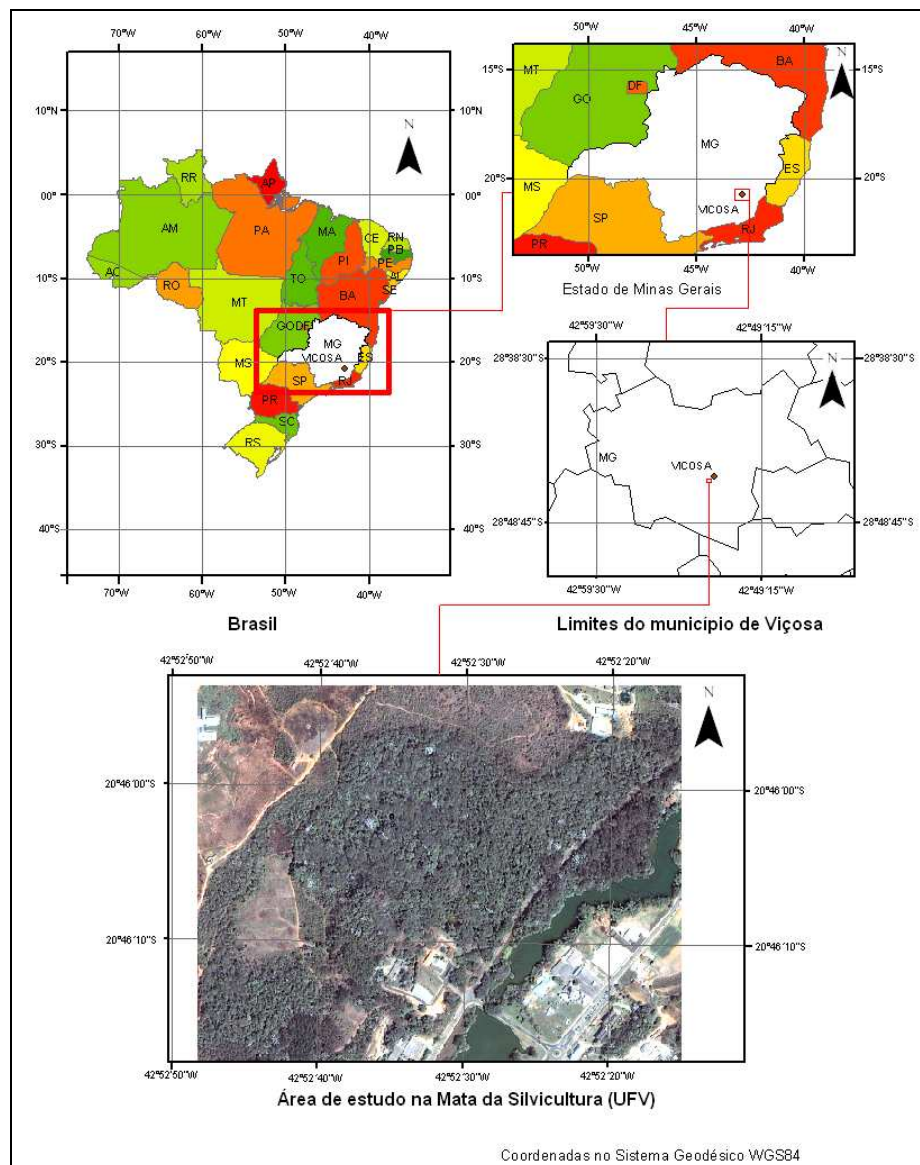
Na região, segundo Rezende (1971), há predominância de duas classes de solo: Latossolo Vermelho-Amarelo Álico (predominante nos topos de morro e encostas) e Podzólico Vermelho-Amarelo Câmbicos (terraços). O clima da região de Viçosa está classificado, segundo Köppen, como sendo Cwb, com verões chuvosos e invernos secos (ROMANOVSKY, 2001). A topografia na área de estudos é acidentada, com relevo fortemente ondulado e com altitudes variando de 650 a 750 metros.

### 4.2 Materiais, equipamentos e *softwares*

Para o desenvolvimento da pesquisa foram utilizados os seguintes recursos:

- imagem IKONOS II, com 1 metro de resolução (outubro de 2007);
- dois receptores GPS Promark2 de uma frequência;

- cartas do IBGE na escala 1:50.000;
- sistema topoGRAPH;
- uma estação total Topcon GTS 102n;
- *Software* OrthoEngine e Focus (PCI Geomatics);
- *Software* ArcGIS 9.2;
- *Software* Ashtech Solutions 2.60;
- *Software* Trimble Geomatics Office 1.63;
- *Software* ERDAS IMAGINE 10.0;
- *Software* GPS TrackMaker PRO 4.8; e
- *Software* Statistica v.10.



Fonte: elaborado pelo autor.

Figura 5 – Localização da área de estudo.

### 4.3 Imagens IKONOS II utilizadas na pesquisa

As imagens digitais utilizadas nesta pesquisa, com resolução radiométrica de 11 bits, foram adquiridas para utilização no projeto denominado *Plano de Segurança da Água*, realizado no município de Viçosa, no ano de 2008, cobrindo a bacia do Ribeirão São Bartolomeu, onde está inserida a área de estudo. As informações sobre os arquivos destas imagens estão detalhadas na Tabela 3.

Tabela 3 – Imagens brutas do satélite IKONOS II adquiridas pelo PSA

<b>Bandas</b>	<b>Arquivo da Imagem</b>	<b>Tamanho (KB)</b>	<b>Sistema Geodésico</b>
Vermelho	po_247515_red_0000000.tif	254.631	WGS84
Verde	po_247515_grn_0000000.tif	254.631	WGS84
Azul	po_247515_blu_0000000.tif	254.631	WGS84
IV Próximo	po_247515_nir_0000000.tif	254.631	WGS84

Fonte: metadados das imagens.

### 4.4 Modelo Digital de Elevação (MDE)

Para obtenção do modelo digital de elevação (MDE) cobrindo toda a área da imagem, necessário ao processo de ortorretificação, foram utilizadas as curvas de nível com equidistância de 20 m, disponibilizadas na forma de arquivos vetoriais. Estes arquivos são correspondentes às folhas topográficas em formato digital, das cartas SF-23-X-B-V-3 (Viçosa, MG) e SF-23-X-B-V-1 (Teixeiras, MG), ambas na escala 1:50.000, elaboradas pelo Instituto Brasileiro de Geografia e Estatística (IBGE) e integrantes do Mapeamento Sistemático Brasileiro.

A edição das curvas de nível, geração e manipulação do MDE, foram realizadas com auxílio do *software* ArcGIS versão 9.3.

### 4.5 Ortorretificação

A ortorretificação foi feita utilizando as ferramentas *Focus* (preparação e visualização das imagens) e *OrtoEngine* (ortorretificação) do *software* *PCI Geomatics*, versão 8.1.0. O método de modelagem empregado foi o Modelo

Funcional Racional, com base em pontos de controle terrestre (*Ground Control Points – GCPs*).

Em virtude das distorções na imagem bruta causadas pelas variações do relevo, devem-se escolher, preferencialmente, pontos situados em posições altimétricas extremas (posições mais altas e mais baixas do terreno). Além disso, conforme destaca Gripp Jr. (2009), na condução do processo de ortorretificação deve ser observado que as altitudes tanto do MDE utilizado quanto dos pontos de controle devem ser de mesma natureza (ou ortométricas ou geométricas).

Inicialmente, foram escolhidos na imagem bruta cerca de 50 pontos, distribuídos por toda a área, a fim de assegurar uma correção de qualidade para toda a imagem. Ao final dos trabalhos foram selecionados 43 pontos (Figura 6) que estavam situados em locais sem obstruções, com boas condições para a recepção de sinais dos satélites.

As coordenadas destes pontos foram obtidas pelo processamento dos arquivos coletados com um receptor de sinal GPS ProMark2, de uma frequência (L1), com tempo de ocupação estática no ponto de, no mínimo, 20 minutos e configurado para o intervalo de registro de posição a cada 5 segundos. Os arquivos de base foram coletados pela estação VICO da Rede Brasileira de Monitoramento Contínuo (RBMC), situada no *campus* da Universidade Federal de Viçosa, equipada a partir de abril de 2007 com um receptor Trimble NetR5 de dupla frequência. Todos os pontos rastreados (CPs e GCPs) situaram-se a uma distância menor que 10 km da base utilizada.

Com os mesmos critérios adotados para a escolha dos GCPs, foram identificados na imagem outros pontos de checagem (CheckPoints – CPs), para utilização na avaliação da qualidade da imagem ortorretificação. A Figura 7 apresenta a distribuição na imagem dos 15 CPs selecionados, cujas coordenadas foram também obtidas após o processamento dos arquivos coletados com o receptor GPS.

Alguns pontos presentes na imagem podem ser de fácil identificação no campo quando o usuário tem um bom conhecimento da região. Mesmo assim, podem ocorrer dúvidas, principalmente se existirem na imagem feições parecidas nas imediações do ponto escolhido. Desta forma, para facilitar a localização em campo das posições dos GCPs e CPs subtraiu-se da imagem bruta




Figura 6 – Distribuição dos pontos de controle na imagem bruta.

as coordenadas (N, E) aproximadas destes pontos, que posteriormente foram transferidas para um receptor GPS de navegação, com auxílio do *software GPS TrackMaker Pro*. Utilizando-se da função GOTO, disponível neste tipo de receptor e uma ampliação da imagem nas imediações do ponto, foi possível identificar com relativa facilidade os pontos desejados.



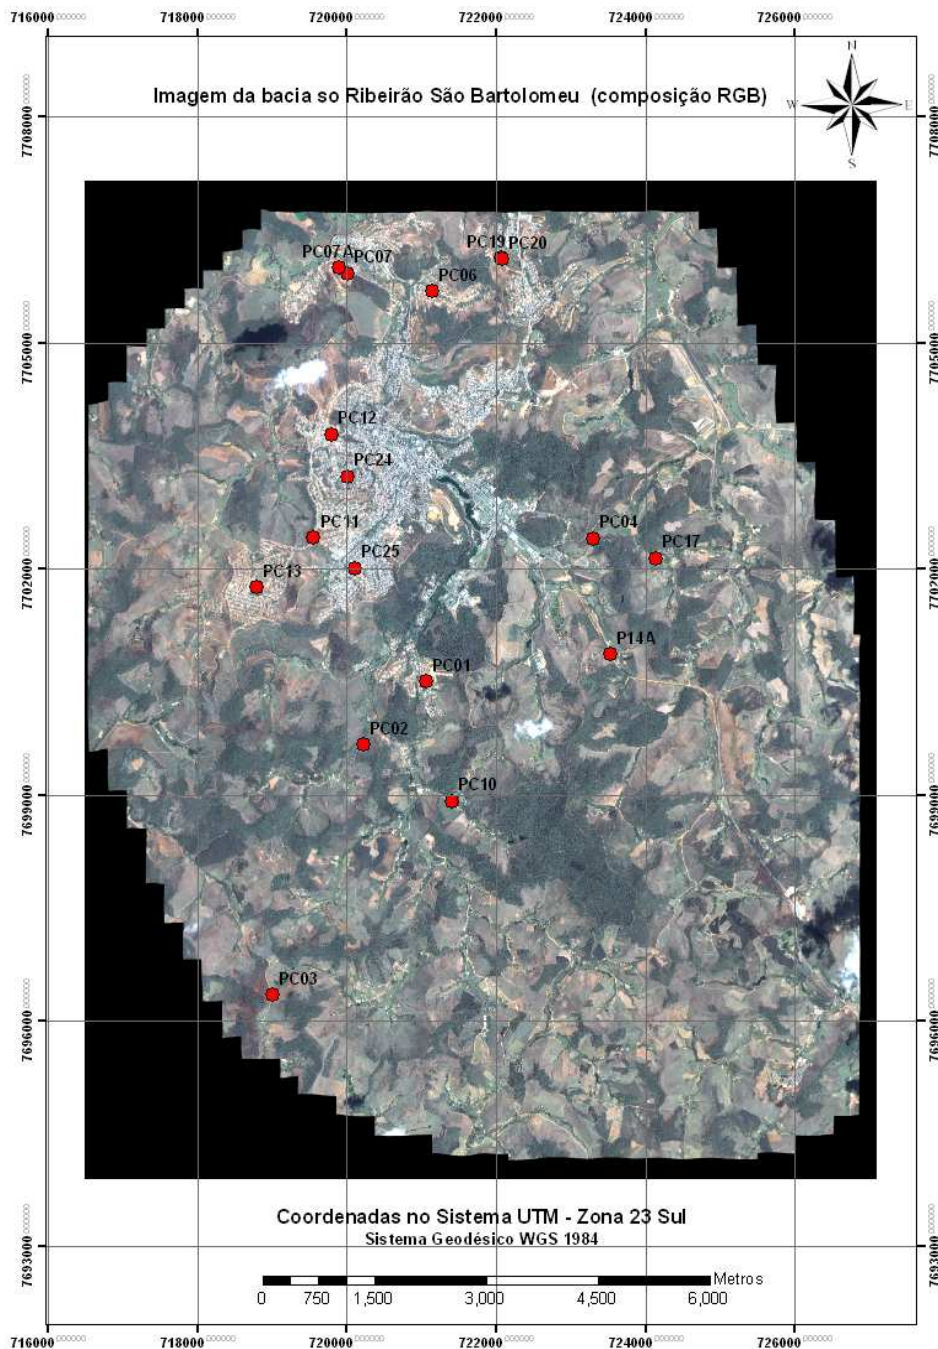


Figura 7 – Distribuição dos pontos de checagem na imagem bruta.

Durante a fase de rastreamento, tanto dos pontos de controle quanto dos pontos de checagem, a posição da antena do receptor foi fotografada (Figuras 8 e 9), possibilitando, com isto, melhorar a qualidade do posicionamento na imagem dos pontos de controle (fase da ortorretificação) e dos pontos de checagem (fase de avaliação da qualidade da imagem ortorretificada).



Fonte: fotografias e montagens do autor.

Figura 8 – Ponto de controle – Rastreio no campo e sua posição imagem.

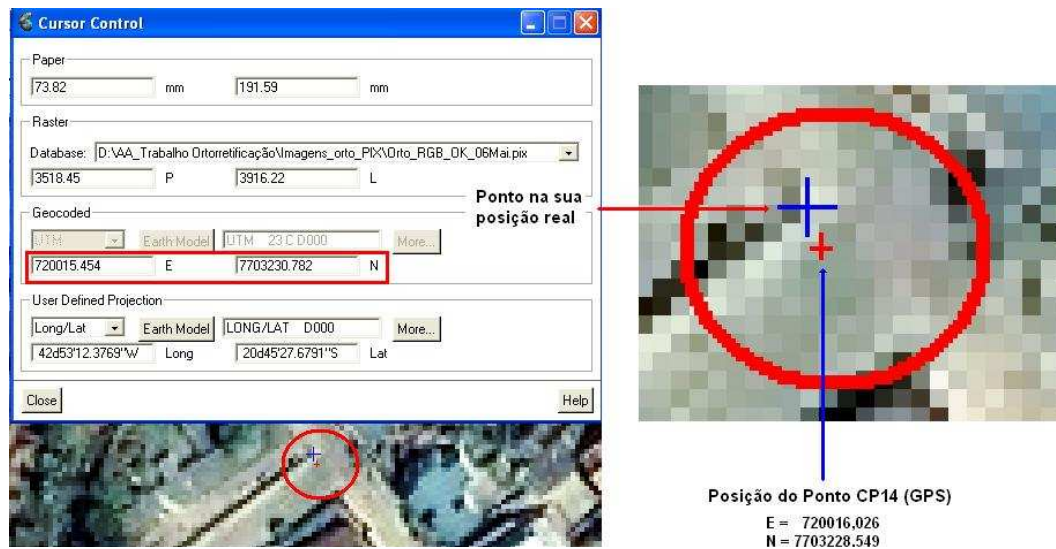


Fonte: fotografias e montagens do autor.

Figura 9 – Ponto de checagem – Rastreio no campo e sua posição imagem.

Para avaliação do resultado dos trabalhos de ortorretificação, criou-se no ArcGIS, um arquivo *shapefile* utilizando as coordenadas dos pontos de controle, obtidas no campo com o receptor ProMark2. Este arquivo foi carregado no *software* PCI (ferramenta *Focus*) juntamente com as imagens ortorretificadas. Na imagem, ao se posicionar o cursor no local onde o ponto foi coletado, as coordenadas do referido ponto na imagem são informadas em um quadro de diálogo relativo à operação executada. Finalmente, comparando as coordenadas do ponto na imagem com as coordenadas do mesmo no campo, obtém-se os deslocamentos planimétricos nos sentidos Norte e Este e, com estes, o valor da componente resultante.

A Figura 10 mostra a situação de um ponto de checagem em uma imagem na composição RGB: as coordenadas (E, N), obtidas para o ponto de controle CP14 após o processamento dos dados coletados com o receptor GPS relativos a este ponto, foram, respectivamente, 720.016,026 m e 7.703.228,549 m. Porém, mesmo após o procedimento de ortorretificação, as coordenadas do ponto (na posição mais próxima possível daquela onde



Fonte: montagem do autor.

Figura 10 – Avaliação das deformações em um ponto de controle.

realmente foi instalada no campo a antena do receptor) apresentam divergência dos valores obtidos a partir dos dados do receptor GPS. Quanto menores forem estas divergências melhor será a qualidade posicional da imagem ortorectificada.

Na situação mostrada na Figura 10, as coordenadas (E, N) informadas pelo *software* após o posicionamento do cursor sobre o ponto na imagem foram, respectivamente, 720.015,454 m e 7.703.230,782 m, ou seja, em relação aos valores obtidos após o processamento dos dados do receptor GPS para um mesmo ponto, há um deslocamento de 0,572 m em relação à abscissa (E) e outro de -2,233 m em relação à ordenada (N). Procedendo de modo análogo, foram calculados os deslocamentos de todos os 15 pontos de controle levantados.

Analisando os resultados obtidos verificou-se que as imagens brutas apresentavam erros na resultante dos deslocamentos em relação às abscissas e ordenadas, variando de 38,919 a 2,113 m (média de 20,292 m para os 15 pontos de controle). Nas imagens finais, obtidas após o procedimento de ortorectificação, estes valores variaram de 2,305 a 0,461 m (média de 1,478 para os 15 pontos de controle).

De acordo com o Decreto nº 89.817, de 20 de junho de 1984, e pelas análises estatísticas efetuadas com base nas discrepâncias entre as coordenadas dos 15 pontos de controle, obtidas em campo e extraídas de seus homó-

logos na imagem, as ortoimagens geradas podem ser classificadas como Classe A para a escala 1:5.000.

#### 4.6 Inventário de biomassa e carbono

Amaro (2010) realizou um inventário florestal temporário (período de janeiro a abril de 2008) em 15 unidades amostrais, com área de 1.000 m<sup>2</sup> (dimensões de 20 x 50 m), distribuídas por todo o fragmento estudado. Nestas unidades foram encontrados 2.026 indivíduos vivos, correspondendo a 2.265 fustes de 198 espécies arbóreas, distribuídas em 46 famílias.

Com relação ao número de indivíduos e de fustes, destacaram-se as famílias *Leguminosae* (322 e 359), *Rubiaceae* (259 e 356), *Monimiaceae* (253 e 263), *Flacourtiaceae* (167 e 181), *Euphorbiaceae* (151 e 159), *Lauraceae* (129 e 133), *Myrtaceae* (91 e 102), *Annonaceae* (71 e 80), *Bignoniaceae* (54 e 59), *Lacistemataceae* (56 e 58), *Clusiaceae* (52 e 57) e *Meliaceae* (56 e 57). Estas famílias contribuíram com 1.661 indivíduos (82,0%) e 1.864 fustes (82,3%) em relação ao total. A representação gráfica da distribuição das principais famílias nas parcelas experimentais é apresentada na Figura 11.




Figura 11 – Indivíduos e fustes das famílias mais encontradas nas unidades amostrais.



As espécies *Anadenanthera peregrina*, *Bathysa nicholsonii*, *Pseudopiptadenia contorta*, *Casearia ulmifolia*, *Apuleia leiocarpa*, *Siparuna arianae*, *Casearia arborea*, *Platypodium elegans*, *Lacistema pubescens* e *Cecropia hololeuca* foram aquelas com os maiores valores de importância volumétrica encontradas na área de estudo.

Em cada unidade amostral todos os indivíduos com dap  $\geq 5$  cm foram identificados pelo nome regional e científico. Além do dap (medido com trena), foram obtidas com o hipsômetro digital Vertex IV a altura dos fustes (hf) (início da copa) e a altura total (ht). Ainda, em cada parcela, foram efetuadas as medidas das coordenadas plano-retangulares (x, y) da posição dos indivíduos na parcela.

A biomassa estocada no fuste de cada árvore-amostra foi determinada multiplicando-se os volumes de madeira e de casca pelas suas respectivas densidades. Já o estoque de carbono foi obtido multiplicando-se as estimativas de biomassa pelos respectivos teores de carbono, determinados em laboratório.

De posse dos estoques de biomassa e carbono e das medidas de diâmetro (dap) e alturas (fuste e total) das árvores-amostra, foram avaliados alguns modelos de regressão e as melhores equações foram utilizadas para estimar o estoque de biomassa e carbono do fuste dos indivíduos presentes nas parcelas do inventário.

Os resultados obtidos por Amaro (2010), a partir das equações que se ajustaram melhor aos dados observados, são apresentados nas Tabelas 4 e 5.

#### **4.7 Limites das parcelas amostrais na imagem**

Para obtenção da localização das unidades amostrais na imagem IKONOS, foi efetuado um levantamento topográfico de precisão da posição de algumas árvores, em cada uma das parcelas, com a utilização de uma estação total Topcon GTS-102n.

O levantamento foi apoiado em pontos implantados na área e previamente ocupados com um receptor GPS ProMark2 (posicionamento estático com tempo de ocupação de no mínimo 30 minutos). As coordenadas geodésicas destes pontos de apoio foram obtidas a partir do processamento, no

Tabela 4 – Estoque total médio de biomassa (t/ha) nas parcelas

Parcelas	Indivíduos com dap $\geq$ 5 cm			dap < 5 cm		Litter (t ha <sup>-1</sup> )	Total
	Árvores (t ha <sup>-1</sup> )		Outros <sup>1/</sup> (t ha <sup>-1</sup> )	Hf $\geq$ 1,3 m (t ha <sup>-1</sup> )	Hf < 1,3 m (t ha <sup>-1</sup> )		
	Vivas	Mortas		(t ha <sup>-1</sup> )	(t ha <sup>-1</sup> )	(t ha <sup>-1</sup> )	
1	243,99	4,44	-	2,90	7,60	9,14	268,07
2	140,09	2,98	7,12	5,39	12,85	168,43	176,24
3	127,08	30,53	-	7,85	2,31	8,47	-
4	97,77	30,75	3,43	9,70	1,66	5,90	149,21
5	135,85	7,80	10,03	8,36	7,61	15,13	184,78
6	203,85	4,48	3,40	3,86	3,10	12,34	231,03
7	401,34	2,71	-	15,23	1,92	8,91	430,11
8	186,71	2,48	-	6,36	1,22	8,70	205,47
9	159,82	1,81	8,70	7,22	1,23	20,51	199,29
10	223,19	0,31	-	5,10	1,92	24,59	255,11
11	179,26	8,21	39,07	3,20	3,47	7,37	240,58
12	158,75	3,32	39,13	0,43	8,05	5,29	214,97
13	136,32	13,48	35,65	6,15	1,34	7,11	200,05
14	136,75	3,53	4,15	7,08	1,25	14,40	167,16
15	291,63	3,31	-	9,49	2,48	13,56	320,47
<b>Média</b>	<b>188,16</b>	<b>8,01</b>	<b>9,57</b>	<b>6,67</b>	<b>3,37</b>	<b>11,62</b>	<b>227,40</b>

Fonte: Amaro (2010).

Tabela 5 – Estoque total médio de carbono (t/ ha) nas parcelas

Parcelas	Indivíduos com dap $\geq$ 5 cm			dap < 5 cm		Litter (t ha <sup>-1</sup> )	Total
	Árvores (t ha <sup>-1</sup> )		Outros <sup>1/</sup> (t ha <sup>-1</sup> )	Hf $\geq$ 1,3 m (t ha <sup>-1</sup> )	Hf < 1,3 m (t ha <sup>-1</sup> )		
	Vivas	Mortas		(t ha <sup>-1</sup> )	(t ha <sup>-1</sup> )	(t ha <sup>-1</sup> )	
1	118,15	2,06	-	1,41	3,69	4,44	129,74
2	66,20	1,39	-	3,46	2,62	6,24	79,90
3	59,93	14,83	-	3,81	1,12	4,11	83,80
4	45,99	14,75	1,64	4,71	0,81	2,86	70,76
5	65,08	3,70	4,81	4,06	3,69	7,34	88,69
6	97,87	2,11	1,62	1,87	1,50	5,99	110,97
7	194,55	1,26	-	7,39	0,93	4,32	208,46
8	88,72	1,16	-	3,09	0,59	4,22	97,78
9	75,73	0,84	4,15	3,50	0,60	9,96	94,78
10	107,13	0,14	-	2,48	0,93	11,94	122,61
11	84,98	3,87	19,09	1,55	1,68	3,58	114,76
12	75,14	1,55	19,05	0,21	3,91	2,57	102,42
13	64,15	6,33	17,33	2,99	0,65	3,45	94,90
14	65,04	1,65	1,99	3,44	0,61	6,99	79,71
15	141,38	1,54	-	4,61	1,20	6,58	155,31
<b>Média</b>	<b>90,01</b>	<b>3,81</b>	<b>4,64</b>	<b>3,24</b>	<b>1,64</b>	<b>5,64</b>	<b>108,98</b>

Fonte: Amaro (2010).

<sup>1/</sup> Espécies não arbóreas, dentre elas algumas da família *Arecaceae* encontradas na área de estudo.

software Ashtech Solutions, dos arquivos coletados nos pontos com receptor ProMark2, utilizando-se como base o ponto da Rede Brasileira de Monitoramento Contínuo (RBMC), situada no *campus* da UFV.

Com as coordenadas cartesianas (X, Y) das árvores da parcela, medidas por Amaro (2010), e as coordenadas com referência geodésica das mesmas, obtidas pelo levantamento topográfico por meio de procedimentos de rotação e translação, foi possível obter a localização e a orientação das parcelas na imagem, conforme mostrado no recorte da imagem IKONOS ortorretificada da Figura 12, o qual contempla todas as análises feitas *a posteriori*.




Figura 12 – Localização e distribuição das parcelas no fragmento estudado.

#### 4.8 Conversão dos números digitais em reflectância planetária

Inicialmente, os números digitais originais da área onde estão situadas as parcelas experimentais, nas bandas MS-1, MS2, MS3 e MS-4 da imagem IKONOS, foram convertidos em radiância espectral ( $L_\lambda$ ) utilizando a equação 3 apresentada em Taylor (2009). Para isto, criou-se um algoritmo no módulo *Model Maker* do software ERDAS (Figura 13).

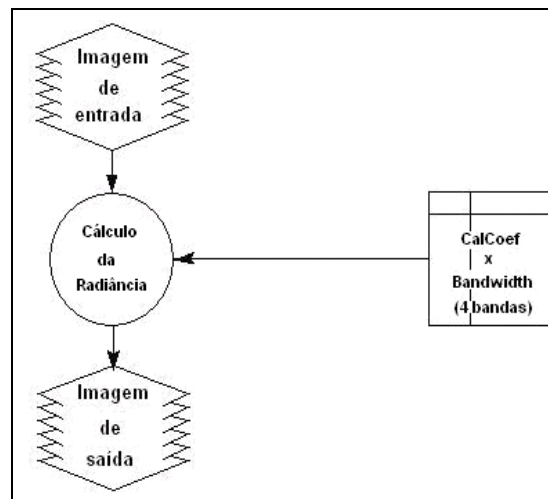


Figura 13 – Modelo para geração da imagem com os valores de radiância.

As imagens de radiância, geradas para as quatro bandas a partir dos elementos presentes na área de estudo, são mostradas na Figura 14.

De acordo com equação 4, apresentada em Taylor (2009), para a conversão de radiância espectral ( $L_\lambda$ ) em reflectância planetária ( $\rho_p$ ), necessita-se do conhecimento do ângulo de zenital solar ( $\theta$ ) no instante da aquisição da imagem, da distância Terra-Sol ( $d$ ), em unidades astronômicas, e da irradiância exoatmosférica média do Sol para cada banda da imagem ( $ESun_\lambda$ ).

Na Tabela 6 são apresentados os metadados da imagem IKONOS utilizada na pesquisa, onde se observa que, no momento da aquisição da imagem, o Sol estava com uma elevação de 69,76101 graus acima do horizonte, portanto, com um ângulo zenital de 20,23899 graus.

A distância Terra-Sol é fornecida em diversos anuários astronômicos e almanaques náuticos. A Tabela 7 mostra um trecho das efemérides do Sol extraído do Anuário Astronômico do Observatório Nacional relativo ao ano de



2007, destacando-se a informação relativa à distância Terra-Sol, em unidades astronômicas (UA), para o dia 29 de outubro, data da aquisição da imagem IKONOS utilizada na pesquisa.




Figura 14 – Imagens de radiância da área de estudo.

Tabela 6 – Metadados das imagens utilizadas na pesquisa

<b>Source Image Metadata - Source Image ID 2007102913163790000011627045</b>	
<b>Product Image ID 000 - Sensor: IKONOS-2</b>	
Acquired Nominal GSD	
Pan Cross Scan	0.91 meters
Pan Along Scan	1.00 meters
MS Cross Scan	3.63 meters
MS Along Scan	4.01 meters
Scan Azimuth	179.98 degrees
Scan Direction	Reverse
Panchromatic TDI Mode	13
Nominal Collection Azimuth	348.7812 degrees
Nominal Collection Elevation	64.12059 degrees
Sun Angle Azimuth	72.3742 degrees
Sun Angle Elevation	69.76101 degrees
Acquisition Date/Time	2007-10-29 13:16 GMT
Percent Cloud Cover	4

Fonte: arquivo po\_247515\_metadata.txt (fornecido com os arquivos das imagens).

Tabela 7 – Elementos astronômicos do Sol (0<sup>h</sup> tempo Terrestre, out./2007)

Dia	Ascensão Reta			Declinação			Dist. à Terra	Raio		Passagem Meridiana em Greenwich		
	H	M	S	°	'	"		UA	'	"	H	M
27	14	3	51,57	-12	34	32,1	0,993 9737	16	05,46	11	43	54,00
28	14	7	42,41	-12	54	50,5	0,993 7061	16	05,72	11	43	48,66
29	14	11	34,02	-13	14	57,0	0,993 4418	16	05,98	11	43	44,08
30	14	15	26,40	-13	34	51,1	0,993 1805	16	06,24	11	43	40,28

Fonte: Observatório Nacional – Anuário Astronômico (2007).

Com os valores de radiância espectral ( $L_\lambda$ ), anteriormente calculados, e com as informações obtidas das Tabelas 1, 6 e 7, desenvolveu-se um novo algoritmo (Figura 15) no módulo *Model Maker*, do software ERDAS, para gerar as imagens de reflectância para a área de estudo, com a formulação apresentada na equação 4.

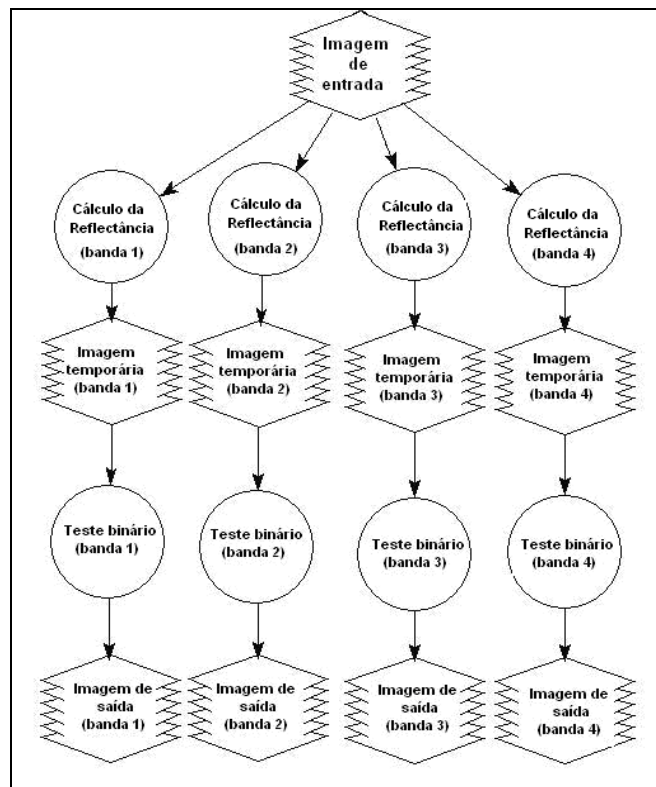


Figura 15 – Modelo para geração das imagens com os valores de reflectância.

As imagens de reflectância, obtidas nas quatro bandas do satélite IKONOS II, para a área de estudos, são apresentadas na Figura 16.






Figura 16 – Imagens de reflectância da área de estudo.

#### **4.9 Estimativas da biomassa e do carbono aéreo a partir das imagens IKONOS II**

Para a avaliação do potencial das variáveis digitais, originárias de dados do sensor IKONOS II, que proporcionam as melhores estimativas das variáveis biométricas (biomassa arbórea e carbono arbóreo), para a área de estudo, foram utilizadas análise de regressão e redes neurais artificiais.

##### **4.9.1 Estimativas por meio de análise de regressão linear**

Foram consideradas como variáveis dependentes os dados de biomassa arbórea e carbono arbóreo, obtidos por meio do inventário florestal e, como independentes, as variáveis digitais, obtidas a partir da imagem do satélite IKONOS II (reflectância nas quatro bandas, os índices de vegetação RVI, NDVI, TVI, SAVI, MSAVI, EVI, ARVI, GEMI, TCap1, TCap2, TCap3 e TCap4).

Durante a fase do inventário florestal foram efetuadas, separadamente, estimativas dos estoques de biomassa e carbono para os indivíduos arbóreos e

não arbóreos, com diferentes variáveis dendrométricas (dap e altura do fuste). Desta forma, tanto a variável dependente biomassa arbórea quanto o carbono arbóreo foram subdivididas em três grupos, de acordo com as variáveis dendrométricas utilizadas no inventário florestal. O objetivo desta subdivisão foi verificar eventuais influências da contribuição dos indivíduos, incluídos nestes grupos as estimativas dos estoques de biomassa e carbono, a partir dos dados oriundos do sensoriamento remoto.

As Tabelas 8 e 9 apresentam a identificação e a descrição das variáveis utilizadas nos modelos de regressão.

Tabela 8 – Variáveis dependentes

Variável	Detalhes
<b>Biom1</b>	Biomassa dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (apenas os arbóreos)
<b>Biom2</b>	Biomassa dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (arbóreos e não arbóreos)
<b>Biom3</b>	Biomassa dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (arbóreos e não arbóreos), bem como aqueles com dap < 5 cm e altura do fuste maiores ou menores que 1,3 m
<b>Carb1</b>	Carbono dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (apenas os arbóreos)
<b>Carb2</b>	Carbono dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (arbóreos e não arbóreos)
<b>Carb3</b>	Carbono dos indivíduos vivos das parcelas com dap $\geq$ 5 cm (arbóreos e não arbóreos), bem como aqueles com dap < 5 cm e altura do fuste maiores ou menores que 1,3 m

Tabela 9 – Variáveis independentes

Variável	Descrição
Banda1	Reflectância planetária na banda espectral 1 (azul)
Banda2	Reflectância planetária na banda espectral 2 (verde)
Banda3	Reflectância planetária na banda espectral 3 (vermelho)
Banda4	Reflectância planetária na banda espectral 4 (IV próximo)
RVI	Índice de vegetação da razão
NDVI	Índice de vegetação da diferença normalizada
TVI	Índice de vegetação transformado
SAVI	Índice de vegetação ajustado ao solo
MSAVI	índice de vegetação ajustado para a interferência do solo
EVI	Índice de vegetação melhorado
ARVI	Índice de vegetação com resistência atmosférica
GEMI	Índice global de monitoramento ambiental
TCap1	Imagem transformada <i>Tasseled Cap</i> para a banda 1
TCap2	Imagem transformada <i>Tasseled Cap</i> para a banda 2
TCap3	Imagem transformada <i>Tasseled Cap</i> para a banda 3
TCap4	Imagem transformada <i>Tasseled Cap</i> para a banda 4

Na Tabela 10 apresenta são apresentados os dados do inventário florestal, de acordo com os grupos definidos na Tabela 8.

Tabela 10 – Estimativas de biomassa e carbono do inventário florestal (t ha<sup>-1</sup>)

Parcelas	Variáveis Dependentes					
	Biom1	Biom2	Biom3	Carb1	Carb2	Carb3
1	243,99	243,99	254,49	118,15	118,15	123,25
2	140,09	140,09	152,60	66,20	66,20	72,28
3	127,08	127,08	137,24	59,93	59,93	64,86
4	97,77	101,20	112,56	45,99	47,63	53,15
5	135,85	145,88	161,85	65,08	69,89	77,64
6	203,85	207,25	214,21	97,87	99,49	102,86
7	401,34	401,34	418,49	194,55	194,55	202,87
8	186,71	186,71	194,29	88,72	88,72	92,40
9	159,82	168,52	176,97	75,73	79,88	83,98
10	223,19	223,19	230,21	107,13	107,13	110,54
11	179,26	218,33	225,00	84,98	104,07	107,30
12	158,75	197,88	206,36	75,14	94,19	98,31
13	136,32	171,97	179,46	64,15	81,48	85,12
14	136,75	140,90	149,23	65,04	67,03	71,08
15	291,63	291,63	303,60	141,38	141,38	147,19

Na Tabela 10 percebem-se nitidamente as influências da diversidade das espécies, da altura das árvores e do diâmetro dos fustes, nos estoques de biomassa e carbono, obtidos para a área de estudo. O estoque de biomassa total (Biom3) ultrapassa 400 t/ha na parcela 7, ao passo que na parcela 4 é de 101,20 t/ha, apesar de todas as parcelas terem a mesma área (1.000 m<sup>2</sup>).

Os valores médios da reflectância nas parcelas experimentais, nas quatro bandas espectrais da imagem do satélite IKONOS II, foram calculados pelo *software* ERDAS. Para este procedimento foram utilizados polígonos AOI (*area of interest*), obtidos a partir das informações coletadas na fase do levantamento topográfico, referentes aos limites de cada uma das parcelas da área de estudo. Com os valores médios da reflectância foram calculados os valores dos índices de vegetação, utilizados na pesquisa, para cada uma das parcelas.

Nas Tabelas 11 e 12, respectivamente, são apresentados os valores das refletâncias médias nas quatro bandas e os valores médios dos índices de vegetação para as duas primeiras parcelas.

Tabela 11 – Valores médios da reflectância nas parcelas experimentais

Parcelas	Reflectância Planetária (Média das Parcelas)			
	Banda1 (MS <sup>-1</sup> )	Banda2 (MS <sup>-2</sup> )	Banda3 (MS <sup>-3</sup> )	Banda4 (MS <sup>-4</sup> )
1	0,170	0,153	0,140	0,355
2	0,175	0,157	0,146	0,398

Tabela 12 – Valores médios dos índices de vegetação nas parcelas experimentais

Parcelas	Índices de Vegetação											
	RVI	NDVI	TVI	SAVI	MSAVI	EVI	ARVI	GEMI	TCap1	TCap2	TCap3	TCap4
1	2,536	0,434	0,967	0,324	0,306	0,584	0,527	0,634	0,413	0,138	-0,079	-0,046
2	2,726	0,463	0,981	0,362	0,348	0,655	0,546	0,675	0,444	0,168	-0,083	-0,049

Inicialmente, foram estimados os coeficientes de correlação linear entre as variáveis biométricas (biomassa e carbono) e digitais (bandas e índices de vegetação), para se determinar o grau de associação linear entre e identificar variáveis com maiores probabilidade de contribuição ao modelo de regressão. O modelo geral utilizado foi:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_p X_p + \varepsilon \quad (19)$$

em que

$Y$  = variável dependente;

$X_p$  = variáveis independentes; e

$\beta_j$  = coeficientes do modelo e  $\varepsilon$  é o erro aleatório,  $\varepsilon \sim NID(0, \sigma^2)$ .

Para a determinação do conjunto das variáveis que contribuiriam para a regressão, foi utilizado o procedimento passo a passo (*Stepwise*), conforme Drapper e Smith (1983), a 5% de significância. Os modelos de regressão foram ajustados apenas para a variável dependente Biom3 (biomassa total), assumindo que a biomassa parcial e os estoques de carbono podem ser estimados por meio de modelos de razão, conforme Campos e Leite (2009). A exatidão e consistência das estimativas geradas pela equação selecionada foram avaliadas pelo coeficiente de determinação ajustado ( $\bar{R}^2$ ), pelo erro padrão residual (*EPR*) e pela análise gráfica dos resíduos.

#### 4.9.2 Redes Neurais Artificiais (RNA)

Neste estudo, o treinamento das redes foi do tipo supervisionado, ou seja, a saída desejada foi fornecida à rede que comparou o erro (diferença entre saída desejada e calculada) com a saída calculada. O erro foi informado à rede, que modificou seus parâmetros, a fim de minimizar o erro global e obter uma melhor solução. As redes foram treinadas para estimação dos valores de biomassa (variáveis Biom1, Biom2 e Biom3) e carbono (variáveis Carb1, Carb2 e Carb3), a partir de três valores de variáveis de entradas diferentes, sendo:

- somente os valores das reflectâncias médias das parcelas experimentais nas quatro bandas espectrais (Banda1, Banda2, Banda3 e Banda4);
- valores médios obtidos para as parcelas experimentais dos índices RVI, NDVI, TVI, SAVI, MSAVI, EVI, ARVI, GEMI, TCap1, TCap2, TCap3 e TCap4; e
- valores médios da reflectância nas bandas e dos índices espectrais.

Foram treinadas 100 redes do tipo *Perceptrons* de Múltiplas Camadas (MLP), para cada combinação de valores de entrada. Das 100 RNA treinadas, selecionou-se apenas a melhor rede, em função do coeficiente de correlação entre valores observados e valores estimados pela RNA. A definição da arquitetura das redes, ou seja, número de neurônios por camada e número de camadas, foi otimizada pela ferramenta *Intelligent Problem Solver* (IPS), do *software* Statística 10 (STATSOFT, Inc, 2011).

As estimativas da variável Biom3, obtidas pelo emprego de RNA, foram comparadas com as estimativas obtidas por meio de regressão, empregando o procedimento estatístico proposto por Leite e Oliveira (2002), a 5% de significância.

## 5 RESULTADOS E DISCUSSÃO

### 5.1 Estimação da biomassa e do carbono por meio de análise de regressão

A matriz de correlação entre as variáveis dependentes (biomassa e carbono) e as variáveis independentes, representadas pelas bandas espectrais e pelos índices de vegetação do sensor IKONOS II, é apresentada na Tabela 13. A análise desta tabela mostra que a maior correlação negativa (-0,74%) foi obtida entre a variável Carb2 e o índice TCap1. No geral, nota-se que as maiores correlações ocorreram para praticamente todas as variáveis dependentes com o índice TCap1.

Tabela 13 – Matriz de correlação entre as variáveis dependentes e independentes

	Reflectâncias nas Bandas				Índices de Vegetação											
	1	2	3	4	RVI	NDVI	TVI	SAVI	MSAVI	EVI	ARVI	GEMI	TCap1	TCap2	TCap3	TCap4
Biom1	-0,24	-0,50	-0,38	-0,68	-0,48	-0,49	-0,50	-0,58	-0,59	-0,62	-0,39	-0,59	-0,72	-0,60	0,63	0,02
Biom2	-0,29	-0,52	-0,43	-0,62	-0,40	-0,42	-0,42	-0,51	-0,51	-0,55	-0,30	-0,52	-0,69	-0,53	0,60	0,08
Biom3	-0,31	-0,53	-0,44	-0,63	-0,41	-0,42	-0,42	-0,51	-0,52	-0,56	-0,31	-0,53	-0,70	-0,54	0,62	0,10
Carb1	-0,24	-0,50	-0,39	-0,68	-0,48	-0,50	-0,50	-0,58	-0,59	-0,62	-0,39	-0,60	-0,73	-0,60	0,63	0,02
Carb2	-0,26	-0,51	-0,40	-0,69	-0,49	-0,50	-0,50	-0,59	-0,59	-0,63	-0,39	-0,60	-0,74	-0,61	0,65	0,04
Carb3	-0,31	-0,53	-0,44	-0,63	-0,41	-0,43	-0,43	-0,52	-0,52	-0,57	-0,31	-0,53	-0,71	-0,54	0,62	0,10

(\*) Valores destacados em vermelho indicam  $p \leq 0,05$ .

Ao analisar apenas a biomassa total (Biom3), foram observadas para as bandas 2 (-0,53%) e 4 (-0,63%) e para os índices MSAVI (-0,52%), GEMI (-0,53%), TCap1 (-0,70%), TCap2 (-0,54%) e TCap3 (0,62%). Já para o carbono total (Carb3), as maiores correlações foram observadas para a banda 4 (-0,63%) e os índices SAVI (-0,52%), MSAVI (-0,52%), GEMI (-0,53%), TCap1



(-0,71%), TCap2 (-0,54%) e TCap3 (0,62%). Nota-se que as correlações encontradas para biomassa total e carbono total, com as variáveis digitais, foram semelhantes. Segundo Watzlawick *et al.* (2009), isto ocorre em virtude de essas duas variáveis serem altamente correlacionadas.

Como a variável TCap1 foi a que apresentou maior correlação com todas as variáveis dependentes, espera-se que ela seja a variável candidata com a maior probabilidade de contribuição ao modelo de regressão.

É interessante observar que os índices de vegetação tradicionais, como o NDVI, RVI e TVI, que não usam informação do solo em suas formulações, apresentaram baixas correlações com a biomassa e o carbono, contradizendo a maioria dos trabalhos citados na literatura. Este fato pode ser explicado pela época da aquisição da imagem utilizada (final de outubro), quando a maioria das espécies florestais predominantes na área de estudo (leguminosas), por serem caducifólias, apresentava acentuada queda de suas folhas, e em consequência, redução de sua biomassa verde. Watzlawick *et al.* (2009), trabalhando com as quatro bandas da imagem IKONOS, além dos índices da razão, NDVI e SAVI, para estimar biomassa e estoque de carbono em floresta de araucária, encontram correlações de -0,80 e -0,79, respectivamente, entre a biomassa e o carbono com a banda 4. Lu *et al.* (2012), utilizando imagens do sensor Landsat TM para estimativas de biomassa arbórea em florestas sucessionais na região amazônica também encontraram coeficiente de determinação ( $R^2$ ) de 0,75 entre a biomassa acima do solo e a banda 4.

As Figuras 17 e 18 ilustram as correlações observadas entre as variáveis dependentes (biomassa e carbono) e as independentes (variáveis digitais). Em geral, nota-se uma grande dispersão dos dados ao longo da reta, indicando baixas correlações entre as variáveis analisadas. No entanto, percebe-se que as menores dispersões com as variáveis biométricas ocorreram com a variável TCap1, conforme pode ser observado na Figura 17.

Para obtenção das estimativas das variáveis biométricas, biomassa total e carbono total, foi utilizado o procedimento *stepwise* analisando o comportamento das variáveis explicativas nas seguintes situações:

- apenas a reflectância nas quatro bandas espectrais;
- todos os índices de vegetação utilizados na pesquisa; e
- a reflectância e os índices de vegetação.




Figura 17 – Representação das correlações entre biomassa e carbono com os índices de vegetação calculados.

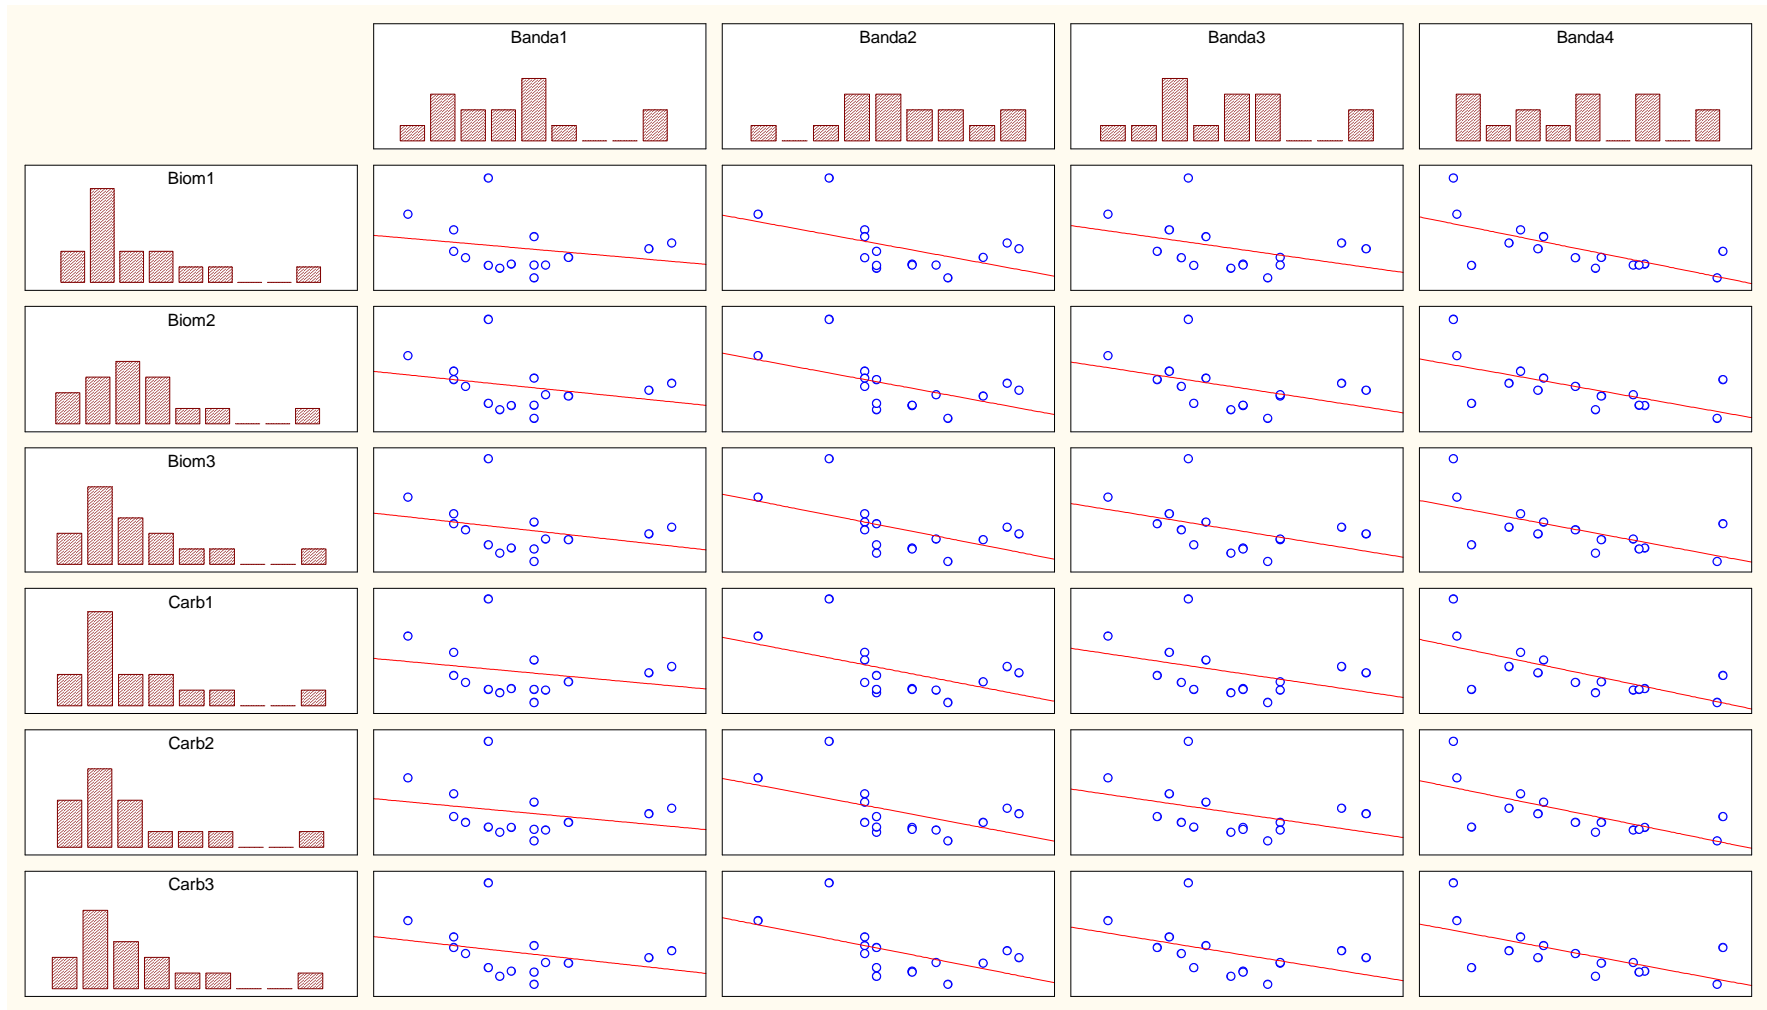


Figura 18 – Representação das correlações entre biomassa e carbono com as bandas 1, 2, 3 e 4.

Para as situações analisadas foram encontrados os seguintes resultados:

- ao incluir apenas a reflectância nas quatro bandas espectrais no modelo, os resultados conduziram a equações lineares simples, em função da reflectância na banda 4, para estimativas tanto da biomassa total (Biom3) quanto para o carbono total (Carb3).

- quando foram incluídos apenas os índices de vegetação utilizados na pesquisa, foram também obtidas relações lineares simples tanto para as estimativas biomassa total quanto para o carbono total, em função do índice TCap1;

- a inclusão de todas as variáveis explicativas (bandas e índices de vegetação) resultou também em relações lineares simples, em função do índice TCap1 para estimar a biomassa total e o carbono total;

- em todas as situações analisadas, outras variáveis explicativas apresentaram significância na correlação linear simples; entretanto, suas inclusões no modelo resultaram em valores de F parciais não significativos.

Assim, o procedimento *stepwise* indicou que, para obtenção das estimativas de biomassa e carbono na área pesquisada com o uso de modelos de regressão, apenas as variáveis Banda4 e, ou, TCap1 são suficientes para estimar tanto a biomassa total quanto o carbono total para as condições da área estudada.

As equações obtidas para as referidas estimativas, geradas pelo *software* Statistica, para os modelos que apresentaram as melhores correlações, são apresentadas nas Tabelas 14 e 15.

Tabela 14 – Equações para estimar a biomassa total

Estimativas de Biomassa Total por Análise de Regressão				
Modelo	Equação	$\bar{R}^2$	EPR	F (1,13)
1	Biom3 = 804,925565 - 1597,601813.Banda4	0,348	61,501	8,4587
2	Biom3 = 1349,841480 - 2656,592356.TCap1	0,458	56,070	12,817

Tabela 15 – Equações para estimar o estoque de carbono

Estimativas de Estoque de Carbono por Análise de Regressão				
Modelo	Equação	$\bar{R}^2$	EPR	F (1,13)
1	Carb3 = 395,236025 - 791,140229.Banda4	0,354	30,059	8,6830
2	Carb3 = 665,164722 - 1315,752154.TCap1	0,466	27,327	13,236

O melhor ajuste de biomassa e carbono com a banda 4 pode ser explicado em razão desta variável (infravermelho próximo) estar estreitamente relacionada com a vegetação; isto é, ocorre uma alta refletância da energia pela vegetação, em função da estrutura interna das células (WATZLAWICK *et al.*, 2009).

Os resultados alcançados pelos ajustes das equações podem ser considerados satisfatórios e similares aos encontrados por Schoeninger (2006), que ao utilizar as quatro bandas do sensor IKONOS para estimar biomassa e carbono em uma floresta ombrófila densa, encontrou valores de  $F = 11,92$ ,  $\bar{R}^2 = 0,50$ , e  $EPR = 44,44$  para a biomassa e  $F = 11,92$ ,  $\bar{R}^2 = 0,51$ , e  $EPR = 18,69$  para o carbono.

Nas Tabelas 16 e 17 são apresentados os valores do estoque de biomassa total (Biom3) e carbono total (Carb3) nas parcelas experimentais, estimados pelo inventário florestal e pelos modelos de regressão das Tabelas 14 e 15, bem como os respectivos resíduos. Os resultados obtidos estão graficamente representados nas Figuras 19 e 20.

A distribuição dos resíduos das estimativas da biomassa total, obtida pelos modelos 1 e 2 da Tabela 14, bem como do carbono total, obtidas pelos modelos 1 e 2 da Tabela 15, é apresentada nas Figuras 21 e 22, onde se observa uma ligeira superioridade nas referidas estimativas ao empregar o TCap1 como variável independente, mesmo que sua distribuição tenha sido heterogênea, porém sem tendenciosidade.

Segundo Watzlawick *et al.* (2009), é importante ressaltar que os resultados apresentados possuem validade para a área de estudo onde foi conduzida a pesquisa, em virtude da variação dos tipos de vegetação e estrutura, bem como da composição de espécies e das diferentes formas dos cálculos das variáveis biomassa e carbono.

Tabela 16 – Estimativas de biomassa total: inventário e modelos de regressão

Parcelas	Estoque de Biomassa Total - Estimativas (t/ha)			Resíduos			
	Inventário	Análise de Regressão		Banda4		TCap1	
		Banda 4	TCap1	(t/ha)	(%)	(t/ha)	(%)
1	254,49	237,78	252,72	-16,71	-6,57	-1,77	-0,70
2	152,60	169,08	169,28	16,48	10,80	16,68	10,93
3	137,24	196,24	201,30	59,00	42,99	64,06	46,68
4	112,56	129,14	122,86	16,58	14,73	10,30	9,15
5	161,85	264,94	271,40	103,09	63,69	109,55	67,69
6	214,21	244,17	205,23	29,96	13,99	-8,98	-4,19
7	418,49	274,95	286,90	-143,54	-34,30	-131,59	-31,44
8	194,29	228,19	187,57	33,90	17,45	-6,72	-3,46
9	176,97	193,04	174,97	16,07	9,08	-2,00	-1,13
10	230,21	225,00	230,14	-5,21	-2,26	-0,07	-0,03
11	225,00	125,94	147,41	-99,06	-44,03	-77,59	-34,48
12	206,36	207,42	221,74	1,06	0,51	15,38	7,45
13	179,46	175,47	165,54	-3,99	-2,22	-13,92	-7,76
14	149,23	172,28	170,56	23,05	15,45	21,33	14,29
15	303,60	272,92	308,93	-30,68	-10,11	5,33	1,76
				<b>Médias</b>	<b>5,95</b>		<b>4,98</b>




Figura 19 – Estoque de biomassa do inventário e modelos de regressão.

Tabela 17 – Estimativas de carbono total: inventário e modelos de regressão

Parcelas	Estoque de Carbono Total - Estimativas (t/ha)			Resíduos			
	Inventário	Análise de Regressão		Banda4		TCap1	
		Banda 4	TCap1	(t/ha)	(%)	(t/ha)	(%)
1	123,25	114,38	121,78	-8,87	-7,20	-1,47	-1,19
2	72,28	80,36	80,46	8,08	11,18	8,18	11,32
3	64,86	93,81	96,32	28,95	44,64	31,46	48,50
4	53,15	60,58	57,47	7,43	13,99	4,32	8,12
5	77,64	127,83	131,04	50,19	64,65	53,40	68,77
6	102,86	117,55	98,27	14,69	14,28	-4,60	-4,47
7	202,87	132,79	138,72	-70,08	-34,54	-64,16	-31,62
8	92,40	109,63	89,52	17,23	18,65	-2,88	-3,12
9	83,98	92,23	83,28	8,25	9,82	-0,70	-0,84
10	110,54	108,05	110,60	-2,49	-2,25	0,06	0,06
11	107,30	59,00	69,63	-48,30	-45,01	-37,67	-35,11
12	98,31	99,35	106,44	1,04	1,06	8,13	8,27
13	85,12	83,53	78,61	-1,59	-1,87	-6,51	-7,65
14	71,08	81,95	81,09	10,87	15,29	10,01	14,09
15	147,19	131,79	149,62	-15,40	-10,47	2,43	1,65
				<b>Médias</b>	<b>6,15</b>		<b>5,12</b>

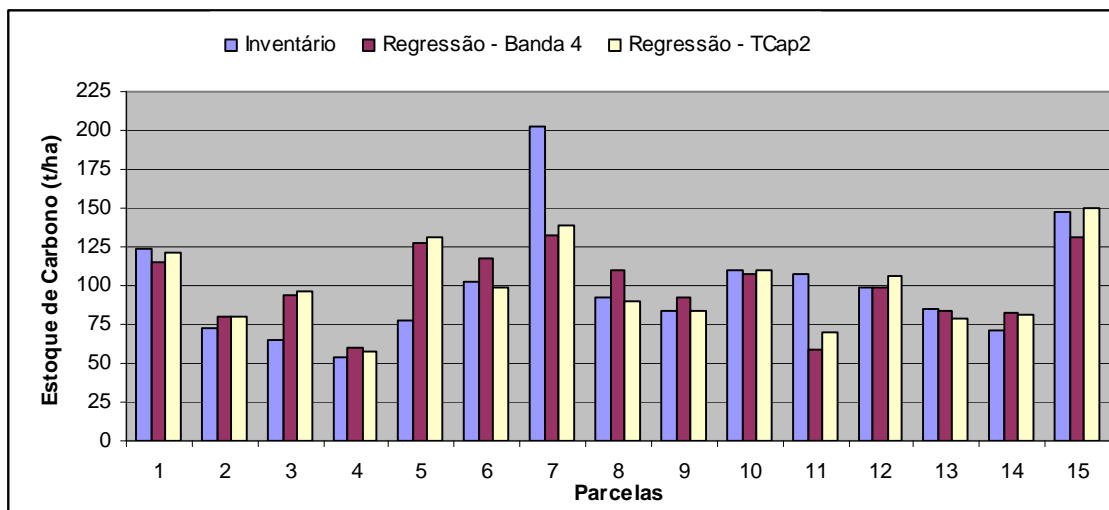


Figura 20 – Estoque de carbono do inventário e modelos de regressão.

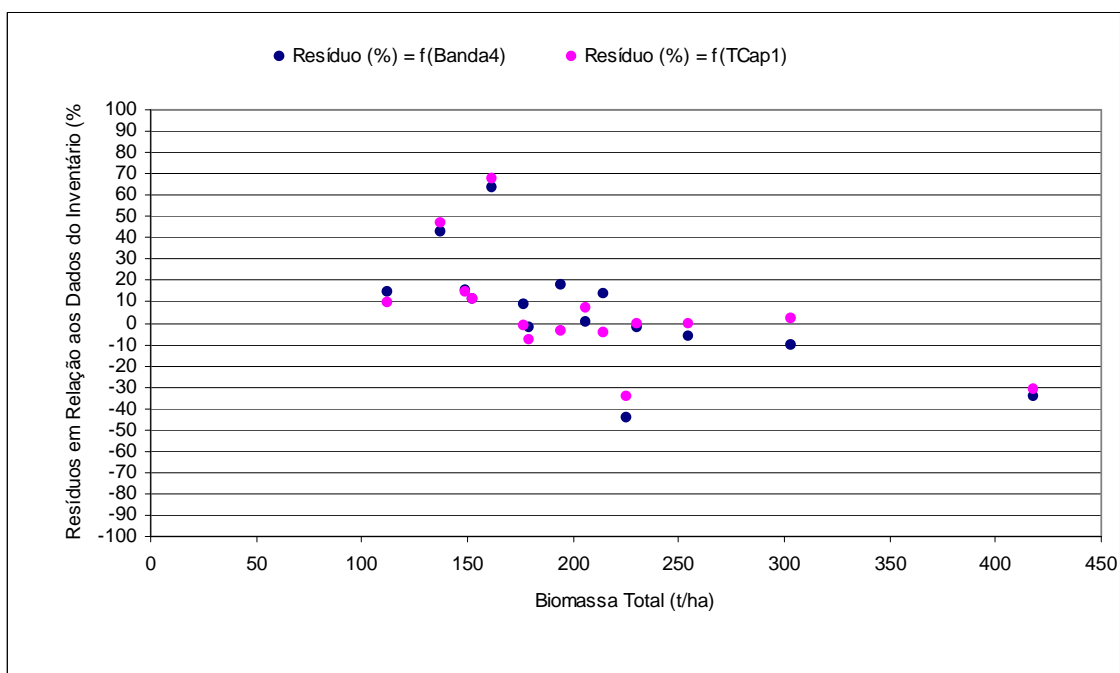


Figura 21 – Análises de resíduos das estimativas de biomassa total, obtidas a partir das variáveis Banda4 e TCap1.

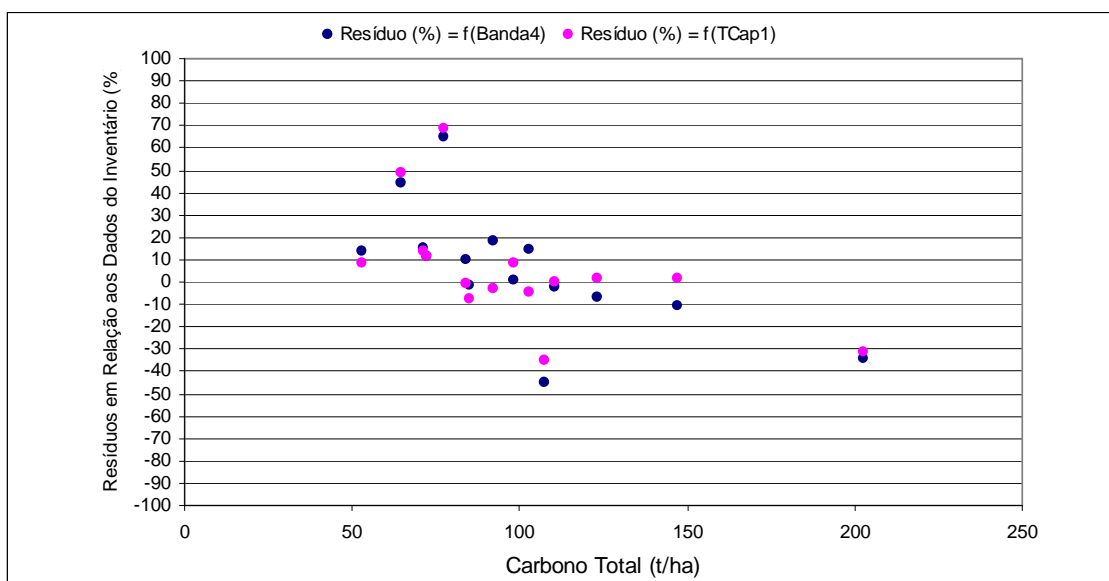


Figura 22 – Análises de resíduos das estimativas de carbono total, obtidas a partir das variáveis Banda4 e TCap1.



Analisando as Tabelas 16 e 17 e as Figuras 21 e 22 verifica-se que os resíduos das estimativas da biomassa total (Biom3), a partir da análise de regressão com a variável independente Banda4, variaram de 63,69% para mais a 44,03% para menos. Já com a variável TCap1 os resíduos das estimativas variaram de 67,69% para mais a 34,48% para menos. Para as estimativas de carbono total (Carb3) os resultados da regressão mostraram que os resíduos das estimativas variaram de 64,55% para mais a 45,01% para menos com a com a variável Banda4, e de 68,77% para mais a 35,11% para menos com a variável TCap1.

Schoeninger (2006) obteve equações de regressão linear múltipla com o uso das quatro bandas multiespectrais do satélite IKONOS II para estimar a biomassa e o carbono arbóreo, a partir de variáveis coletadas em 43 parcelas com dimensões de 90 x 30 m de uma floresta ombrófila densa, situada no estado de Santa Catarina. Os modelos obtidos foram testados em outras cinco parcelas escolhidas para validação e os resíduos variaram de 24,18% para menos a 18,42% para mais nas estimativas de biomassa arbórea. Já para o estoque de carbono, para a mesma área de estudo e com as mesmas variáveis, os resíduos variaram de 24,28% para menos a 17,81% para mais.

Schoeninger (2006) evidencia a homogeneidade da área inventariada utilizada na pesquisa, o que, aliada às diferenças entre a cobertura vegetal da floresta ombrófila densa e a da floresta estacional semidecidual, podem explicar melhores os resultados obtidos pelo autor.

## **5.2 Estimação da biomassa e do carbono por meio de RNA**

As mesmas três situações utilizadas para analisar o comportamento das variáveis explicativas na análise de regressão, foram também empregadas como entrada no treinamento da RNA e as melhores configurações obtidas são apresentadas na Tabela 18.

Os resultados obtidos para as estimativas das variáveis dependentes Biom1, Biom2, Biom3, Carb1, Carb2 e Carb3 com o uso da técnica de redes neurais artificiais para as situações analisadas são apresentados nas Tabelas 19 a 24 e nas Figuras 23 a 28.

Tabela 18 – Configurações das redes neurais artificiais testadas

Entradas	Número de Neurônios na Camada Oculta	Número de Neurônios na Saída	Função de Ativação da Camada Oculta	Função de Ativação da Camada de Saída
1	12	6	Tangente hiperbólica	Identidade
2	12	6	Tangente hiperbólica	Identidade
3	10	6	Tangente hiperbólica	Identidade

Tabela 19 – Estimativas de biomassa: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada

Parcelas	Estoque de Biomassa das Parcelas (t/ha) – RNA: Bandas						Resíduos (t/ha)		
	Inventário			Estimado			Biom1	Biom2	Biom3
	Biom1	Biom2	Biom3	Biom1	Biom2	Biom3			
1	243,99	243,99	254,49	242,56	243,49	255,44	-1,43	-0,50	0,95
2	140,09	140,09	152,60	139,19	139,51	150,65	-0,90	-0,58	-1,95
3	127,08	127,08	137,24	125,93	127,85	138,91	-1,15	0,77	1,67
4	97,77	101,20	112,56	97,81	101,69	112,93	0,04	0,49	0,37
5	135,85	145,88	161,85	137,01	146,66	161,84	1,16	0,78	-0,01
6	203,85	207,25	214,21	204,00	207,27	214,57	0,15	0,02	0,36
7	401,34	401,34	418,49	401,17	401,19	417,32	-0,17	-0,15	-1,17
8	186,71	186,71	194,29	186,65	186,66	193,96	-0,06	-0,05	-0,33
9	159,82	168,52	176,97	158,71	168,48	177,05	-1,11	-0,04	0,08
10	223,19	223,19	230,21	222,25	222,58	230,36	-0,94	-0,61	0,15
11	179,26	218,33	225,00	178,93	218,02	224,98	-0,33	-0,31	-0,02
12	158,75	197,88	206,36	161,10	197,78	205,10	2,35	-0,10	-1,26
13	136,32	171,97	179,46	137,36	171,05	179,64	1,04	-0,92	0,18
14	136,75	140,90	149,23	138,22	141,92	149,47	1,47	1,02	0,24
15	291,63	291,63	303,60	291,63	291,72	304,16	0,00	0,09	0,56

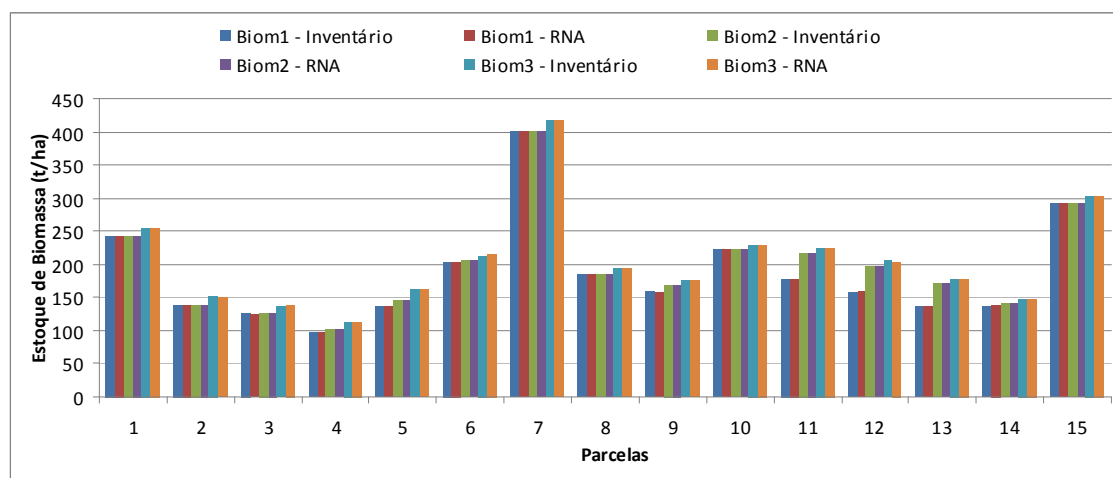


Figura 23 – Representação gráfica do estoque de biomassa: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada.

Tabela 20 – Estimativas de carbono: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada

Parcelas	Estoque de Carbono das Parcelas (t/ha) – RNA:						Resíduos (t/ha)		
	Bandas			Estimado					
	Inventário			Estimado			Carb1	Carb2	Carb3
	Carb1	Carb2	Carb3	Carb1	Carb2	Carb3	Carb1	Carb2	Carb3
1	118,15	118,15	123,25	116,96	117,69	123,40	-1,19	-0,46	0,15
2	66,20	66,20	72,28	65,93	66,17	71,48	-0,27	-0,03	-0,80
3	59,93	59,93	64,86	59,49	60,46	65,77	-0,44	0,53	0,91
4	45,99	47,63	53,15	45,73	47,84	53,18	-0,26	0,21	0,03
5	65,08	69,89	77,64	65,76	70,46	77,75	0,68	0,57	0,11
6	97,87	99,49	102,86	97,70	99,21	102,74	-0,17	-0,28	-0,12
7	194,55	194,55	202,87	194,47	194,66	202,30	-0,08	0,11	-0,57
8	88,72	88,72	92,40	88,95	88,88	92,55	0,23	0,16	0,15
9	75,73	79,88	83,98	75,50	80,19	84,38	-0,23	0,31	0,40
10	107,13	107,13	110,54	106,77	107,04	110,85	-0,36	-0,09	0,31
11	84,98	104,07	107,30	85,01	104,11	107,48	0,03	0,04	0,18
12	75,14	94,19	98,31	76,43	94,05	97,69	1,29	-0,14	-0,63
13	64,15	81,48	85,12	64,56	80,55	84,79	0,41	-0,93	-0,33
14	65,04	67,03	71,08	65,39	67,20	70,95	0,35	0,17	-0,13
15	141,38	141,38	147,19	141,38	141,24	147,41	0,00	-0,14	0,22

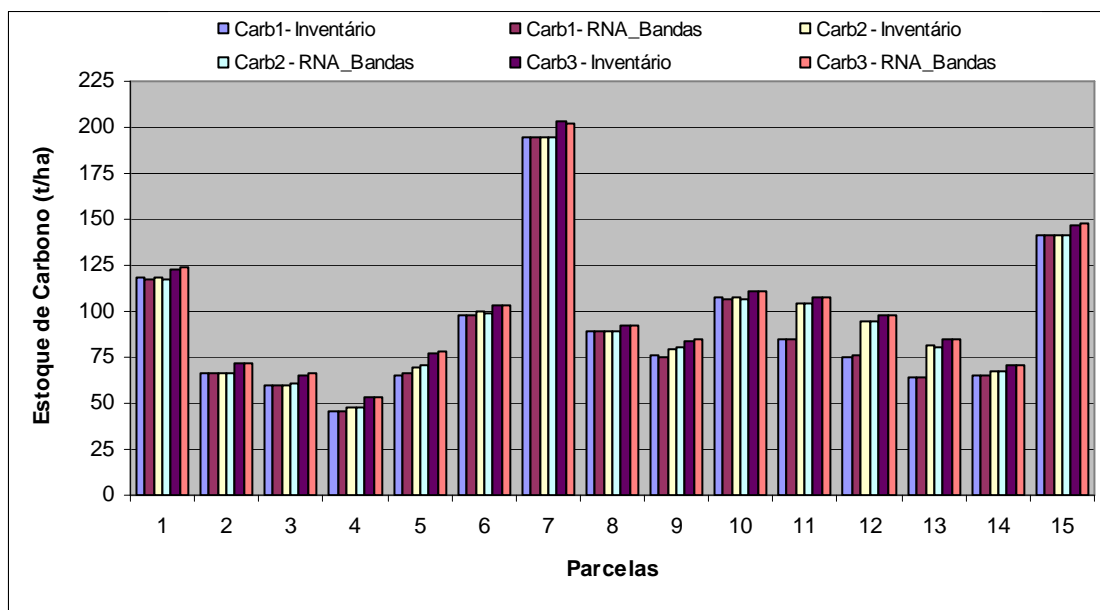


Figura 24 – Representação gráfica do estoque de carbono: inventário e estimado por RNA com as quatro bandas espectrais como variáveis de entrada.

Tabela 21 – Estimativas de biomassa: inventário e estimado por RNA com os índices de vegetação como variáveis de entrada

Parcelas	Estoque de Biomassa das Parcelas (t/ha) – RNA: Índices de Vegetação						Resíduos (t/ha)		
	Inventário			Estimado – Índices			Biom1	Biom2	Biom3
	Biom1	Biom2	Biom3	Biom1	Biom2	Biom3			
1	243,99	243,99	254,49	244,05	244,01	254,57	0,06	0,02	0,08
2	140,09	140,09	152,60	139,84	141,05	151,07	-0,25	0,96	-1,53
3	127,08	127,08	137,24	126,86	126,72	137,30	-0,22	-0,36	0,05
4	97,77	101,20	112,56	97,98	101,31	112,84	0,21	0,11	0,27
5	135,85	145,88	161,85	135,85	145,88	161,85	0,00	0,00	0,00
6	203,85	207,25	214,21	203,81	207,29	214,23	-0,04	0,04	0,02
7	401,34	401,34	418,49	401,34	401,34	418,49	0,00	0,00	0,00
8	186,71	186,71	194,29	186,75	186,68	194,27	0,04	-0,03	-0,02
9	159,82	168,52	176,97	159,60	168,15	176,83	-0,22	-0,37	-0,14
10	223,19	223,19	230,21	223,33	223,28	230,39	0,13	0,09	0,18
11	179,26	218,33	225,00	179,20	218,25	224,98	-0,06	-0,08	-0,02
12	158,75	197,88	206,36	158,63	197,86	206,17	-0,12	-0,02	-0,19
13	136,32	171,97	179,46	136,53	172,17	179,65	0,21	0,20	0,19
14	136,75	140,90	149,23	137,01	140,36	150,34	0,26	-0,54	1,11
15	291,63	291,63	303,60	291,62	291,63	303,59	-0,01	0,00	-0,01

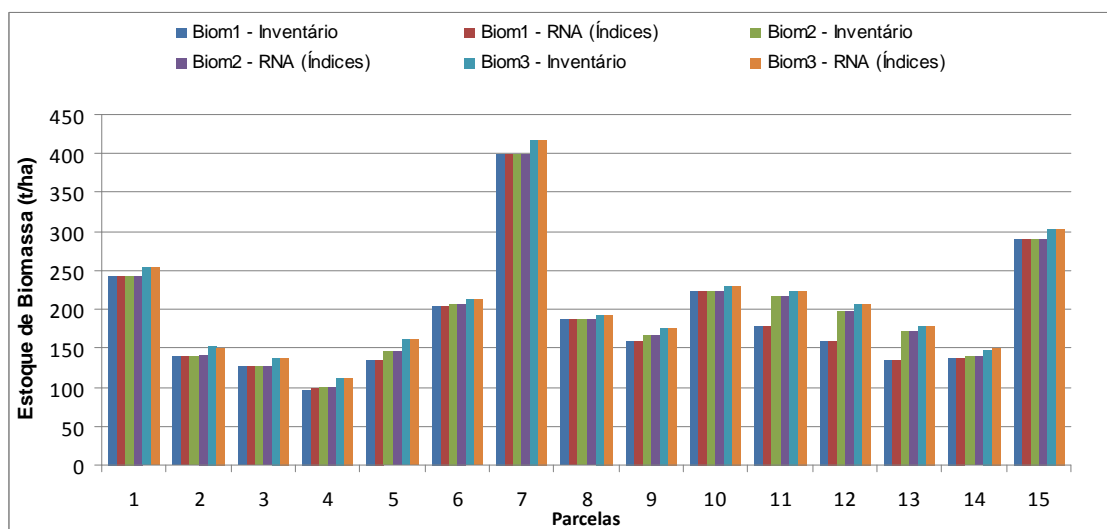


Figura 25 – Representação gráfica do estoque de biomassa: inventário e estimado por RNA com os índices de vegetação como variáveis de entrada.

Tabela 22 – Estimativas de carbono: inventário e estimado e por RNA com os índices de vegetação como variáveis de entrada

Parcelas	Estoque de Carbono das Parcelas (t/ha) – RNA: Índices de Vegetação						Resíduos (t/ha)		
	Inventário			Estimado - RNA			Carb1	Carb2	Carb3
	Carb1	Carb2	Carb3	Carb1	Carb2	Carb3			
1	118,15	118,15	123,25	118,12	118,11	123,24	-0,03	-0,04	-0,01
2	66,20	66,20	72,28	66,33	66,90	71,76	0,13	0,69	-0,52
3	59,93	59,93	64,86	60,03	59,92	65,06	0,09	-0,01	0,20
4	45,99	47,63	53,15	45,90	47,50	53,10	-0,09	-0,13	-0,05
5	65,08	69,89	77,64	65,08	69,89	77,64	0,00	0,00	0,00
6	97,87	99,49	102,86	97,89	99,49	102,83	0,02	0,00	-0,03
7	194,55	194,55	202,87	194,55	194,55	202,87	0,00	0,00	0,00
8	88,72	88,72	92,40	88,70	88,72	92,43	-0,02	0,00	0,03
9	75,73	79,88	83,98	75,82	79,96	84,18	0,09	0,08	0,20
10	107,13	107,13	110,54	107,07	107,04	110,50	-0,06	-0,09	-0,04
11	84,98	104,07	107,30	85,01	104,08	107,34	0,03	0,01	0,04
12	75,14	94,19	98,31	75,19	94,28	98,32	0,05	0,09	0,01
13	64,15	81,48	85,12	64,06	81,38	85,01	-0,09	-0,10	-0,11
14	65,04	67,03	71,08	64,91	66,52	71,37	-0,13	-0,51	0,29
15	141,38	141,38	147,19	141,38	141,38	147,19	0,00	0,00	0,00

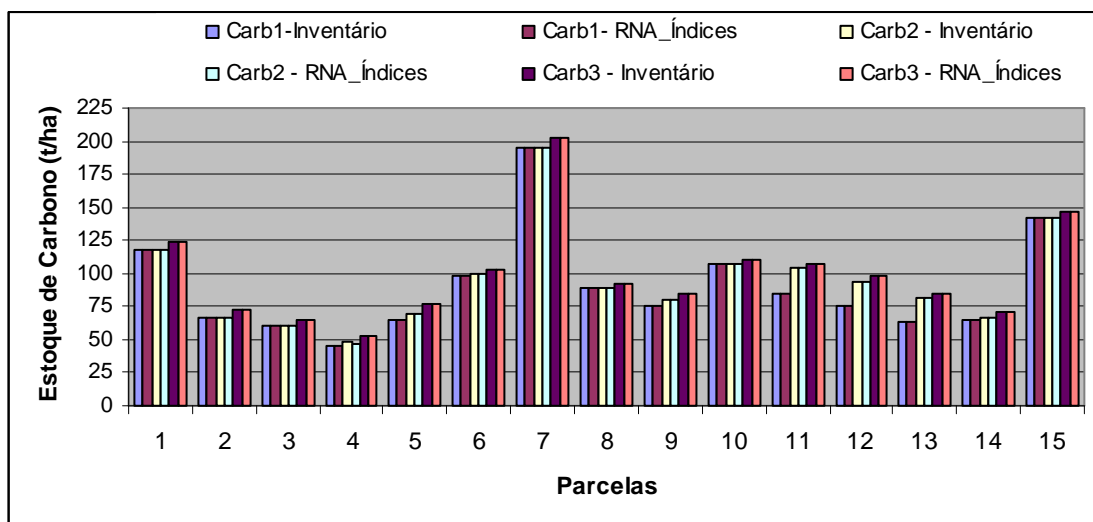


Figura 26 – Representação gráfica do estoque de carbono: inventário e estimado por RNA com os índices de vegetação como variáveis de entrada.

Tabela 23 – Estimativas de biomassa: inventário e estimado por RNA com as bandas espectrais e índices de vegetação como variáveis de entrada

Parcelas	Estoque de Biomassa das Parcelas (t/ha) – RNA: Bandas e Índices						Resíduos (t/ha)		
	Inventário			Estimado - Índices			Biom1	Biom2	Biom3
	Biom1	Biom2	Biom3	Biom1	Biom2	Biom3			
1	243,99	243,99	254,49	243,98	243,98	254,48	-0,01	-0,01	-0,01
2	140,09	140,09	152,60	140,10	140,09	152,62	0,01	0,00	0,02
3	127,08	127,08	137,24	127,04	127,09	137,25	-0,04	0,01	0,01
4	97,77	101,20	112,56	97,72	101,15	112,51	-0,05	-0,05	-0,05
5	135,85	145,88	161,85	135,86	145,88	161,86	0,01	0,00	0,01
6	203,85	207,25	214,21	203,83	207,25	214,21	-0,02	0,00	0,00
7	401,34	401,34	418,49	401,34	401,34	418,49	0,00	0,00	0,00
8	186,71	186,71	194,29	186,69	186,69	194,27	-0,02	-0,02	-0,02
9	159,82	168,52	176,97	159,85	168,52	176,96	0,03	0,00	-0,01
10	223,19	223,19	230,21	223,20	223,18	230,21	0,01	-0,01	0,00
11	179,26	218,33	225,00	179,24	218,32	224,98	-0,02	-0,01	-0,02
12	158,75	197,88	206,36	158,79	197,92	206,40	0,04	0,04	0,04
13	136,32	171,97	179,46	136,29	171,94	179,43	-0,03	-0,03	-0,03
14	136,75	140,90	149,23	136,84	140,98	149,29	0,09	0,08	0,06
15	291,63	291,63	303,60	291,63	291,63	303,60	0,00	0,00	0,00

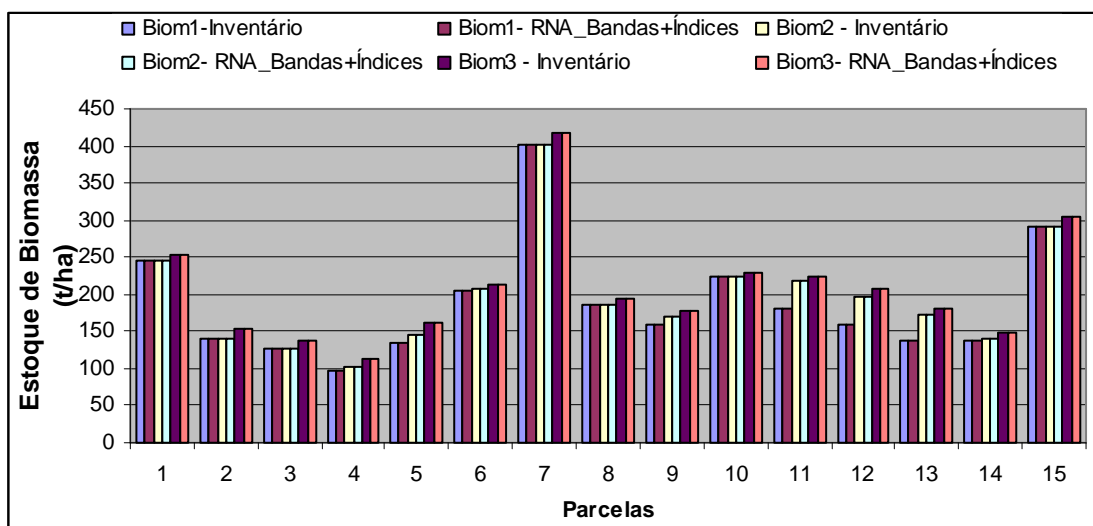


Figura 27 – Representação gráfica do estoque de biomassa: inventário e estimado por RNA com todas as variáveis de entrada consideradas no estudo.

Tabela 24 – Estimativas de carbono: inventário e estimado por RNA com as bandas espectrais e índices de vegetação como variáveis de entrada

Parcelas	Estoque de Carbono das Parcelas (t/ha) – RNA: Bandas e Índices						Resíduos (t/ha)		
	Inventário			Estimado - RNA			Carb1	Carb2	Carb3
	Carb1	Carb2	Carb3	Carb1	Carb2	Carb3			
1	118,15	118,15	123,25	118,16	118,15	123,26	0,00	0,00	0,01
2	66,20	66,20	72,28	66,20	66,20	72,27	-0,01	0,00	-0,01
3	59,93	59,93	64,86	59,95	59,92	64,86	0,02	-0,01	0,00
4	45,99	47,63	53,15	46,01	47,66	53,18	0,02	0,02	0,03
5	65,08	69,89	77,64	65,07	69,89	77,64	-0,01	0,00	0,00
6	97,87	99,49	102,86	97,88	99,49	102,86	0,01	0,00	0,00
7	194,55	194,55	202,87	194,55	194,55	202,87	0,00	0,00	0,00
8	88,72	88,72	92,40	88,73	88,73	92,41	0,01	0,01	0,01
9	75,73	79,88	83,98	75,72	79,88	83,98	-0,01	0,00	0,00
10	107,13	107,13	110,54	107,13	107,14	110,54	0,00	0,01	0,00
11	84,98	104,07	107,30	84,99	104,07	107,31	0,01	0,00	0,01
12	75,14	94,19	98,31	75,12	94,17	98,29	-0,02	-0,02	-0,02
13	64,15	81,48	85,12	64,17	81,50	85,14	0,02	0,02	0,02
14	65,04	67,03	71,08	65,00	67,00	71,05	-0,04	-0,03	-0,03
15	141,38	141,38	147,19	141,38	141,38	147,19	0,00	0,00	0,00

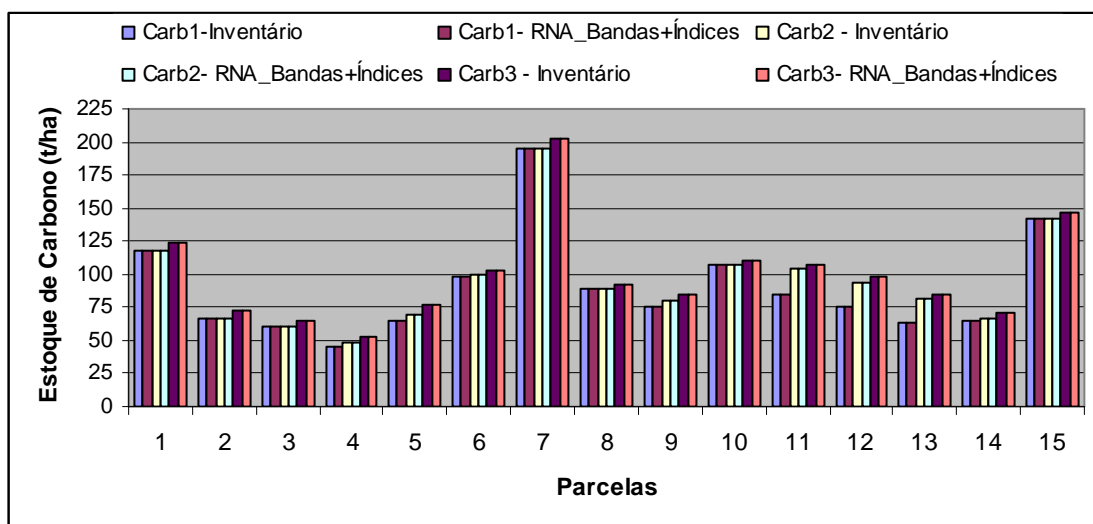


Figura 28 – Representação gráfica do estoque de carbono: inventário e estimado por RNA com todas variáveis de entrada consideradas no estudo.

Análises das informações constantes das Tabelas 19 e 20 e Figuras 23 e 24 mostram que os estoques de biomassa total (Biom3) e carbono total (Carb3) foram estimados com um alto grau de exatidão pelas redes neurais artificiais, com mínimas variações em relação aos valores estimados pelo inventário florestal, quando apenas foram utilizadas as quatro bandas do sensor IKONOS. Resultados similares foram obtidos quando se considerou os estoques parciais de biomassa (Biom1 e Biom2) e carbono (Carb1 e Carb2).

Quando se utilizou apenas os índices de vegetação, os resultados apresentados nas Tabelas 21 e 22 e Figuras 25 e 26, para os estoques de biomassa e carbono estimados pelas redes neurais, mostraram-se muito próximos aos encontrados quando foram utilizadas apenas as quatro bandas.

Similarmente aos resultados apresentados nas Tabelas 19 e 20, os resultados apresentados nas Tabelas 23 e 24 e Figuras 27 e 28, quando se utilizou todas as variáveis para alimentar a rede, também foram bastante eficientes e muito próximos dos dois métodos anteriores. Desta forma, não se justifica o uso dos índices de vegetação nesta metodologia proposta, pelo menos para a área em que o estudo foi conduzido.

As Tabelas 25 e 26 apresentam os resíduos percentuais para as três situações utilizadas como variáveis de entrada, para as estimativas de biomassa e carbono nas 15 parcelas experimentais por meio das redes neurais artificiais.

### **5.3 Comparação dos estoques de biomassa e carbono estimados pela análise de regressão e redes neurais**

Na Figura 29 apresenta-se, graficamente, o estoque de biomassa total (Biom3) observado, o estimado por meio de regressão utilizando separadamente a banda 4 e o índice TCap1 como variáveis de entrada, bem como o estimado por meio de RNA utilizando separadamente apenas as bandas, todos os índices e todas as bandas e os índices.

Nas Figuras 30 e 31 são apresentados, graficamente, os resíduos das estimativas de biomassa total (Biom3), em função dos resultados obtidos pela análise de regressão e pelas redes neurais artificiais.



Tabela 25 – Resíduos das estimativas da biomassa total por RNA

Biomassa Total por Redes Neurais Artificiais							
Parcelas	Inventário	Bandas (1 a 4)	Índices	Bandas e índices	Resíduos (%)		
					f (Bandas)	f (Índices)	f (Bandas e Índices)
1	254,490	255,441	254,573	254,480	0,374	0,033	-0,004
2	152,600	150,654	151,069	152,616	-1,275	-1,003	0,010
3	137,240	138,908	137,295	137,246	1,215	0,040	0,005
4	112,560	112,931	112,835	112,510	0,330	0,245	-0,045
5	161,850	161,839	161,850	161,856	-0,007	0,000	0,004
6	214,210	214,573	214,228	214,208	0,170	0,008	-0,001
7	418,490	417,320	418,490	418,490	-0,280	0,000	0,000
8	194,290	193,964	194,266	194,271	-0,168	-0,012	-0,010
9	176,970	177,051	176,831	176,963	0,046	-0,078	-0,004
10	230,210	230,362	230,394	230,213	0,066	0,080	0,001
11	225,000	224,978	224,980	224,984	-0,010	-0,009	-0,007
12	206,360	205,096	206,168	206,397	-0,613	-0,093	0,018
13	179,460	179,637	179,649	179,434	0,099	0,105	-0,015
14	149,230	149,465	150,337	149,294	0,157	0,742	0,043
15	303,600	304,156	303,594	303,600	0,183	-0,002	0,000

Tabela 26 – Resíduos das estimativas de carbono por RNA

Carbono Total por Redes Neurais Artificiais							
Parcelas	Inventário	Bandas (1 a 4)	Índices	Bandas e índices	Resíduos (%)		
					f (Bandas)	f (Índices)	f (Bandas e Índices)
123,250	123,401	123,239	123,256	123,250	0,123	-0,009	0,005
72,280	71,476	71,764	72,269	72,280	-1,112	-0,713	-0,015
64,860	65,772	65,057	64,861	64,860	1,406	0,304	0,001
53,150	53,179	53,096	53,177	53,150	0,055	-0,102	0,051
77,640	77,745	77,638	77,637	77,640	0,135	-0,003	-0,004
102,860	102,741	102,833	102,862	102,860	-0,115	-0,027	0,002
202,870	202,303	202,871	202,870	202,870	-0,280	0,000	0,000
92,400	92,553	92,427	92,411	92,400	0,165	0,030	0,012
83,980	84,381	84,176	83,983	83,980	0,478	0,233	0,003
110,540	110,853	110,496	110,537	110,540	0,283	-0,040	-0,002
107,300	107,480	107,344	107,310	107,300	0,167	0,041	0,009
98,310	97,685	98,318	98,288	98,310	-0,636	0,008	-0,023
85,120	84,794	85,014	85,135	85,120	-0,383	-0,125	0,017
71,080	70,948	71,367	71,045	71,080	-0,186	0,403	-0,050
147,190	147,406	147,192	147,190	147,190	0,147	0,001	0,000

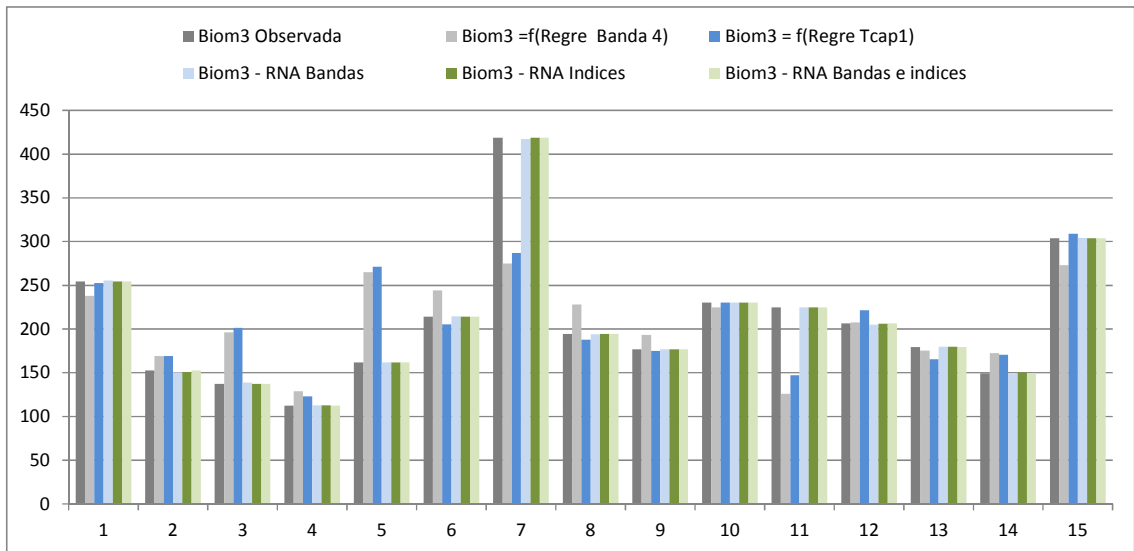


Figura 29 – Biomassa total observada e biomassa total estimada por regressão e por redes neurais artificiais.

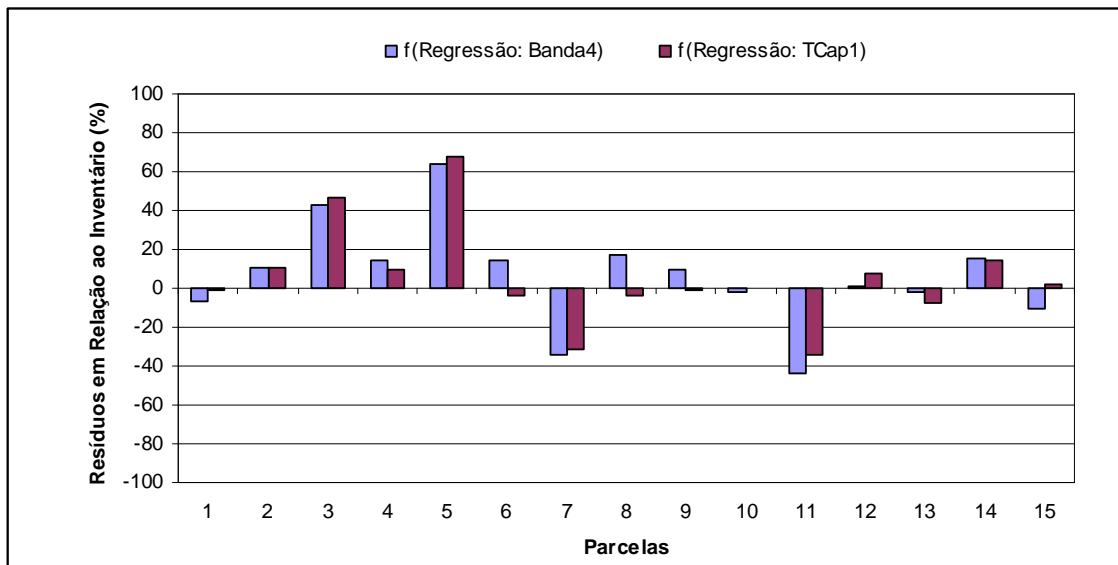


Figura 30 – Resíduos percentuais das estimativas da biomassa total obtidos por meio de regressão.

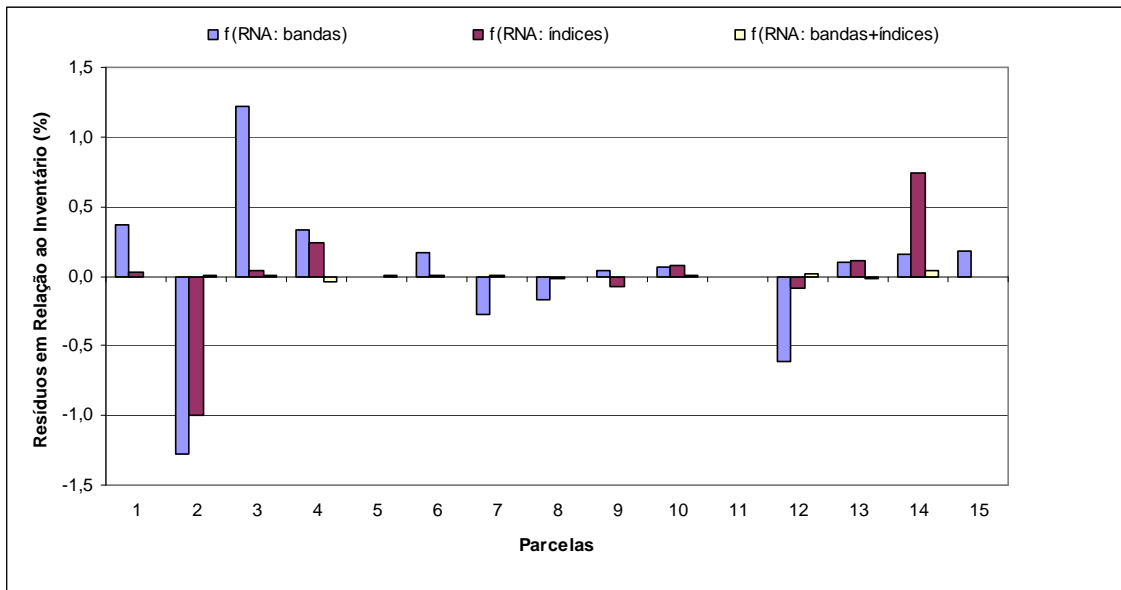


Figura 31 – Resíduos percentuais das estimativas de biomassa total obtidos por meio de RNA.

Pelos gráficos apresentados, verifica-se que os resíduos das estimativas de biomassa obtidos com o emprego da análise de regressão (Figura 32) chegam a ultrapassar 60%, enquanto os resíduos obtidos a partir das redes neurais (Figura 33) encontram-se na faixa de  $\pm 1,5\%$ . Os resultados obtidos para as estimativas de carbono total são similares aos da biomassa.

Com base nas informações apresentadas nas Figuras 29, 30 e 31, verifica-se que, para o caso da área estudada na pesquisa e empregando a técnica de redes neurais artificiais, apenas as bandas 1, 2, 3 e 4 podem ser utilizadas como variáveis de entrada, uma vez que se mostraram eficientes para estimar a biomassa total (Biom3), embora os resíduos tenham sido ainda menores quando foram utilizados as bandas e os índices. O mesmo raciocínio pode ser empregado no caso das estimativas de carbono total, em virtude da alta correlação entre estas duas variáveis.

Schoeninger *et al.* (2008a) usaram redes neurais artificiais para estimar biomassa e carbono, em uma floresta ombrófila densa, estado de Santa Catarina, a partir das quatro bandas do sensor IKONOS. A arquitetura da rede que apresentou o melhor desempenho nas estimativas, tanto de biomassa quanto do carbono (12 neurônios na camada de entrada e quatro na camada de saída para o limiar de 0,01), foi testada em cinco parcelas de verificação. Os resultados mostraram que as diferenças entre a biomassa estimada pelo inventário

e a estimada pela rede apresentaram erros que variaram de 1,05 a 8,18% e um erro percentual médio de 3,73%. No caso do estoque de carbono, os erros percentuais nas parcelas de verificação variaram de -0,78 a 8,17%, sendo o erro médio de 3,59%.

## 6 CONCLUSÕES

Após a análise dos resultados obtidos na presente pesquisa, realizada em um fragmento de floresta estacional semidecidual, foram encontradas as seguintes conclusões:

- no geral, a técnica da análise de regressão não foi eficiente para estimar estoques de biomassa e carbono arbóreo armazenado, talvez em virtude do baixo número de observações avaliadas;

- os melhores resultados pela técnica da análise de regressão foram obtidos com a utilização da primeira transformação Tasseled Cap e da reflectância na banda do infravermelho próximo, mesmo, assim, com moderada correlação;

- os índices de vegetação mais utilizados em pesquisas relacionadas com o monitoramento e mapeamento da cobertura vegetal (como NDVI, RVI, TVI e o SAVI) não foram efetivos nas estimativas dos estoques de biomassa e carbono arbóreo por meio da análise de regressão; talvez em virtude da imagem ter sido obtida em uma época em que a maioria das espécies estimadas encontrava-se desprovida de folhas, especialmente as leguminosas; e

- a técnica das redes neurais artificiais apresentou um excelente desempenho nas estimativas dos estoques de biomassa e carbono arbóreo armazenado.

## 7 REFERÊNCIAS BIBLIOGRÁFICAS

AHAMED, T.; TIAN, L.; ZHANG, Y.; TING, K. C. A review of remote sensing methods for biomass feedstock production. *Biomass and Bioenergy*, v. 35, p. 455-2469, 2011.

ALMEIDA, A. C.; BARROS, P. L. C.; MONTEIRO, J. H. A.; ROCHA, B. R. P. *Estimativa de biomassa arbórea: uma comparação entre métodos estatísticos e redes neurais*. Belém-PA, AGRENER, 2006. 6 p.

AMARO, M. A. *Quantificação do estoque volumétrico, de biomassa e de carbono em uma floresta estacional semidecidual no município de Viçosa-MG*. 2010. 168 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa-MG, 2010.

ANTUNES, M. A. H.; FREIRE, R. M.; BOTELHO, A. S.; TONIOLLI, L. H. Correções atmosféricas de imagens de satélites utilizando o modelo 6S. In: CONGRESSO BRASILEIRO DE CARTOGRAFIA, 21., 2003. Belo Horizonte. *Anais...* Rio de Janeiro: Sociedade Brasileira de Cartografia, 2003. 6 p.

ARAGÃO, L. E. O. C.; SHIMABUKURO, Y. E. *Perspectivas para o estudo da biogeoquímica do carbono em macro-escala integrando diferentes técnicas: modelagem ecológica, sensoriamento remoto e SIG*. São José dos Campos: INPE, 2004. 97 p. (INPE-10731-RPQ/757).

BARET, F.; JACQUEMOUD, S.; HANOCQ, J. F. About the soil line concept in remote sensing. *Advances in Space Research*, v. 13, n. 5, p. 281-284, 1993.

BLACKARD, J. A.; DEAN, J. D. Comparative accuracies of artificial neural networks and discriminant analysis in predicting forest cover types from cartographic variables. *Computers and Electronics in Agriculture*, v. 24, p. 131-151, 1999.

BOTELHO, M. F. *Aplicação de redes neurais artificiais na classificação de imagens de alta resolução espacial e dados do laser scanner, usando uma abordagem orientada a regiões*. 2004. 103 f. Dissertação (Mestrado em Ciências Geodésicas) – Universidade Federal do Paraná, Curitiba, 2004.

BRASIL. Decreto nº 89.817, de 20 de junho de 1984. Estabelece as instruções reguladoras das normas técnicas da cartografia nacional. *Diário Oficial da República Federativa do Brasil*, Brasília, n. 120, p. 8884-8886, 22 jun.1984.

CAMPOS, J. C. C.; LEITE, H. G. *Mensuração florestal: perguntas e respostas*. 3. ed. Viçosa, MG: Universidade Federal de Viçosa, 2009. 543 p.

CARVALHO, F. M. V.; FERREIRA, L. G.; LOBO, F. C.; DINIZ FILHO, J. A. F.; BINI, L. M. Padrões de auto-correlação espacial de índices de vegetação MODIS no bioma cerrado. *Revista Árvore*, v. 32 n. 2, p. 279-290, mar./abr. 2008.

CENAMO, M. C.; CARRERO, G. C. Reducing emissions from deforestation and forest degradation in Apuí, Southern Amazonas: Challenges and caveats related to land tenure and governance in the Brazilian Amazon. *Journal of Sustainable Forestry*, v. 31, n. 4-5, p. 445-468, 2012.

CHAKRABORTY, G.; CHAKRABORTY, B. A novel normalization technique for unsupervised learning in ANN. *IEEE Transactions on Neural Network*, v. 11, n. 1, p. 253-257, 2000.

CHEN, S, C.; HERZ, R. Estudos quantitativos e calibração radiométrica de dados digitais do Landsat-5. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 8., 1996, Salvador. *Anais...* São José dos Campos: INPE, 1996. p. 499-506.

CHEN, X.; VIERLING, L.; ROWELL, E. DeFELICE, T. Using lidar and effective LAI data to evaluate IKONOS and Landsat 7 ETM+ vegetation cover estimates in a ponderosa pine forest. *Remote Sensing of Environment*, v. 91, p. 14-26, 2004.

CHUVIECO, E.; HUETE, A. *Fundamentals of satellite remote sensing*. Boca Raton, FL: CRC Press, Taylor Francis Group, 2010. 436 p.

CLEVERS, J. G. P. W. A simplified approach or yield prediction of sugar beet based on optical remote sensing data. *Remote Sensing of Environment*, v. 61, p. 221-228, 1997.

CLEVERS, J. G. P. W. The derivation of a simplified reflectance model for the estimation of leaf area index. *Remote Sensing of Environment*, v. 35, p. 53-70, 1988.

COLOMBO, R.; BELLINGERI, D.; FASOLINI, D.; MARINO, C.M. Retrieval of leaf area index in different vegetation types using high resolution satellite data. *Remote Sensing of Environment*, v. 86, p. 120-131, 2003.

CROSTA, A. P. *Processamento digital de imagens de sensoriamento remoto*. Campinas: Instituto de Geociências/UNICAMP, 1999, 164 p.

DE PAULA, M. D.; PEREIRA FILHO, W. Estimativa de carbono em um fragmento de floresta madura na Mata Atlântica Nordeste com o uso de índices espectrais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009. Natal. *Anais...* São José dos Campos: INPE, 2009. p. 2881-2888.

DRAPPER, N.; SMITH, H. *Applied regression analysis*. 2. ed., New York: Wiley, 1983.

EL-MEZOUAR, M. C.; TALEB, N.; KPALMA, K.; RONSIN, J. A high-resolution index for vegetation extraction in IKONOS image. *Remote Sensing*, Toulouse, France, 2010. 11 p.

ELVIDGE, C. D.; CHEN, Z. Comparison of broad-band and narrow-band red and near-infrared vegetation indices. *Remote Sensing of Environment*, v. 54, p. 38-48, 1995.

EPIPHANIO, J. C. N.; GLERIANI, J. M.; FORMAGGIO, A. R.; RUDORFF, B. F. T. Índices de vegetação no sensoriamento remoto da cultura do feijão. *Pesquisa Agropecuária Brasileira*, Brasília, v. 31, n. 6, p. 445-454, 1996.

FLEMING, D. *Conversion from DN to planetary reflectance*. Version 3.0. Revisão dos documentos SE-REF-016, N/C e SE-REF-016, Rev. A da Space Imaging, 2003. 3 p.

FLORES, E. J. M. *Potencial produtivo e alternativas de manejo sustentável de um fragmento de Mata Atlântica secundária, município de Viçosa, Minas Gerais*. 1993. 165 f. Dissertação (Mestrado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 1993.

FOODY, G. M.; CUTLER, M. E.; McMORROW, J.; PELZ, D.; TANGKI, H.; BOYD, D. S.; DOUGLAS, I. Mapping the biomass of Bornean tropical rain forest from remotely sensed data. *Global Ecology & Biogeography*, v. 10, p. 379-387, 20, 2001.

GLERIANI, J. M.; ANTUNES, M. A. H.; EPIPHANIO, J. C. N. Coeficientes da Transformação espectral Tasseled Cap para uma cena com predomínio de latossolo roxo. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 11., 2003. Belo Horizonte, *Anais...* São José dos Campos: INPE, 2003. p. 101-107.

GRIPP JR. *Ortorretificação de imagens de alta resolução para aplicação em cadastro técnico rural e mapeamento de áreas de preservação permanente e reservas legais*. 2009. 151 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2009.

HABOUDANI, D.; MILLER, J. R.; PATTEY, E.; ZARCO-TEJADA, P. J.; STRACHAN, I. B. Hyperspectral vegetation indices and novel algorithms for predicting green LAI of crop canopies: Modeling and validation in the context of precision agriculture. *Remote Sensing Environment*, v. 90, p. 337-352, 2004.



HADJIMITSIS, D. G.; PAPADAVID, G.; AGAPIOU, A.; THEMISTOCLEOUS, K., HADJIMITSIS, M. G.; RETALIS, A.; MICHAELIDES, S.; CHRYSOULAKIS, N.; TOULIOS, L.; CLAYTON, C. R. I. Atmospheric correction for satellite remotely sensed data intended for agricultural applications: impact on vegetation indices. *Natural Hazards and Earth System Sciences*, v. 10, p. 89-95, 2010.

HÄME, T.; SALLI, K. A.; 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, n. 15, p. 3211-3243, 1997.

HAYKIN, S. *Redes neurais – Princípios e prática*. 2. ed., Porto Alegre: Bookman Companhia Editora, 2001. 900 p.

HIGUCHI, N.; CARVALHO JÚNIOR, J. A. Fitomassa e conteúdo de carbono de espécies arbóreas da Amazônia. In: SEMINÁRIO EMISSÃO X SEQÜESTRO DE CO<sub>2</sub> – UMA NOVA OPORTUNIDADE DE NEGÓCIOS PARA O BRASIL. Rio de Janeiro, 1994. *Anais...* Rio de Janeiro: CVRD, 1994. p. 125-145.

HOFFER, R. M. Biological and physical considerations in applying computer-aided analysis techniques to remote sensor data. In: SWAIN, P. H.; DAVIS, S. M. (Org.). *Remote sensing: The quantitative approach*. Cap. 5, New York: McGraw-Hill College, 1978. p. 227-289.

HOLBEN, B. N. Characteristics of maximum-value composite images from temporal AVHRR data. *International Journal of Remote Sensing*, v. 7, n. 11, p. 1417-1435, 1986.

HORNE, J. H. A tasseled cap transformation for IKONOS image. In: ASPRS – ANNUAL CONFERENCE PROCEEDINGS, Anchorage, Alasca, 2003. 9 p.

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

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.

JACKSON, R. D.; HUETE, A. R. Interpreting vegetation indices. *Preventive Veterinary Medicine*, v. 11, p. 185-200, 1991.

JENSEN, J. R. *Introductory digital image processing – A remote sensing perspective*. Englewood Cliffs, New Jersey, USA: Prentice-Hall, 1996. 379 p.

JENSEN, J. R. *Sensoriamento remoto do ambiente: uma perspectiva em recursos terrestres*. Tradução de José Carlos Epiphânio, Antonio Roberto Formaggio, Athos Ribeiro dos Santos, Bernardo Friedrich Theodor Rudorff, Claudia Maria de Almeida e Lênio Soares Galvão. São José dos Campos, SP: Parêntese, 2009. 598 p.

JENSEN, J. R.; QIU, F.; JI, M. Predictive modeling of coniferous forest age using statistic and artificial neural network approaches applied to remote sensor data. *International Journal of Remote Sensing*, v. 20, n. 14, p. 2805-2822, 1999.

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

KARDOULAS, N. G.; BIRD, A. C.; LAWAN, A.I. Geometric correction of SPOT and Landsat imagery: A comparison of map and GPS-derived control points. *Photogrammetric Engineering and Remote Sensing*, v. 62, n. 10, p. 1173-1177, 1996.

KAUFMAN, Y. J.; TANRÉ, D. Atmospherically Resistant Vegetation Index (ARVI) for EOS-MODIS. *IEEE Transactions on Geoscience and Remote Sensing*, v. 30, n. 2, p.261-270, 1992.

KAUFMAN, Y. J.; TANRÉ, D. Strategy for direct and indirect methods for correcting the aerosol effect on remote sensing: From AVHRR to EOS-MODIS. *Remote Sensing of Environment*, v. 55, p. 65-79, 1996.

KAUTH, R. J.; THOMAS, G. S. The tasseled cap – A graphic description of the spectral-temporal development of agricultural crops as seen by Landsat. In: *LARS: SYMPOSIUM ON MACHINE PROCESSING OF REMOTELY SENSED DATA*. West Lafayette (IN): Purdue University, 1976. p. 4B-41-4B-51.

KLOBUCAR, D.; PERNAR, R.; LONCARIC, S.; SUBASIC, M. Artificial neural networks in the assessment of stand parameters from an IKONOS satellite image. *Croatian Journal of Forest Engineering*, v. 29, n. 2, p. 201-211, 2008.

KNIPLING, E. B. Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*, v. 1, p. 155-159, 1970.

LEITE, H. G.; OLIVEIRA, F. H. T. Statistical procedure to test the identity of analytical methods. *Communications in Soil Science and Plant Analysis*, v. 33, 2002.

LIU, W. T. H. *Aplicações de sensoriamento remoto*. Campo Grande: Editora da UNINDERP, 2007. 881p.

LU, D. The potential and challenge of remote sensing-based biomass estimation. *International Journal of Remote Sensing*, v. 27, n. 7, p. 1297-1328, 2006.

LU, D.; BATISTELLA, M.; MORAN, E. Satellite estimation aboveground biomass and impacts of forest stand structure. *Photogrammetric Engineering and Remote Sensing*, v. 8, p. 967-974, 2005.

LU, D.; CHEN, Q.; WANG, G.; MORAN, E.; BATISTELLA, M.; ZHANG, M.; LAURIN, G. V.; SAAH, D. Aboveground forest biomass estimation with Landsat and LiDAR data and uncertainty analysis of the estimates. *International Journal of Forestry Research*, v. 12, article ID 436537, 2012. 16 p.

MACIEL, M. N. M., BASTOS, P. C. O. WATRIN, O. S. Estimativa de parâmetros estruturais de uma floresta primária no município de Paragominas (PA), através de dados orbitais. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 13., 2007, Florianópolis. *Anais...* São José dos Campos: INPE, 2007. p. 1725-1732.

MARTINELLI, L. A.; CAMARGO, P. B. O monitoramento do carbono em áreas florestadas. *Série Técnica IPEF*, Piracicaba, v. 10, n. 29, p. 6-10, 1996.

MATHER, P. M. *Classification methods for remotely sensed data*. 2. ed., Boca Raton, FL: CRC Press – Taylor & Francis Group, 2009.

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. 128 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal do Paraná, Curitiba, 2006.

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, jan./mar, 2008.

MCT – MINISTÉRIO DA CIÊNCIA E TECNOLOGIA. *Inventário de emissões e remoções antrópicas de gases de efeito estufa não controlados pelo protocolo de Montreal – Parte II*. Brasília: MCT, 2004. 86 p.

MCT – MINISTÉRIO DA CIÊNCIA E TECNOLOGIA. *Inventário de emissões e remoções antrópicas de gases de efeito estufa – Informações gerais e valores preliminares*. Brasília: MCT, 2009. 16 p.

MORAIS, E. C. *Reconhecimento de padrões e redes neurais artificiais em predição de estruturas secundárias de proteínas*. 2010. 135 f. Tese (Doutorado em Engenharia de Sistemas e Computação) – COPPE – UFRJ, Rio de Janeiro, 2010.

- MOREIRA, M. A. *Fundamentos de sensoriamento remoto e metodologias de aplicação*. 3. ed. Viçosa: Editora UFV, 2007. 320 p.
- MYNENI, R. B.; HALL, F. G.; SELLERS, P. J.; MARSHAK, A. L. The interpretation of Spectral Vegetation Indexes. *IEEE Transactions on Geoscience and Remote Sensing*, v. 33, n. 2, p. 481-486, 1995b.
- MYNENI, R. B.; MAGGION, S. IAQUINTA, J.; PRIVETTE, J.L.; GOBRON, N.; PINTY, B.; KIMES, D. S.; VERSTRAETE, M. M.; WILLIAMS, D. L. Optical remote sensing of vegetation: Modeling, caveats, and algorithms. *Remote Sensing of Environment*, v. 51, n.1, p. 169-188, 1995a.
- NICHOL, J. E.; SARKER, L. R. Improve biomass estimation using the texture parameters of two high-resolution optical sensors. *IEEE Transactions on Geoscience and Remote Sensing*, v. 49, n. 3, p. 930-948, 2011.
- OLIVEIRA, L. G. L.; PONZONI, F. J.; MORAES, E. C. Conversão de dados radiométricos orbitais por diferentes metodologias de caracterização atmosférica. *Revista Brasileira de Geofísica*, v. 27, n. 1, 2009. Disponível em: <[http://www.scielo.br/scielo.php?pid=S0102-61X2009000100010&script=sci\\_arttext](http://www.scielo.br/scielo.php?pid=S0102-61X2009000100010&script=sci_arttext)>. Acesso em: 3 out. 2011.
- PADRÓN, E.; NAVARRO-CERRILLO, R. M. Aboveground biomass in *Prosopis pallida* (Humb. And Bonpl. Ex Willd.) H.B.K. ecosystems using Landsat 7 ETM+ images. *Revista Chilena de História Natural*, v. 3, p. 43-53, 2007.
- PCI GEOMATICS. *Geomatica, orthoengine user guide version 10.1*. Ontário, Canadá: Richmond Hill, 2007. 174 p.
- PÉLLICO NETTO, S.; KAUANO, E. E.; CORAIOLA, M.; WEBER, S. H.; ERDELYI, S. Estimativa do potencial de neutralização de dióxido de carbono no programa VIVAT NEUTRACARBO em Tijucas do Sul, Agudos do Sul e São José dos Pinhais (PR). *Rev. Acad., Ciênc. Agrárias e Ambiental*, Curitiba, v. 6, n. 2, p. 293-306, abr./jun. 2008.
- PINHEIRO, E. S., DURIGAN, G., ADAMI, M. Imagens Landsat e Quickbird são capazes de gerar estimativas precisas de biomassa aérea de cerrado? In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 14., 2009, Natal. *Anais...* São José dos Campos: INPE, 2009. p. 2913-2920
- PINTY, B.; VERSTRAETE, M. M. GEMI: a non-linear index to monitor global vegetation from satellites. *Vegetatio*, v. 1. n. 101, p. 15-20, 1992.
- PONZONI, F. J.; SHIMABUKURO, Y. E. *Sensoriamento remoto da vegetação*. São José dos Campos: Parêntese, 2007. 127 p.

QI, J.; CHEHBOUNI, A.; HUETE, A. R.; KERR, Y. H.; SOROOSHIAN, S. A modified soil adjusted vegetation index. **Remote Sensing of Environment**, v. 48, p. 199-126, 1994.

REZENDE, S. B. *Estudo de crono-toposequência em Viçosa-MG*. 1971. 71 f. Dissertação (Mestrado em Solos e Nutrição de Plantas) – Universidade Federal de Viçosa, Viçosa, 1971.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information: *Photogrammetric engineering and remote sensing*, New York, USA: Elsevier Science Publishing Co., v. 43, n.12, p.1541-1552, 1977.

RICHARDSON, A. J.; WIEGAND, C. L. Distinguishing vegetation from soil background information. *Photogrammetric Engineering and Remote Sensing*, v. 43, n. 12, p. 1541-1552, 1977.

ROCHA, M. T. Os projetos florestais no mecanismo de desenvolvimento limpo. *Florestar Estatístico*, v. 7, n. 16, p. 9-14, jul./2004.

ROMANOVSKI, Z. *Morfologia e aspectos hidrológicos da microbacia Rua Nova, Viçosa-MG, para fins de manejo*. 2001. 99 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal de Viçosa, Viçosa, 2001.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DERING, D. W. Monitoring Vegetation Systems in the Great Plains with ERTS. *Third ERTS Symposium*, NASA SO-351, v. 1, p. 309-317, 1973a.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DERING, D. W. Monitoring the vernal advancement and retrogradation (Greenwave effect) of nature vegetation. *NASA/Goddard Space Flight Center, Type II Report for Period April 1973-September 1973b*, Greenbelt, Maryland (USA), 1973b. 69 p.

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

SCHLUNZEN, E. T. M.; TRINDADE, M. L. B.; SHIMABUKURO, M. H.; SCHLUNZEN JR., K.; ANDRADE NETO, M. L. Perspectivas da aplicação de redes neurais na classificação de dados multiespectrais de sensoriamento remoto. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 7., Curitiba. *Anais...* São Jose dos Campos: INPE, 1993. p. 438-444.

SCHOENINGER, E. R. KOEHLER, H. S.; WATZLAWICK, L. F.; OLIVEIRA FILHO, P. C. Uso de redes neurais artificiais como uma alternativa para mapeamento de biomassa e carbono orgânico no componente arbóreo de florestas naturais. Guarapuava, PR. *Ambiência – Revista do Setor de Ciências Agrárias e Ambientais*, v. 4, n.3, p. 529-549, set./dez. 2008b.

SCHOENINGER, E. R. *Uso de redes neurais artificiais para o mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa*. 2006. 146 f. Tese (Doutorado em Ciências Florestais) – Universidade Federal de do Paraná, Curitiba, 2006.

SCHOENINGER, E. R.; KOEHLER, H. S.; BOTELHO, M. F.; WATZLAWICK, L. C.; OLIVEIRA, P. C. *Uso de Redes Neurais artificiais para mapeamento de biomassa e carbono orgânico no componente arbóreo de uma floresta ombrófila densa*. Guarapuava, PR. *Ambiência – Revista do Setor de Ciências Agrárias e Ambientais*, v. 4, n. 2, p. 175-195. maio/ago. 2008a.

SCHOWENGERDT, R. A. *Remote sensing: Models and methods for image processing*. 3. ed., London: Elsevier/Academic Press, 2007. 515 p.

SEBEM, E. *Aportaciones de la teledetección en el desarrollo de un sistema metodológico para la evaluación de los efectos del cambio climático sobre la producción de las explotaciones agrarias*. 2005. 382 f. Tese (Doutorado: Fotogrametria, Teledetección e Ingeniería Gráfica) – Universidad Politécnica de Madrid, 2005.

SILVEIRA, P. *Estimativa da biomassa e carbono acima do solo em um fragmento de floresta ombrófila densa utilizando o método da derivação do volume comercial*. *Floresta*, v. 40, n. 4, p. 789-800, 2010.

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, jan./mar. 2008.

SOMOGYI, Z.; CIENCIALA, E.; MAKIPAA, R.; MUUKKONEN, P.; LEHTONEN, A.; WEISS, P. *Indirect methods of large-scale forest biomass estimation*. *European Journal of Forest Research*, February/2006.

SOUDANI, K.; FRANÇOIS, C.; LE MAIRE, G.; LE DANTEC, V. ; DUFRÊNE, E. *Comparative analysis of IKONOS, SPOT and ETM+ data for leaf area index estimation in temperate coniferous e deciduous forest stands*. *Remote Sensing of Environment*, v. 102, p. 161-175, 2006.

SOUZA, C. L.; PONZONI, F. J. *Avaliação de índices de vegetação e de bandas TM/Landsat para estimativa de volume de madeira em floresta implantada de Pinus spp.* In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 9., 1988, Santos. *Anais...* São José dos Campos: INPE, 1998. p. 1549-1560.

STATSOFT, Inc. *Statistica* (data analysis software system), version 10. Disponível em: <<http://www.statsoft.com>>. Acesso em: 5 mar. 2011.

TAYLOR, M. IKONOS *planetary reflectance and mean solar exoatmospheric irradiance*. GeoEye – IKONOS Planetary Reflectance. QSOL Rev. 2, 2009. 3 p.

THENKABAIL, P. S. ENCLONA, E. A.; ASHTON, M. S.; LEGG, C.; DE DIEU, M. J. Hyperion, IKONOS, ALI, and ETM+ sensors in the study of African rainforests. *Remote Sensing of Environment*, v. 90, n. 4, p. 23-43, 2004.

UNFCCC – UNITED NATIONS FRAMEWORK CONVENTION ON CLIMATE CHANGE. *Kyoto protocol to the United Nations framework convention on climate change*. United Nations, 1998. Disponível em <<http://unfccc.int/resource/docs/convkp/kpeng.pdf>>. Acesso em: 23 jul. 2010.

WATZLAWICK, L. F. *Estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens do satélite IKONOS II*. 2003. 120 f. Tese (Doutorado em Ciência Florestal) – Universidade Federal do Paraná, Curitiba, 2003.

WATZLAWICK, L. F.; KIRCHNER, F. F.; SANGUETTA, 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, R.; DUNNO, G. A. Riparian vegetation mapping and image processing techniques, Hopi Indian Reservation, Arizona. *Photogrammetric Engineering & Remote Sensing*, v. 66, n. 2, p. 179-186, 2001.

YANG, Z.; WILLIS, P.; MUELLER, R. Impact of band-ratio enhanced awifs image to crop classification accuracy. In: THE 17<sup>th</sup> WILLIAM T. PECORA MEMORIAL REMOTE SENSING SYMPOSIUM – Pecora 17 – *The future of Land Imaging... going operational*. Denver, Colorado, 2008.

YOSHIOKA, H.; MIURA, T.; DEMATTÊ, J. A. M.; BATCHILY, K.; HUETE, A. R. Derivation of soil line influence on two-band vegetation indices and vegetation isolines. *Remote Sensing*, v. 1, n. 4. p. 842-857, 2009.

ZHENG, D.; RADEMACHER, J.; CHEN, J.; CROW, T.; BRESEE, M.; LE MOINE, J.; RYU, S. R. Estimating aboveground biomass using Landsat 7 ETM+ data across a managed landscape in northern Wisconsin, USA. *Remote Sensing of Environment*, v. 93, p. 403-411, 2004.

ZULLO JÚNIOR, J. *Correção atmosférica de imagens de satélite e aplicações*. 1994. 204 f. Tese (Doutorado em Engenharia Elétrica) – Universidade Estadual de Campinas, Campinas, 1994.