

EMERSON ROBERTO SCHOENINGER

**USO DE REDES NEURAS ARTIFICIAIS PARA MAPEAMENTO DE
BIOMASSA E CARBONO ORGÂNICO NO COMPONENTE ARBÓREO
DE UMA FLORESTA OMBRÓFILA DENSA**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Florestal, Área de concentração em Conservação da Natureza, do Setor de Ciências Agrárias da Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Florestais.

Orientador: Prof. Dr. Henrique Soares Koehler

CURITIBA

2006

À Erica, Tânia e Clarice família amada e querida,
DEDÍCO.

AGRADECIMENTOS

Ao amigo, professor e orientador Dr. Henrique Soares Koehler que, por tudo o que é como professor e pessoa, tornou possível a realização desse trabalho;

Ao professor Dr. Flávio Felipe Kirchner, com quem tive o prazer de compartilhar momentos na Universidade e principalmente assistir à suas aulas;

Ao Rolf Jensen Gieseler e Heiko Budag amigos sinceros.

Ao Dr. Luciano Farinha Watzlawick, que tive a satisfação de conhecer ao longo do período em que estive na Universidade;

Ao Dr. Paulo Costa de Oliveira Filho, co-orientador, pela confiança depositada e pelo tempo investido;

A CIA HEMMER INDÚSTRIA E COMÉRCIO LTDA, financiadora da pesquisa e seu Presidente “Marcos” aos quais devo grande parte de meu conhecimento, pelo investimento em todos os momentos necessários;

A coordenadora do Curso de Pós-Graduação Graziela Inês Bolzón de Muniz;

Ao Ministério de Ciência e Tecnologia e ao CNPq pela bolsa de estudos concedida;

Aos professores Dra. Regina do Rocio Andrade e Dr. Pedro Roberto de Azambuja Madruga pelo caloroso e sincero aceite em participar da banca examinadora;

Ao amigo, M.Sc. Darlon O. de Souza pela ajuda e troca de conhecimentos;

Aos amigos e maiores incentivadores, colegas Mosar e Kheila, por todas as contribuições para que esse trabalho fosse concluído;

Aos novos e grandes amigos James Sthal e Gleison Augusto dos Santos;

Aos meus familiares e amigos pela paciência e tolerância demonstradas quando da minha ausência no compartilhar do dia a dia, durante a execução desse trabalho;

Aos amigos Benicio de Melo Filho, Mônica Acco, Pyramon Accioly pelos momentos de companheirismo;

Aos amigos eternos Norton Felipe Knoblauch, Vitor Hugo Knoblauch, Paulo Pereira Feitosa, Margareth Kleina, “Flávios Augustos – o de Betim-MG” e Giovani Lazzarotti; e

A DEUS por ter proporcionado o tempo de vida para que este trabalho, obra SUA com certeza, pudesse ser realizado.

SUMÁRIO

	LISTA DE TABELAS	viii
	LISTA DE QUADROS	x
	LISTA DE FIGURAS	xi
	LISTA DE ANEXOS	xiii
	RESUMO	xv
	ABSTRACT	xvi
1	INTRODUÇÃO	1
1.1	OBJETIVOS	3
2	REVISÃO DE LITERATURA	4
2.1	VEGETAÇÃO.....	4
2.2	AQUECIMENTO GLOBAL.....	4
2.3	GEOPROCESSAMENTO E ESTUDOS AMBIENTAIS.....	7
2.4	SENSORIAMENTO REMOTO.....	9
2.5	SENSOR DO SATÉLITE IKONOS II.....	11
2.5.1	Aplicação de dados do IKONOS II.....	12
2.6	MAPEAMENTO DE BIOMASSA E CARBONO ORGÂNICO ARBÓREO.....	14
2.7	SEGMENTAÇÃO DE IMAGENS.....	15
2.8	REDES NEURAIS ARTIFICIAIS - RNA	18
2.9	REDES NEURAIS ARTIFICIAIS (RNA) NA ÁREA FLORESTAL	22
3	METODOLOGIA	24
3.1	DESCRIÇÃO DA ÁREA	25
3.1.1	Localização	25
3.1.2	Clima	25
3.1.3	Geologia e Geomorfologia	26
3.1.4	Vegetação	27
3.2	INVENTÁRIO FLORESTAL	28
3.2.1	Definição da população.....	28
3.2.2	Sistema de amostragem	28
3.2.3	Unidade de amostra.....	29
3.2.4	Determinação do número de amostras.....	29
3.2.5	Estabelecimento das unidades de amostra no campo	31
3.2.6	Identificação das espécies.....	31
3.2.7	Análise da estrutura horizontal da floresta.....	32

3.2.8	Cubagem de árvores.....	35
3.2.9	Equações alométricas testadas	36
3.3	BIOMASSA E CARBONO.....	38
3.3.1	Quantificação da biomassa da vegetação arbórea.....	38
3.3.2	Determinação do teor de umidade e teor de carbono.....	39
3.3.2	Obtenção da biomassa e teores de carbono	40
3.3.4	Equações de biomassa testadas	40
3.4	IMAGENS ORBITAIS.....	41
3.4.1	Ortorectificação das imagens orbitais.....	43
3.4.2	Avaliação das Ortoimagens Geradas	45
3.4.3	Segmentação	46
3.5	REDES NEURAS ARTIFICIAIS (ANN)	47
3.6	ALGORITMO DE REDES NEURAS ARITFICIAIS (ANN)	48
3.7	ANÁLISE DE REGRESSÃO LINEAR	55
4	RESULTADOS	56
4.1	INVENTÁRIO FLORESTAL	57
4.1.1	Intensidade de amostragem.....	57
4.1.2	Espécies florestais encontradas na área	57
4.1.3	Estrutura horizontal da floresta	58
4.1.4	Estatísticas por espécies	60
4.1.5	Equações alométricas ajustadas	62
4.2	BIOMASSA E QUANTIDADE DE CARBONO ARMAZENADA	64
4.2.1	Equações de biomassa ajustadas	64
4.2.2	Estimativas de biomassa por espécies	65
4.2.3	Estimativas da quantidade de carbono por espécies.....	68
4.2.4	Estimativas por amostras.....	73
4.3	PROCESSAMENTO DAS IMAGENS	74
4.4	SEGMENTAÇÃO MULTI-RESOLUÇÃO.....	74
4.5	ANÁLISE DE CORRELAÇÃO.....	81
4.6	RESULTADOS DA REDE NEURAL ARTIFICIAL PARA BIOMASSA	82
4.6.1	Mapa de biomassa arbórea	87
4.7	RESULTADOS DA REDE NEURAL ARTIFICIAL PARA QUANTIDADE DE CARBONO.....	87
4.7.1	Mapa da quantidade de carbono	92
4.8	MAPEAMENTO COM USO DE REGRESSÃO LINEAR.....	94

4.8.1	Mapa de biomassa arbórea	96
4.8.2	Mapa de conteúdo de carbono	97
5	CONCLUSÕES E RECOMENDAÇÕES	100
5.1	CONCLUSÕES	100
5.2	RECOMENDAÇÕES.....	101
	REFERÊNCIAS	102
	ANEXOS	110

LISTA DE TABELAS

TABELA 01	CONCENTRAÇÕES GLOBAIS DE ALGUNS GASES DO EFEITO ESTUFA GERADAS POR ATIVIDADES HUMANAS	06
TABELA 02	CARACTERÍSTICAS DOS SATÉLITES EM ATIVIDADE	11
TABELA 03	CARACTERÍSTICAS DO SENSOR DO SATÉLITE IKONOS II.....	12
TABELA 04	LIMIARES DE ERRO E PARÂMETROS TESTADOS NA REDE NEURAL ARTIFICIAL	48
TABELA 05	COORDENADAS DOS PONTOS UTILIZADOS NA CORREÇÃO E RESÍDUOS OBTIDOS NO AJUSTAMENTO	74
TABELA 06	MATRIZ DE CORRELAÇÃO ENTRE VARIÁVEIS DIGITAIS E A BIOMASSA EM FLORESTA OMBRÓFILA Densa	82
TABELA 07	MATRIZ DE CORRELAÇÃO ENTRE VARIÁVEIS B VARIÁVEIS DIGITAIS E A CARBONO EM DA FLORESTA OMBRÓFILA Densa	83
TABELA 08	COMPARAÇÃO ENTRE A BIOMASSA ARBÓREA ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,001 e 0,0001	84
TABELA 09	COMPARAÇÃO ENTRE A BIOMASSA ARBÓREA ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,005.....	84
TABELA 10	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01	85
TABELA 11	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01.....	86
TABELA 12	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01.....	86
TABELA 13	COMPARAÇÃO ENTRE A QUANTIDADE DE CARBONO ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,001 e 0,0001	89
TABELA 14	COMPARAÇÃO ENTRE A QUANTIDADE DE CARBONO ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,005.....	90
TABELA 15	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01	91

TABELA 16	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01	91
TABELA 17	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01	92
TABELA 18	COMPARAÇÃO DOS RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ARBÓREA UTILIZANDO A EQUAÇÃO DE REGRESSÃO MÚLTIPLA.....	95
TABELA 19	COMPARAÇÃO DOS RESULTADOS DAS ESTIMATIVAS DO CONTEÚDO DE CARBONO UTILIZANDO A EQUAÇÃO DE REGRESSÃO MÚLTIPLA.....	96

LISTA DE QUADROS

QUADRO 01	ESTATÍSTICAS DAS PARCELAS DOS INVENTÁRIOS FLORESTAIS PRÉVIOS CONTENDO O NÚMERO DE AMOSTRAS COLETADAS (n), NÚMERO DE AMOSTRAS POTENCIAIS (N), ÁREA TOTAL, VOLUME MÉDIO (m^3), VARIÂNCIA (s^2), DESVIO PADRÃO (s) E ERRO PADRÃO (s_x).....	30
QUADRO 02	RESULTADOS DE INTENSIDADE AMOSTRAL OBTIDA CONSIDERANDO DIFERENTES NÍVEIS DE ERRO E PROBABILIDADES.....	57
QUADRO 03	RESULTADOS E ESTATÍSTICAS DO AJUSTE DOS MODELOS PARA OBTENÇÃO DAS ESTIMATIVAS DOS VOLUMES COM CASCA (m^3), VOLUMES SEM CASCA (m^3), ALTURA TOTAL (m) E ALTURA COMERCIAL (m) PARA ESPÉCIES FOLHOSAS, PARA O PALMITO E PARA OS XAXINS.....	63
QUADRO 04	RESULTADOS E ESTATÍSTICAS DO AJUSTE DOS MODELOS PARA OBTENÇÃO DAS ESTIMATIVAS DE BIOMASSA TOTAL (kg) E ALTURA TOTAL (m) PARA ESPÉCIES FOLHOSAS, PARA O PALMITO E PARA OS XAXINS.....	65
QUADRO 05	PESO DE BIOMASSA, EM kg, POR COMPARTIMENTO E PARA O TOTAL, POR ESPÉCIE AVALIADA E MÉDIA GERAL PARA TODAS AS ESPÉCIES	66
QUADRO 06	RESULTADOS DAS ESTIMATIVAS DO NÚMERO DE ÁRVORES POR HA, ÁREA BASAL EM $m^2 HA^{-1}$ E BIOMASSA TOTAL EM $kg ha^{-1}$, PARA AS ESPÉCIES QUE TOTALIZAM 50% DO ÍNDICE DE VALOR DE IMPORTÂNCIA	69
QUADRO 07	TEORES DE CARBONO, EM $g kg^{-1}$, POR COMPONENTES, POR ESPÉCIE AVALIADA E MÉDIA GERAL DE TODAS AS ESPÉCIES.....	70
QUADRO 08	RESULTADOS DAS ESTIMATIVAS DO NÚMERO DE ÁRVORES POR ha, ÁREA BASAL EM $m^2 ha^{-1}$ E CARBONO TOTAL MÉDIO ESTOCADO, EM $kg ha^{-1}$, PARA AS ESPÉCIES QUE TOTALIZAM 50% DO ÍNDICE DE VALOR DE IMPORTÂNCIA.....	72
QUADRO 09	ESTATÍSTICAS REFERENTES AOS VALORES MÉDIOS PARA AS 48 AMOSTRAS EFETUADAS, APRESENTANDO OS VALORES MÍNIMOS, MÁXIMOS E MÉDIOS, O DESVIO PADRÃO E O COEFICIENTE DE VARIAÇÃO PARA AS VARIÁVEIS ESTIMADAS.....	73
QUADRO 10	PARÂMETROS TESTADOS NA SEGMENTAÇÃO.....	75

LISTA DE FIGURAS

FIGURA 01	COMPORTAMENTO ESPECTRAL DE ALVOS	10
FIGURA 02	ESTRUTURA DE UMA RNA DO TIPO <i>MULTILAYER FEEDFOWARD</i> ...	19
FIGURA 03	MODELO NÃO-LINEAR DE UM NEURÔNIO.....	20
FIGURA 04	FLUXOGRAMA DA METODOLOGIA EMPREGADA	24
FIGURA 05	LOCALIZAÇÃO DA ÁREA DE ESTUDO	25
FIGURA 06	REPRESENTAÇÃO ESQUEMÁTICA DA UNIDADE DE AMOSTRA	29
FIGURA 07	CARTA IMAGEM DA LOCALIZAÇÃO DAS AMOSTRAS INVENTÁRIADAS	34
FIGURA 08	ESQUEMA GENÉRICO PARA CUBAGEM DE UMA ÁRVORE INTEIRA PELO MÉTODO DE SMALIAN, UTILIZANDO COMPRIMENTOS (L) DIFERENTES	35
FIGURA 09	CARACTERÍSTICAS DA IMAGENS IKONOS II, APIUNA-SC	42
FIGURA 10	SEQÜÊNCIA DO PROCESSO DE ORTORETIFICAÇÃO NO SOFTWARE <i>ENVI 4.1</i>	43
FIGURA 11	CARACTERÍSTICAS DA ORTORETIFICAÇÃO.....	45
FIGURA 12	FLUXOGRAMA DOS PROCEDIMENTOS DE CÁLCULOS	52
FIGURA 13	ESPÉCIES MAIS FREQUENTES NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE AMOSTRAS EM QUE OCORRERAM	58
FIGURA 14	ESPÉCIES COM MAIOR DENSIDADE NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE CADA UMA EM RELAÇÃO AO NÚMERO TOTAL DE INDIVÍDUOS MEDIDOS	59
FIGURA 15	ESPÉCIES DOMINANTES NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE ÁREA BASAL CADA UMA EM RELAÇÃO À ÁREA BASAL TOTAL DAS AMOSTRAS MEDIDAS	60
FIGURA 16	ESPÉCIES COM OS MAIORES ÍNDICES DE VALOR DE IMPORTÂNCIA ENCONTRADAS NA ÁREA ESTUDADA	60
FIGURA 17	ESPÉCIES COM OS MAIORES ÍNDICES DE VALOR DE COBERTURA ENCONTRADAS NA ÁREA ESTUDADA.....	61
FIGURA 18	ESPÉCIES COM OS MAIORES ÍNDICES DE VALOR DE COBERTURA ENCONTRADAS NA ÁREA ESTUDADA.....	61

FIGURA 19	ESPÉCIES COM OS MAIORES DIÂMETROS MÉDIOS (DAP), EM cm, ENCONTRADAS NA ÁREA ESTUDADA	62
FIGURA 20	ESPÉCIES COM MAIORES DAP, EM cm, ENCONTRADAS NA ÁREA ESTUDADA.....	62
FIGURA 21	ESPÉCIES COM MAIORES ÁREAS BASAIS, EM m ² ha ⁻¹ , ENCONTRADAS NA ÁREA ESTUDADA	63
FIGURA 22	ESPÉCIES COM MAIOR BIOMASSA TOTAL MÉDIA, EM kg ha ⁻¹ , ENCONTRADAS NA ÁREA INVENTARIADA	68
FIGURA 23	BIOMASSA TOTAL MÉDIA, EM kg ha ⁻¹ , POR COMPARTIMENTO, DAS ÁRVORES ENCONTRADAS NA ÁREA INVENTARIADA	68
FIGURA 24	ESPÉCIES COM MAIORES QUANTIDADES MÉDIAS DE CARBONO ESTOCADO, EM kg ha ⁻¹ , ENCONTRADAS NA ÁREA ESTUDADA.....	71
FIGURA 25	QUANTIDADE DE CARBONO TOTAL MÉDIO ARMAZENADO, EM kg ha ⁻¹ , POR COMPARTIMENTO DAS ÁRVORES ENCONTRADAS NA ÁREA ESTUDADA.....	72
FIGURA 26	RESULTADO DA SEGMENTAÇÃO NO NÍVEL 1	76
FIGURA 27	RESULTADO DA SEGMENTAÇÃO NO NÍVEL 2	77
FIGURA 28	RESULTADO DA SEGMENTAÇÃO NO NÍVEL 3	78
FIGURA 29	RESULTADO DA SEGMENTAÇÃO NO NÍVEL 4	79
FIGURA 30	RESULTADO DA SEGMENTAÇÃO NO NÍVEL 5	80
FIGURA 31	MAPA DE BIOMASSA ARBÓREA OBTIDO POR MEIO DA UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS.....	88
FIGURA 32	MAPA DE QUANTIDADE DE CARBONO OBTIDO POR MEIO DA UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS.....	93
FIGURA 33	MAPA DE BIOMASSA ARBÓREA OBTIDO POR MEIO DA UTILIZAÇÃO DA EQUAÇÃO DE REGRESSÃO AJUSTADA	98
FIGURA 34	MAPA DE CONTEÚDO DE CARBONO OBTIDO POR MEIO DA UTILIZAÇÃO DA EQUAÇÃO DE REGRESSÃO AJUSTADA	99

LISTA DE ANEXOS

ANEXO 01	VETORES DE ENTRADA PARA BIOMASSA NO PROGRAMA MATLAB.....	111
ANEXO 02	VETORES DE ENTRADA PARA CARBONO NO PROGRAMA MATLAB.....	112
ANEXO 03	LISTAGEM DA ROTINA USADA PARA TREINAMENTO DA RNA	113
ANEXO 04	LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO	116
ANEXO 05	ESTIMATIVAS POR AMOSTRAS	121
ANEXO 06	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001.....	123
ANEXO 07	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001.....	123
ANEXO 08	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001	123
ANEXO 09	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,005.....	124
ANEXO 10	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,005.....	124
ANEXO 11	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,005.....	124
ANEXO 12	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001.....	125
ANEXO 13	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001.....	125
ANEXO 14	COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001	125
ANEXO 15	GRÁFICO DE CONVERGÊNCIA DA RNA, PARA BIOMASSA.....	126

ANEXO 16	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001	127
ANEXO 17	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001	127
ANEXO 18	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001	127
ANEXO 19	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,005	128
ANEXO 20	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,005	128
ANEXO 21	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,005	128
ANEXO 22	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,001	129
ANEXO 23	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,001	129
ANEXO 24	COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,001	129
ANEXO 25	GRÁFICO DE CONVERGÊNCIA DA RNA, PARA QUANTIDADE DE CARBONO	130

RESUMO

O objetivo principal do presente estudo foi utilizar imagens do satélite IKONOS II para obter mapas temáticos para estimativas de biomassa arbórea e da quantidade de carbono orgânico armazenado em uma Floresta Ombrófila Densa. A área total avaliada foi 3.800 hectares, dos quais 3.324 hectares são cobertos atualmente por floresta natural. Na primeira etapa do estudo foram levantadas 48 amostras de 2700 m² onde todos os indivíduos com diâmetro a 1,30 metros do solo (dap) acima de 10 cm foram medidos e identificados. Na segunda etapa, baseada nos resultados advindos do inventário florestal, 219 árvores foram abatidas, mensuradas e pesadas em toda sua parte aérea para a determinação de sua biomassa arbórea e quantidade de carbono armazenado. As estimativas obtidas foram relacionadas com dados oriundos das bandas das imagens do satélite IKONOS II. Foi verificado o desempenho de Redes Neurais Artificiais (RNA) e de equações de regressão lineares na quantificação de biomassa arbórea e na quantidade de carbono arbóreo armazenado. As estimativas obtidas por ambos os métodos geraram mapas temáticos de biomassa arbórea e da quantidade de carbono armazenado. A biomassa arbórea total média estimada foi de 141,4 t ha⁻¹, enquanto que a média de carbono armazenado na vegetação foi de 59,3 t ha⁻¹. O teor de carbono médio determinado na vegetação arbórea foi de 422 g kg⁻¹. A arquitetura de RNA que apresentou melhores resultados foi com 12 neurônios na camada de entrada e 4 na camada de saída, para um limiar de erro de 0,01, para ambas as variáveis estimadas. O erro percentual médio em relação às amostras de verificação foi de 3,73 e 3,59%, para biomassa e quantidade de carbono, respectivamente. A melhor equação de regressão linear apresentou erros padrão da estimativa em porcentagem na ordem de 29,8 % para ambas as variáveis estimadas. A aplicação de Redes Neurais Artificiais mostrou-se mais exata na estimativa da biomassa e da quantidade de carbono do que as equações de regressão lineares ajustadas. A técnica de Redes Neurais Artificiais mostrou-se promissora na obtenção de estimativas de variáveis biométricas no setor florestal, sendo o estudo de outras variáveis e a aplicação da técnica em outras áreas recomendável para seu uso de forma mais ampla.

Palavras chave: biomassa, carbono, redes neurais, mapas temáticos

ABSTRACT

The main objectives of the study were to use IKONOS II images to create thematic maps for dry above ground biomass and carbon quantities stored in a Dense Ombrophilous Forest. The total area covered by the study is 3.800 hectares, of which 3.324 hectares are covered by natural forest. As the first study stage, 48 samples of 2.700 m² were taken for forest inventory purposes, where all trees with dbh greater than 10 cm were measured and identified. Once the results of the forest inventory were available, 219 trees were cut and had their different fresh portions measured and weighted for biomass and carbon determination. The estimates obtained were related with data from the IKONOS II satellite bands. The performance of Artificial Neural Networks (ANN) and linear regression equations were verified. The estimates of above ground dry biomass and carbon amount stored generated by both methods allowed thematic mapping of these variables. Dry biomass for trees with dbh greater than 10 cm had an average of 141.4 t ha⁻¹, while the average amount of stored carbon was 59.3 t ha⁻¹. The average carbon rate estimated for the above ground vegetation was 422 g kg. The best ANN architecture showed 12 neurons as input and 4 for output for 0,01 threshold error, for both estimated variables. The percentage error for the validation samples was 3,73 and 3,59% for dry biomass and carbon content, respectively. The best linear equation showed standard errors in percentage of 29,8% for both variables. The use of ANN showed more accurate estimates for the studied variables than the linear regression equation. The ANN technique showed very promising results for estimating biometric variables, being the study of another variables and fields of application highly recommended.

Key words: dry biomass, carbon storage, neural networks, thematic maps

1 INTRODUÇÃO

Tratando-se de tema atual, o acúmulo de carbono na atmosfera oriundo da queima de combustíveis fósseis ou de queimadas da vegetação, é um das principais responsáveis pelo aumento da temperatura na terra, e tem por consequência um aumento do nível dos mares e uma variação dos eventos climáticos. Uma alternativa viável para amenizar o agravamento deste processo, que pode colocar em risco a vida na terra, consiste no armazenamento do carbono atmosférico pelas florestas (RENNER, 2004).

Os ciclos do carbono e oxigênio na natureza são processos fundamentais na transformação constante das substâncias orgânicas que constituem a biosfera, definida como o ambiente onde se desenvolvem os fenômenos biológicos. Na primeira etapa do ciclo, a fotossíntese, as partes verdes das plantas absorvem o dióxido de carbono atmosférico e o fazem reagir com a água, servindo-se da luz solar e da presença da clorofila. Formam-se assim compostos de carbono complexos, que vão constituir a estrutura do vegetal, com a consequente liberação de oxigênio. Esse gás que passa ao ar é utilizado na respiração de bactérias e animais, onde se registra o processo inverso, ou seja, o oxigênio é captado e o dióxido de carbono despendido encerrando o ciclo (TAIZ e ZEIGER 2004; WIKIPÉDIA, 2006; APPENZELLER, 2004).

A redução dos ecossistemas tropicais, determinada pelos processos degenerativos resultantes da desordenada atividade humana sob estes ambientes, restringiram a Floresta Atlântica à apenas 7,3% de sua cobertura original. Os diferentes graus de interferência nesses ambientes são agora alvos de estudo no sentido da utilização sustentável dos recursos naturais e da conservação do estoque de carbono contido nos solos, florestas e outros tipos de vegetação, de forma a cooperar com a redução da concentração de CO₂ na atmosfera.

Segundo RENNER (2004), pesquisas têm demonstrando que as florestas são verdadeiros sumidouros de carbono, pois, por meio do processo fotossintético acoplado à produção de celulose durante o crescimento e manutenção das plantas, as florestas acumulam o carbono.

A preocupação com relação à intensificação dos eventos climáticos atípicos tem gerado a possibilidade de captação de recursos financeiros advindo dos países do Anexo I

do Protocolo de Kyoto, (países desenvolvidos), que é composto por países que possuem economias fortes e altos indicadores sociais, tais como qualidade de vida dos seus habitantes (WIKIPÉDIA, 2006).

Os créditos de carbono são um bônus, que dão o direito ao seu possuidor emitir gases nocivos correspondentes à cota adquirida, ou representam um compromisso de reduzir a emissão de gases do efeito estufa. Esse mercado baseia-se no chamado “seqüestro de carbono” por florestas, que farão parte do programa de reduções das emissões dos países desenvolvidos (Anexo I), e que deverão ser implementados em países não pertencentes a este grupo. Estes projetos estariam seqüestrando carbono e ao mesmo tempo ajudando os países em desenvolvimento, pois estes se beneficiarão de recursos financeiros aplicados nestes projetos (RENNER, 2004).

Para que a captação de recursos financeiros seja possível, trabalhos de geração de mapeamentos temáticos de biomassa e quantidade de carbono armazenado utilizando diferentes tipos de satélites/sensores são necessários. Contudo, ainda não existem registros de pesquisas que integrem dados de diferentes escalas e fontes como inventários florestais e imagens satélites, para a obtenção de mapas de distribuição de dados biofísicos para florestas naturais.

A utilização Redes Neurais Artificiais (ANN), que são um conjunto de técnicas não-paramétricas, pode ser utilizada como método alternativo para o mapeamento de padrões de entrada e de saída de classes associadas. Com o uso de um conjunto de pares de treinamento, ou seja, valores de entrada são multiplicados por pesos e somados, gerando os valores de ativação do neurônio, os valores de saídas são comparados aos vetores observados e com base em um limiar de erro são aceitos ou não (TODT, 1998).

Diante das técnicas normalmente utilizadas, torna-se claro a necessidade do desenvolvimento de uma metodologia que permita o mapeamento da biomassa e do carbono orgânico arbóreo de forma mais eficiente. Acredita-se que, para tanto, um modelo que permita integrar diferentes fontes de entradas de dados, para uma mesma saída e que faça o ajuste do modelo de forma mais automatizada, seja o mais adequado e nesse contexto Redes Neurais Artificiais apresentam-se como uma proposta válida.

1.1 OBJETIVOS

O objetivo principal do presente trabalho foi verificar o desempenho das Redes Neurais Artificiais (ANN) na quantificação de biomassa arbórea e na quantidade de carbono orgânico armazenado no componente arbóreo de uma Floresta Ombrófila Densa.

Como objetivos específicos do presente destacam-se:

- descrever a estrutura horizontal da área de estudo sob a ótica de variáveis dendrométricas, de biomassa arbórea e de carbono orgânico armazenada;
- analisar os dados oriundos das bandas das imagens do satélite IKONOS II, verificando sua correlação com dados de biomassa arbórea e de carbono orgânico arbóreo proveniente dos levantamentos de campo;
- verificar o desempenho das Redes Neurais Artificiais (ANN) na quantificação de biomassa arbórea e na quantidade de carbono orgânico arbóreo armazenado;
- ajustar e testar modelos de equações de regressão lineares para estimar a biomassa arbórea e a quantidade de carbono orgânico armazenado em função de variáveis provenientes das imagens de satélite;

2 REVISÃO DE LITERATURA

2.1. VEGETAÇÃO

A Floresta Ombrófila Densa - estende-se por aproximadamente 1,5 milhão de km², abrangendo praticamente todo o litoral brasileiro em 13 estados, desde o Estado do Rio Grande do Norte até o Estado do Rio Grande do Sul (MYERS et al., 2000). Esse complexo de grande amplitude geográfica e climática culmina em uma grande diversidade de ecossistemas complexos (MANTOVANI, 1990), resultantes de uma adaptação às condições de pluviosidade e umidade pouco variáveis, sendo as alterações mais profundas causadas por variações edafoclimáticas (DASMAN et al. 1973).

A flora desse ecossistema é muito diversificada com mais de 25 mil espécies. A riqueza e diversidade dessa vegetação são devidas principalmente a sua extensão e ao relevo em que ocorre, bem como ao elevado índice de chuvas ao longo do ano (LEITÃO-FILHO, 1994).

Contudo, esse cenário de grande diversidade e endemismos de espécies florísticas e faunísticas está sofrendo modificações pela grande pressão antrópica. Estima-se hoje que a demanda anual de madeira no Brasil seja de 350 milhões de metros cúbicos e a produção das florestas plantadas de aproximadamente 90 milhões, havendo dessa forma um déficit de 260 milhões, que tem sido suprimido pelo corte de florestas nativas (FERREIRA e GALVÃO, 2000), acarretando com isso perdas inestimáveis dos repositórios naturais da diversidade biológica.

2.2 AQUECIMENTO GLOBAL

Tratando-se de um tema atual, principalmente no Brasil que é um signatário e ratificou o Protocolo de Kyoto, o acúmulo de carbono na atmosfera, oriundo da queima de combustíveis fósseis ou de queimadas da vegetação, é um dos principais responsáveis pelo aumento da temperatura na terra constituindo-se no principal gás do efeito estufa. A

vegetação vem sendo considerada como grande sumidouro de carbono da atmosfera (RENNER, 2004).

Os ciclos do carbono e do oxigênio na natureza são processos fundamentais na transformação constante das substâncias orgânicas que constituem a biosfera, definida como o ambiente em que se desenvolvem os fenômenos biológicos. O ciclo do carbono com seus elementos de transformação, principalmente via vegetação, é extremamente importante porque, graças a ele, assegura-se à continuidade do equilíbrio ecológico vital. Outras formas de produção de dióxido de carbono são as queimadas e a decomposição de material orgânico no solo. Os reservatórios de CO₂ na terra e nos oceanos são maiores que o total de CO₂ na atmosfera, contudo, pequenas mudanças nesses reservatórios podem causar grandes efeitos na concentração atmosférica (ZIMMER et al. 2002).

Atualmente o homem despeja anualmente 3 bilhões de toneladas de carbono na atmosfera, oriundos do carvão, petróleo, gás natural, elementos essenciais para mover a economia do mundo industrializado. O carbono absorvido pela vegetação é devolvido à atmosfera por chaminés, tubos de escape, agregando-se às emissões das florestas queimadas.

Um dos assuntos de maior paradigma científico da atualidade são as mudanças no aquecimento global. As ações decorrentes das atividades econômicas e industriais têm provocado alterações na biosfera, resultando na quase duplicação da concentração de gases do efeito estufa (GEE) na atmosfera. As áreas de pastagem, no Brasil, por exemplo, aumentaram de 1970 até 2002 cerca de 17% passando de 154 para 180 milhões de hectares (ZIMMER et al. 2002). A cultura da cana de açúcar, que corresponde a 2,3% do PIB brasileiro (ORPLANA, 2006), e ocupa somente no Estado de São Paulo mais de 4,5 milhões de hectares de terra (ÚNICA, 2006).

O efeito estufa é um processo que faz com que a temperatura da Terra seja maior do que a que seria na ausência de atmosfera. O efeito estufa dentro de uma determinada faixa é de vital importância, pois, sem ele, a vida como a conhecemos não poderia existir (WIKIPÉDIA, 2006). Porém, acima do nível desejável gera o conseqüente aquecimento da Terra, que é uma das principais preocupações globais devido ao seu impacto nocivo sobre o meio ambiente. Esse efeito é causado principalmente pelo aumento de CO₂ (dióxido de carbono), CH₄ (metano) e N₂O (óxido nitroso) e carbonos halogênicos na atmosfera. Nesse grupo de gases, o CO₂ tem a maior participação com 60% (IPCC, 2001; COLE et al., 1995) e é também o mais importante porque aumenta a capacidade da atmosfera para reter o calor. A Tabela 01 mostra o aumento dos GEE na atmosfera durante o período de 1750 a 1998.

TABELA 01 - CONCENTRAÇÕES GLOBAIS DE ALGUNS GASES DO EFEITO ESTUFA GERADAS POR ATIVIDADES HUMANAS

	Gás carbônico	Metano	Óxido nitroso
1750	280 ppm	700 ppb	270 ppb
1998	365 ppm	1745 ppb	314 ppb
Taxa de alteração	1,5 ppm/ano	7,0 ppb/ano	0,8 ppb/ano
Residência na Atmosfera (anos)	50-200	12	114

FONTE: Adaptado de *Intergovernmental Panel on Climate Change* (IPCC, 2001).

As alterações da concentração dos GEE poderão desencadear um aumento da temperatura média no planeta entre 1,4 e 5,8 °C nos próximos 100 anos. As incertezas que envolvem as mudanças do clima são muitas. A relação entre a crescente taxa de emissão de CO₂ na atmosfera e as mudanças climáticas não são totalmente compreendidas. Algumas previsões apontam para um aumento da intensidade de tempestades, períodos mais prolongados de secas, mudanças na circulação das correntes oceânicas, levando a aceleração do ciclo hidrológico e culminando em cenários catastróficos (SCHWARTZ e RANDALL, 2003).

Atualmente as estratégias utilizadas para combater o problema de elevação do nível de CO₂ no ar estão focadas principalmente em melhorar o rendimento dos processos que utilizem combustíveis a base de carbono como matéria prima e na substituição dos combustíveis fósseis por fontes renováveis e menos poluentes como, por exemplo, o hidrogênio e o álcool. Outras estratégias para contornar o problema da aceleração do aquecimento global são discutidas nas diferentes reuniões criadas para tratar especificamente dessa questão, quais sejam:

- o Quadro de Convenção das Nações Unidas sobre mudanças no clima (QCNUMC), tem como principal objetivo alcançar a estabilização das concentrações do GEE na atmosfera em nível que impeça interferências danosas no sistema climático global. Estabelece mecanismos que dão continuidade ao processo de negociação em torno de instrumentos, embora ainda não estejam definidas as diretrizes de ação (LOPES, 2002);
- Conferência das Partes (COPs) definiu metas de redução dos GEE para os países com compromisso de redução de emissão de gases (países do Anexo 1). Definiu também critérios e diretrizes para a utilização de mecanismos do mercado, gerando então o chamado Protocolo de Kyoto. Este acordo estabelece que os

países industrializados devam reduzir suas emissões entre 2008 e 2012 em 5,2% abaixo dos níveis observados em 1990 (ROCHA, 2003).

O protocolo de Kyoto é constituído por três instrumentos de mecanismos de flexibilização, com o fim de facilitar o cumprimento das metas de redução dos GEE (UNFCCC, 1997):

- Implementação conjunta: refere-se a projetos que visem a mitigação das mudanças climáticas entre dois países industrializados;
- Mecanismo de Desenvolvimento Limpo: refere-se a projetos de mitigação para a redução do GEE entre um país industrializado e outro não pertencente a esse grupo;
- Comércio de Emissões: dispõe sobre um mecanismo de transferência entre os países industrializados (países do Anexo 1), de partes de suas quantidades designadas de emissão de GEE, e com isso a produção dos gases excedente poderá ser vendida.

2.3 GEOPROCESSAMENTO E ESTUDOS AMBIENTAIS

Na perspectiva moderna de gestão do território, toda ação de planejamento e ordenação ou monitoramento do espaço deve incluir a análise dos diferentes componentes do meio ambiente, incluindo o meio físico-biótico, a ocupação humana e o inter-relacionamento destes. Nesse contexto, vêm se destacando o uso do geoprocessamento e suas ferramentas (CAMARA e MEDEIROS, 1998). Segundo esses autores, o termo geoprocessamento pode ser entendido como a tecnologia que utiliza técnicas computacionais para tratamento de informações geográficas. Esta tecnologia utiliza ferramentas computacionais chamadas de Sistemas de Informações Geográficas (GIS), as quais permitem realizar análises espaciais complexas, ao integrar dados de diversas fontes e ou criar bancos de dados georreferenciados.

O GIS é uma ferramenta computacional criada especialmente para armazenamento, manipulação e exibição de dados e informações espacialmente distribuídos em computador (BURROUGH, 1986). Mais do que um sistema de apresentação e processamento de dados, ele possui módulos para a realização de operações analíticas, sobreposição e cruzamento de informações. Seu banco de dados permite a associação de atributos e a realização de consultas, permitindo a análise e modelagem de informações espacialmente distribuídas.

Segundo MEDEIROS (1999), o requisito de armazenar a geometria dos objetos geográficos e de seus atributos representa uma necessidade básica para um GIS. Para cada objeto geográfico o GIS necessita armazenar seus atributos e as várias representações gráficas associadas a ele. Devido a sua ampla gama de aplicações, que inclui temas como geofísica, agricultura, florestas, cartografia, cadastro urbano e redes de concessionárias (água, energia e telefonia), há pelo menos três grandes maneiras de utilizar um GIS como ferramenta para produção de mapas, quais sejam, como suporte para análise espacial de fenômenos, como banco de dados geográficos ou como funções de armazenamento e recuperação.

A grande adaptabilidade destes sistemas faz com que os GIS tenham grande aplicação, podendo ser utilizados em processos de análise ambiental, de planejamento, de uso da terra, de planejamento de recursos hídricos, de economia, entre outras finalidades de informação espacial (INTERA TYDAC, 1992). Muitos trabalhos foram gerados por diversos autores utilizando GIS. Na agricultura, por exemplo, GUIMARÃES (2004), utilizou fotografias aéreas, mapas de curvas de nível, uso e classificação do solo para a elaboração de mapas temáticos de ambientes de produção para avaliar a geometria dos talhões e o traçado dos carreadores em região canavieira.

SILVA (2005) propondo um geoindicador para caracterização do meio físico em uma microbacia, integrou linguagem de programação LEGAL e lógica *fuzzy* no qual o procedimento permitiu a caracterização de modificações das condições naturais de compactação dos solos da bacia, bem como forneceu um parâmetro para comparação de modificações futuras.

O uso e ocupação desordenada do solo foram as motivações para a definição de áreas prioritárias de conservação e preservação florestal empregando uma abordagem multicriterial em ambiente GIS, com o método da média ponderada ordenada para a combinação dos fatores (características da paisagem). Essa metodologia mostrou-se eficiente para a definição das áreas prioritárias e o processo de tomada de decisão apresentou-se convincente com pesos de compensação, ordenação e solução coerentes (VALENTE, 2005).

A integração de técnicas de fotointerpretação e mapeamento geotécnico com a utilização de imagem IKONOS II (PSM, 1 m) permitiu um levantamento e diagnóstico de áreas degradadas de ambientes urbanos identificando os efeitos danosos e a consequência deste na qualidade de vida da população local (PONS, 2006).

2.4 SENSORIAMENTO REMOTO

Sensoriamento Remoto (SR) pode ser definido como a ciência e a arte de se obter informações sobre um determinado objeto, área ou fenômeno, por meio de dados coletados por um equipamento que não entra em contato direto com o objeto, área ou fenômeno estudado (CREPANI, 1993).

A diversidade de aplicações do SR faz com que um número cada vez maior de pesquisadores de diferentes áreas do conhecimento utilize essa ferramenta. Uma das principais vantagens dessa técnica com relação aos estudos ambientais é ela permitir a análise de grandes áreas em apenas uma imagem, em imageamentos contínuos e em intervalos regulares, permitindo a obtenção de dados multiespectrais, multitemporais e em diferentes resoluções espaciais (KOFFER, 1992).

A radiação eletromagnética (REM) é constituída de várias formas sendo as radiações da faixa do visível apenas algumas delas. As ondas de rádio, radiações termais, raios X, ultravioletas, infravermelho, cósmicos são outras formas de REM e ao conjunto de diferentes tipos de comprimento de onda de REM, denomina-se espectro eletromagnético (AVERY e BERLIN, 1992).

Quando o alvo de interesse é a vegetação, as folhas são os elementos que mais contribuem para o sinal detectado pelos sensores contribuindo em maior parte com os comprimentos de ondas que serão absorvidos pelos sistemas sensores (JACKSON e HUETE, 1991). Os principais aspectos relacionados com o comportamento espectral de uma folha verde sadia nos comprimentos de onda do visível (0,4 - 0,7 μ m), no infravermelho próximo (0,7 - 1,3 μ m) e no infravermelho médio (1,3 - 3,0 μ m) são definidos por vários fatores.

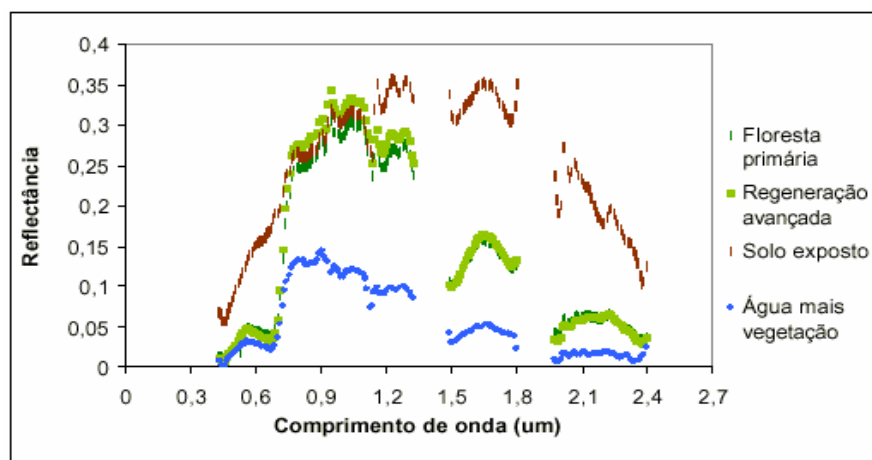
O comportamento espectral da vegetação está relacionado com a presença de pigmentos, de água e pela estrutura do mesófilo das folhas (GATES, 1980). Na região do visível, a maior parte da radiação incidente é absorvida pelos pigmentos presentes nas folhas (clorofila a e b, caroteno e xantofilas), encontrados nos cloroplastos e que absorvem a energia solar deste comprimento de onda e as convertem em calor, fluorescência ou em energia estocada pela fotossíntese (GATES et al., 1965; PONZONI, 2001).

Numa curva de reflectância de uma folha verde sadia são bem marcantes duas bandas de absorção centradas em 0,45 μ m (região do azul) e 0,65 μ m (região do vermelho) (GUYOT et al., 1989), permitindo um pico de reflectância em 0,54 μ m, na região do verde (SWAIN e DAVIS, 1978). A região do infravermelho próximo é caracterizada pela alta reflectância e pela baixa absorção causadas pela ausência de substâncias que absorvem a

radiação nestes comprimentos de onda e também decorrentes do espalhamento interno causado pelo arranjo do mesófilo (GATES et al. 1965; MOREIRA, 2003).

Na região do infravermelho médio, a reflectância da vegetação sofre um decréscimo dos valores da energia refletida, devido principalmente ao conteúdo de água presente na folha (GUYOT, 1990), estando a reflectância relacionada inversamente com a quantidade total de água (BAUER et al., 1980). O comportamento espectral característico de uma folha sadia varia conforme o comprimento de onda proveniente dos raios solares que incidem sobre a mesma, como se pode observar na Figura 01.

FIGURA 01 - COMPORTAMENTO ESPECTRAL DE DIFERENTES ALVOS.



FONTE: SHIMABUKURO et. al. (2003).

Segundo MOREIRA (2003), os equipamentos que medem a radiação eletromagnética são genericamente chamados de radiômetros e podem ser classificados em não imageadores, aqueles que medem a radiância do alvo e apresentam os dados em forma de gráfico ou como dados numéricos, e os radiômetros imageadores, cujo resultado final é uma imagem de uma área de terreno igual à cena.

As cenas coletadas pelos sensores podem ser imageadas pelas diferentes categorias de satélite tais como os militares, científicos e meteorológicos entre outros. Os sensores utilizados para dados em nível orbital estão geralmente voltados para os estudos dos recursos naturais e operam em diferentes números de bandas, de diferente tamanho da largura espectral e diferente resolução espacial. Alguns dos sensores são apresentados na Tabela 02, de acordo com MOREIRA (2003). Segundo o autor existem três categorias de sensores, os de baixa, alta e altíssima resolução, onde estão incluídos o IKONOS II e o QuickBird, que a literatura científica, no entanto, frequentemente se reporta a esses satélites como sendo de alta resolução.

TABELA 02 - CARACTERÍSTICAS DOS SATÉLITES EM ATIVIDADE.

SATÉLITE / SENSOR	BANDAS DOS SENSORES	RESOLUÇÃO ESPACIAL
Landsat MSS	4	80 m
	5	
	6	
	7	
Landsat TM	1	30 m
	2	
	3	
	4	120 m
	5	
	6	
	7	
Landsat ETM +	1	30 m
	2	
	3	
	4	120 m
	5	
	6	
	7	
	8	15 m
NOAA – AVHRR	1	1,1 km
	2	
	3	
	4	
	5	
SPOT – HRV (CCD)	XS1	20 m
	XS2	
	XS3	10 m
	PAN	
IKONOS II	MS1	4 m
	MS2	
	MS3	
	MS4	1 m
	PAN	
QuickBird	GSD1	2,44 m
	GSD2	
	GSD3	
	GSD4	
	PAN	0,61 m
CBERS CCD	1	19,5 m
	2	
	3	
	4	
	PAN	

FONTE: adaptado de MOREIRA, 2003

2.5 SENSOR DO SATÉLITE IKONOS II

O satélite IKONOS II foi lançado em 24 de setembro de 1999 e entrou em fase operacional a partir de janeiro de 2000. Este satélite é operado pela *Space Imaging* e opera em cinco faixas espectrais. É um sensor do tipo CCD que opera nos comprimentos de onda de 450 nm até 900 nm. As características técnicas do satélite IKONOS II são apresentadas na Tabela 03.

TABELA 03 - CARACTERÍSTICAS DO SENSOR DO SATÉLITE IKONOS II.

Altitude	680 km		
Inclinação	98,1°		
Velocidade	Km/s		
Sentido da órbita	Descendente		
Duração da órbita	98 min		
Tipo da órbita	Sol-síncrona		
Resolução espacial	Pancromática 1m / multiespectral 4 m		
Imageamento	Cenas de 13 x 13 km		
Capacidade de aquisição	Faixas de 11 km x 100 km até 1000 km; mosaicos de até 12.000 km ² ; 20.000 km ² de área imageada em uma passagem		
Freq. de revisita	2,9 dias = pancromático; 1,5 dias = multiespectral		
Faixa espectral (nm)	Banda	Região espectral	Resolução espacial
450 – 520	MS – 1	azul	
520 – 600	MS – 2	verde	4 m
630 – 690	MS – 3	vermelho	
760 – 900	MS – 4	IVP	
450 – 900	PAN	Visível e IVP	1 m

FONTE: ENGESAT, 2006.

2.5.1 Aplicação de dados do IKONOS II

As imagens IKONOS II têm amplo uso, desde a gestão do espaço geográfico complexo até análise pontual, porque elas têm a capacidade de ser ampliadas com qualidade até 1:2.500, facilitando estudos em planejamento e meio ambiente integrado com GIS. A diversidade da utilização do IKONOS II pode ser demonstrada por múltiplos trabalhos.

GOWARD et al (2001), realizaram um trabalho de comparação da resolução espacial do IKONOS II e Landsat 7 ETM estudando a complexidade estrutural da floresta tropical e de savanas e revelaram a presença de uma marcante variação espacial para ser medida pelos sensores. WARNER e ASNER (2003) utilizaram 44 imagens IKONOS II para obter a quantificação da variação espacial da fração de cobertura no cerrado brasileiro.

OKIDA e OLIVEIRA (2003), testaram o pacote de ortoretificação para imagens IKONOS II *OrthoEngine Ikonos Models*, analisando a precisão do produto ortoretificado. Os resultados obtidos mostraram-se satisfatórios (RSM = 0,73m), apesar dos vetores da restituição apresentarem uma diferença de 0,82 m entre vetor e imagem ortoretificada

STURM et al. (2003), visando dar suporte ao planejamento de uma área de preservação permanente, realizaram um estudo de classificação em área de floresta ciliar, destinado ao mapeamento e avaliação da ocupação urbana utilizando classificação orientada ao objeto, com base em uma imagem IKONOS II. A classificação orientada ao

objeto realizada no *eCognition* permitiu que fossem encontradas áreas de solo exposto, dando suporte a recomendação de recuperação da área.

GONÇALVES, FONSECA e CAETANO (2001) apresentaram uma análise preliminar das imagens IKONOS II para atualização de cartografia de ocupação do solo com ênfase na cobertura florestal e urbana, realizando processamento ao nível de *pixel*, classificação de uso do solo pelo método da análise orientada ao objeto, implementado no *eCognition* e apresentando uma boa capacidade da extração de informação temática, em comparação com os métodos convencionais de análise baseados no *pixel*.

Avaliar a melhoria dos resultados da classificação digital automática com a utilização de dados auxiliares, como a textura de imagens e informações de relevo foi à proposta de LUZ (2002), que utilizou a classificação da imagem IKONOS II pelo algoritmo de Redes Neurais Artificiais. Os resultados apresentados foram excelentes quando realizados em um recorte da imagem, porém não se mostraram da mesma forma eficiente quando os parâmetros e a arquitetura da rede foram aplicados à imagem inteira.

WATZLAWICK (2003), utilizou uma metodologia com imagens do satélite IKONOS II para realizar estimativas de biomassa e carbono orgânico em plantações de *Pinus taeda*, *Araucaria angustifolia* e na Floresta Ombrófila Mista Montana, caracterizando aspectos estruturais, biomassa e o carbono, determinando a correlação com os dados de radiância das bandas do satélite IKONOS II e mapeando a biomassa e o carbono orgânico na área de estudo.

BARBOSA (2006), realizou a estimativa de biomassa e carbono orgânico para a vegetação herbácea de várzea da Amazônia Central com modelos de regressão múltipla. Apesar das considerações sobre a dificuldade da obtenção de imagens da região, para os dados onde existe a informação de forma íntegra a autora conseguiu resultados animadores, ressaltando o pioneirismo da pesquisa realizada em várzea da Amazônia Central.

ROLIM (2003) avaliou o potencial da classificação orientada a objeto aplicada a imagem de alta resolução espacial (IKONOS II), para a geração de informações a respeito da cobertura e uso do solo em bacias hidrográficas no auxílio ao manejo dos recursos naturais. O autor relata que as informações extraídas de imagens IKONOS II e classificadas por esta metodologia são eficientes para serem inseridas em um Sistema de Informações Geográficas, visando auxiliar o monitoramento em uma microbacia hidrográfica.

Usando a metodologia de regressão linear para correlacionar dados de imagens aos dados de campo, para mapear macro e micronutrientes, CANAVESI (2004) e ACCO (2004) consideraram como variáveis dependentes os macro e micronutrientes e como variáveis independentes os valores digitais das imagens, a reflectância, o índice de vegetação (NDVI)

e o índice de vegetação ajustado para influência do solo (SAVI). Em todas as análises de regressão realizadas as autoras, visando julgar qual a melhor equação que estima adequadamente as variáveis, utilizaram os valores dos coeficientes de determinação ajustado, do erro padrão da estimativa e a distribuição de resíduos.

CANAVESI (2004) trabalhando com macronutrientes obteve um coeficiente de determinação em torno de 0.52, ou seja, conseguiu explicar 52% da variação total das amostras por meio das equações ajustadas. Os erros apresentados por ACCO (2004), BARBOSA (2006) e (WATZLAWICK, 2003), foram aproximadamente 30%, 28% e 23%, respectivamente.

2.6 MAPEAMENTO DE BIOMASSA E CARBONO ORGÂNICO ARBÓREO

MACIEL (2002) procedeu a uma análise de regressão entre as variáveis biométricas e digitais a fim de determinar o grau de dependência entre elas, empregando-se funções lineares como pode ser visto na equação 1 e exponenciais observado na equação 2, definidas por:

$$Y_i = \alpha + \beta x_i + \varepsilon_i \dots \dots \dots \text{linear} \quad (1)$$

$$Y_i = \alpha + e^{\beta x_i} \cdot \varepsilon_i \dots \dots \dots \text{exponencial} \quad (2)$$

onde:

Y_i - variável dependente referente aos valores de densidade, área basal, biomassa, volume e diversidade na i -ésima observação;

X_i - variável independente na i -ésima observação referente aos valores de reflectância, índice de vegetação, proporção e textura.

α, β - coeficientes de regressão;

ε_i - erro aleatório com média zero e variância constante.

Os dados de campo foram relacionados às imagens por meio de equações de regressão, procedimento estatístico que utiliza a relação entre duas ou mais variáveis quantitativas para fazer a previsão de uma variável com base em outra(s) (MACIEL, 2002). Na análise de regressão uma variável aleatória y , denominada dependente, é relacionada à outra variável x , independente. No caso, a variável biomassa foi considerada dependente e os valores digitais extraídos das imagens, reflectâncias e os índices de vegetação correspondentes às unidades amostrais, considerados variáveis independentes. Esta metodologia para mapeamento de biomassa e carbono orgânico arbóreo, foi utilizada por

vários autores, dentre os quais (MACIEL, 2002); (WATZLAWICK, 2003) e (BARBOSA, 2006).

O melhor coeficiente de determinação nestes tipos de trabalhos foi o gerado por MACIEL (2002), utilizando o sensor do satélite Landsat 7TM, que conseguiu explicar em torno de 78% da variação da biomassa, com um erro padrão da estimativa de 10,78%, que pode ser considerado um ótimo resultado, segundo o autor, para uma floresta primária em Moju - Pará. Cabe salientar que todos os autores citados não deixaram amostras para validação dos modelos, utilizando todas as amostras coletadas para o ajuste do modelo.

2.7 SEGMENTAÇÃO DE IMAGENS

Para tornar mais eficiente à identificação dos valores de brilho das imagens referentes aos valores médios de biomassa e carbono das parcelas de um inventário florestal, uma simplificação dos dados da imagem torna mais simples esta tarefa. Esta simplificação conhecida como “SEGMENTAÇÃO DE IMAGEM” consiste em dividir em objetos as regiões espectralmente homogêneas da imagem (MOREIRA, 2001), onde dados biofísicos médios das parcelas com os valores médios de brilho dos segmentos constituem-se nas entradas das redes neurais artificiais utilizadas para treinar o algoritmo.

O critério de semelhança é usado para definir a uniformidade dos segmentos. Dois critérios são usados para descrever a separação do objeto da imagem, o critério espectral e o critério da forma (suavização e compactação). Estes critérios controlam a homogeneidade dos segmentos e regiões (BLASCHKE et al., 2002). A heterogeneidade no domínio espectral, definida pela equação (3) é composta pela soma dos desvios padrão dos níveis digitais para uma dada banda “ σ_c ” ponderada pelos pesos “ W_c ”. Contudo, em muitos casos, a heterogeneidade espectral pode resultar em segmentos fragmentados e por isto deve-se considerar a heterogeneidade no domínio espacial.

$$H_c = \sum W_c \cdot \sigma_c \quad (3)$$

onde:

W_c - pesos;

σ_c - desvio padrão médio dos valores de níveis digitais;

H_c - heterogeneidade de cor.

A heterogeneidade de forma pode ser vista de duas formas, ou calculada pela razão entre o comprimento da borda de um objeto pelo número total de *pixels* deste objeto,

conforme a equação (4) ou como a suavização, que é a razão da borda de um objeto pelo seu limite, ou seja, o comprimento de um quadrado ou retângulo que compreenda o objeto, conforme a equação (5), segundo (ANTUNES, 2003):

$$H_f = \frac{L}{\sqrt{N}} \quad (4)$$

$$H_f = \frac{L}{B} \quad (5)$$

onde:

- L - comprimento da borda (perímetro que compõe os objetos);
- N - número total de *pixels* que compõe o objeto;
- B - razão da borda (perímetro do quadrado que compreende o objeto);
- H_f - heterogeneidade de forma

Após a análise da heterogeneidade espacial e espectral, a segmentação inicia-se com um *pixel* (crescimento de regiões), sendo que a cada etapa, um par de objetos funde-se para formar um objeto maior. O processo de fusão está baseado no critério de homogeneidade, observando-se a heterogeneidade entre objetos adjacentes (ANTUNES, 2003). A fusão dos valores da heterogeneidade de cor e forma é demonstrada pela equação (6):

$$f = w * h_{cor} + (1 - w) * h_{forma} \quad (6)$$

onde:

- f - fusão entre a heterogeneidade de Hc e Hf;
- W - peso para a cor (contra forma).

Segundo ANTUNES (2003), o critério de fusão entre duas regiões adjacentes é descrito pela mudança de heterogeneidade após uma fusão virtual. Dado um determinado critério de heterogeneidade para uma região, o crescimento de heterogeneidade na fusão deve ser minimizado. A expressão (7) corresponde à diferença de heterogeneidade considerando o tamanho dos objetos, desta forma:

$$h_{dif} = h_m - \frac{(h_1 * n_1 + h_2 * n_2)}{n_1 + n_2} \quad (7)$$

onde:

- h_1 e h_2 - heterogeneidade para dois objetos;
- hm - heterogeneidade após a fusão virtual;
- n - tamanho dos objetos.

Como descrito por RIBEIRO (2004), os segmentos são descritos por meio de variáveis espectrais e/ou espaciais. As variáveis ou imagens compostas por níveis digitais espectrais podem ser o “brilho”, o valor médio de brilho ou a razão, e pode-se citar como variáveis espaciais o comprimento, a largura e a direção principal, dentre outras.

GONZALES e WOODS (2000), ressaltam que a segmentação deve isolar os objetos de interesse na imagem para ser eficiente. Os algoritmos de segmentação de imagens são muitos específicos e desenvolvidos para determinada aplicação. O algoritmo que detecta com grande precisão um tumor não obteria o mesmo resultado ao tentar detectar um defeito de uma peça numa linha de montagem, não existindo um modelo formal para segmentação. Esse processo é essencialmente empírico e deverá se ajustar a diferentes tipos de imagens (BAATZ e SCHÄPE, 2001) e ROLIM (2003).

GONZALES e WOODS (2000), afirma que os algoritmos de segmentação para imagens são geralmente baseados nas propriedades básicas dos valores de níveis de cinza, da descontinuidade e da similaridade. A primeira categoria aborda a partição da imagem baseada em mudanças bruscas nos níveis de cinza. Sua utilização é aplicada geralmente para a detecção de pontos isolados ou linhas e bordas na imagem. Já a similaridade baseia-se em limiarização, crescimento de regiões e divisão e fusão de regiões.

O procedimento de segmentação elaborado pelo programa *eCognition* é conhecido como *Multiresolution Segmentation*. A técnica básica utilizada é a de crescimento de regiões por agregação de *pixels* (BAATZ, 2001) e (ROLIM, 2003).

Na segmentação orientada a regiões, uma região é um conjunto de pontos “ligados”, ou seja, de qualquer ponto da região pode-se chegar a qualquer outro ponto por um caminho inteiramente contido na região. As regiões que se desejam detectar em geral são regiões “homogêneas” e apresentam alguma propriedade local aproximadamente constante em toda sua extensão. Algumas propriedades locais usadas comumente são níveis de cinza, textura e cor (MASCARENHAS e VELASCO, 1989).

Para os algoritmos de crescimento de regiões segundo a varredura, a imagem é percorrida de cima pra baixo e da esquerda pra direita. Cada ponto (x,y) é comparado com seus vizinhos anteriores (já rotulados) e adicionado ou não a classe da região de um dos

vizinhos. Se um ponto não for adicionado à região de um vizinho, ele deverá iniciar uma nova região (GONZALES e WOODS, 2000). Os autores comentam que a principal vantagem de se trabalhar com a classificação por regiões é que essa técnica fornece informações de natureza espacial, que não podem ser extraídas individualmente de *pixels* e que são normalmente consideradas durante o processo de análise visual de imagens.

2.8 REDES NEURAIAS ARTIFICIAIS - ANN

Inteligência Computacional (IC) poderia ser definida como um conjunto de modelos, algoritmos, técnicas, ferramentas e aplicações em um sistema computadorizado, que simula algumas das habilidades cognitivas do homem (ALLARD e FUCHS, 1993). A IC abrange o conhecimento de diversas ciências tais como ciências da computação, lingüística, matemática, neurofisiologia, psicologia, que conjuntamente, objetivam o desenvolvimento de computadores e programas capazes de imitar e/ou entender aspectos do pensamento humano.

Existem diversos tipos de Redes Neurais Artificiais e diferentes maneiras de classificá-las. Talvez a mais importante seja quanto à forma de aprendizado que pode ser supervisionada e não supervisionada:

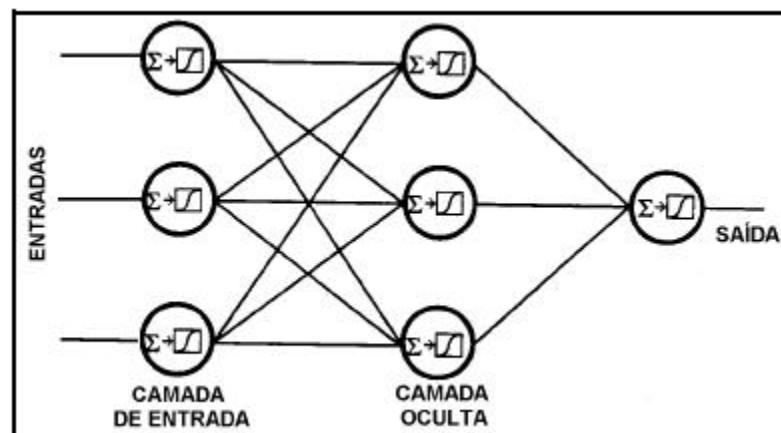
- Supervisionada: são sucessivamente apresentadas à rede conjuntos de padrões de entrada e seus correspondentes padrões de saída. Durante este processo, a rede realiza um ajustamento dos pesos das conexões entre os elementos de processamento, segundo uma determinada lei de aprendizagem, até que o erro entre os padrões de saída gerados pela rede alcancem um valor mínimo desejado, como por exemplo os métodos, *perceptron*, *adaline* e *madaline*, *backpropagation* (HECHT-NIELSEN, 1989; FREEMAN e SKAPURA, 1991; BEALE e JACKSON, 1991);
- Não-supervisionada: a rede “analisa” os conjuntos de dados apresentados a ela, determina algumas propriedades dos conjuntos de dados e “apreende” a refletir estas propriedades na saída. A rede utiliza padrões, regularidades e correlações para agrupar os conjuntos de dados em classes. São exemplos de não supervisionada Mapa Auto-Organizável de Kohonen, Redes de Hopfield e Memória Associativa Bidirecional (HECHT-NIELSEN, 1989; FREEMAN e SKAPURA, 1991; BEALE e JACKSON, 1992).

As redes também podem ser classificadas quanto às suas características, que podem ser contínua, discreta, determinística e estocástica, ou quanto à sua estrutura, redes de múltiplas camadas - *multilayer feedforward network* -, cujo fluxo de dados segue uma única direção e redes recursivas - *recurrent network* ou *Backpropagation* (MEDEIROS, 1999).

O neurônio artificial, elemento de processamento ou ainda unidade de processamento denota um simples dispositivo capaz de calcular o somatório de N entradas ponderadas, cujo resultado passa por meio de uma função não-linear. Basicamente este dispositivo é caracterizado por um *offset* ou limiar interno e por algum tipo de função não-linear. A saída Y do dispositivo é função somatório das entradas X_0, X_1, \dots, X_{n-1} , ponderadas pelos pesos W_0, W_1, \dots, W_{n-1} menos o *offset* θ (MEDEIROS, 1999).

A ANN apresentada na Figura 02 pode ser descrita como uma rede de três camadas totalmente conectada, perfazendo $(3 \times 3) + (3 \times 1) = 12$ conexões e contendo uma camada de entrada com três elementos de processamento, uma camada oculta, também com três elementos de processamento e uma camada de saída, com um elemento de processamento.

FIGURA 2 - ESTRUTURA DE UMA ANN DO TIPO *MULTILAYER FEEDFORWARD*.



Fonte: adaptado de HEWITSON e CRANE (1994).

O algoritmo para treinamento de ANN mais conhecido é o *Backpropagation* ou algoritmo da retropropagação do erro. Ele utiliza o conceito de minimização do gradiente decrescente e o limiar da função sigmóide, considerando uma generalização da regra delta (Erro Quadrático Mínimo) para ANN *feed forward*. O Erro Quadrático Mínimo (E.Q.M.) utiliza um conjunto de treinamento com o qual se pretende uma aproximação linear de tal forma que se obtenha a melhor aproximação possível no sentido do erro quadrático (GERMAN e GAHEGAN, 1996).

O uso de ANN para solução de um dado problema consiste na repetição de um de conjunto de treinamentos. Treinar uma rede significa ajustar a sua matriz de pesos de entrada de forma que o vetor de saída coincida com certo valor desejado para cada vetor de entrada (Figura 03). O processo de treinamento é repetido até que o erro para o conjunto de treinamento alcance valor mínimo ou limite previamente determinado (HAYKIN, 1999).

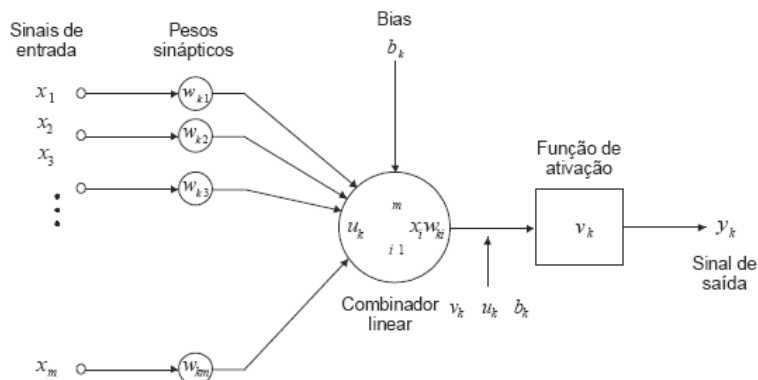
As vantagens para a utilização de ANN são citadas por SMITH e BRIO (1996) MOLINA (2001) são:

- as redes podem, em alguns casos, permitir análises superiores às conseguidas com técnicas estatísticas convencionais;
- não necessitam de conhecimento de especialista para tomar decisões, pois se baseiam unicamente nos exemplos históricos que lhes são fornecidos;
- o tempo necessário para se implementar uma rede é menor que o utilizado para a construção de um sistema especialista equivalente;
- como as unidades da rede operam em paralelo, a destruição ou “defeito” em um de seus nós não torna a rede inoperante;
- as redes conseguem separar o ruído (variações aleatórias, presentes nos dados reais, adicionais aos valores originais) da informação relevante, tendo sido utilizadas inclusive como filtros de dados;
- se as condições de trabalho variam pode-se fazer uso da capacidade das ANN's para adaptar-se a essas mudanças, voltando a treinar o sistema com novos exemplos.

Quanto às desvantagens, BRIO e MOLINA (2001) e SILVA et al., (2001), apontam:

- as redes podem chegar a conclusões que contrariem as regras e teorias estabelecidas;
- o treinamento de uma rede, dependendo de sua aplicação, pode ser demorado;
- uma vez treinada uma rede neural, pode ser difícil interpretar o seu funcionamento. Trata-se de um tipo de funcionamento denominado de “caixa preta”;
- para uma rede apreender corretamente pode chegar a necessitar de milhares de dados históricos, nestes casos, a carência de dados passados relevantes em quantidades suficientes tornam a rede inaplicável.

FIGURA 3 - MODELO NÃO-LINEAR DE UM NEURÔNIO.



FONTE: CARVALHO, 2004.

A literatura sobre processamento digital de imagens e estudos ambientais apresenta importantes trabalhos sobre os esforços de pesquisadores em direção ao desenvolvimento da tecnologia para o monitoramento ambiental. Com o surgimento das imagens de alta resolução espacial, tornou-se necessário disponibilizar novas ferramentas que se estendam além da análise dos *pixels* isoladamente possibilitando um melhor aproveitamento de imagens com resolução espacial abaixo de cinco metros.

Estudos de redes neurais artificiais têm comprovado a utilidade para resolver problemas de classificação multiespectral, quando são utilizados dados de diferentes origens e escalas (RIBEIRO e CENTENO, 2002).

ANDRADE (2003) utilizando imagem de alta resolução do satélite IKONOS II, avaliou a classificação para identificação de objetos na imagem baseando-se em princípios de Redes Neurais Artificiais. Os resultados foram comparados com métodos de classificação convencionais baseados em dados puramente espectrais, para fins de avaliação do ganho obtido, incluindo a forma no processo. A análise da forma provou ser uma poderosa ferramenta para a discriminação de objetos que possuem a mesma aparência espectral.

A comparação entre a aplicação de redes neurais e modelo de regressão utilizando imagens IKONOS II foi feita por RIBEIRO et al. (2005). Estes autores estimaram a profundidade batimétrica adotando como variáveis os valores do contador digital de duas bandas espectrais do IKONOS II (regressão linear) e a posição do *pixel* (ANN do tipo *feedforward*). Os resultados mostraram valores dentro do erro máximo permitido pelas normas náuticas brasileiras.

AKAMINE (2005), avaliou a otimização de algoritmos genéticos para a seleção de ANN's e avaliou a distribuição espacial dos erros das previsões. Embora a utilização de algoritmos genéticos tenha se mostrado eficiente para a relação de uma configuração de

ANN, foram obtidos resultados superiores pelo método gravitacional com dupla restrição. As comparações da distribuição espacial dos erros obtidos pelos dois métodos permitiram observar sub e superestimativas, possibilitando uma melhor escolha para a utilização para planejamento.

Para fazer um mapeamento de plantas aquáticas imersas em reservatório foram utilizadas imagens IKONOS II em multiescala de 8, 16 e 32 metros. Os dados de entrada da ANN foram às cenas multiespectrais do IKONOS II, imagem de textura e uma imagem índice de vegetação. Os resultados mostraram-se adequados para o mapeamento das variações espectrais da água e detecção das infestações por plantas aquáticas nos vários níveis de resolução. A classificação por ANN também foi satisfatória (CRUZ e GALO, 2005).

O uso de ANN para a avaliação do potencial poli-minerálico foi testado por NÓBREGA e FILHO (2003). As análises espaciais por meio de um GIS integraram dados geológicos, geofísicos e geoquímicos para a definição de áreas potenciais para depósitos de minerais fazendo uso de ANN em uma abordagem guiada por dados *data-driven*, produzindo uma boa distribuição de alvos potenciais para os diversos bens minerais.

Todas as alternativas exploradas por BOCANEGRA (2002) ilustraram bem a aplicação de análises com modelos de ANN, sobretudo quando combinados com os GIS. O autor realizou estudos para planejamento estratégico de transporte, destacando que além de permitir a condução de análises de sensibilidade essas técnicas constituem alternativas cruciais para planejamento.

BITTENCOURT (1998), afirma que o método de Redes Neurais Artificiais tem a capacidade de generalização do aprendizado, de maneira a reconhecer instâncias similares que nunca haviam sido treinadas e apresenta bom desempenho em tarefas pouco definidas, onde falta o conhecimento explícito sobre como encontrar uma solução. Baseado nisso, acredita que um dos ramos da Inteligência Artificial (IA), as Redes Neurais Artificiais, podem apresentar bom desempenho para mapeamento do ambiente florestal, onde as coletas de dados de campo são onerosas e trabalhosas.

2.9 REDES NEURAIAS ARTIFICIAIS (ANN) NA ÁREA FLORESTAL

Uma ANN pode ser treinada para resolver problemas de classificação multiespectral. Treinar uma rede significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída (Y) coincida com certo valor desejado para cada vetor de entrada (X). Também se pode fazer um paralelo com o neurônio biológico e dizer que o aprendizado é um ajuste sináptico.

O treinamento pode ser supervisionado ou não supervisionado, sendo que o primeiro exige pares de entrada e de saída para o treinamento e o segundo somente o vetor de entrada.

Os valores de biomassa e carbono precisam ser extraídos das amostras de inventário florestal, da mesma forma que os valores digitais (RGB e NIR) referentes a mesmas amostras. Uma vez pareados, os valores digitais das imagens serão o vetor de entrada (X) e os valores médios de biomassa e carbono para as amostras como vetor de resultado desejado (R). O vetor desejado (R) é comparado ao vetor estimado (Y) e nesta fase é calculado o Erro Quadrático Médio (E.Q.M.). Se estiver abaixo do valor aceitável, finaliza-se o algoritmo e é obtido o resultado, e em caso contrário atualizam-se os pesos e refaz o todo o algoritmo.

Como o treinamento supervisionado necessita de pares de entrada e saída, tais pares são chamados de conjunto de treinamento. Para o treinamento, o vetor de entrada (X), composto com os valores digitais das 4 bandas do satélite IKONOS II (RGB e NIR), é multiplicado por um peso (W) e a saída da rede é calculada e comparada com o vetor de saída esperado (R) que possui para cada valor do vetor (X) seu respectivo valor de biomassa e/ou carbono. Um erro é calculado a partir da diferença e então os pesos são atualizados de acordo com o algoritmo a fim de minimizar esse erro. O processo de treinamento é repetido até que o erro, para o conjunto de vetores de treinamento, alcance um valor limite previamente determinado (E.Q.M.).

O treinamento de uma rede neural artificial (ANN) tem como objetivo reconstruir um vetor original e criar um padrão, segundo (BRAGA et al., 2000) e RIBEIRO (2004). Estes objetivos dependem do tamanho e eficiência do conjunto de treinamento, da arquitetura da rede e da complexidade do problema.

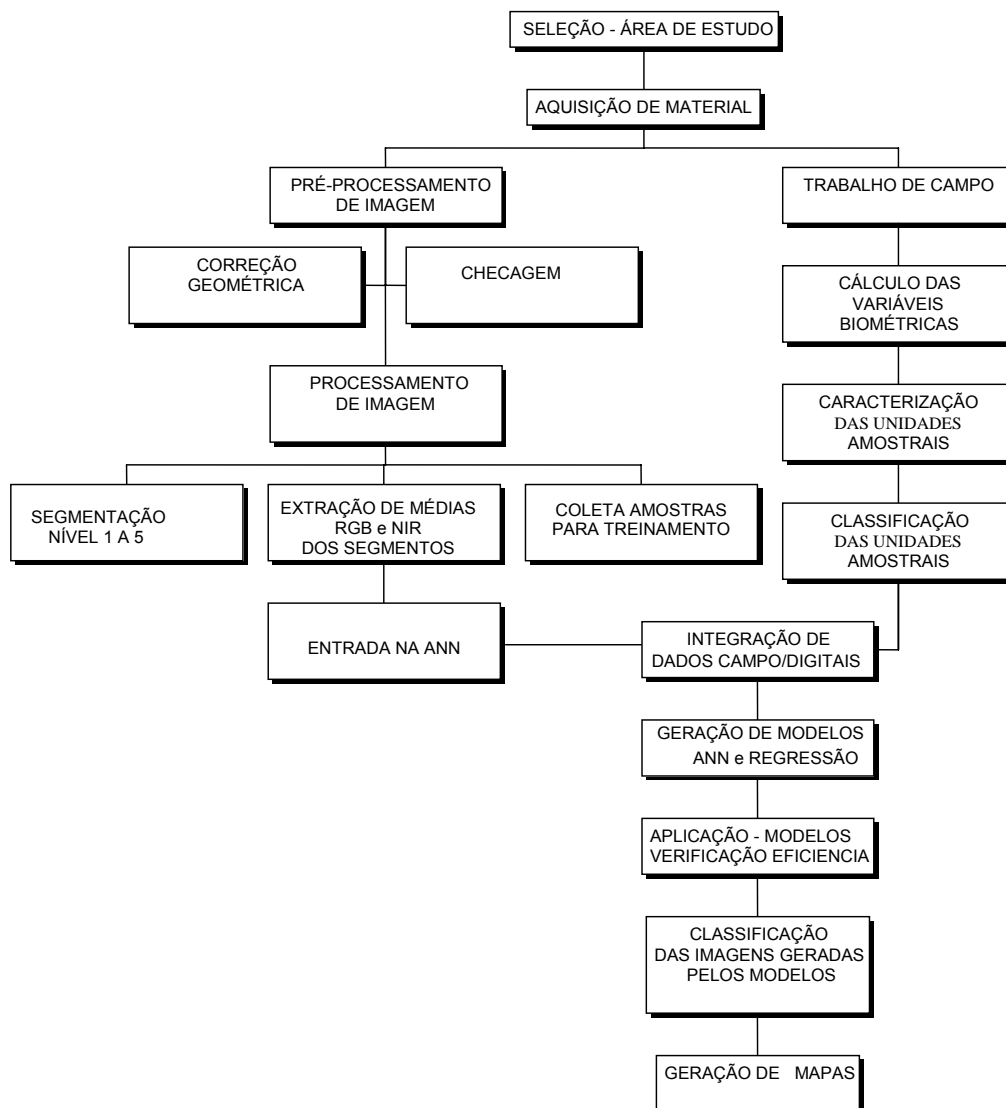
O número de neurônios de saída é fixo em um, pois se considera uma saída exclusiva (biomassa e ou Carbono) e não binária para a rede. Assim, cada neurônio de saída representa um valor gerado pela multiplicação dos pesos da matriz pelos níveis de cinza da imagem.

Durante a etapa de reconhecimento, cada *pixel* das áreas amostrais é fornecido à rede e aquele neurônio de saída cujo valor for maior ou igual a zero é o indicador da classe a qual o *pixel* pertence. Durante a fase de reconhecimento, a rede gera um arquivo com o valor de biomassa ou carbono de cada um dos valores médios de níveis de cinza ou valor digital de segmentos das áreas amostra.

3 METODOLOGIA

A seqüência metodológica adotada é sumarizada no fluxograma de procedimentos realizados, apresentados na Figura 04.

FIGURA 04 - FLUXOGRAMA DA METODOLOGIA EMPREGADA.

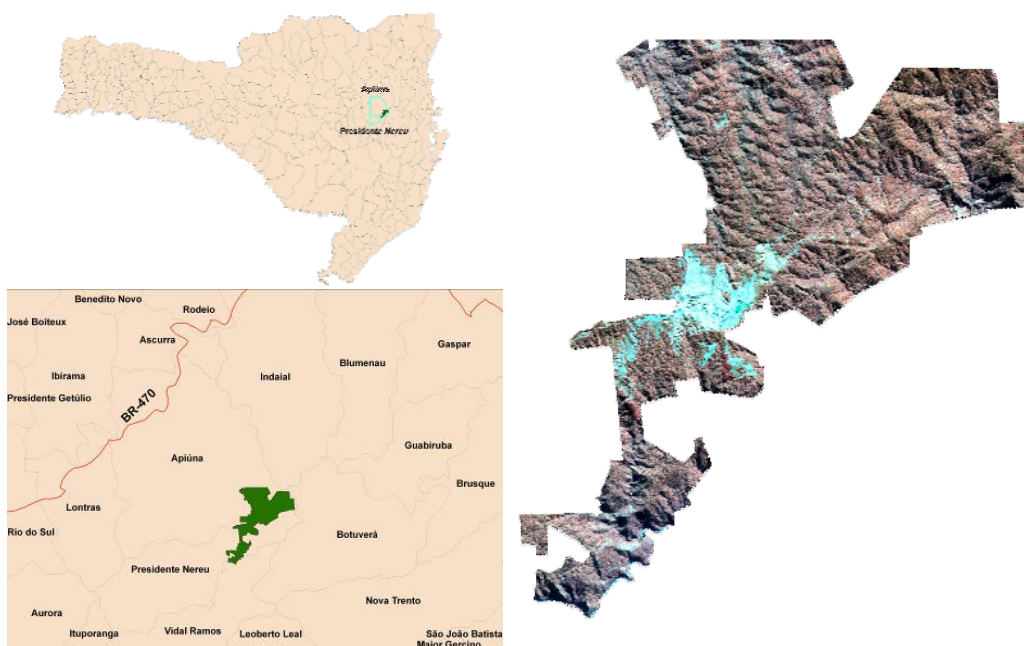


3.1 DESCRIÇÃO DA ÁREA

3.1.1 Localização

As áreas florestais estudadas localizam-se entre os paralelos 27° 08' 34" e 27° 15' 37" latitude sul, e entre os meridianos 49° 11' 57" e 49° 17' 28" longitude oeste de Greenwich, nos municípios de Apiúna e Presidente Nereu, Estado de Santa Catarina, como pode ser observado na Figura 05. Compostos pelo baixo, médio e alto vale do Rio Itajaí e compreendendo uma área total de 3799,2 hectares. A área é composta por seis fazendas: Agrião, Estragão, Itajaí-Mirim, Jundiá, Sabiá e Tranqueira. As fazendas Agrião, Itajaí-Mirim e Sabiá pertencem ao município de Presidente Nereu, enquanto que as fazendas Estragão, Jundiá e Tranqueira, pertencem ao município de Apiúna.

FIGURA 05 – LOCALIZAÇÃO DA ÁREA DE ESTUDO.



3.1.2 Clima

Segundo a nova classificação, proposta por BRAGA e GHELLRE (1999), o Médio e Baixo Vale do Itajaí pertencem ao Tipo 1A, caracterizado por um clima subquente, com o mês mais frio com temperatura média entre 15 °C e 18 °C, superúmido (sem seca) do tipo climático Subtropical 1. O Alto Vale do Itajaí é caracterizado pelo Tipo 2A, mesotérmico

brando superúmido (sem seca) do tipo climático Temperado 2, com o mês mais frio apresentando uma temperatura média entre 13 °C e 15 °C. A temperatura no vale do Rio Itajaí-Mirim apresenta períodos mais frios, possui mínimas de -5 °C e, nos meses mais quentes, temperaturas máximas superiores acima de 36 °C, sendo a média anual entre 21 °C a 25 °C

A precipitação média anual varia entre 1400 mm e 1700 mm, com uma estação chuvosa principal no verão (janeiro a março) e uma estação chuvosa secundária na primavera (setembro e outubro). Um período menos chuvoso ocorre no inverno entre abril e agosto.

3.1.3 Geologia e Geomorfologia

A área de estudo abrange os três domínios geológicos existentes no Estado de Santa Catarina: o embasamento catarinense, a bacia sedimentar do Paraná e os sedimentos quaternários recentes (GAPLAN, 1986).

O embasamento catarinense, com rochas metamórficas e magmáticas, inclui o embasamento mais antigo (do Arqueano e Proterozóico Inferior), formado pelo Complexo Granulítico de Santa Catarina, pelo Complexo Tabuleiro e pelo Complexo Metamórfico Brusque, que ocorrem na parte Sul das serras litorâneas entre a Serra do Itajaí e a Serra do Tijucas e também ao norte do Rio Itajaí (Complexo Granulítico).

O embasamento abrange ainda as rochas areníticas e conglomeradas das Formações Gaspar e Campo Alegre (Grupo Itajaí), numa faixa larga entre Ilhota e Ibirama, e os granitos da Suíte Intrusiva Subida na localidade Subida (em Apiúna e Lontras) e da Suíte Guabiruba e Valsungana, no vale do Itajaí-Mirim. As rochas sedimentares da bacia do Paraná datam do paleozóico (Formações Mafra, Rio do Sul e Rio Bonito) e do mesozóico (Botucatu e Serra Geral) e são de origem glacial, marinha e eólica. Entre elas destacam-se os arenitos, argilitos, folhelhos e siltitos, freqüentes no planalto sedimentar do Alto Vale do Itajaí. Este encontra seu limite geográfico ao oeste e ao sudoeste na borda do planalto vulcânico formado pelo derrame basáltico. Os sedimentos quaternários são depósitos fluviais recentes (holocênicos e pleistocênicos), que se encontram nas planícies aluviais dos rios Itajaí-Açu e Itajaí-Mirim, e, em pequena extensão, depósitos marinhos, na região da foz do Itajaí.

Os três domínios geológicos determinam também as três grandes unidades geomorfológicas da bacia do Itajaí: a porção ocidental do planalto dos sedimentos da Bacia

do Paraná, com os altiplanos escalonados com as suas escarpas (Rio do Sul, Laurentino e Presidente Getúlio); a porção oriental das serras litorâneas com fortes contrastes topográficos do embasamento catarinense, com vales profundos encaixados pelos principais cursos d'água e um relevo muito movimentado; as planícies aluviais da zona sedimentar recente com os meandros dos Rios Itajaí-Açu e Mirim (VIBRANS, 2003).

3.1.4 Vegetação

Segundo KLEIN (1978), a vegetação original da bacia do Itajaí é, em sua maior parte, uma densa floresta pluvial tropical, chamada Floresta Ombrófila Densa (VELLOSO *et al.* 1990). Embora localizada em zona de clima subtropical, esta floresta mostra todas as características da floresta pluvial tropical: grande riqueza específica, onde foram encontradas 359 espécies arbóreas e arbustivas, pertencentes a 72 famílias (SEVEGNANI *et al.* 2003).

Em alguns lugares, nas altitudes maiores que 800 metros, essa floresta é interrompida por trechos da floresta dos pinheiros (Floresta Ombrófila Mista) e por campos naturais. Na foz do Itajaí ocorriam naturalmente e, em pequenas áreas, formações pioneiras como o mangue e a restinga.

KLEIN (1978) descreve detalhadamente a flora e a vegetação da bacia do Itajaí. O autor reconhece quatro formações da Floresta Ombrófila Densa, com aspectos e composição de espécies diferentes: a das terras baixas, nas planícies aluviais até uma altitude de 30 metros, onde espécies importantes do seu estrato arbóreo superior são *Callophyllum brasiliense* (olandi), *Clusia criuva* (mangue-de-formiga), *Ficus organensis* (figueira-da-folha-miúda), *Coussapoa microcarpa* (figueira-mata-pau), *Myrsine umbellata* (capororocão) e *Tapirira guianensis* (cupiúva); a submontana, em altitudes entre 30 e 400 metros, que tem como espécies características típicas: *Sloanea guianensis* (laranjeira-do-mato), *Alchornea triplinervea* (tanheiro), *Ocotea catharinensis* (canela-pinho), *Aspidosperma cf. olivaceum* (peroba), *Virola oleifera* (bicuíba), *Myrcia pubipetala* (guaramirim-branco), *Hieronyma alchormeoides* (licurana) e *Talauma ovata* (bagaçu); a montana, entre 400 e 1800 metros, cunhada pela presença de *Duguetia lanceolata* (pindabuna), *Ormosia arborea* (pau-de-santo-inácio), *Ocotea odorifera* (canela-fogo), *Protium kleinii* (almesca), *Copaifera trapezifolia* (pau-óleo) e *Pterocarpus violaceus* (sangueiro) e finalmente a altomontana, localizada acima de 1800 metros de altitude, com a presença marcante de *Podocarpus sellowii* (pinheiro-bravo), *Weinmania pauliniifolia* (gramimunha), *Lamanonia speciosa*

(guaraperê), *Tibouchina kleinii* (quaresmeira), *Prunus brasiliensis* (pêssego-bravo) e *Roupala brasiliensis* (carvalho-vermelho).

3.2 INVENTÁRIO FLORESTAL

3.2.1 Definição da população

A população inventariada possui uma área total de 3799,2 ha, sendo composta por seis fazendas: Fazenda Agrião com 996,5 ha, Fazenda Estragão com 89,5 ha, Fazenda Itajaí-Mirim com 266,6 ha, Fazenda Jundiá com 493,5 ha, Fazenda Sabiá com 1.203,1 ha e Fazenda Tranqueira com 750,0 ha. Destas, a Fazenda Sabiá possui 365,0 ha de áreas com pastagens, e as Fazendas Agrião e Tranqueira possuem de pastagem 110,0 ha, perfazendo, portanto, um total de 3.323,7 ha de área com floresta natural.

3.2.2 Sistema de amostragem

Considerando as condições da área amostrada por meio dos inventários prévios realizados, optou-se pelo Método de Área Fixa, utilizando um Processo de Amostragem Sistemática em Dois Estágios, utilizando amostras alocadas de forma equidistantes, a cada 900 metros, conforme preconiza PÉLLICO NETTO e BRENA (1997).


Essa escolha justifica-se pelo fato de que em um processo sistemático, as unidades de amostra são selecionadas a partir de um esquema rígido e preestabelecido de sistematização, com o propósito de cobrir toda a população, em toda sua extensão, e obter um modelo sistemático simples e uniforme (LOETSCH e HALLER, 1973).

A localização das unidades de amostra é, em geral, mais fácil quando a amostra é sistemática do que quando a amostra é aleatória, uma vez que as unidades são distribuídas segundo a mesma orientação. Em decorrência disso, o tempo gasto em deslocamento para localizar as unidades amostrais é menor e o custo de amostragem é reduzido (PÉLLICO NETTO e BRENA, 1997).

3.2.3 Unidade de amostra

A unidade de amostra utilizada foi de forma retangular, com 30 metros de largura por 90 metros de comprimento, perfazendo uma área de 2700 m², esquematicamente mostrada na Figura 06. Esta forma e dimensão foram utilizadas para contemplar uma área visível e identificável na imagem do satélite IKONOS II, onde a resolução do *pixel* é de 16m², sendo que a área da amostra possui assim um total de 168 *pixels*. Todas as árvores pertencentes à amostra e que possuíam circunferência à 1,30 metros do solo maiores do que 30 cm foram identificadas e medidas.

FIGURA 06 - REPRESENTAÇÃO ESQUEMÁTICA DA UNIDADE DE AMOSTRA.



3.2.4 Determinação do número de amostras

A intensidade de amostragem, em número de unidades necessárias para estimar os parâmetros da população, requerida para atingir o erro de amostragem e a probabilidade desejada, foi calculada com base em dados coletados em inventários florestais prévios pontuais realizados na área do projeto. Inicialmente foram calculados os volumes individuais das árvores amostradas em cada parcela. As estimativas dos volumes de tronco foram obtidas por meio da integração das funções de afilamento, representadas por um polinômio de 5º grau, ajustadas para uma área similar à do projeto, utilizando uma altura do toco de 0,10 metros e a altura total medida em metros. A equação 8 integrada segue:

$$y = 1,2176 - 3,8008 x + 17,3670 x^2 - 44,6880 x^3 + 54,5590 x^4 - 24,7000 x^5 \quad (8)$$

onde:

$$y = d_i/d_{ap};$$

$$x = h_i/h_t;$$

h_i = altura até o ponto de inversão morfológica (altura comercial);

h_t = altura total da árvore;

d_i = diâmetro à altura relativa correspondente;

d_{ap} = diâmetro à altura do peito (medido à 1,30 m do solo).

Após o cálculo dos volumes individuais, os volumes de cada unidade de amostra foram calculados. Baseado nos cálculos dos volumes por unidade de amostra, as estimativas das estatísticas para as unidades de amostras das áreas inventariadas foram calculadas, resultando nos valores apresentados no Quadro 01.

QUADRO 01 - ESTATÍSTICAS DAS PARCELAS DOS INVENTÁRIOS FLORESTAIS PRÉVIOS CONTENDO O NÚMERO DE AMOSTRAS COLETADAS (n), NÚMERO DE AMOSTRAS POTENCIAIS (N), ÁREA TOTAL, VOLUME MÉDIO (m³), VARIÂNCIA (s²), DESVIO PADRÃO (s) E ERRO PADRÃO (s_x).

FAZENDA	n	N	ÁREA (ha)	VOLUME MÉDIO (m ³)	s ²	s	s _x
AGRIÃO	17	862	232,83	31,5986	402,1397	20,053	4,8637
TRANQUEIRA	4	2426	655,02	5,3715	0,1476	0,3841	0,1921
SABIÁ	4	5020	1355,33	5,1050	7,5913	2,7552	1,3776
ESTRADA	5	-	-	10,0276	4,880191	2,2091	0,9879
TOTAL	30	8308	2243,18	20,9740	378,4879	19,454	3,5519

A determinação da intensidade amostral requerida para amostragem sistemática em dois estágios de uma população infinita, pois todas as áreas pré-inventariadas foram consideradas em conjunto, foi realizada com a aplicação da equação 9:

$$n = \frac{Nt_{\alpha}^2s^2}{NE^2 + t_{\alpha}^2s^2} \quad (9)$$

onde:

n = número de amostras;

N = número de amostras potenciais na área;

t = valor tabelado para um nível α de probabilidade;

S² = variância estimada;

E = erro desejado.

Uma vez determinado o número de amostras, as mesmas foram locadas de forma sistemática e eqüidistantes entre si de 900 metros, sobre um mapa reticulado da área, como pode ser visto na Figura 07.

3.2.5 Estabelecimento das unidades de amostra no campo

As unidades de amostra marcadas de forma sistemática no mapa foram localizadas no campo por meio da utilização de um aparelho de GPS (*Global Positioning System*) de navegação, tendo como base as coordenadas UTM de cada unidade amostral previamente determinada. Localizado o ponto inicial, que corresponde ao vértice inferior esquerdo da unidade amostral, efetuou-se a instalação da unidade de amostra.

As unidades de amostra, de 30 metros x 90 metros (2700 m²) de dimensão, foram locadas com orientação SUL/NORTE. Partindo-se do ponto inicial, demarcado pela equipe de campo com taquara pintada de amarelo, marcou-se o lado esquerdo da unidade amostral, com o auxílio de cruzeta, bússola, balizas e trena. O lado esquerdo da unidade amostral foi piqueteado de 30 em 30 metros até completar 90 metros, com taquaras pintadas de amarelo. Os vértices direitos, inferior e superior, distantes 30 metros à direita do início e do fim da linha esquerda da unidade amostral também foram marcados como exposto.

Os dados coletados nas unidades de amostra, para todos os indivíduos presentes na amostra e que tinham circunferência à 1,30 metros do solo ($cap_{1,30m}$) maior do que 30 cm, com exceção dos palmitos para os quais todos os indivíduos encontrados foram medidos, sendo os dados registrados na ficha de campo elaborada para tal fim.

3.2.6 Identificação das espécies

Foi coletado material botânico de quase todas as espécies encontradas, cujas circunferências à 1,30 metros do solo ($cap_{1,30m}$) eram maiores do que 30 cm. Esse material foi o mais completo possível, isto é, sempre que possível foi feita a coleta de material fértil (flores e frutos). A presença desses elementos é dependente da época do ano e nem sempre foi possível encontrá-los simultaneamente. Foram feitas duas ou três amostras de cada material coletado, para evitar perdas de coleta, quando as condições de umidade prejudicam a secagem do material.

As amostras receberam uma numeração própria, que era a mesma da ficha de coleta de dados e a mesma que a identificava no campo. Foram anexados aos exemplares coletados uma ficha descritiva constando a numeração de coleta, data de coleta e local de coleta (unidade amostral). Uma vez acondicionado nas prensas, o material foi deixado secar.

A identificação das espécies encontradas no Inventário Florestal foi realizada por especialistas da Universidade Federal do Paraná, da Universidade Federal do Rio Grande do Sul, da Universidade Federal de Minas Gerais, da Fundação Universidade Regional de Blumenau e do Herbário Barbosa Rodrigues em Itajaí-SC.

3.2.7 Análise da estrutura horizontal da floresta

A determinação da estrutura horizontal da área inventariada implica na quantificação da participação de cada espécie em relação às outras e de sua distribuição espacial para o conjunto de unidades de amostra coletadas, por meio do cálculo da densidade, dominância, freqüência, valor de importância e valor de cobertura de cada espécie, como proposto por LONGHI (1997). A definição e o algoritmo para obtenção de cada uma dessas estimativas foram descritos por DURIGAN (1999) como:

$$DA = n / \text{parcela} \quad (10)$$

$$DR = DA / N * 100 \quad (11)$$

$$FA = \% \text{ unidades em que ocorre dada espécie} \quad (12)$$

$$FR = (FA / \Sigma FA) * 100 \quad (13)$$

$$DoA = g \quad (14)$$

$$DoR = (DoR / G) * 100 \quad (15)$$

$$IVI = DR + FR + DoR \quad (16)$$

$$PI = (DR + FR + DoR) / 3 \quad (17)$$

$$IVC = DR + DoR \quad (18)$$

$$PC = (DR + DoR) / 2 \quad (19)$$

onde:

DA densidade absoluta = é o número de indivíduos de dada espécie por unidade de área;

DR densidade relativa = é o número de indivíduos de dada espécie em relação ao número total de árvores encontradas por unidade de área;

- FA freqüência absoluta = é a porcentagem de parcelas onde ocorre dada espécie;
- FR freqüência relativa = é a freqüência absoluta de dada espécie em relação à freqüência absoluta total;
- Do dominância absoluta = é a área basal da dada espécie por unidade de área;
- DoR dominância relativa = é a razão entre a dominância absoluta e a área basal total por unidade de área;
- I.V.I. é o índice valor de importância;
- P.I. é a porcentagem de importância;
- I.V.C. é o índice valor de cobertura; e
- P.C. é a porcentagem de cobertura.

FIGURA 07 – CARTA IMAGEM DA LOCALIZAÇÃO DAS AMOSTRAS INVENTARIADAS.




3.2.8 Cubagem de árvores

As espécies abatidas para quantificação da biomassa lenhosa acima do solo, selecionadas dentre os indivíduos que melhor representassem a variação diamétrica das mesmas, e que resultaram em 219 árvores de 75 espécies, foram cubadas para obtenção dos volumes e variáveis dendrométricas necessárias para o ajuste das equações alométricas.

Para cada árvore selecionada para o abate foi feita inicialmente a medição e marcação da circunferência (cap), medida a 1,30 metros do solo. A seguir a árvore era abatida e, após a derrubada, foi realizada a medição da altura total e da altura do ponto de inversão morfológica da árvore (também conhecida como altura comercial), esticando-se uma trena até a copa e sobre o tronco da mesma.

O próximo passo foi a marcação dos pontos para a coleta das circunferências, empregando a metodologia proposta por Smalian, que toma medidas de circunferências à alturas relativas ao longo do fuste, até o ponto de inversão morfológica da árvore. A marcação foi realizada em treze posições relativas à altura comercial da árvore, sendo elas 0,0%, 1%, 5%, 10%, 15%, 25%, 35%, 45%, 55%, 65%, 75%, 85% e a 95% dessa altura, bem como foi marcada a posição à 1,30 metros (cap), segundo esquema de cubagem apresentado na Figura 07.

FIGURA 08 - ESQUEMA GENÉRICO PARA CUBAGEM DE UMA ÁRVORE INTEIRA PELO MÉTODO DE SMALIAN, UTILIZANDO COMPRIMENTOS (L) DIFERENTES.



(Fonte : Adaptado de MACHADO e FIGUEIREDO FILHO, 2003)

Com todas as alturas relativas calculadas e marcadas ao longo do fuste da árvore, realizou-se a medição das circunferências nos pontos marcados, bem como foi feita a medição da espessura de casca no ponto considerado.

Os volumes, com e sem casca, de cada árvore medida, foram calculados pelo método de *Smalian*, descrito por MACHADO E FIGUEIREDO FILHO (2003), como segue na Equação 20:

$$\text{Volume} = \left[\left(\frac{g_0 + g_1}{2} \right) \times h_{0,01} \right] + \left[\left(\frac{g_1 + g_2}{2} \right) \times h_{0,05} \right] + \dots + \left[\left(\frac{g_{11} + g_{12}}{2} \right) \times h_{0,95} \right] + v_p \quad (20)$$

onde:

$$g_i = \frac{\pi \cdot d_i^2}{4}$$

$$V_p = \frac{g_{0,95} \cdot h_{1,00}}{3}$$

onde:

g_i = área transversal na altura relativa correspondente;

d_i = diâmetro na altura relativa correspondente;

h_i = comprimento da seção relativa correspondente;

v_p = volume da ponta.

3.2.9 Equações alométricas testadas

A partir dos volumes reais individuais com casca e sem casca, calculados com o uso dos dados obtidos na cubagem das árvores e dos dados dendrométricos coletados durante a cubagem, foram ajustados modelos de equações lineares simples e múltiplas para a obtenção das estimativas volumétricas com e sem casca, e de altura total e comercial, para as espécies folhosas encontradas na área inventariada, bem como para o palmito e para os xaxins. A razão de se estimar equações específicas para o palmito e para os xaxins foi que essas espécies possuem características únicas de fuste, têm grande expressão em termos de quantidade na área inventariada e para permitir que se obtivessem estimativas mais exatas, pelo uso de equações específicas, do que as que se obteriam se fosse utilizada somente uma equação para todas as espécies existentes na área.

Uma vez obtidas as equações, as estimativas dos diferentes parâmetros foram feitas substituindo-se as variáveis independentes da equação pelos valores medidos no campo, para cada árvore, por ocasião do inventário florestal. Dessa forma, a partir do diâmetro à

1,30 metros do solo (dap) medido em cada indivíduo, foi possível estimar a variável dependente desejada, por meio das equações ajustadas para cada situação.

Os modelos testados foram os seguintes:

a) Volume com e sem casca

$$v = b_0 + b_1 \text{dap} \quad (21)$$

$$v = b_0 + b_1 \text{dap} + b_2 \text{dap}^2 \quad (22)$$

$$v = b_0 + b_1 \text{dap}^2 h \quad (23)$$

$$v = b_0 + b_1 \text{dap}^2 + b_2 \text{dap}^2 h + b_3 h \quad (24)$$

$$v = b_0 + b_1 \text{dap} + b_2 \text{dap}^2 + b_3 \text{dap} h + b_4 \text{dap}^2 h + b_5 h \quad (25)$$

$$v = b_0 + b_1 \text{dap} + b_2 \text{dap}^2 + b_3 \text{dap} h + b_4 \text{dap}^2 h \quad (26)$$

$$v = b_0 + b_2 \text{dap}^2 + b_2 \text{dap}^2 h + b_3 \text{dap} h^2 + b_4 h^2 \quad (27)$$

$$\text{Log}(v) = b_0 + b_1 \text{Log}(\text{dap}) \quad (28)$$

$$\text{Log}(v) = b_0 + b_1 \text{Log}(\text{dap}) + b_2 \text{Log}(h) \quad (29)$$

$$\text{Log}(v) = b_0 + b_1 \text{LOG}(\text{dap}^2 h) \quad (30)$$

b) Altura total e comercial

$$h = b_0 + b_1 \text{dap} + b_2 \text{dap}^2 \quad (31)$$

$$h = b_0 + b_1 \text{Ln}(\text{dap}) \quad (32)$$

$$h = \text{dap}^2 / (b_0 + b_1 \text{dap} + b_2 \text{dap}^2) \quad (33)$$

$$\text{Log}(h) = b_0 + b_1 \text{Log}(\text{dap}) \quad (34)$$

$$h = b_0 + b_1 \text{Log}(\text{dap}) \quad (35)$$

onde:

v = volume com ou sem casca em m^3 ;

dap = diâmetro à 1,30 metros do solo (dap) em cm;

h = altura total ou comercial em m.

A seleção das melhores equações foi feita considerando-se as estatísticas Coeficiente de Determinação ajustado ($R^2_{\text{ajust.}}$), Erro Padrão da Estimativa (S_{xy}) e Somatório dos Resíduos. O Coeficiente de Determinação indica o quanto da relação existente entre a variável resposta e as variáveis explicativas foram absorvidas pelo modelo ajustado. Quanto mais próximo de 1 (um) for seu valor, melhor o modelo ajustado. O Erro Padrão da estimativa indica o erro médio que se comete quando se utiliza a equação ajustada para se obter uma estimativa. Quanto mais próximo de zero for seu valor, melhores são as estimativas obtidas. O Somatório dos Resíduos representa a soma das diferenças entre os valores reais utilizados para o ajuste da equação e os valores estimados pelo uso da equação ajustada. Quanto mais próximo de zero for a soma dos resíduos, melhor o modelo

ajustado. Foram escolhidas as equações que apresentaram melhores estimativas para as estatísticas acima descritas.

3.3 BIOMASSA E CARBONO

3.3.1 Quantificação da biomassa da vegetação arbórea

A quantificação da biomassa da vegetação arbórea, aqui entendida como a vegetação acima do solo e que possui um diâmetro à 1,30 metro do solo (dap) maior ou igual a 10 cm, foi realizada pela utilização do método destrutivo, que abate e separa cada indivíduo em diferentes porções, considerando cada árvore como uma unidade amostral.

As espécies abatidas para quantificação da biomassa lenhosa foram selecionadas a partir dos resultados obtidos no inventário florestal realizado na área, tendo como critérios para a seleção as espécies que apresentaram maior frequência e maior índice de valor de importância (I.V.I.). Espécies de alto valor ecológico ou econômico não foram abatidas.

Tendo sido realizada a seleção das espécies a serem medidas, procedeu-se a escolha dos indivíduos a serem abatidos de cada espécie, procurando-se selecionar indivíduos que melhor representassem a variação diamétrica das mesmas. Dessa forma foram selecionadas e abatidas um total de 219 árvores de 75 espécies diferentes, número esse satisfatório para efeito de avaliação da biomassa da vegetação arbórea. Esse número representa 1,64% do número total de indivíduos amostrados no inventário florestal, sendo que foram considerados aspectos de custo e de menor dano ambiental no abate dos indivíduos selecionados.

As árvores abatidas foram cortadas e separadas em porções referentes aos galhos vivos com folhas, galhos mortos, fuste com casca, frutos, flores e a porção denominada miscelânea (material que não se enquadrava em nenhuma das classes anteriores). Os componentes maiores da biomassa (fuste e galhos grossos), após serem separados em porções menores, foram pesados no campo com balança de braço, enquanto que os componentes menores foram pesados em balança mecânica com precisão de 0,1 g, na sede da área inventariada, onde foram acondicionados, identificados e armazenados em sacos de papel.

A determinação da biomassa dos galhos vivos, galhos mortos e miscelânea, foi feita separando-se e pesando-se cada porção. Para a biomassa das folhas, foi tomada e pesada uma segunda amostra menor de galhos com folhas. A seguir foram retiradas e pesadas

todas as folhas dessa amostra, e com os pesos resultantes foi possível determinar uma razão entre o peso das folhas e o peso dos galhos vivos com folhas, permitindo a obtenção do peso total da biomassa das folhas pelo uso da razão encontrada.

Para a determinação do teor de umidade de cada componente procedeu-se de maneira diferenciada. Na porção relativa ao fuste, que compreende a madeira e a casca, foram retirados dois discos do tronco da árvore, o primeiro à 50 cm de altura do solo e o segundo 50 cm abaixo do ponto de inversão morfológica (altura comercial). As porções referentes à casca e ao lenho dos discos amostrados foram pesados separadamente, resultando uma razão entre o peso da casca sobre o peso do lenho, que foi utilizada como fator de conversão do peso da casca da árvore inteira.

Amostras menores de fuste, casca, galhos vivos, galhos mortos, folhas e miscelânea foram feitas a partir do material coletado, sendo a seguir devidamente pesadas, e enviadas ao laboratório para a determinação do peso seco de cada componente, a fim de que fosse possível a determinação do teor de umidade de cada porção das árvores amostradas.

Para todas as amostras coletadas, foi retirado material para a determinação do teor de carbono existente, por meio de análises laboratoriais, em cada porção amostrada das árvores abatidas.

3.3.2 Determinação do teor de umidade e teor de carbono

Os diferentes tipos de amostras coletadas, que contemplam o tronco, a casca, os galhos vivos, os galhos mortos, as folhas, a miscelânea e a vegetação do sub-bosque, foram acondicionados em sacos de papel, identificados e enviados ao Laboratório de Ecologia Florestal da Universidade Federal de Santa Maria. Em laboratório essas amostras foram secas em estufa de renovação e circulação de ar, a uma temperatura constante de 75°C até atingir o peso constante, para posterior determinação dos pesos secos e preparação para as análises químicas para a obtenção dos teores de carbono. As análises do teor de carbono, nos diferentes tipos de amostras, foram executadas de acordo com o método WALKLEY-BLACK, com calor externo, proposto por TEDESCO et al. (1995).

3.3.3 Obtenção da biomassa e teores de carbono

Com base nos dados relativos a biomassa verde e teores de umidade, para cada componente amostrado nas árvores abatidas, foram calculados as quantidades de biomassa, pelo uso da equação 36:

$$BS = BV \cdot (1-U) \quad (36)$$

onde:

BS = biomassa (kg);

BV = biomassa verde (kg);

U = teor de umidade (%).

Após a obtenção da biomassa, procederam-se os cálculos relativos à quantidade de carbono existente em cada componente para cada espécie, bem como em cada compartimento do ecossistema, utilizando-se para tanto a equação 37:

$$CARB = BS \cdot TC \quad (37)$$

onde:

CARB = quantidade de carbono (kg);

BS = biomassa (kg);

TC = teor de carbono (g kg^{-1}).

3.3.4 Equações de biomassa testadas

Tendo obtido os pesos em kg, de cada um dos componentes para as 219 árvores abatidas, para determinação da biomassa verde e posterior transformação em biomassa e de posse dos dados dendrométricos obtidos durante a cubagem das mesmas árvores, foram ajustados modelos de equações lineares simples e múltiplas para a obtenção das estimativas das quantidades de biomassa para as espécies folhosas encontradas na área inventariada, bem como para o palmito e os xaxins, separadamente, do mesmo modo e pela mesma razão que foram estimados volumes.

A seleção das melhores equações foi feita considerando-se as estatísticas coeficiente de determinação ($R^2_{\text{ajust.}}$), erro padrão da estimativa (S_{xy}) e somatório dos resíduos.

Os modelos testados foram os seguintes:

$$BS = b_0 + b_1 d + b_2 d^2 \quad (38)$$

$$BS = b_0 + b_1 d^2 h \quad (39)$$

$$BS = b_0 + b_1 d^2 + b_2 d^2 h + \quad (40)$$

$$\text{Log}(BS) = b_0 + b_1 \text{Log}(d) \quad (41)$$

$$\text{Log}(BS) = b_0 + b_1 \text{Log}(d) + b_2 \text{Log}(h) \quad (42)$$

$$\text{Log}(BS) = b_0 + b_1 \text{LOG}(d^2 h) \quad (43)$$

onde:

BS = Quantidade de biomassa em kg;

d = diâmetro à 1,30 metros do solo (DAP) em cm;

h = altura total em m.

A estimativa da quantidade de biomassa de cada indivíduo medido nas amostras medidas por ocasião do inventário florestal foi feita calculando-se a altura total da árvore em função de seu diâmetro medido à 1,30 metros do solo (dap), e, uma vez obtida a altura total, a biomassa foi determinada em função dessa altura total estimada e do diâmetro medido.


3.4 IMAGENS ORBITAIS

No presente não foram efetuadas nenhuma das correções normalmente feitas em imagens de satélite dado que só foi utilizada a imagem de um período. Tal procedimento baseia-se no fato de que somente para estudos multitemporais e de correlação de variáveis biofísicas é importante eliminar fatores que possam influenciar nos valores de números digitais, como por exemplo, os efeitos atmosféricos. Segundo HUANG et al. (2002), BARBOSA (2006) e MAFFRA (2004) existem três formas de se normalizar os impactos da atmosfera e da iluminação. A primeira é por meio de correção atmosférica pelo uso de algoritmos específicos, sendo necessário à realização de trabalhos de campo. A segunda é o *pseudos-invariantes*, que foi a técnica empregada neste trabalho de acordo com CHAVEZ (1996). Neste método utiliza-se um objeto de propriedades espectrais que variam pouco ao longo do tempo, como água profunda, que torna-se a base para a correção de toda a cena. A última opção é a conversão dos valores de números digitais para reflectância (MAFFRA, 2004). Cabe salientar, no entanto, que estas técnicas são utilizadas para análise temporal e de correlação de variáveis biofísicas, que não têm grande influência quando se analisa apenas uma imagem.

A imagem IKONOS II utilizada, com nível “Ortho Geo”, foi adquirida com todas as suas bandas multiespectrais, *Red*, *Green*, *Blue* e Infravermelho (RGB e IV). A resolução espacial utilizada nesta pesquisa foi de 4 m, e a localização de precisão em torno de 15 m. A imagem foi entregue em formato digital (CD), com extensão “* tiff” - 11 bits. A imagem estava georeferenciada, porém não ortoretificada. Os dados da coleta são apresentados na Figura 09.

A fim de realizar a ortoretificação, foi adquirido o modelo geométrico na forma de coeficientes numéricos (RPC - *Rational Polynomial Coefficients*) para realizar a ortoretificação da imagem, assim como pontos de campo coletados com GPS topográfico, Modelo Digital do Terreno (MDT) da área de estudo construído com a correção e edição das cartas topográficas do IBGE 1:50.000. Os RPC, ou coordenadas de processamento rápido, combinam uma grande quantidade de dados de entrada para tentar o ajuste mais correto em relação ao posicionamento na terra.

FIGURA 09 - CARACTERÍSTICAS DA IMAGENS IKONOS II, APIUNA-SC.



3.4.1 Ortoretificação das imagens orbitais

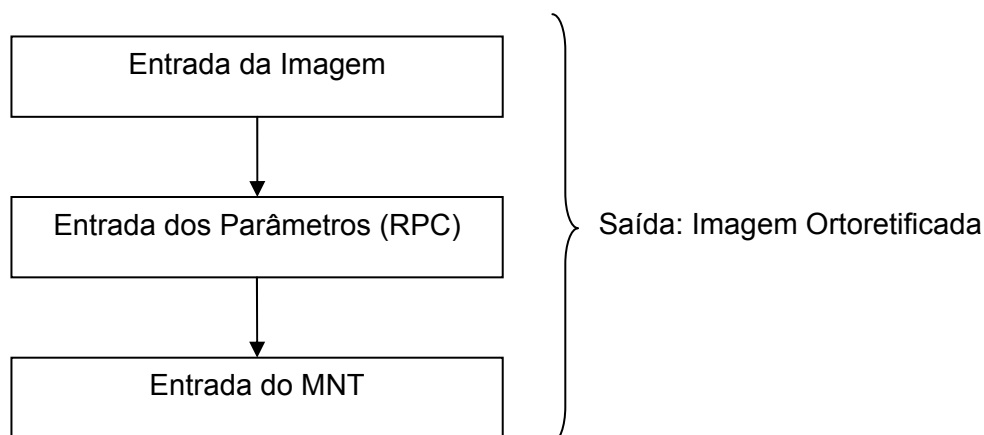
O processo de ortoretificação das imagens IKONOS II é rápido e simples quando são utilizados os coeficientes racionais polinomiais repassados pela empresa concessionária das imagens, possuindo uma seqüência bastante curta, como pode ser observado na Figura 10.

Os modelos RPC relacionam as coordenadas objetos dos pontos (X,Y,Z) para as coordenadas do *pixel* da imagem (r,c). A utilização dos 5 pontos coletados em campo com GPS topográfico fundamentou a avaliação da imagem gerada. A razão dos polinômios neste método é definida de forma direta (XU, 2004 e PEDRO, 2005).

O Datum horizontal da imagem e dos parâmetros de calibração do sensor foram coletados em WGS84. Por este motivo optou-se em transformar a imagem do Modelo Numérico do Terreno (MNT) também para WGS84, o que foi realizado pelo programa *ENVI 4.1*. Após o processo a imagem ortoretificada foi transformada para SAD69.

Todo o processo de ortoretificação foi realizado individualmente para todas as bandas. A tela de definição dos parâmetros da ortoretificação é apresentada na Figura 11. Desta forma, após o processamento da ortoretificação, foi realizada a montagem da composição colorida. Todo o processo foi salvo no programa *ENVI 4.1* em formato “*.tiff”, para posteriormente ser importado pelo programa *Ecognition 4.0*, para a realização da segmentação das imagens.

FIGURA 10 - SEQÜÊNCIA DO PROCESSO DE ORTORETIFICAÇÃO NO SOFTWARE *ENVI 4.1*



A formulação matemática da equação 44 é dada por:

$$\begin{aligned}
 r_n &= \frac{\sum_{i=0}^{m=1} \sum_{j=0}^{m=2} \sum_{k=0}^{m=3} a_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^{m=1} \sum_{j=0}^{m=2} \sum_{k=0}^{m=3} b_{ijk} X_n^i Y_n^j Z_n^k} \\
 c_n &= \frac{\sum_{i=0}^{m=1} \sum_{j=0}^{m=2} \sum_{k=0}^{m=3} c_{ijk} X_n^i Y_n^j Z_n^k}{\sum_{i=0}^{m=1} \sum_{j=0}^{m=2} \sum_{k=0}^{m=3} d_{ijk} X_n^i Y_n^j Z_n^k}
 \end{aligned} \tag{44}$$

onde:

- r_n e c_n - linhas e colunas dos *pixel* no espaço imagem;
- X_n , Y_n e Z_n - coordenadas no espaço do terreno;
- a_{ijk} , b_{ijk} , c_{ijk} e d_{ijk} - coeficientes polinomiais racionais.

A imagem IKONOS II adquirida é a única disponível para a área de estudo no período e a banda pancromática não foi utilizada. Os equipamentos complementares foram um GPS (Sistema de Posicionamento Global) de navegação, utilizado para georeferenciar as parcelas do inventário. Um GPS topográfico utilizado para medir as amostras de verificação, com solução de processamento por código da portadora com correção diferencial obtida em pós-processamento utilizando a técnica baseada em suavização do código através da portadora, com precisão sub-métrica para todos os pontos coletados.

A data da imagem e do trabalho de campo foi compatibilizada para que a resposta espectral da vegetação seja o mais próximo possível dos dados obtidos pelo inventário. A data de coleta da imagem, e de agosto de 2004, e o período em que se realizou o levantamento da biomassa foram de junho a agosto do mesmo ano.

FIGURA 11 - CARACTERÍSTICAS DA ORTORETIFICAÇÃO.

3.4.2 Avaliação das Ortoimagens Geradas

Para verificação da eficiência do modelo utilizado, empregou-se o erro quadrático (e) e o Erro Médio Quadrático (R.M.S.E.), que possui valor diretamente proporcional ao quadrado dos valores do primeiro, como segue na equação 45 e 46:

$$e = \sqrt{\Delta E^2 + \Delta N^2} \quad (45)$$

$$RMSE = \sqrt{\frac{\sum e^2}{n}} \quad (46)$$

onde:

- e - é o erro quadrático;
- ΔE - é a discrepância no eixo Leste;

- ΔN - é a discrepância no eixo (Norte);
 n - é o número de pontos.

Como demonstram essas equações, quanto maior o valor de e maior será o RMS, e conseqüentemente, menor a confiabilidade do modelo.

3.4.3 Segmentação

Com o objetivo de diminuir a variação dos valores de entrada (menor variância), foi executada a segmentação que gerou entradas uniformes uma vez que os valores de biomassa representam porções homogêneas do espaço físico, com características semelhantes.

A seleção pelo método de segmentação foi baseada em aspectos práticos de implementação da metodologia de utilização do programa *eCognition 4.0*, que executa segmentação multi-resolução, baseada na forma e nos valores digitais dos objetos. O critério de semelhança é usado para definir a uniformidade dos segmentos.

Os parâmetros de segmentação foram definidos fixando-se o fator de escala da segmentação das imagens para os valores de dez (10), vinte (20), trinta (30), quarenta (40) e cinquenta (50). Na primeira segmentação a cor e a forma foram definidos com os valores de 0,7 e 0,3, e de 0,5 para os outros níveis, uma vez que o interesse da segmentação deve ocorrer em relação aos níveis digitais considerando também a forma. O fato de se atribuir mesma importância a cor e a forma se deve, ao relevo da área de estudo, rede de drenagem marcante, e áreas de campo e estradas que auxiliaram no agrupamento de segmentos semelhantes, separando os segmentos de floresta nativa.

O fator de forma teve seus valores de compactidade definidos como 0,4 e suavidade como 0,6. O valor da suavidade é maior do que o da compactidade devido as fisionomias serem pouco compactas (talvez que apresentam a estrutura da serra geral).

Foi utilizado como padrão de segmentação o fator 50 para escala e valores 0,5 para a cor, 0,5 para a forma e, para essa, 0,6 de suavidade e 0,4 de compactidade, pois foi o resultado que melhor agrupa os elementos de interesse das imagens. As variáveis utilizadas na etapa seguinte, utilizadas para representar os segmentos na quantificação da biomassa e na quantidade de carbono foram as médias dos valores para cada uma das imagens de entrada, a serem processadas na ANN, que foi a razão entre número de *pixels* que formam o objeto e o brilho destes mesmos *pixels*.

3.5 REDES NEURAIS ARTIFICIAIS (ANN)

As Redes Neurais Artificiais (ANN) podem ser treinadas para resolver problemas de classificação multiespectral. Treinar uma rede significa ajustar a sua matriz de pesos (W) de forma que o vetor de saída (Y) coincida com um certo valor desejado para cada vetor de entrada (X). Também se pode fazer um paralelo com o neurônio biológico e dizer que o aprendizado é um ajuste sináptico. O treinamento pode ser supervisionado ou não supervisionado, sendo que o primeiro exige pares de entrada e de saída para o treinamento e o segundo somente o vetor de entrada.

Como o treinamento supervisionado necessita de pares de entrada e saída, tais pares são chamados de conjunto de treinamento. Para o treinamento, o vetor de entrada é aplicado, a saída da rede é calculada e comparada com o vetor de saída esperado, e um erro é calculado a partir da diferença. A seguir os pesos são atualizados de acordo com o algoritmo a fim de minimizar esse erro. O processo de treinamento é repetido até que o erro, para o conjunto de vetores de treinamento, alcance um valor limite previamente determinado.

O treinamento de uma ANN tem como objetivo reconstruir um vetor original e criar um padrão (BRAGA et. al., 2000). Esse objetivo depende do tamanho e eficiência do conjunto de treinamento, da arquitetura da rede e da complexidade do problema, motivos que conduziram a realização da segmentação multi-resolução.

A classificação da área de estudo pela Rede Neural Multinível com *BackPropagation*, foi realizada com o uso de um conjunto de treinamento, extraído das amostras do inventário florestal. As mesmas amostras foram selecionadas para o ajustamento dos modelos de regressão linear e esse procedimento permitiu que os resultados de ambos os métodos pudessem ser comparados.

A Tabela 04 apresenta o Erro Quadrático Médio (E.Q.M.) e os parâmetros definidos em cada uma das classificações realizadas pela ANN.

O número de neurônios de recepção equivale ao número de bandas consideradas na classificação. A primeira camada de entrada foi testada com os valores multiplicada por 3, 8 e 16 respectivamente, pois para cada neurônio na camada de recepção é atribuído o valor de nível de cinza de cada *pixel*, do conjunto de treinamento, em cada banda.

O número de neurônios de saída é fixo em um, pois foi considerada uma saída exclusiva (biomassa ou carbono) e não binária para a rede. Assim, cada neurônio de saída representa um valor gerado pela multiplicação dos pesos da matriz pelos níveis de cinza da imagem.

TABELA 04 - LIMIARES DE ERRO E PARÂMETROS TESTADOS NA REDE NEURAL ARTIFICIAL.

ERRO QUADRÁTICO MÉDIO	CAMADA DE ENTRADA	CAMADA DE SAÍDA
0,01	12	4
0,01	24	8
0,01	48	16
0,001	12	4
0,001	24	8
0,001	48	16
0,005	12	4
0,005	24	8
0,005	48	16
0,0001	12	4
0,0001	24	8
0,0001	48	16

Durante a etapa de reconhecimento, cada *pixel* das áreas amostrais foi fornecido à rede e àquele neurônio de saída cujo valor fosse maior ou igual a zero, constituindo-se no indicador da classe a qual o *pixel* pertence. A função de ativação utilizada foi a tangente hiperbólica e, em função disto, as entradas foram normalizadas entre 0 e 1 e os pesos inicializados neste mesmo intervalo.

Durante a fase de reconhecimento, a rede gera um arquivo com o valor de biomassa ou carbono de cada um dos valores médios de níveis de cinza ou valor digital de segmentos das áreas amostra. O coeficiente de aprendizado, o número de iterações e a taxa de momento foram fixados em 0.9, 50000 e 0.01 respectivamente, para todos os testes realizados. O algoritmo e sua descrição são apresentados a seguir em tópico específico, segundo a metodologia descrita por TODT (1998). A listagem do programa desenvolvido no programa MATLAB é apresentada no Anexo 03.

A simulação foi realizada pela multiplicação dos pesos calculados na fase de treinamento, e é descrita no Anexo 03 (simulação).

3.6 ALGORITMO DE REDES NEURAIS ARTIFICIAIS (ANN)

Para o início do processo de aprendizado da ANN é necessário selecionar amostras que possuam os padrões (conjunto de treinamento) a serem aprendidos e as saídas desejadas correspondentes. As amostras deverão contemplar as variações da área de estudo em número suficiente, devendo ser selecionadas para cada padrão. Em um segundo momento, os pesos, que representam as conexões entre neurônios, devem ser inicializados com valores pequenos ($\pm 0,5$), que são aleatórios.

Outro requisito importante é a determinação de qual função de ativação será utilizada na rede. Em geral, a função tangente hiperbólica apresenta melhores resultados para o aprendizado, pois converge mais rapidamente. Porém, ao se trabalhar com esta função é necessário normalizar as entradas da rede para o intervalo -1 a 1, antes da propagação. Desta forma, as entradas e saídas da rede ficam compatíveis, ocupando o mesmo espaço vetorial. Caso a escolha seja a função sigmoideal é necessário normalizar as entradas para o intervalo 0 a 1 (WANDRESEN, 2004).

Em função da maioria dos trabalhos práticos aplicados a mapeamento serem não linearmente separáveis, a rede *perceptron* multicamada alimentada adiante (*feedforward*) utilizando o algoritmo de aprendizagem de retro-propagação (*BackPropagation*) gerou muito interesse pela habilidade em aprender padrões não linearmente separáveis, tendo assim uso generalizado (BOTELHO, 2004).

Segundo RIBEIRO (2004), o algoritmo *BackPropagation* baseia-se no Gradiente Descendente do erro, ou seja, na minimização do Erro Quadrático Médio (E.Q.M.). Dependendo dos pesos iniciais, do número de neurônios intermediários e do coeficiente de aprendizado, pode acontecer da ANN atingir um erro mínimo. Se este mínimo local significar um erro médio quadrado (EQM) aceitável, o aprendizado está realizado, caso contrário é necessário continuar o treinamento.

Com duas fases o método de retropropagação gera o vetor de saída, que é obtido por intermédio do processamento dos dados de entrada e treinamento, onde se determina o conjunto de pesos. Nesta fase é realizada a comparação do vetor real com o calculado com o auxílio dos pesos ajustados. Na segunda fase são efetuados os ajustes nos pesos a partir da comparação do valor desejado e do calculado pela rede a cada iteração, iniciando-se na camada de saída até a primeira camada escondida (pensamento), por isso retro-propagação (*BackPropagation*) (GONZALEZ e WOODS, 1998).

Para compreender o processo de aprendizado da ANN podemos considerar X como um vetor de entrada que representa um padrão; W como o peso de conexão entre os neurônios da camada escondida e o neurônio de camada de entrada; V ou E.Q.M. (Erro Quadrático Médio) como sendo a comparação entre a saída desejada (O) e Y a saída obtida pela rede. Visando um melhor entedimento da aplicação do algoritmo de ANN, foi elaborado o fluxograma (Figura 12), que descreve o processo síntese de cálculos dos pesos e dos resultados parciais e finais para a variável desejada.

Para exemplificar cada passo do fluxograma, são descritas as equações e as variáveis do algoritmo de *BackPropagation*. Para começar o processo é necessário iniciar os pesos e os parâmetros da rede (coeficiente de aprendizado, parâmetro do momento),

aplicando o vetor de entrada X à ANN e calculando os valores internos de transferência dos neurônios da camada escondida, segundo a equação 47:

$$S_j^H = \sum_{j=1}^h \sum_{k=1}^m W_{ij}^H * X_i + B_j^H \quad (47)$$

onde:

S_j^H - valores internos de transferência dos neurônios na camada H;

E - número de entradas da arquitetura da rede;

h - número de neurônio da primeira camada oculta;

H - primeira camada oculta;

W_{ij}^H - peso da conexão entre a entrada E e a camada escondida H;

X_i - vetor com as variáveis de entrada;

B_j^H - valor de limiar, conhecido por tendência ou *bias*.

O *bias* é um neurônio com entrada constante em “1” e cada neurônio da camada intermediária e da camada de saída possui o seu próprio *bias*.

O próximo passo é ativar os neurônios da camada escondida (H), segundo a equação 48:

$$Y_j^H = \frac{1}{1 + e^{-S_j^H}} \quad (48)$$

Em geral utiliza-se a função sigmoidal ou a função tangente hiperbólica. Para a função sigmoidal, os neurônios geram valores de ativação dentro do intervalo -1 a 1, calculando os valores internos S_k^o para os neurônios (m) da camada de saída (o) tem-se a equação 49:

$$S_k^o = \sum_{j=1}^h \sum_{k=1}^m W_{jk}^o * Y_j^H + B_k^o \quad (49)$$

onde:

S_k^o - valores internos transferência dos neurônios na camada O;

h - número entradas da arquitetura da rede;

m - número de neurônios na segunda camada escondida O;

W_{jk}^o - peso da conexão entre a camada escondida H e a camada O;

Y_j^H - vetor com as variáveis de entradas ativadas da camada H;

B_k^o - valor de limiar, conhecido por *bias*, para a camada O.

O próximo passo é ativar os neurônios da camada escondida (O):

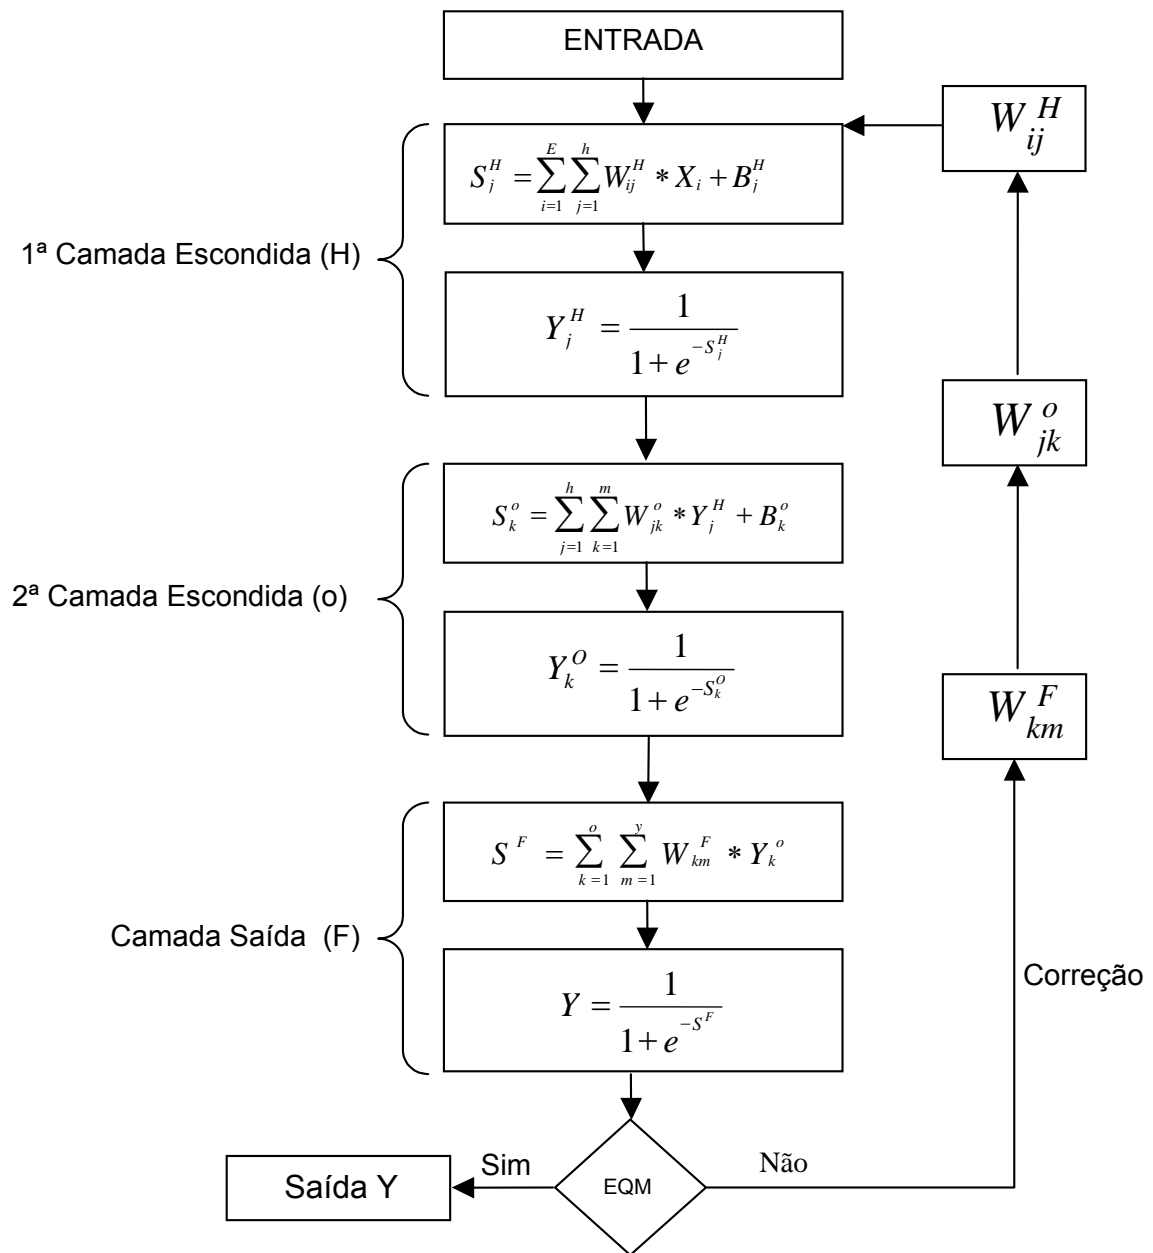
$$Y_k^o = \frac{1}{1 + e^{-S_k^o}} \quad (50)$$

onde:

Y_k^o - função de ativação, entrada da próxima camada;

S_k^o - valores internos de transferência dos neurônios na camada O.

FIGURA 12 - FLUXOGRAMA DOS PROCEDIMENTOS DE CÁLCULOS.



onde:

Y_j^H - função de ativação, entrada da próxima camada;

S_j^H - valores internos de transferência dos neurônios na camada H;

Em função do exemplo demonstrado possuir apenas duas camadas, a próxima etapa é o cálculo dos valores estimados que quando comparados às saídas desejadas, torna-se a última fase de propagação, com pode ser visto na equação 51:

$$S^F = \sum_{k=1}^o \sum_{m=1}^y W_{km}^F * Y_k^o \quad (51)$$

onde:

S^F - vetor de transferência da saída calculada da camada F;

W_{km}^F - peso da conexão entre a camada escondida O e a camada de saída F;

Y_k^o - vetor de entrada de ativação dos neurônios da camada O;

O próximo passo é ativar os neurônios da camada saída (F) segundo a equação 51:

$$Y = \frac{1}{1 + e^{-S^F}} \quad (52)$$

onde:

S^F - função de transferência, para a camada de saída;

Y - valores estimados;

O processo é encerrado quando o Erro Quadrático Médio (E.Q.M.) do padrão Y, for menor ou igual a um erro mínimo previamente estipulado ou ao se atingir um número determinado de iterações (TODT, 1998). O E.Q.M. é calculado pelas equações:

$$EQM = \frac{1}{Y} \sum_{m=1}^y Ep \quad (53)$$

sendo Ep o erro instantâneo obtido ao apresentar o padrão Xp na entrada da rede. Este erro é dado pela equação 53:

$$E_p = \frac{1}{2} \sum_{k=1}^M (Y_{pk} - O_{pk})^2 \quad (54)$$

onde:

Y_{pk} - Vetor de entrada com valores reais;

O_{pk} - Vetor de saída com valores calculados;

Como no gradiente descendente padrão a taxa de aprendizado é constante durante o treinamento, pode ocorrer um processamento muito lento se a taxa de aprendizado é pequena, ou o algoritmo pode se tornar instável, se a taxa fixada é muito alta. Com base nisso, uma solução para se evitar as duas situações é permitir que a taxa de aprendizado seja modificada durante o processo de treinamento (RIBEIRO, 2004).

Primeiro fixa-se uma taxa de aprendizado e a saída inicial da rede. Os erros são calculados e, a cada iteração, novos pesos e limiares são encontrados e utilizando-se a taxa de aprendizado corrente e as novas saídas, os pesos são novamente atualizados. Se o novo erro (calculado) exceder o valor do erro prévio, esses pesos e limiares são descartados, caso contrário os pesos e limiares são conservados. Se o novo erro é menor que o antigo, a taxa de aprendizado é aumentada (TODT, 1998).

Pode-se utilizar no processamento do algoritmo *Backpropagation* outra variação chamada de "Momentum". O "Momentum" é a taxa que prevê os efeitos das mudanças dos pesos no ajustamento em questão, estabelecendo a direção para a minimização mais rápida do erro (JARVIS e STUART, 1996).

O termo "Momentum", que diminui o tempo de convergência tornando o algoritmo mais rápido, é uma constante positiva que permite a ANN responder não só ao gradiente local mas também para a direção recente na superfície de erro (GOSE et al., 1996). Utilizando-se da variação "Momentum", a rede pode permanecer em um mínimo local superficial (MATLAB, 2001).

Ainda devido ao fato da instabilidade da rede e também ao processamento da mesma ocorrer de forma lenta, outra variação do treinamento *Backpropagation* foi desenvolvida por REIDMILLER e BRAWN (1993). Neste caso a atualização feita pela taxa de aprendizado gera um ponto de mínimo local e os pesos podem não ser ajustados a um valor ótimo para o problema. Pode-se então utilizar uma variação do algoritmo "*Backpropagation*" que minimiza esse problema acelerando a convergência esperada da

rede. Essa variação chama-se “*Backpropagation Resilient*”, metodologia utilizada por RIBEIRO (2004).

WANDRESEN (2004) cita que o intuito do treinamento “*Resilient*” (elástico) é eliminar os efeitos de perda de magnitude das derivadas parciais. Somente o sinal da derivada é usado para determinar a direção do ajustamento dos pesos. A magnitude das derivadas não tem efeito sobre o ajustamento dos pesos, isto é, a mudança dos pesos é determinada por ajustamento de valores separados. O ajustamento de cada peso é aumentado por um fator todas as vezes que o desempenho da derivada da função, com respeito aos pesos, tem o mesmo sinal para duas iterações sucessivas. O valor do ajustamento do peso é diminuído por um fator, todas as vezes que a derivada, com respeito aos pesos, muda de sinal na iteração seguinte. Se a derivada é zero, então o valor do gradiente permanece o mesmo. Toda as vezes que os pesos estão oscilando, a mudança dos mesmos será reduzida. Se os pesos continuam a mudar na mesma direção por várias iterações, então sua magnitude do ajuste deles será aumentada (REIDMILLER e BRAWN, 1993).

3.7 ANÁLISE DE REGRESSÃO LINEAR

O cálculo da correlação entre as variáveis biométricas e digitais foi o primeiro passo realizado a fim de determinar o grau de correlação entre os dados. As variáveis digitais empregadas na análise foram os valores digitais da banda 4 (MS-4), da banda 3 (MS-3), da banda 2 (MS-2) e da banda 1 (MS-1).

Os dados obtidos no campo foram relacionados com os das imagens por meio do ajuste de modelos de regressão lineares, que é um procedimento estatístico que visa estabelecer a relação funcional entre duas ou mais variáveis. Na análise de regressão uma variável aleatória y , denominada dependente, é relacionada a uma ou mais variáveis x , chamadas independentes. No presente trabalho as variáveis biomassa arbórea e quantidade de carbono foram consideradas variáveis dependentes e os valores digitais extraídos das imagens IKONOS II foram consideradas como variáveis independentes, segundo metodologia utilizada por WATZLAWICK (2003).

A escolha da melhor equação foi baseada na análise das estatísticas coeficiente de determinação ajustado (R^2_{ajust}), erro padrão da estimativa (s_{xy}), erro padrão da estimativa em porcentagem ($s_{xy}\%$) e na análise dos resíduos. Para a validação do melhor modelo obtido foram separadas cinco amostra dentre as 48 que compunham a base de dados para ajuste das equações testadas.

4 RESULTADOS

Segundo BERTALANFFY (1975), todo modelo é uma abstração, ou representação simplificada, de algum aspecto da realidade. Dessa forma, um modelo espacial de qualquer variável florestal de interesse é uma abstração da dinâmica natural da floresta de onde foram coletados os dados.

Tendo sido definido um determinado objetivo, visando a modelagem de uma característica qualquer de uma floresta, a descoberta dos meios e modos que levem à sua realização requer um especialista de sistemas, para examinar as soluções possíveis e escolher as que prometem ter caráter ótimo com máxima eficiência e mínimo custo numa rede complexa de interações. Isso exige técnicas complicadas e computadores para resolverem problemas que transcendem de muito a capacidade de qualquer matemático individual. Tanto os equipamentos dos computadores (*hardware*) quanto os programas (*software*) da ciência dos sistemas representam novas tecnologias. O uso comum do termo “modelo de representação espacial de uma floresta” geralmente refere-se a um conjunto de procedimentos que permitem representar espacialmente uma variável de interesse sob uma variedade de condições. Para tanto, um modelo de representação espacial de uma floresta pode conter uma série de equações matemáticas, valores numéricos agregados a essas equações, a lógica necessária para unir as equações de modo que tenham significado, o tratamento espacial dos dados e a implementação do modelo em linguagem de computação.

Os procedimentos relativos à realização de um inventário florestal visando a obtenção de estimativas de biomassa e quantidade de carbono armazenado na porção arbórea de uma floresta natural, os cálculos que descrevem sua estrutura horizontal sobre a ótica dessas variáveis, as estatísticas das parcelas medidas, o tratamento das imagens e a apresentação gráfica ou impressa dos resultados obtidos, que permitiram a implementação por meio de mapas de um modelo de representação dessas variáveis para uma floresta natural utilizando o método de Redes Neurais Artificiais, constituem os resultados obtidos no presente trabalho e que são doravante descritos e detalhados.

4.1 INVENTÁRIO FLORESTAL

4.1.1 Intensidade de amostragem

A determinação da intensidade de amostragem necessária para realização do inventário florestal da área de estudo foi feita a partir de volumes existentes, oriundos de inventários florestais prévios realizados na área, e considerou diferentes níveis de erro e de probabilidade. Para a obtenção dos resultados, apresentados no Quadro 02, foi considerada a variável volume, uma vez que não existiam dados disponíveis de biomassa e quantidade de carbono armazenado.

QUADRO 02 - RESULTADOS DE INTENSIDADE AMOSTRAL OBTIDA CONSIDERANDO DIFERENTES NÍVEIS DE ERRO E PROBABILIDADES.

ERRO DESEJADO	PROBABILIDADE DESEJADA	N ₀	N ₁	N ₂
10% da média = 2,10	95% - t _{5%} = 2,04	343	318	318
10% da média = 2,10	90% - t _{10%} = 1,70	241	228	228
10% da média = 2,10	80% - t _{20%} = 1,31	145	144	144
20% da média = 4,19	80% - t _{20%} = 1,31	37	36	36

Diante desses resultados optou-se por realizar 50 amostras de 30 metros de largura por 90 metros de comprimento, perfazendo 2700m² por unidade de amostra. Esse número resultou de um balanço do custo/benefício entre realizar-se 145 amostras para um erro de 10% da média com um nível de 80% de probabilidade, que é em um número muito grande considerando-se o custo para sua realização, ou uma intensidade de amostragem de 37 amostras que permite a obtenção de estimativas com 20% de erro da média para uma probabilidade de 80%. Optou-se por 50 amostras para um erro de 20%, pois esse número assegura uma exatidão maior para o nível de probabilidade desejado (80%), além de levar em conta também que esses parâmetros são os normalmente usados em diversas atividades que envolvem a realização de inventários florestais.

4.1.2 Espécies florestais encontradas na área

Foram encontradas na área inventariada 191 espécies arbóreas, pertencentes a 62 famílias botânicas. As espécies mais freqüentes encontradas pertencem às famílias

Myrtaceae (47%) e Lauraceae (32%). Dentre as espécies encontradas, 50 respondem por 75% do Índice de Valor de Importância.

Quanto ao grupo ecológico ao qual pertencem, 21% são dominantes, 34% são co-dominantes e 33% são dominantes/co-dominantes, evidenciando um estágio intermediário de desenvolvimento da floresta.


A listagem das espécies encontradas, contendo o nome comum em ordem alfabética, o nome científico, a família e o grupo ecológico de cada uma das espécies identificadas, com base nas características dendrométricas e nas exsicatas coletadas, é apresentada no Anexo 04.

4.1.3 Estrutura horizontal da floresta

Os resultados obtidos, e que representam à estrutura horizontal da floresta inventariada, revelam a quantificação da participação de cada espécie em relação às outras e sua distribuição espacial para o conjunto de amostras realizadas na área. Para efeito do cálculo dos índices fitossociológicos, segundo definição da metodologia, a unidade de amostra foi a medida no campo, ou seja, 2700 m².

Foram encontradas árvores mortas em todas as amostras. A espécie mais freqüente foi o xaxim (*Cyathea* spp.), presente em 98% das amostras. Dentre as espécies lenhosas, a canela-fogo (*Ocotea odorifera*) estava presente em 88% das amostras, enquanto que o palmito (*Euterpe edulis*) foi encontrado em 86% das amostras. A Figura 13 mostra as dez espécies mais freqüentes nas amostras coletadas na área.

FIGURA 13 - ESPÉCIES MAIS FREQUENTES NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE AMOSTRAS EM QUE OCORRERAM.



As espécies que apresentaram maior densidade na área estudada, representada pelo número de indivíduos existentes, foram o xaxim (*Cyathea* spp.) com 22% do total de indivíduos, o palmito (*Euterpe edulis*) e o tanheiro (*Alchornea triplinervea*), ambos com 7% de todas as árvores encontradas. Árvores mortas representam 7% do total de árvores medidas. A Figura 14 apresenta as dez espécies com maior densidade na área estudada.

FIGURA 14 - ESPÉCIES COM MAIOR DENSIDADE NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE CADA UMA EM RELAÇÃO AO NÚMERO TOTAL DE INDIVÍDUOS MEDIDOS.



As espécies dominantes na área estudada são o tanheiro (*Alchornea triplinervea*), o xaxim (*Cyathea* spp.) e a canela-fogo (*Ocotea odorifera*), com 10%, 9% e 5% respectivamente, da área basal total de todas as amostras. As árvores mortas contribuíram com 7,9% da área basal total das amostras coletadas. A Figura 15 apresenta as dez espécies dominantes encontradas.

As espécies florestais com maior índice de valor de importância (I.V.I) e índice de valor de cobertura (I.V.C) foram o tanheiro (*Alchornea triplinervea*) com 6,4% de importância e 8,7% de cobertura, o palmito (*Euterpe edulis*) com 3,4% de importância e 4,2% de cobertura e a canela-fogo (*Ocotea odorifera*) com 3,1% de importância e 3,7% de cobertura. Deve ser ressaltado, entretanto, que os xaxins (*Cyathea* spp., *Dicksonia sellowiana* e *Alsophila* spp.) apresentaram os maiores valores de importância e cobertura, uma vez que essas três espécies representam 25% do total de indivíduos medidos. As árvores mortas apresentaram um I.V.I. de 5,7% e um I.V.C. de 7,5%. As Figuras 16 e 17 mostram as dez espécies com os maiores índices de valor de importância e de cobertura encontradas nas amostras medidas.

FIGURA 15 - ESPÉCIES DOMINANTES NA ÁREA ESTUDADA, REPRESENTADAS PELO PERCENTUAL DE ÁREA BASAL CADA UMA EM RELAÇÃO À ÁREA BASAL TOTAL DAS AMOSTRAS MEDIDAS.





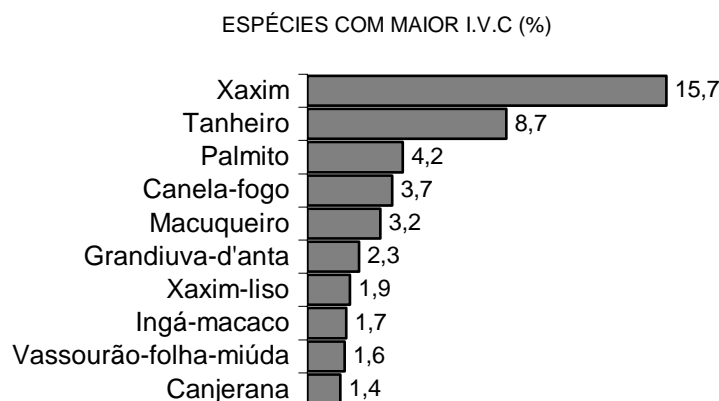
FIGURA 16 - ESPÉCIES COM OS MAIORES ÍNDICES DE VALOR DE IMPORTÂNCIA ENCONTRADAS NA ÁREA ESTUDADA.



4.1.4 Estatísticas por espécies


Os resultados das estatísticas obtidas para todas as espécies encontradas referem-se ao número de árvores por hectare, os diâmetros a 1,30 metro do solo (dap) médio, máximo e mínimo, a área basal em m^2 por hectare e o desvio padrão do dap médio. A área estudada apresentou 1034 árvores por hectare, com um dap médio de 16,0 cm, máximo de 121,6 cm e mínimo de 3,2 cm. O fato do dap mínimo ter sido 3,2 cm e não 10 cm, como foi definido na metodologia, deveu-se ao fato de que todos os palmitos encontrados na área estudada foram considerados e não apenas aqueles cujos diâmetros fossem maiores do que 10 cm, como feito para as demais espécies. A área basal média da área foi $26,3 m^2 ha^{-1}$.

FIGURA 17 - ESPÉCIES COM OS MAIORES ÍNDICES DE VALOR DE COBERTURA ENCONTRADAS NA ÁREA ESTUDADA.



As espécies que apresentaram maior número de árvores foram o xaxim (*Cyathea* spp.) com 240 indivíduos por hectare, o palmito (*Euterpe edulis*) com 71 indivíduos por hectare e o tanheiro (*Alchornea triplinervea*) com 69 indivíduos por hectare. As dez espécies com maior número de indivíduos por ha, encontradas na área estudada, são apresentadas na Figura 18.

FIGURA 18 - ESPÉCIES COM MAIOR NÚMERO DE ÁRVORES POR ha, ENCONTRADAS NA ÁREA ESTUDADA.



Os maiores dap médios pertencem às espécies sacopema (*Sloanea* spp.) com 52,5 cm, tarumã (*Vitex megapotamica*) com 41,4 cm e ao guaraparim (*Vantania compacta*) com 28,7 cm. As dez espécies que apresentaram os maiores diâmetros médios são mostradas na Figura 19.

Os maiores dap encontrados na área inventariada pertencem às espécies sacopema (*Sloanea* spp.), que foi a maior árvore encontrada, com 121,6 cm de dap, ao garuvão (*Ocotea* spp.) com 105,0 cm de dap e a maria-mole (*Phytolacca dioica*) também com 105,0 cm de dap. As dez maiores árvores em dap encontradas são mostradas na Figura 20.

FIGURA 19 - ESPÉCIES COM OS MAIORES DIÂMETROS MÉDIOS (DAP), EM cm, ENCONTRADAS NA ÁREA ESTUDADA.





FIGURA 20 - ESPÉCIES COM MAIORES DAP, EM cm, ENCONTRADAS NA ÁREA ESTUDADA.



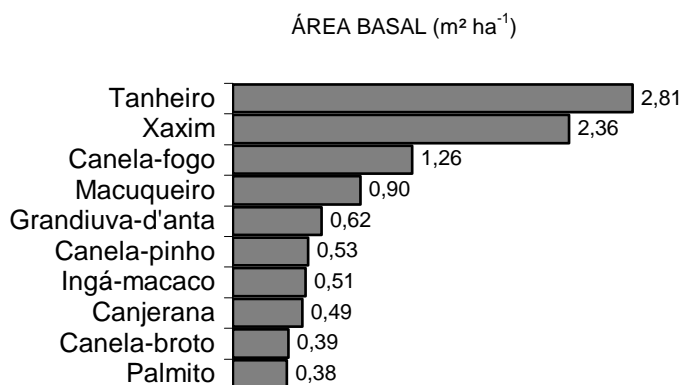
As espécies que apresentaram maior área basal, em $\text{m}^2 \text{ha}^{-1}$, foram o tanheiro (*Alchornea triplinervea*) com $2,81 \text{ m}^2 \text{ha}^{-1}$, o xaxim (*Cyathea* spp.) com $2,36 \text{ m}^2 \text{ha}^{-1}$ e a canela-fogo (*Ocotea odorifera*) com $1,26 \text{ m}^2 \text{ha}^{-1}$. As árvores mortas apresentaram uma área basal de $2,08 \text{ m}^2 \text{ha}^{-1}$. A Figura 21 apresenta as dez maiores espécies em área basal encontradas na área amostrada.

4.1.5 Equações alométricas ajustadas

Foram ajustadas equações alométricas para a obtenção de estimativas individuais dos volumes com casca (m^3), volumes sem casca (m^3), altura total (m) e altura comercial (m). As equações ajustadas para as estimativas de biomassa fresca (kg) serão objeto de tópico específico. Foram ajustadas equações específicas para obtenção dessas estimativas para todas as espécies folhosas, para o palmito (*Euterpe edulis*) e para os xaxins (*Cyathea* spp., *Dicksonia sellowiana* e *Alsophila* spp.). Dentre todos os modelos testados, os que

apresentaram os melhores resultados de ajuste para cada situação, com suas respectivas estatísticas, são apresentados no Quadro 03.

FIGURA 21 - ESPÉCIES COM MAIORES ÁREAS BASAIS, EM $m^2 ha^{-1}$, ENCONTRADAS NA ÁREA ESTUDADA.



QUADRO 03 - RESULTADOS E ESTATÍSTICAS DO AJUSTE DOS MELHORES MODELOS PARA OBTENÇÃO DAS ESTIMATIVAS DOS VOLUMES COM CASCA (m^3), VOLUMES SEM CASCA (m^3), ALTURA TOTAL (m) E ALTURA COMERCIAL (m) PARA ESPÉCIES FOLHOSAS, PARA O PALMITO E PARA OS XAXIMS.

Espécie	Variável	Equação	R ²	S _{xy}
FOLHOSAS	Volume com casca	$\text{Log}(V) = -0,241537 + 0,919510 \text{Log}(DAP^2H)$	0,97	0,075
	Volume sem casca	$\text{Log}(V) = -0,343102 + 0,92713 \text{Log}(DAP^2H)$	0,95	0,096
	Altura total	$H = DAP^2 / (0,000803 - 0,002093 DAP + 0,061840 DAP^2)$	0,89	0,001
	Altura comercial	$H = DAP^2 / (0,004213 - 0,003047 DAP + 0,190180 DAP^2)$	0,63	0,004
PALMITO	Volume com casca	$\text{Log}(V) = -0,385759 + 0,821060 \text{Log}(DAP^2H)$	0,96	0,066
	Altura total	$H = DAP^2 / (0,000309 - 0,001987 DAP + 0,051869 DAP^2)$	0,95	0,001
	Altura comercial	$H = DAP^2 / (0,003098 - 0,037655 DAP + 0,236950 DAP^2)$	0,87	0,001
XAXIM	Volume com casca	$\text{Log}(V) = -0,376804 + 0,75197 \text{Log}(DAP^2H)$	0,80	0,095
	Altura Comercial	$H = DAP^2 / (0,045828 - 0,747830 DAP + 3,163000DAP^2)$	0,77	0,003

4.2 BIOMASSA E QUANTIDADE DE CARBONO ARMAZENADA

4.2.1 Equações de biomassa ajustadas

Um conjunto de equações alométricas foi ajustado e testado para a obtenção de estimativas individuais de biomassa total (kg) por compartimento, utilizando os valores de biomassa calculados após a determinação do conteúdo de umidade de cada componente das árvores abatidas. As equações ajustadas tinham como variável a ser estimada a biomassa de cada compartimento em função do diâmetro medido a 1,30 metro do solo (dap) de cada árvore medida no inventário e da altura total estimada pela equação hipsométrica ajustada. Da mesma forma do que para obtenção das estimativas volumétricas, foram ajustadas equações específicas para obtenção das estimativas de biomassa para todas as espécies folhosas, para o palmito (*Euterpe edulis*) e para os xaxins (*Cyathea* spp., *Dicksonia sellowiana* e *Alsophila* spp.).

Dentre todos os modelos testados para cada compartimento, os únicos que apresentaram resultados aceitáveis do ponto de vista estatístico foram aqueles que estimam a biomassa total da árvore em função da altura total estimada e do diâmetro medido. As equações para estimativas de biomassa de tronco, casca, galhos vivos e mortos, folhas e miscelânea não apresentaram resultados satisfatórios que justificassem seu uso, dado o alto erro padrão da estimativa apresentado.

Devido a esse fato, as estimativas da biomassa de cada compartimento foi feita utilizando-se o percentual relativo de cada compartimento em relação à biomassa total de cada espécie medida. Obteve-se a estimativa da biomassa total de cada árvore medida no inventário pela equação ajustada e a biomassa de cada compartimento foi obtida multiplicando-se o percentual calculado para cada compartimento pela biomassa total estimada. Se a espécie sendo estimada não foi contemplada na determinação da biomassa verde em campo, foram utilizados os percentuais médios de todas as espécies amostradas para a determinação da biomassa de cada compartimento.

As equações obtidas para a estimativa da biomassa total são apresentadas no Quadro 04. Os totais de biomassa em kg, determinados para todas as espécies derrubadas, por compartimento e para o total, que foram usados na determinação dos percentuais de cada compartimento estimado, são apresentados no Quadro 05.

QUADRO 04 - RESULTADOS E ESTATÍSTICAS DO AJUSTE DOS MODELOS PARA OBTENÇÃO DAS ESTIMATIVAS DE BIOMASSA TOTAL (kg) E ALTURA TOTAL (m) PARA ESPÉCIES FOLHOSAS, PARA O PALMITO E PARA OS XAXINS.

Espécie	Variável	Equação	R ²	S _{xy}
FOLHOSAS	Biomassa	$\text{Log}(\text{BST}) = 2,631343 + 2,03600 \text{ Log}(\text{DAP}) + 0,888710 \text{ Log}(\text{H})$	0,93	0,117
	Altura total	$\text{H} = \text{DAP}^2 / (0,000803 - 0,002093 \text{ DAP} + 0,061840 \text{ DAP}^2)$	0,89	0,001
PALMITO	Biomassa	$\text{Log}(\text{BST}) = 3,411134 + 1,79960 \text{ Log}(\text{DAP}) + 0,06428 \text{ Log}(\text{H})$	0,96	0,066
	Altura total	$\text{H} = \text{DAP}^2 / (0,000309 - 0,001987 \text{ DAP} + 0,051869 \text{ DAP}^2)$	0,95	0,001
XAXIM	Biomassa	$\text{Log}(\text{BST}) = 1,97663 + 1,13170 \text{ Log}(\text{DAP}) + 0,94336 \text{ Log}(\text{H})$	0,70	0,137
	Altura Total	$\text{H} = \text{DAP}^2 / (0,045828 - 0,747830 \text{ DAP} + 3,163000 \text{ DAP}^2)$	0,77	0,003

4.2.2 Estimativas de biomassa por espécies

Após a obtenção da biomassa de cada indivíduo e de cada compartimento, em função do dap medido e da altura total estimada, os resultados foram agrupados por espécie.

A biomassa total média estimada foi 141.401 kg ha⁻¹, considerando todas as espécies encontradas. As árvores mortas apresentaram uma biomassa média de 11.232 kg ha⁻¹. Dentre as espécies encontradas, 20 espécies são responsáveis por 52,5% da biomassa total estimada, ou seja, 74.238 kg ha⁻¹, sendo que as espécies que apresentaram maior biomassa total média foram o tanheiro (*Alchornea triplinervea*) com 16.125 kg ha⁻¹, o xaxim (*Cyathea* spp.) com 10.686 kg ha⁻¹ e a canela-fogo (*Ocotea odorifera*) com 7.344 kg ha⁻¹. As dez espécies que apresentaram maior biomassa média em kg ha⁻¹, são mostradas na Figura 21.

O fuste das árvores foi o compartimento que apresentou a maior quantidade de biomassa em kg ha⁻¹, com 50,7% da biomassa total média (71.724 kg ha⁻¹), seguido dos galhos vivos, que representam 32,2 % (45.475 kg ha⁻¹). A Figura 23 mostra a biomassa total média por compartimento, para o total da área inventariada.

QUADRO 5 - PESO DE BIOMASSA, EM kg, POR COMPARTIMENTO E PARA O TOTAL, POR ESPÉCIE AVALIADA E MÉDIA GERAL PARA TODAS AS ESPÉCIES.

ESPÉCIE	PESO DO COMPONENTE EM kg						TOTAL
	FUSTE	CASCA	GALHOS		FOLHAS	MISCELÂNEA	
			VIVOS	MORTOS			
Alma-de-serra	57,03	5,72	82,38	0,10	2,76	117,07	265,07
Baga-de-macaco	60,56	14,85	30,74	0,07	11,79	26,11	144,11
Cafezeiro-do-mato	148,61	24,54	171,25	16,27	19,74	54,05	434,45
Caixeta	215,90	44,17	167,49	0,60	26,26	12,25	466,67
Camboatá-branco	150,58	44,88	155,93	5,79	21,92	19,49	398,59
Camboatá-vermelho	45,25	16,66	76,08	1,16	3,36	2,46	144,97
Canela-amarela	106,96	18,39	182,05	8,02	6,54	0,74	322,70
Canela-bicho	113,46	25,27	68,38	0,28	6,87	20,60	234,87
Canela-burra	147,66	39,65	111,92	0,59	7,78	6,72	314,32
Canela-burra-da-lomba	96,37	23,83	54,72	1,77	6,45	2,95	186,08
Canela-fogo	127,65	24,05	123,37	0,52	12,62	73,60	361,82
Canela-papagaio	145,32	38,22	135,81	0,65	7,55	14,76	342,31
Canela-pimenta	92,74	23,12	97,32	0,22	8,11	53,18	274,68
Canela-pinho	268,17	43,39	195,35	3,37	14,73	43,70	568,71
Canela-sebo	25,82	9,10	9,92	0,00	2,66	0,56	48,05
Canela-taquara	117,11	17,35	121,68	0,00	13,28	4,28	273,70
Canemaçu	23,70	5,36	43,31	0,04	6,20	0,00	78,60
Canjerana	60,47	15,86	91,75	0,24	13,48	4,79	186,59
Capororoca	45,93	11,84	75,67	0,35	5,41	1,82	141,02
Capororocão	22,00	4,84	13,06	0,06	3,42	0,00	43,37
Carne-de-vaca	33,86	2,31	28,68	0,00	2,68	0,00	67,53
Carvoeiro-branco	23,05	3,43	30,94	0,00	7,60	0,98	65,99
Carvoeiro-vermelho	26,34	2,79	23,68	0,00	6,04	1,35	60,20
Caúna	54,59	6,40	47,76	0,02	9,06	1,84	119,68
Cedro	83,56	21,09	145,43	0,67	19,48	0,27	270,50
Coração-de-bugre	100,92	21,35	135,45	0,89	14,94	23,30	296,85
Cortiça-crespa	13,59	5,91	22,33	0,00	4,77	1,82	48,43
Cortiça-preta	86,39	15,29	194,68	0,04	8,89	28,31	333,59
Cutia	20,90	3,73	13,44	0,07	4,73	0,00	42,87
Embiruçu	29,10	22,53	10,14	0,00	4,50	0,00	66,27
Esparela	40,12	7,08	51,99	0,42	3,00	47,81	150,43
Gaioleiro	56,53	8,44	26,09	0,00	1,22	0,00	92,28
Garuvão	93,80	16,92	43,50	0,00	13,55	0,00	167,77
Garuvinha	24,16	6,98	33,22	0,03	7,07	1,25	72,71
Grandiúva	53,02	15,61	11,79	0,05	1,37	0,00	81,84
Grandiúva-d'anta	203,62	46,97	135,19	0,22	16,66	0,00	402,66
Guabiroba	114,90	8,30	87,43	1,36	13,98	4,44	230,41
Guamirim 1	69,76	10,44	24,06	2,20	2,25	16,51	125,21
Guamirim-amarelo	96,83	16,79	56,57	0,08	2,82	13,16	186,24
Guamirim-branco	75,62	8,50	74,35	0,08	8,05	9,76	176,37
Guamirim-d'água 2	123,90	15,77	67,29	0,00	19,24	1,88	228,07
Guamirim-folha-miúda	127,51	17,07	48,67	0,71	4,63	1,69	200,28
Guamirim-pimenta	212,36	31,78	89,14	0,12	9,35	6,60	349,34

QUADRO 5 - PESO DE BIOMASSA, EM kg, POR COMPARTIMENTO E PARA O TOTAL, POR ESPÉCIE AVALIADA E MÉDIA GERAL PARA TODAS AS ESPÉCIES (continuação)

ESPÉCIE	PESO DO COMPONENTE EM kg						TOTAL
	FUSTE	CASCA	GALHOS VIVOS	GALHOS MORTOS	FOLHAS	MISCELÂNEA	
Guamirim-rola	92,75	11,22	77,87	3,06	2,31	2,26	189,47
Ingá-macaco	109,92	12,57	35,02	0,12	4,31	0,06	161,99
Jacatirão	136,48	21,31	149,44	1,58	29,96	17,52	356,29
Laranjeira-do-mato	56,39	7,16	82,88	0,58	8,53	1,45	156,99
Licurana	158,88	42,86	234,30	0,24	30,45	18,21	484,95
Louro-cravo	41,54	5,21	46,93	0,00	3,63	2,06	99,37
Macuqueiro	110,49	8,23	279,59	0,32	14,29	7,86	420,78
Mandioqueiro	178,72	41,58	187,96	2,96	13,21	8,52	432,96
Maria-faceira	130,06	7,35	115,74	0,33	7,44	24,42	285,35
Maria-mole	136,66	10,77	62,11	0,00	12,61	0,00	222,15
Palmito	52,97	0,00	0,00	0,00	20,79	1,41	75,16
Pau-angelim	211,58	27,35	222,70	0,43	7,09	12,85	482,01
Pau-óleo	145,55	19,87	91,74	0,18	9,71	3,03	270,08
Pau-rosa	112,95	12,55	76,25	0,08	20,18	7,13	229,13
Pela-cavalo	73,31	16,84	39,23	1,33	1,54	0,39	132,64
Peroba	117,64	34,76	100,98	0,40	18,68	24,61	297,06
Pêssego-bravo	38,27	8,19	20,30	0,08	4,45	0,25	71,54
Pixirica	39,81	13,89	35,34	0,02	9,54	0,35	98,94
Pixiricão	182,40	53,09	200,30	1,05	25,27	2,56	464,67
Sassafrás	113,33	20,47	149,38	0,59	14,86	15,36	313,99
Seca-ligeiro	75,84	15,65	65,50	0,00	5,53	19,44	181,97
Tanheiro	26,25	7,83	15,18	0,00	1,97	0,00	51,23
Tanheiro-folha-caída	141,03	26,31	145,78	1,02	20,28	0,41	334,82
Vassourão-branco	197,69	57,38	274,31	0,73	21,32	13,64	565,08
Vassourão-d'água	169,91	37,69	216,01	2,46	14,10	1,30	441,47
Vassourão-ferro	43,47	17,79	11,41	0,79	2,45	17,45	93,36
Vassourão-folha-muída	54,44	14,19	69,18	0,47	7,44	1,84	147,56
Vassourão-folha-verm.	105,00	26,43	127,17	2,26	19,70	9,97	290,53
Vassourão-orelha-mula	167,81	28,51	198,55	3,69	8,56	20,64	427,75
Xaxim	36,23	0,00	0,00	0,00	10,22	0,29	46,74
Xaxim-bugiu	22,81	0,00	0,00	0,00	6,39	0,01	29,21
Xaxim-liso	39,69	0,00	0,00	0,00	9,86	0,71	50,25
Morta	146,65	0,00	0,00	0,00	0,00	0,00	146,65
MÉDIA	95,17	17,90	88,08	0,93	10,09	11,12	223,30

O fuste das árvores foi o compartimento que apresentou a maior quantidade de biomassa em kg ha⁻¹, com 50,7% da biomassa total média (71.724 kg ha⁻¹), seguido dos galhos vivos, que representam 32,2 % (45475 kg ha⁻¹). A Figura 23 mostra a biomassa total média por compartimento, para o total da área inventariada.

FIGURA 22 - ESPÉCIES COM MAIOR BIOMASSA TOTAL, EM kg ha^{-1} , ENCONTRADAS NA ÁREA INVENTARIADA.





FIGURA 23 - BIOMASSA TOTAL, EM kg ha^{-1} , POR COMPARTIMENTO, DAS ÁRVORES ENCONTRADAS NA ÁREA INVENTARIADA.



O Quadro 06 apresenta os resultados de biomassa total, em kg ha^{-1} , obtidos pelas 19 espécies com maior Índice de Valor de Importância dentre todas as espécies encontradas na área amostrada, cujo somatório dos índices atinge 50,8% do total, incluindo as três espécies de xaxim e o palmito.

4.2.3 Estimativas da quantidade de carbono por espécies

A obtenção da quantidade de carbono armazenada nos diferentes compartimentos da árvore foi feita multiplicando-se o teor determinado em laboratório, por espécie e por compartimento, pela quantidade de biomassa estimada correspondente. O Quadro 07 apresenta os teores de carbono, em g kg^{-1} , determinado para todas as espécies derrubadas por ocasião da cubagem e determinação da biomassa verde.

QUADRO 6 - RESULTADOS DAS ESTIMATIVAS DO NÚMERO DE ÁRVORES POR HA, ÁREA BASAL EM m² HA⁻¹ E BIOMASSA TOTAL EM kg ha⁻¹, PARA AS ESPÉCIES QUE TOTALIZAM 50% DO ÍNDICE DE VALOR DE IMPORTÂNCIA.

ESPÉCIE	Nº Árvores ha	Área Basal m ² ha ⁻¹	Biomassa Total kg ha ⁻¹
Xaxim	230,9	2,4	10685,9
Tanheiro	68,7	2,8	16124,8
Morta	73,4	2,1	11232,0
Palmito	71,4	0,4	2292,8
Canela-fogo	26,9	1,3	7344,2
Macuqueiro	30,5	0,9	4864,2
Grandiuva-d'anta	22,2	0,6	3343,5
Xaxim-liso	24,5	0,4	1094,2
Ingá-macaco	15,2	0,5	2823,4
Canjerana	10,4	0,5	2867,7
Canela-broto	12,4	0,4	2129,7
Vassourão-folha-miúda	20,5	0,3	1509,1
Canela-pinho	7,7	0,5	3203,6
Canela-papagaio	13,7	0,4	1862,7
Cortiça-preta	13,2	0,3	1550,6
Vassourão-orelha-de-mula	12,0	0,4	1997,0
Maria-faceira	9,6	0,3	1801,5
Vassourão-folha-vermelha	11,7	0,2	1150,5
Tanheiro-folha-caída	9,8	0,3	1906,0

Caso a espécie não tenha sido amostrada, os teores utilizados são os teores médios para todas as espécies. Somando-se os teores encontrados por compartimento, obtém-se o total de carbono armazenado por indivíduo amostrado. O Quadro 07 apresenta os teores de carbono determinados para as espécies amostradas, por compartimento e para a média de todas as espécies, em g kg⁻¹, utilizados na obtenção das quantidades de carbono estocadas.

A quantidade de carbono total média estocada foi estimada em 59.323 kg ha⁻¹, considerando todas as espécies encontradas, inclusive as árvores mortas. Dentre as espécies encontradas, 20 espécies são responsáveis por 52,5% da quantidade de carbono estocado, perfazendo 31.111 kg ha⁻¹. As espécies que apresentaram maior quantidade média de carbono armazenado foram o tanheiro (*Alchornea triplinervea*) com 7.214 kg ha⁻¹, o xaxim (*Cyathea* spp.) com 4.217 kg ha⁻¹ e a canela-fogo (*Ocotea odorifera*) com 3.055 kg ha⁻¹.

As dez espécies que apresentaram maior quantidade média de carbono armazenado, em kg ha⁻¹, são mostradas na Figura 24.

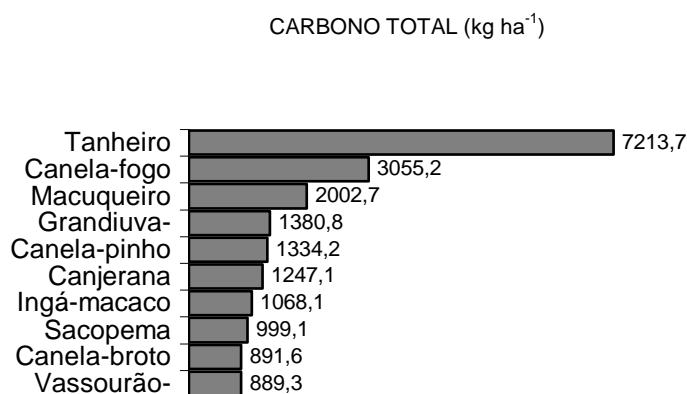
QUADRO 7 - TEORES DE CARBONO, EM g kg⁻¹, POR COMPONENTES, POR ESPÉCIE AVALIADA E MÉDIA GERAL DE TODAS AS ESPÉCIES.

ESPÉCIE	TEORES DE CARBONO (g kg ⁻¹)					
	CASCA	FUSTE	FOLHAS	GALHOS VIVOS	GALHOS MORTOS	MISCELÂNEA
Alma-de-serra	438,99	444,94	383,93	437,50		
Baga-de-macaco	372,03	465,77	467,26	447,92	474,70	
Cafezeiro-do-mato	408,11	442,34	432,29	422,62	478,43	434,52
Caixeta	402,90	334,08	473,96	423,37	450,15	465,77
Camboatá-branco	392,11	429,07	447,42	417,16	456,85	462,80
Camboatá-vermelho	372,77	430,54	407,74	412,20		456,85
Canela-amarela	363,59	416,17	353,18	376,99	404,26	
Canela-bicho	390,63	435,27	403,27	398,81		482,14
Canela-burra	382,44	454,62	421,13	357,14	401,79	438,99
Canela-burra-da-lomba	388,89	431,82	390,38	394,84	391,37	453,87
Canela-fogo	357,56	448,16	397,82	375,99	429,56	449,40
Canela-papagaio	386,41	421,63	418,65	406,25		464,29
Canela-pimenta	418,16	462,05	430,06	434,52		471,73
Canela-sebo	404,51	363,84	429,57	415,93		431,55
Canela-taquara	380,58	417,78	398,07	369,79		483,63
Canemaçu	375,74	225,45	453,87	441,96	421,13	
Canjerana	413,32	449,41	451,64	425,60	450,89	452,38
Capororoca	423,36	429,81	454,86	419,64	421,13	425,60
Capororocão	430,06	397,70	459,08	403,28		
Carne-de-vaca	369,06	459,08	385,42	421,13		
Carvoeiro-branco	361,61	445,69	427,08	413,69	418,15	440,48
Carvoeiro-vermelho	351,19	415,93	416,67	413,69		
Caúna	394,35	393,60	379,46	358,63		
Cedro	429,07	438,49	393,85	392,86	428,57	
Coração-de-bugre	374,26	415,18	440,48	421,13		
Cortiça-crespa	400,85	429,13	424,11	393,98	458,33	421,13
Cortiça-preta	412,58	432,66	406,25	431,55		438,25
Cutia	389,14	440,48	461,31	418,15	486,61	
Embiruçu	412,20	427,09	391,37	424,11		
Esparela	394,72	448,66	401,79	412,95	427,08	443,45
Gaioleiro	403,27	459,83	427,08	450,89		
Garuvão	398,07	450,89	388,39	419,64		
Garuvinha	407,74	421,88	476,19	428,57		434,52
Grandiúva	409,23	436,01	397,32	416,67	491,07	
Guabiroba	377,23	449,41	413,69	431,55	446,43	437,50
Guamirim 1	410,72	411,46	419,64	380,95	373,51	470,24
Guamirim-amarelo	439,73	452,38	388,39	403,27	422,62	
Guamirim-branco	409,97	402,53	397,32	418,15	415,18	462,80
Guamirim-d'água 2	418,90	430,06	401,04	427,83		456,85
Guamirim-folha-miuda	391,37	401,46	403,27	434,52	446,43	
Guamirim-pimenta	389,88	474,70	389,88	388,39		446,43
Guamirim-rola	367,56	401,04	401,79	395,83	416,67	461,31
Guamirim-vermelho	375,75	458,33	403,27	413,69		474,70
Ingá-macaco	387,65	361,98	410,72	421,88	436,76	446,43
Jacatirão	408,48	427,83	441,96	398,81	424,11	465,77
Laranjeira-do-mato	340,78	447,17	401,79	397,32	415,18	458,33
Licurana	387,65	428,57	404,02	415,18	428,57	459,82
Louro-cravo	368,31	333,71	388,39	398,81	409,23	459,08
Macuqueiro	374,01	437,01	372,52	403,77	449,40	447,92
Mandioqueiro	374,26	445,93	469,74	422,62	458,33	444,94
Maria-faceira	405,51	407,74	411,46	412,21	412,21	462,80
Maria-mole	426,71	398,44	400,30	413,69		
Palmito		384,67	407,50			434,52
Pau-angelim	407,24	424,11	395,84	419,15	432,14	453,87

QUADRO 7 - TEORES DE CARBONO, EM g kg^{-1} , POR COMPONENTES, POR ESPÉCIE AVALIADA E MÉDIA GERAL DE TODAS AS ESPÉCIES. (continuação)


ESPÉCIE	TEORES DE CARBONO (g kg^{-1})					
	CASCA	FUSTE	FOLHAS	GALHOS VIVOS	GALHOS MORTOS	MISCELÂNEA
Pau-óleo	415,68	411,71	472,72	424,60	415,92	
Pau-rosa	405,51	469,50	443,45	404,75		
Pela-cavalo	371,28	454,61	351,19	427,08	497,02	465,77
Peroba	388,39	459,08	468,01	417,66	418,90	459,82
Pêssego-bravo	400,30	467,26	404,76	403,27	395,83	
Pixirica	398,81	413,69	415,18	401,79	407,74	
Pixiricão	360,86	422,62	397,32	383,93		418,15
Sassafrás	414,68	426,09	404,27	376,49	449,41	473,21
Seca-ligeiro	372,02	441,22	422,62	397,32		455,36
Tanheiro	389,89	476,19	413,69	431,55		
Tanheiro-folha-caída	346,48	437,26	413,19	398,81	423,36	479,17
Vassourão-branco	382,47	424,85	437,50	418,15		461,31
Vassourão-d'água	397,31	442,71	428,57	429,57	447,18	
Vassourão-ferro	408,48	436,01	409,23	443,45	428,57	455,54
Vassourão-folha-vermelha	359,62	442,46	419,64	417,16	433,78	440,48
Vassourão-orelha-de-mula	409,48	428,39	426,09	428,08	438,99	456,85
Xaxim		389,88	422,62			
Xaxim-bugiu		414,00	403,27			
Xaxim-liso		413,20	413,69			
Mortas	446,43	448,66	401,79	419,64	456,85	447,92
Média	392,10	425,79	416,40	411,47	434,25	453,97

FIGURA 24 - ESPÉCIES COM MAIORES QUANTIDADES MÉDIAS DE CARBONO ESTOCADO, EM kg ha^{-1} , ENCONTRADAS NA ÁREA ESTUDADA.



Também para a quantidade de carbono armazenado, o fuste das árvores foi o compartimento que apresentou a maior quantidade em kg ha^{-1} , com 52,0% da quantidade total média de carbono ($59.323 \text{ kg ha}^{-1}$), seguido dos galhos vivos, que representam 31,4 % ($18.620 \text{ kg ha}^{-1}$). A Figura 25 mostra a quantidade de carbono total média por compartimento, para o total da área estudada.

FIGURA 25 - QUANTIDADE DE CARBONO TOTAL MÉDIO ARMAZENADO, EM kg ha^{-1} , POR COMPARTIMENTO DAS ÁRVORES ENCONTRADAS NA ÁREA ESTUDADA.



O Quadro 08 apresenta os resultados obtidos para a quantidade média de carbono estocada pelas 19 espécies com maior Índice de Valor de Importância dentre todas as espécies encontradas na área amostrada, e cujo somatório dos índices atinge 50,8% do total, incluindo as três espécies de xaxim e o palmito.

QUADRO 8 - RESULTADOS DAS ESTIMATIVAS DO NÚMERO DE ÁRVORES POR ha, ÁREA BASAL EM $\text{m}^2 \text{ha}^{-1}$ E CARBONO TOTAL MÉDIO ESTOCADO, EM kg ha^{-1} , PARA AS ESPÉCIES QUE TOTALIZAM 50% DO ÍNDICE DE VALOR DE IMPORTÂNCIA.

ESPÉCIE	Nº Árvores ha	Área Basal $\text{m}^2 \text{ha}^{-1}$	Carbono Total kg ha^{-1}
Xaxim	230,9	2,4	4217,0
Tanheiro	68,7	2,8	7213,7
Morta	73,4	2,1	5039,3
Palmito	71,4	0,4	898,6
Canela-fogo	26,9	1,3	3055,2
Macaqueiro	30,5	0,9	2002,7
Grandiuva-d'anta	22,2	0,6	1380,8
Xaxim-liso	24,5	0,4	445,8
Ingá-macaco	15,2	0,5	1068,1
Canjerana	10,4	0,5	1247,1
Canela-broto	12,4	0,4	891,6
Vassourão-folha-miúda	20,5	0,3	650,4
Canela-pinho	7,7	0,5	1334,2
Canela-papagaio	13,7	0,4	768,5
Cortiça-preta	13,2	0,3	668,0
Vassourão-orelha-de-mula	12,0	0,4	855,5
Maria-faceira	9,6	0,3	746,4
Vassourão-folha-vermelha	11,7	0,2	485,7
Tanheiro-folha-caída	9,8	0,3	785,1

4.2.4 Estimativas por amostras

Foram medidas 48 unidades de amostra das 50 unidades previstas, de 30 metros de largura por 90 metros de comprimento, perfazendo 2700 m² por amostra. Os resultados das estimativas obtidas por unidade de amostra são apresentados no Anexo 05, e constituem-se nos valores usados para pelos procedimentos de ANN e Regressão Linear.

Para cada amostra realizada são reportados o número de árvores por hectare, o número de árvores mortas por hectare, o diâmetro médio em cm, medido a 1,30 metros do solo (dap), a área basal em m² ha⁻¹, o volume com casca em m³ ha⁻¹, o volume sem casca em m³ ha⁻¹, a quantidade de biomassa total em kg ha⁻¹ e o estoque de carbono total em kg ha⁻¹.

Os dados apresentados no Quadro 10 evidenciam que a área inventariada é bastante homogênea, pois as médias por amostra das variáveis volumétricas e dendrométricas, avaliadas no inventário, apresentaram coeficientes de variação entre 23,8% e 31,4%. O número médio de árvores mortas e o diâmetro médio das amostras apresentou variação condizente com a natureza dessas variáveis, ou seja, os diâmetros médios por amostra variam menos (8,1%) e o número médio de árvores mortas por amostra variam mais (54,%), fato que pode ser explicado pelo estágio intermediário de desenvolvimento da área inventariada.

QUADRO 09 - ESTATÍSTICAS REFERENTES AOS VALORES MÉDIOS PARA AS 48 AMOSTRAS EFETUADAS, APRESENTANDO OS VALORES MÍNIMOS, MÁXIMOS E MÉDIOS, O DESVIO PADRÃO E O COEFICIENTE DE VARIAÇÃO PARA AS VARIÁVEIS ESTIMADAS.

VARIÁVEL	Mínimo	Máximo	Média	Desvio Padrão	C.V. % ⁽¹⁾
Nº Árvores ha ⁻¹	425,9	1581,5	960,6	229,1	23,8
Nº Árvores Mortas ha ⁻¹	11,1	181,5	73,4	39,6	54,0
dap (cm)	13,3	19,0	16,0	1,3	8,1
Área Basal m ² ha ⁻¹	6,5	43,1	26,3	7,5	28,5
Volume com casca m ³ ha ⁻¹	30,0	222,6	136,8	38,8	28,4
Volume sem casca m ³ ha ⁻¹	23,1	164,0	93,1	27,5	29,6
Biomassa Total kg ha ⁻¹	28910,0	247284,0	141401,2	44232,4	31,3
Carbono Total kg.ha ⁻¹	12283,8	104318,8	59322,6	18623,7	31,4

⁽¹⁾ C.V.% Coeficiente de Variação

4.3 - PROCESSAMENTO DAS IMAGENS

Ao examinar o resultado da ortoretificação, pode-se verificar as diferenças existentes entre a imagem ortoretificada e os pontos de verificação. As diferenças apresentadas foram da ordem de 7 m, conforme apresentado na Tabela 05. Esse deslocamento foi aceito como válido, tendo em vista que foi realizado em uma área florestal com cobertura vegetal bastante densa. Além das dificuldades de se conseguir dados, as estimativas foram realizadas por meio de amostragem em parcelas de 2700 m², que perfazem 178 pixels da imagem IKONOS II (4 m).

TABELA 5 - COORDENADAS DOS PONTOS UTILIZADOS NA CORREÇÃO E RESÍDUOS OBTIDOS NO AJUSTAMENTO.

OBSERVADO		CALCULADO		DIFERENÇA		ERRO	RMS
X	Y	X	Y	X	Y		
674883,23	6990863,95	674893,20	6990864,54	9,970	0,590	99,749	
672319,08	6993016,29	672313,73	6993021,03	-5,350	4,740	51,090	
671306,16	6989304,21	671302,53	6989306,65	-3,630	2,440	19,131	7,6064742
670718,89	6989201,16	670715,89	6989198,16	-3,000	-3,000	18,000	
668938,35	6984611,31	668942,54	6984606,22	4,190	-5,090	43,464	

Uma vez realizada a ortoretificação, as variáveis de interesse biomassa e a quantidade de carbono total médio das parcelas foram pareadas aos dados médios de intensidade e brilho obtidos da imagem, a partir das quatro bandas do satélite, para a realização do ajustamento de observações. Uma vez realizado o ajustamento, por meio de simulação, as quantidades de carbono e de biomassa foram estimadas para toda a área de estudo.

Os resultados obtidos foram armazenados no formato “*.tif” pelo programa *ENVI 4.1*, sendo posteriormente importados pelo programa *Ecognition 4.0*, para a realização da segmentação das imagens.

4.4 SEGMENTAÇÃO MULTI-RESOLUÇÃO

Quando da segmentação das imagens, os parâmetros utilizados variam conforme o tipo de imagem utilizada, as características da imagem, as bandas utilizadas e o seu objetivo. Devido a isso, os parâmetros foram determinados a partir de múltiplas tentativas.

Diante desse fato, foi necessário que o processo de segmentação fosse reavaliado continuamente, por meio de uma análise visual dos segmentos formados, visando a

obtenção do melhor resultado para posterior aplicação dos procedimentos de Redes Neurais Artificiais e Regressão Múltipla. O Quadro 11 apresenta os parâmetros testados na busca da melhor segmentação.

QUADRO 10 - PARÂMETROS TESTADOS NA SEGMENTAÇÃO.


Segmentação	Escala	W para cor	W forma	Suavidade	Compacidade
Nível 1	10	0,7	0,3	0.6	0.4
Nível 2	20	0,5	0,5	0.6	0.4
Nível 3	30	0,5	0,5	0.6	0.4
Nível 4	40	0,5	0,5	0.6	0.4
Nível 5	50	0,5	0,5	0.6	0.4

O processo de definição dos parâmetros de segmentação iniciou-se pela fixação dos valores para o fator de escala, tendo sido testados os fatores de escala de 10, 20, 30, 40 e 50. No Nível 1, a imagem segmentada resultou em 564.259 objetos, sendo que estes segmentos mantiveram uma significativa homogeneidade entre os pixels de um mesmo objeto em relação ao valor espectral, conforme pode ser verificado na Figura 26.

Os segmentos do Nível 2 apresentaram objetos com características tendendo a puros, ou seja, apresentaram grupos de pixels de mesma classe. Nesse nível a segmentação gerou 134932 objetos e o resultado é apresentado na Figura 27.


A presença do parâmetro forma no Nível 3, aliada a uma escala maior, permitiu que a segmentação preservasse o tamanho e a forma dos objetos, resultando, entretanto, no aparecimento de mistura entre as classes, ou seja, houve mistura de pixels de classes diferentes. O resultado obtido, em que a imagem foi segmentada em 59485 objetos, é apresentado na Figura 28.

FIGURA 26 - RESULTADO DA SEGMENTAÇÃO NO NÍVEL 1.



A presença do parâmetro forma no Nível 4, auxiliou a segmentação na preservação do tamanho e da forma dos objetos, da mesma forma que ocorreu no Nível 3, resultando em uma forma primitiva de pré-classificação dos segmentos. Esta imagem foi segmentada em 33498 objetos e o resultado obtido é apresentado na Figura 29.

FIGURA 27 – RESULTADO DA SEGMENTAÇÃO NO NÍVEL 2.




A presença do parâmetro forma no Nível 5, melhorou a segmentação na preservação do tamanho e da forma dos objetos, em relação às segmentações prévias realizadas, resultando em uma pré-classificação dos segmentos. A imagem obtida nesse nível foi segmentada em 21490 objetos e é apresentada na Figura 30.

A comparação dos Níveis testados, classe por classe, permitiu a identificação da melhor separação dos objetos para o conjunto. Para identificar os Níveis que apresentaram os melhores resultados, e que foram utilizados para o cálculo da média de cada segmento e como base para o treinamento da Rede Neural Artificial, foi escolhido o Nível que separava

melhor suas classes e possuía uma menor mistura ou contaminação das classes por valores que se distanciavam da média dos segmentos.


FIGURA 28 - RESULTADO DA SEGMENTAÇÃO NO NÍVEL 3.



Os parâmetros finais tiveram que ser selecionados considerando a extração das informações utilizadas para o treinamento e classificação dos valores digitais, que serviram de entrada na ANN, para que se pudesse obter os valores de biomassa e quantidade de carbono para toda a área de estudo. Diante disso, foram padronizadas o numero de entradas utilizadas (variáveis dependentes). As estatísticas calculadas para os polígonos

das imagens foram utilizadas na comparação dos resultados gerados pela aplicação de ANN e por Regressão Múltipla.


FIGURA 29 - RESULTADO DA SEGMENTAÇÃO NO NÍVEL 4.



As análises visuais dos cinco resultados da segmentação definiram os padrões de segmentação com fator de escala 50, 0,5 para a cor, 0,5 para a forma e, para essa, 0,6 de suavidade e 0,4 de compacidade, pois esses foram os resultados que melhor agruparam experimentalmente os elementos de interesse das imagens. As variáveis descritoras utilizadas para representar os segmentos são as médias dos valores para cada uma das

imagens de entrada que foram posteriormente processadas na ANN e por Regressão Múltipla.

FIGURA 30 - RESULTADO DA SEGMENTAÇÃO NO NÍVEL 5.



Diferente de RIBEIRO (2004), que utilizou um fator de escala 20, em função da compatibilidade com a resolução espacial da imagem Landsat 7TM, nesse estudo a escala 50 foi escolhida para melhor separar os objetos que compreendiam os fragmentos florestais da área de estudo. A alta resolução espacial do satélite IKONOS II aliada a homogeneidade da Floresta da área de estudo, uma escala maior foi utilizada.

ROLIM (2003), utilizando três níveis de segmentação, determinou que o Nível 3 com escala 180 foi o Nível em que a segmentação melhor preservou o tamanho e a forma dos objetos, resultando de forma primitiva em uma pré-classificação dos segmentos. No presente a escala que melhor separou os objetos em sua forma e cor foi 50, pois se buscava uma separação mais sensível por se tratar de uma área de floresta nativa.

Os parâmetros de escala analisados e contemplados na geração da segmentação tiveram um bom resultado para a separação de classes. A escolha dos parâmetros atribuídos a cor e a forma tomaram por base as feições das estradas e do solo exposto, uma vez que essas feições se diferenciam das demais por possuírem formas regulares. Essa característica determinou que os pesos dos parâmetros de forma fossem iguais aos do parâmetro cor a partir do Nível 1 da segmentação.

4.5 ANÁLISE DE CORRELAÇÃO

A matriz de correlação permite determinar o grau de associação entre variáveis. As matrizes apresentadas abaixo correlacionam as variáveis dependentes, biomassa arbórea (BIOMASSA) e o conteúdo de carbono (CARBONO) e as variáveis independentes, representadas pelas respostas espectrais das diferentes bandas e índices de vegetação das imagens provenientes do satélite, a saber, MS-1 (banda azul), MS-2 (banda verde), MS-3 (banda vermelha), MS-4 (banda infravermelha).

Os resultados das correlações encontradas, apresentados nas Tabelas 06 e 07, indicam que as variáveis dendrométricas biomassa arbórea e quantidade de carbono apresentam as maiores correlações negativas com as variáveis espectrais MS-4, MS-2 e MS-4. A variável espectral MS-3 apresentou um grau de correlação médio tanto para a biomassa como para o carbono.

Os resultados de correlação obtidos para a biomassa arbórea são semelhantes aos encontrados para a quantidade de carbono, e segundo WATZLAWICK (2003) isso ocorre devido ao fato dessas variáveis serem altamente correlacionadas. A razão da alta correlação entre elas advém do uso de um fator para o cálculo do conteúdo de carbono.

Diferentemente dos trabalhos de WATZLAWICK (2003) e BARBOSA (2006), que utilizaram o valor de apenas um pixel para o cálculo das correlações, no presente as correlações foram calculadas com base no valor médio dos segmentos e, por esse motivo, as correlações com as bandas MS-4, MS-2 (verde) e MS-1 (azul) apresentaram melhores resultados. As áreas segmentadas, por possuírem valores mais homogêneos (grupo de

pixels), apresentaram respostas espectrais da vegetação tanto na região referente ao vermelho quanto na região do infravermelho, com uma menor variação e maior correlação. WATZLAWICK (2003) e MORAES (1996), afirmam que fatores externos à folha podem alterar a reflectância nessa região, e devido a isso pode ocorrer uma diminuição na correlação entre as variáveis oriundas da imagem e as variáveis biomassa arbórea e quantidade de carbono, sendo que essas influências são minimizadas quando se trabalha com valores mais homogêneos, como no caso da segmentação.

TABELA 6 - MATRIZ DE CORRELAÇÃO ENTRE VARIÁVEIS DIGITAIS E A BIOMASSA EM FLORESTA OMBRÓFILA DENSA.

	MS1 Azul	MS2 Verde	MS3 Vermelha	MS4 Infra-vermelha.	BIOMASSA
MS1 Azul	1,00				
MS2 Verde	0,98	1,00			
MS3 Vermelha	0,58	0,69	1,00		
MS4 Infra-Vermelha	0,98	0,99	0,64	1,00	
BIOMASSA	-0,72	-0,71	-0,32	-0,72	1,00

TABELA 7 - MATRIZ DE CORRELAÇÃO ENTRE VARIÁVEIS B VARIÁVEIS DIGITAIS E A CARBONO EM DA FLORESTA OMBRÓFILA DENSA.

	MS1 Azul	MS2 Verde	MS3 Vermelha	MS4 Infra-vermelha.	CARBONO
MS1 Azul	1,00				
MS2 Verde	0,98	1,00			
MS3 Vermelha	0,58	0,69	1,00		
MS4 Infra-Vermelha	0,98	0,99	0,64	1,00	
CARBONO	-0,73	-0,71	-0,32	-0,73	1,00

4.6. RESULTADOS DA REDE NEURAL ARTIFICIAL PARA BIOMASSA ARBÓREA

Partindo do pressuposto que os valores de biomassa arbórea e de quantidade de carbono obtidos no inventário florestal da área são os verdadeiros, foram realizadas duas séries de experimentos, um para biomassa e outro para a quantidade de carbono. Esses experimentos visaram avaliar o desempenho das ANN na fase de treinamento, ou seja, avaliar se as amostras de verificação foram corretamente classificadas. Na primeira série os

dados foram analisados para a variável biomassa e na segunda série os dados de quantidade de carbono, ambas em nível de segmentos.

Em ambos os casos o conjunto de parâmetros foi modificado visando identificar aqueles que minimizavam os erros e tendo como referência os valores da imagem IKONOS II. Os valores digitais médios dos segmentos dessas imagens representam as variáveis de entrada de cada série. A quantidade de interações foi variável, com o Erro Quadrático Médio (E.Q.M.) definido em quatro categorias. Os valores, apresentados na Tabela 04, referem-se aos intervalos de E.Q.M. testados, o número de camadas da ANN e a quantidade de neurônios em cada camada.

Utilizando as equações ajustadas e selecionadas foram geradas novas imagens, com os pesos calculados no treinamento e aplicados aos valores médios das bandas RGB e NIR dos segmentos. Cada segmento passou a representar a quantidade estimada da variável biomassa arbórea ou da quantidade de carbono, para toda a área de estudo.

Os resultados do uso das Redes Neurais Artificiais na obtenção das estimativas das variáveis estudadas foram comparados com os dados agrupados pela segmentação. Ressalta-se que só os resultados que se mostraram coerentes do ponto de vista estatístico são apresentados. As comparações foram feitas pelo cálculo da porcentagem de erro de cada amostra de verificação em relação ao valor estimado.

O número de neurônios da primeira camada foi definido como aproximadamente 1/3 das amostras de treinamento e de 1/4 do número de neurônios da primeira camada escondida como de saída.

Os resultados obtidos pelo uso das ANN para a quantificação da biomassa arbórea foram reunidos em três grupos: experimentos que não tiveram resultados aceitáveis, experimentos com resultados que se aproximaram dos esperados, e os resultados que atenderam as expectativas, do ponto de vista estatístico.

Foram testados três valores para o Erro Quadrático Médio na arquitetura da rede, a saber arquitetura com limiar baixo (0,0001), intermediário (0,005) e alto (0,01).

Os resultados obtidos utilizando os limiares baixos, apresentados na Tabela 08, mostram as arquiteturas usadas, o número de neurônios na camada de entrada na primeira camada escondida e na camada de saída, assim como o número de interações feitas para se atingir o E.Q.M. estipulado, que deveria ser obtido para cada rede testada ao final do treinamento. O treinamento foi realizado com 38 amostras, do total de 48 coletadas, sendo que cinco tomadas de forma aleatória não foram usadas no treinamento e deixadas para a validação do treinamento e outras cinco não foram utilizadas porque não possuíam recobrimento da imagem.

A arquitetura mostrou-se ineficiente quando treinadas com um valor de limiar baixo. Os resultados médios obtidos revelaram erros variando de 18 a 45% para esse limiar. O resultado de 18% seria aceitável se sua variação não fosse tão grande, pois mascarou a média. Essa variação pode ser verificada nos Anexos 06 e 08, onde os valores positivos e negativos equilibraram a média.

TABELA 08 - COMPARAÇÃO ENTRE A BIOMASSA ARBÓREA ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,001 e 0,0001.

E.Q.M	ARQUITETURA DA ANN	BIOMASSA (kg)		RESÍDUO	ERRO %
		REAL	ESTIMADA		
0,0001	12 4	136.046,48	155.414,56	19.368,10	18,06
0,0001	24 8	120.707,97	155.414,58	34.706,61	40,82
0,0001	48 16	106.717,26	155.414,59	48.697,32	45,44
0,001	12 4	128.528,72	155.414,58	26.885,86	24,50
0,001	24 8	142.722,15	155.414,58	12.692,43	29,84
0,001	48 16	128.372,92	155.414,58	27.041,66	22,29

Conforme relatado por JÚNIOR et al. (2001), o E.Q.M. somente não é suficiente para selecionar uma rede neural porque quando estabelecemos um limiar muito pequeno pode ocorrer a memorização dos dados de treinamento, ou seja, a rede torna-se viciada às amostras de treinamento. Segundo MITCHELL (1997) o E.Q.M. será pequeno ao final do treinamento, mas inaceitável para dados diferentes da amostra de treinamento.

Os resultados para as arquiteturas com limiar intermediário (0.005) são apresentados na Tabela 09 e mostram valores insatisfatórios, dada a grande variação dos erros (4,0 a 18,3%) que mascaram a média. Assim como ocorreu quando usado um limiar baixo, o limiar intermediário revelou erros com estimativas maiores do que 10% e menores do que 4%, fazendo com que a média seja tendenciosamente estimada para menos, novamente mascarando os resultados (Anexos 09 a 11).

TABELA 09 - COMPARAÇÃO ENTRE A BIOMASSA ARBÓREA ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,005.

E.Q.M	ARQUITETURA DA ANN	BIOMASSA (kg)		RESÍDUO	ERRO %
		REAL	ESTIMADA		
0,005	12 4	152.429,79	155.414,58	2.984,79	3,96
0,005	24 8	132.608,34	155.414,58	22.806,24	18,14
0,005	48 16	132.913,56	155.414,58	22.501,01	18,32

As arquiteturas que empregaram o limiar mais alto foram as que apresentaram os melhores resultados, apresentados nas Tabelas 10 e 11. A definição da arquitetura da ANN mais apropriada foi baseada no modelo que garantiu a convergência em um número menor de iterações (tempo computacional operacional), e que assegurou a qualidade das

informações geradas. Os melhores resultados da arquitetura da rede foram os obtidos com um Erro Quadrático Médio de 0,01, que proporcionaram os menores erros percentuais, definindo dessa forma a escolha da arquitetura definitiva de classificação (Anexos 12 a 14).

Por se tratarem dos melhores resultados, são discriminados os valores estimados e observados para cada arquitetura definida.

A primeira arquitetura dentro de um limiar de 0,01 de E.Q.M. possuía 48 neurônios na camada de entrada e 16 neurônios na camada escondida. A Tabela 10 apresenta os valores estimados e reais para as amostras de verificação, o erro médio absoluto (resíduo) e o erro médio relativo (%). Observa-se na Tabela 10 que as diferenças totais entre a biomassa real e a estimada com a utilização desta arquitetura foram satisfatórias, variando de 0,5 a 14,54%, com um erro percentual médio de 7,67%.

TABELA 10 - COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,01.

PARCELA	BIOMASSA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	81.393,78	11.829,76	14,53
8	187.175,91	169.392,47	17.783,44	10,50
36	162.205,67	151.131,59	11,074,08	7,33
24	153.075,24	152.243,59	831,65	0,55
30	181.392,53	172.003,96	9,388,57	5,46
Total	777.072,89	726.165,39	50,907,50	38,36
Media	155.414,58	145.233,079	10,181,50	7,67

Observa-se, no entanto, uma variação grande entre as amostras verificadas, em que pese o fato do uso dessa arquitetura já ter começado a apresentar resultados que justificassem investimentos em tecnologia de mapeamento, por tornar viáveis as estimativas obtidas. Os resultados obtidos com essas configurações já viabilizariam a utilização dessa arquitetura de ANN, para este tipo de estimativa.

Para uma arquitetura com 24 neurônios na camada de entrada e 8 na camada escondida, os resultados encontrados podem ser considerados satisfatórios. A Tabela 11 mostra que houve uma diminuição do erro percentual e da variância entre os mesmos. A amplitude de variação foi de 0,55% para menos até 13,34% para mais, com um erro médio da ordem de 6,94, inferior ao obtido com a outra arquitetura, mas não de maneira significativa, pois ainda ocorreram erros percentuais maiores do que 10%.

Os resultados obtidos com a arquitetura de 12 neurônios na camada de entrada e 4 neurônios na camada escondida são apresentados na Tabela 12. Os resultados revelaram uma variação do erro percentual menor entre as amostras, com uma média de 3,7%,

números que atestam a eficiência dessa arquitetura e do método, que utilizou a segmentação de imagem aliada a modelos de ANN.

TABELA 11 - COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,01.

PARCELA	BIOMASSA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	82.249,67	10.973,87	13,34
8	187.175,91	173.859,29	13.316,62	7,66
36	162.205,67	148.237,67	13.968,00	9,42
24	153.075,24	153.930,70	-855,46	-0,56
30	181.392,53	173.006,79	8.385,74	4,85
Total	777.072,89	731.284,12	45.788,77	34,72
Media	155.414,58	146.256,82	9.157,754	6,94

TABELA 12 - COMPARAÇÃO DA BIOMASSA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,01.

PARCELA	BIOMASSA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	86.177,55	7.045,99	8,18
8	187.175,91	185.231,58	1.944,33	1,05
36	162.205,67	151.924,05	10.281,62	6,77
24	153.075,24	150.906,32	2.168,92	1,44
30	181.392,53	179.253,14	2.139,39	1,19
Total	777.072,89	753.492,64	23.580,25	18,62
Media	155.414,58	150.698,53	4.716,05	3,73

Os resultados da TABELA 12 indicam que as diferenças entre a biomassa real e a estimada com a utilização desta arquitetura foram satisfatórias, apresentando erros que variaram de 1,19 a 8,18%, todos abaixo de 10% e também que houve uma menor variação entre eles, para um erro percentual médio de 3,73%, o menor de todos os encontrados. O gráfico de ajustamento e convergência do modelo é apresentado no ANEXO 15.

No que diz respeito aos resultados obtidos no presente diante de outros realizados utilizando os mesmos procedimentos, LUZ (2002) determinou os parâmetros e a arquitetura de uma ANN aplicada à imagem que não resultou em classificações possíveis de serem utilizadas dada à qualidade do produto obtido. Mesmo alterando todos os parâmetros e reduzindo as camadas de saída, introduzindo informações do relevo como o modelo numérico do terreno, o aspecto e a declividade o autor não obteve resultados satisfatórios.

RIBEIRO (2004), encontrou bons resultados para a classificação utilizando ANN, com índices de acerto por classe em torno de 80%. O autor comparou a classificação de imagens por meio de ANN, em nível de pixels e segmentos e comprovou o melhor

experimento em nível de abstração dos segmentos. Utilizando como variáveis de entrada os três componentes principais, o modelo digital do terreno e microbacias. As classes foram melhor agrupadas devido à segmentação, ao invés da análise em nível de “pixel”, com pequenas regiões isoladas.

Resultados expressivos foram encontrados por WANDRESEN (2004), que comprovou a utilização de ANN para implementar computacionalmente procedimentos de identificação de pontos pré-sinalizados e marcas fiduciais, visando aplicações fotogramétricas. O autor conseguiu localizar, automaticamente, pontos pré-sinalizados na imagem de um modelo aerofotográfico, com erros muito inferiores aos admitidos, em torno de 1%.

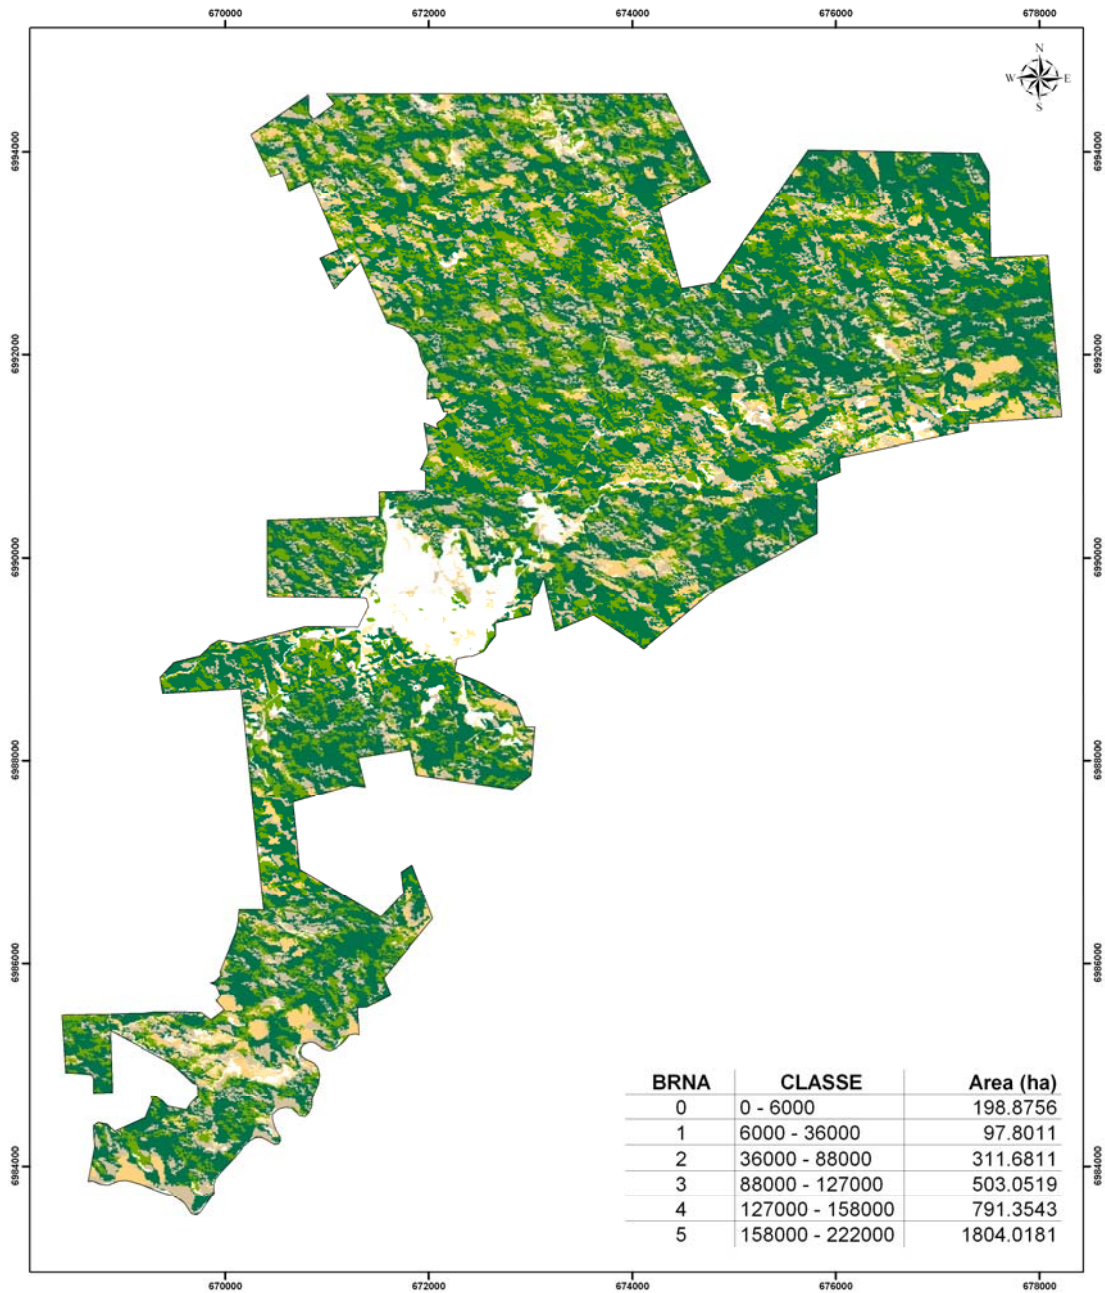
4.6.1 Mapa de biomassa arbórea

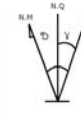
Para obtenção do mapa de biomassa da parte arbórea, foram geradas novas imagens utilizando os coeficientes calculados pela ANN, onde cada segmento passou a representar a quantidade estimada da variável biomassa arbórea. No mapeamento foram utilizados intervalos de classes para melhor avaliar e verificar a aplicação e a interação dos modelos matemáticos com as imagens, os quais tomaram por base os levantamentos realizados em campo. Dessa forma, inicialmente os dados reais obtidos para as amostras no inventário florestal foram classificados em cinco classes de produção, em kg ha^{-1} . Uma vez feita a classificação dos valores das amostras em classes, os valores estimados foram agrupados nessas classes, calculando-se a seguir as áreas existentes em cada classe de produção. O resultado do mapeamento para a biomassa arbórea no fragmento de Floresta Ombrófila Mista Montana é apresentado na Figura 31.

4.7 RESULTADOS DA REDE NEURAL ARTIFICIAL PARA QUANTIDADE DE CARBONO

Os procedimentos utilizados para a obtenção da quantidade de carbono armazenada foram em essência similares aos aplicados na estimativa da biomassa arbórea. A segunda série de experimentos foi feita visando verificar se as amostras de verificação foram corretamente classificadas para a quantidade de carbono. Se na primeira série os dados foram analisados para biomassa arbórea, nessa segunda série os dados de entrada originaram as imagens de saída de carbono, ambas em nível de segmentos.

FIGURA 31 - MAPA DE BIOMASSA ARBÓREA OBTIDO POR MEIO DA UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS.



<p>Legenda (ton/ha)</p> <p>BIOMASSA RNA</p> <ul style="list-style-type: none"> 0 - 6000 6000 - 36000 36000 - 88000 88000 - 127000 127000 - 158000 158000 - 222000 	<p style="text-align: center;">DADOS TÉCNICOS</p> <div style="display: flex; justify-content: space-between;"> <div style="width: 45%;"> <p>PROJEÇÃO UNIVERSAL UTM AMPLITUDE DE FUSO = 6° DATUM VERTICAL: SIBELIA - 65 DATUM HORIZONTAL: SAD - 69 ORIGEM DA QUILOMETRAGEM UTM ACRÉSCIMOS AS CONSTANTES DE 50.000 Km E 500 Km RESPECTIVAMENTE</p> <p>PROJEÇÃO: UTM MERIDIANO CENTRAL: 52° WGR</p> <p>DATA DO VÔO: AGO-SET / 2003 RESTITUIÇÃO AEROFOTOGRAFÉTRICA: DEZEMBRO / 2003</p> <p>FAIXA 28 - FOTOS 285 E 286 COBERTURA AEROFOTOGRAFÉTRICA NA ESCALA DE: 1:30.000</p> <p style="text-align: center;">0 50 100 150 200 m</p> </div> <div style="width: 45%; text-align: center;">  <p>CONVERGÊNCIA MERIDIANA: -0°15'33.1" DECLINAÇÃO MAGNÉTICA: -16°22.4' VARIAÇÃO ANUAL: -0°00.7' COEFICIENTE DE DEFORMAÇÃO K: 0.9996538</p> </div> </div>	<p style="text-align: center;">MAPEAMENTO DE BIOMASSA</p> <p style="text-align: center;">MODELO DE REDES NEURAS ARTIFICIAIS</p> <table border="1" style="width: 100%; border-collapse: collapse;"> <tr> <td style="width: 60%;"></td> <td style="width: 40%;">FAZENDA: SABIA</td> </tr> <tr> <td style="text-align: center;">04/2006</td> <td>LOCALIDADE: APIÚNA</td> </tr> <tr> <td style="text-align: center;">3707,59 ha</td> <td>ARQUIVO: MAPAS</td> </tr> <tr> <td style="text-align: center;">1:40.000</td> <td></td> </tr> </table>		FAZENDA: SABIA	04/2006	LOCALIDADE: APIÚNA	3707,59 ha	ARQUIVO: MAPAS	1:40.000	
	FAZENDA: SABIA									
04/2006	LOCALIDADE: APIÚNA									
3707,59 ha	ARQUIVO: MAPAS									
1:40.000										

Considerando a experiência adquirida quando do processamento da primeira série, o conjunto de parâmetros foi modificado, aplicando-se apenas as seqüências que se mostraram mais promissoras para a biomassa arbórea. Diante disso, os valores digitais da imagem do satélite IKONOS II representaram as variáveis de entrada de cada série, a quantidade de iterações foi variável e o Erro Quadrático Médio foi fixado em quatro categorias. Na Tabela 04 foram apresentados os intervalos testados para o E.Q.M., o número de camadas da ANN e a quantidade de neurônios em cada camada, valores esses que viriam a definir a arquitetura da ANN para a estimativa da quantidade de carbono.

Os resultados do uso das Redes Neurais Artificiais para a obtenção das estimativas da quantidade de carbono foram processados com os dados agrupados pela segmentação. As avaliações para a quantidade de carbono seguiram o mesmo procedimento da biomassa, ou seja, foi avaliado a erro percentual das cinco amostras de verificação não utilizadas no treinamento. O número de neurônios da primeira camada também foi definido como aproximadamente 1/3 das amostras de treinamento e a segunda camada de saída como 1/4 do número de neurônios da primeira camada escondida. Os resultados foram agrupados em três grupos de experimentos, com a definição de um E.Q.M. com limiar baixo, intermediário e alto.

As arquiteturas testadas e reportadas na Tabela 04 apresentam o número de neurônios na camada de entrada, na primeira camada escondida, e na camada de saída, assim como o número de interações utilizadas para se atingir o E.Q.M. estipulado. Foram utilizadas as mesmas 43 amostras usadas no treinamento de biomassa, assim como as cinco amostras deixadas para verificação.

TABELA 13 - COMPARAÇÃO ENTRE A QUANTIDADE DE CARBONO ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,001 e 0,0001.

E.Q.M	ARQUITETURA DA ANN	CARBONO (kg)		RESÍDUO	ERRO %
		REAL	ESTIMADO		
0,0001	12 4	62.641,96	47.038,57	15.603,40	32,98
0,0001	24 8	62.641,96	46.628,57	16.013,39	40,62
0,0001	48 16	62.641,96	47.038,57	15.603,40	32,98
0,001	12 4	62.641,96	46.833,57	15.808,39	36,80
0,001	24 8	62.641,96	46.901,90	15.740,06	35,53
0,001	48 16	62.641,96	46.884,82	15.757,14	35,84

Conforme já mencionado anteriormente, o E.Q.M. não é suficiente para selecionar uma rede neural porque quando se estabelece um limiar muito pequeno pode haver memorização dos dados do treinamento e a rede torna-se viciada com essas amostras (JÚNIOR et al., 2001). O E.Q.M mesmo sendo pequeno ao final do treinamento, será

inaceitável para dados diferentes das amostras de treinamento (MITCHELL, 1997). Os resultados obtidos para a quantidade de carbono confirmam os obtidos para biomassa, quando mesmo com um limiar baixo essa arquitetura apresentou desempenho pobre na classificação das amostras de verificação, com uma piora dos resultados quando se aumentava o limiar.

Para a arquitetura com baixo limiar os erros percentuais variaram de 33 a 41%, erro muito altos em termos de inventário florestal. Os resultados integrais, com todos os valores observados e estimados, com as respectivas estatísticas que testaram sua robustez, são apresentados nos Anexos 16 a 18.

Os resultados para arquiteturas com limiar intermediário de erros, na ordem de 0,005 de E.Q.M., são apresentados na Tabela 14.

TABELA 14 - COMPARAÇÃO ENTRE A QUANTIDADE DE CARBONO ESTIMADA E REAL, PARA REDES NEURAIS ARTIFICIAIS COM LIMIAR FIXADO EM 0,005.

E.Q.M	ARQUITETURA DA ANN	CARBONO (kg)		RESÍDUO	ERRO %
		REAL	ESTIMADO		
0,005	12 4	62.641,96	60.064,35	2.577,61	3,75
0,005	24 8	62.641,96	54.598,73	8.043,24	14,35
0,005	48 16	62.641,96	52.876,81	9.765,16	19,11

Para a configuração da arquitetura com limiar de erro intermediário (Tabela 14), as diferenças encontradas não foram satisfatórias. A amplitude dos erros variou de 3,8 a 19,1%, evidenciando super ou subestimativas e com a média apresentando tendência. Para o limiar de 0,005 somente a arquitetura de 12 camadas de entrada e 4 camadas de saída apresentou resultados abaixo de 10%, o que inviabiliza sua utilização. Os resultados detalhados obtidos são mostrados nos Anexos 19 a 21.

As arquiteturas com limiar alto mostraram-se mais apropriadas e garantiram a convergência em um número menor de interações (Tabela 15), evidenciando resultados mais coerentes com a verdade de campo. Os melhores resultados da arquitetura da rede foram para um Erro Quadrático Médio de 0,01. Essa configuração da Rede Neural Artificial propiciou os melhores resultados estatísticos que embasaram a escolha da arquitetura definitiva de classificação. Por se tratarem dos melhores resultados obtidos, são apresentados os valores estimados e os observados para cada arquitetura.

A arquitetura com 40 neurônios na camada de entrada e 16 na camada escondida apresentou erros variando de 1,9 a 10,8%, com um erro médio de 5,7%, considerando um limiar de erro de 0,01 (Tabela 15). Os erros apresentaram menor variação, com todas as

amostras de verificação apresentando erros menores do que 11%, o que torna essa arquitetura satisfatória mas não ideal do ponto de vista de classificação.

TABELA 15 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,01.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	38.098,30	1.108,03	2,91
8	78.357,82	70.718,30	7.639,52	10,80
36	68.179,06	62.583,84	5.595,21	8,94
24	64.759,75	62.385,91	2.373,84	3,81
30	62.706,86	61.520,27	1.186,60	1,93
Total	313.209,81	295.306,62	17.903,19	28,39
Media	62.641,96	59.061,32	3.580,64	5,68

Para a arquitetura com 24 neurônios na camada de entrada e 8 na camada escondida, os resultados obtidos podem ser considerados bons (Tabela 16). Os erros variaram de -1,9 a 11,8%, com pouca variação e apresentando um erro médio de 5,4%, inferior ao obtido para a arquitetura anterior (5,7%).

TABELA 16 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,01.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	35.073,32	4.133,02	11,78
8	78.357,82	73.613,13	4.744,69	6,44
36	68.179,06	63.469,85	4.709,20	7,42
24	64.759,75	62.635,11	2.124,65	3,39
30	62.706,86	63.932,74	-1.225,88	-1,92
Total	313.209,81	298.724,13	14.485,68	27,12
Media	62.641,96	59.744,83	2.897,14	5,43

Para as estimativas da quantidade de carbono essa arquitetura apresentou o segundo melhor resultado, com homogeneidade semelhante aos dados do inventário florestal. Houve uma diminuição do erro percentual médio, apesar da diferença desse para o obtido nas arquiteturas apresentadas anteriormente não serem significativas.

Os melhores resultados foram obtidos com a arquitetura de 12 neurônios na camada de entrada e 4 neurônios na camada escondida. Os valores observados e estimados são apresentados na Tabela 17.

TABELA 17 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,01.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	93.223,54	86.182,51	7.041,03	8,17
8	187.175,90	184.052,67	3.123,24	1,70
36	162.205,70	152.095,62	10.110,05	6,65
24	153.075,20	149.775,67	3.299,57	2,20
30	149.072,20	150.241,45	-1.169,25	-0,78
Total	744.752,60	722.347,92	22.404,64	17,94
Media	148.950,51	144.469,58	4.480,94	3,59

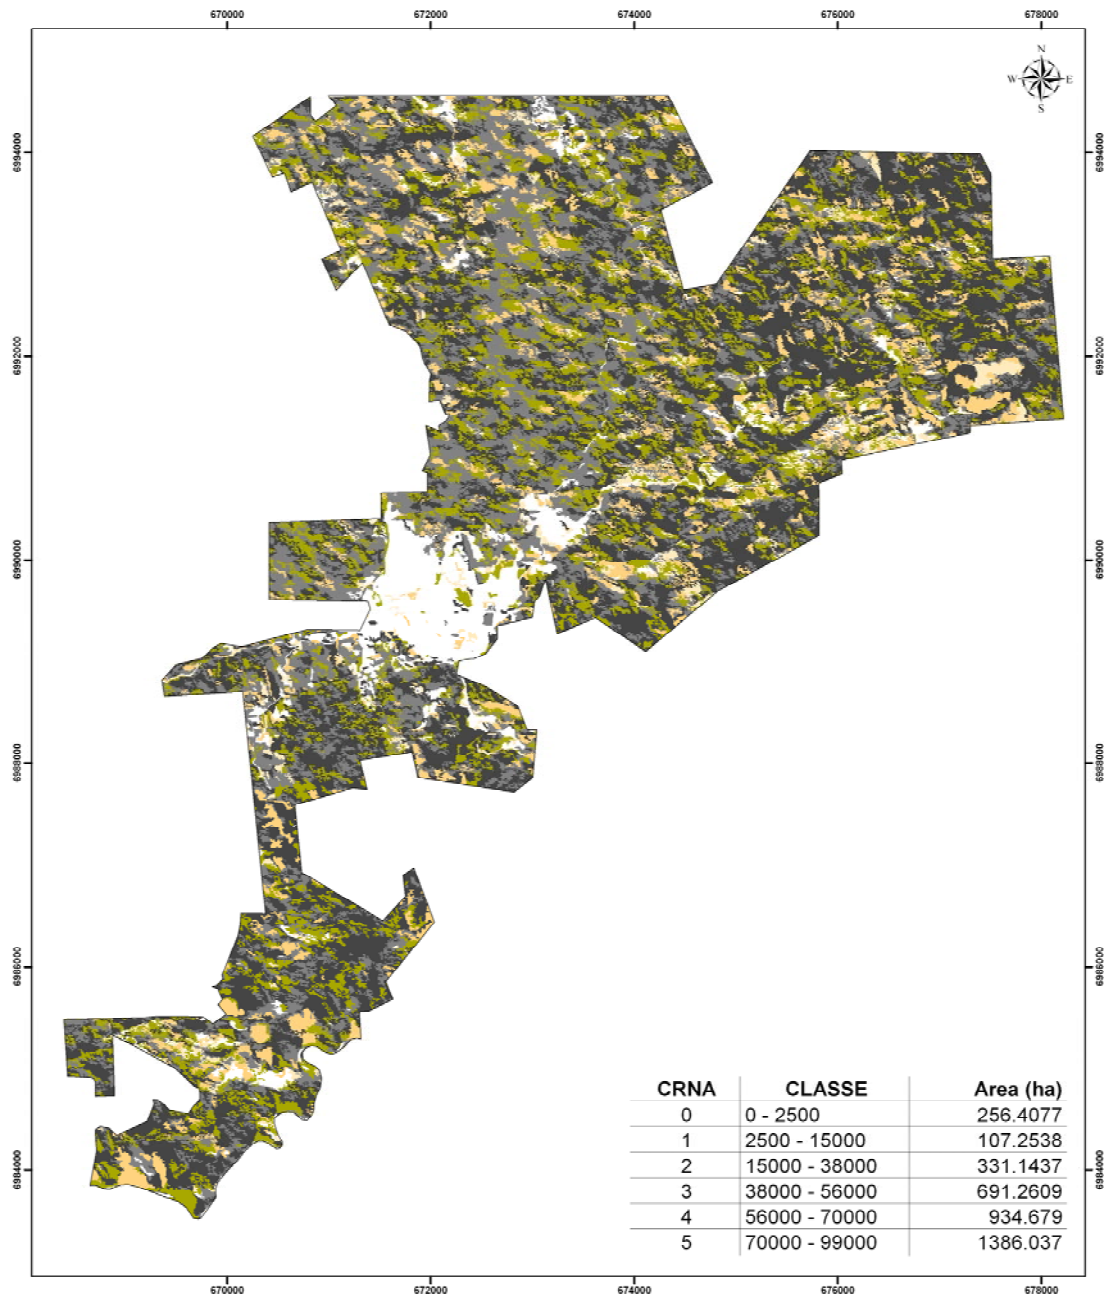
Os resultados obtidos mostram um erro médio da estimativa baixo (3.6%) com todas as amostras apresentando erro percentual abaixo de 10%, o que atesta a eficiência do método sob essa arquitetura. O erro percentual apresentou uma amplitude de - 0,78 a 8,2%, com uma variação pequena entre os valores, levando a conclusão desta ser a melhor arquitetura dentre as testadas. O gráfico de ajuste e as estatísticas de convergência são apresentados no Anexo 25.

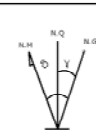
4.7.1 Mapa da quantidade de carbono

Tendo sido definida a melhor arquitetura para a ANN, a quantificação e mapeamento da quantidade de carbono para um fragmento de Floresta Ombrófila Densa pela aplicação do modelo selecionado, pode ser realizado.

Utilizando os coeficientes calculados pela ANN foram geradas novas imagens, onde cada segmento passou a representar a quantidade estimada da quantidade de carbono presente. Para fins de mapeamento os valores de quantidade de carbono observada foram classificados em cinco classes de produção, em kg ha^{-1} . Uma vez obtidas as classes de produção reais, utilizando as equações ajustadas e selecionadas foram geradas novas imagens, com os pesos calculados no treinamento aplicados aos valores médios das bandas RGB e NIR dos segmentos. Cada segmento passou a representar a quantidade estimada de carbono para toda a área de estudo, gerando o mapa apresentado na Figura 32.

FIGURA 32 - MAPA DE QUANTIDADE DE CARBONO OBTIDO POR MEIO DA UTILIZAÇÃO DE REDES NEURAS ARTIFICIAIS.



Legenda (ton/ha) CARBONO RNA 0 - 2500 2500 - 15000 15000 - 38000 38000 - 56000 56000 - 70000 70000 - 99000	DADOS TÉCNICOS  PROJEÇÃO UNIVERSAL - UTM AMPLITUDE DE FUSO = 0° DATUM VERTICAL: BRASUBA - 56 DATUM HORIZONTAL: SAD - 59 ORIGEM DA QUOCIENTAGEM UTM A 500.000 Km E 500 Km RESPECTIVAMENTE. MERIDIANO CENTRAL: 51° WGR DATA DO VOO: AGO-SET / 2003 RESTITUIÇÃO AEROFOTOGRAFICA DEZEMBRO / 2003 FOLHA 25 - FOTOS 288 E 285 COBERTURA AEROFOTOGRAFICA NA ESCALA DE: 1:30.000 CONVERGÊNCIA MERIDIANA: -00°18'33.1" DECLINAÇÃO MAGNETICA: -49°22.4" VARIACÃO ANUAL: -00°08.2" COEFICIENTE DE DEFORMAÇÃO K: 0,9995318	MAPEAMENTO DE CARBONO MODELO DE REDES NEURAS ARTIFICIAIS	
		04/2006 3707,59 ha 1:40.000	FAZENDA: SABIA LOCALIDADE: APIUNA ARQUIVO: MAPAS

4.8 MAPEAMENTO COM USO DE REGRESSÃO LINEAR

O ajuste das equações de regressão lineares múltiplas para obtenção das estimativas de biomassa arbórea e quantidade de carbono utilizou os valores digitais das bandas do satélite IKONOS II (MS-1, MS-2, MS-3, MS-4) como variáveis independentes e os valores de biomassa arbórea e quantidade de carbono das amostras como variáveis dependentes. As variáveis independentes foram às mesmas utilizadas pelo procedimento de Redes Neurais Artificiais, a fim de que os resultados pudessem ser comparados. Para selecionar a melhor equação, dentre os vários modelos ajustados, foram calculadas as estatísticas coeficiente de determinação ajustado ($R^2_{\text{ajust.}}$), erro padrão da estimativa (s_{xy}), erro padrão da estimativa em porcentagem ($s_{xy}\%$) e o valor da razão F de Fisher.

No ajuste das equações não foram usadas cinco amostras dentre as 48 coletadas, que foram deixadas para validação do modelo ajustado, sendo essas amostras as mesmas que validaram o procedimento de Redes Neurais Artificiais. Para as amostras de validação foram calculados os desvios percentuais entre os valores observados e os valores estimados pela melhor equação ajustada.

Para a estimativa da biomassa arbórea a equação que apresentou melhores resultados foi:

$$BSA = 224566,75 + 18,98 * MS-1 - 79,27 * MS-2 + 67,19 * MS-3 - 140,67 * MS-4 \quad (54)$$

$$F = 11,92$$

$$R^2_{\text{ajust.}} = 0,50$$

$$s_{xy} = 44.444$$

$$s_{xy}\% = 29,83$$

onde:

BSA = Biomassa arbórea em kg;

MS-1, MS-2, MS-3 e MS-4 = valores digitais.

Pode-se considerar que as equações obtiveram resultados satisfatórios, embora inferiores aos encontrados por WATZLAWICK (2003), provavelmente porque o autor utilizou além das bandas do satélite os índices de vegetação e de solo (NDVI e SAVI). Cabe salientar que as correlações simples encontradas, apresentadas anteriormente, foram melhores que as obtidas pelo mesmo autor, fato que pode ser explicado em função das

correlações obtidas no presente terem utilizado valores médios dos segmentos, o que proporcionou uma diminuição da variância dos dados.

A validação da equação de biomassa arbórea ajustada, apresentada na Tabela 18, revelou diferenças médias de 13,6%, variando de 24% para menos até 54% para mais. A diferença porcentual média de 13,6% foi menor do que a obtida quando da utilização do procedimento de ANN.

TABELA 18 - COMPARAÇÃO DOS RESULTADOS DAS ESTIMATIVAS DE BIOMASSA ARBÓREA UTILIZANDO A EQUAÇÃO DE REGRESSÃO MÚLTIPLA.

Parcela	Biomassa Arbórea (kg)		Resíduo	Erro (%)
	Estimada	Real		
21	122.960,84	93.223,54	-29.737,30	-24,18
8	158.059,12	187.175,91	29.116,80	18,42
36	138.401,90	162.205,67	23.803,77	17,20
24	138.928,19	153.075,24	14.147,05	10,18
30	137.453,70	149.072,20	11.618,51	8,46
Total	695.803,74	744.752,56	48.948,82	54,26
Média	139.160,75	148.950,51	9.789,76	13,56

MACIEL (2002), com imagens LANDSAT 7TM ajustando equações de regressão lineares múltiplas, obteve distorções de pequena ordem na estimativa de valores de biomassa, por estrato, em floresta natural, tendo registrado equações que conseguiram explicar até 75% da variação total.

Na seleção e ajuste das equações de regressão lineares para gerar as estimativas da quantidade de carbono na Floresta Ombrófila Densa da área estudada, foram utilizados os valores das bandas do satélite IKONOS II, como realizado para a obtenção da biomassa arbórea. A melhor equação ajustada foi:

$$CC = 94443,72 - 8,58 * MS-1 - 36,59 * MS-2 + 28,56 * MS-3 - 55,89 MS-4 \quad (55)$$

$$F = 11,92$$

$$R^2 \text{ ajust.} = 0,51$$

$$s_{xy} = 18.699$$

$$s_{xy}\% = 29,85$$

onde:

CC = Conteúdo de carbono em kg;

MS-1, MS-2, MS-3 e MS-4 = valores digitais.

Baseado nos resultados de validação, apresentados na Tabela 19, pode-se concluir que as diferenças entre as quantidades reais e as estimadas pela equação que estima o conteúdo de carbono foram superiores às obtidas com o uso das técnicas de ANN, sendo que a amplitude de variação foi de 24,28% para menos até 17,22% para mais.

TABELA 19 - COMPARAÇÃO DOS RESULTADOS DAS ESTIMATIVAS DO CONTEÚDO DE CARBONO UTILIZANDO A EQUAÇÃO DE REGRESSÃO MÚLTIPLA.

Parcela	Conteúdo de Carbono (kg)		Resíduo	Erro (%)
	Estimado	Real		
21	39.206,33	51.780,33	-12.574,00	-24,28
8	78.357,82	66.513,29	11.844,53	17,81
36	68.179,05	58.165,39	10.013,67	17,22
24	64.759,75	58.310,94	6.448,81	11,06
30	62.706,86	57.735,51	4.971,35	8,61
Total	313.209,81	292.505,46	20.704,35	30,41
Média	62.641,96	58.501,09	4.140,87	6,08

WATZLAWICK (2003), encontrou desvios percentuais menores, provavelmente por ter utilizado além das bandas do satélite os índices de vegetação e de solo (NDVI e SAVI). Os coeficientes de correlação obtidos no presente foram superiores aos obtidos pelo mesmo autor, uma vez que foram consideradas as médias dos segmentos das bandas puras MS-1, MS-2, MS-3 e MS-4, o que diminuiu a variância dos dados. Os resultados obtidos reafirmam a estreita relação entre a biomassa e o conteúdo de carbono, tendo em vista que o conteúdo de carbono é obtido por meio da utilização de um fator de conversão.

4.8.1 Mapa de biomassa arbórea

Um dos objetivos do presente foi a obtenção da estimativa da biomassa arbórea da área de estudo, com a conseqüente geração de um mapa de biomassa arbórea para um

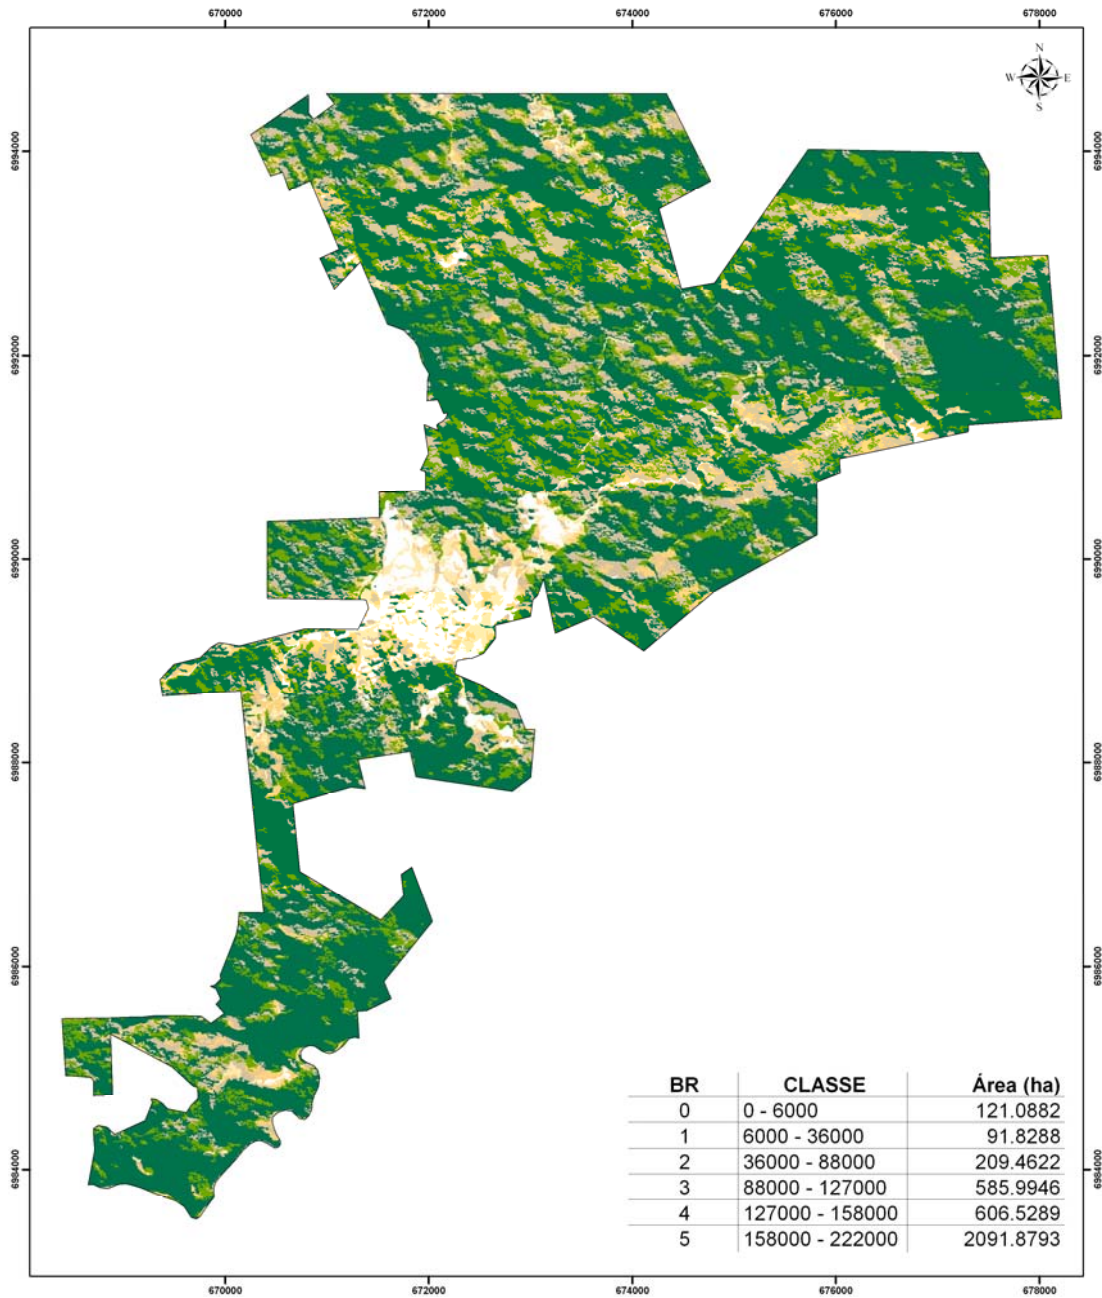
fragmento de Floresta Ombrófila Densa, pela utilização de uma função matemática ajustada para os dados de biomassa coletados na área.

Utilizando a equação selecionada foram geradas novas imagens, onde cada segmento passou a representar a quantidade estimada da variável biomassa arbórea. Para gerar o mapa de biomassa arbórea da área, as quantidades estimadas foram classificadas em cinco classes. Esse procedimento teve por objetivo permitir a avaliação, verificação e visualização dos resultados de biomassa, sendo que o produto obtido é apresentado na Figura 33.

4.8.2 Mapa de conteúdo de carbono

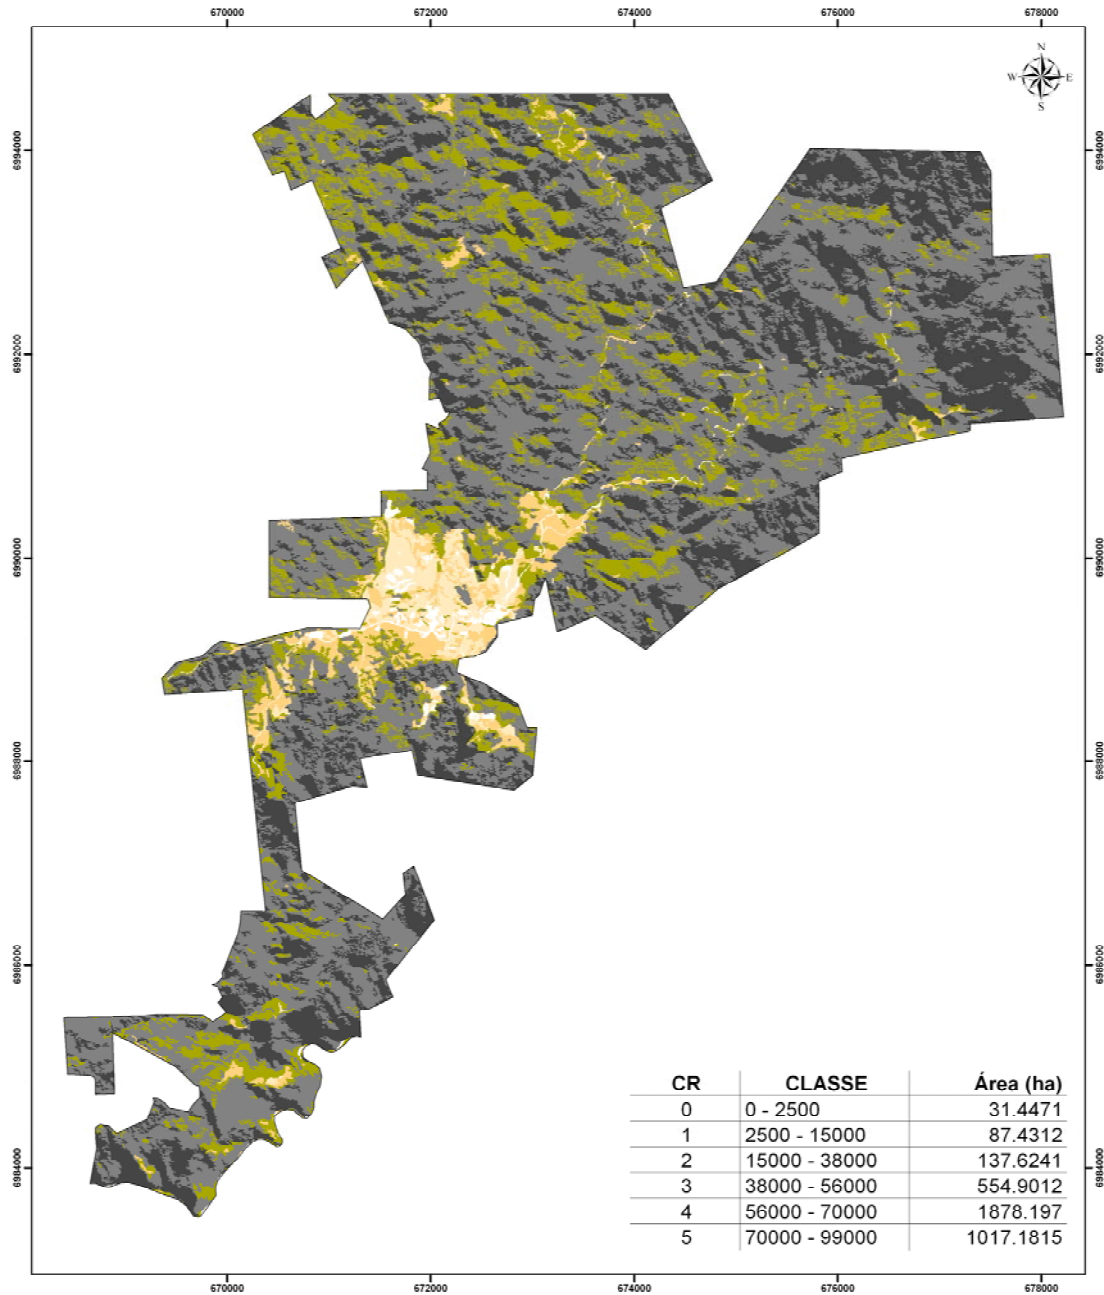
Assim como realizado para a obtenção do mapa de biomassa arbórea, para a geração do mapa de conteúdo de carbono foi utilizada a equação selecionada. Foram geradas novas imagens, onde cada segmento passou a representar a quantidade estimada da variável quantidade de carbono, também classificadas em cinco classes, gerando o mapa apresentado na Figura 34.

FIGURA 33 - MAPA DE BIOMASSA ARBÓREA OBTIDO POR MEIO DA UTILIZAÇÃO DA EQUAÇÃO DE REGRESSÃO AJUSTADA.



<p>Legenda (ton/ha)</p> <p>BIOMASSA REGRESSÃO</p> <ul style="list-style-type: none"> 0 - 6000 6000 - 36000 36000 - 88000 88000 - 127000 127000 - 158000 158000 - 222000 	<p>DADOS TÉCNICOS</p> <p>PROJEÇÃO UNIVERSAL - UTM AMPLITUDE DE FUSO = 60° DATUM VERTICAL - IMBETURA - SC DATUM HORIZONTAL - SAD - 59 ORDEM DA QUILOMETRAGEM UTM ACRESCIDAS AS CONSTANTES DE 10.000 Km E 500 Km RESPECTIVAMENTE. MERIDIANO CENTRAL: 51° WGR</p> <p>DATA DO VÔO: AGO-SET / 2003 RESTITUIÇÃO AEROFOTOGRAFÉTRICA SEZEMBRO / 2003</p> <p>FALSA 38 - FOTOS 288 E 286 COBERTURA AEROFOTOGRAFÉTRICA NA ESCALA DE 1:30.000</p> <p>0 50 100 150 200 m</p>	<p>MAPEAMENTO DE BIOMASSA</p> <p>MODELO DE REGRESSÃO AJUSTADA</p>							
		<table border="1"> <tr> <td></td> <td>FAZENDA: SABIÁ</td> </tr> <tr> <td>04/2006</td> <td>LOCALIDADE: APIÚNA</td> </tr> <tr> <td>3707,59 ha</td> <td>ARQUIVO: MAPAS</td> </tr> <tr> <td>1:40.000</td> <td></td> </tr> </table>			FAZENDA: SABIÁ	04/2006	LOCALIDADE: APIÚNA	3707,59 ha	ARQUIVO: MAPAS
	FAZENDA: SABIÁ								
04/2006	LOCALIDADE: APIÚNA								
3707,59 ha	ARQUIVO: MAPAS								
1:40.000									

FIGURA 34 - MAPA DE CONTEÚDO DE CARBONO OBTIDO POR MEIO DA UTILIZAÇÃO DA EQUAÇÃO DE REGRESSÃO AJUSTADA.



<p>Legenda (ton/ha)</p> <p>CARBONO REGRESSÃO</p> <ul style="list-style-type: none"> 0 - 2500 2500 - 15000 15000 - 38000 38000 - 56000 56000 - 70000 70000 - 99000 	<p>DADOS TÉCNICOS</p> <p>PROJEÇÃO UNIVERSAL - UTM AMPLITUDE DE FUSO = 0° DATUM VERTICAL: BRILUBA - 50 DATUM HORIZONTAL: S42 - 59 ORIGEM DA QUOCIENTAGEM UTM A 500000 m E 500 Km RESPECTIVAMENTE. MERIDIANO CENTRAL: 51° WGR</p> <p>DATA DO VOO: AGO-SET / 2003 RESTITUIÇÃO AEROFOTOGRAFICA DEZEMBRO / 2003 FOLHA 25 - FOTOS 258 E 205 COBERTURA AEROFOTOGRAFICA NA ESCALA DE: 1:30.000</p> <p>CONVERGÊNCIA MERIDIANA: -00°18'33.1" DECLINAÇÃO MAGNÉTICA: -49°22'4" VARIACÃO ANUAL: -00°04'2" COEFICIENTE DE DEFORMAÇÃO K: 0,9995318</p>	<p>MAPEAMENTO DE CARBONO</p> <p>MODELO DE REGRESSÃO AJUSTADA</p> <table border="1"> <tr> <td></td> <td>FAZENDA: SABIA</td> </tr> <tr> <td>04/2006</td> <td>LOCALIDADE: APIUNA</td> </tr> <tr> <td>3707,59 ha</td> <td>ARQUIVO: MAPAS</td> </tr> <tr> <td>1:40.000</td> <td></td> </tr> </table>		FAZENDA: SABIA	04/2006	LOCALIDADE: APIUNA	3707,59 ha	ARQUIVO: MAPAS	1:40.000	
	FAZENDA: SABIA									
04/2006	LOCALIDADE: APIUNA									
3707,59 ha	ARQUIVO: MAPAS									
1:40.000										

5 CONCLUSÕES E RECOMENDAÇÕES

5.1 CONCLUSÕES

Os resultados obtidos no presente trabalho, nas condições em que os dados foram coletados, evidenciaram que:

- a análise da estrutura horizontal da área revelou a presença de uma floresta em estágio intermediário de desenvolvimento, dada a grande presença de espécies da família *Cyatheaceae* (xaxins), característica de áreas nesse estágio de desenvolvimento;
- foram encontradas altas correlações entre os valores de biomassa e carbono armazenado e os valores das bandas das imagens do satélite IKONOS II, superiores aos encontrados na literatura;
- a aplicação da técnica de Redes Neurais Artificiais (ANN) foi efetiva na obtenção de estimativas de biomassa arbórea e na quantidade de carbono orgânico armazenado, bem como produziu mapas temáticos eficazes em Floresta Ombrófila Densa;
- a utilização de ANN possibilita a utilização de variáveis de diferentes origens e escalas, permitindo sua integração e geração pelo emprego de fórmulas matemáticas;
- os algoritmos empregados pela técnica de ANN mostraram-se robustos;
- a utilização da segmentação na modelagem das redes neurais, mostrou-se eficiente pois permitiu a correlação entre as imagens, aumentando o grau de aprendizado da ANN;
- a definição da arquitetura da ANN mostrou-se trabalhosa por iniciar-se de forma empírica, exigindo refinamento do usuário em relação ao conhecimento da área de estudo;
- uma vez treinada para a área em questão, a ANN permite a inserção de um número maior de variáveis de entrada, o que possibilita a obtenção de resultados mais exatos;

- a integração de dados de diferentes origens mostrou ser uma vantagem da ANN em estudos dessa natureza em relação a outras técnicas, pois permite a automação na separação de classes e na obtenção das estimativas desejadas, pois não exige o estabelecimento de padrões de interpretação visuais;
- a integração dos dados de diferentes origens é fator importante na transferência para um só sistema e escala das informações provenientes do Sensoriamento Remoto (imagens IKONOS II), Segmentação (*Ecognition 4.0 / IKONOS II*) e dos dados de campo (Inventário Florestal);
- a classificação obtida, representada pela quantificação da biomassa arbórea e da quantidade de carbono armazenada atingiu os objetivos no que diz respeito à convergência e ao Erro Quadrático Médio especificado;
- as estatísticas obtidas na comparação entre os valores estimados e os valores das amostras de validação atestam a eficiência do uso da técnica de ANN;
- a utilização das técnicas de ANN mostrou-se mais efetiva do que a aplicação das técnicas de regressão linear, pois os erros obtidos foram menores;
- uma vez estruturado o sistema de ANN e encontrada sua arquitetura mais efetiva, a implementação da obtenção de novas estimativas e inserção de outras variáveis é feita de forma facilitada;
- a transferências das informações geradas pela utilização de ANN para um sistema de geoprocessamento é obtida de maneira extremamente fácil, dada à estrutura da ANN.

5.2 RECOMENDAÇÕES

Como principais recomendações o presente trabalho apresenta:

- a necessidade de se executar testes com ANN em outras áreas a fim de determinar sua acuidade;
- a necessidade de se estudar formas mais simples e menos onerosas para a obtenção das estimativas de biomassa arbórea e quantidade de carbono, tendo em vista que o presente baseou-se em onerosos e laboriosos trabalhos de campo;
- a necessidade de se estudar a inclusão de outras variáveis de entrada na ANN, como os índices de vegetação e modelo digital do terreno;
- a necessidade da análise da viabilidade do uso de ANN com imagens oriundas de outros sensores.

6 REFERÊNCIAS

ACCO, M. **Estimativa de micronutrientes em floresta Ombrófila Mista Montana utilizando dados de campo e dados obtidos a partir de imagens do satélite IKONOS II.** Curitiba: Dissertação (Mestrado em Ciências Florestais-Manejo Florestal).Universidade Federal do Paraná. 103p. 2004.

AKAMINE, A. **Explorando alternativas para a construção de modelos neurais de interação espacial.** São Carlos: Dissertação (Escola de Eng. De São Carlos. USP). 2005.

AFONSO, A.G. **Caracterização de fisionomias vegetais na Amazonia oriental através de vidiografia aerotransportada e imagens landsat 7 ETM+.** São José dos Campos: INPE. São Paulo. 120p. 2004

ALLARD. F.; FUCHS, J. Artificial Intelligence - The State of the Art. ESA's Technology. **Programme Quartely.** v.3. n.3. 1993.

AMBIENTEBRASIL - Portal Ambiental. **Mata Atlantica: Patrimonio de Reserva Natural da Humanidade (UNESCO).** Disponível em<<http://www.ambientebrasil.com.br/composer...conteudo=/natural/biomas/mataatlantica.html>> acessado em 3/7/2006.

ANDRADE, A. F. Integração de variáveis espectrais e forma na classificação de imagens de alta resolução utilizando redes neurais artificias. **Bol. Ciênc. Geod.**, Curitiba, v.9, n.1, 152-153p. 2003.

ANTUNES, A. F. B. **Classificação de Ambiente Ciliar Baseada em Orientação a Objeto em Imagens de Alta Resolução Espacial.** TESE (Doutorado Ciências Geodésicas na Universidade Federal do Paraná. 147p. 2003.

APPENZELLER, T. O Caso da Fuga do Carbono. National Geographic Magazine Portugal. disponível em<<http://www.nationalgeographic.pt/revista/2004/feature5/default.asp>> acesso em: 10/01/2006.

AVERY, T.E. e BERLIN, G.L. **Fundamentals of Remote Sensing and Airphoto Interpretation.** New Jersey: Prentice Hall. 472p. 1992.

BAATZ, M.; SCHÄPE, A. **Multiresolution segmentation: an optimization approach for high quality multi-scale image segmentation.** München: 2001. Disponível em <<http://www.definiens.com>> Acesso em 08/08/2005.

BARBOSA, K.M. **Monitoramento Espacial de Biomassa e Carbono Orgânico da Vegetação Herbácea de Várzea na Amazônia Central.** Curitiba: TESE (Doutorado em Ciências Florestais – Manejo Florestal - UFPR). 2006.

BAUER, M.E.; VANDERBILT, V.C.; ROBINSON, B.F. et al. Spectral properties of agricultural crops and soils measured from space, aerial, field and laboratory sensors. Hamburg: Congress of international society photogrametry, 16. **Proceedings.** 56-73p. 1980.

BEALE, R.; JACKSON, T. **Neural Computing**. Bristol - UK. Institute of Physics Publishing. 240p. 1992.

BERTALANFFY, L.V. Teoria geral dos sistemas. Petrópolis: Editora Vozes, 1975. 351 p.

BITTENCOURT, G. **Inteligência artificial**. Florianópolis: Editora UFSC. 400p. 1998.

BLASCHKE, T.; HAY G. **Object-oriented image analysis and scale-space: theory and methods for modeling and evaluating multiscale landscape structure**. 2002. Disponível em:<www.defeniens.com/publication.pdf> Acesso em 10 de janeiro de 2004.

BOCANEGRA, C.W.R. **Procedimentos para tornar mais efetivo o uso das redes neurais artificiais em planejamento de transportes**. São Carlos: DISSERTAÇÃO (Escola de engenharia de São Carlos - USP). 108p. 2002.

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

BRAGA, H. J. ; GHELLRE, R. **Proposta de diferenciação climática para o Estado de Santa Catarina**. In: Reunião Latino-Americana de Agrometeorologia. Anais. 1999.

BRAGA, A .P. ; LUDEMIR, T. B. ; CARVALHO, A . C. P. F. **Redes neurais artificiais – teoria e aplicações**. Rio de Janeiro: LTC Livros Técnicos e Científicos Editora S.A. 237p. 2000.

BRIO, B.M.; MOLINA, A.S. **Redes neurales y sistemas barrosos**. Madrid: RaMa Editorial. 2001.

BURROUGH, P.A. **Principles of geographical information system for earth resources assessment**. Oxford: Clarendon Press. 193p.1986.

CÂMARA, G.; MEDEIROS, J.S. **Geoprocessamento para Projetos Ambientais**. INPE.2ªed.1998. Disponível em <http://www.inpe.br/dpi/cursos/gisbrasil/index.html>. Acessado em 10/05/2006.

CANAVESI, V. **Estimativa de macronutrientes em floresta Ombrófila Mista Montana utilizando dados de campo e dados obtidos a partir de imagens do satélite IKONOS II**. Curitiba: Dissertação (Mestrado em Ciências Florestais-Manejo Florestal).Universidade Federal do Paraná. 116p. 2004.

CARVALHO, L.A.V. Aplicação de redes neurais na Implementação de um sistema de auxílio ao diagnóstico em um Instrumento Médico-hospitalar. **Revista de física aplicada e Instrumentação**, v. 17 n.1. 11/03/2004.

CHAVEZ, P.S. Image – based atmospheric corrections. Revisited and improved. **Photogrammetric Engineering and Remote Sensing**. v. 62, 1025 – 1036p. 1996.

COLE, V.; CERRI, C.; MINAMI, K.; MOSIER, A.; ROSENBERG, N.; SAUERBECK. Agricultural options for mitigation of greenhouse gas emissions. **IN: WATSON, R.T. (Ed.) Climate Change 1995. Impacts, adaptations and mitigations of climate change – Scientific-technical analyses**. Cambridge: Cambridge University Press v.23,. 747-771p. 1995.

CREPANI, E. **Princípios básicos de sensoriamento remoto**. São José dos Campos: CNPQ/INPE, 45p. 1993.

CRUZ, N.C.; GALO, M.L.B.T. mapeamento das infestações por plantas aquáticas em reservatórios utilizando imagens multiescala e redes neurais artificiais. RBC - **Revista Brasileira de Cartografia**. n.57/02. 2005.

DASMAN, R.F.; MILTON, J.P.; FREEMAN, P.H. **Ecological principles for economic development**. New York: John Wiley. 232 p. 1973.

DURIGAN, M.E. **Florística, dinâmica e análise protéica de uma Floresta Ombrófila Mista em São João do Triunfo-PR**. Curitiba: 1999. 125 f. Dissertação (Mestrado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná.

FERREIRA, C.A.; GALVÃO, A.P.M. Importância da atividade florestal no Brasil. In: GALVÃO, A.P.M. **Reflorestamento de propriedades rurais para fins produtivos e ambientais**. Colombo: um guia para ações municipais e regionais. Colombo: Embrapa Florestas. 15-18p. 2000.

FREEMAN, J. A.; SKAPURA, D. M. **Neural Network - Algorithms and Programming Techniques**. Reading. Addison Wesley Pub. Comp. 1991.

GAPLAN. **Atlas de Santa Catarina**. Rio de Janeiro, 1986. 173p.

GATES, D.M. **Biophysical ecology**. New York: Springer-Verlag. 611p. 1980.

GATES, D.M.; KEEGAN, H.J.; SCHLETER, J.C.; WEIDER, V.R. Spectral properties of plants. **Applied Optics**, v.4, n.1. 1-20p. 1965.

GERMAN, G.W.H.; GAHEGAN, M.N. Neural network architectures for the classification of temporal image sequences. **Computers Geosciences**, v.22, n.9. 969-979p. 1996.

GONÇALVES, L.; FONSECA, A.M.; CAETANO, M. Exploração de imagens de alta resolução do satélite IKONOS. LISBOA: **ESIG**. 1-22p. 2001.

GONZALEZ, R. C.; WOODS, R. E. **Processamento de Imagens Digitais**. São Paulo: Ed. Edgard Blücher. 509p. 2000.

GONZALEZ, R.C.; WOODS, R.E. **Digital image processing**. Addison-Wesley Publishing Company, 630p. 1998.

GOSE, E.; JOHNSONBAUGH, R.; JOST, S. **Patter RNA recognition and image analysis**. New Jersey: Prentice Hall, Inc. 484p. 1996.

GOWARD, S.; TOWNSHEND, J.; DAVIS, P.; FLAMING, D. Radiometric Comparison of IKONOS e Landsat 7 ETM+ Observations: Implications for Science Applications. **High Spatial Resolutions Commercial Imagery Workshop**. Maryland: Greenbelt. 2001.

GUIMARÃES, R.V. **Aplicação de geoprocessamento para o aumento da eficiência de percurso em operações agrícolas na cultura da cana de açúcar (Saccharum spp.)**. Piracicaba: TESE (Escola Superior de Agricultura Luiz de Queiroz). 93p. 2004.

GUYOT, L.A.; GUYON,D.; RIOM,J. Factors affecting the spectral response of forest canopies: a review. **Geocarto International**, v.4,n.3, 3-18p. 1989.

GUYOT, G. Optical properties of vegetation canopies. In: STEVEN,M.D.; CLARK,J.A. (Ed.) **Applications of remote sensing in agriculture**. London: Butterworths, v.2. 19-43p. 1990.

HAYKIN, S. **Neural networks. A comprehensive foundation**. New Jersey: Prentice Hall. 842p. (1999).

HECHT-NIELSEN, R. **Neurocomputing**. San Diego: Addison-Wesley. 433p.1989.

HEWITSON, B. C.; CRANE, R. G. **Climate downscaling: techniques and application**. *Clim. Res.*, vol. 7, pág. 85-95.

HUANG, C.; WYLIE, B.; YANG, L.; HOMER, C.; ZYLSTRA, G. **Derivation of a tasseled cap transformation based on Landsat 7 at-satellite reflectance**. *International Journal of Remote Sensing*, v. 23, n. 8, 1741-1748p. 2002.

IBGE. **Manual técnico da vegetação brasileira**. Rio de Janeiro, 1992. 92p.

INTERA TYDAC. **Introduction to Data Structure Using Spans OS/2 SPANS Version 5**. Ottawa: intera tydac.140p. 1992.

IPCC – **INTERGOVERNMENTAL PANEL ON CLIMATE CHANGE. Climate Change 2001: The scientific basis**. HOUGHTON, J.T.; DING, Y.; GRIGGS, D.J.; NOGUER, M.;VAN DER LINDEN, P. J. DAI, X. MASKELL, K.; JOHNSON, C.A. Cambridge: Cambridge University Press. 881p. 2001.

JACKSON, R.D.;HUETE, A.R. Interpreting vegetation indices. **Preventive Veterinary Medicine**, v.11,n. 3-4,p.185-200,1991.

JARVIS, H. C.; STUART, N. 1996. The sensitivity of neural network for classifying remotely sensed imagery. **Computers Geosciences**, v. 22, n.9. 959 – 967p.

JÚNIOR, D. S. G.; PINTO, F. A. C.;QUEIROZ, D. M.; MANTOVANI, E. C. **Algoritmo para classificação de plantas de milho atacadas pela lagarta do cartucho (*Spodoptera frugiperda*, Smith) em imagens digitais**. Campina Grande: Revista Brasileira de Engenharia Agrícola e Ambiental, v.5, n.3, 502-509p, 2001.

KLEIN, R.M. **Mapa fitogeográfico do Estado de Santa Catarina**. Itajaí, 1978. 24p.

KOFFER, N.F. Técnicas de sensoriamento remoto orbital aplicadas ao mapeamento da vegetação e uso da terra. **Geografia**. V.17,n.2. 14-17p. 1992.

LEITÃO-FILHO, H.F. diversity of arboreal species in atlantic rain forest. **Anais da Academia Brasileira de Ciências**, v.16, n.1, 91-96 p.. 1994

LOETSCH, F. & HALLER, K. E. **Forest Inventory**. Munich, 1973. 436 p. Vol. I.

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

LOPES, I.V. **O mecanismo de desenvolvimento limpo – MDL: Guia de orientação**. Rio de Janeiro: Fundação Getulio Vargas. 90p. 2002.

LUZ N. B. **Análise espacial como subsídio à recuperação de ecossistemas apoiada na ecologia de paisagens e imagens ikonos**. Curitiba: Dissertação (Mestrado em Ciências Florestais – Manejo Florestal). Universidade Federal do Paraná. 126p. 2002.

MACHADO, S.A ; FIGUEIREDO FILHO, A. **Dendrometria**. Curitiba, 2003. 309 p.

MACIEL, M. N. M. **Estimativa de parâmetros estruturais de uma floresta primária na amazônia oriental através de dados orbitais**. Curitiba: TESE (Doutorado em Ciências Florestais – Manejo Florestal). Universidade Federal do Paraná. 124p. 2002.

MAFFRA, C. Q. T. **Modelagem da Umidade do Solo a Partir de Dados Multiespectrais dos Sistemas Landsat, Aster e Modis**. Curitiba: TESE (Doutorado em ciência geodésicas – UFPR). 149p. 2004.

MANTOVANI, W. A Dinâmica das floresta de encosta Atlântica. In: Simpósio de ecossistemas da costa sul e sudeste brasileiras, 2. São Paulo: **Anais**. 304-313p. 1990.

MASCARENHAS, N.; VELASCO, F. **Processamento Digital de Imagens**. São Paulo: Instituto de Matemática e Estatística, 1989.

MATLAB. **User's Guide** – Neural Network Toolbox. Version 6.5. Mth Works. 2001.

MEDEIROS, J.S. **Banco de dados geográficos e redes neurais artificiais: Tecnologias de Apoio 'a Gestao do Território**. Tese. (Doutorado em geografia física Universidade de SÃO Paulo). Faculdade de Filosofia, Letras e Ciências Humanas - Departamento de Geografia. SP. 218p. 1999.

Mitchell, T. .M. **Machine learning**. Boston: McGraw Hill Companies Inc. 414p. 1997.

MORAES, E.C. **Radiometria óptica espectral – comportamento espectral**. São José dos Campos: Anais (VIII SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO – INPE). 1996.

MOREIRA, M.A. **Fundamentos do Sensoriamento Remoto e Metodologias de aplicação**. Viçosa: Universidade Federal de Viçosa. 307p. 2003.

MOREIRA, M, A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação**. São José dos Campos: INPE. 249p. 2001.

MYERS, N.; MITTERMEIER, R.A.; MITTERMEIER, C.G. FONSECA, G.A.G.; KENT, J. Biodiversity hotspot for conservation priorities. **Nature**, v.403. 853-858p, 2000.

NOBREGA, R. P. ; FILHO, C.R.S. Análise Espacial Guiada Pelos Dados (Data-Driven): O Uso De Redes Neurais Para Avaliação Do Potencial Poli-Mineralico Na Região Centro-Leste da Bahia. **Revista Brasileira de Geociências Nóbrega**, v.3. 111-120p. 01/06/2003.

OKIDA, R.; LUIZ, S.; OLIVEIRA, C.G. Avaliação da precisão de orto-imagens IKONOS. **Anais XI SBSR**, Belo Horizonte: 05-10 abril 2003. INPE. 285-292p. 2003.

ORPLANA – **Organização de plantadores de cana do estado de São Paulo.** <http://www.orplana.com.br/noticia_orplana.asp> disponível em 20 de junho de 2006.

PEDRO, P. C. **Ortoretificação de Imagens de Alta Resolução IKONOS e QUICKBIRD utilizando o modelo APM (Affine Projection Model).** Curitiba: TESE (Doutorado em Ciências Geodésicas – Universidade Federal do Paraná). 97p. 2005.

PÉLLICO NETTO, S. ; BRENA, D.A. **Inventário Florestal.** Curitiba, 1997. 316 p. Vol. I.

PONS, N.A.D. **Levantamento e diagnostico geológico-geotecnico de áreas degradadas na cidade de São Carlos- SP. com auxilio de geoprocessamento.** (TESE) Doutorado em Geotecnia Escola de Engenharia de São Carlos – USP). 233p. 2006.

PONZONI, F.J. Comportamento Espectral da vegetação. In: MENESES, P.R.; MADEIRA NETTO, J. S. **Sensoriamento Remoto: Reflectancia dos alvos naturais.** Brasília, DF: UNB. Planaltina: EMBRAPA Cerrados. 262p. 2001.

REIDMILLER, M.; BRAUN, H. A direct adaptive method for faster backpropagation learning: the RPROP algorithm. San Francisco: **Proc. IEEE Int. Conf. On NN (ICNN).** 586 – 591p. 1993.

RENNER, R.; GRAÇA, L. R. **Seqüestro de carbono e a viabilização de novos reflorestamentos no Brasil.** Curitiba: Dissertação em Manejo Florestal Universidade Federal do Paraná). 116p. 2004.

RIBEIRO, S.R.A.; CENTENO, J.A.S. Clasificación del uso del suelo utilizando redes neurales y el algoritmo MAXVER. **Innovacion.** Antofagasta: n.1, 55-60p. Antofagasta. 2002.

RIBEIRO, S. **Classificação do uso de solo utilizando redes neurais eo algoritmo MaxVer.** Curitiba: TESE (Doutorado em Ciências Geodésicas Universidade Federal do Paraná). 186p. 2004.

RIBEIRO, S.R.A.; TEDESCO, A., KRUEGER, C.P.; CENTENO, J.A.S. Extração de profundidade mediante redes neurais artificiais e modelo de regressão usando dados de levantamento GPS e de imagens ikonos II – estudo comparativo. **ENGEVISTA**, v.7. n.1. 73-82p. 2005.

ROCHA, M.T. **Aquecimento global e o mercado de carbono: uma aplicação do modelo CERT.** São Paulo: TESE (Doutorado na Escola Superior de Agricultura Luiz de Queiroz. 196p. 2003.

ROLIM, F. A. **Classificação orientada a objeto em imagens de alta resolução para auxílio ao monitoramento ambiental em uma microbacia hidrográfica.** Curitiba: Dissertação (Mestrado em Ciências Florestais-Manejo Florestal). Universidade Federal do Paraná. 120p. 2003

SHIMABUKURO, Y. E.; MIURA, T.; HUETE, A. R.; ARAI, E.; ESPIRITO-SANTO, F.; LATORRE, M. L. **Análise dos Dados Hyperspectrais do EO-1 Obtidos sobre a Floresta Nacional de Tapajós no Estado do Pará.** Belo Horizonte: XI Simpósio Brasileiro de Sensoriamento Remoto. 2003.

SEVEGNANI, L. **Dinâmica de população de *Virola bicuhyba* (Schott) Warb. (Myristicaceae) e estrutura fitossociológica de floresta pluvial atlântica, sob clima**

temperado úmido de verão quente, Blumenau, SC. São Paulo: 2003. 161 f. Tese (Doutorado em Ecologia), Universidade de São Paulo.

SHWARTZ, P.; RANDALL, D. **An abrupt climate change scenario and its implications for United States National Security.** Relatório para Agência de Segurança Nacional dos Estados Unidos. 2003. Disponível em <<http://www.gbn.org/ArticleDisplayServlet.srv?aid=26231>>; acesso em 3 de novembro de 2004.

SILVA, A.N.R. BOCANEGRA, C.W.R.; COSTA, G.C.F.; PEREIRA, M.A. **Uma introdução ao uso de redes neurais artificiais para planejamento urbano e de transportes.** São Paulo: NOTAS (Escola de engenharia de São Carlos). 2001.

SILVA, F. S. **Zoneamento geoambiental com auxílio de lógica Fuzzy e proposta de um geoindicador para caracterização do meio físico da bacia do rio do Peixe.** São Carlos: TESE (Doutorado em Geotecnia Escola de Engenharia de São Carlos - USP). 441p. 2005.

SMITH, M. **Neural networks for statistical modeling.** Londres: UK. International Thomson computer Press. 1996.

STURM, U.; ANTUNES, A.F.; LINGNAU, C.; BAHR, H.P.; Análise da ocupação em áreas de preservação permanente (APP) na área urbana do município de Matinhos utilizando a imagem IKONOS II. In: **Anais do II Colóquio Brasileiro de Ciências Geodésicas.** 2003, Curitiba: Anais do III colóquio Brasileiro de ciências geodésicas, v.1 1-15p. 2003.

SWAIN, P.H.; DAVIS, S.M. **Remote Sensing: The quantitative approach.** New York: McGraw-Hill, 396p. 1978.

TAIZ, L.; ZEIGER, E. **Fisiologia Vegetal.** Trad. SANTARÉM, E.R. et al. (3 ed.). Porto Alegre: Artmed. 184-188p. 2004.

TEDESCO, M.J. ; VOLKWEISS, S.J. ; BOHNEN, H. **Análise de solos, plantas e outros materiais.** Porto Alegre, 1975. 174 p.

TODT, V. **Avaliação do desempenho de classificadores Neurais para aplicações em sensoriamento Remoto.** Porto Alegre: TESE (Doutorado em Geodesia – UFRGS). 232p. 1998.

UNFCCC (United Nations Framework Convention on climate Change). **Kyoto Protocol.** COP 7. 1997.

ÚNICA – **União da agroindústria canavieira do estado de São Paulo.** 2006. http://www.unica.com.br/pages/agroindustria_alta.asp disponível em 20 de junho de 2006.

VALENTE, R.O.A. **Definição de áreas prioritária para conservação e preservação florestal por meio de abordagem multicriterial em ambiente SIG. Recursos Florestais.** Piracicaba: TESE (Escola Superior de Agricultura Luiz de Queiroz). 137p. 2005.

VELOSO, H.P. ; RANGEL FILHO, A.L.R. ; LIMA, J.C.A. **Classificação da vegetação brasileira, adaptada a um sistema universal.** Rio de Janeiro, 1990. 123p.

VIBRANS, A.C. **A Cobertura florestal da bacia do Rio Itajaí. Elementos para uma análise histórica.** Florianópolis: 2003. Tese (Doutorado), Universidade Federal de Santa Catarina.

XU, J.Z. **The Rational Model Function (RFM) in Photogrammetric Mapping: Method and Accuracy.** 2004. North York: disponível em: http://www.geoict.net/resources/publications/final_report_jeff.pdf. Acesso em 10/11/2006.

ZIMMER, A.H.; SILVA, M.P.; MAURO, R. **Sustentabilidade e impactos ambientais da produção animal em pastagens.** Piracicaba: Simposio sobre manejo da pastagem, Anais FEALQ, 2002, 31-58p. 2002.

WANDRESEN R. **Integração entre redes neurais e correlação para identificar pontos de apoio pré-sinalizados.** Curitiba: TESE (Universidade Federal do Paraná). 158p. 2004.

WARNER, A.S.; ASNER, G.P. Canopy shadow in IKONOS satellite observations of tropical forests and savannas. **Remote Sensing of Environmental.** v.87. 521-533p. 2003.

WATZLAWICK, L.F. **Análise e estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens do satélite Ikonos II.** Curitiba: TESE. (Doutorado em Ciências Florestais – Setor de Ciências Agrárias – UFPR). 2003.

WINKIPÉDIA – **Ciclo do Carbono.** A enciclopédia livre. Disponível em <http://pt.wikipedia.org/wiki/Ciclo_do_carbono> acesso em 10 de janeiro de 2006.

ANEXOS

ANEXO 01 - VETORES DE ENTRADA PARA BIOMASSA NO PROGRAMA MATLAB.

```

% "FID_segtot" "Meanblue_s" "Meangreen_" "Meannir_sa" "Meanred_sa" "AMOSTRA" "BIOMASSA"

18659 342.74 316.91 298.16 307.32 41.00 171275.07
5950 442.48 508.27 735.67 526.08 22.00 131416.01
% 5871 584.35 767.31 1190.96 779.92 21.00 93223.54
6619 522.12 645.39 942.46 659.62 20.00 149821.88
4182 473.74 572.76 811.54 592.58 15.00 203526.85
4106 571.58 724.56 1050.66 724.66 14.00 149431.88
4031 603.85 815.06 1351.07 806.31 13.00 28910.04
3931 647.88 843.72 1156.71 844.69 12.00 68691.46
2227 497.49 605.17 861.15 609.55 9.00 137807.17
% 2164 411.25 459.89 677.55 481.77 8.00 187175.91
2096 567.12 710.88 1013.35 720.49 7.00 134452.40
1967 587.39 726.26 919.95 757.72 6.00 197816.39
1883 468.98 553.20 758.21 536.08 5.00 178651.61
8524 542.35 684.94 1033.53 677.63 29.00 108181.52
7622 525.87 680.66 1040.85 695.47 28.00 131416.93
7501 576.04 755.18 1152.39 756.04 27.00 97101.63
10179 486.82 607.90 864.66 609.50 33.00 128993.08
12195 593.81 766.12 1253.90 757.46 35.00 104275.24
9805 595.49 770.79 1112.26 759.44 32.00 66662.13
13969 568.22 733.54 1145.02 730.19 38.00 105776.64
13869 588.06 784.28 1095.21 760.00 37.00 119021.63
%13769 525.26 668.84 1023.36 653.56 36.00 162205.67
15471 563.65 720.11 1099.94 682.61 39.00 102481.16
17539 635.24 800.59 1137.69 755.59 40.00 92395.12
18743 523.78 593.30 837.82 573.79 42.00 128925.69
19758 626.91 736.30 1119.19 681.21 45.00 111383.83
19668 569.05 716.94 986.94 652.10 44.00 104037.93
20655 533.95 628.21 830.22 571.94 47.00 185313.02
21027 299.57 230.38 188.31 215.24 46.00 102553.57
19596 529.56 654.58 856.95 625.28 43.00 159420.00
6296 566.67 787.12 1269.37 735.19 26.00 99678.11
6183 541.37 672.05 1077.63 625.93 25.00 182570.09
% 6093 537.08 675.47 1014.05 640.04 24.00 153075.24
6029 516.58 640.65 911.47 612.94 23.00 215661.84
4561 480.90 626.25 999.36 593.13 19.00 247284.05
4455 277.41 240.14 239.05 242.28 18.00 111516.64
4365 451.97 530.00 779.34 520.80 17.00 179939.28
4279 512.31 667.76 975.61 664.19 16.00 104992.99
2493 346.48 404.42 573.65 403.03 11.00 177368.46
2387 496.09 641.88 994.78 636.04 10.00 155418.01
7890 521.74 684.11 1034.60 657.54 31.00 149072.20
% 7805 466.97 574.94 875.64 583.87 30.00 181392.53
10260 436.87 540.48 866.47 531.38 34.00 227500.36
11947 965.22 1208.16 1024.90 1256.47 100.00 0.00
9746 877.77 1127.82 805.23 1175.09 110.00 0.00
4675 781.96 984.06 775.93 1077.61 120.00 0.00

```

ANEXO 02 - VETORES DE ENTRADA PARA CARBONO NO PROGRAMA MATLAB.

%FID_segtot Meanblue_s Meangreen_ Meannir_sa Meanred_sa AMOSTRA CARBONO

18659	342.74	316.91	298.16	307.32	41	71781.96844
5950	442.48	508.27	735.67	526.08	22	55627.36587
% 5871	584.35	767.31	1190.96	779.92	21	39206.33054
6619	522.12	645.39	942.46	659.62	20	63099.26393
4182	473.74	572.76	811.54	592.58	15	86424.77909
4106	571.58	724.56	1050.66	724.66	14	62799.51461
4031	603.85	815.06	1351.07	806.31	13	12283.84781
3931	647.88	843.72	1156.71	844.69	12	29041.42107
2227	497.49	605.17	861.15	609.55	9	57944.881
% 2164	411.25	459.89	677.55	481.77	8	78357.81803
2096	567.12	710.88	1013.35	720.49	7	55869.16066
1967	587.39	726.26	919.95	757.72	6	81778.60755
1883	468.98	553.20	758.21	536.08	5	75850.99964
8524	542.35	684.94	1033.53	677.63	29	46247.30966
7622	525.87	680.66	1040.85	695.47	28	55628.57353
7501	576.04	755.18	1152.39	756.04	27	40730.33825
10179	486.82	607.90	864.66	609.50	33	53954.67779
12195	593.81	766.12	1253.90	757.46	35	43756.12035
9805	595.49	770.79	1112.26	759.44	32	27771.35637
13969	568.22	733.54	1145.02	730.19	38	44090.73129
13869	588.06	784.28	1095.21	760.00	37	49649.02834
% 13769	525.26	668.84	1023.36	653.56	36	68179.05468
15471	563.65	720.11	1099.94	682.61	39	43333.85121
17539	635.24	800.59	1137.69	755.59	40	38610.24131
18743	523.78	593.30	837.82	573.79	42	53697.82233
19758	626.91	736.30	1119.19	681.21	45	46658.07416
19668	569.05	716.94	986.94	652.10	44	43654.21444
20655	533.95	628.21	830.22	571.94	47	77169.94015
21027	299.57	230.38	188.31	215.24	46	43197.77876
19596	529.56	654.58	856.95	625.28	43	66475.11209
6296	566.67	787.12	1269.37	735.19	26	41899.12273
6183	541.37	672.05	1077.63	625.93	25	76421.78973
% 6093	537.08	675.47	1014.05	640.04	24	64759.75021
6029	516.58	640.65	911.47	612.94	23	91496.63984
4561	480.90	626.25	999.36	593.13	19	104318.8047
4455	277.41	240.14	239.05	242.28	18	47149.06066
4365	451.97	530.00	779.34	520.80	17	73358.80489
4279	512.31	667.76	975.61	664.19	16	43874.99145
2493	346.48	404.42	573.65	403.03	11	74027.71807
2387	496.09	641.88	994.78	636.04	10	65471.52887
% 7890	521.74	684.11	1034.60	657.54	31	62706.85963
7805	466.97	574.94	875.64	583.87	30	77724.50138
10260	436.87	540.48	866.47	531.38	34	96406.17602
11947	965.22	1208.16	1024.90	1256.47	10	0.00000
9746	877.77	1127.82	805.23	1175.09	110	0.00000
4675	781.96	984.06	775.93	1077.61	120	0.00000
10886	1151.88	1376.59	1263.78	1403.34	130	0.00000
10918	1123.50	1338.36	1264.61	1364.90	140	0.00000

ANEXO 03 - LISTAGEM DA ROTINA USADA PARA TREINAMENTO DA ANN.

```

% PROGRAMA PARA TREINAR A REDE NEURAL

% OBJETIVO: SALVAR OS PESOS PARA SIMULACAO

clear all

% Chamar o arquivo com AMOSTRAS de ENTRADA

load 'D:\Meus documentos\vaio\TESE\RNA_Final\segamos.dat' % O, N, Z

DRT = segamos;

[~,c]=size(DRT);

% Calculo da Escala (E)

load 'D:\Meus documentos\vaio\TESE\RNA_Final\GerarEscala\Escalas.dat'

EMedR = Escalas(1,1);
EMedB = Escalas(2,1);
EMedG = Escalas(3,1);
EMedIV = Escalas(4,1);
EBi = Escalas(5,1);
MiMedR = Escalas(1,2);
MiMedB = Escalas(2,2);
MiMedG = Escalas(3,2);
MiMedIV = Escalas(4,2);
MiBi = Escalas(5,2);

% Compatibilizacao das amostras de TREINO

% OBJETIVO: os valores serao expressos entre (0 - 1) = Normalização

% Calculando a Normalização dos Dados de TREINAMENTO (TRN)

% E N Bio C R G B IV

for i=1:l
    for j=1:c
        if j==5 IMG_V_N(i,1) = (DRT(i,j) - MiMedR)*EMedR; end
        if j==2 IMG_V_N(i,2) = (DRT(i,j) - MiMedB)*EMedB; end
        if j==3 IMG_V_N(i,3) = (DRT(i,j) - MiMedG)*EMedG; end
        if j==4 IMG_V_N(i,4) = (DRT(i,j) - MiMedIV)*EMedIV; end
        if j==7 IMG_V_N(i,5) =(DRT(i,j) - MiBi)*EBi; end
    end
end

% Coletando os pontos de Saida da REDE (T)

% T = Z

for (i=1:l)
    T(i,1) = IMG_V_N(i,5); % Biomassa
end
T=T';

```

```

% Coletando os pontos de ENTRADA da REDE (P)

% P = O,N,B,P

for (i=1:l)
    for (j=1:c)
        P(i,1) = IMG_V_N(i,1); % R
        P(i,2) = IMG_V_N(i,2); % G
        P(i,3) = IMG_V_N(i,3); % B
        P(i,4) = IMG_V_N(i,4); % IV
    end
end

P=P';

% Criar Redes Neurais

net=newff([0 1;0 1;0 1;0 1],[60,20,1],{'logsig','logsig','logsig'},'trainrp');

% Variaveis de Treinamento

net.trainParam.goal=0.01;
net.trainParam.epochs=50000;
net.trainParam.show=50;
net.trainParam.lr=0.9;
net.trainParam.lm=0.01;
[net]=train(net,P,T);

% Salvando os PESOS da Rede

save PesoRede.mat net

% Arbir Arquivo de Verificacao

%load 'C:\Documents and Settings\Perfil\Meus
documentos\Dr\RNA_Final\gerarEscala\deztrezentos50TR.dat'

%VRN = deztrezentos50TR;

% (SIMULAÇÃO)&

load 'D:\Meus documentos\vaio\TESE\RNA_Final\segamosresul.dat';

VRN = segamosresul;

[l,c]=size(VRN);

for (i=1:l)
    for (j=1:c)
        if j==1 IMG_V(i,1) = (VRN(i,j) - MiMedR)*EMedR; end
        if j==2 IMG_V(i,2) = (VRN(i,j) - MiMedB)*EMedB; end
        if j==3 IMG_V(i,3) = (VRN(i,j) - MiMedG)*EMedG; end
        if j==4 IMG_V(i,4) = (VRN(i,j) - MiMedIV)*EMedIV; end
    end
end
end

```

```
IMG_V = IMG_V';  
  
% Generalizando Dados  
  
S = sim(net,IMG_V);  
  
S = S';  
  
[l,c]=size(S);  
  
for i=1:l  
    for j=1:c  
        DS(i,1)= (S(i,j)/EBi) + MiBi;  
        Resul(i,1) = DS(i,1);  
        Resul(i,2) = VRN(i,7);  
        Resul(i,3) = Resul(i,1)- Resul(i,2);  
    end  
end  
  
Resul  
  
save Resul.dat Resul -ascii
```

ANEXO 04 - LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO.

NOME COMUM	NOME CIENTÍFICO	FAMÍLIA	GRUPO ECOLÓGICO
Abacate	<i>Persea americana</i>	Lauraceae	Co-Dominante
Açoita-cavalo	<i>Luehea divaricata</i>	Tiliaceae	Dominante
Alecrim	<i>Senna multijuga</i>	Caesalpinaceae	Dominante
Alma-de-serra	<i>Sickingia</i> sp.	Rubiaceae	Co-Dominante
Almesca	<i>Protium kleinii</i>	Burseraceae	Dominante
Araçá-branco	<i>Marlieria parviflora</i>	Myrtaceae	Dominante/Co-Dominante
Araçá-cereja	<i>Eugenia involucrata</i>	Myrtaceae	Dominante/Co-Dominante
Araticum-cagão	<i>Annona cacans</i>	Annonaceae	Dominante
Bacupari	<i>Rheedia gardneriana</i>	Guttiferae	Co-Dominante
Baga-de-macaco	<i>Posoqueria latifolia</i>	Rubiaceae	Co-Dominante/Dominada
Baga-de-morcego	<i>Trichilia casaretti</i>	Meliaceae	Co-Dominante
Baguaçu	<i>Talauma ovata</i>	Magnoliaceae	Co-Dominante
Batinga	<i>Chrysophyllum inornatum</i>	Sapotaceae	Dominada
Bicuíba	<i>Virola oleifera</i>	Miristicaceae	Co-Dominante
Botuqueiro	<i>Erythrina falcata</i>	Fabaceae	Dominante
Botuqueiro-miúdo	<i>Machaerium</i> cf. <i>hirtum</i>	Fabaceae	Co-Dominante
Cafezeiro-do-mato	<i>Casearia silvestris</i>	Flacourtiaceae	Co-Dominante
Caixeta	<i>Chrysophyllum viride</i>	Sapotaceae	Co-Dominante
Camboatá-branco	<i>Matayba guianensis</i>	Sapindaceae	Dominante/Co-Dominante
Camboatá-vermelho	<i>Cupania vernalis</i>	Sapindaceae	Dominante/Co-Dominante
Canela-amarela	<i>Nectandra</i> spp.	Lauraceae	Dominante/Co-Dominante
Canela-amarela-folha-comprida	<i>Ocotea aciphylla</i>	Lauraceae	Dominante/Co-Dominante
Canela-babosa	<i>Aiouea saligna</i>	Lauraceae	Co-Dominante
Canela-bicho	<i>Ocotea</i> sp. 2	Lauraceae	Dominante
Canela-branca-da-lomba	<i>Cinnamomum</i> cf. <i>pseudoclaziovii</i>	Lauraceae	Dominante
Canela-broto	<i>Ocotea</i> sp. 3	Lauraceae	Dominante/Co-Dominante
Canela-burra	<i>Endicheria paniculata</i>	Lauraceae	Dominante
Canela-burra-da-lomba	<i>Ocotea</i> sp. 4	Lauraceae	Dominante
Canela-cedro-folha-miúda	<i>Persea alba</i>	Lauraceae	Dominante/Co-Dominante
Canela-fogo	<i>Ocotea odorifera</i>	Lauraceae	Dominante/Co-Dominante
Canela-garuva	<i>Ocotea</i> cf. <i>diospirifolia</i>	Lauraceae	Dominante
Canela-papagaio	<i>Ocotea</i> cf. <i>laxa</i>	Lauraceae	Dominante
Canela-pimenta	<i>Aniba firmula</i>	Lauraceae	Dominante/Co-Dominante
Canela-pinho	<i>Ocotea catharinensis</i>	Lauraceae	Dominante/Co-Dominante
Canela-sabão	<i>Persea venosa</i>	Lauraceae	Dominante
Canela-sebo	<i>Persea</i> sp.	Lauraceae	Dominante
Canela-taquara	<i>Piper cernuum</i>	Piperaceae	Dominante/Co-Dominante
Canemaçu	<i>Tetrorchidium rubrivenium</i>	Euphorbiaceae	Co-Dominante
Canjerana	<i>Cabralea canjerana</i>	Meliaceae	Co-Dominante
Capororoca	<i>Myrsine coriacea</i>	Myrsinaceae	Dominante/Co-Dominante
Capororocão	<i>Myrsine umbellata</i>	Myrsinaceae	Dominante/Co-Dominante
Carne-de-vaca	<i>Clethra scabra</i>	Cletraceae	Dominante
Caroba	<i>Jacaranda micrantha</i>	Bignoniaceae	Co-Dominante
Carvalho-vermelho	<i>Roupala brasiliensis</i>	Proteaceae	Co-Dominante
Carvoeiro-branco	<i>Amaioua guianensis</i>	Rubiaceae	Dominante/Co-Dominante

ANEXO 04 - LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO
(continuação)

NOME COMUM	NOME CIENTÍFICO	FAMÍLIA	GRUPO ECOLÓGICO
Carvoeiro-vermelho	<i>Hirtella hebeclada</i>	Chrysobalanaceae	Co-Dominante
Casco-de-tatu	<i>Heisteria silvianii</i>	Olacaceae	Dominante/Co-Dominante
Catiguá-morcego	<i>Guarea macrophylla</i>	Meliaceae	Dominada/Suprimida
Catingueiro	<i>Solanum</i> sp. 2	Solanaceae	Co-Dominante
Caúna	<i>Ilex theezans</i>	Aquifoliaceae	Dominante/Co-Dominante
Cauninha	<i>Ilex amara</i>	Aquifoliaceae	Co-Dominante
Cedro	<i>Cedrela fissilis</i>	Meliaceae	Dominante
Chal-chal	<i>Allophylus edulis</i>	Sapindaceae	Co-Dominante
Chorão-d'água	<i>Meliosma</i> cf. <i>sellowii</i>	Sabiaceae	Co-Dominante
Cincho	<i>Sorocea bonplandii</i>	Moraceae	Co-Dominante
Cinzeiro-branco	<i>Alibertia concolor</i>	Rubiaceae	Co-Dominante
Cocão	<i>Erythroxylum</i> sp.	Erythroxylaceae	Co-Dominante
Congonha-miúda	<i>Symplocos</i> sp. 2	Symplocaceae	Dominante
Congonha-verdadeira	<i>Citronella paniculata</i>	Icacinaceae	Co-Dominante
Copiúva	<i>Tapirira guianensis</i>	Anacardiaceae	Dominante
Coqueiro-jerivá	<i>Syagrus romanzoffianum</i>	Arecaceae	Dominante
Coração-de-bugre	<i>Eugenia</i> sp. 1	Myrtaceae	Dominante/Co-Dominante
Cortiça-crespa	<i>Rollinia</i> spp.	Annonaceae	Co-Dominante
Cortiça-lisa	<i>Annona</i> spp.	Annonaceae	Co-Dominante
Cortiça-preta	<i>Guatteria australis</i>	Annonaceae	Dominante/Co-Dominante
Cutia	<i>Esebeckia grandiflora</i>	Rutaceae	Co-Dominante/Dominada
Dedaleiro	<i>Lafoensia pacari</i>	Lythraceae	Dominante
Embaúba	<i>Cecropia glaziovii</i>	Cecropiaceae	Dominante/Co-Dominante
Embira-sapo	<i>Lonchocarpus</i> sp.	Fabaceae	Dominante/Co-Dominante
Embiruçu	<i>Pseudobombax grandiflorum</i>	Bombacaceae	Dominante/Co-Dominante
Erva-mate	<i>Ilex paraguariensis</i>	Aquifoliaceae	Co-Dominante
Esparela	<i>Casearia decandra</i>	Flacourtiaceae	Dominante/Co-Dominante
Espinheira-santa	<i>Maytenus ilicifolia</i>	Celastraceae	Co-Dominante
Farinha-seca	<i>Machaerium stipitatum</i>	Fabaceae	Dominante
Figueira-branca	<i>Ficus insipida</i>	Moraceae	Co-Dominante
Figueira-folha-miúda	<i>Ficus organensis</i>	Moraceae	Dominante
Figueira-roxa	<i>Ficus luschnathiana</i>	Moraceae	Co-Dominante/Dominada
Fumo-bravo	<i>Solanum granuloso-leprosum</i>	Solanaceae	Co-Dominante
Gaioleiro	<i>Aegiphila sellowiana</i>	Verbenaceae	Co-Dominante
Garajuva	<i>Buchenavia kleinii</i>	Combretaceae	Dominante
Garuvão	<i>Ocotea</i> sp. 1	Lauraceae	Dominante/Co-Dominante
Garuvinha	<i>Mollinedia schottiana</i>	Monimiaceae	Co-Dominante/Dominada
Garuvinha-amarela	<i>Mollinedia uleana</i>	Monimiaceae	Co-Dominante/Dominada
Garuvinha-folha-miúda	<i>Agarista niederleinii</i>	Erycaceae	Co-Dominante
Gramimunha	<i>Weinmania paulinifolia</i>	Cunoniaceae	Dominante
Gramimunha-miúda	<i>Weinmania</i> cf. <i>discolor</i>	Cunoniaceae	Co-Dominante
Grandiúva	<i>Trema micrantha</i>	Ulmaceae	Co-Dominante
Grandiúva-d'anta	<i>Psychotria</i> cf. <i>sessilis</i>	Rubiaceae	Co-Dominante
Guabiropa	<i>Campomanesia xanthocarpa</i>	Myrtaceae	Co-Dominante
Guamirim 1	<i>Myrceugenia miersiana</i>	Myrtaceae	Dominante/Co-Dominante

ANEXO 04 - LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO
(continuação)

NOME COMUM	NOME CIENTÍFICO	FAMÍLIA	GRUPO ECOLÓGICO
Guamirim 2	<i>Myrceugenia ovalifolia</i>	Myrtaceae	Co-Dominante
Guamirim 3	<i>Myrcia breviramis</i>	Myrtaceae	Dominante
Guamirim 4	<i>Myrcia</i> sp. 2	Myrtaceae	Co-Dominante
Guamirim 5	<i>Myrceugenia</i> cf. <i>venosa</i>	Myrtaceae	Co-Dominante
Guamirim 6	<i>Eugenia</i> cf. <i>florida</i>	Myrtaceae	Dominante
Guamirim 7	<i>Eugenia</i> sp. 5	Myrtaceae	Dominante/Co-Dominante
Guamirim-amarelo	<i>Eugenia</i> sp. 4	Myrtaceae	Dominante/Co-Dominante
Guamirim-branco	<i>Myrcia pubipetala</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-branco-folha-miúda	<i>Neomitranthes glomerata</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-chorão	<i>Marleria tomentosa</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-d'água 1	<i>Myrcia anacardiifolia</i>	Myrtaceae	Co-Dominante
Guamirim-d'água 2	<i>Marleria</i> sp.	Myrtaceae	Dominante/Co-Dominante
Guamirim-d'água-folha-miúda	<i>Calyptanthes</i> cf. <i>strigipes</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-ferro	<i>Gomidesia tijucensis</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-ferro-amarelo	<i>Eugenia</i> sp. 3	Myrtaceae	Co-Dominante/Dominada
Guamirim-ferro-vermelho	<i>Myrciaria</i> sp.	Myrtaceae	Dominante/Co-Dominante
Guamirim-folha-miúda	<i>Myrcia rostrata</i>	Myrtaceae	Co-Dominante
Guamirim-pimenta	<i>Eugenia</i> sp. 2	Myrtaceae	Dominante/Co-Dominante
Guamirim-pitanga	<i>Eugenia neoverrucosa</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-rola	<i>Myrcia</i> spp.	Myrtaceae	Dominante/Co-Dominante
Guamirim-rola-folha-larga	<i>Myrcia</i> sp. 1	Myrtaceae	Co-Dominante/Dominada
Guamirim-roxo	<i>Myrcia obtecta</i>	Myrtaceae	Dominante/Co-Dominante
Guamirim-vermelho	<i>Calyptanthes grandifolia</i>	Myrtaceae	Co-Dominante
Guamirim-xaxim	<i>Mouriri chamissoana</i>	Melastomataceae	Co-Dominante
Guaraparim	<i>Vantania compacta</i>	Humiriaceae	Dominante
Guaraparim-miúdo	<i>Ouratea vaccinioides</i>	Ochnaceae	Dominante/Co-Dominante
Guaraperê	<i>Lamanonia speciosa</i>	Cunoniaceae	Dominante/Co-Dominante
Guarapuvu	<i>Schizolobium parahyba</i>	Caesalpiniaceae	Co-Dominante
Imbuia	<i>Ocotea porosa</i>	Lauraceae	Dominante
Ingá-banana	<i>Inga edulis</i>	Mimosaceae	Co-Dominante
Ingá-feijão	<i>Inga marginata</i>	Mimosaceae	Co-Dominante
Ingá-ferro	<i>Inga lentiscifolia</i>	Mimosaceae	Dominante
Ingá-macaco	<i>Inga sessilis</i>	Mimosaceae	Dominante
Ipê-roxo	<i>Tabebuia</i> cf. <i>catharinensis</i>	Bignoniaceae	Co-Dominante
Jacatirão	<i>Miconia cinnamomifolia</i>	Melastomataceae	Co-Dominante
Jasmim-pipoca	<i>Tabernaemontana australis</i>	Apocynaceae	Co-Dominante
Laranja-do-mato	<i>Sloanea guianensis</i>	Elaeocarpaceae	Co-Dominante
Leiteiro	<i>Brosimum lactescens</i>	Moraceae	Dominante/Co-Dominante
Licurana	<i>Hieronyma alchorneoides</i>	Euphorbiaceae	Dominante/Co-Dominante
Limoeiro-do-mato	<i>SeQUIERIA langsdorfii</i>	Phytolaccaceae	Co-Dominante
Louro	<i>Cordia</i> sp.	Boraginaceae	Dominante
Louro-cravo	<i>Pimenta pseudocaryophyllus</i>	Myrtaceae	Co-Dominante
Macuqueiro	<i>Bathysa meridionalis</i>	Rubiaceae	Co-Dominante
Mamica-de-cadela	<i>Zanthoxylum kleinii</i>	Rutaceae	Dominada/Suprimida
Manacá-da-serra	<i>Tibouchina sellowiana</i>	Melastomataceae	Co-Dominante

ANEXO 04 - LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO
(continuação)

NOME COMUM	NOME CIENTÍFICO	FAMÍLIA	GRUPO ECOLÓGICO
Mandioqueiro	<i>Schefflera morototoni</i>	Araliaceae	Dominante/Co-Dominante
Maria-faceira	<i>Guapira opposita</i>	Nyctaginaceae	Co-Dominante
Maria-mole	<i>Phytolacca dioica</i>	Phytolaccaceae	Dominante/Co-Dominante
Marmeleiro	<i>Machaerium</i> sp.	Fabaceae	Dominante
Mata-olho	<i>Pachystroma longifolium</i>	Euphorbiaceae	Co-Dominante
Mata-pau	<i>Coussapoa microcarpa</i>	Moraceae	Dominante/Co-Dominante
Mata-pau-de-barreira	<i>Clusia criuva</i>	Clusiaceae	Dominante/Co-Dominante
Orelha-de-onça	<i>Symplocos</i> sp. 1	Symplocaceae	Co-Dominante
Palmito	<i>Euterpe edulis</i>	Arecaceae	Co-Dominante/Dominada
Pata-de-vaca	<i>Bauhinia</i> sp.	Caesalpinaceae	Co-Dominante
Pau-angelim	<i>Ormosia arborea</i>	Fabaceae	Dominante/Co-Dominante
Pau-canzil	<i>Actinostemon concolor</i>	Euphorbiaceae	Dominada
Pau-de-cangalha	<i>Symplocos tenuifolia</i>	Symplocaceae	Dominante/Co-Dominante
Pau-gafanhoto	<i>Cestrum</i> cf. <i>intermedium</i>	Solanaceae	Co-Dominante
Pau-gambá	<i>Pithecellobium langsdorffii</i>	Mimosaceae	Dominante/Co-Dominante
Pau-manteiga	<i>Byrsonima ligustrifolia</i>	Malpighiaceae	Dominante/Co-Dominante
Pau-oléo	<i>Copaifera trapezifolia</i>	Caesalpinaceae	Dominante
Pau-ripa	<i>Andira fraxinifolia</i>	Fabaceae	Dominante/Co-Dominante
Pau-rosa	<i>Maytenus robusta</i>	Celastraceae	Dominante/Co-Dominante
Pela-cavalo	<i>Sapium glandulatum</i>	Euphorbiaceae	Dominante/Co-Dominante
Peroba	<i>Aspidosperma</i> cf. <i>olivaceum</i>	Apocynaceae	Dominante
Pêssego-bravo	<i>Prunus brasiliensis</i>	Rosaceae	Dominante/Co-Dominante
Pimenteira	<i>Psychotria nuda</i>	Rubiaceae	Dominada
Pindabuna	<i>Duguetia lanceolata</i>	Annonaceae	Dominante
Pindaíba	<i>Xylopia brasiliensis</i>	Annonaceae	Dominante
Pinheiro-bravo	<i>Podocarpus sellowii</i>	Podocarpaceae	Co-Dominante
Pinho-do-campo	<i>Gordonia fruticosa</i>	Theaceae	Dominante/Co-Dominante
Piquiá	<i>Aspidosperma</i> cf. <i>camporum</i>	Apocynaceae	Dominante
Pixirica	<i>Miconia cinerascens</i>	Melastomataceae	Co-Dominante
Pixirica-folha-escura	<i>Miconia</i> cf. <i>pusilliflora</i>	Melastomataceae	Co-Dominante
Pixirica-roxa	<i>Miconia willdenowii</i>	Melastomataceae	Co-Dominante
Pixiricão	<i>Miconia cabussu</i>	Melastomataceae	Co-Dominante
Pixiriquinha	<i>Miconia cubatanensis</i>	Melastomataceae	Co-Dominante
Sacopema	<i>Sloanea</i> sp.	Elaeocarpaceae	Dominante
Sangueiro	<i>Pterocarpus violaceus</i>	Papilionaceae	Dominante/Co-Dominante
Sassafrás	<i>Ocotea pretiosa</i>	Lauraceae	Dominante/Co-Dominante
Seca-ligeiro	<i>Pera glabrata</i>	Euphorbiaceae	Dominante
Tanheiro	<i>Alchornea triplinervea</i>	Euphorbiaceae	Dominante/Co-Dominante
Tanheiro-folha-caída	<i>Alchornea glandulosa</i>	Euphorbiaceae	Dominante/Co-Dominante
Tarumã	<i>Vitex megapotamica</i>	Verbenaceae	Co-Dominante
Tucaneiro	<i>Cytharexylum myrianthum</i>	Verbenaceae	Dominante
Urtigão	<i>Boehmeria caudata</i>	Urticaceae	Dominada/Suprimida
Uva-do-mato	<i>Solanum</i> sp. 1	Solanaceae	Co-Dominante
Vassourão	<i>Piptocarpha sellowii</i>	Asteraceae	Co-Dominante
Vassourão-branco	<i>Piptocarpha angustifolia</i>	Asteraceae	Dominante

ANEXO 04 - LISTA DAS ESPÉCIES ENCONTRADAS NA ÁREA EM ESTUDO
(continuação)

NOME COMUM	NOME CIENTÍFICO	FAMÍLIA	GRUPO ECOLÓGICO
Vassourão-branco-folha-larga	Piptocarpha sp. 1	Asteraceae	Dominante
Vassourão-d'água	Vernonia sp. 2	Asteraceae	Dominante/Co-Dominante
Vassourão-ferro	Eupatorium cf. laevigatum	Asteraceae	Co-Dominante
Vassourão-folha-miúda	Piptocarpha regnelii	Asteraceae	Dominante
Vassourão-folha-vermelha	Vernonia petiolaris	Asteraceae	Dominante/Co-Dominante
Vassourão-orelha-de-mula	Vernonia discolor	Asteraceae	Dominante/Co-Dominante
Vassourão-preto	Vernonia sp. 1	Asteraceae	Dominante/Co-Dominante
Vassourão-preto-folha-miúda	Vernonia quinqueflora	Asteraceae	Co-Dominante
Xaxim	Cyathea spp.	Cyatheaceae	Dominada/Suprimida
Xaxim-bugio	Dicksonia sellowiana	Cyatheaceae	Suprimida
Xaxim-liso	Alsophila spp.	Cyatheaceae	Co-Dominante/Dominada

ANEXO 05 - ESTIMATIVAS POR AMOSTRAS.

AMOSTRA	Nº DE ÁRVORES ha	DAP MÉDIO cm	ÁREA BASAL m ² ha ⁻¹	VOLUME C/CASCA m ³ ha ⁻¹	VOLUME S/CASCA m ³ ha ⁻¹	BIOMASSA SECA kg ha ⁻¹	CARBONO Kg ha ⁻¹
1	1166,67	15,94	32,96	173,85	105,98	184085,18	76901,19
2	933,33	16,64	25,48	133,34	98,22	136148,10	56899,34
3	1325,92	15,56	33,33	151,64	76,22	140646,37	57596,62
4	1181,48	14,31	24,92	132,57	67,68	128975,07	53070,61
5	974,07	16,56	32,12	156,92	106,63	178651,61	75851,00
6	1581,48	14,89	37,19	202,07	103,69	197816,39	81778,61
7	870,37	16,32	24,50	129,56	88,61	134452,40	55869,16
8	1281,48	15,49	33,86	178,07	108,07	187175,91	78357,82
9	1033,33	15,44	25,51	136,95	88,20	137807,17	57944,88
10	959,26	16,79	28,27	148,41	100,09	155418,01	65471,53
11	1140,74	16,62	32,65	173,09	122,32	177368,46	74027,72
12	725,93	14,72	14,23	71,02	54,34	68691,46	29041,42
13	425,93	13,33	6,46	30,02	23,12	28910,04	12283,85
14	1129,63	15,89	28,05	147,41	105,30	149431,88	62799,51
15	1107,41	17,81	36,44	193,39	134,84	203526,85	86424,78
16	888,89	14,49	20,24	104,48	70,26	104992,99	43874,99
17	1151,85	15,87	32,80	172,21	119,10	179939,28	73358,80
18	770,37	15,08	20,91	109,02	73,91	111516,64	47149,06
19	1070,37	18,59	43,13	222,56	163,96	247284,05	104318,80
20	1185,18	15,41	28,41	155,97	93,39	149821,88	63099,26
21	851,85	14,57	17,78	100,42	53,35	93223,54	39206,33
22	870,37	15,99	24,45	130,81	84,58	131416,01	55627,37
23	818,52	19,02	36,56	180,84	134,32	215661,84	91496,64
24	1137,04	14,94	28,77	151,99	101,74	153075,24	64759,75
25	1170,37	16,13	33,04	173,95	119,25	182570,09	76421,79
26	851,85	15,82	19,62	101,29	75,66	99678,11	41899,12
27	877,78	14,71	18,96	99,27	67,64	97101,63	40730,34
28	837,04	16,67	24,87	130,31	87,77	131416,93	55628,57
29	688,89	16,64	19,80	100,53	74,27	108181,52	46247,31
30	877,78	18,51	32,97	171,25	117,16	181392,53	77724,50
31	844,44	17,05	27,82	143,67	108,25	149072,20	62706,86
32	600,00	14,37	12,85	68,73	39,85	66662,13	27771,36
33	911,11	15,29	23,90	124,56	79,53	128993,08	53954,68
34	940,74	19,03	38,83	198,63	145,11	227500,36	96406,18
35	929,63	15,37	21,09	107,40	82,32	104275,24	43756,12
36	944,44	16,89	29,59	153,75	110,74	162205,67	68179,05
37	740,74	16,64	22,21	114,97	87,36	119021,63	49649,03
38	822,22	16,10	20,56	107,64	77,18	105776,64	44090,73
39	618,52	16,87	19,07	99,88	75,05	102481,16	43333,85
40	744,44	14,99	17,20	92,22	53,41	92395,12	38610,24
41	1229,63	15,85	31,86	165,46	127,86	171275,07	71781,97
42	1044,44	14,96	24,07	123,47	89,47	128925,69	53697,82
43	1085,18	16,99	30,58	157,84	110,95	159420,00	66475,11
44	818,52	15,98	20,22	104,65	79,80	104037,93	43654,21

ANEXO 05 - ESTIMATIVAS POR AMOSTRAS (continuação).

AMOSTRA	Nº DE ÁRVORES ha	DAP MÉDIO cm	ÁREA BASAL m ² ha ⁻¹	VOLUME C/CASCA m ³ ha ⁻¹	VOLUME S/CASCA m ³ ha ⁻¹	BIOMASSA SECA kg ha ⁻¹	CARBONO Kg ha ⁻¹
45	788,89	15,43	20,52	106,92	80,40	111383,83	46658,07
46	559,26	18,64	18,58	99,23	77,13	102553,57	43197,78
47	1422,22	14,51	33,55	175,13	130,90	185313,02	77169,94
48	1177,78	15,16	31,15	161,35	95,85	169585,72	70531,76

ANEXO 06 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	95.495,18	-2.271,64	-2,38
8	187.175,91	142.307,24	44.868,67	31,53
36	162.205,67	139.926,69	22.278,98	15,92
24	153.075,24	193.246,98	-40.171,74	-20,79
30	181.392,53	109.256,32	72.136,21	66,03
Total	777.072,89	680.232,41	96.840,48	90,31
Media	155.414,58	136.046,48	19.368,10	18,06

ANEXO 07 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	70.135,28	23.088,26	32,92
8	187.175,91	99.334,14	87.841,78	88,43
36	162.205,67	125.036,16	37.169,51	29,73
24	153.075,24	207.916,16	- 54.840,92	- 26,38
30	181.392,53	101.118,12	80.274,41	79,39
Total	777.072,89	603.539,87	173.533,04	204,09
Media	155.414,58	120.707,97	34.706,61	40,82

ANEXO 08 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,0001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	90.187,26	3.036,28	3,37
8	187.175,91	102.701,13	84.474,78	82,25
36	162.205,67	109.336,00	52.869,67	48,36
24	153.075,24	125.378,16	27.697,08	22,09
30	181.392,53	105.983,75	75.408,78	71,15
Total	777.072,89	533.586,30	243.486,59	227,22
Media	155.414,58	106.717,26	48.697,32	45,44

ANEXO 09 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMÍAR 0,005.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	84.041,30	9.182,24	10,93
8	187.175,91	181.167,63	6.008,28	3,32
36	162.205,67	142.940,25	19.265,42	13,48
24	153.075,24	145.984,57	7.090,67	4,86
30	181.392,53	208.015,18	-26.622,65	-12,80
Total	777.072,89	762.148,93	14.923,96	19,78
Media	155.414,58	152.429,79	2.984,79	3,96

ANEXO 10 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMÍAR 0,005.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	82.484,36	10.739,18	13,02
8	187.175,91	125.448,86	61.727,05	49,21
36	162.205,67	140.343,18	21.862,49	15,58
24	153.075,24	141.344,31	11.730,93	8,30
30	181.392,53	173.420,98	7.971,55	4,60
Total	777.072,89	663.041,69	114.031,20	90,70
Media	155.414,58	132.608,34	22.806,24	18,14

ANEXO 11 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMÍAR 0,005.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	78.170,60	15.052,94	19,26
8	187.175,91	136.225,29	50.950,62	37,40
36	162.205,67	134.179,82	28.025,85	20,89
24	153.075,24	133.499,30	19.575,94	14,66
30	181.392,53	182.492,81	-11.00,28	-0,60
Total	777.072,89	664.567,82	112.505,07	91,61
Media	155.414,58	132.913,57	22.501,01	18,32

ANEXO 12 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	103.801,98	-10.578,44	-10,19
8	187.175,91	117.387,49	69.788,42	59,45
36	162.205,67	110.466,73	51.738,94	46,84
24	153.075,24	184.510,33	-31.435,09	-17,04
30	181.392,53	126.477,06	54.915,47	43,42
Total	777.072,89	642.643,59	134.429,30	122,48
Media	155.414,58	128.528,72	26.885,86	24,50

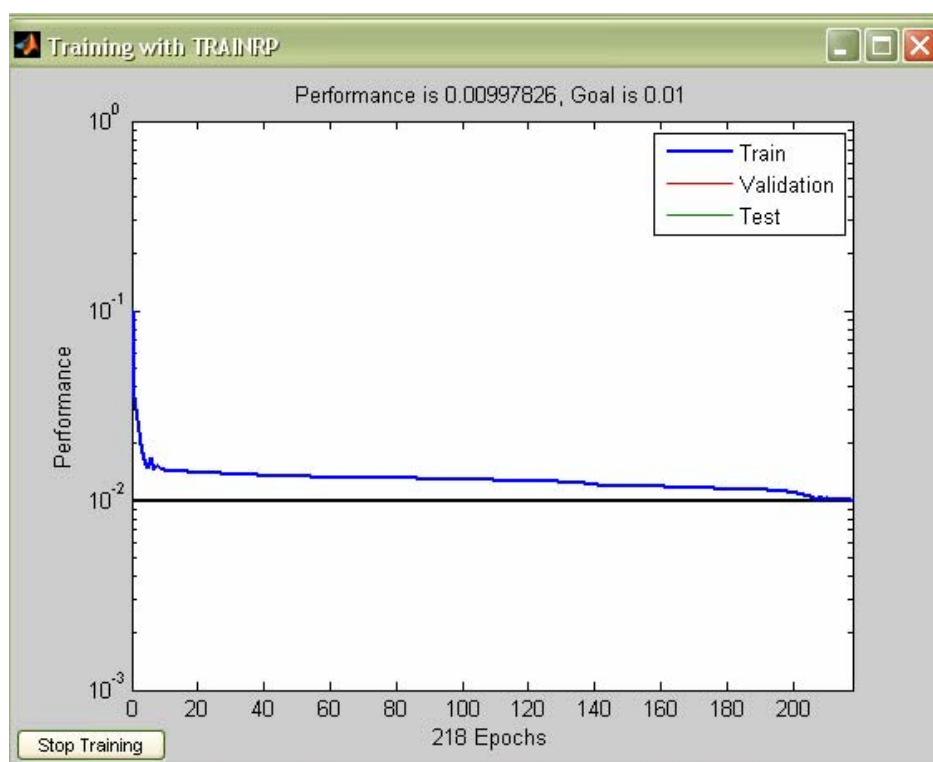
ANEXO 13 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	204.686,00	-111.462,46	-54,46
8	187.175,91	77.204,03	109.971,89	142,44
36	162.205,67	112.192,80	50.012,87	44,58
24	153.075,24	183.266,19	-30.190,95	-16,47
30	181.392,53	136.261,72	45.130,81	33,12
Total	777.072,89	713.610,74	63.462,16	149,21
Media	155.414,58	142.722,15	12.692,43	29,84

ANEXO 14 - COMPARAÇÃO DA BIOMASSA SECA REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMIAR 0,001.

PARCELA	BIOMASSA SECA (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADA		
21	93.223,54	86.081,47	7.142,07	8,30
8	187.175,91	116.701,84	70.474,07	60,39
36	162.205,67	146.240,72	15.964,95	10,92
24	153.075,24	159.119,91	-6.044,67	-3,80
30	181.392,53	133.720,64	47.671,89	35,65
Total	777.072,89	641.864,58	135.208,31	111,45
Media	155.414,58	128.372,92	27.041,66	22,29

ANEXO 15 - GRÁFICO DE CONVERGÊNCIA DA ANN, PARA BIOMASSA SECA.



ANEXO 16 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	38.788,63	417,71	1,08
8	78.357,82	47.974,41	30.383,41	63,33
36	68.179,06	44.509,07	23.669,98	53,18
24	64.759,75	57.059,02	7.700,73	13,50
30	62.706,86	46.861,71	15.845,15	33,81
Total	313.209,81	235.192,84	78.016,98	164,90
Media	62.641,96	47.038,57	15.603,40	32,98

ANEXO 17 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	45.216,11	-6.009,77	-13,29
8	78.357,82	66.096,13	12.261,69	18,55
36	68.179,06	40.245,46	27.933,59	69,41
24	64.759,75	50.098,64	14.661,11	29,26
30	62.706,86	31.486,54	31.220,32	99,15
Total	313.209,81	233.142,87	80.066,94	203,09
Media	62.641,96	46.628,57	16.013,39	40,62

ANEXO 18 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,0001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	35.626,46	3.579,87	10,05
8	78.357,82	42.021,09	36.336,73	86,47
36	68.179,06	49.496,82	18.682,25	37,74
24	64.759,75	50.802,56	13.957,19	27,47
30	62.706,86	52.202,78	10.504,08	20,12
Total	313.209,81	230.149,68	83.060,13	181,86
Media	62.641,96	46.029,94	16.612,03	36,37

ANEXO 19 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,005.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	41.504,19	-2.297,86	-5,54
8	78.357,82	76.190,28	2.167,54	2,85
36	68.179,06	60.697,65	7.481,41	12,33
24	64.759,75	60.513,94	4.245,82	7,02
30	62.706,86	61.415,70	1.291,16	2,10
Total	313.209,81	300.321,75	12.888,06	18,75
Media	62.641,96	60.064,35	2.577,61	3,75

ANEXO 20 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,005.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	35.443,60	3.762,76	10,62
8	78.357,82	60.600,73	17.757,09	29,30
36	68.179,06	59.538,24	8.640,81	14,51
24	64.759,75	61.055,33	3.704,42	6,07
30	62.706,86	56.355,76	6.351,10	11,27
Total	313.209,81	272.993,63	40.216,18	71,77
Media	62.641,96	54.598,73	8.043,24	14,35

ANEXO 21 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,005.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	31.074,15	8.132,18	26,17
8	78.357,82	64.980,25	13.377,56	20,59
36	68.179,06	56.268,05	11.911,00	21,17
24	64.759,75	57.866,32	6.893,43	11,91
30	62.706,86	54.195,26	8.511,60	15,71
Total	313.209,81	264.384,03	48.825,79	95,54
Media	62.641,96	52.876,81	9.765,16	19,11

ANEXO 22 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 12 NEURÔNIOS NA CAMADA DE ENTRADA E 4 NA CAMADA DE SAÍDA PARA O LIMAR 0,001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	38.140,08	1.066,25	2,80
8	78.357,82	48.372,39	29.985,43	61,99
36	68.179,06	50.384,01	17.795,04	35,32
24	64.759,75	57.857,17	6.902,59	11,93
30	62.706,86	50.704,70	12.002,16	23,67
Total	313.209,81	245.458,34	67.751,47	135,70
Media	62.641,96	49.091,67	13.550,29	27,14

ANEXO 23 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 24 NEURÔNIOS NA CAMADA DE ENTRADA E 8 NA CAMADA DE SAÍDA PARA O LIMAR 0,001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	41.849,26	-2.642,93	-6,32
8	78.357,82	44.025,64	34.332,18	77,98
36	68.179,06	46.133,90	22.045,16	47,79
24	64.759,75	52.236,81	12.522,94	23,97
30	62.706,86	43.533,99	19.172,87	44,04
Total	313.209,81	227.779,59	85.430,22	187,47
Media	62.641,96	45.555,92	17.086,04	37,49

ANEXO 24 - COMPARAÇÃO DA QUANTIDADE DE CARBONO REAL E ESTIMADA, PARA 48 NEURÔNIOS NA CAMADA DE ENTRADA E 16 NA CAMADA DE SAÍDA PARA O LIMAR 0,001.

PARCELA	CARBONO (kg)		RESÍDUO	ERRO %
	REAL	ESTIMADO		
21	39.206,33	48.896,25	-9.689,91	-19,82
8	78.357,82	59.599,49	18.758,33	31,47
36	68.179,06	49.645,66	18.533,40	37,33
24	64.759,75	49.502,67	15.257,08	30,82
30	62.706,86	50.949,73	11.757,14	23,08
Total	313.209,81	258.593,79	54.616,02	102,88
Media	62.641,96	51.718,76	10.923,24	20,58

ANEXO 25 - GRÁFICO DE CONVERGÊNCIA DA ANN, PARA QUANTIDADE DE CARBONO.

